

Sistemas Adaptativos Baseados em IA para Melhoria da Experiência de Aprendizado em Educação a Distância: Um Mapeamento Sistemático

Renan Grion, Laura O. Moraes

Universidade Federal do Estado do Rio de Janeiro (UNIRIO)
Rio de Janeiro – RJ – Brasil

renan.grion@edu.unirio.br, laura@uniriotec.br

Abstract. *This systematic mapping analyzes 20 studies published between 2020 and 2024 on artificial intelligence-based adaptive systems applied to distance education. The results highlight the use of machine learning, fuzzy logic, knowledge modeling, and emerging technologies for learning personalization, dynamic content adaptation, and continuous learner assessment. The studies report increased engagement and improved academic performance, although challenges related to data quality, privacy, and scalability remain. Future directions include pedagogical alignment, data governance, and broader adoption of these technologies.*

Keywords— *Adaptive Systems, Artificial Intelligence, Distance Education.*

Resumo. *Este mapeamento sistemático analisa 20 estudos publicados entre 2020 e 2024 sobre sistemas adaptativos baseados em inteligência artificial aplicados à educação a distância. Os resultados destacam o uso de aprendizado de máquina, lógica fuzzy, modelagem de conhecimento e tecnologias emergentes para personalização da aprendizagem, adaptação dinâmica de conteúdo e avaliação contínua dos estudantes. Os estudos relatam maior engajamento e melhoria do desempenho acadêmico, embora persistam desafios relacionados à qualidade dos dados, privacidade e escalabilidade. As direções futuras incluem alinhamento pedagógico, governança de dados e ampliação da adoção dessas tecnologias.*

Palavras-chave— *Sistemas Adaptativos, Inteligência Artificial, Educação a Distância.*

1. Introdução

A educação a distância (EaD) emergiu como uma modalidade essencial no cenário educacional contemporâneo, promovendo acessibilidade, flexibilidade e democratização do aprendizado em diferentes contextos [Wang *et al.* 2020]. Essa modalidade, amplamente adotada em cursos técnicos, ensino superior e programas corporativos, permite que alunos superem barreiras geográficas e temporais.

Nesse contexto, os sistemas adaptativos baseados em Inteligência Artificial (IA) têm sido apontados como ferramentas promissoras para potencializar a personalização da aprendizagem. Esses sistemas utilizam técnicas como aprendizado de máquina, lógica fuzzy e modelos probabilísticos para analisar, em tempo real, o desempenho, os

estilos de aprendizagem e as necessidades específicas de cada aluno [Eryilmaz and Adabashi 2020; Prihar *et al.* 2022; Chergui *et al.* 2024].

Estudos recentes destacam o potencial dos sistemas adaptativos baseados em IA para apoiar trajetórias personalizadas de aprendizagem na educação a distância [Qu and Ogunkunle 2021; Singh *et al.* 2022; Prihar *et al.* 2022; Ezzaim *et al.* 2024]. Entretanto, a implementação desses sistemas ainda enfrenta limitações relevantes que influenciam sua adoção e integração em ambientes de EaD [Jamal *et al.* 2020; Wang *et al.* 2020].

Diante desse cenário, o presente trabalho busca responder à seguinte questão: Como os sistemas adaptativos baseados em IA contribuem para a personalização e a melhoria da experiência de aprendizado na educação a distância?

Os objetivos específicos incluem: (i) identificar e categorizar as técnicas de IA mais utilizadas; (ii) explorar os principais desafios enfrentados na implementação desses sistemas; e (iii) analisar os benefícios reportados pelos estudos em termos de engajamento e desempenho acadêmico dos alunos [Pavlik *et al.* 2020; Chergui *et al.* 2024]. A partir desse mapeamento sistemático, espera-se contribuir para o avanço do conhecimento na área, oferecendo subsídios para a aplicação prática e orientando futuras pesquisas no desenvolvimento de soluções mais eficazes e inclusivas.

2. Trabalhos Relacionados

Estudos de revisão e mapeamento sistemático sobre sistemas adaptativos e uso de inteligência artificial na educação têm sido conduzidos ao longo da última década, contribuindo para a organização do conhecimento e identificação de tendências na área. Entretanto, esses trabalhos apresentam recortes temporais, contextuais e analíticos distintos do adotado nesta pesquisa, não tendo como foco específico os sistemas adaptativos baseados em IA aplicados à Educação a Distância.

Entre os estudos de revisão, destaca-se um mapeamento sistemático [Jamal *et al.* 2020], que analisou 68 estudos publicados entre 2012 e 2020 no contexto da Educação em Computação. Os autores identificaram a predominância de técnicas como lógica fuzzy, clustering e seleção de atributos, com foco principal na caracterização das abordagens técnicas empregadas em sistemas adaptativos. Embora abrangente, o estudo concentra-se no contexto da Educação em Computação, não tendo como foco específico a Educação a Distância. Além disso, não contempla pesquisas posteriores a 2020 nem analisa de forma integrada aspectos pedagógicos, éticos ou organizacionais associados à adoção desses sistemas.

Outro estudo de referência consiste em uma revisão da literatura [Wang *et al.* 2020], que investigou lacunas no uso e na pesquisa sobre sistemas adaptativos em educação. Os autores destacam desafios relacionados à escalabilidade, à qualidade dos dados e à limitada integração pedagógica. O estudo, contudo, aborda sistemas adaptativos em contextos educacionais gerais, sem foco específico na Educação a Distância.

Em contraste com os estudos anteriormente revisados, o presente mapeamento adota um recorte temporal mais recente (2020–2024), ampliando a cobertura dos estudos analisados e incorporando pesquisas desenvolvidas após a intensificação do uso da EaD no período pós-pandemia. Além desse recorte específico, este trabalho não se restringe à caracterização técnica das soluções, integrando múltiplas dimensões de

análise — técnicas de IA, benefícios educacionais e desafios pedagógicos, éticos e operacionais — de forma conjunta.

