Perspectivas da Inteligência Artificial na Educação

uma coletânea de
Revisões da Literatura

UNIVERSIDADE FEDERAL
DE SANTA CATARINA

Eliane Pozzebon
Tatiana Nilson dos Santos
Organizadoras

PPGTIC
Programa de Pós-Graduação em
Tecnologias da Informação e
Comunicação

UNIVERSIDADE FEDERAL
DE SANTA CATARINA

Eliane Pozzebon
Tatiana Nilson dos Santos
Organizadoras

PPGTIC
Programa de Pós-Graduação em
Tecnologias da Informação e
Comunicação

Perspectivas da Inteligência Artificial na Educação

Projeto Gráfico e Experiência Visual
Tatiana Nilson dos Santos

Apoio Técnico
Débora Maria Russiano Pereira

Perspectivas da inteligência artificial na educação: uma coletânea de Revisões de literatura / Eliane Pozzebon, Tatiana Nilson dos Santos (orgs.). – Araranguá : UFSC ; LABTEC, 2026.
410 p. : il.

ISBN: 978-65-02-40804-9

1. Inteligência artificial. 2. Educação. 3. Revisões de literatura. I. Pozzebon, Eliane, org. II. Santos, Tatiana Nilson dos, org. III. Título

CDU: 378.147:004.8

Catalogação na fonte elaborada por Débora Maria Russiano Pereira, CRB-14/1125

UNIVERSIDADE FEDERAL DE SANTA CATARINA

PPGTIC
Programa de Pós-Graduação em Tecnologias da Informação e Comunicação

Apresentação

A Inteligência Artificial (IA) vem ganhando espaço na educação, trazendo novas possibilidades para o ensino, a aprendizagem e a gestão educacional. Suas aplicações abrangem áreas como personalização da aprendizagem, produção de conteúdos, avaliação, análise de dados e apoio à prática docente.

Este e-book reúne uma coletânea de revisões da literatura que exploram diferentes aplicações e perspectivas sobre o uso da IA na educação. Os capítulos apresentam resultados de pesquisas e discussões que contribuem para compreender os avanços, as possibilidades e os desafios relacionados à adoção dessas tecnologias no contexto educacional.

A obra busca oferecer ao leitor uma visão ampla e fundamentada sobre o tema, incentivando a reflexão e novas pesquisas sobre o papel da Inteligência Artificial na construção de uma educação mais inovadora, inclusiva e consciente.

Boa leitura!

As organizadoras

Sumário

- **PARTE I - DADOS APRENDIZAGEM E PERSONALIZAÇÃO**

Big data e inteligência artificial na educação: contribuições e desafios para a personalização da aprendizagem 9
Mirtes Balbinot

Segurança e integridade de dados no uso de inteligência artificial em universidade federais 31
José Eduardo Moreira Colombo

Identificação de padrões de aprendizagem com inteligência artificial 46
Dionatan Carlos de Souza

***Learning Analytics* e inteligência artificial na gestão da aprendizagem:** uma revisão sistemática da literatura 64
Jardel Batista Gonçalves

Análise preditiva educacional: modelos preditivos para identificação de risco de evasão 87
Gislaine Pereira Candido

- **PARTE II - IA COMO SUPORTE E PERSONALIZAÇÃO DO ENSINO**

Plataformas adaptativas e personalização da educação 102
Carla Cristiane Boita

Sistemas de recomendação de conteúdo: uma revisão sistemática da literatura 115
Cleber Luiz Damin Ferro

Assistentes virtuais educacionais: tecnologias de inteligênia artificial no apoio ao ensino 132
Maeve Espindola Pereira

Sumário

Inteligência artificial generativa como apoio à prática docente: uma revisão sistemática 160
Thaise Cechinel Bozzelo Vassoler

- **PARTE III - IA APLICADA ÀS EXPERIÊNCIAS DE APRENDIZAGEM**

Jogos educacionais baseados em inteligência artificial para o ensino de matemática: uma revisão sistemática da literatura 190
Lucimara Muzykant da Silva

Avaliação da aprendizagem automatizada por inteligência artificial na educação básica: uma revisão sistemática de literatura 210
Juliana Pires da Silva

Da predição à intervenção: aplicações de inteligência artificial na evasão no ensino superior 231
Luã Alfredo Gonçalves

- **PARTE IV - IA, INCLUSÃO E DIMENSÕES HUMANAS DA APRENDIZAGEM**

Aplicações de inteligência artificial no apoio à aprendizagem inclusiva 248
Ludmila Oliveira Daufenbach

Tecnologias assistivas baseadas em inteligência artificial: uma revisão sistemática 263
Willians Rodrigo Rossa

Estados afetivos e aprendizado: uma revisão sistemática sobre detecção automática de emoções 290
Maria Eduarda Mariano

Sumário

Inteligência artificial e detecção de emoções na voz em contextos educacionais: uma revisão sistemática 306
Lucas Moraes Amancio

- **PARTE V - IA NA FORMAÇÃO E NA PRODUÇÃO DO CONHECIMENTO**

A importância da inteligência artificial na formação dos educadores 343
Soraia dos Santos Mangili Vidal

Inteligência artificial na produção de recursos educacionais: uma revisão sistemática da literatura 364
Júlia Hahn Gonçalves

A inserção da inteligência artificial generativa na pós-graduação e seus reflexos na produção acadêmica 387
Natália de Freitas Silveira

Sobre as organizadoras 409
Eliane Pozzebon
Tatiana Nilson dos Santos

PARTE I

DADOS, APRENDIZAGEM E PERSONALIZAÇÃO

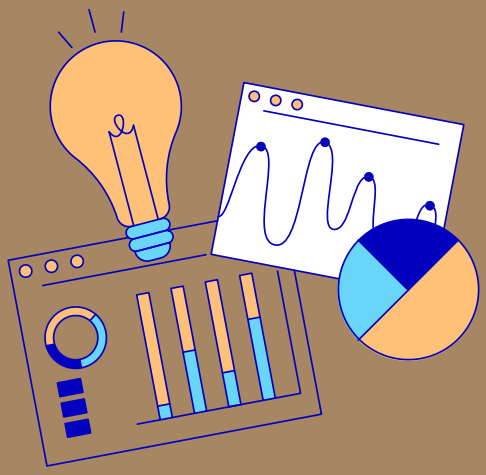

CAPÍTULO 1

Big Data e IA na Educação: contribuições e desafios para a personalização da aprendizagem

Mirtes Balbinot

1. Introdução

A sociedade tem se transformado profundamente com os avanços tecnológicos. Em todos os setores da sociedade percebe-se um crescente ingresso e a necessidade das tecnologias tanto para uso pessoal quanto no exercício das profissões, estimulando mudanças significativas na forma de comunicar-se, produzir, tomar decisões e organizar se socialmente.

A educação também não está alheia a essa situação. O acesso e a popularização das Tecnologias Digitais de Informação e Comunicação (TDICs), como *smartphones*, *notebooks* e *tablets* cresce no ritmo da globalização e possibilita o surgimento de novas metodologias e oportunidades no âmbito escolar, desde do processo ensino-aprendizagem à gestão dos recursos escolares.

A educação contemporânea enfrenta grandes desafios, que vão desde a necessidade de personalização do ensino aprendizagem até a gestão eficiente dos recursos no processo escolar. Neste contexto de inserção crescente das TIDCs na sociedade atual e na educação, destaca-se neste artigo, o uso do *Big Data* e Inteligência Artificial (IA). Pensando no processo ensino - aprendizagem, essas tecnologias têm o potencial de transformar a administração, melhorando a tomada de decisões, otimizando recursos e, sobretudo, personalizando as experiências na sala de aula para alunos e professores.

O uso do *Big Data* e da IA na gestão escolar representa um marco, fornecendo ferramentas que permitem uma administração mais estratégica, informada e orientada por dados (Barbosa, 2023). O conceito de *Big Data* refere-se ao amplo volume de dados gerados continuamente na sociedade contemporânea, envolvendo não apenas a quantidade, mas também a diversidade, a velocidade e a complexidade dessas informações.

Esse processo está relacionado à capacidade de coletar, organizar e analisar dados provenientes de diferentes fontes, considerando aspectos como volume, variedade, variabilidade e velocidade. No contexto educacional, o uso do *Big Data* possibilita

compreender melhor os processos de ensino e aprendizagem, contribuindo para a tomada de decisões pedagógicas mais assertivas, o acompanhamento do desempenho dos estudantes e a personalização das práticas educativas.

2. Referencial Teórico

Este artigo baseia-se em três conceitos: *Big Data*, IA na Educação e Personalização do Ensino. Primeiramente, estes serão elucidados, para no decorrer da pesquisa serem empregados para responder os temas alçados.

2.1 *Big Data*

O conceito de *Big Data* diz respeito ao amplo volume de dados gerados continuamente na sociedade contemporânea, envolvendo não apenas a quantidade, mas também a diversidade, a velocidade e a complexidade dessas informações. Esse processo está relacionado à capacidade de coletar, organizar e analisar dados provenientes de diferentes fontes, considerando aspectos como volume, veracidade, variedade, variabilidade e velocidade.

Essa análise de dados é conhecida como *Big Data*, que serve para definir um grande volume de dados que fazem uso de ferramentas especiais para encontrar e analisar, em tempo hábil, o que de fato é útil em tudo que foi coletado e armazenado (Esposito *et al*., 2023). Neste sentido, não há como não implementar nos processos educativos, pois faz parte do cotidiano da sociedade contemporânea.

2.2 Inteligência Artificial na Educação

A Inteligência Artificial na educação compreende as tecnologias computacionais com capacidade de imitar operações mentais de processamento de informações como aprendizagem, raciocínio e tomada de decisão, com intuito de aprimorar o processo de ensino e aprendizagem, dar apoio e personalizá-lo. A Inteligência artificial pode ser entendida como uma ferramenta complementar no processo ensino-aprendizagem, colaborando para qualificar o ensino, mas que não substitui o professor como o mediador desse processo.

Utilizando algoritmos inteligentes e processando dados, a IA é capaz de ajustar conteúdos, exercícios e métodos pedagógicos às exigências e ao compasso de cada aluno. A Inteligência Artificial também contribui fortemente para o trabalho do professor, como em tarefas mecanizadas de cunho administrativo, para verificar o aproveitamento dos estudantes e preparar ações pedagógicas mais exitosas (Ferreira, 2025).

2.3 Personalização do Ensino

A personalização do ensino pode ofertar uma aprendizagem distinta, possibilitando a cada estudante aprimorar suas habilidades de maneira relevante. A personalização permite maior aproximação do que é fundamental para o educando, pois, através dos dados gerados pelo Big Data e que alimentam e treinam a Inteligência Artificial é possível identificar as necessidades, habilidades, ritmo, interesse e as características de cada aluno. Por ser centrada no aluno, promove maior envolvimento, independência e efetividade. Como expõe Felippe *et al.* (2024), *"essa personalização permite um avanço mais alinhado com o ritmo e estilo de aprendizado de cada aluno, promovendo uma educação mais inclusiva e eficiente."*

3. Metodologia

Este estudo caracteriza-se como uma pesquisa de abordagem qualitativa, de natureza bibliográfica, conforme Prodanov e Freitas (2013), sendo fundamentado na análise de produções científicas nacionais e internacionais relacionadas ao uso do *Big Data* e da Inteligência Artificial na educação. Segundo os autores, a pesquisa bibliográfica é elaborada a partir de material já publicado, constituído principalmente por revistas, artigos científicos e documentos disponíveis em bases de dados acadêmicas, permitindo ao pesquisador aprofundar o conhecimento sobre o tema investigado.

A análise dos dados ocorreu de forma interpretativa, buscando identificar conceitos, aplicações, potencialidades e desafios associados à integração dessas tecnologias no contexto educacional, conforme a abordagem qualitativa, que, segundo Prodanov e Freitas (2013), prioriza a compreensão dos fenômenos em seus contextos e significados. Para a execução do projeto, utilizou-se a metodologia *Systematic SearchFlow* (SSF), a qual foi desenvolvida por Ferenhof e Fernandes (2016) com o intuito de pesquisar em bases de dados a fim de permitir a replicação das pesquisas com mais facilidade, evitando possíveis replicações e vieses do pesquisador no momento de escolha dos artigos.

Esse método baseia-se em método não aleatório e segue um procedimento metodológico rigoroso o qual minimiza tendências de pesquisadores que podem ocorrer no momento de escolha de documentos (Ferenhof; Fernandes, 2016). A metodologia SSF ocorre em 4 fases:

- Na **Fase 1** é elaborado o protocolo de pesquisa, a qual engloba 5 atividades:
    a. definição da estratégia de busca;
    b. pesquisa nas bases de dados;

c. organização do portfólio;
d. definição dos critérios de seleção dos documentos;
e. composição do portfólio bibliográfico.

- Na **Fase 2**, procura-se consolidar os dados apurados na primeira fase, detalhando os resultados, analisando as publicações bibliométricamente.
- A **Fase 3** destina-se para a sintetização e organização dos dados e conhecimentos na análise dos dados.
- Finaliza se todo o processo, na **Fase 4**, com a construção do trabalho (Ferenhof; Fernandes, 2016).

A análise dos dados aconteceu nos meses de março a julho de 2026 utilizando *Google Acadêmico*, *sciELO* e *Scopus*. A estratégia de busca compreendeu os seguintes termos, acompanhada dos operadores *booleanos AND* e *OR:*

("*big data*") AND ("*inteligência artificial*" OR "*intelligence artificial*") AND ("*education*" OR "*educação*") AND ("personalização do ensino")

Como critérios de inclusão (CI) e exclusão (CE) adotou-se:

- CI: textos publicados a partir de 2021;
- CI: acesso aberto;
- CI: texto completo dispoível;
- CI: nos idiomas português, inglês e espanhol;
- CE: textos não aplicados ao contexto educacional;
- CE: publicados em outros idiomas;
- CE: textos que abordassem outros tipos de personalização do ensino.

Quadro 1 - Quantitativo das buscas nas bases de dados

Atividades	***Google* Acadêmico**	***SciELO***	***Scopus***
Busca inicial	741	1	0
Primeiro filtro (critérios de inclusão)	47	1	0
Segundo filtro (critérios de exclusão)	36	1	0
Seleção final	30	1	0

Fonte: elaborado pelo autor (2026)

O portfólio final contendo todos os artigos selecionados pode ser visualizado no Quadro 2, a seguir:

Quadro 2 - Portfólio final

Autores	Ano	Título	Local da publicação
Aguiar, J. J. B.	2023	Inteligência artificial e tecnologias digitais na educação: oportunidades e desafios	*Open Minds International Journal*
Albuquerque, J. G. M.; Abreu, M. T. C. de & Lima, I. N.	2024	O impacto da Inteligência Artificial na personalização do ensino	Revista Brasileira de Ensino e Aprendizagem
Alves, E. & Grohs, A. C. da C. P.	2024	Inteligência Artificial e Big Data: por uma educação midiática crítica e ativa das relações públicas	*Organicom*
Araujo, P. B. L. P. Freires, Kevin Cristian Paulino e outros	2024	O impacto do uso da Inteligência Artificial nos processos de ensino e aprendizagem	Revista Tópicos
Barboza, H. L.; Ferneda, A. S. da S. & Cristóvam, J. S.	2023	A Estratégia brasileira de Inteligência artificial no paradigma do governo digital	Revista do Direito
Breviário, A. G. do G. do; Rosa, D. O. da; Ventura, L. C. L; Tannous, F. W.; Rebello, F. A. S. & Levy, A. P. L. F.	2024	Competências digitais e análise avançada de dados: explorando o papel de TDICs, IA e Big Data na educação profissional e tecnológica	Revista Acadêmica de Tecnologias em Educação
da Silva, A.	2024	Educação 4.0 Como a Inteligência Artificial está redefinindo o ensino.	EaD e Tecnologias Digitais na Educação
Breviário, A. G. do; De Souza, J. M.; Lucena, J. B.; Rago, L. F.; Gomes, M. D. T. & Fróes, D. S. da S.	2025 a	*Artificial Intelligence and Big Data in science education: computational modeling and data analysis to promote scientific thinking in students*	*Current Scientific Journal*

continua

continuação

Breviário, Á. G. do; Souza, J. M. de; Lucena, J. B.; Rago, L. F.; D'Ávila, M.; Gomes, T.; Sousa, D. & Fróes, S.	2025b	*Distance learning in the 21st century: application of artificial intelligence and big data analytics for the development of BNCC skills in interactive virtual environments.*	*Current Scientific Journal*
Breviário, Á. G. do; Souza, J. M. de; Lucena, J. B.; Rago, L. F.; D'Ávila, M.; Gomes, T.; Sousa, D. & Fróes, S.	2025c	*Educational transformation with advanced TDICs integration of Artificial Intelligence and big data for the development of bncc skills in the initial and final years of elementary education.*	*Current Scientific Journal*
Cabral, D.; Davel, M.; Pereira, M. dos S.; Campanharo, P. S. Q.; Angelo, R. N. F. da S.; Marinho, S. M. de O. & Dalvi, Z. M. de V.	2024	Inteligência Artificial no Desenvolvimento Curricular: Impactos e Desafios para a Educação do Futuro.	*Revista Ibero-Americana De Humanidades, Ciências e Educação*
Costa, L. C.; Rodrigues, S. F. N.; Paixão, J. L. da; Batista, R. V.; Morais, E. C. & Silva, E. N.	2026	*Learning analytics* na educação contemporânea: fundamentos, aplicações e desafios epidemiológicos e éticos.	Revista Ibero-Americana De Humanidades, Ciências e Educação
Cruz, K. R. da; Toledo, R. da S.; Oliveira, A. S. de.; Almeida, J. K. da S.; Moreira, A. M. & Gandin, L. R. A.	2023	IA na sala de aula: como a Inteligência Artificial está redefinindo os métodos de ensino	Revista Brasileira de Ensino e Aprendizagem
Da Costa, J. P. M. & Paz, A. P. da	2025	Aplicações da Inteligência Artificial na educação: análise adaptativa e desempenho estudantil.	TC Sistemas de Informação
Nunes, M. do A. da S. & Mercado, L. P. L.	2025	Impacto da Inteligência Artificial na educação básica: equidade e desafios	Revista Docência e Cibercultura

continua

continuação

Gomes, J. de S.; Penha, M. C. S. de M. Ribeiro, L. B.; Almeida, A. B. B.; Gondim, F. J. & Damião, J. D. dos S.	2024	Educação 4.0: inovações tecnológicas e suas contribuições para a transformação do processo de ensino-aprendizagem.	ARACÊ
Narciso, R.; Silva, J. G.; Rodrigues, O. R.; Souza, A. M. O.; Cruz, L. A. X. & Morais, R. N. G. L.	2024	Transformação e desafios: a integração da Inteligência Artificial no ensino superior.	Revista Ibero-Americana de Humanidades, Ciências e Educação – REASE.
Oliveira, C. G. B. de	2022	Desafios da regulação do digital e da inteligência artificial no Brasil	Revista USP
Oliveira, M., D. de; Costa, F. S. da; Lima, D. N. D.; Oliveira, A. P. P. L. & Vieira, V. G. dos S.	2025	Gamificação, inteligência artificial e realidade virtual: o futuro da sala de aula já chegou!	Revista Aracê
Paixão, J. L. da	2025	Inteligência Artificial e personalização do ensino: revisão sistemática da literatura.	Revista Tópicos
Guimaraes Junior, J. C.	2023	análise de dados educacionais: como a tecnologias pode ser usada para obter insights sobre o desempenhos dos alunos	CEP
Godinho Junior, J. F. C.; dos Santos, C. E. R.; Freire, M. C. F.; Santos, A. C. O.; Souza Junior, M. M.; Arcanjo, A. C.; Machado, C. F. A.; Ruas, L. M. M.; Nascimento, G. C. R. & Silva, C. O.	2025	Educação na era da Inteligência Artificial: entre a inovação e a dessumanização do ensino	Aracê

continua

continuação

Ridolfi, L. F.; Ramos, A. A.; Rapôso, C. F. L.; Macedo, de M.; Leal, D. A.; Santos, M., da C.; Borin, E.; Diniz, G. F. da S.; Silva, M. P. da; Alvez, Andreza de F. S. & Silva, R. R. da.	2026	A Inteligência Artificial generativa na educação 5.0: limites éticos-jurídicos, governança algorítmica e a reconfiguração da personalização da aprendizagem.	Revista Veredas do Direito
Rocha, L. A.	2025	*An evaluation of machine learning approaches in educational environments: a systematic literature review.*	Revista acadêmica Texto Livre
Santos, M. A. V. S.; Lima, B. G. de; Andrade, A. S. de; Carvalho, J. dos S. de; Francio, M. E. de S. M. & Viana, S. C.	2025	Big Data na educação: analisando o futuro da aprendizagem por meio da coleta e análise de dados.	Revista Ibero-Americana de Humanidades, Ciências e Educação
Souza, A. P. de S.; Conceição, C. de J.; Pancoto, M. A.; Cecote, N. Q. B.; Pedra, R. R.; Oliveira, R. M. da S.; Pinão, V. R. Z.; Gomes, W. T.	2024	Personalização da aprendizagem com Inteligência Artificial: Como a IA está transformando o ensino e o currículo.	Revista Aracê
Veríssimo, A. C. de A.; Silva, A. L. G. da; Bacelar, K. F.; Detoni, V. S. S.; Barboza, A. P. L. L.; Carvalho, V. T. de; Oliveira, D. A. de & Sá, G. B. de	2024	Plataformas educacionais e personalização do ensino: uma revolução no aprendizado	*Lumen et Virtus*
Esteves, P. C. L.; Goulart, J. & Venos, M. C.	2023	Políticas públicas para o desenvolvimento de inteligência artificial no Brasil	

continua

continuação

Xu, Z.; Cheng, S.	2024	*Transformation of educational philosophy: an evaluation of higher education management innovation against the background of Big Data*	Trans/Form/Açã:Revisa de Filosofia da Unesp
Gonsales, P. & Kaufman, D.	2023	*Ia na educação: do programa alfabetização em dados*	ETD educação tematica digital
Sacramento, J. da. S. & Coutinho, D. J. G.	2025	Inteligência Artificial e educação: da identificação de padrões à transformação das práticas pedagógicas	Revista Ibero-Americana de Humanidades, Ciências e Educação

Fonte: elaborado pelo autor (2026)

4. Resultados e Discussões

No contexto da crescente digitalização da sociedade, torna-se fundamental compreender o papel dos dados na transformação dos diferentes setores, incluindo a educação. Nesse sentido, o conceito de *Big Data* ganha destaque ao se referir a grandes volumes de dados armazenados e gerados continuamente a partir de múltiplas fontes.

Esses dados podem ser provenientes da internet e de diversos dispositivos tecnológicos, como *smartphones*, *notebooks*, *tablets* e computadores pessoais, além de tecnologias associadas à Internet das Coisas, que engloba objetos do cotidiano conectados à rede, como televisores, eletrodomésticos, veículos e dispositivos vestíveis (Santos et al, 2025). Além disso, o Big Data é comumente caracterizado pelos chamados "5 Vs": volume, variedade, velocidade, veracidade e valor, que evidenciam a complexidade, a dinamicidade e o potencial analítico dos dados em larga escala. Esse cenário reforça o potencial do *Big Data* para subsidiar análises e tomadas de decisão mais assertivas no âmbito educacional (Souza et al, 2024).

No campo educacional, destaca-se o conceito de Learning Analytics, entendido como um conjunto de práticas voltadas à coleta, análise e interpretação de dados educacionais, com a finalidade de compreender e otimizar os processos de ensino e aprendizagem. Segundo Cabral et al (2024), "A IA oferece a possibilidade de criar um currículo mais dinâmico, personalizado e adaptável, potencialmente atendendo às necessidades individuais dos alunos de maneira mais eficaz". N contexto, tais análises permitem identificar padrões de comportamento, monitorar o desempenho dos estudantes e subsidiar intervenções pedagógicas mais eficazes e personalizadas. Sob essa perspectiva, a efetivação de propostas de ensino adaptativo está diretamente relacionada à capacidade de compreender as particularidades de cada estudante, especialmente no que se refere à

individualização das estratégias de ensino conforme suas necessidades específicas.

Para isso, torna-se fundamental o uso de dados educacionais que permitam inferir o nível de aprendizagem dos alunos, a partir da análise de informações acumuladas sobre seu desempenho. Adicionalmente, a possibilidade de classificar e agrupar estudantes com perfis, habilidades ou dificuldades semelhantes configura-se como uma estratégia relevante para o planejamento de intervenções pedagógicas mais direcionadas, contribuindo para a organização de práticas educativas mais eficientes e personalizadas como expôs Junior et al, (2023).

Diante disso, o Big Data, embora ainda em consolidação no campo educacional, apresenta-se como um elemento fundamental para o desenvolvimento de abordagens pedagógicas mais orientadas por dados. Sua utilização possibilita não apenas a compreensão mais aprofundada dos processos de ensino e aprendizagem, mas também a criação de soluções educacionais mais eficientes e personalizadas. Nesse contexto, destaca-se sua estreita relação com a Inteligência Artificial, uma vez que o desenvolvimento de sistemas inteligentes depende diretamente da disponibilidade e da análise de grandes volumes de dados.

4.1 Inteligência Artificial na Educação

Como articula Barbosa; Portes (2023),a Inteligência Artificial (IA) pode ser compreendida como um campo da computação voltado ao desenvolvimento de sistemas capazes de simular capacidades cognitivas humanas, como percepção, aprendizagem, tomada de decisão e resolução de problemas. Dessa forma, tais sistemas são projetados para interpretar dados, aprender a partir dessas informações e utilizar esse conhecimento na execução de tarefas específicas e no alcance de objetivos determinados.

No âmbito docente, a Inteligência Artificial (IA) demonstra-se como uma ferramenta de apoio que atua juntamente com os professores, otimizando a rotina pedagógica de modo a resgatar o foco na interação humana e no desenvolvimento dos estudantes. Longe de suprimir o papel do professor, a Inteligência Artificial (IA) atua na informatização de processos burocráticos e no enriquecimento das metodologias de ensino. É possível observar o impacto e a relevância da IA nas atividades cotidianas do professor, tanto na preparação quanto na execução das aulas, em diferentes áreas do conhecimento.

Destacam-se, entre suas aplicações, a otimização do tempo e assim, a redução da carga de trabalho, personalização do ensino por meio da adaptação de conteúdos conforme o desempenho e as dificuldades e necessidades, na gestão pedagógica e decisões baseadas em dados, dessa forma, a Inteligência Artificial (IA) pode auxiliar os professores em uma visão diagnóstica detalhada da turma. Portanto, observa-se a transformação do papel docente, transformando os estudantes que antes seriam apenas receptores, em sujeitos críticos e agentes de transformação social.

Ainda pensando nas diversas contribuições da Inteligência Artificial (IA) na Educação e mais especificamente no campo docente, pode-se ampliar essa dimensão para nível global, como afirma, Machado (2021), se com os sistemas simples usados na educação é possível oferecer um ensino

mais adaptado às necessidades do aluno imagine o que poderia ser ofertado aos alunos se houvesse a comparação de dados de uma rede de ensino, num estado ou país. Dialogando com Aguiar (2023), reforça-se a gama de contribuições da Inteligência Artificial (IA) na sala de aula e no processo ensino-aprendizagem em relação a identificação de padrões e tendências dos estudantes:

> Outra oportunidade da IA é a análise de grandes quantidades de dados educacionais. É possível identificar padrões e tendências que ajudam a compreender o desempenho dos estudantes e o impacto das estratégias de ensino-aprendizagem. Essas informações podem ser usadas pelos professores para ajustar o conteúdo e as atividades do curso para atender às necessidades discentes melhorando a aprendizagem (Aguiar, 2023).

O mesmo autor, também destaca a contribuição e integração da Inteligência Artificial (IA) nas metodologias, principalmente, com o desenvolvimento de jogos educacionais: com a análise de grandes quantidades de dados da área da educação fica exequível verificar padrões, assim colaborar com trabalho dos professores de ajustar os roteiros pedagógicos e exercícios para os alunos de forma que o ensino seja mais efetivo.

Nessa gama de possibilidades e ferramentas baseadas na Inteligência Artificial(IA), e a crescente utilização no ambiente escolar traz também para a sala de aula, plataformas como o Duolingo utilizam algoritmos adaptativos para ajustar o nível de dificuldade das atividades conforme o desempenho do usuário, promovendo um percurso formativo individualizado. De forma semelhante, a *Khan Academy* emprega sistemas de recomendação que auxiliam na identificação de lacunas de aprendizagem e na proposição de conteúdos específicos para cada estudante. Complementarmente, ferramentas como o ChatGPT têm sido utilizadas como apoio ao processo de ensino, permitindo a resolução de dúvidas, a explicação de conceitos e o fornecimento de feedback imediato. Para Rocha (2025), o ensino personalizado utilizando dispositivos computacionais contribui para engajar os educandos na autoaprendizagem, pois respeita seu ritmo, exigências e interesses.

No contexto brasileiro, a Inteligência Artificial tem sido reconhecida como uma prioridade estratégica, conforme estabelecido no Plano Nacional de Educação 2024-2034, que prevê ações voltadas à formação, capacitação e aplicação dessa tecnologia em diferentes níveis educacionais. O plano destaca a importância da qualificação de profissionais, desde a educação básica até a pós-graduação, bem como o uso da IA para aprimorar a gestão educacional, incluindo o monitoramento do desempenho e o enfrentamento da evasão escolar por meio da análise de dados.

Além disso, enfatiza a necessidade de uma abordagem ética, segura e inclusiva, que promova a equidade e o uso responsável das tecnologias (Lazarotto et al, 2025). Picão et al (2023), apresenta em seu estudo, um exemplo bem-sucedido da aplicação da Inteligência Artificial no contexto educacional, ao analisarem o caso da Georgia State University, nos Estados Unidos. A instituição

implementou a plataforma preditiva Pounce, que utiliza algoritmos de aprendizado de máquina para analisar dados dos estudantes, como desempenho acadêmico, frequência e participação. Com base nessas análises, o sistema gera alertas que auxiliam professores na identificação de alunos em risco de dificuldades acadêmicas, possibilitando intervenções mais rápidas e eficazes.

Estudos de revisão bibliográfica, como o de Gomes et al. (2024) indicam que a Inteligência Artificial apresenta um elevado potencial de transformação da educação, especialmente no que se refere à personalização da aprendizagem, ao uso de sistemas de tutoria inteligente e à análise de dados educacionais. No entanto, a literatura também evidencia desafios significativos, como a necessidade de formação adequada de professores, questões éticas relacionadas ao uso de dados e a desigualdade no acesso às tecnologias, fatores que podem comprometer a efetividade e a equidade de sua implementação no contexto educacional.

Desde as primeiras discussões sobre tecnologias educacionais, já se vislumbrava a possibilidade de sistemas capazes de ensinar e avaliar com mínima intervenção humana, perspectiva que se intensifica com o avanço da Inteligência Artificial. Dessa forma, a IA tende a desempenhar um papel cada vez mais relevante na educação, exigindo uma integração crítica, ética e pedagogicamente orientada, de modo a potencializar seus benefícios sem desconsiderar seus limites e desafios. Nesse contexto, sua articulação com outras tecnologias emergentes, como o Big Data, amplia ainda mais suas possibilidades de aplicação no campo educacional, aspecto que será aprofundado na seção seguinte.

4.2 Ética

O Big Data, Inteligência Artificial e ética compõem um triângulo de parceria para o aperfeiçoamento da educação. Mesmo que essas tecnologias tenham alta capacidade para impulsionar a personalização da aprendizagem, auxiliar o gerenciamento escolar e favorecer o processo ensino- aprendizagem, sua execução deve estar legitimada em fundamentos éticos que garantam proteger os dados, a transparência, a equidade, o respeito e a responsabilidade para com os direitos humanos. Junior et al. (2025b) elucida que vazamentos massivos de dados não são incomuns, dados como nomes, e-mails, registros de desempenho dos alunos, que são dados frágeis podem cair na dark web. A coleta indiscriminada e excessiva de dados, por empresas com sistema de segurança fracos e mais preocupadas com a escalabilidade, com o pretexto de personalizar o ensino, pode expor a privacidade da comunidade escolar.

A personalização do ensino aparece como uma esperança, ao viabilizar adequação de conteúdos, práticas, trajeto formativo às carências individuais dos alunos. Mas a utilização acelerada de sistemas algorítmicos no âmbito escolar, precisa examinar à transparência, à proteção de dados, à discriminação algorítmica, à independência dos professores e à concretização dos direitos fundamentais.

A revisão de Ridolfi et al (2023) sustenta que Inteligência Artificial tem enorme capacidade para reorganizar o processo ensino-aprendizagem, no entanto, é de suma importância preparar estruturas regulatórias para proteção de dados pessoais a responsabilização ética-jurídica sobre direitos fundamentais, preservação de discriminações algorítmicas e a preservação da dignidade humana. Portanto, é de suma importância a efetivação de políticas públicas, para regulamentar o uso responsável e seguro desses meios tecnológicos. A formação dos docentes e gestores é fatal para diminuir esses riscos e maximizar os benefícios oferecidos com o uso das tecnologias.

4.3 Equidade

O fomento da equidade através da Inteligência Artificial e do Big Data está continuamente vinculado ao uso ético, a transparência e o compromisso dessas inovações. Apesar de apresentar excelente capacidade para personalizar o ensino e maximizar as possibilidades de aprendizagem, sua aplicação também pode intensificar discrepâncias se os algoritmos forem elaborados a contar de bases de dados fragmentados, ultrapassados ou com inclinações.

Nesse cenário, deliberações automáticas são capazes de gerar discriminações históricas e sociais, facilitar para grupos específicos e comprometer a promoção de chances educacionais equitativas. Pereira et al. (2026), descreve que na educação, isso manifesta uma ameaça para os estudantes que podem acabar sendo rotulados, limitar suas chances de aprendizagem e a desigualdade ser naturalizada. Então, para promover a equidade, faz se imprescindível a elaboração de sistemas translúcidos, inspecionados e suscetíveis à multiplicidade sociocultural.

Além das ameaças referentes às tendências dos algorítmicos, a infoexclusão representa um relevante entrave à implementação da equidade na educação. A dificuldade de ingresso à internet de qualidade, de instrumentos tecnológicos compatíveis e de suporte nas escolas restringe o envolvimento de muitos estudantes nas atividades educacionais permeadas por inovações digitais. Para Nunes (2025), as inovações tecnológicas apenas corroboram para o aperfeiçoamento do aprendizado se assistidas de aporte em estrutura, preparo docente e políticas públicas dirigidas à inclusão digital. Do contrário, as discrepâncias socioeconômicas podem ser alargadas, limitando as vantagens do Big Data e da Inteligência Artificial aos alunos que já dispõem de condições superiores de alcance.

Outro item importante diz respeito aos dados pessoais dos estudantes quanto à proteção e a privacidade. O colher dados, o guardar e o processamento dessas informações precisam respeitar aos preceitos da segurança, de transparência, propósito e responsabilidade, segundo determina a Lei Geral de Proteção de Dados Pessoais (LGPD – Lei no 13.709/2018). De acordo com Cristóvam, Bergamini e Hahn (2021), a LGPD procura mitigar prejuízos e estragos ligados à coleta, armazenamento, distribuição e tratamento dos dados pessoais.

A proteção na utilização da Inteligência Artificial no âmbito escolar necessita da existência de dispositivos do governo que garantam a proteção dos dados, a aplicabilidade dos algoritmos e a responsabilidade dos órgãos que operam essas tecnologias. Dessa forma, certifica-se que os dados

utilizados são somente para o aperfeiçoar o processo de ensino e aprendizagem, garantindo os direitos fundamentais dos estudantes. No Brasil, pesquisas também evidenciam que a integração da Inteligência Artificial e do Big Data à educação precisa estar aliada a valores como inclusão, equidade e justiça social. Albuquerque, Abreu e Lima (2024), destacam que, apesar da vantagens oferecidas pela IA para a personalização da aprendizagem e a monitoração do desempenho dos alunos, sua execução requer planejamento, formação docente e zelo de caráter ético ligado a tendências algorítmicas, à privacidade e à desigualdade de acesso às tecnologias.

A capacidade revolucionária da IA equivale a implementação de políticas educacionais que assegurem o acesso de todos às tecnologias digitais e estimulem o uso cuidadoso desses instrumentos. Assim, as potencialidades tecnológicas do Big Data e da Inteligência Artificial para estimular uma educação mais equitativa está sujeita a admissão de práticas éticas, inclusivas e socialmente responsáveis. As inovações educacionais carecem ser elaboradas e executadas com cerne na inclusão, na diversidade e na mitigação das discrepâncias.

Portanto, para Junior et al. (2025a) é necessário investir em construção de suporte tecnológico, aperfeiçoamento continuado dos docentes, na gestão de dados e políticas públicas que fortaleçam o ingresso democrático às tecnologias digitais, possibilitando que as vantagens do Big Data e da Inteligência Artificial chegue para todos os estudantes, de forma imparcial de sua situação socioeconômica.

4.4 Formação Docente

O preparo dos professores consiste em um dos fatores primordiais para a implementação da Inteligência Artificial (IA) e do Big Data no sistema educacional. As inovaçõestecnológicas propiciam uma gama de possibilidades para personalizar o ensino, melhorar métodos pedagógicos e dar suporte e deliberar de decisões educacionais, suas vantagens apenas podem ser usufruídas no momento que os docentes tiverem entendimento técnico, pedagógico e ético para empregar de forma crítica e responsável.

A automatização de tarefas administrativas, distinguir problemas de aprendizagem, sugerir meios didáticos personalizados e proporcionar feedback sobre o desempenho em tempo real aos educandos são vantagens possibilitadas pela Inteligência Artificial.

O Big Data, coleta, estrutura e averigua quantidades massivas de dados educacionais, proporcionando esclarecimentos importantes sobre a atuação, a frequência, e exigências individuais dos educandos. Porém, a existência e acesso desses recursos não asseguram avanços na qualidade da educação. Faze se mister que os docentes entendam como operar esses instrumentos, decodificar esses dados e se apropriar deles para apoiar suas deliberações pedagógicas.

Nesse cenário, o preparo inicial e contínuo dos docentes necessita considerar habilidades referentes ao letramento digital, exame de dados educacionais e ao uso pedagógico da Inteligência Artificial. Segundo Xu; Cheng (2024), o aprimoramento dos docentes carece de organizar os

professores para agregar a Inteligência Artificial aos métodos de ensino e aprendizagem de maneira ética, inclusiva e com foco no ser humano.

Da mesma forma, destaca-se que a conversão digital da educação está condicionada a aptidão dos docentes de perceber, aferir e empregar tecnologias digitais para alavancar aprendizagens expressivas. Porém, além das habilidades técnicas, a formação dos professores precisa salientar aspectos éticos associados ao uso da Inteligência Artificial e do Big Data. Os docentes precisam ter conhecimento dos preceitos sobre a proteção de dados pessoais, privacidade, transparência e segurança, garantindo que as escolhas embasadas por sistemas de automação inteligentes não perpetuam preconceitos ou expandam desigualdades educacionais.

No Brasil, esse zelo é corroborado pela Lei Geral de Proteção de Dados Pessoais (LGPD), que determina diretrizes para o trato confiável dos dados dos estudantes (Brasil, 2018). A mediação humana permanece essencial para gerenciar resultados gerados pelas tecnologias digitais. A formação constante também exerce papel fundamental perante o acelerado progresso tecnológico. Portanto, também configura o ponto central para que a Inteligência Artificial e o Big Data colaborem realmente para aprimorar a educação.

Docentes preparados sentem-se encorajados a usar inovações tecnológicas que personalizam o ensino, identificar precocemente dificuldades de aprendizagem, apoiar decisões pedagógicas baseadas em evidências e promover práticas educacionais mais inclusivas, eficientes e éticas (Breviário et al., 2025c). Dito isso, a qualificação dos professores é imprescindível para que as TDICs sejam agentes transformadoras e ocorra avanços na qualidade do ensino e na aprendizagem, resguardando o educador como mediador da compreensão e principal representante do processo educativo.

4.5 Desafios éticos, estruturais e pedagógicos na integração do Big Data e Inteligência Artificial na Educação

Debatendo com Narcizo et al. (2024)1: a integração entre Big Data e Inteligência Artificial na educação, embora marcada por avanços significativos, evidencia desafios que impactam diretamente sua implementação e efetividade no contexto educacional. Observa-se que as desigualdades no acesso a recursos tecnológicos e à internet tendem a intensificar disparidades educacionais, ao mesmo tempo em que emergem preocupações relacionadas à privacidade, à segurança e ao uso ético dos dados dos estudantes.

Nesse contexto, evidencia-se que a desigualdade digital não se limita apenas ao acesso a dispositivos e à internet, mas também envolve diferenças na qualidade da conexão, no letramento digital e nas condições de uso das tecnologias. Esse cenário reforça a exclusão de determinados grupos sociais e compromete a efetividade das propostas de personalização da aprendizagem.

Dialogando com Grohs; Alves (2024), identifica-se um dos grandes desafios da efetiva implementação da Inteligência Artificial (IA) e da Big Data na educação, que está na questão estrutural e econômica, pois:

> Plataformas de geração de conteúdo por IA utilizam big data aparentando oferecer serviços gratuitos, mas, na prática, capitalizam com os dados dos usuários. Esses sistemas coletam informações pessoais para criar conteúdo personalizado e explorar comercialmente esses dados, destacando a necessidade de ética e transparência. (Alves, p.163, 2024).

Nos aspectos estruturais, técnicos e econômicos, identifica-se ainda a necessidade de padronização das informações, e os elevados custos de desenvolvimento e implementação dessas tecnologias, configuram-se como entraves relevantes à sua ampla adoção. Conforme Silva (2024), essas questões são acompanhadas pela carência de profissionais qualificados para atuar em um campo interdisciplinar, o que reforça a complexidade de sua integração ao ambiente escolar. Além dos aspectos técnicos, torna-se evidente a necessidade de formação docente para o uso crítico e pedagógico dessas tecnologias.

Observa-se, no contexto educacional, que muitos professores ainda não se sentem preparados para interpretar dados educacionais ou utilizar sistemas baseados em Inteligência Artificial em suas práticas, o que pode limitar o potencial dessas ferramentas no contexto escolar. No âmbito pedagógico, verifica-se que a inserção da Inteligência Artificial tem gerado debates e controvérsias, especialmente no que se refere à possível substituição de atividades tradicionalmente desempenhadas por professores. Nesse sentido, é possível inferir que interpretações simplificadas do uso dessas tecnologias podem levar à concepção equivocada de que sistemas automatizados seriam capazes de substituir o papel docente, desconsiderando a dimensão humana e relacional do processo educativo.

De modo complementar, é possível problematizar a crescente dependência de sistemas automatizados no contexto educacional, o que pode levar à redução da autonomia docente e à centralização das decisões pedagógicas em plataformas digitais. Esse aspecto levanta questionamentos sobre o papel das tecnologias como suporte ou como elemento dominante no processo de ensino. Ademais, apenas coletar dados educacionais não é mais suficiente, sendo necessário desenvolver métodos capazes de compreender o que está ocorrendo no presente e prever cenários futuros, de modo a subsidiar intervenções pedagógicas mais eficazes. Nesse contexto, destaca-se que tais análises são realizadas por sistemas baseados em algoritmos, cujos critérios de funcionamento nem sempre são explicitados de forma clara.

Outro ponto relevante refere-se à dificuldade de compreensão dos processos utilizados na análise e recomendação de conteúdos, o que pode comprometer a transparência e favorecer a ocorrência de decisões enviesadas no contexto educacional. Diante desse cenário, salienta-se que os desafios associados à integração entre Big Data e Inteligência Artificial na educação extrapolam questões técnicas, envolvendo dimensões éticas, pedagógicas e sociais. Assim, torna-se fundamental que sua implementação ocorra de forma crítica e responsável, garantindo não apenas a eficiência dos processos educacionais, mas também a equidade, a transparência e a valorização

do papel humano no ensino.

5 Considerações Finais

O Big Data e Inteligência Artificial no campo educacional evidencia-se como um processo marcado por significativas potencialidades, especialmente no que se refere à personalização da aprendizagem e à otimização dos processos de ensino. Ao longo desta pesquisa, foi possível compreender que o uso dessas tecnologias permite a análise de grandes volumes de dados educacionais, contribuindo para a adaptação de conteúdos, metodologias e ritmos de aprendizagem às necessidades individuais dos estudantes. Entretanto, também se constatou que o Big Data e a Inteligência Artificial envolvem desafios complexos que ultrapassam aspectos técnicos, abrangendo dimensões éticas, pedagógicas e estruturais.

Questões relacionadas à desigualdade digital, à formação docente, à transparência dos sistemas e aos possíveis vieses algorítmicos evidenciam a necessidade de uma abordagem crítica e responsável na implementação dessas tecnologias no contexto educacional. Nesse sentido, destaca-se que a efetividade do uso do Big Data e da Inteligência Artificial na educação não depende exclusivamente do avanço tecnológico, mas, sobretudo, da forma como essas ferramentas são incorporadas às práticas pedagógicas.

O papel do professor permanece central nesse processo, sendo fundamental para mediar, interpretar e contextualizar o uso dessas tecnologias, garantindo que seu uso esteja alinhado aos objetivos educacionais e às necessidades dos estudantes. Por fim, conclui-se que o Big Data e Inteligência Artificial apresentam potencial para contribuir significativamente com a transformação da educação, desde que sua aplicação esteja pautada em princípios éticos, na equidade de acesso e na valorização da dimensão humana do ensino. Sugere-se, ainda, como contribuição para estudos futuros que aprofundem a análise empírica dessas tecnologias no contexto escolar, bem como investigações que explorem estratégias de formação docente voltadas ao uso crítico e pedagógico dessas ferramentas.

Referências

Aguiar, J. J. B. Inteligência artificial e tecnologias digitais na educação: oportunidades e desafios. **Open Minds International Journal**, v. 4, n. 2, p. 183-188, 2023.

Albuquerque, J. G. M.; Abreu, M. T. C. de & Lima, I. N. de. O impacto da Inteligência Artificial na personalização do ensino. **Revista Brasileira de Ensino e Aprendizagem** (REBENA), v. 9, p. 182–192, 2024.

Alves, E. & Grohs, A. C. da C. P. Inteligência artificial e big data: por uma educação midiática crítica e ativa das Relações Públicas. **Organicom**, São Paulo, v. 21, n. 44, p. 159–170, 2024.

Araujo, P. B. L. P. O impacto do uso da inteligência artificial no contexto educacional, seus benefícios e desafios. **Revista Tópicos**, Rio de Janeiro, v. 2, n. 8, p. 1-10, 2024.

Barbosa, C. R. de A. C. Transformações no ensino-aprendizagem com o uso da inteligência artificial: revisão sistemática da literatura. RECIMA21 – **Revista Científica Multidisciplinar**, [S. l.], v. 4, n. 5, p. e453103, 2023.

Barbosa, L. M. & Portes, L. A. F. A inteligência artificial. **Revista Tecnologia Educacional**, Rio de Janeiro, v. 236, p. 16-27, 2023.

Barboza, H. L.; Ferneda, A. S. & Cristóvam, J. S. da S. A estratégia brasileira de inteligência artificial no paradigma do governo digital. **Revista do Direito**, Santa Cruz do Sul, n. 67, p. 1–18, 2023.

BRASIL. Lei no 13.709, de 14 de agosto de 2018. **Lei Geral de Proteção de Dados Pessoais** (LGPD). Brasília, DF: Presidência da República, 2018.

Breviário, Á. G. do; Souza, J. M. de; Lucena, J. B.; Rago, L. F.; Gomes, M. D. T. & Fróes, D. S. da S. Artificial intelligence and Big Data in science education: computational modeling and data analysis to promote scientific thinking in students. **Current Scientific Journal**, v. 5, n. 6, p. 97–117, 2025a.

Breviário, Á. G. do; Souza, J. M. de; Rago L. F. Gomes, M. D. T. & Fróes, D. S. da S. Artificial intelligence and Big Data in science education: computational modeling and data analysis to promote scientific thinking in students. **Current Scientific Journal**, v. 5, n. 6, p. 182–201, 2025b.

Breviário, Á. G. do; Souza, J. M.; Lucena, J. B. & Rago, L. F. Educational transformation with advanced TDICs: integration of artificial intelligence and Big Data for the development of BNCC skills in the initial and final years of elementary education. **Current Scientific Journal**, v. 5, n. 4, abr. 2025c.

Breviário, Á. G. do; Rosa, D. O. da; Ventura, L. C. L.; Tannous, F. W.; Rebello, F. A. S. & Levy, A. P. L. F. Competências digitais e análise avançada de dados: explorando o papel de TDICs, IA e Big Data na educação profissional e tecnológica. **Revista Acadêmica de Tecnologias em Educação**, Santos, v. 4, n. 4, 2024.

Cabral, D. Davel, M.; Pereira, M. dos S.; Campanharo, P. S. Q.; Angelo, R. N. F. da S.; Marinho, S. M. de O. & Dalvi, Z. M. de V. Inteligência artificial no desenvolvimento curricular: impactos e desafios para a educação do futuro. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, São Paulo, v. 10, n. 10, p. 4063–4081, out. 2024.

Costa Junior, J. F.; Godinho, C. E. R.; Santos, M. C. F. dos ; Freire, A. C.; Santos, M. M. de O.; Souza Junior, A. C. de.; Arcanjo, C. F.; Machado, L. M. M. de A.; Ruas, G. C. R.; Nascimento, C. O. S. do; Soares, G. de A.; Rodrigues, M. B.; Santos, I. B. dos & Amorim, L. M. Educação na era da inteligência artificial: entre a inovação e a desumanização do ensino. **Revista ARACÊ**, [S. l.], v. 7, n. 7, p. 35409–35427, 2025.

Costa Júnior, J. F.; Souza, C. L. C. N. de; Melo, C. R. G. de; Reinoso, L. F.; Nascimento, A. L.; Lima, S. do S. A.; Almeida, J. do S. R. de; Souza, M. A. de M. A.; Duarte, E. M. da S.; Castro, D. dos S. C. de; D'Oliveira, K. S. & Lacerda, J. L. Educação 4.0: o papel da Inteligência Artificial no desenvolvimento de novas competências. **Conhecimento em rede:** explorando a multidisciplinaridade. Editora Impacto Científico, 1161-1177, 2025a.

Costa, L. C.; Rodrigues, S. F. N.; Paixão, J. L. da; Batista, R. V.; Morais, E. C. & Silva, E. N. Learning Analytics na educação contemporânea: fundamentos, aplicações e desafios epistemológicos e éticos. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, São Paulo, v. 12, n. 3, 2026.

Cristóvam, J. S. da S.; Bergamini, J. C. L. & Hahn, T. M.. Governança de dados no setor público brasileiro: uma análise a partir da Lei Geral de Proteção de Dados (LGPD). **Interesse Público** – IP, Belo Horizonte, n. 129, p. 75-101, 2021.

Cruz, K. R. da; Toledo, R. da S.; Oliveira, A. S. de; Almeida, J. K. da S. T. de; Moreira, A. M. & Gandin, L. R. A. IA na sala de aula: como a Inteligência Artificial está redefinindo os métodos de ensino. Rebena - **Revista Brasileira de Ensino e Aprendizagem**, [S. l.], v. 7, p. 19–25, 2023.

Espósito, G. E.; Neves, A. R.; Cruz, A. J. da S. & Arseno, E. F. O conceito de Big Data na educação. **Revista Amor Mundi**, Santo Ângelo, v. 4, n. 10, p. 3–12, 2023.

Felippe, K. R.. C.; Souza, D. C. de; Melo Júnior, H. G.; Carmo, J. P. G. do; Andrade Filho, M. A. S. de; Santos, R. F. dos; Pedra, R. R. & Demuner, J. A. O uso de IA em ambientes de aprendizagem personalizados. **Caderno Pedagógico**, [S. l.], v. 21, n. 5, p. e4149, 2024.

Ferenhof, H. A. & Fernandes, R. F. Desmistificando a revisão de literature como base para redação científica: método SSF. **Revista ACB**: Biblioteconomia em Santa Catarina, Florianópolis, 2016, v.21, n.3.

Ferreira, R. P. A Inteligência Artificial na Educação: Entre os Benefícios e os Riscos. **Revista Tópicos**, Rio de Janeiro, v. 3, n. 24, p. 1-16, 2025. ISSN: 2965-6672.

Fialho, T. da S.; Silva, C. de V.; Herpich, F.; Carradores, M. S. & Pozzebon, E. Inteligência artificial e educação básica: uma revisão sistemática das aplicações. **Revista Iberoamericana de Tecnología en Educación y Educación en Tecnología**, La Plata, n. 41, p. 41–52, 2025.

Gomes, J. de S.; Penha, M. C. S. de M.; Ribeiro, L. B.; Godim, F. J. & Damião, J. D. dos S. Educação 4.0: inovações tecnológicas e suas contribuições para a transformação do processo de ensino-aprendizagem. **Revista ARACÊ**, [S.l.], v. 6, n. 2, p. 2596–2609, 2024.

Gonsales, P. & Kaufman, D. IA na educação: da programação à alfabetização em dados. **ETD – Educação Temática Digital**, Campinas, SP, v. 25, e 023032, 2023.

Guimarães Junior, J. C. G.; Nascimento, I. J. B. M. F. do; Polak, A.; Chagas, L. P.; Silva, I. A. da; Paula, W. S. de; Souza, E. D. & Santana, M. C. de. Análise de dados educacionais: como a tecnologia pode ser usada para obter insights sobre o desempenho dos alunos. **Revista Contemporânea,** v. 3, n. 8, p. 11056–11072, 2023.

Lazarotto, K. R.; B. A.; Scheffer, N. F. & Petry, O. J. Políticas de implementação das tecnologias digitais e inteligência artificial na educação: o que diz a proposta do Plano Nacional de Educação 2024-2034. **Inter-Ação**, Goiânia, v. 50, n. 2, p. 832–847, 2025.

Machado, J. L. de A. Inteligência artificial e educação. **Trem de Letras**, Alfenas, v. 8, n. 1, p. e021011, 2021.

Narciso, R.; Silva, J. G. da; Rodrigues, O. R.; Souza, A. M. de O.; Cruz, L. A. X. da & Morais, R. N. G. L. Transformação e desafios: a integração da inteligência artificial no ensino superior. **Revista Ibero-Americana de Humanidades, Ciências e Educação** (REASE), São Paulo, v. 10, n. 4, p. 445–460, abr. 2024.

Nunes, M. do A. da S. & Mercado, L. P. L. Impacto da inteligência artificial na educação básica: equidade e desafios. **Revista Docência e Cibercultura**, [S. l.], v. 9, n. 1, p. 1–19, 2025.

Oliveira, C. G. B. de. Desafios da regulação do digital e da inteligência artificial no Brasil. **Revista USP**, São Paulo, n. 135, p. 137–162, out./nov./dez. 2022.

Oliveira, I.; Pereira, A.; Amante, L. & Rocio, V. Inteligência artificial e aprendizagem autorregulada: que desafios? **Revista Docência e Cibercultura**, v. 9, n. 1, p. 1–19, 2025.

Oliveira, M. D.; Costa, F. S. da; Lima, D. N. D.; Oliveira, A. P. P. L. & Vieira, V. G. dos S. Gamificação, inteligência artificial e realidade virtual: o futuro da sala de aula já chegou! **Revista Aracê**, São José dos Pinhais, v. 7, n. 4, p. 15954–15968, 2025.

Paixão, J. L. da. Inteligência Artificial e Personalização do Ensino: Revisão Sistemática da Literatura. **Revista Tópicos**, Rio de Janeiro, v. 3, n. 26, p. 1-22, 2025.

Pereira, N. M. da S.; Araújo, J. A. da S.; Silva, J. P. M. da; Luz, K. C. R. da; Bezerra, K. W.; Silva, L. A. M. da; Oliveira, M. D. D. de; Costa, C. M. F. da & Santos, E. da S. Inteligência Artificial na educação: implicações éticas para a equidade e a autonomia pedagógica. **South Florida Journal of Environmental and Animal Science**, Miami, v. 6, n. 1, e6203, 2026.

Picão, F. F.; Gomes, L. F.; Alves, L. & Barpi, O. Inteligência artificial e educação: como a IA está mudando a maneira como aprendemos e ensinamos. **Revista Amor Mundi**, Santo Ângelo, v. 4, n. 5, p. 197–201, set. 2023.

Prodanov, C. C. & Freitas, E. C. de. **Metodologia do trabalho científico:** métodos e técnicas da pesquisa e do trabalho acadêmico. 2. ed. Novo Hamburgo: Feevale, 2013.

Ridolfi, L. F.; Silva, J. A. da; Silva, R. R. da; Fernandes, L. de S.; Paula, C. A. de; Pixinine, M. P. D.; Procópio, E. L. S.; Andrade, J. da C. & Reis, M. W. R. dos. A inteligência artificial na formação docente: caminhos para uma adoção ética e inovadora na educação inclusiva. **Veredas do Direito**, Belo Horizonte, v. 23, e6993, 2026.

Rocha, L. A. An evaluation of machine learning approaches in educational environments: a systematic. **Texto Livre**, Belo Horizonte, 2025.

Santos, S. M. A. V.; Lima, B. G. de; Andrade, A. S. de; Carvalho, J. dos S. de; Francio, M. E. de S. M. & Viana, S. C. Big Data na educação: analisando o futuro da aprendizagem por meio da coleta e análise de dados. **Revista Ibero-Americana de Humanidades, Ciências e Educação** (REASE), São Paulo, v. 11, n. 1, p. 1907–1924, 2025.

Santos, S. M. A. V.; Rodrigues, B. dos S.; Graciotto, C. D. M. & Almeida, C. S. de. Personalizing education: the role of adaptive technologies in individualized education. **Contribuciones a las Ciencias Sociales**, São José dos Pinhais, v. 17, n. 2, p. 1–17, 2024.

Santos, Z. R. dos; Souza, F. C. de; Góes, M. S.; Damacena, R. & Nascimento, R. da S. Personalização do currículo na educação 4.0: integração de plataformas adaptativas no planejamento pedagógico. **Revista Políticas Públicas & Cidades**, [S. l.], v. 14, n. 6, p. e2270, 2025.

Silva, A. da. Educação 4.0: como a Inteligência Artificial está redefinindo o ensino. **EaD & Tecnologias Digitais na Educação**, Dourados, v. 12, n. 17, p. 96–106, 2024.

Souza, A. J. S. de; Possato, A. B.; Curtulo, J. P.; Silva, D. R. da; Santos, A. C. dos; Ferla, T.; Oliveira Junior, M. E. de & Gonçalves, E. H. da S. IA na educação: tendências e desafios recentes. **Cuadernos de Educación y Desarrollo**, v. 17, n. 5, e8447, 2025.

Veríssimo, A. C. de A.; Silva, A. L. G. da; Bacelar, K. F.; Detoni, V. S. S.; Barboza, A. P. L. L.; Carvalho, V. T. de; Oliveira, D. A. de & Sá, G. B. de. Plataformas educacionais e personalização do ensino: uma revolução no aprendizado. **Lumen et Virtus**, São José dos Pinhais, v. 15, n. 43, p. 7776–7790, 2024.

Vicario, R. M. Influências das tecnologias da inteligência artificial no ensino. **Estudos Avançados**, São Paulo, v. 35, n. 101, p. 73–84, 2021.

Xu, Z. & Cheng, S. Transformation of educational philosophy: an evaluation of higher education management innovation against the background of Big Data. **Trans/Form/Ação**: Revista de Filosofia da Unesp, Marília, v. 47, n. 2, e02400162, 2024.

Sobre o autor(a)

Mirtes Balbinot

Mestranda em Tecnologias da Informação e Comunicação pelo Programa de Pós-Graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina.

Especialista em Metodologia e Prática Interdisciplinar de Ensino pela Faculdade De Capivari (FUCAP - 2007).

Graduada em Licenciatura Plena em Ciências com habilitação em Matemática pela Universidade do Extremo Sul Catarinense (UNESC - 2001).

Atua como professora de Matemática e suas Tecnologias em escola pública da rede estadual de Santa Catarina desde 2002.

Lattes: http://lattes.cnpq.br/9018860580925962

CAPÍTULO 2

Segurança e integridade de dados no uso de inteligência artificial em universidade federais

José Eduardo Moreira Colombo

1. Introdução

Nas universidades federais, a inteligência artificial deixou de ser apenas um tema de pesquisa para ocupar lugar crescente na rotina administrativa, acadêmica e científica. Plataformas de apoio ao estudante, sistemas de recomendação, tutores inteligentes, ferramentas de análise preditiva e aplicações de linguagem generativa passaram a ser testadas em diferentes contextos institucionais. Esse movimento, contudo, não deve ser interpretado apenas como modernização tecnológica. A expansão da IA também amplia a superfície de exposição de dados pessoais, acadêmicos e institucionais, o que recoloca a segurança da informação no centro do debate universitário.

O problema é particularmente sensível no ensino superior público federal porque as instituições lidam com grandes volumes de dados de estudantes, servidores, projetos de pesquisa, registros de extensão, dados financeiros e, em muitos casos, informações sensíveis relacionadas à saúde, à assistência estudantil e à pesquisa com seres humanos. Segundo UNESCO (2023), a ausência de marcos regulatórios e de políticas institucionais específicas deixa instituições educacionais despreparadas para validar ferramentas de IA e para proteger a privacidade de seus usuários. No mesmo sentido, NIST (2024), destaca que sistemas generativos podem sofrer injeção de prompts, vazamento de dados e envenenamento de bases de treinamento, o que ameaça diretamente a integridade das informações e a confiança nos resultados produzidos.

A discussão sobre IA em universidades federais também se conecta à integridade acadêmica. Ferramentas generativas podem ser úteis para rascunho, revisão e apoio à aprendizagem, mas igualmente podem ser empregadas para produção indevida de trabalhos, manipulação de evidências e simulação de autoria. Consoante Moya et al., 2024, a literatura recente sobre integridade acadêmica e IA identifica perspectivas de uso legítimo, mas também desafios persistentes ligados a trapaça, equidade e formulação de respostas institucionais. Assim, a questão central não é apenas se a IA deve ser usada, mas sob quais condições ela pode ser incorporada sem comprometer a segurança dos dados e a credibilidade da vida acadêmica.

No caso brasileiro, o debate se intensifica porque a Estratégia Brasileira de Inteligência

Artificial e a Lei Geral de Proteção de Dados oferecem referências importantes, mas ainda insuficientes, para o cotidiano das instituições federais. Conforme Brasil (2021), a EBIA busca promover desenvolvimento, uso e inovação em IA no país, ao passo que a LGPD estabelece parâmetros para o tratamento de dados pessoais. O desafio, entretanto, está em traduzir essas orientações em práticas concretas de governança universitária, especialmente em ambientes marcados por diversidade de usuários, heterogeneidade tecnológica e forte dependência de sistemas terceirizados. Diante desse cenário, este artigo analisa a segurança e a integridade de dados no uso de IA em universidades federais, articulando fundamentos conceituais, riscos, marcos regulatórios e boas práticas institucionais.

2. Metodologia

Trata-se de uma revisão bibliográfica de natureza qualitativa, voltada a organizar criticamente a produção científica e documental sobre segurança da informação, integridade de dados e uso de IA em universidades federais. De acordo com Marconi e Lakatos (2003), a pesquisa bibliográfica caracteriza-se pela revisão sistemática dos principais trabalhos já publicados sobre determinado tema, sendo essencial fornecer informações atualizadas e relevantes para a investigação proposta.

A busca priorizou artigos revisados, livros de referência, relatórios de organismos internacionais e documentos oficiais brasileiros e estrangeiros, com ênfase em fontes que pudessem ser verificadas por DOI, título, periódico ou domínio institucional.

A estratégia de seleção foi orientada por palavras-chave como: “inteligência artificial”, “ensino superior”, “universidades federais”, “segurança da informação”, “proteção de dados”, “integridade acadêmica”, “governança algorítmica”, “privacidade” e “IA generativa”. Foram privilegiadas publicações recentes, sobretudo de 2019 a 2025, utilizadas diversas bases de dados e acervos científicos, nacionais e internacionais, incluindo Google Acadêmico, periódicos científicos indexados, privilegiando publicações com DOI ou disponibilizadas em fontes institucionais; sem desconsiderar trabalhos clássicos do tema.

A análise do material coletado ocorreu por meio de uma síntese temática, que articulou pilares fundamentais como: conceitos e princípios de segurança e integridade de dados; emprego da inteligência artificial no cotidiano das instituições de ensino superior; vulnerabilidades técnicas, éticas e institucionais; mecanismos de governança; e legislação e regulação. Esse arranjo permitiu construir um texto coerente, com encadeamento lógico entre as seções e com foco nas especificidades das universidades federais. Por transparência metodológica, registra-se que ferramentas de IA, ChatGPT e Claude, foram utilizadas como apoio à estruturação lógica do trabalho, tradução, bem como para revisão ortográfica e coerência textual.

3. Fundamentação Teórica

3.1 Conceitos de Inteligência Artificial

A Inteligência Artificial (IA) constitui um campo interdisciplinar da ciência da computação voltado ao desenvolvimento de sistemas capazes de executar tarefas que, quando realizadas por seres humanos, demandaria algum nível de inteligência, como aprendizagem, tomada de decisão, reconhecimento de padrões e resolução de problemas complexos. As origens conceituais da IA antecedem a consolidação dos computadores modernos, com destaque para as reflexões de Alan Turing, que, ao questionar a possibilidade de máquinas pensantes, lançou bases teóricas fundamentais para o campo (Damasceno; Vasconcelos, 2018).

Do ponto de vista epistemológico, a literatura indica que a IA não possui uma definição única e consensual, uma vez que incorpora abordagens empíricas e racionalistas. Segundo Russell e Norvig (2004), a área oscila entre perspectivas que buscam simular o comportamento humano e aquelas que privilegiam a racionalidade formal, apoiando-se em modelos matemáticos e computacionais. Essa diversidade conceitual evidencia a complexidade do campo e sua natureza híbrida, envolvendo contribuições da filosofia, matemática, psicologia, neurociência, linguística, economia e engenharia de computação (Rusell; Norvig, 2004).

Autores clássicos apresentam definições que refletem essas múltiplas abordagens. Para Haugeland (1985), a IA representa o esforço de fazer máquinas pensarem de forma análoga aos seres humanos, enquanto Bellman (1978) associa a IA à automatização de atividades cognitivas humanas, como aprendizado e tomada de decisão.

3.2 Inteligência Artificial no setor público e nas universidades federais

A consolidação da IA como tecnologia de uso amplo também é evidenciada por sua crescente aplicação em contextos institucionais e públicos. Produtos e serviços baseados em IA já estão se fazem presentes de maneira muitas vezes imperceptível no cotidiano das organizações, influenciando processos administrativos, educacionais e decisórios (Violante; Andrade, 2022). No setor público, essas tecnologias assumem papel estratégico ao potencializar a eficiência operacional, a transparência e a capacidade analítica do Estado, o que reforça a necessidade de compreendê-las não apenas sob o prisma técnico, mas também sob perspectivas éticas, regulatórias e de governança (Desordi; Della Bona, 2020).

A adoção da Inteligência Artificial no setor público está diretamente associada aos processos contemporâneos de transformação digital do Estado, caracterizados pela incorporação intensiva de tecnologias da informação com vistas à melhoria da eficiência administrativa, da capacidade analítica e da qualidade dos serviços públicos. De acordo Dunleavy et al. (2006), a chamada era digital governance redefine o funcionamento das organizações públicas ao substituir modelos burocráticos tradicionais por estruturas orientadas a dados, integração sistêmica e uso intensivo de tecnologias digitais.

No âmbito brasileiro, a Estratégia Brasileira de Inteligência Artificial (EBIA) reconhece

explicitamente o caráter transversal da IA e sua relevância para áreas como educação, administração pública, saúde e segurança. O documento enfatiza que a adoção responsável da IA deve estar ancorada em princípios éticos, transparência, inclusão e respeito aos direitos humanos, de modo a assegurar que o avanço tecnológico contribua para o desenvolvimento sustentável e o bem-estar social (Brasil (2021)). Essa diretriz reforça a importância de estudos que investiguem, de forma crítica e sistemática, os impactos da IA em organizações públicas intensivas em informação, como as universidades federais.

Segundo Brasil (2021), a IA nos serviços públicos vai além da modernização: ela supera barreiras burocráticas e orçamentárias, permitindo que o Estado entregue soluções de alta qualidade. Ao automatizar rotinas com algoritmos avançados, o setor público ganha eficiência operacional, reduzindo o tempo de espera e respondendo com mais agilidade às demandas populares.

Estudos sobre transformação digital em instituições de ensino superior indicam que a incorporação de tecnologias avançadas ocorre, frequentemente, de forma fragmentada e incremental, impulsionada por iniciativas locais e projetos isolados. George e Wooden (2023) destacam que a fase atual da transformação digital no Ensino Superior é caracterizada pela integração de sistemas de inteligência artificial. De acordo com os autores, essa inovação promove mudanças significativas ao viabilizar feedbacks personalizados aos estudantes, a automação de rotinas administrativas e o aprimoramento da qualidade do ensino.

Conforme Jin et al. (2025), a integração da IA no Ensino Superior alinha-se à missão acadêmica de formar profissionais preparados para as demandas futuras. Nesse cenário, as instituições buscam capacitar os estudantes para um mercado onde a inteligência artificial será essencial, priorizando o desenvolvimento de competências digitais e o conhecimento necessário para uma aplicação ética e responsável da tecnologia.

Goulart e Colombo (2024, p.10) explicam que:

> Não é novidade que as ferramentas de Tecnologias da Informação e Comunicação tem um rápido desenvolvimento e crescimento de sua aplicabilidade na sociedade. Quando se fala em Inteligência Artificial este crescimento é exponencial. Por isso, ela tende a ser englobada no dia a dia das atividades sociais, quer as pessoas queiram, quer não (Goulart e Colombo, 2024, p. 10).

No Ensino Superior, essa tecnologia deve ser ainda mais explorada, visto que muitas dessas inovações originam-se de pesquisas das próprias instituições. É fundamental que uma estratégia robusta considere esse aspecto e oriente o uso adequado e sustentável de tais recursos (Goulart; Colombo, 2024).

Zawacki-Richter et al. (2019) explica que a pesquisa sobre IA no ensino superior, até então, concentrava-se principalmente em sistemas de previsão, avaliação e tutoria inteligente, enquanto o

papel dos educadores permanecia subrepresentado. Essa observação continua atual, porque boa parte das soluções de IA introduzidas em universidades federais ainda chega ao cotidiano institucional por meio de plataformas externas, com pouca participação docente na fase de concepção. O resultado é uma adoção frequentemente orientada por eficiência operacional, e não por desenho pedagógico.

Sob a perspectiva de Crompton e Burke (2023), os usos mais frequentes de IA no ensino superior incluem avaliação, predição, assistentes inteligentes, sistemas tutores e gestão da aprendizagem discente. Em universidades federais brasileiras, essas aplicações já aparecem em ferramentas de atendimento ao estudante, análise de evasão, triagem de demandas administrativas, apoio à pesquisa bibliográfica e automação de tarefas repetitivas. O valor dessas soluções é inegável, sobretudo em instituições com restrição orçamentária e grande escala de atendimento. Ainda assim, a promessa de eficiência precisa ser lida em paralelo com os custos de governança, a dependência tecnológica e o risco de transferência indevida de dados para plataformas de terceiros.

UNESCO (2023) destaca que a expansão de ferramentas generativas ocorre mais rapidamente do que a adaptação dos marcos regulatórios nacionais, deixando instituições educacionais pouco preparadas para validar essas tecnologias. Em universidades federais, isso se traduz em uma situação paradoxal: ao mesmo tempo em que há pressão para inovar e digitalizar serviços, faltam políticas institucionais estáveis sobre uso aceitável, armazenamento de dados, retenção de logs, responsabilidade por falhas e auditoria de fornecedores. A ausência de padronização cria assimetrias entre setores da própria instituição e abre espaço para práticas improvisadas.

3.3 Segurança e integridade de dados no ambiente universitário

Em sistemas de IA, a integridade dos dados assume papel estratégico, pois dados corrompidos, enviesados ou manipulados comprometem diretamente a qualidade dos modelos e a legitimidade das decisões produzidas. Floridi et al. (2018) destacam que falhas na gestão dos dados podem gerar efeitos sistêmicos, amplificando erros, vieses algorítmicos e riscos éticos, especialmente quando decisões automatizadas impactam indivíduos e coletividades.

Estudos sobre segurança da informação e integridade de dados no setor público ressaltam que a utilização de sistemas inteligentes amplia a superfície de exposição a riscos, introduzindo vulnerabilidades associadas ao tratamento automatizado de dados, ao uso de modelos algorítmicos e à integração de múltiplas bases informacionais. A ausência de mecanismos robustos de governança pode comprometer não apenas a segurança técnica dos sistemas, mas também a legitimidade institucional e a confiança da sociedade nas organizações públicas (Ferreira et al., 2021). No setor público, esses riscos são potencializados pela sensibilidade das informações tratadas e pela responsabilidade institucional associada à sua custódia. Goulart et al. (2025, p.16) apontam que:

> as universidades e os formuladores de políticas educacionais precisam se envolver em discussões abrangentes e inclusivas

> sobre o papel da IA no ensino superior e elaborar diretrizes e melhores práticas para seu uso responsável. Esse compromisso envolve assegurar a transparência e a responsabilização dos sistemas de Inteligência Artificial, ao mesmo tempo em que se protege a privacidade e a segurança dos dados utilizados Goulart et al. (2025, p. 16).

A presença da IA na vida contemporânea tornou-se praticamente onipresente. Sua aplicação abrange campos como ciência da computação, estatística, psicologia, filosofia e linguística, o que reforça sua capacidade de operar de forma transversal também no ecossistema educacional (Kuleto et al., 2021). No Ensino Superior, os impactos são variados: desde a personalização do ensino e a automação de processos até o suporte à tomada de decisão institucional (Popenici; Kerr, 2017). No entanto, tais benefícios vêm acompanhados de desafios éticos, pedagógicos e organizacionais que exigem reflexão crítica e articulação entre diferentes atores.

O recente lançamento de ferramentas de IA Generativa, como o ChatGPT e Gemini, intensificou esse debate, levantando preocupações sobre a integridade acadêmica, a confiabilidade dos sistemas e eventuais distorções no processo formativo. A ascensão desses recursos exige que as instituições reavaliem seus métodos pedagógicos e modelos de avaliação, incorporando princípios de governança ética e estratégias de formação crítica para o uso responsável de tais ferramentas (George; Wooden, 2023).

Conforme NIST (2024), sistemas generativos criam riscos específicos para privacidade, integridade da informação e segurança, inclusive quando operam em ambientes integrados a bases corporativas. O documento destaca que ataques de prompt injection podem induzir o sistema a revelar dados proprietários ou a executar comportamentos não previstos, ao passo que o data poisoning compromete conjuntos de treinamento e altera o funcionamento do modelo. Para universidades, isso significa que a proteção não pode se limitar a senhas ou filtros de acesso; ela precisa alcançar também a camada de dados, modelos, integrações e fornecedores.

A integridade de dados também assume dimensão acadêmica. Em ambientes de aprendizagem, um sistema que produz respostas incorretas, citações inventadas ou classificações enviesadas pode comprometer decisões pedagógicas, avaliações e pareceres. Consoante Kasneci et al., 2023, modelos de linguagem têm potencial para apoiar o ensino, mas exigem vigilância quanto à veracidade do conteúdo, à explicabilidade e à verificação humana. Quando esse tipo de sistema é usado em escala institucional, a integridade deixa de ser apenas um atributo técnico e passa a ser uma condição de legitimidade do processo educacional.

3.4 Riscos específicos para a segurança e a integridade de dados

O primeiro risco relevante é o vazamento de dados. Quando docentes, técnicos ou estudantes inserem em sistemas generativos informações sobre projetos, avaliações, prontuários, dados de pesquisa ou situações pessoais, parte desses conteúdos pode ser processada externamente e

permanecer fora do controle da instituição. Segundo NIST (2024), a privacidade é afetada porque o treinamento de sistemas de IA pode envolver grandes volumes de dados pessoais, e o uso de informações sensíveis exige cautela redobrada. Em universidades federais, o problema se agrava quando há ausência de política de classificação da informação e quando o uso de IA ocorre sem orientação formal.

Outro risco é a integridade algorítmica. Sistemas generativos podem produzir respostas plausíveis, porém incorretas, inventar referências, simplificar excessivamente conceitos ou reproduzir vieses presentes nos dados de treinamento. Já Kasneci et al. (2023) afirma que a qualidade do uso pedagógico depende de revisão humana, treinamento docente e desenho adequado da interface. Em ambientes de ensino superior, esse ponto é decisivo, pois a confiança acrítica em saídas automatizadas pode afetar planos de aula, avaliações, relatórios e até decisões de pesquisa.

Há também riscos associados à integridade acadêmica. De acordo com Moya et al. (2024), a literatura sobre IA e honestidade acadêmica identifica dois movimentos simultâneos: por um lado, o uso legítimo como apoio à aprendizagem; por outro, a possibilidade de fraude, substituição indevida da autoria e enfraquecimento das práticas formativas. Em universidades federais, onde a credibilidade acadêmica é um ativo público, a resposta não pode ser meramente punitiva. É necessário promover letramento em IA, critérios claros de citação e uso, e avaliações mais autênticas, capazes de distinguir desempenho real de geração automatizada.

Um quarto risco, menos visível, é a dependência de fornecedores externos. Plataformas comerciais podem reter metadados, registrar interações e combinar dados de uso para fins diversos do contexto universitário. De acordo com UNESCO (2023), a proteção da privacidade dos usuários e a validação dos sistemas são pontos centrais de uma abordagem human-centered. Isso é especialmente importante nas universidades federais, que precisam assegurar que a soberania sobre dados acadêmicos não seja enfraquecida por contratos pouco claros ou por integrações sem análise de risco.

3.5 Marco regulatório, governança e boas práticas

No plano normativo, a Lei Geral de Proteção de Dados estabelece que o tratamento de dados pessoais, inclusive em meios digitais, deve observar bases legais, finalidade, necessidade, transparência e segurança. Segundo Brasil (2018), o tratamento de dados não é livre nem neutro; ele exige justificativa e responsabilidade. Para universidades federais, isso implica mapear fluxos de dados, identificar responsáveis pelo tratamento e revisar contratos com fornecedores de IA para evitar compartilhamentos indevidos.

No campo estratégico, a Estratégia Brasileira de Inteligência Artificial reconhece a importância de pesquisa, desenvolvimento, inovação e uso responsável da IA no país. Segundo Brasil (2021), a iniciativa busca fomentar avanços em setores prioritários e promover soluções voltadas ao interesse público. Embora a EBIA não resolva por si só os desafios cotidianos das universidades

federais, ela oferece um marco útil para orientar políticas internas, especialmente quando associada a diretrizes de ética, segurança e formação.

Conforme UNESCO (2023), instituições educacionais devem validar sistemas de IA quanto à adequação ética e pedagógica, ao mesmo tempo em que desenvolvem políticas compreensivas para seu uso. Já conforme NIST (2024), uma governança adequada precisa incluir documentação da origem e do histórico dos dados, avaliação periódica das capacidades do sistema, inventário de aplicações e mecanismos de desativação segura. Esses elementos apontam para uma lógica de governança por ciclo de vida, na qual a instituição não apenas adquire tecnologia, mas acompanha continuamente seu comportamento, seus riscos e seus efeitos.

Quadro 1 - Riscos associados ao uso de IA em universidades federais e medidas de mitigação

Risco	Efeito institucional	Medida de mitigação
Vazamento de dados	Exposição de informações pessoais, acadêmicas e de pesquisa	Minimização de dados, controle de acesso, cláusulas de proteção e revisão humana
Prompt injection e data poisoning	Manipulação de respostas e comprometimento do modelo	Monitoramento, isolamento de ambientes, testes de segurança e validação contínua
Alucinações e vieses	Decisões incorretas, citações inventadas e injustiças	Supervisão humana, checagem de evidências e treinamento dos usuários
Dependência de fornecedores	Perda de autonomia e risco de compartilhamento indevido	Governança contratual, auditoria e preferência por soluções auditáveis
Fragilidade na integridade acadêmica	Plágio, autoria simulada e uso indevido	Normas claras, letramento em IA e avaliações autênticas

Fonte: elaborado pelo autor (2026)

4. Discussões

A literatura analisada indica que a principal vantagem da IA nas universidades federais está na capacidade de ampliar o alcance dos serviços e reduzir tarefas repetitivas, liberando tempo para atividades analíticas, pedagógicas e de pesquisa. Ainda assim, a mesma literatura mostra que a inovação não se sustenta apenas pela adoção de ferramentas. Consoante Crompton e Burke (2023), o crescimento das aplicações em IA no ensino superior foi acompanhado por novos usos em avaliação, predição e apoio à aprendizagem; no entanto, esse movimento não elimina a necessidade de mediação docente, critérios institucionais e supervisão ética. Em outras palavras, a IA pode ser útil, mas não deve ser tratada como solução autossuficiente.

Embora ainda sejam incipientes, observa-se que diversas universidades federais brasileiras vêm discutindo políticas internas para utilização de ferramentas de IA generativa em atividades de ensino, pesquisa e gestão. Esse movimento demonstra que o debate deixou de ser exclusivamente teórico e passou a integrar a agenda institucional das universidade, ainda que em diferentes níveis de maturidade.

No cotidiano das universidades federais, a aplicação da IA tende a aparecer em pelo menos quatro frentes. A primeira é a gestão acadêmica, com apoio à triagem de demandas, resposta automatizada e previsão de evasão. A segunda é o ensino, por meio de tutores, assistentes de escrita, ferramentas de feedback e apoio à personalização da aprendizagem. A terceira é a pesquisa, sobretudo na busca bibliográfica, na organização de dados e na revisão textual. A quarta é a administração pública universitária, com automação de fluxos internos e análise de documentos.

A resposta a essas perguntas exige governança de dados. UNESCO (2023) explica que as instituições educacionais precisam validar as ferramentas de IA e garantir que a proteção da privacidade seja parte integrante da implementação. Consoante NIST (2024), a documentação da origem dos dados, a definição clara de inventários e a avaliação contínua dos sistemas são componentes decisivos para reduzir riscos. Para universidades federais, isso significa criar políticas internas sobre uso aceitável, classificação da informação, retenção de registros, anonimização e resposta a incidentes. Sem esses mecanismos, a adoção de IA pode ampliar a eficiência em algumas rotinas, mas ao custo de fragilizar a confiança institucional.

Embora UNESCO (2023) e NIST (2024) apresentem perspectivas distintas sobre a governança da IA, observa-se convergência quanto à necessidade de mecanismos institucionais capazes de assegurar transparência, responsabilização e supervisão humana. Enquanto a UNESCO enfatiza aspectos éticos e educacionais, o NIST dedica maior atenção à gestão técnica dos riscos. Para universidades federais, ambas as abordagens mostram-se complementares, indicando que políticas institucionais efetivas devem integrar dimensões tecnológicas, jurídicas e pedagógicas.

Outro ponto decisivo é a formação das pessoas. A literatura aponta que muitos riscos não decorrem apenas da tecnologia, mas do modo como ela é utilizada. Conforme Kasneci et al. (2023), o uso educacional de modelos de linguagem depende de interfaces adequadas, revisão constante e desenvolvimento de competências críticas. Isso vale, sobretudo, para universidades federais, onde a diversidade de perfis formativos é grande e a assimetria de letramento digital pode ser significativa. Professores, estudantes e técnicos precisam compreender tanto os benefícios quanto os limites da IA, inclusive o fato de que respostas bem formuladas não equivalem necessariamente a respostas verdadeiras.

A integridade acadêmica, nesse cenário, não pode ser reduzida a um problema disciplinar. Ela precisa ser tratada como uma cultura institucional. Conforme Moya et al., 2024, a literatura sobre integridade e IA abrange desde a ideia de trapaça até o reconhecimento de usos legítimos e de apoio à aprendizagem. Essa ambivalência mostra que políticas proibicionistas tendem a ser pouco eficazes. Em vez disso, universidades federais precisam construir normas de uso que explicitem quando a IA pode ser empregada, como deve ser declarada e quais limites se aplicam a atividades

avaliativas, produção de texto, análise de dados e autoria. A transparência aqui não é um detalhe; ela é parte da própria validade do processo formativo.

Há ainda uma dimensão de soberania institucional. Em ambientes em que dados acadêmicos e administrativos são frequentemente tratados por plataformas de terceiros, a universidade corre o risco de perder controle sobre sua própria informação. Isso é especialmente delicado no setor público, porque dados coletados para fins acadêmicos podem ser combinados, retidos ou reutilizados de modo não previsto inicialmente. Segundo Brasil (2018), o tratamento de dados pessoais deve respeitar finalidade e necessidade; portanto, o simples apelo à inovação não basta para justificar qualquer integração tecnológica. A universidade federal precisa decidir o que pode ser externalizado, o que deve permanecer em infraestrutura própria e quais dados jamais devem ser enviados a serviços de IA sem salvaguardas reforçadas.

Nesse sentido, a discussão aponta para um modelo de adoção responsável baseado em cinco pilares. O primeiro é a segurança por desenho, com políticas de acesso, criptografia, segmentação de ambientes e testes periódicos. O segundo é a minimização de dados, evitando inserir em modelos externos informações que não sejam estritamente necessárias. O terceiro é a supervisão humana, especialmente em atividades avaliativas, de pesquisa e de atendimento ao público. O quarto é a auditabilidade, com registro de uso, logs e revisão dos sistemas adotados. O quinto é a formação contínua, para que a comunidade universitária saiba identificar riscos, reportar incidentes e usar a tecnologia com criticidade.

O debate sobre o uso de IA em universidades federais também precisa levar em conta a desigualdade de capacidades entre instituições. Nem todas dispõem da mesma infraestrutura de rede, da mesma maturidade em cibersegurança ou do mesmo nível de pessoal qualificado para gerir contratos tecnológicos complexos. Por isso, qualquer política nacional ou institucional deve considerar critérios de escalabilidade, interoperabilidade e sustentabilidade. De acordo com Brasil (2021), a EBIA busca fomentar desenvolvimento e uso de IA em benefício do país; para que isso ocorra de fato no ensino superior federal, é necessário traduzir a estratégia em apoio técnico, financiamento, capacitação e coordenação interinstitucional.

Em síntese, a IA pode fortalecer as universidades federais, mas somente se a inovação vier acompanhada de governança. Quando a tecnologia é introduzida sem política, o risco é transformar eficiência em vulnerabilidade. Quando é incorporada com critérios, pode melhorar processos, ampliar acesso e apoiar o trabalho acadêmico sem comprometer a integridade dos dados.

5. Conclusão

A análise realizada permite afirmar que a segurança e a integridade de dados são condições estruturais para o uso responsável de inteligência artificial em universidades federais. O tema não se resume à proteção técnica contra ataques ou vazamentos; ele envolve também confiabilidade

informacional, validade acadêmica, soberania institucional e respeito aos direitos dos usuários. Em instituições que lidam simultaneamente com ensino, pesquisa, extensão e administração, qualquer solução de IA precisa ser pensada como parte de um ecossistema de governança, e não como ferramenta isolada.

A revisão bibliográfica evidencia que a literatura internacional já reconhece o potencial da IA para apoiar avaliação, personalização, tutoria e gestão acadêmica, mas também indica lacunas importantes quanto à participação dos educadores, à validação das ferramentas e à proteção dos dados. Consoante Zawacki-Richter et al. (2019), a pesquisa em IA no ensino superior foi historicamente concentrada em poucos usos, já conforme Crompton e Burke (2023), o campo se expandiu rapidamente, exigindo respostas institucionais mais consistentes. Somam-se a isso os alertas de UNESCO (2023), e NIST (2024), sobre privacidade, prompt injection, data poisoning e necessidade de governança contínua.

Para as universidades federais, a conclusão prática é clara: adotar IA sem política de dados, sem capacitação e sem supervisão humana amplia o risco institucional. Por outro lado, quando a tecnologia é integrada com critérios de minimização, transparência, auditoria, avaliação ética e adequação à LGPD, ela pode fortalecer a capacidade acadêmica e administrativa sem sacrificar a integridade. O caminho mais promissor, portanto, não é a proibição indiscriminada nem a adesão acrítica, mas uma incorporação responsável, progressiva e institucionalmente controlada.

Como limitação, este artigo tem natureza bibliográfica e não incorpora evidências empíricas sobre a ocorrência desses riscos em universidades federais brasileiras específicas, tampouco propõe um modelo próprio de governança. Pesquisas futuras podem preencher essa lacuna por meio de estudos de caso institucionais, entrevistas com gestores de tecnologia da informação e mapeamento da maturidade de governança de IA nas universidades, de modo a converter os riscos aqui sistematizados em evidências localmente validadas.

Por fim, destaca-se que a construção de uma cultura de uso seguro de IA nas universidades federais depende de decisão política, formação permanente e compromisso com o interesse público. Em um cenário de expansão acelerada das ferramentas generativas, a universidade federal precisa permanecer como espaço de criticidade, validação do conhecimento e proteção dos dados que legitimam sua missão social.

REFERÊNCIAS

Anthropic. **Claude**. Disponível em: https://claude.ai. Acesso em: 24 abr. 2026.

Bellman, R. **An introduction to artificial intelligence: can computers think?** San Francisco: Boyd & Fraser, 1978.

Brasil. Lei nº 13.709, de 14 de agosto de 2018. **Lei Geral de Proteção de Dados Pessoais (LGPD)**. Brasília, DF, 2018.

Brasil. Portaria MCTI nº 4.617, de 6 de abril de 2021. **Estratégia Brasileira de Inteligência Artificial**. Brasília, DF, 2021.

Crompton, H. & Burke, D. Artificial intelligence in higher education: the state of the field. International **Journal of Educational Technology in Higher Education**, v. 20, n. 22, 2023.

Damasceno, S. S. & Vasconcelos, R. O. Inteligência artificial: uma breve abordagem sobre seu conceito real e o conhecimento popular. Caderno de Graduação – **Ciências Exatas e Tecnológicas**, [s. l.], v. 5, n. 1, 2018.

Desordi, D. & Deella Bona, C. **A inteligência artificial e a eficiência na administração pública. Revista de Direito**, [s. l.], v. 12, n. 2, 2020.

Dunleavy, P.; Margetts, H.; Bastow, S. & Tinkler, J. **Digital era governance**. Oxford: Oxford University Press, 2006. Disponível em: http://repo.darmajaya.ac.id/3926/1/Digital%20era%20governance%20IT%20corporations%2C%20the%20state%2C%20and%20e-government%20by%20Patrick%20Dunleavy%2C%20Helen%20Margetts%2C%20Simon%20Bastow%2C%20Jane%20Tinkler%20%28z-lib.org%29.pdf . Acesso em: 02 mai. 2026.

Floridi, L.; Cowls, J; Beltrametti, M.; Chatila, P.; Dignum, V.; Luetge, C.; Madelin, R.; Pagallo, U.; Rossi, F.; Schafer, B.; Valcke, P. & Vayena, E. AI4People—An ethical framework for a good AI society. **Minds and Machines**, [s. l.], 2018. Acesso em: 02 mai. 2026.

George, B. & Wooden, O. **Managing the strategic transformation of higher education through artificial intelligence**. Administrative Sciences, [s. l.], v. 13, n. 9, art. 196, 2023. DOI: https://doi.org/10.3390/admsci13090196.

Goulart, J. M. & Colombo, J. E. M. **A revisão da estratégia brasileira de inteligência artificial e as universidades públicas federais**. In: COLÓQUIO INTERNACIONAL DE GESTIÓN UNIVERSITARIA, 2024, Montevideo. Anais [...]. Montevideo: CIGU, 2024.

Goulart, J. M.; Colombo, J. E. M. & Naspolini, T. Da utopia tecnológica ao ChatGPT em sala de aula: um ensaio teórico sobre inteligência artificial no ensino superior. **Lumen et Virtus,** [s. l.], v. 16, n. 50, p. 8469-8490, 2025.

Goulart, J. M.; Picalho, A. C.; Colombo, J. E. M. & Melo, P. A. **Processos de Governança em Inteligência artificial em Órgãos Públicos Brasileiros:** revisão integrativa**.** In: International Journal of Knowledge Engineering, Management and Media, Florianópolis, v. 14, p. 1-21, 2025.

Haugeland, J. **Artificial intelligence: the very idea**. Cambridge: MIT Press, 1985.

Jin, Y.; Yan, L.; Echeverria, V.; Gasevic, D. & Martinez-Maldonado, R. Generative AI in higher education**.** **Computers and Education:** Artificial Intelligence, [s. l.], v. 8, p. 100348, 2025. DOI: https://doi.org/10.1016/j.caeai.2024.100348

Kasneci, E.; Sessler, K.; Kuchemann, S.; Bannert, M.; Dementieva, D.; Fischer, F.; Gasse, U.; Groh, G.; Gunnemann, S.; Hullermeier, E.; Krusche, S.; Kutyniok, G.; Michaeli, T.; Nerdel, C.; Pfeffer, J.; Poquet, O.; Sailer, M.; Schmidt, A.; Seidel, T.; Stadler, M.; Weller, J.; Kuhn, J. & Kasneci, G. ChatGPT for good? On opportunities and challenges of large language models for education. **Learning and Individual Differences**, v. 103, art. 102274, 2023.

Kuleto, V.; Ilic, M.; Dumangiu, M.; Rankovic, M.; Martins, O. M. D.; Paun, D. & Mihoreanu, L. Exploring opportunities and challenges of artificial intelligence and machine learning in higher education institutions. **Sustainability**, [s. l.], v. 13, n. 18, art. 10424, 2021. DOI: https://doi.org/10.3390/su131810424 . Acesso em: 25 abr. 2026.

Marconi, M. A. & Lakatos, E. M. **Fundamentos da metodologia científica.** 5. ed. São Paulo: Atlas, 2003. Disponível em: https://docente.ifrn.edu.br/olivianeta/disciplinas/copy_of_historia-i/historia-ii/china-eindia/view. Acesso em: 10 mai. 2026.

Moya, B. A.; Eaton, S. E.; Pethrick, H.; Hayden, K. A.; Brennan, R.; Wies, J.; McDermott, B. & Lesage, J. **Academic integrity and artificial intelligence in higher education contexts: a rapid scoping review**. Canadian Perspectives on Academic Integrity, v. 7, n. 3, 2024.

NIST. National Institute of Standars and Technology. **Artificial Intelligence Risk Management Framework: Generative Artificial Intelligence Profile.** NIST AI 600-1. Gaithersburg: NIST (2024). Disponível em: https://nvlpubs.nist.gov/nistpubs/ai/NIST.AI.600-1.pdf . Acesso em: 02 mai. 2026.

NIST. National Institute of Standars and Technology. **Adversarial Machine Learning: A Taxonomy and Terminology of Attacks and Mitigations**. NIST AI 100-2e2023. Gaithersburg: NIST (2024). Disponível em: https://nvlpubs.nist.gov/nistpubs/ai/NIST.AI.100-2e2023.pdf. Acesso em: 02 mai. 2026.

OpenAI. **ChatGPT**. Disponível em: https://chat.openai.com. Acesso em: 24 abr. 2026.

Popenici, S. A. D. & Kerr, S. Exploring the impact of artificial intelligence on teaching and learning in higher education. **Research and Practice in Technology Enhanced Learning**, [s. l.], v. 12, art. 22, p. 1-13, 2017. DOI: https://doi.org/10.1186/s41039-017-0062-8 .

Russel, S. & Norvig, P. **Artificial Intelligence: a modern approach**. 2. ed. Upper Saddle River: Prentice Hall, 2004.

UNESCO. **Guidance for generative AI in education and research**. Paris: UNESCO (2023). Disponível em: https://www.unesco.org/en/articles/guidance-generative-ai-education-and-research. Acesso em: 05 mai. 2026.

Violante, A. & Aandrade, A. **O potencial da inteligência artificial na gestão**. Gestão e Desenvolvimento, [s. l.], n. 30, p. 439-479, 2022. Disponível em: https://journals.ucp.pt/index.php/gestaoedesenvolvimento/article/view/11627 . Acesso em: 05 mai. 2026.

Zawacki-Richter, O.; Martin, V. I.; Bond, M. & Gouverneur, F. Systematic review of research on artificial intelligence applications in higher education – where are the educators?**. International Journal of Educational Technology in Higher Education**, v. 16, art. 39, 2019. Disponível em: https://link.springer.com/article/10.1186/s41239-019-0171-0 . Acesso em: 02 mai. 2026.

Sobre o autor(a)

José Eduardo Moreira Colombo

Mestre em Tecnologias da Informação e Comunicação pelo Programa de Pós-Graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina (UFSC - 2023).

Bacharel em Administração pela Universidade de Região de Joinville (UNIVILLE - 2014), bacharel Ciências Contábeis pelo Centro Universitário Cidade Verde (UNICIVE - 2020) e Tecnólogo em Gestão da Tecnologia da Informação também pelo UNICIVE (2024).

Pós-graduado (*lato sensu*) em Matemática, suas Tecnologias e o Mundo do Trabalho pela Universidade Federal do Piauí (UFPI - 2022), Gestão Pública na Educação Profissional e Tecnológica pelo Instituto Federal de Santa Catarina (IFSC, 2022), e MBA em Administração, Finanças e Negócios pela Universidade Candido Mendes (UCAM - 2016).

Servidor Público Federal desde 2017 na Universidade Federal de Santa Catarina - Campus Araranguá

Lattes: http://lattes.cnpq.br/7232477187942359

CAPÍTULO 3

Identificação de padrões de aprendizagem com IA

Dionatan Carlos de Souza

1. Introdução

Quando consideramos novas modalidades de ensino e aprendizagem, o uso de tecnologias baseadas em linguagens computacionais, em especial a inteligência artificial (IA), revela-se uma oportunidade valiosa para otimizar os processos de estudo. Contudo, conforme apontam Oliveira e Santos (2024), é fundamental estabelecer critérios e metodologias para a aplicação desse recurso nos conteúdos didáticos, assegurando, dessa forma, a relevância das informações coletadas.

É importante evidenciar que a inteligência artificial não substitui o professor; ela o capacita e o deixa com maiores possibilidades para desenvolver o ensino e sua personalização, expandindo as formas de atuação e adaptando-se às novas demandas de maneira mais direta, assertiva e direcionada (Gabriel, 2023). Nesse contexto (Arão, 2024) argumenta que a IA não consegue substituir a capacidade humana de reflexão crítica, criatividade e julgamento ético, sendo o mesmo insubstituível neste papel.

O reconhecimento dos padrões de aprendizado analisa, por meio da inteligência artificial, grandes volumes de dados, compreendendo comportamentos que se repetem e tendências na forma em que os alunos apreendem, em vez de abordar todos os estudantes da mesma forma, essa tecnologia é capaz de considerar as especificidades individuais e coletivas, apontando oportunidades de melhoraria no processo educacional, criando também modelos que podem ser utilizados como referenciais para entender melhor cada aluno. Promovendo cada vez mais os ambientes adaptativos de aprendizagem, de maneira personalizada e eficaz (Cieb, 2019).

2. Referencial teórico

Buscando compreender melhor a temática, este estudo baseia-se em três grandes conceitos: A mudança do Perfil Discente, o Reconhecimento de Padrões de Aprendizagem e o Aprendizado de Máquina. Estes terão como objetivo inicial conceituar o tema explorado e servirão de base para a análise das problemáticas levantadas durante a pesquisa.

2.1. A mudança do perfil discente: integrando a inteligência artificial no cotidiano da pesquisa e aprendizagem.

A utilização da inteligência artificial (IA) na educação vem sendo objeto de estudo, compreensão e desafios. Conhecer suas potencialidades é um dos grandes desafios da atualidade, assim como propor melhorias para o processo de ensino e aprendizagem. A inteligência artificial pode ser usada para personalizar o ensino e aprendizagem, levando em conta as preferências e dificuldades de cada aluno, além de fornecer feedbacks mais precisos e imediatos. (Vicari, n.d., p. 2).

Considerando a possibilidade de personalizar as estratégias e metodologias de ensino, a inteligência artificial (IA) pode representar um grande avanço na educação, é sabido que, quando personalizamos as estratégias de ensino, buscando compreender as dificuldades e até mesmo as próprias preferências de cada aluno, portanto, tendo acesso a uma quantidade maior de informações sobre todo o processo, é possível também otimizar as ações, como, reconhecer os problemas de aprendizado, e por meio desses padrões, aprimorar os processos formativos e avaliativos do aluno.

A inteligencia artificial, segundo Pereira (2018), neste contexto, não busca substituir o professor, mas apresenta-se como uma ferramenta capaz de complementar de maneira eficaz o processo de ensino, auxiliando na identificação e desenvolvimento das principais habilidades de cada aluno, reconhecer essas possibilidades, é uma forma clara de promover a melhoria do processo de aprendizagem.

Para Baltar (2023), essas tecnologias devem ser vivenciadas por escolas, professores e alunos. Deixar de utilizá-las significa desconsiderar um avanço tecnológico inevitável e passar a seguir decisões tomadas por outras pessoas. Quem não utilizar, ou mesmo ignorar a inteligencia artificial estará a margem de um grande movimento. Mesmo que ainda esteja em desenvolvimento e aplicação, já pode ser considerada uma forte tendência para a educação na atualidade.

É importante lembrar que estamos vivenciando uma ruptura geracional, e o desafio pedagógico não está mais em apenas oferecer o conteúdo, mas em ensinar o estudante, que utiliza frequentemente esses recursos, a compreender o caminho percorrido. Sua autonomia digital, pode ser uma grande aliada na construção do conhecimento.

> O aluno já não é mais o mesmo e não atua como antes. Ele não lê mais em material impresso e prefere ler nas telas. Quando solicitado a fazer uma pesquisa, provavelmente vai utilizar um sistema de busca como o Google ou os sistemas de acesso às bases de dados digitais (Valente, 2018, p. 17).

Desta forma, fica claro que o aluno evidencia uma possível mudança sociocultural, sendo um sujeito ativo durante esse processo. A substituição do material impresso reflete uma mudança na

maneira de buscar informações, redefinindo o ato de pesquisar e exigindo novas estratégias de ensino para acompanhar essas transformações.

2.2. Reconhecimento de padrões de aprendizagem

O reconhecimento de padrões de aprendizagem é um dos princípios fundamentais da inteligencia artificial na atualidade. A possibilidade de identificar características e utilizar essas informações para executar ações ou fazer previsões representa uma grande oportunidade para o andamento do ensino. Dessa maneira, Oliveira e Santos (2024), destacam a importância que a personalização do ensino e a identificação dos padrões podem gerar em uma abordagem educacional, passando a ser muito mais inclusiva e eficaz para a aprendizagem dos alunos.

Levando em consideração a Nota Técnica no 16 do Centro de Inovação para a Educação Brasileira (CIEB), destaca-se que Dependendo dos conhecimentos, habilidades e características pessoais do estudante, o sistema apresenta conteúdos diferenciados, utiliza estratégias pedagógicas que tragam mais benefícios, considerando as particularidades do indivíduo e oferecendo gatilhos motivacionais adequados para que ele consiga construir seu próprio conhecimento. (Cieb, 2019, p. 15).

A oferta de conteúdos diversificados ao aluno pode proporcionar diversos benefícios ao aprendizado. Nesse contexto, é possível explorar as particularidades de cada estudante, focando na individualidade para permitir que o aluno seja capaz de construir o seu próprio conhecimento. Assim, o reconhecimento desses padrões constitui uma ferramenta capaz de reconhecer comportamentos recorrentes e buscar compreender melhor o perfil ou o estado de cada aluno.

Ainda de acordo com Russell e Norvig (2016), a inteligência artificial desenvolve a autonomia do sujeito, tornando-o capaz de observar o ambiente, tomar decisões e aumentar suas chances de sucesso. É por meio do reconhecimento de padrões que o processamento de dados pode identificar características e, com base no histórico de resultados, propor soluções assertivas e personalizadas às necessidades dos estudantes.

2.3. Aprendizado de máquina

O aprendizado de máquina segundo Faceli et al. (2011), faz parte de uma área de pesquisa da inteligência artificial, visando, por meio da linguagem computacional, à capacidade de executar e aprender com a realização de tarefas, o que resulta em experiência e na possibilidade de apreender de maneira autônoma, com base nas informações e nos dados disponíveis.

Pode-se mencionar que conforme Cerri e Carvalho (2017), o aprendizado de máquina é uma área de pesquisa multidisciplinar, capaz de interligar diversos conhecimentos, como a probabilidade e estatística, complexidade computacional, teoria da informação, filosofia e psicologia entre outros. Dentro dessas atividades podemos citar como exemplo a classificação e agrupamento de dados e a previsão de séries temporais.

Os conceitos relacionados aos modelos generativos de aprendizado de máquina surgiram há bastante tempo, e de acordo com Alom et al. (2019), esses modelos vêm se tornando cada vez mais populares, pois são capazes de apresentar bons resultados em distintos domínios de aplicação. Projetados para compreender a estrutura dos dados, eles são capazes de criar novos conteúdos, produzindo resultados semelhantes aos gerados originalmente.

O aprendizado de máquina é orientado por dados e, quanto maior a quantidade de informações de entrada, melhor tende ser o seu desempenho, tornando seus resultados mais competentes e abrangentes nesse contexto. Segundo Domingos (2015), Goodfellow, Bengio e Courville (2016) e Alpaydin, (2016), atualmente o aprendizado de máquina, que é uma subárea da inteligencia artificial, é responsável por desenvolver algoritmos capazes de aprender a partir de dados, melhorando seu desempenho ao longo do tempo, sendo certamente o maior subcampo da IA em números de praticantes.

3. Metodologia

Buscando compreender como a inteligência artificial tem sido utilizada para identificar padrões de aprendizagem na educação, adotou-se como referência metodológica desta pesquisa a revisão sistemática de literatura (RSL), por possibilitar uma pesquisa direcionada a um tema específico. Para realizar essa revisão sistemática, foi utilizado o método *Systematic Search Flow* (SSF), abordagem desenvolvida por Ferenhof e Fernandes (2016), que busca seguir um fluxo estruturado e reprodutível e tem como principais fases a definição do protocolo, a análise dos dados, a síntese e a escrita.

Na primeira etapa da pesquisa foi definido o protocolo de investigação e seu planejamento, levando em consideração a pergunta da pesquisa, em seguida realizou-se a consulta em base de dados, definindo-se a forma de organização, padronização e escolha dos artigos selecionados, bem como a organização das referências bibliográficas. Ainda segundo Ferenhof e Fernandes (2016), na segunda etapa foi analisado os dados, observando-se a consolidação das informações e realizando a análise crítica dos estudos selecionados, nessa fase foi avaliado a qualidade metodológica dos trabalhos pesquisados e utilizados nessa revisão.

Na terceira etapa foi realizado a síntese dos dados extraídos que foram organizados através de um relatório, possibilitando a geração de novos conhecimentos a partir das informações obtidas. Na quarta e última fase temos o escrever, fase essa que destinasse a consolidação dos resultados através da escrita cientifica, resgatando o objetivo da revisão de literatura, e apresentando o resultado na analise e da síntese.

Levando em consideração a Portaria CNPq no 2.664/2026, informa-se que o ChatGPT (OpenAI, GPT-5.5) foi utilizado como ferramenta de auxílio em atividades específicas do desenvolvimento deste estudo, tais como a revisão gramatical e a formatação de referências. Também foi utilizado o Gemini (Google) para auxiliar na comparação dos objetivos, das metodologias e das conclusões dos artigos selecionados.

4. Análise e discussão dos resultados

Nesta primeira fase do método *Systematic Search Flow* (SSF), são realizadas as atividades que constituem o protocolo de pesquisa, conforme detalhado abaixo.

Quadro 1 - Protocolo de pesquisa

Fase 1 - Definição do protocolo de pesquisa	
Atividade 1 Estratégia de Busca	A estratégia de busca elaborada utilizou os seguintes termos em inglês: “Identification patterns of learning” e "AI-based education”; e os termos em português; “inteligência artificial”, “padrões de aprendizagem” e “Aprendizado de máquina”. Buscou-se utilizar palavras capazes de direcionar a pesquisa para trabalhos que apresentassem relação com contextos educacionais. Além disso, foram utilizadas aspas como estratégia para refinar e direcionar a pequisa. Para combinar os termos de busca, foi utilizado os operadores booleanos “AND” e “OR”. Como critério de inclusão e exclusão, assumiu-se: 1. Selecionar artigos que tivessem, no resumo (abstract), nas palavras-chave ou mesmo no corpo do texto, os termos desta pesquisa. 2. Artigos publicados nos últimos quatro anos e que estivessem vinculados a áreas temáticas como Ciências Humanas, Ciências Sociais e Multidisciplinar. 3. Artigos com texto completo (Fulltext) disponível para download por meio do Google Scholar® e SciElo®. 4. Artigos nos idiomas inglês, espanhol e português.
Atividade 2 Consulta em bases de dados	As bases selecionadas para esta pesquisa foram a SciElo® e o Google Scholar®. As strings de busca foram montadas considerando as características de cada base de dados. Além disso, a alternância de idiomas foi utilizada como estratégia para ampliar a recuperação de resultados. A seguir, são apresentadas as expressões de busca utilizadas, considerando as pesquisas direcionadas ao resumo (abstract), nas palavras-chave e ao corpo do texto. **SciElo:** (*inteligência artificial) OR (*padrões de aprendizagem) OR (*Aprendizado de máquina). Foram recuperados 61 documentos.

continua

continuação

	Google Scholar: ((Identification "patterns of learning") AND ("AI-based" education)). Foram encontrados 107 resultados. Foram utilizados filtros para reduzir e direcionar a quantidade de documentos recuperados. Esses filtros estavam relacionados à área temática e ao ano de publicação dos materiais.
Atividade 3 Organização das bibliografias	Para organização das bibliografias, foi utilizado o software gratuito e de código aberto Zotero®, um dos mais populares assistentes de pesquisa, coleta e gerenciamento e organização de referências bibliográficas.
Atividade 4 Seleção padronizada dos artigos	Nesta etapa, por meio da leitura dos títulos, resumos (abstract) e palavras-chave de cada artigo, realizou-se de uma nova seleção com base na aderência ao tema de pesquisa, resultando em um total nova quantia somada de 38 artigos. Uma nova e segunda filtragem foi realizada, levando em consideração ao acesso na integra e de forma gratuita chegamos na quantidade de 31 artigos.
Atividade 5 Composição do portfólio	Nesta etapa, foi realizado a leitura dos materiais na íntegra, e materiais sem aderência a proposta da pesquisa foram retirados, resultando na quantidade total de 17 artigos na composição do portfólio final.

Fonte: elaborado pelo autor (2026)

Os resultados obtidos nas pesquisa que resultaram no portfólio final, além das demais informações sobre o processo de seleção podem ser vistos no quadro 2.

Quadro 2 - Atividades e números de documentos selecionados

Busca nas bases de dados	168 (61 resultados na SciElo e 107 no Google Scholar)
Documentos duplicados que foram excluídos	7
Seleção de documentos com base na leitura dos títulos, resumos e palavras-chave.	38
Número de documentos lidos integralmente	31
Seleção para o portfólio final	17

Na etapa 2, considerada como atividade 6, que resulta na analise do conteúdo selecionado para composição do portfólio final da pesquisa, foi desenvolvido uma planilha que segundo os autores Ferenhof e Fernandes (2016), intitulam de Matriz do Conhecimento, atividade capaz de auxiliar o pesquisador com uma visão sistêmica dos principais elementos abordados na revisão. Nessa planilha, foi possível comparar dados, metodologias, intervenções, principais resultados obtidos e as conclusões dos autores referentes às suas pesquisas.

Pode-se mencionar que o material revela um cenário de transição. Enquanto os estudos de engenharia de software e plataformas de aprendizagem eletrônica celebram resultados estatísticos dos algoritmos, os grupos de revisão e ensaio crítico desenvolvem um freio ético e pedagógico, apresentando ao público a necessidade de superar problemas já conhecidos, como a interação humana, os vieses algorítmicos, as alucinações na construção dos novos currículos e as propostas de padrões de aprendizagem com inteligencia artificial que contribuam de forma responsável para a formação escolar do aluno.

O portfólio final, composto por todos os artigos selecionados e suas respectivas predominâncias temáticas, pode ser visualizado no quadro 3 abaixo.

Quadro 3 - Portifólio final

Autores	Ano	Título	Temática
Arão, C.	2024	Por trás da inteligência artificial: uma análise das bases epistemológicas do aprendizado de máquina.	Análise filosófica e epistemológica da inteligência artificial e do aprendizado de máquina.
Ennibras, F. et Al.	2026	*Personalized Evaluation of Online Predictive Systems through Learner Profiles.*	Desenvolvimento e avaliação de sistemas preditivos educacionais baseados em perfis de estudantes.
Fatima, M. & Khawar, M. H.	2025	*Impact Of Ai-Based Adaptive Learning Systems On Student Engagement And Learning Outcomes.*	O impacto de sistemas de aprendizagem adaptativos baseados em IA no engajamento e no desempenho acadêmico de estudantes universitários.

continua

continuação

Fauzi, R. & Sisilia, N.	2025	*AI Integration In Learning Systems: Literature Review Analysis On Teaching Optimisation Through Virtual Tutors, Data Analysis, And Automated Educational Material Creation.*	Integração da IA em sistemas de aprendizagem com foco em tutores virtuais, análise de dados e criação automatizada de materiais por meio de tecnologias gerativas.
Grove, M.	2025	*Designing the Student Learning Journey: A Practical Approach to Integrating Generative AI within Higher Education.*	Um framework prático e programático para a integração intencional e ética da IA Generativa no currículo do ensino.
Mousa, M.	2025	*AI-Supported Formative Assessments: Enhancing Student- Centered Learning and Teacher Perceptions.*	O uso de avaliações formativas suportadas por Inteligência Artificial no contexto de um ambiente de aprendizagem centrado no aluno.
Nancy, R.	2025	*Ethical and Privacy-Preserving Framework for AI-Based Personalized Learning Systems.*	Uma estrutura ética e de preservação da privacidade para sistemas de aprendizado personalizado baseados em IA.
Nancy, R.	2025	*Intelligent Adaptive Learning Framework for Personalized Feedback and Dynamic Learning Pathways.*	Desenvolvimento de uma arquitetura de aprendizado adaptativo inteligente voltada para o fornecimento de feedback personalizado.
Nuralita, A. et Al.	2025	*Mapping Project-Based Learning E-Modules: A Bibliometric and Systematic Literature Review.*	Desenvolvimento e aplicação de e-módulos digitais integrados à metodologia de aprendizagem Baseada em Projetos.

continua

continuação

Patnaik, S.	2026	*Applications of Artificial Intelligence in Education: A Review of Learning Analytics and Open Educational Data Sources.*	Revisão de literatura sobre a aplicação e a integração de inteligência artificial e ferramentas análise de aprendizagem.
Pimentel, C. Et Al.	2025	*Integrating Machine Learning and Educational Robotics: The Frankie Platform for Teaching Artificial Intelligence in High School.*	O ensino de conceitos complexos de Aprendizado de Máquina e Inteligência Artificial para alunos do ensino médio.
Rafiq-Uz-Zaman, M.	2026	*Artificial Intelligence-based Recommendation Systems for Personalized and Adaptive Learning Resources using Learning Analytics.*	Sistemas de recomendação baseados em IA para recursos de aprendizagem personalizados e adaptativos.
Rocha, L.	2025	*An evaluation of machine learning approaches in educational environments: a systematic literature review..*	Revisão sistemática da literatura avaliando como as abordagens de aprendizado de máquina e IA estão sendo aplicadas em salas de aula inteligentes.
Sampaio, R. et Al.	2024	*ChatGPT e outras IAs transformarão a pesquisa científica: reflexões sobre seus usos.*	Reflexões sobre o impacto do ChatGPT e de Grandes Modelos de Linguagem (LLMs) na pesquisa científica.
Santos, A. et Al.	2025	*Extracting the meaning of a word: an artificial intelligence approach.*	Abordagem de IA e Processamento de Linguagem Natural (PLN) voltada para a análise textual.
Sarochar, R. & Manuel, J.	2025	*Propuesta de categorización de investigaciones sobre y aplicaciones de inteligencia artificial en educación.*	Modelo de categorização estruturado e abrangente para organizar as pesquisas acadêmicas e as ferramentas práticas de Inteligência Artificial na educação.

