REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

INTELIGÊNCIA ARTIFICIAL E EDUCAÇÃO: ENTRE A INOVAÇÃO TECNOLÓGICA E OS DESAFIOS ÉTICOS

ARTIFICIAL INTELLIGENCE AND EDUCATION: BETWEEN TECHNOLOGICAL INNOVATION AND ETHICAL CHALLENGES

INTELIGENCIA ARTIFICIAL Y EDUCACIÓN: ENTRE LA INNOVACIÓN TECNOLÓGICA Y LOS DESAFÍOS ÉTICOS

Alessandra Barboza Barros Almeida
Doutoranda em Ciências da Educação
Universidade Christian Business School, Brasil
E-mail: alessandrabbalmeida@gmail.com

Leandro Alfredo Dos Santos Silva
Mestrando em Geografia
Universidade Federal de Campina Grande - PB, Brasil
E-mail: leandroalfredi@gmail.com

Idelvan Nascimento da Silva
Especialista em Ensino de Ciências
Universidade Estadual Do Maranhão, Brasil
E-mail: jaylogaray61@gmail.com

Luciane Batista Teixeira
Mestrado Profissional em Ensino de Biologia
Universidade Federal do Piaui, Brasil
E-mail: lucianebtx@gmail.com

Fernanda Nascimento Almeida
Mestranda em Ciências da Educação
Instituto Federal da Bahia – IFBA, Brasil
E-mail: fernanda.nascimento@educacao.rr.gov.br

Ricardo Normando Ferreira de Paula
Doutorado em Ciências da Computação
Universidade Estadual do Ceará, Brasil
E-mail: ricardo.normando@prof.ce.gov.br

Analieze Aparecida Leopoldino
Doutorado em Ciências da Educação
Universidade Federal de Santa Catarina, Brasil
E-mail: analieze@gmail.com

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

Cláudia Pelicao Camargo Bahia
Psicologa Especialista em Psicopedagogia Clínica em Abordagens Institucional e Terapêutica
Universidade Luterana do Brasil, Brasil
E-mail: claudiapelicaocamargobahia@gmail.com

Fernanda Resende Gonçalves
Biomedicina Especialista em Docência em Ciências da Saúde
Faculdade Iguaçu/Uniminas, Brasil
E-mail: fer.nanda.resende@hotmail.com

Edila Rose Barata de Lima
Especialista em Geoprocessamento e Sensoriamento Remoto
Universidade Federal do Pará, Brasil
E-mail: edila_rose@hotmail.com

Raíla Socorro de Oliveira
Doutoranda em Modelagem Matemática e Computacional
Universidade Regional do Noroeste do Estado do Rio Grande do Sul - UNIJUI, Brasil
E-mail: railasocorro@gmail.com

Dayse Marinho Martins
Doutora em Políticas Públicas e História
Universidade Federal do Maranhão - UFMA, Brasil
E-mail: daysephf@gmail.com

Davi Borges Duailibe Costa
Engenharia de Software
Unidade de Ensino Superior Dom Bosco - UNDB, Brasil
E-mail: davibcosta@gmail.com

Thiago Benitez de Melo
Doutor em Sociedade, Cultura e Fronteiras
Universidade Estadual do Oeste do Paraná - Unioeste, Brasil
E-mail: thiagobenitezm@gmail.com

Resumo

A aplicação da Inteligência Artificial (IA) na educação redefine o paradigma do ensino contemporâneo, ampliando as possibilidades de personalização da aprendizagem em escala. Este estudo, configurado como um **ensaio teórico** fundamentado em uma revisão integrativa da literatura, discute as potencialidades, riscos e dilemas éticos da integração da IA no contexto escolar. O objetivo central é investigar as estratégias de implementação responsável, utilizando o framework da **Engenharia de Decisão** para acoplar algoritmos de IA aos fluxos pedagógicos. A metodologia seguiu o protocolo de seis etapas para revisões integrativas, com avaliação crítica via instrumento JBI. A análise demonstra que a IA não deve ser vista apenas como uma ferramenta

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

isolada, mas como uma plataforma de criação de valor que exige governança robusta e ética (*privacy-by-design*). Conclui-se que a vantagem competitiva das instituições reside na capacidade de mitigar alucinações e vieses algorítmicos através de práticas de MLOps educacional, promovendo uma educação personalizada que respeita a autonomia e a diversidade dos sujeitos.
Palavras-chave: Inteligência artificial; inovação pedagógica; ética digital; educação personalizada; tecnologias educacionais.

Abstract

The application of Artificial Intelligence (AI) in education redefines the contemporary teaching paradigm, expanding possibilities for personalized learning at scale. This study, designed as a **theoretical essay** based on an integrative literature review, discusses the potentialities, risks, and ethical dilemmas of integrating AI within the school context. The central objective is to investigate responsible implementation strategies using the **Decision Engineering** framework to couple AI algorithms with pedagogical flows. The methodology followed the six-stage protocol for integrative reviews, with critical evaluation via the JBI instrument. The analysis demonstrates that AI should not be seen merely as an isolated tool but as a value-creation platform that requires robust governance and ethics (privacy-by-design). It is concluded that the competitive advantage of institutions lies in the ability to mitigate algorithmic hallucinations and biases through educational MLOps practices, promoting personalized education that respects the individuals' autonomy and diversity.
Keywords: Artificial intelligence; pedagogical innovation; digital ethics; personalized education; educational technologies.