Dessa forma, este mapeamento complementa os estudos anteriores ao oferecer uma visão atualizada sobre sistemas adaptativos baseados em IA aplicados à Educação a Distância, reunindo evidências de um contexto que não constituiu o foco específico das revisões analisadas. Assim, contribui para a identificação de tendências atuais e de lacunas que podem orientar pesquisas futuras.

3. Método de pesquisa

Este mapeamento sistemático foi conduzido com o objetivo de investigar como os sistemas adaptativos baseados em IA contribuem para a personalização e melhoria da experiência de aprendizado em ambientes de EaD. Para garantir rigor metodológico, o protocolo seguido está alinhado às diretrizes para revisões sistemáticas em Engenharia de Software [Kitchenham and Charters 2007], amplamente adotadas em estudos da área de tecnologia educacional.

Estrutura PICOC

- **População:** estudantes, ambientes de educação a distância, plataformas de *e-learning*, ensino superior e cursos técnicos.
- **Intervenção:** sistemas adaptativos baseados em IA, ajustes de conteúdo em tempo real, estilos de aprendizagem e acompanhamento de progresso.
- **Resultados Esperados:** melhoria da experiência de aprendizagem, engajamento, desempenho acadêmico, personalização e satisfação dos estudantes.

Optou-se por não incluir os componentes Comparação e Contexto do modelo PICOC, pois o foco deste mapeamento é descritivo e não envolve a comparação de intervenções nem a análise de contextos específicos, em conformidade com recomendações metodológicas para revisões desse tipo [Kitchenham and Charters 2007].

3.1. Questões de Pesquisa

As questões de pesquisa foram definidas para orientar a coleta, análise e síntese dos estudos, garantindo que o trabalho responda aos objetivos centrais da revisão:

QP: Como os sistemas adaptativos baseados em IA contribuem para a personalização e a melhoria da experiência de aprendizado em ambientes de educação a distância?

- **SQP1:** Quais técnicas de inteligência artificial são mais utilizadas em sistemas adaptativos para educação a distância, e como elas impactam a personalização do aprendizado?
- **SQP2:** Quais são os principais desafios e limitações enfrentados na implementação de sistemas adaptativos baseados em IA em plataformas de ensino a distância?
- **SQP3:** Quais benefícios os estudos selecionados reportam em relação ao engajamento, desempenho acadêmico e satisfação dos alunos?

3.2. Fontes de Dados e Estratégias de Busca

Este mapeamento sistemático foi conduzido com dados coletados de seis bases científicas: ACM Digital Library, Engineering Village, IEEE Xplore, SBC OpenLib, ScienceDirect e Scopus. O gerenciamento das referências, a remoção de duplicatas e o processo de seleção dos estudos foram conduzidos com o apoio da ferramenta Parsifal.

Para a condução da busca, foi elaborada uma string estruturada, combinando termos relacionados a sistemas adaptativos, inteligência artificial e educação a distância. Na base ScienceDirect, a string precisou ser adaptada devido à limitação de até oito conectores booleanos por campo, preservando-se a equivalência semântica em relação à versão original.

("adaptive learning systems" OR "intelligent tutoring systems" OR "sistemas de aprendizado adaptativo" OR "sistemas tutores inteligentes") AND ("artificial intelligence" OR "machine learning" OR "neural networks" OR "inteligência artificial" OR "aprendizado de máquina" OR "redes neurais") AND ("distance learning" OR "online education" OR "e-learning" OR "educação a distância" OR "educação online" OR "e-learning")

Além disso, foram aplicados filtros que restringiram os resultados a publicações entre 2020 e 2024, nos idiomas inglês e português.

Esse recorte temporal (2020–2024) foi adotado porque o campo avançou significativamente a partir de 2020, com o surgimento de técnicas como modelos de linguagem e aprendizado profundo [Chen *et al.* 2024; Santhosh *et al.* 2024], além da intensificação do ensino remoto no período pós-pandemia, que impulsionou pesquisas sobre personalização na EaD [Wang *et al.* 2020]. O ano de 2024 foi definido como limite superior por corresponder ao período de realização das buscas, assegurando um conjunto de estudos consolidado e consistente para análise.

O processo de busca inicial resultou na identificação de 823 estudos. Em seguida, os dados passaram por etapas de filtragem para garantir relevância e qualidade. As etapas incluíram a remoção de 105 estudos duplicados e a exclusão de 687 estudos que não atendiam aos critérios de inclusão e exclusão previamente definidos e detalhados na próxima seção. Após esse processo, 31 estudos foram selecionados para avaliação de qualidade. Nessa etapa, 11 estudos foram excluídos, resultando em um conjunto final de 20 estudos incluídos neste mapeamento sistemático, conforme ilustrado no fluxograma PRISMA da Fig. 1.




Figura 1. Fluxo PRISMA do mapeamento sistemático, com as fases de Identificação, Triagem, Elegibilidade e Inclusão.

3.3 Critérios de Inclusão e Exclusão

Os critérios de inclusão e exclusão foram aplicados para selecionar estudos relevantes e evitar vieses:

- **Critérios de Inclusão:**
 - Estudos focados em sistemas adaptativos e IA aplicados à EaD.
 - Estudos que fornecem evidências empíricas ou análises detalhadas, independentemente do aspecto avaliado do sistema adaptativo.
- **Critérios de Exclusão:**
 - Estudos fora do escopo de EaD e sistemas adaptativos.
 - Artigos de opinião ou trabalhos sem revisão por pares.
 - Estudos cujo texto completo não estivesse acessível para análise integral.