Fonte: elaborado pelo autor (2026)

5. Observações Gerais

Após analisar os artigos do portfólio final, foi possível compreender cenários e tendências sobre a utilização de padrões de aprendizagem com Inteligência Artificial. Segundo os autores, esses padrões tem grande potencial de otimizar o processo de ensino, aumentar o engajamento com o conteúdo e, de maneira geral, melhorar o processo de aprendizado.

5.1. Inteligência Artificial na Educação: O Panorama da Utilização dos padrões de aprendizagem

Nas revisões sistemáticas e narrativas comparadas neste estudo, podemos observar segundo os autores (NURALITA, 2025; RAFIK, 2026; RANE, 2026; ROCHA, 2025; PATNAIK, 2026), de forma quase unânime, que a inteligência artificial e a análise de aprendizagem trazem benefícios, otimizam o ensino através da personalização e são capazes de identificar dificuldades, alcançando melhorias de precisão que chegam a 15% sobre os métodos tradicionais já conhecidos.

Os autores também chamam atenção para os riscos e alertam sobre as barreiras críticas que a temática enfrenta. Mesmo apresentando benefícios claros, existe uma grande preocupação sobre problemas de privacidade de dados, viés algorítmico, plágio e exclusão digital. Para Rocha (2025) e Rafik (2026), a inteligencia artificial não substitui a necessidade de interações humanas e do desenvolvimento de habilidades socioemocionais.

Os estudos dos autores citados anteriormente utilizam de maneira predominantemente o método PRISMA (Preferred Reporting Items for Systematic reviews and Meta-Analyses) para guiar suas revisões sistemáticas. As amostras utilizam grandes bases de dados como Scopus e Web of Science, e, por se tratarem de revisões sistemáticas, não apresentam participantes diretos, mas analisam dados de estudantes desde a educação básica até o ensino superior.

5.2. O Impacto da IA na Aprendizagem: Ganhos Acadêmicos e Desafios

Para os autores (Arão, 2024; Sampaio, 2024; Sarochar e Risso 2025), por meio de estudos conceituais, qualitativos e bibliográficos, a utilização da inteligencia artificial deve ser vista com cautela. Não se pode considerar como fonte absoluta de verdade, seus resultados necessitam de acurácia e consciência humana. A necessidade de um discernimento ético é indispensável para a validação das informações pesquisadas.

Arão (2024) destaca também que o “fetichismo” tecnológico pode potencializar as limitações indutivas e estatísticas, generalizando dados amostrais e criando conclusões sistêmicas carregadas de alucinações de dados e informações falsas. Sampaio (2024) complementa em sua pesquisa que a deterioração da integridade científica e essas “alucinações”são consideradas grandes riscos ao processo.

Sarochar (2025) propõe a reflexão para novas formas de pensar o ecossistema educacional, criando dimensões onde exista a categorização das ferramentas educacionais, com foco em questões de carácter prático e dinâmico que considerem as necessidades e limitações, permitindo avançar nas construções de propostas mais completas. Dentro dessa perspectiva de pesquisas focadas no desenvolvimento, teste e validação de ferramentas e plataformas de aprendizado inteligente, os estudos de Fatima (2025), Ennibras (2026) e Nancy (2025) apresentam abordagens qualitativas, experimentais e de métodos mistos.

Através da coleta de dados digitais de logs educacionais (LMS) durante períodos de estudo, foi extraído informações importantes de acessos, linhas de interesse e tempo de permanência. Para Nancy (2025) a saltos na acurácia de quizzes de (78% para 88%) o que também contribuiu para a conclusão de tarefas nesta estrutura adaptativa e segundo Fatima (2025) houve um aumento de (+19,7%) nas notas de testes enquanto o engajamento registra aumentos que chegam a (28,6%), comprovando através dessas estatísticas robustas a melhoria acadêmica com ganhos quantificáveis.

5.3. O Design Educacional e a Proposta de Integração Curricular da IA

Através desta revisão sistemática, foi possível identificar que diversos autores defendem a necessidade da reformulação dos currículos e das práticas pedagógicas. Grove (2025) propõe um conjunto de ferramentas e diretrizes capazes de estruturar a grade curricular em créditos garantidos, nos quais cerca de um terço deve ser desenvolvido sem o uso de inteligência Artificial, buscando assegurar a aprendizagem independente da utilização da ferramenta. As demais porcentagens se dividem em créditos exploratórios, complementando a totalidade do currículo amplo.

Para Mousa (2025), os professores, de maneira geral, possuem uma percepção altamente positiva em relação a inteligencia artificial (média 92,79), destacando-a como uma ferramenta que otimiza o tempo, auxilia na formulação de exercícios e atividades, sendo um importante recurso para avaliações formativas. No estudo de Pimentel (2025), os alunos apresentaram resultados positivos com o uso de robótica educativa, através da plataforma Frankie, e o algoritmo WISARD auxiliaram para os mesmos atingirem proficiência no entendimento de redes neurais, superando os desafios da programação.

Em suma, a tecnologia utilizada por meio da integração e identificação dos padrões de aprendizagem comprovou através de dados matemáticos, que a personalização do currículo, traz benefícios ao processo de aprendizagem. Contudo, a comunidade cientifica concentra seus esforços em criar barreias éticas, e de novos modelos de ensino que garantam que os alunos consigam pensar por si mesmos, sendo a tecnologia uma importante ferramenta de ampliação cognitiva e não uma substituta do pensamento.

6. Considerações Finais

Levando em consideração os estudos apresentados nessa revisão sistemática, este artigo buscou melhor compreender como a inteligência artificial pode contribuir para a personalização da aprendizagem, por meio desta pesquisa foi possível analisar quais as principais questões em torno da utilização da inteligencia artificial na identificação de padrões de aprendizagem na educação.

Além disso, buscou-se identificar quais as principais intervenções, preocupações e quais os resultados apresentados pelos autores através do material desta revisão. Para atingir os objetivos deste trabalho buscou-se responder às questões que direcionaram a pesquisa, conforme apresentado no quadro 4.

Quadro 4 - Principais revelações sobre as questões de pesquisa

Questões	Revelações
Quais são as principais intervenções utilizadas nos padrões de aprendizagem utilizando IA na educação?	• Implementação de sistemas adaptativos de aprendizagem baseados em inteligência artificial. • Propostas de categorização das pesquisas e aplicações da inteligência artificial na educação. • Desenvolvimento e avaliação personalizada de sistemas preditivos educacionais. • Plataforma de aprendizagem personalizada que combina análise de dados comportamentais, feedback adaptativo e algoritmos de IA.
Quais são as principais preocupações relacionadas à utilização dos padrões de aprendizagem com inteligência artificial?	• Necessidade de um modelo de categorização mais claro e estruturado para organizar as pesquisas e aplicações de IA na educação. • A IA não deve ser vista como fonte absoluta de verdade ou racionalidade objetiva, mas como uma construção humana, carregada de limitações, subjetividades e vieses. • Métricas globais de desempenho, podem ser insuficientes, pois mascaram vieses e falhas do modelo em subgrupos específicos de estudantes. • As instituições de ensino devem evoluir de políticas puramente reativas (focadas apenas em segurança da avaliação e detecção de plágio) para um design curricular intencional e transparente. • Embora a IA ofereça excelentes ferramentas, ela não é capaz de substituir as habilidades humanas socioemocionais, como comunicação, criatividade, liderança, relacionamento interpessoal e pensamento crítico.

continua

continuação

Que tipo de resultados têm sido observados com a utilização dos padrões de aprendizagem com IA?	• A integração com a inteligência artificial promove uma mudança do modelo de ensino unidirecional para um ecossistema centrado no aluno, sendo mais responsivo e inclusivo. • Aumento do engajamento, da motivação e do desempenho acadêmico dos estudantes. • Potencial para promover a aprendizagem ativa, contextualizada e centrada no estudante. • Soluções inteligentes de aprendizagem adaptativa, tornando os ambientes de educação digital muito mais eficazes.

Fonte: elaborado pelo autor (2026)

Conforme apresentado nos quadros 2 e 4, foram identificados 17 artigos. Esses estudos foram divididos em quatro grandes grupos, a fim de organizar, facilitar o entendimento e permitir a categorização do material. No primeiro grupo (revisões sistemáticas e revisões narrativas), encontram-se estudos que sintetizam a literatura, buscando mapear o estado da arte, e identificar tendências, benefícios e riscos do uso da inteligência artificial na educação.

O segundo grupo reúne estudos de natureza teórica, conceitual e documental, que avaliam o impacto social e as bases epistemológicas da inteligência artificial. No terceiro grupo apresentam-se as pesquisas focadas no desenvolvimento, teste e validação de ferramentas, algoritmos e frameworks de aprendizagem inteligente. No quarto e último grupo, foi possível observar propostas de metodologias ativas, voltadas à estruturação da grade curricular e às questões éticas relacionadas à sua implementação.

Por fim, foi identificado um artigo que ficou fora do escopo específico da pesquisa. Quando selecionado, o objetivo era compreender como a combinação de modelos de linguagem e redes neurais poderia melhorar o desempenho e a classificação das pesquisas. Entretanto após a seleção e comparação de todos os artigos, o estudo intitulado (Extracting the meaning of a word: an artificial intelligence approach) permaneceu isolado perante aos demais trabalhos analisados. Embora represente uma contribuição para o tema, sua relevância mostrou-se menor quando comparada à dos demais artigos.

Entre as principais intervenções identificadas nos padrões de aprendizagem da Inteligência Artificial aplicadas ao ensino, destaca-se o uso de plataformas de ensino personalizadas. Essas plataformas viabilizam a análise de dados comportamentais e o fornecimento de feedbacks adaptativo, resultando em avaliações personalizadas por meio de sistemas preditivos. Além disso, permitem a categorização de pesquisas relacionadas aos sistemas adaptativos de aprendizagem.

Como principais preocupações relacionadas ao uso dos padrões de aprendizagem, destaca-se a necessidade de avanços em politicas públicas e institucionais que estabeleçam modelos de categorização mais claros e estruturados, auxiliando as pesquisas de forma mais organizada e eficaz. As métricas globais de desempenho, podem mascarar falhas e vieses, mostrando-se

insuficientes para uma visão sistêmica de todo o processo.

Outro ponto de atenção recorrente nos estudos refere-se à necessidade de não considerar a utilização da inteligência artificial como uma fonte de verdades absolutas ou de resultados totalmente objetivos. Pelo contrário, trata-se de um processo, em constante desenvolvimento, sujeito a limitações e desafios, não sendo capaz de substituir as habilidades humanas e nem seu pensamento crítico.

Entre os principais resultados da utilização dos padrões de aprendizagem com inteligência artificial apresentados nesta revisão sistemática, destacam-se o aumento do engajamento, da motivação e do desempenho acadêmico. Essa abordagem também é responsável por promover reflexões e propostas de mudança no modelo atual de ensino, transformando o espaço pedagógico em um ecossistema centrado no aluno e favorecendo a aprendizagem ativa em ambientes mais responsivos e inclusivos.

Como limitação desta pesquisa, podem ser consideradas a escolha das bases de dados, o período de revisão e a seleção dos operadores e palavras-chave que compuseram o processo de pesquisa. Esses fatores podem influenciar os resultados e as características dos materiais selecionados. Como possibilidade para trabalhos futuros, sugere-se a descrição dos processos e métodos de maneira mais clara e objetiva, a fim de apresentar um melhor embasamento das ações necessárias à sua implantação, auxiliando interessados a compreender como operacionalizar a utilização de padrões de aprendizagem com inteligência artificial na educação.

7. Referências

Alom, Md Z.; Taha, T. M.; Yakopic, C.; Westberg, S.; Sidike, P.; Nasrin, S.; Hasan, M.; Essen, B. C. V.; Awwal, A. A. S. & Asari, V. K. A State-of-the-Art Survey on Deep Learning Theory and Architectures. **Electronics**, [s. l.], v. 8, n. 3, p. 292, mar. 2019. Disponível em: https://doi.org/10.3390/electronics8030292. Acesso em: 9 maio 2026.

Arão, C. Por trás da inteligência artificial: uma análise das bases epistemológicas do aprendizado de máquina. **Trans/Form/Ação**, [s. l.], v. 47, e02400163, 2024. Disponível em: https://www.scielo.br/j/trans/a/wKP3thTz35fmhG9pnmXNdMj/?lang=pt. Acesso em: 31 maio 2026.

Baltar, R. **Professores serão substituídos pela inteligência artificial?** LinkedIn, 2023. Disponível em: https://www.linkedin.com/pulse/professores-ser %C3%A3o-substitu%C3%ADdos-pela-intelig%C3%AAncia-ronaldo-baltar. Acesso em: 9 maio 2026.

Brasil. Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). **Portaria CNPq nº 2.664, de 6 de março de 2026**. Institui a Política de Integridade na Atividade Científica do CNPq. Diário Oficial da União: seção 1, Brasília, DF, ed. 47, p. 4, 11 mar. 2026. Disponível em: https://memoria2.cnpq.br/web/guest/view/-/journal_content/56_INSTANCE_0oED/10157/23142775COMPANY_ID=10132. Acesso em: 19 maio 2026.

Cerri, R., & Carvalho, A. C. P. de L. F. de. (2019). Aprendizado de máquina: breve introdução e aplicações. **Cadernos De Ciência & Tecnologia**, 34(3), 297–313. Disponível em: https://doi.org/10.35977/0104-1096.cct2017.v34.26381. Acesso em: 10 maio 2026.

CIEB - CENTRO DE INOVAÇÃO PARA A EDUCAÇÃO BRASILEIRA. **Notas técnicas #16: inteligência artificial na educação**. São Paulo: CIEB, 2019. Disponível em: https://cieb.net.br/wp-content/uploads/2019/11/CIEB_Nota_Tecnica16_nov_2019_digital.pdf. Acesso em: 03 maio. 2026.

Domingos, P. **The master algorithm: how the quest for the ultimate learning machine will remake our world.** New York, Basic Books, 2015.

Ennibras, F.; Bouihi, B.; Aasri, R. E.; Aoula, E. & Bousselham, A. Personalized Evaluation of Online Predictive Systems through Learner Profiles. **Engineering, Technology & Applied Science Research**, v. 16, n. 2, p. 32876–32882, 4 abr. 2026.

Faceli, K.; Lorena, A. C.; Gama, J. ; Carvalho, A. C. P. L. F. de. **Inteligência artificial:** uma abordagem de aprendizado de máquina. Rio de Janeiro: LTC, 2011.

Fatima, M. & Khawar, M. H. Impact of AI-based adaptive learning systems on student engagement and learning outcomes. **Spectrum of Engineering Sciences**, [s. l.], v. 3, n. 12, p. 317–340, 13 dez. 2025. Disponível em: https://thesesjournal.com/index.php/1/article/view/1646. Acesso em: 04 maio 2026.

Fatima, R. & Sisilia, N. AI integration in learning systems: literature review analysis on teaching optimisation through virtual tutors, data analysis, and automated educational material creation. **Indonesian Journal of Education** (INJOE), [s. l.], v. 5, n. 1, p. 265–277, 16 dez. 2025. Disponível em: https://felifa.net/index.php/INJOE/article/view/349. Acesso em: 10 maio 2026.

Ferenhof, H. A. & Fernandes, R. F. Desmistificando a revisão de literatura como base para redação científica: método SSF. **Revista ACB:** Biblioteconomia em Santa Catarina, Florianópolis, 2016, v. 21, n.3. Disponível em: https://revista.acbsc.org.br/racb/article/view/1194/pdf. Acesso em: 02 de mai. 2026.

Gabriel, M. **Educação na Era Digital.** 2. ed. São Paulo: Atlas, 2023.

Grove, M. Designing the Student Learning Journey: A Practical Approach to Integrating Generative AI within Higher Education. **MSOR Connections**, v. 24, n. 1, 14 nov. 2025.

Mousa, M. AI-supported formative assessments: enhancing student-centered learning and teacher perceptions. **Journal of Pedagogy and Education Science**, [s. l.], v. 4, n. 2, p. 127–141, 10 abr. 2025. Disponível em: https://doi.org/10.56741/jpes.v4i02.857. Acesso em: 11 maio 2026.

Nancy, R. Ethical and Privacy-Preserving Framework for AI-Based Personalized Learning Systems. **Engineering Research**, v. 2, n. 01, p. 15–15, 2025.

Nancy, R. Intelligent Adaptive Learning Framework for Personalized Feedback and Dynamic Learning Pathways. **Engineering Research**, v. 2, n. 2, 2025.

Nuralita, A. D. A.; Shubali, B.; Nugroho, S. E.; Wiyanto, W. & Yusof, M. M. M. Mapping Project-Based Learning E-Modules: A Bibliometric and Systematic Literature Review. **Jurnal Inovasi Pendidikan IPA**, v. 11, n. 2, p. 418–434, 20 out. 2025.

Oliveira, R. N. D. & Santos, D. P. A. Uso da inteligência artificial na educação: uma revisão integrativa das publicações de 2023 e 2024 na Revista Brasileira de Informática na Educação. Recite – **Revista Carioca de Ciência Tecnologia e Educação**, 2024. Disponível em: https://www.semanticscholar.org/paper/e6acca426b7a5012b52bb83ec43a61342f3fc0d5 . Acesso em: 02 mai. 2026.

Patnaik, S. Applications of Artificial Intelligence in Education: A Review of Learning Analytics and Open Educational Data Sources. **International Journal of Elite Research and Innovation**, v. 1, n. 1, p. 45–54, 13 abr. 2026.

Pereira, A. C. P. (2018). O uso da inteligência artificial na educação: possibilidades e limitações. **Revista de Inovação**, Tecnologia e Educação, São Paulo, v. 5, n. 1, jan./jun. from https://revistaeixo.ifs p.edu.br/index.php/RTE/article/view/273/197. Acesso em: 05 maio 2026.

Pereira, A. S.; Shitsuka, R.; Parreira, F. J. & Shitsuka, D. M. **Metodologia da pesquisa científica**. 1. ed. Santa Maria: Núcleo de Tecnologia Educacional da Universidade Federal de Santa Maria, 2018. Disponível em: https://repositorio.ufsm.br/handle/1/15824. Acesso em: 02 maio 2026.

Pimentel, C. S. & Sampaio, F. F. Integrating machine learning and educational robotics: the Frankie platform for teaching artificial intelligence in high school. **Sisyphus - Journal of Education**, [s. l.], v. 13, n. 2, p. 79–110, out. 2025. Disponível em: https://scielo.pt/scielo.php?script=sci_abstract&pid=S2182-84742025000300079&lng=pt&nrm=iso&tlng=en. Acesso em: 10 maio 2026.

Rafiq-Uz-Zaman, M. AI-driven competency-based education: shaping lifelong learning and skill acquisition in dynamic educational environments. **Artificial Intelligence in Lifelong and Life-Course Education**, [s. l.], v. 1, n. 1, p. 61–77, 20 jan. 2026. Disponível em: https://journal.abcollab.id/index.php/AILLCE/article/view/29. Acesso em: 7 maio 2026.

Rane, N. Artificial Intelligence-based Recommendation Systems for Personalized and Adaptive Learning Resources using Learning Analytics. Rochester, **NYSocial Science Research Network**, 16 fev. 2026. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=6372318. Acesso em: 17 maio 2026.

Risso, J. M. S. Propuesta de categorización de investigaciones sobre y aplicaciones de inteligencia artificial en educación. **Cuadernos de Investigación Educativa**, [s. l.], v. 16, n. 1, p. 1–?, 2025. Disponível em: https://doi.org/10.18861/cied.2025.16.1.3955. Acesso em: 10 maio 2026.

Rocha, L. A. An evaluation of machine learning approaches in educational environments: a systematic literature review. Texto Livre, v. 18, p. e54910, 2025. Disponível em: https://periodicos.ufmg.br/index.php/textolivre/article/view/54910. Acesso em: 10 maio 2026.

Russel, S. & Norvig, P. **Artificial Intelligence**: A Modern Approach. 4th. ed. Upper Saddle River: Pearson, 2016.

Sampaio, R. C.; Nicolás, M. A.; Junquilho, T. A.; Silva, L. R. L; Freitas, C. S. de; Telles, M.; Teixeira, J. S.; Escóssia, F. & Santos, L. C. dos. ChatGPT e outras IAs transformarão a pesquisa científica: reflexões sobre seus usos. **Revista de Sociologia e Política**, v. 32, p. e008, 2024.

SANTOS, A. P. dos; Oliveira, E. A. S.; Pirovani, J. P. C. & Oliveira, E. Extracting the meaning of a word: an artificial intelligence approach. **Transinformação**, v. 37, e2514829, 2025. Disponível em: https://doi.org/10.1590/2318-0889202537e2514829. Acesso em: 10 maio 2026.

Valente, J. Inovação nos processos de ensino e de aprendizagem: o papel das tecnologias digitais. In: Valente, J. A.; Freire, F.-M. -P.; Arantes, F. L., (org.). **Tecnologia e educação:** passado, presente e o que está por vir. Campinas: NIED/Unicamp, 2018. p. 17-41.

Vicari, R. M. **Inteligência artificial aplicada à educação**. Disponível em: https://ceie.sbc.org.br/livrodidatico/index.php/inteligenciaartificial/. Acesso em: 2 maio 2026.

Sobre o autor(a)

Dionatan Carlos de Souza

Mestrando em Tecnologias da Informação e Comunicação pelo Programa de Pós-graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina (UFSC).

Especialista em Educação Profissional pelo Instituto Federal de Santa Catarina (IFSC - 2020) e em Docência para o Ensino Superior pelo Centro Universitário Leonardo Da Vinci (Uniasselvi - 2013).

Graduado em Design de Moda pela Universidade do Sul de Santa Catarina (Unisul - 2009).

Professor do Ensino Básico, Técnico e Tecnológico no Instituto Federal de Santa Catarina (IFSC) - Campus Araranguá

Lattes: http://lattes.cnpq.br/7232477187942359

CAPÍTULO 4

Learning Analytics e IA na gestão da aprendizagem: uma revisão sistemática da literatura

Jardel Batista Gonçalves

1. Introdução

Nas ultimas décadas, a infraestrutura das instituições de ensino passou por uma reconfiguração estrutural profunda. Os Ambientes Virtuais de Aprendizagem (AVA) e os Sistemas de Gestão de Aprendizagem, que historicamente serviam como meros repositórios de apoio extraclasse, assumiram o protagonismo da rotina educativa. Na prática, essas plataformas operam como bases de monitoramento contínuo, capturando sistematicamente desde o acesso a materiais ate as trocas de mensagens entre alunos e professores (Long & Siemens, 2011).

Embora essa transição digital já estivesse em curso no setor, as medidas de isolamento da pandemia de COVID-19 impuseram uma adoção imediata ao formato remoto. Como consequÊncia, acompanhar o percurso dos estudantes no meio digital deixou de ser uma inovação opcional para se tornar uma necessidade básica da gestão acadêmica (Yan et al., 2024b).

Estamos lidando, portanto, com um verdadeiro "ecossistema de dados educacionais". Cada nota lançada, mensagem no fórum, tempo de leitura e tentativa de avaliação gera um rastro digital valioso. A grande dificuldade agora não e mais coletar essa informação, mas sim descobrir o que fazer com ela. Como transformar esse mar de registros em ações concretas que realmente melhorem a sala de aula e os resultados dos alunos?

E exatamente essa lacuna que o campo do *Learning Analytics* (LA) tenta preencher. Com a incorporação das técnicas de Inteligência Artificial (IA), essa área ganhou uma força adicional. Hoje já conseguimos, por exemplo, rodar modelos preditivos para alertar se um aluno corre risco de evasão muito antes de isso acontecer. Al em disso, sistemas recomendam trilhas de estudo personalizadas, algoritmos processam textos em massa e dashboards traduzem toda essa matemática complexa em gráficos fáceis para os docentes interpretarem (Ouhaichi; Spikol & Vogel, 2023; Yan et al., 2024b).

O foco de toda essa tecnologia deve ser a gestão da aprendizagem. Entendemos esse conceito como as práticas, processos e decisões que escolas, professores e os próprios alunos tomam para guiar o ensino até os objetivos esperados. Ou seja, a IA e o LA não servem como fins em si mesmos, eles são apenas instrumentos a serviço de uma gestão mais informada e justa.

Diante de tudo isso, o problema de pesquisa que norteia esta revisão é: de que modo o LA e a IA tem sido aplicados na prática para gerir a aprendizagem, e quais os reais benefícios, limitações e desafios éticos apontados pela ciência hoje? Para responder a essa questão, o objetivo geral deste estudo é conduzir uma revisão sistemática da literatura sobre o uso de LA e IA na gestão educacional.

De forma mais específica, este estudo busca: (A) Identificar e sistematizar as principais aplicações práticas de LA e IA documentadas na literatura na gestão da aprendizagem; (B) Analisar as técnicas de IA mais frequentes na educação e os resultados que entregam; (C) Investigar os principais benefícios e desafios técnicos e pedagógicos dessas abordagens; (D) Discutir os desafios éticos, especialmente no trato e proteção dos dados dos estudantes; (E) Apontar tendências emergentes e lacunas que ainda demandam pesquisas futuras.

2. Fundamentação Teórica

Esta seção estabelece as bases teóricas do estudo. O texto apresenta os fundamentos do LA e da IA, detalha a aplicação dessas tecnologias na gestão da aprendizagem e, por fim, discute os desafios éticos envolvidos no tratamento de dados estudantis.

2.1. Learning Analytics

O marco conceitual do LA remete as discussões da *International Conference on Learning Analytics and Knowledge* (LAK) de 2011. Naquela ocasião, Long e Siemens (2011) delimitaram a área como a prática de medir, coletar, analisar e relatar os dados dos estudantes com um fim bastante específico: otimizar as próprias condições e ambientes de ensino. Convém, no entanto, traçar uma linha divisória em relação à Mineração de Dados Educacionais (EDM). A fronteira entre elas está no objetivo final. A EDM prioriza o refinamento dos métodos de extração computacional (Siemens & Baker, 2012). O LA assume uma postura essencialmente prática, focada na aplicação pedagógica imediata dessas métricas.

O campo começou a se estruturar no início dos anos 2000, quando os AVAs se expandiram e pesquisadores passaram a se basear nos estudos de EDM (Romero; Ventura & Garcia, 2008). Conforme aponta Siemens (2013), o campo tornou-se uma área de estudo própria na década de 2010, dividida em níveis. Recentemente, o período entre 2020 e 2026 marcou a fase de maior aceleração da área. A pandemia forçou a digitalização do ensino, enquanto a popularização dos Grandes Modelos de Linguagem (LLMs), a partir do final de 2022, inaugurou aplicações muito

mais sofisticadas, como tutores conversacionais e análises profundas de textos em grande volume (Yan et al., 2024b).

Para operar, os sistemas de LA rastreiam indicadores práticos, como frequência de acesso, tempo de tela, taxa de conclusão de tarefas e padrões de interação nos fóruns (Yan et al., 2024a). Estudos indicam que analisar esses dados digitais corretamente traz grandes vantagens. Como apontam Yan et al. (2024a), essa prática ajuda a evitar a evasão escolar ao permitir ações rápidas, aumenta o interesse dos alunos por meio do ensino personalizado e da aos professores uma visão clara sobre a evolução das turmas.

Apesar de todo esse potencial, a adoção real do LA ainda enfrenta barreiras consideráveis. Na prática, poucas instituições utilizam ferramentas preditivas de forma sistemática para identificar alunos em risco (Ouhaichi; Spikol & Vogel, 2023). O abismo entre ter a tecnologia e usá-la pedagogicamente mostra que o avanço puramente algorítmico não basta. Para que o LA funcione de verdade no dia a dia das escolas, é preciso vencer barreiras como a falta de computadores e internet, a dificuldade dos professores em entender os dados e a resistência em mudar a rotina. Além disso, Yan et al. (2024a) destacam que o maior desafio está nas complexas questões éticas e de privacidade dos estudantes.

2.2. Inteligência Artificial na Educação

A entrada da IA no ambiente educacional não é recente; ela começou há décadas com os Sistemas Tutores Inteligentes (STI). A arquitetura clássica dessas ferramentas dependia de quatro módulos básicos: o domínio do conhecimento, o modelo do estudante, a pedagogia e a interface (Yan et al., 2024a). O cenário mudou radicalmente quando o LA foi acoplado a esses sistemas. O Machine Learning (ML) substituiu regras estáticas por adaptação em tempo real.

Algoritmos supervisionados passaram a classificar e prever o desempenho dos alunos (Romero; Ventura; Garcia, 2008), enquanto técnicas não supervisionadas começaram a agrupar turmas por padrões de comportamento (YAN et al., 2024a). O ganho de precisão foi imediato. A aplicação de redes convolucionais em logs do Moodle, por exemplo, superou a acurácia de modelos mais antigos (Ouhaichi; Spikol & Vogel, 2023).

O salto técnico seguinte envolveu a interpretação de textos. O Processamento de Linguagem Natural (PLN) permitiu aos sistemas analisar redações, mapear discussões em fóruns e até inferir o estado motivacional do aluno (Ouhaichi; Spikol & Vogel, 2023). Essa capacidade explodiu no final de 2022 com a IA Generativa e o ChatGPT. Alimentados por LLMs, os tutores computacionais ganharam a habilidade de dialogar e redigir feedbacks narrativos que, em tarefas específicas, se equiparam a avaliação humana (Ouhaichi; Spikol & Vogel, 2023).

Hoje, a literatura já contabiliza mais de 53 aplicações distintas para a IA Generativa na educação, automatizando desde a criação de material didático até a interpretação de dados complexos (Yan et al., 2024b). No cotidiano da gestão pedagógica, toda essa infraestrutura

tecnológica sustenta duas frentes prioritarias. A primeira é o combate a evasão. O cruzamento de dados cria perfis preditivos que acionam a instituição muito antes de o aluno abandonar o curso de fato (Siemens & Baker, 2012). A segunda frente e a personalização do ensino. Motores de recomendação utilizam filtragem colaborativa e análise de conteúdo para sugerir materiais específicos. O resultado e a substituição de um currículo rígido por percursos de aprendizagem ajustados as necessidades imediatas de cada estudante (Yan et al., 2024b).

2.3. Gestao da Aprendizagem com Suporte de Dados

A gestao da aprendizagem contemporânea baseia-se na integração entre IA e o monitoramento contínuo de dados analíticos. Ferramentas como os STI, amparadas por arquiteturas que envolvem modelos de domínio e do estudante, permitem que o suporte pedagógico seja automatizado e personalizado (Yan et al., 2024a). Com o aporte do ML e do PLN, plataformas como o Moodle deixaram de ser simples repositórios para se tornarem sistemas capazes de prever o desempenho acadêmico com alta precisão (Ouhaichi; Spikol & Vogel, 2023). Essa infraestrutura técnica permite rastrear desde indicadores básicos de acesso e tempo de engajamento até análises semânticas complexas em fóruns e redações, especialmente com o advento da IA Generativa e dos LLMs (Yan et al., 2024a).

Os dashboards educacionais conectam os dados coletados às decisões do professor. Esses painéis transformam métricas complexas em gráficos acionáveis, permitindo que docentes acompanhem o progresso dos alunos nas trilhas de aprendizagem e avaliem os resultados curriculares em tempo real (Yan et al., 2024a). Na gestão operacional, o uso de alertas automatizados de risco acadêmico permite que coordenadores e professores ajam precocemente sobre padrões de comportamento associados a evasão, como a queda na regularidade de acesso ou o baixo desempenho em avaliações formativas (Yan et al., 2024a).

Em ultima análise, a gestão orientada por evidências altera a ecologia da sala de aula virtual, deslocando o foco de avaliações pontuais para um acompanhamento processual (Yan et al., 2024a). Sistemas de recomendação e modelos adaptativos viabilizam percursos personalizados, sugerindo recursos de acordo com o perfil de cada estudante. Contudo, a eficácia dessas ferramentas depende da compreensão de que os dados não substituem o julgamento docente, mas o complementam. Conforme alertam Long e Siemens (2011), a analítica não deve promover soluções genéricas, pois o sucesso acadêmico e influenciado por contextos e culturas específicas que exigem uma interpretação humana e situada dos achados tecnológicos.

2.4. Aspectos Eticos do Learning Analytics

A coleta massiva de informações estudantis esbarra diretamente em questões de consentimento. O aluno raramente tem dimensão da quantidade de informações capturadas pelas plataformas educacionais. Detalhes sobre o tempo de retenção e o propósito exato dessas métricas costumam

passar despercebidos por eles (Maretto & Barcellos, 2023). Essa coleta passiva colide diretamente com a Lei Geral de Proteção de Dados Pessoais (LGPD). Para se adequar a legislação brasileira, as instituições estão precisando alterar suas normas internas. O cenário atual obriga as escolas e universidades a aplicar técnicas de anonimização e a coletar autorizações explícitas e inequívocas dos usuários (Maretto & Barcellos, 2023).

No nível algorítmico, o risco principal reside no treinamento dos modelos. Sistemas de ML alimentados por históricos educacionais tendem a espelhar e amplificar desigualdades estruturais preexistentes. Isso pode criar um ciclo vicioso onde grupos marginalizados recebem predições enviesadas e, consequentemente, menos recursos (Yan et al., 2024a). Para evitar preconceitos ou erros nos sistemas, Yan et al. (2024a) defendem que é necessário avaliar se os algoritmos são justos e utilizar dados mais variados. O problema fica ainda pior devido a falta de transparência da tecnologia, já que modelos complexos e LLMs costumam funcionar como "caixas-pretas": eles trazem previsões, mas não explicam o caminho que usaram para chegar até aquela resposta.

Olhando pelo lado do comportamento e do ensino, acompanhar o aluno a cada segundo na internet pode acabar se transformando em uma vigilância digital exagerada e perigosa. O monitoramento excessivo pode instaurar um ambiente de controle absoluto que sufoca a autonomia e a autenticidade do aluno (Yan et al., 2024a). A fronteira entre o apoio instrucional e a invasão de privacidade é bastante frágil. Por isso, a concepção dessas plataformas precisa envolver ativamente os estudantes na definição dos limites de automação. A literatura recente recomenda que os princípios de segurança e transparência moldem o design estrutural dos sistemas desde a prancheta, em vez de serem tratados como simples correções posteriores (Yan et al., 2024a).

3. Metodologia

Esta pesquisa possui natureza qualitativa e exploratória, conduzida sob o formato de uma Revisão Sistemática da Literatura (RSL). O método foi escolhido para mapear o uso de LA e IA na gestão da aprendizagem de forma rigorosa e replicável. Ao contrário de um levantamento narrativo livre, a RSL obriga o pesquisador a definir previamente suas perguntas, termos de busca e filtros de seleção. Esse rigor técnico minimiza viéses e garante a transparência de toda a coleta de dados (Ercole; Melo & Alcoforado, 2014).

O processo de triagem e seleção dos estudos foi realizado por meio do Rayyan (Ouzzani et al., 2016), uma plataforma projetada para conferir agilidade e rigor sistemático à fase de seleção bibliográfica, permitindo a gestão eficiente dos critérios de inclusão e exclusão.

3.1. Questões de Pesquisa

A RSL foi orientada pelas seguintes questões de pesquisa:

- **QP1**: Como LA e IA vêm sendo aplicados na gestão da aprendizagem em instituições educacionais?

- **QP2**: Quais técnicas de IA são mais frequentemente empregadas em sistemas de LA e quais resultados têm produzido?
- **QP3**: Quais são os principais benefícios e desafios técnicos, pedagógicos e éticos identificados na literatura sobre o uso de LA e TA na gestão da aprendizagem?
- **QP4**: Quais tendências emergentes e lacunas de pesquisa podem ser identificadas no campo de LA e TA na educação?

3.2. Bases de Dados Utilizadas

Para a realização do levantamento bibliográfico, foram utilizadas as seguintes bases de dados:

- **Scopus** (https://www.scopus.com): acervo multidisciplinar focado em artigos revisados por pares.
- **IEEE Xplore** (https://ieeexplore.ieee.org): literatura especializada em computação.

3.3. String de Busca

A fim de mapear a literatura com precisão, a estratégia de extração foi consolidada em uma frente linguística unificada em língua inglesa, visando abranger a indexação global dos repositórios selecionados. Os descritores foram organizados por meio de operadores booleanos, cruzando os conceitos centrais da tecnologia e do seu impacto prático na educação.

A equação base foi estruturada da seguinte forma:

("Learning Analytics" OR "Educational Analytics")
AND
("Artificial Intelligence" OR "Machine Learning" OR "Deep Learning" OR "Natural Language Processing")
AND
("Learning Management" OR "Academic Performance" OR "Student Dropout" OR "Personalized Learning" OR "Educational Dashboard" OR "At-risk Students")

3.4. Critérios de Inclusão e Exclusão

A seleção dos estudos obedeceu a cinco critérios obrigatórios. Para compor a amostra final, o trabalho precisava atender cumulativamente aos seguintes pontos:

- **CI1**: Publicação entre janeiro de 2020 e maio de 2026;
- **CI2**: Validação por pares (artigos em periódicos científicos ou trabalhos completos em anais de conferências);
- **CI3**: Foco central na aplicação de LA e IA no ecossistema educacional;

- **CI4:** Escrita nos idiomas português, inglês ou espanhol;
- **CI5:** Disponibilidade do texto na íntegra (seja por acesso aberto ou institucional).
- **CI6:** Relevância acadêmica mínima, atestada por ao menos 10 citações registradas nas próprias bases selecionadas.

Por outro lado, o processo de triagem descartou qualquer material que esbarrasse em pelo menos um destes filtros:

- **CE1**: Duplicatas ou versões preliminares de pesquisas já contabilizadas na versão final;
- **CE2**: Indisponibilidade de leitura do texto completo, mesmo após tentativas de recuperação legítimas;
- **CE3**: Aplicações fora do escopo escolar ou acadêmico (como o uso de LA em setores corporativos ou de saúde sem cruzamento com a educação);
- **CE4**: Formatos desprovidos de rigor metodológico detalhado (como editoriais, cartas ao editor ou resumos simples de eventos);
- **CE5**: Pesquisas estritamente tecnológicas ou algorítmicas que não discutissem implicações práticas para a gestão da aprendizagem.

3.5. Processo de Seleção

A seleção dos artigos ocorreu em quatro fases progressivas de filtragem, conforme detalhado a seguir:

- **Etapa 1 (Busca e remoção de duplicatas):** A execução da string de busca nas bases selecionadas retornou 181 resultados iniciais. Após o cruzamento de títulos e autores para a eliminação de ocorrências repetidas, restaram 171 registros únicos para análise.
- **Etapa 2 (Triagem de títulos e resumos):** Nessa etapa, as informações principais e os resumos dos artigos foram avaliados com base nas regras de seleção da pesquisa. Foram descartados 149 trabalhos que fugiam do assunto ou não tratavam diretamente da gestão da aprendizagem, restando apenas 22 artigos para a análise final.
- **Etapa 3 (Leitura integral):** Os 22 documentos remanescentes foram submetidos ao exame completo de seu conteúdo. Esta análise minuciosa visou verificar se os textos apresentavam dados suficientistas e qualidade metodológica para responder às questões de pesquisa desta revisão.
- **Etapa 4 (Seleção final):** Após a leitura integral, 1 estudo foi excluído por não cumprir integralmente os requisitos de dados, fechando a amostra definitiva em 21 estudos, que compõem o corpus de análise desta pesquisa.

A Figura 1 sintetiza visualmente as quatro etapas de filtragem descritas acima, desde a

identificação inicial dos registros até a amostra final de 21 estudos.

Figura 1. Fluxograma PRISMA do Processo de Selec¸ao dos Estudos

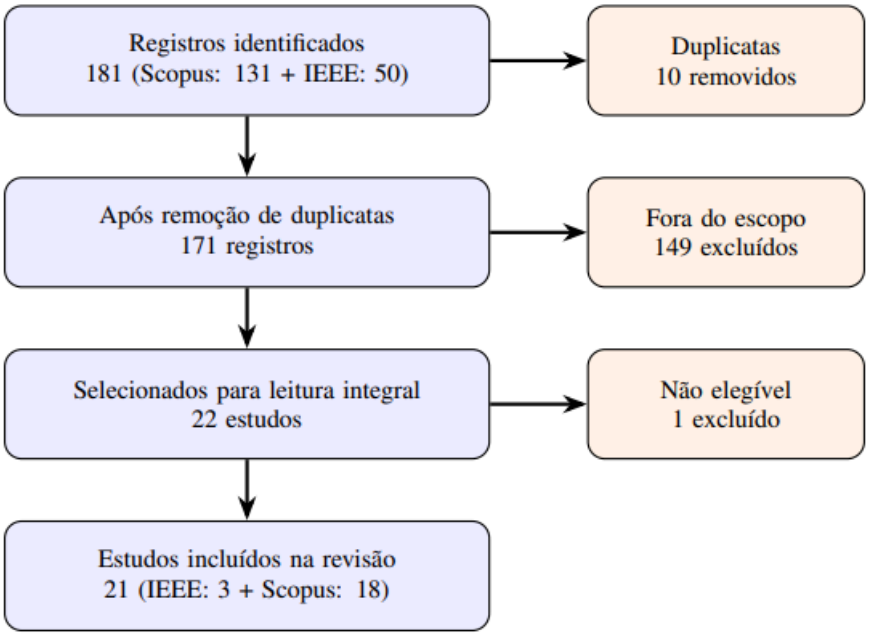

Fonte: Elaborado pelo autor (2026)

Como complemento, a Tabela 1 apresenta a evolução quantitativa da seleção dos estudos, discriminada por base de dados e etapa de filtragem.

Tabela 1 - Processo de seleção dos estudos por base de dados

Base de dados	Registros iniciais	Após duplicatas	Após título e resumo	Após leitura integral
IEEE Xplore	50	50	4	3
Scopus	131	121	18	18
Total	181	171	22	21

Fonte: Elaborado pelo autor (2026)

3.6. Declaração de Uso de Inteligência Artificial Generativa

Em conformidade com o Art. 9º, inciso I, alíneas “c”, “d” e “f” da Portaria CNPq nº 2.664, de 6 de março de 2026, que institui a política de Integridade na Atividade Científica do CNPq, declara-

se que ferramentas de IA Generativa, especificamente Gemini e Claude, foram utilizadas durante o desenvolvimento deste trabalho nas finalidades de refinamento textual e revisão linguística. Todo o material gerado com suporte dessas ferramentas foi integralmente supervisionado, revisado e validado pelo autor. Nenhum conteúdo foi submetido como se fosse de autoria humana sem verificação crítica, tampouco houve fabricação, falsificação ou manipulação de dados em qualquer etapa da pesquisa. Todas as fontes e referências bibliográficas foram verificadas manualmente. O autor assume responsabilidade integral pelo conteúdo final, inclusive por eventuais imprecisões ou plágios decorrentes do uso das ferramentas declaradas.

4. Análise e Discussão dos Resultados

A análise dos 21 artigos selecionados revela um panorama produtivo concentrado entre 2020 e 2026. Nota-se que a maioria das publicações se agrupa no biênio 2024–2025, fenômeno impulsionado pela maturidade das técnicas de ML e, fundamentalmente, pela integração da IA Generativa ao ecossistema educacional. Quanto ao rigor metodológico e temático, a amostra reflete a transição do campo para aplicações práticas e prescritivas, organizadas em seis eixos fundamentais. Predominam os estudos voltados a inovação técnica e predição (5 trabalhos) e as pesquisas sobre IA Generativa e feedback automático (4). O restante do corpus distribui-se de forma equilibrada entre intervenção pedagógica e comportamento (4), ética, justiça e proteção de dados (3), frameworks sistêmicos (3) e explicabilidade de modelos (2). Essa distribuição, detalhada na Tabela 2, sugere que o campo não apenas cresceu em volume, mas evoluiu em complexidade técnica e em uma necessária preocupação com a transparência e a justiça algorítmica

Tabela 2 - Artigos selecionados na revisão sistemática da literatura

Ano	Título	Temática Simplificada
Bloco A - Frameworks e Visão Sistêmica da Área		
2024	*The End is the Beginning is the End: The Closed-Loop Learning Analytics Framework.* **Sailer et al.**	Organizar todo o ciclo de uso de dados educacionais, abrangendo desde a coleta até a intervenção, em um processo contínuo e fundamentado em teoria pedagógica, garantindo que a análise de dados sirva efetivamente à melhoria do aprendizado

continua

continuação

2025	*Generative AI and Learning Analytics: Pushing Boundaries, Preserving Principles.* **Khosravi et al**	Definir como ferramentas de IA Generativa podem ser integradas a análise educacional de forma responsável, sem comprometer a autonomia dos alunos, a privacidade dos dados e os princípios éticos do ensino.
2025	*An Extended Learning Analytics Framework Integrating Machine Learning and Pedagogical Approaches for Student Performance Prediction and Intervention.* **Alalawi et al.**	Permitir que professores identifiquem alunos em risco e criem planos de estudo personalizados no ambiente virtual, sem precisar de equipe técnica especializada ou investimento adicional em infraestrutura institucional.
Bloco B — IA Generativa, LLMs e Feedback Automático		
2024	*Beyond Predictive Learning Analytics Modelling and onto Explainable AI with Prescriptive Analytics and ChatGPT.* **Susnjak**	Sugerir automaticamente, em linguagem acessível, o que cada aluno em risco deve fazer para melhorar, combinando explicações transparentes da IA com recomendações práticas geradas por modelos de linguagem.
2025	*Integrating AI and Learning Analytics for Data-Driven Pedagogical Decisions and Personalized Interventions in Education.* **Sajja et al.**	Medir em tempo real o engajamento, a curiosidade e o desenvolvimento cognitivo dos alunos por meio de assistente baseado em IA generativa, oferecendo ao professor informações para guiar suas decisões pedagógicas.
2023	Integration of Artificial Intelligence Performance Prediction and Learning Analytics to Improve Student Learning in Online Engineering Course. Ouyang et al.	Demonstrar, por meio de experimento controlado, que usar previsoes de IA combinadas com o acompanhamento ˜ cont´ınuo da aprendizagem colaborativa melhora o engajamento e o desempenho dos alunos em cursos online.
2025	*Beware of Metacognitive Laziness: Effects of Generative Artificial Intelligence on Learning Motivation, Processes, and Performance.* **Fan; Gasevic et al.**	Alertar gestores e professores de que o ChatGPT pode melhorar resultados imediatos, mas reduzir a capacidade do aluno de pensar de forma independente e de se autogerir, exigindo planejamento pedagógico cuidadoso sobre quando e como utilizar IA.

continua

continuação

Bloco C — Explicabilidade e Transparência dos Modelos		
2024	*Explainable Learning Analytics: Assessing the Stability of Student Success Prediction Models by Means of Explainable AI.* **Tiukhova et al.**	Verificar se as previsões da IA sobre o sucesso dos alunos continuam confiáveis de um semestre para o outro, garantindo consistência nas recomendações oferecidas a professores e gestores educacionais.
2024	*Course Success Prediction and Early Identification of At-Risk Students Using Explainable Artificial Intelligence.* **Ujkani et al**	Identificar precocemente alunos com risco de reprovação e explicar, de forma compreensível para professores e coordenadores, quais fatores levaram aquela previsão, tornando a decisão da IA auditável e confiável.
Bloco D — Inovação Técnica Aplicada a Educação		
2024	*Idiographic Artificial Intelligence to Explain Students' SelfRegulation: Toward Precision Education.* **Saqr et al.**	Construir um modelo de IA exclusivo para cada aluno, utilizando apenas os dados daquela pessoa, para compreender como ela aprende e se organiza, reconhecendo que soluções genéricas raramente representam qualquer estudante individualmente
2024	*Advanced Student Success Predictions in Higher Education with Graph Attention Networks for Personalized Learning.* **Shukla et al.**	Medir em tempo real o engajamento, a curiosidade e o desenvolvimento cognitivo dos alunos por meio de assistente baseado em IA generativa, oferecendo ao professor informações para guiar suas decisões pedagógicas.
2024	*A Novel Deep Learning Model for Student Performance Prediction Using Engagement Data.* **Fazil et al.**	Analisar o comportamento semanal dos alunos em plataformas virtuais para prever, já nas primeiras sete semanas do semestre, quem precisará de apoio pedagógico antes que as dificuldades se consolidem
2021	*PAKES: A Reinforcement Learning-Based Personalized Adaptability Knowledge Extraction Strategy for Adaptive Learning Systems.* **Islam et al**	Sugerir automaticamente o próximo conteúdo ideal para cada aluno, com base no que ele já sabe e no que ainda precisa aprender, funcionando como um tutor inteligente que ajusta o caminho de estudo em tempo real.

continua

continuação

2023	*Predicting Student Performance Using Clickstream Data and Machine Learning.* **Liu et al.**	Revelar quais recursos do ambiente virtual são mais decisivos para o desempenho dos alunos, analisando o histórico de cliques e acessos para orientar o redesign de cursos e a alocação estratégica de suporte pedagógico
Bloco E — Intervenção Pedagógica e Comportamento do Aluno		
2025	*Mitigating Conceptual Learning Gaps in Mixed-Ability Classrooms: A Learning Analytics-Based Evaluation of AI-Driven Adaptive Feedback for Struggling Learners.* **Naseer; Khawaja**	Reduzir desigualdades de aprendizagem em turmas mistas, oferecendo feedback personalizado por IA a estudantes com dificuldade, com evidência experimental de melhoria de 28 % em maestria conceitual entre 700 alunos de cursos de ciências e tecnologia
2025	*Dynamics of Self-Regulated Learning: The Effectiveness of Students' Strategies Across Course Periods.* **Cristea; Saqr et al**	Acompanhar como as estratégias de estudo mudam ao longo do semestre e identificar o momento mais adequado para o professor intervir, com base em dados de 41 disciplinas ao longo de dois anos letivos.
2023	*Predictive Analytics Study to Determine Undergraduate Students at Risk of Dropout.* **Gonzalez-Nucamendi et al.**	Prever, desde as primeiras semanas do curso, quais alunos tem maior risco de abandonar a graduação, com base em dados acadêmicos e de contexto, para que a instituição atue antes que a evasão se concretize
2023	*Prediction of Dilatory Behavior in eLearning: A Comparison of Multiple Machine Learning Models.* **Imhof et al.**	Identificar alunos com tendência a adiar a entrega de atividades, usando registros de uso da plataforma virtual, para que o professor intervenha preventivamente antes que a procrastinação comprometa o desempenho final.
Bloco F — Ética, Justiça Algorítmica e Proteção de Dados		
2024	*A Comparison of Bias Mitigation Techniques for Educational Classification Tasks Using Supervised Machine Learning.* **Wongvorachan et al.**	Tornar os modelos de IA mais justos, testando técnicas que reduzem a discriminação de grupos vulneráveis nas previsões de evasão, para que decisões baseadas em dados não penalizem estudantes já em situação de desvantagem.

continua

continuação

2024	*Explainable Artificial Intelligence for Academic Performance Prediction: An Experimental Study on the Impact of Accuracy and Simplicity of Decision Trees on Causability and Fairness Perceptions.* **Lunich; Keller**	Investigar como os próprios estudantes percebem a justiça dos sistemas de IA que avaliam seu desempenho, revelando que a compreensibilidade do modelo importa mais que sua acurácia para que alunos confiem nas decisões algorítmicas.
2023	*Federated Learning for Data Analytics in Education.* **Fachola et al.**	Proteger a privacidade dos alunos permitindo que modelos de IA aprendam com dados de múltiplas instituições sem centralizar informações pessoais, garantindo análises educacionais eficazes e em conformidade com legislações de proteção de dados, como a LGPD.

Fonte: Elaborado pelo autor (2026)

4.1. Aplicações de LA e IA na Gestão da Aprendizagem

A literatura examinada revela que a aplicação de LA e IA na gestão da aprendizagem consolidou-se como um campo amplo. As iniciativas atuais variam desde a modelagem preditiva do desempenho acadêmico até a personalização de trajetórias formativas e o apoio estratégico a decisão pedagógica. Ao analisarem essa dinâmica, Sailer et al. (2024) propõem que o uso de dados educacionais seja compreendido como um ciclo contínuo, denominado closed-loop. Para os autores, esse processo deve abranger desde a coleta inicial até a formulação de intervenções práticas, garantindo que os resultados retroalimentem as estratégias de ensino de forma sistemática.

Olhar o cenário de forma integrada é um grande avanço. Isso substitui aquela antiga dinâmica onde os dados eram coletados de forma isolada e quase nunca se transformavam em atitudes práticas para ajudar na sala de aula. Nessa mesma linha de raciocínio, Alalawi, Athauda e Chiong (2025) sugerem um framework de LA que une técnicas de aprendizado de máquina a fundamentos pedagógicos. O objetivo central é capacitar o corpo docente para que consiga identificar alunos em risco e elaborar planos de estudo individualizados diretamente no ambiente virtual de aprendizagem. A proposta ganha relevância ao buscar autonomia para o professor, reduzindo a dependência de equipes técnicas especializadas. Tal movimento sinaliza uma tendência de democratização da LA, tornando o suporte analítico uma ferramenta acessível e integrada ao cotidiano da prática docente.

No cenário da IA Generativa, Khosravi et al. (2025) e Sajja et al. (2025) concordam que sua integração à análise educacional é um caminho promissor, embora tragam ênfases

complementares. Khosravi et al. (2025) concentram sua discussão nos pilares éticos fundamentais,como a proteção de dados, a responsabilidade algorítmica e a preservação da autonomia do estudante. Por outro lado, Sajja et al. (2025) destacam o potencial operacional dessa tecnologia para mensurar, em tempo real, variáveis subjetivas e complexas, a exemplo da curiosidade intelectual e do engajamento cognitivo.

Contudo, Fan et al. (2025) introduzem uma perspectiva cautelar ao demonstrar que o uso de ferramentas como o ChatGPT, apesar de elevar a produtividade imediata, pode prejudicar, no longo prazo, a capacidade do aluno de gerenciar seus próprios estudos e de entender como ele aprende melhor. Esse fenômeno, que os autores chamam de metacognitive laziness, evidencia uma tensão crítica entre a busca por eficiência e a garantia de um crescimento intelectual sustentável.

De maneira complementar, as investigações de Ouyang et al. (2023) reforçam que a tecnologia ganha sentido quando aliada a prática. Por meio de um experimento em cursos de engenharia online, os autores demonstraram que combinar previsões de IA com o monitoramento da aprendizagem colaborativa gera ganhos reais de desempenho e engajamento. Essa evidencia sustenta o argumento de que o sucesso das aplicações de LA e IA não depende apenas da implementação tecnológica, mas de sua articulação estreita com estratégias pedagógicas intencionais e bem estruturadas.

4.2. Técnicas de IA Empregadas em Sistemas de LA e Resultados Produzidos

O mapeamento das técnicas de IA empregadas nesta revisão revela uma diversidade metodológica notável. O cenário abrange desde os algoritmos clássicos de aprendizado de máquina supervisionado até arquiteturas profundas de redes neurais e métodos de aprendizado por reforço. Essa pluralidade técnica demonstra, por um lado, que o campo está amadurecendo, por outro lado, indica a falta de um paradigma tecnológico unico. Essa fragmentação acaba gerando desafios importantes quando se tenta comparar ou replicar resultados em diferentes contextos institucionais.

No que diz respeito as técnicas preditivas tradicionais, Liu et al. (2023) utilizam dados de clickstream, que são os registros detalhados das interações discentes no ambiente virtual, para identificar quais recursos digitais mais influenciam o desempenho acadêmico. Os resultados do estudo mostram que os padrões de engajamento com o material didático são indicadores valiosos do sucesso do aluno, oferecendo pistas concretas para o redesenho das estratégias instrucionais.

Em uma linha semelhante, Fazil, Rısquez e Halpin (2024) apresentam um modelo de deep learning que consegue antecipar, ainda na metade do semestre, quais estudantes precisarão de apoio pedagógico. Ao analisar o comportamento semanal nas plataformas, a pesquisa destaca que a rapidez na predição é um diferencial crucial, pois amplia o tempo disponível para que as instituições realizem intervenções preventivas eficazes.

Buscando maior sofisticação, Shukla et al. (2024) aplicam Redes de Atenção em Grafos (GANs) para mapear relações complexas entre as variáveis dos estudantes. Esse método alcança alta precisão ao capturar interdependências que modelos lineares comuns costumam ignorar. Já para

Saqr et al. (2024), a inovação não está necessariamente na complexidade matemática, mas na individualização do processo. Os autores defendem o uso de modelos de IA personalizados, alimentados exclusivamente pelos dados de cada indivíduo. O argumento central é que soluções genéricas, embora precisas em nível de grupo, raramente refletem com fidelidade a trajetória única de um aluno. Essa abordagem consolida o conceito de precision education, inspirado na medicina de precisão, e configura-se como uma das contribuições mais originais desta revisão.

No campo da aprendizagem adaptativa, Islam et al. (2021) utilizam o aprendizado por reforço para criar um sistema que recomenda automaticamente o próximo conteúdo para o estudante. Funcionando como um tutor inteligente que ajusta o percurso em tempo real, a ferramenta busca aproximar-se do ideal de personalização completa. Por outro lado, Imhof et al. (2023) realizam um estudo comparativo entre diversos modelos de aprendizado de máquina para prever a procrastinação dos alunos. Ao testarem diferentes abordagens, os autores concluem que não existe uma técnica universalmente superior. A escolha do algoritmo mais eficaz depende sempre do objetivo específico da predição.

Por fim, no que toca à transparência dos sistemas, Tiukhova et al. (2024) e Ujkani, Minkovska e Hinov (2024) concordam que a precisão dos modelos, isoladamente, não garante que eles serão adotados pelas instituições. Tiukhova et al. (2024) demonstram que a estabilidade das previsões ao longo dos semestres é vital, pois inconsistências podem minar a confiança de gestores e professores. Complementando essa visão, Ujkani, Minkovska e Hinov (2024) reforçam que as predições devem vir acompanhadas de explicações claras sobre os fatores que levaram a determinado resultado, tornando o processo auditável. Seguindo essa tendência, Susnjak (2024) propõe unir a IA Explicável a LLMs. O objetivo é traduzir dados técnicos complexos em recomendações práticas e compreensíveis, facilitando o suporte direto ao estudante em situação de risco.

4.3. Benefícios Identificados

A literatura analisada revela um conjunto sólido de benefícios ao integrar LA e IA no cenário educacional. Sob a perspectiva pedagógica, destacam-se a detecção precoce de estudantes em risco de evasão ou reprovação, conforme observado por Ujkani, Minkovska e Hinov (2024) e Gonzalez-Nucamendi et al. (2023), além da personalização de feedbacks e trajetórias de aprendizagem, abordada por Naseer e Khawaja (2025) e Islam et al. (2021).

Complementarmente, Cristea et al. (2025) apontam que essas tecnologias oferecem um suporte valioso para que os alunos desenvolvam sua autorregulação e monitorem melhor suas estratégias de estudo durante o semestre. Um exemplo notável desse impacto é apresentado por Naseer e Khawaja (2025), que ao analisarem 7700 alunos de cursos de ciências e tecnologia, os autores verificaram que o uso de feedback adaptativo baseado em IA gerou uma melhoria de 28% na compreensão de conteúdos entre estudantes com dificuldades. Esse resultado reforça como tais ferramentas podem ser transformadoras em turmas com perfis tão diversos.

No âmbito institucional, a adoção de LA permite que as organizações educacionais evoluam de uma postura reativa, que lida com reprovações já ocorridas, para uma gestão proativa e voltada à prevenção. De acordo com Sailer et al. (2024), essa transição é fundamental para uma administração fundamentada em dados. Nesse sentido, Gonzalez- Nucamendi et al. (2023) demonstram que o risco de abandono pode ser previsto logo nas primeiras semanas de aula. Tal antecipação oferece à instituição uma oportunidade de intervenção que a gestão acadêmica tradicional, em geral, não consegue alcançar.

4.4. Desafios Técnicos

Mesmo com os avanços recentes, levar essas tecnologias para a prática ainda esbarra em obstáculos técnicos significativos, especialmente no que diz respeito à generalização dos modelos. É comum que resultados obtidos em uma disciplina ou instituição específica não se repitam em outros cenários, o que acaba dificultando a expansão dessas soluções.

Tiukhova et al. (2024) chamam a atenção para a questão da instabilidade temporal, onde modelos que funcionam bem em um semestre podem perder a precisão nos períodos seguintes, o que põe em xeque a sua utilidade no longo prazo. Indo além da acurácia, Shukla et al. (2024) e Fazil, Rísquez e Halpin (2024) discutem o uso de arquiteturas mais complexas. Embora esses modelos sejam mais precisos, eles trazem novos dilemas, como a dificuldade de entender como a IA chegou a certas conclusões e o alto custo computacional, que é um ponto crítico para instituições com pouca infraestrutura tecnológica.

Outro problema que aparece com frequência na literatura é o quanto esses sistemas dependem da qualidade dos dados coletados. Se os registros de interação dos alunos no ambiente virtual forem inconsistentes ou incompletos, o desempenho das predições cai drasticamente, como apontam Liu et al. (2023) e Imhof et al. (2023).

4.5. Desafios Pedagógicos

Um dos principais desafios pedagógicos é o risco de automatizar demais as decisões educacionais. Fan et al. (2025) mostram que, quando os alunos delegam tarefas cognitivas à IA, eles reduzem o esforço metacognitivo necessário para desenvolver a autorregulação. Para Cristea et al. (2025), o sucesso das intervenções depende diretamente do momento em que elas ocorrem. Agir precocemente pode inibir o desenvolvimento da autonomia, enquanto uma ação tardia pode se mostrar ineficaz. Encontrar essa janela temporal ideal para intervir continua sendo, portanto, uma questão em aberto para os pesquisadores.

Além disso, Alalawi, Athauda e Chiong (2025) e Naseer e Khawaja (2025) concordam que a resistência dos professores ao uso de ferramentas de LA é uma barreira significativa. Esse obstáculo costuma ser subestimado em projetos de implementação, mas sua relevância é alta. Embora a formação continuada para que docentes saibam interpretar dashboards e relatórios de IA

seja um passo fundamental, ela raramente é suficiente para garantir que as intervenções pedagógicas sejam realmente efetivas.

4.6. Desafios Éticos

As questões éticas formam a dimensão mais sensível e profunda deste campo. Khosravi et al. (2025) organizam os princípios essenciais para o uso responsável da IA Generativa na educação, enfatizando a autonomia do aprendiz, a transparência dos algoritmos e a proteção à privacidade dos dados. Por outro lado, Wongvorachan et al. (2024) apresentam evidências de que os modelos preditivos usados em LA podem, involuntariamente, reproduzir ou até agravar desigualdades sociais. Isso reforça a urgência de uma vigilância constante e de auditorias frequentes nos sistemas em uso.

Liinich e Keller (2024) trazem uma perspectiva importante ao analisar como os próprios estudantes percebem a justiça nos sistemas de IA que avaliam seu desempenho. Os resultados indicam que, para o aluno confiar na ferramenta, a capacidade de entender como uma decisão foi tomada importa mais do que a precisão técnica do modelo. Essa descoberta coloca a explicabilidade no centro do debate ético, e não apenas técnico. Por fim, ao tratar da conformidade com legislações como a LGPD, Fachola et al. (2023) argumentam que o aprendizado federado surge como uma alternativa viável. Essa arquitetura permite realizar análises educacionais em larga escala respeitando as normas de proteção de dados.

4.7. Tendências Emergentes e Lacunas de Pesquisa

Avaliar todos os estudos selecionados em conjunto ajuda a perceber as novas tendências do mercado, mostrando quais serão os caminhos mais promissores para o uso de IA e LA nos próximos anos. Ao mesmo tempo, essa investigação revela lacunas de pesquisa importantes, que ainda limitam o avanço do conhecimento e a aplicação prática desses achados nas instituições de ensino. A principal tendência atual é a integração entre IA Generativa e LA.

LLMs agora conseguem traduzir análises técnicas complexas em recomendações claras para professores e alunos (KHOSRAVI et al., 2025; SAJJA et al., 2025; SUSNJAK, 2024). Isso resolve um problema antigo: as gerações anteriores de sistemas de LA usavam interfaces técnicas que excluíam usuários não especializados. Seguindo essa mesma linha, Saqr et al. (2024) propõem a precision education. Ao utilizarem modelos construídos individualmente para cada estudante, os autores sinalizam um distanciamento das soluções genéricas em favor de abordagens profundamente personalizadas. Outra tendencia consolidada é a crescente atenção voltada a explicabilidade e à transparência dos algoritmos. Os trabalhos de Tiukhova et al. (2024), Ujkani, Minkovska e Hinov (2024) e Lunich e Keller (2024) evidenciam que o campo caminha para adotar padrões mínimos de explicabilidade como um requisito de legitimidade para os sistemas de LA.

Essa exigência vai além de simples escolhas técnicas, visto que envolve compromissos éticos por parte das instituições que decidem adotar tais tecnologias.

Ainda são raros os trabalhos que se propõem a acompanhar o impacto das ferramentas de LA durante toda a trajetória acadêmica do estudante. Como boa parte da literatura, incluindo os estudos de Fazil, Risquez e Halpin (2024), Imhof et al. (2023) e Cristea et al. (2025), concentra-se em períodos curtos, como um único semestre ou disciplina, fica difícil saber se os benefícios encontrados de fato se mantém a longo prazo. Além disso, o campo sofre com a carência de estudos de replicação em cenários variados. Essa lacuna é ainda mais visível em países em desenvolvimento, locais onde os problemas de infraestrutura e as disparidades sociais são profundos e acabam dificultando que as descobertas feitas em países centrais sejam aplicadas de forma geral.

Sob o aspecto metodológico, observa-se uma predominância de abordagens quantitativas e preditivas. Ainda são raras as investigações qualitativas que explorem, de fato, as percepções e experiências de professores e alunos no uso cotidiano dessas ferramentas. Essa assimetria dificulta a compreensão dos fatores contextuais que determinam se a implementação de um sistema terá sucesso ou não. Por fim, a interseção entre LA, IA e equidade educacional permanece pouco explorada. Embora autores como Wongvorachan et al. (2024) e Fachola et al. (2023) tenham avançado nesse sentido, a maioria dos estudos ainda não seguem esse mesmo padrão. Superar essa lacuna é essencial para que o potencial transformador da IA e da LA seja aproveitado de forma verdadeiramente inclusiva e justa.

5. Considerações Finais

Esta RSL mapeou como a LA e a IA tem transformado a gestão da aprendizagem, investigando 21 artigos científicos distribuídos em seis eixos temáticos, o que permitiu responder às questões de pesquisa estabelecidas. Em relação a primeira questão de pesquisa (QP1), os resultados revelam que a aplicação dessas tecnologias na gestão educacional está cada vez mais integrada: o foco deixou de ser a coleta passiva de dados para se concentrar em ciclos de intervenção pedagógica baseados em evidências. A perspectiva de *closed-loop*, defendida por Sailer et al. (2024), ilustra bem esse movimento ao tratar o uso de dados como um processo contínuo de retroalimentação. Esse novo paradigma supera antigas abordagens fragmentadas, nas quais a análise da informação raramente se transformava em uma ação prática no ambiente de ensino.

Ao abordar a segunda questão de pesquisa (QP2), identificou-se um repertório variado de técnicas de IA aplicadas aos sistemas de LA. O cenário abrange desde algoritmos de aprendizado supervisionado e modelos de *deep learning* até redes de atenção em grafos, aprendizado por reforço e, mais recentemente, os LLMs. O impacto dessas ferramentas é notável, permitindo identificar precocemente alunos em risco, personalizar trajetórias formativas e prever comportamentos procrastinadores. Além disso, essas tecnologias conseguem traduzir análises

densas em recomendações pedagógicas acessíveis. No entanto, essa diversidade metodológica também indica que o campo ainda não possui um padrão técnico único, o que traz desafios para quem deseja comparar ou replicar esses resultados em diferentes instituições.

Quanto a terceira questão de pesquisa (QP3), os estudos analisados revelam benefícios institucionais e pedagógicos expressivos. Destacam-se, sobretudo, a capacidade de prever riscos de evasão e reprovação, a oferta de feedbacks personalizados e o estímulo a autorregulação dos estudantes. Por outro lado, os desafios mapeados são igualmente importantes e se dividem em três frentes. No campo técnico, os principais obstáculos são a instabilidade temporal dos modelos, a forte dependência da qualidade dos dados e o alto custo computacional de certas arquiteturas.

Na dimensão pedagógica, surgem barreiras que a literatura ainda parece subestimar, como o risco da preguiça metacognitiva (*metacognitive laziness*), causada pelo uso acrítico da IA Generativa, e a resistência dos docentes ao uso de ferramentas de LA. Já no plano ético, a reprodução ao de desigualdades estruturais por algoritmos e as dificuldades de adequação a normas como a LGPD mostram-se questões urgentes para o desenvolvimento responsável da área.

No que diz respeito a quarta questão de pesquisa (QP4), esta revisão identificou tendências promissoras, como a convergência entre IA Generativa e LA, a exigência de sistemas mais transparentes e o avanço rumo à *precision education*. Ao mesmo tempo, lacunas importantes ainda persistem: há poucos estudos longitudinais de longa duração, faltam investigações qualitativas sobre a experiência real de professores e alunos, e os resultados ainda são pouco replicados em contextos de países em desenvolvimento. Além disso, a justiça algorítmica raramente e tratada como um critério central nas avaliações de impacto.

Diante desse cenário, conclui-se que o uso de LA e IA na gestão da aprendizagem vive um momento de transição. Embora a tecnologia já produza resultados notáveis, o campo ainda carece de marcos éticos mais sólidos, pesquisas de longo prazo e estratégias eficazes de formação docente. O sucesso dessa área depende de um olhar que integre as dimensoes técnica, pedagóogica e ética de forma inseparável. Sem esse equilíbrio, corre-se o risco de que soluções sofisticadas acabem reproduzindo ou até agravando as desigualdades educacionais que deveriam ajudar a superar.

Referências

Alalawi, K.; Athauda, R. & Chiong, R. An extended learning analytics framework integrating machine learning and pedagogical approaches for student performance prediction and intervention. International **Journal of Artificial Intelligence in Education**, v. 35, n. 3, p. 1239–1287, 2025.

Cristea, T. S.; Heikkinen, S.; Snijders, C.; Sarq, M.; Matzat, U.; Conijn, R. & Kleingeld, A. Dynamics of self-regulated learning: The effectiveness of students' strategies across course periods. **Computers and Education**, v. 228, 2025.

Ercole, F. F.; Melo, L. S. de & Aalcoforado, C. L. G. C. Revisao integrativa versus revisão sistemática. **REME-Revista Mineira de Enfermagem**, v. 18, n. 1, 2014.

Fachola, C.; Tornaria, A.; Bermolen, P.; Capdehourat, G.; Etcheverry, L. & Fariello, M. I. Federated learning for data analytics in education. **Data**, v. 8, n. 2, 2023.

Fan, Y.; Tang, L.; Le, H.; Shen, K.; Tan, S.; Zhao, Y.; Shen, Y.; Li, X. & Gasevic, D. Beware of metacognitive laziness: Effects of generative artificial intelligence on learning motivation, processes, and performance. **British Journal of Educational Technology**, v. 56, n. 2, p. 489–530, 2025.

Fazil, M.; Risquez, A.; Halpin, C. A novel deep learning model for student performance prediction using engagement data. **Journal of Learning Analytics,** v. 11, n. 2, p. 23–41, 2024.

Gonzales-Nucamendi, A.; Noguez, J.; Neri, L.; Robledo-Rella, V.; Garcia-Castelan, R. M. G. Predictive analytics study to determine undergraduate students at risk of dropout. **Frontiers in Education**, v. 8, 2023.

Imhof, C.; Comsa, I. S.; Hlosta, M.; Parsaeifard, B.; Moser, I. & Bergamin, P. Prediction of dilatory behavior in elearning: A comparison of multiple machine learning models. **IEEE Transactions on Learning Technologies**, v. 16, n. 5, p. 648–663, 2023.

Islam, M. Z.; Ali, R.; Haider, A.; Islam, M. Z. & Kim, H. S. Pakes: A reinforcement learning-based personalized adaptability knowledge extraction strategy for adaptive learning systems. **IEEE Access**, v. 9, p. 155123–155137, 2021.

Khosravi, H.; Shibani, A.; Jovanovic, J.; Pardos, Z. A. & Yan, L. Generative ai and learning analytics: Pushing boundaries, preserving principles. **Journal of Learning Analytics**, v. 12, n. 1, p. 1–11, 2025.

Liu, Y.; Fan, S.; Xu, S.; Sajjanhar, A.; Yeom, S. ¨Wei, Y. Predicting student performance using clickstream data and machine learning. **Education Sciences**, v. 13, n. 1, 2023.

Long, P.; Siemens, G. **Penetrating the fog:** Analytics in learning and education. **EDUCAUSE Review** (Online), sep 2011. Disponível em: https://www.proquest.com/ scholarly-journals/penetrating-fog-analytics-learning-education/docview/3224594060/ se-2.

Lunich, M. & Keller, B. **Explainable artificial intelligence for academic performance prediction an experimental study on the impact of accuracy and simplicity of decision trees on causability and fairness perceptions.** In: 2024 ACM Conference on Fairness, Accountability, and Transparency (FAccT 2024). [S.l.: s.n.], 2024. p. 1031–1042.

Maretto, C. & Barcellos, M. Uma avaliação de dados abertos educacionais brasileiros: Qualidade, privacidade e learning analytics. In: Anais do XXXIV Simpósio Brasileiro de Informática na Educação (SBIE 2023). Porto Alegre, RS, Brasil: SBC, 2023. p. 1341–1350. Disponível em: https://sol.sbc.org.br/index.php/sbie/article/view/ 26759.

NASEER, F.; KHAWAJA, S. Mitigating conceptual learning gaps in mixed-ability classrooms: A learning analytics-based evaluation of ai-driven adaptive feedback for struggling learners. Applied Sciences (Switzerland), v. 15, n. 8, 2025.

OUHAICHI, H.; SPIKOL, D.; VOGEL, B. Research trends in multimodal learning analytics: A systematic mapping study. Computers and Education: Artificial Intelligence, v. 4, p. 100136, 2023.

Ouyang, F.; Wu, M.; Zheng, L. & Jiao, P. Integration of artificial intelligence performance prediction and learning analytics to improve student learning in online engineering course. **International Journal of Educational Technology in Higher Education**, v. 20, n. 1, 2023.

Ouzzani, M.; Hammady, H.; Fedorowicz, Z. & Elmagarmid, A. Rayyan—a web and mobile app for systematic reviews. **Systematic Reviews,** Springer, v. 5, n. 1, p. 210, 2016. Disponíível em: https://doi.org/10.1186/s13643-016-0384-4.

Romero, C.; Ventura, S.; Garcia, E. Data mining in course management systems: Moodle case study and tutorial. **Computers & Education**, v. 51, n. 1, p. 368–384, 2008.

Sailer, M.; Ninaus, M.; Huber, S. E.; Bauer, E. & Greiff, S. The end is the beginning is the end: The closed-loop learning analytics framework. **Computers in Human Behavior**, v. 158, 2024.

SAJJA, R. et al. Integrating ai and learning analytics for data-driven pedagogical decisions and personalized interventions in education. **Technology, Knowledge and Learning**, 2025.

Saqr, M.; Cheng, R.; López-Pernas, S. & Beck, E. D. Idiographic artificial intelligence to explain students' self-regulation: Toward precision education. **Learning and Individual Differences**, v. 114, 2024.

Shukla, T. D.; Radha, G.; Yadav, D. K.; Bhattacharya, C.; Praveen, R. & Yokar, N. N. **Advanced student success predictions in higher education with graph attention networks for personalized learning**. In: 2024 First International Conference on Software, Systems and Information Technology (SSITCON). [S.l.: s.n.], 2024. p. 1–6.

Siemens, G. Learning analytics: The emergence of a discipline. **American Behavioral Scientist**, v. 57, n. 10, p. 1380–1400, 2013.

Siemens, G. & Baker, R. S. J. d. **Learning analytics and educational data mining:** towards communication and collaboration. In: Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK '12). New York, NY, USA: ACM, 2012. p. 252–254.

Susnjak, T. Beyond predictive learning analytics modelling and onto explainable artificial intelligence with prescriptive analytics and chatgpt. **International Journal of Artificial Intelligence in Education**, v. 34, n. 2, p. 452–482, 2024.

TIiukhova, E.; Vemuri, P.; Flores, N. L.; Islind, A. S.; Óskarsdóttir, M.; Poelmans, S.; Baesens, B. & Snoeck, M. Explainable learning analytics: Assessing the stability of student success prediction models by means of explainable ai. **Decision Support Systems**, v. 182, 2024.

Ujkani, B.; Minkovska, D. & Hinov, N. Course success prediction and early identification of at-risk students using explainable artificial intelligence. **Electronics** (Switzerland), v. 13, n. 21, 2024.

Wongvorachan, T.; Bulut, O.; Liu, J. X. & Mazzullo, E. A comparison of bias mitigation techniques for educational classification tasks using supervised machine learning. **Information** (Switzerland), v. 15, n. 6, 2024.

Yan, L.; Echeverria, V.; Jin, Y.; Fernandez-Nieto, G.; Zhao, L.; Li, X.; Alfredo, R.; Swiecki, Z.; Gasevic, D. & Martinez-Maldonado, R. Evidence-based multimodal learning analytics for feedback and reflection in collaborative learning. **British Journal of Educational Technology**, v. 55, n. 5, p. 1900–1925, 2024.

Yan, L.; Greiff, S.; Teuber, Z. & Gasevic, D. Promises and challenges of generative artificial intelligence for human learning. **Nature Human Behaviour,** v. 8, n. 10, p. 1839–1850, 2024.

Sobre o autor(a)

Jardel Batista Gonçalves

Mestrando em Tecnologias da Informação e Comunicação pelo Programa de Pós-graduação em Tecnologias da Informação e Comunicação (PPGTIC) da Universidade Federal de Santa Catarina.

Tecnólogo em Redes de Computadores pela Universidade Federal de Santa Maria (UFSM - 2024) e Especialista em Desenvolvimento Full Stack para Cloud Native pela Universidade do Extremo Sul Catarinense (UNESC - 2025).

Oficial da Reserva, formado no Núcleo de Preparação de Oficiais da Reserva (NPOR - 3° GAC AP) em 2020.

Professor substituto no Instituto Federal Catarinense (IFC) - Campus Sombrio

Lattes: http://lattes.cnpq.br/2970690719862446

CAPÍTULO 5

Análise preditiva educacional: modelos preditivos para identificação de risco de evasão

Gislaine Pereira Candido

1. Introdução

A evasão estudantil representa um dos principais desafios enfrentados pelas instituições de ensino, devido aos impactos acadêmicos, sociais e econômicos associados ao abandono da trajetória educacional. Esse fenômeno está presente em todos os níveis de ensino, desde a educação básica até o ensino superior, e resulta da interação de múltiplos fatores, entre eles condições socioeconômicas desfavoráveis, dificuldades de acesso a serviços básicos, violência, trabalho infantil, gravidez precoce, fragilidades no processo de ensino e aprendizagem, além da falta de engajamento dos estudantes (Sihare, 2024).

Diante dessa complexidade, a identificação antecipada de estudantes em situação de risco tornou-se uma estratégia relevante para possibilitar ações preventivas e reduzir os índices de evasão. Nesse contexto, a utilização de tecnologias de análise preditiva apresenta-se como uma alternativa promissora para auxiliar instituições na tomada de decisão e no desenvolvimento de intervenções pedagógicas mais direcionadas.

A análise preditiva educacional utiliza técnicas estatísticas, mineração de dados educacionais e algoritmos de aprendizado de máquina (*machine learning*) para identificar padrões presentes em grandes volumes de dados acadêmicos. A partir dessas informações, os modelos preditivos são capazes de estimar possíveis comportamentos futuros dos estudantes, permitindo o reconhecimento antecipado de fatores associados ao risco de abandono e possibilitando ações institucionais antes que a evasão ocorra.

Nos últimos anos, diferentes pesquisas têm aplicado modelos de aprendizado de máquina para prever a evasão estudantil utilizando variáveis acadêmicas, socioeconômicas e comportamentais. Entre os algoritmos frequentemente empregados destacam-se *Random Forest*, Regressão Logística, Árvores de Decisão, *Support Vector Machine* (SVM), Redes Neurais Artificiais e *Gradient Boosting*. Essas abordagens apresentam potencial para identificar relações complexas entre diferentes características dos estudantes e o processo de permanência ou abandono escolar.

Nesse sentido, Deleña et al. (2025) avaliaram diferentes algoritmos de aprendizado de máquina para estimar a evasão de estudantes no ensino superior, considerando variáveis sociodemográficas e acadêmicas. Os resultados demonstraram a capacidade desses modelos em realizar o reconhecimento precoce de estudantes com possibilidade de evasão, evidenciando o potencial da inteligência artificial como ferramenta de apoio às instituições educacionais. Entretanto, apesar dos avanços tecnológicos, a evasão permanece como um fenômeno complexo e multifatorial, influenciado por diferentes aspectos relacionados ao desempenho acadêmico, condições socioeconômicas, características individuais e vínculo do estudante com o ambiente educacional.

Embora os modelos preditivos apresentem resultados relevantes, ainda existem desafios relacionados à seleção das variáveis mais significativas, interpretação dos resultados obtidos pelos algoritmos, qualidade dos dados utilizados e aplicação prática das previsões no desenvolvimento de estratégias preventivas. Dessa forma, torna-se importante compreender quais modelos têm sido empregados, quais fatores apresentam maior influência na previsão da evasão e quais limitações ainda precisam ser superadas.

Diante desse cenário, esta pesquisa justifica-se pela importância de analisar os modelos preditivos utilizados na identificação do risco de evasão estudantil, contribuindo para a compreensão das abordagens baseadas em inteligência artificial, aprendizado de máquina e mineração de dados educacionais, bem como suas possibilidades de aplicação em instituições de ensino.

Esta RSL busca responder às seguintes questões de pesquisa:

1. Quais modelos preditivos são mais utilizados na identificação do risco de evasão estudantil?
2. Quais fatores relacionados aos estudantes são considerados relevantes pelos modelos preditivos de evasão?
3. Quais contribuições os modelos preditivos oferecem para a identificação precoce do risco de evasão?
4. Quais são os principais desafios identificados nos estudos relacionados à predição da evasão?

2. Fundamentação Teórica

2.1 Evasão no Ensino

A evasão estudantil constitui um fenômeno complexo e multifatorial, influenciado por diferentes aspectos relacionados às condições individuais, acadêmicas, sociais e institucionais dos estudantes. Entre os fatores associados ao abandono escolar destacam-se características

socioeconômicas, estrutura familiar, dificuldades de aprendizagem, falta de motivação, baixa interação com a comunidade acadêmica e limitações relacionadas à permanência no ambiente educacional (Martinez & Castillo, 2024).

A saída precoce dos estudantes representa um desafio para diferentes atores envolvidos no processo educacional, incluindo instituições de ensino, gestores, professores e familiares. No contexto do ensino superior, a evasão gera impactos tanto para os estudantes, que interrompem sua formação acadêmica, quanto para as instituições, que enfrentam dificuldades relacionadas à retenção, planejamento acadêmico e indicadores institucionais (Duro et al., 2026).

Entretanto, a evasão normalmente não ocorre de forma repentina. Antes do abandono efetivo, os estudantes podem apresentar sinais relacionados ao baixo desempenho acadêmico, redução da participação, baixa frequência e menor interação com as atividades propostas. Nesse sentido, Pecuchova e Drlik (2023) destacam que características relacionadas ao desempenho acadêmico e às interações dos estudantes durante o curso apresentam grande relevância para a identificação de alunos em risco de evasão.

Dessa forma, compreender os fatores associados ao abandono permite que instituições desenvolvam estratégias preventivas, utilizando informações acadêmicas e comportamentais para identificar estudantes que necessitam de acompanhamento. Desse modo, a análise preditiva surge como uma alternativa capaz de auxiliar na tomada de decisão, permitindo intervenções antecipadas.

2.2 Mineração de Dados Educacionais

A evolução das tecnologias digitais possibilitou que instituições educacionais passassem a armazenar grandes volumes de informações relacionadas ao percurso acadêmico dos estudantes. Deleña et al. (2025) afirmam que a partir desse cenário, surgiu a Mineração de Dados Educacionais, área destinada à aplicação de técnicas computacionais para analisar informações educacionais e identificar padrões relacionados ao processo de ensino e aprendizagem.

Segundo Medeiros et al. (2024), a mineração e análise de dados educacionais envolvem processos de coleta, medição, análise e interpretação de informações sobre estudantes e seus contextos, buscando compreender e aperfeiçoar os ambientes educacionais. Essas técnicas possibilitam acompanhar aspectos como desempenho acadêmico, frequência, participação em atividades, interações em ambientes virtuais de aprendizagem e progressão individual dos estudantes.

Diante do exposto, a análise preditiva educacional utiliza métodos estatísticos e algoritmos de aprendizado de máquina para identificar padrões históricos e estimar possíveis comportamentos futuros dos estudantes. Deleña et al. (2025) destacam que a aplicação de modelos preditivos sobre dados educacionais permite identificar estudantes com maior probabilidade de evasão, oferecendo suporte para ações institucionais preventivas.

Os modelos preditivos dependem da seleção adequada das variáveis utilizadas no processo de aprendizagem. Estudos demonstram que informações acadêmicas, como notas, frequência e aprovação em disciplinas, combinadas com características socioeconômicas e comportamentais, apresentam relevância na identificação de estudantes em situação de risco (Niyogisubizo et al., 2022).

Mustofa et al. (2025) utilizaram variáveis acadêmicas, socioeconômicas e institucionais, incluindo desempenho em disciplinas, situação financeira, características familiares e indicadores econômicos regionais, demonstrando que a combinação de diferentes dimensões da vida estudantil pode contribuir para uma identificação mais ampla dos fatores associados à evasão.

Além disso, pesquisas recentes têm destacado a importância de modelos interpretáveis, pois apenas prever quais estudantes apresentam risco de evasão não é suficiente. É necessário compreender quais fatores contribuíram para essa previsão, permitindo que as instituições desenvolvam intervenções mais adequadas e transparentes (Krüger et al., 2023; Carvalho et al., 2023).

O aprendizado de máquina (*machine learning*) tem sido amplamente utilizado na predição da evasão estudantil devido à sua capacidade de identificar padrões complexos em grandes conjuntos de dados. Entre os algoritmos frequentemente utilizados destacam-se *Random Forest*, Árvores de Decisão, Redes Neurais Artificiais, *Support Vector Machine* (SVM), *Gradient Boosting* e *XGBoost*.

O algoritmo *Random Forest* consiste em um conjunto de árvores preditoras que trabalham de forma combinada para melhorar a capacidade de classificação. Segundo Niyogisubizyo et al. (2022), essa abordagem permite obter maior precisão quando comparada à utilização de modelos individuais, sendo aplicada em diferentes problemas de classificação educacional.

As Redes Neurais Artificiais (Artificial Neural *Networks* – ANN) são modelos computacionais inspirados no funcionamento das redes neurais biológicas, capazes de estabelecer relações entre variáveis de entrada e produzir resultados preditivos. Esses modelos são compostos por camadas de entrada, camadas intermediárias e camada de saída, permitindo identificar relações não lineares presentes nos dados (Niygisubizo et al., 2022).

Outro modelo utilizado é o Gradient Boosting, uma técnica de aprendizado em conjunto (ensemble learning) aplicada em problemas de classificação e regressão. O XGBoost, uma evolução desse método, destaca-se pela capacidade de lidar com conjuntos de dados complexos e pela utilização de técnicas de regularização para melhorar o desempenho preditivo (Niygisubizo et al., 2022). Além desses modelos, algoritmos como *Naive Bayes*, máquinas de vetor de suporte e técnicas de agrupamento também apresentam aplicações na previsão da evasão. Pecuchova e Drlik (2023) destacam que diferentes técnicas de classificação apresentam resultados

relevantes dependendo das características dos dados analisados e do contexto educacional.

Para avaliar o desempenho desses modelos, são utilizadas métricas como acurácia, precisão, recall e F1-score. O rigor representa a proporção de previsões corretas realizadas pelo modelo; a precisão indica a proporção de estudantes identificados corretamente como pertencentes à classe de risco; o recall demonstra a capacidade do modelo em encontrar estudantes realmente vulneráveis à evasão; enquanto o F1-score representa o equilíbrio entre precisão e recall (Pecuchova & Drlik, 2023).

Deste modo, a combinação entre mineração de dados educacionais, aprendizado de máquina e análise preditiva apresenta potencial para auxiliar instituições na identificação antecipada de estudantes em risco, contribuindo para estratégias de permanência e redução da evasão escolar.

3. Metodologia

Este estudo caracteriza-se como uma Revisão Sistemática da Literatura (RSL), método amplamente utilizado na pesquisa científica para identificar, analisar e sintetizar evidências disponíveis sobre determinado tema. Segundo Maurício e Mill (2025), a RSL apresenta uma abordagem estruturada e abrangente para a obtenção e análise de estudos existentes, contribuindo para a redução de vieses subjetivas por meio da adoção de procedimentos sistemáticos, garantindo maior rigor, objetividade e possibilidade de replicação dos resultados.

O processo de identificação, seleção, elegibilidade e inclusão dos estudos foi conduzido conforme as recomendações do protocolo PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*). De acordo com Page, Moher, Bossuyt et al. (2021), o PRISMA 2020 foi desenvolvido para aprimorar a transparência e a qualidade das revisões sistemáticas, especialmente em estudos que avaliam os efeitos de intervenções na área da saúde.

Em razão de sua estrutura metodológica rigorosa e sistematizada, suas recomendações passaram a ser amplamente adotadas em diferentes áreas do conhecimento, incluindo pesquisas em educação e tecnologia educacional. Neste estudo, o protocolo PRISMA foi utilizado para orientar e documentar as etapas de identificação, remoção de duplicatas, triagem, avaliação da elegibilidade e inclusão dos estudos selecionados.

Para o gerenciamento e a organização dos estudos, foi utilizado o software Parsifal, uma ferramenta desenvolvida para apoiar revisões sistemáticas da literatura. O software possibilita estruturar a base de dados dos artigos selecionados, auxiliar no processo de triagem, organizar as informações extraídas dos estudos e favorecer o desenvolvimento colaborativo da revisão (Mauricio & Mill, 2025).

A busca foi realizada nas bases de dados Scopus e ScienceDirect, selecionadas por sua ampla relevância científica nas áreas de tecnologia educacional, inteligência artificial e análise de dados aplicada à educação. A estratégia de busca foi adaptada às especificidades de cada base. Em ambas, utilizou-se a seguinte *string* de pesquisa:

("school dropout" OR "educational dropout" OR "student dropout") AND ("predictive models")

A pesquisa foi realizada nos campos título, resumo e palavras-chave (TITLE-ABS-KEY), com o objetivo de identificar estudos relacionados à utilização de modelos preditivos para identificação e prevenção da evasão estudantil. Foram estabelecidos os seguintes critérios de inclusão: (I) estudos que apresentam modelos preditivos aplicados à identificação ou prevenção da evasão escolar; (II) artigos científicos completos com texto integral disponível; (III) publicações realizadas entre 2015 e 2026; (IV) estudos publicados nos idiomas português ou inglês; (V) artigos disponíveis em acesso aberto.

Como critérios de exclusão, foram considerados: (I) estudos duplicados; (II) resumos expandidos, trabalhos incompletos ou documentos que não fossem artigos científicos; (III) publicações em idiomas diferentes de português ou inglês; (IV) estudos sem disponibilidade de texto completo; (V) trabalhos que não apresentassem relação com análise preditiva aplicada à evasão estudantil.

Inicialmente, foram identificados 310 estudos, sendo 188 provenientes da Scopus e 122 da ScienceDirect. Após a aplicação dos filtros referentes ao período de publicação (2015 a 2026), tipo de documento (artigos científicos), idioma (português e inglês) e disponibilidade de acesso aberto, permaneceram 131 estudos, dos quais 65 eram provenientes da Scopus e 66 da ScienceDirect.

Na etapa de triagem, foram removidos 15 artigos duplicados, resultando em 116 estudos para análise dos títulos. Após essa etapa, 86 artigos foram excluídos por não apresentarem relação direta com o tema investigado, permanecendo 30 estudos para análise dos resumos. Em seguida, 23 estudos foram excluídos por não atenderem aos critérios estabelecidos, restando sete artigos para leitura na íntegra. Na etapa de elegibilidade, um artigo foi excluído por não atender aos critérios definidos, totalizando seis estudos incluídos na revisão sistemática, conforme apresentado na Figura 1.

Figura 1 – Fluxograma do processo de seleção dos estudos segundo o protocolo PRISMA 2020.

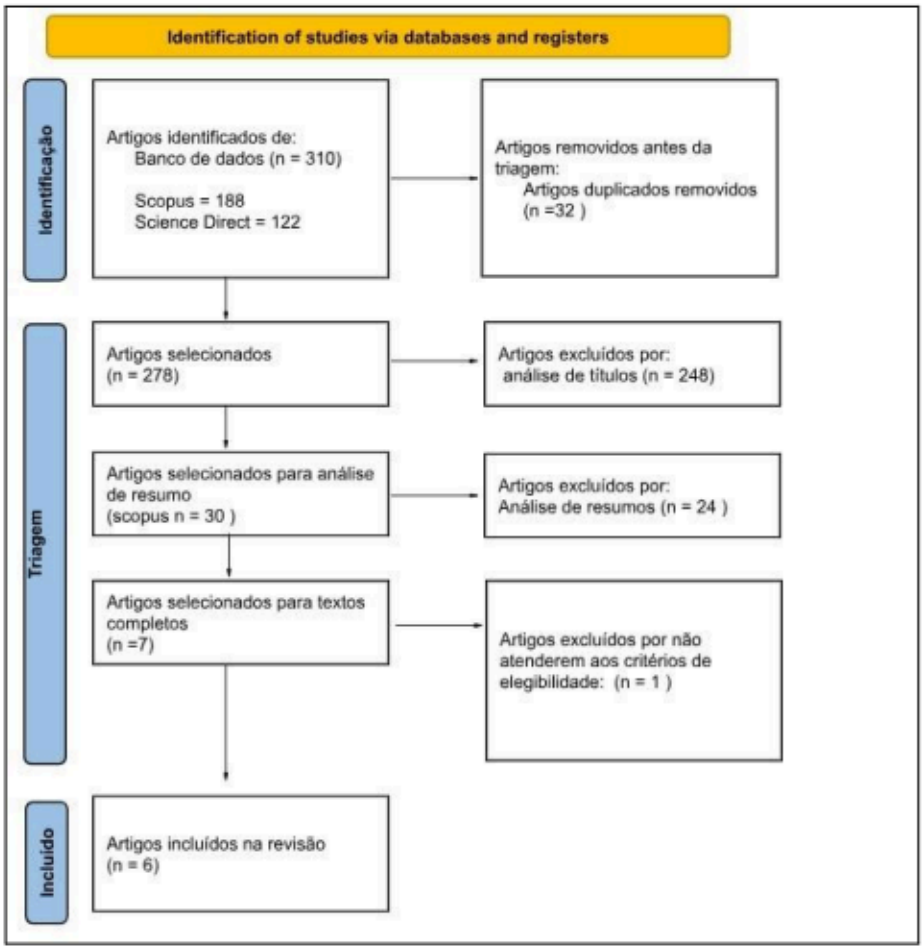

Fonte: elaborado pelo autor (2026)

Após a aplicação dos critérios estabelecidos, os seis estudos incluídos foram analisados quanto aos seus objetivos, métodos preditivos empregados, bases de dados utilizadas, variáveis consideradas e principais resultados, possibilitando uma análise comparativa das abordagens adotadas para a identificação do risco de evasão estudantil.

4. Resultados e Discussão

4.1 Síntese dos estudos incluídos na revisão sistemática

Após a aplicação dos critérios de inclusão e exclusão estabelecidos na revisão sistemática, foram selecionados seis estudos para análise. Os artigos incluídos foram avaliados considerando seus objetivos, abordagens metodológicas, técnicas de modelagem preditiva utilizadas e principais contribuições para a identificação do risco de evasão estudantil. A síntese dos estudos selecionados é apresentada na Tabela 1.

Tabela 1 - Síntese dos estudos selecionados

Autor/Ano	Objetivo	Método/Algoritmo	Principais resultados
Krüger; Britto Jr. & Barddal (2023)	Desenvolver um modelo de aprendizado de máquina explicável para prever a evasão estudantil e identificar fatores associados ao abandono.	XGBoost, LightGBM, CatBoost e Random Forest, com técnicas de IA Explicável (SHAP).	O modelo apresentou elevado desempenho preditivo e permitiu identificar fatores associados à evasão, favorecendo ações preventivas.
Carvalho; Mattos & Aguiar (2023)	Investigar a interpretabilidade de modelos preditivos aplicados à evasão no ensino superior.	Modelos de Machine Learning Explicável (XAI), utilizando SHAP e clusterização das explicações.	Modelos com desempenho semelhante apresentaram diferentes níveis de interpretabilidade, contribuindo para a compreensão dos fatores relacionados à evasão.
Lopez-Muñoz; Gonzalez Serrano & Sanchez-Fer reira (2026)	Revisar técnicas de aprendizado de máquina utilizadas na predição da evasão no ensino superior.	Revisão sistemática de modelos de Machine Learning, destacando Random Forest, Árvores de Decisão, SVM, Redes Neurais, XGBoost e Gradient Boosting.	Identificou ampla utilização de modelos preditivos e destacou a importância da integração de diferentes fatores e da interpretabilidade dos modelos.
Niyogisubizo et al. (2022)	Desenvolver um modelo preditivo baseado em ensemble learning para identificar estudantes em risco de evasão.	Stacking Ensemble, combinando Random Forest, Decision Tree, Naïve Bayes, Logistic Regression, KNN e SVM.	O modelo ensemble apresentou melhor desempenho que os modelos individuais, favorecendo a identificação precoce de estudantes em risco.
Souza et al. (2026)	Analisar o estado da arte da aplicação de Machine Learning na prevenção da evasão escolar.	Revisão sistemática com predominância de Random Forest, Redes Neurais Artificiais, XGBoost, Árvores de Decisão, SVM e Regressão Logística.	Predominaram algoritmos supervisionados, com destaque para Random Forest, Redes Neurais e XGBoost, além de relevância da seleção de atributos.

continua

continuação

Vingi et al. (2024)	Revisar estudos sobre algoritmos de aprendizado de máquina aplicados à predição do abandono escolar.	Revisão sistemática com destaque para Random Forest, Decision Tree, SVM, Redes Neurais, Naïve Bayes, Regressão Logística e Gradient Boosting.	Os modelos mostraram potencial para prever a evasão, embora persistam desafios relacionados à qualidade dos dados e à interpretabilidade.

Fonte: elaborado pelo autor (2026)

A análise dos estudos selecionados evidencia que a utilização de técnicas de aprendizado de máquina tem se consolidado como uma abordagem promissora para a identificação precoce de estudantes em risco de evasão. Os trabalhos analisados demonstram uma evolução dos modelos preditivos, passando de abordagens voltadas exclusivamente ao desempenho dos algoritmos para métodos capazes de fornecer informações que auxiliem a compreensão dos fatores relacionados ao abandono escolar.

Niyogisubizo et al. (2022) desenvolveram um modelo baseado em ensemble learning, utilizando a combinação de algoritmos como Random Forest, Extreme Gradient Boosting (XGBoost), Gradient Boosting e Redes Neurais Artificiais. Os resultados indicaram que a abordagem combinada apresentou desempenho superior aos modelos individuais, demonstrando que a integração de diferentes técnicas pode contribuir para aumentar a capacidade de identificação de estudantes com maior probabilidade de evasão.

Segundo os autores, a previsão antecipada permite que instituições de ensino adotem medidas preventivas antes que o abandono ocorra. De forma complementar, Krüger et al. (2023) destacam que a capacidade preditiva dos modelos não deve ser avaliada somente pela precisão dos resultados, mas também pela possibilidade de compreender os fatores que influenciam as previsões. Nesse sentido, os autores utilizaram técnicas de aprendizado de máquina explicável para identificar possíveis razões associadas à evasão, evidenciando que a interpretação dos resultados é fundamental para transformar previsões em ações institucionais.

Entretanto, os estudos analisados também apontam desafios relacionados à aplicação desses modelos. Conforme Souza et al. (2026), “desafios relacionados à interpretabilidade dos modelos e à integração de dados heterogêneos persistem”. A identificação dos fatores associados à evasão é uma tarefa complexa, pois, embora determinados padrões possam ser observados em diferentes instituições, outros aspectos dependem das características específicas do contexto educacional analisado.

Nesse sentido, Vingi et al. (2026) ressalta a necessidade de maior interpretabilidade dos modelos preditivos, uma vez que apenas indicar quais estudantes apresentam risco de abandono não é suficiente. É necessário compreender quais fatores contribuíram para essa classificação, permitindo que gestores e equipes pedagógicas desenvolvam intervenções mais adequadas.

Essa questão também é abordada por Carvalho, Mattos e Aguiar (2023), que investigaram a interpretabilidade de modelos aplicados à predição de evasão no ensino superior. Os autores demonstram que modelos com desempenho preditivo semelhante podem apresentar diferentes características quanto às métricas de interpretabilidade, reforçando que a avaliação de um modelo deve considerar não apenas sua capacidade de previsão, mas também sua transparência e utilidade prática.

Outro desafio identificado refere-se à disponibilidade e qualidade dos dados utilizados para treinamento dos modelos. Niyogisubizo et al. (2022) destacam que conjuntos de dados limitados podem restringir a capacidade dos algoritmos em encontrar padrões mais precisos, sendo necessária a ampliação das bases utilizadas e a incorporação de diferentes características dos estudantes. Além disso, os autores ressaltam que o fator temporal deve ser considerado, pois diferentes períodos acadêmicos podem apresentar comportamentos distintos e influenciar a interpretação dos resultados preditivos.

De modo geral, os estudos analisados indicam que os modelos preditivos baseados em aprendizado de máquina apresentam grande potencial para auxiliar no enfrentamento da evasão escolar. Contudo, sua utilização efetiva depende de avanços relacionados à explicabilidade dos modelos, qualidade dos dados, adaptação ao contexto institucional e uso ético das informações. Assim, essas ferramentas devem ser compreendidas como instrumentos de apoio à tomada de decisão, contribuindo para a identificação antecipada de situações de risco e para o desenvolvimento de estratégias preventivas.

5. Considerações Finais

A presente Revisão Sistemática da Literatura permitiu analisar diferentes modelos preditivos utilizados para a identificação de estudantes em risco de evasão, evidenciando o potencial da análise preditiva educacional como ferramenta de apoio às instituições de ensino. Os estudos analisados demonstram que a utilização de técnicas de aprendizado de máquina possibilita identificar padrões associados ao abandono estudantil, contribuindo para a criação de estratégias preventivas e intervenções mais direcionadas.

Os resultados indicam a predominância de algoritmos supervisionados na predição

da evasão, com destaque para técnicas como Random Forest, Regressão Logística, Árvores de Decisão, Support Vector Machine (SVM), Redes Neurais e métodos de ensemble learning. Essas abordagens apresentam resultados relevantes ao analisarem diferentes características presentes nos dados educacionais, possibilitando maior capacidade de identificação de estudantes em situação de risco.

A análise dos estudos também evidenciou que a evasão escolar é um fenômeno multifatorial, envolvendo aspectos acadêmicos, socioeconômicos e comportamentais. Além das características relacionadas ao desempenho dos estudantes, fatores como participação, engajamento, condições sociais e sentimento de pertencimento institucional apresentam influência significativa no processo de permanência ou abandono.

Entretanto, apesar dos avanços proporcionados pelos modelos preditivos, permanecem desafios relacionados à qualidade e disponibilidade dos dados, à integração de diferentes fontes de informação, à interpretabilidade dos modelos e às questões éticas envolvidas no uso dessas tecnologias. Nesse contexto, destaca-se a importância de modelos que, além de apresentarem bons resultados preditivos, possibilitem compreender os fatores que influenciam as previsões, permitindo uma utilização mais transparente e responsável.

Dessa forma, conclui-se que a análise preditiva educacional apresenta grande potencial para auxiliar gestores e instituições de ensino na identificação antecipada de situações de risco de evasão. Contudo, sua aplicação deve ser associada a estratégias institucionais de acompanhamento e apoio aos estudantes, utilizando os modelos preditivos como instrumentos de suporte à tomada de decisão e não como mecanismos isolados de avaliação.

Referências

Carvalho, C. S.; Mattos, J. C. B. de & Aguiar, M. S. **Avaliação da interpretabilidade de modelos por meio da clusterização de explicações no contexto da predição de evasão no ensino superior.** 2023. In: Simpósio Brasileiro de Informática na Educação (SBIE). DOI: https://doi.org/10.5753/sbie.2023.234435.

Deleña, R. D.; Dia, N. J.; Sacayan, R. R.; Sieras, J. C.; Khalid, S. A.; Macatotong, A. H. T. & Gulam, S. B. Predicting student retention: A comparative study of machine learning approach utilizing sociodemographic and academic factors. 2025. **Systems and Soft Computing**. DOI: https://doi.org/10.1016/j.sasc.2025.200352.

Duro, B.; Gomes, A.; Borges, A. R. & Correira, F. B. Understanding and Preventing Student Dropout in Higher Education: A Literature Review. 2026. **Procedia Computer Science**. DOI: https://doi.org/10.1016/j.procs.2026.02.444

Krüger, J. G. C.; Britto Junior, A. de S. & Barddal, J. P. An explainable machine learning approach for student dropout prediction. **Expert Systems with Applications**, v. 233, 2023.

Lopez-Muñoz, G. L.; Serrano, C. G. & Sanchez-Ferreira, C. Student dropout prediction in higher education: A systematic review of machine learning methods and risk factors. **Journal of Information Technology Education: Research**, v. 25, p. 1-28, 2026.

Martinez, J. & Castillo, D. Prediction of student dropout using Artificial Intelligence algorithms. **Procedia Computer Science**, v. 251, 2024

Mauricio, G. C. & Mill, D. Condução de revisões sistemáticas de literatura mediada pela ferramenta Parsif.al: potencialidades e limites. 2025. **Dialogia**, São Paulo. DOI: https://doi.org/10.5585/54.2025.28438. Acesso em: maio de 2026.

Medeiros, L. B. G. de & Padilha, T. P. P. **Mineração de dados para detectar evasão escolar utilizando algoritmos de classificação.** 2024. Anais CIET:Horizonte. Disponível em: https://ciet.ufscar.br/submissao/index.php/ciet/article/view/988. Acesso em: maio de 2026.

Mustofa, S.; Emon, Y. R.; Mamun, S. B.; Akhy, S. A. & Ahad, M. T. A novel AI-driven model for student dropout risk analysis with explainable AI insights. **Computers and Education**: Artificial Intelligence. 2025. DOI: https://doi.org/10.1016/j.caeai.2024.100352. Acesso em: maio de 2026.

Niyogisubizo, J.; Liao, L.; Nziyumva, E.; Murwanashyaka, E. & Nshimyumukiza, P. C. Predicting student's dropout in university classes using two-layer ensemble machine learning approach: A novel stacked generalization. **Computers and Education**: Artificial Intelligence, DOI: https://doi.org/10.1016/j.caeai.2022.100066. Acesso em: jul. de 2026.

Page, M. J.; McKenzie, J. E.; Bossuyt, P. M.; Boutron, H. T. C; Mulrow, C. D. **A declaração PRISMA 2020:** uma diretriz atualizada para relatar revisões sistemáticas. Disponível em: http://www.prisma-statement.org/ Acesso em: 02 jul. 2026.

Pecuchova, J. & Drlik, M. (2023) Predicting Students at Risk of Early Dropping Out from Course Using Ensemble Classification Methods. **Procedia Computer Science**. DOI: https://doi.org/10.1016/j.procs.2023.10.316 . Acesso em maio de 2026.

Souza, W. S. de et al. Modelagem preditiva baseada em machine learning para prevenção da evasão escolar: uma revisão sistemática. 2026. **Revista Multidisciplinar Integrada – REMI.** Disponível em: https://revistas.unipacto.com.br/index.php/multidisciplinar/pt_BR/article/view/385. Acesso em: maio de 2026.

Sihare, S. R. (2024). Student dropout analysis in higher education and retention by artificial intelligence and machine learning. **SN Computer Science**. 2026. DOI: https://doi.org/10.1007/s42979-023-02458-w Acesso em: maio de 2026.

Vingi, A.; Correia, A. R. L; Oliveira, A. L. T. & Abreu, C. B. C. Predição de abandono escolar utilizando algoritmos de aprendizado de máquina: uma revisão sistemática e análise crítica. 2026. **Revista Multidisciplinar Integrada** - REMI, 2(07), 2026.

Sobre o autor(a)

Gislaine Pereira de Souza

Pós-graduada em Clínica e Terapêutica Nutricional pelo Instituto de Pesquisa, Capacitação e Especialização (IPCE - 2004)

Graduação em Nutrição pelo Centro Universitário Franciscano (2003).

Nutricionista e Responsável Técnica pelo Serviço de Alimentação e Nutrição do refeitório do Instituto Federal de Santa Catarina (IFSC) – Câmpus Araranguá.

PARTE II

IA COMO SUPORTE E PERSONALIZAÇÃO DO ENSINO

CAPÍTULO 6

Plataforma adaptativas e personalização da educação

Carla Cristiane Boita

1. Introdução

A inserção da Inteligência Artificial (IA) e das tecnologias digitais modifica o cenário educacional contemporâneo. A cultura digital estabelece um ambiente onde a tecnologia atua como elemento estratégico para o ensino, possibilitando a transição de modelos padronizados para formatos de aprendizagem personalizados. A estrutura tradicional de educação em massa apresenta limites para atender às demandas cognitivas específicas de cada aluno. Sistemas educacionais baseados em IA identificam os ritmos individuais e fornecem soluções para essas barreiras estruturais.

As plataformas educacionais inteligentes operam por meio de análise de dados e algoritmos de aprendizado de máquina para mapear o perfil do estudante. Estes sistemas avaliam o conhecimento prévio, rastreiam o progresso em tempo real e ajustam o nível de complexidade do conteúdo apresentado. A aplicação de tecnologias adaptativas cria trajetórias pedagógicas individualizadas, elevando o engajamento e o rendimento escolar.

Ferramentas como a *Khan Academy* exemplificam o uso prático destes mecanismos, entregando respostas contínuas e recursos interativos adaptados ao usuário. A fundamentação teórica para o uso das plataformas adaptativas apoia-se em conceitos das ciências cognitivas. A Teoria da Carga Cognitiva, estruturada por Sweller (1988), indica que a apresentação gradual e organizada da informação minimiza a sobrecarga mental e otimiza a assimilação dos saberes. A Teoria das Inteligências Múltiplas, de Gardner (1995), reforça a urgência de contemplar diferentes estilos de compreensão e raciocínio no processo educativo. A tecnologia atua como suporte prático para materializar essas teorias na rotina escolar.

O objetivo deste artigo é analisar a aplicação de plataformas adaptativas na personalização da educação. O estudo investiga os mecanismos de funcionamento destas ferramentas, as implicações pedagógicas do seu uso e as barreiras operacionais para a implementação no ambiente de ensino. A pesquisa fundamenta-se em uma revisão de literatura para examinar como a inteligência artificial promove o

desenvolvimento educacional e quais são as exigências de infraestrutura e de capacitação requeridas para a prática docente.

2. Referencial Teórico

A transição para a educação personalizada exige a compreensão de elementos pedagógicos e tecnológicos integrados. Esta seção estrutura os fundamentos que sustentam a aplicação de sistemas inteligentes no ambiente escolar. Inicialmente, o texto explora os princípios da instrução individualizada sob a ótica das teorias cognitivas da aprendizagem. Na sequência, a pesquisa examina a operação algorítmica da inteligência artificial nas plataformas adaptativas. O referencial encerra com a análise da reconfiguração do papel docente na mediação digital articulada às metodologias ativas.

2.1 Fundamentos da Educação Personalizada e Teorias Cognitivas

A educação personalizada organiza o aprendizado nas demandas e no ritmo específico do estudante. O modelo de instrução padronizado transita para dinâmicas individualizadas. A exigência de adaptação em tempo real requer ferramentas tecnológicas estruturadas. O foco da educação reside em fornecer respostas e recomendações direcionadas para respeitar a capacidade de assimilação individual, conforme definem Blay e McClaskey (2010). O ensino ajusta a navegação no espaço escolar e atende as necessidades específicas, segundo Costa (2021).

