REVISTA TÓPICOS
ISSN 2965-6672 | Qualis A2

O ESTATUTO DIGITAL DA CRIANÇA E DO ADOLESCENTE E A ARQUITETURA RAG: FUNDAMENTOS PARA UMA EDUCAÇÃO MATEMÁTICA COM INTELIGÊNCIA ARTIFICIAL AUDITÁVEL E TRANSPARENTE

THE DIGITAL STATUTE OF THE CHILD AND ADOLESCENT AND THE RAG ARCHITECTURE: FOUNDATIONS FOR AUDITABLE AND TRANSPARENT ARTIFICIAL INTELLIGENCE IN MATHEMATICS EDUCATION

Ciências Exatas e da Terra • 16/11/2026

REGISTRO DOI: 10.70773/revistatopicos/794654540

Edídio Rubens Dantas Lima[1]

Alex Paubel Junger[2]

RESUMO

O artigo analisa a complementaridade entre a Lei nº 15.211/2025 (Estatuto Digital da Criança e do Adolescente) e a Base Nacional Comum Curricular (BNCC) e propõe a arquitetura Retrieval-Augmented Generation (RAG) como solução técnica para assistentes educacionais de inteligência artificial que atendam às exigências legais de auditabilidade e às diretrizes curriculares de formação crítica. A lei impõe exigências de transparência, auditabilidade e segurança a produtos e serviços de tecnologia da informação e prevê a revisão regular de ferramentas de inteligência artificial (art. 17, § 4º, VIII), enquanto a BNCC preconiza o desenvolvimento do pensamento computacional e do letramento matemático crítico. Trata-se de pesquisa qualitativa, exploratória e bibliográfica, baseada na análise de documentos legais e curriculares e em revisão narrativa da literatura sobre aplicações educacionais da RAG (2020-2026). Os estudos analisados indicam que sistemas baseados nessa arquitetura oferecem rastreabilidade das respostas, redução de alucinações, personalização contextualizada e possibilidade de implantação local, favorável à soberania de dados. A pesquisa resultou, ainda, no sistema DeepEdu, prova de conceito disponível em repositório público, que demonstra a viabilidade técnica da arquitetura proposta; a avaliação de seus efeitos pedagógicos permanece como etapa futura. Conclui-se que a arquitetura RAG, quando projetada com padrões de transparência desde a concepção, permite converter a conformidade legal em oportunidade pedagógica, articulando proteção integral, desenvolvimento da autonomia e formação para o uso crítico da tecnologia.

Palavras-chave: Estatuto Digital da Criança e do Adolescente; BNCC; Retrieval-Augmented Generation; Educação Matemática; auditabilidade.

ABSTRACT

This article analyzes the complementarity between Law No. 15,211/2025 (Digital Statute of the Child and Adolescent) and the Brazilian National Common Curricular Base (BNCC) and proposes the Retrieval-Augmented Generation (RAG) architecture as a technical solution for educational artificial intelligence assistants that meet legal auditability requirements and curriculum guidelines for critical education. The law imposes transparency, auditability and security requirements on information technology products and services and provides for the regular review of artificial intelligence tools (art. 17, § 4, VIII), while the BNCC advocates the development of computational thinking and critical mathematical literacy. This is a qualitative, exploratory and bibliographic study, based on the analysis of legal and curricular documents and on a narrative review of the literature on educational applications of RAG (2020-2026). The studies analyzed indicate that systems based on this architecture provide traceability of responses, reduced hallucination, contextualized personalization and the possibility of local deployment, which supports data sovereignty. The research also resulted in the DeepEdu system, a proof of concept available in a public repository, which demonstrates the technical feasibility of the proposed architecture; the assessment of its pedagogical effects remains a future step. The study concludes that the RAG architecture, when designed with transparency standards from the outset, makes it possible to turn legal compliance into a pedagogical opportunity, combining integral protection, the development of autonomy and education for the critical use of technology.

Keywords: Digital Statute of the Child and Adolescent; BNCC; Retrieval-Augmented Generation; Mathematics Education; auditability.

1. INTRODUÇÃO

A promulgação da Lei nº 15.211, de 17 de setembro de 2025, denominada Estatuto Digital da Criança e do Adolescente, estabelece um regime específico de proteção para crianças e adolescentes em ambientes digitais. Embora não constitua um marco legal geral da inteligência artificial (IA), a lei contém dispositivo específico sobre o tema, o art. 17, § 4º, VIII, que exige a revisão regular das ferramentas de IA com participação de especialistas, além de um conjunto de princípios, obrigações e salvaguardas que incidem sobre o desenvolvimento, a disponibilização e a operação de sistemas de IA voltados a esse público ou por ele acessíveis (Brasil, 2025).

Paralelamente, a Base Nacional Comum Curricular (BNCC), em sua área de Matemática e suas Tecnologias e no Complemento de Computação, estabelece diretrizes para a formação dos estudantes no que tange ao raciocínio matemático, à resolução de problemas e ao desenvolvimento do pensamento computacional. No Ensino Médio, a BNCC propõe consolidar, ampliar e aprofundar o que foi aprendido no Ensino Fundamental, com uma Matemática vista de forma integrada e aplicada a situações reais, e destaca o uso de tecnologias digitais e de aplicativos na investigação matemática e na continuidade do desenvolvimento do pensamento computacional (Brasil, 2018, p. 527).

O avanço dos grandes modelos de linguagem (*Large Language Models* — LLMs), como os descritos por Brown *et al.* (2020) e Touvron *et al.* (2023), tem ampliado as aplicações da IA no ensino e na aprendizagem. Contudo, os LLMs enfrentam desafios quando implantados em ambientes educacionais reais, especialmente a

alucinação, na qual os modelos geram informações factualmente incorretas ou enganosas, e o conhecimento estático incorporado, que não reflete atualizações curriculares (Taneja *et al.*, 2025; Lewis *et al.*, 2020). Em contextos nos quais a precisão e a confiabilidade são requisitos, tais questões podem comprometer os resultados de aprendizagem.

A Lei nº 15.211/2025 parte de premissas alinhadas ao Estatuto da Criança e do Adolescente (Lei nº 8.069/1990) e à Lei Geral de Proteção de Dados Pessoais (Lei nº 13.709/2018), adotando a proteção integral, o melhor interesse da criança e do adolescente e a condição peculiar de pessoa em desenvolvimento como eixos de toda interação digital (arts. 3º e 4º). Aplicados ao contexto da IA, esses princípios demandam dos fornecedores uma postura de prevenção e mitigação de riscos desde a concepção dos sistemas e ao longo de sua operação (art. 6º).

Nesse cenário, a pesquisa que origina este artigo, desenvolvida em nível de mestrado, formulou o seguinte problema: como a arquitetura *Retrieval-Augmented Generation* (RAG) pode ser utilizada para desenvolver assistentes educacionais de IA que estejam em conformidade com as exigências de transparência, auditabilidade e revisão regular da Lei nº 15.211/2025, ao mesmo tempo em que promovem as competências de pensamento computacional e letramento matemático crítico preconizadas pela BNCC?

O objetivo geral é analisar a complementaridade entre a Lei nº 15.211/2025 e a BNCC, propondo a arquitetura RAG como solução técnica para o desenvolvimento de assistentes educacionais de IA que atendam simultaneamente às exigências legais de

auditabilidade e às diretrizes curriculares de formação crítica. Os objetivos específicos são: analisar as obrigações da Lei nº 15.211/2025 que incidem sobre ferramentas de IA voltadas ao público infantojuvenil; identificar as competências e habilidades da BNCC que preparam os estudantes para uma interação crítica e segura com essas ferramentas; descrever os fundamentos técnicos da arquitetura RAG; revisar a literatura sobre aplicações educacionais da RAG no período de 2020 a 2026; propor um modelo de implementação da RAG em escolas brasileiras; e verificar a viabilidade técnica da proposta por meio de uma prova de conceito documentada.

A justificativa reside na convergência de três fatores: a necessidade de proteger crianças e adolescentes no ambiente digital, conforme imposto pela nova legislação; a necessidade de preparar os estudantes para um mundo mediado por tecnologias digitais e IA, conforme orientado pela BNCC; e a disponibilidade de uma tecnologia, a RAG, que pode contribuir para essa convergência ao fundamentar as respostas em uma base de conhecimento identificável (Lewis *et al.*, 2020). A arquitetura, proposta originalmente por Lewis *et al.* (2020), conecta modelos de linguagem a bases de conhecimento específicas e controladas (Gao *et al.*, 2024), o que permite às escolas desenvolver assistentes de IA com rastreabilidade das informações geradas, tornando a auditoria um elemento estrutural do sistema.