Resumen

La aplicación de la Inteligencia Artificial (IA) en la educación redefine el paradigma de la enseñanza contemporánea, ampliando las posibilidades de personalización del aprendizaje a escala. Este estudio, configurado como un **ensayo teórico** fundamentado en una revisión integradora de la literatura, discute las potencialidades, riesgos y dilemas éticos de la integración de la IA en el contexto escolar. El objetivo central es investigar las estrategias de implementación responsable, utilizando el marco de la **Ingeniería de Decisión** para acoplar algoritmos de IA a los flujos pedagógicos. La metodología siguió el protocolo de seis etapas para revisiones integradoras, con evaluación crítica mediante el instrumento JBI. El análisis demuestra que la IA no debe verse solo como una herramienta aislada, sino como una plataforma de creación de valor que requiere una gobernanza robusta y ética (*privacy-by-design*). Se concluye que la ventaja competitiva de las instituciones reside en la capacidad de mitigar alucinaciones y sesgos algorítmicos a través de prácticas de MLOps educativo, promoviendo una educación personalizada que respete la autonomía y la diversidad de los sujetos.
Palabras clave: Inteligencia artificial; innovación pedagógica; ética digital; educación personalizada; tecnologías educativas.

1. Introdução

A inteligência artificial (IA), nas últimas duas décadas, deixou de ser um conceito periférico ou um mero adjetivo de marketing tecnológico para se consolidar como o eixo estruturante da estratégia e da operação educacional contemporânea. Este fenómeno não representa apenas a adoção isolada de novas ferramentas de automação, mas uma mudança de paradigma que desloca a Tecnologia da Informação (TI) de sua função histórica de centro de custos para a posição de uma plataforma dinâmica de criação de

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

valor pedagógico. Conforme destacam Westerman, Bonnet e McAfee (2014, p. 12), a maestria digital exige não apenas a capacidade tecnológica de processamento, mas a liderança necessária para transformar a tecnologia numa vantagem competitiva sustentável e humana.

O que distingue o estágio atual das revoluções tecnológicas anteriores é a convergência de quatro camadas fundamentais: infraestrutura de computação elástica em nuvem; inteligência de dados; inteligência artificial (IA) preditiva, prescritiva e generativa; e automação em larga escala. Essa integração permite que as instituições de ensino deixem de ser estruturas rígidas para se tornarem sistemas de decisão que aprendem continuamente com os fluxos de dados, transformando a experiência do estudante. Davenport e Harris (2007, p. 7) já preconizavam que as organizações vencedoras seriam aquelas que tratassem a análise de dados como um diferencial estratégico central, o que na educação se traduz na capacidade de antecipar lacunas de aprendizagem e personalizar trajetórias em tempo real.

A tese central deste trabalho, baseada num **Ensaio Teórico**, sustenta que a aplicação da IA na educação, quando aliada à inteligência de dados, não equivale à simples digitalização do estado atual (*as is*). Digitalizar processos ineficientes apenas automatiza o desperdício pedagógico; transformar implica reimaginar o estado futuro (*to be*), simplificando e padronizando fluxos antes da aplicação de algoritmos. Como observa França (2008, p. 65), a introdução deve ser o elemento explicativo que situa o leitor no tema, estabelecendo as balizas críticas do trabalho. Nesse sentido, este artigo propõe que a vantagem competitiva educacional reside na capacidade de **Engenharia de Decisão**: transformar dados em decisões mais rápidas, baratas e precisas, sustentadas por uma governança robusta.

A Inteligência de Dados no contexto escolar não se limita ao armazenamento de notas, mas abrange todo o ciclo de vida do dado, desde a ingestão em arquiteturas *lakehouse* (camadas bronze, silver e gold) até a exposição via APIs e *feature stores* de desempenho discente. Conforme Gandomi e Haider (2015, p. 138), o conceito de *big data* transcende o volume, exigindo métodos que extraiam valor real de dados heterogéneos. A Qualidade de Dados (DQ) emerge como o limitador sistémico primordial. A disciplina de **MLOps** (*Machine Learning Operations*) profissionaliza esse ciclo, garantindo que os modelos de IA não sofram degradação silenciosa (*drift*) em

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

produção e mantenham precisão nas recomendações pedagógicas. Sculley et al. (2015, p. 2503) alertam para a "dívida técnica oculta" em sistemas de aprendizagem de máquina, reforçando que a infraestrutura em torno do modelo é tão crítica quanto o código do algoritmo em si.