3.4 Processo de Seleção e Extração de Dados

O processo de seleção dos estudos foi conduzido com o apoio da ferramenta Parsifal e organizado em três etapas:

- **Triagem Inicial:** Os títulos e resumos dos artigos foram avaliados para identificar trabalhos que potencialmente atendiam aos critérios de inclusão.
- **Análise do Texto Completo:** Os artigos pré-selecionados foram lidos integralmente para confirmar sua relevância.
- **Extração de Dados:** Os dados extraídos incluíram as técnicas de IA utilizadas, desafios, os benefícios reportados pelos estudos e os contextos de aplicação.

Além disso, a revisão de mapeamento sistemático foi conduzida individualmente pelo autor e supervisionada pela orientadora, com apoio de IA generativa apenas para subsidiar a reflexão sobre os critérios de elegibilidade. As decisões finais de inclusão e exclusão dos estudos foram tomadas exclusivamente pelo autor.

3.5 Avaliação da Qualidade dos Estudos

Os estudos selecionados foram avaliados por meio de cinco critérios de qualidade: (i) clareza e alinhamento dos objetivos; (ii) descrição adequada dos dados e do método de análise; (iii) análise crítica dos resultados; (iv) robustez das evidências empíricas; e (v) relevância e contribuição para o avanço do conhecimento. Cada critério recebeu pontuação de 0 (não), 0.5 (parcialmente) ou 1.0 (sim), totalizando um máximo de 5 pontos. Estudos com pontuação igual ou superior a 3 foram considerados adequados para inclusão na síntese final.

3.6 Organização e Análise dos Dados

Os dados extraídos foram organizados em categorias, facilitando a análise comparativa:

- Técnicas de IA, como aprendizado de máquina, lógica fuzzy e modelos probabilísticos [Eryilmaz and Adabashi 2020].
- Principais desafios, incluindo questões técnicas, pedagógicas e éticas [Jamal *et al.* 2020; Wang *et al.* 2020].
- Benefícios relatados, como engajamento, personalização e melhorias no desempenho acadêmico [Qu and Ogunkunle 2021; Santhosh *et al.* 2024].

4. Resultados

Nesta seção, discutimos as técnicas identificadas, os benefícios observados e os desafios enfrentados, com base na análise dos estudos selecionados.

4.1 Técnicas de IA Identificadas

A análise dos 20 estudos revelou um conjunto diversificado de técnicas de inteligência artificial empregadas em sistemas adaptativos para educação a distância. Essas técnicas foram organizadas em categorias, permitindo identificar padrões de uso e finalidades pedagógicas. As principais categorias incluem: (i) lógica fuzzy e sistemas baseados em regras, utilizadas para lidar com incertezas e representar julgamentos pedagógicos; (ii) modelos probabilísticos, como redes Bayesianas, aplicados para inferir estados de conhecimento e apoiar decisões adaptativas; (iii) aprendizado de máquina, abrangendo métodos de predição, técnicas de agrupamento aplicadas a estudantes, análise de comportamento e personalização; (iv) modelagem de conhecimento, empregada para estruturar competências, sub-habilidades e relações pedagógicas; (v) abordagens baseadas em IA generativa, especialmente modelos de linguagem de grande escala, e o uso de sensores de engajamento como fontes adicionais de dados para adaptação; e (vi) abordagens analíticas mais amplas, como *learning progression analytics* e *evidence-centered design*, voltadas à compreensão de trajetórias de aprendizagem em escala. A relação completa entre essas técnicas e os estudos que as utilizam encontra-se sintetizada na Tabela 1.

Tabela 1. Categorias de técnicas de IA e estudos que as utilizam

Técnica	Estudos
Lógica Fuzzy	[Eryılmaz and Adabashi 2020; AL-Chalabi <i>et al.</i> 2021; Troussas <i>et al.</i> 2023]
Redes Bayesianas	[Eryılmaz and Adabashi 2020; AL-Chalabi <i>et al.</i> 2021]
<i>Machine Learning</i> – Predição / Classificação	[Pavlik <i>et al.</i> 2020; Qu and Ogunkunle 2021; Rao and Kumar 2021; Mandal and Naskar 2021; Prihar <i>et al.</i> 2022; Assiry and Muniasamy 2022; Singh <i>et al.</i> 2022]
<i>Machine Learning</i> – Modelagem Interpretável	[Prihar <i>et al.</i> 2022]
Modelagem de Conhecimento / <i>Subskills</i>	[Ghergulescu <i>et al.</i> 2021; Chergui <i>et al.</i> 2021; Chergui <i>et al.</i> 2024]
<i>Evidence-Centered Design</i> (ECD)	[Kubsch <i>et al.</i> 2022]
<i>Learning Progression Analytics</i>	[Kubsch <i>et al.</i> 2022]
Sensores e Adaptação Ubíqua (<i>Context-aware</i>)	[Liu <i>et al.</i> 2021]
IA Generativa - <i>Large Language Model</i> (LLM)	[Chen <i>et al.</i> 2024; Santhosh <i>et al.</i> 2024; Calò and MacLellan 2024]
Rastreamento Ocular (<i>Eye-tracking</i>)	[Chen <i>et al.</i> 2024]

A partir da síntese apresentada na Tabela 1, observa-se que não há uma técnica dominante entre os estudos recentes. Apesar do crescimento do aprendizado de máquina e de modelos de linguagem, abordagens como lógica fuzzy e redes Bayesianas permanecem recorrentes. Por outro lado, algumas técnicas, como modelagem interpretável por aprendizado de máquina, rastreamento ocular (*eye-tracking*), *Evidence-Centered Design*, *Learning Progression Analytics* e adaptação ubíqua baseada em sensores, aparecem em apenas um estudo cada, indicando abordagens ainda emergentes no contexto dos sistemas adaptativos para educação a distância.

