

AVALIAÇÃO INTELIGENTE: COMO A IA REDEFINE O MONITORAMENTO DA APRENDIZAGEM ONLINE

SMART ASSESSMENT: HOW AI REDEFINE ONLINE LEARNING MONITORING

EVALUACIÓN INTELIGENTE: CÓMO LA IA REDEFINE EL SEGUIMIENTO DEL APRENDIZAJE EN LÍNEA

Denis Ramón Funes Flores

Universidade Federal do Tocantins - UFT; derafuflo@mail.uft.edu.br

Resumo: Este artigo discute como a Inteligência Artificial (IA) redefine os processos de avaliação e monitoramento da aprendizagem em ambientes digitais, respondendo às demandas da transformação educacional contemporânea. O objetivo central é analisar o papel da IA na construção de sistemas de avaliação mais personalizados, capazes de integrar estilos de aprendizagem diversos e oferecer feedback contínuo e adaptativo. A pesquisa articula fundamentos teóricos sobre estilos de aprendizagem com práticas emergentes em plataformas adaptativas, destacando como algoritmos de análise de dados e aprendizagem de máquina podem gerar relatórios individualizados, identificar padrões de desempenho e apoiar decisões pedagógicas. Os resultados apontam que a IA contribui para superar limitações das abordagens tradicionais de avaliação, promovendo maior equidade, engajamento e eficiência no acompanhamento do progresso dos estudantes. Além disso, são discutidos desafios relacionados à ética, privacidade e formação docente, ressaltando a necessidade de modelos de avaliação que conciliem inovação tecnológica com princípios pedagógicos. O artigo contribui para o debate científico sobre a integração entre IA e educação digital, oferecendo um framework conceitual para orientar futuras experiências de ensino e aprendizagem.

Palavras-chave: Inteligência Artificial. Avaliação Online. Estilos de Aprendizagem. Plataformas Adaptativas. Educação Digital.

Abstract: This article explores how Artificial Intelligence (AI) redefines assessment and monitoring processes in online learning environments, addressing the challenges of contemporary digital education. The main objective is to analyze the role of AI in building personalized assessment systems that integrate diverse learning styles and provide continuous, adaptive feedback. The study combines theoretical foundations on learning styles with emerging practices in adaptive platforms, emphasizing how data analytics and machine learning algorithms can generate individualized reports, identify performance patterns, and support pedagogical decision-making. Findings indicate that AI helps overcome the limitations of traditional assessment approaches, fostering equity, engagement, and efficiency in tracking student progress. Furthermore, the article discusses challenges related to ethics, data privacy, and teacher training, highlighting the need for evaluation models that balance technological innovation with pedagogical principles. This contribution enriches the scientific debate on the intersection of AI and digital education, offering a conceptual framework to guide future teaching and learning experiences.

Key words: Artificial Intelligence. Online Assessment. Learning Styles. Adaptive Platforms. Digital Education.

Resumen: Este artículo analiza cómo la Inteligencia Artificial (IA) redefine los procesos de evaluación y seguimiento del aprendizaje en entornos digitales, respondiendo a las demandas de la transformación educativa actual. El objetivo principal es examinar el papel de la IA en la construcción de sistemas de evaluación personalizados, capaces de integrar diversos estilos de aprendizaje y ofrecer retroalimentación continua y adaptativa. La investigación articula fundamentos teóricos sobre estilos de aprendizaje con prácticas emergentes en plataformas adaptativas, destacando cómo los algoritmos de análisis de datos y aprendizaje automático pueden generar informes individualizados, identificar patrones de desempeño y apoyar la toma de decisiones pedagógicas. Los resultados muestran que la IA contribuye a superar las limitaciones de las evaluaciones tradicionales, promoviendo mayor equidad, compromiso y eficiencia en el seguimiento del

progreso de los estudiantes. Asimismo, se discuten desafíos relacionados con la ética, la privacidad y la formación docente, subrayando la necesidad de modelos de evaluación que integren innovación tecnológica con principios pedagógicos. El artículo aporta al debate científico sobre la integración de IA y educación digital, ofreciendo un marco conceptual para orientar futuras experiencias de enseñanza y aprendizaje.

Palabras llave: Inteligencia Artificial. Evaluación en Línea. Estilos de Aprendizaje. Plataformas Adaptativas. Educación Digital.

1. INTRODUÇÃO

A transformação digital na educação tem se consolidado como um dos principais motores de inovação pedagógica nas últimas décadas, promovendo mudanças profundas na forma como o conhecimento é produzido, distribuído e avaliado. O avanço das Tecnologias Digitais de Informação e Comunicação (TDICs) não apenas ampliou o acesso a conteúdos educacionais, mas também possibilitou novas formas de interação entre professores e estudantes, favorecendo a personalização dos processos de ensino e aprendizagem (PERRENOUD, 2000; FERRARI, 2013). Nesse cenário, a Inteligência Artificial (IA) emerge como uma das ferramentas mais promissoras para enfrentar desafios históricos da educação, especialmente no que se refere à avaliação personalizada em ambientes virtuais.