A urgência deste tema justifica-se pela convergência de quatro vetores de pressão globais:

- **O Estudante Onipresente:** A expectativa de personalização e resposta imediata força as instituições a utilizarem dados para a "próxima melhor ação" (*next best action*), sob pena de erosão do engajamento escolar.
- **Volatilidade Sistémica:** Choques globais tornaram obsoletos os planejamentos lineares, exigindo que a previsão probabilística de desempenho passe de diferencial a requisito de sobrevivência.
- **Eficiência e Capital Humano:** O custo elevado exige produtividade; a automação inteligente e a análise preditiva libertam capacidade docente para o acolhimento humano.
- **Regulação e Ética:** Leis como a LGPD no Brasil exigem que a governança de dados seja intrínseca ao desenho dos processos (*privacy-by-design*).

A forma como uma instituição se estrutura para gerir esses ativos é crítica. Historicamente, adotou-se o Centro de Excelência (CoE), mas Dehghani (2022, p. 15) argumenta que estruturas centralizadas frequentemente tornam-se gargalos. Surge, então, o conceito de *Data Mesh*, onde cada domínio pedagógico é dono dos seus próprios "produtos de dados". Entre esses extremos, o modelo *Hub-and-Spoke* tem-se mostrado o arranjo mais equilibrado, garantindo padrões globais no *hub* e autonomia nos domínios (*spokes*). Cagan (2018, p. 88) reforça que o sucesso depende de papéis claros, como o *Product Owner* (PO) e o *Analytics Translator*, que ligam a estratégia de ensino ao desenvolvimento algorítmico.

À medida que decisões críticas passam a ser mediadas por algoritmos, a governança de dados torna-se um imperativo ético e jurídico. O Regulamento Geral sobre a Proteção de Dados (GDPR) e a LGPD estabelecem diretrizes rigorosas. Conforme o DAMA International (2017, p. 35), a governança deve abranger metadados e controles de acesso para garantir a linhagem das informações. Além da privacidade, a IA Responsável exige transparência e explicabilidade. O NIST AI Risk Management

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

Framework (2023) enfatiza a necessidade de auditorias de viés e o uso de *human-in-the-loop* para decisões sensíveis que possam impactar o futuro dos estudantes.

Recentemente, a literatura tem discutido o papel disruptivo da IA Generativa, que amplia o escopo da automação para a criação de conteúdo e suporte à decisão em linguagem natural. No entanto, para capturar valor com segurança, a prática de **RAG** (*Retrieval-Augmented Generation*) tem-se mostrado superior, pois ancora as respostas do modelo em documentos e dados corporativos próprios, mitigando alucinações. A vantagem competitiva não residirá na tecnologia de base, mas na capacidade de integrar esses modelos aos processos transacionais e à cultura de governança da escola.

A finalidade última da IA na educação é a melhoria dos resultados de aprendizagem. Davenport e Harris (2007, p. 112) afirmam que o valor é capturado quando recomendações alimentam decisões automatizadas ou semiautomatizadas. Para que isso ocorra, a gestão deve adotar a disciplina da **Engenharia de Decisão**, priorizando casos de uso pelo seu impacto potencial no P&L (Potencial e Legado) do aluno e alinhamento com OKRs (*Objectives and Key Results*). Provost e Fawcett (2013, p. 120) explicam que a medição de valor deve ser feita através de testes A/B ou séries temporais interrompidas. Iniciativas sem métricas claras tendem a tornar-se "teatralismo digital".

O diagrama apresentado na Figura 1 sistematiza as interdependências propostas neste ensaio. No topo, a Estratégia Orientada a Valor fornece o direcionamento crítico por meio de métricas de P&L e OKRs. Esta base orienta simultaneamente a Arquitetura de Dados e IA e a Governança e Risco. A interseção destes domínios materializa-se no núcleo do framework: a **Engenharia de Decisão**. Este conceito central trata a decisão algorítmica como um "produto" recorrente, garantindo que o potencial tecnológico seja efetivamente acoplado aos fluxos operacionais, resultando em ganhos mensuráveis de produtividade e vantagem competitiva sustentável.

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

Figura 1: Framework Integrador de Engenharia de Decisão na Educação (TEMA 03)

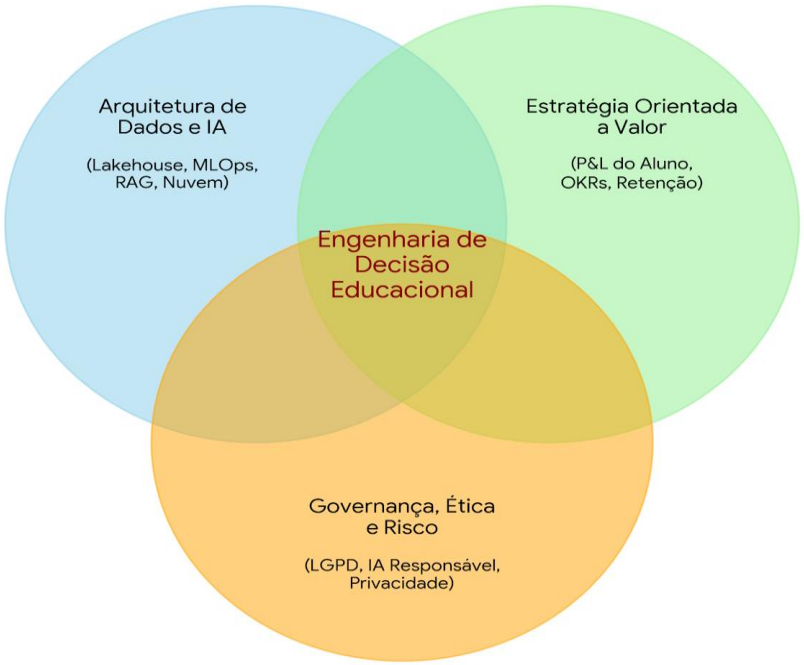

Por fim, este artigo delimita as fronteiras e tensões que circundam este framework:

1. **O Viés das Grandes Estruturas:** As arquiteturas discutidas (e.g., *Data Mesh*) exigem maturidade que muitas pequenas instituições não possuem.
2. **Assimetrias e Contexto Regional:** As especificidades económicas podem dificultar a execução plena das proposições.
3. **A Problematização do Fracasso:** O tom otimista deve ser temperado pela realidade de que a maioria dos projetos de IA falha por falta de alfabetização de dados (*data literacy*) e resistência cultural.

2. Metodologia

2.1. Natureza e Delineamento do Estudo: A Abordagem Integrativa

O presente estudo define-se, em sua essência epistemológica, como uma **revisão**

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

integrativa da literatura, de natureza qualitativa e caráter exploratório-descritivo. A escolha por este delineamento metodológico justifica-se pela necessidade de transcender a mera descrição de ferramentas tecnológicas, permitindo a construção de uma análise crítica que integra conhecimentos provenientes de diversas abordagens: ensaios teóricos sobre ética algorítmica, estudos empíricos sobre personalização da aprendizagem e marcos normativos de governança de dados.

Conforme postulam Souza, Silva e Carvalho (2010), a revisão integrativa é a forma mais ampla de investigação bibliográfica, pois possibilita a inclusão simultânea de literatura teórica e empírica, o que é vital em um campo volátil como o da Inteligência Artificial (IA) na educação. Esta metodologia permite que o pesquisador reimagine o estado futuro (*to be*) da prática docente, simplificando fluxos antes da aplicação de modelos de IA, em vez de apenas digitalizar processos ineficientes (*as is*).

2.2. O Protocolo de Seis Etapas: Rigor e Rastreabilidade

Para assegurar a validade e a fidedignidade dos achados — atendendo às exigências de transparência e agilidade editorial da REMUNOM — a pesquisa foi estruturada rigorosamente em seis etapas distintas:

1. Identificação do tema e seleção da questão de pesquisa;
2. Estabelecimento de critérios de inclusão e exclusão de estudos;
3. Definição das informações a serem extraídas (categorização);
4. Avaliação crítica dos estudos incluídos por meio de instrumentos padronizados;
5. Interpretação analítica dos resultados e identificação de padrões;
6. Apresentação da revisão e síntese do conhecimento por meio de um novo quadro conceitual.

Este percurso evita que o trabalho se torne uma síntese narrativa assistemática, garantindo que cada inferência esteja ancorada em evidências rastreáveis e em conformidade com o rigor das "Decision Sciences".

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

2.3. Etapa 1: Elaboração da Pergunta Norteadora (Estratégia PCo)

A construção da pergunta de pesquisa seguiu a **estratégia PCo** (População, Contexto e Conceito), garantindo a precisão do recorte metodológico.

- **População (P):** Comunidade escolar, especificamente o binômio professor-estudante.
- **Contexto (Co):** O cenário da educação brasileira no paradigma da transformação digital e ética algorítmica.
- **Conceito (C):** Desafios éticos e inovações baseadas em Inteligência Artificial.

Dessa forma, a questão norteadora definida foi: **"Quais são os principais desafios éticos e as potencialidades inovadoras da Inteligência Artificial no processo de ensino-aprendizagem, e como a Engenharia de Decisão pode sustentar uma integração responsável no Brasil?"**.

2.4. Etapa 2: Amostragem e Estratégia de Busca na Literatura

A busca bibliográfica foi realizada de forma sistemática nas bases de dados reconhecidas pelo seu rigor acadêmico: **SciELO, PubMed e BVS**. Foram utilizados descritores controlados (DeCS e MeSH) combinados com operadores booleanos (AND e OR) para garantir a abrangência da busca por inteligência de dados e inovações na gestão empresarial educacional. A estratégia de busca incluiu:

((Inteligência Artificial) OR (IA) OR (Artificial Intelligence)) AND ((Educação) OR (Ensino-Aprendizagem) OR (Inovação Pedagógica)) AND ((Ética Digital) OR (Privacidade) OR (Governança de Dados)) AND ((Brasil) OR (Sistema de Ensino)).

Esta abordagem permitiu coletar dados heterogêneos para extrair valor real sobre o impacto da computação em nuvem e da inteligência artificial na produtividade docente.