4.2 Impactos e Benefícios Observados

A análise dos estudos revelou benefícios recorrentes proporcionados por sistemas adaptativos baseados em IA na EaD, sintetizados na Tabela 2. Em geral, os estudos analisados relatam que esses sistemas favorecem a personalização do ensino [Ghergulescu *et al.* 2021; Prihar *et al.* 2022; Troussas *et al.* 2023; Szczepański and Marciniak 2023] e maior engajamento, sobretudo quando associados a modelos de linguagem e a técnicas de rastreamento ocular [Troussas *et al.* 2023; Santhosh *et al.* 2024]. Também são relatadas melhorias de desempenho, com avanços na retenção de conteúdo e na progressão da aprendizagem [Eryılmaz and Adabashi 2020; Mandal and Naskar 2021; Prihar *et al.* 2022; Assiry and Muniasamy 2022], além da redução de lacunas de conhecimento por meio de diagnósticos contínuos [Ghergulescu *et al.* 2021; AL-Chalabi *et al.* 2021; Chergui *et al.* 2021].

Os estudos também relatam que estratégias adaptativas, como práticas personalizadas e recomendações inteligentes, contribuem para tornar o estudo mais direcionado e adequado ao perfil do estudante [Pavlik *et al.* 2020; Mandal and Naskar 2021; Prihar *et al.* 2022]. Também são relatados apoio pedagógico a docentes e potencial de inclusão e acessibilidade [Wang *et al.* 2020; AL-Chalabi *et al.* 2021; Liu *et al.* 2021].

Tabela 2. Benefícios identificados nos 20 estudos selecionados

Benefícios	Estudos
Melhoria do desempenho acadêmico	[Pavlik <i>et al.</i> 2020; Eryılmaz and Adabashi 2020; AL-Chalabi <i>et al.</i> 2021; Mandal and Naskar 2021; Prihar <i>et al.</i> 2022; Assiry and Muniasamy 2022]
Aumento do engajamento / motivação	[Ghergulescu <i>et al.</i> 2021; Liu <i>et al.</i> 2021; Troussas <i>et al.</i> 2023; Szczepański and Marciniak 2023; Santhosh <i>et al.</i> 2024]
Personalização efetiva do aprendizado	[Eryılmaz and Adabashi 2020; Ghergulescu <i>et al.</i> 2021; AL-Chalabi <i>et al.</i> 2021; Assiry and Muniasamy 2022; Troussas <i>et al.</i> 2023; Chen <i>et al.</i> 2024]
Redução de lacunas de conhecimento	[Eryılmaz and Adabashi 2020; AL-Chalabi <i>et al.</i> 2021; Ghergulescu <i>et al.</i> 2021; Chergui <i>et al.</i> 2021; Chergui <i>et al.</i> 2024]
Aprendizagem mais eficiente / otimizada	[Pavlik <i>et al.</i> 2020; Mandal and Naskar 2021; Prihar <i>et al.</i> 2022]
Apoio pedagógico a professores / tutores	[Ghergulescu <i>et al.</i> 2021; Assiry and Muniasamy 2022; Calò and MacLellan 2024]
Inclusão e acessibilidade	[Wang <i>et al.</i> 2020; AL-Chalabi <i>et al.</i> 2021]

4.3 Desafios Identificados

A análise revelou desafios recorrentes que limitam a adoção em larga escala de sistemas adaptativos baseados em IA na EaD, conforme sintetizado na Tabela 3. Entre os desafios técnicos, destacam-se a integração de dados heterogêneos — como registros de interação em plataformas virtuais, resultados de avaliações, logs de navegação e dados comportamentais — limitações de escalabilidade associadas principalmente a demandas de infraestrutura computacional e ao custo de processamento, e o alto custo computacional de técnicas avançadas, especialmente modelos de linguagem e abordagens de monitoramento contínuo [Liu *et al.* 2021; Assiry and Muniasamy 2022; Chen *et al.* 2024; Santhosh *et al.* 2024]. A qualidade e disponibilidade dos dados também surgem como limitações frequentes, afetando a confiabilidade das inferências adaptativas [Mandal and Naskar 2021; AL-Chalabi *et al.* 2021; Prihar *et al.* 2022].

Do ponto de vista pedagógico, a literatura aponta dificuldades de alinhamento entre tecnologias adaptativas, currículos e práticas docentes, em razão da ausência de *frameworks* consolidados [Ghergulescu *et al.* 2021; Assiry and Muniasamy 2022; Chergui *et al.* 2024]. No âmbito ético e legal, destacam-se preocupações com privacidade, transparência e conformidade regulatória, sobretudo em sistemas que

coletam dados sensíveis de forma contínua [Wang *et al.* 2020; Liu *et al.* 2021]. Desafios organizacionais incluem infraestrutura limitada, escassez de profissionais qualificados e resistência institucional à adoção de tecnologias emergentes [Chergui *et al.* 2021; Assiry and Muniasamy 2022; Troussas *et al.* 2023].

Tabela 3. Desafios identificados nos 20 estudos selecionados

Desafios	Estudos
Integração e qualidade dos dados	[Eryılmaz and Adabashi 2020; Ghergulescu <i>et al.</i> 2021; AL-Chalabi <i>et al.</i> 2021; Mandal and Naskar 2021; Qu and Ogunkunle 2021; Prihar <i>et al.</i> 2022; Singh <i>et al.</i> 2022]
Escalabilidade e custo computacional	[Pavlik <i>et al.</i> 2020; Liu <i>et al.</i> 2021; Assiry and Muniasamy 2022; Singh <i>et al.</i> 2022; Szczepański and Marciniak 2023; Chen <i>et al.</i> 2024; Santhosh <i>et al.</i> 2024]
Alinhamento pedagógico e integração curricular	[Eryılmaz and Adabashi 2020; Ghergulescu <i>et al.</i> 2021; AL-Chalabi <i>et al.</i> 2021; Chergui <i>et al.</i> 2021; Prihar <i>et al.</i> 2022; Troussas <i>et al.</i> 2023; Chergui <i>et al.</i> 2024]
Privacidade, ética e segurança dos dados	[Wang <i>et al.</i> 2020; Liu <i>et al.</i> 2021; Chen <i>et al.</i> 2024; Santhosh <i>et al.</i> 2024]
Infraestrutura, capacitação e fatores organizacionais	[Pavlik <i>et al.</i> 2020; AL-Chalabi <i>et al.</i> 2021; Chergui <i>et al.</i> 2021; Assiry and Muniasamy 2022; Singh <i>et al.</i> 2022; Troussas <i>et al.</i> 2023]