A eficácia das abordagens educacionais personalizadas encontra fundamentação teórica rigorosa nas ciências cognitivas humanas clássicas. A memória de trabalho das pessoas apresenta restrições para processar e armazenar muitas informações novas simultaneamente. A Teoria da Carga Cognitiva, postulada por Sweller (1988), indica a precisão de ordenar gradualmente os estímulos escolares para prevenir o esgotamento mental do aluno. O fracionamento lógico dos materiais otimiza a assimilação dos conceitos durante as atividades nas escolas, conforme Sweller (1988).

Projetos educacionais focados em materiais interativos autossuficientes e na aprendizagem autodirigida acomodam diferentes estilos de processamento lógico ou visual. A organização metodológica contempla diversas variações de compreensão individual, como detalham Barberà e Rocheira (2010). O estudante atua como agente central na construção da rede de informações. A disposição de múltiplas representações sonoras e visuais adequa as aulas aos ritmos cognitivos dos aprendizes, consolidando a matriz teórica essencial para o andamento dos projetos.

O desenho de estratégias didáticas modernas requer a materialização dos pressupostos cognitivos listados nas práticas diárias de educação. As intervenções

exatas geram maior engajamento estudantil quando consideram a carga mental suportada pelo aluno durante o período letivo, conforme os preceitos de Sweller (1988).

A proposição de um roteiro de navegação individual reforça a necessidade da aprendizagem autodirigida analisada criticamente nos estudos desenvolvidos por Barberà e Rocheira (2010) sobre suportes tecnológicos. A articulação destas matrizes conceituais estabelece a base teórica adequada para a inserção das ferramentas de instrução individualizada nas instituições de ensino.

O alinhamento rigoroso entre a estruturação metodológica e a capacidade cognitiva dos aprendizes conduz a elaboração de projetos educacionais inovadores, segundo Blay e McClaskey (2010). A teoria demonstra que o ensino direcionado garante um ritmo constante de progressão nas disciplinas curriculares para os usuários do sistema, conforme Costa
(2021).

2.2 Mecanismos de Inteligência Artificial em Plataformas Adaptativas

As plataformas adaptativas operam como espaços virtuais inteligentes amparados no poder analítico da inteligência artificial. Os algoritmos processam dados massivos para estruturar modelos dinâmicos de avaliação contínua do perfil de cada aluno, como explicam Brusilovsky e Millán (2007). A arquitetura computacional prevê os padrões de acertos e falhas registrados pelo usuário nas sessões. Os sistemas de hipermídia selecionam testes e roteiros apropriados para solucionar as lacunas mapeadas no desenvolvimento lógico.

Os mecanismos aplicados pelo aprendizado de máquina classificam o domínio cognitivo do estudante em escalas precisas de proficiência lógica. A modelagem preditiva viabiliza o ajuste dinâmico da complexidade das disciplinas oferecidas na tela dos dispositivos. O cruzamento contínuo de variáveis matemáticas aumenta a assertividade das recomendações geradas de forma ininterrupta pelo software, segundo expõe Domingos (2017). As plataformas examinam o desempenho histórico para traçar projeções futuras consistentes com a realidade discente.

O sequenciamento didático garante a oferta de desafios computacionais proporcionais à evolução do conhecimento absorvido pelo usuário em cada módulo. A estrutura de inteligência híbrida articula os dados armazenados para formular trilhas flexíveis de conteúdos, como defende Cukurova (2024). Os sistemas de testagem informatizada detectam os erros recorrentes do indivíduo e apresentam correções focadas nas matrizes conceituais de maior fragilidade para o aluno, conforme apontam Alavares e Catalani (2015).

A capacidade de modulação algorítmica permite a construção do ensino individual

em larga escala nas redes educacionais contemporâneas. As interações sucessivas com os painéis gráficos transformam as informações estatísticas em soluções lógicas automáticas fornecidas para a gestão. O rastreamento de dados em hipermídia detalhado na obra de Brusilovsky e Millán (2007) possibilita a inserção de novos conteúdos didáticos para elevar o tempo de permanência produtiva no sistema de aprendizado.

O funcionamento integrado das inteligências artificiais baseia as metodologias de ensino suportadas por tecnologias contemporâneas de alta precisão. Os parâmetros organizados pelos modelos de processamento analítico verificados por Domingos (2017) validam o suporte estrutural. A aplicação técnica das testagens sucessivas estabelecidas por Alavares e Catalani (2015) consolida o processo formativo dos discentes nos ambientes digitais interativos com respostas focadas nas fragilidades acadêmicas mapeadas nas atividades e lições diárias nas escolas.

2.3 A Transformação do Papel Docente e as Metodologias Ativas

A introdução das ferramentas digitais inteligentes reorganiza as práticas pedagógicas e a posição ocupada pelo professor no interior das instituições de ensino. O educador, de acordo com as reflexões de Valente (2018), substitui a ação de repasse unilateral da informação para assumir a condição central de mediador técnico e motivacional do saber sistematizado. A discente estrutura o seu percurso de raciocínio lógico em atividades fundamentadas na aplicação rigorosa das metodologias ativas.

Os recursos automatizados processam as dinâmicas analíticas do ensino para apoiar diretamente o planejamento didático formulado diariamente. A tecnologia trabalha sob as premissas de um modelo consolidado de inteligência híbrida, segundo defende Cukurova (2024), na tutoria contínua escolar. O profissional decodifica as métricas exibidas nos painéis gráficos das máquinas para determinar intervenções acadêmicas direcionadas. Os sistemas tecnológicos inteligentes jamais extinguem as relações humanas exigidas na formação cognitiva e emocional dos jovens nas escolas.

Os algoritmos executam os cálculos de repetição matemática e geram laudos com a evolução estatística de cada turma acompanhada. A manutenção do vínculo interpessoal, como evidenciam os estudos de Valente (2018), garante o amadurecimento das competências de comunicação requeridas no progresso das metodologias ativas. O professor concentra as suas energias na contextualização social rigorosa da disciplina ensinada e direciona a relação de empatia indispensável e existente no ambiente diário da sala.

A assimilação completa dos dispositivos inovadores demanda a capacitação técnica para garantir a inserção ética da inteligência artificial nas escolas. O letramento digital dos professores instrui a leitura exata do volume de informações geradas

diariamente nas plataformas, conforme recomendam Akgun e Greenhow (2021). Os educadores precisam compreender a mecânica dos algoritmos para impedir análises incorretas dos diagnósticos individuais oferecidos para os jovens envolvidos na formação curricular nas respectivas unidades.

A infraestrutura pedagógica moderna determina a proteção sistemática dos registros escolares como premissa inviolável das ferramentas digitais. A instrução especializada firma a governança de dados no cotidiano da atividade docente aplicada na educação básica. As premissas apontadas por Akgun e Greenhow (2021) consolidam a necessidade inegável do planejamento estruturado pelas redes de ensino para habilitar os profissionais na mediação plena do modelo de inteligência híbrida referendado por Cukurova (2024).

3. Metodologia

Esta pesquisa adota a abordagem de Revisão de Literatura articulada a um estudo de natureza qualitativa para investigar a aplicação das plataformas adaptativas na educação. A escolha metodológica justifica-se pela capacidade de fornecer uma síntese abrangente das evidências científicas disponíveis sobre o tema. A pesquisa bibliográfica qualitativa permite a identificação dos conhecimentos documentados para a construção de uma base teórica rigorosa, segundo definem as diretrizes de Gil (2010).

O levantamento das obras ocorreu por meio de buscas em bases acadêmicas e repositórios científicos, selecionando artigos revisados por pares, teses e capítulos de livros. A pesquisa utilizou descritores norteadores, como inteligência artificial, plataformas adaptativas, ensino personalizado e metodologias de aprendizagem. O foco da leitura recaiu sobre produções que discutissem a implementação prática dessas tecnologias, os seus fundamentos cognitivos e as exigências operacionais associadas à infraestrutura escolar.

A seleção dos materiais abrangeu estudos que apresentassem resultados empíricos ou revisões teóricas consistentes voltadas para os níveis de Educação Básica. Trabalhos focados estritamente no Ensino Superior ou na educação de jovens e adultos não foram priorizados, de modo a manter o escopo alinhado à proposta central do artigo. Além disso, editoriais e materiais de opinião sem embasamento científico foram descartados para garantir a validade acadêmica da investigação.

A análise dos textos seguiu um procedimento de síntese temática, agrupando as informações em categorias pertinentes ao objeto de estudo. A partir da leitura integral das obras selecionadas, a organização do referencial bibliográfico possibilitou identificar padrões, tendências e lacunas na literatura, estruturando uma narrativa baseada em evidências sobre o estado atual do uso de tecnologias adaptativas no

ambiente de ensino.

4. Análise e Discussão dos Resultados

A integração de tecnologias digitais altera substancialmente a dinâmica escolar contemporânea. Esta seção examina as evidências práticas do uso de plataformas inteligentes nas instituições de ensino. O primeiro segmento avalia os impactos diretos no engajamento e no desempenho dos estudantes. A segunda etapa investiga a arquitetura algorítmica responsável pela modulação dos conteúdos em tempo real. O último item analisa as barreiras éticas, as exigências estruturais e a necessidade de formação docente para assegurar o funcionamento ininterrupto destas inovações.

4.1 Impactos Práticos no Engajamento e Desempenho Escolar

A aplicação prática de recursos digitais modifica os indicadores de proficiência matemática nas escolas brasileiras. A utilização contínua da Khan Academy gera melhorias quantitativas expressivas no aprendizado, como evidenciam Machado et al. (2020). As plataformas funcionam como agentes catalisadores do rendimento, pois entregam trilhas flexíveis e corrigem defasagens históricas, conforme os relatos descritos por Sena (2022). O engajamento aumenta quando a interface reconhece o avanço individual e fornece respostas interativas durante o processo de resolução de equações complexas.

O sucesso das ferramentas depende da capacidade de prender a atenção do aluno durante a navegação. Os estudos revisados por Barros, Silva e Silva (2020) comprovam que o formato visual e os estímulos constantes mantêm o foco nas lições. O retorno imediato oferecido pelos sistemas digitais elimina dúvidas pontuais e otimiza a construção do conhecimento matemático, segundo a perspectiva de Baião e Oliveira (2021). O dinamismo do software impede a dispersão comum verificada nas aulas expositivas convencionais.

A análise de casos empíricos ratifica a utilidade das inovações na rotina pedagógica das instituições. A plataforma Geekie One apresenta resultados sólidos ao mapear fragilidades cognitivas e sugerir intervenções precisas, de acordo com as observações de Ferreira e Monteiro (2022). O sistema atua com eficiência ao reconfigurar as recomendações para cada estudante.

Esses mecanismos formam a essência dos ambientes virtuais contemporâneos listados nas diretrizes da AACE (2021), que classificam a aprendizagem moldável como o pilar da educação moderna. O impacto estende-se para além das ciências exatas, englobando também as habilidades de escrita e idiomas. A inteligência artificial estimula a redação na educação básica ao fornecer correções sintáticas

instantâneas, conforme Şahin (2026). A presença virtual do instrutor em vídeos interativos amplia a conexão social e favorece a assimilação dos conteúdos linguísticos, como constatam os experimentos empíricos coordenados por Kizilcec, Bailenson e Gomez (2017).

Os dados apurados nesta pesquisa respondem positivamente às demandas de modernização do letramento. A investigação comprova que as tecnologias de informação figuram como recursos didáticos centrais para o sucesso educativo, corroborando as teses de Lima e Araújo (2021). Os índices de aprovação nas disciplinas analisadas saltam significativamente após a adoção dos sistemas virtuais. A teoria cruza com a realidade escolar verificada, comprovando que a ferramenta digital reduz falhas de aprendizagem e consolida o saber prático.

A evidência prática revela o alcance da inserção tecnológica perante as limitações estruturais observadas. As informações extraídas demonstram que a inteligência artificial expande o potencial cognitivo dos alunos, alinhando-se aos argumentos propostos por Luckin et al. (2016). A pesquisa constata a viabilidade plena da modulação escolar contínua. As avaliações de desempenho ratificam a hipótese inicial da eficácia algorítmica. Os recursos digitais transformam a instrução passiva em uma experiência autônoma capaz de elevar a qualidade educacional.

4.2 A Arquitetura Algorítmica e a Modulação do Ensino

A personalização exige uma infraestrutura algorítmica sofisticada para rastrear o histórico de cada usuário. Os sistemas de hipermídia formulam modelos precisos que ajustam a navegação e a entrega de materiais didáticos, como definem Brusilovsky e Millán (2007). As máquinas processam dados massivos para identificar padrões lógicos de raciocínio. O aprendizado de máquina refina as recomendações educacionais com base em cálculos estatísticos constantes e ininterruptos, processo detalhado na análise técnica conduzida pelos estudos de Domingos (2017).

A arquitetura computacional respeita as limitações da memória humana. A fragmentação das informações evita a sobrecarga mental durante os estudos complexos, aplicando fielmente a Teoria da Carga Cognitiva de Sweller (1988). A programação digital estrutura as lições para manter o ritmo exato de assimilação de cada indivíduo, como orientam Blay e McClaskey (2010). Essa adequação sistêmica materializa a dinâmica flexível exigida pelas abordagens educacionais modernas analisadas cuidadosamente na tese acadêmica estruturada pelas investigações de Costa (2021).

O avanço das redes virtuais possibilita o desenho de tutores inteligentes altamente responsivos. A conteinerização de algoritmos otimiza o processamento gráfico nas escolas, garantindo velocidade nas respostas fornecidas, segundo aponta Radu (2025).

As técnicas de reforço profundo criam caminhos virtuais flexíveis que recompensam o acerto e ajustam as falhas instantaneamente, conforme demonstram Sallaah et al. (2025). A lógica matemática dos computadores converte as atividades estanques em experiências moldáveis fundamentais para a rotina de qualquer estudante.

As soluções algorítmicas organizam o conhecimento por meio de conexões visuais. A estruturação baseada em grafos aprimora a sugestão de conteúdos técnicos ao prever as dificuldades do aluno, conforme investigam Costa, Pinto e Gonçalves (2025). O diagnóstico inicial ocorre rapidamente com o suporte de testes informatizados. A referida testagem calibra a dificuldade das questões apresentadas na tela em tempo real, metodologia validada cientificamente pelos extensos mapeamentos educacionais executados pelos pesquisadores brasileiros Alavares e Catalani (2015).

A investigação atual atesta o funcionamento prático dos códigos estruturais avaliados na teoria. Os dados extraídos confirmam que as plataformas operam a leitura contínua de proficiência sem sobrecarregar o usuário. A pesquisa revela a precisão das avaliações formativas automatizadas, estabelecendo um diálogo coerente com as críticas levantadas por Borvalho (2023) sobre mensuração escolar. A arquitetura inteligente promove ajustes milimétricos nas trilhas de ensino. O cruzamento das informações garante a validade técnica dos softwares empregados no sistema educacional.

O estudo comprova que os materiais autossuficientes ganham efetividade com a gestão computacional. A autonomia discente documentada na pesquisa prática espelha os conceitos de aprendizagem autodirigida defendidos por Barberà e Rocheira (2010). Os registros confirmam a necessidade de construir inteligências artificiais robustas e seguras para suportar variações extremas de acesso, conforme alerta Dietterich (2017). A modulação algorítmica entrega os resultados esperados pelas escolas, resolvendo a questão central de como aplicar a tecnologia em larga escala.

4.3 Desafios Éticos, Segurança de Dados e Infraestrutura

O processamento massivo de registros escolares exige políticas severas de governança digital. A preservação da privacidade necessita de modelos arquitetônicos que blindem as informações dos estudantes contra violações externas, premissa inegociável descrita por Imohimi (2025). As decisões das máquinas frequentemente carecem de transparência técnica. A adoção de sistemas explicáveis torna o raciocínio computacional visível e compreensível para toda a comunidade acadêmica, garantindo a lisura do processo de avaliação, segundo as análises recentes de Manna e Sett (2024).

As inovações geram dilemas morais relacionados à equidade e aos vieses algorítmicos. O uso irrestrito da inteligência artificial na mensuração de notas suscita

riscos que demandam regulamentações estritas, conforme alertam Bulut et al. (2024). A tecnologia não deve ampliar as desigualdades estruturais antigas. As instituições precisam debater as barreiras éticas na educação básica para promover uma cultura de letramento tecnológico justo e inclusivo, seguindo os apontamentos teóricos formulados nas extensas publicações de Akgun e Greenhow (2021).

A presença humana permanece insubstituível na dinâmica pedagógica modernizada. O conceito de inteligência híbrida une o rigor analítico dos computadores à empatia mediadora dos educadores, como fundamenta magistralmente Cukurova (2024). A escola deixa de focar na transmissão unilateral para adotar projetos integrados. O professor assume a função de orientar o raciocínio enquanto os alunos atuam na construção lógica do saber diário, refletindo o modelo de metodologias ativas examinado com precisão pelas pesquisas conduzidas por Valente (2018).

O sucesso da implementação tecnológica depende primordialmente da materialização adequada do planejamento didático. O designer instrucional traduz os conteúdos densos em experiências visuais acessíveis e fluídas nos ambientes virtuais, na visão arquitetônica de Fernandes (2024). As contribuições destas ferramentas exigem computadores atualizados e conectividade ininterrupta nas redes de ensino públicas e privadas. A infraestrutura básica condiciona a qualidade da entrega do conhecimento e o nível de engajamento do estudante, conforme salientam Guimarães, Vimercate e Schizzi (2022).

A pesquisa revela que as lacunas de infraestrutura prejudicam a aplicação equitativa da tecnologia. Os achados de campo contrastam a inteligência de Cukurova (2024) com as limitações de hardware presentes nas escolas estudadas. O estudo comprova que a capacitação docente atenua a opacidade algorítmica advertida por Manna e Sett (2024). Os dados apurados indicam que a transição para ambientes virtuais requer a formulação de diretrizes morais internas. As informações coletadas respondem afirmativamente sobre a eficácia pedagógica quando há suporte estrutural.

A investigação conclui que a segurança informacional é indissociável da prática educativa moderna. A comparação dos resultados valida a urgência de governança ressaltada por Imohimi (2025) e as premissas de Akgun e Greenhow (2021). A rotina escolar analisada prova que os professores utilizam os diagnósticos virtuais para promover a humanização do ensino. A integração entre a máquina e a ação docente efetiva a melhoria contínua. A adoção tecnológica investigada supera as barreiras limitantes e garante a viabilidade o sistema adaptativo.

5. Considerações Finais

A integração de plataformas adaptativas transforma o cenário educacional contemporâneo ao superar as limitações do ensino padronizado. A pesquisa evidencia

que ferramentas digitais inteligentes mapeiam o perfil cognitivo dos estudantes para oferecer trajetórias de aprendizagem ajustadas em tempo real. O uso dessa tecnologia eleva o engajamento e melhora os índices de proficiência acadêmica nas escolas.

A eficácia dos sistemas analisados encontra fundamentação nas ciências cognitivas humanas. A fragmentação dos conteúdos evita o esgotamento mental e garante a retenção da informação exigida na rotina escolar diária. O estudante assume uma posição ativa na construção do saber, enquanto o educador passa a atuar como mediador essencial apoiado por relatórios diagnósticos altamente precisos.

A integração tecnológica nas escolas exige a superação de barreiras operacionais e éticas inegáveis. O sucesso educacional requer investimentos constantes em infraestrutura digital e letramento computacional para todos os docentes envolvidos. A proteção rigorosa da privacidade estudantil necessita de modelos de governança robustos que assegurem o uso transparente da inteligência artificial dentro de qualquer instituição de ensino.

As perspectivas futuras indicam a expansão contínua das plataformas adaptativas para diferentes disciplinas e níveis acadêmicos. O aprimoramento dos algoritmos preditivos poderá identificar dificuldades precoces com maior exatidão. O avanço científico dependerá da formulação de políticas públicas que democratizem o acesso às inovações, consolidando um ambiente escolar flexível, colaborativo, plenamente inclusivo e tecnologicamente sustentável.

Referências

AACE. Association for the Advancement of Computing in Education. **What are adaptive learning systems,** 2021

Akgun, S. & Greenhow, C. Artificial intelligence in education: Addressing ethical challenges in K-12 settings. **AI and Ethics**, 2021.

Alavares, M. A. & Catalani, E. T. **Alfabetização e TIC:** os testes adaptativos informatizados (TAI) como recurso. In: Pesquisa sobre o uso das tecnologias de informação e comunicação nas escolas brasileiras: TIC Educação 2015. Comitê Gestor da Internet no Brasil, 2015.

Baião, J. A. & Oliveira, M. Impacto da plataforma Khan Academy no ensino de matemática: Uma revisão sistemática da literatura. **Educação e Tecnologia**, 2021.

Barros, B. M.; Silva, L. S. & Silva, L. R. Uso das plataformas adaptativas no ensino da matemática: uma revisão sistemática. **Revista Científica Multidisciplinar Núcleo do Conhecimento**, 5(11), 1-18, 2020

Blay, B. & McClaskey, K. Personalization vs Differentiation vs Individualization, 2010.

Borvalho, L. M. A evolução das avaliações educacionais com IA: um panorama crítico. Revista Brasileira de Educação e Tecnologia, 31(2), 45-65, 2023.

Brusilovsky, P. & Millán, E. User models for adaptive hypermedia and adaptive educational systems. **The Adaptive Web:** Methods and Strategies of Web Personalization. Springer, 2007.

Bulut, O.; Beiting-Parrish, M.; Casabianca, J. M.; Slater, S. C. The Rise of Artificial Intelligence in Educational Measurement: Opportunities and Ethical Challenges, **Chinese/English Journal of Educational Measurement and Evaluation,** Vol. 5, Iss. 3, Article 3, December 2024. https://doi.org/10.59863/MIQL7785.

Costa, D. **Plataformas Adaptativas e o Ensino Personalizado**. Must University, 2021.

Costa, S.; Pinto, R. & Gonçalves, G. **Graph-Based PersonalizedRecommendation in Intelligent Educational Platforms:** A Case Study in Engineering Education. Proceedings of the 21st International Conference on Web Information Systems and Technologies, 2025.

Cukurova, M. The Interplay of Learning, Analytics, and Artificial Intelligence in Education: A Vision for Hybrid Intelligence, 2024.

Dietterich, T. G. Steps toward robust artificial intelligence. **AI Magazine**, 38(3), 3-24, 2017.

Domingos, P. **O algoritmo mestre:** como a busca pelo algoritmo de machine learning definitivo recriará nosso mundo. Novatec Editora, 2017.

Fernandes, A. B. Arquitetura do conhecimento: o designer instrucional e seu ato de materializar o processo de ensino-aprendizagem. **IOSR Journal of Humanities and Social Science**, 29(10), 08-12, 2024.

Ferreira, J. P. & Monteiro, A. O impacto das plataformas adaptativas na aprendizagem escolar: Um estudo de caso com a Geekie One. **Revista Brasileira de Educação**, 27, 2022

Gardner, H. **Inteligências múltiplas:** A teoria na prática. Porto Alegre: Penso Editora, Artes Médicas, 1995.

Gil, A. C. Como elaborar projetos de pesquisa (5a ed.). Atlas, 2010.

Guimarães, U. A.; Vimercate, J. M. & Schizzi, J. A. C. Contribuições das plataformas adaptativas no ensino aprendizagem. **RECIMA21 - Revista Científica Multidisciplinar**, 3(8), 2021.

Imohimi, E. O. Building Privacy and Preserving AI Models for Secure Student Data Management in Educational Technology Platforms. **Journal of Intelligent Learning Systems and Applications**, 2025.

Kizilcec, R. F.; Bailenson, J. N. & Gomez, C. J. The instructor's face in video instruction: Evidence from two large-scale field studies. **Journal of Educational Psychology**, 109(6), 909-925, 2017.

Lima, M. F. de & Araújo, J. F. S. de. A utilização das tecnologias de informação e comunicação como recurso didático-pedagógico no processo de ensino e aprendizagem. Revista Educação Pública, 21(23), 2021.

Luckin, R.; Holmes, W.; Griffiths, M. & Forcier, L. Intelligence Unleashed: An argument for AI in Education. Pearson Education, 2016.

Machado, R. et al. Uso da Khan Academy em escolas brasileiras: impactos na aprendizagem. Revista Brasileira de Aprendizagem Aberta e a Distância, 19(1), 180-197, 2020.

Manna, S. & Sett, N. **Need of AI in Modern Education**: in the Eyes of Explainable AI (xAI), 2024.

Radu, A. Containerization of Machine Learning Algorithms for Intelligent Educational Platforms. **ICERI Proceedings,** 2025.

Sallaah, M. H.; Akila, V.; Sharma, P.; et al. **Deep Reinforcement Learning for Personalized AI Tutors in Intelligent Education Systems and Adaptive E-Learning Platforms.** 3rd International Conference on Cyber Resilience (ICCR), 2025.

Sena, W. N. Os impactos na educação do uso de plataformas adaptativas: o exemplo da Khan Academy. **Revista Educar Mais,** 6, 1029-1038, 2022.

Şahin, G. AI-Based Adaptive Learning Systems for Developing Writing Skills in Primary Education. **Advances in Computational Intelligence and Robotics**, 2026.

Sweller, J. **Carga cognitiva durante a resolução de problemas:** Efeitos na aprendizagem. Ciência Cognitiva, 12(2), 257-285, 1988.

Valente, J. A. **A sala de aula invertida e a possibilidade do ensino personalizado:** uma experiência com a graduação em midialogia. In: BACICH, L.; MORAN, J. (org.). Metodologias ativas para uma educação inovadora: uma abordagem teórico-prática. Penso, 2018.

Sobre o autor(a)

Carla Cristiane Boita

Bacharel em Direito pela Federação de Estabelecimentos de Ensino Superior em Novo Hamburgo (Feevale - 2012).

Licenciada em Letras Português e Espanhol pela Faculdade de Venda Nova do Imigrante (FAVENI - 2021).

Pós Graduação (*lato sensu*) em Carreira Pública - Gestão e Governança pelo Centro Universitário de Tecnologia Avança (UniBTA - 2021).

Vice-diretora do Instituto Estadual de Educação Marcílio Dias - Torres RS.

Professora efetiva de Espanhol na Rede de Ensino da educação básica de Santa Catarina.

CAPÍTULO 7

Sistemas de recomendação de conteúdo: uma Revisão Sistemática da Literatura

Cleber Luiz Damin Ferro

1. Introdução

O uso integrado de tecnologias digitais permitiu que instituições educacionais começassem a desenvolver lentamente ferramentas inteligentes que podem personalizar as abordagens de ensino e aprendizagem para os alunos. De todas essas tecnologias, os sistemas de recomendação são muito importantes, pois têm a capacidade de recomendar conteúdos, bem como atividades e materiais de aprendizagem com base no perfil e nas necessidades dos estudantes.

Os sistemas de recomendação são populares em várias plataformas comerciais hoje em dia, variando de serviços de streaming a plataformas de *e-commerce*. No entanto, eles estão se tornando uma solução mais prática para a educação, pois podem realmente servir para promover uma aprendizagem mais adaptativa e personalizada (Ricci; Rokach; Shapira, 2015).

Acredita-se que a Inteligência Artificial (IA) desempenha um papel importante em fornecer mecanismos inteligentes para manipulação de informações (análise de dados), detecção de padrões e previsão de preferências. Além disso, métodos de Processamento de Linguagem Natural (PLN) e IA generativa nos permitem sugerir materiais personalizados que promovem a interatividade dos alunos, especialmente no caso de ambientes virtuais de aprendizagem.

A aprendizagem personalizada é importante em muitas escolas com perfis, ritmos de aprendizagem e estilos de aprendizagem diferentes. De acordo com Luckin *et al.* (2016), a IA na educação apresenta potencial para apoiar processos pedagógicos por meio da oferta de assistência personalizada aos estudantes e do suporte à tomada de decisões pedagógicas pelos professores.

Como resultado, o objetivo deste artigo é apresentar uma revisão sistemática estruturada da literatura sobre sistemas de recomendação de aprendizagem, delineando os princípios críticos, métodos, aplicação e restrições dessas tecnologias em contextos educacionais.

2. Fundamentação Teórica

Esta seção explica o embasamento teórico deste estudo, que inclui os seguintes conceitos: Inteligência Artificial na Educação, técnicas de Processamento de Linguagem Natural (PLN), IA Generativa e sistemas de recomendação na Educação. Esses conceitos criam a base para a análise para responder às questões de pesquisa estabelecidas.

2.1 Inteligência Artificial na Educação

A Inteligência Artificial é uma das principais tecnologias que tem ganhado terreno rapidamente no contexto educacional, em particular devido ao uso de tecnologias de IA na educação, com automação de processos, análise de dados e personalização de experiências de aprendizagem. Russell & Norvig (2021), descrevem a IA como a criação de sistemas computacionais para a realização de tarefas tipicamente associadas à inteligência humana, como raciocínio, aprendizado e tomada de decisão.

Em um contexto de ensino e aprendizagem, isso também significa que podemos construir ambientes adaptativos que preveem onde os alunos estão tendo dificuldades, analisam dados de desempenho e oferecem experiências de aprendizagem personalizadas. Para Luckin *et al.* (2016), a IA pode potencialmente modificar processos pedagógicos ao oferecer suporte personalizado aos alunos e apoiar os professores a tomarem decisões eficazes na educação.

Da mesma forma, Holmes; Bialik & Fadel (2019), afirmam que sistemas inteligentes se adaptam à velocidade e aos estilos de aprendizagem de cada aluno para induzir maior interesse e aprimoramento no desempenho educacional. Além disso, o progresso do aprendizado de máquina também levou a uma grande expansão da IA no campo educacional.

Algoritmos de aprendizado de máquina são uma das poucas tecnologias que aprendem automaticamente a capturar grandes volumes de dados (Alpaydin, 2021), encontrar padrões nesses dados e prever o comportamento entre os usuários. Na educação, esses algoritmos são empregados para prever evasão escolar, sugerir conteúdos, diagnosticar dificuldades de aprendizagem e auxiliar sistemas de tutoria inteligente.

Com o advento da IA, vem a crescente importância da pesquisa educacional e da análise de tais pesquisas. A Análise de Aprendizagem (também conhecida como ferramenta analítica) é o elemento fundamental desse esforço. Siemens & Baker (2012) observam que a análise de dados de ambientes virtuais de aprendizagem permite entender o comportamento dos alunos de maneira sofisticada.

De fato, uma visão moderna do que está acontecendo com a educação nesta era das tecnologias da informação pode ser vista como uma melhoria do que antes era uma área limitada e, portanto, certamente será vista como uma área adicional que não deve mais ser ignorada. Por exemplo, educadores como Neil Selwyn (2019) e Olaf Zawacki Richter et al. (2019) alertam para questões de ética, privacidade de dados, transparência algorítmica e até mesmo potenciais disparidades no acesso à tecnologia digital que requerem uma abordagem responsável e pedagogicamente focada no uso de tais ferramentas.

2.2 Técnicas de Processamento de Linguagem Natural (PLN)

O Processamento de Linguagem Natural (PLN) é uma subdisciplina crítica da IA preocupada com o contato de um computador com a linguagem humana. Jurafsky & Martin (2023) argumentam que o PLN combina linguística computacional, aprendizado de máquina e algoritmos estatísticos para ajudar sistemas computacionais a reconhecer, analisar e gerar linguagem natural.

No domínio da educação, esses métodos têm sido amplamente implementados em sistemas de correção automatizada, chatbots educacionais, tutores inteligentes, análise discursiva e recomendação de conteúdo personalizado.

Segundo Liddy (2001), o PLN capacita a conversão de textos em representações baseadas em computação que podem então ser analisadas automaticamente, permitindo o desenvolvimento de sistemas educacionais muito mais inteligentes e interativos. Como apontado por Manning; Raghavan & Schütze (2008), técnicas como *tokenização*, *stemming*, lematização e análise semântica são consideradas cruciais para o processamento de texto em aprendizado digital.

O advento de redes neurais profundas como o *Word2Vec* em 2013 trouxe o PLN para a vanguarda e ampliou muito seu uso em sistemas educacionais inteligentes. Mikolov *et al*., criaram os modelos *Word2Vec* (2013) que possibilitaram representar palavras em vetores capazes de capturar relações semânticas. Posteriormente, modelos baseados na arquitetura *Transformer* (como o BERT) propostos por Devlin *et al.* (2019) fizeram grandes avanços na compreensão dos contextos da linguagem humana.

Esses modelos têm sido usados em sistemas de recomendação educacional, análise automática de texto, bem como *feedback* direcionado. Além disso, o uso de modelos GPT feitos por Brown *et al.* (2020) aumentou a capacidade de geração textual de sistemas inteligentes, de modo que pode haver um diálogo mais natural entre alunos e plataformas educacionais.

Krouska; Troussas & Virvou (2020), afirmaram que o PLN na educação desempenha um papel fundamental na personalização do processo de aprendizagem

para recomendar conteúdos mais contextualizados. No entanto, autores como Bender *et al.* (2021) alertam que modelos de linguagem também podem reproduzir vieses dos dados de treinamento nos quais são construídos, de modo que avanços éticos e responsáveis (ainda que transparentes) dessas tecnologias são um pré-requisito.

2.3 O Papel da IA Generativa

A IA generativa é uma das invenções mais importantes em Inteligência Artificial nos últimos anos, e é capaz de gerar textos, imagens, códigos e multimídia novos e únicos. Conforme relatado por Bommasani *et al.* (2021), modelos de IA generativa fundamentais são desenvolvidos com uma enorme quantidade de dados e são mais capazes de aprender padrões complexos da linguagem humana, ou seja, gerar respostas contextuais e coerentes.

O progresso feito por essas tecnologias está intimamente ligado ao desenvolvimento da arquitetura *Transformer* por Vaswani *et al.* (2017) que transformou o Processamento de Linguagem Natural ao aprimorar a compreensão contextual dos sistemas inteligentes. No ensino, a IA generativa tem sido usada com sucesso na geração automatizada de conteúdos educacionais, treinamento personalizado, geração de resumos, tutoria inteligente e recomendação de conteúdos educacionais.

Como apontado por Kasneci *et al.* (2023), ferramentas baseadas em IA generativa podem contribuir para o aprimoramento das práticas pedagógicas, oferecendo suporte personalizado e *feedback* em tempo oportuno aos estudantes. Além disso, a IA generativa melhora drasticamente a personalização do aprendizado. Um sistema inteligente é capaz de estudar o desempenho do aluno e produzir explicações com base em suas dificuldades individuais.

Holmes & Tuomi (2022), afirmaram que a IA generativa pode servir como uma ferramenta pedagógica tanto para professores quanto para alunos, automatizando tarefas repetitivas para gerar experiências de aprendizado mais eficazes em um ambiente de aprendizado dinâmico. Modelos generativos também podem ser usados em *chatbots* educacionais para servir como uma plataforma, fornecer orientação e responder a perguntas dos alunos em ambientes de aprendizado virtual (Okonkwo & Ade-Ibijola, 2021).

No entanto, apesar dessas oportunidades, autores como Luciano Floridi e Massimo Chiriatti (2020) alertam e discutem questões éticas, confiabilidade das informações geradas, plágio acadêmico, autoria intelectual e dependência tecnológica para abordar a questão e apoiar a demanda por regulamentação e uso adequado dessas ferramentas na educação.

2.4 Sistemas de Recomendação na Educação

Sistemas de recomendação referem-se a ferramentas computacionais que fazem sugestões com base em preferências individuais, comportamentos e registros de uso. Como apontam Ricci; Rokach & Shapira (2015), os sistemas de recomendação começaram em aplicativos comerciais, no entanto, rapidamente se espalharam além das aplicações comerciais para outros setores, entre eles a educação.

No nível universitário, esses sistemas geralmente são destinados a ajudar os alunos a escolher o conteúdo, objetos de aprendizado, atividades e a forma como devem frequentar a escola para atender às suas necessidades.

Para Manouselis *et al.* (2013), explica-se como os sistemas de recomendação educacional aliviam a sobrecarga de informações e melhoram a personalização do aprendizado em um espaço digital. Métodos comuns usados nesses sistemas incluem filtragem colaborativa, filtragem baseada em conteúdo e sistemas híbridos.

Com base em Schafer *et al.* (2007), a filtragem colaborativa envolve recomendações feitas por usuários semelhantes cujo comportamento é similar ao do sistema proposto, enquanto a filtragem baseada em conteúdo foca nas características do próprio material educacional. Burke (2002) enfatiza que sistemas híbridos aproveitam várias técnicas para recomendações precisas. Além disso, graças à convergência de sistemas de recomendação e técnicas de Inteligência Artificial com mineração de dados educacionais, o escopo para ensino individualizado expandiu-se dramaticamente.

Verbert *et al.* (2012), quando dados de ambientes de aprendizado virtual são aplicados, recomendações contextualizadas e eficientes podem ocorrer e os alunos podem ter um desempenho melhor durante o semestre. No entanto, sistemas de recomendação educacional ainda enfrentam questões significativas, apesar do progresso significativo que foi feito. Desafios como escassez de dados, início a frio, privacidade da informação e transparência algorítmica ainda são bem explorados na literatura científica.

Como Bobadilla *et al.* (2013), restrições de qualidade de dados podem afetar a precisão das recomendações de sistemas inteligentes. Além disso, porque o algoritmo não é explicável, Kizilcec (2016) aponta que os usuários perdem a confiança nas recomendações geradas. No entanto, as tecnologias de recomendação continuam sendo uma das tendências fundamentais na educação inteligente e uma que pode contribuir para um ambiente de aprendizado mais personalizado, flexível e orientado para o aluno.

3. Metodologia

O estudo atual é denominado Revisão Sistemática da Literatura (RSL). Ao contrário de uma pesquisa narrativa livre, a RSL desafia o pesquisador a preparar suas perguntas, termos de busca e filtros de seleção com antecedência. Esse rigor técnico reduz o viés e promove a transparência na coleta de dados (Eecole & Melo-Alcoforado, 2014).

Os estudos foram triados e selecionados com base na plataforma *Rayyan* (Ouzzani *et al.*, 2016), que visa proporcionar tanto agilidade quanto rigor sistemático à fase de seleção bibliográfica, oferecendo uma gestão eficiente dos critérios de inclusão e exclusão.

3.1 Perguntas de Pesquisa (PQ)

Para nortear o mapeamento, foram elaboradas as seguintes questões:

- **PQ1:** Quais técnicas de IA e PLN são mais utilizadas no desenvolvimento de SR educacionais?
- **PQ2:** Como os SR contribuem para a personalização do ensino e a autonomia do estudante?
- **PQ3:** Quais os principais desafios éticos e legais (vieses, LGPD) apontados pela literatura?

3.2 Bases de Dados

Para ampliar a abrangência da revisão e reduzir o risco de viés de indexação, foram consultadas três bases de dados internacionais amplamente utilizadas em pesquisas sobre Educação e Ciência da Computação:

- ***Scopus*** — https://www.scopus.com
- ***ScienceDirect*** — https://www.sciencedirect.com
- ***IEEEXplore*** — https://www.ieeexplore.ieee.org

3.3. String de Pesquisa

A estratégia de busca foi construída a partir da combinação de descritores relacionados à Inteligência Artificial, sistemas de recomendação, personalização da aprendizagem e learning analytics. Utilizaram-se operadores booleanos e termos sinônimos para ampliar a recuperação de estudos relevantes.

(education OR "higher education" OR e-learning OR "virtual learning environment") AND ("artificial intelligence" OR "machine learning" OR "learning analytics") AND ("recommender system" OR "recommendation system*" OR "educational recommendation") AND ("personalized learning" OR "adaptive learning" OR "content recommendation") AND ("natural language processing" OR NLP OR transformer OR BERT OR GPT)*

A ampliação dos termos de busca permitiu contemplar estudos que utilizam diferentes nomenclaturas para sistemas adaptativos e recomendação educacional, reduzindo a possibilidade de exclusão de trabalhos relevantes. Foram encontrados 101 resultados.

3.4. Critérios de Inclusão e Exclusão

A seleção dos estudos obedeceu a cinco critérios obrigatórios. Para compor a amostra final, o trabalho precisava atender cumulativamente aos seguintes pontos:

- **CI1:** publicação entre 2021 e 2026;
- **CI2:** validação por pares (artigos em periódicos científicos ou trabalhos completos em anais de conferências);
- **CI3:** foco na aplicação de sistemas de recomendação no contexto educacional.;
- **CI4:** escrita nos idiomas português, inglês ou espanhol;
- **CI5:** disponibilidade do texto na íntegra (seja por acesso aberto ou institucional).

Já os critérios de exclusão no processo de triagem descartaram qualquer material que não atendesse em pelo menos um destes filtros:

- **CE1:** duplicatas ou versões preliminares de pesquisas já contabilizadas na versão final;
- **CE2:** indisponibilidade de leitura do texto completo, mesmo após tentativas de recuperação legítimas;
- **CE3:** aplicações fora do escopo escolar ou acadêmico (como o uso de Sistemas de Recomendação em setores corporativos ou de saúde sem ligação com a educação);
- **CE4:** formatos desprovidos de rigor metodológico detalhado (como editoriais, cartas ao editor ou resumos simples de eventos);
- **CE5:** pesquisas exclusivamente técnicas que não apresentassem aplicação, validação experimental ou discussão de uso em contextos educacionais reais ou simulados.

Após a seleção, os estudos foram organizados e analisados qualitativamente, permitindo identificar tendências, aplicações e desafios da área.

3.5. Processo de Seleção

Quatro camadas de filtragem foram aplicadas para selecionar artigos. Inicialmente, usando a *string* de busca nos bancos de dados selecionados, foram encontrados 118 trabalhos. Após verificar duplicata comparando títulos e autores, 117 estudos foram incluídos para avaliação.

Na segunda etapa, os respectivos títulos e resumos dos trabalhos foram lidos de acordo com os critérios de inclusão e exclusão definidos para a pesquisa. Nesta etapa, artigos foram excluídos dos estudos com base na falta de relevância para o tema. Assim, 20 estudos avançaram para a próxima iteração. Os artigos foram então lidos na íntegra e estudados minuciosamente para determinar o que relataram, como relataram e o que acrescentaram à literatura.

Esta fase forneceu a estrutura para confirmar que os estudos incluídos tinham o tipo de informação coerente e adequada que havia sido exigida para satisfazer os objetivos da revisão. Além disso, na quarta etapa, após uma leitura minuciosa dos trabalhos, 2 artigos que não satisfaziam os critérios foram excluídos. Assim, aqui, a amostra final da nossa pesquisa consiste em 18 estudos, que formam a base da análise neste trabalho.

4. Análise e Discussão dos Resultados

A análise dos 18 artigos selecionados revela um panorama produtivo concentrado entre 2021 e 2026. O portfólio final contendo todos os artigos selecionados pode ser visualizado na tabela 1.

Quadro 1 - Análise comparativa das ferramentas

Autores	Ano	Título	Temática simplificada
Salazar, C.; Aguilar, J.; Monsalve-Pulido, J. & Montoya, E.	2021	Sistemas de recomendação afetivos na área educacional. Uma abordagem sistemática.	Sistemas de recomendação

continua

continuação

Odoom, R.; Kosiba, J. P. B. & Odoom, P. T.	2026	Uma investigação mediada sobre o impacto de recomendações de conteúdo personalizadas nos resultados da experiência com o *chatbot* [*My AI*] do *Snapchat*.	Recomendações de conteúdo personalizadas, IA generativa
Afoudi, Y.; Lazaar, M. & Hmaidi, S.	2023	Um sistema de recomendação aprimorado baseado na previsão de links em grafos heterogêneos.	Sistemas de recomendação
Xu, C.; Gao, F. & Han, L.	2025	Aprimorando a intenção de divulgação de informações do usuário em conversas dinâmicas de sistemas de recomendação inteligentes baseados em grandes modelos de linguagem: uma perspectiva de gratificação do usuário e cálculo de privacidade.	Sistemas de recomendação
Raza, S.; Rahman, M.; Kamawal, S.; Toroghi, A.; Raval, A.; Navah, F. & Kazemeini, A.	2026	Uma análise abrangente dos sistemas de recomendação: da teoria à prática.	Sistemas de recomendação, Sistemas baseados em conhecimento, Aprendizado profundo
Guo, T.	2026	Aprimorando as recomendações de leitura personalizadas na primeira infância	Sistema de recomendação, PLN
Li, Y. & Wang, E.	2024	Construção de um modelo de recomendação personalizado para recursos de jogos educativos em vídeo com base em um grafo de conhecimento	Educação e ensino, Algoritmo de recomendação
Joy, J. & Pillai, R. V. G.	2022	Análise e classificação de sistemas de recomendação de conteúdo em ambientes de e *learning*.	Sistemas de recomendação de conteúdo, Técnicas de recomendação.

continua

continuação

Gomaa., Y.; Moussa, S.; Lahoud, C. & Abel, M.	2024	Explorando sistemas de recomendação para auxiliar professores na gamificação do ensino a distância.	Sistemas de recomendação
Dong, C.	2025	Aplicação e pesquisa do mecanismo de atenção combinado com a visualização de dados para um sistema de recomendação de cursos de aprendizagem empreendedora em universidades e faculdades.	Sistemas de recomendação
Zhang, W.; Quintana, M. & Miller, C.	2025	Sistemas de recomendação e aprendizado por reforço para interação humano-edifício e suporte contextual: uma revisão da literatura científica orientada por mineração de texto	Sistemas de recomendação, PLN
Shafiee, S.	2024	Revelando as últimas tendências e avanços em algoritmos de aprendizado de máquina para sistemas de recomendação: uma Revisão da literatura	Sistema de recomendação
Petrovic, T., & Alvarez, R.	2025	Recomendação de conteúdo orientada por IA em sistemas de gestão de aprendizagem (LMS): uma abordagem de filtragem híbrida	IA na Educação e na aprendizagem, Sistemas de IA de Recomendação
Delianidi, M., Diamantaras, K., Kokkonis, G., Sidiropoulos, A., Evangelidis, G., Karapiperis, D.	2026	DK-PRACTICE: Uma plataforma inteligente para rastreamento de conhecimento e recomendação de conteúdo educacional: um estudo de caso no ensino superior	Educação, IA, sistemas de recomendação

continua

Qiang, M.	2024	Projeto de um sistema de recomendação de conteúdo personalizado para leitura em inglês baseado em aprendizado profundo e algoritmos inteligentes	IA, Sistemas de Recomendação de Conteúdo personalizado, Recomendações de Conteúdo
Mfogo, V. S.; Zemkoho, A.; Njilla, L.; Nkenlifack, M. & Kamhoua, C.	2024	Sistema de recomendação híbrido baseado em aprendizado adaptativo para detecção de engano na Internet das Coisas	Sistemas de recomendação
Liu, W.; Lyu, Y.; Jain L. C.; Wu Q.; Shi F. & Balas V.E.	2026	Pesquisa sobre o mecanismo de recomendação e geração de conteúdo textual ideológico e político com base na compreensão semântica	Sistemas de recomendação, recomendações de conteúdo
Dong, X.;, Li, H.; Fu W. & Sun G	2022	Sistema de recomendação personalizada de recursos didáticos online ideológicos e políticos baseado em inteligência artificial.	IA, Sistemas de recomendação, Tecnologias de IA

Fonte: elaborado pelo autor (2026)

Com base na análise dos estudos selecionados, foram identificadas tendências relevantes em relação ao uso de IA, PLN e sistemas de recomendação em um ambiente educacional. Os trabalhos examinados mostram que o desenvolvimento de tecnologias inteligentes tem impulsionado essa personalização do aprendizado, a adaptação de conteúdo e o alcance da autonomia dos estudantes em ambientes de aprendizagem virtual.

Em relação à **QP1**: *"Quais técnicas de IA e PLN são mais utilizadas no desenvolvimento de SR educacionais?"* As principais técnicas comuns incluem aprendizado de máquina, redes neurais artificiais, mineração de dados educacionais, filtragem colaborativa, filtragem baseada em conteúdo e modelos de recomendação híbridos. Vários estudos enfatizam o uso de algoritmos que podem analisar o comportamento dos alunos, histórico de navegação, desempenho acadêmico e preferências de aprendizado, recomendando conteúdo adaptado a esses estudantes.

Da mesma forma, métodos de PLN têm sido amplamente utilizados na interpretação de texto, análise semântica, extração de palavras-chave, bem como na contextualização de conteúdo educacional. Novas pesquisas documentam o surgimento da adoção de modelos de linguagem

baseados em arquiteturas *Transformer*, mais notavelmente BERT e GPT, que desenvolveram significativamente o desempenho dos sistemas de linguagem natural e sua capacidade de fazer sugestões contextualizadas.

Essas tecnologias permitem que sistemas educacionais estudem as interações textuais dos alunos em fóruns, *chats* e atividades discursivas para fornecer materiais alinhados ao perfil de aprendizado de cada usuário. Técnicas de análise preditiva estão sendo cada vez mais utilizadas, ajudando a identificar alunos em risco durante os anos escolares, prevendo taxas de evasão o mais cedo possível e detectando dificuldades de aprendizado específicas muito antes do declínio do desempenho acadêmico.

Quanto à **QP2**: *"Como os SR contribuem para a personalização do ensino e a autonomia do estudante?"* Os trabalhos revisados sugerem que os sistemas de recomendação foram fundamentais para a criação de experiências de aprendizado personalizadas. Esses sistemas perfilam cada aluno como uma pessoa, incluindo preferências, desempenho, ritmo de aprendizado e interesses, para como um aluno experimentaria conteúdo, exercícios, vídeos, artigos e caminhos de estudo de acordo com as necessidades específicas dos alunos, com base em um perfil específico do aluno.

Essa personalização ajuda a aliviar grande parte da sobrecarga de informações em ambientes *online*, permitindo um aprendizado mais focado e eficiente. Além disso, os sistemas de recomendação contribuem para o conceito de voz do usuário e autonomia do aluno: eles capacitam os usuários por meio de uma experiência de aprendizado muito mais empoderada. Um ambiente educacional inteligente permite que os alunos selecionem conteúdo prescrito, como conteúdo que percebem ser mais desafiador, adaptado aos seus desafios ou para atender aos seus objetivos desejados e, assim, promove práticas de aprendizado independentes e auto-organizadas.

De acordo com a literatura, os alunos que usam sistemas personalizados tendem a se engajar mais, têm um alto nível de motivação e participam mais de atividades acadêmicas. Normalmente, esses sistemas também oferecem *feedback* instantâneo, monitoramento de desempenho e recomendações adaptativas em tempo real na preferência de construir caminhos de aprendizado personalizados.

As descobertas também confirmam que a conexão entre um sistema de recomendação e IA generativa está ampliando o alcance da personalização educacional. Essas ferramentas inteligentes não são apenas capazes de recomendar material já existente, mas também podem, por exemplo, fornecer automaticamente resumos, exercícios, outras explicações ou materiais complementares com base no nível de conhecimento do aluno. Tal cenário evidencia tendências crescentes em direção a sistemas educacionais adaptativos cada vez mais focados no aluno.

No que se refere à **QP3**: *"Quais os principais desafios éticos e legais (vieses, LGPD) apontados pela literatura?"* Os estudos revisados levantam várias preocupações sobre o papel da IA e dos sistemas de recomendação na educação. O principal problema de preocupação identificado diz respeito aos vieses algorítmicos em modelos inteligentes. Como os sistemas

aprendem a partir de dados históricos, seus dados de treinamento carregam o potencial de reproduzir preconceitos, desigualdades e padrões discriminatórios. Isso pode, no entanto, afetar negativamente a qualidade das recomendações e a equidade educacional.

Outro tópico de debate geral é a segurança e privacidade dos dados dos alunos no setor educacional. Os sistemas de recomendação também dependem da coleta e análise contínua de detalhes pessoais, comportamentais e acadêmicos dos usuários, mas é preciso ter cuidado com o armazenamento, processamento e compartilhamento de dados. Nesse sentido, a Lei Geral de Proteção de Dados (LGPD) no Brasil propõe parâmetros críticos para transparência, consentimento e segurança das informações pessoais usadas por sistemas inteligentes.

Além disso, a literatura também aborda preocupações sobre a transparência algorítmica e a explicabilidade das recomendações fornecidas pelos sistemas. Muitas vezes, alunos e professores não entendem claramente como as recomendações são geradas, o que pode resultar em desconfiança das soluções educacionais inteligentes. No entanto, os autores se preocupam com o potencial de depender demais das tecnologias, retirando dos professores sua independência pedagógica, ou o uso indevido de conteúdo produzido automaticamente por IA generativa.

Como resultado, os resultados da revisão da literatura mostram que os sistemas de recomendação educacional têm alta capacidade potencial de transformar os procedimentos de ensino e aprendizado, especialmente no que diz respeito à individualização do ensino e ao apoio ao aprendizado independente. No entanto, os desafios identificados na literatura sobre ética, legalidade e pedagogia sustentam a necessidade do desenvolvimento responsável das tecnologias no âmbito da transparência, inclusão, proteção de dados e supervisão humana em seu contexto educacional.

5. Considerações Finais

O ensino de aplicações de sistemas de recomendação de conteúdo para a aprendizagem constitui uma inovação tecnológica significativa no mundo educacional de hoje. Eles melhoram muito a aprendizagem ao personalizar o material educacional e tornar as experiências de aprendizagem mais interativas. De perspectiva em perspectiva, a revisão da literatura identificou que a Inteligência Artificial, o Processamento de Linguagem Natural e a IA Generativa são facilitadores chave para o desenvolvimento de tais sistemas.

Os sistemas de recomendação educacional podem:

- estimular o engajamento dos alunos;
- melhorar o desempenho acadêmico;
- auxiliar os professores;
- personalizar os caminhos de aprendizagem.

Ética, privacidade e a confiabilidade dos sistemas inteligentes continuam sendo uma preocupação, apesar desses avanços. Estudos futuros devem se concentrar na transparência

algorítmica, na redução de viés e na integração com IA generativa e ambientes virtuais de aprendizagem

Como contribuição científica, esta revisão propõe uma categorização das abordagens de recomendação educacional em quatro grupos (colaborativa, baseada em conteúdo, híbrida e baseada em PLN/LLMs), relacionando cada categoria às suas vantagens, limitações e implicações pedagógicas. Além disso, o estudo sintetiza lacunas de pesquisa e tendências emergentes que podem orientar investigações futuras sobre sistemas adaptativos e IA generativa na educação.

Portanto, os sistemas de recomendação de conteúdo são uma das principais tendências a emergir no campo da educação inteligente e podem contribuir de forma significativa para a evolução dos métodos de ensino, especialmente em contextos de aprendizagem personalizada e adaptativa.

Referências

ALPAYDIN, E. **Machine Learning**. 4. ed. Cambridge: MIT Press, 2021.

Bender, E. M.; Gebru, T.; McMillan-Major, A. &Shmitchell, S. **On the Dangers of Stochastic Parrots:** Can Language Models Be Too Big? In: Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency. New York: ACM, 2021.

Bobadilla, J.; Ortega, F.; Hernando, A. & Gutiérrez, A. Recommender Systems Survey. **Knowledge-Based Systems**, v. 46, p. 109–132, 2013.

Bommasani, R. et al. **On the Opportunities and Risks of Foundation Models.** Stanford: Stanford University, 2021.

Brown, T.; et al. Language Models are Few-Shot Learners. **Advances in Neural Information Processing Systems** (NeurIPS), 2020.

Brusilovsky, P. & Millán, E. **User Models for Adaptive Hypermedia and Adaptive Educational Systems**. In: Brusilovsky, P.; Kobsa, A.; Nejdl, W. (org.). The Adaptive Web. Berlin: Springer, 2007.

Burke, R. Hybrid Recommender Systems: Survey and Experiments. **User Modeling and User-Adapted Interaction**, v. 12, n. 4, p. 331–370, 2002.

Cambria, E. & White, B. Jumping NLP Curves: A Review of Natural Language Processing Research. IEEE **Computational Intelligence Magazine**, v. 9, n. 2, p. 48–57, 2014.

Devlin, J.; Chang, M.; Lee, K & Toutanova, K. **BERT**: Pre-training of Deep Bidirectional Transformers for Language Understanding. In: Proceedings of NAACL-HLT 2019. Minneapolis: Association for Computational Linguistics, 2019.

Drachsler, H. et al. Panoramix and Sparklr: Recommendation Support for Learning Activities. International **Journal of Technology Enhanced Learning**, v. 7, n. 1, p. 68–87, 2015.

Drachsler, H.; Verbert, K. & Duval, E. Recommender Systems for Learning. New York: Springer, 2013.

Ercole, F. F.; Melo, L. S. de & Alcoforado, C. L. G. C. Revisão integrativa versus revisão sistemática. **REME-Revista Mineira de Enfermagem,** v. 18, n. 1, 2014.

Floridi, L. & Chiriatti, M. GPT-3: Its Nature, Scope, Limits, and Consequences. **Minds and Machines**, v. 30, p. 681–694, 2020.

Holmes, W.; Tuomi, I. State of the Art and Practice in AI in Education. **European Journal of Education**, v. 57, n. 4, p. 542–570, 2022.

Holmes, W.; Bialik, M. & Fadel, C. **Artificial Intelligence in Education:** Promises and Implications for Teaching and Learning. Boston: Center for Curriculum Redesign, 2019.

Jurafsky, D. & Martin, J. H. **Speech and Language Processing**. 3. ed. Stanford: Stanford University, 2023.

Kasneci, E.; Sessler, K.; Küchemann, S.; Bannert, M.; Dementieva, D.; Fischer, F.; Gasser, U.; Groh, G.; Günnrmann, S.; Hüllermeier, E.; Krusche, S.; Kutyniok, G.; Michaeli, T.; Nerdel, C.; Pfeffer, O.; Sailer, M.; Schmidt, A.; Seidel, T.; Stadler, M. & Kasneci, G.et al. ChatGPT for Good? On Opportunities and Challenges of Large Language Models for Education. **Learning and Individual Differences**, v. 103, 2023.

Kizilcec, R. F. **How Much Information?** Effects of Transparency on Trust in an Algorithmic Interface. In: Proceedings of the 2016 CHI Conference on Human Factorsin Computing Systems. New York: ACM, 2016.

Krouska, A.; Troussas, C. & Virvou, M. Deep Learning for Educational Data Mining: A Review. **Applied Sciences**, v. 10, n. 14, 2020.

Liddy, E. D. **Natural Language Processing**. In: Encyclopedia of Library and Information Science. New York: Marcel Decker, 2001.

Luckin, R. et al. **Intelligence Unleashed:** An Argument for AI in Education. London: Pearson Education, 2016.

Manning, C. D.; Raghavan, P. & Schütze, H. **Introduction to Information Retrieval.** Cambridge: Cambridge University Press, 2008.

Drachsler, H.; Verbert, K. & Duval, E. **Recommender Systems for Learning**. New York: Springer, 2013.

Mikolov, T.; Chen, K.; Corrado, G. & Dean J. Efficient Estimation of Word Representations in Vector **Computer Science**, 2013.

Okonkwo, C. W.; Ade-Ibijola, A. Chatbots Applications in Education: A Systematic Review. **Computers and Education: Artificial Intelligence**, v. 2, 2021.

Ouzzani, M. et al. Rayyan—a web and mobile app for systematic reviews. Systematic Reviews, **Springer**, v. 5, n. 1, p. 210, 2016. Disponível em: https://doi.org/10.1186/s13643-016-0384-4 .›

Pazzani, M. & Billsus, D. **Content-Based Recommendation Systems.** In: Brusilovsky, P.; Kobsa, A. & Nejdl, W. (org.). The Adaptive Web. Berlin: Springer, 2007.

Ricci, F.; Rokach, L. & Shapira, B. **Recommender Systems Handbook**. 2. ed. Boston: Springer, 2015.

Russel, S.; Norvig, P. **Artificial Intelligence:** A Modern Approach. 4. ed. Hoboken: Pearson, 2021.

Schafer, J.; Frankowski, D.; Herlocker, J. & Sen, S. **Collaborative Filtering Recommender Systems**. In: Brusilovsky, P.; Kobsa, A. & Nejdl, W. (org.). The Adaptive Web. Berlin: Springer, 2007.

Selwyn, N. **Should Robots Replace Teachers?** AI and the Future of Education. Cambridge: Polity Press, 2019.

Siemens, G. & Baker, R. **Learning Analytics and Educational Data Mining:** Towards Communication and Collaboration. In: Proceedings of the 2nd International Conference on Learning Analytics and Knowledge. New York: ACM, 2012.

UNESCO. **Guidance for Generative AI in Education and Research**. Paris: UNESCO, 2023.

Vaswani, A.; Shazeer, N.; Parmar, N.; Uszkoreit, J.; Jones, L.; Gomez, A. N.; Kaiser, L. & Polosukhin, I. **Attention Is All You Need**. In: Advances in Neural Information Processing Systems (NeurIPS), 2017.

Verbert, K; Manouselis, N.; Ochoa, X.; Wolpers, M.; Drachsler, H & Bosnic, I. Context-Aware Recommender Systems for Learning: A Survey and Future Challenges. **IEEE Transactions on Learning Technologies**, v. 5, n. 4, p. 318–335, 2012.

Winkler, R. & Söllner, M. Unleashing the Potential of Chatbots in Education: A State-of-the-Art Analysis. In: **Academy of Management Annual Meeting Proceedings**, 2018.

Zawacki-Richter, O.; Marín, V. I.; Bond, M. & Gouverneur, F. Systematic Review of Research on Artificial Intelligence Applications in Higher Education. **International Journal of Educational Technology in Higher Education**, v. 16, n. 39, 2019

Sobre o autor(a)

Cleber Luiz Damin Ferro

Especialização em Educação Profissional e Tecnológica pelo Instituto Federal Catarinense (IFC - 2020).

Especialização em Governança em TI pela UNYLEYA Editora e Cursos (2017).

Graduado em Gestão de TI pela Universidade do Sul de Santa Catarina (UNISUL - 2012).

Professor de Informática no Instituto Federal Catarinense - Campus Sombrio.

Lattes: http://lattes.cnpq.br/0636855066998476

CAPÍTULO 8

Assistentes virtuais edcacionais: tecnologias de inteligência artificial no apoio ao ensino

Maeve Espindola Pereira

1. Introdução

A integração da inteligência artificial redefine os processos de ensino na educação contemporânea. Os assistentes virtuais educacionais surgem como agentes tecnológicos capazes de mapear as interações dos estudantes para fornecer um suporte contínuo e individualizado. A presença dessas ferramentas altera a dinâmica escolar tradicional, exigindo uma reconfiguração da ação docente e a implementação de infraestruturas digitais adequadas para sustentar o fluxo de dados.

Os tutores inteligentes processam métricas de aprendizagem para modular o conteúdo entregue a cada usuário diariamente. A personalização ocorre por meio de algoritmos que rastreiam o histórico de respostas durante a navegação, ajustando as trilhas de ensino em tempo real (Brusilovsky; Millán, 2007). O aprendizado automatizado aprimora o funcionamento dessas máquinas, criando recomendações precisas e imediatas para o discente em formação.

A tecnologia atua como um suporte analítico que não substitui a necessidade da mediação humana nas escolas. O conceito de inteligência híbrida formulado por Cukurova (2024) estabelece que a máquina executa cálculos e tarefas baseadas em dados, enquanto o professor concentra sua atuação na empatia. O educador utiliza os relatórios gerados pelos assistentes virtuais para fundamentar o planejamento pedagógico de forma técnica.

A leitura contínua de informações dos alunos levanta desafios morais que requerem políticas rígidas de governança digital. A inteligência artificial exige transparência algorítmica para evitar vieses discriminatórios e garantir decisões computacionais compreensíveis para todos (Manna; Sett, 2024). A proteção da privacidade estudantil necessita de modelos de segurança inquebráveis que blindem os registros contra exposições externas indesejadas no ambiente escolar.

Este artigo aborda sobre o impacto da implementação de assistentes virtuais no suporte direto à instrução escolar. A pesquisa examina o funcionamento algorítmico

dos tutores inteligentes, a colaboração prática entre a máquina e o docente e as barreiras operacionais enfrentadas pelas instituições. O estudo fundamenta-se em revisão da literatura para demonstrar a utilidade da automação inteligente na evolução das metodologias de ensino atuais.

2. Referencial Teórico

A fundamentação teórica explora os conceitos estruturais que viabilizam o uso de inteligência artificial no ambiente escolar. A inserção de assistentes virtuais exige uma análise sobre o funcionamento dos algoritmos e a arquitetura dos tutores inteligentes. A revisão examina o modelo de inteligência híbrida, destacando a colaboração indispensável entre a capacidade computacional e a mediação do professor.

O referencial trata sobre os desafios éticos inerentes ao processamento de dados estudantis, a necessidade de governança digital e a urgência da transparência algorítmica para garantir práticas educacionais seguras e equitativas.

2.1 Fundamentos Algorítmicos dos Tutores Inteligentes

Os sistemas educacionais modernos utilizam inteligência artificial para rastrear e modelar o comportamento estudantil durante a navegação. Os tutores inteligentes coletam registros de interação para identificar o nível de compreensão do usuário, viabilizando adaptações precisas (Brusilovsky; Millán, 2007). A estruturação desse conhecimento pode ser modelada graficamente para sugerir caminhos otimizados de ensino (Costa et al., 2025). A arquitetura computacional constrói perfis cognitivos que orientam a máquina no momento exato de apresentar novos desafios ou revisar conceitos anteriores.

O funcionamento dos assistentes virtuais depende intimamente das técnicas de aprendizado de máquina para prever dificuldades de assimilação de conteúdo. As plataformas processam volumes massivos de informações para encontrar padrões lógicos, ajustando suas regras internas a cada novo dado inserido pelo estudante, processo evidenciado nas pesquisas de Domingos (2017). O uso de algoritmos sofisticados permite o desenvolvimento de tutores personalizados altamente responsivos, na perspectiva defendida por Sallaah et al. (2025). A tecnologia converte respostas fragmentadas em um fluxo ininterrupto de análise estatística.

A evolução do processamento de dados originou abordagens complexas para a instrução individualizada nas escolas. A aplicação de inteligência artificial promove o desenvolvimento individual ao reconhecer as formas com que cada aluno aprende mais facilmente, como argumentado por Sena (2022). O programa simula caminhos de ensino e ajusta a dificuldade dos exercícios instantaneamente. As tecnologias de

aprendizado adaptativo demonstram impacto significativo na personalização, permitindo que conteúdos sejam modificados dinamicamente (Ferreira; Lima, 2023). A ferramenta oferece uma experiência instrucional amoldada às demandas do usuário.

A arquitetura digital altera a dinâmica da sala de aula ao automatizar etapas mecânicas do processo de instrução diária. Os sistemas inteligentes assumem a responsabilidade de aplicar avaliações formativas e corrigir tarefas repetitivas com extrema exatidão. O uso de recursos tecnológicos libera espaço para a realização de projetos interativos densos, alinhando a prática aos conceitos de Luckin et al. (2016).

A inteligência artificial transforma métodos tradicionais de mensuração de conhecimento, conforme indicam Freitas et al. (2025). Os códigos identificam defasagens e entregam rotas de recuperação. A construção de tutores inteligentes demanda infraestrutura tecnológica capaz de suportar o processamento contínuo de interações. As redes neurais artificiais exigem servidores potentes para manter o sistema responsivo durante o uso simultâneo por milhares de estudantes.

A integração de mídias digitais na educação enfrenta barreiras diretas de conectividade e acesso (Silva; Costa, 2024). O planejamento cuidadoso garante a aplicação correta dos recursos pedagógicos, como defendem Guimarães et al. (2022). Os programas transformam registros brutos em trajetórias de aprendizagem estruturadas com alta eficiência.

2.2 O Papel Docente e o Modelo de Inteligência Híbrida

A inserção tecnológica na escola propõe a coexistência colaborativa entre os sistemas digitais e a ação pedagógica humana. A máquina processa grandes escalas numéricas e sugere intervenções lógicas baseadas em algoritmos estatísticos. O referencial teórico classifica essa dinâmica de integração profunda como inteligência híbrida (Cukurova, 2024).

A união das competências computacionais com as habilidades humanas potencializa os resultados educacionais. A escola atual necessita romper com modelos obsoletos para abraçar metodologias ativas mediadas por tecnologia (Gómez, 2015). A presença dos assistentes virtuais redefine a função do professor diante das exigências da cultura digital. O educador deixa de atuar como transmissor primário de conteúdos para assumir a posição de orientador do conhecimento.

A mudança metodológica exige letramento computacional para que o docente compreenda e utilize as ferramentas a favor do ensino (Gonçalves; Ferreira, 2021). A adaptação profissional torna-se um requisito central na integração dessas inovações (Costa Júnior et al., 2022). A tecnologia exige intencionalidade pedagógica para funcionar adequadamente.

A utilização de relatórios algorítmicos orienta o planejamento das atividades

práticas nas instituições de ensino básico e superior. O tutor inteligente fornece painéis de diagnóstico que indicam o progresso diário e as fragilidades de cada estudante. A leitura correta dessas métricas possibilita intervenções precisas e eleva a interação em sala, realidade observada por Marins et al. (2023).

O trabalho docente baseia-se na aprendizagem em seu significado mais amplo, utilizando os dados para guiar os discentes. Para Teixeira et al. (2021), o professor comanda a mediação. A interação entre a máquina e o sujeito em formação demanda sensibilidade para interpretar os dados além dos números frios. Os algoritmos identificam falhas na resolução de uma equação, mas não conseguem compreender as motivações emocionais que causaram o erro.

A mediação docente complementa a limitação do software ao estudar as causas sociais do baixo rendimento escolar (Valente, 2018). O educador atua como articulador crítico diante da inserção dessas plataformas no ambiente escolar (Nascimento, 2024). O equilíbrio entre eficiência e acolhimento é vital.

A construção de uma cultura escolar inovadora repousa na valorização da figura do professor em ambientes mediados por inteligência artificial. A utilização de assistentes virtuais sem o acompanhamento adequado restringe a aprendizagem ao consumo passivo de informações em telas.

A implementação inteligente dessas ferramentas traz melhorias significativas na experiência educacional, na conclusão de Santos e Oliveira (2021). A instrução atinge seu potencial pleno ao explorar recursos para transformar o aprendizado de modo ético e criativo (Meroto et al., 2024). A tecnologia serve ao propósito do educador.

2.3 Governança de Dados, Ética e Transparência Algorítmica

O processamento de dados sensíveis no ambiente escolar impõe a criação de infraestruturas tecnológicas altamente seguras. Essa arquitetura de proteção, evidenciada por Imohimi (2025), exige a adoção de protocolos de privacidade desde a concepção do sistema para evitar vazamentos de informações estudantis.

Plataformas inteligentes lidam com registros comportamentais e cognitivos que demandam criptografia rigorosa. O tratamento informacional no contexto digital, sob a ótica de Elias et al. (2023), envolve implicações éticas profundas que requerem responsabilidade contínua das instituições. A governança atua como uma barreira protetora inegociável dentro das escolas modernas. Questões morais sobre a equidade no acesso aos recursos digitais acompanham o desenvolvimento de tutores virtuais. O acesso desigual à tecnologia, como argumentam Costa et al. (2024), tem o potencial de agravar assimetrias sociais pré-existentes se não houver regulamentação adequada.

A implementação dessas ferramentas exige políticas públicas claras para garantir justiça educacional. O enfrentamento direto de desafios práticos na educação básica,

orientadas por Akgun e Greenhow (2021), assegura que todos os alunos sejam beneficiados de maneira uniforme. A inovação necessita servir à democratização plena do conhecimento humano.

Modelos de consentimento rigorosos são necessários para limitar a exploração comercial das métricas extraídas pelos sistemas educacionais. A gestão do conhecimento na era digital, alertadas por Moreira e Ribeiro (2023), exige um letramento crítico por parte dos educadores e gestores para proteger os discentes. As instituições devem construir diretrizes que preservem a identidade contra violações de corporações desenvolvedoras de software.

As promessas e implicações do ensino automatizado, defendidas por Holmes et al. (2019), demandam transparência absoluta nas relações com os usuários. O cuidado informacional garante a integridade acadêmica. Processos de inteligência artificial operam frequentemente sob lógicas opacas que geram desconfiança na comunidade acadêmica. A adoção de mecanismos explicáveis, um aspecto demonstrado nos estudos de Manna e Sett (2024), possibilita entender os critérios exatos utilizados pela máquina para recomendar atividades ou mensurar notas.

O funcionamento interno dos algoritmos precisa ser compreensível para professores e alunos. A avaliação mediada por essas tecnologias, recomendados por Bulut et al. (2024), deve incorporar análises rigorosas de viés para evitar injustiças. A claridade operacional valida o uso dessas ferramentas diariamente.

Revisões constantes dos códigos de programação tornam-se obrigatórias para neutralizar preconceitos inseridos involuntariamente no treinamento do sistema. O planejamento das infraestruturas de integração, sob a ótica de Silva e Costa (2024), enfrenta desafios diretos que exigem suporte técnico e pedagógico especializado. O aprendizado da máquina deve contemplar a diversidade cultural e linguística da população conectada. A inserção tecnológica nas escolas, requer metodologias científicas consistentes para validar sua eficácia sem expor o estudante a riscos (Narciso; Santana, 2025). A supervisão humana mantém o ecossistema educacional ético.

2.4 Aplicações Práticas e a Personalização da Aprendizagem

O processo de personalização instrucional rompe com os modelos padronizados ao ajustar o conteúdo às necessidades particulares de cada estudante. Essa estruturação, demonstrada por Blay e McClaskey (2010), garante que a instrução responda diretamente aos interesses e ao ritmo cognitivo do indivíduo. O ensino individualizado ganha força quando as ferramentas digitais conseguem mapear defasagens específicas.

O uso de intervenções direcionadas eleva a compreensão conceitual em ambientes

virtuais, constatados por Horn e Staker (2015), viabilizando rotas de estudo alternativas. A tecnologia transforma o espaço escolar em um ambiente responsivo.

Sistemas educacionais baseados em inteligência artificial processam métricas de navegação para reconhecer as formas com que cada sujeito aprende mais facilmente. A configuração dessas redes, evidenciada por Costa (2021), adapta inteligentemente as etapas de avaliação em resposta ao progresso acadêmico diário durante o uso contínuo.

Essa arquitetura digital fomenta o protagonismo nos percursos de aquisição de conhecimento, auxiliando no desenvolvimento de uma maior autonomia de estudos. O estudante exerce controle sobre suas rotinas de discussão teórica, apontadas por Sena (2022), navegando em plataformas interativas guiadas por dados. A personalização modifica a interação tradicional.

Diagnósticos instantâneos gerados por algoritmos oferecem retornos precisos para que os alunos corrijam falhas lógicas prontamente. A estruturação de mapas de conhecimento, delineados Khan (2013), possibilita que o programa indique o assunto exato a ser trabalhado na sequência instrucional de cada disciplina. Os tutores virtuais fornecem relatórios detalhados que facilitam a criação de planos de aula. O recurso computacional otimiza a rotina escolar, documentadas por Teixeira et al. (2021), ao prever interesses e antecipar dificuldades cognitivas da turma. A sala de aula adquire novos fluxos operacionais.

Ambientes de estudo mediados por redes informáticas rompem com a passividade discente ao exigir participação ativa. O processamento ágil de informações, examinado por Loureiro (2019), apoia o desenvolvimento cognitivo e transforma o aluno no foco central da pesquisa escolar durante as atividades propostas. Intervenções pedagógicas ganham extrema exatidão quando o software consegue adequar o estilo de ensino.

O avanço tecnológico viabilizou metodologias responsivas altamente populares, em consonância com Führ (2022), moldando os diferentes níveis de assimilação apresentados pela classe. O acompanhamento algorítmico eleva a qualidade educacional diária.

Formatos de instrução e modelos educacionais virtuais ampliam suas capacidades interativas mediante o suporte de algoritmos modernos. A integração direta dessas ferramentas tecnológicas pode potencializar a flexibilidade dos métodos instrucionais (Freitas et al., 2025). O monitoramento ininterrupto das respostas inseridas no sistema altera os padrões convencionais de mensuração. A interpretação contínua de dados modifica profundamente as rotinas de avaliação, como afirmam Marins et al. (2023), fornecendo diagnósticos baseados no engajamento individual. As estratégias de ensino tornam-se plenamente dinâmicas e precisas.

3. Metodologia

Esta pesquisa caracteriza-se como uma revisão sistemática de literatura, conduzida para garantir a replicabilidade e o rigor na coleta de dados. O levantamento bibliográfico foi realizado em bases de dados científicas nacionais e internacionais: SciELO, Scopus, IEEEXplore, ACM Digital Library e Google Acadêmico. O processo seguiu critérios estruturados para identificar o estado da arte sobre assistentes virtuais e tutores inteligentes.

Procedimentos de coleta de dados envolveram a exploração em repositórios acadêmicos renomados. A aplicação de rigor investigativo, segundo as diretrizes de Sampaio e Mancini (2007) minimiza vieses na identificação de artigos sobre plataformas inteligentes. A estruturação desses registros documentais constrói a fundamentação necessária. O mapeamento sistemático contribui para a fidedignidade dos achados e para a organização do referencial teórico.

Critérios de triagem refinaram o acervo para focar no uso pedagógico de tutores automatizados. A organização dessas fontes, aspecto delineado nas pesquisas de Ferenhof e Fernandes (2016), evita desvios e estabelece um panorama atualizado sobre as tecnologias educacionais. Os descritores aplicados englobaram termos associados à personalização da aprendizagem. A filtragem apurada valida a pertinência do material selecionado.

Operações de análise de conteúdo guiaram a interpretação qualitativa dos resultados extraídos durante o levantamento literário. O agrupamento sistemático dessas obras, como evidenciam Vosgerau e Romanowski (2014), permite traduzir o estado da arte e as fronteiras da inovação escolar. A avaliação identificou padrões algorítmicos ligados aos modelos de inteligência híbrida. A síntese consolida o embasamento teórico da pesquisa. As etapas detalhadas deste processo de busca e seleção estão estruturadas no Quadro 1 a seguir:

Quadro 1 - Protocolo de pesquisa

Atividade	Descrição
1: Estratégia de busca	Aplicação da string de busca: ("assistentes virtuais educacionais" OR "tutores inteligentes") AND ("inteligência artificial" OR "inteligência híbrida"). Recorte temporal: 2015 a 2025.
2: Consulta em bases de dados	A busca foi realizada em repositórios acadêmicos renomados, priorizando artigos alinhados à personalização da aprendizagem e à automação escolar.

continua

continuação

3: Organização das bibliografias	Estruturação dos registros documentais recuperados para compor a fundamentação teórica e exclusão criteriosa de trabalhos duplicados.
4: Seleção padronizada	Aplicação de critérios de inclusão (artigos de periódicos, revisão por pares, foco em ferramentas de IA) e exclusão (teses, dissertações, artigos duplicados ou que não abordam o contexto escolar).
5: Composição do portfólio	Leitura na íntegra das obras selecionadas e aplicação de operações de análise de conteúdo qualitativa para traduzir o estado da arte e as inovações escolares.

Fonte: elaborado pela autora (2026)

A aplicação desse protocolo permitiu refinar o acervo, removendo os trabalhos duplicados e aqueles que fugiam do tema. O quantitativo de artigos recuperados e filtrados em cada etapa, até a definição do portfólio final, está detalhado no Quadro 2.

Quadro 2 - Atividades e números de documentos recuperados

Atividades de seleção	**Números de documentos**
Busca nas bases (recorte de 10 anos - 2015 a 2025)	115
Excluindo documentos duplicados	89
Primeiro filtro (leitura de títulos e resumos)	55
Total de documentos lidos integralmente	48
Portifólio final	**38**

Fonte: elaborado pela autora (2026)

Após a consolidação do portfólio final detalhado no quadro, a pesquisa avança para a etapa de análise dos resultados. Os dados extraídos desses documentos formam a base para averiguar a aplicação prática dos assistentes virtuais educacionais e seus impactos no ambiente escolar.

4. Análise e Discussão dos Resultados

Estudos sobre a implementação de tecnologias educacionais revelam um cenário de transformação profunda nas metodologias de ensino contemporâneas. O processamento de dados por plataformas inteligentes, na percepção de Barros et al. (2023), potencializa a personalização instrucional ao adequar o conteúdo ao ritmo individual de cada estudante.

A avaliação sistemática dessas ferramentas evidencia um rompimento com os modelos tradicionais de transmissão massiva de conhecimento. A arquitetura de assistentes virtuais, mapeadas por Fabrizzio et al. (2023), consolida a coprodução entre humanos e máquinas na gestão da informação.

A análise crítica das evidências bibliográficas comprova que a inovação tecnológica exige planejamento estratégico para funcionar de maneira eficiente no ambiente escolar. Os estudos selecionados indicam que o sucesso dessas inovações ultrapassa a simples adoção de dispositivos digitais. O funcionamento dos algoritmos de aprendizado de máquina, de acordo com as pesquisas de Domingos (2017), permite categorizar os interesses dos alunos para prefigurar trilhas de estudo exatas.

As instituições de ensino necessitam integrar essas facilidades computacionais a um projeto de mediação humana estruturado. A leitura atenta da literatura, como evidenciam as reflexões de Cukurova (2024), reforça a urgência de estabelecer o modelo de inteligência híbrida nas escolas. O cruzamento sistemático da pesquisa documental sustenta a construção das categorias analíticas debatidas nas subseções seguintes.

O portfólio selecionado abrange estudos focados na personalização da aprendizagem, no papel docente e nos desafios éticos da automação escolar. A amostra com a síntese das principais obras analisadas está organizada no Quadro 3.

Quadro 3 - Portifólio final

Autores	Ano	Título	Temática
Akgun, S. & Greenhow, C.	2021	Artificial intelligence in education: Addressing ethical challenges...	Ética e Transparência Algorítmica
Barros, A. et al.	2023	Educação a distância e o uso da inteligência artificial	Personalização da Aprendizagem

continua

continuação

Bulut, O. et al.	2024	*The Rise of Artificial Intelligence in Educational Measurement...*	Ética e Transparência Algorítmica
Corrêa, P. M. H.	2016	A plataforma Khan Academy como auxílio ao ensino híbrido...	Personalização da Aprendizagem
Costa, D.	2021	Plataformas Adaptativas e o Ensino Personalizado	Personalização da Aprendizagem
Costa, J. et al.	2024	Desigualdades sociais e o acesso à tecnologia de IA...	Ética e Transparência Algorítmica
Costa, S. et al.	2025	*Graph-Based Personalized Recommendation in Intelligent...*	Personalização da Aprendizagem
Costa Júnior, R. M. et al.	2022	Formação docente e tecnologias emergentes...	O Papel Docente e a Inteligência Híbrida
Cukurova, M.	2024	*The Interplay of Learning, Analytics, and Artificial Intelligence...*	O Papel Docente e a Inteligência Híbrida
Dietterich, T. G.	2017	*Steps toward robust artificial intelligence*	Ética e Transparência Algorítmica
Domingos, P.	2017	O algoritmo mestre: como a busca pelo algoritmo...	Personalização da Aprendizagem
Elias, M. et al.	2023	Inteligência artificial em saúde e implicações bioéticas...	Ética e Transparência Algorítmica
Fabrizzio, G. et al.	2023	Assistente virtual: ferramenta para coprodução em saúde...	O Papel Docente e a Inteligência Híbrida
Ferreira, L. & Lima, R.	2023	Tecnologias de aprendizado adaptativo e o futuro...	Personalização da Aprendizagem

continua

continuação

Freitas, C. A. et al.	2025	Impacto da inteligência artificial na avaliação acadêmica...	Personalização da Aprendizagem
Führ, R. C.	2022	Educação 4.0 nos impactos da quarta revolução industrial	Personalização da Aprendizagem
Gonçalves, F. & Ferreira, L.	2021	A integração de tecnologias digitais na prática docente...	O Papel Docente e a Inteligência Híbrida
Guimarães, U. A.	2023	Plataformas adaptativas como ferramenta de apoio...	Personalização da Aprendizagem
Guimarães, U. A. et al.	2022	Contribuições das plataformas adaptativas no ensino...	Personalização da Aprendizagem
Holmes, W. et al.	2019	*Artificial Intelligence in Education: Promises and Implications...*	O Papel Docente e a Inteligência Híbrida
Horn, M. B. & Staker, H.	2015	*Blended: usando a inovação disruptiva para aprimorar...*	Personalização da Aprendizagem
Imohimi, E. O.	2025	*Building Privacy and Preserving AI Models for Secure...*	Privacidade de Dados Estudantis
Kizilcec, R. F. et al.	2017	*The instructor's face in video instruction...*	Personalização da Aprendizagem
Łodzikowski, K. et al.	2023	*Generative AI and Its Educational Implications*	Ética e Transparência Algorítmica
Loureiro, B. C. O.	2019	O uso das tecnologias da informação e comunicação...	O Papel Docente e a Inteligência Híbrida
Luckin, R. et al.	2016	*Intelligence Unleashed: An argument for AI in Education*	Personalização da Aprendizagem
Machado, R. et al.	2020	Uso da Khan Academy em escolas brasileiras...	Personalização da Aprendizagem

continua

continuação

Manna, S. & Sett, N.	2024	*Need of AI in Modern Education: in the Eyes of Explainable AI...*	Ética e Transparência Algorítmica
Marins, J. et al.	2023	Os impactos da inserção de tecnologias baseadas em IA...	O Papel Docente e a Inteligência Híbrida
Meroto, M. et al.	2024	Revolucionando a educação: explorando o potencial da inteligência...	O Papel Docente e a Inteligência Híbrida
Moreira, J. & Ribeiro, J.	2023	*Letramento e competência informacional e as relações éticas...*	Ética e Transparência Algorítmica
Radu, A.	2025	*Containerization of Machine Learning Algorithms...*	Privacidade de Dados Estudantis
Sallaah, M. H. et al.	2025	*Deep Reinforcement Learning for Personalized AI Tutors...*	Personalização da Aprendizagem
Santos, L. C. & Oliveira, M. L.	2021	*IA na educação: transformando o ensino e a aprendizagem*	O Papel Docente e a Inteligência Híbrida
Łodzikowski, K. et al.	2023	*Generative AI and Its Educational Implications*	Ética e Transparência Algorítmica
Sena, W. N.	2022	Os impactos na educação do uso de plataformas adaptativas...	Personalização da Aprendizagem
Silva, A. P. & Costa, F. A.	2024	Desafios e oportunidades da integração de mídias digitais...	O Papel Docente e a Inteligência Híbrida
Teixeira, M. A. S. et al.	2021	Potencializando a educação: o impacto da inteligência artificial...	Personalização da Aprendizagem
Valente, J. A.	2018	A sala de aula invertida e a possibilidade do ensino personalizado	Personalização da Aprendizagem

Fonte: elaborado pela autora (2026)

A partir das temáticas definidas no Quadro 3, a análise dos dados foi dividida em eixos específicos para detalhar a aplicação dessas ferramentas no ambiente acadêmico. Essa estrutura orienta a discussão das próximas subseções, iniciando pelo impacto dessas tecnologias na personalização do ensino.

4.1 Personalização da Aprendizagem e a Eficácia dos Assistentes Virtuais

Modelos educacionais tradicionais perdem espaço quando as instituições integram tecnologias capazes de mapear as particularidades cognitivas de cada estudante. Sistemas adaptativos, definidos por Brusilovsky e Millán (2007), processam dados em tempo real para ajustar a entrega de conteúdos com altíssima precisão.

Essa dinâmica computacional substitui a instrução massiva por trajetórias singulares de conhecimento. O ensino individualizado, na compreensão de Horn e Staker (2015), ganha força ao direcionar o suporte lógico diretamente às fragilidades apresentadas. A máquina transforma a sala de aula em um ecossistema focado nas necessidades do aluno.

Mecanismos de inteligência artificial monitoram o progresso contínuo para estruturar um ritmo de estudo perfeitamente alinhado à capacidade de assimilação do jovem. A utilização de aprendizado de máquina, processo evidenciado por Domingos (2017), permite prever os interesses e agrupar as ações que favorecem a resolução das tarefas propostas. Essa arquitetura tecnológica reage instantaneamente aos comandos inseridos nas telas interativas.

Ferramentas digitais modernas, na visão de Costa (2021), identificam deficiências pontuais para recomendar materiais complementares de recuperação exatos. O rastreamento inteligente eleva a eficiência das intervenções instrucionais diárias. Estruturas curriculares tornam-se consideravelmente acessíveis quando os programas respeitam os limites de processamento mental de quem está aprendendo.

A redução da sobrecarga cognitiva, aspecto fortemente defendido por Sweller (1988), garante que as informações sejam fragmentadas logicamente para evitar a exaustão durante os exercícios. O uso de mídias diversificadas engaja o sujeito ao estimular capacidades variadas.

A personalização das plataformas, consoante as teorias de Gardner (1995), possibilita que os recursos atinjam múltiplas formas de compreensão humana simultaneamente. O desenho algorítmico cuidadoso potencializa a absorção de conceitos complexos na escola.

Experiências concretas nas instituições evidenciam melhorias notáveis na proficiência de disciplinas exatas e linguísticas mediante o suporte computacional contínuo. A adoção de assistentes virtuais no ambiente público, realidade analisada

por Machado et al. (2020), resultou em avanços estatísticos significativos nas notas de avaliações institucionais.

O sistema entrega respostas corretivas imediatas a cada falha detectada. Retornos avaliativos automáticos, documentados por Corrêa (2016), instigam os usuários a superarem os próprios erros sem aguardar correções manuais demoradas. A agilidade informacional mantém o nível de motivação dos estudantes sempre elevado durante as práticas.

Projetos de engenharia de software avançam rapidamente para converter programas reativos em agentes virtuais extremamente proativos. A inserção de aprendizado por reforço profundo, metodologia detalhada por Sallaah et al. (2025), viabiliza a criação de tutores capazes de antecipar obstáculos lógicos antes mesmo que o aluno erre. O ambiente virtual adapta seu grau de exigência passo a passo.

Tecnologias de instrução responsiva, rompem barreiras históricas ao oferecerem aulas moldadas às especificidades individuais (Ferreira; Lima, 2023). A predição de comportamento consolida uma nova era de excelência instrucional acadêmica. Ambientes de estudo modernos utilizam estratégias lúdicas para prender a atenção e transformar o esforço intelectual em uma jornada altamente atrativa. O uso de mecânicas de jogos, elemento explorado por Kizilcec et al. (2017), incentiva o engajamento contínuo por meio de pontuações e recompensas visuais a cada vitória alcançada. O envolvimento interativo constante promove um senso de conquista inigualável.

Essa imersão digital, na menção de Teixeira et al. (2021), facilita a participação em redes de aprendizagem e solidifica a autonomia estudantil perante as telas, elementos que podem potencializar a participação ativa dos discentes em sua própria formação.

4.1.1 Análise Comparativa e Taxonomia dos Assistentes Virtuais

Para aprofundar a compreensão sobre a aplicação prática de sistemas inteligentes na personalização do ensino, faz-se necessário analisar ferramentas reais adotadas no contexto educacional contemporâneo. O Quadro 4 apresenta uma análise comparativa de cinco assistentes virtuais proeminentes Khanmigo, ChatGPT, Duolingo Max, Gemini for Education e Microsoft Copilot mapeando seus focos pedagógicos, recursos principais e políticas de privacidade.

Quadro 4 - Análise coparativa de assistentes virtuais

Ferramenta	Foco Pedagógico	Recusos Principais	Privacidade e Governança de Dados
Khanmigo (Khan Academy)	Tutoria socrática individual para alunos e assistência de preparação para professores.	Desafia o pensamento crítico sem dar respostas diretas; apoia a elaboração de planos de aula, rubricas e questionários para docentes.	Focado em privacidade escolar; acesso para menores de 18 anos restrito a parcerias com distritos ou autorização dos pais.
ChatGPT (OpenAI)	*Brainstorming* de projetos, suporte de escrita e programação para estudantes.	Geração de perguntas práticas, suporte de codificação e diferenciação por nível de leitura.	O tier ChatGPT Edu garante controles administrativos e impede o treinamento de modelos com dados de usuários.
Duolingo Max	Aprendizado interativo de línguas estrangeiras apoiado pelo modelo GPT-4.	Video Call com a personagem Lily para conversas em tempo real e Roleplay de cenários cotidianos.	Cenários definidos por especialistas humanos; o conteúdo gerado por IA é constantemente revisado para manter o tom pedagógico apropriado.
Gemini for Education (Google)	Assistência de produtividade e criação de conteúdo embutida no Workspace.	Geração de planos de aula no Docs, síntese de e-mails no Gmail e criação de imagens ilustrativas no Slides.	Proteções de nível empresarial; as interações não passam por revisão humana nem servem ao treinamento de IA.
Microsoft Copilot	Planejamento instrucional e design de atividades por meio do módulo Teach.	Elaboração de planos de aula, rubricas, quizzes e flashcards alinhados a padrões curriculares.	Desenvolvido sob princípios de IA Responsável da Microsoft; disponível para usuários com licenças educacionais.

Fonte: elaborado pela autora (2026)

Com base nas funcionalidades e nos focos instrucionais mapeados, propõe-se uma taxonomia para classificar esses assistentes educacionais em três categorias fundamentais:

1. Tutores Socráticos e Sistemas Práticos Adaptativos: Sistemas voltados para a aprendizagem autônoma que utilizam feedback explicativo e questionamentos em vez de respostas diretas para guiar o raciocínio do discente (ex: Khanmigo e Duolingo Max).
2. Assistentes de Produtividade Docente e Design de Aula: Ferramentas plenamente integradas a suítes de produtividade, voltadas a otimizar o tempo de preparação do professor por meio da automação de tarefas administrativas (ex: Gemini for Education e o módulo Teach do Microsoft Copilot).
3. Motores de IA Generativa Multiuso: Plataformas amplas baseadas em grandes modelos de linguagem que oferecem suporte versátil a tarefas de redação, programação e pesquisa, demandando maior letramento crítico dos estudantes para evitar riscos de plágio e dependência cognitiva.

Essa classificação taxonômica demonstra que a eficácia dessas ferramentas reside na intencionalidade do seu design e na adequação de seus protocolos de segurança às faixas etárias dos alunos. A partir dessa contextualização das ferramentas, a discussão prossegue para examinar a necessária integração entre a capacidade computacional das máquinas e a mediação humana na prática escolar.

4.2 O Papel Docente e a Integração da Inteligência Híbrida no Ambiente Escolar

Reconfigurações profundas no espaço escolar exigem uma alteração imediata nas funções tradicionalmente exercidas pelos educadores diante da automação. O reposicionamento do professor, argumentado por Nóvoa (2019), transforma o antigo transmissor de conteúdo em um mediador estratégico do conhecimento. Essa nova dinâmica relacional, fundamentada na inteligência híbrida proposta por Cukurova (2024), estabelece uma colaboração na qual a máquina processa dados enquanto o humano foca na empatia.

A tecnologia assume a execução de tarefas mecânicas e libera o docente para interações complexas. O ensino humanizado fortalece o vínculo pedagógico nas salas de aula. Planejamentos curriculares precisos requerem um alinhamento rigoroso no momento de inserir assistentes virtuais na rotina das instituições.

A união entre inovação tecnológica e humanização, consoante as análises de Moran (2015), cria ambientes interativos onde os estudantes aprendem de maneira significativa. O acompanhamento contínuo por parte do educador, na orientação de Gonçalves e Ferreira (2021), garante que a ferramenta digital funcione como um complemento à instrução, sem substituir a supervisão humana. O sistema fornece métricas exatas para orientar as decisões didáticas diárias. A expertise do professor valida a utilidade das intervenções computadorizadas.

Dinâmicas de monitoramento estudantil atingem níveis elevados de precisão mediante a interpretação correta dos relatórios algorítmicos gerados pelas plataformas. O uso de inteligência artificial, aspecto evidenciado por Santos e Oliveira (2021), traz melhorias significativas na experiência educacional ao identificar padrões de assimilação de conteúdo.

A mediação pedagógica fundamenta-se na aprendizagem em seu sentido amplo, que como fundamentado por Teixeira et al. (2021), utilizam os dados coletados para guiar as metodologias de ensino. O educador mapeia as defasagens cognitivas rapidamente para corrigir rotas instrucionais. A intervenção humana imediata maximiza o rendimento escolar.

Programas estruturados de formação contínua tornam-se essenciais para que o corpo docente domine as inovações computacionais nas redes de ensino. O treinamento focado em tecnologias emergentes, conforme os apontamentos de Costa Júnior et al. (2022), capacita os professores para extrair o máximo potencial dos tutores virtuais disponíveis. Essa preparação profissional, enfatizada por Nascimento (2024), deve incorporar obrigatoriamente uma postura ética e reflexiva sobre as aplicações pedagógicas da máquina. O aprimoramento técnico assegura que os educadores utilizem os algoritmos com intencionalidade clara. O preparo metodológico eleva a confiança durante a prática educacional.

Redes de compartilhamento de vivências e saberes surgem naturalmente com o avanço da cultura digital entre os profissionais escolares. A criação de comunidades de prática, sob o prisma dos apontamentos de Martinic e Gregorio (2019), desenvolve a reflexão permanente sobre a ação didática mediada por sistemas inteligentes. O educador atua como um formador que centra seu trabalho no desenvolvimento autônomo, que como explicam Guimarães et al. (2022), promove um processamento ativo de ideias.

A troca de metodologias exitosas entre colegas enriquece o repertório da instituição. A união de esforços aprimora a qualidade acadêmica. Rotinas avaliativas automatizadas transferem definitivamente o foco do trabalho educacional para o estímulo das capacidades interpessoais de cada discente. O uso de assistentes virtuais como ferramentas de coprodução, aspecto abordado por Fabrizzio et al. (2023), sugere uma colaboração mútua que otimiza o tempo gasto no gerenciamento escolar.

A fluência informacional do educador, analisado por Sena (2022), deve articular-se com a empatia e o respeito para consolidar espaços sólidos de aprendizagem colaborativa. A máquina fornece o suporte lógico estrutural necessário. O acolhimento humano contribui para tornar o ambiente de aprendizagem mais acolhedor e inclusivo.

4.3 Desafios Éticos, Privacidade de Dados e Transparência Algorítmica

Proteções informacionais rigorosas tornam-se indispensáveis diante do volume de interações processadas pelos sistemas educacionais contemporâneos. O desenho de arquiteturas seguras, orientado por Imohimi (2025), exige a incorporação de protocolos de privacidade desde a concepção das plataformas, blindando o histórico cognitivo dos estudantes. Ambientes fechados garantem o isolamento necessário contra invasões cibernéticas externas indesejadas.

A técnica de conteinerização de algoritmos de aprendizado, detalhada por Radu (2025), encapsula códigos para mitigar riscos de acessos não autorizados. A governança tecnológica transforma o espaço virtual em um ecossistema escolar verdadeiramente protegido.

Dilemas morais surgem rapidamente quando corporações desenvolvedoras de software gerenciam informações extraídas do comportamento de estudantes. O acesso indiscriminado a registros sensíveis, preocupação central nas análises de Dietterich (2017), reforça a urgência de debates sobre a exploração comercial das métricas acadêmicas armazenadas na nuvem.

Modelos de consentimento precisam ser compreensíveis para as famílias envolvidas. A gestão desse conhecimento digital, segundo alertam Moreira e Ribeiro (2023), demanda letramento crítico por parte dos gestores para evitar violações de privacidade. A ética norteia a implementação tecnológica plenamente responsável nas escolas.

Processos decisórios executados por tutores virtuais frequentemente operam sob lógicas ocultas que dificultam o entendimento dos critérios de avaliação. A inteligência artificial explicável, mecanismo amplamente defendido por Manna e Sett (2024), revela os parâmetros exatos utilizados pela máquina para recomendar caminhos instrucionais ou corrigir exercícios diários.

O funcionamento algorítmico necessita de claridade absoluta para conquistar a confiança dos professores. A mensuração de notas computadorizadas, alertadas por Bulut et al. (2024), deve incorporar auditorias de viés para impedir julgamentos injustos durante o uso. A transparência operacional valida o sistema.

Desigualdades estruturais podem ser acentuadas se o acesso às inovações computacionais ocorrer de forma desordenada no sistema de ensino básico. A distribuição assimétrica de recursos digitais, aspecto mapeado por Costa et al. (2024), limita o potencial de integração das camadas populacionais mais vulneráveis da sociedade. O avanço tecnológico exige reflexões profundas sobre justiça social e equidade de oportunidades.

A implementação de plataformas adaptativas, como Elias et al. (2023), carrega implicações bioéticas severas que não podem ser ignoradas pelas instituições públicas.

Inovações eficientes necessitam alcançar todos os aprendizes equitativamente. Equipamentos adequados e redes de conexão estáveis representam o alicerce material para o funcionamento das inteligências interativas.

O planejamento estratégico das escolas, na perspectiva de Silva e Costa (2024), enfrenta desafios operacionais constantes para manter laboratórios atualizados e prontos para o processamento de dados instantâneo. A barreira técnica é apenas a primeira etapa da modernização educacional.

O engajamento com essas novas mídias, como argumenta Nascimento (2024), exige uma postura docente amplamente reflexiva sobre as armadilhas morais presentes na automação. A união entre infraestrutura e preparo intelectual assegura resultados sólidos. Arquiteturas de inteligência generativa trazem questionamentos normativos ao ambiente acadêmico devido à sua capacidade de criar respostas autônomas inéditas.

A formulação de diretrizes específicas, exigência identificada nas pesquisas de Łodzikowski et al. (2023), protege a integridade intelectual das produções escolares diante da facilidade de manipulação textual. O monitoramento contínuo das plataformas afasta riscos de dependência cognitiva. O uso prudente da tecnologia, preserva a função mediadora do professor e eleva o engajamento diário significativamente (Santos; Oliveira, 2021). A inovação atua como instrumento direto de emancipação discente.

4.4 Discussão dos Resultados

Reflexões aprofundadas sobre o cenário atual demonstram que a automação reestrutura as bases metodológicas nas escolas. O uso de plataformas adaptativas, analisadas por Ramos (2018), rompe com a instrução padronizada ao mapear o ritmo individual de cada estudante. A máquina oferece retornos contínuos que otimizam o tempo gasto na assimilação de novos conceitos diários.

Esse ensino moldado às necessidades específicas, publicados nas pesquisas de Horn e Staker (2015), pode contribuir para o engajamento e a compreensão lógica. A ionovação tecnológica oferece subsídios para que o acompanhamento das rotinas escolares ocorra de maneira mais personalizada.

Interações mediadas por tecnologia exigem um reposicionamento estratégico e urgente do educador contemporâneo. A dinâmica da inteligência híbrida, evidenciados por Cukurova (2024), estabelece uma colaboração profunda na qual os algoritmos assumem o processamento analítico de dados massivos.

O professor utiliza essas métricas computadorizadas para diagnosticar fragilidades cognitivas em tempo real. Essa atuação conjunta, fundamentadas por Valente (1999), permite que a mediação humana foque na empatia e na resolução de conflitos sociais.

O acolhimento afetivo consolida o sucesso das intervenções didáticas sugeridas pelo sistema. Estratégias instrucionais ganham eficácia quando os ambientes virtuais oferecem simulações práticas que exigem ações diretas dos jovens. A exploração de cenários digitais, um aspecto examinado por Guimarães (2023), incentiva o raciocínio lógico e a analise científica contínua durante as tarefas. O aprendiz abandona a posição passiva para comandar as etapas metodológicas propostas.

O planejamento didático atento viabiliza que essas ferramentas funcionem como espaços interativos de construção conceitual (Sena, 2022). O engajamento constante transforma a retenção de saberes em uma prática consolidada. Preocupações morais sobre a gestão informacional evidenciam a necessidade urgente de políticas de segurança mais robustas. O processamento de métricas sensíveis, nos apontamentos de Moreira e Ribeiro (2023), demanda letramento ético por parte dos gestores escolares para evitar violações de privacidade indesejadas.

As famílias necessitam de garantias claras sobre o armazenamento dos históricos de acesso. A clareza nas decisões automatizadas, defendidas por Manna e Sett (2024), possibilita a contestação de notas geradas pelos programas de computador. A transparência algorítmica legitima a utilização das máquinas diariamente. Disparidades históricas no acesso aos equipamentos eletrônicos ameaçam o avanço igualitário dessas inovações tecnológicas.

A dependência de infraestruturas conectadas, problema evidenciado por Dietterich (2017), exige ações governamentais firmes para impedir que populações vulneráveis fiquem excluídas da modernização metodológica. O ecossistema acadêmico precisa democratizar a distribuição de recursos materiais rapidamente.

A implantação de plataformas inteligentes, na observação de Costa et al. (2024), carrega o risco intrínseco de ampliar assimetrias se ocorrer de forma desordenada. O planejamento inclusivo assegura oportunidades justas de desenvolvimento intelectual acadêmico. Transformações nas rotinas de avaliação demonstram o impacto estrutural da inteligência artificial nas instituições. O uso de mecanismos explicáveis, aspecto central nas conclusões de Freitas et al. (2025), muda a mensuração de notas, oferecendo um mapeamento preditivo das capacidades individuais ao invés de análises punitivas.

O educador recebe diagnósticos antecipados para conduzir intervenções assertivas. O monitoramento contínuo das plataformas virtuais, como constatam Marins et al. (2023), eleva a interação e flexibiliza as práticas diárias. A integração tecnológica garante rotas instrucionais altamente precisas e equitativas. A reflexão sobre os eixos temáticos analisados permite responder aos questionamentos que nortearam este levantamento. O Quadro 5 sintetiza as principais descobertas do estudo.

Quadro 5 - Principais descobertas sobre as questões de pesquisa

Questão de pesquisa	Descobertas
(a) Qual o impacto da adoção de assistentes virtuais na aprendizagem?	Otimiza o tempo docente, rompe com a instrução padronizada e eleva o engajamento estudantil ao personalizar a entrega de conteúdos ao ritmo de cada aluno.
(b) Qual o papel do professor diante dessas inovações?	O docente atua como mediador. Consolida-se a "inteligência híbrida": a máquina processa grandes volumes de dados, enquanto o professor foca na empatia e no acolhimento.
(c) Quais são as principais barreiras e riscos éticos identificados?	O processamento de dados exige infraestruturas de segurança para proteger a privacidade estudantil. Além disso, há o risco de acentuar desigualdades sociais caso o acesso à tecnologia não seja igualitário.
(d) Qual a importância da transparência algorítmica?	A adoção de mecanismos explicáveis (xAI) é necessária para evitar vieses. As lógicas de avaliação do sistema precisam ser claras para garantir julgamentos justos.

Fonte: elaborado pela autora (2026)

O resumo dessas constatações indica que o funcionamento prático dos tutores virtuais depende da infraestrutura das escolas e do planejamento das equipes. Para que o uso da tecnologia atinja seus objetivos pedagógicos, é necessário equilibrar o processamento dos dados com a mediação contínua do professor.

4.5 Análise Crítica: Divergências, Lacunas e Tendências da Literatura

Ao analisar os trabalhos selecionados, fica claro que a integração de assistentes virtuais na educação está longe de ser um tema consensual. Existem debates e divergências importantes entre os autores. De um lado, pesquisadores focados no desenvolvimento técnico das ferramentas, como Sallaah et al. (2025) e Sena (2022), defendem que os tutores inteligentes conseguem personalizar o ensino de forma muito precisa, ajudando o aluno a estudar no seu próprio
tempo de maneira independente.

De outro, autores voltados para a pedagogia e a relação humana, como Holmes et al. (2019) e Cukurova (2024), trazem um contraponto importante: eles alertam que o uso exagerado dessas ferramentas pode deixar o aluno dependente da máquina, prejudicando o esforço necessário para desenvolver o pensamento crítico. Para eles, a

tecnologia deve apenas apoiar o professor dentro do modelo de inteligência híbrida, e não guiar todo o processo de forma isolada.

Outro ponto de discórdia marcante envolve o acesso a essas tecnologias. Enquanto os discursos oficiais e comerciais tratam a inteligência artificial como uma forma de democratizar o ensino, pesquisadores como Costa et al. (2024) e Dietterich (2017) lembram que, se as escolas não tiverem uma estrutura básica de internet e equipamentos, esses assistentes de última geração vão apenas aumentar a desigualdade que já existe entre os estudantes.

A revisão da literatura também permitiu identificar algumas lacunas nas pesquisas atuais:

- Falta de estudos de longo prazo: A maioria das pesquisas acompanha apenas projetos pilotos rápidos de poucos meses, o que nos deixa sem dados reais sobre os efeitos desse tipo de ensino ao longo de vários anos de vida escolar.
- Forte concentração no Norte Global: Há pouca produção científica focada na realidade de países em desenvolvimento, onde a falta de recursos e infraestrutura muda completamente a dinâmica de uso da tecnologia.
- Limitações em pesquisas com crianças pequenas: Por conta das restrições legais para proteger os dados de menores de 13 anos, existem poucos testes práticos sobre como os alunos do ensino fundamental interagem com essas ferramentas de conversação.

E, a fundamentação teórica aponta para três caminhos que a educação com tecnologia deve seguir no futuro:

- A busca por algoritmos transparentes (xAI): Sistemas de avaliação baseados em inteligência artificial precisarão ser mais explicáveis, permitindo que professores e alunos entendam como a máquina chegou a determinada recomendação ou nota.
- Foco em tutores de método socrático: Consolidação de ferramentas como o Khanmigo, que fazem perguntas para instigar o pensamento e guiar o raciocínio em vez de apenas entregar respostas prontas.
- Mudança no formato das avaliações: Como os programas geram textos rápidos, as escolas precisarão adotar exames focados no processo de criação do aluno, defesas orais e avaliação de competências ativas.

5. Considerações Finais

A pesquisa evidencia que a integração de assistentes virtuais transforma

estruturalmente as metodologias de ensino escolares. As plataformas inteligentes processam dados estudantis para personalizar a instrução, adequando o conteúdo às necessidades cognitivas individuais. Essa tecnologia rompe com os modelos tradicionais de transmissão massiva, estabelecendo um ecossistema educacional pautado pela precisão e pelo respeito ao ritmo de cada estudante.

Dinâmicas de inteligência híbrida revelam-se indispensáveis para o sucesso da automação no ambiente acadêmico. A máquina assume a execução de cálculos estatísticos e diagnósticos precisos, enquanto o professor concentra sua atuação na mediação pedagógica e no acolhimento humano.

O trabalho colaborativo entre o educador e o algoritmo garante que as ferramentas digitais funcionem com intencionalidade e eficiência prática. Barreiras éticas e operacionais exigem protocolos rigorosos de governança digital nas instituições. A proteção da privacidade de informações sensíveis e a exigência por transparência algorítmica configuram princípios inegociáveis para uma implementação segura.

As escolas necessitam assegurar que as decisões computacionais sejam compreensíveis e livres de vieses, promovendo um espaço de aprendizagem altamente tecnológico, equitativo e totalmente protegido. Pesquisas futuras devem explorar o impacto prolongado dessas plataformas no desenvolvimento crítico dos jovens. O aprimoramento do sistema educacional demanda a formulação de políticas públicas focadas na infraestrutura tecnológica e na capacitação contínua do corpo docente. A evolução das inteligências interativas consolidará novas rotas de ensino, exigindo revisões constantes para manter a inovação alinhada à justiça social.

Referências

Akgun, S. & Greenhow, C. Artificial intelligence in education: Addressing ethical challenges in K-12 settings, **AI and Ethics**, p. 1-10, 2021

Barros, A.; Carvalho, I.; Laet, L.; Gallo, S; & Silva, T. Educação a distância e o uso da inteligência artificial, **Revista Ilustração**, v. 4, n. 4, p. 31-37, 2023.

Blay, B. & McClaskey, K. Personalization vs Differentiation vs Individualization, 2010.

Brusilovsky, P. & Millán, E. User models for adaptive hypermedia and adaptive educational systems. In: **The Adaptive Web: Methods and Strategies of Web Personalization**, Springer, Heidelberg, LNCS, vol. 4321, p. 3-53, 2007.

Bulut, O.; Beiting-Parrish, M. & Casabianca, J. M. The Rise of Artificial Intelligence in Educational Measurement: **Opportunities and Ethical Challenges**, 2024.

Corrêa, P. M. H. **A plataforma Khan Academy como auxílio ao ensino híbrido em Matemática:** um relato de experiência. Dissertação (Mestrado Profissional), Universidade Federal do Rio Grande, 2016.

Costa, D. Plataformas Adaptativas e o Ensino Personalizado, Must Universit, 2021.

Costa, J.; Moreira, R.; Nascimento, C. & Carvalho, M. Desigualdades sociais e o acesso à tecnologia de IA: um estudo sociocultural. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 10, n. 11, p. 7446-7463, 2024.

Costa, S., Pinto, R. & Gonçalves, G. **Graph-Based Personalized Recommendation in Intelligent Educational Platforms:** A Case Study in Engineering Education, Proceedings of the 21st International Conference on Web Information Systems and Technologies (WEBIST), 21. Porto. Proceedings. Portugal: SciTePress, 2025. p. 210-217. DOI: https://doi.org/10.5220/0013050000003844.

Costa Júnior, R. M.; Santos, P. A. & Silva, M. L. Formação docente e tecnologias emergentes: impactos na prática pedagógica. **Revista Brasileira de Educação**, v. 27, n. 3, p. 123-138, 2022.

Cukurova, M. **The Interplay of Learning, Analytics, and Artificial Intelligence in Education:** A Vision for Hybrid Intelligence, 2024.

Dietterich, T. G. Steps toward robust artificial intelligence. **AI Magazine**, v. 38, n. 3, p. 3-24, 2017.

Domingos, P. **O algoritmo mestre: como a busca pelo algoritmo de machine learning definitivo recriará nosso mundo.** Novatec Editora, 2017.

Elias, M.; Faversani, L.; Moreira, J.; Masiero, A. & Cunha, N. Inteligência artificial em saúde e implicações bioéticas: uma revisão sistemática. **Revista Bioética**, v. 31, 2023.

Fabrizzio, G.; Oliveira, L.; Costa, D.; Erdmann, A. & Santos, J. Assistente virtual: ferramenta para coprodução em saúde no enfrentamento à COVID-19. **Texto & Contexto - Enfermagem**, v. 32, 2023.

Ferenhof, H. A. & Fernandes, R. F. Desmistificando a revisão de literatura como base para redação científica: método SSF. **Revista ACB: Biblioteconomia em Santa Catarina**, v. 21, n. 3, 2016.

Ferreira, L. & Lima, R. Tecnologias de aprendizado adaptativo e o futuro da educação personalizada. **Revista Educação em Foco**, v. 25, n. 3, p. 45-63, 2023.