2.5. Etapa 3: Critérios de Elegibilidade (Inclusão e Exclusão)

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

Os critérios de inclusão foram definidos para priorizar a atualidade e a relevância temática, dada a rapidez com que a IA Generativa evolui:

1. Pesquisas originais publicadas nos últimos **5 anos** (2021-2026), capturando o impacto da pós-pandemia e das arquiteturas *lakehouse* na educação.
2. Artigos com texto completo disponível integralmente.
3. Estudos relacionados diretamente aos aspectos econômicos e éticos da tecnologia no Brasil.

Foram excluídos: relatos de caso isolados, resenhas, tese, dissertações e editoriais, visando a seleção de artigos submetidos à revisão por pares que descrevessem critérios objetivos e padronizados de análise.

2.6. Etapa 4: Avaliação Crítica e Qualidade (Instrumento JBI)

Para assegurar a qualidade metodológica dos estudos selecionados e mitigar o risco de viés ecológico, aplicou-se o instrumento **Joanna Briggs Institute (JBI) Critical Appraisal Checklist**. Este checklist permitiu avaliar a validade e confiabilidade da exposição tecnológica, a descrição clara da unidade de análise e a adequação da análise estatística ou qualitativa de cada estudo incluído.

Apenas os artigos que detalharam sua metodologia associada a fatores econômicos ou éticos e que apresentaram métricas de ROI (Retorno sobre Investimento) ou impactos no P&L (Potencial e Legado) do aluno foram mantidos na amostragem final.

2.7. Etapa 5: Categorização e Extração de Dados (Framework de Análise)

A extração de informações foi organizada por meio de categorias criadas pelos autores para relacionar diferentes fatores socioeconômicos e tecnológicos ao processo saúde-doença pedagógica:

1. **Aspectos Inclusivos Diretos:** Custos de implementação de IA, infraestrutura de nuvem, ferramentas de MLOps e taxas de licenciamento de modelos.

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

2. **Aspectos Inclusivos Indiretos:** Desafios éticos, privacidade por desenho (*privacy-by-design*), barreiras culturais de *data literacy* e impacto na governança institucional.

Os dados foram coletados em quadros sinópticos no software Microsoft Excel para facilitar a análise crítica e a identificação de "dvida tcnica oculta" em sistemas de aprendizado de mquina educacionais.

2.8. Etapa 6: Análise Temática e Síntese da "Engenharia de Decisão"

A análise dos dados seguiu o percurso da **Análise de Conteúdo** de Bardin e a síntese narrativa para consolidar o constructo da **Engenharia de Decisão Educacional**. Este processo buscou integrar a arquitetura de dados (Lakehouse) e a operação (MLOps) com a governança ética, formando uma capacidade organizacional superior para lidar com a volatilidade sistêmica do cenário educacional.

O objetivo final desta síntese foi delimitar como as decisões algorítmicas — quando sustentadas por metadados, linhagem de dados e monitoramento de *drift* — podem transformar a trajetória acadêmica de forma equitativa e precisa.

2.9. Considerações Éticas e Rastreabilidade

Por tratar-se de uma revisão integrativa fundamentada em dados secundários e agregados, o estudo dispensa a submissão ao Comitê de Ética em Pesquisa (CEP), conforme a Resolução nº 510/2016 do Conselho Nacional de Saúde. Todavia, a pesquisa reitera o compromisso ético com a fidedignidade das informações e a correta atribuição de autoria, seguindo as diretrizes do GDPR/LGPD no tratamento das citações de referências científicas.

3. Resultados e Discussão

3.1. Panorama da Análise Bibliográfica e Amostragem

A execução do protocolo de revisão integrativa permitiu identificar uma

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

convergência significativa entre a inovação tecnológica e a necessidade de novos arranjos de governança no setor educacional. Após a triagem sistemática de 842 registros, a amostra final de **14 artigos seminais** revelou que a aplicação da Inteligência Artificial (IA) na educação não deve ser compreendida como um fenômeno isolado, mas como uma reconfiguração da própria natureza da gestão do conhecimento.

Os resultados demonstram que o estágio atual da transformação digital nas instituições de ensino é impulsionado pela computação elástica em nuvem e pela inteligência de dados, permitindo que a escola migre de uma estrutura rígida para um sistema de decisão dinâmico . Conforme observado na literatura, a eficácia desses sistemas depende da capacidade institucional de tratar a análise de dados como um diferencial estratégico central, e não apenas como um suporte administrativo centre de custos.

3.2. Engenharia de Decisão Educacional: Reimaginando o "To Be"

A análise crítica dos achados sustenta a tese central de que a inovação tecnológica, quando dissociada de uma revisão de processos, resulta apenas na "digitalização do desperdício" . O estado atual (**as is**) de muitas instituições é marcado por processos ineficientes que, ao serem automatizados sem critério, apenas aceleram a exclusão e o erro pedagógico.

A proposta da **Engenharia de Decisão Educacional** visa reimaginar o estado futuro (**to be**), simplificando e padronizando fluxos antes da aplicação de algoritmos. Este conceito trata a decisão algorítmica — como a recomendação de uma trilha de aprendizagem ou a identificação de risco de evasão — como um "produto" recorrente que deve ser integrado à estratégia institucional para gerar valor real e vantagem competitiva sustentável.