4.4 Análise de Coocorrência entre Técnicas, Benefícios e Desafios

Para identificar relações entre as técnicas utilizadas nos estudos e os benefícios e desafios reportados, foi realizada uma análise de coocorrência entre esses elementos. A Fig. 2 apresenta o *heatmap* resultante, evidenciando as combinações mais frequentes entre técnicas, benefícios e desafios.

Observa-se que o aprendizado de máquina voltado à predição e classificação o que sugere maior diversidade de associações, estando relacionado a benefícios como melhoria do desempenho, eficiência e qualidade dos dados, mas também a desafios como custo computacional e infraestrutura. A lógica fuzzy destaca-se principalmente pela associação com personalização da aprendizagem, engajamento e redução de lacunas de conhecimento, enquanto as redes Bayesianas apresentam aplicações distribuídas entre diferentes benefícios e desafios. Em contraste, abordagens como modelos de linguagem de grande porte, sensores ubíquos e *eye-tracking* aparecem com menor frequência, indicando que ainda representam tendências emergentes no conjunto de estudos analisados.




Figura 2. *Heatmap* de coocorrência entre técnicas de IA, benefícios e desafios.

4.5 Respostas às Questões de Pesquisa

QP: Como os sistemas adaptativos baseados em IA contribuem para a personalização e a melhoria da experiência de aprendizado em ambientes de educação a distância? Os estudos analisados indicam que os sistemas adaptativos baseados em IA contribuem para a personalização da aprendizagem na EaD ao ajustar conteúdos, atividades e níveis de apoio conforme o perfil do estudante [Ghergulescu *et al.* 2021; AL-Chalabi *et al.* 2021; Prihar *et al.* 2022; Szczepański and Marciniak 2023].

SQP1: Quais técnicas de inteligência artificial são mais utilizadas em sistemas adaptativos para educação a distância, e como elas impactam a personalização do aprendizado? As técnicas de IA mais utilizadas incluem aprendizado de máquina, lógica fuzzy, redes Bayesianas, modelagem de conhecimento e tecnologias emergentes, aplicadas principalmente para diagnóstico contínuo e recomendação personalizada [Eryilmaz and Adabashi 2020; Ghergulescu *et al.* 2021; AL-Chalabi *et al.* 2021; Prihar *et al.* 2022; Santhosh *et al.* 2024].

SQP2: Quais são os principais desafios e limitações enfrentados na implementação de sistemas adaptativos baseados em IA em plataformas de ensino a distância? Os desafios recorrentes envolvem limitações técnicas (dados e escalabilidade), dificuldades de alinhamento pedagógico e questões éticas relacionadas à privacidade e ao monitoramento de estudantes [Chergui *et al.* 2021; Liu *et al.* 2021; Assiry and Muniasamy 2022].

SQP3: Quais benefícios os estudos selecionados reportam em relação ao engajamento, desempenho acadêmico e satisfação dos alunos? Os benefícios relatados pelos estudos incluem personalização mais eficaz, maior engajamento, melhor desempenho acadêmico, redução de lacunas de conhecimento e apoio pedagógico, com

potencial adicional para promover inclusão [Mandal and Naskar 2021; AL-Chalabi *et al.* 2021; Assiry and Muniasamy 2022; Szczepański and Marciniak 2023; Santhosh *et al.* 2024].

5. Discussão

Os achados evidenciam avanços tecnológicos e pedagógicos nos sistemas adaptativos baseados em IA, ainda acompanhados de desafios estruturais que limitam sua adoção em larga escala. Nesta seção, discutimos as implicações desses achados nas dimensões tecnológica, pedagógica, ética e operacional.

5.1 Contribuições Tecnológicas

Os estudos mostram maturidade crescente no uso de técnicas de IA para personalização da aprendizagem. Abordagens como lógica fuzzy, aprendizado de máquina e redes Bayesianas permitem diagnósticos contínuos, ajuste dinâmico de conteúdos e previsão de desempenho [Eryilmaz and Adabashi 2020; Szczepański and Marciniak 2023].

Recursos baseados em modelos de linguagem e em sensores voltados à captação de engajamento — como rastreamento ocular e outros dispositivos contextuais — ampliam a capacidade dos sistemas em oferecer interações mais responsivas [Chen *et al.* 2024; Santhosh *et al.* 2024]. Enquanto abordagens baseadas em modelos de linguagem tendem a favorecer a escalabilidade das soluções, o uso de sensores físicos impõe desafios adicionais à adoção em larga escala, especialmente em ambientes de EaD [Wang *et al.* 2020; Santhosh *et al.* 2024].

5.2 Implicações Pedagógicas

Do ponto de vista pedagógico, os estudos analisados reforçam o papel central da personalização como estratégia associada à melhoria do engajamento e do desempenho [Ghergulescu *et al.* 2021; Prihar *et al.* 2022]. No entanto, o impacto educacional depende não apenas das técnicas empregadas, mas de sua inserção coerente em práticas docentes e estruturas curriculares. Vários estudos indicam que esse alinhamento ocorre de forma heterogênea, variando conforme o nível de integração aos objetivos de aprendizagem, à atuação docente e ao currículo institucional, o que dificulta a adoção plena em diferentes contextos educacionais [Wang *et al.* 2020; Chergui *et al.* 2024].