Freitas, C. A.; Pereira, L. G.; Nascimento, F. M.; Albuquerque, M. A. A. & Araujo, M. I. Impacto da inteligência artificial na avaliação acadêmica: transformando métodos tradicionais de avaliação no ensino superior. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 11, n. 1, p. 2736-2752, 2025. DOI: https://doi.org/10.29327/217519.11.1-2.

Führ, R. C. **Educação 4.0 nos impactos da quarta revolução industrial.** Editora Appris, 2022.

Gardner, H. **Inteligências múltiplas**: A teoria na prática. Porto Alegre: Penso Editora, 1995.

Gil, A. C. **Como elaborar projetos de pesquisa.** 5a ed., São Paulo: Atlas, 2010.

Gómez, A. I. P. **Educação na Era Digital:** a escola educativa. Porto Alegre: Penso, 2015.

Gonçalves, F. & Ferreira, L. A integração de tecnologias digitais na prática docente: desafios e possibilidades. **Revista Educação e Tecnologia**, v. 16, n. 2, p. 45-59, 2021.

Guimarães, U. A. **Plataformas adaptativas como ferramenta de apoio ao processo de aprendizagem de Física no ensino médio**, Formiga (MG): Editora MultiAtual, 2023.

Guimarães, U. A.; Vimercate, J. M. & Schizzi, J. A. C. Contribuições das plataformas adaptativas no ensino aprendizagem. **RECIMA21 - Revista Científica Multidisciplinar**, v. 3, n. 8, 2022..

Holmes, W.; Bialik, M. & Fink, E. **Artificial Intelligence in Education: Promises and Implications for Teaching and Learning**, OECD, 2019.

Horn, M. B. & Staker, H. **Blended**: usando a inovação disruptiva para aprimorar a educação, Porto Alegre: Penso, 2015.

Imohimi, E. O. Building Privacy and Preserving AI Models for Secure Student Data Management in Educational Technology Platforms. **Journal of Intelligent Learning Systems and Applications**, v. 17, n. 1, p. 45-58, 2025. DOI: https://doi.org/10.4236/jilsa.2025.171003.

Khan, S. **Um mundo, uma escola:** a educação reinventada. Rio de Janeiro: Intrínseca, 2013.

Kizilcec, R. F.; Bailenson, J. N. & Gomez, C. J. The instructor's face in video instruction: Evidence from two large-scale field studies. **Journal of Educational Psychology**, 109(6), 909–925, 2017.

Łodzikowski, K.; Foltz, P. W. & Behrens, J. T. **Generative AI and Its Educational Implications**, 2023.

Loureiro, B. C. O. O uso das tecnologias da informação e comunicação como recursos didáticos no ensino de Física. **Revista do Professor de Física**, 3(2), 93-102, 2019.

Luckin, R.; Holmes, W.; Griffiths, M. & Forcier, L. **Intelligence Unleashed:** An argument for AI in Education. Pearson Education, 2016.

Machado, R. et al. Uso da Khan Academy em escolas brasileiras: impactos na aprendizagem. **Revista Brasileira de Aprendizagem Aberta e a Distância**, 19(1), 180-197, 2020.

Manna, S. & Sett, N. **Need of AI in Modern Education**: in the Eyes of Explainable AI (xAI), 2024.

Marins, J.; Ferreira, K.; Ribeiro, R.; Galvão, R. & Mira, S. Os impactos da inserção de tecnologias baseadas em inteligência artificial na educação à distância. **Revista Ilustração**, v. 4, n. 5, p. 63-74, 2023.

Martinic, S. & Gregorio, M. D. **Promover a equidade social no sistema de educação escolar por meio do uso da Tecnologia da Informação:** o caso do Plan EIBAL no Uruguai. Portal Idea, 2019.

Meroto, M.; Guimarães, C. D.; Silva, C. K. da & Carvalho, F. M. da S. Revolucionando a educação: explorando o potencial da inteligência artificial para transformar métodos de ensino e aprendizado. **Revista Foco**, v. 17, n. 1, 2024.

Moran, J. M. **A educação que desejamos**: Novos desafios e como chegar lá. Vitória: Papirus, 2015.

Moreira, J. & Ribeiro, J. Letramento e competência informacional e as relações éticas na gestão da informação e do conhecimento no contexto da inteligência artificial. **Brazilian Journal of Information Science**, v. 17, 2023.

Narciso, R. & Santana, A. C. A. Metodologias científicas na educação: uma revisão crítica e proposta de novos caminhos. **Revista ARACÊ**, v. 6, n. 4, p. 19459-19475, 2025.

Nascimento, E. R. **Política Nacional de Educação Digital**: uma reflexão sobre a formação dos professores no contexto da Educação Básica e Superior no Brasil, São Paulo: Editora Digital Educação, p. 241-260, 2024.

Nóvoa, A. Os professores e a sua formação em tempos de pandemia. **Educação e Pesquisa**, v. 46, 2019.

Radu, A. Containerization of Machine Learning Algorithms for Intelligent Educational Platforms, In: **International Conference on Education, Research and Innovation,** 2025,

Ramos, C. A. S. **Ensino personalizado:** o humano, o computador e a função social da educação. Dissertação (Mestrado) – Pontifícia Universidade Católica de São Paulo, 2018.

Sallaah, M. H.; Kumar, A. A.; Akila, V.; Singh, K. R. & Sharma, P. **Deep Reinforcement Learning for Personalized AI Tutors in Intelligent Education Systems and Adaptive E-Learning Platforms.** In: 3rd International Conference on Cyber Resilience (ICCR), 3., 2025, Dubai. Proceedings. Piscataway: IEEE, 2025. p. 1-6. DOI: https://doi.org/10.1109/ICCR61234.2025.1012345.

Sampaio, R. & Mancini, M. Estudos de revisão sistemática: um guia para síntese criteriosa da evidência científica. **Revista Brasileira de Fisioterapia**, v. 11, n. 1, p. 83–89, 2007.

Santana, A. C. A. & Narciso, R. Pilares da pesquisa educacional: autores e metodologias científicas em destaque. **Revista ARACÊ,** v. 7, n. 1, p. 1577-1590, 2025.

Santos, L. C. & Oliveira, M. L. IA na educação: transformando o ensino e a aprendizagem. **Educação e Pesquisa**, v. 47, 2021.

Sena, W. N. Os impactos na educação do uso de plataformas adaptativas: o exemplo da Khan Academy. **Revista Educar Mais**, 6, 1029-1038, 2022.

Silva, A. P. & Costa, F. A. Desafios e oportunidades da integração de mídias digitais na educação: infraestrutura, acesso e formação de professores. **Revista Brasileira de Educação**, v. 29, n. 2, p. 95-112, 2024.

Sweller, J. Carga cognitiva durante a resolução de problemas: Efeitos na aprendizagem. **Ciência Cognitiva**, v. 12, n. 2, p. 257-285, 1988.

Teixeira, M. A. S. et al. Potencializando a educação: o impacto da inteligência artificial na aprendizagem, 2021.

Valente, J. A. **O computador na sociedade do conhecimento.** Campinas: UNICAMP/NIED, 1999.

Valente, J. A. A sala de aula invertida e a possibilidade do ensino personalizado: uma experiência com a graduação em midialogia. In: **Metodologias ativas para uma educação inovadora**, Porto Alegre: Penso, p. 26-44, 2018

Vosgerau, D. S. R. & Romanowski, J. P. Estudos de revisão: implicações conceituais e metodológicas. **Revista Diálogo Educacional**, v. 14, n. 41, p. 165-189, 2014.

Sobre o autor(a)

Maeve Espindola Pereira

Especialização em Educação Infantil Séries Inicias e Gestão Escolar pela Faculdade de Administração, Ciências, Educação e Letras (FACEL - 2007).

Graduação em Pedagogia pela Universidade do Sul de Santa Catarina (UNISUL - 2007).

Coordenadora da Universidade Aberta do Brasil desde 2021.

Lattes: http://lattes.cnpq.br/5689364545686980

CAPÍTULO 9

IA generativa como apoio à prática docente: uma revisãio sistemática

Thaise Cechinel Bozzelo Vassoler

1. Introdução

Os métodos tradicionais de ensino têm passado por mudanças e progressos após o surgimento das Tecnologias da Informação e Comunicação (TICs). O uso das novas tecnologias modifica a forma de compartilhamento de conhecimento entre professores e alunos, possibilitando um ensino-aprendizagem mais significativo em sala de aula. Conforme mencionou Libâneo (2013) a aprendizagem não deve ser apenas recepção de conteúdos e o ensino não somente transmissão de conhecimentos. O objetivo de ensinar é o desenvolvimento mental dos estudantes e isso se dá de maneira ativa e consciente.

Diante das novas tecnologias a inteligência artificial (IA) se destaca pois vem provocando uma revolução na maneira de aprender e ensinar na última década. Conforme apontam os estudos recentes, "a inteligência artificial está colidindo com novas ideias de ensino num momento crítico para a didática - a arte de escolher métodos e estratégias que ajudem os alunos a aprender" (Villegas & Delgado-Garcia, 2024).

Libâneo (2013) menciona que a educação está pronta para a transformação que a IA Generativa e seus recursos oferecem. Essa fusão entre Inteligência Artificial e educação gerou um crescimento significativo no número de publicações científicas nos últimos 6 anos, trazendo à tona tanto o potencial quanto os desafios dessa união. Fato é que a IA Generativa facilita e amplia o repertório de práticas de ensino uma vez que são capazes de transformar o ambiente de sala de aula em um cenário de protagonismo estudantil, mais dinâmico e interativo.

Nesse cenário, a IA Generativa surgiu como um marco para educação tanto quanto para uma infinidade de outras áreas. Desde o seu lançamento em novembro de 2022 o ChatGPT se tornou a aplicação de crescimento mais rápido na história da internet até aquele momento. Segundo a Reuters (2023), o ChatGPT- 3.5 atingiu 100 milhões de usuários em apenas dois meses. De acordo com Jauhiainen & Garagorry-Guerra (2024)

esse fato gerou discussões sobre a integração dessas tecnologias na sala de aula especialmente no que se refere a possibilidade de geração automática de conteúdos (Michel-Vilarreal, et al., 2023). De acordo com o que se apresenta, “a educação permanece como uma arena Central preparada para a transformação através da implementação da IA Generativa” (Jauhiainen & Garagorry Guerra 2024).

Um campo bastante fértil para IAG na educação é a geração de materiais didáticos, "as ferramentas tradicionais para a criação de materiais didáticos são mutuamente independentes e carecem de inteligência auto suficiente, resultando em baixa eficiência e adaptabilidade limitada" (Chein et al., 2023). Nesse contexto, sistemas de LLMs como o ChatGPT - 4 conseguem gerar abordagens que superam as anteriores gerando planos de aula, apresentações, atividades personalizadas, gerar vídeos e converter formatos. A literatura já demonstra que IA Generativa é capaz de transformar conteúdos estáticos em vídeos e pesquisas recentes demonstram que é possível converter mais de 50 mil transcrições de vídeos em notas de estudos resumos estruturados e materiais de avaliação.

A pesquisa feita por Zabala ID, et al. (2025) demonstra o potencial da IA Generativa para transformar conteúdos educacionais em materiais de aprendizagem realmente interativos uma vez que pode criar textos, códigos e imagens de forma independente e contextualmente relevante.

Desta forma, este trabalho buscou consolidar-se na revisão sistemática para analisar publicações recentes sobre o tema buscando compreender como IA Generativa pode atuar como ferramenta na geração de conteúdos educacionais sem substituir o pensamento crítico e o trabalho intelectual autônomo dos Estudantes. Estudando as publicações selecionadas na revisão buscamos responder Os questionamentos norteadores da pesquisa:

a. Como a IA generativa está sendo usada para geração de conteúdos educacionais?
b. Quais são os benefícios e resultados positivos?
c. Quais são os desafios, limitações e questões éticas?
d. Quais são as recomendações e boas práticas?
e. Quais são as lacunas de pesquisa e oportunidades futuras?

Assim, o presente trabalho tem a intenção de reunir e analisar documentos recentes observando a aplicação da IA Generativa na prática docente, servindo de base para futuras práticas educacionais e aumentando a familiaridade com o assunto, colaborando desta forma, com a formação dos profissionais da área.

2. Referencial Teórico

Este trabalho se apoia em três pilares fundamentais: Inovação na Educação, Inteligência Artificial na Educação e Geração de Conteúdos Educacionais por Inteligência Artificial. Começamos explorando e explicando cada um deles para, depois, utilizá-las como ferramentas para compreender e responder os questionamentos que norteiam esta pesquisa.

2.1 Inovação na educação

A sociedade de forma geral, vem sofrendo uma nova revolução digital. Essa revolução atinge todas as áreas sociais com destaque para a área educacional, isso exige das instituições de ensino um acompanhamento desse progresso de forma a buscar também a Inovação Educacional.

A personalização da aprendizagem, a eficiência e a dinamicidade das interações de sala de aula estão entre os maiores desafios educacionais vividos na atualidade(Fortuna et al., 2025). Diante do atual cenário: escolas com salas de aula numerosas e tempo de aula limitado, a educação carece, segundo Rangana KS e Dias G.(2024,) de soluções inovadoras que complementem os métodos didáticos atuais e proporcionam experiências educativas personalizadas aos estudantes.

A compreensão do que significa e se constitui essa inovação no contexto Educacional deve diferenciar o que são mudanças (que vem para aperfeiçoar) do que são transformações radicais (que quebram o padrão existente). Em sua teoria da Inovação disruptiva, Christensen define que "uma inovação disruptiva traz ao mercado um produto ou serviço que não é tão bom quanto as melhores ofertas tradicionais, mas é mais barato e mais fácil de usar". (Christensen, Horn & Staker, 2013). Na Ótica Educacional, essa teoria sugere que "a aprendizagem online é uma tecnologia disruptiva que está fazendo colégios e universidades reconsiderarem seus modelos de ensino (Christensen,2013).

A utilização de ferramentas de IA generativa como o ChatGPT exemplifica essa nova fronteira entre mudança e ruptura. O uso dessas plataformas na educação "demonstra o seu potencial para aprimorar as experiências educacionais por meio de conversas interativas e metodologias inovadoras" (Shoul, T.A.I. et. al). Entretanto as novas tecnologias não excluem o papel humano mas sim incentivam a mudança de postura.

Para que a inovação e o design instrucional não se abatam perante os avanços tecnológicos Conklin et al. 2024 considera importante incluir no cotidiano escolar, ferramentas inovadoras, bem como incentivar a abordagens didáticas colaborativas. Dessa forma a geração de conteúdos ocorrerá de forma alinhada aos objetivos

educacionais e éticos. No campo da geração de conteúdos educacionais, a IA Generativa "trouxe inovações proeminentes na pedagogia" (Ofosu, A. 2025) onde os materiais didáticos estáticos transformam-se em recursos interativos e adaptáveis. A tecnologia atua de forma colaborativa com o professor na criação de materiais, otimizando o tempo do professor e permitindo liberdade para mediação do conhecimento.

Entretanto, alguns autores apresentam críticas a essa inovação. Sidorkin (2021) diz que "a educação é diferente de outras áreas por sua natureza relacional" ele sugere reestruturar uma noção de inovação educacional focando nessa perspectiva. Destaca ainda que a educação não é como um produto comercial, ela envolve relações humanas complexas que não podem ser simplesmente "interrompidas por novas tecnologias"(Rangana,K.S).

Diante dos Desafios sobre os métodos ideais para a área pedagógica, a IA Generativa surge como um dos maiores impulsionadores dessa reestruturação.

> A rápida integração da Inteligência Artificial na educação oferece oportunidades transformadoras para aprimorar o ensino e a aprendizagem. Entre essas inovações, os modelos de linguagem em grande escala (LLM s), como o ChatGPT, possuem um imenso potencial para o design instrucional e a aprendizagem personalizada". (AYANWALE, et al. 2025, p.4)

Suyo-Vega et al (2024), reforça a ideia de que a tecnologia, por si só, não tem o poder de transformar a educação e a maneira de ensinar, em sua revisão sistemática, os autores evidenciam através de um estudo sobre práticas pedagógicas, que a Inovação abrange novas formas de organizar o ensino e a avaliação, fatores que a tecnologia isoladamente não poderia resolver.

Villenas-José e Delgado-Garcia (2024)Enfatizam que o encontro entre a IA a educação "não ocorre porque a Inovação está na moda, mas por que os educadores enfrentam problemas reais a busca por caminhos personalizados e a necessidade de salas de aula verdadeiramente inclusivas ".

2.2. Inteligência artificial na educação

A alta velocidade com que a Inteligência artificial se integra na educação traz consigo oportunidades inovadoras para mudar significativamente os processos de ensino e aprendizagem. Os LLMs como o ChatGPT, possuem grande capacidade para o design instrucional, eficiência administrativa e aprendizagem personalizada(Ayanwale et al., 2025).

A inteligência artificial já demonstrou ser capaz de revolucionar abordagens pedagógicas tradicionais, maneiras de ensinar mais condizentes com as necessidades individuais dos alunos(Fortuna et al., 2025).Essa inovação tecnológica é um marco no campo educacional que pode se comparar ao surgimento de outras transformações disruptivas que já redefiniram os rumos da educação em outros tempos.

A implementação da IA na sala de aula avança a passos largos, sua abrangência vai desde o assessoramento personalizado até a criação automática de conteúdos. Pesquisas recentes indicam que a IA melhora a ergonomia cognitiva e aumenta o engajamento dos alunos uma vez que funciona como interlocutor, provedor de conteúdo, assistente de ensino e avaliador (Jauhiainen & Garagorry Guerra, 2024). Esses resultados indicam que a IA é mais do que uma ferramenta que complementa o ensino, ela é, cada vez mais, um agente transformador da experiência educacional.

Apesar de um horizonte promissor, o uso da IA na educação enfrenta desafios críticos e questões éticas sérias que exigem atenção. Esses desafios incluem a instabilidade da qualidade do conteúdo gerado, privacidade de dados, viés algoritmico, questões de integridade acadêmica e falta de transparência nos processos de tomada de decisão(García-López et al., 2024). Outra questão, considerada uma lacuna crítica entre o potencial tecnológico e a implementação prática é a falta de adesão dos professores as ferramentas, aproximadamente 75% dos educadores ainda não utilizam a IA(Santos Júnior et al., 2025).

2.3. IA generativa na elaboração de conteúdos educacionais

Muitos são os desafios do trabalho docente, porém a criação de materiais didáticos literalmente é um dos mais exigentes. A criação de um curso completo pode levar de 6 a 9 meses (Allen & Seaman, 2008) e envolve investimento de mais de 120 horas de trabalho (Kim & Bank, 2008).

A partir da criação do ChatGPT em novembro de 2022, esse cenário começou a mudar significativamente. De acordo com Garcia-Lopez et al (2025) diferente da IA tradicional, que apenas resolve problemas sem gerar novas informações, a IA Generativa é capaz de "gerar conteúdos inéditos e respostas imediatas devido ao seu processamento de informações”.

A IA Generativa se diferencia das tecnologias educacionais anteriores pela sua originalidade de criação de conteúdos e por não apenas reorganizar os materiais já existentes. Chein et al (2023) Classifica a criação de materiais didáticos em:

a. Sistema de Combinação (agrupam materiais pré-existentes);
b. Sistemas de Conversão de Formato (transformam conteúdos de um formato para outro);

c. Sistemas Generativos (modelos de linguagem de grande escala como o ChatGPT podem gerar textos automaticamente, imagens e vídeos).

Essa classificação evidencia uma transição de fase entre a inteligência artificial e as antigas abordagens. Conklin et al(2024) em um estudo sobre criação de cursos investigou a criação de um curso de pós-graduação totalmente online e assíncrono que usou o modelo de Backward Design. O curso de 14 semanas, incluindo geração de código HTML e CSS foi criado em um tempo significativamente reduzido.

Na área de design instrucional os LLMs mostram-se "úteis em todos os níveis, especialmente na estruturação de conteúdos acadêmicos como ementas, planos de aula, atividades e até caminhos de aprendizagem personalizados". (Ghimire, V. et al, 2025). No mesmo artigo, destaca-se que Sridhar et al. 2024 destacou que o ChatGPT-4 "pode redigir objetivos de aprendizagem segundo a taxonomia de Bloom, permitindo que os instrutores criem ementas com 50% menos tempo".

Chen S. et al (2023) realizou um trabalho completo sobre geração de materiais chamado TMGS (Generative Al Based Teaching Material System) que abrange três módulos: geração de materiais pré-aula (plano de aula, apresentações e vídeos), materiais para uso em sala (planos de atividades) e materiais pós aula (tarefas personalizadas). Quando testado com GPT- 4 em uma aula de matemática primária o sistema demonstrou "excelente abrangência e adaptabilidade"(CHEN S. et al.2023)

No que se refere a transformação de conteúdo existente um artigo de Zabala I.D. et. al (2025) apresenta uma pesquisa sobre a conversão de

> [...] mais de 50.000 transcrições de vídeos educativos em materiais de aprendizagem abrangentes por meio de IA.O sistema é capaz de converter transcrições brutas em documentos acadêmicos estruturados incluindo notas de estudo desenvolvido, resumos concisos de conceitos chave e resumos otimizados, além de gerar materiais para avaliação automaticamente (Zabala et al., 2025, p.1).

Após testes com quatro LLMs (Lhama 3.370 B, GPT-40, GPT-40 Mini e Gemini Flash 2.0) o Gemini Flash 2.0 entregou desempenho superior na geração de materiais pedagogicamente sólidos. Liu, L. et al. (2025) propõem um framework para avaliações, ele combina algoritmos de clustering com o ChatGPT para gerar questões adaptadas a cada perfil de aluno.

Os autores destacam que *"ao gerar automaticamente questões de testes adaptadas ao nível de conhecimento e as preferências de aprendizagem de cada aluno, a IA Generativa reduz a carga de trabalho dos educadores e facilita uma implementação mais escalável e eficiente de estratégias de aprendizagem personalizadas".*

3. Metodologia

Com o objetivo de compreender de que maneira a Inteligência Artificial Generativa (IAG) vem sendo usada como ferramenta para a Prática docente, bem como responder às questões de pesquisa levantadas, tomou-se base na revisão sistemática de literatura (RSL) e da análise bibliométrica. A RSL tem por finalidade pesquisar a literatura sobre um tema específico, disponibilizando um resumo das evidências encontradas com relação a um assunto específico, organizando e explicitando de forma sistemática o modo como foram feitas as buscas, análise e sínteses das publicações recuperadas (Sampaio & ManciniI, 2007).

Esta revisão sistemática foi realizada no mês de março de 2026 e para a sua execução foi adotado o método *Systematic Search Flow* (SSF) desenvolvido por Ferenhof e Fernandes (2016), a qual se utiliza de buscas em bases de dados para permitir a replicação das pesquisas com mais facilidade, evitando possíveis vieses de pesquisadores na escolha de artigos através de métodos exploratórios, isso ocorre em outros métodos de revisão de literatura como a revisão narrativa. O SSF é um método não aleatório ou exploratório, pois segue um procedimento metodológico rigoroso que garante repetibilidade da pesquisa, minimizando tendências de pesquisadores que possam ocorrer derivadas da escolha de documentos aleatórios (Ferenhof & Fernandes, 2016).

A metodologia SSF é composta por quatro fases. A primeira fase visa à elaboração do protocolo de pesquisa. Esta fase é composta por cinco atividades, compreendendo:

1. definição da estratégia de busca;
2. consultas nas bases de dados;
3. organização do portfólio;
4. definição dos critérios de seleção dos documentos; e
5. composição do portfólio bibliográfico.

Na fase dois (atividade seis), o pesquisador parte para a consolidação dos dados apurados na primeira fase, buscando esmiuçar os resultados obtidos, analisando as publicações bibliométricamente. A terceira fase (atividade sete), destina-se a sintetizar e organizar os dados e conhecimentos mais relevantes obtidos com a análise dos documentos. A quarta e última fase, se refere à consolidação dos dados, encerrando-se com a atividade 8 que é a redação do trabalho (Ferenhof & Fernandes, 2016). Destaca-se que este trabalho seguiu as 4 fases e 8 atividades do método SSF, resultando nos resultados apresentados e discutidos a seguir.

Quadro 1 - Protocolo de pesquisa

Atividade 1 Estratégia de Busca	A estratégia de busca elaborada utilizou os termos em inglês "generative AI", "generative artificial intelligence" "generative model", "large language model","LLM", ty"ChatGPT", "GPT-4", "educational content", "learning material","course content" "educational resource", "teaching material", "content generation" Como critério de inclusão e exclusão: 1. Selecionar artigos que contivessem, no título, abstract, nas palavras-chave ou no corpo do texto, os termos desta pesquisa. 2. Artigos com fulltext disponíveis por meio do acesso CAPES, Download pelo Google®, Google Scholar®, Microsoft Academic Search® ou enviados diretamente pelos autores. 3. Língua: inglês, espanhol e português
Atividade 2 Consulta em bases de dados	As consultas foram realizadas no mês de março de 2026. Para garantir a abrangência e a relevância científica dos estudos recuperados, foram selecionadas cinco bases de dados acadêmicas: Scopus, Science Direct, IEEE Xplore, Scholar Google (Google Acadêmico) e Periódicos CAPES. As strings de busca foram adaptadas para a sintaxe específica de cada plataforma, utilizando operadores booleanos (AND e OR) com foco em termos em inglês devido à maior concentração de publicações sobre o tema. Foram aplicados filtros de corte temporal (2023–2026), tipo de documento (artigos científicos e revisados por pares) e idiomas (inglês, espanhol e português). A busca inicial resultou em um total de **59 registros identificados,** distribuídos conforme detalhado a seguir: • **Science Direct :** ("generative AI" OR "generative artificial intelligence" OR "generative model" OR "large language model" OR "LLM" OR "ChatGPT" OR "GPT-4" OR "Claude" OR "Gemini" OR "Bard" OR "Copilot") AND ("educational content" OR "learning material" OR "course content" OR "educational resource" OR "teaching material" OR "instructional design" OR "content creation" OR "content generation" OR "e-learning" OR "digital learning" OR "online education") Registros encontrados: 21 • **Science Direct** : *(Busca avançada com os mesmos descritores no título ou texto)* Registros encontrados: 17 • **Scopus**: TITLE-ABS-KEY *(mesmos termos combinados)* Registros encontrados: 14 • **IEEE Xplore**: *(Busca em metadados com descritores equivalentes)* Registros encontrados: 5 • **Periódicos CAPES**: *(Busca por assunto com descritores equivalentes)* Registros encontrados: 2

continua

continuação

Atividade 3 Organização das bibliografias	Para ajudar no planejamento, na execução e na elaboração do relatório da revisão foi usada a plataforma parsif.al juntamente com a IA Manus. Para a triagem e elegibilidade dos documentos, foram estabelecidos Critérios de Inclusão (CI) e Critérios de Exclusão (CE) bem definidos, aplicados de forma sistemática nas fases de avaliação de título/resumo e leitura integral: • Critérios de Inclusão (CI): ◦ Artigos científicos originais publicados em periódicos revisados por pares entre 2023 e 2026. ◦ Trabalhos que abordem diretamente o uso da Inteligência Artificial Generativa (IAG) como ferramenta de apoio à prática docente, design instrucional ou desenvolvimento de materiais didáticos. ◦ Estudos disponíveis em texto completo para acesso acadêmico. • Critérios de Exclusão (CE): ◦ CE1 (Temporal): Estudos publicados fora do intervalo de 2023 a 2026 (ou dados históricos sem relação direta com a IAG moderna pós-ChatGPT). ◦ CE2 (Temático/Escopo): Pesquisas sobre Inteligência Artificial preditiva tradicional ou algoritmos de machine learning puro que não apresentem aplicações voltadas à geração de conteúdos educacionais ou à prática docente. ◦ CE3 (Tipo de Documento): Documentos não revisados por pares, capítulos de livros, revisões de livros, editoriais, notas de rodapé, relatórios técnicos cinzentos ou resumos expandidos sem disponibilização de texto completo. ◦ CE4 (Acesso): Artigos cujo texto integral não pôde ser recuperado gratuitamente através dos portais de periódicos assinados (CAPES), repositórios públicos ou via contato direto com os autores. ◦ CE5 (Duplicidade): Registros idênticos recuperados em mais de uma base de dados (mantendo-se apenas uma ocorrência para fins de triagem)
Atividade 4 Seleção padronizada dos artigos	Essa fase envolveu a leitura dos títulos, resumos e palavras-chave de cada artigo individualmente, tendo sido selecionados os que tivessem maior aderência ao tema da pesquisa. Resultaram desta análise 59 artigos, os quais obteve-se acesso gratuito aos textos.
Atividade 5 Composição do portfólio	Nesta atividade, os artigos foram lidos integralmente de forma a realizar a filtragem, evitando desalinhamento ao tema e objetivo da pesquisa. Desta análise restaram 21 artigos no portfólio final.

Fonte: elaborado pela autora (2026)

As atividades realizadas resultam no portfólio final e o número de documentos recuperados em cada etapa pode ser demonstrado no Fluxograma PRISMA da Figura 1.

Figura 1 - Atividades e Número de documentos recuperados

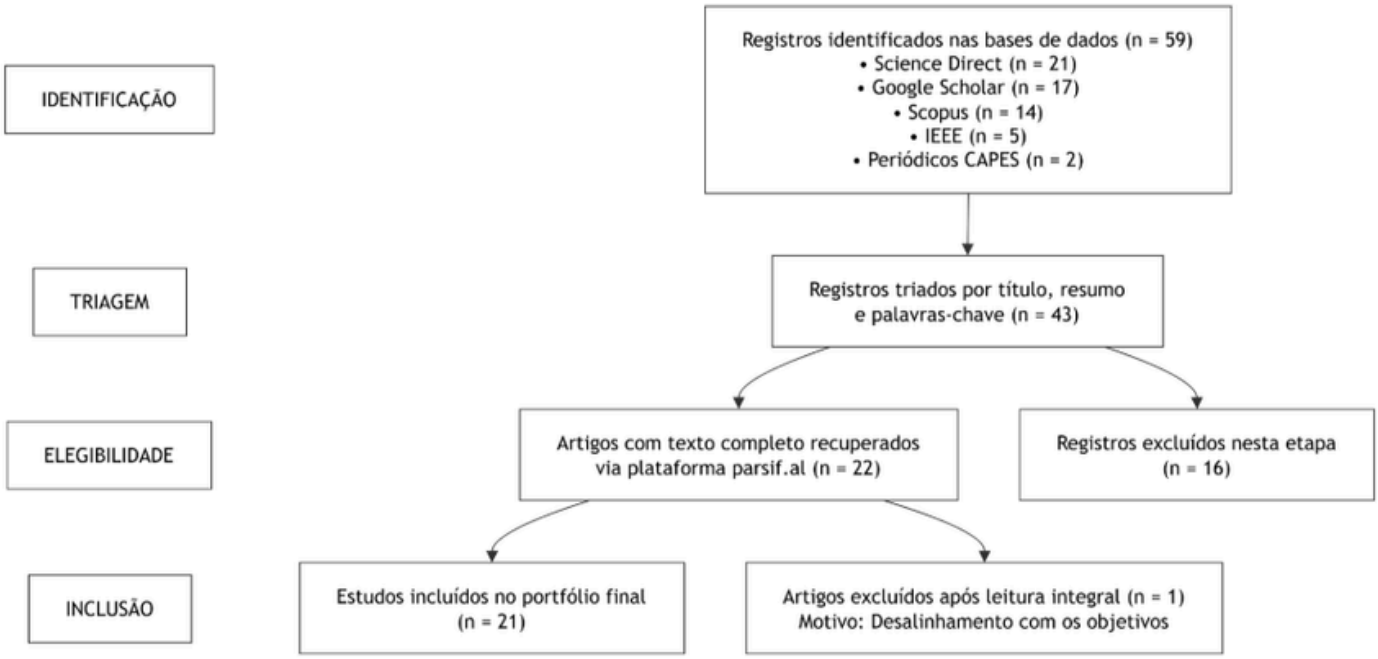

Fonte: elaborado pela autora (2026)

O processo de seleção seguiu as diretrizes metodológicas do Systematic Search Flow (SSF) e a representação estrutural do modelo PRISMA. Inicialmente foram identificados 59 registros nas bases de dados selecionadas. Após a etapa de triagem de duplicatas e período, 16 artigos foram removidos, restando 43 registros para análise de títulos, resumos e palavras-chave.

Na etapa de triagem por leitura de título e resumo, 16 artigos foram excluídos por não estarem diretamente alinhados com o tema de pesquisa. Além disso, 5 documentos não puderam ser totalmente recuperados por limitações de acesso ao texto integral. Isso resultou em 22 artigos selecionados para leitura integral de elegibilidade.

Após a leitura completa, 1 artigo foi excluído devido ao desalinhamento específico com os objetivos de apoio à prática docente. Assim o portfólio bibliográfico final foi composto por exatamente 21 artigos estudados sistematicamente.

A fase 2 (atividade 6) compreende a etapa de análise dos documentos selecionados para compor o portfólio bibliográfico final. Para auxiliar nesta etapa, os dados das publicações foram exportados do software de gerenciamento bibliográfico para o formato de planilha, resultando, desta forma, no que Ferenhof e Fernandes (2016) chamaram de Matriz do Conhecimento, planilha que também auxilia na fase de síntese (atividade 7).

Utilizando a matriz do conhecimento, e também a Inteligência Artificial Manus (2024) foi possível extrair os principais dados que se buscava com a realização da revisão sistemática. Foram recuperadas publicações do período compreendido entre os anos de 2023 a 2026, destacando-se o ano de 2024 que apresenta 10 publicações, correspondendo a mais de 47% dos trabalhos encontrados.

A análise bibliométrica dos 21 artigos sobre Inteligência Artificial Generativa na educação revela:

- Crescimento exponencial: O tema está em expansão acelerada, com 76,2% das publicações concentradas em 2024-2025, representando um aumento de aproximadamente 8 vezes em relação a 2023.
- Interesse global: Pesquisadores de 12 países diferentes (incluindo Espanha, China, Brasil, México, Itália, Austrália, Reino Unido, Nigéria, Singapura, Palestina, Hong Kong, Índia, Coreia do Sul, USA e Malásia) estão investigando o tema.
- Destaque de instituições Chinesas (23,8%) e Espanholas (19%), a China consolidou-se como o principal polo de pesquisa em IA na educação, superando a Espanha e destacando-se como um dos principais pólos de pesquisa em IA na educação.
- Diversidade de periódicos: As pesquisas estão distribuídas em diversos periódicos de qualidade (ScienceDirect, IEEE, Frontiers, etc.), indicando relevância multidisciplinar e reconhecimento acadêmico.
- Colaborações internacionais: Há tendência crescente de colaborações entre pesquisadores de diferentes países, refletindo a natureza global dos desafios e oportunidades da IA na educação
- Temas emergentes: Geração de conteúdos educacionais (28,6%), personalização de aprendizagem (23,8%) e letramento em IA (19%) são temas centrais nas pesquisas recentes.
- Foco em educação superior: Embora haja artigos sobre educação primária e secundária, a maioria das pesquisas concentra-se em contextos de educação superior e formação de professores.
- Equilíbrio entre oportunidades e desafios: Aproximadamente 14,3% dos artigos focam em questões éticas e desafios, demonstrando preocupação equilibrada com benefícios e riscos da tecnologia.

O portfólio final contendo todos os artigos selecionados e a qual categoria ficaram vinculados pode ser visualizado no quadro 2.

Quadro 2 - Portfólio Final de Artigos sobre IA Generativa na Educação

Autores	Ano	Título	Temática
Chen, S.; Liu, Q. & He, B.	2023	A Generative AI-based Teaching Material System Using a Human-In-The-Loop Model	Sistema de geração de materiais didáticos com IA; Colaboração humano-máquina; Modelo Human-In-The-Loop
Okagbue, E. F.; Ezeachikulo, U. P.; Akintunde, T. Y.; Tsakuwa, M. B.; Ilokanulo, S. N.; Obiasoanya, K. M.; Ilodibe, C. E. & Ouattara, C. A. T.	2023	A comprehensive overview of artificial intelligence and machine learning in education pedagogy: 21 Years (2000-2021) of research indexed in the scopus database	Revisão bibliométrica de IA e aprendizagem de máquina em educação; Análise de tendências em pesquisa educacional
Jauhiainen, J. S. & Garagorry Guerra, A	2024	Generative AI and education: dynamic personalization of pupils' school learning material with ChatGPT	Personalização dinâmica de conteúdo educacional; ChatGPT na educação; Ergonomia cognitiva
García-López, I. M.; González González, C. S.; Ramírez-Montoya, M. S. & Molina-Espinosa, J. M.	2024	Challenges of implementing ChatGPT on education: Systematic literature review	Desafios da implementação de ChatGPT; Questões éticas e de privacidade; Integridade acadêmica
Santos Júnior, D. B.; Brinkhues, R. A.; Rosa, J. C. O.; Frantz, B. B. & Gonçalves, B. B.	2025	Digital transformation in content creation: An analysis of ChatGPT user profiles	Transformação digital na educação; Perfis de usuários de ChatGPT; Adoção de IA em educação
Fortuna, A.; Prasetya F.; Samala, A. D.; Rawas, S.; Criollo-C, S.; Kaya D.; Raihan, M.; Andriani, W; Safitri, D. & Nabawi, R. A.	2025	Artificial intelligence in personalized learning: A global systematic review of current advancements and shaping future opportunities	Personalização de aprendizagem com IA; Revisão sistemática global; Oportunidades futuras

continua

continuação

Pei, B.; Lu, J.; Park, S.; et al.	2026	Enhancing AI literacy for educators: Where to start and to what end?	Letramento em IA para educadores; Competências docentes; Formação de professores
Yaw Ofosu - Asare	2025	Guiding the future: developing an ethical framework for generative AI use in education	Framework ético para IA generativa; Questões éticas; Governança de IA
Iris Heung Yue Yim.	2024	A critical review of teaching and learning artificial intelligence (AI) literacy: Developing an intelligence-based AI literacy framework for primary school education	Letramento em IA para educação primária; Framework de competências; Ensino de IA
Zabala, I. D.; Ribalta, C. T. & Mataix, J. B.	2025	Enhancing Educational Content Through AI-Assisted Transformation of Video Transcriptions	Transformação de transcrições de vídeos; Geração automática de conteúdo; Escalabilidade
Ayanwale, M. A.; Adelana, O. P.; Bamiro, N. B.; Olatunbosun, S. O.; Idowu, K. O. & Adewale, K. A.	2025	Large language models and GenAI in education: Insights from Nigerian in-service teachers through a hybrid ANN-PLS-SEM approach	LLMs em educação; Perspectivas de professores; Contextos em desenvolvimento
Tamara Al Shloul , Tehseen Mazhar Yazeed Yasin Ghadi, Tariq Shahzad, Qamar Abbas , Fatma Mallek, Muhammad Iqbal , Habib Hamam	2024	Role of activity-based learning and ChatGPT on students' performance in education	Aprendizagem baseada em atividades; ChatGPT e desempenho; Impacto em resultados
LIU, L.; HAN, M.; POURIYEH, S.; ZHOU, Y.; DEHBOZORGI, N.	2025	Beyond One-Size-Fits-All: An AI-Driven Approach for Personalized Quiz Generation	Geração personalizada de questões; Adaptação ao aluno; Avaliação automática

continua

continuação

Ghimire, V.; Lama J. S.; Dhungana, B.; Sadat, N. & Caporusso, N.	2024	Evaluating Output Novelty in Iterative Prompting in Educational Content Generation	Engenharia de prompts; Qualidade de conteúdo gerado; Novidade e originalidade
Rangana, K. S. & Dias, G.	2024	Educational Material Development with Active Learning for Secondary School Subjects	Desenvolvimento de materiais didáticos; Aprendizagem ativa; Educação secundária
Kovari, A.	2024	A systematic review of AI-powered collaborative learning in higher education	Aprendizagem colaborativa com IA; Educação superior; Colaboração entre alunos
Mena Guacas, A. F. & Pelicano Piris, N.	2024	Mapping artificial-intelligence-driven innovation in higher education	Inovação impulsionada por IA; Mapeamento de tendências; Educação superior
Cheung, S. & Hu W.	2024	Unleashing human potential: An artificial intelligence comtency framework for educators	Framework de competências em IA; Desenvolvimento profissional; Potencial humano
Samala, A. D.; Rawas, S.; Zainuddin, Z.; Howard, N.-J. & Shilina, S.	2024	The role of non-fungible tokens in education: A comprehensive review and future perspectives	NFTs em educação; Tecnologias emergentes; Perspectivas futuras
Long, D. Y.; Wang, S.; Rashid, S. M. & Lu, X. T.	2026	Artificial intelligence in higher education: a systematic review of its impact on student engagement and the mediating role of teaching methods	IA em educação superior; Engajamento de alunos; Mediação de métodos de ensino; Modelo PMAISE
Wang, S.; Xu, T.; Li, H.; Zhang, C.; Liang, J.; Tang, J.; Yu, P. S. & Wen, Q.	2026	Large Language Models for Education: A survey and outlook	Survey de LLMs em educação; Assistência a alunos e professores; Aprendizagem adaptativa; Ferramentas comerciais

Fonte: elaborado pela autora (2026)

A partir da análise dos artigos foi possível perceber algumas tendências no uso da Inteligência Artificial Generativa como ferramenta de apoio à prática docente e aplicações voltadas para o ensino.

- **Geração de conteúdos educacionais**

O processo de ensino aprendizagem é diretamente influenciado pelos materiais educacionais utilizados pelo professor pois eles são elementos fundamentais para melhorar o desempenho deste processo. Porém as ferramentas utilizadas tradicionalmente para criar materiais apresentam significativas limitações sendo mutuamente independentes e carecendo de inteligência suficiente o que resulta em baixa eficiência e adaptabilidade limitada (Chen, Liu & He, 2023).

Emergindo como uma solução inovadora e promissora, a inteligência artificial generativa, permite a criação automática de materiais didáticos estruturados através de sistemas como o TMGS (Teaching Material Generation System) que integra módulos de geração para diferentes estágios do processo educacional: pré-aula aula e pós aula.

Outro avanço significativo na educação é a capacidade de transformar grandes volumes de conteúdo em materiais de aprendizagem. Zabala, Ribalta & Mataix (2025) demonstraram que é possível converter transcrições de vídeos educacionais em documentos acadêmicos bem estruturados e concisos. Além disso, Wang et al.(2026) destaca que as LLMs (Modelos de Linguagem Grande) possuem capacidade para geração de conteúdos diversos, desde notas de aula até atividades interativas e avaliações de aprendizagem, minimizando o tempo e esforço para criação de novos conteúdos, preservando a qualidade pedagógica das aulas.

- **Personalização de aprendizagem**

Jauhiainen; Garagorry & Guerra (2024) demonstram que o ChatGPT permite a personalização dinâmica de materiais em tempo real, adaptando o conteúdo às necessidades, preferências e ritmo de aprendizagem de cada aluno, melhorando sua ergonomia cognitiva e o engajamento. A personalização da aprendizagem já foi descrita como um dos maiores desafios educacionais contemporâneos. Hoje a Inteligência artificial se apresenta com algumas soluções inovadoras e muito bem vistas pelos educadores.

Complementarmente, Fortuna et al(2025) indicam que a IA generativa consegue analisar dados de comportamento dos educandos para criar caminhos de aprendizagem personalizados que se adaptam às lacunas de conhecimento, resultando em melhora nos resultados de aprendizagem. A abordagem de personalização vai além de adaptações de conteúdo. Liu et al. (2025) propõem um sistema de geração de *quizzes*

que usa algoritmos de clustering e ChatGPT para criar questões adaptadas ao nível e progresso de cada aluno, superando as limitações das abordagens padronizadas. Quando integrada com aprendizagem baseada em atividades, a IA pode fornecer feedback e orientação personalizada aos alunos, ajudando a superar desafios específicos e alcançar melhor desempenho acadêmico (Tamara Al et al., 2024).

- **Letramento em IA para educadores.**

Para a implementação efetiva e responsável da tecnologia em ambientes educacionais é essencial desenvolver o letramento em Inteligência Artificial entre educadores. Pei et al.(2026) destaca que este letramento deve ser abrangente e transcender o conhecimento técnico, incluindo as capacidades, limitações, implicações éticas, e aplicações pedagógicas. Este letramento é fundamental para uso eficaz e responsável em ambientes educacionais. Complementando, Yim I (2024) propõem um framework de letramento em IA para educação primária que inclui fundamentos em IA, ética e habilidades práticas que devem preparar os alunos para um futuro tecnológico.

A formação dos educadores em Inteligência Artificial, deve ser abrangente e contínua, incorporando, além de habilidades técnicas, competências pedagógicas e éticas. Samala et al (2024) destacam que um Framework de competências em IA para educadores deve abordar habilidades técnicas, aplicações pedagógicas, considerações éticas e desenvolvimento profissional contínuo, capacitando os educadores a aproveitar a IA efetivamente enquanto mantém a educação centrada no ser humano.

Wang et al (2026) reforçam que os envolvidos no processo educacional requerem treinamento e suporte adequados para usar os Modelos de Linguagem Grande em contextos educacionais, o que inclui compreensão das capacidades do modelo, reconhecimento de limitações e desenvolvimento de habilidades de avaliação crítica para conteúdo gerado por IA.

- **Colaboração Humano-Máquina e o Papel do Docente na Avaliação Automática**

O Estudo comparativo dos artigos selecionados revela uma importante tensão teórica e prática no que se refere aos limites da automação na avaliação e ao papel do professor como supervisor ético. Por um lado, pesquisas voltadas a sistemas de avaliação automática, como a proposta por Liu et al.(2025), demonstram que a integração de algoritmos de agrupamento (*clustering*) ao ChatGPT permite a geração de quizzes em escala e questões personalizadas que se adaptam a cada estudante e reduzem muito a carga operacional docente. Porém, os autores também reconhecem

que essa personalização só garante equidade adequada de dificuldade quando mediada por prompts desenhados e validados por especialistas humanos.

Essa dependência da agência humana é o cerne do modelo Human-in-The-Loop (colaboração humano-máquina) defendido por Chen, Liu e He (2023). Desta forma, embora os sistemas generativos possuam capacidade de processamento para criar materiais de pré, durante e pós-aula, a inteligência computacional é tratada meramente como um assistente, cabendo ao professor o papel insubstituível de editar, revisar e realizar ajustes finos para assegurar a precisão e a coerência pedagógica dos conteúdos gerados.

Essa importância de controle pedagógico aumenta quando se discute o impacto da IA no desenvolvimento cognitivo e no engajamento dos alunos. De acordo com o modelo PMAISE (Pedagogical Mediation of AI for Student Engagement) proposto por Long et al. (2026), o uso sem planejamento e puramente automatizado de ferramentas de IA generativa pode induzir ao “descolamento pedagógico” e a redução do esforço cognitivo dos alunos, que preferem a conveniência ao pensamento crítico.

Os autores destacam que a intervenção docente precisa ser como um filtro regulatório, onde as ferramentas de IA atuam como parceiras cognitivas e não como substitutas do esforço intelectual. De maneira análoga, Kovari (2025) e Wang et al. (2026) alertam que, embora essa resposta imediata da IA pareçam benéficas para a aprendizagem, os sistemas frequentemente operam em estruturas de “caixa-preta”, propensas a vieses algorítmicos e em casos de avaliação textual, à inflação de notas e à perda do "toque humano" essencial na didática.

Portanto a literatura converge para o fato de que a eficácia da IA Generativa na pratica docente não reside na completa autonomia dos algoritmos, e sim na capacidade de professores atuarem como validadores éticos e mediadores de uma co-agência equilibrada entre humanos e máquinas.

- **Desafios e questões éticas**

A inclusão da Inteligência Artificial no meio educacional traz consigo muitos desafios que exigem atenção, cuidado e políticas institucionais robustas. Garcia-López et al., (2024) identificam que a implementação do ChatGPT na educação enfrenta grandes desafios, entre eles, a preocupação com a integridade acadêmica, a privacidade de dados, viés algorítmico e dependência dos alunos em relação a assistência de IA, exigido políticas institucionais cuidadosas e frameworks éticos e bem estruturados.

Ofosu (2025) complementam essa perspectiva propondo um framework ético para IA generativa na educação, sua proposta aborda transparência, responsabilidade, equidade e agência humana, isso garante que os sistemas de IA apoiem a tomada de

decisão humana ao invés de substituí-la em contextos educacionais.

Em regiões em desenvolvimento os desafios éticos assumem dimensões particulares em contextos específicos. Ayanwale et al. (2025) observam que nessas regiões, os professores enfrentam desafios únicos na adoção da IA Generativa, incluindo a preocupação com segurança de dados, adequação do conteúdo a cultura local e acesso equitativo a tecnologia, fatores conceituais que devem ser considerados nas estratégias de implementação.

- **Transformação digital**

A adoção da Inteligência Artificial na Educação é uma transformação e este processo é complexo e não engloba apenas a implementação tecnológica. Santos Júnior et al., (2025) demonstram que a transformação digital na educação através da adoção do ChatGPT revela perfis de usuários distintos baseados em idade, experiência e contexto institucional sendo crucial entender esses perfis para projetar estratégias de implementação eficazes e programas de treinamento adequados. Essa atenção aos perfis de usuários é crucial para entender como diferentes grupos de educadores e alunos utilizam as tecnologias de IA, isso permite personalização nas abordagens para implementação.

Algumas mudanças organizacionais drásticas são necessárias para a transformação digital efetiva. Os autores ainda enfatizam que a transformação digital na criação de conteúdo exige não apenas adoção tecnológica, mas também mudanças culturais em como as instituições educacionais abordam o ensino e a aprendizagem. Este processo de transição deve ser apoiado por políticas institucionais claras, investimento em formação de pessoal e criação de uma cultura organizacional que valorize a inovação e uso ético da tecnologia.

- **Aprendizagem colaborativa**

A aprendizagem colaborativa pode ser potencializada pela IA, ela abre novas possibilidades para a interação mais ricas e significativas entre os estudantes. Os sistemas de IA podem aprimorar a aprendizagem colaborativa incentivando a colaboração entre pares, *"recomendando atividades colaborativas e relevantes e fornecendo suporte imediato para o trabalho em grupos"* (Kovari, et al. 2024) Estes sistemas criam ambientes mais dinâmicos, inclusivos e permitem que os estudantes que possuem diferentes ritmos e estilos de aprendizagem participem ativamente das atividades.

O estudo de Kovari (2025) destaca que a mediação da IA em ambientes colaborativos pode ser valiosa para identificar oportunidades de aprendizagem entre

pares e facilitar as conexões e interações produtivas. Além de analisar padrões de colaboração, identificar alunos que poderiam evoluir melhor ao trabalhar juntos e adaptar composições de grupo com base nos resultados de aprendizagens anteriores. Isso aumentaria significativamente a efetividade da aprendizagem colaborativa em contextos de educação superior onde a diversidade de alunos é maior.

- **Tecnologias emergentes**

Os Grandes Modelos de Linguagem (LLMs) não são as únicas tecnologias com potencial para emergir na área educacional, segundo Samala et al. (2024), os tokens não-fungíveis (NFTs) representam uma tecnologia com aplicações potenciais na educação, incluindo credenciais digitais verificáveis, badges de aprendizagem que reconhecem competências específicas e proteção de propriedade intelectual de trabalhos de alunos e professores. Embora sejam promissores, os NFTs ainda não foram amplamente incorporados aos contextos educacionais, permanecendo como um campo que demanda mais estudos para avaliar sua viabilidade pedagógica e seu impacto.

Ainda segundo a autora, a integração dos NFTs com sistemas de IA Generativa pode criar novas possibilidades para reconhecimento de aprendizagem e proteção de conteúdo educacional. Porém questões de custo, escalabilidade e aceitação institucional ainda precisam ser resolvidas antes que essas tecnologias possam ser amplamente implementadas em ambientes educacionais tradicionais.

- **Engajamento e métodos de ensino**

A IA pode ser um aliado do professor no que diz respeito ao engajamento dos alunos em sala de aula. Long et al., (2026) demonstram através de uma RSL que os sistemas de IA podem impactar significativamente o engajamento dos alunos no ensino superior, com os métodos de ensino desempenhando um papel mediador crucial nesse processo. Os autores citam o método PMAISE (*Pedagogical Mediation of Al for Student Engagement*), este método ilustra como a mediação por IA aprimora o engajamento sem perder a qualidade educacional e evita a substituição de decisões humanas por automatização.

A relação entre a IA e o engajamento não é natural, ela depende fortemente da maneira como a IA é implementada e adequada aos métodos de ensino existentes. Se a IA for utilizada como uma ferramenta de suporte pedagógico ela pode adaptar os métodos de ensino e com isso aproveitar as capacidades de forma estratégica. Isso reforça a importância e o papel central do professor como mediador entre tecnologia e

aprendizagem, garantindo que a tecnologia seja utilizada para aprimorar a educação humana ao invés de substituí-la.

- **Survey e revisão sistemática**

O interesse acadêmico em IA na educação não para de crescer. Nos últimos 21 anos, pesquisadores como Okagbue et al. (2023) observaram um aumento notável de estudos sobre o tema, com crescente atenção para aplicações práticas que realmente funcionam em sala de aula, como análise de dados de aprendizagem e sistemas que se adaptam ao ritmo de cada aluno. Mais recentemente, Wang et al. (2026) mostram como os Modelos de Linguagem Grande evoluíram rapidamente, saindo dos primeiros chatbots para sistemas sofisticados de aprendizagem adaptativa. Esses estudos nos ajudam a entender melhor o potencial da IA na educação e apontam caminhos para o futuro, como a integração com outras tecnologias e o desenvolvimento de práticas éticas robustas.

- **Observações finais**

Diante do contexto da implementação de inovações tecnológicas na educação utilizando Inteligência Artificial Generativa, este artigo buscou entender de que forma os estudiosos vêm usando a IA Generativa para melhorar os processos educativos. Além disso, buscou-se identificar barreiras e incentivadores quanto ao uso da IA na educação e suas recomendações e sugestões de futuros estudos.

Para atingir o objetivo deste trabalho, tomou-se base na revisão sistemática de literatura resultando em fornecer subsídio informacional para professores interessados em desenvolver práticas com uso de IA Generativa, respondendo às questões que nortearam a pesquisa, conforme mostra o Quadro 3.

Quadro 2 - Portfólio Final de Artigos sobre IA Generativa na Educação

Questão	Descoberta
(a) Como a IA Generativa está sendo usada para geração de conteúdos educacionais?	• Geração automática de materiais didáticos estruturados através de sistemas como TMGS (Teaching Material Generation System) com módulos para pré-aula, durante a aula e pós-aula (Chen, Liu & He, 2023) • Transformação de grandes volumes de conteúdo educacional (50.000+ transcrições de vídeos) em materiais de aprendizagem abrangentes, incluindo notas de estudo, resumos de conceitos-chave e abstratos otimizados (Zabala, Ribalta & Mataix, 2025)

continua

continuação

	• Geração personalizada de questões de avaliação adaptadas ao nível de aprendizagem individual de cada aluno (Liu et al., 2025) • Criação de conteúdo educacional diverso, desde notas de aula até exercícios interativos e materiais de avaliação, reduzindo significativamente tempo e esforço necessários (Wang, Xu, Li, Zhang, Liang, Tang, Yu & Wen, 2026) • Desenvolvimento de materiais didáticos através de aprendizagem ativa combinada com geração de conteúdo assistida por IA (Rangana & Dias, 2024) • Engenharia de prompts para melhorar qualidade, novidade e originalidade do conteúdo gerado (Ghimire, V et al., 2024)
(b) Quais são os benefícios e resultados positivos da implementação de IA Generativa na educação?	• Personalização dinâmica de materiais educacionais em tempo real, adaptando conteúdo às necessidades, preferências e ritmo de aprendizagem individual (Jauhiainen & Garagorry Guerra, 2024) • Melhoria estatisticamente comprovada no desempenho dos alunos e engajamento quando combinada com aprendizagem baseada em atividades (Tamara Al et al., 2024) • Criação de caminhos de aprendizagem personalizados que se adaptam aos estilos individuais, ritmo e lacunas de conhecimento, resultando em melhoria de resultados de aprendizagem (Fortuna et al., 2025) • Redução significativa da carga de trabalho docente na preparação de aulas e criação de conteúdo (Chen, Liu & He, 2023) • Aumento na motivação e compreensão dos conteúdos por parte dos alunos (Santos Júnior, Brinkhues, Rosa, Frantz & Gonçalves, 2025) • Melhoria de ergonomia cognitiva e feedback em tempo real (Jauhiainen & Garagorry Guerra, 2024) • Escalabilidade da personalização em ambientes educacionais de grande escala (Wang et al., 2026) • Impacto significativo no engajamento dos alunos em educação superior, com mediação pedagógica apropriada (Long, Wang, Rashid & Lu, 2026)
(c) Quais são os desafios, limitações e questões éticas na implementação de IA Generativa?	• Variabilidade na qualidade do conteúdo gerado e necessidade de revisão manual (Ghimire, V. et al., 2024) • Preocupações com integridade acadêmica, privacidade de dados e viés algorítmico (García-López, González González, Ramírez-Montoya & Molina-Espinosa, 2024) • Risco de dependência excessiva dos alunos em relação à assistência de IA (García-López et al., 2024) • Questões de transparência e responsabilidade nos sistemas de IA (Kovari, 2025)

continua

continuação

	• Desafios únicos em contextos em desenvolvimento, incluindo segurança de dados, adequação cultural do conteúdo e acesso equitativo à tecnologia (Ayanwale, Adelana, Bamiro, Olatunbosun, Idowu & Adewale, 2025) • Divisão digital e necessidade de garantir que soluções impulsionadas por IA não agravem desigualdades existentes em educação rural (Jangir, 2024) • Falta de letramento em IA entre educadores para uso responsável (Pei, Lu, Park et al., 2026) • Adoção limitada entre professores (aproximadamente 75% não utilizam IA em suas práticas)
(d) Quais são as recomendações e boas práticas para implementação efetiva de IA Generativa na educação?	• Implementação do modelo Human-In-The-Loop, garantindo que professores mantenham papel central como revisores, validadores e supervisores éticos (Chen, Liu & He, 2023) • Desenvolvimento de letramento abrangente em IA para educadores, incluindo compreensão de capacidades, limitações, implicações éticas e aplicações pedagógicas (Pei, Lu, Park et al., 2026) • Estabelecimento de frameworks éticos robustos que abordem transparência, responsabilidade, equidade e agência humana (Kovari, 2025) • Criação de políticas institucionais claras que equilibrem inovação tecnológica com proteção de direitos e bem-estar dos alunos (García-López et al., 2024) • Formação contínua de professores em habilidades técnicas, aplicações pedagógicas e considerações éticas (Cheung & Hu, 2024) • Implementação de auditorias de viés e proteção robusta de dados (Ayanwale et al., 2025)• Personalização de estratégias de implementação conforme perfis de usuários distintos baseados em idade, experiência e contexto institucional (Santos Júnior et al., 2025) • Desenvolvimento de sistemas adaptativos que consideram contextos educacionais específicos e necessidades locais (Kovari, 2024) • Mediação pedagógica apropriada de sistemas de IA para maximizar engajamento mantendo qualidade educacional (Long, Wang, Rashid & Lu, 2026)
(e) Quais são as lacunas de pesquisa e oportunidades futuras para IA Generativa na educação?	• Desenvolvimento de sistemas integrados multimodais que combinem IA Generativa com outras tecnologias emergentes (Wang et al., 2026) • Pesquisa em contextos educacionais específicos (educação rural, educação em regiões em desenvolvimento, educação superior) (Jangir, 2024; Ayanwale et al., 2025) • Estudo de equidade em diferentes regiões socioeconômicas e acesso equitativo à tecnologia (Jangir, 2024

continua

continuação

	• Desenvolvimento de métricas sofisticadas para avaliar qualidade, novidade e originalidade do conteúdo gerado (Ghimire, V. et al., 2024) • Pesquisa sobre aceitação e adoção entre professores, especialmente considerando os 75% que ainda não utilizam IA (Santos Júnior et al., 2025) • Educação em cidadania digital e letramento crítico em IA para alunos (Yim I, 2024)• Estudos de impacto a longo prazo da IA na aprendizagem e desenvolvimento cognitivo (Long, Wang, Rashid & Lu, 2026) • Exploração de tecnologias emergentes como NFTs para credenciais digitais e proteção de propriedade intelectual (Samala et al., 2024) • Pesquisa sobre colaboração humano-máquina e novos papéis do professor em ambientes impulsionados por IA (Chen, Liu & He, 2023) • Mapeamento de inovações impulsionadas por IA em diferentes contextos de educação superior (Guacas et al., 2024)

Fonte: elaborado pela autora (2026)

CONSIDERAÇÕES FINAIS

Conforme consta no Quadro 4, foram identificados nos 21 artigos estudados que as principais práticas de uso de IA Generativa na prática docente estão integradas às seguintes temáticas: Geração Automática de Conteúdos Educacionais através de sistemas como TMGS (Teaching Material Generation System); Personalização Dinâmica de Aprendizagem adaptando conteúdo ao ritmo individual de cada aluno; Letramento em IA para Educadores, capacitando professores para uso responsável; Desafios e Questões Éticas incluindo privacidade, viés algorítmico e integridade acadêmica; Transformação Digital nas instituições educacionais; Aprendizagem Colaborativa potencializada por IA; Tecnologias Emergentes como NFTs para credenciais; Engajamento e Métodos de Ensino mediados por IA; e Survey/Revisão Sistemática consolidando conhecimento existente.

Essa visão diversificada revela que a IA Generativa é mais do que uma solução única, ela é um conjunto de aplicações contextualizadas que devem ser adaptadas às necessidades específicas de cada ambiente educacional. Os estudos analisados destacaram que a maioria dos estudantes envolvidos em pesquisas aumentou significativamente a compreensão e motivação quando a IA foi utilizada de forma estratégica nas aulas.

Este avanço registrado nas pesquisas , especialmente quando a IA foi combinada com abordagens de aprendizagem ativa, mostra que a tecnologia pode ser um impulsionador dos resultados positivos dos estudantes. Além de reduzir a carga de trabalho docente no que diz respeito à preparação de aulas, criação de planejamento e

geração de conteúdos, liberando tempo para a efetiva prática docente. Uma verdadeira transformação também se dá na personalização quando se menciona a educação em massa, visto que neste contexto cada aluno recebe atenção individualizada e pessoal.

Entre as barreiras para a implementação da IA Generativa na educação apresentam-se: a falta de letramento em IA entre os professores (aproximadamente 75% dos professores ainda não utilizam IA em suas práticas), questões de privacidade de dados, viés algorítmico, integridade acadêmica e dependência excessiva dos alunos em relação a assistência de IA.

Alguns fatores amplificam essas barreiras quando se trata de ambientes educacionais em desenvolvimento, entre elas estão a divisão digita, a inadequação cultural do conteúdo gerado e o acesso não igualitário às tecnologias. Desta maneira, a capacitação docente para o uso responsável e fundamentado de IA Generativa são temas importantes para trabalhos futuros.

Respondendo às questões de pesquisa, as recomendações e boas práticas consolidadas na literatura indicam a necessidade do uso do modelo Human-In-The-Loop, o que garante que professores mantenham seu papel central de revisores, validadores e supervisores éticos da máquina. A oferta de letramento em IA para educadores incluindo compreensão de capacidades, limitações, implicações éticas e aplicações pedagógicas surge como pré-requisito fundamental.

O estabelecimento de frameworks éticos completos que abordam tanto ética quanto transparência, equidade e agência humana é estritamente necessário para a implementação responsável dessa tecnologia. Políticas institucionais claras e personalização de estratégias de implementação aparecem como demandas que devem ser desenvolvidas em colaboração entre educadores e administradores.

Como fatores limitadores desta pesquisa, podemos considerar que a escolha dos descritores, a combinação de operadores, e a escolha das bases de dados e o período de realização de buscas são fatores que podem influenciar nos resultados obtidos. Portanto, novas revisões sistemáticas sobre o tema também podem agregar novas descobertas. Ademais, a maioria dos artigos analisados estão inseridos no contexto de educação superior e em regiões desenvolvidas, isso abre lacunas de conhecimento sobre aplicação em educação primária e secundária e em regiões em desenvolvimento.

Entendemos que pesquisas futuras podem ser interessantes ao envolver estudos que orientem sobre a criação de aplicações com IA Generativa e possibilitem a análise de ferramentas de criação de aplicações, demonstrando suas vantagens, embasando possíveis interessados no desenvolvimento das mesmas. Recomendamos especificamente: 1) desenvolvimento de sistemas integrados multimodais que combinem IA Generativa com outras tecnologias emergentes; (2) pesquisa em contextos educacionais específicos, particularmente em educação rural e regiões em desenvolvimento; (3) estudos longitudinais sobre impacto a longo prazo da IA na

aprendizagem e desenvolvimento cognitivo; (4) investigação sobre aceitação e adoção entre professores, compreendendo os fatores que impedem os 75% de educadores que ainda não utilizam IA; (5) desenvolvimento de métricas sofisticadas para avaliar qualidade, novidade e originalidade do conteúdo gerado por IA; (6) pesquisa sobre colaboração humano-máquina e novos papéis do professor em ambientes impulsionados por IA; (7) educação em cidadania digital e letramento crítico em IA para alunos; e (8) exploração de tecnologias emergentes como NFTs para credenciais digitais e proteção de propriedade intelectual.

Tais pesquisas futuras podem consolidar conhecimento, identificar lacunas e orientar a implementação da IA Generativa na educação de forma responsável, garantindo que a tecnologia sirva aos objetivos pedagógicos/educacionais ao invés de substituí-lo.

Referências

Adelana, O. P.; Ayanwale, M. A.; Bamiro, N. B.; Olatunbosun, S. O.; Idowu, K. O. & Adewale, K. A. Large language models and GenAI in education: Insights from Nigerian in-service teachers through a hybrid ANN-PLS-SEM approach. **F1000Research,** v. 14, n. 258, p. 1-25, 4 mar. 2025. DOI: https://doi.org/10.12688/f1000research.161637.1.

Allen, I. E.; Seaman, J. **Staying the course:** Online education in the United States. Wellesley: Sloan Consortium, 2008. Disponível em: https://onlinelearningconsortium.org/read. Acesso em: [23/04/2026].

Ayanwala, YANWALE, M. A.; Adelana, O. P.; Bamiro, N. B.; Olatunbosun, S. O.; Idowu, K. O. & Adewale, K. A. Large language models and GenAI in education: Insights from Nigerian in-service teachers through a hybrid ANN-PLS-SEM approach. **F1000Research**, v. 14, n. 258, p. 1-25, 4 mar. 2025. DOI: https://doi.org/10.12688/f1000research.161637.1

Chen, S.; Liu, Q. & He, B. A Generative AI-based Teaching Material System Using a Human-In-The-Loop Model. **IEEE Transactions on Education**, 2023. Disponível em: https://ieeexplore.ieee.org/document/10391244 Acesso em: [23/04/2026].

Cheung, S. & Hu, W. Unleashing human potential: An artificial intelligence competency framework for educators. **Journal of Educational Computing Research**, 2024. Disponível em: https://www.sciencedirect.com/science/article/pii/S2666920X26000172 Acesso em: [23/04/2026].

Christensen, C. M.; Horn, M. B.; Staker, H.. **Is K-12 Blended Learning Disruptive?** An Introduction to the Theory of Hybrids. Clayton Christensen Institute for Disruptive Innovation, 2013.

Conklin, S.; Dorgan, T. & Barreto, D. A IA é a nova criadora de cursos? **Discover Education**, v. 3, n. 1, p. 285, 2024. Disponível em: Acesso em : 24/04/2026

Dias, G. & Rangana, K. S. Educational Material Development with Active Learning for Secondary School Subjects. **Education Sciences**, 2024. Disponível em:https://ieeexplore.ieee.org/abstract/document/11156564 Acesso em: [23/04/2026].

Ferenhof, H. A. & Fernandes, R. F. **Passo a passo para elaboração de uma revisão sistemática**. In: Congresso IberoAmericano de Pesquisa Qualitativa, 5., 2016, Anais [...]. Salamanca: Universidade de Salamanca, 2016. p. 1-10.

Fortuna, A.; Prasetya, F.; Samala, A. D.; Rawas, S.; Criollo-C, S.; Kaya, D.; Raihan, M.; Andriani, W.; Safitri, D. & Nabawi, R. A. Artificial intelligence in personalized learning: A global systematic review of current advancements and shaping future opportunities. **Computers and Education: Artificial Intelligence**, v. 5, 2025. Disponível em: https://www.sciencedirect.com/science/article/pii/S2666920X24000201. Acesso em: [23/04/2026].

Garcia-Lopez, I. M.; Gonzalez, C. S.; Ramirez-Montoya, M. S. & Molina-Espinosa, J. M. Challenges of implementing ChatGPT on education: Systematic literature review. **Education Sciences,** v. 14, n. 2, p. 148, 2024. Disponível em: https://www.mdpi.com/2227-7102/14/2/148. Acesso em: [23/04/2026].

Guacas, A. F. M.; Moreno, P. C. R. M.; Calderón-Cisneros, J. T. & Piris, N. P. Mapping artificial-intelligence-driven innovation in higher education: A bibliometric review. **Social Sciences & Humanities Open,** Volume 13, 2026, 102561, ISSN 2590-2911. DOI: https://doi.org/10.1016/j.ssaho.2026.102561

Jauhiainen, J. S. & Guerra, A. G. Generative AI and education: dynamic personalization of pupils' school learning material with ChatGPT. **Frontiers in Education**, v. 9, p. 1288723, 2024. Disponível em: https://www.frontiersin.org/journals/education/articles/10.3389/feduc.2024.1288723/full. Acesso em: [23/04/2026].

Junior, D. B. S.; Brinkhues, R. A.; Rosa, J. C. O.; Frantz, B. B. & Gonçalves, B. B. Transformação digital na criação de conteúdo: Uma análise do perfil. **Revista de Inovação**, v. 1, n. 1, p. 1-20, 2024. Disponível em: https://uninove.emnuvens.com.br/innovation/article/view/27451. Acesso em: [23/04/2026].

Kim, K.-J.; Bank, S. Time investment in course development for online learning. **Educational Technology Research and Development**, v. 56, n. 5-6, p. 597–612, 2008. Disponível em: https://link.springer.com/article/10.1007/s11423-008-9094-7 . Acesso em: [23/04/2026]

Kovari, A. A systematic review of AI-powered collaborative learning in higher education: trends and outcomes from the last decade. **Social Sciences & Humanities Open**, v. 11, 2025, 101335. DOI: https://doi.org/10.1016/j.ssaho.2025.101335 . Acesso em: [23/042026].

Libâneo, J. C. **Didática** 2. ed. São Paulo: Cortez, 2013.

Long D. Y.; Wang S.; Rashid, S. & Lu, X. T. (2026) Artificial intelligence in higher education: a systematic review of its impact on student engagement and the mediating role of teaching methods. **Front. Educ**. doi: 10.3389/feduc.2025.1648661. Disponível em: https://www.frontiersin.org/journals/education/articles/10.3389/feduc.2025.1648661/full?utm_source=chatgpt.com Acesso em: [23/04/2026].

Manus. **Inteligência Artificial Generativa**. Disponível em: https://www.manus.im. Acesso em: [23/04/2026].

Pei, B.; Lu, J.; Zhang, Z.; Tuffour, P. & Sanghoon, P. Enhancing AI literacy for educators: Where to start and to what end? **International Journal of Artificial Intelligence in Education**, v. 36, n. 2, p. 1-25, 2026. Disponível em: https://www.sciencedirect.com/science/article/pii/S2666920X26000111. Acesso em: [23/04/2026].

Samala, A. D.; Rawas, S.; Zainuddin, Z.; Howard, N.-J.; Shilina, S. The role of non-fungible tokens in education: A comprehensive review and future perspectives. **Education Sciences**, v. 14, n. 5, p. 1-18, 2024.

Sampaio, R. F. & Mancini, M. C. Estudos de revisão sistemática: um guia para síntese criteriosa da evidência científica. **Revista Brasileira de Fisioterapia**, São Carlos, v. 11, n. 1, p. 83-89, jan./fev. 2007. Disponível em: https://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-35552007000100013. Acesso em: [23/04/2026].

Tal Shloul, T.; Mazhar, T.; Abbas, Q.; Iqbal, M.; Ghadi, Y. Y.; Shahzad, T.; Mallek, F. & Hamam, H. Role of activity-based learning and ChatGPT on students' performance in education. **Computers and Education:** Artificial Intelligence, v. 5, 2024. Disponível em: https://www.sciencedirect.com/science/article/pii/S2666920X24000201. Acesso em: [23/04/2026].

Villegas-José, V. & Delgado-Garcia, M. Artificial Intelligence: innovative educational revolution in Higher Education. Píxel-Bit. **Revista de Medios y Educación**, v. 71, p. 159-177, 2024. DOI: https://doi.org/10.12795/pixelbit.107760.

Wang, S.; Xu, T.; Li, H.; Zhang, C.; Liang, J.; Tang, J.; Yu, P. S. & Wen, Q. Large Language Models for Education: A survey and outlook. **IEEE Signal Processing Magazine**, v. 43, n. 5, p. 1-20, 2026.

Yim, I. H. Y. A critical review of teaching and learning artificial intelligence (AI) literacy: Developing an intelligence-based AI literacy framework for primary school education, **Computers and Education:** Artificial Intelligence, Volume 7, 2024, 100319, ISSN 2666-920X, DOI: https://doi.org/10.1016/j.caeai.2024.100319.

Ghimire, V.; Lama, J. S.; Dhungana, B.; Sadat, N. & Caporusso, N. **Avaliação da Novidade da Saída em Solicitações Iterativas na Geração de Conteúdo Educacional.** In: Conferência Internacional de Tecnologia e Computadores na Educação (ICETC) de 2025, Barcelona, Espanha, 2025, pp. 226-230. DOI 10.1109/ICETC66579.2025.11387667.

Sobre o autor(a)

Thaise Cechinel Bozzelo Vassoler

Mestranda em Tecnologias da Informação e Comunicação pelo Programa de Pós-graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina (UFSC)

Especialização em Gestão Escolar pela Universidade Regional de Blumenau (Furb - 2011).

Graduada em Matemática pela Universidade Federal de Santa Catarina (UFSC - 2005).

Professora de Matemática efetiva da rede Estaual Básica de Ensino de Santa Catarina.

Lattes:

PARTE III

IA APLICADA ÀS EXPERIÊNCIAS DE APRENDIZAGEM

CAPÍTULO 10

Jogos educacionais baseados em IA para o ensino de matemática

Lucimara Muzykant da Silva

1. Introdução

Como avanço dastecnologias emetodologiasinovadoras para o ensino e a aprendizagem, as ferramentas digitais, vêm se consolidando como importantes aliadas na educação, trazendo melhorias na compreensão de conceitos matemáticos. Os jogos educacionais baseados em Inteligência Artificial, em particular, destacam- se como uma possibilidade de criar ambientes diferentes para o aprendizado, onde os estudantes podem manipular conceitos, visualizar operações e entender essas relações de maneira mais lúdica. Para isso, exige uma boa preparação dos docentes em relação a essas tecnologias.

Contudo, a falta de compreensão dos professores ainda é um grande obstáculo ao uso correto e ético dessas ferramentas. Nesse sentido, questionou-se quais as características e funcionalidades das plataformas de jogos educacionais baseados em Inteligencia Artificial (IA) para o ensino de matemática? E como a IA se integra corretamente ao jogo e às práticas pedagógicas?

Desta forma, visou-se como objetivo identificar plataformas de jogos educacionais baseados em IA voltados ao ensino de matemática, avaliando funcionalidades e características. Na busca de identificar jogos educacionais baseados em IA com aplicações e estudos voltados para a matemática, e entender como esses jogos podem promover um aprendizado por meio dessa tecnologia. Para isso, foi realizada uma pesquisa bibliográfica por meio da plataforma Parsifal, adotando-se uma abordagem qualitativa e uma Revisão Sistemática da Literatura (RSL).

A plataforma foi utilizada como ambiente digital para o planejamento, execução, triagem e registro dos resultados. Este estudo surgiu do interesse em ampliar os conhecimentos adquiridos na disciplina de Inteligência Artificial na Educação, cursada durante o mestrado na UFSC, campus de Araranguá. Nesse contexto, buscou-se também consolidar os fundamentos teóricos sobre tecnologias digitais relacionados à Inteligência Artificial abordados ao longo da disciplina. Além disso, pretende-se

complementar essa formação por meio da análise de estudos que investigam jogos educativos integrados à Inteligência Artificial no ensino da matemática.

Na seção a seguir, descreve-se a fundamentação teórica na qual se baseia este estudo, posteriormente, apresenta-se os procedimentos metodológicos adotados. Analisa- se, então, os resultados obtidos, enfim, apresenta-se as considerações finais.

2. Fundamentação teórica

Nos últimos anos, as tecnologias se tornaram uma parte do nosso cotidiano, afetando todos os setores e transformando as relações sociais. No campo da educação, essa investigação tecnológica também é evidente, com o surgimento de novas ideias e propostas inovadoras. No entanto, Reis et al (2022), revelam que uma verdadeira mudança na educação depende de uma série de fatores. Entre eles, destaca-se a especialização de professores para o domínio e aplicação de ferramentas tecnológicas em suas práticas pedagógicas.

É fundamental criar um ambiente que permita aos professores compreender tanto as potencialidades quanto as limitações dessas ferramentas. Segundo Ribeiro e Ponte (2000, p.18), quando se referem à formação continuada, destacam que, se o professor ficar "isolado e sem possibilidade de realizar uma reflexão continuada, parece improvável que a porta da sala de aula se abra à introdução da tecnologia num sentido educacionalmente inovador".

Assim, é essencial que o professor esteja em constante atualização, sempre em busca de novas práticas pedagógicas. Isso exige que os docentes adquiram novos conhecimentos e se apropriem de novas inovações tecnológicas, de maneira a incorporá-las ao currículo escolar e promover novas metodologias de ensino.

Segundo as ideias de Prensky (2010), muitos professores sentem-se desorientados diante das diversas possibilidades de integração das tecnologias digitais no ensino. Esse cenário torna-se ainda mais desafiador com o avanço das tecnologias mais recentes, que intensificam essas dificuldades justamente por ainda envolverem questões pouco compreendidas, como aspectos éticos e formas adequadas de utilização.

Um exemplo evidente é o uso da Inteligência Artificial na Educação, que, embora pode apresentar grande potencial pedagógico, ainda gera dúvidas quanto à sua aplicação responsável, seus limites e suas implicações no processo de ensino e aprendizagem. O estudo de Holmes, Bialik e Fadel (2019) vem ao encontro dessas ideias. Nesse trabalho é discutido o uso da Inteligência Artificial na educação destacando seu potencial para personalizar a aprendizagem e apoiar o ensino. Os autores reforçam com preocupações sobre lacunas no entendimento ético e pedagógico da IA. O uso de dadoseducacionais gerados por sistemas de IA que monitora os

comportamentos e desempenhos dos estudantes levanta questões éticas que precisam ser investigadas.

> [...] quem é o proprietário e quem pode acessar esses dados, quais são as preocupações com a privacidade, como os dados devem ser analisados, interpretados e compartilhados, e quem deve ser considerado responsável caso algo dê errado? (Holmes; Bialik; Fadel, 2019, p. 30).

Assim, o texto amplia a reflexão ao indicar que não se trata apenas de aprender a usar novas ideias, tecnologias ou formas de aplicação que estão surgindo ou ganhando força recentemente em determinada área, mas de compreender criticamente seus impactos, limites e possibilidades no contexto educacional.

Entre essas tendências emergentes da Inteligência Artificial na Educação, destacam-se a personalização da aprendizagem, os agentes inteligentes, os jogos adaptativos baseados em modelos de linguagem e a utilização da IA generativa para apoiar a criação de respostas, narrativas e desafios. Essas possibilidades ampliam a capacidade dos jogos de ajustar situações e fornecer apoio conforme as necessidades dos estudantes, mas também exigem supervisão humana, critérios pedagógicos e atenção às questões éticas relacionadas ao uso de dados educacionais (Holmes; Bialik & Fadel, 2019).

No conjunto de estudos desenvolvidos, essas tendências aparecem no uso de LLM como oponente no DaMath (Alicando et al., 2025), na utilização da IA generativa no EOQ World Tour (Trindade et al., 2025) e no apoio à investigação colaborativa no Math City (Singh et al., 2025).

3. Metodologia

O desenho metodológico adotado nesta contribuição foi uma pesquisa bibliográfica de abordagem qualitativa, fundamentada na análise de artigos científicos. Para isso, realizou-se uma Revisão Sistemática da Literatura (RSL), conduzida com o apoio da plataforma Parsifal para planejamento, execução e registro dos resultados.

A revisão foi cadastrada sob o título “Jogos Educacionais Baseados em IA”. No planejamento, definiu-se como objetivo identificar plataformas de jogos educacionais baseados em IA voltados ao ensino de matemática, analisando suas funcionalidades e características. A partir disso, elaboraram-se as perguntas de pesquisa: como funcionam e quais são as características das plataformas de jogos educacionais baseados em IA? Quais são as principais plataformas de jogos educacionais baseados em IA para matemática? E como a IA se integra corretamente ao jogo e às práticas pedagógicas?

Após a elaboração do PICOC, delimitando população (estudantes e professores), intervenção (plataformas ou jogos com IA matemática), comparação (jogos tradicionais sem IA), resultado (aprendizagem) e contexto (educação), definiu-se as palavras-chave: IA, inteligência artificial, jogos educacionais e matemática. Assim, foi construída, com apoio da própria plataforma Parsifal, a string de busca inicial: ("IA" OR "Inteligência Artificial" OR "Jogos Educacionais" OR "Matemática").

Em seguida, a string de busca foi adaptada, mantendo o conectivo OR para ampliar os termos de busca e incorporar palavras-chave que inicialmente estavam apenas em português. Além disso, foi inserido o conectivo AND com a finalidade de refinar a pesquisa, tornando os resultados mais alinhados ao tema, gerando a string final para a pesquisa: (("jogos educacionais" OR "educational games") AND ("IA" OR "inteligência artificial" OR "artificial intelligence") AND ("matemática" OR "math" OR "mathematics")).

As buscas foram realizadas nas bases IEEE Xplore, Scopus e ScienceDirect, resultando em 127 estudos no total, distribuídos em 8 na IEEE, 19 na Scopus e 100 na ScienceDirect. Na base ScienceDirect, aplicaram-se filtros que reduziram os resultados de 342 para 100, priorizando artigos de revisão e de pesquisa, além de documentos com acesso e arquivo aberto, conforme as opções disponíveis na base.

Os estudos selecionados foram importados para o Parsifal por meio de BibTeX. A triagem inicial ocorreu pela leitura dos títulos e resumos, com apoio de tradução do inglês para o português via Google Tradutor. A Tabela 1 apresenta a relação entre os estudos importados e os estudos selecionados.

Tabela 1 - Relação entre os estudos

Base de dados	Importados	Selecionados
IEEEXplore	8	0
ScienceDirect	100	5
Scopus	19	3

Fonte: elaborado pela autora (2026)

Os critérios de exclusão contemplaram estudos publicados antes de 2018, duplicados, em idiomas diferentes do inglês e do português, que não envolvesse matemática, que não fossem baseados em jogos educacionais com IA ou que não apresentassem IA em sua proposta. Já os critérios de inclusão abrangem estudos que tratam de plataformas ou jogos com IA, de jogos educativos integrando IA e de relatos

de experiências com jogos e plataformas baseadas em IA.

Os estudos foram desenvolvidos conforme seu grau de relação com o ensino de matemática, distinguindo aqueles que abordaram diretamente conteúdos matemáticos, os que integraram a matemática a outras áreas e os que discutiram aspectos de design, usabilidade e incorporação da IA em jogos educacionais. A tabela 2 mostra o título dos trabalhos selecionados para o estudo com a respectiva base de dados e autores.

Tabela 2 - Trabalhos selecionados

Base de dados	Título do trabalho	Autores
ScienceDirect	*Revolutionizing learning − A journey into educational games with immersive and AI technologies*	Rapaka, A.; Dharmadhikari, S. C.; Kasat, K.; Mohand, C. R.; Chouhan, K. Gupta, M.
ScienceDirect	*Exploring the Potential of LLM-Driven Opponent in DaMath*	Alicando, G. V.; Jamen, R. C.; Escasio, E. V. & Maulana,
ScienceDirect	*Impact of intelligent vs non-intelligent mCSCL on mathematics performance: A comparative study of grade 5 students*	Bringula, R. P.; Atienza, F. A. L.; Mangubat, J.; Roxas, M. & Miranda, J. P. P.
ScienceDirect	*Teaching mathematical concepts in management with generative artificial intelligence: The power of human oversight in AI-driven learning*	Trindade, M. A. M.; Edirisinghe, G.; & Luo, L.
ScienceDirect	*Design and implementation of Math City: An inquiry-based metaverse platform for mathematics education*	Singh, M.; Sun, D. & Yang, Y.
Scopus	*Design and Implementation of an Educational Game for Teaching Artificial Intelligence to High School Students*	Wang, N.; Montgomery, R.; Greenwald, E. & Leitner, M.
Scopus	*Student agency and game-based learning: A study comparing low and high agency*	Nguyen, Huy; Harpstead, E.; Wang, Y. & McLaren, B. M.
Scopus	*Characterizing User Needs for GenAI Incorporation in Educational Games*	Goldstein, M.; Ahmed, I.; YU, F.; Verma, V.; McNamara, D. & Arner, T.racy

Fonte: elaborado pela autora (2026)

Os documentos selecionados foram traduzidos com o apoio de plataformas digitais de tradução e, em seguida, lidos para a construção da próxima etapa de análise. A avaliação de qualidade dos estudos foi realizada por meio de 4 perguntas, onde analisou-se quanto à clareza do objetivo, descrição da plataforma ou jogo com IA, explicitação da prática pedagógica e realização de aplicações com estudantes.

Atribuiu-se resultados graduais conforme o grau de atendimento a cada item (1 ponto atribuido a que responde totalmente a pergunta, 0,5 para que responde parcialmente e 0 a que não responde). O fluxograma 1 apresenta, de forma sintética, as etapas percorridas nesta pesquisa na plataforma Parsifal.

Figura 1 - Fluxograma das etapas da pesquisa

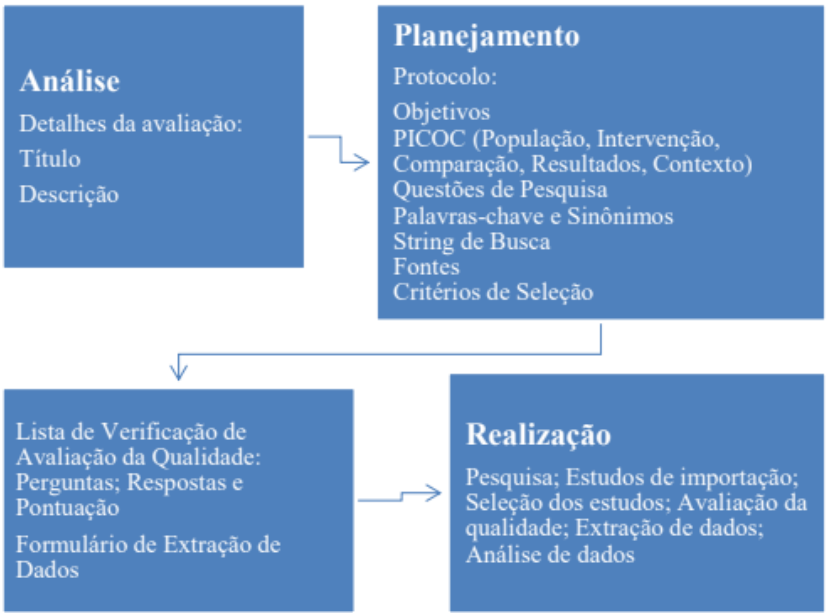

Fonte: elaborado pela autora (2026)

Este trabalho contou com o apoio das inteligências artificiais Perplexity AI e ChatGPT para auxiliar na revisão gramatical, traduções e na reestruturação de parágrafos, incluindo ajustes de linguagem e concordância verbal.

4. Resultados e Discussões

Apresentam-se nessa seção os resultados do estudo dos trabalhos que foram selecionados para a análise. O processo de seleção gerou 8 estudos que atenderam aos critérios de inclusão. A Tabela 3 apresenta a pontuação obtida por cada estudo na avaliação de qualidade. A predominância foi de pontuações máximas (4,0), com apenas um estudo sem descrição de jogos com IA (3,0).

Tabela 3 - Avaliação de qualidade

Título do trabalho	Pontuação
Revolutionizing learning − A journey into educational games with immersive and AI technologies	4,0
Design and Implementation of an Educational Game for Teaching Artificial Intelligence to High School Students	4,0
Student agency and game-based learning: A study comparing low and high agency	4,0
Exploring the Potential of LLM-Driven Opponent in DaMath	4,0
Impact of intelligent vs non-intelligent mCSCL on mathematics performance: A comparative study of grade 5 students	4,0
Teaching mathematical concepts in management with generative artificial intelligence: The power of human oversight in AI-driven learning	4,0
Design and implementation of Math City: An inquiry-based metaverse platform for mathematics education	4,0
Characterizing User Needs for GenAI Incorporation in Educational Games	3,0

Fonte: elaborado pela autora (2026)

Inicialmente, apresenta-se uma visão geral desses estudos, em seguida, realize-se uma avaliação individual de cada um, com base nas perguntas de pesquisa. A Tabela 4 apresenta uma síntese comparativa dos estudos selecionados, considerando a função desempenhada pela IA, os conteúdos matemáticos estratégicos, os recursos utilizados, os principais resultados e as especificações identificadas. Essa organização permite observar que os estudos não avaliam exatamente o mesmo tipo de intervenção.

Tabela 4 - Síntese comparativa dos estudos

Autores	Jogo ou plataforma	Função da IA	Conteúdo	Resultados	Observações
Rapaka, A.; Dharmadhi, S. C.; Kasat, K.; Mohand, C. R.; Chouhan, K. & Gupta, M.	Jogo educacional imersivo, com versão tradicional e inteligente	IA adaptativa, com identificação de padrões de acerto e erro	Alfabetiza-ção e matemática inicial	A versão inteligente aumentou os acertos, chegando a até 89,9%	Estudo voltado para crianças pequenas e o conteúdo inicial; os resultados dependem da adaptação automática das atividades
Wang, N.; Montgomery, R.; Greenwald, E. & Leitner, M.	ARIN-561	IA integrou os desafios de busca: BFS, DFS e Greedy	Matemática aplicada à análise de caminhos e complexida-de	Produziu pequenos ganhos no conheci-mento de IA, principal-mente sobre BFS	O jogo apresentou menor efeito nos conteúdos relacionados a DFS e Greedy e adaptação para diferentes níveis matemáticos
Nguyen, H.; Harpstead, E.; Wang, Y. & McLaren, B. M.	Ponto Decimal	Personaliza-ção baseada nas escolhas e na agência do estudante	Números decimais e operações relacionadas	Não houve diferença significativa entre a versão de baixa e de alta agência	Maior liberdade de escolha não garantiu melhores resultados de aprendizagem
Alicando, G. V.; Jamen, R. C.; Escasio, E. V. & Maulna	DaMath	LLM como oponente e gerador de jogadas	Operações matemáticas integradas ao jogo de damas	O LLM funcionou como oponente, mas teve desempenho inferior ao Minimax	Modelo de linguagem de demonstração. Limitações estratégicas em comparação com uma IA específica para jogos

continua

continuação

Bringula, R. P.; Atienza, F. A. L.; Mangubat, J.; Roxas, M. & Miranda, J. P.	Ibigkas! Math	IA adaptativa, com seleção de problemas, alertas e detecção de chutes	Adição, subtração, multiplica-ção, divisão e frações	Ambas as versões melhoraram o desempenho; a versão inteligente produzida respostas mais precisas e em menor tempo	Foi indicado fadiga de trabalho em tarefas complexas realizadas em grupo
Trindade, M. A. M.; Edirisinghe, G. S. & Luo, L.	EOQ World Tour	IA generativa com supervisão humana	Quantidade Econômica de Pedido e cálculos de custos	Melhorou a compreensão, a interação, o pensamento crítico e a retenção do conteúdo	Exige validação humana dos cálculos e acompanha-mento docente constante
Singh, M.; Sun, D. & Yang, Y.	Math City	IA generativa como apoio à pesquisa e à colaboração	Geometria espacial: faces, arestas e vértices	Apresentou boa usabilidade, com pontuação de 74,54, além de favorecer a colaboração	A IA apoia a aprendiza-gem, mas não constitui o principal organizador pedagógico do jogo
Goldstein, M.; Ahmed, I.; Yu, F.; Verma, V.; McNamara, D.; & Arner, T.	Estudo sobre necessida-des de usuários em jogos educacio-nais	IA generativa como apoio, pistas e narrativa interativa	Não se concentra em um conteúdo matemático especifico	Os estudantes consideraram a IA uma ferramenta complementar e valorizaram respostas claras e pistas personalizadas	Não apresenta um jogo nem disponível diretamente a aprendizagem matemática

Fonte: elaborado pela autora (2026)

A comparação apresentada na Tabela 4 mostra que os resultados mais diretamente relacionados ao desempenho matemático foram apresentados nos estudos que utilizaram a IA para adaptar problemas, oferecer feedback e identificar padrões de

erro. Portanto, os resultados não devem ser classificados apenas como positivos ou negativos, mas analisados de acordo com a função pedagógica.

A integração entre IA, jogos e matemática é promissora quando há intencionalidade pedagógica, tarefas bem estruturadas e apoio ao processo de aprendizagem. Os estudos demonstraram que a IA tende a favorecer a personalização das etapas dos jogos, mas seus efeitos variam conforme o desenho do jogo, a mediação do professor, a clareza e vinculação ao conteúdo. A análise comparativa dos estudos evidencia que as abordagens adaptativas, nas quais a IA identifica padrões de desempenho e ajuste do nível de dificuldade, a sequência das atividades ou o tipo de problema apresentado, foram as que apresentaram resultados mais diretamente relacionados à melhoria do desempenho dos estudantes.

Esse aspecto foi observado principalmente no jogo infantil desenvolvido por Rapaka et al. (2025) e no jogo ibigkas!Math, treinado por Bringula et al. (2025). No primeiro caso, a inteligente apresentou aumento dos acertos, enquanto, no segundo, a versão com IA contribuiu para respostas mais precisas e para a resolução das tarefas em menor tempo.

Entretanto, os resultados não permitem afirmar que a adaptação algorítmica seja, isoladamente, uma técnica mais eficaz. No estudo de Nguyen et al. (2018), por exemplo, a maior liberdade de escolha dos estudantes não produziu diferenças importantes em relação à aprendizagem, embora tenha ampliado o espaço para a personalização da sequência do jogo. Esse resultado sugere que a personalização tende apenas a produzir efeitos educacionais quando está articulada a tarefas matemáticas relevantes, objetivos claros e estratégias de acompanhamento da aprendizagem.

Também foram identificadas outras formas de integração da IA. No DaMath, o modelo de linguagem foi utilizado como oponente, tornando a atividade mais interativa, mas apresentou desempenho inferior ao algoritmo Minimax em relação à estratégia de jogo (Alicanto et al 2025). No EOQ World Tour, uma IA generativa atuosa como gerente de compras, mas os cálculos precisaram ser conferidos pelos estudantes em planilhas eletrônicas (Trindade et al, 2025).

Já na Math City, a IA trabalhou como ferramenta de pesquisa e colaboração, subordinada à organização pedagógica do modelo 5E (Singh et al., 2025). Esses exemplos indicam que a IA não desempenha uma função única nos jogos educacionais: pode adaptar atividades, atuar como adversária, gerar respostas, apoiar investigações ou situações.

Desta forma, os estudos sugerem que os melhores resultados não estão necessariamente associados à utilização de tecnologia mais complexa, mas à correspondência entre a função da IA e o objetivo pedagógico do jogo. Os resultados desta revisão dialogam com tendências internacionais da pesquisa em Inteligência Artificial na Educação, especialmente com a busca por experiências de aprendizagem

personalizadas, ambientes imersivos, uso de modelos de linguagem e integração entre IA generativa e atividades colaborativas.

Os estudos analisados também reforçam uma tendência de compreender a IA como recurso de apoio ao professor e ao estudante, e não como substituta da mediação pedagógica. Nesse contexto, os resultados desta revisão destacam que a adoção dessas tecnologias precisa estar vinculada aos objetivos curriculares claros, à supervisão humana e à atenção às questões éticas relacionadas ao uso educacional da IA.

Em alguns trabalhos, os autores apresentam uma proposta de aplicação como sugestão para que os professores o utilizem em sala de aula. No jogo Math City, por exemplo, é proposto um plano de aula onde o jogo pode ser usado em aulas de Geometria Espacial no Ensino Médio ou Superior, preferencialmente em formato de aula laboratorial e com trabalho em grupo (Singh et al., 2025, p.10). Já no jogo EOQ World Tour, os autores descrevem uma implementação em sala de aula que combina uma simulação com IA, uma etapa de validação dos cálculos por meio de uma planilha Excel e um painel em Google Sheets para monitorar o progresso das equipes e apoiar a discussão ao final do jogo (Trindade et al., 2025, p.9).

Apesar dos resultados e sugestões detalhadas, a análise do conjunto de estudos também revela limitações importantes. A primeira delas é a heterogeneidade das propostas investigadas. Os trabalhos abordam diferentes públicos, conteúdos, objetivos e formas de utilização da IA, incluindo alfabetização inicial, operações com frações, números decimais, geometria espacial, algoritmos de busca e conceitos matemáticos relacionados à gestão. Essa diversidade dificulta a comparação direta dos resultados e impede a identificação de uma abordagem única como superior em todos os contextos.

Outra limitação refere-se ao fato de que nem todos os estudos avaliaram diretamente a aprendizagem matemática. O trabalho de Wang et al. (2023), por exemplo, concentra-se no ensino de Inteligência Artificial, utilizando a matemática como apoio à resolução de problemas. Do mesmo modo, Goldstein et al. (2026) investigaram as necessidades dos usuários para a incorporação da IA em jogos educacionais, mas não avaliaram um jogo nem avaliaram resultados de aprendizagem.

Esses estudos são relevantes para compreender o design e as possibilidades de integração da IA, mas devem ser diferenciados dos estudos que efetivamente mediram o desempenho dos estudantes em conteúdos matemáticos. Observe também que os estudos apresentam diferentes níveis de detalhamento quanto à implementação pedagógica, ao acompanhamento dos estudantes e aos efeitos de longo prazo. Alguns trabalhos relatam resultados de desempenho, enquanto outros se concentram na usabilidade, na satisfação dos participantes, na agência do estudante ou nas possibilidades de utilização da tecnologia.

Assim, os resultados positivos identificados devem ser interpretados com cautela,

pois nem sempre indicam aprendizagem matemática, rigor ou transferência do conhecimento para diferentes situações das apresentadas no jogo.

Além disso, a mediação docente aparece como uma condição comum para o uso adequado da IA. No EOQ World Tour, por exemplo, as respostas produzidas pela IA foram acompanhadas de validação dos cálculos e de discussão. No Math City, a tecnologia foi inserida em uma sequência didática estruturada pelo modelo 5E. Esses exemplos mostram que a IA não deve ser detalhada como substituto do professor, mas como um recurso inserido em uma proposta pedagógica. A seguir, a apresentação de cada estudo.

Em um estudo realizado por Rapaka et al (2025) foi avaliado o uso de jogos educacionais integrados a tecnologias imersivas e inteligência artificial para desenvolver ambientes adaptativos e melhorar o aprendizado. Os autores analisaram ferramentas acessíveis para criação desses jogos sem uso de programação e colocaram o uso do algoritmo SSGOA(IA) para otimizar a experiência.

Trata-se de um experimento para o estudo com crianças de 3 a 4 anos usando um jogo de alfabetização ou matemática inicial em uma versão tradicional (sem IA) e outra versão inteligente (com IA). Na jogada, a criança recebe um áudio pedindo para encontrar determinada letra na tela. Na versão tradicional, se acerta emite som visual, se erra continua até o acerto. Na versão inteligente, protótipo usa "SSGOA IA" para adaptação onde detecta padrões no acerto ou erro e faz ajustes e personalizações para próxima rodada, com o objetivo de facilitar. O estudo demonstrou que a integração de IA melhora o desempenho das crianças, aumentando acertos (até 89,9%).

Figura 2 - Comparação entre jogo tradicional e inteligente

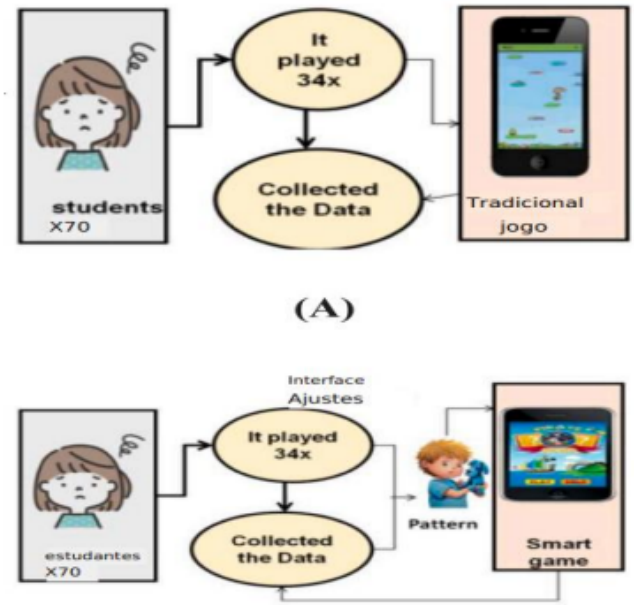

Fonte: extraído de Rapaka et al (2025)

No texto de Alicando et al (2025), os autores investigaram LLMs como oponentes independentes em um jogo denominado DaMath (tabuleiro de damas tradicionais combinado com operações matemáticas). O LLMs funciona como agente adversário em DaMath criando códigos para gerar jogadas em partidas de jogos baseados em regras e emite instruções de melhor jogada.

Os autores concluíram que LLMs funcionam como oponentes em jogos educativos como DaMath. Entretanto, tem desvantagem em relação a uma IA estratégica (Minimax), pois esta tem desempenho maior no domínio, tempo e estratégicas. A figura mostra o gráfico comparando o resultado de 50 jogos entre o Agente LLM e a IA de escolha solicitada (RCG). Posteriormente entre o Agente LLM e o Minimax.

Figura 3 - Resultados do jogo DaMath

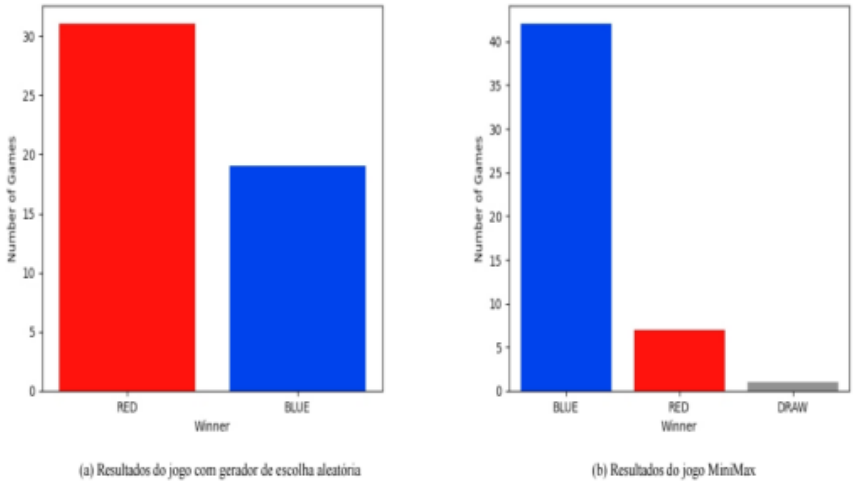

Fonte: adaptado de Alicando et al (2025)

No estudo descrito por Bringula et al (2025) é investigado os efeitos do uso das versões inteligente e não inteligente do ibigkas!Math, um jogo de exercícios em grupo que ajuda na adição, subtração, multiplicação e divisão. "[...] o aplicativo gera problemas aritméticos e os exibe em um dos dispositivos móveis dos membros da equipe". A IA é a versão inteligente, que sugere problemas menos praticados, dá avisos no privado e detecta chutes.

Os autores utilizaram operações com frações no jogo, e concluíram que ambas versões (inteligente e não inteligente) melhoram o desempenho dos estudantes. No entanto, a inteligente se mostra superior, pelo fato das respostas mais precisas (menos chutes) e resolução em menor tempo. Descobriram "fadiga de colaboração"(pausas antes da próxima jogada) em tarefas complexas de grupo, os estudantes pensam antes da próxima rodada, que resulta em interações de grupo que afetam o aprendizado.

Em um estudo realizado por Trindade et al (2025) é apresentado um jogo educacional chamado EOQ World Tour , criado para ensinar o conceito de Quantidade

de Pedidos Econômicos (EOQ) em Gestão de Operações. Os autores adquiriram o jogo para mostrar como a IA generativa , com supervisão humana, pode melhorar a compreensão de conceitos matemáticos de gestão e a retenção do conteúdo. Ele foi aplicado em sala de aula como uma atividade em equipes: os alunos usam a IA (ChatGPT) como gerente de compras , validam os cálculos e custos em uma planilha Excel e depois acompanham os resultados em um painel no Google Sheets.

Os resultados apontaram que o jogo melhora o entendimento de conceitos matemáticos, aumenta a interação entre os estudantes, desenvolve pensamento crítico sobre o uso da IA e melhora a retenção do conteúdo. No artigo, é ressaltado que "a IA só funciona bem com supervisão humana", parte central do método. Os autores detalham a visão geral do jogo da seguinte maneira:

> [...] Empregamos várias estratégias-chave em nossa abordagem inovadora para garantir supervisão humana sobre a IA Generativa na sala de aula para jogos quantitativos. Primeiro, estabelecemos uma estrutura de jogo em que equipes de alunos representam empresas buscando otimizar os custos de estoque, enquanto o ChatGPT atua atuando como seu gerente de compras. O jogo começa quando cada equipe instrui o ChatGPT a agir como seu gerente de compras e solicita gerar o custo de pedir e manter o estoque com base em uma especificação do produto e na localização da empresa fornecidas por cada equipe. Fornecemos um modelo de prompt, que os estudantes podem alterar conforme necessário, para garantir consistência da configuração do jogo entre as equipes. O objetivo estabelecido para cada equipe é discutir o custo total de estoque associado ao posicionamento de diferentes números de pedidos ao longo do ano e decidir o tamanho ótimo do pedido. Essa configuração estruturada fornece clareza, evitando desvios não intencionais dos objetivos de aprendizagem" (Trindade et al, 2025, p.6).

No trabalho de Singh et al (2025) o objetivo foi desenvolver e avaliar uma plataforma imersiva no Metaverso chamada Math City, um jogo projetado para ensinar propriedades de formas tridimensionais na disciplina de matemática. Os autores integraram o modelo 5E (Engajar, Explorar, Explicar, Elaborar e Avaliar) de forma estruturada dentro de do jogo.

Esse modelo organiza as missões do jogo para que cada fase da experiência virtual corresponda a uma etapa do 5E. A IA entra como ferramenta de apoio dentro da fase Explorar/Elaborar , onde os estudantes, na fase laboratório, usam poe.com (plataforma que reúne vários chatbots de IA em um só lugar) para investigar e sintetizar

informações. Assim, é permitido criar uma conversa compartilhada com outras pessoas e com modelos de IA ao mesmo tempo, tudo no mesmo espaço. Em outras palavras, o 5E organiza a pedagogia do jogo, enquanto a IA apoia a aprendizagem.

A imagem abaixo representa as etapas do jogo. Na primeira etapa o estudante entra no Math City como avatar e recebe orientação inicial da recepção. A seguir, explora slides e responde questões básicas. Após entrar no laboratório, trabalha em grupo, usa ChatGPT/Google via Poe.com para pesquisar. Na Sala de exposições, observa os sólidos e identifica faces, arestas e vértices. Por último, responde perguntas e conclui o jogo com recompensas.

Figura 4 - Jogo Math City

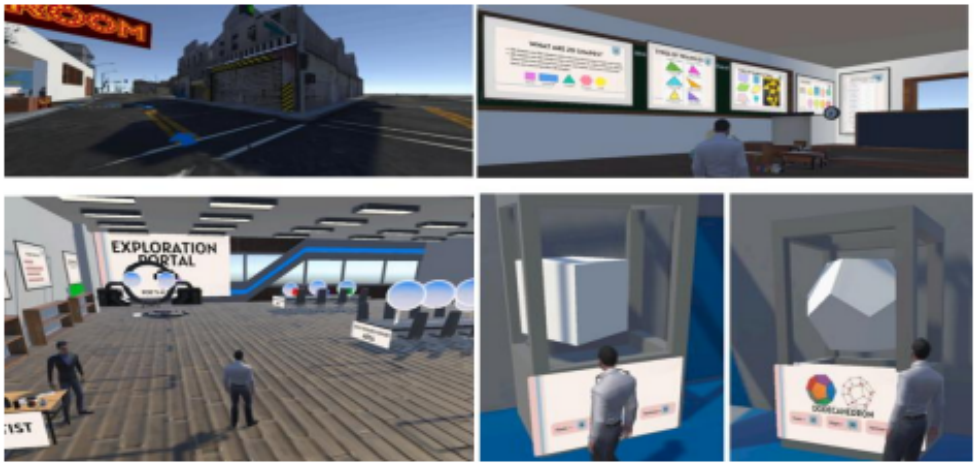

Fonte: adaptado de Singh et al., (2026)

A maioria dos participantes nesta pesquisa considerou a plataforma funcional, eficiente e satisfatória, com bom potencial para aprendizado de formas tridimensionais. Em uma escala simples para medir a usabilidade, a plataforma Math City obteve uma pontuação geral de 74,54, considerada muito boa. Além disso, a IA possibilitou que os alunos pesquisassem, discutissem e produzissem conjuntamente em um mesmo ambiente, favorecendo a interação e a construção coletiva do conhecimento.

No estudo de Wang et al (2023) é apresentado o design e avaliação do jogo educativo ARIN-561 para ensinar conceitos de Inteligência Artificial. O jogo é um ambiente educativo em 3D que ensina por meio de desafios jogáveis, especialmente algoritmos de busca como BFS, DFS e greedy (formas de buscar caminhos em problemas de IA e gráficos).

A matemática entra como base para modelar os problemas, analisar caminhos e calcular a eficiência das estratégias. Assim, o aluno aprende IA aplicando cálculo matemático em situações práticas. A IA entra quando o estudante modela o problema como busca, espandindo em BFS/DFS/greedy e comparando estratégias dentro da missão. Os autores apresentam o jogo da seguinte forma:

> [...] Canto superior direito: o aluno recebe uma pergunta de questionário sobre estimar a complexidade de algoritmos de busca. Canto inferior esquerdo: o aluno pensa em voz alta sobre o algoritmo de busca gulosa. Canto inferior direito: o aluno resolve um quebra-cabeça 8 usando um dos algoritmos de busca para consertar a placa de circuito do robô companheiro (Wang et al., 2023, p. 3).

Figura 5 - Jogo ARIN-561

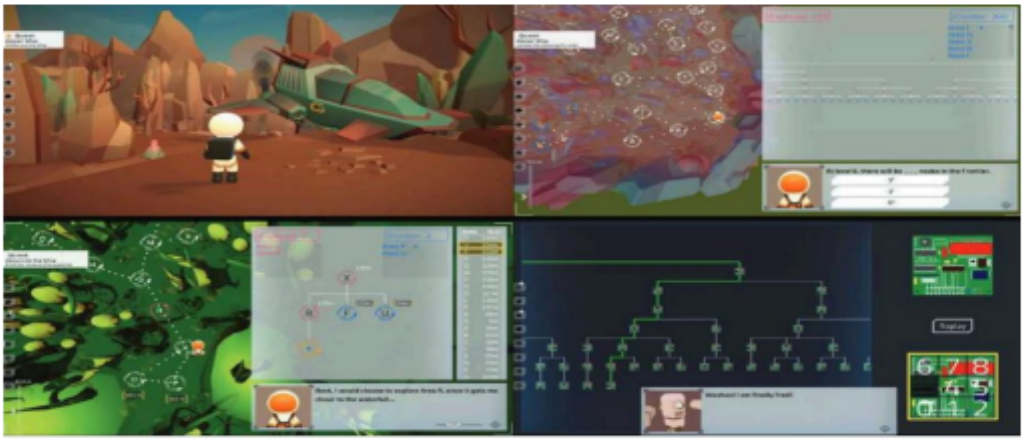

Fonte: adaptado de Wang et al., (2023)

O jogo gerou ganhos, porém pequenos, em conhecimento de AI (concentrados principalmente no BFS). Alunos com maior experiência em videogames e melhor conhecimento prévio de matemática obtiveram ganhos maiores. O jogo mostrou boa viabilidade para uso em sala de aula, mas os autores destacaram a necessidade de melhorias para suportar estudantes com diferentes níveis de matemática e reforçar o aprendizado dos algoritmos mais avançados (DFS e Greedy).

No trabalho de Nguyen et al (2018) é mostrado como a capacidade dos estudantes de tomar decisões próprias, influencia o aprendizado e o comprometimento. Os pesquisadores queriam comparar uma versão guiada (baixa agência) de um jogo denominado Ponto Decimal com outra mais livre (alta agência), para ver se dar mais escolhas ao estudante realmente traz melhores resultados.

O jogo tem uma temática em que o estudante passa por diferentes áreas e resolve operações e conceitos com números decimais. A IA atua melhor na versão mais livre , o sistema observa as escolhas do estudante e personaliza a sequência (apresenta mais ordens e quantidades). Na versão guiada, o caminho já vem mais definido; a IA tem menos espaço para adaptar. Os resultados indicaram que não houve diferenças em relação ao aprendizado, muitos estudantes acabaram jogando quase do mesmo jeito mesmo na versão com mais liberdade.