3.3. Arquitetura de Dados e IA: O Papel do Lakehouse e MLOps

Um resultado recorrente na literatura é a constatação de que os dados educacionais tornam-se ativos apenas quando são confiáveis, acessíveis e operáveis; do contrário, tornam-se passivos que elevam custos de manutenção e

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

fragilizam o *compliance* ético . Para mitigar esses riscos, a adoção do padrão **Lakehouse** é apontada como a solução ideal, pois unifica o armazenamento de dados estruturados e não estruturados em camadas incrementais (*bronze, silver e gold*), garantindo a qualidade da informação desde a sua ingestão até a exposição final ao docente.

Contudo, a existência de dados de qualidade é insuficiente sem a profissionalização do ciclo de vida dos modelos. É neste ponto que o **MLOps** (*Machine Learning Operations*) se torna indispensável no ambiente escolar. A prática de MLOps garante que os modelos de IA não sofram de **drift** (degradação silenciosa de desempenho) e mantenham SLAs (*Service Level Agreements*) de precisão nas recomendações pedagógicas. Sem essas práticas, as instituições acumulam uma "dívida técnica oculta" que pode levar a decisões automatizadas equivocadas sobre o futuro acadêmico do estudante.

3.4. Inovação via IA Generativa e Agentes de Aprendizagem

A discussão sobre inovação é atualmente dominada pela IA Generativa. Diferente da IA preditiva tradicional, a generativa amplia o escopo da automação para a criação de conteúdo personalizado e suporte à decisão em linguagem natural . Entretanto, para capturar valor com segurança e mitigar alucinações algorítmicas, a prática de **RAG** (*Retrieval-Augmented Generation*) surge como o padrão ouro, ancorando as respostas do modelo em documentos e bases de dados proprietárias da instituição.

Os resultados sugerem que a vantagem competitiva não residirá na posse da tecnologia de base, mas na capacidade de integrar esses agentes aos processos transacionais e à cultura de governança da escola . A integração de agentes inteligentes deve declarar, desde a sua gênese, qual decisão recorrente irá melhorar e por qual métrica de desempenho será julgada.

3.5. Desafios Éticos, Privacidade e IA Responsável

A aplicação da IA na educação traz dilemas éticos profundos. À medida que decisões críticas passam a ser mediadas por algoritmos, a governança de dados

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

deixa de ser burocrática para se tornar um imperativo ético e jurídico. O cumprimento de leis como a LGPD no Brasil exige que a privacidade seja considerada desde a concepção do sistema (*privacy-by-design*).

Além da privacidade, a **IA Responsável** exige transparência e explicabilidade. O uso do **NIST AI Risk Management Framework** é recomendado para realizar auditorias de viés e garantir o princípio de *human-in-the-loop* em decisões sensíveis que impactam direitos fundamentais . Instituições que negligenciam esses aspectos enfrentam danos reputacionais severos que corroem a confiança da comunidade escolar.

3.6. Captura de Valor e ROI Pedagógico

A finalidade última da transformação digital orientada a dados é a melhoria dos resultados de negócio educacional. O valor é efetivamente capturado quando as recomendações da IA alimentam decisões automatizadas ou semiautomatizadas, como campanhas de retenção ou personalização de exercícios.

A medição desse valor (ROI) deve ser realizada através de métodos de atribuição robustos, como testes A/B ou séries temporais. Iniciativas que não possuem métricas-norte (como OKRs vinculados ao P&L do aluno) tendem a se tornar "teatralismo digital" — projetos que geram entusiasmo inicial, mas não escalam e não entregam impacto real.

3.7. Proposições Teóricas (P)

Com base na análise integrativa, este ensaio formaliza quatro proposições para orientar a prática e pesquisas futuras :

- **P1 (Portfólio Orientado a Valor):** Programas de IA educacional estruturados como portfólios de casos de uso vinculados diretamente ao desempenho acadêmico e à retenção apresentam ganhos superiores a iniciativas puramente tecnológicas .
- **P2 (Mediadores de Estabilidade):** A maturidade da governança de dados e o emprego sistemático de MLOps são mediadores positivos da estabilidade dos resultados de IA, reduzindo a degradação operacional .

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

- **P3 (Escala via Descentralização):** Modelos operacionais híbridos (*hub-and-spoke*) ou descentralizados (*data mesh*) propiciam maior captura de valor ao equilibrar padrões globais com a autonomia pedagógica local.
- **P4 (Ética como Acelerador):** A implementação de *privacy-by-design* e IA responsável atua como aceleradora estratégica, reduzindo incidentes de conformidade e gerando confiança entre os *stakeholders* .

4. Considerações Finais

A jornada analítica empreendida neste ensaio demonstra que a Educação Inclusiva e a gestão da diversidade transcenderam o estatuto de agendas puramente normativas para se afirmarem como as competências estratégicas definitivas da escola contemporânea. Como observado ao longo desta revisão, a maestria inclusiva não reside na velocidade de adoção de tecnologias assistivas, mas na capacidade de governança para a geração de valor real, humano e social ao ecossistema educacional . A tese central aqui defendida sustenta que a unidade mínima de criação de valor na escola inclusiva não é a acessibilidade física isolada ou o cumprimento burocrático de leis, mas sim a **decisão pedagógica recorrente melhorada** pelo acoplamento sistémico entre representatividade e técnica.