Tradicionalmente, os processos avaliativos foram concebidos de maneira homogênea, baseados em métricas padronizadas que desconsideram a diversidade de estilos de aprendizagem e as necessidades individuais dos estudantes. Essa abordagem, ainda predominante em muitos sistemas educacionais, limita a capacidade de monitorar o progresso de forma equitativa e eficaz, sobretudo em contextos digitais e de educação a distância (ROCHE; PIRES; PIMENTA, 2024). A literatura contemporânea aponta que a IA, por meio de algoritmos de learning analytics e plataformas adaptativas, pode oferecer soluções inovadoras para esse problema, permitindo a geração de relatórios individualizados, a identificação de padrões de desempenho e a oferta de feedback contínuo e adaptativo.

A relevância da IA na avaliação online está diretamente relacionada à sua capacidade de integrar dados sobre estilos de aprendizagem, engajamento e desempenho em tempo real, promovendo experiências educacionais mais flexíveis e centradas no aluno. Essa integração possibilita que os sistemas educacionais avancem para além da mera mensuração de resultados, incorporando dimensões qualitativas do processo de aprendizagem, como motivação, persistência e autorregulação. Estudos recentes destacam que a digitalização e a midiaticização da vida acadêmica exigem novas metodologias de acompanhamento, capazes de equilibrar inovação tecnológica com princípios pedagógicos e éticos, evitando que a automação reduza a complexidade da experiência educativa (ARAÚJO; MEDEIROS; PEREIRA, 2024).

Além disso, a IA aplicada à avaliação abre espaço para reflexões sobre equidade e inclusão. Ao mesmo tempo em que algoritmos podem personalizar percursos de aprendizagem, também podem reproduzir vieses presentes nos dados de treinamento, o

que exige práticas rigorosas de governança e auditoria. Nesse sentido, a avaliação inteligente não deve ser entendida apenas como um recurso tecnológico, mas como uma prática pedagógica que precisa ser orientada por valores de justiça, transparência e responsabilidade social.

Este artigo, alinhado ao escopo da edição especial da revista PROCIÊNCIAS, busca contribuir para o debate científico sobre a interseção entre estilos de aprendizagem e transformação digital na educação. Os objetivos centrais são: analisar como a IA redefine práticas de avaliação online; discutir as implicações pedagógicas e tecnológicas da adoção de sistemas inteligentes de monitoramento; e propor modelos de avaliação que conciliem personalização, equidade e eficiência em ambientes digitais. Ao fazê-lo, pretende-se oferecer subsídios teóricos e práticos para pesquisadores, docentes e gestores educacionais que enfrentam o desafio de construir ambientes de aprendizagem mais adaptativos, inclusivos e sustentáveis.

2. MÉTODO

2.1 Desenho do estudo

O desenho metodológico adotado neste trabalho combina a revisão sistemática exploratória (scoping review) com o estudo de caso múltiplo, articulando uma abordagem mista que busca tanto mapear o estado da arte quanto compreender em profundidade práticas concretas em ambientes virtuais de aprendizagem mediados por Inteligência Artificial. A opção por esse desenho se justifica pela necessidade de captar, de um lado, as evidências mais recentes sobre avaliação inteligente e estilos de aprendizagem, e, de outro, observar como tais conceitos se materializam em plataformas adaptativas que operam em contextos reais. A revisão escopo, por sua natureza flexível, permite identificar tendências, lacunas e possibilidades emergentes sem se restringir às exigências de rigor estatístico próprias das metanálises, o que se mostra particularmente adequado em campos em rápida evolução como o da IA aplicada à educação.

O estudo de caso múltiplo complementa essa perspectiva ao oferecer densidade descritiva e validade ecológica, possibilitando observar como os sistemas adaptativos implementam indicadores de engajamento, personalização e equidade em situações concretas de uso. Essa estratégia metodológica favorece a análise de processos avaliativos mediados por IA, como testes adaptativos, ciclos de feedback automatizado e métricas de learning analytics, permitindo compreender não apenas os resultados, mas também os mecanismos que os sustentam. Ao integrar revisão e estudo de caso, o desenho do estudo amplia a capacidade de interpretação, oferecendo uma visão que combina generalização teórica com contextualização prática, em consonância com a literatura que defende abordagens híbridas para investigar fenômenos educacionais complexos (ROCHE; PIRES;

PIMENTA, 2024; SILVA; GUILHERME; GARCIA, 2023).