O artigo está organizado em cinco seções. Após esta introdução, a seção 2 apresenta a fundamentação teórica sobre a Lei nº 15.211/2025, a BNCC e a arquitetura RAG. A seção 3 descreve a metodologia. A seção 4 apresenta e discute os resultados: a complementaridade entre a lei e a BNCC, a correspondência entre a RAG e as exigências

legais, a síntese da literatura, o modelo de implementação proposto e a prova de conceito DeepEdu. A seção 5 traz as considerações finais.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. A Lei Nº 15.211/2025 e as Exigências de Transparência e Auditabilidade

A Lei nº 15.211/2025 determina que os produtos e serviços de tecnologia da informação voltados a crianças e adolescentes, ou que tendam a ser acessados por esse público, priorizem sua proteção, orientados pelo seu melhor interesse e por medidas proporcionais que assegurem alto nível de privacidade, proteção de dados e segurança (Brasil, 2025, art. 3º). O art. 4º elenca fundamentos como a proteção integral (inciso I), a condição peculiar de pessoa em desenvolvimento biopsicossocial (inciso III), a proteção contra intimidação, exploração, abuso, ameaça e outras violências (inciso IV), o respeito à autonomia e ao desenvolvimento progressivo do indivíduo (inciso V), a promoção da educação digital (inciso VIII) e a transparência e responsabilidade no tratamento de dados pessoais (inciso IX).

O art. 6º obriga os fornecedores a adotar, do projeto à operação das aplicações, medidas que previnam e reduzam a exposição de crianças e adolescentes a conteúdos e práticas nocivos, como exploração e abuso sexual, violência física, intimidação sistemática virtual, assédio e incentivo a danos à saúde física ou mental (Brasil, 2025, art. 6º). O art. 7º exige que, desde a concepção, os produtos e serviços adotem por padrão a opção que mais protege a privacidade e os dados pessoais, e o § 1º do mesmo artigo obriga o fornecedor a

informar de modo claro e acessível a criança, o adolescente e seus responsáveis, para que possam decidir com conhecimento sobre configurações menos protetivas (Brasil, 2025, art. 7º).

Nos arts. 9º a 15, a lei estabelece mecanismos de verificação de idade, vedando a autodeclaração e exigindo métodos proporcionais, auditáveis e tecnicamente seguros para aferir a faixa etária dos usuários (Brasil, 2025, art. 12, I). O art. 13 restringe o uso dos dados coletados para verificação de idade unicamente a essa finalidade, e o art. 12, § 1º, determina que o fornecimento de sinal de idade por meio de APIs observe o princípio da minimização de dados.

No que concerne à transparência e à prestação de contas, o art. 31 obriga os provedores com mais de um milhão de usuários crianças e adolescentes registrados a publicar relatórios semestrais que descrevam, entre outros itens, como avaliam, identificam e gerenciam os riscos à segurança e à saúde desse público e quais resultados obtiveram (Brasil, 2025, art. 31, VII). O art. 34 atribui à autoridade administrativa autônoma a fiscalização do cumprimento da lei e a edição de normas complementares, vedando que a regulamentação resulte em mecanismos de vigilância massiva, genérica ou indiscriminada.

Por fim, no âmbito da supervisão parental, o art. 17, § 4º, determina que as configurações-padrão dessas ferramentas adotem o mais alto nível de proteção disponível e inclui, entre as garantias mínimas, no inciso VIII, a

> *revisão regular das ferramentas de inteligência artificial, com participação de especialistas e órgãos competentes, com base em critérios técnicos que assegurem sua segurança e adequação ao uso por crianças e adolescentes, garantida a possibilidade de desabilitar funcionalidades não essenciais ao funcionamento básico dos sistemas (Brasil, 2025, art. 17, § 4º, VIII).*

O dispositivo institui, assim, um regime de revisão contínua de sistemas de IA, em vez de uma avaliação pontual, e se conecta ao art. 31, VII, que exige o detalhamento dos métodos e dos resultados das avaliações de impacto.

2.2. A BNCC e o Desenvolvimento do Pensamento Computacional e Crítico

A BNCC de Matemática estabelece cinco competências específicas para o Ensino Médio. A Competência Específica 1 prevê que os estudantes utilizem "estratégias, conceitos e procedimentos matemáticos para interpretar situações em diversos contextos, sejam atividades cotidianas, sejam fatos das Ciências da Natureza e Humanas, das questões socioeconômicas ou tecnológicas, divulgados por diferentes meios, de modo a contribuir para uma formação geral" (Brasil, 2018, p. 532). A Competência Específica 4 prevê que os estudantes compreendam e utilizem, "com flexibilidade e precisão, diferentes registros de representação matemáticos (algébrico, geométrico, estatístico, computacional etc.), na busca de solução e comunicação de resultados de problemas" (Brasil, 2018, p. 538).

No que tange ao pensamento computacional, a habilidade EM13MAT315 estabelece que os estudantes investiguem e registrem, “por meio de um fluxograma, quando possível, um algoritmo que resolve um problema” (Brasil, 2018, p. 537). A habilidade EM13MAT102 determina que os estudantes analisem “tabelas, gráficos e amostras de pesquisas estatísticas apresentadas em relatórios divulgados por diferentes meios de comunicação, identificando, quando for o caso, inadequações que possam induzir a erros de interpretação, como escalas e amostras não apropriadas” (Brasil, 2018, p. 533).

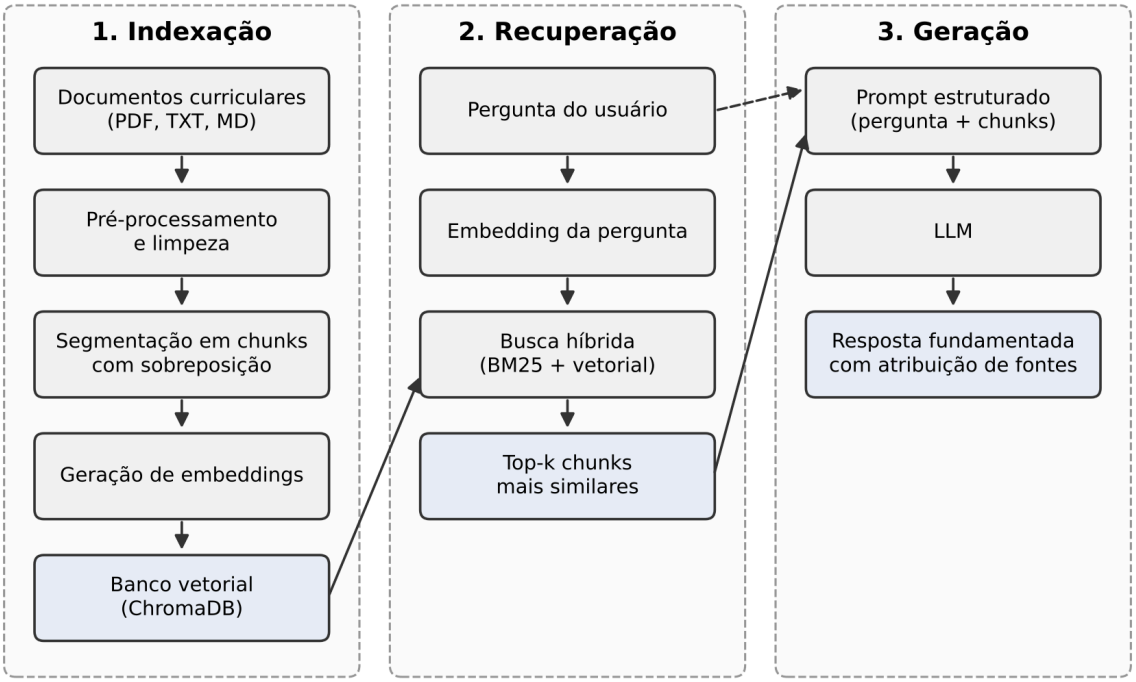
O Complemento de Computação à BNCC propõe que os estudantes desenvolvam habilidades para compreender o funcionamento de dispositivos computacionais, criar e simular algoritmos, representar informações de maneira estruturada e utilizar tecnologias digitais de forma segura, ética e responsável (Brasil, 2022). No Ensino Médio, suas competências específicas incluem a análise crítica de artefatos computacionais, com a identificação de suas vulnerabilidades, de modo a proteger a integridade, a privacidade, o sigilo e a segurança das informações (Brasil, 2022, p. 61). Entre as habilidades, destacam-se a EM13CO10, “Conhecer os fundamentos da Inteligência Artificial, comparando-a com a inteligência humana, analisando suas potencialidades, riscos e limites” (Brasil, 2022, p. 64); a EM13CO14, que prevê que os estudantes avaliem “a confiabilidade das informações encontradas em meio digital, investigando seus modos de construção e considerando a autoria, a estrutura e o propósito da mensagem” (Brasil, 2022, p. 66); a EM13CO06, que prevê a avaliação de “software levando em consideração diferentes características e métricas associadas” (Brasil, 2022, p. 62); e a EM13CO08, que trata de como “mudanças na tecnologia afetam a segurança, incluindo novas maneiras de preservar sua privacidade e dados pessoais on-line” (Brasil, 2022, p. 64).