Os resultados também indicam a necessidade de maior participação dos educadores nos processos de concepção e ajuste dos sistemas, especialmente na interpretação das análises geradas pela IA e na definição de intervenções pedagógicas [Wang *et al.* 2020; Ghergulescu *et al.* 2021; Chergui *et al.* 2024]. Essa participação é essencial para transformar as recomendações dos sistemas em ações de ensino efetivas [Prihar *et al.* 2022].

5.3 Cursos e contextos de aplicação

Embora a estratégia de busca não tenha restringido os estudos à área de Computação, observou-se que a maior parte das aplicações identificadas ocorreu nesse contexto. Assim, a predominância de cursos de Computação representa um achado deste mapeamento, e não um critério de seleção dos estudos.

Dos 20 estudos analisados, 14 foram aplicados diretamente em cursos online relacionados à área de Computação, incluindo disciplinas introdutórias de programação,

resolução de problemas algorítmicos, sistemas tutores computacionais e ambientes virtuais de prática [Eryılmaz and Adabashi 2020; Pavlik *et al.* 2020; Prihar *et al.* 2022; Assiry and Muniasamy 2022; Kubsch *et al.* 2022]. Nesses contextos educacionais, os sistemas adaptativos são utilizados para ajustar níveis de dificuldade, recomendar atividades e fornecer *feedback* automático ao longo do processo de aprendizagem [Pavlik *et al.* 2020; Ghergulescu *et al.* 2021; Prihar *et al.* 2022].

Mesmo quando aplicados a outras áreas, as soluções são implementadas por meio de plataformas, *dashboards* e modelos de IA desenvolvidos como artefatos computacionais [Assiry and Muniasamy 2022; Calò and MacLellan 2024]. Assim, o mapeamento dialoga diretamente com a comunidade de Educação em Computação ao demonstrar como técnicas como aprendizado de máquina, lógica fuzzy, redes Bayesianas e modelos de linguagem são incorporadas a cursos online, sistemas tutores e ambientes de prática, apoiando decisões de projeto de software educacional e estratégias de personalização em disciplinas da área [Eryılmaz and Adabashi 2020; Mandal and Naskar 2021; Santhosh *et al.* 2024].

5.4 Desafios Éticos e Operacionais

A literatura aponta desafios consistentes que limitam a maturidade das soluções. Questões estruturais como integração e qualidade dos dados, custo computacional e limitação de infraestrutura afetam diretamente a escalabilidade e o uso em instituições com menos recursos [Chergui *et al.* 2021; Assiry and Muniasamy 2022; Singh *et al.* 2022].

Em paralelo, a coleta contínua de dados sensíveis — incluindo interações, padrões comportamentais e métricas de atenção — acentua preocupações sobre privacidade, transparência e conformidade com regulações internacionais [Liu *et al.* 2021; Chen *et al.* 2024; Santhosh *et al.* 2024].

5.5 Integração entre Técnicas, Benefícios e Desafios: Evidências da Coocorrência

A análise integrada das técnicas e efeitos observados nos estudos indica que diferentes abordagens de IA tendem a se associar a perfis específicos de benefícios e desafios. Técnicas mais estruturadas mostram relação com exigências de qualidade de dados e alinhamento pedagógico, como observado em sistemas baseados em lógica fuzzy, redes Bayesianas e modelagem de conhecimento [Eryılmaz and Adabashi 2020; Ghergulescu *et al.* 2021; Chergui *et al.* 2024]. Por sua vez, abordagens orientadas à interação direta com o estudante e ao monitoramento contínuo, incluindo o uso de chatbots, modelos de linguagem e sensores de engajamento, associam-se mais diretamente a ganhos de engajamento, mas também a desafios relacionados à privacidade e à escalabilidade [Troussas *et al.* 2023; Chen *et al.* 2024; Santhosh *et al.* 2024]. Esses padrões sugerem que os impactos dos sistemas adaptativos resultam da combinação entre características técnicas e condições pedagógicas e institucionais, e não apenas da escolha isolada de uma técnica.

5.6 Comparação com Estudos Anteriores

Em relação às revisões anteriores, observa-se uma evolução no foco das pesquisas sobre sistemas adaptativos em educação. Enquanto o mapeamento sistemático [Jamal *et al.* 2020] concentrou-se na caracterização das técnicas empregadas em sistemas adaptativos

no contexto da Educação em Computação, e a revisão da literatura [Wang et al. 2020] discutiu desafios gerais relacionados ao uso desses sistemas em educação, o presente mapeamento concentra-se especificamente em sistemas adaptativos baseados em IA aplicados à Educação a Distância.

Nesse contexto, observa-se que técnicas anteriormente predominantemente experimentais passaram a incorporar abordagens mais maduras, com maior atenção à explicabilidade, ao monitoramento contínuo e à integração com práticas educacionais [Jamal *et al.* 2020]. Apesar desses avanços, desafios relacionados à adoção em larga escala permanecem presentes, especialmente em contextos com restrições estruturais, conforme apontado por revisões anteriores [Wang *et al.* 2020]. Os achados também reforçam o potencial dos sistemas adaptativos para apoiar a inclusão e atender a perfis diversos de estudantes [AL-Chalabi *et al.* 2021].