Figura 6 - Versão baixa agência vs. alta agência

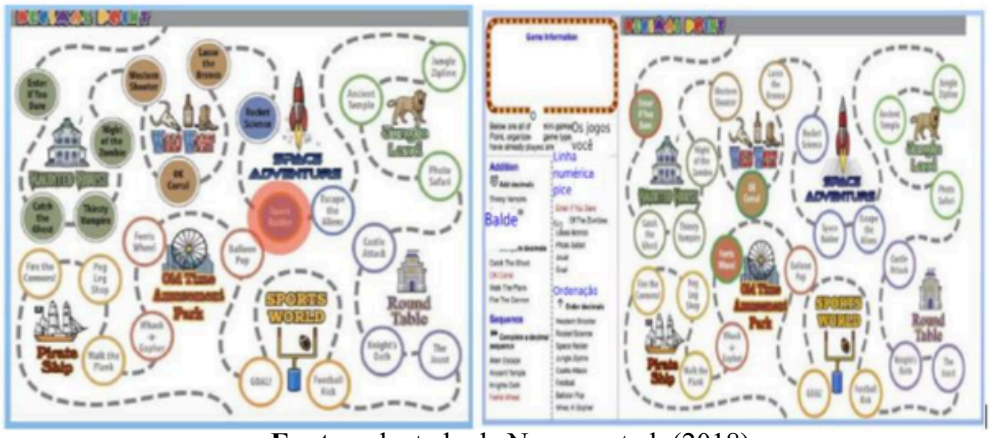

Fonte: adaptado de Nguyen et al. (2018)

No estudo conduzido por Goldstein et al (2026) não é apresentado um jogo. Entretanto, os autores analisam as necessidades dos usuários para pensar como incorporar Inteligência Artificial em jogos educacionais. O objetivo é descobrir o que os estudantes querem, para orientar o desenvolvimento de ferramentas educacionais mais úteis, transparentes e personalizadas.

Por meio de um questionário com 345 participantes, os pesquisadores descobriram que, os estudantes observam a IA como uma ferramenta complementar , não como substituta da aprendizagem, e usam principalmente para entender conceitos, pesquisar e escrever textos. Dessa forma, ao desenvolver o jogo, destacam a importância da elaboração de um bom design, sugerindo que a Inteligência Artificial deve oferecer apoio, respostas mais claras, pistas personalizadas e narrativas interativas. O estudo complementa sugerindo a implementação da IA como facilitadora narrativa dinâmica em jogos baseados em texto, reduzindo a complexidade do desenvolvimento técnico.

5. Considerações finais

Apesar dos benefícios, o uso de ferramentas pedagógicas como jogos educacionais baseados em IA deve ser tratado com cautela. É fundamental considerar as implicações éticas do seu uso, e as funções atribuídas a essa tecnologia no processo de ensino e aprendizagem, para garantir que ela seja empregada de forma responsável e coerente com os objetivos educacionais. Além disso, é importante considerar os cuidados necessários no uso da inteligência artificial nos jogos.

Em alguns casos, ela pode interromper o raciocínio dos estudantes ao sugerir ou indicar caminhos prontos, como se jogasse por eles, o que limita o desenvolvimento do pensamento, da criatividade e da intuição. Por outro lado, quando utilizada como adversário ou como apoio didático que orienta o processo sem fornecer respostas diretas, a IA pode contribuir de forma mais adequada para a aprendizagem.

Portanto, a análise dos estudos indica que a IA pode contribuir para a personalização das atividades, o apoio à resolução de problemas, o feedback e o aumento da interação dos estudantes. Contudo, os resultados mais consistentes foram observados quando a IA desempenhou uma função pedagógica delimitada, como adaptar tarefas, identificar erros, oferecer pistas ou propor desafios, sem substituir o julgamento do estudante.

Não foi possível afirmar que uma única técnica de IA seja superior em todos os contextos. Assim, a efetividade dos jogos educacionais baseados em IA depende da articulação entre tecnologia, objetivos curriculares, mediação docente e participação ativa dos estudantes.

Referências

Alicando, G. V.; Jamen, R. C.; Escasio, E. V. & Maulana, M. Exploring the potential of LLM-driven opponent in DaMath. **Procedia Computer Science**, v. 272, p. 68–75, 2025. Disponível em: https://doi.org/10.1016/j.procs.2025.10.180. Acesso em 01 de maio de 2026.

Bringula, R. P.; Atienza, F. A. L.; Mangubat, J.; Roxas, M. & Miranda, J. P. P. Impact of intelligent vs non-intelligent mCSCL on mathematics performance: A comparative study of grade 5 students. **Acta Psychologica**, v. 260, 105507, 2025. Disponível em: https://doi.org/10.1016/j.actpsy.2025.105507. Acesso em 01 de maio de 2026.

Goldstein, M.; Ahmed, I.; Yu, F.; Verma, V.; McNamara, D. & Arner, T. Characterizing user needs for GenAI incorporation in educational games. **Education Sciences**, Basel, v. 16, n. 300, 2026. DOI: https://doi.org/10.3390/educsci16020300. Acesso em 04 de maio de 2026.

Holmes, W.; Bialik, M.; Fadel, C. Artificial intelligence in education: promises and implications for teaching and learning. Boston: Center for Curriculum Redesign, 2019.

Nguyen, H.; Harpstead, E.; Wang, Y.; McLaren, B. M**. Student agency and game-based learning:** A study comparing low and high agency. In: International Conference on Artificial Intelligence in education, 2018.

OpenAI. **ChatGPT:** GPT-4o. ferramenta de inteligência artificial utilizada para apoio à revisão da linguagem. Versão de 4 de junho de 2024. [Sl]: OpenAI, 2024. IA. Disponível em: https://chat.openai.com. Acesso em: 10 de maio de 2026.

Parsifal. **Parsifal:** realizar revisões sistemáticas da literatura . Disponível em: https://parsif.al/. Acesso em: 16 de maio de 2026.

Prensky, M. O papel da tecnologia no ensino e na sala de aula. **Conjectura**, Caxias do Sul, v. 5, n. 2, p. 201-204, 2010.

Perplexy. **Perplexity AI:** ferramenta de inteligência artificial utilizada para apoio à revisão gramatical e reestruturação textual. Versão de 2026. [Sl]: Perplexidade AI, 2026. IA. Disponível em: https://www.perplexity.ai. Acesso em: 10 de maio de 2026.

Rapaka, A.; Dharmadhikari, S. C.; Kasat, K.; Mohand, C. R.; Chouhan, K. & Gupta, M. Revolutionizing learning – A journey into educational games with immersive and AI technologies. **Entertainment Computing**, v. 52, 2025. DOI: ttps://doi.org/10.1016/j.entcom.2024.100809.

Reis, D. A. dos; Negrão, F. da C. O uso pedagógico das tecnologias digitais: do currículo à formação de professores em tempos de pandemia . **Rev. FAEEBA – Educação e Contemporaneidade**, Salvador, v. 65, pág. 174-187, 2022. DOI: https://dx.doi.org/10.21879/faeeba2358-0194.2022.v31.n65.p174-187.

Ribeiro, M. J. B. & Ponte, J. P. A formação em novas tecnologias e as concepções e práticas dos professores de matemática. **Revista Quadrante**, Lisboa, v. 9, n. 2, p. 3- 26, 2000.

Singh, M.; Sol, D.; Yang, Y. Design and implementation of Math City: An inquiry-based metaverse platform for mathematics education. **Computers and Education**: Artificial Intelligence , v. 9, 2025. DOI: https://doi.org/10.1016/j.caeai.2025.100462.

Trindade, M. A. M.; Edirisinghe, G. S. & Luo, L. Teaching mathematical concepts in management with generative artificial intelligence: The power of human oversight in AI-driven learning. **The International Journal of Management Education**, v. 23, 101104, 2025. DOI: https://doi.org/10.1016/j.ijme.2024.101104.

Wang, N.; Montgomery, R.; Greenwald, E. & Leitner, M. **Design and implementation of an educational game for teaching artificial intelligence to high school students.** In: Proceedings of the 31st International Conference on Computers in Education, 2023. DOI: https://doi.org/10.1007/978-3-031-47324-6_56.

Sobre o autor(a)

Lucimara Muzykant da Silva

Mestranda em Tecnologias da Informação e Comunicação pelo Programa de Pós-graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina (UFSC).

Especialização em Didática do ensino de matemática e em Atendimento Educacional Especializado, ambos pelo Intituto Facuminas EAD (2024).

Graduada em Licenciatura em Matemática pelo Instituto Federal Catarinense - Campus Sombrio (IFC - 2023).

Professora de Matemática na rede estadual de ensino básico de Santa Catarina.

Lattes: http://lattes.cnpq.br/2399485730128760

CAPÍTULO 11

Avaliação da aprendizagem automatizada por IA na educação básica: uma revisão sistemática de literatura

Juliana Pires da Silva

1. Introdução

A difusão das tecnologias artificiais generativas no contexto educacional tem tensionado concepções tradicionais de ensino, autoria e avaliação (Gonsales, 2022), (Tang, 2024). A capacidade dessas tecnologias de gerar textos completos de diferentes gêneros; resolver problemas e apresentar respostas de certa forma coerentes desafia os modelos avaliativos centrados majoritariamente em avaliações somativas empregando questões de múltipla escolha, redação e perguntas de resposta curta (Swiecki et al., 2022).

Neste cenário, estas avaliações, tradicionalmente consideradas em muitas escolas e universidades, passam a ser questionadas, sobretudo porque elas podem ser parcialmente ou integralmente respondidas por sistemas de Inteligência Artificial (IA). Junto com isso, tem-se o uso crescente das IAs generativas pelos estudantes em atividades escolares. Entre os alunos do Ensino Médio, são sete a cada dez que recorrem à IA generativa (CGI.br, 2025).

Paradoxalmente, no mesmo cenário em que a IAs generativas desafiam práticas avaliativas tradicionais emergem pesquisas e soluções de IA que propõe utilizar a IA para suporte ao trabalho docente, especialmente na correção de avaliações e redações, geração de feedbacks, elaboração de provas, análise do desempenho estudantil, dentre outras (Swiecki et. al, 2022), (Li et al, 2025) (Martínez-Comesaña et al., 2023).

Embora, essas aplicações apresentem potencial para reduzir a carga de trabalho docente e aumentar o feedback aos alunos, ainda persistem questionamentos sobre a validade da aprendizagem, confiabilidade, vieses algorítmicos e distanciamento pedagógico do ato avaliativo (Swiecki et. al, 2022).

Diante disso, este artigo visa identificar tendências, aplicações e limitações sobre avaliação automatizada por IA na Educação Básica na literatura recente por meio de

uma revisão sistemática de literatura. Para alcançar este objetivo, tem-se as seguintes perguntas norteadoras: Q1) Quais soluções de avaliação automatizada por IA estão sendo propostas nos estudos para a Educação Básica? Q2) Quais os objetivos dos estudos? Q3) Quais concepções de avaliação sustentam estes trabalhos? Q4) Quais resultados emergem desses trabalhos? E, por fim, Q5) Quais limites éticos e pedagógicos aparecem? Estudos de Tang et al. (2024) justificam a pesquisa, uma vez que apontam que há pouca literatura sobre a aplicação da IA generativa na avaliação em escolas de ensino fundamental.

Espera-se com esta revisão contribuir para as pesquisas na interface Tecnologias de IA e Educação que problematizam os novos papéis de docentes e estudantes na era da IA como sujeitos ativos e centrais em qualquer abordagem tecnológica. Para fins de leitura, este artigo está estruturado da seguinte forma, na seção 2 apresenta-se o referencial teórico sobre avaliação assistida por IA com implicações para a prática pedagógica. Na seção 3 explicita-se os caminhos teórico-metodológicos adotados. Na seção 4 discute-se os artigos encontrados à luz do referencial e das perguntas de pesquisa. Por fim, encerra-se a discussão com as conclusões e limitações da pesquisa.

2. Referencial teórico

Uma das principais funções do professor é avaliar a aprendizagem dos estudantes. Geralmente esta avaliação compreende o processo de verificação do conhecimento, habilidades, competências e atitudes do aluno por meio de diferentes instrumentos e métodos, como testes escritos, orais, trabalhos em grupos, rubricas, observações de comportamento.

Grande parte destas práticas avaliativas estão centradas em avaliações somativas, tendo como instrumento provas escritas para medir o conhecimento dos estudantes. Elas atuam como flashs, retratando pontualmente o que os estudantes responderam naquele instante, o que não diz muito sobre os detalhes da aprendizagem deles. (Swiecki et. al, 2022).

Para Swiecki et. al, (2022), com base em Vigotski e Cole (1978), a aprendizagem é definida como uma mudança nas representações mentais do que se consegue fazer com a ajuda de outrem do que se consegue fazer sozinho levando a processos novos de adaptação. Então, é necessário que a avaliação consiga diagnosticar essas transformações dos conhecimentos prévios do estudante com a de novos conhecimentos. “ [...] se não temos noção de mudança, não temos noção de aprendizagem.”(Swiecki et. al, 2022, p. 02, tradução nossa). Logo, utilizar unicamente avaliações pontuais impossibilita averiguar ganhos de aprendizagem.

Ainda, citando o mesmo trabalho, Swiecki e outros de 2022, tecem críticas ao modelo tradicional de avaliação alegando que apresentam vários problemas. Além do

já citado nos parágrafos anteriores, sobre avaliações pontuais, eles também as caracterizam como onerosas, inautênticas e antiquadas. Por onerosas, entende-se o trabalho manual de correção de trabalhos e provas que pode levar a erros e percentuais de subjetividade no julgamento avaliativo, além de toda a carga de trabalho dos docentes, como detalhado no trecho a seguir:

> A avaliação é apenas uma parte da prática do educador em sala de aula. Ele também planeja e conduz atividades de aprendizagem, fornece feedback e, de forma mais geral, gerencia a cultura da sala de aula. Dependendo do número de alunos, das outras responsabilidades do educador e do nível de apoio disponível, o planejamento manual de avaliações e a inferência a partir delas podem ser trabalhosos e potencialmente propensos a erros (Swiecki et al., 2022, p.01, tradução nossa).

Outra característica apontada pelos autores é que as avaliações geralmente são iguais para toda a turma independentes de suas habilidades, experiências e origens escolares, o que segundo Gipps e Stobart (2009) apud Swiecki et. al (2022) acaba por trazer vieses no resultado, tendo em vista que nem os estudantes terão oportunidades iguais de demonstrarem as suas aprendizagens (Swiecki et. al (2022). Também alegam que as avaliações, especialmente, as baseadas em redação podem ser inautênticas.

Isso porque fora do ambiente escolar o processo de escrita é colaborativo com pesquisas e utilização de ideias de terceiros; uso de processadores de textos que possuem corretores ortográficos, de gramática e até sugestões de frases; compartilham esboços e recebem sugestões de revisão diferentemente do ambiente escolar que a escrita de redações acaba sendo isolada sem acessos a tais auxílios (Swiecki, et. al (2022). Por fim, os autores retratam as avaliações como frequentemente antiquadas por avaliarem habilidades, dependendo do nivel educacional e objetivos esperados, que estão se tornando obsoletas, por exemplo, avaliar cálculos que podem ser feitos por uma calculadora (Swiecki, et. al (2022).

Estas caracterizações do modelo padrão de avaliação são ainda, em grande parte, os existentes na cultura escolar (Swiecki et. al (2022). Em tempos de IA, muitas aplicações estão sendo desenvolvidas e no campo da avaliação, a IA pode causar rupturas e transformação tanto benéficas quanto problemáticas (Li et al, 2026).

> A avaliação habilitada por IA utiliza artefatos e processos drasticamente diferentes das avaliações tradicionais... De fato, a IA pode significar o abandono e a substituição das avaliações tradicionais e, com isso, uma transformação nos processos educacionais (Cope, Kalantzis; Searsmith, 2021 apud Swiecki, et. al, 2022, p. 02, tradução nossa).

Considerando esse cenário, há algumas aplicações de IA nos processos avaliativos, como: construção de questões, avaliação assistida por pares; correção de redações; avaliação de comportamento estudantil; plataformas avaliativas; learnig analytics nos processos avaliativos; *computerized adptive testig* (CAT) e avaliação automatizada de redações e questões, que buscam atacar os problemas anteriores citados (Li et al., 2025; Henkel et al., 2025; Swiecki et al., 2025; Krange et al., 2023).

Com relação à construção de questões, modelos generativos de IA como ChatGPT-4, entre outros, são promissores para criação de questões de diferentes formatos e abordagens podendo gerar textos, exercícios ou problemas para alunos com diferentes níveis de proficiência ampliando a variedade de materiais (Jindaduang; Junpeng & Intharah, 2025; Bottentuit Jr., 2024; Vicari, et al., 2023).

Também as plataformas eletrônicas de avaliação possibilitam a aplicação de exames online e offline. Nestas plataformas é possivel utilizar de multimidias, como videos, que no papel seriam impossíveis, assim como, ter possibilidades de questões aleatórias ou não e, ainda, a capacidade de fornecer feedbacks rápidos. Também nesses ambientes são incorporadas técnicas de IA que coletam dados enquanto os estudantes interagem com a plataforma (Swiecki et. al, 2022). Já as avaliações automatizada por IA prometem desafogar os docentes do trabalho da correção, eliminar erros e subjetividades e fornecer feedbacks rápidos. De todo modo, toda facilidade deve ser recebida com atenção.

Swiecki et. al (2022) relata que as primeiras avaliações automatizadas foram concebidas para a correção de redações. Nos anos de 1966, o professor *Ellis Batten Page* com o trabalho pioneiro intitulado *The imminence of grading essays by computer*, introduziu a ideia de corrigir redações com o uso do computador.

Com o passar do tempo e os avanços das últimas duas décadas, tem-se a passagem das primeiras implementações de sistemas automatizados de correção de provas com foco em avaliações objetivas, como as de questões de múltipla escolha, que podem ser verificadas com relativa facilidade por algoritmos predefinidos, até as implementações com IA para questões abertas, redações, processamento da notação matemática, variedade linguística intercultura. Estas últimas ainda representam os maiores desafios (Li et al., 2025).

O uso de modelos generativos parecem ser promissores para automatização de tarefas de avaliação e o fornecimento de feedback. Mas ainda está em seus estágios iniciais, quando considera-se a evolução desses modelos e as poucas pesquisas voltadas ao público da educação básica, às peculiaridades de cada disciplina escolar e de cada domínio linguístico regional (Li et al., 2025). Quanto aos desafios, tem-se o fato de que a IA às vezes fornece avaliações menos precisas/contextualizadas, uma vez que não conhece os alunos; que professores e alunos podem não ter letramento em IA pra uso adequado (Burner; Lindvig; Waerness, 2025); que os professores podem sentir

que sua expertise profissional está sendo desconsiderada e prejudicada quando o julgamento final sobre a nota do estudante é delegado para a IA.

Nesse sentido, se os docentes, devido à turmas grandes e pouco tempo, considerarem o resultado da avaliação feita pela IA correto automaticamente pode levar a preocupações com relação à capacidade da tomada de decisão do professor que perderia o tato à medida que o distancia das análises das provas que deveriam ocorrer (Swiecki et al., 2022). Inclusive, prejudicando o conhecimento das dificuldades da turma ficando dependente da tecnologia. Isso reverbera até na reflexão da própria prática pedagógica.

Outros desafios aparecem com relação à responsabilidade pelas avaliações. Como coloca Swiecki et al. (2022), retirar do docente a responsabilidade pela modelagem e confecção da avaliação, por um lado, pode ser vista como bom, porque evita os vieses dos docentes, mas por outro levanta preocupações sobre as intenções e vieses de terceiros (desenvolvedores e engenheiros) que desconhecem os estudantes que estão sendo avaliados. Assim, deve haver uma rigorosa supervisão da avaliação concebida e estabelecimentos de regras explicitas de com estas IAs chegaram a composição da nota.

Além disso, há um problema de vigilância de dados dos docentes e estudantes. Também se pode questionar se a IA consegue avaliar de forma holística, em vez de avaliar uma quantidade limitada de conhecimento (Swiecki et al., 2022). Por fim, importante destacar que avaliação baseada em IA *"[...] não é um espaço neutro onde qualquer forma de aprendizado será detectada e avaliada"* (Swiecki et al., 2022, p 07, tradução nossa).

Um dos desdobramentos disso, significa que qualquer instância avaliativa inevitavelmente embutirá normas e valores que podem refletir na postura do aluno diante da prova. Ao invés de estudar para a prova, que antes tinha um contrato didático conhecido, agora deve-se estudar e aprender a se comportar conforme maneiras que sejam avaliadas e recompensadas algoritmicamente.

3. Caminhos metodológicos

Para responder ao objetivo da pesquisa, adota-se como metodologia a revisão sistemática de literatura (RSL), entendida como um método rigoroso e replicável, em que explicita-se o processo de identificação, seleção, coleta de dados, análise e descrição sob um conjunto de estudos primários e originais gerando sínteses e novos conhecimentos, (Lopes et al., 2019) baseado no método Systematic Search Flow (SSF) desenvolvido por Ferenhof e Fernandes (2016). Este método busca sistematizar o processo de busca à bases de dados, a fase de seleção e síntese dos artigos ajustando

as etapas às características desta pesquisa, garantindo assim a replicabilidade da pesquisa e a diminuição de possíveis vieses das pesquisadoras (Ferenhof; Fernandes, 2016).

A metodologia SSF é composta por quatro fases: a primeira fase compreende a elaboração do protocolo de pesquisa, a qual é composta por cinco atividades, a saber: 1) definição da estratégia de busca; 2) consultas nas bases de dados; 3) organização do portfólio; 4) definição dos critérios de seleção dos documentos; e 5) composição do portfólio bibliográfico. Na segunda fase (atividade seis), o pesquisador parte para a consolidação dos dados apurados na primeira fase, buscando vasculhar os resultados obtidos realizando análises bibliométricas. A terceira fase (atividade sete), destina-se a sintetizar e sistematizar os conhecimentos mais relevantes obtidos com a análise dos documentos. A quarta e última fase, se refere à consolidação dos dados, encerrando-se com a atividade 8 que é a redação do trabalho (Ferenhof; Fernandes, 2016) (Lopes et al., 2019).

Importante destacar que nesta pesquisa, toma-se como base o método SSF, entretanto algumas etapas foram ajustadas resultando na organização e discussão a seguir.

Quadro 1 - Protocolo de Pesquisa

Fase 1 - definição do protocolo de pesquisa	
Atividade 1 Estratégia de busca	A estratégia de busca elaborada utilizou as seguintes combinações de termos em inglês com objetivo de abarcar estudos nacionais e internacionais: artificial intelligence OR machine learning OR deep learning OR generative AI OR generative artificial intelligence OR large language model OR automated scoring OR automated assessment AND educational assessment OR student assessment OR assessment of learning OR essay scoring OR formative assessment AND primary education OR secondary education OR elementary education OR middle school OR high school OR basic education OR ensino fundamental OR ensino medio OR educação básica. Como critério de inclusão e exclusão, adotou-se: 1. Selecionar artigos que contivessem, no título, abstract ou no corpo do texto os termos desta pesquisa. 2. Artigos completos abertos disponíveis ou enviados diretamente pelos autores. 3. Língua: inglês, espanhol e português. 4. Período: últimos cinco anos (2020 a 2025) 5. Revisado por pares. 6. Exclusão de artigos puramente teóricos ou com desenvolvimentos de soluções sem aplicações empíricas com estudantes da Educação Básica.

continua

continuação

Atividade 2 Consulta em bases de dados	7. Exclusão daqueles que não tratam de avaliação (criação/correção) automatizada por IA como foco principal. 8. Exclusão de revisões sistemáticas. As bases de dados escolhidas foram a Scopus, Web of Science, IEEE Xplore e Scielo Brasil (posteriormente adicionada para abarcar o contexto brasileiro). As querys de pesquisa foram montadas em cada base, conforme descrito abaixo, de maneira a recuperar os termos selecionados nos campos de título, resumo e palavras-chave. A busca ocorreu em 08 de maio de 2026. • **Scopus:** (TITLE-ABS-KEY ("a*rtificial intelligence" OR " generative artificial intelligence" OR "machine learning" OR "deep learning" OR "generative AI" OR "generative artificial intelligence" OR "large language model*" OR "automated scoring" OR "automated assessment") AND TITLE-ABS-KEY ("educational assessment" OR "student assessment" OR "learning assessment" OR "assessment of learning" OR "essay scoring" OR "formative assessment") AND TITLE-ABS-KEY ("primary school" OR "primary education" OR "secondary school" OR "secondary education" OR "elementary education" OR "middle school" OR "Sixth Form" OR "high school" OR "basic education" OR* "ensino fundamental" *OR* "ensino medio" *OR* "educação básica")) *AND (LIMIT-TO (DOCTYPE , "ar")) AND (LIMIT-TO (LANGUAGE , "English") OR LIMIT-TO (LANGUAGE , "Spanish")) AND (LIMIT-TO (OA , "all")) AND (LIMIT-TO (PUBSTAGE , "final")) AND (LIMIT-TO (SUBJAREA, "PSYC") OR LIMIT-TO (SUBJAREA , "SOCI") OR LIMIT-TO (SUBJAREA , "COMP") OR LIMIT-TO (SUBJAREA , "MULT") OR LIMIT-TO (SUBJAREA , "DECI") OR LIMIT-TO (SUBJAREA, "ENGI") OR LIMIT-TO (SUBJAREA , "MATH")) AND PUBYEAR > 2019 AND PUBYEAR* < 2024. Foram recuperados 32 documentos. • **WoS:** (*("artificial intelligence" OR "machine learning" OR "deep learning" OR "generative AI" OR "generative artificial intelligence" OR "large language model*" OR "automated scoring" OR "automated assessment")) (All Fields) and (("educational assessment" OR "student assessment" OR "learning assessment" OR "assessment of learning" OR "essay scoring" OR "formative assessment")) (All Fields) and (("primary school" OR "primary education" OR "secondary school" OR "secondary education" OR "elementary education" OR "middle school" OR "Sixth Form" OR "high school" OR "basic education" OR* "ensino fundamental" *OR* "ensino medio" *OR* "educação básica")) *(All Fields) and Open Access and Article (Document Types) and Enriched Cited References and All Open Access (Open Access)*. Foram encontrados 19 trabalhos. • **IEEE:** Todos os metadados: (*"artificial intelligence" OR "machine learning" OR "deep learning" OR "generative ai" OR "generative artificial intelligence" OR "large language model*" OR "automated scoring" OR "automated assessment") AND ("educational assessment" OR "student assessment" OR*

continua

	- *"learning assessment" OR "assessment of learning" OR "essay scoring" OR "formative assessment") AND ("primary education" OR "secondary education" OR "secondary school" OR "elementary school" OR "middle school" OR "high school" OR "sixth form" OR "basic education" OR "ensino fundamental" OR* "ensino medio" OR "educação básica"). Foram achados 92 trabalhos. Aqui, inclui-se os artigos completos publicados em eventos, devido à escassez de resultados que seriam apenas 7 trabalhos. • **Scielo Brasil:** (("inteligência artificial" *OR* "IA" *OR* "inteligência artificial generativa" *OR* "IA generativa" *OR* "IAGen" *OR* "sistemas inteligentes" *OR* "aprendizagem de máquina" OR "machine learning" OR "algoritmos inteligentes" *OR* "*chatbot*" *OR* "*chatbots* educacionais" *OR* "modelos de linguagem" *OR* "grandes modelos de linguagem") *AND* ("avaliação automatizada" *OR* "avaliação automática" *OR* "correção automática" *OR* "correção automatizada" *OR* "feedback automatizado" OR "feedback inteligente" OR "avaliação adaptativa" *OR* "avaliação assistida por IA" *OR* "correção de redações" *OR* "análise automática de desempenho" *OR* "avaliação formativa automatizada" *OR* "sistemas de avaliação inteligente" *OR* "mensuração educacional automatizada") *AND* ("educação básica" *OR* "ensino fundamental" *OR* "ensino médio" *OR* "escola" *OR* "educação escolar" *OR* "ensino regular" *OR* "rede pública de ensino" *OR* "BNCC" *OR* "alunos da educação básica" *OR* "professores da educação básica" *OR* "contexto escolar brasileiro")). Foram encontrados 2 trabalhos. A busca foi realizada em 30 de julho de 2026.
Atividade 3 Organização das bibliografias	Para a organização dos dados, importou-se os arquivos para o gerenciador de referências Zotero e fez-se um trabalho de verificação de duplicatas. Dos 145 trabalhos, restaram 133 para a etapa seguinte.
Atividade 4 Seleção padronizada dos artigos	Esta fase compreendeu a leitura dos títulos, resumos (abstract) e palavras-chave de cada um dos artigos, tendo sido selecionados aqueles que contivessem aderência ao tema de pesquisa. Esta parte foi feita dentro do Ryyan.Ai. Ao realizar esta filtragem, restaram 42 artigos. Uma segunda filtragem foi realizada fazendo a leitura completa dos artigos, visando manter somente documentos aos quais se conseguiu acesso ao texto integral de forma gratuita. Assim, nesta etapa chegamos ao número de 22 artigos.
Atividade 5 Composição do portfólio	Nesta atividade, os artigos foram lidos na íntegra de forma a realizar um novo filtro, evitando que publicações desalinhadas ao objetivo da pesquisa compusessem o portfólio final. Nesta fase, foram eliminados 14 artigos, chegando ao total de 8 artigos no portfólio final.

Fonte: elaborado pela autora (2026)

As atividades realizadas resultam no portfólio final e o número de documentos recuperados em cada etapa pode ser verificado no quadro 2.

Quadro 2 - Atividades e número de documentos recuperados

Atividade	Total
Busca nas baseas	145 (92 resultados na IEEE, 32 na Scopus, 19 na Web of Science e 2 na Scielo)
Excluindo documentos duplicados	12
Primeiro filtro (leitura dos títulos, resumos e palavras-chave)	42
Texto completo de acordo com os critérios de inclusão e exclusão	22
Portifólio final	8

Fonte: elaborado pela autora (2026)

Desse modo, o portfólio final foi composto por 8 trabalhos, conforme apresentados no Quadro 3.

Quadro 3 - Relação dos trabalhos encontrados

Autores	Título	Ano
Ade-Ibijola, A.; Chikezie, I.J. & Oyelere, S.S.	*Human vs. Machine Marking: A Comparative Study of Chemistry Assessments*	2025
Alsulami, S.; Alsubhi, A. & Alabdli, A.; Alafif, T.; Jassas, M. & Albishre, K.	*Towards Automatic Arabic Test Scoring: Leveraging ChatGPT for Prompt Design*	2025
Henkel, O.; Horne-Robinson, H.; Dyshel, M.; Thompson, G.; Abboud, R. Nahin C. N. A.; Moreau-Pernet, B. & Vanacore, K.	*Learning to Love LLMs for Answer Interpretation: Chain-of-Thought Prompting and the AMMORE Dataset*	2025

continua

continua

Jaramillo, J. J.; Chiappe, A. & Delgado, F. S.	*From Struggle to Mastery: AI-Powered Writing Skills in ESL Education*	2025
Khan, S.; Liow, W. T. & Kee Ang, L.	*Human or AI? Comparing Design Thinking Assessments by Teaching Assistants and Bots*	2025
Li, X.; Zappatore, M.; Li, T.; Zhang, W.; Tao, S. Wei, X.; Zhou, X.; Guan, N. & Chan, A.	*GAI Versus Teacher Scoring: Which is Better for Assessing Student Performance?*	2025
Krange, I.; Segaran, M.; Gamlem, S.; Moltudal, S. & Engeness, I.	*A Triple Challenge: Students' Identification, Interpretation, and Use of Individualized Automated Feedback in Learning to Write English as a Foreign Language*	2023
Sachete, A. S.; Loiola, A. V. S. F.; Pereira, A. M.; Rossi, F. D. & Gomes, R. S..	EnemIA: correção de redações do Enem com Inteligência Artificial	2025

Fonte: elaborado pela autora (2026)

4. Análise e Discussão dos Resultados

Na segunda fase (atividade seis) do método SSF, apresenta-se a análise bibliométrica.

4.1 Análise Bibliométrica

Do corpus de 8 trabalhos recuperados, a maior parte deles concentra-se no ano de 2025 com 7 publicações, o que corresponde a 87% dos trabalhos encontrados. Isso mostra uma tendência da evolução dos trabalhos nos últimos anos relacionados com avaliação e IA podendo ser ocasionado pela evolução e popularização de modelos generativos e das discussões em torno de diminuir a sobrecarga de trabalho docente (Swiecki et. al, 2022).

Com relação à área de atuação, dos 38 pesquisadores envolvidos, 13 são oriundos de departamentos e Centros de Educação, o que demonstra equipes multidisciplinares das áreas das tecnologias e educação trabalhando conjuntamente. Já no que tange às publicações, não há prevalência de um periódico ou evento que tenha publicado mais sobre o assunto nos termos desta pesquisa: (1 artigo) Interaction Design and

Architecture(s); (1 artigo) Applied Sciences; (1 artigo) Texto Livre; (1 artigo) IEEE Transactions on Learning Technologies; (1 artigo) IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALE); (1 artigo) Journal Of Science Education And Technology; (1 artigo) Journal of Learning Analytics e (1 artigo) 8th International Conference on Data Science and Machine Learning Applications (CDMA).

Quanto às origens das instituições dos pesquisadores, 39% da região euro-america, 32% da região asiática, 21% da região sul-americana e 8% da região africana. Destes, observa-se trabalhos conjuntos entre países evidenciando parcerias de pesquisa na área de avaliação automatizada por IA. Ainda, percebe-se uma concentração de pesquisadores do norte-global e asiáticos. Por fim, a terceira fase e quarta fase (atividade sete e oito), depois de sintetizar e sistematizar os conhecimentos mais relevantes obtidos para responder as perguntas norteadoras, chega-se aos resultados encontrados a seguir.

4.2 Modelos generativos como soluções de IA voltadas a avaliação para a Educação Básica

Com o objetivo de identificar tendências, aplicações e limitações do uso da avaliação automatizada no âmbito da Educação Básica, a primeira pergunta norteadora desta revisão buscou compreender quais soluções de IA têm sido propostas na literatura recente para avaliação automatizada. Os estudos analisados revelam um cenário de aplicações de modelos generativos de linguagem (LLMs), sendo identificados seis trabalhos que utilizam diretamente IA generativa em processos avaliativos.

Henkel et al. (2025) apresentam o Rori, um tutor educacional de matemática que responde via WhatsApp, utilizado por estudantes africanos do Ensino Fundamental e Médio. Os dados gerados pela interação com o Rori resultaram em 53.000 pares de perguntas e respostas abertas de matemática. No estudo, os autores testaram técnicas de prompt: o zero-shot, few-shot e Chain-of-Thought (CoT) para interpretar e corrigir questões abertas em matemática. Eles constataram que o prompt CoT conseguiu orrigir corretamente 96% dos casos elevando a acurácia do GPT-4 para 97% tornando os LLMs usando a CoT potencialmente valiosos na correção de questões abertas em matemática.

Já, Alsulami et al. (2025) propõem o sistema web AutoGrader, que utiliza ChatGPT e o algoritmo Frequência de Termos e Frequência Inversa de Documentos (TF-IDF) para comparar respostas dos estudantes com respostas geradas pela IA, automatizando a correção e fornecendo feedback rápido sem intervenção humana. Os testes aplicados com estudantes tiveram uma taxa de acerto de 85%, considerada pelos autores como

eficiente.

Li et al. (2025) descrevem um assistente de ensino personalizado baseado em IA generativa para automatizar correções e fornecer feedback formativo em contextos de educação online. A base de treinamento escolhida foram disciplinas de matemática, inglês, contabilidade e estudos linguísticos por apresentarem diferentes formatos de avaliação, como perguntas de respostas curtas, gráficos e diagramas, redação e avaliação bilingue. Os autores compararam as respostas dos modelos ChatGPT-4, ChatGPT4o e Trained-GPT com a de professores. O estudo concluiu que os modelos generativos fornecem avaliações relativamente estáveis. O modelo Trained-GPT se destacou por sua consistência superior em todas as disciplinas. Esses resultados enfatizam o potencial do Trained-GPT como uma ferramenta confiável para avaliar diversas disciplinas acadêmicas.

O trabalho de Sachete et al. (2025) apresenta um tecnologia para apoiar docentes na correção de redações com foco na preparação de estudantes brasileiros para o Exame Nacional do Ensino Médio (ENEM). A análise é feita com modelo generativo da OpenAi. O sistema faz sugestões com base nas competências cobradas pelo exame, mas não emite pontuação. Os autores indicam que o EnemIA é uma alternativa eficaz para auxiliar na correção das redações com significativa melhoria na precisão e na agilidade das correções.

Contudo, também esclarecem que a tecnologia não considerou questões, como rasuras, desenhos nas provas nesta implementação. Por fim, reforçam a tese de que o julgamento humano é primordial. “Embora contribua para reduzir a sobrecarga dos docentes, seu uso deve ser cauteloso, a fim de garantir que complemente e fortaleça a avaliação pedagógica, sem substituí-la” (Sachete et al., p. 13, 2025).

Outros estudos, junto com a avaliação automatizada também trouxeram soluções voltadas ao feedback formativo e ao acompanhamento da aprendizagem. Krange et al. (2023) apresentam um sistema automatizado de avaliação/correção de redações com IAs em inglês como língua estrangeira que busca incutir a avaliação formativa, estimular a reflexão sobre os erros linguísticos e o processo de escrita. Este sistema engloba perspectiva de avaliação formativa exigida na Era da IA, como apresentado por Swickie et al., (2025) diferentemente de estudos que propõem soluções de IA, mas não discutem a necessidade de novas abordagens avaliativas.

4.3 Avaliação formativa: uma abordagem no uso dos modelos generativos

Com relação às abordagens avaliativas, grande parte dos trabalhos (Khan; Liow ;Kee Ang, 2025), (Henkel et al.,2025), (Krange, 2023), (Jaramillo;Chiappe;Delgado, 2025), (Li et. al, 2025) buscam integrar as tecnologias de IA pautadas na avaliação formativa. Esta entendida por Henkel et al., (2025) como avaliação processual da

aprendizagem ocorrendo de modo sistemático e baseada em diálogos entre professor e aluno com avaliações contínuas; feedbacks para revisão e melhoria; desenvolvimento de postura ativa de como aprender e mediação pedagógica colaborativa.

Segundo Krange (2023, p.39, tradução nossa) "[...] envolver os alunos ativamente nas atividades de avaliação é percebido como um fator que promove a aprendizagem quando os alunos são colocados no centro de sua jornada educacional[...]" isso orienta métodos de como integrar as tecnologias de IA sendo a centralidade, supervisão e colaboração humanas essenciais.

Os estudos mostram a tendência de integrar a IA aos processos avaliativos exigindo novas formas de colaboração, participação de estudantes e docentes nos processos educativos. A avaliação formativa nesses trabalhos traz consigo a necessidade de feedbacks formativos e conhecimento das dificuldades dos estudantes. Para Henkel et. al, (2025) a avaliação é compreendida sob um viés formativo. Privilegiam-se questões abertas, em vez de múltipla escolha para capturar com mais riqueza o processo de construção do conhecimento e resolução de problemas dos alunos, ampliando as possibilidades de uso dos modelos generativos para além de avaliações somativas e de múltipla escolha (Swiecki et al., 2025).

Um exemplo é o trabalho de Jaramillo, Chiappe e Delgado (2025) que utilizam uma abordagem inovadora para educadores que buscam integrar a IA na avaliação formativa, no feedback em tempo real e nos ciclos iterativos de revisão dentro de uma pedagogia envolvendo IA. A intervenção ocorreu com alunos do 10o ano de uma escola na Colômbia, Equador. Constou de 6 oficinas mediadas pelos docentes, utilizando o Modelo Instruccional de Oficina de Escrita (WWIM) com o uso do Grammarly e do ChatGPT. Os modelos generativos permitiram que os alunos se envolvessem em escrita autorregulada, refinando iterativamente seus textos em múltiplas versões.

Também foi encontrado no trabalho de Ade-Ibijola, Chikezie e Oyelere (2025), desenvolvido com 30 alunos do Ensino Médio do estado de Abia, Nigéria, que defende que o conhecimento é desenvolvido por meio de interações sociais e que a aprendizagem ocorre dentro da Zona de Desenvolvimento Proximal (ZDP) através do suporte pedagógico, o que leva a classificar a abordagem dentro de uma perspectiva sociointeracionista.

4.4 Necessidade de modelos híbridos: IA + supervisão docente

Diante dos objetivos traçados nesta pesquisa, percebe-se um interesse dos pesquisadores em avaliar ou testar ferramentas que usam modelos generativos em comparação com correções humanas, como os de (Alsulami et al.,2025), (Ade-Ibijola; Chikezie; Oyelere (2025). Outras ainda querem testar os modelos generativos diante

de correções a questões abertas, especialmente, de matemática que exige demonstração do raciocínio e notação simbólica (Henkel et. al, 2025), (Li et. al,2025). Ou ainda avaliar se é viável um modelo de correção automática sem intervenção humana como no caso do (Alsulami et al.,2025) .

Os resultados encontrados convergem para a necessidade de modelos híbridos de avaliação, integrando eficiência computacional e supervisão pedagógica humana. Em Khan, Liow e Kee Ang (2025), por exemplo, a comparação entre avaliações realizadas por GPT-4 e por assistentes humanos em atividades de Design mostrou que os professores reconheceram o potencial da IA para apoiar feedbacks formativos, mas ainda preferiram avaliações humanas em grande parte das amostras devido às dificuldades da IA em interpretar criatividade e raciocínio visual. De forma semelhante, Ade-Ibijola, Chikezie e Oyelere (2025) identificaram que, embora o ChatGPT tenha potencial para correção automatizada de questões discursivas curtas de química, seu desempenho ainda é menos consistente que os padrões de avaliação humana.

Os estudos também evidenciam que a mediação docente permanece central nos processos avaliativos apoiados por IA. Jaramillo, Chiappe e Delgado (2025) demonstraram resultados positivos no desenvolvimento da escrita em inglês a partir de um modelo híbrido que integrou Grammarly, ChatGPT e oficinas mediadas por professores. Segundo os autores, a IA contribuiu para revisões iterativas e feedback imediato, enquanto a intervenção docente favoreceu reflexão crítica, consciência e aprendizagem colaborativa.

Na mesma direção, Henkel et al. (2025) apontam que abordagens baseadas em LLMs e técnicas como Chain-of-Thought (CoT) são promissoras para lidar com diferentes formatos de respostas matemáticas, mas defendem que os modelos generativos sejam utilizados principalmente em casos que demandem interpretação aberta, mantendo sistemas determinísticos para respostas mais previsíveis.

Li et al. (2025) observaram que modelos treinados especificamente para avaliação, como o Trained-GPT, alcançaram níveis elevados de precisão e consistência, aproximando-se das avaliações humanas. Entretanto, os autores reforçam que a IA deve atuar como suporte ao trabalho docente, e não como substituição integral da avaliação humana.

Enfim, os estudos apontam que, embora a IA generativa apresente potencial significativo para automatizar correções, gerar feedbacks rápidos e ampliar processos de personalização da aprendizagem, persistem limitações relacionadas à interpretação contextual, variabilidade das respostas, subjetividade, criatividade e diversidade linguística das respostas estudantis. Assim, os estudos encontrados nesta revisão sistemática apontam que o caminho são modelos híbridos que combinam modelos generativos com supervisão e mediação pedagógica humana.

4.5 Limites éticos e pedagógicos

Os estudos analisados evidenciam que, embora a IA apresente potencial para apoiar processos avaliativos, persistem importantes limitações éticas e pedagógicas relacionadas à validade, confiabilidade, injustiça avaliativa e interpretação do contexto das respostas estudantis. Parte dessas limitações está associada aos próprios dados de treinamento dos modelos generativos, majoritariamente desenvolvidos a partir de bases em língua inglesa e alinhados a determinados contextos culturais. Ade-Ibijola, Chikezie e Oyelere (2025) apontam que os modelos de IA necessitam de adaptações adicionais para se alinharem aos critérios de correção das escolas secundárias nigerianas.

De forma semelhante, Alsulami et al. (2025), Jaramillo, Chiappe e Delgado (2025) e Li et al. (2025) identificaram dificuldades relacionadas à avaliação de estudantes da Arábia Saudita, Colômbia e China, respectivamente, indicando problemas de vieses linguísticos e culturais que podem comprometer grupos minoritários e gerar injustiça avaliativa (Silva, Luz e Rosa, 2026).

Outra limitação recorrente refere-se às dificuldades dos modelos generativos em compreender nuances da comunicação humana, raciocínios complexos e representações não padronizadas. Alsulami et al. (2025) destacam que o ChatGPT-4.0, em alguns casos, apresentou respostas ilógicas ou inadequadas por falta de conhecimento contextual. Em Henkel et al. (2025), observou-se que os LLMs ainda apresentam falhas no raciocínio matemático, variabilidade frente a diferentes símbolos e tendência à geração de falsos negativos, isto é, indicar respostas corretas como incorretas.

Os autores ressaltam que respostas elaboradas de maneira original, regional ou não padronizada podem ser penalizadas injustamente, além da própria natureza probabilística dos LLMs produzir inconsistências avaliativas, em que diferentes estudantes podem receber correções distintas para respostas equivalentes. O estudo também aponta que a classificação binária entre “certo” e “errado” reduz a complexidade da aprendizagem, desconsiderando níveis intermediários de compreensão parcial.

As limitações pedagógicas também aparecem relacionadas à interpretação e ao uso do feedback automatizado pelos estudantes. Krange et al. (2023) observaram que o simples fornecimento de feedback por sistemas automatizados não garante que os estudantes consigam compreender ou aplicar as recomendações em seus processos de escrita. Os autores concluem que a mediação docente continua sendo essencial para transformar o feedback em aprendizagem significativa, assim como, Sachete et al., (2025) alertam para a necessidade de sempre avaliar as correções da IA, pois a tecnologia tende a ser mais rigorosa e “insensível” do que os avaliadores humanos.

Na mesma direção, Jaramillo, Chiappe e Delgado (2025) alertam para o risco de dependência excessiva das ferramentas de IA, o que pode comprometer o desenvolvimento do pensamento crítico e da autoria estudantil. Os autores também destacam preocupações relacionadas à apropriação de autoria e à necessidade de adaptação cultural das ferramentas de IA aos diferentes contextos educacionais.

Questões relacionadas à precisão, confiabilidade e transparência dos sistemas também foram identificadas. Khan, Liow e Kee Ang (2025) verificaram divergências significativas entre avaliações realizadas por IA e por professores, especialmente em atividades que envolviam criatividade, interpretações visuais complexas e elementos abstratos. Os autores argumentam que, embora os sistemas de IA sejam eficientes em termos de escalabilidade e velocidade, frequentemente operam de forma mecânica, sem captar nuances da expressão individual dos estudantes. Além disso, permanecem desafios relacionados à interpretação de símbolos matemáticos, esquemas de raciocínio manuscritos dos estudantes e fórmulas complexas. Os autores também apontam preocupações éticas envolvendo viés algorítmico, privacidade de dados e transparência nos processos de pontuação automatizada.

De modo geral, os estudos convergem para a compreensão de que a IA não substitui o julgamento humano, exigindo supervisão docente e regulações institucionais em sua implementação. As limitações identificadas envolvem vieses algorítmicos e linguísticos, problemas de validade e confiabilidade, alucinações dos modelos generativos, riscos à autoria e desafios relacionados à privacidade de dados.

Nesse contexto, a literatura aponta que a mitigação desses problemas depende da formação diversificada de profissionais da área de IA em temas de justiça social, ética e equidade; da ocupação de espaços de desenvolvimento tecnológicos por grupos historicamente marginalizados e, por fim, o fortalecimento do letramento em IA por parte dos docentes e discentes, garantindo uso crítico, ético e pedagogicamente intencional dessas tecnologias (Silva; Luz; Rosa, 2026).

5. Conclusões e Considerações Finais

Com o objetivo de identificar tendências, aplicações e limitações das soluções propostas na literatura recente sobre avaliação automatizada por IA, realizou-se uma revisão sistemática de literatura inspirada no método SSF. Os resultados permitiram identificar quatro eixos principais: 1) o predomínio de modelos generativos como soluções de IA voltadas à avaliação; 2) a centralidade da avaliação formativa nas aplicações encontradas; 3) a necessidade de modelos híbridos que articulem IA e supervisão docente; e 4) os limites éticos e pedagógicos associados à implementação dessas tecnologias.

Dos estudos analisados, 85% deles evidenciam um interesse crescente no uso de modelos generativos, especialmente o ChatGPT, em avaliação automatizada por IA. Observou-se que as aplicações mais recorrentes estão associadas a práticas de avaliação formativa, nas quais a IA é utilizada principalmente para ampliar feedbacks rápidos, apoiar revisões iterativas e auxiliar o acompanhamento do percurso de aprendizagem dos estudantes. Nesse cenário, a literatura aponta para abordagens pedagógicas híbridas, centradas na colaboração entre humano e IA, em vez da substituição do professor pelos sistemas automatizados.

Os resultados também indicam que os modelos híbridos podem representar uma resposta às tensões enfrentadas pelos docentes em um contexto no qual estudantes já utilizam amplamente IAs generativas em suas atividades escolares. Contudo, os estudos reforçam que a efetividade dessas soluções depende diretamente da mediação pedagógica e da supervisão humana. Assim, a formação docente para atuação em cenários mediados por IA torna-se essencial, especialmente no que se refere ao desenvolvimento do letramento crítico em IA, como defendido em Silva, Fiuza e Gioacomazzo (2026).

Este letramento deverá dar condições de discutir os limites éticos e pedagógicos, alguns encontrados nesses estudos sobre justiça avaliativa, consciência da variabilidade de respostas devido a natureza probabilísticas dos modelos generativos, vieses algorítmicos e linguísticos, problemas de validade e confiabilidade, alucinações dos modelos generativos, riscos à autoria e desafios relacionados à privacidade de dados. Como futuras pesquisas, é necessário estudos empíricos sobre a inserção de modelos pedagógicos híbridos em contextos reais de sala de aula, assim como o desenvolvimento do letramento crítico de docentes e discentes.

6. Limitações da pesquisa

Uma das limitações da pesquisa está relacionada às bases de dados escolhidas e as strings de busca que podem não ter abarcado todos os estudos da área. Os poucos trabalhos podem ser indicativos de que a pesquisa empírica voltada à Educação Básica ainda é incipiente e demanda mais estudos in loco sobre a realidade escolar, como apontado por Li et al. (2025).

7. Declaração de uso da IA

Declaramos, conforme as diretrizes do CNPq, que fizemos uso de IA Generativa na tradução dos artigos, na definição das strings de busca, assim como no apoio à leitura e compreensão. O conteúdo científico, análise de dados e interpretação dos resultados são inteiramente de responsabilidade dos autores. Todas as informações fornecidas

pela ferramenta foram cuidadosamente revisadas e validadas pelos autores, os quais temos responsabilidade sobre o conteúdo aqui presente.

Referências

Gonsales, P. **Inteligência além da Artificial:** Educar para o pensar complexo. 1. ed. São Paulo: Z Edições, 2022. 182 p.

Tang, K. S.; Cooper, G.; Rappa, N.; Cooper, M.; Sims, C. & Nonis, K. A dialogic approach to transform teaching, learning & assessment with generative AI in secondary education: a proof of concept. **Pedagogies: An International Journal**, 19(3), 493–503, 2024. DOI: https://doi.org/10.1080/1554480X.2024.2379774

CGIB. Comitê Gestor da Internet no Brasil. (2025). **Pesquisa sobre o uso das tecnologias de informação e comunicação nas escolas brasileiras:** TIC Educação 2024. Núcleo de Informação e Coordenação do Ponto BR. Disponível em: https://www.cetic.br/media/docs/publicacoes/2/pt-br/20251217165522/tic_educacao_2024_livro_completo.pdf

Swiecki, Z., Khosravi, H., Chen, G., Martinez-Maldonado, R., Lodge, J. M., Milligan, S., Selwyn, N., & Gašević, D. Assessment in the age of artificial intelligence. **Computers and Education:** Artificial Intelligence, 3, 100075, 2022. DOI: https://doi.org/10.1016/j.caeai.2022.100075

Martínez-Comesaña, M., Rigueira-Díaz, X., Larrañaga-Janeiro, A., Martínez-Torres, J., Ocarranza-Prado, I., & Kreibel, D. Impacto de la inteligencia artificial en los métodos de evaluación en la educación primaria y secundaria: revisión sistemática de la literatura. **Revista de Psicodidáctica**, 28(2), 93–103, 2023 DOI: https://doi.org/10.1016/j.psicod.2023.06.001

Bottentuit Jr., J. Inteligência Artificial na Educação: propostas pedagógicas com o ChatGPT. In: Porto, Cristiane; Santos, Edméa; Bottentuit Jr., João Batista (Orgs.). ChatGPT e outras inteligências artificiais: práticas educativas na Cibercultura. São Luís: **EDUFMA**, 2024. v.2. 133 p.

Vicari, R. M. et al. **Inteligência Artificial na Educação.** São Paulo: Novatec, 2023.

Jindaduang,T., Junpeng, P. & Intharah,T. A **qualidade do conjunto de ferramentas de pensamento crítico gerado por IA a partir de contos em inglês, Conferência Técnica Internacional de Circuitos/Sistemas, Computadores e Comunicações** (ITC-CSCC) de 2025, Seul, Coreia do Sul, 2025, pp. 1-7,DOI:10.1109/ITC-CSCC66376.2025.11137600

Burner, T.; Lindvig, Y. & Waerness, J. I. We Should Not Be Like a Dinosaur: Using AI Technologies to Provide Formative Feedback to Students. **Education Sciences**, 15(1), 58, 2025. DOI: https://doi.org/10.3390/educsci15010058

Ferenhof, H. A. & Fernandes, R. F. Desmistificando a revisão de literatura como base para redação científica: método - SSF. **Revista ACB: Biblioteconomia em Santa Catarina**, Florianópolis, v. 21, n.3, 2016. Disponível em: https://revista.acbsc.org.br/racb/article/view/1194/pdf.

Lopes, L. M. D.; Vidotto, K. N. S.; Pozzebon, E., & Ferenhof, H. A. Inovações Educacionais com o uso da Realidade Aumentada: Uma Revisão Sistemática. **Educação Em Revista**, 35, e197403, 2019. DOI: https://doi.org/10.1590/0102-4698197403.

Silva, J. P. da; Luz, P. F. & Rosa, R. A. Vieses, ilusões e decisões: até que ponto podemos confiar na inteligência artificial?. **Devir Educação**, 10(1), E-1108, 2026. DOI: https://doi.org/10.30905/rde.v10i1.1108

Silva, J. P. da; Fiuza, P. J. & Giacomazzo, G. F. IAs Generativas na Educação: o Letramento em IA e o Pensamento Crítico como caminhos possíveis para o uso consciente. **RENOTE**, 24(2), 47–58, 2026. DOI: https://doi.org/10.22456/1679-1916.153522.

Ade-Ibijola, A.; Chikezie, I., & Oyelere, S. Human vs. Machine Marking: A Comparative Study of Chemistry Assessments. **Journal of Science Education and Technology**, 34(6), 1430–1440, 2025. DOI: https://doi.org/10.1007/s10956-025-10223-2

Alsulami, S.; Alsubhi, A.; Alabdli, A.; Alafif, T.; Jassas, M. & Albishre, K. **Towards Automatic Arabic Test Scoring:** Leveraging ChatGPT for Prompt Design. In: 8th International Conference on Data Science and Machine Learning Applications (CDMA), 1–6, 2025. DOI: https://doi.org/10.1109/CDMA61895.2025.00006

Henkel, O.; Horne-Robinson, H.; Dyshel, M.; Thompson, G.; Abboud, R.; Nahin Ch, N. A.; Moreau-Pernet, B. & Vanacore, K. Learning to Love LLMs for Answer Interpretation: Chain-of-Thought Prompting and the AMMORE Dataset. **Journal of Learning Analytics**, 12(1), 50–64, 2025. DOI: https://doi.org/10.18608/jla.2025.8621

Jaramillo, J. J.; Chiappe, A. & Delgado, F. S. From Struggle to Mastery: AI-Powered Writing Skills in ESL Education. **Applied Sciences** (Switzerland), 15(14), 2025. DOI: https://doi.org/10.3390/app15148079

Khan, S.; Liow, W. T.; Kee Ang, L. Human or AI? Comparing Design Thinking Assessments by Teaching Assistants and Bots. **IEEE International Conference on Teaching, Assessment, and Learning for Engineering** (TALE), 1–8, 2025. DOI: https://doi.org/10.1109/TALE66047.2025.11346622

Krange, I.; Segaran, M.; Gamlem, S.; Moltudal, S. & Engeness, I. A Triple Challenge: Students' Identification, Interpretation, and Use of Individualized Automated Feedback in Learning to Write English as a Foreign Language. **Interaction Design and Architecture(s)**, (59), 37–61, 2023. DOI: https://doi.org/10.55612/S-5002-059-001

Li, X.; Zappatore, M.; Li, T.; Zhang, W.; Tao, S.; Wei, X.; Zhou, X.; Guan, N. & Chan, A. GAI Versus Teacher Scoring: Which is Better for Assessing Student Performance? **IEEE Transactions on Learning Technologies**, 18, 569–580, 2025. DOI: https://doi.org/10.1109/TLT.2025.3572518

Sachete, A. dos S.; Loiola, A. V. de S. de F.; Pereira, A. M.; Rossi, F. D. & Gomes, R. S. EnemIA: correção de redações do Enem com Inteligência Artificial. **Texto Livre**, 18, e58426, 2025. DOI: https://doi.org/10.1590/1983-3652.2025.58426.

Sobre o autor(a)

Juliana Pires da Silva

Doutoranda em Tecnologias da Informação e Comunicação no Programa de Pós-graduação em Tecnologias da Informação e Comunicação (PPGTIC) da Universidade Federal de Santa Catarina (UFSC)

Mestrado em Educação Científica e Tecnológica pela Universidade Federal de Santa Catarina (UFSC - 2015).

Especialização em Educação Matemática pela Universidade do Sul de Santa Catarina (Unisul - 2011).

Graduação em Licenciatura Plena em Matemática pela Universidade do Sul de Santa Catarina (Unisul - 2007).

Técnica em assuntos educacionais da Universidade Federal de Santa Catarina (UFSC) - Campus Araranguá.

Lattes: http://lattes.cnpq.br/8714309711195190

CAPÍTULO 12

Da predição à intervenção: aplicações de Inteligência Artificial na evasão no ensino superior

Luã Alfredo Gonçalves

1. Introdução

A evasão no ensino superior representa um dos desafios mais persistentes e complexos para sistemas educacionais em todo o mundo. Mais do que uma estatística institucional, o abandono do curso acarreta prejuízos profundos tanto para o estudante, que tem seu projeto de vida interrompido e enfrenta a desvalorização do tempo e do esforço investido, quanto para a instituição, que vê sua eficiência, reputação e financiamento comprometidos, bem como para a sociedade, que deixa de contar com profissionais qualificados e perpetua ciclos de desigualdade (Catterall, 2011; Rumberger, 1987).

No Brasil, o cenário não é diferente; o impacto dessa realidade é traduzido em números preocupantes. Segundo dados do Instituto Semesp (2026), entidade representativa das mantenedoras de instituições de ensino superior no Brasil, com base em informações do INEP de 2014 a 2024, as taxas de evasão no ensino superior brasileiro permanecem em níveis elevados, alcançando 24,8% nos cursos presenciais. O cenário torna-se ainda mais preocupante na modalidade de Educação a Distância (EaD), na qual a taxa de desistência atinge 41,6%.

A evasão no ensino superior constitui um fenômeno multifacetado, influenciado por fatores acadêmicos, sociais, econômicos e individuais que interagem entre si. Entre as causas mais frequentemente associadas ao abandono estão dificuldades acadêmicas, desajuste de expectativas em relação ao curso, problemas socioeconômicos e limitações na integração à vida universitária [Tinto 1975]. Pesquisas mais recentes ampliam essa compreensão ao destacar fatores como dificuldades de aprendizagem, falta de apoio familiar e incertezas relacionadas ao percurso profissional (Behr et al. 2021; Long & Noor, 2023). Diante dessa complexidade, as Instituições de Ensino Superior (IES) têm buscado mecanismos

capazes de identificar precocemente estudantes em situação de risco, permitindo intervenções mais direcionadas e efetivas.

Nas últimas duas décadas, a ascensão das tecnologias digitais e a massificação dos dados educacionais, chamados de rastros digitais, abriram uma nova fronteira de pesquisa. Ambientes Virtuais de Aprendizagem (AVA), sistemas de gestão acadêmica, redes sociais e plataformas de biblioteca geram enormes volumes de dados sobre o comportamento do estudante (Kuzilek et al., 2017). A Inteligência Artificial (IA), especialmente técnicas de aprendizado de máquina (*Machine Learning* – ML) e seu subconjunto *deep learning* passaram a ser vistos como ferramentas promissoras para enfrentar a evasão, prometendo identificar padrões complexos e gerar alertas precoces.

Este artigo parte do potencial que a Inteligência Artificial tem demonstrado no enfrentamento da evasão no ensino superior. A análise da literatura recente revela um movimento consistente, no qual grande parte dos estudos se concentra no desenvolvimento de modelos preditivos cada vez mais precisos. Algumas pesquisas, por exemplo, alcançaram taxas de acerto superiores a 90% na identificação de estudantes em risco de evasão, enquanto determinadas plataformas chegaram a detectar corretamente mais de 99% dos casos de desistência em disciplinas. Esses resultados evidenciam avanços importantes na capacidade de identificação precoce do risco, ao mesmo tempo em que ampliam a discussão sobre como essas predições podem ser convertidas em ações concretas de apoio ao estudante.

É justamente nessa transição, da predição para a ação, que se situa a principal lacuna e o argumento central deste artigo. Além disso, a “caixa-preta” presente em muitos modelos de IA, levanta questões éticas. Professores e gestores educacionais, ao receberem uma predição de risco, têm o direito de compreender por que um algoritmo classificou determinado aluno como "em risco de evasão". Quais características mais influenciaram a decisão? Há viés oculto nos dados? A Inteligência Artificial Explicável (XAI) emerge como uma ponte necessária para garantir transparência, justiça e confiança nesses sistemas (Zanellati et al., 2024; Goran et al., 2024).

Diante desse cenário, esta Revisão Sistemática da Literatura (RSL) busca responder às seguintes perguntas de pesquisa: a) De que forma as técnicas de Inteligência Artificial estão sendo aplicadas para a predição da evasão no Ensino Superior? b) Como a Inteligência Artificial contribui para que professores e gestores compreendam os motivos por trás da evasão? c) Quais intervenções ativas baseadas em IA estão sendo desenvolvidas para evitar o abandono após a detecção do risco?

O objetivo central não é apenas identificar o papel da inteligência artificial na prevenção da evasão do ensino superior, mas também apontar caminhos para o desenvolvimento da área. Observa-se que o campo da IA aplicada à evasão no ensino superior tem forte ênfase na predição, podendo evoluir para uma abordagem mais abrangente, que incorpore a ética, a transparência e, sobretudo, sistemas que atuem

ativamente na retenção dos estudantes.

2. Metodologia

Para garantir o rigor e a transparência do processo de revisão (RSL), adotou-se o método Systematic Search Flow (SSF) (Ferenhof & Fernandes 2016)]. Esse método estrutura a pesquisa bibliográfica em quatro fases e oito atividades, minimizando vieses e assegurando a reprodutibilidade.

Na definição do protocolo, que consiste em cinco atividades: 1) Estabelecer a estratégia de busca; 2) Consultar base de dados; 3) Organizar o portfólio bibliográfico; 4) Uniformizar a seleção dos artigos; e 5) Criar o portfólio de artigos (Ferenhof & Fernandes 2016.

2.1. Protocolo de pesquisa

A estratégia de busca foi construída para capturar artigos que abordassem a interseção entre Inteligência Artificial, evasão e ensino superior. A coleta ocorreu em 27 de Abril de 2026, com os seguintes parâmetros:

Tabela 1 - Protocolo de pesquisa

Definição do protocolo de pesquisa	
Atividade 1 Estabelecer a estratégia de busca	A estratégia de busca utilizou os termos em inglês “artificial intelligence”, “dropout” e “higher education”. Para pesquisar foi utilizado o operador booleano “AND” Foram adotados os seguintes critérios de inclusão e exclusão: 1. Selecionar apenas artigos; e que contivessem, nos campos disponíveis de indexação definidos em cada base (título, resumo, palavras-chave e metadados), as strings dessa pesquisa. 2. Selecionar apenas os artigos que tivessem acesso aberto, através da rede da UFSC. 3. Selecionar apenas artigos em língua inglesa
Atividade 2 Consultar base de dados	Foram consultadas duas bases de dados: IEEE e ScienceDirect. As “queries” de pesquisa foram estabelecidas em cada base, conforme descritas abaixo, de maneira a recuperar as “strings” selecionadas nos campos de título, resumo e palavras-chave .

continua

continuação

	• IEEE: ("All Metadata":"artificial intelligence") AND ("All Metadata":"dropout") AND ("Full Text & Metadata":"higher education"). Foram encontrados 57 artigos como resultado • ScienceDirect: Find articles with these terms Title = higher education, abstract or author-specified keywords = "artificial intelligence" AND "dropout". Foram encontrados 33 artigos Não foi aplicada restrição temporal; os estudos recuperados situaram-se entre 2020 e 2026. Nesta etapa, os artigos foram exportados das bases, via web, em formato RIS para o software gerenciador de referências.
Atividade 3 Organizar o portfólio bibliográfico	Para gestão das referências, foi utilizado o Zotero, software livre e de código aberto para gerenciamento de referências bibliográficas. Ele opera em vários sistemas operacionais e sincroniza as referências em uma única conta.
Atividade 4 Uniformizar a seleção dos artigos	Esta etapa compreendeu a leitura dos títulos, resumos e palavras-chave de cada artigo, selecionando os que estivessem no escopo da pesquisa. Restaram 18 artigos. Um artigo foi descartado pois mencionava a IA apenas no final, como possível ferramenta de apoio, sem realmente aplicá-la ao tema da evasão.
Atividade 5 Criar portfólios de artigos	Os 17 artigos foram lidos na íntegra e suas informações organizadas em uma matriz de conhecimento com: autores, ano, títulos, temática, objetivo, técnicas de IA, como contribui para retenção e principais métricas. A síntese foi estruturada em três eixos: predição (pergunta a), explicabilidade (pergunta b) e intervenção (pergunta c).

Fonte: elaborado pelo autor (2026)

A execução das cinco atividades gerou o portfólio final. A tabela 2 abaixo apresenta a quantidade de documentos recuperados em cada etapa.

Tabela 2 - Número de documentos recuperados

Atividade	Total
Busca nas bases	90

continua

continuação

Excluindo documentos duplicados	79
Primeiro Filtro (leitura dos títulos, resumos e palavras-chave de cada um dos artigos)	18
Total de artigos lidos integralmente (portfólio final)	17

Fonte: elaborado pelo autor (2026)

Na etapa 2, a atividade 6 compreende a análise dos documentos selecionados. Para auxiliar nessa fase, os dados foram exportados do Zotero para uma planilha, chamada matriz do conhecimento, conforme Ferenhof e Fernandes (2016) que também orienta a fase de síntese (atividade 7).

Após a leitura dos artigos e com a matriz do conhecimento como guia, foi possível categorizar os artigos para análise e discussão, a saber: (1) artigos sobre predição e evasão, (2) artigos sobre IA Explicável e (3) artigos sobre intervenção ativa.

Tabela 3 - Portifólio Final

Autor/Ano	Títulos	Temática
Altalhi e Ragab (2026)	*Modelling of enhanced predictive analytics and decision-making approach using recurrent autoencoder with attribute subset reduction for students' academic performance*	Predição da evasão
Borges et al. (2025)	*A Platform for Early Class Dropout Prediction of University Students*	Predição da evasão
Fernández-García et al. (2020)	*Creating a Recommender System to Support Higher Education Students in the Subject Enrollment Decision*	Intervenção ativa
Fernández-García et al. (2021)	*A Real-Life Machine Learning Experience for Predicting University Dropout at Different Stages Using Academic Data*	Predição da evasão
Goran et al. (2024)	*Identifying and Understanding Student Dropouts Using Metaheuristic Optimized Classifiers and Explainable Artificial Intelligence Techniques*	IA Explicável (XAI)

continua

continuação

Gorshkov et al (2025)	*Predicting Student Dropout Through Text and Media Content Analysis of VKontakte Profiles*	Predição da evasão
Hachaichi et al. (2025)	*A Predictive Model for Personalized Course Advising Using Data Mining Techniques*	Intervenção ativa
Lu et al. (2025)	*Course-Level Clustering to Enhance Dropout Prediction Accuracy*	Predição da evasão
Martinez e Castillo (2024)	*Prediction of student dropout using Artificial Intelligence algorithms*	Predição da evasão
Nabil et al. (2021)	*Prediction of Students' Academic Performance Based on Courses' Grades Using Deep Neural Networks*	Predição da evasão
Niyogisubizo et al. (2022)	*Predicting student's dropout in university classes using two-layer ensemble machine learning approach: A novel stacked generalization*	Predição da evasão
Pecuchova e Drlik (2024)	*Enhancing the Early Student Dropout Prediction Model Through Clustering Analysis of Students' Digital Traces*	Predição da evasão
Prada et al. (2020)	*Educational Data Mining for Tutoring Support in Higher Education: A Web-Based Tool Case Study in Engineering Degrees*	Intervenção ativa
Qamhieh et al. (2020)	*PCRS: Personalized Career-Path Recommender System for Engineering Students*	Intervenção ativa
Ulyan et al. (2021)	*Deep Learning Model to Predict Students Retention Using BLSTM and CRF*	Predição da evasão
Vega-Rebolledo et. al. (2025)	*Applying survival analysis and Explainable Artificial Intelligence to understand academic success in software engineering students*	IA Explicável (XAI)
Zanellati et al. (2024)	*Balancing Performance and Explainability in Academic Dropout Prediction*	IA Explicável (XAI)

Fonte: elaborado pelo autor (2026)

O ChatGPT, modelo de linguagem desenvolvido pela OpenAI, foi utilizado nesta pesquisa como ferramenta de apoio para brainstorming inicial e revisão gramatical do texto, sendo a redação, interpretação e análise dos dados realizadas integralmente pelo autor.

3. Resultados e discussão

Para responder às três perguntas que guiam esta revisão, os 17 artigos foram agrupados por objetivo principal. O primeiro grupo, que responde à primeira pergunta de pesquisa (a), reúne os trabalhos focados na predição da evasão. O segundo grupo, alinhado à segunda pergunta (b), reúne os estudos que incorporam técnicas de IA para tornar as predições mais transparentes. O terceiro grupo, que responde à terceira pergunta (c), é formado pelos artigos que propõem intervenções ativas após a detecção do risco.

A discussão a seguir parte de uma perspectiva pedagógica e ética, destacando os tipos de dados utilizados, sua sensibilidade e as implicações para a prática educacional.

3.1. O cenário dominante: a predição da evasão – Pergunta (a).

Dos 17 artigos, 10 concentram-se em predizer a evasão: Altalhi e Ragab (2026), Borges et al. (2025), Fernández-García et al. (2021), Gorshkov et al. (2025), Lu et al. (2025), Martinez e Castillo (2024), Nabil et al. (2021), Niyogisubizo et al. (2022), Pecuchova e Drlik (2024) e Ulyan et al. (2021). Seus autores desenvolvem modelos que, a partir de dados históricos, tentam classificar quais estudantes estão em risco de abandonar o curso. A maioria desses trabalhos utiliza uma combinação de três fontes principais de dados.

A primeira fonte são os dados acadêmicos tradicionais, como notas em disciplinas, número de reprovações, créditos cursados e coeficiente de rendimento. Esses dados são os mais comuns e, em geral, menos sensíveis, pois já fazem parte do registro escolar. Por exemplo, Niyogisubizo et al. (2022) usaram notas de provas, projetos e exercícios para prever evasão em aulas de banco de dados, enquanto Nabil et al. (2021) previram o desempenho em uma disciplina de Estrutura de Dados a partir das notas de 12 disciplinas do primeiro ano.

A segunda fonte são os rastros de interação em Ambientes Virtuais de Aprendizagem (AVA), como cliques, acessos a materiais, participação em fóruns e submissão de atividades. Pecuchova e Drlik (2024) analisaram logs do Moodle de 152 alunos, registrando 150.883 interações ao longo de um semestre. Já Borges et al. (2025) usaram frequência a aulas, histórico de matrículas e dados de tutoria para prever

abandono de disciplinas na Universidade de Coimbra.

A terceira fonte são os dados demográficos e socioeconômicos, como idade, gênero, escolaridade dos pais e renda familiar. Vega-Rebolledo et al. (2025) – que está no grupo da IA Explicável, mas ilustra bem o uso desses dados – incluíram idade, nota de ingresso, progresso de créditos e nível de escolaridade pretendido. Gorshkov et al. (2025) foram além e analisaram perfis públicos do VKontakte, extraindo fotos, vídeos, preferências musicais e posts textuais.

A maioria desses modelos opera como "caixas-pretas". O professor recebe um alerta do tipo "aluno X tem 80% de chance de evadir", mas não sabe por quê. Isso é particularmente grave quando dados sensíveis – como renda familiar, escolaridade dos pais ou atividade em redes sociais – são usados sem transparência. Um coordenador de curso pode, por exemplo, agir com base em um alerta gerado por viés algorítmico contra alunos de baixa renda, sem nunca ter acesso a essa informação.

A coleta de dados de redes sociais, como no estudo de Gorshkov et al. (2025), levanta questões que merecem atenção: ainda que os perfis sejam 'públicos' e os participantes informados sobre os objetivos da pesquisa, os tipos de dados utilizados e os direitos de retirada, isso não elimina a necessidade de protocolos mais claros sobre consentimento e uso de dados na pesquisa educacional. Poucos estudos discutem quais ações devem ser implementadas após a emissão do alerta — e é isso que veremos a seguir.

3.2. A ponte necessária: Inteligência Artificial Explicável – Pergunta (b).

Apenas 3 dos 17 artigos incorporam técnicas que abrem a "caixa-preta" e permitem que educadores compreendam as razões por trás das predições. Esses estudos utilizam a chamada Inteligência Artificial Explicável (XAI), em especial o método SHAP, (SHapley Additive exPlanations), um framework consolidado na literatura (Lundberg and Lee 2017) que atribui a cada variável uma importância para uma determinada predição.

Vega-Rebolledo et al. (2025) aplicaram SHAP a modelos de regressão multinomial e árvores de decisão. Eles identificaram que idade, nota e progresso de créditos foram as variáveis com maior influência nas predições do modelo para prever se um aluno de Engenharia de Software se forma no tempo esperado, com atraso ou evadiu. Para educadores, isso significa que políticas de nivelamento para alunos mais velhos ou com notas de ingresso mais baixas podem ser mais eficazes do que intervenções genéricas.

Zanellati et al. (2024) compararam dois modelos (Random Forest e uma rede neural com mecanismo de atenção) e usaram SHAP para mostrar que o número de créditos acumulados no primeiro ano é o preditor mais forte de não evasão. Para um gestor,

isso sugere que ações para garantir que o aluno avance nos créditos iniciais – como mentoria em disciplinas críticas – podem ter grande impacto.

Goran et al. (2024) otimizaram modelos de AdaBoost e XGBoost com meta-heurísticas e depois usaram SHAP para identificar os fatores de risco mais relevantes: unidades curriculares no segundo semestre, taxas de matrícula em dia e número de unidades aprovadas. Esses resultados são acionáveis: uma instituição pode, por exemplo, oferecer planos de pagamento flexíveis a alunos cujas taxas estejam atrasadas.

A XAI é fundamental na prática pedagógica porque devolve ao professor e ao gestor a capacidade de intervir com conhecimento de causa. Em vez de reagir a um alerta cego, o educador pode direcionar recursos: oferecer nivelamento para alunos com baixo desempenho inicial, criar programas de mentoria para estudantes mais velhos ou negociar parcelamento de mensalidades. A XAI transforma a predição de um exercício estatístico em uma ferramenta de planejamento educacional. Infelizmente, a ausência de XAI nos outros 14 artigos significa que suas predições, por mais precisas, são limitadas para orientar decisões pedagógicas concretas.

3.3. A lacuna crítica: da detecção à intervenção – Pergunta (c)

Uma questão central analisada nesta revisão refere-se a: quantos desses sistemas preditivos realmente fazem algo para ajudar o aluno depois que o risco é detectado? Apenas 4 dos 17 artigos propõem intervenções ativas. Os demais param na detecção. O primeiro artigo analisado é dos autores Hachaichi et al. (2025), que desenvolveram um sistema de aconselhamento personalizado de curso. Além de prever o desempenho do aluno, o sistema recomenda quais disciplinas ele deve cursar a seguir, respeitando seus pontos fortes e os pré-requisitos. A lógica é simples: em vez de apenas dizer "você está em risco", o sistema ajuda o aluno a construir um percurso mais adequado.

Fernández-García et al. (2020) criaram um sistema de recomendação de disciplinas para um curso de Ciência da Computação. O sistema analisa o histórico acadêmico do aluno e sugere as disciplinas eletivas nas quais ele tem maior probabilidade de sucesso, orientando a escolha do estudante e reduzindo a chance de matrícula em disciplinas para as quais não está preparado. Prada et al. (2020) entregaram a ferramenta SPEET, um painel web para tutores.

A ferramenta agrupa alunos por perfil de desempenho, classifica o risco de evasão e apresenta tudo em gráficos interativos. O tutor pode identificar rapidamente quais alunos precisam de apoio e planejar ações individuais ou em grupo. Aqui, a intervenção é humana, mas orientada por dados.

Qamhieh et al. (2020) propuseram o PCRS, um sistema fuzzy que recomenda, a calouros, qual das sete engenharias se alinha melhor com seu perfil de personalidade

(teste MBTI), seu desempenho no ensino médio e suas habilidades extracurriculares. É uma intervenção na entrada do curso, tentando reduzir a evasão por desajuste de expectativas desde o primeiro dia.

O que esses quatro casos têm em comum é que entendem a predição como um meio, não um fim. A detecção do risco dispara uma ação concreta: recomendar um percurso, sugerir uma disciplina, organizar um painel para o tutor, orientar a escolha da carreira. Em contraste, os outros 13 artigos se limitam a publicar métricas de acurácia – como se a tarefa da IA estivesse concluída quando o alerta é emitido. Do ponto de vista pedagógico, a diferença é significativa.

Sistemas focados exclusivamente na detecção de risco tendem a priorizar o monitoramento dos estudantes, enquanto abordagens interventivas ampliam as possibilidades de apoio à permanência e ao progresso acadêmico. A literatura analisada ainda concentra maior atenção em modelos preditivos, deixando em segundo plano o desenvolvimento de artefatos de IA voltados ao suporte ativo ao estudante.

3.4. Síntese dos achados

Os 17 artigos analisados podem ser sintetizados da seguinte forma. Na primeira pergunta de pesquisa (predição), 10 artigos utilizam notas, rastros de AVA e dados demográficos, alcançando alta acurácia, mas operam como caixas-pretas, com uso de dados que nem sempre são tratados com a devida transparência. Na segunda pergunta (IA Explicável), 3 artigos aplicam SHAP e outras técnicas, revelando fatores de risco acionáveis, mas ainda são minoria. Na terceira pergunta (intervenção ativa), 4 artigos propõem sistemas de recomendação, tutoria e aconselhamento de percurso, mas a quantidade é muito pequena.

As implicações éticas e de privacidade são múltiplas. Dados sensíveis como idade, gênero, renda familiar, escolaridade dos pais e perfis de redes sociais podem gerar discriminação algorítmica. Alguns dos estudos que usam dados demográficos não discutem as implicações do uso de variáveis como renda familiar e escolaridade dos pais, o que abre espaço para que padrões históricos de exclusão sejam reproduzidos pelos modelos. Sobre consentimento e transparência, parte dos estudos analisados não detalhou explicitamente o processo de obtenção de consentimento individual dos alunos. Em outros estudos, a coleta é feita a partir de registros institucionais, muitas vezes sem que o estudante saiba que seus dados estão sendo usados para predição de evasão.

A legislação, como a LGPD no Brasil ou a GDPR na Europa, estabelece requisitos relacionados à transparência, finalidade e proteção de dados, o que não se observa na prática em alguns estudos. Há também uma falsa objetividade: a alta acurácia publicada pode dar aos gestores uma falsa sensação de que o modelo é neutro e

científico, quando, na realidade, os dados de treinamento carregam os vieses históricos da instituição. Se a universidade já reprovou mais alunos de um determinado perfil, o modelo poderá reproduzir ou amplificar padrões históricos presentes nos dados.

A lacuna da intervenção é a mais grave do ponto de vista pedagógico. A IA não deveria ser apenas um instrumento de diagnóstico; ela deveria ser parte da solução. Sistemas que se limitam a apontar o risco, sem oferecer um caminho de apoio, correm o risco de se tornar ferramentas que podem, inadvertidamente, reforçar processos de exclusão.

Recomenda-se que pesquisas futuras se concentrem em construir artefatos de IA que atuem, não apenas que detectem. Além das questões de privacidade e transparência, existe também um desafio relacionado à infraestrutura computacional. Modelos avançados de Inteligência Artificial frequentemente demandam elevado poder de processamento e armazenamento, o que pode representar limitações para instituições com menor capacidade tecnológica.

Em muitos casos, a alternativa adotada consiste na utilização de serviços externos de computação em nuvem. Embora essa estratégia reduza custos de infraestrutura local, ela pode implicar a transferência de dados sensíveis dos estudantes para servidores externos, levantando preocupações relacionadas à soberania institucional e à proteção de dados.

4. Considerações Finais

Esta Revisão Sistemática da Literatura, baseada na análise de 17 artigos, buscou não apenas identificar, mas discutir o papel da Inteligência Artificial na prevenção da evasão no ensino superior. Os resultados confirmam as três perguntas iniciais e revelam um campo com avanços relevantes, porém desbalanceado.

Primeiro, constata-se um domínio da predição, referente à pergunta de pesquisa (a). Algoritmos de Machine Learning e Deep Learning, alimentados por grande volume de rastros digitais e dados acadêmicos, demonstram alta capacidade de classificar alunos em risco. As métricas alcançadas, frequentemente apresentando valores elevados de AUC e acurácia, mostram que os estudos analisados apresentam avanços significativos na capacidade técnica de predição.

Segundo, a necessidade de transparência é endereçada pela Inteligência Artificial Explicável, pergunta de pesquisa (b), com o SHAP como técnica emergente para abrir as "caixas-pretas" algorítmicas. No entanto, apenas três dos 17 estudos incorporam XAI de forma substantiva, indicando que a preocupação com a explicabilidade ainda é periférica. Isso é preocupante, pois, sem transparência, a confiança dos educadores e a possibilidade de intervenções justas ficam seriamente comprometidas.

Terceiro, revela-se uma lacuna crítica de intervenção à pergunta de pesquisa (c): apenas quatro artigos propõem sistemas ativos de suporte, tutoramento ou recomendação. A maioria dos estudos se limita a detectar o risco, sem oferecer qualquer mecanismo automatizado ou semi-automatizado para agir sobre ele.

Para além dessas conclusões, os resultados também evidenciam desafios relacionados à infraestrutura computacional e à soberania dos dados educacionais. Modelos preditivos de alto desempenho frequentemente exigem infraestrutura computacional robusta, o que pode representar uma limitação para instituições de ensino superior, especialmente em países em desenvolvimento. Nesse contexto, uma alternativa frequentemente adotada é a utilização de serviços de computação em nuvem fornecidos por grandes provedores externos.

Embora essa estratégia reduza a necessidade de infraestrutura local, ela pode implicar a transferência de dados sensíveis dos estudantes para servidores localizados fora do controle institucional, levantando preocupações relacionadas à soberania digital e à proteção dos dados educacionais. Esse tipo de fenômeno tem sido discutido na literatura sob o conceito de colonialismo de dados (Couldry and Mejias, 2019).

Torna-se necessário, portanto, que pesquisadores e gestores busquem modelos computacionalmente mais leves, estratégias de processamento local e soluções de código aberto que respeitem a privacidade e a soberania institucional. Recomenda-se que futuros estudos ampliem a abrangência para outras bases de dados, trazendo dados de veículos especializados em educação e com foco social, que podem conter trabalhos relevantes que não foram indexados nas bases aqui consultadas (IEEE e ScienceDirect).

Para pesquisas futuras, deve-se priorizar o desenvolvimento de sistemas interventivos: construir e avaliar, no mundo real, ferramentas de tutoria inteligente, sistemas de recomendação de percursos personalizados e plataformas de suporte ao aluno acionadas a partir das predições. Esses sistemas devem ter a colaboração de educadores e estudantes. Consolidar a adoção da XAI como padrão também é urgente: a explicabilidade não pode ser um "extra". Deve ser um requisito de design para qualquer sistema de IA aplicado à educação. Pesquisas sobre métodos de XAI mais simples e interpretáveis para não-especialistas são necessárias.

Desse modo, as conclusões deste estudo não se limitam à identificação dos algoritmos mais eficazes. Embora a IA ofereça ferramentas valiosas para a inclusão e retenção de estudantes, sua eficácia exige uma transição da monitorização passiva para abordagens mais ativas, éticas e transparentes, auxiliando professores e gestores na realização de intervenções mais diretas e contextualizadas.

Referências

Altalhi, A. H. & Ragab, M. Modelling of enhanced predictive analytics and decision-making approach using recurrent autoencoder with attribute subset reduction for students' academic performance. **Ain Shams Engineering Journal,** 2026. DOI: https://doi.org/10.1016/j.asej.2026.103999

Behr, A; Giese, M.; Kamdjou, H. D. T. & Theune, K. Motives for dropping out from higher education—An analysis of bachelor's degree students in Germany. **European Journal of Education**, 325-343, 2021. DOI: https://doi.org/10.1111/ejed.12433

Borges, G. A.; Pedro, C. F. dos S.; Anjos, J. C. S. dos; Rodrigues, A.; Boavida, F. & Silva, J. S. A Platform for Early Class Dropout Prediction of University Students. **IEEE Access,** 2025. DOI: https://doi.org/10.1109/ACCESS.2025.3581751

Catterall, J. S. On the social costs of dropping out of school. **High School Journal**, 19-30, 2011. https://doi.org/10.1155/2011/957303

Couldry, N. & Mejias, U. A. The Costs of Connection: How Data Is Colonizing Human Life and Appropriating It for Capitalism. **Stanford University Press**, 2019.

Ferenhof, H. A. & Fernandes, R. F. Desmistificando a revisão de literatura como base para redação científica: método SSF. **Revista ACB**, 2016. DOI: https://revista.acbsc.org.br/racb/article/view/1194

Fernández-García, A. J.; Rodríguez-Echeverria, R.; Preciado, J. C.; Manzano, M. C. & Sánchez-Figueroa, F. Creating a Recommender System to Support Higher Education Students in the Subject Enrollment Decision. **IEEE Access**, v. 8, 2020. DOI: https://doi.org/10.1109/ACCESS.2020.3031572

Fernández-García, A. J.; Preciado, J. C.; Melchor, F.; Rodriguez-Echeverria, R.; Conejero, J. M. & Sánchez-Figueroa, F. A Real-Life Machine Learning Experience for Predicting University Dropout at Different Stages Using Academic Data. **IEEE Access**, v. 9, 2021. DOI: https://doi.org/10.1109/ACCESS.2021.3115851

Goran, R.; Jovanovic, L.; Bacanin, N.; Stankovic, M. S.; Simic, V. & Antonijevic, M. Identifying and Understanding Student Dropouts Using Metaheuristic Optimized Classifiers and Explainable Artificial Intelligence Techniques. **IEEE Access**, v. 12, 2024. DOI: https://doi.org/10.1109/ACCESS.2024.3446653

Gorshkov, S. S.; Ignatov D. I., & Chernysheva A. Y. Predicting Student Dropout Through Text and Media Content Analysis of VKontakte Profiles. **IEEE Access**, 2025. DOI: https://doi.org/10.1109/ACCESS.2025.3550817

Hachaichi, Y.; Khedr, A. E.; Belal, M. A. & Elhrawy, A. S. (2025). A Predictive Model for Personalized Course Advising Using Data Mining Techniques. **IEEE Access**. DOI: https://doi.org/10.1109/ACCESS.2025.3600578

Instituto Semesp (2026). **16º Mapa do Ensino Superior no Brasil:** Dados Brasil. Disponível em: https://www.semesp.org.br/mapa/edicao-16/brasil/#secao-11

Kuzilek, J.; Hlosta, M. & Zdrahal, Z. Open University Learning Analytics dataset. **Scientific Data,** 2017. DOI: https://doi.org/10.1038/sdata.2017.171

Long, Z. A. & Noor, M. F. M. Factors Influencing Dropout Students in Higher Education. **Education Research International**, 2023. DOI: https://doi.org/10.1155/2023/7704142

Lu, Y.; Yeom, S.; Ryu, R. & Kim, S. H. Course-Level Clustering to Enhance Dropout Prediction Accuracy. **IEEE Access,** v. 13, 2025. DOI: https://doi.org/10.1109/ACCESS.2025.3639083

Lundberg, S. M. & Lee, S.-I. A Unified Approach to Interpreting Model Predictions. **Advances in Neural Information Processing Systems**, 2017. Disponível em: https://www.researchgate.net/publication/317062430_A_Unified_Approach_to_Interpreting_Model_Predictions

Martinez, J., & Castillo, D. Prediction of student dropout using Artificial Intelligence algorithms. **Procedia Computer Science**, 764-770, 2024. DOI: https://doi.org/10.1016/j.procs.2024.11.182

Nabil, A.; Seyam, M. & Abou-Elfetouh, A. Prediction of Students' Academic Performance Based on Courses' Grades Using Deep Neural Networks. **IEEE Access**, 2021. DOI: https://doi.org/10.1109/ACCESS.2021.3119596

Niyogisubizo, J.; Liao, L.; Nziyumva, E.; Murwanashyaka, E. & Nshimyumukiza, P. C. Predicting student's dropout in university classes using two-layer ensemble machine learning approach: A novel stacked generalization. **Computers and Education: Artificial Intelligence,** 2022. DOI: https://doi.org/10.1016/j.caeai.2022.100066

Pecuchova, J. & Drlik, M. Enhancing the Early Student Dropout Prediction Model Through Clustering Analysis of Students' Digital Traces. **IEEE Access**, 2024. DOI: https://doi.org/10.1109/ACCESS.2024.3486762

Prada, M. A.; Dominguez, M.; Vicario, J. L.; Alvez, P. A. V.; Barbu, M. & Podpora, M. Educational Data Mining for Tutoring Support in Higher Education: A Web-Based Tool Case Study in Engineering Degrees. **IEEE Access**, v. 8, 2020. DOI: https://doi.org/10.1109/ACCESS.2020.3040858

Qamhieh, M.; Sammaneh H. & Demaidi M. N. PCRS: Personalized Career-Path Recommender System for Engineering Students. **IEEE Access**, 2020. DOI: https://doi.org/10.1109/ACCESS.2020.3040338

Rumberger, R. W. High school dropouts: A review of issues and evidence. **Review of Educational Research**, 57(2), 101-121, 1987. DOI: https://doi.org/10.3102/00346543057002101

Tinto, V. Dropout from higher education: A theoretical synthesis of recent research. **Review of Educational Research**, 45(1), 89-125, 1975. DOI: https://doi.org/10.3102/00346543045001089

Ulyan, D.; Aljaloud, A. S.; Alkhalil, A.; Amer, H. S. A.; Elrhman, M. A.; Mohamed, A. & Alogali, A. F. M. Deep Learning Model to Predict Students Retention Using BLSTM and CRF. **IEEE Access**, v. 9, 2021. DOI: https://doi.org/10.1109/ACCESS.2021.3117117

Vega-Rebolledo, I.; Sánchez-García, A. J.; León, J. J. M.; Ocharán-Hernández, J. O. & Cortés-Verdín, K. Applying survival analysis and Explainable Artificial Intelligence to understand academic success in software engineering students. **Array**, 2025 https://doi.org/10.1016/j.array.2025.100540

Zanellati, A.; Zingaro, S. P. & Gabbrielli, M. Balancing Performance and Explainability in Academic Dropout Prediction. **IEEE Access**, 2024. DOI: https://doi.org/10.1109/TLT.2024.3425959

Sobre o autor(a)

Luã Alfredo Gonçalves

Mestrando em Tecnologias da Informação e Comnunicação pelo Programa de Pós-Graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina.

Especialização em Práticas Pedagógicas Interdisciplinar pela Faculdade Dom Bosco (2017).

Graduação em Tecnologia em Redes de Computadores pelo Instituto Federal Catarinense – Campus Sombrio (IFC - 2013).

Técnico em Laboratório – Área Informática no Instituto Federal Catarinense (IFC) – Campus Santa Rosa do Sul.

Lattes: http://lattes.cnpq.br/9417470851058564

PARTE IV

IA, INCLUSÃO E DIMENSÕES HUMANAS DA APRENDIZAGEM

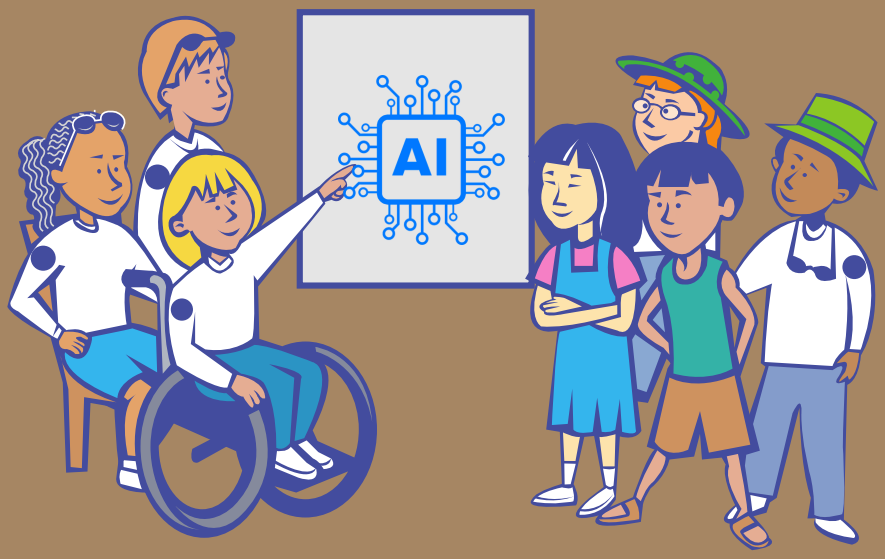

CAPÍTULO 13

Aplicações de inteligência artificial no apoio à aprendizagem inclusiva

Ludmila Oliveira Daufenbach

1. Introdução

Paulo Freire (2011) já trazia preocupações com a adaptação do sistema educacional à pessoa com deficiência nos anos 1980, quando pouco se falava em inteligência artificial - IA, época que sequer víamos computadores nas escolas. Utilizando a metodologia de revisão sistemática de literatura, propomos discussões sobre o impacto da IA na educação inclusiva, bem como a análise da utilização de ferramentas baseadas em IA na aprendizagem de alunos com deficiência sob a perspectiva legal.

Para tanto, teremos como objetivo geral da pesquisa o uso de inteligência artificial como ferramenta de auxílio na aprendizagem do aluno com deficiência, trazendo como estratégia o desenho universal de aprendizado (DUA) para a confecção de currículos personalizados, promovendo a equidade no ensino. Como objetivos específicos, nos propomos a fundamentar a educação inclusiva, apresentar o DUA como ferramenta de flexibilização de currículos, identificar ferramentas que apoiem os alunos com deficiência e usos pedagógicos da IA e analisar desafios da implantação, como falta de estrutura, formação de docentes e questões éticas.

Nosso problema de pesquisa reside na possibilidade da adoção de IA para o auxílio como recurso pedagógico a alunos com deficiência, por meio de pesquisa qualitativa nas plataformas Google Acadêmico, Portal Capes, Scielo e IEEE Xplore Digital Library .

2. Referencial Teórico

Com o objetivo de alcançar o problema de pesquisa, facilitando a análise dos objetivos, faremos a explanação da pesquisa em três tópicos, com a inclusão de um subtópico no último.

2.1 Fundamentos Teóricos: educação inclusiva, acessibilidade e desenho universal para a aprendizagem - DUA/UDL

A educação de qualidade e inclusiva consta na quarta posição dos objetivos de desenvolvimento sustentável da ONU, disposta na agenda 2030, que tem como um dos objetivos promover educação de forma igualitária, promovendo a igualdade às pessoas com deficiência. Tal compromisso foi assumido pelos países membros em razão de ser uma prioridade, com a aplicação de uma pedagogia da inclusão, sem aplicação de rótulos.

O direito à educação foi assegurado no art. 205 da Constituição Federal (de 1988), que garante a todos educação de qualidade, bem como dever da família e do Estado garantir seu exercício (BRASIL, 1988). Após a promulgação da Carta Magna Brasileira, a UNESCO publicou a Declaração de Salamanca (1994), que garante a educação inclusiva, dispondo que alunos com deficiência frequentem o ensino regular, tornando-se um marco internacional referente à inclusão, adotado pelo Brasil através da Lei de Diretrizes e Bases da Educação Nacional (BRASIL, 1996), que aponta como regra a inclusão do aluno com deficiência em classes regulares, oferecendo o apoio necessário, sendo sua matrícula efetuada na rede especializada somente em caso de impossibilidade de sua inclusão.

Com o intuito de eliminar as barreiras que impedem o aprendizado da pessoa com deficiência e, baseado na convenção da Organização das Nações Unidas - ONU sobre Direitos de Pessoas com Deficiência, o Ministério da Educação - MEC lançou, em 2008, a Política Nacional de Educação Especial na Perspectiva da Educação Inclusiva (PNEEPEI). Na tentativa de tornar mais efetivas as políticas públicas em relação à inclusão, em 2015, foi instituído o Estatuto da Pessoa com Deficiência que, entre seus artigos 27 e 30, dispõe acerca dos direitos à inclusão na educação.

Para que seja aplicada a inclusão da pessoa com deficiência, há necessidade de uma rede de apoio do sistema educacional, que precisa deixar de lado a "educação bancária", que tem como propósito adequar o indivíduo à sociedade (Freire, 2011). Corroborando com a ideia de Paulo Freire (Freire, 2011), a Presidência da República publicou o decreto n. 12.686/2025 que, em seu artigo 2o, inciso VI, garante a acessibilidade e o incentivo ao desenvolvimento de tecnologias que assegurem o direito à educação ao público da educação especial (Brasil, 2025).

No campo pedagógico, para que seja assegurado a inclusão, faz-se primordial que haja recursos de acessibilidade disponíveis como regra, não como exceção, a exemplo do que já se tornou prioridade na arquitetura de edifícios, a área da educação tem caminhado para um futuro que prevê a mitigação das barreiras para todos.

A questão da acessibilidade não pode ser benefício de alguns segmentos, devendo ser ampliado para atender a uma gama maior de pessoas, sendo conceituado como

desenho universal, que passou a desenvolver projetos como, por exemplo, rampas para cadeiras de rodas, que passou a ser uma necessidade universal, utilizada por todos, seja para passar com carrinho de bebê ou de supermercado. Tal conceito deu origem ao termo Desenho Universal para a Aprendizagem (DUA), que tem como objetivo adaptar os currículos que, segundo Heredero (2020), é a parte que contém deficiência, não os estudantes, já que são feitos para uma média fictícia, contando com aulas narrativas ou expositivas.

A literatura aponta que currículos inflexíveis não alcançam os objetivos das normas referentes à educação, razão pela qual tem adotado o entendimento de aplicação de currículos flexíveis, que atendam a demanda de todos os alunos, não apenas aqueles que estão dentro do "critério ilusório da média" (Heredero, 2020), mas àqueles com altas capacidade e com maior dificuldade no aprendizado, se adaptando aos alunos.

O DUA tem como objetivo atender a gama de diversidade de alunos sem a necessidade de permanecer em constante adaptação individual e tardia, focando na remoção de barreiras pedagógicas através da flexibilização curricular e utilização de ferramentas tecnológicas.

Em março de 2003, foi promovido pelo Banco Mundial, o Seminário Sobre Educação Inclusiva no Brasil, no Instituto Helena Antipoff, no Rio de Janeiro, que já inseriu entre suas recomendações a acessibilidade digital, tendo como principais instrumentos a legislação, formação e capacitação de professores, além da utilização de recursos acessíveis, apontando como forma de instituição das políticas públicas voltadas à acessibilidade a pesquisa e criação de plataformas por parte das universidades, em especial as públicas.

2.2 Aplicações da IA: ferramentas, exemplos e usos pedagógicos

Visando adaptar os currículos à realidade pedagógica, faz-se necessário a integração entre o DUA e as tecnologias da informação e comunicação - TICs para que sejam adotadas na educação plataformas adaptativas com personalização em grande escala. Nesta junção, verificamos que o DUA possui a função de fornecer a base pedagógica, adaptando os currículos, e a TIC exerce papel na execução tecnológica.

Em meados dos anos de 1950 o mundo passou a conhecer o termo "inteligência artificial", que é a simulação da inteligência humana desenvolvida na ciência da computação, passando a se tornar mais popular nos anos de 1990, década que o professor Marcelo Pimentel (UFRJ) criou o DOSVOX, sistema operacional que permitiu o acesso às informações por pessoas com deficiência visual. (Valls & Cardoso, 2025)

A partir do ano 2000 a IA ganhou força, tendo como exemplos populares de assistentes virtuais a Alexia e a Siri, acompanhados pela criação de plataformas de IA generativa, que assessoram a condução pedagógica. Atualmente há plataformas tecnológicas que utilizam a IA generativa como forma de apoio à aprendizagem do aluno com deficiência, como leitores de tela por IA, reconhecimento de voz e ditados por fala, tradutores de libras, ambientes de aprendizagem adaptativos e reconhecimento de imagens de descrição de ambientes.

Neste cenário, cabe ao professor a tarefa de selecionar as plataformas a serem adotadas e se tornar um orientador na aprendizagem adaptativa, já que as plataformas que utilizam a IA necessitam de tutoria ao serem aplicadas aos alunos, papel a ser desenvolvido pelo professor, que ajustará as ferramentas de acordo com a necessidade de cada aluno, criando conteúdo e fomentando o pensamento crítico (LOPES, 2026).

Na educação de alunos com deficiência, o professor poderá selecionar recursos que contam com softwares que utilizam a IA para adaptar o currículo às necessidades de cada aluno com a utilização de sistemas de tutores inteligentes - STIs.

A literatura aponta maior eficácia na adoção de STIs na educação em relação ao sistemas tradicionais em especial por causa da facilidade de adaptação e feedbacks enviados ao professor para mediação do ensino, além do uso dos chatbots, programa computacional que simula a conversação humana, atuando como assistentes virtuais para perguntas e respostas, oferecendo suporte contínuo ao aluno, porém, sempre com a supervisão do professor para que seja utilizado como complemento focado no conteúdo curricular (Almeida, 2026).

A pandemia de COVID-19 impulsionou as pesquisas e o progresso relativo ao uso da IA na educação, coincidentemente, após a publicação do Decreto n. 9.854/2019, do Ministério da Ciência, Tecnologia e Inovação (BRASIL, 2019), que instituiu o plano nacional de internet das coisas (IoT), termo utilizado para definir a conexão entre dispositivos inteligentes e a nuvem através da internet (IBM).

As tecnologias da IoT passaram a ser utilizadas em conjunto com a IA, surgindo o termo AIoT (inteligência artificial das coisas) ou IoIT (internet das coisas inteligentes), implicando a capacidade de processamento de dados e modelos de aprendizagem de máquina, passando a ser objeto de pesquisa para a expansão no auxílio de pessoas com deficiência (Mitre & Zeneli, 2024).

Com o surgimento da AIoT, a IA passou a se basear em redes neurais (deep learning) para compreender e gerar linguagem semelhante à linguagem humana ao processar dados em grande quantidade, nomeando este sistema como linguagem de larga escala (LLM - large language models), representando a ampliação no auxílio de alunos com deficiência através da combinação de recursos nas estratégias da educação inclusiva como, por exemplo, o uso do ChatGPT (Mitre & Zeneli, 2024).

> Um estudo explora o ChatGPT como uma ferramenta de tecnologia assistiva dentro da estrutura do Desenho Universal para Aprendizagem (DUA) para apoiar estudantes com deficiência. O ChatGPT pode realizar conversão de texto em fala, reconhecimento de fala, legendagem em tempo real, intérpretes de língua gestual, fornecer respostas personalizadas com princípios do DUA e adaptar a apresentação do conteúdo, entre outras funcionalidades que podem impactar e melhorar a acessibilidade e a inclusão de estudantes com deficiência. O ChatGPT permite que estudantes com deficiência acessem informações e recursos altamente relevantes, decompõe informações usando linguagem simplificada para explicar conceitos no nível necessário, incentiva o engajamento por meio de sua natureza interativa e, mais importante, oferece suporte ao não fazer julgamentos em relação aos estudantes com deficiência (Mitre & Zeneli, 2024, tradução nossa).

Apesar de dispor de ferramentas capazes de adaptar o currículo e os métodos pedagógicos às necessidades dos alunos, o ChaGPT possui falhas, podendo fornecer respostas incorretas ou adotar vieses distorcidos, razão pela qual se faz necessário a participação do professor, visando garantir a integridade acadêmica.

O aprendizado de máquina também demonstra eficiência quanto à análise do perfil dos alunos, podendo fornecer sugestões ao especialista para adaptação dos currículos. H. El Fazazi, M. Elgarej, M. Qbadou e K. Mansouri (2021) propõe um sistema de e-leaning adaptativo baseado em multiagentes, "um conjunto de agentes organizados e independentes que se comunicam entre si para resolver um problema ou atingir um objetivo bem definido", capaz de personalizar o conteúdo de acordo com a necessidade dos alunos, considerando o nível de conhecimento, estilo de aprendizagem e tipo de deficiência.

O sistema proposto no estudo dos autores supracitados se adequam às plataformas de tutores inteligentes, tendo como componentes o conteúdo do professor estruturados em camadas, tais como modelo de aprendizagem e conteúdos, o modelo do aluno, contendo camadas como dados e preferências pessoais, tipos de deficiência e estilos de aprendizagem e os modelos de adaptação.

2.3. Desafios: infraestrutura, formação dos docentes e ética

A literatura demonstra confiança no uso da IA como objeto de auxílio na aprendizagem do aluno com deficiência, porém, ressaltamos alguns empecilhos, tais como a destinação de recursos financeiros para a aquisição da tecnologia, manutenção

e suporte técnico.

Cada unidade escolar possui suas características, devendo adaptar as plataformas educacionais aos alunos, podendo reduzir custos através da adoção de plataformas de uso gratuito e softwares abertos, como ferramentas produzidas em universidades públicas e escolas técnicas.

Ao analisarmos os dados de indicadores da educação coletados pelo último censo realizado pelo Instituto Nacional de Estudos e Pesquisas Educacionais - INEP, verificamos que as escolas públicas, federais e estaduais, possuem estrutura tecnológica similar as privadas, verificando desigualdade nas escolas administradas pelos municípios que, geralmente, são responsáveis pelo ensino fundamental, como podemos verificar na comparação dos gráficos a seguir:

Figura 1 - Percentual de escolas da educação básica com acesso à internet, segundo o município

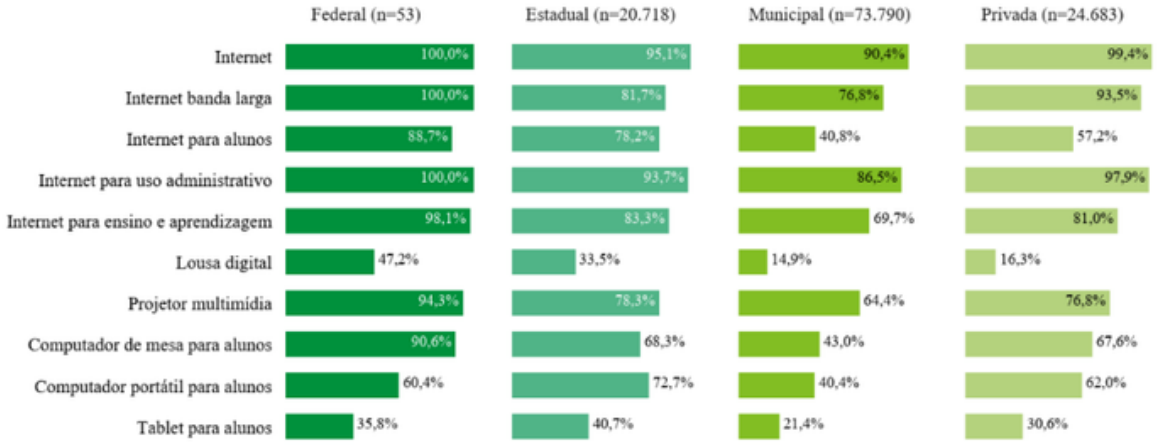

Fonte: Elaborado pela Deed/Inep com base nos dados do Censo Escolar da Educação Básica. (Brasil. Inep, 2025b).

Figura 2 - Recursos tecnológicos disponíveis nas escolas de ensino médio, segundo a dependência administrativa

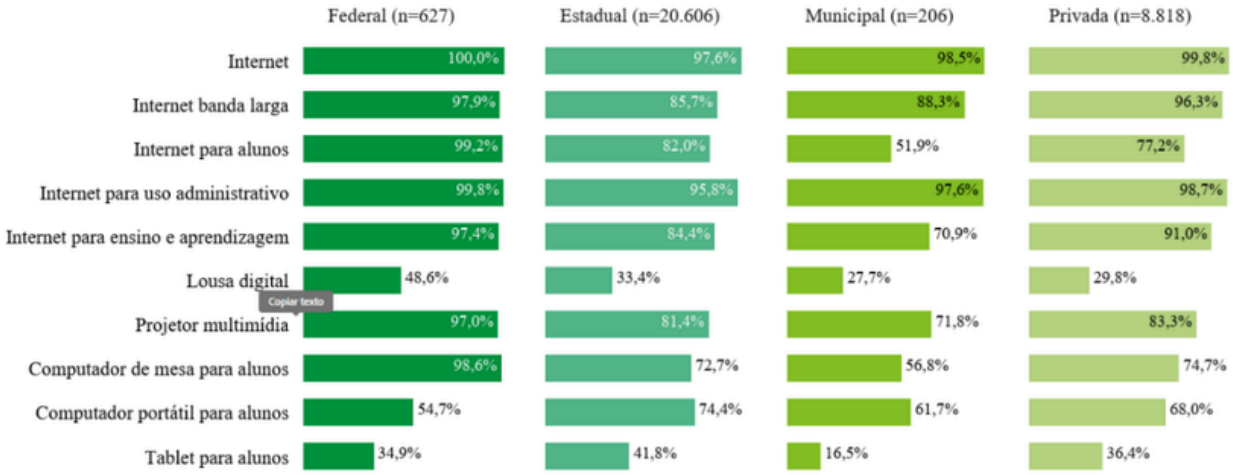

Fonte: Elaborado pela Deed/Inep com base nos dados do Censo Escolar da Educação Básica (Brasil. Inep, 2025b).

Através da análise dos índices, verificamos que as escolas brasileiras possuem condições técnicas para a adoção de recursos tecnológicos como ferramentas para a promoção da equidade na educação de alunos que apresentam diversidade de necessidades a serem adaptadas em razão de suas deficiências.

Além da questão da infraestrutura para a implementação de tecnologia assistiva nas escolas, verificamos que a literatura aponta preocupações em relação à formação dos docentes, indicando que não basta adquirir equipamentos e fornecer infraestrutura sem capacitar os professores, que precisam ter habilidades técnicas para atuar nas plataformas com o uso de IA, bem como conhecimento nos aspectos pedagógicos para a implementação de sistemas baseados em IA para adequar às necessidades de cada aluno. Para tanto, é necessário disponibilizar cursos e oficinas para que os profissionais da educação possam trocar experiências sobre o uso de IA na educação (Sousa, 2024).

3. Considerações éticas

Com a cooperação da Unesco, que visa expandir o uso da inteligência artificial a serviço de todos, o MEC publicou documento contendo orientações para o uso responsável das plataformas baseadas em IA, alinhado ao disposto na Base Nacional Comum Curricular - BNCC (MEC, 2026). O documento menciona preocupação com o uso da IA ao indicar que cerca de 49% dos jovens entre 17 e 27 anos não possuem capacidade crítica sobre a "alucinação" das plataformas de IA generativa, que é utilizada para a pesquisa e realização de atividades escolares por 37% dos estudantes, subindo para 70% em pesquisas realizadas somente por estudantes do ensino médio, enquanto apenas 43% dos professores utilizam as ferramentas como recurso pedagógico.

> Os principais documentos internacionais (incluídos no Anexo I) estabelecem uma visão estratégica global para a integração da Inteligência Artificial (IA) na educação, fundamentada em uma abordagem centrada no ser humano e no respeito aos direitos fundamentais. Iniciativas como o Consenso de Beijing (2019) e a Lei da IA da União Europeia (UNIÃO EUROPEIA, 2024) preconizam que o desenvolvimento tecnológico deve ser acompanhado por marcos regulatórios robustos que garantam a transparência, a proteção de dados e a supervisão humana constante, evitando práticas discriminatórias ou de vigilância. A finalidade central é alavancar a inovação para atingir os Objetivos de Desenvolvimento Sustentável (ODS) 4, 10 e 12, assegurando que o uso de sistemas de IA nagestão e no ensino promova a equidade e a inclusão, especialmente para grupos vulneráveis e em países menos desenvolvidos. (MEC, 2026)

Segundo o documento publicado pelo MEC, ao adotar o uso de ferramentas baseadas em IA como recurso pedagógico, se faz necessário zelar pela privacidade dos dados dos alunos, bem como a proteção contra ataques cibernéticos, adotando dispositivos constantes na lei geral de proteção de dados - LGPD (BRASIL, 2018) e no estatuto da criança e do adolescente - ECA Digital (BRASIL, 2026). Acrescenta-se às questões legais o cuidado em relação aos vieses que podem surgir em tecnologias baseadas em IA, sendo mais discutidos pela literatura os vieses em relação ao gênero e raça (S. Ponmalar, K. Naveen Kumar, RV Balaji, T. Rohith e AK Naren Kaarthick, 2025).