2.3. A Arquitetura Retrieval-Augmented Generation (RAG)

A RAG integra sistemas de recuperação de informação a modelos generativos de linguagem com o propósito de aprimorar a precisão e a confiabilidade das respostas. A arquitetura foi proposta por Lewis *et al.* (2020), que combinaram uma memória paramétrica (um modelo *seq2seq* pré-treinado, o BART) com uma memória não paramétrica (um índice vetorial denso da Wikipedia, acessado por um recuperador neural, o *Dense Passage Retrieval* — DPR), treinando os componentes de forma conjunta e obtendo ganhos em tarefas intensivas em conhecimento, como resposta a perguntas de domínio aberto, geração de perguntas e verificação de fatos.

Diferentemente dos LLMs que dependem exclusivamente do conhecimento pré-treinado, a RAG recupera documentos relevantes de uma base de conhecimento externa antes de gerar a resposta (Lewis *et al.*, 2020; Taneja *et al.*, 2025). Esse processo em duas etapas tende a melhorar a precisão factual, a atualização do conhecimento e a transparência, o que o torna adequado a aplicações educacionais que exigem informações verificáveis (Gao *et al.*, 2024). O fluxo de trabalho da RAG compreende três estágios (Lewis *et al.*, 2020; Finardi *et al.*, 2024), ilustrados na Figura 1.

Figura 1. Pipeline RAG: fluxo de indexação, recuperação e geração



Fonte: elaborado pelo autor (2026).

No estágio de indexação, os documentos são pré-processados, segmentados em trechos (*chunks*) e convertidos em representações vetoriais (*embeddings*) armazenadas em um banco vetorial. A segmentação é uma decisão arquitetural: trechos extensos podem conter informações irrelevantes que degradam a precisão da recuperação, enquanto trechos reduzidos podem perder o contexto necessário à geração. No estágio de recuperação, os trechos mais relevantes para a consulta são identificados por recuperação esparsa (baseada em correspondência lexical, como o BM25), densa (baseada em *embeddings* neurais, como o DPR) ou híbrida, que combina as duas (Karpukhin *et al.*, 2020); a busca densa em grandes coleções apoia-se em bibliotecas de busca por similaridade, como a FAISS (Johnson; Douze; Jégou, 2021). Abordagens híbridas executam as buscas em paralelo e fundem os resultados por algoritmos como o *Reciprocal Rank Fusion* (RRF). No estágio de geração, o LLM sintetiza uma resposta a partir de um *prompt* que combina a consulta com os trechos recuperados (Lewis *et al.*, 2020).

Lewis *et al.* (2020) já apontavam a possibilidade de substituir o índice sem retreinar o modelo, o que é relevante para o contexto educacional, no qual currículos e materiais didáticos são atualizados periodicamente. Os autores também mostraram que modelos híbridos paramétricos e não paramétricos exigem menos parâmetros treináveis para alcançar alto desempenho em tarefas intensivas em conhecimento, o que fundamenta a viabilidade de implantações locais em escolas com recursos computacionais limitados.

A avaliação de sistemas RAG requer métricas que vão além da acurácia: Precisão@k e *Recall*@k mensuram a qualidade da recuperação, enquanto a fidelidade à fonte (*faithfulness*) e a relevância da resposta avaliam a geração. *Frameworks* como o RAGAS permitem a avaliação automática dessas métricas, como no trabalho de Borges (2025); como alternativa, Albuquerque *et al.* (2024) propuseram a avaliação por meio de *feedback* implícito, derivado das ações dos usuários sobre as respostas, e o uso de LLMs como avaliadores (*LLM-as-a-judge*), como no *framework* G-Eval, tem sido empregado para métricas qualitativas (Lima, M. V. de S., 2026). A integração da RAG em contextos educacionais também levanta questões éticas relacionadas à privacidade, ao viés nos dados e aos impactos sociais (Bostrom; Yudkowsky, 2014; Zeng *et al.*, 2024).

3. METODOLOGIA

A pesquisa adota abordagem qualitativa e exploratória e caracteriza-se como pesquisa bibliográfica. O método de abordagem é o hipotético-dedutivo, partindo da hipótese de que a arquitetura RAG, quando projetada com padrões de transparência e auditabilidade desde a concepção (*safety by design*), é uma solução tecnicamente

viável para assistentes educacionais de IA capazes de atender simultaneamente às exigências da Lei nº 15.211/2025, incluindo a revisão regular prevista no art. 17, § 4º, VIII, e às diretrizes da BNCC para a formação crítica.

O corpus é composto por documentos legais (Lei nº 15.211/2025, Lei nº 8.069/1990 e Lei nº 13.709/2018), documentos curriculares (BNCC e seu Complemento de Computação) e literatura científica — artigos, teses, dissertações e trabalhos de conclusão de curso sobre a arquitetura RAG e suas aplicações educacionais, publicados entre 2020 e 2026, com destaque para pesquisas em contexto brasileiro. A revisão da literatura caracteriza-se como revisão narrativa, cuja seleção de estudos se inspirou nas diretrizes do protocolo PRISMA (Moher *et al.*, 2009) e nas recomendações de Kitchenham e Charters (2007) e de Wohlin (2014) para revisões em engenharia de software e áreas afins.

Por se tratar de pesquisa sem mensuração experimental, a hipótese foi examinada a partir de três categorias de análise: a arquitetura de sistema (RAG com implantação local e base de conhecimento controlada), o quadro legal (Lei nº 15.211/2025) e o quadro curricular (BNCC). O critério de exame foi a correspondência entre os componentes da arquitetura proposta, as exigências da lei e as habilidades da BNCC, verificada por análise documental e por uma prova de conceito.

A prova de conceito consistiu na construção e na documentação técnica do sistema DeepEdu, um tutor de Matemática para o Ensino Médio baseado em RAG, disponível em repositório público (Lima, E. R. D., 2026). A descrição apresentada na seção 4.5 refere-se à versão correspondente ao *commit* 6d67901, de 1º de novembro de 2026, e

cada mecanismo descrito foi conferido no código-fonte dessa versão. A prova de conceito não constitui estudo empírico com estudantes: sua finalidade é demonstrar a exequibilidade técnica dos componentes arquiteturais propostos.

4. RESULTADOS E DISCUSSÃO

4.1. Pontos de Complementaridade Entre a Lei Nº 15.211/2025 e a BNCC

A análise documental permitiu identificar cinco pontos de complementaridade entre a lei e a BNCC. O primeiro é a formação para o uso crítico e seguro de tecnologias: a lei exige a promoção da educação digital (Brasil, 2025, art. 4º, VIII), e a BNCC propõe que os estudantes interpretem situações divulgadas por diferentes meios (Competência Específica 1 da Matemática) e compreendam a Computação como área que contribui para explicar o mundo atual (Brasil, 2022). O segundo é o letramento em dados e estatística: a lei veda práticas publicitárias predatórias (Brasil, 2025, art. 6º, V) e a criação de perfis comportamentais para publicidade (Brasil, 2025, art. 26), enquanto a BNCC ensina o estudante a identificar inadequações em tabelas, gráficos e amostras (Brasil, 2018, EM13MAT102) e a interpretar taxas e índices de natureza socioeconômica (Brasil, 2018, EM13MAT104).

O terceiro ponto é o pensamento computacional e algorítmico: a lei exige a revisão regular das ferramentas de IA (Brasil, 2025, art. 17, § 4º, VIII), e a BNCC forma o estudante para conhecer os fundamentos da IA, suas potencialidades, riscos e limites (Brasil, 2022, EM13CO10), e para investigar algoritmos por meio de fluxogramas (Brasil, 2018, EM13MAT315). O quarto é a supervisão parental e a autonomia

progressiva: a lei estabelece o dever parental de acompanhamento (Brasil, 2025, art. 3º, parágrafo único) e o respeito à autonomia e ao desenvolvimento progressivo (Brasil, 2025, art. 4º, V), e a BNCC desenvolve a capacidade de distinguir conteúdos confiáveis de não confiáveis na internet (Brasil, 2022, EF05CO08). O quinto é a transparência e a auditoria: a lei exige relatórios com o detalhamento dos métodos e dos resultados das avaliações de impacto (Brasil, 2025, art. 31, VII), e a BNCC forma o estudante para avaliar software com base em métricas (Brasil, 2022, EM13CO06) e avaliar a confiabilidade das informações em meio digital (Brasil, 2022, EM13CO14).