5.7 Implicações Práticas e Futuras Direções

Os resultados sugerem três frentes prioritárias para pesquisa e desenvolvimento:

- **Integração tecnológica e pedagógica:** É necessário desenvolver *frameworks* que permitam incorporar as recomendações algorítmicas aos currículos e práticas docentes, promovendo maior clareza no papel do professor e na interpretação dos dados gerados pelos sistemas [Ghergulescu *et al.* 2021; Chergui *et al.* 2024].
- **Privacidade e governança de dados:** Avanços futuros devem contemplar mecanismos robustos de proteção de dados, minimização de riscos e explicabilidade, especialmente em sistemas que realizam monitoramento contínuo [Liu *et al.* 2021; Santhosh *et al.* 2024].
- **Escalabilidade e inclusão:** Tornar as soluções mais leves, interoperáveis, ou seja, capazes de operar em diferentes plataformas e contextos institucionais, e acessíveis é fundamental para ampliar o uso de sistemas adaptativos em instituições com recursos limitados [Pavlik *et al.* 2020; Assiry and Muniasamy 2022].

Além disso, destaca-se a necessidade de diretrizes práticas que orientem a integração pedagógica de sistemas adaptativos, reduzindo a distância entre suas capacidades técnicas e as demandas reais dos ambientes de EaD.

5.8 Ameaças à Validade e Limitações

Este mapeamento sistemático apresenta limitações que devem ser consideradas na interpretação dos resultados. A busca foi restrita às seis bases selecionadas, sem utilização da técnica de amostragem em bola de neve, o que pode ter levado à ausência de estudos relevantes que não apareciam diretamente nos resultados iniciais. Além disso, embora as cadeias de busca tenham sido elaboradas a partir da estratégia PICOC e refinadas por meio de estudos piloto, é possível que variações de terminologia utilizadas pelos autores tenham limitado a recuperação de alguns trabalhos relevantes.

Outro aspecto refere-se ao possível viés de publicação, uma vez que estudos com resultados positivos tendem a ser publicados com maior frequência do que aqueles com resultados negativos ou inconclusivos, influenciando o conjunto de evidências disponível nas bases consultadas.

A classificação das técnicas, benefícios e desafios dependeu das informações disponibilizadas pelos autores dos estudos, podendo refletir variações na terminologia ou no nível de detalhamento metodológico. Ainda assim, os procedimentos sistemáticos adotados sustentam a confiabilidade geral dos achados.

Por ter sido conduzida por um único pesquisador, esta revisão pode refletir parcialmente interpretações individuais durante as etapas de seleção e análise dos estudos.

6. Conclusão e Trabalhos Futuros

De forma geral, os achados deste mapeamento indicam que a literatura analisada atribui aos sistemas adaptativos baseados em IA um potencial consistente para aprimorar a experiência de aprendizagem na EaD, desde que integrados de maneira coerente às práticas pedagógicas e às condições institucionais.

Quanto a perspectivas futuras, destacam-se a necessidade de aprofundar a integração entre mecanismos adaptativos e práticas pedagógicas, fortalecer a governança e proteção de dados e desenvolver soluções mais leves e interoperáveis que favoreçam a inclusão e o uso em instituições com menos recursos.

Em síntese, as evidências neste mapeamento indicam que os sistemas adaptativos baseados em IA apresentam potencial consistente para aprimorar a experiência de aprendizagem em ambientes digitais, e o conjunto de evidências desta revisão contribui para orientar pesquisas e iniciativas voltadas a soluções mais eficazes, éticas e alinhadas às demandas educacionais.

Conformidade com Ciência Aberta

O material suplementar deste estudo — incluindo a string de busca, tabelas de seleção de estudos, avaliação da qualidade, extração de dados, o dataset consolidado e os scripts utilizados para as análises e geração das visualizações — está disponível publicamente em: <https://doi.org/10.5281/zenodo.17847384>. A disponibilização desses elementos garante transparência, replicabilidade e reprodutibilidade ao mapeamento sistemático.

Uso de Inteligência Artificial

Ferramentas de IA Generativa (ChatGPT, OpenAI) foram utilizadas para revisão textual, checagem de consistência e apoio à reflexão sobre os critérios de elegibilidade dos estudos. Nenhuma etapa de delineamento metodológico, seleção, inclusão, exclusão, extração ou análise dos estudos foi realizada ou decidida por IA, permanecendo todas as decisões científicas sob responsabilidade exclusiva dos autores.

Agradecimentos

Os autores expressam seus agradecimentos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Universidade Federal do Estado do Rio de Janeiro (UNIRIO) pelo apoio institucional à realização desta pesquisa.