Os autores supracitados apresentaram na Terceira Conferência Internacional sobre Inteligência Aumentada e Sistemas Sustentáveis (ICAISS), realizada em 2025, estudos de casos contendo considerações acerca da probabilidade de apresentação de vieses de dados, que apresenta problemas nos dados inseridos na plataforma, algorítmico, em que o sistema interpreta informações de forma equivocada e/ou enviesada e o viés interativo, que surge através a interação entre a plataforma de IA e o usuário, podendo gerar discriminação e criar ciclos de feedbacks, citando três casos de vieses discriminatórios em relação ao sexo do usuário em empresas que utilizavam plataformas apoiadas pela IA (Ponmalar et al.; 2025).

4. Metodologia

Com o intuito de buscar informações acerca da possibilidade de uso da IA como recurso pedagógico para a facilitação na aprendizagem de alunos com deficiência, realizamos uma revisão sistemática de literatura - RSL, que consiste na síntese de forma padronizada e rigorosa de obras já publicadas acerca de determinado tema. (Campos; Caetano & Gomes, 2023).

O método Systematic-Serch Flow (SSF) (Ferenhof & Teza, 2025) foi adotado nesta pesquisa por meio dos seguintes passos:

1. Protocolo de pesquisa, com a definição de palavras-chave e consulta às bases de pesquisa Google acadêmico, Scielo, Portal Cape e IEE - Xplore Digital Library, digitando as palavras-chave da pesquisa em português nos três primeiros portais e em inglês nesta plataforma de pesquisa, utilizando filtros de pesquisa para documentos publicados a partir de 2021;

2. Leitura e seleção de títulos: nesta etapa foram selecionados os artigos mais recentes que apontam relação entre IA e educação, iniciando com a análise de 1.360 títulos, sendo excluídos os mais antigos e sem relevância com o tema.

Após a triagem realizada através da leitura dos títulos, foi realizada leitura dos documentos com o auxílio da plataforma NotebookLM para resumo de seis artigos, sendo os demais analisados através de leitura dinâmica, já que verificamos que a IA não estava sendo fiel aos resumos produzidos;

3. Análises de dados, etapa que consistiu na organização dos dados coletados do material selecionado para a pesquisa, que contou com artigos científicos, conferências e normas legais;

4. Confecção de fichamentos: as publicações utilizadas nesta pesquisa, no total de 21, foram resumidas após leitura integral das obras com a inclusão das referências bibliográficas na data da confecção dos fichamentos ;

5. Escrita: Os critérios de inclusão foram feitos por meio de seleção de revisões sistemáticas escritas nos últimos 5 anos, além de consulta à legislação e normativas internacionais nas línguas português, inglês e espanhol na investigação do problema de pesquisa proposto que tem como escopo a verificação da possibilidade de utilização da IA na educação inclusiva.

5. Análise e discussão de resultados

O método Systematic-Search Flow (SSF) foi utilizado na pesquisa para facilitar a estruturação da revisão sistemática de literatura, que busca respaldo em trabalhos científicos publicados com o intuito de mitigar o viés da autora. O primeiro capítulo foi dedicado à análise da base legal que fundamenta a educação inclusiva e questões conceituais do DUA. Já o segundo capítulo traz informações acerca do uso de IA na educação de alunos com deficiência como forma de facilitar a aprendizagem.

A análise de infraestrutura da educação, formação de docentes e considerações éticas foram discutidas no terceiro capítulo, demonstrando a viabilidade da implantação de plataformas baseadas em IA nas escolas públicas e privadas, por meio de análise dos dados do último censo da educação (Brasil. Inep, 2025). Apesar de verificar a viabilidade do uso de Aa na educação de alunos com deficiência, por meio de investigação da infraestrutura e adoção do DUA, constatamos que a pesquisa sobre questões éticas é incipiente.

Para sintetizar os achados da revisão sistemática de literatura quanto ao uso da tecnologia no apoio à aprendizagem, apresenta-se o quadro abaixo. Nele, relacionam se as principais ferramentas identificadas, os tipos de inteligência artificial empregados, o público-alvo, os benefícios proporcionados ao ensino inclusivo e as limitações reportadas.

Quadro 1 - Ferramentas e Aplicações de IA na Educação Inclusiva

Ferramenta / Recurso	**Tipo de IA / Tecnologia**	**Público alvo**	**Deficiência / Necessidade Atendida**	**Benefícios**
DOSVOX	Sistema operacional com síntese de voz/ tecnologia assistiva	Estudantes e pessoas com deficiência visual	Deficiência visual	Permite o acesso a informações no ambiente digital por pessoas cegas.
Chat GPT (e Modelos de Linguagem LLM)	IA Generativa, Modelos de Linguagem de Larga Escala (LLM) e AIoT / Deep Learning	Estudantes com deficiência e professores	Deficiência visual, auditiva, cognitiva e dificuldades de aprendizagem	Conversão de texto em fala, reconhecimento de fala, legendagem em tempo real, respostas alinhadas ao DUA, explicação simplificada e engajamentos sem julgamentos
Sistemas de Tutoria Inteligente (STIs) e Chatbots Educacionais	Sistemas Adaptativos, Agentes Inteligentes e Programas de Conversação Computacional	Estudantes com deficiência e docentes	Deficiência cognitiva, intelectual e ritmo individualizado de aprendizagem	Adaptação automatizada do currículo, suporte contínuo para perguntas/respostas e envio de feedbacks em tempo real para o professor.
Sistema de e-Learning Adaptativo Multiagentes (El Fazazi et al., 2021)	Aprendizado de Máquina (Machine Learning), Aprendizado por Reforço e Multiagentes	Estudantes com necessidades diversas e educadores	Múltiplos tipos de deficiência e diferentes estilos de aprendizagem	Personalização de conteúdos estruturada em camadas (dados pessoais, tipo de deficiência e estilo de aprendizagem)

continua

continuação

Leitores de Tela por IA, Tradutores de Libras e Reconheci-mento de Imagens	Visão Computacional, Processamento de Linguagem Natural (PLN) e Reconheciment o de Padrões	Estudantes com deficiências sensoriais e motoras	Deficiência visual, auditiva e psicomotora	Descrição de ambientes e imagens, transcrição de voz para texto e facilitação da comunicação em Libras, promovendo autonomia.

Fonte: Elaborado pela autora (2026)

6. Considerações finais

Mediante análise das informações dispostas neste artigo, verificamos que a legislação tem acompanhado a evolução da tecnologia no que se refere à utilização de IA para alunos com deficiência, facilitando a adoção de novas tecnologias com o intuito de adaptar os currículos a características e necessidades diversas de alunos que compõem a mesma classe.

Um currículo padrão, destinado às massas, e métodos tradicionais de ensino pode fomentar a exclusão do aluno que apresenta alguma dificuldade. Compreendemos que a pedagogia tem demonstrado avanços em consonância com a legislação, passando a adotar técnicas como o DUA, com o escopo de flexibilizar currículos que se adaptam aos alunos. Plataformas diversas têm sido criadas no intuito de facilitar o aprendizado dos alunos com deficiência, sendo constatado que há viabilidade técnica para sua utilização nas redes públicas e privadas de ensino, visto que o último censo da educação aponta que a maioria das escolas têm acesso à internet e recursos tecnológicos.

Apesar de constatar a viabilidade estrutural para a adoção de plataformas baseadas em IA como ferramenta no auxílio da aprendizagem do aluno com deficiência, a literatura aponta preocupação em relação às questões éticas, seja em razão de falta de legislação específica ou pela possibilidade da criação de viés discriminatório.

Em relação aos vieses apontados pela literatura, detectamos incipiência nos estudos em relação às discriminações voltadas aos alunos com deficiência, visto que os trabalhos científicos analisados apontam vieses relacionados ao gênero e raça do usuário.

Referências

Almeida, A. B. B. Uso de Agentes Inteligentes em Contextos Educacionais: Chatbots Educacionais e Tutores Inteligentes. **Remunom**, v 01.03, p.1-14., 2025. DOI: 10.61164/v3qvve66

BRASIL. **Decreto n. 9.854 de 25 de junho de 2019**. Institui o Plano Nacional de Internet das Coisas. Disponível em: <https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/transformacaodigital/internet-das-coisas> Acesso em: 12 de mai. 2026.

BRASIL, **Decreto n. 12.686 de 20 de outubro de 2025**. Política Nacional de Educação Especial Inclusiva e a Rede Nacional de Educação Especial Inclusiva. Diário Oficial da União: seção 1, Brasília, DF, 21 out. 2025.

BRASIL. **Inteligência Artificial na Educação Básica**. Ministério da Educação - MEC. 2026. Disponível em: https://www.gov.br/mec/pt-br/escolas<-conectadas/documentos/ia-educacao-basica.pdf>. Acesso em: 03 mai. 2026.

BRASIL. **Instituto Nacional de Estudos e Pesquisas Educacionais - INEP**. Disponível em: <https://www.gov.br/inep/pt-br/areas-de-atuacao/pesquisas-estatisticas-e-indicadores/ideb> Acesso em: 03 mai. 2026.

BRASIL. **Lei 13.709**. Lei Geral de Proteção de Dados - LGPD. Diário oficial da União: 14 de agosto de 2018.

BRASIL. **Lei 15.2011/2025**. Estatuto da Criança e do Adolescente para o ambiente virtual. Diário oficial da União: 17 de março de 2026.

Camisão, V.; Pamplona, M. & Ades, R. **Acessibilidade e Educação Inclusiva**. 2004. Disponível em: <https://www.acessibilidade.net/at/kit2004/Programas%20CD/ATs/cnotinfor/Relatorio_Inclusiva/pdf/Acessibilidade_extra_pt.pdf >. Acesso: 21 abril 2026.

Campos, A. F. M.; Caetano, L. M. D. & Gomes, V. M. L. R.. Revisão Sistemática de Literatura em Educação: Características, estrutura e Possibilidades às Pesquisas Qualitativas. **Linguagens, Educação e Sociedade,** v. 27, n. 54, 2023. DOI: 10.26694/rles.v27i54.2702

Costa, A. A.; Cordeiro, I. G. R. & Larguesa, F. S. de A. Alfabetização e deficiência cognitiva: o papel da educação inclusiva e da inteligência artificial. **Revista Processando o Saber,** [s. l.], v. 17, n. 01, 197-211, 6 jun. 2025. DOI 10.5281/zenodo.15492977.

Ferenhof, H. A. & Teza, R. F. F. Desmistificando a revisão da literatura na era da ia: atualizando o método ssf com o suporte da inteligência artificial generativa. **Biblios** (Peru), v., n. 88, 2025.

Freire, P. **Pedagogia do oprimido**. 50. ed. Rio de Janeiro: Paz e Terra, 2011.

Fazazi, H. E.; Elgarej, M.; Qbadou, M. & Mandouri, K. Design of an Adaptive e-Learning System based on Multi-Agent Approach and Reinforcement Learning. **Eng. Technol. Appl. Sci. Res**., vol. 11, no. 1, pp. 6637–6644, fev. 2021.

Heredero, E. S. Diretrizes para o Desenho Universal para a Aprendizagem (DUA). Revisão de Literatura. **Rev. bras. educ. espec**., 26 (4), oct-Dec 2020. DOI: https://doi.org/10.1590/1980-54702020v26e0155.

IBM. **O que é IoT (internet das coisas)?** Disponível em: <https://www.ibm.com/br-pt/think/topics/internet-of-things>. Acesso em 12 mai. 2026.

Lopes, L. V. S. Tecnologias Educacionais e Aprendizagem Adaptativa: Perspectivas para a Educação 5.0. **Revista Tópicos**, Rio de Janeiro, v. 4, n. 32, p. 1-19, 2026. ISSN: 2965-6672.

Mitre, X. & Zeneli, M. **Using AI to Improve Accessibility and Inclusivity in Higher Education for Students with Disabilities**. In: 21st International Conference on Information Technology Based Higher Education and Training (ITHET), Paris, France, 2024, pp. 1-8, doi: 10.1109/ITHET61869.2024.10837607.

ONU - Organização das Nações Unidas. **Declaração Universal dos Direitos Humanos**. 1948. Disponível em: unicef.org. Acesso em: 19 abr. 2026.

Ponmalar, S.; Kumar, K. N.; Balaji, R. V.; Rohith, T. & Kaarthick, A. K. N. Desafios Éticos e Viés na IA do Mundo Real: Uma Abordagem Orientada à Imparcialidade para Sistemas de Triagem de Currículos. In: Third International Conference on Augmented Intelligence and Sustainable Systems (ICAISS) , Trichy, Índia, 2025, pp. 674-681, 2025. DOI: 10.1109/ICAISS61471.2025.11042179.

Sousa, R. R. A. de. Desafios da implementação da IA na educação: quais são os desafios práticos de implementar a IA nas instituições educacionais?. **Revista Interseção**, 6(1), 272–296, 2024.

Telaska,T. dos S. & Lopes, D. A. Inclusão de crianças com transtorno do espectro autista: Revisão sistemática da literatura. **Revista de Psicopedagogia.** 2022. DOI: https://doi.org/10.51207/2179-4057.20220040.

Valls, L. N. &; Cardoso, A. P. A Inteligência Artificial como Ferramenta de Inclusão para Pessoas com Deficiência na Educação Profissional: Olhares a partir da experiência do Senac Comunidade. **Competência**, Porto Alegre, v. 18, n. 1, jul. 2025.

Declaração de uso de IA

Durante a preparação deste trabalho, a autora utilizou as plataformas Perplexity para consultar ideias para estruturação deste artigo e referências bibliográficas. Após o uso desta ferramenta com o tema do artigo constando no prompt, a autora acessou as páginas que continham os artigos.

Como ferramenta de resumo na fase de seleção de artigos foi utilizado a ferramenta Notebook LM com o intuito de agilizar a triagem do material de pesquisa. O artigo foi inserido na plataforma NotebookLM para a confecção do resumo em seis artigos.

Declaro a utilização da plataforma Gemini para a confecção do Quadro Comparativo: Ferramentas e Aplicações de IA na Educação Inclusiva. Que não foi utilizada a IA na redação do artigo, sendo revisado e editado o conteúdo em conformidade com o método científico e assumindo total responsabilidade pelo conteúdo da publicação.

Sobre o autor(a)

Ludmila Oliveira Daufenbach

Mestranda em Tecnologias da Informação e Comunicação pelo Programa de Pós-graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina (UFSC).

Especialização em processo penal de direito penal pela Faculdade IDC (2011) e em Gestão de Segurança Pública e Investigação Criminal Aplicada pela Academia da Polícia Civil de Santa Catarina (2019).

Escrivã da Polícia Civil.

Lattes: http://lattes.cnpq.br/4459007054966993

CAPÍTULO 14

Tecnologias assistivas baseadas em Inteligência Artificial: uma revisão bibliográfica

Willians Rodrigo Rossa

1. Introdução

O acesso à educação de qualidade é um direito humano e uma das bases do desenvolvimento do indivíduo e da sociedade. Estudantes com deficiência, porém, continuam a enfrentar barreiras ao acesso equitativo às oportunidades educacionais, tanto em ambientes tradicionais quanto em contextos digitais (Habib; Jelani; Najla, 2022). Contra esse quadro se organiza a educação inclusiva, modelo voltado a assegurar acesso igualitário à educação de qualidade a todos os estudantes, independentemente de suas necessidades individuais, habilidades ou condição socioeconômica. Seu objetivo central é remover barreiras à aprendizagem e criar condições para que todos os aprendizes participem ativamente do processo educativo (Nusheva; Yankova-Hadzhieva, 2025).

Marcos internacionais reiteram a necessidade de eliminar as barreiras que impedem o acesso de aprendizes com deficiência à educação de qualidade, entre eles a iniciativa Educação para Todos, da UNESCO, e a Convenção das Nações Unidas sobre os Direitos das Pessoas com Deficiência (Venus, 2025). A integração da Inteligência Artificial (IA) responde a esse mesmo compromisso e se alinha ao Objetivo de Desenvolvimento Sustentável 4 (ODS 4) das Nações Unidas, voltado à educação inclusiva e equitativa de qualidade: a IA pode reduzir barreiras de acessibilidade e ampliar as oportunidades de aprendizagem para estudantes com deficiência (Khlaif et al., 2026).

O avanço da Inteligência Artificial nos últimos anos alterou o panorama educacional. Aprendizado de máquina, processamento de linguagem natural e sistemas de tutoria inteligente vêm sendo empregados para aprimorar o ensino e a aprendizagem por meio de feedback adaptativo, conteúdo personalizado e análises orientadas por dados (Dabaghi; D'Urso; Sciarrone, 2026). Mais do que oferecer

suporte técnico, a IA tem impulsionado práticas educacionais mais inclusivas e flexíveis, com efeito direto sobre o apoio a aprendizes com necessidades educacionais específicas.

As tecnologias assistivas já sustentam há tempos a educação inclusiva, ao disponibilizar recursos de aprendizagem e facilitar o envolvimento de estudantes com deficiência (Venus, 2025). A evolução recente da IA ampliou de forma expressiva o alcance desses recursos. Sistemas baseados em IA permitem funcionalidades aprimoradas de reconhecimento de voz, legendagem automática, tutoria inteligente e aprendizagem adaptativa, ajustando dinamicamente o conteúdo instrucional às necessidades de cada aprendiz (Venus, 2025). Para estudantes com deficiências visuais, físicas e cognitivas, essas ferramentas removem barreiras de acesso e favorecem autonomia, engajamento acadêmico e acessibilidade ao conteúdo (Kooli; Chakraoui, 2025).

Entre as soluções baseadas em IA voltadas à inclusão estão os leitores de tela, os assistentes de voz, as interfaces de processamento de linguagem natural, os sistemas de texto para fala e fala para texto, as plataformas de aprendizagem adaptativa e os ambientes de realidade virtual e aumentada (Kooli; Chakraoui, 2025; Habib; Jelani; Najla, 2022; Nusheva; Yankova-Hadzhieva, 2025). Esses recursos oferecem a aprendizes com deficiências visuais, auditivas, cognitivas e motoras meios alternativos de acessar o conteúdo educacional e de interagir com as plataformas de aprendizagem (Venus, 2025).

A Inteligência Artificial Generativa alargou o repertório, ao facilitar a tradução, a tutoria individualizada e a criação de materiais adaptados às necessidades dos estudantes (Khlaif et al., 2026). Esse potencial, contudo, não se realiza sem desafios técnicos e éticos. Infraestrutura tecnológica insuficiente, formação inadequada de professores, restrições de financiamento, preocupações com a privacidade de dados e viés algorítmico figuram na literatura como obstáculos recorrentes (Venus, 2025; Kooli; Chakraoui, 2025; Naveen Kumar et al., 2026).

Há ainda uma tendência a examinar tecnologias assistivas isoladamente, sem investigar como poderiam articular-se para sustentar experiências de aprendizagem inclusivas em escala (Venus, 2025). A mesma fragmentação se manifesta no descompasso entre IA, tecnologia assistiva e desenho pedagógico, que costumam evoluir em paralelo, e não em conjunto, limitando o potencial coletivo de promover equidade (Koranteng, 2025).

Esse panorama justifica uma revisão bibliográfica que sistematize o conhecimento recente sobre as tecnologias assistivas baseadas em Inteligência Artificial e seu lugar na educação inclusiva. O objetivo geral deste artigo é analisar, a partir da literatura científica recente, de que modo as tecnologias assistivas fundamentadas em IA e os sistemas adaptativos de aprendizagem podem ampliar o acesso, o engajamento e a

personalização da aprendizagem de estudantes com deficiência, além de identificar os benefícios, os desafios e as lacunas associados à sua adoção em contextos educacionais inclusivos.

Os objetivos específicos são: (i) identificar e categorizar as principais tecnologias assistivas baseadas em Inteligência Artificial e os sistemas adaptativos de aprendizagem voltados a estudantes com deficiência; (ii) sistematizar os benefícios atribuídos a essas tecnologias no que se refere ao acesso, à personalização, ao engajamento e à autonomia dos estudantes; (iii) mapear os desafios e as barreiras (técnicos, formativos, financeiros, pedagógicos e éticos) associados à adoção dessas tecnologias em contextos educacionais inclusivos; e (iv) identificar lacunas na literatura que apontem direções para pesquisas futuras sobre o tema.

O objeto de estudo são as tecnologias assistivas baseadas em Inteligência Artificial aplicadas à educação inclusiva de estudantes com deficiência, conforme descritas na literatura científica recente. A pergunta de pesquisa que norteia este artigo é a seguinte: de que modo as tecnologias assistivas baseadas em Inteligência Artificial e os sistemas adaptativos de aprendizagem têm contribuído para a educação inclusiva de estudantes com deficiência, segundo a literatura científica recente?

O trabalho organiza-se em quatro seções. O referencial teórico reúne os fundamentos conceituais sobre IA na educação, sistemas adaptativos de aprendizagem, tecnologias assistivas e educação inclusiva. A metodologia descreve o protocolo de busca sistemática adotado. A análise e discussão dos resultados integra e interpreta os achados dos estudos selecionados. As considerações finais sintetizam as contribuições do estudo e apontam direções para pesquisas futuras.

2. Referencial Teórico

Este referencial organiza-se em torno de quatro eixos conceituais que estruturam o objeto de estudo: a Inteligência Artificial na educação, os sistemas adaptativos de aprendizagem, as tecnologias assistivas e a educação inclusiva. Os quatro se entrelaçam na constituição de ambientes de aprendizagem mais equitativos, ainda que, como adverte Koranteng (2025), com frequência evoluam em paralelo, sem articulação entre si. A discussão a seguir delineia os fundamentos de cada eixo e situa suas zonas de convergência.

2.1. Educação inclusiva e acessibilidade

A educação inclusiva consolidou-se como um dos objetivos centrais dos sistemas educacionais contemporâneos, orientada à oferta de oportunidades de aprendizagem

equitativas a todos os estudantes, a despeito de suas diferenças físicas, cognitivas e socioemocionais (Venus, 2025). Seu propósito é remover barreiras à aprendizagem e criar condições para a participação ativa de todos os aprendizes, alcance que abrange crianças com necessidades educacionais especiais, estudantes de comunidades marginalizadas, migrantes e aprendizes com diferentes estilos de aprendizagem (Nusheva; Yankova-Hadzhieva, 2025).

Convém demarcar conceitualmente os termos que sustentam o campo. Khlaif *et al*. (2026) distinguem três noções correlatas, porém não equivalentes: a equidade refere-se a prover a cada aprendiz o apoio apropriado para que alcance resultados comparáveis; a acessibilidade diz respeito à remoção de barreiras físicas, tecnológicas e sistêmicas à participação; e a inclusão estende-se para além do acesso, ao enfatizar o engajamento significativo e o sentimento de pertencimento.

A distinção tem consequências teóricas: desloca o entendimento de inclusão de uma lógica de provisão material para uma lógica de participação e representação. Os próprios autores ampliam essa dimensão ao demonstrar que, para aprendizes com deficiência visual, a inclusão depende da visibilidade cultural e linguística, e não só da conectividade.

O respaldo normativo do campo vem de marcos internacionais, entre eles a iniciativa Educação para Todos, da UNESCO, e a Convenção das Nações Unidas sobre os Direitos das Pessoas com Deficiência, que propõem contextos pedagógicos pautados pelo engajamento, pela disponibilidade e pela igualdade nas atividades de aprendizagem (Venus, 2025). O endosso normativo não eliminou o descompasso entre a formulação e a realidade vivida pelos estudantes.

Aprendizes com deficiência visual, auditiva ou cognitiva enfrentam dificuldades consideráveis para acessar recursos educacionais, participar de tarefas e operar sistemas de aprendizagem on-line, com baixo envolvimento acadêmico como resultado frequente (Venus, 2025).

A expansão dos ambientes digitais de aprendizagem criou possibilidades de acesso e, ao mesmo tempo, riscos de exclusão. Venus (2025) observa que ambientes digitais concebidos sem princípios de design inclusivo podem agravar problemas de acessibilidade: interfaces mal desenvolvidas restringem o acesso de aprendizes com deficiência visual, ao passo que recursos baseados em áudio desfavorecem estudantes com deficiência auditiva.

Diante desse paradoxo, a literatura recorre ao Desenho Universal para a Aprendizagem (*Universal Design for Learning* – UDL), que valoriza um design instrucional flexível, dotado de múltiplos meios de representação, engajamento e expressão, capaz de contemplar a variabilidade dos aprendizes (Venus, 2025; Koranteng, 2025). Rao e Meo, citados por Koranteng (2025), enfatizam que o UDL

converte o design de aulas de uma lógica de acomodação em uma lógica de inclusão, e transfere a acessibilidade da condição de resposta posterior à identificação de barreiras para a de princípio antecipatório de projeto.

2.2. Inteligência Artificial na educação

A Inteligência Artificial tem reconfigurado o panorama educacional ao abrir possibilidades de aprimoramento da acessibilidade, da personalização e da aprendizagem inclusiva (Khlaif et al., 2026). Do ponto de vista funcional, os sistemas de IA analisam grandes volumes de dados, identificam padrões complexos e ajustam suas respostas conforme as ações do usuário.

Essa capacidade sustenta tecnologias educacionais inteligentes voltadas à oferta de experiências de aprendizagem personalizadas a estudantes com deficiência (Venus, 2025). Integram esse repertório o aprendizado de máquina (machine learning), o processamento de linguagem natural (**Natural Language Processing** – NLP) e os sistemas de tutoria inteligente (**Intelligent Tutoring Systems** – ITS), empregados para aprimorar o ensino por meio de feedback adaptativo, conteúdo personalizado e análises orientadas por dados (Dabaghi; D'Urso; Sciarrone, 2026).

No campo da educação especial, Venus (2025) sistematiza as aplicações de IA de maior alcance. Os sistemas de reconhecimento de voz convertem a fala em texto e auxiliam aprendizes com dificuldades motoras ou de escrita. As aplicações de texto para fala transformam informação escrita em áudio de sonoridade natural, o que beneficia estudantes com deficiência visual ou dislexia.

A legendagem automática baseada em NLP gera legendas em tempo real durante videoaulas e amplia o acesso de estudantes com deficiência auditiva. Já os sistemas de tutoria inteligente fornecem feedback individualizado e apoio instrucional adaptativo conforme o comportamento de aprendizagem do estudante. Esse mesmo conjunto reaparece, com nuances, nos demais estudos do corpus, o que sugere certa estabilidade conceitual quanto às categorias funcionais da IA aplicada à inclusão.

A passagem das abordagens baseadas em regras e em estatística básica para os modelos de aprendizagem profunda marca uma virada nesse campo. Dabaghi, D'Urso e Sciarrone (2026) situam 2018 como fronteira qualitativa, ano que coincide com a emergência das arquiteturas *Transformer* e o início da era moderna do aprendizado profundo, quando se tornaram viáveis sistemas mais adaptativos e linguisticamente poderosos.

Os sistemas anteriores a esse marco, observam os autores, apresentavam quatro limitações: dificuldade de adaptação às diferenças individuais de aprendizagem, baixa naturalidade nas tecnologias de texto para fala, dependência de conjuntos de dados

restritos nas ferramentas de diagnóstico e opacidade nos processos de decisão, esta última comprometendo a confiança de educadores e aprendizes.

Dessa transição emerge a Inteligência Artificial Generativa. Ela entrega funcionalidades instrucionais já consolidadas, como geração e revisão de conteúdo, feedback e apoio à compreensão de conceitos complexos, mas o faz por meio de modelos de linguagem de grande escala (Large Language Models – LLMs) de propósito geral, que interagem em linguagem natural e tornam o suporte mais imediato, aberto e transferível entre disciplinas (Khlaif et al., 2026).

Zapata-Rivera et al. (2024) descrevem funcionamento semelhante: os sistemas de GenAI extraem insights de vastos volumes de dados, analisam o nível de proficiência, o estilo e o ritmo de aprendizagem do estudante e ajustam o material conforme suas necessidades, com possibilidade de atuar como tutores disponíveis para além do horário regular de aula. Os autores ponderam que o uso da GenAI como tutora exige investigação adicional sobre a acurácia das respostas e também sobre seu conteúdo emocional, dado o peso das emoções na aprendizagem.

2.3. Sistemas adaptativos de aprendizagem

Os sistemas adaptativos de aprendizagem estão entre as aplicações mais expressivas da IA na educação inclusiva. Essas plataformas operam com algoritmos de aprendizado de máquina para prever o comportamento de aprendizagem, as tendências de desempenho e o engajamento dos estudantes, e customizam o material instrucional de modo contínuo (Venus, 2025). O princípio que as organiza é a personalização: a partir da análise do desempenho do estudante, o sistema ajusta dinamicamente o conteúdo, o nível de dificuldade e os percursos de aprendizagem segundo as necessidades de cada aprendiz (Venus, 2025).

Quando o estudante apresenta dificuldade em determinado tópico, o sistema pode oferecer explicações complementares, material simplificado ou exercícios de prática; diante de boa compreensão, pode introduzir recursos mais sofisticados. Para estudantes com deficiências cognitivas, dificuldades de aprendizagem ou questões relacionadas à atenção, esses sistemas representam um aporte considerável, uma vez que os planos individualizados permitem aprender em ritmo próprio e obter assistência instrucional focada (Venus, 2025).

Habib, Jelani e Najla (2022) acrescentam que a aprendizagem adaptativa potencializada pela IA processa grandes conjuntos de dados sobre o modo como os estudantes abordam seus estudos e altera automaticamente a instrução. Desse processamento resultam análises preditivas que apontam áreas de dificuldade de estudantes com deficiências cognitivas e permitem a intervenção docente antes que a defasagem se acentue.

A literatura registra exemplos concretos dessas plataformas. Nusheva e Yankova-Hadzhieva (2025) citam Knewton, Smart Sparrow e DreamBox, que empregam análise de dados para melhorar a aprendizagem, além de IBM Watson Education e Squirrel AI, que analisam o estilo de aprendizagem de cada estudante e ofertam conteúdo apropriado. Em Venus (2025), aparecem DreamBox Learning, Smart Sparrow e Carnegie Learning, plataformas que produzem experiências educacionais personalizadas com apoio de analítica de aprendizagem e IA.

O conjunto mapeado por Naveen Kumar et al. (2026) é mais amplo: MATHia, ALEKS, Knewton Alta e DreamBox, distribuídas em categorias como sistemas de tutoria inteligente e plataformas de aprendizagem adaptativa, com evidências de melhoria na proficiência matemática em ambientes adaptativos. Chama atenção a recorrência das mesmas soluções em levantamentos independentes: DreamBox aparece nos três estudos e Smart Sparrow em dois, o que sugere concentração da produção acadêmica em um número reduzido de produtos comerciais e recomenda cautela ao generalizar os achados para o campo como um todo.

Há, porém, uma tensão teórica registrada na literatura. Ao compararem três plataformas (texto para fala, aprendizagem gamificada e realidade virtual), Habib, Jelani e Najla (2022) constataram que o engajamento, embora correlacionado com o desempenho acadêmico, não se traduz automaticamente em ganhos de aprendizagem.

A plataforma gamificada, apesar do elevado engajamento (78%), apresentou a menor melhoria nos testes (25%). Diante desse resultado, os autores advertem que a gamificação pode priorizar a motivação e o entretenimento em detrimento da prática acadêmica substantiva. O achado sugere que a eficácia dos sistemas adaptativos depende menos da sofisticação técnica do que do alinhamento a fundamentos pedagógicos consistentes.

2.4. Tecnologias assistivas baseadas em IA

Tecnologia assistiva pode ser definida como qualquer ferramenta, programa de computador ou mecanismo que confere à pessoa com deficiência melhores capacidades funcionais e permite o engajamento em atividades que, de outro modo, seriam difíceis ou impossíveis (Venus, 2025). No domínio educacional, essas tecnologias facilitam o acesso a materiais de aprendizagem, a comunicação e a operação de plataformas on-line. Entre as convencionais estão os leitores de tela, os programas de ampliação, os dispositivos de entrada alternativos e os programas de comunicação aumentativa (Venus, 2025).

A incorporação da IA ampliou de forma expressiva as capacidades dessas tecnologias. Kooli e Chakraoui (2025) mostram que os leitores de tela convencionais

operam por conversão linear e pré-programada de texto em fala, ao passo que os sistemas orientados por IA oferecem modulação adaptativa da fala, ênfase contextual e navegação preditiva das plataformas. Os autores distinguem três categorias de interfaces: leitores de tela e assistentes de voz, voltados a estudantes com deficiência visual e física; ferramentas de reconhecimento de fala e ditado, dirigidas a estudantes com deficiências motoras e dificuldades de escrita; e interfaces de NLP, que apoiam estudantes com deficiências de linguagem e cognitivas, em especial os com Transtorno do Espectro Autista (TEA).

Os métodos tradicionais de apoio, como auxiliares de ensino, glossários estáticos ou guias de leitura, não acompanham o processo do estudante em tempo real. As ferramentas de NLP baseadas em IA proporcionam feedback dinâmico e individualizado, ajustado ao que o estudante lê ou escreve e ao modo como processa e responde (Kooli; Chakraoui, 2025).

O repertório documentado é amplo. Naveen Kumar et al. (2026) relatam que a tecnologia de texto para fala melhora de forma significativa a compreensão leitora de estudantes com dislexia; que tecnologias de reconhecimento automático de fala alcançam alta acurácia na geração de legendas em tempo real para estudantes surdos ou com deficiência auditiva; e que sistemas de Comunicação Aumentativa e Alternativa (Augmentative and Alternative Communication – AAC), inclusive baseados em rastreamento ocular, ampliam a independência comunicativa de aprendizes com deficiências motoras severas.

O mesmo estudo aponta o lugar emergente da Edge AI e do TinyML, que permitem inferência em dispositivos de baixo consumo, com redução de latência e preservação da privacidade. O recurso interessa sobretudo a ambientes com restrição de banda, situação comum em muitas escolas. No caso específico da dislexia, Dabaghi, D'Urso e Sciarrone (2026) identificam três frentes de aplicação da IA: detecção, apoio assistivo e aprendizagem personalizada.

A evidência disponível, ponderam, permanece fragmentada, e a validação experimental é limitada. A partir de 2024, observam os autores, a IA Generativa começa a suplantar as técnicas clássicas de aprendizado de máquina como ferramenta de apoio ao aprendiz, sobretudo por meio de chatbots inteligentes que interagem com estudantes para aprimorar o processo de aprendizagem. O uso da tecnologia nesse domínio, ainda assim, permanece largamente exploratório.

A literatura sinaliza, ainda, uma fronteira de convergência entre IA e tecnologia assistiva. Koranteng (2025) argumenta que ferramentas assistivas orientadas por IA, como a geração preditiva de texto, a legendagem adaptativa e os leitores de tela inteligentes, articulam os dois campos de modo novo. A tecnologia assistiva deixa de operar como mecanismo compensatório, acionado depois que a barreira se manifesta, e

passa a funcionar como ponte dinâmica entre a capacidade do usuário e o contexto de aprendizagem. Iannone e Giansanti, citados pelo autor, mostram que sistemas assistivos potencializados por IA, no cuidado ao autismo, interpretam sinais comportamentais e ajustam intervenções em tempo real, resultado que aponta na direção de ambientes assistivos plenamente inteligentes.

2.5. Convergências conceituais e a necessidade de integração

Articulados entre si, os quatro eixos convergem para uma constatação recorrente na literatura: o alcance da IA na educação inclusiva depende de sua integração intencional a fundamentos pedagógicos, e não da tecnologia em si. Koranteng (2025) formula essa tese de modo mais explícito ao propor o AI-Inclusive Framework (AIF), modelo conceitual que reúne a Adaptatividade de IA, a Habilitação Assistiva e os Fundamentos do UDL em uma arquitetura única, orientada ao Acesso e Empoderamento de Aprendizagem Inclusiva (*Inclusive Learning Access and Empowermen*t – ILAE).

Na proposta do autor, a camada de UDL opera como âncora pedagógica e ética. Ela verifica se os mecanismos adaptativos e assistivos permanecem alinhados a uma pedagogia inclusiva e impede que a adaptatividade derive para o viés algorítmico. Essa perspectiva integradora encontra eco em Naveen Kumar et al. (2026), para quem a capacidade técnica é necessária, mas insuficiente sem alinhamento pedagógico e prontidão institucional. Song et al., citados por Koranteng (2025), sustentam algo próximo: a inclusividade decorre do alinhamento intencional ao design pedagógico, e não da automação.

Desenha-se um consenso teórico segundo o qual personalização, acessibilidade e ampliação da atuação docente formam em conjunto a base de percursos de aprendizagem equitativos (Khlaif et al., 2026). É desse consenso que parte a análise das seções seguintes.

3. Metodologia

3.1. Caracterização da pesquisa

Esta pesquisa caracteriza-se como revisão bibliográfica de natureza qualitativa, voltada a mapear, analisar e sintetizar a produção científica recente sobre as tecnologias assistivas baseadas em Inteligência Artificial e seu lugar na educação inclusiva. Quanto aos objetivos, é exploratória e descritiva: reconhece o estado atual do conhecimento sobre o tema e descreve as convergências, divergências e lacunas identificadas no corpus analisado.

Para conferir rigor e reprodutibilidade ao levantamento e à seleção das fontes, adotou-se o método Systematic Search Flow (SSF), ou Fluxo de Pesquisa Sistemática, que organiza a revisão em quatro fases articuladas: Definição do Protocolo de Pesquisa, Análise, Síntese e Escrita. Essa estrutura reduz a arbitrariedade na seleção do material e torna explícitas as decisões tomadas em cada etapa. A escolha do método deve-se à necessidade de delimitar, com critério, um conjunto representativo de estudos a partir de um universo amplo de publicações, de modo que a seleção final responda a parâmetros objetivos e auditáveis.

3.2. Fase de definição do protocolo de pesquisa

A primeira fase do SSF consiste na definição do protocolo de pesquisa, quando se estabelecem os parâmetros que orientam a busca: a estratégia de construção da expressão de busca, as bases de dados consultadas e os critérios de inclusão e de exclusão.

- **Estratégia de busca e descritores:** A delimitação do objeto apoiou-se em quatro descritores centrais, derivados das palavras-chave da pesquisa: IA na Educação, Sistemas Adaptativos de Aprendizagem, Tecnologias Assistivas e Educação Inclusiva. A expressão de busca foi construída com operadores booleanos (AND e OR), aspas para a delimitação de termos compostos e parênteses para o agrupamento lógico das condições, o que permitiu recuperar estudos pertinentes com maior precisão. A formulação em língua inglesa ampliou o alcance da recuperação nas bases internacionais. A expressão final foi:

("AI in Education" OR "Adaptive Learning Systems") AND ("Assistive Technologies") AND ("Inclusive Education")

A lógica dessa construção articula pelo operador OR os dois descritores tecnológicos correlatos, IA na educação e sistemas adaptativos de aprendizagem, o que permite recuperar estudos que abordem qualquer uma das vertentes. O operador AND, por sua vez, impõe a coocorrência obrigatória dos descritores tecnologias assistivas e educação inclusiva. O conjunto recuperado fica restrito aos trabalhos situados na interseção dos quatro eixos conceituais que sustentam a pesquisa.

- **Bases de dados:** A busca foi conduzida em quatro bases de dados, escolhidas por sua cobertura e pertinência às áreas de tecnologia, educação e ciências da computação: o Portal de Periódicos CAPES, a IEEE Xplore, a ScienceDirect e o Google Acadêmico. Duas delas são multidisciplinares e de ampla cobertura (Portal

CAPES e Google Acadêmico); as outras duas, especializadas em tecnologia e engenharia (IEEE Xplore e ScienceDirect). A combinação equilibra amplitude e especificidade, e alcança a produção de caráter educacional e a de natureza técnica.

- **Critérios de inclusão:** Adotaram-se dois critérios de inclusão: (i) o enquadramento dos resultados na expressão de busca definida, com a presença dos descritores articulados pelos operadores booleanos; e (ii) a data de publicação posterior a 2022. A delimitação temporal assegura a atualidade do corpus e capta a produção mais recente sobre o tema, precaução pertinente em um campo de evolução rápida, sobretudo após a consolidação das arquiteturas de aprendizagem profunda e o advento da Inteligência Artificial Generativa.

Conduzida em 17 de maio de 2024, a busca retornou os seguintes quantitativos brutos:

Quadro 1 — Critérios de Inclusão

Base de dados	Resultados
Portal CAPES Periódicos	458
IEEE Xplore	3
ScienceDirect	36
Google Acadêmico	1.310
Total	1.807

Fonte: elaborado pelo autor (2026)

- **Critérios de exclusão:** A partir do universo inicial de 1.807 resultados, aplicaram-se os critérios de exclusão. Os resultados de cada base foram primeiro ordenados pelo parâmetro de "Relevância" e limitados aos 20 primeiros registros por plataforma, procedimento que concentra a análise nos estudos de maior aderência temática segundo os mecanismos de ordenação das próprias bases. A filtragem produziu 20 registros no Portal CAPES, 3 na IEEE Xplore (totalidade dos resultados disponíveis), 20 na ScienceDirect e 20 no Google Acadêmico, num subtotal de 63 registros.

Aplicaram-se, na sequência, dois critérios adicionais. Descartaram-se 12 registros

bloqueados ou sem permissão de download, o que inviabilizava o acesso ao texto integral exigido pela análise. Excluiu-se também 1 registro com observação de retratação destacada em vermelho, por comprometimento de sua confiabilidade científica. A depuração deixou um saldo de 50 registros.

- **Procedimentos de gestão e seleção final do corpus - Trecho revisado**: Os 50 registros remanescentes foram importados para o software de gerenciamento de referências Zotero, que permitiu organizar, catalogar e verificar a consistência do material. Nessa etapa, identificaram-se e eliminaram-se 2 registros duplicados, o que reduziu o conjunto a 48 artigos.

- Sobre esses 48 artigos aplicou-se nova filtragem, a partir da análise dos títulos e resumos. Parte dos textos recuperados estava redigida em idiomas distintos do português, e o Google Tradutor serviu de apoio à tradução de títulos e resumos, o que permitiu avaliar a pertinência temática de todos os registros sob critérios uniformes. O uso da ferramenta limitou-se ao suporte à compreensão dos textos, sem interferência na seleção crítica nem na análise de conteúdo.

- Da triagem por alinhamento entre o conteúdo dos resumos e o objeto da pesquisa, restaram 9 artigos, corpus definitivo sobre o qual incidiram as fases seguintes de análise e síntese. O Quadro 2 sintetiza o fluxo completo de seleção.

Quadro 2 - Fluxo de seleção do corpus segundo o método SSF

Etapa	Procedimento	Resultados
Busca bruta	Aplicação da expressão de busca nas quatro bases	1807
Filtro de relevância	Ordenação por relevância limitada a 20 registros por base	63
Exclusão por acesso e retratação	Descarte de 12 bloqueados/sem permissão e retratado	50
Gestão no Zotero	Eliminação de 2 duplicatas	48
Análise de títulos e resumos	Triagem por aderência temática (com apoio do google tradutor)	9

Fonte: elaborado pelo autor (2026)

- **Fases de análise, síntese e escrita:** Definido o corpus de 9 artigos, as fases seguintes do SSF foram conduzidas em três movimentos. A Análise consistiu na leitura integral de cada artigo e na identificação de seus elementos constitutivos: objetivos, abordagem metodológica, principais achados, benefícios e desafios reportados, organizados segundo os eixos conceituais da pesquisa. Na Síntese, esses achados foram integrados tematicamente, o que evidenciou convergências, divergências e lacunas recorrentes na literatura. A Escrita converteu os resultados dessa síntese em texto articulado, que deu origem às seções de análise e discussão apresentadas a seguir.

O corpus reúne estudos de naturezas metodológicas distintas, e essa variedade sustenta a base analítica da revisão. Entre os 9 artigos figuram revisões de literatura, qualitativas e sistemáticas, estas orientadas pelo protocolo PRISMA, estudos empíricos de abordagem qualitativa e de método misto, uma proposta de framework conceitual e um editorial científico. A composição heterogênea amplia a perspectiva analítica, ao reunir evidências empíricas, elaborações teóricas e sínteses de campo, e favorece uma compreensão mais ampla do objeto de estudo.

4. Análise e discussão dos resultados

Esta seção apresenta a análise e a discussão dos nove artigos que compõem o corpus definitivo da revisão, em duas dimensões complementares. A primeira caracteriza o corpus quanto à distribuição metodológica e temporal e às categorias de deficiência contempladas.

A segunda integra os achados em torno de eixos temáticos recorrentes na literatura: a tipologia das tecnologias assistivas baseadas em IA, os benefícios reportados, os desafios à implementação, as questões éticas e a necessidade de integração entre tecnologia e pedagogia. O percurso põe em relevo as convergências, as divergências e as lacunas que atravessam o conjunto dos estudos.

4.1. Caracterização do corpus

O corpus reúne nove estudos publicados entre 2022 e 2026, com predominância da produção mais recente: sete dos nove artigos datam de 2024 ou de anos posteriores. A concentração indica a atualidade do tema e o adensamento da produção científica depois da consolidação da Inteligência Artificial Generativa. O Quadro 3 sintetiza a caracterização dos estudos:

Quadro 3 - Caracterização do corpus analisado

Autor(es) / Ano	Abordagem metodológica	Foco / População
Vênus (2025)	Revisão qualitativa de literatura	Deficiências visial, auditiva, cognitiva e motora
Khlaif et al. (2026)	Estudo de caso qualitativo (21 participantes)	Estudantes com deficiência visual (ensino superior)
Dabagui, D'Urso e Sciarrone	Revisão sistemática (PRISMA, 72 estudos)	Estudantes com dislexia
Kooli e Chakraoui (2025)	Análise conceitual com estudos de caso	Deficiências visual, física e cognitiva
Nusheva e Yankova-Hadzhieva (2025)	Análise de soluções e práticas	Necessidades educacionais diversas
Habib, Jelani e Najla (2022)	Método misto (três plataformas)	Deficiência visual, cognitiva e TEA
Zapata-Rivera et al. (2024)	Zapata-Rivera et al. (2024)	IA Generativa na educação (geral)
Naveen Kumar et al. (2026)	Revisão sistemática (PRISMA, 30 estudos)	Transtornos do neurodesenvolvimento e deficiências
Koranteng (s.d.)	Proposta de framework conceitual	Educação inclusiva (modelo integrador)

Fonte: elaborado pelo autor (2026)

A diversidade metodológica marca o conjunto. Há três revisões de literatura, uma qualitativa (Venus, 2025) e duas sistemáticas orientadas pelo protocolo PRISMA (Dabaghi; D'Urso; Sciarrone, 2026; Naveen Kumar et al., 2026). Somam-se a elas dois estudos empíricos, um qualitativo (Khlaif et al., 2026) e um de método misto (Habib; Jelani; Najla, 2022), uma análise conceitual ancorada em estudos de caso (Kooli; Chakraoui, 2025), uma análise de soluções tecnológicas e políticas (Nusheva; Yankova-Hadzhieva, 2025), uma proposta de framework (Koranteng, 2025) e um editorial científico (Zapata-Rivera et al., 2024).

A pluralidade permite triangular evidências de ordens distintas, empíricas, sintéticas e teóricas, e ao mesmo tempo recomenda cautela na comparação direta dos achados, dada a heterogeneidade de objetivos, métodos e populações.

A cobertura de categorias de deficiência é ampla. Parte dos estudos aborda múltiplas deficiências de forma transversal (Venus, 2025; Kooli; Chakraoui, 2025; Naveen Kumar et al., 2026); outros se concentram em populações específicas, como a deficiência visual (Khlaif et al., 2026) e a dislexia (Dabaghi; D'Urso; Sciarrone, 2026). Reunidos, os dois recortes permitem identificar princípios gerais sem perder de vista as particularidades de cada condição.

4.2. Tipologia das tecnologias assistivas baseadas em IA

A primeira convergência do corpus diz respeito ao repertório de tecnologias assistivas baseadas em IA. Apesar das diferentes abordagens metodológicas, os estudos identificam um núcleo comum de soluções, indício de certa estabilidade do campo quanto às categorias funcionais. O Quadro 4 sistematiza as tecnologias mais citadas e os estudos que as documentam.

Quadro 4 — Tecnologias assistivas baseadas em IA recorrentes no corpus

Tecnologia	Função / Deficiência atendida	Estudos que a documentam
Reconhecimento de voz / fala para texto	Interação por voz; deficiências motoras e de escrita	Venus (2025); Kooli e Chakraoui (2025); Nusheva e Yankova-Hadzhieva (2025); Naveen Kumar et al. (2026)
Texto para fala (TTS)	Conversão de texto em áudio; deficiência visual e dislexia	Venus (2025); Habib, Jelani e Najla (2022); Nusheva e Yankova-Hadzhieva (2025); Naveen Kumar et al. (2026)
Legendagem automática	Legendas em tempo real; deficiência auditiva	Venus (2025); Naveen Kumar et al. (2026)
Leitores de tela	Acesso a conteúdo digital; deficiência visual	Kooli e Chakraoui (2025); Nusheva e Yankova-Hadzhieva (2025)
Plataformas adaptativas	Percursos personalizados; deficiências cognitivas	Venus (2025); Habib, Jelani e Najla (2022); Nusheva e Yankova-Hadzhieva (2025); Naveen Kumar et al. (2026)

continua

continuação

Interfaces de NLP	Simplificação e feedback; deficiências cognitivas e de linguagem	Kooli e Chakraoui (2025)
Comunicação Aumentativa e Alternativa (AAC)	Comunicação; deficiências motoras severas	Naveen Kumar et al. (2026)
Realidade virtual e aumentada	Ambientes imersivos; TEA e deficiências diversas	Habib, Jelani e Najla (2022); Naveen Kumar et al. (2026)
IA Generativa / chatbots	Tutoria, tradução e geração de conteúdo; transversal	Khlaif et al. (2026); Dabaghi, D'Urso e Sciarrone (2026); Zapata-Rivera et al. (2024)

Fonte: elaborado pelo autor (2026)

A leitura transversal do Quadro 4 revela um deslocamento no campo. As tecnologias de primeira geração, reconhecimento de voz, texto para fala, legendagem e leitores de tela, aparecem consolidadas e documentadas pela maioria dos estudos. As baseadas em IA Generativa, apontadas como promissoras, estão em estágio incipiente. Dabaghi, D'Urso e Sciarrone (2026) registram essa distinção ao constatar, a partir de 2024, a substituição progressiva das técnicas clássicas de aprendizado de máquina pela IA Generativa como ferramenta de apoio ao aprendiz, sobretudo por meio de chatbots inteligentes. Os autores ressalvam, porém, o caráter largamente exploratório desse uso e a escassa validação experimental.

A própria natureza das tecnologias se transforma com a incorporação da IA. Kooli e Chakraoui (2025) demonstram que os leitores de tela orientados por IA superam a conversão linear e pré-programada dos sistemas convencionais, ao oferecer modulação adaptativa da fala, ênfase contextual e navegação preditiva. O repertório não cresce apenas em extensão: muda a capacidade de adaptação das ferramentas. Essa capacidade, como se verá adiante, é sua maior força e a origem de novos desafios.

4.3. Benefícios reportados

Os benefícios atribuídos às tecnologias assistivas baseadas em IA convergem em quatro dimensões: acessibilidade, personalização, engajamento e autonomia. A ampliação da acessibilidade é o benefício mais consensual. Venus (2025) sustenta que ferramentas como reconhecimento de voz, texto para fala e legendagem automática

removem barreiras ao abrir vias alternativas de acesso à informação: estudantes cegos passam a acessar livros didáticos em áudio, e estudantes surdos acompanham aulas por legendas geradas automaticamente.

O achado empírico de Habib, Jelani e Najla (2022) sustenta essa leitura. Entre as três plataformas avaliadas, a de texto para fala obteve o maior índice de engajamento (85%) e o maior ganho nos testes (30%), resultado que levou os autores a concluir que a remoção de barreiras básicas de acessibilidade produz efeito acadêmico mais imediato.

A personalização da aprendizagem é a segunda dimensão. Venus (2025) observa que a IA permite ajustar o material educacional ao ritmo, às habilidades e às necessidades de cada estudante, o que supera a abordagem homogênea do ensino tradicional. No terreno da IA Generativa, Khlaif et al. (2026) aprofundam a noção: para aprendizes com deficiência visual, a adaptabilidade precisa incluir a flexibilidade de modalidade, com alternância entre texto, áudio e formatos simplificados, e a agilidade da resposta.

Para essa população, os dois atributos são requisitos de acessibilidade, e não conveniências adicionais. Os relatos dos participantes, sintetizados pelos autores, mostram a face subjetiva do benefício: a IA é descrita como um assistente que compreende o estilo de aprendizagem do estudante e reduz a sensação de exclusão nas discussões em sala.

O aumento do engajamento e da participação é a terceira dimensão. Habib, Jelani e Najla (2022) registram índices elevados nas três plataformas avaliadas, 85%, 78% e 82%, e atribuem os resultados à capacidade de adaptar o material às habilidades dos estudantes. Naveen Kumar *et al.* (2026) chegam a achado convergente: relatam aumento da participação, da compreensão e do desenvolvimento de habilidades quando as ferramentas de IA se combinam a práticas pedagógicas eficazes.

A autonomia é o quarto benefício, de natureza mais qualitativa que os anteriores. Venus (2025) destaca que as tecnologias baseadas em IA reduzem a dependência de professores e cuidadores: o estudante acessa materiais, resolve problemas e interage com os sistemas educacionais sem mediação humana constante. Kooli e Chakraoui (2025) convergem nesse ponto com dois casos, o de Jane, estudante com deficiência visual que alcançou independência no acesso a conteúdos digitais, e o de Alex, estudante com dificuldades de processamento auditivo cuja experiência de aprendizagem mudou com o uso de tecnologias de transcrição em tempo real. Naveen Kumar et al. (2026) acrescentam evidências de aumento da independência comunicativa entre usuários de sistemas de Comunicação Aumentativa e Alternativa.

Há, contudo, uma divergência relevante quanto à relação entre engajamento e desempenho. Habib, Jelani e Najla (2022) advertem que o engajamento elevado não se converte automaticamente em ganho de aprendizagem.

A plataforma de aprendizagem gamificada registrou 78% de engajamento e a menor melhoria nos testes entre as três, 25%, sinal de que a motivação isolada pode priorizar o entretenimento em detrimento da aprendizagem substantiva. O achado tensiona a ênfase de Zapata-Rivera et al. (2024) no potencial da IA Generativa para aumentar o engajamento e introduz uma ressalva: o benefício do engajamento depende do alinhamento a fundamentos pedagógicos consistentes.

4.4. Desafios e barreiras à implementação

A convergência é ainda maior no caso dos desafios. Quase todos os estudos do corpus identificam o mesmo conjunto de barreiras, o que dá consistência ao achado. Elas se agrupam em quatro categorias: infraestrutura tecnológica, formação docente, restrições financeiras e adequação pedagógica.

Venus (2025) aponta a insuficiência de infraestrutura tecnológica: recursos avançados de IA exigem conexão estável à internet, equipamentos modernos e plataformas on-line, condições nem sempre presentes nas instituições de ensino. No contexto indiano, Naveen Kumar et al. (2026) detalham a desigualdade de infraestrutura digital entre regiões, com escolas rurais e semiurbanas carentes de conexão consistente e de equipamentos adequados.

A barreira atinge sobretudo estudantes com transtornos do neurodesenvolvimento, que mais se beneficiam do uso contínuo das ferramentas. Nusheva e Yankova-Hadzhieva (2025) identificam o mesmo padrão ao apontar a distribuição desigual de recursos digitais como fator limitante do acesso.

A formação inadequada de professores é a barreira mais transversal do corpus. Quatro estudos convergem ao apontar que muitos docentes não dispõem das competências técnicas e pedagógicas para usar ferramentas baseadas em IA (Venus, 2025; Kooli; Chakraoui, 2025; Nusheva; Yankova-Hadzhieva, 2025; Naveen Kumar *et al.*, 2026). Um dado empírico dá a medida do problema: Nusheva e Yankova-Hadzhieva (2025) relatam que, segundo levantamento de janeiro de 2024, 72% dos professores búlgaros ainda não usavam IA em sua prática. Dabaghi, D'Urso e Sciarrone (2026) apontam a mesma lacuna do lado da pesquisa, ao registrar o limitado foco no apoio e na formação docente entre os desafios em aberto nos estudos sobre IA e dislexia.

As restrições financeiras formam a terceira barreira. Venus (2025) destaca o custo elevado das tecnologias avançadas de IA, entre softwares, hardwares e assinaturas dedicadas, peso considerável para escolas de menor orçamento. Naveen Kumar et al. (2026) aprofundam a questão no contexto indiano: os recursos de programas governamentais tendem a privilegiar infraestrutura e salários docentes, em detrimento de ferramentas de IA, enquanto escolas privadas mais bem financiadas adotam essas

tecnologias com rapidez, o que aprofunda a divisão digital.

A adequação pedagógica e curricular é a barreira de natureza mais estrutural. Naveen Kumar et al. (2026) observam que implantar a IA nos currículos vigentes exige alinhar as funcionalidades das ferramentas aos resultados de aprendizagem esperados. Currículos rígidos, abordagens orientadas a exames e a falta de adaptação das ferramentas a idiomas locais dificultam esse alinhamento. A questão remete à tese integradora que percorre o corpus, discutida na seção seguinte.

4.5. Questões éticas: privacidade, viés e dependência

As questões éticas preocupam quase todos os estudos e se organizam em três núcleos: privacidade de dados, viés algorítmico e dependência da tecnologia. A privacidade e a proteção de dados aparecem em vários estudos. Venus (2025) observa que os sistemas de IA sustentam suas experiências personalizadas em dados dos estudantes, o que suscita questões de proteção e justiça. Kooli e Chakraoui (2025) aprofundam a preocupação ao notar que interfaces de NLP coletam informações sensíveis, como padrões de escrita, tom emocional e respostas cognitivas, dados que ficam expostos a usos indevidos na ausência de políticas rigorosas de governança.

Os autores chamam atenção para um aspecto menos evidente: o registro contínuo das interações pode configurar monitoramento comportamental permanente, sobretudo quando os aprendizes desconhecem o uso de seus dados. Daí a exigência de transparência e de mecanismos de consentimento.

O viés algorítmico é o segundo núcleo. Nusheva e Yankova-Hadzhieva (2025) sintetizam a questão ao afirmar que sistemas de IA baseados em dados reproduzem os vieses presentes nos dados de treinamento, o que abre uma pergunta incômoda: quais vieses seriam social e culturalmente aceitáveis. Kooli e Chakraoui (2025) detalham o efeito educacional do fenômeno.

Modelos de NLP treinados em corpora que não refletem a diversidade linguística podem marginalizar estudantes cujo uso da língua se afasta das normas dominantes, com interpretações equivocadas, avaliações injustas e feedback inadequado. Para aprendizes com deficiência visual, observam Khlaif et al. (2026), saídas enviesadas ou imprecisas funcionam como barreiras concretas, reforçam a exclusão e minam a confiança acadêmica.

O terceiro núcleo, de identificação mais recente, é o risco de dependência da tecnologia. Kooli e Chakraoui (2025) propõem o conceito de Síndrome de Adição à IA Generativa (Generative AI Addiction Syndrome – GAID), caracterizada pelo engajamento compulsivo e cocriativo com sistemas de IA. Entre os prejuízos possíveis estão perdas cognitivas, emocionais e sociais, com redução do pensamento crítico e da independência criativa. Nusheva e Yankova-Hadzhieva (2025) seguem a mesma

direção ao alertar que o uso excessivo de recursos digitais pode diminuir o pensamento crítico e as habilidades sociais dos estudantes.

Os estudos são unânimes em propor respostas de caráter ético e regulatório. Venus (2025) defende a integração das tecnologias a políticas objetivas e práticas responsáveis. Kooli e Chakraoui (2025) dirigem recomendações a formuladores de políticas, instituições e desenvolvedores, entre elas o treinamento de modelos em conjuntos de dados diversos, a conformidade com padrões internacionais de acessibilidade, como as WCAG, e a adoção de princípios de design ético. Naveen Kumar et al. (2026) sistematizam recomendações por grupo de interessados, alinhadas a princípios da UNESCO e da OCDE.

4.6. Integração entre tecnologia e pedagogia: a convergência central do corpus

A análise transversal do corpus revela uma tese integradora que ultrapassa a soma dos achados individuais: o potencial das tecnologias assistivas baseadas em IA se realiza por sua integração intencional a fundamentos pedagógicos, e não pela tecnologia em si. A constatação percorre a maioria dos estudos, sob formulações distintas, e é talvez a contribuição teórica de maior alcance do conjunto. Por tratar-se de síntese autoral entre fontes, a formulação pede reflexão adicional e validação em pesquisas posteriores.

A formulação mais explícita está em Koranteng (2025), que propõe articular a Adaptatividade de IA, a Habilitação Assistiva e os Fundamentos do Universal Design for Learning em uma arquitetura única, orientada ao Acesso e Empoderamento de Aprendizagem Inclusiva. A autora argumenta que IA, tecnologia assistiva e desenho pedagógico têm evoluído em paralelo, sem articulação entre si, e que a fragmentação limita seu potencial coletivo de promover equidade. O diagnóstico converge com a constatação de Venus (2025) de que a literatura tende a concentrar-se em tecnologias específicas, sem analisar sua integração em escala.

Outros estudos sustentam a mesma perspectiva. Naveen Kumar et al. (2026) afirmam de modo categórico que a capacidade técnica é necessária, mas insuficiente sem alinhamento pedagógico e prontidão institucional. O suporte empírico vem de Habib, Jelani e Najla (2022), que demonstram não haver ganho de aprendizagem quando o engajamento se dá sem fundamentação pedagógica.

Em Khlaif et al. (2026), a IA Generativa deve complementar a atuação do professor, e os participantes a percebem como instrumento de ampliação da capacidade docente. Zapata-Rivera et al. (2024) acrescentam uma dimensão pouco explorada: o uso da IA como tutora requer atenção ao conteúdo emocional de suas respostas, dado o peso das emoções na aprendizagem

. Configura-se um consenso teórico: a centralidade do professor e o alinhamento pedagógico são condições para que as tecnologias assistivas baseadas em IA cumpram sua promessa de inclusão. A tecnologia amplifica a mediação humana em vez de substituí-la, formulação que Koranteng (2025) sintetiza ao situar a amplificação do potencial humano, e não a automação, como propósito maior da tecnologia na educação.

4.7 Lacunas identificadas na literatura

A análise do corpus permite identificar lacunas recorrentes, que delimitam as fronteiras atuais do conhecimento e apontam caminhos para a pesquisa futura. A mais evidente é a escassez de validação experimental e de estudos longitudinais. Dabaghi, D'Urso e Sciarrone (2026) constatam que muitos trabalhos propõem ferramentas baseadas em IA sem validar sua eficácia em ambientes educacionais reais.

Naveen Kumar et al. (2026) observam que grande parte das implementações permanece em pilotos de pequena escala, com pouco compartilhamento de dados entre instituições e foco predominante em casos de deficiência única, sem atenção aos resultados educacionais de longo prazo. Três estudos apontam de modo convergente a ausência de pesquisas longitudinais e recomendam investigar os efeitos sustentados da IA no desempenho acadêmico, no bem-estar e na literacia digital dos estudantes (Venus, 2025; Kooli; Chakraoui, 2025; Koranteng, 2025).

A segunda lacuna são as barreiras linguísticas e culturais. Dabaghi, D'Urso e Sciarrone (2026) destacam que a maior parte da pesquisa se concentra em populações de língua inglesa e recomendam a expansão para contextos linguísticos e culturais diversos. A partir de um contexto do Sul Global, Khlaif *et al.* (2026) demonstram que a equidade requer saídas de IA capazes de refletir a diversidade linguística e cultural, e que a inclusão depende da visibilidade cultural, e não só da conectividade.

A terceira, de caráter teórico, é a fragmentação do campo e a carência de modelos integradores, discutida na seção 4.6. Koranteng (2025), Naveen Kumar *et al.* (2026) e Venus (2025) sinalizam a necessidade de modelos que articulem de forma sistêmica tecnologia, acessibilidade e pedagogia. O framework de Koranteng responde a essa demanda, ainda que sem validação empírica, como o próprio autor reconhece.

A quarta lacuna é a subexploração da IA Generativa no campo específico das tecnologias assistivas. Dabaghi, D'Urso e Sciarrone (2026) constatam que sua presença na literatura sobre dislexia permanece mínima e exploratória, apesar do potencial atribuído à tecnologia. O contraste com o entusiasmo de Zapata-Rivera et al. (2024) diante das possibilidades da IA Generativa na educação expõe um descompasso entre a expectativa em torno da tecnologia e a maturidade da evidência disponível. Esse descompasso resume o estado atual do campo e sustenta a continuidade da

investigação sobre o tema.

5. **Considerações finais**

Esta revisão analisou, a partir da literatura científica recente, de que modo as tecnologias assistivas fundamentadas em Inteligência Artificial e os sistemas adaptativos de aprendizagem podem ampliar o acesso, o engajamento e a personalização da aprendizagem de estudantes com deficiência, além de identificar os benefícios, os desafios e as lacunas associados à sua adoção em contextos educacionais inclusivos. A investigação seguiu o método *Systematic Search Flow* (SSF), que conferiu rigor e reprodutibilidade à seleção e resultou em um corpus de nove estudos publicados entre 2022 e 2026.

Os achados autorizam afirmar que as tecnologias assistivas baseadas em IA representam um avanço na promoção da educação inclusiva. A análise revelou um núcleo consolidado de soluções voltadas a estudantes com deficiências visuais, auditivas, motoras e cognitivas, e também a estudantes com transtornos do neurodesenvolvimento: reconhecimento de voz, texto para fala, legendagem automática, leitores de tela, plataformas adaptativas, interfaces de processamento de linguagem natural, comunicação aumentativa e alternativa, ambientes imersivos e, mais recentemente, a Inteligência Artificial Generativa. A incorporação da IA alterou a capacidade de adaptação das ferramentas, que passaram a ajustar-se ao conteúdo e ao modo como cada estudante processa e responde à informação.

Quanto aos benefícios, a literatura converge em quatro dimensões: ampliação da acessibilidade, personalização da aprendizagem, aumento do engajamento e promoção da autonomia. As quatro se articulam entre si e sustentam a hipótese de que as tecnologias assistivas baseadas em IA podem favorecer ambientes de aprendizagem mais equitativos. O corpus traz, porém, uma ressalva: o engajamento não se traduz automaticamente em ganho de aprendizagem, sinal de que a eficácia dessas tecnologias depende menos da sofisticação técnica do que do alinhamento a fundamentos pedagógicos consistentes.

A convergência é maior no caso dos desafios. Insuficiência de infraestrutura tecnológica, formação inadequada dos professores, restrições financeiras e dificuldade de adequação pedagógica e curricular se repetem de modo transversal nos estudos, qualquer que seja o contexto geográfico ou a população investigada. A esses obstáculos somam-se preocupações éticas presentes em todo o corpus: privacidade e proteção de dados, viés algorítmico e o risco emergente de dependência da tecnologia. A adoção responsável dessas ferramentas exige, portanto, inovação técnica acompanhada de governança, políticas públicas e desenvolvimento profissional docente.

A contribuição teórica desta revisão está na constatação de que o alcance das tecnologias assistivas baseadas em IA depende de sua integração intencional a fundamentos pedagógicos, e não da tecnologia em si. Recorrente no corpus e formulada de modo mais elaborado na proposta de articulação entre Inteligência Artificial, tecnologia assistiva e Desenho Universal para a Aprendizagem, a tese desloca o eixo do debate da capacidade técnica das ferramentas para a qualidade de sua incorporação às práticas educativas. Por esse ângulo, a tecnologia amplifica a mediação humana em vez de substituí-la, e a centralidade do professor se reafirma como condição para que a promessa de inclusão se concretize.

A pesquisa permitiu identificar lacunas que demarcam as fronteiras atuais do conhecimento e indicam direções para investigações futuras. A mais urgente é a escassez de validação experimental e de estudos longitudinais capazes de avaliar os efeitos sustentados dessas tecnologias sobre o desempenho acadêmico, o bem-estar e a literacia digital dos estudantes, entendida como a capacidade de ler, escrever, compreender e interpretar informações de forma eficaz.

Somam-se a ela a concentração da pesquisa em populações de língua inglesa, em detrimento da diversidade linguística e cultural, a fragmentação do campo e a carência de modelos integradores validados empiricamente, além da subexploração da Inteligência Artificial Generativa no domínio específico das tecnologias assistivas. O potencial anunciado para essa tecnologia ainda não encontra correspondência na maturidade da evidência disponível, e o descompasso entre expectativa e validação científica resume o estado atual do campo.

Este estudo apresenta limitações que convém reconhecer. A delimitação temporal a publicações posteriores a 2022, ainda que justificada pela busca de atualidade, pode ter excluído contribuições anteriores relevantes para a compreensão histórica do tema. A restrição a quatro bases de dados, o corte nos vinte resultados mais relevantes por plataforma e a exclusão de estudos sem permissão de acesso integral circunscrevem o alcance dos achados, mesmo com justificativa metodológica.

O corpus final reúne nove estudos de naturezas metodológicas heterogêneas, o que favorece a triangulação de evidências e ao mesmo tempo recomenda cautela na generalização das conclusões. Esses limites delineiam o escopo dentro do qual os resultados devem ser lidos.

Para pesquisas futuras, recomendam-se estudos empíricos e longitudinais que avaliem, em contextos educacionais reais, a eficácia das tecnologias assistivas baseadas em IA, com atenção aos resultados de aprendizagem de longo prazo. Uma segunda frente é a ampliação das investigações para contextos linguística e culturalmente diversos, sobretudo no Sul Global, sem reproduzir as desigualdades sistêmicas que o próprio corpus registra. Cabe também aprofundar modelos integradores que articulem tecnologia, acessibilidade e pedagogia, e verificar

empiricamente o potencial da Inteligência Artificial Generativa como recurso assistivo.

No contexto brasileiro, em particular no âmbito dos estudos sobre tecnologia da informação e comunicação aplicada à educação, abre-se um campo de investigação que precisa considerar as especificidades da infraestrutura, das políticas públicas e da formação docente nacionais. É por esse caminho que a adoção dessas tecnologias pode se fazer de modo equitativo, ético e pedagogicamente fundamentado.

As tecnologias assistivas baseadas em Inteligência Artificial mostram potencial considerável para uma educação mais inclusiva e acessível. Sua efetividade depende da conjugação entre inovação, fundamentação pedagógica, responsabilidade ética e compromisso institucional, e não da simples disponibilização tecnológica. A literatura analisada sinaliza que o futuro da educação inclusiva mediada por IA dependerá menos da sofisticação das ferramentas do que da capacidade humana de incorporá-las, de forma crítica e intencional, a projetos educativos comprometidos com a dignidade e o pleno desenvolvimento de todos os estudantes.

Referências

Dabaghi, K.; D'urso, S. & Sciarrone, F. Artificial intelligence to help people with dyslexia in education: an interdisciplinary literature review. **International Journal of Artificial Intelligence in Education**, v. 36, 2026. Article 100012. DOI: https://doi.org/10.1016/j.ijaied.2026.100012.

Habib, H.; Jelani, S. A. K. & Najla, S. Revolutionizing inclusion: AI in adaptive learning for students with disabilities. **Multidisciplinary Science Journal**, v. 1, n. 1, p. 1-11, fev. 2022. Disponível em: https://media.neliti.com/media/publications/590978-revolutionizing-inclusion-ai-in-adaptive-7d71c59a.pdf. Acesso em: 17/05/2026.

Khlaif, Z. N.; Alshakhshir, R.; Hamamra, B.; Joma, A. Assistive generative AI for visually impaired learners: personalization and inclusion in higher education. **International Journal of Artificial Intelligence in Education**, v. 36, 2026. Article 100008. DOI: https://doi.org/10.1016/j.ijaied.2026.100008.

Kooli, C. & Chakraoui, R. AI-driven assistive technologies in inclusive education: benefits, challenges, and policy recommendations. **Sustainable Futures**, v. 10, 2025. Article 101042. DOI: https://doi.org/10.1016/j.sftr.2025.101042.

Koranteng, U. Designing the AI-Inclusive Framework (AIF): integrating artificial intelligence, assistive technology, and universal design for learning in inclusive education. **Newark: University of Delaware**, 2025. Disponível em: https://scholar.google.com/citations?view_op=view_citation&hl=en&user=By5Rd8EAAAAJ&citation_for_view=By5Rd8EAAAAJ:9yKSN-GCB0IC. Acesso em 17/05/2026.

Kumar, H. N.; Patil, C. M.; Sudheesh, K. V.; Jagadeesh, B.; Aisiri, A. P. & Mahadevaswamy. Inclusive learning through AI: a comprehensive review of assistive educational technologies for students with neurodevelopmental disorders and other disabilities. **Journal of Engineering Education Transformations**, v. 39, Special Issue 2, p. 332-340, jan. 2026. eISSN 2394-1707.

Nusheva, K. & Yankova-Hadzheiva, B. Inclusive education in the era of artificial intelligence and technology. **Education and New Developments** 2025, p. 472-476, 2025. DOI: https://doi.org/10.36315/2025v2end103.

Venus, M. AI-supported assistive technologies for inclusive digital classrooms: enhancing learning for students with disabilities. Fusion EDU: **Journal of Education and Learning Sciences**, v. 1, n. 2, p. 1-8, 2025. Disponível em: https://fusionedu.org/home/index.php/JELS/article/download/7/7. Acesso em: 17/05/2026.

Zapata-Riveira, D.; Torre, I.; Lee, C.; Sarasa-Cabezuelo, A.; Ghergulesc, I.; Libbrecht, P. Editorial: Generative AI in education. **Frontiers in Artificial Intelligence**, v. 7, Article 1532896, 10 dez. 2024. DOI: https://doi.org/10.3389/frai.2024.1532896

Declaração de Uso de inteligência artificial

Durante o desenvolvimento desta pesquisa, foram utilizadas ferramentas de Inteligência Artificial Generativa como recurso de apoio à organização textual, à estruturação inicial dos tópicos, ao aprimoramento linguístico e à identificação de descritores para o levantamento bibliográfico. O uso dessas ferramentas restringiu-se ao suporte assistivo, não sendo empregado para a geração automática de resultados, análises científicas ou conclusões.

A seleção da bibliografia, a interpretação dos dados, a análise crítica, a construção das discussões e a redação final do trabalho permaneceram sob responsabilidade integral do autor. Todo o conteúdo produzido com auxílio de Inteligência Artificial foi submetido a processos de verificação, validação e revisão crítica, em conformidade com os princípios da integridade científica, da ética em pesquisa e da responsabilidade autoral.

Prompts aplicados:

#01 - *"Preciso escrever um artigo científico a nível mestrado. Um trabalho muito sério. O tópico será "Inteligência Artificial na Educação" e o título será "Tecnologias Assistivas baseadas em IA", com foco em educação inclusiva. Será uma revisão bibliográfica. Vou procurar artigos em fontes confiáveis, como google academico,*

Science direct, scopus, IEEE, Portal Caps. Quero sugestões de palavras chaves relevantes".

#02 - *"As palavras chaves selecionadas no grupo de inteligência artificial foram: IA na Educação, Sistemas Adaptativos de Aprendizagem, AI in Education, Adaptive Learning Systems. As palavras chaves selecionadas no grupo de Tecnologias Assistivas foram: Tecnologias Assistivas, Tecnologia Educacional Assistiva, Assistive Technologies, Educational Assistive Technology. As palavras chaves selecionadas no grupo de Educação Inclusiva foram: Acessibilidade Educacional, Ensino Inclusivo, Inclusive Education, School Inclusion. Com base nessas informações, elabore sugestões avançadas de busca com operadores booleanos que sejam relevantes".*

#03- *"Execute a revisão ortográfica do artigo enviado, inclusive acentuações e espaçamentos". Substitua palavras fora de contexto ou erradas por sinônimos plausíveis".*

#04 – *"Traduza o Resumo a seguir para a língua inglesa: "..." ".*

Sobre o autor(a)

Willians Rodrigo Ross

Mestrando em Tecnologias da Informação e Comunicação pelo Programa de Pós-graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina (UFSC).

Mestrando em Sistemas Produtivos pelo Programa de Pós-graduação em Sistemas Produtivos (PPGSP) na Universidade do Extremo Sul Catarinense (UNESC).

Graduação em Administração pela Escola Superior de Criciúma (ESUCRI - 2006) com Complementação Pedagógica em Educação Profissional pela Faculdade de Capivari (FUCAP - 2014).

Especialização em Gestão de Negócios e Marketing (2024), Empreendedorismo e Inovação (2024), Docência no Ensino Superior (2021) e Educação à Distância Gestão e Tutoria (2021), ambos pelo Centro Universitário Leonardo da Vinci (Uniasselvi).

Professor efetivo pela SED-SC no eixo Gestão e Negócios, no CEDUP Abilio Paulo, em Criciúma/SC e em consultoria nas àreas de Gestão e Marketing.

Lattes: http://lattes.cnpq.br/3017981942904902

CAPÍTULO 15

Estados afetivos e aprendizado: um revisão sistemática sobre detecção automática de emoções

Maria Eduarda Mariano

1. Introdução

É fundamental que a mediação dos processos de ensino e aprendizagem na era da educação digital seja compreendida para além da mera mediação cognitiva. Ao longo da história, a educação formal sempre se concentrou mais na transmissão de conteúdos e na avaliação de competências técnicas, relegando a subjetividade do aprendiz a um segundo plano. Entretanto, como destacam Lopes et al. (2019) em sua pesquisa "Inovações educacionais com o uso da Realidade Aumentada: uma revisão sistemática", a adoção de tecnologias emergentes pode resultar em grandes avanços no compartilhamento de saberes, desde que essas tecnologias consigam se adequar ao perfil do usuário, o que implica, necessariamente, em considerar a dimensão emocional.

A Computação Afetiva é o ramo que estuda como conferir aos computadores a habilidade de identificar, compreender e reagir às emoções humanas, um conceito pioneiro introduzido por Rosalind Picard em 1997. No campo da educação, isso se torna particularmente crucial quando se busca reduzir o chamado "fosso afetivo", a incapacidade do software em reconhecer e responder à frustração, ao tédio ou ao engajamento do aluno. Esse distanciamento afetivo é uma das maiores fontes de abandono em cursos a distância, já que a ausência do contato físico com o docente impossibilita a leitura de sinais não-verbais que indicariam a urgência de uma intervenção pedagógica.

Essa questão se torna ainda mais desafiadora no ensino de áreas complexas, como lógica e programação. Nesses contextos, é comum que o aluno enfrente momentos de dificuldade ao lidar com erros de sintaxe ou de lógica, que muitas vezes entram em conflito com seus conhecimentos prévios. Essas situações podem gerar o chamado "desequilíbrio cognitivo", exigindo do estudante um esforço maior de adaptação e reconstrução do seu entendimento. Se não houver um suporte adequado, a confusão

inicial pode rapidamente se transformar em frustração e, eventualmente, em desistência.

Esta revisão sistemática, portanto, visa investigar de que maneira a computação afetiva, por meio da Inteligência Artificial, tem sido utilizada para tornar mais humana a interação entre humanos e computadores, fazendo com que sistemas tutores se tornem agentes que oferecem apoio empático e individualizado. Para tanto, o presente trabalho adota uma metodologia rigorosa, baseada no protocolo PRISMA, e apresenta um corpus de análise expandido para incluir a literatura internacional mais recente e relevante.

2. Metodologia e protocolo de pesquisa

Para assegurar o rigor científico, a transparência e a reprodutibilidade desta revisão de literatura, foi adotado um protocolo de pesquisa sistemático, seguindo as diretrizes do PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). Este protocolo foi estruturado em etapas que abrangem a formulação da questão de pesquisa, a estratégia de busca, a seleção dos estudos, a extração e a síntese dos dados. O processo detalhado é ilustrado no fluxograma PRISMA (Figura 1).

Figura 1 - Fluxograma PRISMA do Processo de Seleção dos Estudos

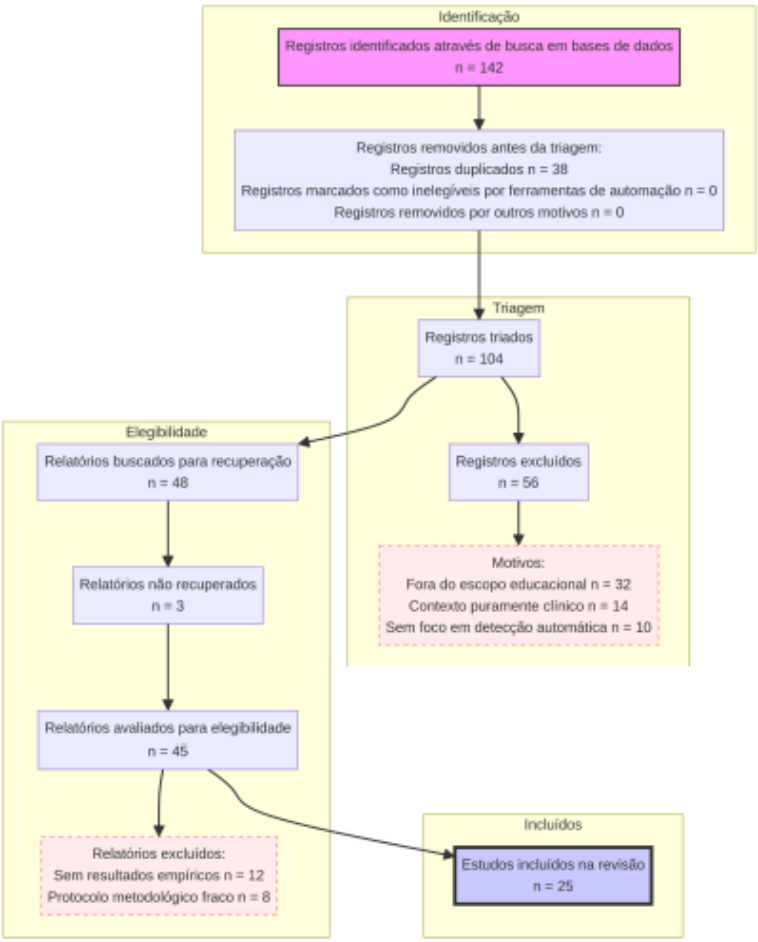

Fonte: elaborado pela autora (2026)

2.1 Questão de pesquisa

A questão de pesquisa que guiou esta revisão foi: "De que maneira a Computação Afetiva, por meio da Inteligência Artificial, tem sido utilizada para tornar mais humana a interação entre humanos e computadores no contexto educacional, oferecendo apoio empático e individualizado?"

2.2 Estratégia de busca

A estratégia de busca foi cuidadosamente planejada para abranger a interseção entre a psicologia da educação e a ciência da computação, com foco em detecção automática de emoções e suas aplicações no aprendizado. Foram utilizados termos em português e inglês para maximizar o alcance dos resultados. Os termos de busca incluíram:

- Português: "detecção de emoções", "emoções na aprendizagem", "programação", "informática na educação", "computação afetiva", "sistemas tutores inteligentes", "inteligência artificial na educação".

- Inglês: "emotion detection", "emotions in learning", "programming learning", "computers in education", "affective computing", "intelligent tutoring systems", "artificial intelligence in education", "emotion-aware tutoring systems", "learning analytics", "educational data mining".

Operadores booleanos "AND" e "OR" foram aplicados para refinar as combinações, buscando artigos que abordassem a detecção de emoções e o contexto educacional ou de aprendizagem.

2.3 Bases de dados consultadas

Para garantir uma abrangência internacional e um corpus robusto, a busca foi realizada nas seguintes bases de dados:

- Google Acadêmico: Para uma busca inicial ampla e identificação de artigos relevantes.
- Biblioteca Digital Brasileira de Computação (BDBComp) e Portal de Periódicos da CAPES: Para incluir a produção científica nacional.
- Scopus: Base de dados multidisciplinar com vasta cobertura de periódicos e conferências.
- Web of Science: Plataforma abrangente para pesquisa científica, com foco em artigos de alto impacto.

- IEEE Xplore Digital Library: Essencial para artigos nas áreas de engenharia elétrica, eletrônica e ciência da computação.
- ACM Digital Library: Focada em computação e tecnologia da informação.

2.4 Critérios de inclusão e exclusão

Os estudos foram selecionados com base nos seguintes critérios:

- Critérios de Inclusão:
    - Artigos de periódicos, anais de conferências e monografias com texto completo disponível.
    - Publicados entre 2019 e 2026 (para garantir a atualidade da revisão).
    - Foco em modelos computacionais de detecção de estados afetivos no ensino ou na aprendizagem.
    - Abordagens que integrem Inteligência Artificial e Computação Afetiva no contexto educacional.
- Critérios de Exclusão:
    - Trabalhos que tratavam de emoções de forma puramente clínica, organizacional ou em contextos não relacionados diretamente à aprendizagem e tecnologias educacionais.
    - Artigos duplicados.
    - Estudos que não apresentavam resultados empíricos ou revisões de literatura que não seguiam um protocolo sistemático claro.

2.5 Processo de seleção e composição do portfólio

O processo de seleção dos estudos seguiu as etapas de identificação, triagem, elegibilidade e inclusão, conforme o PRISMA. Inicialmente, os resultados da busca foram compilados e duplicatas removidas. Em seguida, os títulos e resumos foram triados para identificar estudos potencialmente relevantes. Os artigos selecionados foram então avaliados em texto completo para elegibilidade, aplicando-se os critérios de inclusão e exclusão.

O portfólio final foi composto por 25 trabalhos centrais, incluindo revisões sistemáticas, artigos de pesquisa e estudos de caso, que representam diferentes abordagens (visão computacional, logs de interação, modelos livres de sensores, tutores inteligentes) e contextos de aplicação. Esta ampliação do corpus visa fornecer

uma visão mais abrangente e robusta do estágio atual de desenvolvimento da área.

2.6 Análise e síntese dos dados

Os dados dos estudos incluídos foram extraídos e sintetizados qualitativamente, focando nos seguintes aspectos:

- Objetivo principal do estudo.
- Metodologia de detecção de emoções utilizada.
- Tecnologias e algoritmos empregados (e.g., CNNs, BKT, LLMs).
- Principais resultados e achados.
- Limitações identificadas pelos próprios autores.
- Implicações para a educação e o aprendizado.

Um quadro comparativo foi elaborado para sintetizar as informações dos estudos mais relevantes, facilitando a identificação de tendências, lacunas e áreas de pesquisa emergentes (ver Apêndice A).

3. Declaração de uso da IA generativa

- Nome da ferramenta: Gemini (Google).
- Versão: Gemini 1.5 Pro (2024).
- Finalidade: A ferramenta foi utilizada para a estruturação lógica do manuscrito, formatação normativa, síntese de informações, tradução do abstract e geração de figura, sob supervisão humana.
- Rigor e Responsabilidade: Em conformidade com a Portaria n° 2.664/2026 do CNPq, declara-se que as inferências críticas, a seleção das bases teóricas e a interpretação dos resultados dos autores citados foram realizadas de forma autoral. O pesquisador validou manualmente cada citação e dado técnico para evitar alucinações de IA, garantindo a integridade científica da revisão.

4. Fundamentação teórica: a interdependência entre afeto e cognição

Antes de abordarmos a questão da viabilidade na detecção automática de emoções, é crucial entender, de maneira sólida, como a afetividade influencia o desenvolvimento humano. Diferentemente das visões dualistas que distinguem razão e emoção, a psicologia moderna e as neurociências mostram que esses processos são aspectos de um mesmo fenômeno.

4.1 A emoção na perspectiva histórico-cultural e bioecológica

A obra de Lev Vygotsky é fundamental para compreender a influência das emoções no processo de aprendizado. De acordo com Souza et al. (2020), em sua pesquisa "A influência das emoções no aprendizado de escolares", eles se apoiam na teoria de Vygotsky para ressaltar que o aprendizado não ocorre sem levar em conta as emoções. Vygotsky era a favor da união dos processos intelectuais e emocionais, afirmando que toda ideia tem um laço afetivo com a realidade. As emoções constituem funções psicológicas superiores que se conectam de maneira direta à memória, à atenção e à percepção.

Nesse contexto, a Zona de Desenvolvimento Proximal (ZDP), o espaço entre o que o estudante é capaz de fazer de forma independente e o que consegue realizar com auxílio, é intensamente influenciada pelo clima emocional. Um ambiente que provoca ansiedade em excesso pode "impedir" a ZDP, ao passo que um ambiente que oferece suporte e desafios equilibrados a estimula. Adicionalmente, a teoria bioecológica de Bronfenbrenner propõe que o contexto familiar, as relações interpessoais e o ambiente tecnológico constituem um ecossistema que afeta o "clima emocional" do aprendiz.

As teorias de Henri Wallon também contribuem para enriquecer essa discussão. Wallon propõe a "psicogênese da pessoa completa", na qual a afetividade e a cognição se alternam como predominantes no processo de desenvolvimento. Wallon sustenta que a emoção é a forma primordial de interação social, e que a inteligência se edifica sobre essa base. Em sistemas de ensino que dependem da computação, negligenciar essa fundação walloniana é o mesmo que ver o aluno como um mero processador de dados puramente lógico, sem levar em conta a complexidade do ser humano.

4.2 Estados afetivos específicos da aprendizagem

Ao contrário das emoções básicas universais (como alegria, medo, raiva, surpresa, nojo e tristeza) identificadas por Paul Ekman, o campo da Informática na Educação se concentra em estados afetivos complexos e acadêmicos. No artigo "Emoções na Aprendizagem: Estimando a Duração da Confusão e Aprimorando Intervenções Pedagógicas", Goldoni e Reis (2023) ressaltam que a confusão é um dos estados mais críticos e produtivos para a aprendizagem.

No contexto educacional, a confusão indica um desajuste cognitivo, onde o aluno percebe que o que sabe não é suficiente para resolver uma questão. A confusão quando bem gerenciada, pode levar à aprendizagem profunda (*deep learning*) porque mobiliza esforço para resolução do conflito. No entanto, quando a confusão se estende por muito tempo sem receber apoio, ela se converte em frustração e apatia. Kong et al. (2025), reforçam a importância do rastreamento em tempo real desses estados para

intervenções pedagógicas eficazes.

A Teoria do Fluxo (*Flow*) de Mihaly Csikszentmihalyi é outro conceito importante. O estado de fluxo acontece quando o desafio da tarefa está perfeitamente alinhado com as habilidades do estudante. A ansiedade surge quando o desafio é muito alto, enquanto o tédio aparece quando ele é muito baixo. Sistemas de detecção automática procuram identificar essas variações para ajustar a dificuldade do conteúdo de forma dinâmica, mantendo o aprendiz no canal de fluxo, onde a aprendizagem é otimizada e a percepção do tempo é modificada.

5. Abordagens tecnológicas para detecção automática de emoções

A conversão de conceitos psicológicos em algoritmos computacionais requer a aplicação de técnicas sofisticadas de Inteligência Artificial, que se dividem principalmente em métodos fundamentados na visão e métodos fundamentados na interação, com avanços significativos em modelos híbridos e na integração com sistemas tutores inteligentes.

5.1 Fluxo de emoções e visão computacional

O rosto humano é o principal meio de expressão emocional, possuindo milhares de microexpressões que demonstram o estado interno da pessoa. Werlang e Jaques(2023) sugerem a utilização de Redes Neurais Convolucionais (CNNs) para uma detecção sólida. Ao contrário dos modelos tradicionais que analisam frames isolados, essa abordagem se destaca pelo conceito de fluxo de emoções.

Os CNNs funcionam através de várias camadas de filtros que vão extraindo, de forma hierárquica, as características da imagem, desde bordas e texturas nas primeiras camadas até formas mais complexas, como a curvatura dos lábios ou o franzir da testa nas últimas camadas. O sistema é capaz de reconhecer tanto um estado emocional estático quanto a dinâmica da transição emocional ao considerar a sequência temporal das microexpressões.

Isso torna possível, por exemplo, distinguir entre um sorriso genuíno e um sorriso nervoso ao resolver um problema de lógica, o que aumenta muito a precisão em situações reais, onde a iluminação e a postura do aluno podem mudar. Em um estudo de 2023, a ACM explorou o desenvolvimento de uma API para detecção de emoções em expressões faciais especificamente no contexto do aprendizado de algoritmos, demonstrando a aplicabilidade prática dessas técnicas.

5.2 Detecção livre de sensores e estimativas de conhecimento

Uma abordagem inovadora e eticamente relevante procura identificar emoções sem recorrer a câmeras, com o objetivo de preservar a privacidade do aluno e diminuir os gastos com hardware. Kautzmann et al. (2024) exploram de que maneira os registros de interação (cliques, tempo de resposta, taxa de erros) podem funcionar como sensores indiretos. Esta pesquisa se destaca principalmente ao integrar estimativas de conhecimento, como o Bayesian Knowledge Tracing (BKT).

O BKT é um modelo que estima a probabilidade de um aluno ter dominado uma habilidade específica, levando em conta seu histórico de respostas corretas e incorretas. A lógica é que, se um sistema detecta que um aluno está gastando muito tempo em um exercício que deveria ser simples para o nível de habilidade já conhecido, o modelo pode inferir estados de confusão ou desinteresse com bastante precisão, sem precisar ver a expressão do rosto do estudante. Essa estratégia "invisível" é menos intrusiva e contorna barreiras culturais ou de infraestrutura que limitam o uso de webcams.

Adicionalmente, novos modelos híbridos para detecção de emoções em texto, que identificam nuances emocionais intrincadas, oferecem outra via para a detecção livre de sensores, analisando a comunicação escrita do aluno.

5.3 Contexto prático: aprendizado de algoritmos e sistemas tutores inteligentes

Lima (2023), em sua pesquisa sobre a detecção automática de emoções no aprendizado de algoritmos, aplica essas tecnologias em um dos campos mais férteis para o surgimento de estados de frustração. O ensino de programação exige um alto nível de abstração e resiliência frente ao erro. O estudo revela que, para que os modelos funcionem eficazmente, é crucial que sejam treinados com dados específicos do domínio e da população-alvo.

A integração da detecção de emoções em Sistemas Tutores Inteligentes (ITS) tem sido uma área de pesquisa ativa. Fernández-Herrero (2024), realizou uma scoping review avaliando os avanços recentes em ITS afetivos, destacando seus impactos educacionais e perspectivas futuras. Kong et al. (2025) desenvolveram um framework integrado para rastreamento em tempo real de estados cognitivos e emocionais em ITS, visando aprimorar os resultados de aprendizagem através de feedback adaptativo.

Mais recentemente, a emergência de tutores de IA generativa (GenAI) emocionalmente inteligentes, que combinam modelagem cognitiva com sensoriamento afetivo para oferecer feedback personalizado, representa um avanço significativo na criação de ambientes de aprendizagem mais empáticos e eficazes. Sistemas de mentoria por IA com detecção multilíngue de emoções também estão sendo

desenvolvidos para aprimorar a personalização e a adaptabilidade cultural no aprendizado.

5.4. Implicações éticas e práticas da detecção automática de emoções

A aplicação da detecção automática de emoções no contexto educacional levanta importantes questões éticas e práticas que precisam ser cuidadosamente consideradas. A discussão sobre vigilância afetiva, privacidade e o uso ético de dados biométricos e de interação é fundamental para garantir que essas tecnologias sejam implementadas de forma responsável. A detecção livre de sensores é uma forma de preservar a privacidade, o que é um ponto forte.

Iren (2023) realizou uma análise temática sobre os riscos, preocupações e práticas éticas da Computação Afetiva, destacando a necessidade de diretrizes claras e de um consentimento informado robusto. É imperativo que os estudos e sistemas que utilizam DAE garantam a transparência sobre como os dados são coletados, armazenados e utilizados, e que os alunos tenham controle sobre suas informações. A Portaria n° 2.664/2026 do CNPq sobre integridade na atividade científica, que inclui diretrizes para o uso de IA, reforça a importância dessas considerações.

Do ponto de vista prático, a equiparação entre grupos em tempo de instrução e qualidade pedagógica é crucial em qualquer estudo que compare diferentes abordagens de ensino. A DAE pode auxiliar na monitorização do engajamento e da frustração, permitindo ajustes pedagógicos em tempo real que visam manter a equidade e a eficácia da instrução para todos os alunos, independentemente da metodologia utilizada.

No entanto, a implementação dessas tecnologias deve ser acompanhada de uma formação pedagógica adequada para os educadores, a fim de que os dados emocionais sejam interpretados e utilizados de forma significativa para o suporte educacional, e não apenas como métricas de desempenho.

5.5. Integração dos dados e critérios de comprovação

A integração dos dados provenientes de diferentes fontes é essencial para fundamentar conclusões robustas sobre o impacto da detecção automática de emoções na aprendizagem. Os estudos revisados demonstram diversas abordagens para essa integração. Por exemplo, dados de interação (cliques, tempo de resposta) podem ser combinados com estimativas de conhecimento (BKT) para inferir estados emocionais, que por sua vez são correlacionados com o desempenho em tarefas de aprendizagem.

A análise do fluxo de emoções faciais pode ser integrada com o progresso do aluno em exercícios, permitindo identificar padrões que indicam confusão ou engajamento.

O critério de "comprovação" de que a DAE "auxilia de forma comprovada" na aprendizagem é multifacetado e depende do objetivo específico da intervenção. Pode incluir:

- Melhora no Desempenho Acadêmico: Aumento estatisticamente significativo em notas, acertos em testes ou conclusão de tarefas.
- Redução da Frustração e Abandono: Diminuição dos indicadores de frustração (medidos por DAE) e das taxas de desistência em cursos ou módulos.
- Aumento do Engajamento e Motivação: Elevação dos níveis de engajamento (medidos por DAE) e da persistência em tarefas desafiadoras.
- Otimização do Estado de Fluxo: Manutenção do aluno em um estado de fluxo ideal, onde o desafio e a habilidade estão equilibrados, conforme a teoria de Csikszentmihalyi.

É importante que o artigo diferencie claramente os resultados consolidados, que apresentam evidências empíricas robustas, das hipóteses prospectivas ou tendências emergentes. Por exemplo, enquanto a capacidade de DAE para identificar frustração e confusão é bem estabelecida [20], a eficácia de tutores de IA generativa emocionalmente inteligentes ainda está em fase inicial de comprovação empírica [4]. A revisão deve apresentar essas distinções de forma clara, evitando extrapolações que não sejam suportadas pelas evidências atuais.

6. Conclusão

A presente revisão sistemática reforça a premissa de que o afeto desempenha um papel indissociável no processo de aprendizado, e que a Computação Afetiva, impulsionada pela Inteligência Artificial, oferece ferramentas promissoras para otimizar a experiência educacional. A expansão do corpus de pesquisa e a aplicação de um protocolo metodológico rigoroso, como o PRISMA, permitiram uma análise mais abrangente e aprofundada das abordagens tecnológicas e suas implicações.

Observou-se um avanço significativo na detecção automática de emoções, tanto por meio de visão computacional, que analisa o fluxo de microexpressões faciais, quanto por métodos livres de sensores, que inferem estados emocionais a partir de padrões de interação e estimativas de conhecimento. A integração dessas tecnologias em Sistemas Tutores Inteligentes e a emergência de tutores de IA generativa emocionalmente inteligentes apontam para um futuro onde o suporte pedagógico será cada vez mais personalizado e empático.

Contudo, a eficácia desses sistemas transcende a mera precisão algorítmica, exigindo uma sensibilidade pedagógica na interpretação e aplicação dos dados

emocionais. As implicações éticas, como privacidade e vigilância afetiva, permanecem como desafios centrais, demandando diretrizes claras e um compromisso contínuo com o uso responsável da tecnologia. É crucial, também, diferenciar as evidências consolidadas das tendências emergentes, garantindo que as conclusões sejam fundamentadas em rigor científico e não em extrapolações.

Em suma, a Computação Afetiva na educação não é apenas uma ferramenta tecnológica, mas um campo de pesquisa que busca humanizar a interação digital, transformando dados emocionais em oportunidades para um aprendizado mais engajador, eficaz e equitativo. As futuras pesquisas devem continuar a explorar a integração multimodal de dados, a validação empírica de novas abordagens e o desenvolvimento de arcabouços éticos robustos para garantir o pleno potencial dessa área.

Referências

Page, M. J.; McKenzie, J. E.; Bossuyt, P. M.; Boutron, I.; Hoffmann, T. C.; Mulrow, C. D. & Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. BMJ, 372. Disponível em: https://www.bmj.com/content/372/bmj.n71

Yadegaridehkordi, E.; Noor, N. F. B. M.; Ayub, M. N. B.; Affal, H. B. & Hussin, N. B. Affective computing in education: A systematic review and future research. **Computers & Education: Artificial intelligence**. 2019

Shingjergji, K.; Iren, D.; Urlings, C. & Klemke, R. Affective computing in online higher education: A systematic literature review using PRISMA. **Computers and Education: artificial intelligence**. 2025.

Dadabada, P. K. Building emotionally intelligent generative AI tutors for education. **Discover Education**, v. 5, n. 176, 2026

Kong, K.; Isleem, H. F.; Aluvalu, R.; Tejani, G. G. & Metwally, A. S. M. Real-time cognitive and emotional state tracking in intelligent tutoring systems for enhanced learning outcomes. **Journal of Big Data,** v. 12, n. 266, 2025.

Khan, B.; Usman, M. & Binsawad, M. novel hybrid model for emotion detection in text through sequential and transformer-based approaches: LSTM enhanced RoBERTa (LER). **Scientific Reports**, v. 16, n. 2224, 2026.

Lima, P. V. B. O.; Maranhão, D. & Soares, C. de S. Automatic Emotion Detection in the Learning of Algorithms. **Association for Computing Machinery**, 2023.

Ashraf, T.; Anas, M.; Bhatti, P. & Tahir, M. **Emotion Aware AI Mentorship System for Personalized Learning Enhancement Using Multilingual Emotion Detection**. In: Conference: 2026 International Conference on Information Science and Communication Technology (ICISCT), 2026.

Iren, D.; Yildirim, E. & Shingjergji, K. Ethical Risks, Concerns, and Practices of Affective Computing. In: 11th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW) At: MIT, Boston, 2023.

Fernández-Herrero, J. Evaluating recent advances in affective intelligent tutoring systems: A scoping review of educational impacts and future prospects. **Education Sciences**, 2024

Portaria CNPq No 2.664, de 6 de março de 2026. Institui a Política de Integridade na Atividade Científica do CNPq. Disponível em: http://memoria2.cnpq.br/web/guest/view/-/journal_content/56_INSTANCE_0oED/10157/23142775

A portaria 2664/2026 do Cnpq estabelece regras claras ... - Instagram. Disponível em: https://www.instagram.com/p/DW7hfNSCcen/

Análise COMPLETA da Portaria 2664/2026 que institui a Política de ... - Instagram. Disponível em: https://www.instagram.com/reel/DWEnAuZDflQ/?hl=en

Nova portaria do CNPq define limites para o uso de inteligência ... - PPGARTES UNESPAR. Disponível em: https://ppgartes.unespar.edu.br/nova-portaria-do-cnpq-define-limites-para-o-uso-de-inteligencia-artificial-na-pesquisa-academica

conheça os principais pontos da Portaria no 2664/2026 do CNPq - Fisiologia UFRJ. Disponível em: https://fisiologia.posgraduacao.biof.ufrj.br/destaques/noticias/integridade-cientifica-e-uso-de-ia-conheca-os-principais-pontos-da-portaria-no-2664-2026-do-cnpq

Lopes, A. S.; Vidotto, K. N. S.; Pozzebon, E. & Ferenhof, H. A. Inovações educacionais com o uso da Realidade Aumentada: uma revisão sistemática. **Educ. rev.,** 35, 2019.

Picard, R. W. **Affective computing**. MIT press, 1997.

Portaria CNPq No 2.664, de 6 de março de 2026. Institui a Política de Integridade na Atividade Científica do CNPq. Disponível em: https://www.gov.br/cnpq/pt-br/assuntos/noticias/cnpq-em-acao/cnpq-publica-portaria-que-institui-politica-de-integridade-na-atividade-cientifica

Souza, A. S.; Hickmann, A. A.; Asinelli-Luz, A. & Hickmann, G. M. A influência das emoções no aprendizado de escolares. **Rev. Bras. Estud. Pedagog.** 101 (258), 2020.

Goldoni, A.; Reis, J. & Jaques, P. A. Emoções na Aprendizagem: Estimando a Duração da Confusão e Aprimorando Intervenções Pedagógicas. **Revista Brasileira de Informática na Educação**, v. 31, 2023.

Werlang, M., & Jaques, P. A. Detecção de emoções através de redes neurais convolucionais e fluxo de emoções. **Revista Brasileira de Informática na Educação**, v. 31, 2023.

Kautzmann, C., et al. (2024). Detecção de Emoções na Aprendizagem de Programação: Os Efeitos de Usar Estimativas de Conhecimento em Modelos Livres de Sensores que Detectam a Confusão do Aluno. **Revista Brasileira de Informática na Educação,** v. 32, 2024.

Lima, R. **Detecção automática de emoções no aprendizado de algoritmos.** Trabalho de Conclusão de Curso (graduação) - Ciência da Computação, Universidade do Maranhão, Campus do Bacanga, 2023.

Dubovi, A. Automated emotion recognition of students in virtual reality classrooms. **Computers & Education: Artificial Intelligence**, 4, 100134, 2023.

Yu, B. An Affective Computing-Enhanced Instructional Design Framework for Digital Learning Environments. **ACM Transactions on Computing Education**, 2026.

Apêndice A: quadro comparativo dos estudos centrais

Referência	Tipo de estudo	Foco principal	Metodologia de detecção	Principais achados / contribuições	Implicações para educação
Fernández-Herrero, J. (2024) [10]	Scoping Review	Avaliação de ATS afetivos	Diversas (revisão)	Análise de impactos educacionais e perspectivas futuras de ATS afetivos. Uso do ROBIS para viés.	Fornece uma visão abrangente do estado da arte e lacunas em ATS afetivos.
Yadegaridh kordi, E (Ano recente) [2]	Revisão Sistemáti-ca	Computa-ção Afetiva na Educação	Diversas (revisão)	Síntese do conhecimento atual e direções futuras para CA na educação.	Ajuda a identificar tendências e áreas de pesquisa emergentes.

continua

continuação

Dadabada, P. K. (2026) [4]	Artigo de Pesquisa	Tutores de IA Generativa Emocional-mente Inteligentes	Modelagem cognitiva + sensoriamento afetivo	Desenvolvi-mento de EAGAITs para feedback personalizado.	Apresenta o estado da arte em tutores de IA com foco em emoções e IA generativa.
Science Direct (2025) [3]	Revisão Sistemá-tica (PRISMA)	Computa-ção Afetiva em Ensino Superior Online	Diversas (revisão)	Análise de 96 estudos (2019-2024) usando PRISMA.	Demonstra a aplicação rigorosa do PRISMA e a abrangência necessária para o corpus.
Kong, K. et al. (2025) [5]	Artigo de Pesquisa	Rastrea-mento de estados cognitivos e emocionais em ITS	Framework integrado em tempo real	Melhoria dos resultados de aprendizagem através de feedback adaptativo.	Destaca a importância do rastreamento em tempo real para intervenções pedagógicas
Nature (2026) [6]	Artigo de Pesquisa	Modelo híbrido para detecção de emoções em texto	Modelo híbrido (detalhes a serem extraídos)	Detecção eficiente de nuances emocionais em texto.	Relevante para detecção livre de sensores e análise de interações textuais.
ACM (2023) [7]	Artigo de Pesquisa	Detecção automática de emoções no aprendiza-do de algoritmos	Deep Learning (API para expressões faciais)	Desenvolvi-mento de API para detecção de emoções em expressões faciais no contexto de programação.	Foco específico na área de programação, alinhado ao artigo original.

continua

continuação

Iren (2023) [9]	Análise Temática	Riscos, preocupa-ções e práticas éticas da computação afetiva	Análise temática	Investigação das considerações éticas na pesquisa em computação afetiva.	Fundamenta a discussão ética e as melhores práticas.
Ashraf, T. et al. (2026) [8]	Artigo de Pesquisa	Sistema de mentoria por IA com detecção multilíngue de Emoções	Detecção de emoções multilingue	Mentoria personalizada e aprimoramento da aprendizagem.	Aborda a personalização e a adaptabilidade cultural na detecção de emoções.

Sobre o autor(a)

Maria Eduarda Mariano

Mestranda em Tecnologias da Informação e Comunicação pelo Programa de Pós-Graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina (UFSC).

Licenciada em Matemática pela Universidade do Extremo Sul Catarinense (UNESC - 2021)

CAPÍTULO 16

Inteligência artificial e detecção de emoções na voz em contextos educacionais: uma revisão sistemática

Lucas Moraes Amancio

1. Introdução

O processo de aprendizagem foi historicamente tratado como um fenômeno puramente lógico, isolado das condições corporais e sentimentais do aluno. Contudo, evidências neurocientíficas desconstroem essa visão ao revelar que a cognição e a emoção operam de forma indissociável. As habilidades exigidas no ambiente educacional não funcionam de maneira desincorporada da realidade humana. Segundo Immordino-Yang e Damasio (2007, p.3, tradução nossa), essas funções cognitivas são "profundamente afetadas e subsumidas nos processos da emoção". Assim, o estado afetivo atua como o próprio alicerce da construção do conhecimento.

A Inteligência Artificial desponta como uma ferramenta capaz de transformar as práticas pedagógicas e lidar com essas complexidades da aprendizagem. Os grandes modelos de linguagem apresentam um potencial notável para a construção de experiências educacionais adaptativas e moldadas às necessidades de cada estudante. Apesar desses avanços na geração de conteúdo e tutoria, a atual interação computacional permanece predominantemente textual. Essa barreira técnica limita a capacidade da máquina de captar sinais afetivos essenciais que ocorrem naturalmente durante a fala humana (KASNECI et al., 2023).

De acordo com Schuller e Schuller (2021), a análise computacional do afeto vocal amadureceu substancialmente impulsionada pelos avanços do aprendizado profundo. As tecnologias anteriores dependiam de parâmetros acústicos definidos por especialistas. Em contrapartida, os modelos atuais aprendem de forma autônoma a extrair representações emocionais diretamente do áudio bruto. Essa identificação de padrões complexos aproxima a percepção computacional à audição humana natural, logo, esse salto tecnológico viabiliza a detecção emocional de forma contínua em ambientes virtuais de ensino.

Para viabilizar essa leitura emocional, a literatura categoriza a captação de dados em sinais físicos e fisiológicos (KHARE et al., 2024). A fala humana se insere na primeira categoria, configurando um método de análise não invasivo e de alta viabilidade para plataformas educacionais. O processamento desses dados acústicos complexos exige arquiteturas computacionais robustas. Segundo Khare et al. (2024), nesse cenário os "modelos de aprendizado profundo ganharam popularidade sobre o aprendizado de máquina tradicional" (KHARE et al., 2024, p.16, tradução nossa). Essa superioridade técnica permite classificar as nuances vocais dos discentes com altíssima precisão.

A fala desempenha um papel fundamental na comunicação, exibindo com clareza os estados cognitivos e as intenções dos indivíduos (IMANI; MONTAZER, 2019). Contudo, a integração do reconhecimento de emoções por voz nas Tecnologias de Informação e Comunicação (TIC) educacionais enfrenta obstáculos, como a dificuldade técnica em distinguir sentimentos com níveis de excitação semelhantes. Diante dessa complexidade, este trabalho apresenta uma revisão sistemática da literatura para mapear o estado da arte da Inteligência Artificial aplicada à detecção do afeto vocal no ensino.

Assim, este trabalho tem por objetivos identificar estudos que tratam do uso de detecção de emoções na voz com IA em contextos educacionais, verificar a quantidade de trabalhos na área e analisar o período com maior número de publicações. Busca também investigar os métodos e ferramentas utilizados, categorizando-os conforme a área de atuação, e detalhar os resultados dos estudos a fim de verificar se houve ganhos no uso da detecção de emoções na voz com IA na educação.

Para atender a esses objetivos, a revisão sistemática foi conduzida pelas seguintes perguntas norteadoras:

a. Qual é o panorama atual das publicações sobre o uso de IA para reconhecimento de emoção na fala no contexto educacional?
b. Quais são as principais arquiteturas de IA, ferramentas e sua eficácia reportada na detecção de emoções via voz na educação?
c. Como as aplicações de detecção de emoções na voz variam de acordo com a área de atuação ou nível de ensino?
d. Quais são os principais achados e benefícios relatados pelo uso dessas tecnologias no processo de ensino-aprendizagem?
e. Quais são os principais desafios e limitações identificados na implementação da detecção de emoções por voz em contextos educacionais?
f. Qual é a qualidade metodológica dos estudos que sustentam esses achados?

Assim, o presente trabalho reúne e analisa referências existentes sobre o tema, observando modos de aplicação da IA para reconhecimento emocional vocal na educação, o que possibilita maior familiaridade com o assunto e serve de

embasamento para estudos e práticas futuras nesse campo.

2. Referencial teórico

Este trabalho toma base em três conceitos principais: o Modelo Circumplexo do Afeto, a Inteligência Artificial na Educação e o Reconhecimento de Emoções na Voz. Estes temas serão, em primeiro lugar, esclarecidos e, em seguida, utilizados como lente teórica para fundamentar a análise e responder às questões de pesquisa levantadas por esta revisão sistemática.

2.1. Modelo circumplexo do afeto

A literatura psicológica tradicionalmente categorizava os estados afetivos como fatores independentes e unipolares, tratando sentimentos como tristeza, raiva ou alegria como dimensões isoladas. Esse paradigma foi reestruturado pela teoria de Russell (1980), que evidenciou uma inter-relação sistemática entre essas diferentes emoções. O autor introduziu o Modelo Circumplexo do Afeto, argumentando que a experiência emocional humana não é composta por caixas cognitivas separadas, mas sim representada de forma contínua em um espaço bidimensional. Nessa modelagem, as emoções se distribuem de maneira circular, refletindo a estrutura mental que as pessoas utilizam naturalmente para compreender seus próprios sentimentos e os estímulos ao seu redor (Russel, 1980).

A sustentação desse modelo espacial se apoia em dois eixos bipolares centrais: o nível de prazer em oposição ao desprazer e o grau de ativação em contraste com a sonolência. Cada conceito afetivo encontra seu lugar no perímetro desse círculo como uma combinação exata dessas duas coordenadas fundamentais. A empolgação localiza-se na interseção entre alto prazer e alta ativação, enquanto a depressão se define pelo desprazer somado à baixa energia. Essa disposição circular fornece um mapa robusto das variações afetivas e se torna uma base metodológica essencial para que sistemas computacionais consigam interpretar e classificar a complexidade fluida das emoções humanas de forma matematicamente precisa (Russel, 1980).