Esses pontos indicam que a arquitetura RAG pode ser tratada também como objeto pedagógico. Ao tornar visível o percurso entre a pergunta, a recuperação de fontes e a geração da resposta, a RAG oferece um objeto concreto para o desenvolvimento das habilidades EM13CO10, EM13CO14 e EM13CO06: o aluno pode verificar de onde a informação veio, quais documentos foram recuperados e como a resposta foi construída. A transparência estrutural da arquitetura atende, assim, a uma exigência legal e constitui, ao mesmo tempo, um recurso pedagógico alinhado à BNCC.

4.2. A RAG Como Resposta às Exigências Legais

A análise permitiu estabelecer uma correspondência entre os requisitos da Lei nº 15.211/2025 e as capacidades da arquitetura RAG. Quanto à auditabilidade, embora o art. 12, I, se refira à verificação de idade por lojas de aplicativos e sistemas operacionais, o princípio de que os mecanismos de proteção sejam auditáveis pode ser estendido, por analogia, aos sistemas de IA educacionais. Sistemas RAG oferecem rastreabilidade, pois cada resposta pode ser

vinculada aos documentos que a fundamentaram, por meio de metadados associados a cada trecho indexado (identificador do documento, data de indexação, versão do conteúdo e trilha de recuperação). A revisão sistemática de Yahaya *et al.* (2025) aponta ganhos na factualidade das respostas, no desempenho dos estudantes e na explicabilidade. Do ponto de vista pedagógico, essa rastreabilidade é também um recurso para a habilidade EM13CO14.

Quanto à transparência (art. 31), ainda que o dispositivo se dirija a provedores com mais de um milhão de usuários crianças e adolescentes, a proposta adota suas exigências como referência de boa prática: a base de conhecimento pode ser inspecionada por educadores, pais e alunos. Thesen e Park (2025) relatam que a transparência contribuiu para a confiança dos estudantes, que valorizaram saber que as respostas se fundamentavam em materiais curriculares. Quanto à prevenção de riscos (arts. 4º, IV, e 6º), a literatura indica que a RAG reduz a alucinação de LLMs (Nouali; Badache; Bellot, 2025; Lewis *et al.*, 2020) e reduz a alucinação na geração de saídas estruturadas (Béchard; Ayala, 2024); além disso, a arquitetura comporta camadas de validação de saída capazes de rejeitar respostas inadequadas.

Quanto ao controle parental e à supervisão (arts. 16 a 18), sistemas RAG implantados localmente favorecem a privacidade dos dados por dispensarem serviços de IA em nuvem: Taneja *et al.* (2025) desenvolveram um agente de aprendizagem baseado em RAG que reside na máquina local do aprendiz. A implantação local amplia o controle da escola sobre os dados e reduz a dependência de provedores externos. Quanto à configuração mais protetiva (art. 7º), a RAG pode operar, por padrão, com a base de conhecimento mais restrita e controlada, e o sistema pode comunicar explicitamente

quando não encontra informações suficientes, evitando respostas falsamente confiantes (Vetluzhskikh; Alam, 2025).

Quanto à revisão regular de ferramentas de IA (art. 17, § 4º, VIII), a arquitetura pode fornecer infraestrutura técnica por três razões: a base de conhecimento é inspecionável e versionada, o que permite examinar o corpus que fundamenta as respostas; a trilha de auditoria registra cada interação com metadados, o que permite a reconstrução retrospectiva de decisões; e a separação entre recuperação e geração permite atualizar componentes de forma independente (Lewis *et al.*, 2020; Finardi *et al.*, 2024). Por fim, quanto à minimização de dados (art. 12, § 1º, e art. 13), a arquitetura permite políticas de retenção granulares, incluindo a exclusão de *embeddings* armazenados e a desativação de bancos vetoriais quando necessário.

A indexação de documentos introduz, contudo, um vetor de ataque específico: documentos maliciosos podem conter instruções que, quando recuperadas, manipulam o comportamento do modelo gerador. Entre as medidas de mitigação estão controles pré-recuperação, sanitização do conteúdo indexado e validação da integridade dos documentos-fonte. O versionamento da base de conhecimento, por sua vez, permite que respostas geradas em momentos diferentes sejam auditadas com referência à versão do conteúdo vigente à época.

4.3. Aplicações Educacionais da RAG: Síntese da Literatura (2020-2026)

Os estudos revisados concentram-se em resposta a perguntas, aprendizagem personalizada e tutoria. Em tutoria baseada em

currículo, a busca vetorial pode ser combinada a filtros de metadados, como curso, módulo e tópico, restringindo a recuperação aos conteúdos relevantes (Lima, M. V. de S., 2026). Pampel, Martin e Padó (2025) desenvolveram uma solução de baixo código que permite a educadores com alguma familiaridade técnica construir seus próprios *chatbots* baseados em RAG, mantendo controle sobre o conteúdo e o comportamento do sistema. Em cursos online massivos, Miladi *et al.* (2025) avaliaram um agente conversacional com RAG junto a 25 aprendizes e relataram ganho de conhecimento de 17% no grupo experimental, contra 10% no grupo de controle (p = 0,017), com pontuação média de 80,4 no *System Usability Scale* (SUS).

Em educação médica, Thesen e Park (2025) desenvolveram o NeuroBot TA, assistente que responde apenas a perguntas que pode fundamentar com materiais curriculares selecionados; o estudo acompanhou 190 estudantes, e quase metade dos 143 respondentes da pesquisa final considerou o software um auxílio de estudo útil. Vetluzhskikh e Alam (2025) introduziram o RAGent, que classifica as perguntas em diretamente respondíveis, relevantes mas não resolvidas e fora do escopo; em estudo com 125 estudantes, 94,4% responderam “sim” ou “talvez” quando perguntados se gostariam de manter o sistema no curso. Lang e Gürpinar (2025) também investigaram a efetividade de um *chatbot* RAG em curso online. A integração entre RAG e agentes, como na abordagem ReAct, que intercala raciocínio e ação, tem sido explorada para ampliar a adaptabilidade desses sistemas (Yao *et al.*, 2022; Souza; Souza; Dias, 2024).

No contexto brasileiro, Coelho, Nascimento Junior e Gomes (2025) aplicaram a RAG a consultas em linguagem natural ao Projeto

Pedagógico de um curso de Ensino Médio Integrado ao Técnico. O CEIA-UFG (2025) disponibilizou o GAIA-EDU, corpus curricular com 8.135 registros em português, incluindo questões do ENEM e do ENCCEJA, habilidades da BNCC e cadernos da OBMEP. Taschetto e Fileto (2024) verificaram que a combinação de RAG com três exemplos no *prompt* melhora o desempenho de LLMs em questões do ENEM, particularmente em Matemática e Ciências da Natureza. Estrela *et al.* (2024) desenvolveram o CosmoBot, de apoio a avaliações de algoritmos, e Carneiro (2025) aplicou a RAG à geração automática de questões a partir de um regulamento esportivo.

Também no Brasil, Schweizer Silvestre (2025) desenvolveu um *chatbot* sobre normas acadêmicas da Universidade de Brasília, avaliado por 34 alunos; Bordin *et al.* (2025) apresentaram o UniChat, com taxa de sucesso de 76,7% em avaliação com usuários reais; Rodrigues *et al.* (2025) apresentaram o Sabiá, avaliado com a abordagem *LLM-as-a-Judge*; Soares *et al.* (2025) desenvolveram um assistente integrado ao WhatsApp para dúvidas de um curso de licenciatura em Computação; e Oliveira (2025) desenvolveu o PLUTO, que obteve média geral de 9,87 (escala de 0 a 10) em teste com 15 perguntas frequentes. Ferreira (2025) relatou, em um tutor virtual para um curso técnico a distância, aumento de 45 pontos percentuais na completude da resposta (de 16% para 61%) e de 32 pontos percentuais na resolução da intenção (de 63% para 95%). Borges (2025) não encontrou diferença estatisticamente significativa na métrica *Factual Correctness* entre um modelo proprietário e um modelo *open-weight*. Lima, M. V. de S. (2026) verificou, com modelos como GPT-4o, LLaMA 3 e DeepSeek-LLM, que o uso de RAG orientada por metadados melhorou todas as métricas avaliadas, sobretudo a *Faithfulness*. Carlos (2025) executou localmente o Llama 3.2, via Ollama, em um sistema RAG sobre teses e dissertações, e

relatou desafios ligados à qualidade dos dados de origem, ao *chunking* e às capacidades de LLMs de menor porte.