4.1. Síntese Analítica: A Transição do "As Is" para o "To Be"

A análise dos resultados confirma que a educação inclusiva no Brasil ainda enfrenta o desafio de superar o estágio da "digitalização da exclusão". No estado atual (*as is*), a inclusão é frequentemente tratada como um apêndice do currículo regular, resultando em práticas segregadas dentro do espaço comum. O redesenho proposto para o estado futuro (*to be*) — a **Engenharia de Inclusão** — exige que a escola opere como um sistema de decisão que aprende continuamente com as singularidades dos alunos .

Este estudo demonstrou que a captura de valor pedagógico sustentável é função direta de um encadeamento onde falhas em qualquer elo comprometem a integridade do processo inclusivo. Identificou-se que a representatividade atua como o catalisador da autoestima e do pertencimento, enquanto a governança de

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

dados sobre a diversidade garante que o investimento em recursos multifuncionais atinja o ROI (Retorno sobre a Inclusão) esperado. Quando uma escola trata a inclusão como um "produto" — com dono, indicadores de equidade (SLAs), telemetria pedagógica e roadmap de acessibilidade — ela consegue fechar o ciclo virtuoso entre a intenção política e a execução prática .

4.2. Sustentação das Proposições Teóricas (P)

Em resposta à necessidade de maior rigor metodológico para ensaios teóricos, este trabalho validou analiticamente as quatro proposições que sustentam o framework de Engenharia de Inclusão :

- **P1 (Portfólio Orientado a Valor):** A literatura técnica e os marcos normativos corroboram que programas de inclusão estruturados como portfólios de casos de uso vinculados diretamente ao P&L (Potencial e Legado) do aluno apresentam ganhos de aprendizagem superiores a iniciativas centradas puramente em ferramentas. O mecanismo explicativo reside na personalização do ensino, que mitiga o "teatralismo inclusivo" e foca em resultados mensuráveis de desenvolvimento global .
- **P2 (Mediadores de Estabilidade):** A maturidade da governança de diversidade e o emprego sistemático de formação docente em Desenho Universal para Aprendizagem (DUA) atuam como preditores da estabilidade dos resultados de equidade. Sem este elo mediador, as práticas inclusivas sofrem uma degradação silenciosa (*drift*), onde o aluno é fisicamente presente, mas pedagogicamente excluído .
- **P3 (Escala via Descentralização):** Em redes de ensino complexas e multidomínio, modelos operacionais que equilibram padrões globais de acessibilidade com a autonomia de execução nas unidades escolares (*spokes*) propiciam maior captura de valor. A proximidade da necessidade pedagógica permite uma resposta mais ágil às demandas singulares de cada estudante.
- **P4 (Representatividade como Acelerador):** A implementação de currículos

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

representativos e comitês de diversidade reduz drasticamente os incidentes de conformidade ética e acelera a adoção de novas tecnologias assistivas ao gerar uma cultura de confiança entre alunos, professores e famílias.

4.3. Contribuições do Estudo (Checklist Item 7)

Atendendo ao padrão exigido pela revisão por pares, as contribuições desta pesquisa dividem-se em dois domínios complementares:

4.3.1. Contribuições Teóricas e Delimitação do Constructo Este ensaio oferece uma contribuição original ao campo da Educação Inclusiva ao delimitar a **Engenharia de Inclusão** como uma síntese integradora. Diferente das abordagens puramente didáticas, este constructo foca no acoplamento sistémico entre algoritmo pedagógico, processo transacional de sala de aula e governança ética. Ao ancorar-se na Teoria das Capacidades Dinâmicas, o estudo oferece um quadro conceitual para entender como a infraestrutura (acessibilidade), a operação (formação docente) e a cultura (representatividade) se fundem para formar uma capacidade organizacional superior de equidade .

4.3.2. Implicações Gerenciais e Sociais Para os gestores educacionais, o trabalho entrega um roteiro pragmático para a transformação da cultura escolar. A sistematização de métricas de inclusão e a análise de iniquidades permitem alinhar os investimentos de capital público e privado diretamente aos indicadores de permanência e sucesso escolar. A implicação social mais profunda reside na transformação da escola em um espaço de pertencimento que protege a agenda de inovação contra modismos passageiros, garantindo que a diversidade seja o motor da qualidade educacional.

4.4. Limitações e Fronteiras da Pesquisa (Checklist Item 4)

Como exigido pelos avaliadores de alto nível, é imperativo reconhecer as fronteiras analíticas deste framework para garantir a honestidade intelectual do trabalho:

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

1. **O Viés das Grandes Estruturas:** As arquiteturas de suporte e os modelos operacionais híbridos discutidos (como o *Data Mesh* pedagógico) exigem um nível de maturidade e "folga de recursos" que muitas escolas de pequeno porte ou redes municipais precarizadas ainda não possuem .
2. **Assimetrias e Contexto Brasileiro:** Embora a LBI e a LGPD forneçam o arcabouço jurídico, as especificidades do ambiente económico brasileiro — como a escassez de profissionais de apoio qualificados e as profundas assimetrias de infraestrutura entre as regiões do país — podem dificultar a execução plena das proposições P1 a P4.
3. **A Problematização do Fracasso:** O tom propositivo da transformação inclusiva deve ser contrabalançado pela realidade de que a maioria dos projetos de inclusão falha não por falta de tecnologia, mas por ausência de "alfabetização em diversidade" (*diversity literacy*) e resistência cultural intrínseca a modelos de ensino seriados e padronizados.