Referências

- AL-Chalabi, H. K. M., Hussein, A. M. A. and Apoki, U. C. (2021). “An Adaptive Learning System Based on Learner's Knowledge Level”. In: *2021 13th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)*, pp. 1–4. <https://doi.org/10.1109/ECAI52376.2021.9515158>.
- Assiry, K. A. H. and Muniasamy, A. (2022). “Predicting Learning Styles Using Machine Learning Classifiers”. In: *2022 International Conference on Electrical, Computer and Energy Technologies (ICECET)*, pp. 1–7. <https://doi.org/10.1109/ICECET55527.2022.9872971>.
- Calò, T. and MacLellan, C. J. (2024). “Towards Educator-Driven Tutor Authoring: Generative AI Approaches for Creating Intelligent Tutor Interfaces”. In: *Proceedings of the Eleventh ACM Conference on Learning @ Scale (L@S '24)*, pp. 305–309. <https://doi.org/10.1145/3657604.3664694>.
- Chergui, M., Chakir, A., Mansouri, H. and Sayouti, A. (2021). “Smart Pedagogical Knowledge Management Model for Higher Education”. In: *Innovations in Smart Cities Applications*, vol. 4, pp. 230–239. Springer. https://doi.org/10.1007/978-3-030-66840-2_18.
- Chergui, M., Nagano, A. and Ammoumou, A. (2024). “Toward an Adaptive Learning System by Managing Pedagogical Knowledge in a Smart Way”. *Multimedia Tools and Applications*, 84, 27777–27793. <https://doi.org/10.1007/s11042-024-20207-w>.
- Chen, Y., Ding, N., Zheng, H. T., Liu, Z., Sun, M. and Zhou, B. (2024). “Empowering Private Tutoring by Chaining Large Language Models”. In: *Proceedings of the 33rd ACM International Conference on Information and Knowledge Management*, pp. 354–364. <https://doi.org/10.1145/3627673.3679665>.
- Eryılmaz, M. and Adabashi, A. (2020). “Development of an Intelligent Tutoring System Using Bayesian Networks and Fuzzy Logic for a Higher Student Academic Performance”. *Applied Sciences*, 10(19), 6638. <https://doi.org/10.3390/app10196638>.
- Ezzaim, A., Dahbi, A., Haidine, A., Aqqal, A. (2024). “Development, Implementation, and Evaluation of a Machine Learning-Based Multi-Factor Adaptive E-Learning System”. *IAENG International Journal of Computer Science*, 51(9), 1250–1271.
- Ghergulescu, I., Flynn, C., O'Sullivan, C., van Heck, I. and Slob, M. (2021). “A Conceptual Framework for Extending Domain Model of AI-enabled Adaptive Learning with Sub-skills Modelling”. In: *Proceedings of the 13th International Conference on Computer Supported Education (CSEDU 2021)*, vol. 1, pp. 116–123. <https://doi.org/10.5220/0010451201160123>.
- Jamal, N. N., Jawawi, D. N. A., Hassan, R. and Kamil, R. M. I. (2020). “Adaptive Learning in Computing Education: A Systematic Mapping Study”. In: *IOP Conference Series: Materials Science and Engineering*, vol. 864, 012069. <https://doi.org/10.1088/1757-899X/864/1/012069>.
- Kitchenham, B. and Charters, S. (2007). “Guidelines for Performing Systematic Literature Reviews in Software Engineering”. EBSE Technical Report, Version 2.3.
- Kubsch, M., Czinczel, B., Lossjew, J., Wyrwich, T., Bednorz, D., Bernholt, S., Fiedler, D., Straß, S., Cress, U., Drachsler, H., Neumann, K. and Rummel, N. (2022).

- “Toward Learning Progression Analytics: Developing Learning Environments for the Automated Analysis of Learning Using Evidence-Centered Design”. *Frontiers in Education*, 7, 981910. <https://doi.org/10.3389/feduc.2022.981910>.
- Liu, S., Zhang, X., Chen, W. and Zhang, W. (2021). “Construction of Intelligent Adaptive Learning Platform in Ubiquitous Environment”. In: *Proceedings of the 2021 10th International Conference on Educational and Information Technology (ICEIT 2021)*, pp. 56–60. <https://doi.org/10.1109/ICEIT51700.2021.9375613>.
- Mandal, S. and Naskar, S. K. (2021). “Classifying and Solving Arithmetic Math Word Problems—An Intelligent Math Solver”. *IEEE Transactions on Learning Technologies*, 14(1), 28–41. <https://doi.org/10.1109/TLT.2021.3057805>.
- Pavlik, P. I., Olney, A. M., Banker, A., Eglington, L. and Yarbrow, J. (2020). “The Mobile Fact and Concept Textbook System (MoFaCTS)”. In: *21st International Conference on Artificial Intelligence in Education (AIED 2020), Second Workshop on Intelligent Textbooks*. CEUR Workshop Proceedings.
- Prihar, E., Haim, A., Sales, A. and Heffernan, N. (2022). “Automatic Interpretable Personalized Learning”. In: *Proceedings of the Ninth ACM Conference on Learning @ Scale*, pp. 1–11. <https://doi.org/10.1145/3491140.3528267>.
- Qu, Y. and Ogunkunle, O. (2021). “Enhancing the Intelligence of the Adaptive Learning Software through an AI Assisted Data Analytics on Students Learning Attributes with Unequal Weight”. In: *2021 IEEE Frontiers in Education Conference (FIE)*, pp. 1–6. <https://doi.org/10.1109/FIE49875.2021.9637387>.
- Rao, G. M. and Kumar, K. K. (2021). “Students Performance Prediction in Online Courses Using Machine Learning Algorithms”. *United International Journal for Research & Technology*, 2(11), 74–79.
- Santhosh, J., Dengel, A. and Ishimaru, S. (2024). “Gaze-Driven Adaptive Learning System With ChatGPT-Generated Summaries”. *IEEE Access*, 12, 173714–173733. <https://doi.org/10.1109/ACCESS.2024.3503059>.
- Singh, N., Gunjan, V. K. and Nasralla, M. M. (2022). “A Parametrized Comparative Analysis of Performance Between Proposed Adaptive and Personalized Tutoring System “Seis Tutor” With Existing Online Tutoring System”. *IEEE Access*, 10, 39376–39386. <https://doi.org/10.1109/ACCESS.2022.3166261>.
- Szczepański, M. and Marciniak, J. (2023). “Application of a Fuzzy Controller in Adaptive E-Learning Content Used to Evaluate Student Activity”. *Procedia Computer Science*, 225, 2526–2535. <https://doi.org/10.1016/j.procs.2023.10.244>.
- Troussas, C., Krouska, A., Mylonas, P. and Sgouropoulou, C. (2023). “Personalized Learner Assistance Through Dynamic Adaptation of Chatbot Using Fuzzy Logic Knowledge Modeling”. In: *18th International Workshop on Semantic and Social Media Adaptation & Personalization (SMAP 2023)*, pp. 1–5. <https://doi.org/10.1109/SMAP59435.2023.10255169>.
- Wang, S., Christensen, C., McBride, E. A., Kelly, H., Cui, W., Tong, R., Shear, L., Yarnall, L. and Feng, M. (2020). “Identifying Gaps in Use of and Research on Adaptive Learning Systems”. In: *International Conference on Computer Supported Education*. <https://doi.org/10.5220/0009590701180124>.