Permanecem, contudo, desafios no raciocínio, na precisão da recuperação e na integração dos sistemas (Gao *et al.*, 2024). A revisão de Yahaya *et al.* (2025) identificou limitações persistentes, como restrições de infraestrutura, viés de dados e preocupações éticas, e concluiu que o acesso equitativo e a implementação responsável permanecem críticos. Song *et al.* (2024) propuseram o RAG-HAT, que reduziu a taxa de alucinações em cerca de 27%, em termos relativos, e Béchard e Ayala (2024) mostraram que um recuperador supervisionado reduziu a taxa de alucinações em saídas estruturadas de até 21% para menos de 7,5% nos passos e menos de 4,5% nas tabelas. A latência e a sobrecarga computacional também aparecem como desafios recorrentes em ambientes com restrições de infraestrutura (Souza; Souza; Dias, 2024). Em conjunto, os estudos indicam ganhos de aprendizagem e boa aceitação pelos estudantes em diferentes contextos, mas a maior parte foi conduzida no ensino superior e com amostras reduzidas.

4.4. Modelo de Implementação da RAG em Escolas

Com base na literatura e nas exigências da lei e da BNCC, propõe-se um modelo de implementação composto por cinco componentes. O primeiro é uma base de conhecimento curricular controlada, formada por documentos curriculares oficiais, materiais didáticos adotados pela escola e conteúdo produzido pelos professores, inspecionável por educadores, pais e alunos, com metadados de fonte, data, versão, público-alvo e status de aprovação, organizada em coleções que podem ser ativadas ou desativadas conforme o contexto pedagógico e a faixa etária. Esses metadados permitem

filtrar a recuperação por parâmetros do contexto, à semelhança dos filtros por curso, módulo e tópico empregados por Lima, M. V. de S. (2026). O segundo é um sistema de indexação e recuperação híbrida, que combina recuperação lexical para termos técnicos e curriculares e recuperação semântica para consultas conceituais (Karpukhin *et al.*, 2020), com segmentação adequada à natureza do conteúdo educacional.

O terceiro componente é um modelo generativo de pesos abertos, como os da família LLaMA (Touvron *et al.*, 2023), implantado localmente para favorecer a soberania de dados. Taneja *et al.* (2025) verificaram que um modelo de pequeno porte executado localmente com RAG produziu resumos semanticamente próximos aos do GPT-4o, segundo a métrica BERTScore, e Touvron *et al.* (2023) relatam que o LLaMA-13B pode ser executado em uma única GPU. O quarto componente reúne camadas de transparência e auditoria: painel de governança com métricas de recuperação, fidelidade à fonte e taxa de recusa; atribuição de fontes até o nível do trecho recuperado (Lewis *et al.*, 2020); e comunicação de incerteza quando não há informação suficiente na base (Vetluzhskikh; Alam, 2025), com limiar de similaridade para recusa configurável pela escola e auditável. O quinto componente reúne mecanismos de supervisão parental e controle de acesso: verificação de idade conforme o art. 9º da lei, sem criação de perfis individualizados; controle de acesso baseado em papéis para alunos, professores, responsáveis e administradores; possibilidade de desativar funcionalidades não essenciais, conforme o art. 17, § 4º, VIII; e revisão das interações por educadores e responsáveis.

O fluxo de funcionamento proposto compreende autenticação com minimização de dados, consulta em linguagem natural, recuperação

híbrida, geração restrita ao contexto recuperado, apresentação da resposta com as fontes, registro das interações em trilha de auditoria, revisão periódica com participação de especialistas e incorporação de *feedback*. O Quadro 1 sintetiza a correspondência entre os componentes da arquitetura e as habilidades da BNCC.

Quadro 1. Correspondência entre componentes da arquitetura RAG e habilidades da BNCC

Componente da RAG	**Habilidade da BNCC**	**Como a habilidade é materializada**
Pipeline de recuperação e geração (pergunta → recuperação → geração → resposta)	EM13CO10; EM13MAT315	O aluno visualiza o fluxo algorítmico e compreende que a resposta é fundamentada em documentos, e não gerada sem origem identificável.
Atribuição de fontes (metadados de chunk, documento e data)	EM13CO14; EM13MAT102	O aluno verifica a proveniência da informação e avalia sua confiabilidade.
Painel de governança (métricas de precisão, recall, fidelidade)	EM13CO06	O aluno analisa o software com base em métricas, comparando desempenho e limitações.
Política de abstenção e comunicação de incerteza	EM13CO10; EM13CO08	O aluno compreende os limites da IA e a importância de não confiar cegamente em respostas não fundamentadas.
Mecanismos de pseudonimização e minimização de dados	EM13CO08	O aluno entende como a tecnologia pode ser projetada para preservar a privacidade.

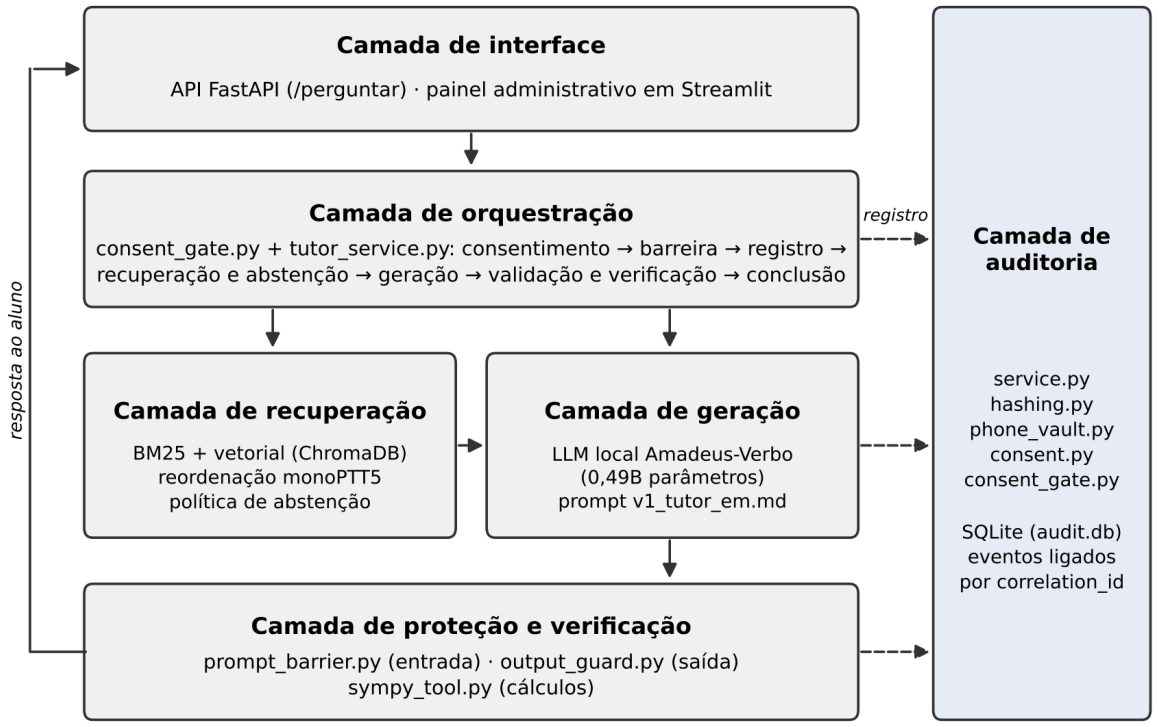
Fonte: elaborado pelo autor (2026).

A visualização do pipeline (Figura 1) permite ao aluno compreender que a resposta resulta de um processo de recuperação e geração (EM13CO10), e o próprio fluxo pergunta–recuperação–geração–resposta pode ser representado em fluxograma, com suas decisões (“há documentos suficientes?”) e saídas (resposta fundamentada ou recusa), o que corresponde à habilidade EM13MAT315. A atribuição de fontes, acompanhada do documento, do trecho e da data de indexação, permite verificar não apenas o que o sistema respondeu, mas de onde a informação veio (EM13CO14). As métricas do painel de governança podem ser analisadas pelos alunos, que podem comparar configurações e identificar limitações (EM13CO06), e os mecanismos de pseudonimização servem como exemplo de projeto orientado à privacidade (EM13CO08).

4.5. Prova de Conceito: O Sistema DeepEdu

O DeepEdu é um tutor de Matemática para o Ensino Médio construído sobre a arquitetura RAG (Lima, E. R. D., 2026). Conforme a documentação do projeto, a RAG é o objeto auditado, e não o tema da pesquisa. O sistema adota arquitetura em camadas, com separação entre interface, orquestração, recuperação, geração, proteção e verificação, e auditoria, como ilustra a Figura 2.