2.2. Inteligência Artificial na Educação

O envolvimento dos alunos consolidou-se como um pilar autônomo da educação contemporânea. Segundo Whitehill et al. (2014), este engajamento é multidimensional e abrange componentes comportamentais, emocionais e cognitivas. A medição clássica deste interesse dependia de observações manuais e autorrelatos, que apresentam fortes limitações de resolução temporal. Com a inserção de tecnologias digitais no ensino,

abriu-se espaço para a automação dessas medidas, permitindo que Sistemas Tutores Inteligentes e outras plataformas de aprendizagem comecem a utilizar a Inteligência Artificial para monitorar a atenção e a motivação dos alunos em tempo real.

A efetividade dessa automação pedagógica depende diretamente dos avanços da computação afetiva, um campo focado em criar interações mais naturais entre humanos e computadores. A captação de dados emocionais enriquece os ambientes virtuais de ensino, pois o estado afetivo afeta a memória, o desempenho e a capacidade de processamento de informações (Bahreini; Nadolski & Westera, 2016).

> É amplamente aceito que as emoções são fatores significativos em qualquer processo de aprendizagem, porque influenciam o processamento de informações, a memória e o desempenho. O fornecimento de feedback aos alunos torna-se mais personalizado quando os estados emocionais são levados em conta. (Bahreini; Nadolski & Westera, 2016, p. 1368, tradução nossa).

Quando equipada com ferramentas capazes de interpretar o afeto, uma plataforma de ensino evolui para um Sistema Tutor Afetivo. Essa transformação viabiliza a entrega de um feedback perfeitamente ajustado às necessidades do aluno, guiando o seu processo educacional de forma responsiva e personalizada (Bahreini; Nadolski & Westera, 2016).

Mattioli e Cabitza (2024) argumentam que a implementação dessas tecnologias impõe desafios significativos, uma vez que a premissa de medição universal de estados internos é frequentemente contestada por ignorar influências culturais e contextuais. O uso de dados biométricos para monitorar emoções pode instaurar desequilíbrios de poder e ameaçar a privacidade individual, tornando essencial uma avaliação crítica sobre a legitimidade e o impacto social dessas ferramentas no ambiente educacional. Segundo os autores, a vigilância automatizada é problemática pois transforma as expressões humanas em dados brutos utilizados por algoritmos que podem invadir a esfera privada, desafiando a autonomia dos sujeitos monitorados.

2.3. Reconhecimento de emoções na fala com IA

O Reconhecimento de Emoções na Fala, ou *"Speech Emotion Recognition"* (SER), é um campo que se dedica a classificar automaticamente estados afetivos a partir de sinais de voz, interpretando nuances como tom, ritmo e intensidade. Essa tarefa permanece desafiadora devido à variabilidade acústica entre falantes e à dificuldade de isolar características emocionais estáveis, mas o seu potencial para enriquecer interações em aprendizagem eletrônica, saúde móvel e assistentes virtuais justifica o

crescente interesse científico (Issa; Demirci & Yazici, 2020).

Para enfrentar essa complexidade, os modelos de inteligência artificial, com destaque para as redes neurais profundas e convolucionais, têm se mostrado particularmente eficazes. Segundo Issa, Demirci e Yazici (2020) "uma das principais vantagens das técnicas de aprendizado profundo reside na seleção automática de características, que poderiam, por exemplo, ser aplicadas a atributos importantes inerentes aos arquivos de som com uma emoção particular na tarefa de reconhecimento de emoções na fala" (Issa; Demirci & Yazici, 2020, p.1, tradução nossa).

As arquiteturas convolucionais unidimensionais propostas por esses autores processam diretamente representações espectrais do áudio, extraindo padrões emocionais sem a necessidade de conversões visuais intermediárias, o que torna a classificação mais direta e computacionalmente eficiente.

Além da análise acústica, a incorporação de arquiteturas baseadas em atenção, como o BERT, permite capturar dependências contextuais complexas em dados sequenciais. Devlin et al. (2019) demonstram que o pré-treinamento bidirecional profundo viabiliza a modelagem conjunta do contexto linguístico, integrando informações de ambas as direções do texto. Essa capacidade de representação enriquece a interpretação do conteúdo verbal associado à fala, refinando a precisão do reconhecimento emocional em cenários educacionais.

A etapa de extração de características espectrais é determinante para a eficácia dos sistemas de SER. Tradicionalmente, o Mel Frequency Cepstral Coefficient (MFCC) tem sido amplamente utilizado por sua capacidade de representar o sinal de voz de forma alinhada à percepção auditiva humana (Ancilin & Milton, 2021).

Ancilin e Milton (2021) propuseram uma modificação nesse processo, denominada Mel Frequency Magnitude Coefficient (MFMC), que substitui o espectro de energia pelo espectro de magnitude e elimina a transformada discreta do cosseno. Os experimentos conduzidos pelos autores demonstraram que o MFMC, como característica isolada, superou o MFCC e outras representações espectrais em seis bases de dados distintas, alcançando 81,50% de acurácia no Berlin e 64,31% no Ravdess. Essa evolução nas técnicas de extração contribui diretamente para o aprimoramento da detecção de emoções em contextos educacionais.

3. Metodologia

A fim de identificar estudos sobre o uso de detecção de emoções na voz com IA em contextos educacionais e responder às perguntas de pesquisa levantadas, tomou-se como base a Revisão Sistemática de Literatura (RSL) e a análise bibliométrica. A RSL tem por finalidade pesquisar a literatura sobre um tema específico, disponibilizando um resumo das evidências encontradas e explicitando de forma sistemática o modo

como foram feitas as buscas, a análise e a síntese das publicações recuperadas (Ferenhof & Fernandes, 2016)

Para operacionalizar esse processo, utilizou-se o método "Systematic Search Flow" (SSF), composto por quatro fases e oito atividades que sistematizam desde a definição do protocolo de pesquisa até a redação final dos resultados (FERENHOF; FERNANDES, 2016). A escolha por esse método justifica-se pela sua capacidade de garantir a repetibilidade do estudo e evitar tendências na seleção de documentos.

A fase inicial do SSF, dedicada à definição do protocolo de pesquisa, desdobrou-se em cinco atividades interligadas: definição da estratégia de busca, consulta às bases de dados, organização do portfólio bibliográfico, padronização da seleção dos artigos e composição do portfólio final (Ferenhof & Fernandes, 2016).

A estratégia de busca foi elaborada a partir de palavras-chave alinhadas aos eixos temáticos da pesquisa, utilizando operadores lógicos e delimitações temporais e de idioma. As consultas foram executadas em bases de dados científicas selecionadas por sua relevância para a área, e os registros recuperados foram armazenados em um software de gerenciamento bibliográfico para assegurar a integridade e a rastreabilidade do processo.

Para conduzir o processo de seleção e análise dos estudos primários, empregou-se o sistema "Parsif.al", uma ferramenta online projetada especificamente para auxiliar pesquisadores na realização de revisões sistemáticas da literatura (Klock, 2018). A plataforma permitiu a aplicação dos critérios de inclusão e exclusão conforme o protocolo estabelecido e a extração padronizada dos dados. A segunda fase analítica, correspondente ao detalhamento dos dados coletados da primeira parte, envolveu a organização de informações como autores, periódicos, definição dos constructos estudados e pontos fracos e fortes acerca do objeto de estudo, analisados bibliometricamente.

Esse exame permitiu identificar os principais arquétipos e lacunas de conhecimento sobre o tema investigado (Ferenhof & Fernandes, 2016). A etapa de síntese (terceira fase) foi conduzida por meio de uma matriz do conhecimento, que organizou os dados extraídos para facilitar a interpretação e a construção de relações entre os achados dos estudos primários (Ferenhof & Fernandes, 2016).

Essa sistematização possibilitou gerar novos conhecimentos a partir dos resultados previamente publicados, identificando convergências e divergências entre as abordagens de reconhecimento emocional na fala e suas aplicações educacionais. Por fim, a quarta fase do método SSF consolidou todo o percurso metodológico nesta redação científica, resgatando o objetivo da revisão e fundamentando a escrita dos resultados com base na análise e síntese realizadas demonstradas no capítulo 4 deste artigo (Ferenhof & Fernandes, 2016).

As consultas às seis bases de dados foram executadas em 24 de maio de 2026. Nenhuma atualização de busca foi realizada após essa data, de modo que estudos publicados posteriormente não integram o portfólio analisado. Embora o SSF forneça a estrutura condutora desta revisão, o reporte do processo de seleção foi adicionalmente organizado segundo as recomendações do PRISMA 2020 (Page et al., 2021), padrão internacional para a comunicação transparente de revisões sistemáticas.

Os dois instrumentos não são concorrentes e cumprem funções distintas: o SSF orienta a condução das fases da revisão, enquanto o PRISMA padroniza a apresentação do fluxo de identificação, triagem, elegibilidade e inclusão, discriminando o número de registros excluídos em cada etapa e os motivos correspondentes. Essa complementaridade permite que o percurso seja auditado por leitores externos e replicado por outros pesquisadores. O fluxograma resultante é apresentado na Figura 1, na seção 4.

3.1. AVALIAÇÃO DA QUALIDADE METODOLÓGICA DOS ESTUDOS

A aplicação de critérios de inclusão e exclusão assegura a pertinência temática do portfólio, mas não informa sobre o rigor com que cada estudo foi conduzido. Para que a síntese não atribuísse peso idêntico a trabalhos metodologicamente desiguais, os 19 estudos aprovados na etapa anterior foram submetidos a um instrumento de avaliação da qualidade, em conformidade com a recomendação consolidada de que revisões sistemáticas na área de computação incorporem essa etapa (Kitchenham & Charters, 2007; Dyba & Dingsoyr, 2008).

O instrumento foi elaborado pelo autor e aplicado no módulo de Quality Assessment do Parsif.al (Klock, 2018), o que garantiu o registro individual de cada resposta na própria plataforma em que a revisão foi conduzida. Compõe-se de oito critérios que combinam elementos genéricos de reporte científico com aspectos específicos do reconhecimento de emoções na fala, como a centralidade do sinal de voz a arquitetura proposta e a descrição das técnicas de pré-processamento de áudio. Cada critério admite três respostas: Sim (1,0), Parcialmente (0,5) e Não (0,0), totalizando um escore máximo de 8,0 pontos por estudo. Os critérios são apresentados no Quadro 1.

Quadro 1. Instrumento de avaliação da qualidade metodológica

Critérios	Pergunta aplicada
Q1. Algoritmos de IA	O estudo descreve claramente os algoritmos de IA utilizados para o treinamento do SER?

continua

continuação

Q2. Centralidade da voz	O estudo estabelece claramente a voz (áudio/SER) como o foco central da arquitetura de IA proposta?
Q3. Dataset e pré-processamento	O estudo descreve claramente o conjunto de dados (dataset) e as técnicas de pré-processamento de áudio utilizadas?
Q4. Replicabilidade	A metodologia experimental é descrita com detalhes suficientes para permitir a replicação?
Q5. Métricas de desempenho	Os resultados são validados através de métricas de desempenho claras (ex.: Acurácia, F1-Score, recall)?
Q6. Contexto educacional	O contexto educacional e o perfil dos participantes (estudantes/professores) são bem definidos?
Q7. Limitações	O estudo discute as limitações e os desafios encontrados na implementação prática?
Q8. Objetivo	O objetivo da pesquisa é claramente descrito?

Fonte: Elaborado pelo autor no módulo de Quality Assessment do Parsif.al.

Diferentemente das etapas anteriores, em que a exclusão decorria do não atendimento a um critério categórico, esta etapa operou por ponto de corte: fixou-se em 7,0 pontos o escore mínimo para integrar o portfólio final. Cinco dos 19 estudos avaliados ficaram abaixo desse limiar e foram excluídos, resultando nos 14 artigos analisados nas seções seguintes. A separação entre os dois grupos mostrou-se nítida, sem casos limítrofes: o menor escore entre os incluídos foi 7,0 e o maior entre os excluídos, 6,5.

Registre-se que o instrumento mede a qualidade do desenho e do reporte metodológico, e não a validade das conclusões de cada estudo. Um escore baixo indica que informações necessárias à avaliação crítica não foram disponibilizadas pelos autores ou que o objeto do trabalho se afasta do escopo desta revisão, o que não equivale a afirmar que o estudo esteja incorreto. Cabe ainda a ressalva de que a pontuação foi atribuída por um único avaliador, sem cálculo de concordância entre revisores, limitação retomada na seção 5.

3.2. Declaração de uso de inteligência artificial generativa

Em conformidade com a Portaria CNPq no 2.664/2026, informa-se que as ferramentas ChatGPT (OpenAI, GPT-5.5, versão padrão instantânea), Gemini (Google, versões 3.1 Flash Lite, 3.5 Flash e 3.1 Pro), NotebookLM (Google), DeepSeek (DeepSeek V-4) e Claude (Anthropic, Opus 4.8) foram utilizadas como ferramentas auxiliares nas seguintes atividades: formatação de referências, apoio técnico em programação e análise textual, apoio à estruturação do artigo, auxílio metodológico, organização de categorias, formatação, revisão gramatical, reorganização textual, tradução, verificação de integridade referencial dos estudos triados, construção do fluxograma PRISMA, pontuação preliminar do instrumento de qualidade metodológica e geração dos gráficos da análise quantitativa. Todas as análises, interpretações e conclusões apresentadas neste manuscrito foram desenvolvidas e validadas pelo autor.

Dado que o emprego de modelos generativos na triagem tem implicações direta sobre a reprodutibilidade da revisão, detalha-se o procedimento adotado na verificação de integridade referencial. Para cada um dos 50 estudos aprovados na leitura de títulos e resumos, os modelos foram solicitados a examinar as referências citadas no texto e a verificar a existência e a correspondência das fontes originais. Consideraram-se indícios de inconsistência crítica: referências inexistentes ou não localizáveis, atribuição de afirmações a fontes que não as sustentam e discrepâncias entre os dados citados e os dados da fonte primária.

A verificação cobriu a totalidade dos 50 estudos, sem qualquer exclusão automática. Todos os apontamentos de inconsistência foram conferidos manualmente junto às fontes primárias antes da exclusão, e os estudos sem apontamentos foram submetidos a uma segunda leitura de atenção reforçada, por constituírem candidatos ao portfólio final. Reconhece-se, ainda assim, que a etapa depende do julgamento humano na confirmação de cada caso e que modelos generativos podem produzir tanto falsos positivos quanto falsos negativos nessa tarefa.

4. Análise e discussão dos resultados

A fase 1 do método SSF compreende cinco atividades que compõem o protocolo de pesquisa, conforme detalhada na sequência (Quadro 2).

Quadro 2 - Protocolo de pesquisa

Atividade 1 Estratégia de busca	A estratégia de busca, com o objetivo de ser o mais abrangente possível, utilizou termos em inglês e português. O objetivo foi encontrar artigos que conectassem especificamente reconhecimento de emoções na voz com inteligência artificial e educação.

continua

continuação

Verificou-se que não são todas as bases que aceitam o asterisco como generalizador de termos, então o seu uso foi vetado.

Vetou-se a utilização do termo “SER” para pesquisa nas bases de dados, apesar de ser amplamente conhecido na comunidade acadêmica como abreviação de “Speech Emotion Recognition”, devido a ambiguidade com o verbo “ser” presente na língua portuguesa.

Foi verificado um problema de ambiguidade quanto as palavras “Teacher” e “Student” devido a uma forma de treinamento de IA com as mesmas palavras.

Utilizou-se aspas nos termos para garantir a integridade da busca pelo conjunto completo do texto.

Os termos utilizados foram: “Speech Emotion Recognition”, “Vocal Emotion Recognition”, “Reconhecimento de Emoção na Fala”, “Reconhecimento de Emoções na Voz”, “Detecção de Emoção na Fala”, “Education”, “Educação”, “Ensino”, “Aprendizagem”, “Classroom”, “Sala de aula”, “Teacher”, “Professor”, “Student”, “Estudante”, “Aluno”, “K12”, “Instructional”, “Aula”.

Foram utilizados operadores booleanos “ou” (OR) com os diferentes termos referentes a reconhecimento de emoções na fala e “e” (AND), juntando com os termos relacionados a educação, que também são diversos, então, receberam o operador booleano “ou” (OR) de igual forma entre seus termos.

Como critérios de inclusão, adotaram-se:

- Estudos que descrevem a aplicação de modelos de Inteligência Artificial para processar sinais acústicos da voz humana com o objetivo de identificar estados afetivos de estudantes ou professores;
- Estudos que descrevem o desenvolvimento de modelos de Inteligência Artificial para o Reconhecimento de Emoção na Fala (SER) especificamente voltados em contextos educacionais;
- Estudos que descrevem o desenvolvimento e a aplicação de modelos de Inteligência Artificial para o Reconhecimento de Emoção na Fala (SER) especificamente voltados para contextos educacionais.

Como critérios de exclusão, foram selecionados:

- Artigos que não possuem aplicação no contexto educacional (exemplo: SER para diagnóstico médico, segurança ou “call centers”);
- Estudos cujo texto completo não está disponível para acesso via Portal de Periódicos da CAPES (incluindo todas as bases de dados assinadas e acessíveis via rede CAFe/UFSC) ou que não possuem versão pública;
- Estudos duplicados;
- Estudos escritos em idiomas diferentes de inglês ou português;

continua

continuação

	• Estudos que não descrevem métodos, algoritmos ou ferramentas tecnológicas aplicadas ao ensino-aprendizagem; • Estudos que não passaram por revisão por pares (“peer-reviewed”); • Estudos que não utilizam Reconhecimento de Emoção na Fala (SER) ou utilizam de maneira minoritária ou acessória; • Estudos que tratam de reconhecimento de emoções exclusivamente por outras modalidades (exemplo: apenas expressão facial, gestos ou biossensores) sem envolver a voz; • Inconsistência Crítica de Integridade Científica; • Publicações com data anterior a 2021; • Resumos expandidos, pôsteres, editoriais, capítulos de livros ou revisões informais; • Resumos sistemáticos;
Atividade 2 Consulta às bases de dados	As bases de dados escolhidas foram: ACM Digital Library, IEEE Digital Library, ISI Web of Science, Portal de Periódicos da CAPES, Science@Direct e Scopus. Os textos de busca foram montados em cada base, mas é possível generalizá-lo: ("Speech Emotion Recognition" OR "Vocal Emotion Recognition" OR "Reconhecimento de Emoção na Fala" OR "Reconhecimento de Emoções na Voz" OR "Detecção de Emoção na Fala") AND ("Education" OR "Educação" OR "Ensino" OR "Aprendizagem" OR "Classroom" OR "Sala de aula" OR "Teacher" OR "Professor" OR "Student" OR "Estudante" OR "Aluno" OR "K12" OR "Instructional" OR “Aula”). Em certas bases específicas, foi necessário adaptações, como: • ACM Digital Library: O texto genérico de busca foi utilizado e foram encontrados 114 resultados; • IEEE Digital Library: O texto genérico de busca foi utilizado e foram encontrados 243 resultados; • ISI Web of Science: TS=(("Speech Emotion Recognition" OR "Vocal Emotion Recognition" OR "Reconhecimento de Emoção na Fala" OR "Reconhecimento de Emoções na Voz" OR "Detecção de Emoção na Fala") AND ("Education" OR "Educação" OR "Ensino" OR "Aprendizagem" OR "Classroom" OR "Sala de aula" OR "Teacher" OR "Professor" OR "Student" OR "Estudante" OR "Aluno" OR "K12" OR "Instructional" OR "Aula")). Foram encontrados 99 resultados; • Portal de Periódicos da CAPES: O texto genérico de busca foi utilizado e foram encontrados 42 resultados;

continua

continuação

	• Science@Direct: Apenas no campo específico de pesquisa avançada "Title, abstract or author-specified keywords": ("Speech Emotion Recognition" OR "Vocal Emotion Recognition") AND ("Education" OR "Classroom" OR "Teacher" OR "Student" OR "K12" OR "Instructional"). Foram encontrados 18 resultados; • Scopus: TITLE-ABS-KEY(("Speech Emotion Recognition" OR "Vocal Emotion Recognition" OR "Reconhecimento de Emoção na Fala" OR "Reconhecimento de Emoções na Voz" OR "Detecção de Emoção na Fala") AND ("Education" OR "Educação" OR "Ensino" OR "Aprendizagem" OR "Classroom" OR "Sala de aula" OR "Teacher" OR "Professor" OR "Student" OR "Estudante" OR "Aluno" OR "K12" OR "Instructional" OR "Aula")). Foram encontrados 242 resultados. O resultado foi de 758 estudos. Não foram utilizados outros filtros nas bases de dados, como tipo ou ano de publicação, buscando recuperar o maior número de resultados possível.
Atividade 3 Organização do portfólio bibliográfico	Para organização dos materiais encontrados foi utilizada a previamente descrita ferramenta online Parsif.al. Ela possui diversas funcionalidades para facilitação do processo, como um verificador automatizado de artigos duplicados e interface amigável. Os metadados de todos os materiais foram enviados no formato BibTeX para a plataforma.
Atividade 4 Padronização da seleção dos artigos	Pela grande quantidade de estudos encontrados, essa fase foi separada em etapas: 1. Filtragem dos arquivos duplicados: foram removidas 230 publicações, restando 528; 2. Filtragem por ano: a remoção das publicações anteriores a 2021 excluiu 121 registros, restando 407; 3. Leitura dos títulos e resumos (abstracts): foram excluídos 357 registros e selecionados 50. Os motivos predominantes, conforme os critérios registrados no Parsif.al, foram a ausência de aplicação em contexto educacional, a ausência de descrição de métodos, algoritmos ou ferramentas aplicadas ao ensino-aprendizagem, a natureza da publicação (resumos expandidos, pôsteres, editoriais e capítulos de livro), a condição de revisão sistemática, o tratamento exclusivo de outras modalidades de reconhecimento emocional e a ausência de revisão por pares; 4. Análise da acessibilidade e verificação de integridade referencial: os 50 estudos restantes tiveram seus textos completos buscados e suas referências verificadas com apoio de modelos de IA, conforme o procedimento descrito na seção 3.2. Foram excluídos 29 estudos: 8 por indisponibilidade do texto completo, 19 por inconsistência referencial confirmada manualmente pelo pesquisador e 2 por critérios de conteúdo identificados na leitura preliminar. Restaram 21 estudos.

continua

continuação

Atividade 5 Composição do portfólio final	Nessa atividade, cada um dos 21 estudos remanescentes foi lido na íntegra. Dois foram excluídos por não descreverem métodos, algoritmos ou ferramentas tecnológicas aplicadas ao ensino-aprendizagem, uma vez que ambos limitavam o contexto educacional à justificativa motivacional, validando seus modelos exclusivamente sobre repositórios públicos de fala encenada, sem professores, alunos ou dinâmicas pedagógicas reais. Os 19 estudos restantes foram submetidos ao instrumento de avaliação da qualidade metodológica descrito na seção 3.1, aplicado no módulo de Quality Assessment do Parsif.al. Cinco deles obtiveram escore inferior ao ponto de corte de 7,0 pontos e foram excluídos, resultando no portfólio final de 14 artigos.

Fonte: Elaborado pelo autor (2026)

Após a conclusão das etapas de filtragem e seleção no sistema Parsif.al (Klock, 2018), os dados dos 14 artigos que compuseram o portfólio bibliográfico final foram exportados para o formato de planilha. Esse procedimento resultou na construção do que Ferenhof e Fernandes (2016) denominam Matriz do Conhecimento, instrumento que organiza as informações extraídas e auxilia tanto a fase de análise quanto a de síntese dos resultados.

O percurso completo de identificação, triagem, elegibilidade e inclusão, com o número de registros excluídos em cada etapa e os respectivos motivos, é sintetizado na Figura 1, construída segundo o modelo de fluxograma do PRISMA 2020 (Page et al., 2021). Os quantitativos foram extraídos diretamente da exportação da base de dados do Parsif.al, o que assegura a rastreabilidade entre o relato e o registro operacional da revisão.

Figura 1 - Fluxograma PRISMA 2020 do processo de seleção dos estudos

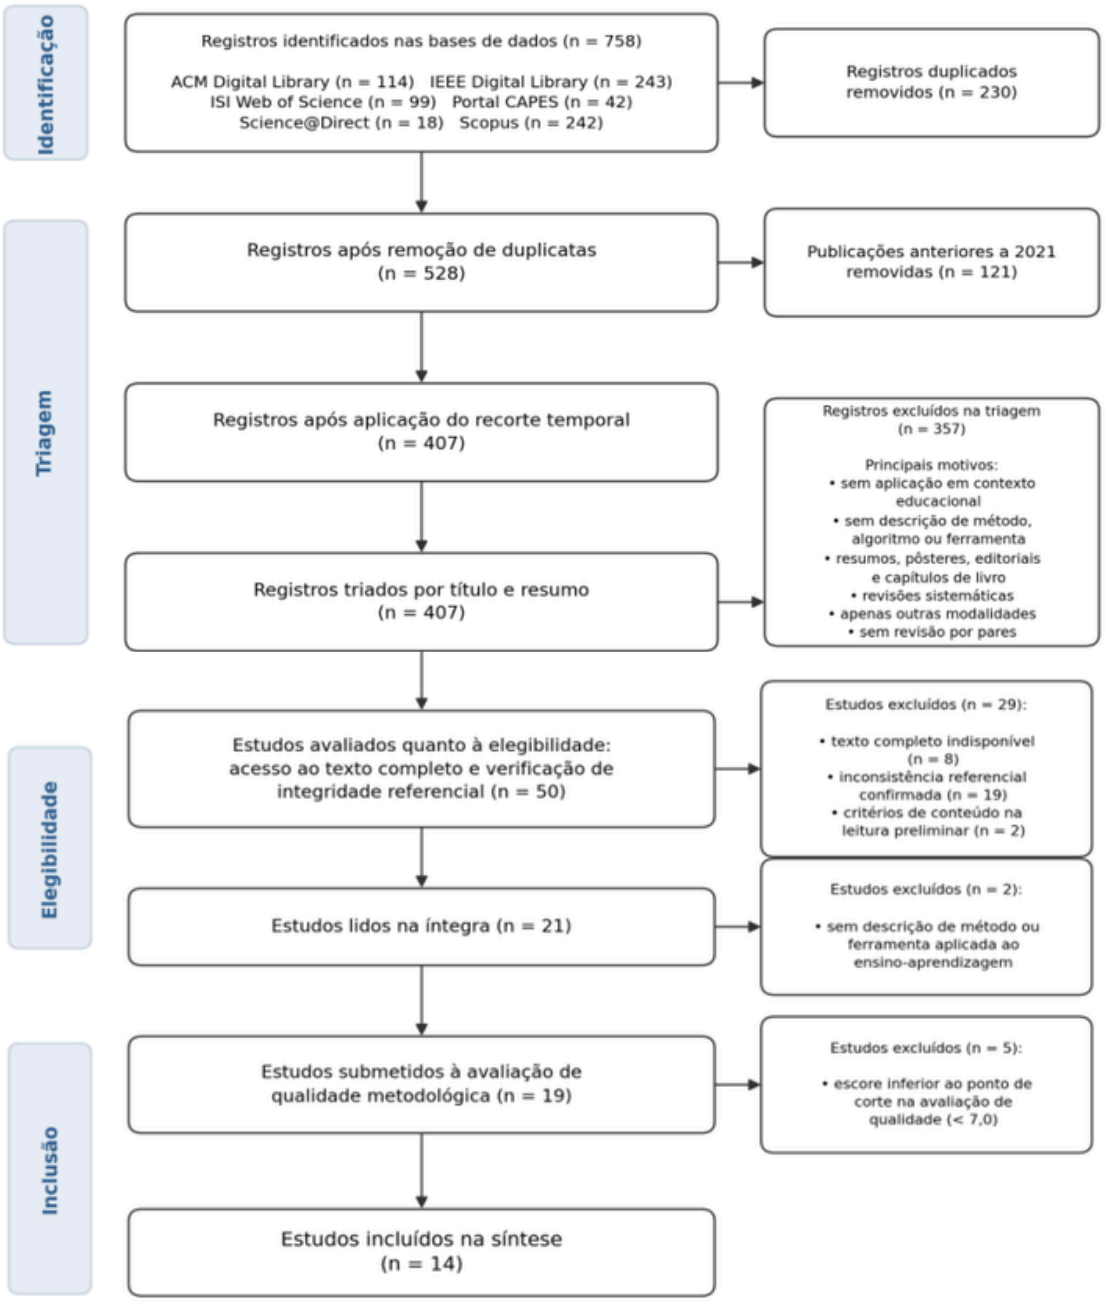

Fonte: Elaborado pelo autor (2026)

A utilização da Matriz do Conhecimento permitiu extrair, de maneira prática e estruturada, os principais dados que se buscava com a realização desta revisão sistemática, como as arquiteturas de IA empregadas, as métricas de eficácia reportadas, os ganhos educacionais observados e os desafios enfrentados pelos pesquisadores (FERENHOF; FERNANDES, 2016). Neste sentido, constatou-se que as publicações recuperadas abrangem o período de 2022 a 2025, com destaque para o ano de 2024, que concentrou seis dos 14 artigos analisados, evidenciando a atualidade e o crescimento do interesse científico pelo tema, embora o volume absoluto de publicações na interseção específica com a educação ainda seja incipiente.

Figura 2 - Distribuição das publicções do portfólio por ano

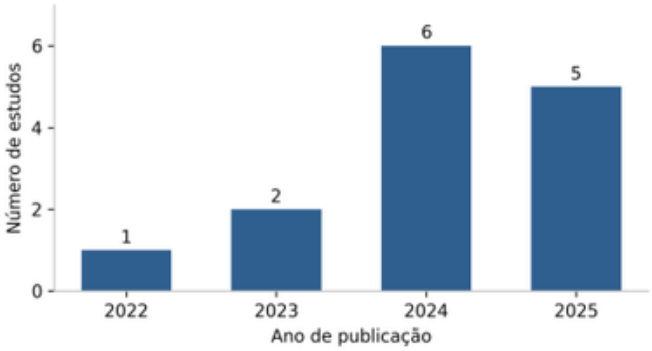

Fonte: Elaborado pelo autor (2026)

Em relação à origem geográfica das pesquisas, a China desponta na vanguarda desses estudos, sendo responsável por cinco publicações, o que representa pouco mais de um terço do portfólio total. A Turquia contribui com dois estudos, enquanto Alemanha, Arábia Saudita, Brasil, Cazaquistão, Estados Unidos, Indonésia e Taiwan respondem por um estudo cada, conforme a Figura 3.

Registre-se que Taiwan foi contabilizado separadamente da China, critério que explica a diferença em relação a contagens que agregam as duas origens. Esse protagonismo chinês sinaliza um investimento consistente do país na interseção entre inteligência artificial, reconhecimento de emoções e educação.

Figura 3 - Distribuição das publicações do portfólio por país de origem

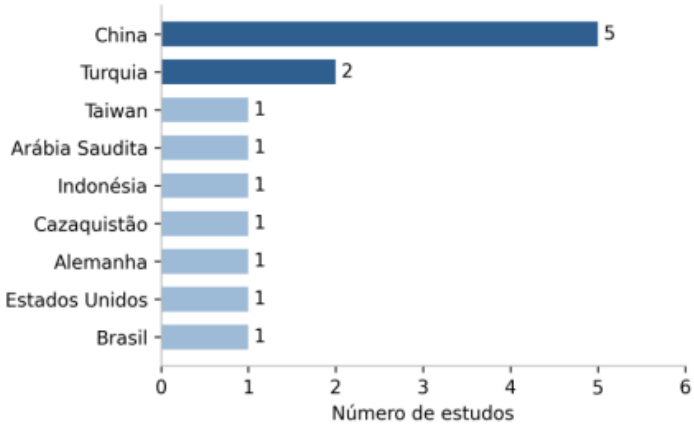

Fonte: Elaborado pelo autor (2026)

A análise dos constructos revelou que a grande maioria das pesquisas mantém a figura do professor como eixo central ou componente majoritário da análise emocional. Embora o comportamento do aluno seja abordado em diversos trabalhos, essa abordagem predominantemente secundária das emoções discentes na maior parte do portfólio sugere uma lacuna metodológica considerável a ser explorada em pesquisas futuras.

Quanto às bases de dados, após passagem pelas bases indexadoras e verificando as entidades em que eles estão publicados, conferiu-se que a IEEE Digital Library concentrou a maior parte das publicações, com cinco artigos, seguida pela MDPI e pela ScienceDirect, com dois artigos cada. A distribuição dos artigos entre as bases indexadoras originais serve apenas como mapeamento de indexação, visto que a triagem e a eliminação de duplicatas foram realizadas centralizadamente na etapa de organização do portfólio.

Após a leitura integral dos artigos, a extração dos dados principais e o agrupamento por assuntos similares, foram criadas três categorias de classificação temática nas quais os artigos ficaram enquadrados para análise e discussão, sendo elas: (1) SER para Avaliação da Prática Docente em Sala de Aula Presencial, (2) SER para Detecção de Engajamento e Estados Afetivos do Aluno e (3) SER em Ambientes de Educação a Distância (EAD).

O portfólio final contendo todos os artigos selecionados e a qual categoria ficaram vinculados pode ser visualizado no Quadro 3.

Quadro 3 - Portfólio final

Autores	Ano	Título	Temática
Dehbozorgi, N. & Kunuku, M. T.	2023	*Affective Computing: A TopicBased SER Approach on Collaborative Discussions in Academic Setting*	SER para Detecção de Engajamento e Estados Afetivos do Aluno
Tokhtarov, A.; et al.	2025	*AI-Based Analysis of Student Frustration: Speech and Facial Expression Recognition*	SER para Detecção de Engajamento e Estados Afetivos do Aluno
Beccaro, W.; et al.	2024	*Analysis of Oral Exams With Speaker Diarization and Speech Emotion Recognition: A Case Study*	SER em Ambientes de Educação a Distância (EAD) e Estados Afetivos do Aluno
Hou, R.; et al	2024	*Automated Assessment of Encouragement and Warmth in Classrooms Leveraging Multimodal Emotional Features and ChatGPT*	SER para Avaliação da Prática Docente em Sala de Aula Presencial e SER para Detecção de Engajamento e Estados Afetivos do Aluno

continua

continuação

Zhao, G.; Zhang, Y.; Chu, J.	2024	*A multimodal teacher speech emotion recognition method in the smart classroom*	SER para Avaliação da Prática Docente em Sala de Aula Presencial
Cheng, Y.; Lin, Y.; Wang W	2025	*A Study on Teachers' Classroom Speech Emotion Expression Based on Speech Emotion Recognition*	SER para Avaliação da Prática Docente em Sala de Aula Presencial
Rosita, Y. D.; Saputra, W. A	2025	*Classifier model for lecturer evaluation by students using speech emotion recognition and deep learning approaches*	SER para Avaliação da Prática Docente em Sala de Aula Presencial
Alkhamali, E. A.; Allinjawi, A.; Ashari, R. B	2024	*Combining Transformer, Convolutional Neural Network, and Long Short-Term Memory Architectures: A Novel Ensemble Learning Technique That Leverages Multi-Acoustic Features for Speech Emotion Recognition in Distance Education Classrooms*	SER em Ambientes de Educação a Distância (EAD)
Chen, C. & Cai, Y	2025	*Cross-Cultural Speech Emotion Recognition for L2 Pronunciation Training*	SER para Detecção de Engajamento e Estados Afetivos do Aluno
Zhu, M.; Wang, C. & Huang, C.	2024	*Fidgety Speech Emotion Recognition for Learning Process Modeling*	SER em Ambientes de Educação a Distância (EAD) e SER para Detecção de Engajamento e Estados Afetivos do Aluno
He, Y.; et al.	2024	*Research on Teacher Classroom Teaching Speech Emotion Recognition Based on LSTM*	SER para Avaliação da Prática Docente em Sala de Aula Presencial
Tanko, D.; et al.	2022	*Shoelace pattern-based speech emotion recognition of the lecturers in distance education: ShoePat23*	SER em Ambientes de Educação a Distância (EAD)

continua

continuação

Suen, H. & Su, Y.;	2025	*Teachers' Vocal Expressions and Student Engagement in Asynchronous Video Learning*	SER em Ambientes de Educação a Distância (EAD) e SER para Detecção de Engajamento e Estados Afetivos do Aluno

Fonte: Elaborado pelo autor (2026)

4.1. Observações gerais

A partir da análise dos artigos do portfólio final foi possível perceber algumas tendências sobre a aplicação do reconhecimento de emoções na fala em contextos educacionais. Prevaleceram as redes neurais profundas, com destaque para as redes neurais convolucionais (CNN) e as redes de memória de longo prazo (LSTM) combinadas em arquiteturas híbridas, enquanto bases consolidadas como IEMOCAP e EMO-DB foram amplamente empregadas no treinamento e validação dos modelos. Além disso, a maioria dos estudos utilizou datasets próprios, aplicando-os predominantemente na fase de testes empíricos dos modelos treinados.

O Quadro 4 detalha a arquitetura adotada em cada um dos 14 estudos. Além das combinações de CNN e LSTM já mencionadas, o portfólio contempla arquiteturas baseadas em Transformers e em aprendizado auto supervisionado, como o HuBERT, e abordagens que recorrem a grandes modelos de linguagem, como o ChatGPT e o GPT4, para extrair emoções e tópicos a partir da fala transcrita. Chama atenção a persistência de dois trabalhos que dispensam o aprendizado profundo, extraindo atributos matemáticos manualmente projetados e classificando-os com máquinas de vetores de suporte (SVM): reportam acurácias entre as mais altas do portfólio, superiores a 93%, o que antecipa a discussão sobre as condições em que esses números foram obtidos.

Quadro 4 - Arquiteturas de IA empregadas em cada estudo do portifólio

Estudo	Arquitetura de IA Proposta
Dehbozorgi e Kunuku (2023)	Transcrição da fala pela API AssemblyAI; extração de emoções do texto transcrito com o pacote Text2emotion e a API do ChatGPT; modelagem de tópicos por sumarização (ChatGPT) e NMF
Tokhtarov et al. (2025)	CNN (expressão facial) e Transformer (voz), com fusão multimodal por atenção

continua

continuação

Beccaro et al. (2024)	Diarização de locutor; reconhecimento de emoção com HuBERT (modelo autossupervisionado) como extrator de atributos e classificador InceptionTime
Hou et al. (2024)	Pipeline multimodal com reconhecimento facial (EmoNet), reconhecimento da fala por XLSR/wav2vec 2.0 (autossupervisionado) e análise de sentimento do texto (TextBlob); estimativa combinando modelos supervisionados (RF, SVM, MLP) e GPT-4 zero-shot em ensemble
Tanko et al. (2023)	Decomposição wavelet (DWT) com seleção de subbandas; atributos manuais por 1D-OLBP, seleção de atributos por NCA e classificação por SVM
Zhao, Zhang e Chu (2024)	ProsodyBERT: codificador de prosódia por CNN 1D com pooling atencional, codificador de texto BERT (Transformer) e fusão por rede BiLSTM
Cheng, Lin e Wang (2025)	CNN sobre atributos eGeMAPS (comparada a SVM e LSTM)
Rosita e Saputra (2025)	CNN 1D combinada a Bi-LSTM (melhor entre cinco arquiteturas testadas: CNN-1D, LSTM, Bi-LSTM e duas híbridas), sobre atributos acústicos (MFCC, energia e ZCR)
Alkhamali, Allinjawi e Ashari (2024)	Ensemble de Transformer, CNN e LSTM
Chen e Cai (2025)	Rede convolucional recorrente (CRN: 3 camadas convolucionais + 2 BiLSTM) com treinamento adversarial de domínio (gradient reversal) e classificação hierárquica de emoções, sobre espectrograma log-Mel e atributos MFCC
Zhu, Wang e Huang (2024)	CNN residual multiescala 1D (convoluções dilatadas) para o vetor de emoção; fusão com vetor cognitivo por árvore de decisão C5.0 para o reconhecimento final
He et al. (2024)	Rede LSTM profunda empilhada (blocos LSTM + BN + Dropout) com classificador Softmax, sobre atributos acústicos extraídos pelo openSMILE (conjunto IS09)
Tanko et al. (2022)	Decomposição wavelet TQWT com seleção de subbandas; atributos manuais por Shoelace Pattern (ShoePat23), seleção por Chi2 e NCA, e classificação por SVM cúbico

continua

continuação

Suen e Su (2025)	Fala não verbal: modelo de aprendizado profundo CNN + LSTM (treinado no CASIA) sobre atributos acústicos; conteúdo verbal: transcrição por ASR (Whisper) e análise de sentimento com o léxico Chinese EmoBank

Fonte: Elaborado pelo autor (2026)

A maioria das pesquisas concentrou-se na figura do professor, e as métricas de eficácia, a maioria sendo Accuracy (Acurácia), F1-Score e Recall, evidenciaram uma diferença expressiva entre o alto desempenho em ambientes controlados e os resultados mais moderados em cenários reais de sala de aula.

4.2. Qualidade metodológica do portfólio

A aplicação do instrumento descrito na seção 3.1 aos 19 estudos habilitados produziu escores entre 3,5 e 8,0 pontos. Os 14 estudos que compõem o portfólio final apresentam média de 7,54 pontos, ao passo que os cinco excluídos por não atingirem o corte de 7,0 apresentam média de 5,6, com escores entre 3,5 e 6,5, e não são detalhados por não integrarem o portfólio. Os escores individuais dos estudos incluídos constam do Quadro 5.

Quadro 5 - Escores de qualidade metodológica dos estudos incluídos

Estudo	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Escore
Zhao, Zhang e Chu (2024)	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	8,0
Beccaro et al. (2024)	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	8,0
Tanko et al. (2023)	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	8,0
Alkhamali; Allinjawi & Ashari (2024)	1,0	1,0	1,0	1,0	1,0	1,0	1,0	1,0	8,0
Cheng, Lin e Wang (2025)	1,0	1,0	1,0	1,0	0,5	1,0	1,0	1,0	7,5

continua

continuação

Dehbozorgi e Kunuku (2023)	1,0	1,0	1,0	1,0	0,5	1,0	1,0	1,0	7,5
Hou et al. (2024)	1,0	0,5	1,0	1,0	1,0	1,0	1,0	1,0	7,5
Chen e Cai (2025)	1,0	1,0	1,0	1,0	0,5	1,0	1,0	1,0	7,5
Zhu, Wang e Huang (2024)	1,0	1,0	1,0	1,0	0,5	1,0	1,0	1,0	7,5
He et al. (2024)	1,0	1,0	1,0	1,0	0,5	1,0	1,0	1,0	7,5
Tanko et al. (2022)	1,0	1,0	1,0	1,0	1,0	0,5	1,0	1,0	7,5
Tokhtarov et al. (2025)	1,0	0,0	1,0	1,0	1,0	1,0	1,0	1,0	7,0
Rosita e Saputra (2025)	1,0	1,0	1,0	1,0	0,5	0,5	1,0	1,0	7,0
Suen e Su (2025)	0,5	1,0	1,0	1,0	0,5	1,0	1,0	1,0	7,0
Média dos 14 incluídos	0,96	0,89	1,00	1,00	0,75	0,92	1,00	1,00	7,53

Fonte: Dados da pesquisa, extraídos do módulo de Quality Assessment do Parsif.al

Entre os incluídos, quatro estudos alcançaram a pontuação máxima e nenhum ficou abaixo de 7,0, o que indica um portfólio final metodologicamente homogêneo e de qualidade elevada segundo os critérios adotados. A Figura 4 representa graficamente

essa distribuição, na qual se observa a concentração dos escores na faixa entre 7,0 e 8,0 pontos e a nitidez do limiar aplicado na seleção.

Figura 4 - Escore de qualidade metodológica dos estudos incluídos

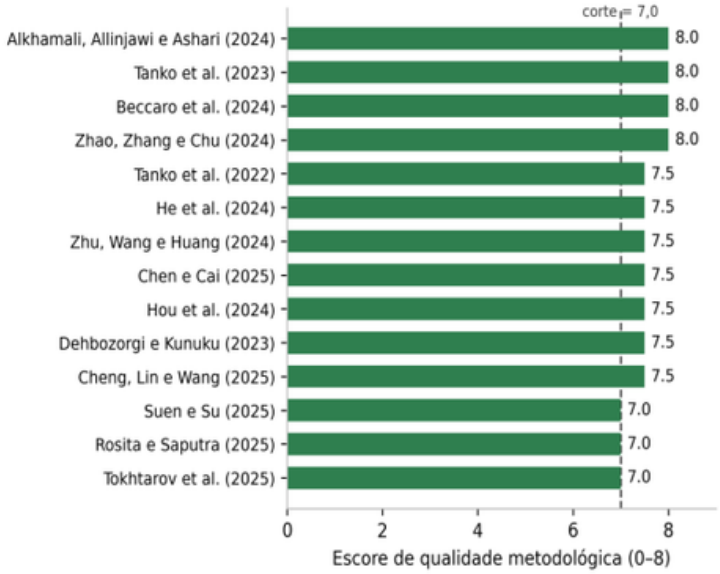

Fonte: elaborado pelo autor (2026)

A leitura por critério, apresentada na Figura 5, é mais informativa que o escore agregado. Entre os 14 estudos incluídos, quatro critérios foram integralmente atendidos: a descrição do dataset e das técnicas de pré-processamento (Q3), o detalhamento metodológico suficiente para replicação (Q4), a discussão de limitações (Q7) e a clareza do objetivo (Q8). O critério mais frágil é o reporte de métricas de desempenho (Q5 = 0,75): metade do portfólio recebeu avaliação parcial, por apresentar exclusivamente a acurácia ou por reportar resultados sem detalhamento por classe emocional.

Figura 5 - Pontuação média dos estudos incluídos por critério de qualidade

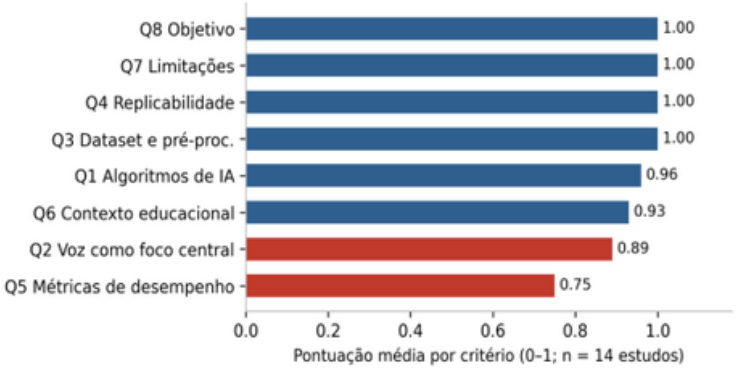

Fonte: elaborado pelo autor (2026)

O critério de centralidade da voz (Q2 = 0,89) merece observação à parte, por ser o único em que um estudo incluído recebeu avaliação negativa. Tokhtarov et al. (2025) e Hou et al. (2024) adotam arquiteturas multimodais nas quais o sinal acústico divide espaço com expressões faciais e conteúdo textual. A permanência desses trabalhos no portfólio é deliberada, pois ambos produzem achados diretamente relevantes sobre o papel comparativo da voz, entre os quais a constatação de que os sinais vocais superam as expressões faciais como indicadores de desengajamento.

Excluí-los eliminaria justamente a evidência que sustenta a discussão sobre multimodalidade apresentada nas seções seguintes. A título de observação complementar, independente do instrumento formal, cabe registrar uma regularidade evidenciada pela leitura integral dos artigos. Os estudos que validaram seus modelos em ambiente educacional real são precisamente os que reportam os resultados mais modestos: Tokhtarov et al. (2025) registram queda de 85% para 84% de acurácia ao migrar dos datasets de referência para 160 estudantes em aulas presenciais e online; Hou et al. (2024) obtêm correlação de 0,513 com a avaliação humana sobre 367 segmentos de aulas autênticas; e Alkhamali, Allinjawi e Ashari (2024) passam de 97,13% em bases consolidadas para 83% no dataset próprio de instrutores.

Em contraste, os dois trabalhos baseados em atributos manuais anunciam acurácias superiores a 93%, porém obtidas exclusivamente sobre gravações controladas e com número reduzido de classes emocionais, sem validação em ambiente real (Tanko et al., 2022; Tanko et al., 2023). Trata-se de constatação factual sobre as condições de avaliação, e não de julgamento de qualidade: essa diferença não é capturada pelo instrumento aplicado, que não contempla critério de validade ecológica.

4.3. SER Para avaliação da prática docente em sala de aula presencial

Os estudos agrupados nesta categoria concentram-se no reconhecimento de emoções na fala do professor durante aulas presenciais, abrangendo tanto a educação básica quanto o ensino superior. Cheng, Lin e Wang (2025) analisaram vídeos de salas de aula do ensino fundamental e médio, enquanto He et al. (2024) e Rosita e Saputra (2025) direcionaram suas investigações para o contexto universitário. Em todos os casos, o ambiente de aplicação foi a sala de aula física tradicional, o que impõe desafios acústicos como ruído ambiente e variações na qualidade dos microfones.

Os principais ganhos reportados vinculam-se diretamente ao fornecimento de feedback para o professor. Cheng, Lin e Wang (2025) constataram que as emoções docentes se alteram conforme o nível escolar, com emoções positivas diminuindo ao longo dos anos. Zhao, Zhang e Chu (2024) demonstraram que a fusão de áudio e texto gerou um ganho de acurácia de até 21,4% em relação a abordagens unimodais. Rosita e Saputra (2025) propuseram uma alternativa objetiva aos questionários tradicionais

de avaliação docente, enquanto Hou et al. (2024) atingiram uma correlação de 0,513 com a avaliação humana, igualando a consistência interavaliadores.

Diversos desafios foram identificados nesta categoria. A qualidade dos dados de áudio em ambientes reais foi um obstáculo comum, assim como o tamanho reduzido de algumas amostras, que gerou risco de overfitting em He et al. (2024). Zhao, Zhang e Chu (2024) alertaram para o custo computacional elevado do processamento acústico e para o risco de o monitoramento constante contribuir para o esgotamento profissional docente. Questões de privacidade também foram mencionadas, uma vez que gravações de voz em sala de aula envolvem dados sensíveis. Sob uma ótica teórica, a dificuldade técnica relatada em discriminar sentimentos acústicos semelhantes também corrobora a complexidade apontada pelo Modelo Circumplexo do Afeto (Russel, 1980).

Diferenciar emoções que habitam o mesmo quadrante de alta ativação (como o entusiasmo motivacional e a tensão/estresse docente) exige uma leitura extremamente refinada do eixo de valência (prazer/desprazer), o que ainda desafia a precisão dos modelos atuais em ambientes ruidosos. As sugestões para pesquisas futuras apontam para a integração de múltiplas modalidades, como expressões faciais e linguagem corporal (Cheng; Lin & Wang, 2025).

A incorporação de mecanismos de atenção e de características acústicas mais refinadas também é recomendada (Rosita & Saputra, 2025). Além disso, destaca-se a necessidade de expandir os datasets para contextos culturais diversos e de utilizar sistemas automáticos de reconhecimento de fala e grandes modelos de linguagem para processamento multimodal em tempo real (Hou et al., 2024).

4.4. SER para detecção de engajamento e estados afetivos do aluno

Os estudos aqui agrupados exploram como as emoções discentes afetam e refletem o processo de aprendizagem em múltiplos níveis educacionais, abrangendo desde a Educação Básica e o Ensino Superior até ambientes de Educação de Jovens e Adultos (EJA) e Sistemas de Tutoria Inteligente (Hou et al., 2024; Suen & Su, 2025; Chen & Cai, 2025).

A aplicação dessas tecnologias perpassa salas de aula presenciais tradicionais, plataformas de Ensino a Distância (EAD) e modelos híbridos, exigindo arquiteturas flexíveis que consigam rastrear a resposta emocional do aluno tanto em interações colaborativas em grupo quanto no estudo individual assíncrono (Dehbozorgi & Kunuku, 2023; Tokhtarov et al., 2025).

Os principais ganhos documentados revelam que o SER atua como um poderoso termômetro cognitivo, gerando feedback objetivo para a personalização do ensino e intervenção docente. No Ensino Superior, por exemplo, a integração de reconhecimento de emoções com modelagem de tópicos permitiu aos professores um

“raio-x” do clima de equipes, indicando que discussões focadas na matéria aliadas a emoções de suporte associam-se a notas mais altas (Dehbozorgi & Kunuku, 2023).

A detecção de frustração também obteve avanços: abordagens multimodais indicaram que os sinais vocais são indicadores de desengajamento mais confiáveis do que as expressões faciais, frequentemente mascaradas socialmente pelos estudantes, operando como um alerta precoce e escalável (Tokhtarov et al., 2025). Progressos semelhantes foram registrados na detecção de estados não básicos, como a “inquietação”, onde a união de dados emocionais (fala) e cognitivos (taxa de acerto e tempo) melhorou drasticamente a precisão da IA (Zhu; Wang; Huang, 2024).

Ademais, estudos cruzados com a análise docente confirmaram a relação de mão dupla no aprendizado, indicando que o estímulo vocal do professor afeta direta e imediatamente o engajamento do aluno (Suen & Su, 2025). Apesar dos resultados promissores, a captura precisa das emoções discentes enfrenta desafios metodológicos e técnicos substanciais. A principal barreira reportada nos artigos é a validade ecológica: a maior parte do treinamento de IA ainda se apoia em datasets construídos com falas encenadas e rotulagens binárias, carecendo de validação em ambientes naturais onde o aluno se expressa de maneira espontânea (Tokhtarov et al., 2025; Chen; Cai, 2025).

Tecnologias de transcrição tiveram grande dificuldade em capturar indicadores emocionais não verbais puros, como as risadas (Dehbozorgi & Kunuku, 2023), enquanto os classificadores encontram obstáculos ao lidar com estados afetivos complexos e sobrepostos, frequentemente limitando a análise apenas a categorias restritas, como focar exclusivamente na frustração e ignorar o tédio ou a confusão (Tokhtarov et al., 2025). Essa limitação técnica ilustra com perfeição o desafio previsto pelo Modelo Circumplexo de Russell (1980) em mapear computacionalmente estados que compartilham parâmetros próximos: frustração e confusão, por exemplo, habitam espectros vizinhos de alto desprazer e níveis variados de ativação, exigindo que a IA seja capaz de navegar pelas sutilezas do espaço bidimensional do afeto em vez de tentar enquadrá-las em categorias rígidas independentes.

O tamanho reduzido e desbalanceado de algumas amostras, somado ao alto custo computacional que ainda impede análises robustas em tempo real na maioria das arquiteturas, também foram citados como desafios críticos (Dehbozorgi & Kunuku, 2023; Chen & Cai, 2025). Para superar tais limitações, as sugestões de trabalhos futuros apontam para o desenvolvimento de soluções mais holísticas, temporalmente ágeis e ecologicamente válidas. Recomenda-se fortemente a diversificação cultural e a expansão quantitativa dos datasets, priorizando gravações de diálogos puramente não roteirizados (Chen & Cai, 2025).

A literatura também destaca a necessidade de abandonar as métricas subjetivas, como questionários de autorrelato, em favor de medições contínuas via IA (Suen & Su,

2025), além da urgência de desenvolver abordagens multiclasse que consigam mapear as sutis transições emocionais de um aluno durante uma tarefa difícil (Tokhtarov et al., 2025). Por fim, os pesquisadores sugerem incorporar dados contextuais de comportamento, como os logs de progresso na plataforma, aos modelos acústicos, com o objetivo final de otimizar essas arquiteturas para operarem perfeitamente em tempo real, permitindo aos educadores intervir no momento exato em que o aluno entra em risco de evasão ou sobrecarga cognitiva (Dehbozorgi & Kunuku, 2023; Zhu; Wang & Huang, 2024; Tokhtarov et al., 2025).

4.5. SER em ambientes de educação a distância (EAD)

O cenário predominante de aplicação abrange o Ensino Superior e a Pós-Graduação, englobando também a Educação de Jovens e Adultos (EJA) e cursos livres online (como os MOOCs) (Suen & Su, 2025). A transição do ambiente físico para o virtual, seja por meio de aulas síncronas, exames orais remotos ou videoaulas assíncronas, exige que a arquitetura dos algoritmos seja adaptada para a realidade digital.

Para lidar com fluxos de áudio online, os estudos têm explorado tanto o desenvolvimento de redes rasas (lightweight) baseadas em engenharia matemática tradicional (Tanko et al., 2022; Tanko et al., 2023), quanto agrupamentos de algoritmos (ensembles) robustos fundamentados na união de Transformers e Redes Neurais Convolucionais (Alkhamali; Allinjawi & Ashari, 2024).

Os principais ganhos relatados evidenciam o SER como uma ferramenta estratégica para gerar feedback docente, avaliar a performance estudantil e personalizar plataformas digitais. Em avaliações online síncronas, o uso de algoritmos de diarização (separação de locutores) permitiu provar estatisticamente que a fluidez e o tempo de fala do estudante em exames orais remotos correlacionam-se diretamente com sua nota final, viabilizando métricas automáticas de desempenho e validando a integridade avaliativa mesmo sob o estresse do formato remoto (Beccaro et al., 2024).

No contexto assíncrono, a análise empírica confirmou que a expressividade vocal do professor nas gravações impacta o engajamento afetivo de forma mais contundente que o próprio conteúdo verbal, fornecendo um manual de diretrizes práticas para criadores de cursos EAD (Suen & Su, 2025). Paralelamente, houve ganhos significativos em eficiência computacional: técnicas de seleção inteligente de subbandas acústicas e padrões matemáticos inovadores (como o *Shoelace Pattern*) conseguiram reduzir drasticamente a redundância de dados de voz, atingindo acurácias superiores a 93% com algoritmos leves, sugerindo capacidade de generalização em múltiplos idiomas (Tanki et al., 2022; Tanko et al., 2023).

Contudo, a aplicação das ferramentas de SER em ecossistemas reais de EAD (in-the-wild) esbarra em desafios técnicos inerentes às plataformas de comunicação remota. Ferramentas de videoconferência frequentemente sofrem com falas sobrepostas (overlapping speech), e as dinâmicas de exames orais apresentam longas pausas de planejamento por parte do aluno, o que confunde os Detectores de Atividade de Voz (VAD) e distorce o cálculo das métricas de tempo (Beccaro et al., 2024).

Além disso, pesquisadores reportaram uma queda substancial de desempenho quando os modelos, inicialmente treinados em datasets de benchmark puramente laboratoriais ou com falas lidas, foram testados em cenários reais complexos com áudios de durações variáveis e dados desbalanceados (Tanko et al., 2023; Alkhamali; Allinjawi & Ashari, 2024). A dependência de recursos estritamente unimodais (ignorando pistas visuais do aluno na webcam) e o foco em emoções básicas restritas também limitam a capacidade do sistema de mapear a real complexidade do aprendizado online (Alkhamali; Allinjawi & Ashari, 2024).

Essa abordagem baseada em rótulos fechados omite a premissa de Russell (1980) de que as emoções não são caixas independentes, mas pontos num espaço fluido. Para que as plataformas EAD alcancem a verdadeira "tutoria afetiva", as IAs precisarão evoluir da classificação de emoções unipolares para a medição contínua dos eixos de valência e excitação do aluno em tempo real.

Para superar essas barreiras, as sugestões de trabalhos futuros apontam para a integração orgânica dessas arquiteturas na infraestrutura em nuvem (Cloud) das plataformas de EAD, garantindo escalabilidade comercial e alta disponibilidade (ALKHAMALI; ALLINJAWI; ASHARI, 2024). Recomenda-se a condução de testes empíricos extensos utilizando gravações espontâneas nativas de sistemas de ensino remoto, abandonando as bases de dados teatrais (Tanko et al., 2022; Alkhamali; Allinjawi & Ashari, 2024).

Tecnologicamente, há uma demanda por incorporar técnicas de Aprendizado Federado (Federated Learning), permitindo o treinamento colaborativo de IA entre múltiplas instituições de ensino sem violar a privacidade e o compartilhamento de áudios sensíveis dos alunos (Alkhamali; Allinjawi & Ashari, 2024). A criação de softwares open-source acessíveis aos professores (Beccaro et al., 2024), somada à evolução de modelos capazes de adaptar dinamicamente o nível de dificuldade da plataforma online (Zhu; Wang; Huang, 2024) e atribuir notas automáticas baseadas em IA (Beccaro et al., 2024), constitui o horizonte prático e inovador desta categoria.

5. Considerações finais

No contexto da integração da Inteligência Artificial na educação, este artigo buscou mapear o estado da arte do uso do Reconhecimento de Emoções na Fala (SER) para

compreender como os pesquisadores vêm aplicando essa tecnologia nos processos de ensino e aprendizagem. Além disso, buscou-se identificar as principais arquiteturas tecnológicas empregadas, os benefícios alcançados e as barreiras que ainda limitam a sua utilização prática.

Assim, para atingir o objetivo deste trabalho, tomou-se base na revisão sistemática da literatura (guiada pelo método SSF), resultando no fornecimento de um subsídio informacional robusto para as partes interessadas em desenvolver ou aplicar a computação afetiva vocal no âmbito educacional. O Quadro 6 sintetiza as respostas às questões norteadoras que conduziram esta pesquisa.

Quadro 6 - Principais descobertas sobre as questões de pesquisa

(a) Qual é o panorama atual das publicações sobre o uso de IA para reconhecimento de emoção na fala no contexto educacional?	Publicações recentes com leve crescimento (destaque para 2024); Forte protagonismo de pesquisas de origem asiática (China); Foco metodológico majoritariamente centralizado na avaliação da emoção do professor, havendo poucos estudos centrados exclusivamente no aluno.
(b) Quais são as principais arquiteturas de IA, ferramentas e sua eficácia reportada?	Predominância de modelos de aprendizado profundo (Deep Learning), com destaque para redes CNN, LSTM e Transformers; Notou-se alta eficácia (acurácia superior a 90%) em ambientes laboratoriais controlados, mas com expressiva queda de desempenho em cenários reais (in-thewild).
(c) Como as aplicações variam de acordo com a área de atuação ou nível de ensino?	Forte concentração no Ensino Superior e em plataformas de Educação a Distância (EAD); Também há aplicações consistentes no Ensino Básico para a avaliação da prática docente em salas de aula presenciais tradicionais.
(d) Quais são os principais achados e benefícios relatados pelo uso dessas tecnologias?	Geração de feedback objetivo e livre de viés de autorrelato para educadores; Comprovação empírica de que a expressividade vocal impacta o engajamento afetivo; Potencial da voz como preditor autônomo do desempenho estudantil e de estados emocionais diversos como frustração e inquietação.
(e) Quais são os principais desafios e limitações identificados na implementação?	Baixa validade ecológica dos datasets atuais (que usam falas encenadas em vez de espontâneas); Dificuldade técnica com ruídos de sala e falas sobrepostas (overlapping speech); Elevado custo computacional para análise em tempo real; Preocupações éticas relacionadas à vigilância e privacidade biométrica.

continua

continua

(f) Qual é a qualidade metodológica dos estudos que sustentam esses achados?	Escore médio de 7,54 em 8 entre os 14 estudos incluídos, com corte em 7,0; Critério mais frágil: reporte de métricas de desempenho (0,75), com metade do portfólio apresentando apenas a acurácia; Cinco estudos foram excluídos por escore inferior ao corte, com média de 5,6.

Fonte: elaborado pelo autor (2026)

Conforme consolidado no Quadro 6, identificou-se nos 14 artigos resultantes que as principais práticas de uso do SER na educação estão atreladas aos cenários de Ensino Superior e EAD, ramificando-se em três temáticas primárias: a avaliação da prática docente em ambientes presenciais, a detecção contínua do engajamento e dos estados afetivos discentes, e a otimização de ambientes de ensino virtual assíncronos e síncronos.

Os limitadores percebidos na leitura técnica apontam majoritariamente para os desafios acústicos. Neste sentido, sobressai a dificuldade de os modelos de IA manterem a acurácia no "mundo real", lidando com falas sobrepostas, ruídos de fundo e a complexidade de categorizar emoções de alta excitação, mas com valências opostas (como o entusiasmo e a tensão). Ademais, a escassez de bancos de dados (datasets) ecologicamente válidos, construídos com falas espontâneas naturais de alunos e professores, em vez de falas encenadas por atores, persiste como um gargalo metodológico severo para o treinamento das arquiteturas.

Um dos principais catalisadores para a utilização do SER na educação é a sua capacidade de fornecer avaliações contínuas e não-invasivas, superando a dependência de questionários clássicos de autorrelato. Os estudos avaliados apontam para um aumento substancial na capacidade de prever o desempenho e o foco cognitivo do aluno por meio da voz, sustentando a premissa de que a expressividade acústica é um alicerce relevante da comunicação e do engajamento em sala.

Uma tendência que atravessa o portfólio, ainda que de forma incipiente, diz respeito à incorporação de grandes modelos de linguagem ao reconhecimento de emoções na fala. Dois trabalhos já os empregam: Hou et al. (2024) utilizam o GPT-4 em regime de inferência sem ajuste prévio (zero-shot) sobre transcrições de aulas para pontuar dimensões socioemocionais da prática docente, demonstrando desempenho superior ao da versão anterior do mesmo modelo; e Dehbozorgi e Kunuku (2023) recorrem ao ChatGPT para extrair emoções e modelar tópicos a partir da fala transcrita.

Em ambos, contudo, o modelo opera sobre texto previamente transcrito, e não diretamente sobre o sinal acústico. Hou et al. (2024) constituem, ainda, o estudo que alcançou o escore máximo no instrumento de qualidade, o que confere peso adicional ao seu resultado.

Os próprios autores indicam o caminho seguinte: substituir a transcrição manual por reconhecimento automático de fala e integrar o processamento multimodal em tempo real, de modo que o modelo opere sobre o sinal acústico e o conteúdo verbal simultaneamente, e não sobre texto previamente preparado (Hou et al., 2024).

Alkhamali, Allinjawi e Ashari (2024) apontam na mesma direção ao recomendar a exploração de arquiteturas de granularidade mais fina capazes de operar na infraestrutura das plataformas de ensino. A convergência dessas duas recomendações sugere que a barreira atual do SER educacional é menos a capacidade de classificação e mais a integração dos sinais em fluxo contínuo.

Cabe registrar que essa perspectiva permanece, no portfólio analisado, mais uma projeção dos autores do que um resultado consolidado: nenhum dos 14 estudos avalia empiricamente um modelo multimodal de linguagem operando diretamente sobre áudio em contexto educacional. Trata-se, portanto, de uma lacuna de pesquisa identificada, e não de uma tecnologia já validada para a sala de aula.

Investigar se a competência desses modelos em tarefas textuais se transfere para a leitura do afeto vocal espontâneo, e a que custo computacional, constitui uma agenda promissora e ainda inexplorada nesta interseção. Ainda respondendo aos questionamentos da pesquisa, identificou-se uma lacuna empírica notável: a área ainda se volta, majoritariamente, para monitorar a didática do professor. Embora essencial, isso deixa o rastreio do estado afetivo direto do aluno como uma temática secundária na maior parte do portfólio analisado.

Como limitações desta pesquisa, destaca-se que a condução do estudo foi realizada por um único pesquisador, o que pode introduzir vieses (bias) subjetivos durante as etapas de triagem e análise qualitativa dos dados. Além disso, a restrição de acesso à versão integral de determinados artigos impossibilitou a inclusão de trabalhos potencialmente relevantes no portfólio. Esses fatores, aliados à seleção estrita das palavras-chave, à escolha das bases de dados e ao recorte temporal, influenciam o volume e a composição dos resultados obtidos. Logo, novas revisões sistemáticas conduzidas de forma colaborativa por múltiplos avaliadores poderão mitigar tais vieses e agregar novas perspectivas.

Especificamente, a pontuação do instrumento de qualidade metodológica foi atribuída por um único avaliador, sem cálculo de concordância entre revisores, de modo que os escores devem ser lidos como um julgamento fundamentado e auditável, cuja evidência textual de cada atribuição foi registrada, porém não como uma medida independentemente replicada. A etapa de verificação de integridade referencial, por sua vez, foi conduzida de forma redundante, com a totalidade dos estudos examinada tanto pelos modelos generativos de linguagem quanto pelo pesquisador, o que reforça a confiabilidade dessa fase da seleção.

Considera-se que trabalhos futuros devem envolver uma análise métrica

aprofundada das ferramentas e algoritmos de IA disponíveis para o SER, com o objetivo empírico de identificar as soluções que entregam a maior acurácia, confiabilidade técnica e o menor custo computacional e de implementação. Somado a isso, pesquisas que comparem as vantagens e desvantagens práticas dessas arquiteturas, e orientem a criação de datasets com falas ecologicamente válidas, serão fundamentais para embasar pesquisadores e educadores interessados em desenvolver e aplicar tecnologias de tutoria afetiva na realidade educacional.

Referências

ALKHAMALI, E. A.; ALLINJAWI, A.; ASHARI, R. B. Combining transformer, convolutional neural network, and long short-term memory architectures: a novel ensemble learning technique that leverages multi-acoustic features for speech emotion recognition in distance education classrooms. **Applied Sciences**, [S. l.], v. 14, n. 12, p. 5050, 2024. DOI: 10.3390/app14125050. Disponível em: https://www.mdpi.com/2076-3417/14/12/5050. Acesso em: 26 maio 2026.

ANCILIN, J.; MILTON, A. Improved speech emotion recognition with Mel frequency magnitude coefficient. **Applied Acoustics**, [S. l.], v. 179, p. 108046, 2021. DOI: 10.1016/j.apacoust.2021.108046. Disponível em: https://www.sciencedirect.com/science/article/pii/S0003682X21001390. Acesso em: 26 maio 2026.

BAHREINI, K.; NADOLSKI, R.; WESTERA, W. Towards real-time speech emotion recognition for affective e-learning. **Education and Information Technologies**, [S. l.], v. 21, p. 1367-1386, 2016. DOI: 10.1007/s10639-015-9388-2. Disponível em: https://link.springer.com/article/10.1007/s10639-015-9388-2. Acesso em: 26 maio 2026.

BECCARO, Wesley et al. Analysis of oral exams with speaker diarization and speech emotion recognition: a case study. IEEE Transactions on Education, [S. l.], v. 67, n. 1, p. 74-86, 2024. DOI: 10.1109/TE.2023.3321155. Disponível em: https://ieeexplore.ieee.org/document/10287917. Acesso em: 26 maio 2026.

Chen, C. & Cai, Y. Cross-cultural speech emotion recognition for L2 pronunciation training. **IEEE Access**, [S. l.], v. 13, p. 216394-216407, 2025. DOI: 10.1109/ACCESS.2025.3632973. Disponível em: https://ieeexplore.ieee.org/document/11249683. Acesso em: 26 maio 2026.

CHENG, Yu; LIN, Yu; WANG, Wei. A study on teachers' classroom speech emotion expression based on speech emotion recognition. In: INTERNATIONAL CONFERENCE ON COMPUTER SCIENCE AND TECHNOLOGIES IN EDUCATION (CSTE), 7., 2025, Wuhan. Proceedings of the 2025 7th International Conference on Computer Science and Technologies in Education (CSTE). [S. l.]: IEEE, 2025. p. 454-457. DOI: 10.1109/CSTE64638.2025.11092022. Disponível em: https://ieeexplore.ieee.org/document/11092022. Acesso em: 26 maio 2026.

DEHBOZORGI, N.; KUNUKU, M. T. **Affective computing**: a topic-based SER approach on collaborative discussions in academic setting. In: IEEE FRONTIERS IN EDUCATION CONFERENCE (FIE), 2023, College Station. Proceedings of the 2023 IEEE Frontiers in Education Conference (FIE). [S. l.]: IEEE, 2023. p. 1-7. DOI: 10.1109/FIE58773.2023.10342963. Disponível em: https://ieeexplore.ieee.org/document/10342963. Acesso em: 26 maio 2026.

DEVLIN, J. et al. **BERT:** pre-training of deep bidirectional transformers for language understanding. In: CONFERENCE OF THE NORTH AMERICAN CHAPTER OF THE ASSOCIATION FOR COMPUTATIONAL LINGUISTICS: HUMAN LANGUAGE TECHNOLOGIES, 2019, Minneapolis. Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers). Minneapolis: Association for Computational Linguistics, 2019. p. 4171-4186. DOI: 10.18653/v1/N19-1423. Disponível em: https://aclanthology.org/N19-1423/. Acesso em: 26 maio 2026.

DYBÅ, Tore; DINGSØYR, Torgeir. Empirical studies of agile software development: a systematic review. Information and Software Technology, [S. l.], v. 50, n. 9-10, p. 833-859, 2008. DOI: 10.1016/j.infsof.2008.01.006. Disponível em: https://www.sciencedirect.com/science/article/pii/S0950584908000256. Acesso em: 19 jul. 2026.

FERENHOF, H. A.; FERNANDES, R. F. Desmistificando a revisão de literatura como base para redação científica: método SSF. Revista ACB, Florianópolis, v. 21, n. 3, p. 550–563, 2016. Disponível em: https://revista.acbsc.org.br/racb/article/view/1194. Acesso em: 26 maio 2026

HE, Yimin et al. Research on teacher classroom teaching speech emotion recognition based on LSTM. In: INTERNATIONAL CONFERENCE ON ASIAN LANGUAGE PROCESSING (IALP), 2024, Hohhot. Proceedings of the 2024 International Conference on Asian Language Processing (IALP). [S. l.]: IEEE, 2024. p. 326- 331. DOI: 10.1109/IALP63756.2024.10661152. Disponível em: https://ieeexplore.ieee.org/document/10661152. Acesso em: 26 maio 2026.

HOU, Ruikun et al. Automated assessment of encouragement and warmth in classrooms leveraging multimodal emotional features and ChatGPT. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE IN EDUCATION (AIED), 25., 2024, [S. l.]. Artificial Intelligence in Education. [S. l.]: Springer Nature Switzerland, 2024. p. 60-74. DOI: 10.1007/978-3-031-64302-6_5. Disponível em: https://link.springer.com/chapter/10.1007/978-3-031-64302-6_5. Acesso em: 26 maio 2026.

IMANI, Maryam; MONTAZER, Gholam Ali. A survey of emotion recognition methods with emphasis on E-Learning environments. Journal of Network and Computer Applications, [S. l.], v. 147, p. 102423, 2019. DOI: 10.1016/j.jnca.2019.102423. Disponível em: https://www.sciencedirect.com/science/article/pii/S1084804519302759. Acesso em: 24 maio 2026.

IMMORDINO-YANG, Mary Helen; DAMASIO, Antonio. We feel, therefore we learn: the relevance of affective and social neuroscience to education. Mind, Brain, and Education, [S. l.], v. 1, n. 1, p. 3-10, 2007. DOI: 10.1111/j.1751- 228X.2007.00004.x. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1111/j.1751-228X.2007.00004.x. Acesso em: 24 maio 2026.

ISSA, Dias; DEMIRCI, M. Fatih; YAZICI, Adnan. Speech emotion recognition with deep convolutional neural networks. Biomedical Signal Processing and Control, [S. l.], v. 59, p. 101894, 2020. DOI: 10.1016/j.bspc.2020.101894. Disponível em: https://www.sciencedirect.com/science/article/pii/S1746809420300501. Acesso em: 26 maio 2026.

KASNECI, Enkelejda et al. ChatGPT for good? On opportunities and challenges of large language models for education. Learning and Individual Differences, [S. l.], v. 103, p. 102274, 2023. DOI: 10.1016/j.lindif.2023.102274. Disponível em: https://www.sciencedirect.com/science/article/pii/S1041608023000195. Acesso em: 24 maio 2026.

KHARE, Smith K. et al. Emotion recognition and artificial intelligence: a systematic review (2014–2023) and research recommendations. Information Fusion, [S. l.], v. 102, p. 102019, 2024. DOI: 10.1016/j.inffus.2023.102019. Disponível em: https://www.sciencedirect.com/science/article/pii/S1566253523003354. Acesso em: 24 maio 2026.

KITCHENHAM, Barbara; CHARTERS, Stuart. Guidelines for performing systematic literature reviews in software engineering. Version 2.3. Keele; Durham: Keele University and University of Durham, 2007. (EBSE Technical Report, EBSE-2007- 001). Disponível em: https://www.elsevier.com/__data/promis_misc/525444systematicreviewsguide.pdf. Acesso em: 19 jul. 2026.

KLOCK, Ana Carolina Tomé. Mapeamentos e Revisões Sistemáticos da Literatura: um Guia Teórico e Prático. Cadernos de Informática, [S. l.], v. 10, n. 1, p. 01–09, 2018. Disponível em: https://seer.ufrgs.br/index.php/cadernosdeinformatica/article/view/v10n1201801-09. Acesso em: 26 maio 2026.

MATTIOLI, Martina; CABITZA, Federico. Not in my face: challenges and ethical considerations in automatic face emotion recognition technology. Machine Learning and Knowledge Extraction, [S. l.], v. 6, n. 4, p. 2201-2231, 2024. DOI: 10.3390/make6040109. Disponível em: https://www.mdpi.com/2504-4990/6/4/109. Acesso em: 26 maio 2026.

PAGE, Matthew J. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. BMJ, [S. l.], v. 372, n. 71, 2021. DOI: 10.1136/bmj.n71. Disponível em: https://www.bmj.com/content/372/bmj.n71. Acesso em: 19 jul. 2026.

ROSITA, Yesy Diah; SAPUTRA, Wahyu Andi. Classifier model for lecturer evaluation by students using speech emotion recognition and deep learning approaches. IAES International Journal of Artificial Intelligence, [S. l.], v. 14, n. 6, p. 5157-5171, 2025. DOI: 10.11591/ijai.v14.i6.pp5157-5171. Disponível em: https://ijai.iaescore.com/index.php/IJAI/article/view/26650. Acesso em: 26 maio 2026.

RUSSELL, James A. A circumplex model of affect. Journal of Personality and Social Psychology, [S. l.], v. 39, n. 6, p. 1161-1178, 1980. DOI: 10.1037/h0077714. Disponível em: https://www.researchgate.net/publication/235361517_A_circumplex_model_of_affe ct. Acesso em: 26 maio 2026.

SCHULLER, Dagmar M.; SCHULLER, Björn W. A review on five recent and nearfuture developments in computational processing of emotion in the human voice. Emotion Review, [S. l.], v. 13, n. 1, p. 44-50, 2021. DOI: 10.1177/1754073919898526. Disponível em: https://journals.sagepub.com/doi/10.1177/1754073919898526. Acesso em: 24 maio 2026.

SUEN, Hung-Yue; SU, Yu-Sheng. Teachers' vocal expressions and student engagement in asynchronous video learning. International Journal of Human–Computer Interaction, [S. l.], v. 41, n. 21, p. 13483-13494, 2025. DOI: 10.1080/10447318.2025.2474469. Disponível em: https://www.tandfonline.com/doi/full/10.1080/10447318.2025.2474469. Acesso em: 26 maio 2026.

TANKO, Dahiru et al. Shoelace pattern-based speech emotion recognition of the lecturers in distance education: ShoePat23. Applied Acoustics, [S. l.], v. 190, p. 108637, 2022. DOI: 10.1016/j.apacoust.2022.108637. Disponível em: https://www.sciencedirect.com/science/article/pii/S0003682X22000111. Acesso em: 26 maio 2026.

TANKO, Dahiru et al. Automated speech emotion polarization for a distance education system based on orbital local binary pattern and an appropriate sub-band selection technique. Multimedia Tools and Applications, [S. l.], v. 82, p. 40839-40856, 2023. DOI: 10.1007/s11042-023-14648-y. Disponível em: https://link.springer.com/article/10.1007/s11042-023-14648-y. Acesso em: 26 maio 2026.

TOKHTAROV, Akniyet et al. AI-based analysis of student frustration: speech and facial expression recognition. Electronic Journal of e-Learning, [S. l.], v. 23, n. 2, 2025. DOI: 10.34190/ejel.23.2.4043. Disponível em: https://academicpublishing.org/index.php/ejel/article/view/4043. Acesso em: 26 maio 2026.

WHITEHILL, Jacob et al. The faces of engagement: automatic recognition of student engagement from facial expressions. IEEE Transactions on Affective Computing, [S. l.], v. 5, n. 1, p. 86-98, 2014. DOI: 10.1109/TAFFC.2014.2316163. Disponível em: https://ieeexplore.ieee.org/document/6786307. Acesso em: 26 maio 2026.

ZHAO, Gang; ZHANG, Yinan; CHU, Jie. A multimodal teacher speech emotion recognition method in the smart classroom. Internet of Things, [S. l.], v. 25, p. 101069, 2024. DOI: 10.1016/j.iot.2024.101069. Disponível em: https://www.sciencedirect.com/science/article/pii/S2542660524000118. Acesso em: 26 maio 2026.

ZHU, Ming; WANG, Chunchieh; HUANG, Chengwei. Fidgety speech emotion recognition for learning process modeling. Electronics, [S. l.], v. 13, n. 1, p. 146, 2024. DOI: 10.3390/electronics13010146. Disponível em: https://www.mdpi.com/2079-9292/13/1/146. Acesso em: 26 maio 2026.

Sobre o autor(a)

Lucas Moraes Amancio

Mestrandp em Tecnologias da Informação e Comunicação pelo Programa de Pós-graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina (UFSC).

Graduação em Tecnologias da Informação e Comunicação pela Universidade Federal de Santa Catarina (UFSC - 2025).

Desenvolvedor Full Stack Pleno no SENAI/SC - Soluções Digitais.

Lattes: http://lattes.cnpq.br/7232477187942359

PARTE V

IA NA FORMAÇÃO E NA PRODUÇÃO DO CONHECIMENTO

CAPÍTULO 17

A importância da IA na formação dos educadores

Soraia dos Santos Mangili Vidal

1. Introdução

A mudança social tem sido muito rápida nos últimos anos, especialmente nas tecnologias digitais. Esses aspectos da cultura foram além das escolas e agora estão forçando os professores a reavaliar sua prática, como fazem o trabalho e como interagem com os alunos. As crianças e os jovens que chegam às escolas hoje estão cercados por tecnologia e informação, mídias sociais e diferentes tecnologias online; as escolas precisam seguir as regras e evoluir nessa direção.

Nesse contexto, a Inteligência Artificial tem se tornado mais prevalente em diversos aspectos da sociedade. Os professores precisam receber treinamentos e participar de formações continuadas para que possam fazer uso da IA de forma ética e, de alguma forma, evitar o distanciamento das crianças e jovens.

Quando a IA é aplicada pedagogicamente com intenção genuína, pode levar a um aprendizado mais prático que pode apoiar aulas mais dinâmicas, ensinar melhor e viver bem juntos, proporcionando mais oportunidades de aprendizado na sala de aula.

No contexto brasileiro, as mudanças foram ainda mais claras com a pandemia de COVID-19. Os professores tiveram que aprender algo novo (por exemplo, recursos tecnológicos para aulas remotas) e precisaram interagir com algo que lhes parecia muito distante. O que costumava acontecer lentamente tornou-se um aspecto intenso e problemático da vida escolar diária.

Segundo Brasão e Araújo (2022),

> A pandemia evidenciou a urgência de repensar o modelo educacional, uma vez que muitos educadores continuaram a utilizar métodos tradicionais de ensino, porém agora em plataformas digitais, sem o devido suporte das Tecnologias Digitais de Informação e Comunicação (TDICs).

Diante disso, é importante reconhecer que essa transição rápida não permitiu uma reflexão profunda sobre as implicações das tecnologias emergentes no processo educacional.

O artigo tratará da importância do professor se manter em constante formação e, sobretudo, na era da Inteligência Artificial (IA), ativando as competências que a atualidade vem exigindo e tornando esta ferramenta uma grande aliada na construção de uma excelência acadêmica desde a educação básica.

Assim, esta Revisão Sistemática da Literatura (RSL) tem como objetivo: analisar a importância dos estudos realizados junto aos professores pensando na utilização da Inteligência Artificial(IA) de forma fluida e responsável, numa perspectiva de apoio e aprofundamento das questões que por ora eram tratadas de forma superficial.

2. Referencial Teórico

Para responder aos questionamentos desta pesquisa, foram utilizadas as palavras-chave: IA, Formação dos Educadores e Competências.

2.1 Inteligência Artificial

O desenvolvimento da inteligência artificial (IA) está diretamente associado ao progresso da computação durante os anos 1950. No presente, vivenciamos um novo ciclo de grande otimismo em relação às potenciais vantagens que a IA pode trazer, embora essa empolgação seja acompanhada por uma variedade de receios.

A mídia frequentemente tende a apresentar definições e esclarecimentos que podem ser imprecisos sobre os aspectos centrais de uma tecnologia quando ela gera grande entusiasmo, fenômeno que certamente acontece com a IA atualmente. Em vez de tentar definir a IA, uma abordagem mais produtiva é caracterizar os propósitos do campo.

Conforme Rich e Knight (1991),

> Uma das propostas iniciais era que a meta da IA consistia em criar sistemas para executar tarefas que, naquele momento, pessoas executavam melhor que máquinas ou para as quais a computação convencional não oferecia uma solução algorítmica viável.

Portanto, um algoritmo pode solucionar problemas de naturezas muito diversas, como cálculos de engenharia na concepção de uma ponte, manipulação de dados para gerar uma folha de pagamento e organização de atividades ao definir um pacote de viagem. Adicionalmente, ele pode aprimorar a exposição de conteúdos em ambientes educacionais por professores e alunos, de todas as esferas.

2.2 Formação Continuada dos Professores

A capacitação docente constitui uma área extremamente produtiva para discussões e

propostas. Abordar a preparação de educadores significa tratar da edificação de um profissionalismo, de uma identidade específica da profissão que, conforme Nóvoa (2022), é o que atribui propósito à atividade de lecionar.

Nóvoa (1988) ressalta também que a formação de pessoas adultas envolve princípios fundamentais: o primeiro é o reconhecimento de que cada educador tem uma história de vida, experiência e conhecimento que precisam ser incluídos no processo de formação. O segundo é que o processo de formação é tão individual porque cada pessoa tem suas próprias necessidades, seu próprio caminho e interesses. O terceiro é que a qualificação ocorre pela produção de conhecimento. Assim, o educador é um agente de interpretação, reelaboração e geração de conhecimento no contexto do trabalho.

Nessa visão, a formação continuada deve ser vista como desenvolvimento profissional contínuo, não como eventos ocasionais ou ações desconexas. É um processo de mudança, baseado na rotina escolar diária, que nos ajuda a rever práticas pedagógicas e a atualizar conhecimentos. O desenvolvimento profissional está conectado com a mudança social, científica e cultural e é um processo que está em constante construção, não um fim. É necessário que a formação continuada seja:

- **Contextualizada:** relacionada à realidade da escola e às necessidades dos educadores.
- **Coerente:** articulada com os propósitos da escola e com as políticas educacionais.
- **Participativa:** Que possibilite aos educadores participarem ativamente da construção do processo formativo.
- **Significativa:** Que promova a reflexão crítica sobre a prática pedagógica e a construção de novos conhecimentos e habilidades, superando a visão fragmentada e instrumentalizada da formação continuada, como apontado por Gatti (2009).
- **Consciente:** O educador responsabiliza-se por sua aprendizagem, agindo como autorregulador no seu processo formativo.
- **Interdisciplinar:** Que possibilite uma compreensão globalizadora dos objetos de estudo e das realidades, estabelecendo nexos entre os conhecimentos.
- **Com um viés investigativo e problematizador:** É preciso considerar o questionamento das realidades nos âmbitos social, cultural, político, científico e natural, bem como a elaboração de trajetórias pessoais ou coletivas, com o objetivo de construir criticamente novos saberes, discursos, conhecimentos, competências, linguagens e tecnologias.
- **De natureza permanente:** A capacitação deve ser configurada como um processo ininterrupto e integrado ao cotidiano escolar, prevenindo-se assim as ações pontuais e desarticuladas. Isso requer acompanhamento sistemático e avaliação permanente das ações formativas, de modo a qualificar seus sentidos e impactos no cotidiano educativo.

Perrenoud (2008, p. 133) afirma que:a educação superior, por si só, não assegura a capacitação de professores competentes. De acordo com sua perspectiva, a construção de habilidades profissionais torna-se inviável ao se restringir a formação à simples transmissão de conhecimentos e à confiança em estágios de final de curso para realizar a ponte entre o aprendizado teórico e a sua aplicação, nesse sentido, o desenvolvimento das habilidades e competência dos professores exige muito mais que apenas a conclusão de um curso superior, há que se possa ter determinação e disposição para se colocar como aprendente e a formação precisa ser continua e continuada.

Após a graduação, que marca a entrada formal na carreira, a prática diária fornecerá, com o tempo, os conhecimentos práticos e específicos que constituem o fazer docente, denominados por Tardif e Lessard (2008) como saberes da experiência. Concorda-se, assim, com a perspectiva de Franco (2019) de que a formação continuada deve se dedicar às problemáticas e carências expressas pelos educadores em seu dia a dia na escola, em vez de simplesmente suprir deficiências. Um exemplo relevante disso é a necessidade de adaptação dos professores ao advento das IAs, bem como a sua integração curricular e pedagógica.

2.3 Competências

Débora Ribeiro em seu dicionário define competência como:

> Capacidade decorrente de profundo conhecimento que alguém tem sobre um assunto... Capacidade de fazer alguma coisa; aptidão. Dever ligado a um ofício, cargo, trabalho; atribuição, alçada... (RIBEIRO,2026)

A BNCC define 10 competências gerais que orientam a formação integral dos estudantes da Educação Básica, promovendo conhecimentos, habilidades, atitudes e valores essenciais para a vida pessoal, social e profissional. No contexto educacional, os professores normalmente são profissionais que se destacam por competências teóricas e socioemocionais.

Mas atualmente novas exigências vêm surgindo. Num tempo em que as ferramentas tecnológicas e a integração da inteligência artificial estão cada vez mais presentes, o profissional que sempre focou suas formações em aprofundamentos conceituais de áreas específicas precisa ampliar suas competências para além dos conteúdos óbvios de quem se dispõe a ser professor. Competências de ética, capacidade de senso crítico, adaptação e formação contínua. Inclusive, alguns autores sugerem competência para utilizar o modelo TPACK, que interseciona os saberes tecnológicos, pedagógicos e de conteúdos.

Desta forma, o professor que opta por usar IA em sua prática pedagógica precisa alinhar e ampliar seus conhecimentos a fim de utilizar os recursos tecnológicos para qualificar as aprendizagens e contribuir para que os estudantes obtenham uma formação qualificada.

3. Metodologia de pesquisa

Para elucidar e responder ao objetivo deste artigo, sobre a importância da IA na formação dos professores, foram utilizadas a Revisão Sistemática da Literatura e a análise bibliográfica.

Tabela 1 – Protocolo de Planejamento da Revisão Sistemática

Item	Descrição
Título	IA na formação de professores da Educação Básica
Objetivo	Identificar nas referências disponíveis registros que abordem a importância da IA na formação dos professores
Período analisado	2021 - 2026
Contexto	Educação Básica
Resultados esperados	Qualidade, eficiência e satisfação ética

Fonte: elaborado pela autora (2026)

O método PICOC, utilizado pela ferramenta Parsifal, auxilia o pesquisador no que de fato a pergunta de pesquisa deve especificar. O método compreende cinco critérios que foram definidos a seguir: População (artigos relacionados a professores da Educação Básica), Intervenção (Identificar estudos que tratam da importância da IA na formação docente), Comparação (Métodos tradicionais versus Inteligência Artificial), os Resultados (Qualidade, eficiência e satisfação ética) e o Contexto (Educação Básica, estudos publicados entre 2021e2026).

Tabela 2 – Estratégia PICOC

Elemento	Definição
Population (P)	Professores da Educação Básica
Intervention (I)	Identificar estudos que tratam da importância da IA na formação docente
Comparison (C)	Métodos tradicionais versus Inteligência Artificial
Outcome (O)	Qualidade, eficiência e satisfação ética
Context (C)	Educação Básica, estudos publicados entre 2021e2026

Fonte: elaborado pela autora (2026)

3.1 Questões de pesquisa e Objetivos

As questões de pesquisa e os objetivos estão baseados na relação entre o uso da IA e a formação dos professores, no processo de ensino-aprendizagem.

Tabela 3 – Questões de Pesquisa e Objetivos

Código	Questão de Pesquisa	Objetivo
RQ1	De que forma a IA pode auxiliar o professor em sua prática?	Identificar como ferramentas de Inteligência Artificial podem contribuir para a prática pedagógica e apoiar o desenvolvimento das atividades docentes.
RQ2	Como a IA pode auxiliar o professor a compreender o contexto atual da educação?	Analisar de que maneira a Inteligência Artificial pode apoiar os professores na compreensão das transformações educacionais contemporâneas e das demandas do contexto digital.
RQ3	Quanto a IA pode facilitar o trabalho dos professores em seu cotidiano?	Investigar os impactos da IA na otimização das tarefas diárias dos professores, considerando aspectos como tempo, produtividade e eficiência.
RQ4	Quais os desafios para formar professores que saibam utilizar a IA?	Identificar os principais desafios relacionados à formação docente para o uso ético, crítico e pedagógico da Inteligência Artificial.

Fonte: elaborado pela autora (2026)

Para esta pesquisa, foram realizadas buscas nas bases Scopus,IEEE Digital Library, ScienceDirect e Google Acadêmico. A string ("Formação de professores" **OR** "Teacher training" **OR** "Formación de profesores) **AND** ("Educação" **OR** "Education") **AND** ("Inteligência artificial" **OR** "Artificial intelligence" **OR** "Inteligencia artificial") **AND** ("Educação básica" **OR** "Basic education" **OR** "Educación básica").

Os critérios de seleção foram artigos publicados após 2021, em português, inglês e espanhol, de acesso aberto; assim, a busca abrangeu 76 artigos.

A abordagem evidenciou a necessidade de uma avaliação criteriosa dos estudos encontrados. Esse processo é essencial para garantir que apenas os artigos mais relevantes e de alta qualidade sejam selecionados, garantindo que as conclusões da revisão sejam fundamentadas em dados sólidos e alinhadas aos objetivos definidos pela pesquisa.

Após os resultados da busca automática, iniciou-se a etapa de seleção dos estudos. A ferramenta Parsifal faz a análise automática dos estudos considerando os seguintes critérios estabelecidos:

- Critérios de Inclusão:
  - Formação em IA para professores da Educação Básica;
  - IA como aliada da educação;
  - Importância da IA na qualidade acadêmica;
  - Artigos publicados entre 2021 e 2026.

Por conseguinte, realizou-se a leitura dos títulos, palavras-chave e resumos dos artigos, avaliando a qualidade dos estudos e a exclusão dos artigos de acordo com os critérios estabelecidos:

- Critérios de exclusão:
  - Estudos duplicados;
  - Literatura cinzenta;
  - Estudos secundários ou técnicos;
  - Idiomas diferentes de português, inglês e espanhol;
  - Estudos fora do escopo;
  - Estudos anteriores a 2021;
  - Formação específica em áreas isoladas;

Artigos que não tratam da Educação Básica. O percurso da pesquisa será apresentado no PRISMA abaixo:

Figura 1 - Fluxograma do processo de identificação, seleção e inclusão dos estudos

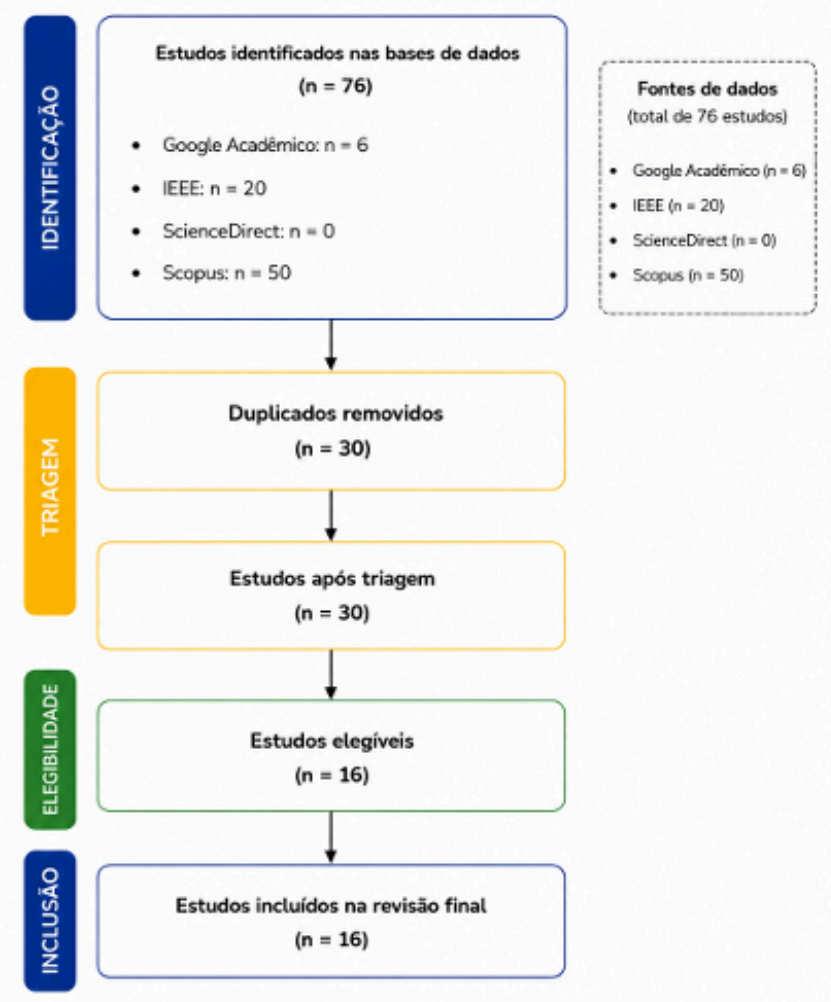

Fonte: adaptado doelaborado pelo autor adaptado de PRISMA 2020.

Para avaliar o conteúdo dos artigos selecionados, usou-se a tabela de Verificação de Avaliação de Qualidade, sugerida pelo Parsifal, conforme as questões elaboradas na fase de planejamento. Após planejamento e regência com apoio da ferramenta Parsifal, buscas e seleções, chegamos a 16 artigos selecionados.

O portfólio final, apresenta os artigos selecionados com respectivos autores e anos de publicação. Todos abordam o tema relacionado à importância da Inteligência Artificial na formação dos professores e à busca pela qualidade acadêmica.

Tabela 4 - Portfólio Final

Autores	Ano	Título	Tema
Porto, A. T.; Castro, R. P.; Silva, A. P. & Damasceno, E. F.	2026	Uma Proposta de Formação Docente em Inteligência Artificial: Perspectivas e Desafios na Educação Básica	Formação docente em IA e desafios educacionais

continua

continuação

Calimbo, A. L.; Ramos, R. F.; Magcuyao, J. P. H. & De Angel, R. M.	2025	*Empowering Educators: A Framework for*	Alfabetização em IA e competência digital docente
Zhang, N.	2025	*Exploring the Role of AI Tools in Pre-Service Early Childhood Teacher Training: Perceptions, Challenges, and Future Directions*	Uso de IA na formação inicial de professores
Tillman, D. A.; Cochran, C.; Soto, T. J.; Robertson, W. H.; An, S. A. & Tinajero, J. V.	2024	*Use of Artificial Intelligence to Improve Teacher Preparation*	IA aplicada à preparação docente
Zhou, Y.	2024	*The impact of the artificial intelligence (AI) Art Generator in pre-service art teacher training*	Transformação educacional mediada por IA
Orlanda-Venta yen, C. C.	2024	*Empowering Education Through Transformative Role of Artificial Intelligence (AI) in Teaching and Learning: Educators' Perspective and Research Trends*	Transformação educacional mediada por IA
Flores, G. T.	2025	*Adoption and Implementation of Artificial Intelligence in Education: Insights from Science Teachers*	Implementação da IA na prática docente
Feng, M.; Hong, S. & Wang, Z.	2025	*The Association Between Pre-service Preschool Teachers' AI Literacy and Learning Engagement in Educational Internship: The Mediating Role of AI Awareness*	Alfabetização em IA e desenvolvimento profissional

continua

continuação

Yang, Y. & Xia, X.	2025	*Examining the Association Between Teacher Education Students' AI Literacy and Digital Competence in Educational Internship*	Competência digital e alfabetização em IA
Lighter, T.; Elmore, B.; Smarr, S.; Wright, B.; Burge, L.; Mugo, M.; Lynch, E. & Austin, S. J.	2025	*Empowering Educators with Generative AI: Insights from Professional Development Workshops on Ethical and Practical Applications in the Classroom*	Formação continuada e uso ético da IA
Christou, P. A.	2024	*Implications of Artificial Intelligence (AI) in Education: A Critical Review, Evaluation, and Conceptualization*	Impactos e desafios da IA na educação
André, C. F.; Azevedo, A. B.; Andrade, F.	2023	Inclusão Digital e Inteligência Artificial na Educação: Avanços, Desafios e Oportunidades para Alunos e Professores da Educação Básica à Educação Superior	Inclusão digital e IA na educação
Santos, M. F. da C.	2024	Inteligência Artificial na Formação Docente: Desafios, Possibilidades e Capacitação para a Educação Básica	Capacitação docente em IA
Silva, W. M.; Mota, S. A.; Ramos, R. D.; Machado, E. S. F.	2026	A Inteligência Artificial como Estratégia Inovadora na Educação Básica: Desafios de um Futuro Digital para a Formação de Professores	IA como inovação e formação docente
Guimarães, M. P. da S. & Souza, D. C. D. B. N. de	2025	Proposta de Formação Continuada de Professores sobre a Utilização da Inteligência Artificial Generativa na Educação Básica	Formação continuada em IA generativa

continua

continuação

Fofonca, E.; Pasinato, N. M. B. & Florencio, R.	2025	Formação Continuada de Professores da Educação Básica, Currículo e Inteligência Artificial: Contrapontos para a Reflexão	Currículo, IA e formação docente

Fonte: elaborado pela autora (2026)

4.Resultados

A análise dos 16 artigos selecionados mostra que a introdução da Inteligência Artificial (IA) no contexto educacional ampliou a discussão sobre a formação de professores e as condições em que a IA pode ser utilizada para se tornar uma realidade na prática pedagógica. Embora esta pesquisa tenha partido da necessidade de IA na formação de professores da Educação Básica, a análise dos estudos sobre os temas indicou que essa discussão abrange todos os aspectos da educação: formação inicial e continuada, formas de aprender a ser digital, questões éticas, inclusão, políticas públicas e práticas pedagógicas e curriculares.

A formação de professores é um dos principais pontos de convergência entre os estudos, mesmo que de diferentes perspectivas. Porto et al. (2026) destacam a necessidade de ações de formação acessíveis e comunicação entre órgãos públicos e universidades; Calimbo et al. (2025) apontam a desconexão entre o conhecimento ético dos professores e a formação técnica em IA. Os resultados dos autores, em outras palavras, indicam que os professores podem estar cientes da prevalência dessas tecnologias e de sua importância, mas também se sentem inseguros quanto ao seu uso no dia a dia. Juntos, esses estudos indicam que o reconhecimento do potencial da IA tem sido mais rápido do que sua efetiva apropriação pedagógica pelos professores.

A lacuna de interesse e uso pedagógico na Educação Infantil é muito evidente. Professores em formação mostraram grande interesse em IA em Zhang (2025), mas ainda a utilizam para fins burocráticos e sua aplicação na prática pedagógica não é tão eficaz quanto poderia realmente ser. A IA também é vista como uma oportunidade complementar em oposição a uma alternativa às práticas estabelecidas, de acordo com o estudo. Este é um resultado marcante porque, em vez de educar o professor sobre uma ferramenta específica que pode ser usada, é importante ensiná-los quando, como e para que propósito pedagógico ela pode ser usada.

Existem também estudos que sugerem que, se os professores puderem usar a IA de forma eficaz, a formação deve ir além de uma perspectiva técnica. Tillman et al. (2024) apresentam o modelo TPACK (Conhecimento Tecnológico Pedagógico de

Conteúdo) como um modelo para descrever o que é considerado conhecimento tecnológico, pedagógico e de conteúdo na preparação de professores.

Silva et al. (2026) recomendam o ensino de conteúdos de IA e Processamento de Linguagem Natural (PLN) na formação de professores e residências pedagógicas para planejamento estratégico e ação, bem como princípios de agência humana, proteção de dados e equidade. Embora comecem com ideias diferentes, os estudos concordam que conhecer uma ferramenta não é suficiente para garantir seu uso pedagógico. A tecnologia na educação precisa estar conectada com os objetivos de aprendizagem, o currículo e as características dos diferentes contextos educacionais.

A relação entre letramento em IA e desenvolvimento profissional também é discutida na pesquisa conduzida por Feng et al. (2025) e Yang et al. (2025), mas de maneiras diferentes. Na pesquisa conduzida por Feng et al. (2025), investiga-se a relação entre o letramento em IA de futuros professores da Educação Infantil e a aprendizagem em estágios educacionais e o conhecimento sobre IA. Na pesquisa de Yang et al. (2025), discute-se a relação entre letramento em IA e competência digital de estudantes de formação de professores em estágios educacionais. Com base nesses estudos, podemos ver que o letramento em IA não é apenas conhecimento operacional de ferramentas, mas também diferentes aspectos da formação profissional, como conhecimento, atitude, engajamento e habilidades digitais.

O potencial de aplicação da IA varia com as áreas de conhecimento e o contexto educacional considerado. Zhou (2024) discute a aplicação de geradores de arte de IA na formação de professores de Arte e a possibilidade de geradores de arte de IA nesse campo, construindo e usando tecnologia para esse propósito. Ao estudar professores de Ciências, Flores (2025) foca no uso da IA na prática docente. Os resultados desses estudos também mostram que não há maneiras singulares de integrar a Inteligência Artificial na educação. Sua aplicação pode ser diferente de uma área para outra, com base nas áreas de conhecimento e na agenda pedagógica e no contexto em que professores e alunos estão inseridos.

Embora esses estudos reconheçam o potencial para inovação, preocupações éticas são sempre levantadas sobre a IA. Orlanda-Ventayen (2024) fala sobre a IA como uma ferramenta para ensino e aprendizagem, mas também sobre os desafios que vêm com o uso da IA. Christou (2024) também está preocupado com os efeitos da IA na educação, com sua dependência tecnológica, ética, pensamento crítico e efeitos a longo prazo. A aproximação dos resultados demonstra a tensão no cenário de pesquisa. A IA tem o potencial de ser transformadora, mas seu alcance na educação não é apenas uma inovação.

Essa preocupação também é expressa em Santos (2024) em relação à perda de habilidades cognitivas e dependência tecnológica. O estudo também nos leva a considerar o impacto potencial que o desenvolvimento tecnológico pode ter na

aprendizagem e no processamento do conhecimento. Essa perspectiva impede uma visão excessivamente otimista sobre a IA e uma interpretação que acredite que ela seja uma ameaça. O desafio que surge desses estudos é entender essas transformações e qual seria a abordagem correta para usá-las para manter o pensamento crítico, a autonomia e a participação ativa dos alunos na aprendizagem.

Nesse sentido, uma lacuna no conjunto de produções investigadas está relacionada à necessidade de expandir a pesquisa que monitore os efeitos do uso da IA em contextos concretos da Educação Básica. Enquanto os estudos discutem possibilidades, riscos e recomendações, mais pesquisas são necessárias para entender, ao longo do tempo, como essas tecnologias impactam a aprendizagem, o desenvolvimento do pensamento crítico e as práticas pedagógicas. Também é relevante examinar como os processos de formação de professores levam efetivamente a mudanças na prática diária dos professores.

A importância da educação continuada também é alta nesse cenário, dado que novas ferramentas de IA generativa estão sendo rapidamente adotadas na sociedade e na educação. Lighter et al. (2025) consideram essa questão em seus workshops de desenvolvimento profissional, que são sobre aplicações éticas e práticas para IA generativa na sala de aula, e Silva et al. (2025) propõem uma educação continuada para o uso dessas ferramentas na Educação Básica. Ambas as produções enfatizam a necessidade de os professores conhecerem as ferramentas e como elas funcionam na vida real. As semelhanças com esses estudos e outros trabalhos sugerem que a formação específica pode ser usada para uma primeira introdução às tecnologias, mas esta pode ser insuficiente dentro do contexto de rápidas mudanças na IA. A formação contínua deve ser entendida como um processo permanente que pode ser articulado para que o conhecimento tecnológico, pedagógico e ético possa ser estabelecido e as demandas do ambiente escolar hoje possam ser atendidas.

Outro tema discutido nesses estudos é a inclusão e o acesso à tecnologia. André et al. (2023) analisam a Inteligência Artificial na educação e seus potenciais e barreiras no contexto da inclusão, formação de professores e, ao mesmo tempo, a discussão sobre infraestrutura digital e formação. Isso está em linha com outros trabalhos dentro do corpus que focam na necessidade de políticas públicas e ações institucionais para ajudar os professores a usar e aplicar essas tecnologias.

De acordo com esses resultados, a responsabilidade pela incorporação da IA na Educação Básica não recai apenas sobre o professor. Se os educadores não têm acesso às suas ferramentas, infraestrutura e formação, é difícil pedir que inovem em seu caminho adiante. A IA também é politicamente carregada nesse sentido, em termos de quem usará as tecnologias e que tipo de oportunidades terão para usá-las. Sem essas condições, as tecnologias que veremos como possibilidades de inovação apenas contribuirão para aumentar as desigualdades que já existem na educação.

A transformação da tecnologia também está permeando o currículo. Fofonca et al. (2025) e sua abordagem de formação contínua, currículo e inteligência artificial apontam para o currículo web como uma forma de integrar uma gama de mídias e tecnologias no processo de educação e aprendizagem. Nesse sentido, a integração da tecnologia não é apenas adicionar novos recursos aos já existentes, mas aos sistemas e formas de ensino e aprendizagem que se abrem para a linguagem e potencial da cultura digital e das pessoas.

E, dessa forma, essa é a melhor maneira de entender a inovação educacional. A IA sozinha não muda uma prática pedagógica. Seu efeito depende da escolha do professor, da intenção pedagógica e de como tecnologia, currículo e objetivos de aprendizagem estão vinculados. Portanto, a inovação não é sobre a ferramenta utilizada, mas a capacidade de criar experiências de aprendizagem mais significativas, críticas e coerentes com as necessidades dos alunos.

Para a análise conjunta dos estudos, não há um impulso para substituir o professor pela Inteligência Artificial, mas os resultados apenas reforçam o papel do professor na mediação da aprendizagem. Quanto mais complexo o ambiente tecnológico, mais necessário parece ser o papel do professor em selecionar informações, definir experiências educacionais, promover o pensamento crítico e estabelecer padrões éticos para o uso das tecnologias.

Essa constatação também reafirma a forma como pensamos a formação de professores. Formar professores em IA não é apenas ensinar comandos, plataformas ou ferramentas. Todos os estudos examinados consideram a formação de conhecimentos tecnológicos, pedagógicos e curriculares, mas também habilidades críticas, sensibilidade ética, proteção de dados, inclusão e conhecimento das implicações sociais dessas tecnologias. Assim, a formação em IA precisa acompanhar as mudanças tecnológicas sem colocar a educação acima da inovação pela inovação.

Ao analisar o conjunto de pesquisas, ainda há um descompasso entre a velocidade com que as tecnologias de IA se desenvolvem e chegam à sociedade e o tempo para que escolas, professores e políticas educacionais construam respostas para sua integração. Enquanto alguns estudos oferecem oportunidades de aplicação e propostas de formação, outros revelam insegurança dos professores, limitações de uso, barreiras estruturais e preocupações éticas. Essa divergência não representa oposição aos estudos, mas reflete diferentes estágios de apropriação da IA e reforça a necessidade de que a pesquisa acadêmica, a formação de professores, as políticas públicas e a realidade escolar estejam mais próximas.

Os resultados desta revisão também exigem uma conexão estreita com a Base Nacional Comum Curricular (BNCC). Ao defender uma formação que ajude a desenvolver todos os alunos, a BNCC inclui habilidades em autonomia, pensamento crítico, responsabilidade, comunicação e envolvimento na cultura digital. Nesse

sentido, a discussão sobre IA na Educação Básica não pode se restringir ao aprendizado técnico de ferramentas e deve também abordar como usá-las de forma consciente e coerente com os propósitos educacionais.

Isso é particularmente verdadeiro para a Competência Geral 5 da BNCC (Tecnologia Digital de Informação e Comunicação), que trata da compreensão, aplicação e criação de tecnologias digitais de informação e comunicação de maneira crítica, significativa, reflexiva e ética. Esta revisão apoia essa perspectiva ao demonstrar a importância da formação crítica, intencionalidade pedagógica, consciência ética, inclusão e uso responsável das tecnologias. Ao mesmo tempo, as questões destacadas pelos estudos (como a insegurança dos professores, desigualdade de acesso e infraestrutura insuficiente e ainda aplicação limitada da IA em contextos específicos) demonstram que a implementação dessas diretrizes ainda é problemática no cotidiano das instituições educacionais.

Nesse aspecto, a questão em que devemos nos concentrar é que, se a Educação Básica deve formar estudantes na cultura digital para serem modelos de inovação e responsabilidade, ela também deve ajudar os professores a desenvolver e atualizar suas próprias habilidades. Não parece suficiente que a escola forme estudantes autônomos para serem amigáveis à tecnologia sem treiná-los para entender e testar a tecnologia e para que os professores possam olhar criticamente e avaliar a mesma tecnologia.

Os resultados desta revisão, portanto, apontam para a necessidade de políticas públicas para formação inicial e continuada que não se limitem a treinamentos específicos sobre ferramentas específicas. Neste cenário atual, são necessários processos de formação permanente que possam articular conhecimentos tecnológicos, pedagógicos, curriculares e éticos e, ao mesmo tempo, considerar as diferentes realidades das instituições de Educação Básica.

Em geral, os 16 estudos examinados mostraram que a Inteligência Artificial é uma tecnologia muito importante na educação, mas seu potencial não se deve apenas ao uso da IA na escola. A qualidade da integração é determinada pela formação dos professores e pela intenção sobre seu uso, condições de acesso e políticas públicas, bem como pelos princípios fundamentais da educação (autonomia, criticidade, ética, inclusão e formação integral). E mais do que treinar professores para usar IA, mostra que os professores precisam ser treinados na habilidade de ler e questionar, selecionar e ressignificar no contexto do propósito da educação. Dessa forma, a Inteligência Artificial deixará de ser uma nova tecnologia na escola para se tornar um elemento pedagógico que pode ser articulado de forma crítica, ética e coerente com os desafios atuais da Educação Básica.