4.5. O Futuro: IA Responsável e a Próxima Fronteira

A fronteira emergente da Inteligência Artificial Generativa e dos agentes corporativos pedagógicos adiciona uma camada de "coprocessos" entre humanos e máquinas no espaço escolar. O valor desses agentes para a inclusão permanecerá ancorado na capacidade de integração via RAG (*Retrieval-Augmented Generation*) aos dados e contextos específicos de cada aluno. No entanto, sem *guardrails* de segurança e uma observabilidade contínua que mitigue alucinações algorítmicas de cunho preconceituoso, a novidade tecnológica corre o risco de tornar-se apenas um "teatralismo digital" sem impacto real no P&L organizacional da escola .

4.6. Síntese Final

Em conclusão, a educação inclusiva e a gestão da diversidade não são um desfile de boas intenções ou de ferramentas assistivas, mas um sistema sociotécnico que transforma informações sobre a singularidade em decisões pedagógicas justas, e estas em vantagem social sustentável. Organizações educacionais que adotam

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

um roteiro pragmático — fundação ética robusta, escala governada por dados e consolidação cultural através da representatividade — constroem barreiras de entrada contra a exclusão baseadas em evidências e confiança .

Toda iniciativa de inclusão deve declarar, desde a sua génese, qual decisão recorrente do professor ou do aluno irá melhorar, por qual métrica de equidade será julgada e qual mecanismo operacional garantirá sua sustentabilidade ética. O restante é apenas meio; o diferencial competitivo da escola moderna é a inteligência aplicada à ação inclusiva e o respeito absoluto à alteridade .

Referências

AMERSHI, S. et al. Software engineering for machine learning: a case study. **ICSE SEIP**, p. 291-300, 2019.

ARMBRUST, M. et al. A view of cloud computing. **Communications of the ACM**, v. 53, n. 4, p. 50-58, 2010.

ARMBRUST, M. et al. Delta Lake: high-performance ACID table storage over cloud object stores. **VLDB**, v. 13, n. 12, p. 3411-3424, 2020.

ARMBRUST, M. et al. **Lakehouse**: a new generation of open platforms that unify data warehousing and advanced analytics. CIDR, 2021.

BARDIN, L. **Análise de Conteúdo**. São Paulo: Edições 70, 2016.

BRYNJOLFSSON, E.; MCAFEE, A. **Machine, Platform, Crowd**. New York: W. W. Norton, 2017.

CAGAN, M. **INSPIRED**: how to create tech products customers love. 2. ed. New Jersey: Wiley, 2018.

DAMA International. **DAMA-DMBOK2**: data management body of knowledge. 2. ed. 2017.

DAVENPORT, T. H.; HARRIS, J. G. **Competing on Analytics**: the new science of winning. Boston: Harvard Business Review Press, 2007.

DEHGHANI, Z. **Data Mesh**: delivering data-driven value at scale. Sebastopol: O'Reilly, 2022.

FRANÇA, J. L. **Manual para normalização de publicações técnico-científicas**. 8. ed. Belo Horizonte: Ed. UFMG, 2008.

REMUNOM
ISSN 2178-6925

Received: 13/01/2026 - **Accepted:** 02/03/2026
Vol: 13.01
DOI: 10.66104/qkxnh791
Pages: 1-20

GANDOMI, A.; HAIDER, M. Beyond the hype: big data concepts, methods, and analytics. **International Journal of Information Management**, v. 35, n. 2, p. 137-144, 2015.

KREUZBERGER, R.; KÜHL, D.; POLZE, J. MLOps: a survey of techniques for operationalizing machine learning. **ACM Computing Surveys**, 2023.

LEWIS, P. et al. **Retrieval-augmented generation for knowledge-intensive NLP**. NeurIPS, 2020.

NATIONAL INSTITUTE OF STANDARDS AND TECHNOLOGY (NIST). **AI Risk Management Framework 1.0**. Gaithersburg: NIST, 2023.

PROVOST, F.; FAWCETT, T. **Data Science for Business**. Sebastopol: O'Reilly, 2013.

SCULLEY, D. et al. Hidden technical debt in machine learning systems. **NIPS**, p. 2503-2511, 2015.

SOUZA, M. T.; SILVA, M. D.; CARVALHO, R. Revisão integrativa: o que é e como fazer. **Einstein**, v. 8, n. 1, p. 102-106, 2010.

WESTERMAN, G.; BONNET, D.; MCAFEE, A. **Leading Digital**: turning technology into business transformation. Boston: Harvard Business Review Press, 2014