Figura 2. Arquitetura em camadas do sistema DeepEdu



Fonte: elaborado pelo autor (2026).

A camada de interface expõe uma API em FastAPI, cujo ponto de entrada para perguntas é o *endpoint* /perguntar, e um painel administrativo em Streamlit. A recuperação combina a busca lexical BM25 (peso 0,35) e a busca vetorial no ChromaDB (peso 0,65), funde as listas por *Reciprocal Rank Fusion* ponderada e reordena os trechos com o modelo monoPTT5, mantendo os três mais relevantes. A geração utiliza o modelo Amadeus-Verbo, com 0,49 bilhão de parâmetros, em português, executado localmente. O Quadro 2 apresenta as tecnologias e as versões declaradas nos arquivos de dependências do projeto.

Quadro 2. Tecnologias utilizadas no sistema DeepEdu

Componente	Tecnologia	Versão	Função no sistema
Linguagem	Python	3.11+	Ecossistema maduro para IA

Framework web	FastAPI	0.115.0	API assíncrona com tipagem
Servidor ASGI	Uvicorn + Gunicorn	0.30.6 / 23.0.0	Execução em produção
Orquestração RAG	LangChain	0.3.0	Abstração de pipelines
Banco vetorial	ChromaDB	0.5.3	Armazenamento local dos vetores
Busca lexical	rank-bm25	0.2.2	BM25 para recuperação híbrida
Embeddings	sentence-transformers	3.1.1	paraphrase-multilingual-MiniLM-L12-v2
Reordenação	Transformers (monoPTT5)	≥4.37.0	unicamp-dl/monoptt5-3b
LLM	Hugging Face Transformers	≥4.37.0	amadeusai/Amadeus-Verbo-FI-Qwen2.5-0.5B-PT-BR-Instruct
Extração de PDF	PyMuPDF + pypdf	1.24.10 / 5.0.1	Extração de texto, com alternativa de contingência
Ferramenta matemática	SymPy	1.13.2	Verificação simbólica de cálculos
Criptografia	cryptography (Fernet)	43.0.1	Cifragem do telefone do estudante
Observabilidade	LangSmith	0.1.125	Rastreamento opcional (serviço externo; desativado por padrão)
Painel administrativo	Streamlit	1.39.0	Gestão de materiais, matrículas e auditoria

Testes	unittest (biblioteca padrão)	—	Testes sem dependência externa

Fonte: elaborado pelo autor (2026), com base nos arquivos de dependências do repositório (Lima, E. R. D., 2026).

Sete mecanismos da implementação são relevantes como evidência da viabilidade técnica da proposta. O primeiro é a pseudonimização de identificadores: o identificador do estudante é transformado em *hash* SHA-256 com *salt* antes do registro em auditoria, e o telefone, quando precisa ser armazenado de forma recuperável, como na matrícula, é cifrado de forma simétrica. Isso permite que a trilha de auditoria seja reconstruível sem conter dados pessoais diretamente identificáveis. O segundo é a verificação de consentimento a cada mensagem: nenhuma pergunta é processada sem aceite ativo e vigente do estudante; uma nova versão dos termos exige novo aceite, a revogação remove o histórico da conversa e os eventos de consentimento usam política *fail-closed*. Na versão analisada, a existência de matrícula verificada não é condição para o atendimento.

O terceiro mecanismo é a política de abstenção, que leva o sistema a recusar-se a responder quando não há documentos recuperados ou quando a maior pontuação, normalizada para o intervalo de 0 a 1, fica abaixo do limiar de 0,35; cada decisão é registrada em auditoria com seus metadados. O quarto é a recuperação híbrida auditada, registrada na trilha de auditoria por meio de uma classe que aplica o padrão de projeto *Decorator* para acrescentar o registro a qualquer recuperador. O quinto é um *prompt* do tutor com contrato explícito, que restringe a resposta ao material delimitado entre marcadores de contexto, exige passos numerados e citação da fonte, proíbe a

invenção de teoremas e resultados e define um formato de resposta em quatro partes.

O sexto mecanismo reúne proteções na entrada e na saída do modelo: uma barreira contra injeção de instruções delimita a pergunta do aluno no *prompt* e neutraliza tentativas de manipulação; a validação de saída bloqueia respostas que vazem instruções internas ou contenham conteúdo impróprio para menores, como violência, autolesão, conteúdo sexual, drogas ou ofensas; e a verificação simbólica, com SymPy, confere os cálculos apresentados. Essas camadas materializam, no plano técnico, os fundamentos do art. 4º, IV, e as obrigações de prevenção de riscos do art. 6º da Lei nº 15.211/2025, ainda que por meio de listas de padrões, e não de classificadores treinados.

O sétimo mecanismo é a trilha de auditoria com política de falha diferenciada: os eventos centrais do atendimento e os de consentimento são gravados em modo *fail-closed*, de modo que a operação é interrompida se o registro falhar, enquanto os eventos auxiliares são gravados em modo *fail-open*. A trilha alimenta um painel de métricas consolidadas (taxa de abstenção, bloqueios, tentativas de manipulação neutralizadas e acerto dos cálculos), calculadas exclusivamente a partir dos eventos registrados, e cada reindexação gera uma versão numerada da base de conhecimento, com o *hash* de cada material, registrada em cada resposta e passível de restauração. O sistema permite, ainda, desativar por configuração a reordenação e o rastreamento externo sem comprometer o funcionamento básico, e o repositório inclui documentos de conformidade, como avaliação de impacto à proteção de dados, registro das operações de tratamento e *checklist* do Estatuto Digital.

Esses elementos oferecem suporte concreto à revisão regular exigida pelo art. 17, § 4º, VIII.

O projeto inclui 59 testes unitários, distribuídos em dez arquivos e executados por integração contínua, que verificam, entre outros aspectos, o núcleo de auditoria, o fluxo de consentimento, a política de abstenção, a barreira contra injeção, a validação de saída, o versionamento da base e o cálculo das métricas. Na versão analisada, os 59 testes foram executados sem falhas em ambiente local com todas as dependências instaladas. O repositório contém também um conjunto de 50 perguntas de referência e um *script* de avaliação automatizada, cuja execução depende do modelo de linguagem e dos materiais indexados; seus resultados não são relatados neste artigo.

Esses mecanismos, em conjunto, materializam a noção de sistema "auditável por projeto" (*auditable by design*): a auditabilidade está no caminho crítico do sistema, e não na periferia. A prova de conceito apresenta, contudo, limitações: a base de conhecimento é uma amostra; não houve avaliação com estudantes; o modelo de linguagem é de pequeno porte; a barreira e a validação de saída baseiam-se em listas fixas de palavras e expressões, que podem não detectar formulações ausentes da lista e podem bloquear respostas legítimas; a verificação simbólica restringe-se a expressões aritméticas reconhecíveis; figuras e PDFs escaneados sem OCR não são indexados; não foram realizados testes de escalabilidade; e a matrícula e o consentimento dos responsáveis são registrados administrativamente, mas não são exigidos no fluxo de atendimento.

5. CONSIDERAÇÕES FINAIS

A Lei nº 15.211/2025 e a BNCC, embora sejam documentos de naturezas distintas, convergem para um objetivo comum: preparar crianças e adolescentes para uma interação segura, crítica e ética com as tecnologias digitais. A lei estabelece exigências de transparência, auditabilidade, proteção contra violência e revisão regular de ferramentas de IA; a BNCC oferece o arcabouço curricular para desenvolver as competências necessárias para que os estudantes compreendam essas proteções e saibam exigi-las.

Em resposta ao problema de pesquisa, a análise indica que a arquitetura RAG pode ser utilizada para desenvolver assistentes educacionais de IA em conformidade com a Lei nº 15.211/2025 e alinhados à BNCC por meio de quatro características: a restrição das respostas a uma base de conhecimento curricular controlada e inspecionável; a atribuição explícita de fontes e o registro de cada interação em trilha de auditoria; a política de abstenção, que leva o sistema a não responder quando não há fundamentação suficiente; e a separação modular entre recuperação e geração, que permite revisar componentes de forma independente, como pede o art. 17, § 4º, VIII. Essas mesmas características tornam visível ao aluno o percurso entre a pergunta, a recuperação de fontes e a geração da resposta, o que as converte em objeto de estudo para as habilidades EM13CO10, EM13CO14, EM13CO06 e EM13MAT315.