5. Considerações Finais

Nesta revisão de literatura, observou-se que a Inteligência Artificial está cada vez mais presente no discurso sobre educação e formação de professores. Os estudos que examinamos mostram não apenas o crescente interesse em introduzir essas tecnologias em ambientes educacionais, mas também como isso vem sendo feito. Por um lado, a IA abre oportunidades para expandir e diversificar as abordagens pedagógicas, mas, por outro, traz dificuldades no ensino, na ética, na inclusão digital, na infraestrutura, no currículo e nas políticas públicas.

Diante das principais observações da revisão, a formação dos professores é fundamental. A disponibilidade de ferramentas de Inteligência Artificial não garante necessariamente que elas sejam intrinsecamente integradas ao ensino e à aprendizagem. O professor também está no centro desses processos de mediação pedagógica, de seleção de recursos e de como os alunos usam e tomam decisões intencionais que orientam o uso dessas tecnologias. A formação para IA requer mais do que conhecimento da tecnologia. Os educadores precisam entender o potencial e os limites dessas tecnologias e usá-las de forma sábia e ética, de maneira culturalmente responsável e consistente com os objetivos educacionais.

Os artigos que foram examinados também mostram que ainda há uma lacuna entre o interesse dos professores em Inteligência Artificial e sua efetiva apropriação pedagógica. A insegurança em relação às ferramentas, limitações de conhecimento técnico, níveis de uso encontrados na pesquisa indicam que a formação inicial e continuada deve estar alinhada com as mudanças trazidas pela cultura digital. Assim, para que os professores trabalhem com IA, não significa simplesmente ensiná-los a usar novas ferramentas, mas formar para que aprendam a usar IA, experimentem, avaliem e tomem decisões conscientes sobre sua presença na educação.

Questões éticas são de especial importância. Entre os estudos, destacam-se as questões de dependência tecnológica, pensamento crítico, proteção de dados, equidade e os possíveis efeitos da IA nos processos de aprendizagem. Essas são questões que reforçam a necessidade de manter a autonomia, o envolvimento ativo de professores e alunos e não adotar a tecnologia com o objetivo de inovação.

Outro aspecto destacado nesta revisão é a ligação entre a formação de professores e as políticas públicas. Para preparar os professores para um mundo cada vez mais mediado pela tecnologia, precisamos de investimentos contínuos, infraestrutura para apoiar isso, bem como oportunidades de formação para profissionais em diferentes etapas da Educação Básica. Sem esse apoio, a integração da IA seria desigualmente benéfica em certos contextos e não em outros e poderia causar mais desigualdades.

Nesse sentido, constatamos que nossos resultados têm boa ressonância com a Base Nacional Comum Curricular (BNCC), particularmente no contexto de formação que é

relevante e significativo para a cultura digital e em termos éticos. Se a Educação Básica deve desenvolver essas habilidades nos estudantes, então é igualmente importante que os professores tenham condições de desenvolver e atualizar seus próprios conhecimentos e habilidades. Essa relação torna a formação de professores parte da transformação que vem ocorrendo na educação no contexto da Inteligência Artificial.

A revisão também facilitou a identificação de aspectos que ainda precisam ser mais explorados em pesquisas futuras. Embora os estudos indiquem o potencial, desafios e propostas para integrar a IA na educação, são necessários mais estudos para avaliar o impacto da IA em ambientes práticos da Educação Básica e ao longo do tempo. Pesquisas futuras poderiam explorar mais como o treinamento em IA é uma ferramenta eficaz para professores e alunos e o impacto que tem nas práticas dos professores, nos processos de aprendizagem dos alunos, no desenvolvimento do pensamento crítico e nas diferentes etapas da educação. E é importante expandir a pesquisa sobre as condições em que essa integração é possível e aplicada com respeito às diferentes realidades educacionais.

Conforme mencionado anteriormente, é claro que esta revisão está no contexto de um campo em rápida mudança. Ferramentas de Inteligência Artificial constantemente trazem novas possibilidades, desafios e problemas em um curto espaço de tempo, e as propostas de pesquisa e formação de professores precisam ser atualizadas constantemente. Isso é algo bom para trabalhar, pois não interromperia a discussão, mas nos ajudaria a entender um cenário muito novo e em construção.

Com isso, entende-se que a educação precisa fazer mais do que simplesmente abraçar ou rejeitar a IA, mas criar condições para que sua existência seja compreendida e analisada criticamente. A formação de professores é central nesse processo e deve estar alinhada com políticas públicas, currículo, condições de acesso e os princípios éticos que informam a educação. Mais do que preparar os professores para as ferramentas de IA, é necessário prepará-los para tomar decisões conscientes sobre essas tecnologias e manter a intencionalidade pedagógica, além de entender que a inovação só é viável se servir à aprendizagem e ao desenvolvimento integral dos alunos.

Os resultados desta revisão apontam para a necessidade de políticas públicas para formação inicial e contínua que não se limitem a treinamentos específicos sobre ferramentas específicas. A situação atual exige processos de formação permanentes que possam articular conhecimentos tecnológicos, pedagógicos, curriculares e éticos, ao mesmo tempo em que abordem as diferentes realidades das instituições educacionais.

Referências

ANDRÉ, C. F.; AZEVEDO, A. B. & ANDRADE, F. **Inclusão digital e inteligência artificial na educação: avanços, desafios e oportunidades para alunos e professores da educação básica à educação superior**. Educação & Linguagem, v. 26, n. 1, p. 211–236, 2023.

ALMEIDA, M. E. B. de; VALENTE, J. A. **Tecnologias e currículo: trajetórias convergentes ou divergentes?** São Paulo: Paulus, 2014.

CALIMBO, A. L.; RAMOS, R. F.; MAGCUYAO, J. P. H.; DE ANGEL, R. M. **Empoderando educadores: uma estrutura para cultivar a alfabetização em IA e a competência digital em programas de formação de professores**. In: 2nd International Conference on Artificial Intelligence and Teacher Education (ICAITE), Kyoto, Japão, 2025. p. 249–253. DOI: 10.1109/ICAITE68636.2025.11442547.

CHRISTOU, P. A. **Implicações da inteligência artificial na educação: uma revisão crítica, avaliação e conceituação**. In: 6th International Workshop on Artificial Intelligence and Education (WAIE), Tóquio, Japão, 2024. p. 56–60. DOI: 10.1109/WAIE63876.2024.00017.

FENG, M.; HONG, S. & WANG, Z. **A associação entre a alfabetização em IA dos professores pré-escolares e o engajamento na aprendizagem em estágios educacionais**. 2025.

FOFONCA, E.; PASINATO, N. M. B. & FLORENCIO, R. **Formação continuada de professores da educação básica, currículo e inteligência artificial: contrapontos para a reflexão**. Revista de Estudos de Cultura, São Cristóvão, v. 11, n. 27, p. 67–82, 2025.

FLORES, G. T. **Adoção e implementação da inteligência artificial na educação: insights de professores de ciências**. 2025.

GATTI, B. A.; BARRETTO, E. S. de S.; ANDRÉ, M. E. D. A. de & ALMEIDA, P. C. A. de. **Professores do Brasil: novos cenários de formação**. Brasília, DF: UNESCO, 2019.

KENSKI, M. E. B. **Tecnologias e ensino presencial e a distância**. Campinas: Papirus, 2015.

LIGHTER, T.; ELMORE, B.; SMARR, S.; WRIGHT, B. Capacitando educadores com IA generativa: insights de workshops de desenvolvimento profissional sobre aplicações éticas e práticas em sala de aula. 2025.

NÓVOA, A.. Profissão professor. Porto: Porto Editora, 1988.

NÓVOA, A. **Os professores e a sua formação**. Lisboa: Dom Quixote, 2022.

ORLANDA-VENTAYEN, C. C. **Empoderando a educação por meio do papel transformador da inteligência artificial no ensino e na aprendizagem: perspectiva dos educadores e tendências de pesquisa**. In: 9th International Conference on Information Technology and Digital Applications (ICITDA), Malásia, 2024. p. 1–5. DOI: 10.1109/ICITDA64560.2024.10809596.

PERRENOUD, P. **Construir as competências desde a escola**. Porto Alegre: Artmed, 2008.

PORTO, A. T.; PRADO, R. de C.; SILVA, A. P. da & DAMASCENO, E. F. **Uma proposta de formação docente em inteligência artificial: perspectivas e desafios na educação básica**. Revista de Estudos Interdisciplinares, v. 8, n. 1, p. 1–15, 2026. DOI: 10.56579/rei.v8i1.2378. Disponível em: https://doi.org/10.56579/rei.v8i1.2378. Acesso em: 22 maio 2026.

RIBEIRO, D. **Competência**. In: Dicionário Online, 2026.

RICH, E. & KNIGHT, K. **Artificial Intelligence**. 2. ed. New York: McGraw-Hill, 1991.

SACRISTÁN, J. G. **O currículo: uma reflexão sobre a prática**. Porto Alegre: Artmed, 2000.

SANTOS, M. F. da C. **Inteligência artificial na formação docente: desafios, possibilidades e capacitação para a educação básica**. Urutaí: Instituto Federal Goiano, 2024.

SILVA, M. P. G.; MOTA, S. A.; RAMOS, R. D. & MACHADO, E. S. F. **Proposta de formação continuada de professores sobre a utilização da inteligência artificial generativa na educação básica**. Caderno Pedagógico, v. 22, n. 12, 2025. DOI: 10.54033/cadpedv22n12-201.

SILVA, W. M.; MOTA, S. A.; RAMOS, R. D. & MACHADO, E. S. F. **A inteligência artificial como estratégia inovadora na educação básica: desafios de um futuro digital para a formação de professores**. Cadernos Cajuína, v. 11, n. 2, p. e1926, 2026. DOI: 10.52641/cadcajv11i2.1926. Disponível em: https://v3.cadernoscajuina.pro.br/index.php/revista/article/view/1926. Acesso em: 22 maio 2026.

TILLMAN, D. A.; COCHRAN, C.; SOTO, T. J.; ROBERTSON, W. H.; AN, S. A. & TINAJERO, J. V. Uso da inteligência artificial para melhorar a preparação dos professores. Laguna Hills, CA, EUA, 2024. p. 41–45. DOI: 10.1109/AIxHeart62327.2024.00014.

YANG, Y. & XIA, X. Examinando a associação entre a alfabetização em IA dos alunos da formação de professores e a competência digital no estágio educacional. 2025.

ZHANG, N. Explorando o papel das ferramentas de IA no treinamento de professores pré-formativos: percepções, desafios e direções futuras. In: 13th International Conference on Information and Education Technology (ICIET), Japão, 2025. p. 451–455. DOI: 10.1109/ICIET66371.2025.11046241.

ZHOU, Y. **O impacto do gerador de arte por inteligência artificial no treinamento de professores de arte em formação**. In: IEEE Conference on Artificial Intelligence (CAI), Singapura, 2024. p. 1406–1407. DOI: 10.1109/CAI59869.2024.00250.

Observação: A IA foi atualizada para gerar tabelas, realizar traduções, criar fluxograma e revisar ortografia.

Sobre o autor(a)

Soraia dos Santos Mangili Vidal

Especialização em TELEFORMAR - Formação na Espiritualidade Apostólica Marista pela Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS - 2002).

Especialização em SUPERVISÃO ESCOLAR pela Universidade do Extremo Sul Catarinense (UNESC 1995).

Especialização em Psicologia da Educação pelo Instituto Severino Sombra (ISS - 1989)

Lattes: http://lattes.cnpq.br/4236131689423994

CAPÍTULO 18

Inteligência Artificial na Produção de Recursos Educacionais: uma revisão sistemática da literatura

Júlia Hahn Gonçalves

1. Introdução

Com o acesso massificado a plataformas de IA diversos segmentos e profissionais estão procurando testar modelos e prompts para a otimização de trabalhos que demandam muita repetição para a sua realização. Segundo Carvalho (2021) a IA pode contribuir para a redução da exposição humana a atividades perigosas, assim como automatizar tarefas repetitivas e monótonas, possibilitando que às pessoas foquem em atividades mais criativas e desafiadoras. O autor afirma que a automação promovida pela IA pode diminuir a carga de trabalho e ampliar o tempo disponível para convivência social, lazer e qualidade de vida, o que pode ser comparado ao fenômeno ocorrido durante a Revolução Industrial.

Apesar do discurso do autor, sobre o ser humano poder focar mais em atividades tradicionalmente percebidas como criativas e desafiadoras, podemos notar como a indústria do audiovisual, design e escrita criativa foram impactados pela Inteligência Artificial Generativa (IAGen), transformando o modo como peças publicitárias são produzidas. Em um segmento como este que exige refinamento estético constante, construção de narrativas sedutoras que envolvam o usuário a consumir os demais não ficaram à margem.

No âmbito educacional, os impactos dessa transformação também são notáveis. O trabalho docente, que ultrapassa a atuação em sala de aula, começou a contar com uma ampla variedade de plataformas de IA voltadas ao apoio no planejamento pedagógico, na criação de atividades e no desenvolvimento de materiais adaptativos alinhados aos distintos estilos de ensino e aprendizagem. Segundo Ezayyat, Mohammad e Zaqout (2025) destacam que o uso de modelos de linguagem de grande escala (LLMs) pode otimizar a eficiência na criação de avaliações, permitindo que conteúdos complexos possam ser gerados em uma fração do tempo exigido por métodos tradicionais.

Dessa forma, assessores pedagógicos, equipes responsáveis pela produção de

conteúdos educacionais e disciplinas que utilizem ambiente virtual de aprendizagem, estudam como inserir frameworks específicos para desde a aplicação em geração de recursos educacionais como questões avaliativas até a incorporações de tutores inteligentes baseados em IA. Diante do movimento acelerado no uso dos modelos LLMs, Chi, Cui e Xi (2026) enfatizam o fato de que a tecnologia deve ser encarada como um parceiro assistivo que amplia a capacidade do educador, sem substituir o seu papel central na curadoria e no pensamento crítico.

Nesse contexto, diferentes personagens educacionais vêm buscando compreender de que forma a Inteligência Artificial pode contribuir para a geração automática de recursos educacionais, bem como quais são os benefícios, desafios e o papel do professor nesse processo. Em suma, esta Revisão Sistemática da Literatura busca responder à seguinte questão de pesquisa: "Como a Inteligência Artificial tem sido utilizada na geração automática de recursos educacionais e quais são suas aplicações, benefícios e limitações no contexto educacional?".

Dessa forma, esta pesquisa tem como objetivo analisar como a Inteligência tem sido aplicada na utilização de geração automática de recursos educacionais, buscando identificar às principais tecnologias empregadas nesse processo, mapear os tipos de materiais educacionais produzidos, analisar os benefícios e desafios dessas tecnologias na educação e identificar tendências e lacunas presentes na literatura científica.

2. Referencial Teórico

Este trabalho possui como base três pilares centrais: inovação na educação, inteligência artificial e inteligência artificial na educação. Os conceitos são apresentados e debatidos de forma articulada, oferecendo como base teórica para compreender a utilização da IA na geração automática de recursos educacionais, seguindo a estrutura semelhante utilizada por Lopes et a. (2019).

2.1 Inovação na Educação

O crescimento das Tecnologias da Informação e Comunicação (TICs) estão modificando diferentes áreas do conhecimento, sendo a educação um dos locais com potencial para implementação de práticas inovadoras. Contexto que vai de encontro com o pensamento de Levy (2008), que a sociedade contemporânea vive de modo conectado, proporcionando transformações no compartilhamento de informações e nas formas de interação entre os indivíduos.

A escola passa a adicionar tecnologias digitais em seus processos de ensino e aprendizagem, buscando proximidade com a realidade tecnológica vivenciada pelos discentes. Segundo Belloni (2005), a escola precisa integrar às TICs às suas práticas,

considerando que elas já estão presentes em cada momento da vida social.

Em um contexto de alta velocidade nas mudanças tecnológicas, autores como Veen e Vrakking (2009) indicam que a escola não acompanha a intensidade com que os estudantes usufruem tecnologias fora do ambiente educacional, criando um distanciamento entre esses mundos. Desse modo, Prensky (2012) argumenta que os alunos do século XXI não aprendem com modelos de aprendizagem até então considerados modelos educacionais tradicionais. No âmbito educacional, o uso de IA pode ser compreendido como uma possibilidade de inovação ao automatizar processos, ampliar o acesso à informação e apoiar novos meios de construção do conhecimento.

2.2 Inteligência Artificial

A Inteligência Artificial tem sido adicionada em contextos profissionais e sociais de formas distintas. Ela amplia possibilidades de automação, processamento de dados e geração de conteúdos digitais. Com o desenvolvimento das tecnologias computacionais, modelos capazes de produzir textos, imagens, vídeos e outros formatos multimodais passaram a fazer parte de atividades antes desenvolvidas apenas por humanos.

Em paralelo ao crescimento da IA também temos a expansão das TICs e das tecnologias digitais aplicadas à educação. Conforme abordado por Lopes et al. (2019), o avanço tecnológico está promovendo transformações notáveis nos processos educativos, criando possibilidades para o desenvolvimento de práticas mais inovadoras, adaptativas e interativas.

2.3 Inteligência Artificial na Educação

O uso da IA no contexto educacional cresceu significativamente nos últimos anos, em especial nas aplicações relacionadas à personalização da aprendizagem, automação de atividades pedagógicas - como o planejamento de aulas - e geração automática de recursos educacionais. A utilização das plataformas de IA passa pela geração automática de vídeos instrucionais, criação de questões múltiplas, escolha, desenvolvimento de materiais adaptativos, produção de feedback automatizado, apoio ao planejamento instrucional e construção de tutores inteligentes.

Mesmo com o otimismo na inclusão das ferramentas de IA na educação, os autores Chi, Cui e Xi (2026) ressaltam que a eficácia de novo paradigma depende intrinsecamente da supervisão humana (human-in-the-loop), sendo importante para a validação das informações e afim de evitar riscos como às “alucinações”e viesses algorítmicos.

Segundo Balaji, Ogange e Mays (2025), a inovação acontece por meio do

empoderamento docente, no qual o professor deixa de ser apenas um transmissor para tornar-se um curador crítico no processo de co-criação de materiais.

3. Metodologia

Com a intenção de visualizar o panorama geral sobre o uso de IA durante a geração de conteúdos educacionais e responder às questões de pesquisa, tornou-se o ponto inicial para esta revisão sistemática de literatura (RSL) e da análise bibliométrica. Conforme Sampaio e Mancini (2007), uma RSL tem como objetivo pesquisar a literatura sobre um tema específico, apresentando um resumo das evidências encontradas e que relacionam-se com um tema, de uma forma que seja apresentado de forma sistemática como às buscas foram realizadas, analisadas e a síntese das publicações.

Esta revisão sistemática foi realizada no dia 16 de maio de 2026 e para o teor científico foi utilizado o método Systematic Search Flow (SSF) desenvolvido por Ferenhof e Fernandes (2016), que permite a replicação das pesquisas de modo mais simples. Os autores desta metodologia citam que o SSF trata-se de um método não aleatório ou exploratório, pois segue um procedimento metodológico fiel que garante a repetibilidade da pesquisa, reduzindo tendências de pesquisadores.

Segundo Ferenhof e Fernandes (2016), quatro fases são utilizadas na metodologia SSF:

1. A primeira fase é responsável pela elaboração do protocolo de pesquisa, no qual esta fase é construída por cinco atividades, contendo: 1) definição da estratégia de busca; 2) consultas nas bases de dados; 3) organização do portfólio; 4) definição dos critérios de seleção dos documentos; e 5) composição do portfólio bibliográfico.
2. Na fase dois, o pesquisador inicia o refinamento dos dados apurados na primeira fase, analisando às publicações bibliométricamente.
3. A terceira fase, acontece a sintetização e organização dos dados e os conhecimentos mais relevantes adquiridos com a análise dos documentos.
4. Na última fase, a quarta, temos a consolidação dos dados, concluindo com a atividade oito que resume-se a descrição do trabalho em formato de redação.

Para o apoio organizacional e síntese dos dados extraídos na Matriz do Conhecimento, utilizou-se a ferramenta de IA Gemini no recurso de "Projeto”, área do Google Drive para clientes PRO, com o foco em auxiliar na identificação de padrões temáticos entre os estudos analisados. O uso da ferramenta contribuiu para o agrupamento dos artigos em grupos temáticos, em seguida revisadas e validades

manualmente pela pesquisadora, buscando garantir coerência analítica e alinhamento com os objetivos da revisão.

4. Análise e discussão dos resultados

Quadro 1 - Protocolo de pesquisa

Fase 1 - Definicação do protocolo de pesquisa	
Atividade 1 Estratégia de busca	Na estratégia de busca desta pesquisa foram utilizados descritores relacionados à Inteligência Artificial, geração automática de conteúdo e recursos educacionais. Foram acionados apenas termos em inglês. Os grupos temáticos definidos foram: Inteligência Artificial, geração automática de conteúdo, recursos educacionais e educação. Para cada grupo, foram estabelecidos descritores específicos, incluindo termos como “Artificial Intelligence”, “Generative AI”, “Large Language Models”, “content generation”, “educational resources” e “educational technology”, As expressões de busca foram estruturadas utilizando os operadores booleanos “AND” e “OR”, permitindo a combinação entre os grupos temáticos e a ampliação da recuperação de estudos potencialmente relevantes. As estratégias de busca foram personalizadas conforme as especificidades sintáticas de cada base de dados consultada. As buscas foram realizadas nas bases Scopus, Web of Science, IEEE Xplore via Portal CAPES, selecionadas devido à relevância e abrangência nas áreas de tecnologia, educação e inteligência artificial. Como critérios de inclusão, foram considerados: • Estudos relacionados à aplicação da Inteligência Artificial na geração automática de recursos educacionais; • Trabalhos que abordassem geração automática de conteúdo educacional; • Artigos científicos, revisões sistemáticas, trabalhos de conferência, teses e dissertações; • Estudos publicados entre 2025 e 2026; • Publicações nos idiomas inglês, português e espanhol; • Trabalhos disponíveis em texto completo. Como critérios de exclusão, foram desconsiderados: • Estudos duplicados; • Trabalhos sem acesso ao texto completo; • Pesquisas sem relação com o contexto educacional; • Estudos que não abordam geração automática de recursos educacionais utilizando Inteligência Artificial.

continua

continuação

Atividade 2 Consulta em bases de dados	As bases de dados selecionadas para a realização das buscas foram Scopus, Web of Science e IEEE Xplore, por conta da abrangência e relevância dessas plataformas nas áreas de tecnologia, educação e inteligência artificial. As estratégias de busca foram adaptadas conforme as especificidades sintáticas de cada base de dados, mantendo a mesma estrutura lógica de recuperação dos estudos. A string principal utilizada na pesquisa foi composta por quatro grupos temáticos relacionados à Inteligência Artificial, geração automática de conteúdo, recursos educacionais e educação, combinados por meio dos operadores booleanos “AND” e “OR”, conforme apresentado a seguir: ("Artificial Intelligence" OR AI OR "Generative AI" OR "Generative Artificial Intelligence" OR "Machine Learning" OR "Deep Learning" OR "Natural Language Processing" OR NLP OR "Large Language Models" OR LLM) AND ("content generation" OR "automatic content creation" OR "text generation" OR "AI-generated content" OR "automatic generation" OR "automated content") AND ("educational resources" OR "learning materials" OR "educational content" OR "instructional materials" OR "learning objects" OR "teaching materials") AND ("education" OR teaching OR learning OR "educational technology" OR EdTech OR "e-learning"). A aplicação das estratégias de busca resultou em 116 documentos recuperados na Scopus, 105 na Web of Science e 63 na IEEE Xplore. Foram aplicados filtros relacionados ao idioma e período de publicação, considerando estudos publicados entre 2025 e 2026, apenas no idioma em inglês.
Atividade 3 Organização das bibliografias	Na organização das bibliografias o gerenciador utilizado foi o software Zotero, pois além de possuir uma boa detectação de itens duplicados também permite a inclusão de links.

continua

continuação

Atividade 4 Seleção padronizada dos artigos	Neste momento foi realizada a leitura dos títulos, resumos e palavras-chaves de cada um dos artigos, selecionando aqueles que atendessem aos critérios de inclusão. Ao final desta filtragem, restaram 46 artigos.
Atividade 5 Composição do portfólio	Na atividade 5 os artigos foram lidos na íntegra e revisados na matriz de conhecimento, analisando os itens: ID; Autor/Ano; Objetivo, Tipo de material gerado; Ferramenta IA; Público; Método; Benefícios; Desafios; Papel do professor; Resultados e Observações. Afim de evitar publicações sem alinhado ao objetivo da pesquisa, nesta atividade foram eliminados 4 artigos, resultando em um total de 41 artigos no portfólio final.

Fonte: elaborado pela autora (2026)

Com a fase um estruturada, podemos visualizar os seguintes números:

Quadro 2 - Atividades e número de documentos recuperados

Atividade	Número de documentos
Busca nas bases	284 (63 resultados na IEEE, 116 na Scopus e 105 na Web Of Science)
Excluindo documentos duplicados	67
Primeiro filtro (Leitura dos títulos, resumos e palavras-chave)	97
Texto completo recuperado automaticamente pelo software de gestão de referências Zotero®	46
Texto completo de acordo com os critérios de inclusão e exclusão	46
Total de documentos disponíveis, lidos integralmente	46
Portfólio final	41

Fonte: elaborado pela autora (2026)

Na fase 2 (atividade 6) aconteceu a etapa de análise dos documentos selecionados para o portfólio bibliográfico final. Como suporte desta etapa, os dados das

publicações foram organizados em uma planilha denominada Matriz do Conhecimento, conforme indicado por Ferenhof e Fernandes (2016). O uso da matriz facilitou a extração de dados bibliométricos e qualitativos, permitindo responder às questões norteadoras desta Revisão Sistemática da Literatura.

Com a conclusão da etapa de leitura integral e refinamento dos estudos elencados, o portfólio bibliográfico final resultou em 41 publicações distribuídas entre os anos de 2025 e 2026. Observou-se uma concentração no ano de 2025, com 35 publicações (85,4% do total), enquanto o ano de 2026 apresentou 6 estudos (14.6%). Este fato relaciona-se ao período de coleta nas bases de dados, que foi realizado até maio de 2026. Os resultados demonstram a atualidade do tema e o crescimento robusto do interesse científico relacionado à Inteligência Artificial Generativa no âmbito da educação.

É notável na origem das pesquisas o destaque para instituições Chinesas e Indianas. Universidades como a The Hong Kong Polytechnic University e a Beijing University of Posts and Telecommunications, na China, além do Sri Eshwar College of Engineering e do Indian Institute of Technology Madras, na Índia, apresentam estudos voltados à automação de recursos educacionais.

No contexto de geração de vídeos instrucionais foram identificadas pesquisas desenvolvidas por instituições dos Estados Unidos, como a Purdue University e a Northwestern University. Além da análise bibliométrica, a Matriz do Conhecimento permitiu classificar os artigos em seis grupos temáticos principais:

1. Geração Automática de Vídeos Instrucionais: estudos com foco em criação automatizada de vídeos educacionais por meio de avatares, síntese de voz e transformação de slides e roteiros em conteúdos multimodais.
2. Criação e Avaliação de Questões (MCQs): estudos direcionados para o desenvolvimento de sistemas baseados em LLMs para geração automática de questões, avaliações e explicações pedagógicas.
3. Apoio ao Planejamento Instrucional e Automação de Tarefas: testes de aplicação de IA destinada à redução da carga horária de trabalho do docente, incluindo planejamento de aulas, produção de recursos educacionais e automação de processos educacionais.
4. Educação Multilíngue e Equidade Digital: estudos relacionados à criação de recursos educacionais em idiomas diversos e ao uso da IA para ampliação do acesso educacional.
5. Personalização e Aprendizagem Baseada em Erros: sistemas capazes de realizar adaptação de conteúdos, gerar feedback personalizado e criar novos desafios com base no desempenho e nos erros dos estudantes.

Quadro 3 - Grupos Temáticos

Autor	Ano	Título do Artigo	Grupo
Chi, M; Cui, Y & Xi, L.	2026	*Advances in the application of artificial intelligence in ophthalmic education and clinical training*	3. Apoio ao Planejamento Instrucional e Automação de Tarefas
Xie, Z. & Hong, Y.	2025	*AI + Art and Design Education: Research on Intelligent Algorithm Driven Educational Content Generation Mechanism*	6. Engenharia de Prompts e Colaboração Humano-IA
Tan, Z. et al.	2025	*AI in tourism education: a review of AIGC teaching and evaluation tools*	5. Personalização e Aprendizagem Baseada em Erros
Shu, J. et al.	2025	*AI-Generated Instructional Videos: A Systematic Review of Learning Impacts, Applications, and Research Perspectives*	1. Geração Automática de Vídeos Instrucionais
Nacheva, R.	2025	*AI-powered Moodle modules for advanced e-learning*	5. Personalização e Aprendizagem Baseada em Erros
Stalin V. et al.	2025	*AIDEN: Automatic Speaker Notes Creation and Navigation*	2. Criação e Avaliação de Questões (MCQs)
Yen, C. C. et al.	2025	*Analysis of a Generative AI-Based Graphical Learning Assistance Tool in IPR Courses*	4. Educação Multilíngue e Equidade Digital

continua

continuação

Morland, R. D. & Lin, F.	2025	*An Adaptable Client-Server Architecture for Generating Educational Content using Large Language Models*	3. Apoio ao Planejamento Instrucional e Automação de Tarefas
Huang, Z.	2025	*Application of AIGC in multilingual teaching in higher education*	6.Engenharia de Prompts e Colaboração Humano-IA
Elzayyat, M.; Mohammad, J. N. & Zaqout, S.	2025	*Assessing LLM-generated vs. expert-created clinical anatomy MCQs: a student perception-based comparative study in medical education*	2. Criação e Avaliação de Questões (MCQs)
Thankachan, J. A.; Srinivasan, B. & Bhupathy, N.	2026	*Automated educational task generation and solution guidance using LLMs and reinforcement learning*	2. Criação e Avaliação de Questões (MCQs)
Karuppan, A. S. et al.	2025	*Automated Generation of Context-Aware Assessments using AI and NLP Techniques*	2. Criação e Avaliação de Questões (MCQs)
Babu, G. S. et al.	2025	*Automated Text-to-Video Integration with Audio and Question Answer Generation*	1. Geração Automática de Vídeos Instrucionais
So, C. C. et al.	2025	*Automatic Generation of High Quality MCQs With LLMs for Artificial Intelligence Education*	2. Criação e Avaliação de Questões (MCQs)
Viramontes, L. B.	2025	*Automating STEM Education: An AI Driven Platform for Learning Modules*	3. Apoio ao Planejamento Instrucional e Automação de Tarefas
Wang, R. et al.	2025	*Comparative Evaluation of Teaching Plans on Prostate Cancer Generated by Various Large Language Models and a Human Expert*	3. Apoio ao Planejamento Instrucional e Automação de Tarefas

continua

continuação

Kim, D.; Park, S. W. & Lee, J.	2026	*CQELedu: Design and Implementation of a LangChain and GPT-4o Mini-Based Web Application for Custom Question Generation and Error-Based Learning in Education*	4. Educação Multilíngue e Equidade Digital
Jie, Z. & Zhuming, N.	2025	*Design of a Dynamic Generation System for Personalized Learning Resources Based on Generative AI and Sparse Attention Mechanisms*	6. Engenharia de Prompts e Colaboração Humano-IA
Khaoula, A. et al.	2025	*EduXgame: Gamified learning for secondary education*	3. Apoio ao Planejamento Instrucional e Automação de Tarefas
Mikroyanni, A. et al.	2025	*Enhancing Language Learning with Generative AI: The Case of the OpenLang Network Platform*	4. Educação Multilíngue e Equidade Digital
Zabala, I. D.; Ribalta, C. T. & Mataix, J. B.	2025	*Enhancing Educational Content Through AI-Assisted Transformation of Video Transcriptions*	1. Geração Automática de Vídeos Instrucionais
Tang, Z. et al.	2025	*Examination Questions Generation System Based on Soft Knowledge Prompt and Large Language Model*	2. Criação e Avaliação de Questões (MCQs)
Zhou, Y. et al.	2026	*ExPeerience: Support Student-AI Co-Creation in a Learnersourcing Workflow*	5. Personalização e Aprendizagem Baseada em Erros
Sharma, A.; Shailendra, S. & Kadel, R.	2025	*Experiences with Content Development and Assessment Design in the Era of GenAI*	3. Apoio ao Planejamento Instrucional e Automação de Tarefas
Xu, T. et al.	2025	*From recorded to AI-generated instructional videos: A comparison of learning performance and experience*	1. Geração Automática de Vídeos Instrucionais

continua

continuação

Lu, X.	2025	*Generative AI-Based Digital Narrative Content Generation for Ideological and Political Education and Ethical Risk Prevention*	2. Criação e Avaliação de Questões (MCQs)
Blazauskas, T. et al.	2025	*Immersive Pedagogy: Converting AI-Driven Podcasts into Virtual Reality Learning Objects*	3. Apoio ao Planejamento Instrucional e Automação de Tarefas
Oh , S.	2025	*Integration of MATH41 and Generative AI in Pre-Service Mathematics Teacher Education: An Empirical Study on Lesson Design Competency*	5. Personalização e Aprendizagem Baseada em Erros
Yang, X. et al.	2025	*Integration of Intelligent Generation and Education: Research and Practice of AIGC Driven Intelligent Teaching Resources in Universities*	1. Geração Automática de Vídeos Instrucionais
Wang, S. et al.	2025	*Language Learning Content Development from Human Effort to AI Generation: Successes and Challenges*	1. Geração Automática de Vídeos Instrucionais
Getino-Diez, R. & García-Madariaga, M.	2026	*Linguistic Control in AI Text Generation: An Accessible Prompt-Based Approach Targeting L2 Spanish Absolute Beginners*	6. Engenharia de Prompts e Colaboração Humano-IA
Karbasi, K. et al.	2025	*Multi-Agent Collaborative Framework For Math Problem Generation*	5. Personalização e Aprendizagem Baseada em Erros
Talledo, D.; Reategui, C. & Huillca, V.	2025	*NLP-Based Mobile Application for the Automatic Generation of Learning Activities in Peruvian Universities*	3. Apoio ao Planejamento Instrucional e Automação de Tarefas

continua

continuação

Lin, J. et al.	2025	*Opportunities and Challenges of AIGC in Smart Education*	1. Geração Automática de Vídeos Instrucionais
Yuan, X. et al.	2025	*Personalized learning resources created by generative artificial intelligence: A systematic review*	5. Personalização e Aprendizagem Baseada em Erros
Reza, M. et al.	2025	*PromptHive: Bringing Subject Matter Experts Back to the Forefront with Collaborative Prompt Engineering for Educational Content Creation*	6. Engenharia de Prompts e Colaboração Humano-IA
Hwang, W. Y. & Utami, I. Q.	2026	*SocioMathLLM: A Multimodal Large Language Model Framework for Generating Authentic Mathematical Word Problems Driving Socialization*	2. Criação e Avaliação de Questões (MCQs)
Chontal, G. et al.	2026	*Task automation and instructional planning support with large language models: a systematic review*	3. Apoio ao Planejamento Instrucional e Automação de Tarefas
Balaji, V.; Ogange, B. & Mays, T.	2025	*Teacher in the Loop AI (TiL-AI): A Strategy for Empowering Educators in Developing Countries through OER Adaptation*	4. Educação Multilíngue e Equidade Digital
Abri, M. A. et al.	2025	*The Exploration of Generative Textbooks in Higher Education: A Design-Based Research Intervention*	6. Engenharia de Prompts e Colaboração Humano-IA

Fonte: elaborado pela autora (2026)

5. Observações Gerais

A Revisão Sistemática da Literatura sobre como a Inteligência Artificial tem sido utilizada na geração automática de recursos educacionais e quais são suas aplicações, benefícios e limitações no contexto educacional, revelou que a concentração de

estudos não baseia-se em uma única frente. Existe um panorama multifacetado da aplicação da IA, tanto no ensino superior quanto no básico, com destaque em uma transição de modelos tradicionais para ecossistemas de aprendizagem inteligentes e personalizados.

No gráfico a seguir fica evidente o equilíbrio de estudos entre os temas dos grupos temáticos, com exceção do tema “Educação Multilíngue e Equidade Digital".

Figura 1 - Quantidade de artigos científicos por grupo (2025-2026)

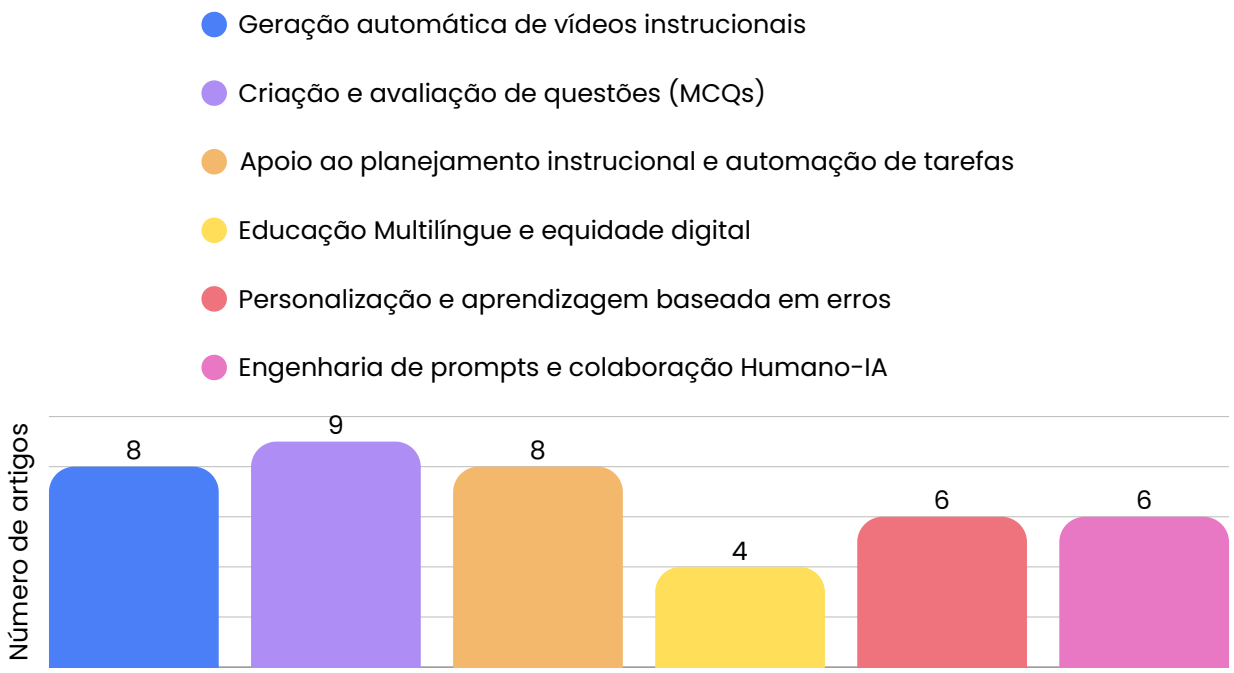

Fonte: Gerada pelo autor utilizando a inteligência artificial Gemini (2026).

Em uma visão ampla nota-se o esforço em reduzir a carga de trabalho do docente, em situações distintas dentro do contexto de geração de recursos educacionais. Desde o planejamento de aulas, a criação de avaliação de questões e até a geração automática de vídeos instrucionais.

A utilização da IA na educação tem apresentando um potencial disruptivo na otimização do tempo docentes e na escalabilidade da produção de materiais didáticos. Os estudos encontrados nesta RSL indicam que o uso de modelos LLMs podem reduzir o esforço manual necessário para a criação de avaliações e conteúdos multimodais.

Segundo Elzayyat, Mohammad e Zaqout (2025), a IA é capaz de produzir 50 questões de múltipla escolha em 20 minutos, em comparação se fosse realizada por um especialista seria necessário mais de 3,5 horas. Essa eficácia está de acordo com os achados de Karuppan et al. (2025), que descrevem sistemas automatizados aptos a processar 10 páginas de conteúdo educativo para gerar até 45 questões em menos de 12 segundos.

Êxito também encontrado na automação de criação de módulos interativos e roteiros de vídeo, gerando em minutos ou algumas horas algo que levaria dias ou semanas, conforme discutido por Yang et al. (2025). Esses recursos permitem que os educadores direcionem o seu foco em tarefas administrativas repetitivas para uma espécie de mentoria e suporte personalizado aos alunos.

Entre os artigos analisados destacam-se cinco artigos que tratam do tema Teacher-in-the-Loop (TiL-AI), como uma infraestrutura crítica para equilibrar a agilidade de entrega da Inteligência Artificial com a curadoria pedagógica humana. Neste conceito o docente é parte central no processo de geração de recursos educacionais. Segundo Balaji, Ogange e Mays (2025), essa estratégia é essencial para emponderar educadores a utilizarem a IA Generativa para adaptar recursos educacionais e uma forma de diminuir riscos como viesses ou conteúdos inadequados.

Corroborando com esta visão, Reza et al. (2025) introduzem o framework PromptHive, que apresenta como a colaboração entre IA e especialista pode reduzir o tempo de produção de conteúdos complexos ao mesmo tempo em que reduz a carga cognitiva dos educadores pela metade. Em campos específicos como a educação médica, Chi, Cui e Xi (2026) são enfáticos no quesito que a IA deve atuar como um parceiro assistivo e não substituto, tendo a supervisão humana como algo indispensável no processo de validação de diagnósticos e materiais instrucionais. No quesito de aplicação prática em áreas como a matemática apresenta que o monitoramento do professor é importante para evitar que os alunos tornem-se dependentes da ferramenta, afim de garantir que a automação estimule o aprendizado profundo e não apenas fornecer respostas prontas (OH, 2025).

O uso da IA na educação tem demonstrado força para se consolidar como um pilar para a inovação pedagógica, possibilitando a transição de modelos de ensino estáticos para ecossistemas dinâmicos e personalizados. De acordo com Balaji, Ogange e Mays (2025), esta inovação acontece por meio do empoderamento docente, no momento em que o professor deixa de ser apenas um transmissor para torna-se um curador crítico no processo de co-criação dos recursos educacionais. Segundo Xie e Hong (2025), às ferramentas de IA podem aumentar a eficiência da aprendizagem em até 32,7%, no entanto para isto acontecer depende de forma significativa da supervisão humana de um especialista (human-in-the-loop).

Entre os desafios e limitações da utilização de IA para a geração de recursos educacionais temos a questão de alucinações, necessidade de supervisão humana e fatores éticos. Na Matriz de Conhecimento destaca-se como uma das principais barreiras técnicas a possibilidade de alucinações, assim como a suscetibilidade dos conteúdos gerados tenderem a ser superficiais no quesito pedagógico, com falhas quando o objetivo é estimular o pensamento analítico profundo ou raciocínio complexo.

No quesito ético o viés algorítmico pode reproduzir preconceitos culturais e assim como preocupações relacionadas à privacidade de dados e à autoria dos materiais. Este contexto reforça a necessidade da supervisão humana por meio do framework human-in-the-loop.

6. Considerações finais

Esta revisão sistemática da literatura demonstra que, na maioria dos estudos, o papel do docente não está em debate de substituição, mas como um curador crítico. A atuação do professor assume uma posição estratégica na otimização dos processos educacionais que envolvem a geração de recursos educacionais via IA, sendo importante a sua presença para assegurar a qualidade, precisão e integridade pedagógica do material produzido. Às ferramentas de IA utilizadas nas pesquisas, devem ser compreendidas como facilitadores e não como substitutas do conhecimento docente. O professor contemporâneo fortifica-se como uma figura guia no processo de ensino-aprendizagem, afastando-se do papel de mero expositor de informações. Nesse contexto, às plataformas de IA atuam como protagonistas de eficiência nos processos administrativos, de planejamento e recursos adaptativos.

Às alucinações comuns ainda são uma grande dor no âmbito da utilização das ferramentas de IA, por isto a necessidade de uma visão humana criteriosa e que além do conhecimento possua um conhecimento tático profundo. O paradigma "Teacher-in-the-Loop" (TiL-AI) reforça essa situação, da necessidade de sinergia entre a IA e o professor para potencializarem a adaptação de conteúdos.

Em suma, a supervisão humana permanece como avaliador crítico para garantir o alinhamento entre automação e os objetivos de aprendizagem de forma que contenha profundidade analítica. Sobre frameworks envolvendo o conceito de Teacher-in-the-Loop percebe-se apenas um artigo abordando o tema, o que pode indicar uma lacuna de estudos no contexto de orientações de uso eficaz das ferramentas de IA para a geração de recursos educacionais. Pesquisas posteriores sobre o tema podem estender o período da revisão, com a intenção de detectar se a lacuna identificada neste estudo é viável.

Referências

Babu, G. S.; Lenka, V. S.; Yamuna, G. V.; Kumar, S. N. T. R. & Sangeeta, P. **Automated Text-to-Video Integration with Audio and Question Answer Generation.** In: OITS International Conference on Information Technology (OCIT), Bhubaneswar, India, 2025, pp. 840-845, doi: 10.1109/OCIT66168.2025.11400519.

BALAJI, V.; OGANGE, B. O.; MAYS, T. (2025). Teacher in the Loop AI (TiL-AI): A Strategy for Empowering Educators in Developing Countries through OER Adaptation. **Journal of Learning for Development**, v. 12, n. 2, p. 439-445.

BELLONI, M. L. (2005). **O que é mídia-educação**. Campinas: Autores Associados.

Blažauskas, T., Butkevičiūtė, E., Sanfilippo, F., Armalis, P., & Auksoraityte, U. (2025). **Immersive Pedagogy:** Converting AI-Driven Podcasts into Virtual Reality Learning Objects. International Computer Programming Education Conference.

CARVALHO, A. C. P. de L. F. de. (2021). Inteligência Artificial: riscos, benefícios e uso responsável. **Estudos Avançados**, v. 35.

CHI, M.; CUI, Y.; XI, L. (2026). Advances in the application of artificial intelligence in ophthalmic education and clinical training**. Frontiers in Medicine**, v. 12, art. 1753411.

ELZAYYAT, M.; MOHAMMAD, J. N.; ZAQOUT, S. (2025). Assessing LLM-generated vs. expert-created clinical anatomy MCQs: a student perception-based comparative study in medical education. **Medical Education Online**, v. 30, n. 1.

FERENHOF, H. A. and FERNANDES, R. F. (2016). Desmistificando a revisão de literatura como base para redação científica: método SSF. **Revista ACB**, Florianópolis, v. 21, n. 3. Available at: https://revista.acbsc.org.br/racb/article/view/1194. Accessed on: 20 May 2026.

Getino-Diez, R., & García-Madariaga, M. (2026). Linguistic control in AI text generation: An accessible prompt-based approach targeting L2 Spanish absolute beginners. Technology in Language Teaching & Learning, 8, 103327. https://doi.org/10.29140/tltl.2026.103327

KARUPPAN, S. et al. (2025). **Automated Generation of Context-Aware Assessments using AI and NLP Techniques**. In: 2025 2nd International Conference on Software, Systems and Information Technology (SSITCON). IEEE, p. 1-6. LEVY, P. (2008). Cibercultura. São Paulo: Editora 34.

LOPES, L. M. D. et al. (2019). Inovações educacionais com o uso da realidade aumentada: uma revisão sistemática. **Educação em Revista**, Belo Horizonte, v. 35.

OCDE. (2005). **Manual de Oslo: diretrizes para coleta e interpretação de dados sobre inovação**. Paris: Organisation for Economic Co-operation and Development.

OH, S. (2025). Integration of MATH41 and Generative AI in Pre-Service Mathematics Teacher Education: An Empirical Study on Lesson Design Competency. IEEE Access, v. 13, p. 128959-128973

PRENSKY, M. (2012). Aprendizagem baseada em jogos digitais. São Paulo: Senac.

REZA, M. et al. (2025). PromptHive: Bringing Subject Matter Experts Back to the Forefront with Collaborative Prompt Engineering for Educational Content Creation. In: CHI Conference on Human Factors in Computing Systems (CHI '25), Yokohama, Japão, abr./maio 2025. Nova York: ACM.

SAMPAIO, R. and MANCINI, M. (2007). Estudos de revisão sistemática: um guia para síntese criteriosa da evidência científica. Revista Brasileira de Fisioterapia, v. 11, n. 1, p. 83–89.

VEEN, W. and VRAKKING, B. (2009). Homo Zappiens: educando na era digital. Porto Alegre: Artmed.

XIE, Z.; HONG, Y. (2025). AI + Art and Design Education: Research on Intelligent Algorithm-Driven Educational Content Generation Mechanism. In: 2025 International Conference on Artificial Intelligence and Educational Systems (ICAIES 2025). Beijing, China: ACM.

YANG, X. et al. (2025). AI in Tourism Education: A Review of AIGC Teaching and Evaluation Tools. In: 2025 11th International Conference on Education and Training Technologies (ICETT). IEEE, p. 71-79.

TAN, Zehan; YANG, Yanchao; YANG, Xinxin; LIU, Xinyu; WEI, Qiu; KONG, Lo Hoi. AI in Tourism Education: A Review of AIGC Teaching and Evaluation Tools. In: 2025 11th International Conference on Education and Training Technologies (ICETT 2025). Macau, China, 2025, p. 34–35. DOI: 10.1109/ICETT66247.2025.11136881.

Shu, J; Kou, H.; Zhang, J.; Zhang, T.; Zhang, H.; Xu, T. & "AI-Generated Instructional Videos: A Systematic Review of Learning Impacts, Applications, and Research Perspectives," 2025 7th International Conference on Computer Science and Technologies in Education (CSTE), Wuhan, China, 2025, pp. 877-881, doi: 10.1109/CSTE64638.2025.11091997.

NACHEVA, Radka. AI-powered Moodle modules for advanced e-learning. In: 2025 9th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT). 2025. DOI: 10.1109/ISMSIT67332.2025.11268055

An Adaptable Client-Server Architecture for Generating Educational Content using Large Language Models. Bulletin of the Technical Committee on Learning Technology (ISSN: 2306-0212) Volume 25, Number 1, 42-49(2025) Authors: Raymond D. Morland[1], and Fuhua Lin[1]

Wang, R., Ding, Y., Shen, Y., Liu, H., Wang, P. and Gao, Z. (2025), Comparative Evaluation of Teaching Plans on Prostate Cancer Generated by Various Large Language Models and a Human Expert. Engineering Reports, 7: e70303. https://doi.org/10.1002/eng2.70303

Stalin Varanasi, Umer Butt, Guenter Neumann, and Josef van Genabith. 2025. **AIDEN: Automatic Speaker Notes Creation and Navigation for Enhancing Online Learning Experience**. In Proceedings of the 15th International Conference on Recent Advances in Natural Language Processing - Natural Language Processing in the Generative AI Era, pages 1299–1303, Varna, Bulgaria. INCOMA Ltd., Shoumen, Bulgaria.

C. -C. Yen, P. -T. Hsieh, Y. -C. Chen and C. -K. Chang, **Analysis of a Generative AI-Based Graphical Learning Assistance Tool in IPR Courses**, 2025 IEEE International Conference on Advanced Learning Technologies (ICALT), Changhua, Taiwan, 2025, pp. 226-228, doi: 10.1109/ICALT64023.2025.00071.

Elzayyat M, Mohammad JN, Zaqout S. Assessing LLM-generated vs. expert-created clinical anatomy MCQs: a student perception-based comparative study in medical education. **Med Educ Online**. 2025 Dec;30(1):2554678. doi: 10.1080/10872981.2025.2554678.

Jeena A. Thankachan, Bama Srinivasan, Nandini Bhupathy, Automated educational task generation and solution guidance using LLMs and reinforcement learning. **Applied Soft Computing**, Volume 198, 2026, 115301, ISSN 1568-4946, https://doi.org/10.1016/j.asoc.2026.115301.

KARUPPAN, A. Sandana; HARIHARAN, M.; MOORTHY, K. Sunthara; SASHWIN, K.; RAMKUMAR, T. R. **Automated Generation of Context-Aware Assessments using AI and NLP Techniques**. In: 2025 2nd International Conference on Software, Systems and Information Technology (SSITCON). 2025. DOI: 10.1109/SSITCON66133.2025.11342286.

C. C. So, C. H. Lee, D. Yang, A. W. K. Loh and C. K. Sze. Automatic Generation of High-Quality MCQs With LLMs for Artificial Intelligence Education. **IEEE Access**, vol. 13, pp. 184332-184347, 2025, doi: 10.1109/ACCESS.2025.3624820.

VIRAMONTES, Luciano Bermudez. Automating STEM education: an AI driven platform for learning modules. **Artificial Intelligence x Humanities, Education, and Art** (AIxHEART). 2025. p. 134–145. DOI: 10.1109/AIxHEART65685.2025.00028.

D. Kim, S. Won Park and J. Lee. CQELedu: Design and Implementation of a LangChain and GPT-4o Mini-Based Web Application for Custom Question Generation and Error-Based Learning in Education. **IEEE Access**, vol. 13, pp. 208932-208947, 2025, doi: 10.1109/ACCESS.2025.3639087.

Z. Jie and N. Zhuming. **Design of a Dynamic Generation System for Personalized Learning Resources Based on Generative AI and Sparse Attention Mechanisms**. 2025 In: 7th International Conference on Computer Science and Technologies in Education (CSTE), Wuhan, China, 2025, pp. 1125-1129, doi: 10.1109/CSTE64638.2025.11091962.

Achour Khaoula, Lachgar Mohamed, Elloubab Aya, Ait Ouahda Younes, Laanaoui My Driss, Ourahay Mustapha, EduXgame: Gamified learning for secondary education, **Software Impacts**, Volume 24, 2025, ISSN 2665-9638, https://doi.org/10.1016/j.simpa.2025.100761. (https://www.sciencedirect.com/science/article/pii/S2665963825000211)

Mikroyannidis, A., Perifanou, M., & Economides, A. A. (2025). Enhancing Language Learning with Generative AI: The Case of the OpenLang Network Platform. **Computers**, *14*(12), 546. https://doi.org/10.3390/computers14120546

I. D. Zabala, C. Turró Ribalta and J. B. Mataix, Enhancing Educational Content Through AI-Assisted Transformation of Video Transcriptions. **IEEE Digital Education and MOOCS Conference** (DEMOcon), Boca Raton, FL, USA, 2025, pp. 1-6, doi: 10.1109/DEMOcon65705.2025.11282786.

Zhan Tang, Xiaoyu Lu, Nian Yang, Xiaohong Xiang, Xiang Hou, and Xiaoli Peng. **Examination Questions Generation System Based on Soft Knowledge Prompt and Large Language Model.** In: Proceedings of the 2nd Guangdong-Hong Kong-Macao Greater Bay Area Education Digitalization and Computer Science International Conference (EDCS '25). Association for Computing Machinery, New York, NY, USA, 152–156. https://doi.org/10.1145/3746469.3746495

Yuzhe Zhou, Prithvi Manjunatha Babu, Udayan Pandey, Alejandra J. Magana, and Tianyi Li. **ExPeerience:** Support Student-AI Co-Creation in a Learnersourcing Workflow. In Companion Proceedings of the 31st International Conference on Intelligent User Interfaces (IUI '26 Companion). Association for Computing Machinery, New York, NY, USA, 176–179, 2026. https://doi.org/10.1145/3742414.3794774

A. Sharma, S. Shailendra and R. Kadel. **Experiences with Content Development and Assessment Design in the Era of GenAI**. In: 6th International Conference on Computer Science, Engineering, and Education (CSEE), Nanjing, China, 2025, pp. 1-5, doi: 10.1109/CSEE64583.2025.00008.

Xu, T., Liu, Y., Jin, Y., Qu, Y., Bai, J., Zhang, W., & Zhou, Y. (2025). **From recorded to AI-generated instructional videos:** A comparison of learning performance and experience. British Journal of Educational Technology, 56, 1463–1487. https://doi.org/10.1111/bjet.13530

LU, Xiuying. **Generative AI-Based Digital Narrative Content Generation for Ideological and Political Education and Ethical Risk Prevention**. In: 2025 9th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT). 2025. DOI: 10.1109/ISMSIT67332.2025.11267803.

S. Oh, Integration of MATH41 and Generative AI in Pre-Service Mathematics Teacher Education: An Empirical Study on Lesson Design Competency. **IEEE Access**, vol. 13, pp. 128959-128973, 2025, doi: 10.1109/ACCESS.2025.3586593.

X. Yang, X. Xie and R. Cui**. Integration of Intelligent Generation and Education: Research and Practice of AIGC Driven Intelligent Teaching Resources in Universities**. 2025 In: 7th International Conference on Computer Science and Technologies in Education (CSTE), Wuhan, China, 2025, pp. 656-660, doi: 10.1109/CSTE64638.2025.11092085.

S. Wang, J. Iwata and X. Wang, **Language Learning Content Development from Human Effort to AI Generation:** Successes and Challenges. 2025. In: 5th International Conference on Educational Technology (ICET), Chongqing, China, 2025, pp. 255-260, doi: 10.1109/ICET67421.2025.11380641.

Kia Karbasi, Kevin Hong, Mohammad Amin Samadi, & Gregory Pottie. (2025)**. Multi-Agent Collaborative Framework For Math Problem Generation**. In: Proceedings of the 18th International Conference on Educational Data Mining, 613--618 DOI: https://doi.org/10.5281/zenodo.15870246

TALLEDO, Diego; REATEGUI, Caleb; HUILLCA, Vicky. **NLP-Based Mobile Application for the Automatic Generation of Learning Activities in Peruvian Universities**. In: 2025 IEEE XXXII International Conference on Electronics, Electrical Engineering and Computing (INTERCON). 2025. p. 41–46. DOI: 10.1109/INTERCON67304.2025.11244637

J. Lin, Y. Ge, J. Lin and H. Pu, Opportunities and Challenges of AIGC in Smart Education. **International Journal of Crowd Science**, vol. 9, no. 4, pp. 239-250, Dec. 2025, doi: 10.26599/IJCS.2024.9100018.

YUAN, Xu; DING, Zhihan; ZHANG, Zhenyi; ZHOU, Liuxu; ZHOU, Yanbing; GE, Zigang. **Personalized learning resources created by generative artificial intelligence:** A systematic review. In: 11th International Conference on Education and Training Technologies (ICETT). 2025. p. 84–89. DOI: 10.1109/ICETT66247.2025.11137092.

Mohi Reza, Ioannis Anastasopoulos, Shreya Bhandari, and Zachary A. Pardos. 2025. **PromptHive**: Bringing Subject Matter Experts Back to the Forefront with Collaborative Prompt Engineering for Educational Content Creation. In Proceedings of the 2025 CHI Conference on Human Factors in Computing Systems (CHI '25). Association for Computing Machinery, New York, NY, USA, Article 148, 1–22. https://doi.org/10.1145/3706598.3714051

W. -Y. Hwang and I. Q. Utami. SocioMathLLM: A Multimodal Large Language Model Framework for Generating Authentic Mathematical Word Problems Driving Socialization. **IEEE Transactions on Learning Technologies**, vol. 19, pp. 271-285, 2026, doi: 10.1109/TLT.2026.3677266.

Luna Chontal G, Melendez-Armenta RA, Degante-Aguilar E and Fernández-Domínguez FJ (2026) Task automation and instructional planning support with large language models: a systematic review. **Front. Educ**. 11:1733861. doi: 10.3389/feduc.2026.1733861

Balaji, V., Ogange, B. O., & Mays, T. J. (2025). Teacher in the Loop AI (TiL-AI): A Strategy for Empowering Educators in Developing Countries through OER Adaptation. **Journal of Learning for Development**, 12(2), 439-445. https://doi.org/10.56059/jl4d.v12i2.1934

Al Abri, M., Dabbagh, N., Hussain, R. M. R., Elhag, A., & Alsiyabi, M. (2025). The Exploration of Generative Textbooks in Higher Education: A Design-Based Research Intervention. **Education Sciences**, 15(12), 1667. https://doi.org/10.3390/educsci15121667

Sobre o autor(a)

Júlia Hahn Gonçalves

Mestranda em Tecnologias da Informação e Comunicação pelo Programa de Pós-graduação em Tecnologias da Informação e Comunicação (PPGTIC) na Universidade Federal de Santa Catarina (UFSC).

Especialização em Branding & Criação Publicitária pela Universidade do Sul de Santa Catarina (UNISUL - 2017).

Graduação em Publicidade e Propaganda pela Universidade do Sul de Santa Catarina (UNISUL - 2013).

Lattes: http://lattes.cnpq.br/7232477187942359

CAPÍTULO 19

A inserção da inteligência artificial generativa na pós-graduação e seus reflexos na produção acadêmica

Natália de Freitas Silveira

1. Introdução

A capacidade crítica do pesquisador é moldada pela formação e o desenvolvimento da autonomia pessoal, profissional e risco de aprendizagem. O que se discute, no âmbito de programas de pós-graduação, é o comprometimento com o ensino para além do resultado, mas a absorção de conteúdo. A expansão dessas novas tecnologias e uso desenfreado da inteligência artificial generativa (IAG) representa um cenário transformador no ambiente acadêmico.

Ferramentas como ChatGPT, Microsoft Copilot e Google Gemini, baseadas em modelos de linguagem de grande escala (Large Language Models — LLMs), tornaram-se acessíveis ao público em geral a partir de 2022, promovendo mudanças profundas nas formas de produzir, organizar e comunicar o conhecimento científico (GONZALES et al., 2024). Porém nesse contexto, a discussão apresenta nuances ainda mais complexas, uma vez que o que se espera da formação em nível stricto sensu é o desenvolvimento da autonomia intelectual, a escrita científica original e a capacidade crítica do pesquisador.

Os estudantes de pós-graduação têm, de forma automática, incorporado e inserido essas ferramentas em seus métodos de pesquisa. Apesar de ocorrer de forma acelerada, fica passivo o desconhecimento das diretrizes de uso, bem como a utilização de forma ética e fadada à colaboração circunstancial no processo de ensino-aprendizagem. Uma pesquisa realizada por Lopes, Forgas e Cerdà-Navarro (2024, p.7) aponta que 88,6% dos pós-graduandos desconhecem formalmente ferramentas de IAG voltadas à produção textual, mas 84,5% deles indicaram tendência ao uso dessas tecnologias na elaboração de textos acadêmicos.

Silva et al. (2025) e Da Fonseca et al. (2026), confirmam que a produção de textos acadêmicos com auxílio da inteligência artificial é um fenômeno crescente que demanda investigação rigorosa e respostas institucionais articuladas. Essa discussão

ocorre também no âmbito pedagógico e neste ponto de vista, estas ferramentas podem dar suporte e apoio à escrita, pesquisa bibliográfica, estruturação de ideias e síntese de informações e personalização de experiências de aprendizagem em escala (GONZALES et al., 2024; MIYAMOTO, 2024; RIBEIRO et al., 2025). Em contrapartida, suscitam desafios igualmente expressivos, como o risco de enfraquecimento do pensamento crítico, a geração de informações imprecisas ou fabricadas, a dificuldade de detecção de plágio e a ausência de marcos regulatórios nos programas de pós-graduação (BANDEIRA; AQUINO, 2025; COSTA et al., 2025; SAMPAIO; SABBATINI; LIMONGI, 2024).

Esta pesquisa busca responder o seguinte problema: de que modo o uso dessas ferramentas por estudantes de pós-graduação impacta o processo de aprendizagem, a produção científica e a integridade acadêmica? É importante compreender os impactos reais das novas tecnologias e a contribuição dessas ferramentas na formação de cientistas e pesquisadores com níveis avançados de conhecimento.

O objetivo geral deste artigo é analisar, a partir da literatura científica recente, os benefícios e os desafios associados ao uso de ferramentas de Inteligência Artificial Generativa por estudantes de pós-graduação, identificando implicações para a prática acadêmica e perspectivas para a regulamentação e o uso responsável dessas tecnologias. Para melhor entender e refletir sobre esta temática, busca-se caracterizar o panorama das principais ferramentas no contexto acadêmico, identificar os benefícios relatados na literatura, mapear os desafios e riscos, com ênfase na integridade acadêmica e discutir perspectivas e recomendações para a integração ética e pedagógica da IAG nos programas de pós-graduação.

Esta pesquisa tem como intuito reunir e analisar a literatura com base no tema, observando, analisando e podendo servir também para futuras reflexões sobre a IAG e a inserção delas no aprendizado e resultado dos estudantes de programas de pós-graduação.

2 REFERENCIAL TEÓRICO

2.1 Inteligência Artificial Generativa: conceitos e evolução

A inteligência artificial (IA) destaca-se como uma das áreas mais amplas e dinâmicas de pesquisas voltadas às tecnologias na atualidade. De acordo com McCarthy et al. (1955 apud BANDEIRA; AQUINO, 2025), a IA corresponde à habilidade da automatização em simularem comportamentos humanos, concepção estabelecida desde a Conferência de

Dartmouth, em 1956. Desde então, a IA passou por ciclos de avanço e retração até alcançar, nas duas últimas décadas, um estágio de aceleração tecnológica sem

precedentes, impulsionado por investimentos massivos das grandes corporações de tecnologia e pelo aumento exponencial de dados disponíveis (BANDEIRA; AQUINO, 2025).

Tavares, Meira e Amaral (2020), identificaram que os Sistemas Tutores Inteligentes e o Machine Learning aplicado à educação faziam parte, até 2020, das mais seguras linhas de pesquisa. Nesse contexto, pode-se perceber a ampliação dos debates sobre IAG, visto que, essa notoriedade só ganhou espaço após o lançamento do ChatGPT no ano de 2022, ou seja, dois anos após a implementação da IA em contextos educacionais.

Esse panorama evidencia que as discussões sobre IAG representam uma expansão em relação à história, cujo desenvolvimento só ganhou mais notoriedade e atenção após o lançamento do ChatGPT em novembro de 2022. No âmbito desse desenvolvimento, destaca-se a emergência da IAG como conjunto de recursos computacionais capazes de produzir conteúdo novo e realista, incluindo textos, imagens e códigos de programação, a partir de comandos fornecidos pelo usuário (COSTA et al., 2025).

Campos (2024), analisa que a quantidade de publicações sobre essa temática aumentou a partir do ano de 2022, mas ainda apresenta lacunas bastante relevantes em alguns contextos, como é no caso da pós-graduação e produção científica. Da Fonseca et al. (2026), reforçam que a capacidade e desafio de criar conteúdo com originalidade mais contexto, acaba gerando distinção entre gerações anteriores de sistemas automatizados, fazendo com que a IAG seja um fenômeno relevante singular no segmento educacional.

Alves (2023) problematiza os desafios dessa inserção, alertando para a necessidade da capacidade crítica que acompanha a revolução tecnológica, principalmente no que se refere à formação intelectual, acadêmica e ao desenvolvimento do pensamento crítico dos estudantes. No contexto brasileiro, Gonzales et al. (2024) estimam que cerca de 30% das instituições de ensino superior já implementaram alguma forma de IA em seus planos de desenvolvimento educacionais ou administrativos, indicando uma inserção crescente do uso, ainda que desigual, não-regulamentadas completamente e ainda sem fiscalização adequada.

2.2 Ferramentas de IAG na pesquisa científica e na produção textual acadêmica

O fenômeno, que é a utilização da IAG em ambientes acadêmicos e educacionais, principalmente no que se diz à produção do conhecimento e escrita científica, tem gerado grandes questionamentos e controvérsias no que se diz à aplicação dessa inteligência. Silva et al. (2025), identificaram que as ferramentas oferecem suporte em diferentes etapas da produção científica: desde a fase de levantamento e síntese

bibliográfica até a organização estrutural e a revisão gramatical e estilística dos manuscritos. Os autores reconhecem, contudo, que os riscos associados — especialmente no que se refere à autenticidade, à originalidade e à integridade do texto — demandam atenção sistemática por parte das instituições e dos próprios pesquisadores (SILVA et al., 2025).

É possível já observar os resultados demandados da utilização e aplicação dessas ferramentas na produção. Miyamoto (2024), em estudo de caso em uma instituição de pesquisa, documentou ganhos de eficiência na busca e triagem de referências bibliográficas, na sistematização de dados e na elaboração de relatórios preliminares. Dos Santos e Reategui (2025) demonstraram que o uso combinado de IAG e análise de palavras-chave pode colaborar positivamente com o planejamento de projetos de pesquisa no ensino superior. Vasconcelos (2025), em abordagem computacional, identificou padrões textuais que distinguem produções geradas ou fortemente auxiliadas por algoritmos daquelas de autoria predominantemente humana.

A expansão da IAG impacta, de alguma forma, também os serviços de informação e comunicação interna vinculados às universidades. Costa (2025) investigou a influência das tecnologias de IAG nas bibliotecas especializadas e universitárias brasileiras, identificando resultados e demandas na apropriação dessas ferramentas para a prestação de serviços de informação científica como estratégia. Pinheiro, Costa e Vitoriano (2025) exploram a interface entre IA e a condução de informação no ensino superior, destacando que a competência em informação torna-se ainda mais essencial em um contexto em que algoritmos generativos produzem conteúdo em escala, exigindo dos estudantes e pesquisadores maior capacidade de avaliação crítica das fontes.

Da Paixão et al. (2026) apontam que os ganhos de eficiência são reais mas acompanhados de riscos e perspectivas críticas que precisam ser considerados, especialmente em contextos acadêmicos onde o processo de construção do conhecimento maior tem valor — não apenas o produto final. Essa distinção é fundamental para compreender os limites do uso da IAG na pesquisa científica: a ferramenta pode otimizar etapas operacionais, mas não pode substituir o processo genuíno de problematização, análise e interpretação.

2.3 IA na Educação Superior Brasileira e Internacional

Conforme já citado nesta pesquisa, a trajetória da IA na educação superior brasileira tem apresentado crescimento significativo, especialmente a partir de 2022. Junior et al. (2025) identificaram que a inserção dessas tecnologias no ensino superior brasileiro ocorre de forma heterogênea e ainda em falta no quesito sistematização. Gonzales et al. (2024) denominam esse processo de "revolução silenciosa": uma

transformação que não se manifesta em mudanças drásticas e repentinas, mas em inovações que, juntas, alteram o panorama educacional.

Ribeiro et al. (2025), ao observarem os ambientes educacionais inteligentes mediados por IA, apontaram vantagens e desvantagens do uso dessas tecnologias para estudantes, professores e instituições, concluindo que a integração é um caminho sem volta — mas que exige equilíbrio entre potencialidades e riscos. Oliveira, Sobreiro e Mársico (2025) ampliam essa ideia ao analisar especificamente o impacto da IA generativa no ensino e na aprendizagem em nível de graduação, identificando transformações nos modos de aprendizagem dos estudantes e nos formatos de aplicação desses métodos pelos próprios profissionais da educação. Reis (2025) examina a interface entre IAG, metodologias ativas e escolarização aberta, argumentando que a combinação delas pode ampliar o potencial transformador da IA na educação.

Já Da Silva e Kampff (2023), relatam experiência sobre o uso da IAG e identificam que a integração bem-sucedida dessas tecnologias depende de mediação docente qualificada e reflexão sobre os papéis que a ferramenta pode assumir no processo de formação acadêmica — distinguindo entre o uso como suporte ao aprendizado e a utilização indevida como papel principal na construção do conhecimento.

No plano internacional, Bannister, Alcalde Peñalver e Santamaría Urbieta (2023) identificaram que a literatura disponível sobre o tema ainda é escassa, com número limitado de trabalhos relevantes — evidência de que o campo se encontra em estágio inicial de discussão científica. Em contraponto, Ramírez Ochoa, Villagran Vizcarra e Trevizo Zamarrón (2024) contribuem com análise dos impactos das Tecnologias Digitais da Informação e Comunicação com a da IA sobre o futuro da educação, expondo casos de uso em universidades que revelam avanços no acesso à aprendizagem.

Como um dado estritamente relevante para a temática, Arias Ortiz et al. (2025) observam que menos de 10% das escolas e universidades do mundo possuem políticas institucionais ou diretrizes relativas à IAG (UNESCO, 2023). A adoção acelerada de tecnologias na educação, segundo Felix e Fernandes (2022), pode destacar desigualdades quando não há eficácia de políticas públicas que garantam acesso igualitário e discussão democrática sobre seus impactos no sistema. Essa perspectiva é corroborada por Junqueira (2025) que identifica a apropriação crítica e criativa dessas ferramenta.

2.4 O estudante de pós-graduação e a IAG

A formação pressupõe o apontamento de competências específicas como a autonomia intelectual, capacidade cognitiva e crítica, domínio da escrita científica e

engajamento na pesquisa acadêmica. É nesse contexto que, o estudante de pós-graduação se depara com as ferramentas de IAG e seus impactos no processo de aprendizagem e absorção de conteúdo.

O estudo de Lopes, Forgas e Cerdà-Navarro (2024, p.7), realizado com mestrandos e doutorandos em Educação da Universidade de Brasília, aponta dados pouco explorados nesta relação. Os autores identificaram que 88,6% dos pós-graduandos participantes desconhecem a utilização de ferramentas de IAG voltadas à produção textual. Já 84,5% dos mesmos questionados, de forma anônima, indicaram tendência ao uso de IAG na criação, organização e redação de textos acadêmicos. Quando questionados de forma hipotética, 70,6% dos pós-graduandos manifestaram algum receio quanto aos princípios éticos e normas.

Da análise de conteúdo das entrevistas, os autores derivaram uma tipologia de textos produzidos com ou sem auxílio da IAG, sendo eles: o "texto artesanal" (concebido integralmente pelo humano, com marca identitária de estilo próprio); o "texto híbrido: IA e humano" (em que a IAG produz uma base textual que o estudante edita e personaliza); e o "texto padrão" (gerado automaticamente pela IA, sem incidência criativa humana, com tendência à homogeneização) (LOPES; FORGAS; CERDÀ-NAVARRO, 2024). Essa tipologia evidencia que a inserção da IAG na escrita acadêmica é um fenômeno contínuo de possibilidades na formação do pesquisador.

Cunha (2024), ao buscar sobre IA na pós-graduação no Brasil na perspectiva da igualdade de gênero, identificou que a produção científica sobre IA ainda é marcada por sub-representação de mulheres tanto na pesquisa quanto na autoria de trabalhos acadêmicos sobre o tema —, o que amplia a reflexão sobre as implicações sociais dessas tecnologias para além dos contextos pedagógicos e éticos.

2.5 Integridade, autoria e ética na era da IAG

A questão da integridade acadêmica se configura como ponto mais sensível e debatido na relação entre IAG e a educação superior. O texto gerado pela inteligência não é copiado de uma fonte cujo se possa identificar, ele é redigido a partir do cruzamento de padrões de bases de dados, fazendo com que não se enquadre estritamente nas definições de plágio. Para Lopes, Forgas e Cerdà-Navarro (2024), a IA constitui uma nova forma sofisticada de fraude acadêmica, capaz de dificultar ou até mesmo inviabilizar a detecção de similaridade através de software — método este, bastante utilizado pela academia.

Algumas diretrizes são apontadas por Sampaio, Sabbatini e Limongi (2024), em um guia prático para pesquisadores, para o uso ético e responsável da IAG, propondo o uso da IAG como ferramenta de suporte e o uso como substituta da autoria intelectual — eticamente inaceitável. Da Silva Coelho (2026) reforça que a transparência sobre a

produção de um texto científico com o uso de IA, deve ser essencial e ética na pesquisa.

De Brito Pires e Siquelli (2026) identificaram que as principais dimensões éticas discutidas incluem: a questão da autoria e co-autoria com algoritmos; a privacidade e o uso de dados dos estudantes; o viés algorítmico e suas implicações para a equidade educacional; e os impactos sobre o desenvolvimento da agência intelectual dos aprendizes. Muniz, Reis e Kohls-Santos (2026) propõem uma abordagem prática para esses desafios ao sistematizar a construção de trilhas de aprendizagem em IAG — percursos que combinam dimensões técnicas, éticas e pedagógicas, e que podem colaborar à formação de pesquisadores em programas de pós-graduação.

Docentes de pós-graduação, segundo Costa et al. (2025), apontam o risco de plágio como o principal desafio associado ao uso de IAG no contexto acadêmico, ao lado da dependência tecnológica e da falta de reflexão crítica. Bandeira e Aquino (2025) acrescentam a dimensão das "alucinações" da IA — a produção de informações inventadas com aparência de veracidade — como risco pedagógico específico, particularmente problemático quando estudantes delegam ao algoritmo que atue em etapas fundamentais do processo de pesquisa.

2.6 Formação e letramento em IA: o uso pedagógico qualificado

A integração da IAG nos processos educacionais da pós-graduação não depende somente da disponibilidade das ferramentas ou do interesse dos estudantes — ela é condicionada pelo preparo e posicionamento dos docentes diante dessas tecnologias. Salvi (2025) identificou que a maioria dos professores universitários ingressam nesse novo cenário sem formação específica para lidar com as IAGs gerando, desta forma, insegurança. Para Costa et al. (2025) os professores reconhecem a ausência de treinamentos específicos sobre o tema e o desconhecimento de diretrizes normativas que orientem sua atuação em sala de aula.

Santos (2024) reforça que as lacunas não se restringem ao ensino superior — elas constituem um problema sistêmico de todos os níveis educacionais. A dimensão para a formação demonstra urgência em um cenário onde, conforme Bandeira e Aquino (2025), a verdadeira divisão no cenário docente não será entre professores que usam ou não usam IA, mas entre aqueles que dominam com o uso ético e pedagogicamente fundamentado dessas ferramentas versus aqueles que as desconhecem ou as rejeitam.

Junqueira (2025) propõe que a formação em IAG para estudantes universitários deve ser concebida como uma prática de letramento em três dimensões complementares: técnica (saber operar as ferramentas), crítica (saber avaliar resultados e reconhecer limitações) e ética (saber decidir quando e como usar, com responsabilidade sobre os produtos gerados). Teixeira e Da Silva (2025) destacam a

importância de incorporar o ensino de boas práticas de pesquisa — incluindo o uso responsável de IAG — como componente curricular explícito nos programas de pós-graduação. Reis (2025) argumenta que o uso da IAG em ambientes de aprendizagem que privilegiam a autonomia e a resolução de problemas reais potencializa o desenvolvimento do letramento em IA de forma integrada ao processo de formação acadêmica.

2.7 Diretrizes para o uso de IAG nas universidades

A IAG nas universidades públicas brasileiras e suas diretrizes, emergem como um dos principais desafios abordados nas linhas de pesquisas. Gomes (2025) identificou que a maioria das instituições ainda se encontram em estágios iniciais de discussão sobre o tema, sem políticas formalizadas, sem estruturas de decisão específicas e sem mecanismos de monitoramento do uso dessas tecnologias. Paz (2026) avança nessa reflexão ao analisar as diretrizes para o uso de IAG no ensino superior identificando que, onde existem, as diretrizes tendem a adotar uma posição do emprego das ferramentas, desde que com declaração explícita e supervisão docente.

Sampaio, Sabbatini e Limongi (2024) propõem um conjunto de princípios para a instituição de políticas institucionais, organizados em quatro eixos: (1) transparência — declaração obrigatória do uso em qualquer produto científico; (2) responsabilidade — manutenção intelectual e ética pelo pesquisador; (3) qualidade — garantia de que não compromete o rigor metodológico; e (4) equidade — prevenção de assimetrias no acesso às ferramentas.

Arias Ortiz et al. (2025) reforçam que a integração da IA deve basear-se nas lições aprendidas com experiências anteriores de tecnologia educacional, para evitar os contratempos que outras iniciativas precoces precisaram enfrentar. O dado de que menos de 10% das escolas e universidades possuem políticas formais sobre IAG (UNESCO apud ARIAS ORTIZ et al., 2025) reafirma a urgência da ação institucional.

Em perspectiva internacional, Oni e Alade (s/d) argumentam, a partir do contexto do ensino superior na Nigéria, que as reformas das universidades devem alinhar-se às demandas de uma sociedade crescentemente conectada e tecnológica, o que inclui a formulação de políticas institucionais que integrem as tecnologias emergentes de forma estratégica e orientada para o desenvolvimento humano e social.

Embora no cenário africano, esse argumento combina com demandas identificadas nas universidades brasileiras, sugerindo que os desafios da governança da IA no ensino superior são de natureza global. Por esse olhar, aponta-se o papel do Estado e das instituições públicas na definição da regulamentação para o uso de IA na educação.

3. Metodologia

3.1 Caracterização da pesquisa

O presente estudo caracteriza-se como uma pesquisa de natureza qualitativa, com abordagem exploratória e descritiva (GIL, 2008). Quanto aos procedimentos técnicos, adota-se a revisão de literatura como método central de investigação, orientada pelo método SSF (Systematic Search Flow — Fluxo de Busca Sistemática), desenvolvido por Ferenhof e Fernandes (2016) na Universidade Federal de Santa Catarina. O SSF organiza a revisão de literatura em três fases sequenciais e interdependentes — Protocolo e Busca, Análise e Síntese, e Escrita da Revisão —, proporcionando um fluxo sistemático e transparente de busca, triagem e síntese da produção científica sobre a temática proposta.

3.2 Fase 1 — Protocolo e Busca

A questão norteadora da pesquisa consiste em compreender de que forma o uso de ferramentas de Inteligência Artificial Generativa (IAG) por estudantes de pós-graduação influencia o processo de aprendizagem, a produção científica e a integridade acadêmica, considerando tanto suas potencialidades quanto os desafios decorrentes de sua utilização. Os eixos temáticos e os respectivos descritores de busca, organizados para orientar a etapa de identificação de estudos, estão sintetizados no Quadro 1.

Quadro 1 — Eixos temáticos e descritores de busca

Eixo	Descritores utilizados
1 - Ferramentas de IA	inteligência artificial generativa; ChatGPT; LLM
2 - contexto educacional	pós-graduação; ensino superior
3 - Impactos	integridade acadêmica; plágio; escrita acadêmica; benefícios; desafios

Fonte: elaborado pela autora (2026)

As buscas foram realizadas nas bases Google Acadêmico, Scopus, SciELO e Portal de Periódicos CAPES, selecionadas por sua representatividade e complementaridade na cobertura da produção científica nacional e internacional sobre o tema, com delimitação temporal entre 2020 e 2026. Os três eixos do Quadro 1 foram combinados

por meio de operadores com adaptações de sintaxe, em cada uma das quatro bases.

Neste trabalho, foi utilizada Inteligência Artificial Generativa (IA Claude, Anthropic) conforme a Política de Integridade na Atividade Científica do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), instituída pela Portaria de março de 2026, como apoio à busca de multiplicidade de autores, à estruturação e à correção ortográfica do texto. O uso da ferramenta não substituiu o processo de pesquisa: nenhuma seção do trabalho foi gerada e submetida como de autoria humana sem revisão e validação criteriosa por parte da responsável pela pesquisa, constituindo, assim, uma literatura híbrida.

3.3 Fase 2 — Análise e Síntese (seção inteiramente nova)

Após a execução das buscas, os registros recuperados em cada base foram submetidos a um processo de triagem em duas etapas — leitura de títulos, seguida de leitura de resumos —, e os estudos remanescentes foram avaliados na íntegra à luz dos critérios de elegibilidade descritos na seção 3.4. O Quadro 2 documenta o protocolo de registro das buscas, com o volume de registros recuperados e triados em cada base.

Quadro 2 - Protocolo de registro das buscas

Base de dados	Total recuperado	Após título	Após resumo	Incluídos
Google Acadêmico	≈ 1.400	≈ 90	≈ 35	≈ 20
Scopus	≈ 250	≈ 70	≈ 32	≈ 24
SciELO	≈ 28	≈ 15	≈ 9	≈ 7
Portal CAPES	≈ 800	≈ 110	≈ 37	≈ 22
Total (bruto, pré-deduplicação)	≈ 2.480	≈ 285	≈ 113	≈ 73
Total após remoção de duplicatas entre bases	—	—	—	≈ 35

Fonte: elaborado pela autora, a partir da string do Quadro 1 aplicada em cada base (recorte 2020–2026).

O fluxo de seleção resultante — da identificação nas quatro bases até a inclusão final, passando pela triagem por título, pela triagem por resumo e pela remoção de duplicatas entre bases — está representado na Figura 1.

Figura 1 – Fluxograma de seleção dos estudos (método SSF)

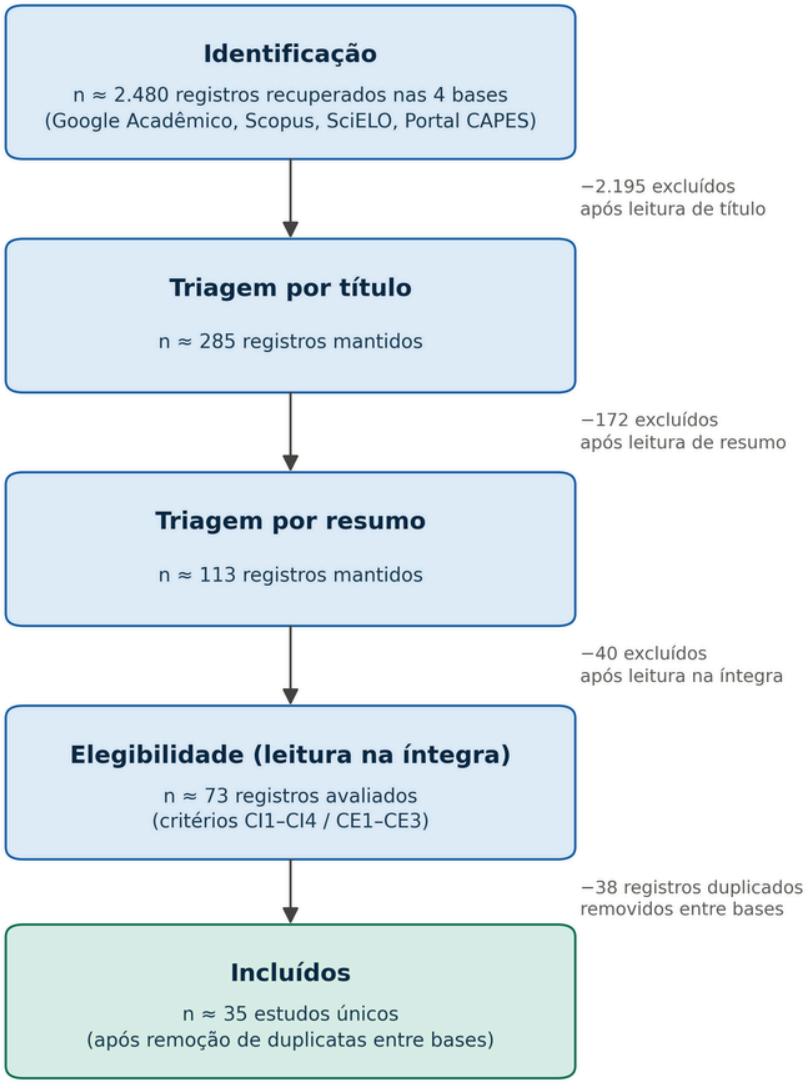

Fonte: elaborado pela autora, com base no protocolo do Quadro 2.

Os estudos aprovados após a leitura na íntegra foram sistematizados em uma matriz de síntese temática, organizada em torno de três categorias analíticas centrais: (a) benefícios do uso da IAG por estudantes de pós-graduação; (b) desafios e riscos associados a essa incorporação; e (c) perspectivas e recomendações para uma integração ética e pedagogicamente fundamentada. O Quadro 3 apresenta a síntese comparativa de sete estudos centrais, evidenciando objetivo, metodologia e principais resultados de cada um — elemento que subsidia diretamente a análise crítica desenvolvida na Seção 4.

Quadro 3 — Síntese comparativa dos estudos selecionados

Autor(es) / Ano	Objetivo	Metodologia	Principais resultados
Lopes, Forgas e Cerdà-Navarro (2024)	Analisar a percepção de mestrandos e doutorandos em Educação (UnB) sobre a produção textual com uso de IA	Método misto: questionário + entrevistas semiestruturadas; análise de conteúdo temático-categorial (Bardin, 2011); testes qui-quadrado	88,6% desconheciam formalmente ferramentas de IAG; 84,5% indicaram tendência ao uso; tipologia de três perfis textuais (artesanal, híbrido, padrão)
Costa et al. (2025)	Investigar a percepção docente sobre desafios e oportunidades da IA na COPPE/UFRJ	Estudo de caso único (Yin, 2001): análise documental institucional + duas entrevistas com chefes de área	Potencial para gestão administrativa e acompanhamento de orientandos; risco de dependência tecnológica; ausência de políticas formalizadas
Gonzales et al. (2024)	Investigar como a IA transforma a educação superior no Brasil	Pesquisa bibliográfica + estudo de caso múltiplo em 3 IES; bases SciELO, Google Scholar, CAPES; recorte 2013–2023	Cunhou o termo "revolução silenciosa"; ≈30% das IES já implementaram alguma forma de IA, de modo heterogêneo e pouco regulado
Ribeiro et al. (2025)	Explorar desafios, vantagens e desvantagens da IA para alunos, professores e instituições	Pesquisa bibliográfica qualitativa/exploratória; bases CAPES e SciELO; últimos 5 anos, textos em português	Vantagens (personalização, engajamento) e desvantagens (dependência tecnológica, perda de habilidades sociais) equilibradas entre os três públicos

continua

continuação

Bannister, A. P. e Santamaría U. (2023)	Mapear a literatura sobre IAG em Ensino Superior com Instrução em Inglês (EMI)	Revisão sistemática com protocolo PRISMA (Page et al., 2021); Google Scholar, Scopus, Web of Science, ERIC	138 artigos recuperados, 70 excluídos pelos critérios, 68 incluídos; campo em estágio inicial, com lacunas expressivas
Arias Ortiz et al. — BID (2025)	Propor um marco de integração da IA à educação na América Latina e Caribe	Nota técnica institucional; revisão de literatura estruturada em torno de 3 objetivos de política pública	Menos de 10% das escolas/universidades do mundo têm políticas formais sobre IAG; impacto depende das condições de implementação
Ramírez O., Villagran V. e Trevizo Z. (2024)	Investigar a intersecção entre TIC e IA na educação, com foco em acesso e personalização	Revisão sistemática (MIR); IEEE Xplore, ScienceDirect, SpringerLink, Scopus, Google Scholar; recorte 2010–2024	Casos de sucesso (Stanford, Georgia State "Pounce"); benefícios de acesso/personalização; riscos de brecha digital e formação docente

Fonte: elaborado pela autora (2026)

3.4 Critérios de seleção e corpus final

Foram adotados como critérios de inclusão: (CI1) publicações entre 2020 e 2026; (CI2) artigos revisados por pares ou trabalhos acadêmicos com banca avaliadora; (CI3) estudos que abordam o uso de IAG no contexto educacional, com ênfase na educação superior e/ou pós-graduação; (CI4) textos em português, inglês ou espanhol. Os critérios de exclusão foram: (CE1) artigos sobre IA em contextos não educacionais; (CE2) textos de opinião sem base empírica ou teórica sólida; (CE3) trabalhos publicados anteriormente a 2020, ressalvados os de referência teórica fundante. O corpus bibliográfico final integra estudos empíricos, revisões sistemáticas, revisões integrativas, estudos de caso e análises documentais, conforme sintetizado no Quadro 3.

3.5 Fase 3 — Escrita da Revisão

A última fase do método corresponde à redação da revisão propriamente dita, na qual os achados sistematizados na matriz de síntese temática (Fase 2) são articulados e analisados — benefícios, desafios e perspectivas — e apresentados de forma crítica, com ênfase nas convergências e divergências entre os estudos consultados. É essa organização que estrutura a Seção 4 deste artigo, na qual os resultados são discutidos não como uma lista sequencial de achados, mas como um diálogo entre autores e abordagens metodológicas distintas.

4. Resultados e discussão

A análise da literatura selecionada permitiu identificar três grandes eixos temáticos: os benefícios associados ao uso de ferramentas de IAG por estudantes de pós-graduação; os desafios e riscos decorrentes dessa incorporação; e as perspectivas e recomendações para uma integração ética e pedagogicamente fundamentada. Um dos benefícios mais recorrentes diz respeito ao papel da IAG como apoio ao processo de escrita acadêmica. Silva et al. (2025) confirmam o suporte à escrita. Da Silva e Kampff (2023) apontam que estudantes que integraram IAG ao processo de escrita relataram maior fluidez na organização das ideias.

No âmbito da pesquisa bibliográfica, Miyamoto (2024) documentou ganhos concretos na triagem e síntese de referências. Costa (2025) identificou ainda que as bibliotecas universitárias têm explorado essas ferramentas para aprimorar seus serviços de informação científica, beneficiando diretamente pesquisadores vinculados a programas de pós-graduação.

Costa et al. (2025) corroboram: professores da COPPE/UFRJ identificaram no uso da IA potencial significativo para a gestão de rotinas administrativas e o acompanhamento acadêmico de orientandos. Da Paixão et al. (2026) confirmam que os ganhos de produtividade proporcionados pela IAG são reais, especialmente em tarefas de síntese, sistematização e formatação.

Costa et al. (2025) registraram, nas falas de docentes de pós-graduação, a preocupação com o fato de que o uso irrestrito da IAG pode gerar dependência tecnológica — comprometendo a capacidade de problematização autônoma que define o pesquisador. Alves (2023) problematiza especificamente o impacto sobre a criatividade e a originalidade, alertando que a naturalização do uso da IAG na produção acadêmica pode resultar em uma homogeneização progressiva das produções científicas, empobrecendo a diversidade intelectual que caracteriza o avanço do conhecimento.

Felix e Fernandes (2022), em perspectiva crítica, alertam que a ausência de

regulação favorece a privatização da agenda educacional pela IA, transferindo poder decisório sobre processos pedagógicos fundamentais de instâncias públicas para empresas privadas de tecnologia.

Os fundamentos da autoria ainda acadêmica ainda são questionados por De Almeida e Da Cruz (2025) na era da IAG. Da Silva Coelho (2026) e De Brito Pires e Siquelli (2026) convergem ao identificar que o debate sobre autoria ainda carece de consenso. Bannister, Alcalde Peñalver e Santamaría Urbieta (2023) confirmam, em perspectiva internacional, que mesmo em contextos com maior tradição de pesquisa em IA, as questões éticas relacionadas à autoria permanecem em aberto, sem respostas institucionais consolidadas.

Ao confrontar diretamente os estudos sistematizados no Quadro 3, observa-se convergência entre Arias Ortiz et al. (2025), Ribeiro et al. (2025) e Gonzales et al. (2024) quanto à ideia de que o impacto da IA depende menos da tecnologia em si e mais das condições de implementação — formação docente, infraestrutura e governança institucional. Já quanto à natureza do risco central, os estudos divergem conforme o público investigado: para Lopes, Forgas e Cerdà-Navarro (2024), que ouviram estudantes de pós-graduação, o risco predominante é o de uma fraude acadêmica sofisticada, de difícil detecção por software de similaridade.

Para Costa et al. (2025), que ouviram docentes da COPPE/UFRJ, o risco mais citado é a dependência tecnológica e o enfraquecimento da problematização autônoma. Essa diferença sugere que a percepção do risco varia conforme o papel do sujeito na relação com a ferramenta — quem escreve teme a fraude, quem orienta teme a dependência. A divergência de ênfase é reforçada pela constatação de Bannister, Alcalde Peñalver e Santamaría Urbieta (2023) de que a produção científica internacional sobre IAG no ensino superior ainda é escassa (68 estudos incluídos, de um universo inicial de 138 recuperados), o que ajuda a explicar por que a literatura carece, até o momento, de consenso sobre qual risco deveria ser tratado como prioritário nas políticas institucionais.

A literatura converge no entendimento de que a resposta mais adequada ao fenômeno da IAG na pós-graduação não é a proibição nem a permissividade, mas o letramento. Junqueira (2025) propõe três dimensões complementares: técnica, crítica e ética. Paz (2026) identifica que universidades pioneiras adotam a posição de "uso condicionado". Lopes, Forgas e Cerdà-Navarro (2024) argumentam que essas diretrizes devem emergir de construção coletiva entre docentes, pesquisadores e estudantes. Bannister, Alcalde Peñalver e Santamaría Urbieta (2023) recomendam que as instituições invistam em pesquisa empírica sobre o uso real da IAG por seus estudantes como ponto de partida para a elaboração de políticas eficazes e contextualizadas.

Bandeira e Aquino (2025) enfatizam que sem políticas públicas de capacitação

docente e de inclusão digital, a IA tende a aprofundar desigualdades. Arias Ortiz et al. (2025) sugerem que os governos utilizem a IA de forma estratégica para melhorar os sistemas educacionais em todos os níveis, integrando o planejamento a uma visão estratégica de transformação digital.

5. Considerações finais

Este estudo teve como intuito analisar, com base na literatura científica e bibliográfica, os desafios relacionados à inserção da IAG (Inteligência Artificial Generativa) na aplicação de estudos voltados aos programas de pós-graduação acadêmica. Principalmente, no uso dessas ferramentas e novas tecnologias, no desenvolvimento de pesquisas e textos científicos durante a prática na academia

Analisando estudos publicados entre 2020 e 2026, notou-se que a propagação e popularização da IA deu-se num período pós-pandêmico, momento da história em que as pessoas passaram a ter mais contato e, até mesmo, entender a necessidade de se adaptar às novas tecnologias e ao âmbito virtual. Em 2022, com a intensa propagação do ChatGPT, a discussão também foi ampliada no contexto educacional no Brasil.

A partir desse diálogo, há o debate também pela conversão entre a inserção da IA nos métodos de ensino-aprendizado, tanto quanto para a regulamentação que deve beirar os sistemas automatizados e tecnológicos, criando assim novas regras e diretrizes a serem seguidas pelos usuários.

Com essa pesquisa, foi possível identificar que os estudantes também duelam entre o desconhecimento formal dessas ferramentas, mas também o uso propenso da IA, visto que muitos acabam refletindo ainda sobre as questões éticas e de regulação institucional.

O impacto da IAG é, ainda que promissor, também desafiador. Como benefícios, anotou-se o apoio às pesquisas, a busca pelo referencial teórico, estruturação e planejamento desses projetos acadêmicos. Além disso, também foi possível avaliar que, alguns autores entendem, como ganho de produtividade e um acesso democrático ao conhecimento.

Já enquanto desafio para esta temática, avaliou-se a discussão sobre autoria e co-autoria quando se tem um projeto científico escrito utilizando das ferramentas de inteligência, quais os limites para essa utilização e como esse contato com essas tecnologias segmentadas e automatizadas podem causar risco de dependência tecnológica. Outro ponto importante a se destacar é em função dos marcos regulatórios e como eles serão desenvolvidos dentro dos próprios métodos disciplinares e educacionais nas instituições de ensino.

A contribuição desta pesquisa está na discussão e debate amplo sobre evidências e perspectivas brasileiras, mas também internacionais, sobre um tema que — ainda que

urgente — necessita de mais estudos abordando especificamente a inserção dessas ferramentas no contexto de pós-graduação, e como essa popularização tecnológica deve refletir no futuro educacional.

Para tanto, a tipologia de textos proposta por Lopes, Forgas e Cerdà-Navarro (2024), articulada com os princípios éticos de Sampaio, Sabbatini e Limongi (2024), as trilhas de aprendizagem de Muniz, Reis e Kohls-Santos (2026) e as orientações normativas de Paz (2026), analisam com praticidade e utilidade para que programas de pós-graduação possam avançar na inserção de suas políticas de uso de IAG.

Uma das principais limitações deste artigo é o fato de que parte das referências utilizadas é composta por trabalhos muito recentes — visto que todas essas discussões ainda são muito novas neste cenário. Soma-se a essa limitação o caráter estimado dos números do protocolo de busca sistematizados no Quadro 2, que aguardam confirmação com os valores de cada base de dados consultada.

Buscando redescobrir esse novo formato de escrita científica, com a colaboração da Inteligência Artificial Generativa, é possível redesenhar esses novos métodos para que se amplie a bagagem de autoria própria, embasamento teórico e produção de conhecimento científico e acadêmico. Além disso, entende-se a necessidade da participação do Estado no desenvolvimento de políticas públicas que garantam o acesso à tecnologia à sociedade.

Conclui-se, por fim, que as instituições educacionais e de ensino superior devem assumir o protagonismo nessa reformulação metodológica e de planejamento de ensino-aprendizagem em programas de pós-graduação e à comunidade acadêmica, reforçando o compromisso ético e crítico na formação de pesquisadores e futuros cientistas, capazes de utilizar dessas ferramentas para a produção de conteúdos relevantes e de interesse social.

Referências

ALVES, Lynn. I**nteligência artificial e educação:** refletindo sobre os desafios contemporâneos. Brasil, 2023.

ARIAS ORTIZ, Elena; CASTRO, Nicolás; FORERO, Tatiana; GAMBI, Gabriela; GIAMBRUNO, Cecilia; PÉREZ-ALFARO, Marcelo; RODRÍGUEZ-SEGURA, Daniel**. IA e educação:** construindo o futuro pela transformação digital. Notas Técnicas, n. IDB-TN-03122. Washington: Banco Interamericano de Desenvolvimento (BID), Divisão de Educação, abr. 2025.

BANDEIRA, Yris Araújo; AQUINO, Francisco José Alves de. Futuro da educação com inteligência artificial: euforia ou revolução? Rev. Nova Paideia — **Revista Interdisciplinar em Educação e Pesquisa**, Brasília/DF, v. 7, n. 1, p. 315-331, jan./abr. 2025. ISSN 2674-5976.

BANNISTER, Peter; ALCALDE PEÑALVER, Elena; SANTAMARÍA URBIETA, Alexandra. A systematic review of generative AI and (English Medium Instruction) higher education. **Aula Abierta**, v. 52, n. 4, p. 401-409, out./dez. 2023. DOI: https://doi.org/10.17811/rifie.52.4.2023.401-409

BRASIL. Ministério da Ciência, Tecnologia e Inovações (MCTI). **Estratégia brasileira de inteligência artificial (EBIA)**. Brasília: MCTI, 2021.

CAMPOS, Mara Jane de Oliveira. **Inteligência artificial generativa e educação: uma leitura a partir de revisão bibliográfica sistemática**. 2024. Dissertação — Universidade Estadual Paulista (Unesp), 2024.

COSTA, Ana Cristina Soares da. **A influência das tecnologias de inteligência artificial generativa nas bibliotecas especializadas e universitárias brasileiras**: análise das experiências e desafios na apropriação para a prestação de serviços. 2025. Trabalho acadêmico — [Instituição], 2025.

COSTA, Marcelle Feitoza Bassi et al. Desafios e oportunidades da inteligência artificial no ensino superior: percepções dos docentes no ambiente universitário. Avaliação: **Revista da Avaliação da Educação Superior**, Campinas, Sorocaba, v. 30, e025003, 2025. DOI: http://dx.doi.org/10.1590/1982-57652025v30id286435

CUNHA, Leila Aparecida dos Santos Motta. **A ciência como fator da igualdade de gênero na era da inteligência artificial:** um panorama sobre a pesquisa de IA na pós-graduação no Brasil. 2024. Dissertação — Universidade Federal de Minas Gerais, 2024.

DA FONSECA, Elson Max Fernandes et al. Inteligência artificial generativa na educação: implicações pedagógicas, cognitivas e éticas — revisão integrativa. **Revista Tópicos**, v. 4, n. 31, p. 1-21, 2026.

DA PAIXÃO, Joelson Lopes et al. Inteligência artificial generativa e produtividade humana: ganhos, riscos e perspectivas críticas para o trabalho na era digital. **Cadernos de InterCulturas**, v. 1, n. 1, p. 72-95, 2026.

DA SILVA, Diego Scherer; KAMPFF, Adriana Justin Cerveira. **A inteligência artificial generativa como ferramenta educativa:** perspectivas futuras e lições de um relato de experiência. 2023. Trabalho acadêmico — [Instituição], 2023.

DA SILVA COELHO, Iandra Maria Weirich. Comunicação científica e inteligência artificial: possibilidades e desafios éticos. Educitec — **Revista de Estudos e Pesquisas sobre Ensino Tecnológico**, v. 12, e299326, jan./dez. 2026.
tárias, 2025. p. 1-13.

DE ALMEIDA, Adriana; DA CRUZ, Andréia Gomes. Educação superior e desafios contemporâneos na produção do conhecimento: contradições entre autoria, pesquisa e inteligência artificial. **Revista Interinstitucional Artes de Educar**, v. 11, n. 1, p. 292-310, 2025.

DE BRITO PIRES, Anna Luíza; SIQUELLI, Sônia Aparecida. Inteligência artificial e ética no ensino superior: uma análise da produção científica. Revista Cactácea — **Educação, Filosofia**, v. 6, n. 16, 2026.

DOS SANTOS, Rafael Antunes; REATEGUI, Eliseo Berni. Uso de inteligência artificial generativa e análise de palavras-chave para apoiar o planejamento de projetos de pesquisa no ensino superior. **Revista Latinoamericana de Tecnología Educativa** — RELATEC, v. 24, n. 2, p. 87-104, 2025.

FELIX, Cleiton; FERNANDES, Claudia. O futuro da educação é on-line? Discussão sobre tecnologia e educação a partir de uma visão crítica. **Acervo**, Rio de Janeiro, v. 35, n. 1, p. 1-14, jan./abr. 2022.

FERENHOF, H. A.; FERNANDES, R. F. Desmistificando a revisão de literatura como base para redação científica: método SSF. **Revista ACB**: Biblioteconomia em Santa Catarina, Florianópolis, v. 21, n. 3, p. 550-563, 2016.

GIL, Antonio Carlos. **Métodos e técnicas de pesquisa social.** 6. ed. São Paulo: Atlas, 2008.

GOMES, Maria Gabrielle Soares. **A adoção da governança da inteligência artificial generativa em universidades públicas brasileiras**. 2025. Dissertação — [Instituição], 2025.

GONZALES, Anderson et al. Revolução silenciosa: como a inteligência artificial está transformando o futuro da educação superior**. Revista ARACÊ**, São José dos Pinhais, v. 6, n. 2, p. 1567-1586, 2024. DOI: https://doi.org/10.56238/arev6n2-068

JUNIOR, José Evaldo Gonçalves Lopes et al. Inteligência artificial no ensino superior: avanços, desafios éticos e contribuições para a excelência acadêmica. **Caderno Pedagógico**, v. 22, n. 9, e18347, 2025.

JUNQUEIRA, Eduardo. Inteligência artificial generativa e estudantes universitários no contexto dos multiletramentos. **Revista Docência e Cibercultura,** v. 9, n. 1, p. 1-17, 2025.

LOPES, Carlos; FORGAS, Rubén Comas; CERDÀ-NAVARRO, Antoni. Tese de doutorado em educação escrita por inteligência artificial? **Revista Brasileira de Educação,** v. 29, e290065, 2024. DOI: https://doi.org/10.1590/S1413-24782024290065

MIYAMOTO, Priscila Barbosa. **Benefícios de uso da inteligência artificial generativa no processo de pesquisa científica:** um estudo de caso em uma instituição de pesquisa. 2024. Trabalho acadêmico — [Instituição], 2024.

MUNIZ, Aline Barbosa Xavier; REIS, Gauss Catarinozi; KOHLS-SANTOS, Pricila. Construindo trilhas de aprendizagem em inteligência artificial generativa. **ETD — Educação Temática Digital**, v. 28, e026010, 2026.

OLIVEIRA, Mariana Ferreira; SOBREIRO, Leila Gatti; MÁRSICO, Eliane Teixeira. Revolução digital na graduação: o impacto da IA generativa no ensino e aprendizado. **A Inteligência Artificial em Debate**, p. 82, 2025.

ONI, Adesoji A.; ALADE, Ibiwumi A. The future of higher education in Nigeria. In: **Towards quality in African higher education.** [S.l.: s.n.], [s.d.]. p. 307-318.

PAZ, Aline Amaral. Diretrizes para o uso de inteligência artificial generativa no ensino superior: orientações a partir de documentos de universidades brasileiras. **Educitec — Revista de Estudos e Pesquisas sobre Ensino Tecnológico**, v. 12, e274726, jan./dez. 2026.

PINHEIRO, Maria Heldaiva Bezerra; COSTA, Marcos Rogério Martins; VITORIANO, Maria Albeti Vieira. A interface entre inteligência artificial e letramento informacional no ensino superior: contextos, avanços e desafios inter e multidisciplinares. **Encontros Bibli**, v. 30, e103105, 2025. SciELO Brasil.

RAMÍREZ OCHOA, Miriam del Carmen; VILLAGRAN VIZCARRA, Ana Cristina; TREVIZO ZAMARRÓN, Marcela. DTIC e IA, el futuro de la educación: mejorando el acceso y la efectividad del aprendizaje. **Revista Electrónica Científica de Investigación Educativa** — RECIE, v. 8, e2309, 2024.

REIS, Cristina da Silva. **Inteligência artificial generativa, metodologias ativas e escolarização aberta:** desafios e potencialidades no ambiente educacional no ensino superior. 2025. Trabalho acadêmico — [Instituição], 2025.

RIBEIRO, Elenilda da Costa Moreira et al. Ambientes educacionais inteligentes: o futuro do aprendizado mediado por IA. **Missioneira**, Santo Ângelo, v. 27, n. 7, p. 219-228, 2025. DOI: https://doi.org/10.46550/w3pa9565

SALVI, Leonardo Monari. **Formação docente na era da inteligência artificial:** desafios e possibilidades — uma revisão sistemática da literatura. Florianópolis, SC, 2025.

SAMPAIO, Rafael Cardoso; SABBATINI, Marcelo; LIMONGI, Ricardo. Diretrizes para o uso ético e responsável da inteligência artificial generativa: um guia prático para pesquisadores. **Boletim Técnico do PPEC**, v. 10, e025003, 2024.

SANTOS, Mayke Franklin da Cruz. **Inteligência artificial na formação docente**: desafios, possibilidades e capacitação para a educação básica. 2024. Trabalho acadêmico — Instituto Federal Goiano, 2024.

SILVA, Jimmy Naially; OLIVEIRA, Rebeca Trajano; DA SILVA, Elizabeth Maria. Potencialidades e desafios do uso de inteligência artificial generativa na produção de textos acadêmicos: uma revisão sistemática. **Revista Docência do Ensino Superior**, v. 15, p. 1-23, 2025.

TAVARES, Luis Antonio; MEIRA, Matheus Carvalho; AMARAL, Sergio Ferreira do. Inteligência artificial na educação: survey. **Brazilian Journal of Development**, Curitiba, v. 6, n. 7, p. 48699-48714, jul. 2020. DOI: 10.34117/bjdv6n7-496

TEIXEIRA, Mariana Pedroso; DA SILVA, Wanilson Luiz. **A importância do ensino de boas práticas de pesquisa na era da inteligência artificial.** In: XXIII Seminário Nacional de Bibliotecas Universitárias, 2025. p. 1-13.

UNESCO — Organização das Nações Unidas para a Educação, a Ciência e a Cultura. **AI and education:** guidance for policy-makers. Paris: UNESCO, 2021.

VASCONCELOS, Guilherme Ayres. **Avaliação sobre a inteligência artificial generativa em escrita acadêmica:** uma abordagem computacional. 2025. Trabalho acadêmico — Universidade La Salle, 2025.

VEIGA, Aroldo César Paiva. **Dilemas e critérios para o uso da inteligência artificial generativa no ensino superior:** uma análise documental. In: Simpósio Internacional de Educação e Comunicação — SIMEDUC, n. 12, 2025.

Sobre o autor(a)

Natália de Freitas Silveira

Pós-graduada em Jornalismo Investigativo e em Jornalismo Digital pelo Centro Universitário Internacional (UNINTER - 2025 e 2026).

Graduação em Jornalismo pela Associação Beneficente da Indústria Carbonífera de Santa Catarina (UniSATC - 2018).

Jornalista local através da Post TV e Jornal Enfoque Popular.

Lattes: http://lattes.cnpq.br/4460678153192208

Sobre as organizadoras

Eliane Pozzebon

É professora titular do Departamento de Computação da Universidade Federal de Santa Catarina (UFSC), com atuação na área de computação, com ênfase em inteligência artificial. Desde 2013, coordena o Laboratório de Tecnologias Computacionais (LabTeC-UFSC) e, entre 2017 e 2018, foi coordenadora do curso de Engenharia de Computação da UFSC. É líder do Grupo de Pesquisa em Tecnologias Computacionais (CNPq) e coordena diversos projetos de inovação tecnológica, entre eles o HoloAnaPath (holoanapath.ufsc.br), MIGMA (migma.ufsc.br) , RAEscolas (raescolas.ufsc.br) e o Tutor Inteligente MAZK (mazk.ufsc.br). Possui pós-doutorado em Computação, com foco em Inteligência Artificial, pelo Programa de Pós-Graduação em Computação da Universidade Federal do Rio Grande do Sul (UFRGS). É doutora em Engenharia Elétrica, com ênfase em Automação e Sistemas, pela UFSC (2008), mestre em Ciência da Computação pela UFSC (2003), especialista em Engenharia de Software (1999) e graduada em Processamento de Dados (1998). Sua produção científica e tecnológica concentra-se nas áreas de inteligência artificial, tutores inteligentes, reconhecimento de expressões faciais, tecnologias imersivas e inclusão de mulheres na computação.

Lattes: http://lattes.cnpq.br/9999217523842385

Sobre as organizadoras

Tatiana Nilson dos Santos

É bolsista de pós-doutorado júnior da Universidade Federal de Santa Catarina (UFSC) pelo Programa de Pós-Graduação em Tecnologias da Informação e Comunicação (PPGTIC) e professora regente na Unicesumar. Desde 2013 é membro do Laboratório de Tecnologias Computacionais (LabTeC-UFSC) e atualmente auxilia na coordenação do projeto Meninas Digitais: Integrando Universidades, Institutos e Escolas. É doutora em Engenharia e Gestão do Conhecimento com ênfase em Mídias Digitais para Surdos pela UFSC (2025), mestre em Tecnologias da Informação e Comunicação, com ênfase em Tecnologias Educacionais, pela UFSC (2017), especialista em Tecnologias para Educação Profissional e Tecnológica, pelo IFSC (2020), graduada em Tecnologias da Informação e Comunicação, pela UFSC (2014) e graduada em Pedagogia, pela Universidade Norte do Paraná (UNOPAR) (2013). Sua produção científica e tecnológica concentra-se nas áreas de games na educação, ludicidade e tecnologias aplicadas ao processo de ensino e aprendizagem, gamificação, e-learning, inteligência artificial.

Lattes: http://lattes.cnpq.br/8372325192731922