A hipótese central encontra sustentação no plano da viabilidade técnica. A implementação do DeepEdu mostra que pseudonimização de identificadores, verificação de consentimento a cada mensagem, política de abstenção, recuperação híbrida auditada, contrato explícito de *prompt*, barreira contra injeção de instruções, validação de saída, verificação simbólica de cálculos, trilha de auditoria com política de falha diferenciada, versionamento

da base de conhecimento e métricas consolidadas podem ser implementados em conjunto em um mesmo sistema, executado localmente e com modelo de linguagem de pequeno porte. A eficácia pedagógica do sistema não foi objeto desta pesquisa e permanece por ser avaliada.

A principal contribuição do trabalho está em mostrar que a conformidade legal e a formação crítica podem ser tratadas de forma integrada. Quando a IA é concebida como auditável por projeto, os mesmos mecanismos que permitem à escola cumprir as exigências legais oferecem aos alunos um objeto concreto para compreender os fundamentos, as potencialidades e os limites da inteligência artificial.

O estudo apresenta limitações. A revisão narrativa não pretende ser exaustiva, e a maior parte dos estudos revisados foi conduzida no ensino superior e com amostras reduzidas, o que limita sua transposição direta para a educação básica. A prova de conceito não foi avaliada com estudantes, utiliza modelo de 0,49 bilhão de parâmetros e base de conhecimento restrita, e suas proteções de entrada e de saída baseiam-se em listas de padrões. A correspondência entre alguns dispositivos legais (arts. 12 e 31) e o contexto escolar foi estabelecida por analogia e poderá ser revista à luz da regulamentação a ser editada pela autoridade administrativa competente.

Para pesquisas futuras, recomendam-se estudos empíricos no contexto brasileiro que avaliem a eficácia de sistemas RAG em diferentes níveis de ensino e disciplinas; a criação de diretrizes específicas para a implementação da RAG em escolas, consideradas as assimetrias regulatórias e infraestruturais do país; a substituição

das listas de padrões por classificadores treinados, com avaliação de falsos positivos e falsos negativos; o desenvolvimento de metodologias para a formação continuada de educadores no uso crítico desses sistemas; e a avaliação dos impactos de longo prazo do uso da RAG no desenvolvimento cognitivo e crítico de crianças e adolescentes.

REFERÊNCIAS BIBLIOGRÁFICAS

ALBUQUERQUE, A. M. de *et al.* Avaliação de aplicações de geração aumentada de recuperação por meio de feedback implícito. In: SIMPÓSIO BRASILEIRO DE BANCOS DE DADOS (SBBD), 39., 2024, Florianópolis. **Anais Estendidos** [...]. Porto Alegre: SBC, 2024. p. 253-259.

BÉCHARD, P.; AYALA, O. M. Reducing hallucination in structured outputs via retrieval-augmented generation. In: CONFERENCE OF THE NORTH AMERICAN CHAPTER OF THE ASSOCIATION FOR COMPUTATIONAL LINGUISTICS: HUMAN LANGUAGE TECHNOLOGIES, 2024, Mexico City. **Proceedings** [...]. Volume 6: Industry Track. Mexico City: ACL, 2024. p. 228-238.

BORDIN, A. C. B. *et al.* UniChat: arquitetura e avaliação de um agente RAG de baixo custo para o contexto universitário. In: SIMPÓSIO BRASILEIRO DE BANCOS DE DADOS (SBBD), 40., 2025, Fortaleza. **Anais** [...]. Porto Alegre: SBC, 2025. p. 886-892.

BORGES, J. M. **Desenvolvimento e avaliação de chatbot pedagógico open source com RAG para educação online.** 2025. 96 f. Trabalho de Conclusão de Curso (Bacharelado em Sistemas de Informação) — Universidade Federal de Uberlândia, Uberlândia, 2025.

BOSTROM, N.; YUDKOWSKY, E. The ethics of artificial intelligence. In: FRANKISH, K.; RAMSEY, W. M. (ed.). **The Cambridge handbook of artificial intelligence.** Cambridge: Cambridge University Press, 2014. p. 316-334.

BRASIL. **Lei nº 15.211, de 17 de setembro de 2025.** Dispõe sobre a proteção de crianças e adolescentes em ambientes digitais (Estatuto Digital da Criança e do Adolescente). Brasília, DF: Presidência da República, 2025. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2023-2026/2025/lei/l15211.htm. Acesso em: 15 mar. 2026.

BRASIL. Ministério da Educação. **Base Nacional Comum Curricular.** Brasília, DF: MEC, 2018. Disponível em: https://basenacionalcomum.mec.gov.br/. Acesso em: 15 mar. 2026.

BRASIL. Ministério da Educação. Conselho Nacional de Educação. Câmara de Educação Básica. **Normas sobre computação na educação básica:** complemento à BNCC. Parecer CNE/CEB nº 2/2022 e Resolução CNE/CEB nº 1/2022. Brasília, DF: MEC, 2022. Disponível em: https://portal.mec.gov.br/ima/apresentacao/30000-uncategorised/61911-base-nacional-comum-curricular-bncc-2. Acesso em: 15 mar. 2026.

BROWN, T. B. *et al.* Language models are few-shot learners. **Advances in Neural Information Processing Systems,** v. 33, p. 1877-1901, 2020.

CARLOS, L. L. **RAG acadêmico:** facilitando o acesso à informação com LLMs e repositórios abertos de universidades. 2025. Monografia (Bacharelado em Engenharia de Computação) — Universidade

Federal do Rio Grande do Sul, Porto Alegre, 2025. Disponível em: https://lume.ufrgs.br/handle/10183/294650. Acesso em: 15 mar. 2026.

CARNEIRO, Y. P. R. G. **Geração automática de questões com RAG e processamento de linguagem natural:** um estudo aplicado ao regulamento da World Triathlon. 2025. Trabalho de Conclusão de Curso (Bacharelado em Sistemas de Informação) — Instituto Federal do Espírito Santo, Cachoeiro de Itapemirim, 2025.

CEIA-UFG. **GAIA-EDU:** corpus RAG (conteúdo curricular brasileiro). Hugging Face, 2025. Disponível em: https://huggingface.co/datasets/CEIA-GAIA-EDU/gaia-edu-corpus-rag. Acesso em: 5 nov. 2026.

COELHO, D. S.; NASCIMENTO JUNIOR, N.; GOMES, A. S. M. Aplicação prática da arquitetura RAG no desenvolvimento de interfaces educacionais com IA. **REGRASP,** v. 10, n. 4, p. 69-74, 2025. DOI: 10.47734/regrasp.v10.04.p69-74.

ESTRELA, I. R. B. *et al.* Ferramenta CosmoBot: um chatbot de apoio a alunos em avaliações de algoritmos. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (SBIE), 35., 2024, Rio de Janeiro. **Anais** [...]. Porto Alegre: SBC, 2024. p. 380-391. DOI: 10.5753/sbie.2024.242585.

FERREIRA, M. S. **Tutor virtual baseado em inteligência artificial:** uma ferramenta de apoio ao curso técnico em Multimeios Didáticos do Câmpus São João da Boa Vista. 2025. 41 p. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) — Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, São João da Boa Vista, 2025. Disponível em: https://repositorio.ifsp.edu.br/server/api/core/bitstreams/30d5129a-9b80-43b1-957b-a87dd34d7e78/content. Acesso em: 5 nov. 2026.

FINARDI, P. *et al.* **The chronicles of RAG:** the retriever, the chunk and the generator. arXiv preprint arXiv:2401.07883, 2024. Disponível em: https://arxiv.org/abs/2401.07883. Acesso em: 15 mar. 2026.

GAO, Y. *et al.* **Retrieval-augmented generation for large language models:** a survey. arXiv preprint arXiv:2312.10997, 2024. Disponível em: https://arxiv.org/abs/2312.10997. Acesso em: 15 mar. 2026.

JOHNSON, J.; DOUZE, M.; JÉGOU, H. Billion-scale similarity search with GPUs. **IEEE Transactions on Big Data,** v. 7, n. 3, p. 535-547, 2021. DOI: 10.1109/TBDATA.2019.2921572.

KARPUKHIN, V. *et al.* Dense passage retrieval for open-domain question answering. In: CONFERENCE ON EMPIRICAL METHODS IN NATURAL LANGUAGE PROCESSING (EMNLP), 2020. **Proceedings** [...]. [*S. l.*]: ACL, 2020. p. 6769-6781. DOI: 10.18653/v1/2020.emnlp-main.550.

KITCHENHAM, B.; CHARTERS, S. **Guidelines for performing systematic literature reviews in software engineering.** Version 2.3. Keele: Keele University; Durham: Durham University, 2007. (Technical Report EBSE-2007-01).

LANG, G.; GÜRPINAR, T. AI-powered learning support: a study of retrieval-augmented generation (RAG) chatbot effectiveness in an online course. **Information Systems Education Journal,** v. 23, n. 2, p. 4-13, 2025. DOI: 10.62273/ZKLK5988.

LEWIS, P. *et al.* Retrieval-augmented generation for knowledge-intensive NLP tasks. **Advances in Neural Information Processing Systems,** v. 33, p. 9459-9474, 2020.

LIMA, E. R. D. **DeepEdu:** tutor de Matemática auditável baseado em RAG. Versão do commit 6d67901, 1 nov. 2026. Repositório GitHub. Disponível em: https://github.com/edidiodantas/deepEdu. Acesso em: 1 nov. 2026.

LIMA, M. V. de S. **Uso de RAG e engenharia de prompt para mitigação de alucinações em LLMs no contexto de plataformas educacionais.** 2026. Trabalho de Conclusão de Curso (Bacharelado em Sistemas de Informação) — Universidade Federal do Ceará, Quixadá, 2026.

MILADI, F. *et al.* Evaluating a GPT-4 and retrieval-augmented generation-based conversational agent to enhance learning experience in a MOOC. In: INTERNATIONAL CONFERENCE ON COMPUTER SUPPORTED EDUCATION (CSEDU), 17., 2025. **Proceedings** [...]. [*S. l.*]: SciTePress, 2025. p. 347-354. DOI: 10.5220/0013366100003932.

MOHER, D. *et al.* Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. **PLoS Medicine,** v. 6, n. 7, e1000097, 2009.

NOUALI, S.; BADACHE, I.; BELLOT, P. Exploration du RAG pour la génération de réponses à des questions en contexte éducatif: étude sur les données SCIQ. In: WORKSHOP EN INTELLIGENCE ARTIFICIELLE GÉNÉRATIVE ET ÉDUCATION (IA-ÉDU@CORIA-TALN2025), 1., 2025, Marseille. **Actes** [...]. Marseille: Aix-Marseille Université, 2025. p. 29-41.

OLIVEIRA, E. S. de. **PLUTO:** um sistema de chatbot que utiliza IA e a abordagem RAG para responder dúvidas sobre o SIGAA. 2025. Trabalho de Conclusão de Curso (Graduação em Ciência da

Computação) — Universidade Federal de Alagoas, Campus Arapiraca, Arapiraca, 2025. Disponível em: https://ud10.arapiraca.ufal.br/repositorio/publicacoes/5907. Acesso em: 1 nov. 2026.

PAMPEL, B.; MARTIN, S.; PADÓ, U. Regaining control: enabling educators to build specialized AI chat bots with retrieval augmented generation. In: INTERNATIONAL CONFERENCE ON COMPUTER SUPPORTED EDUCATION (CSEDU), 17., 2025. **Proceedings** [...]. [*S. l.*]: SciTePress, 2025. p. 371-378. DOI: 10.5220/0013425500003932.

RODRIGUES, G. B. *et al.* Sabiá: um chatbot de inteligência artificial generativa para suporte no dia a dia do ensino superior. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (SBIE), 36., 2025, Curitiba. **Anais** [...]. Porto Alegre: SBC, 2025. p. 1401-1414. DOI: 10.5753/sbie.2025.12925.

SCHWEIZER SILVESTRE, A. S. **Retrieval augmented generation aplicado a um ChatBot para estudantes sobre procedimentos e normas acadêmicas da UnB.** 2025. 52 p. Monografia (Bacharelado em Ciência da Computação) — Universidade de Brasília, Brasília, 2025. Disponível em: https://bdm.unb.br/bitstream/10483/43115/1/2025_AnaSofiaSchweizerSilvestre_tcc.pdf. Acesso em: 5 nov. 2026.

SOARES, R. R. P. *et al.* Desenvolvimento de um assistente virtual como suporte acadêmico do curso de licenciatura em Computação usando IA generativa personalizada e RAG. **Revista Sítio Novo,** Palmas, v. 9, e1757, 2025. DOI: 10.47236/2594-7036.2025.v9.1757. Disponível em:

https://sitionovo.ifto.edu.br/index.php/sitionovo/article/view/1757. Acesso em: 5 nov. 2026.

SONG, J. *et al.* RAG-HAT: a hallucination-aware tuning pipeline for LLM in retrieval-augmented generation. In: CONFERENCE ON EMPIRICAL METHODS IN NATURAL LANGUAGE PROCESSING, 2024, Miami. **Proceedings** [...]: Industry Track. Miami: ACL, 2024. p. 1548-1558. DOI: 10.18653/v1/2024.emnlp-industry.113.

SOUZA, A. H. N. M. de; SOUZA, I. M. de; DIAS, J. C. Arquitetura RAG e agentes. **Interface Tecnológica,** v. 21, n. 2, p. 15-26, 2024. DOI: 10.31510/infa.v21i2.1995.

TANEJA, S. *et al.* Agentic RAG for personalized learning: design of an AI-powered learning agent using open-source small language models. **Electronic Journal of e-Learning,** v. 23, n. 4, p. 69-80, 2025. DOI: 10.34190/ejel.23.4.4044.

TASCHETTO, L. de C.; FILETO, R. Using retrieval-augmented generation to improve performance of large language models on the Brazilian university admission exam. In: SIMPÓSIO BRASILEIRO DE BANCOS DE DADOS (SBBD), 39., 2024, Florianópolis. **Anais** [...]. Porto Alegre: SBC, 2024. p. 799-805.

THESEN, T.; PARK, S. H. A generative AI teaching assistant for personalized learning in medical education. **npj Digital Medicine,** v. 8, art. 627, 2025. DOI: 10.1038/s41746-025-02022-1.

TOUVRON, H. *et al.* **LLaMA:** open and efficient foundation language models. arXiv preprint arXiv:2302.13971, 2023. Disponível em: https://arxiv.org/abs/2302.13971. Acesso em: 15 mar. 2026.

VETLUZHSKIKH, M.; ALAM, F. F. RAGent: a self-learning RAG agent for adaptive data science education. In: INTERNATIONAL COMPUTER PROGRAMMING EDUCATION CONFERENCE (ICPEC 2025), 6., 2025. **Proceedings** [...]. Dagstuhl: Schloss Dagstuhl — Leibniz-Zentrum für Informatik, 2025. p. 8:1-8:10. DOI: 10.4230/OASIcs.ICPEC.2025.8.

WOHLIN, C. Guidelines for snowballing in systematic literature studies and a replication in software engineering. In: INTERNATIONAL CONFERENCE ON EVALUATION AND ASSESSMENT IN SOFTWARE ENGINEERING (EASE '14), 18., 2014. **Proceedings** [...]. New York: ACM, 2014. p. 1-10. DOI: 10.1145/2601248.2601268.

YAHAYA, N. *et al.* AI-powered learning content generation through retrieval-augmented generation for improved accuracy and personalisation. **Jurnal Pendidikan Malaysia,** v. 50, n. 2, p. 58-68, 2025. DOI: 10.17576/JPEN-2025-50.02-01.

YAO, S. *et al.* **ReAct:** synergizing reasoning and acting in language models. arXiv preprint arXiv:2210.03629, 2022. Disponível em: https://arxiv.org/abs/2210.03629. Acesso em: 15 mar. 2026.

ZENG, S. *et al.* The good and the bad: exploring privacy issues in retrieval-augmented generation (RAG). In: FINDINGS OF THE ASSOCIATION FOR COMPUTATIONAL LINGUISTICS: ACL 2024, 2024, Bangkok. **Findings** [...]. Bangkok: Association for Computational Linguistics, 2024. p. 4505-4524. DOI: 10.18653/v1/2024.findings-acl.267.

---

[1] Mestrando do Programa de Pós-Graduação em Ensino de Ciências e Matemática da Universidade Cruzeiro do Sul. Este artigo deriva da dissertação de mestrado do autor, em andamento nesse programa.

Professor titular dos cursos de Análise e Desenvolvimento de Sistemas e de Ciência da Computação da Universidade Cruzeiro do Sul. Especialista em Formação Pedagógica para Professores em Informática (IFSP) e em Gestão Empresarial Estratégica (MBA, USP). Endereço postal: Rua Santa Virgínia, 408, apto 53, Tatuapé, São Paulo – SP, CEP 03084-000. E-mail: acesse o artigo original para visualizar o e-mail. E-mail: acesse o artigo original para visualizar o e-mail.

[2] Pós-Doutor em Engenharia e Gestão da Inovação e Doutor em Energia pela Universidade Federal do ABC. Professor Doutor da Univesp e pesquisador permanente do Programa de Pós-Graduação em Ensino de Ciências e Matemática da Universidade Cruzeiro do Sul. Endereço postal: Rua Atibaia, 127, Guaxinduva, Bom Jesus dos Perdões – SP, CEP 12959-304. E-mail: acesse o artigo original para visualizar o e-mail.