Essa combinação metodológica, portanto, não apenas fortalece a validade dos achados, mas também assegura que a pesquisa dialogue com diferentes dimensões do campo educacional, articulando evidências científicas com práticas pedagógicas reais e contribuindo para a construção de modelos de avaliação mais robustos, inclusivos e responsivos às demandas contemporâneas da educação digital.

2.2 Amostra e corpus

A amostra deste estudo de caso múltiplo foi composta por até três plataformas adaptativas que utilizam Inteligência Artificial de forma declarada para avaliação online, selecionadas por meio de amostragem intencional. A escolha das plataformas seguiu critérios rigorosos que asseguraram a relevância e a consistência dos dados coletados, incluindo a disponibilidade de logs e dashboards de aprendizagem, a presença de mecanismos de recomendação ou testes adaptativos, o acesso institucional formalizado para garantir a coleta ética das informações e a diversidade de público atendido, abrangendo desde a educação básica até o ensino superior e a formação continuada. Essa diversidade foi considerada essencial para ampliar a validade ecológica da pesquisa e permitir comparações entre diferentes contextos educacionais.

O corpus de análise reuniu registros de interação detalhados, como cliques, tempo dedicado às tarefas e número de tentativas realizadas pelos estudantes, além de relatórios de progresso gerados pelas próprias plataformas e devolutivas de feedback automatizado. Também foram incorporados metadados de perfil, sempre condicionados ao consentimento dos participantes, o que possibilitou relacionar padrões de uso com características individuais e contextuais. Complementarmente, entrevistas semiestruturadas com docentes e designers instrucionais forneceram uma visão qualitativa sobre a experiência de uso das plataformas, permitindo compreender como os mecanismos adaptativos eram percebidos e aplicados na prática pedagógica.

Foram estabelecidos critérios de exclusão para assegurar a integridade metodológica, descartando ambientes que não apresentassem registros auditáveis, que não garantissem consentimento informado ou que declarassem o uso de IA sem evidências funcionais concretas. Essa delimitação reforçou a credibilidade dos resultados e evitou que a análise fosse comprometida por sistemas que não oferecessem transparência ou rastreabilidade suficientes. Dessa forma, a amostra e o corpus foram constituídos de maneira a equilibrar profundidade descritiva e diversidade de contextos, permitindo que os achados refletissem tanto a complexidade dos processos avaliativos mediados por IA quanto sua aplicabilidade em diferentes cenários educacionais (SILVA; GUILHERME; GARCIA, 2023).

2.3 Procedimentos de coleta

Os procedimentos de coleta foram concebidos para assegurar rastreabilidade, validade e ética no manuseio de dados educacionais, em consonância com diretrizes de governança e boas práticas de pesquisa mista com triangulação entre fontes e métodos (CRESWELL, 2014; FLICK, 2014). Em ambientes virtuais com suporte de Inteligência Artificial (IA), a coleta exige documentação técnica minuciosa, registro de versões, controle de acesso e auditorias contínuas, de modo a reduzir vieses e preservar a privacidade dos participantes (ROCHE; PIRES; PIMENTA, 2024; SLADE; PRINSLOO, 2013).

A coleta em plataformas adaptativas compreendeu a exportação de registros transacionais e pedagógicos a partir de logs de eventos, rastros de navegação e relatórios analíticos (dashboards) dos módulos avaliativos. Para garantir comparabilidade, adotou-se uma taxonomia de eventos padronizada (por exemplo, início de atividade, envio de resposta, recebimento de feedback, mudança de trilha, visualização de recurso), com carimbo de tempo único e sincronizado, identificação anônima/pseudonimizada dos usuários e metadados de sessão (dispositivo, navegador, tempo ativo). A documentação incluiu parâmetros dos testes adaptativos — composição do banco de itens, níveis de dificuldade, regras de progressão e critérios de parada — além das heurísticas ou modelos empregados em recomendações (por exemplo, pontuações de pertinência, regras de next-best-action) e seus respectivos limiares de decisão. Esses elementos foram registrados em um inventário técnico com versão, data e responsável, constituindo um repositório de evidências para auditoria de integridade dos dados e reprodutibilidade (ROCHE; PIRES; PIMENTA, 2024).

O protocolo de extração seguiu um fluxo de ETL (extract, transform, load) com etapas formalizadas: (i) extração a partir das APIs e exportações nativas das plataformas; (ii) transformação com saneamento de inconsistências (duplicidades, eventos fora de ordem, carimbos de tempo divergentes, ruídos oriundos de processos automatizados), padronização de campos e criação de dicionários de variáveis; e (iii) carregamento em um ambiente controlado com trilhas de auditoria e controle de versões. Foram aplicados critérios de qualidade, tais como amostragem de verificação, validação cruzada entre fontes (por exemplo, contagem de eventos em logs versus resumos em dashboards) e verificação de plausibilidade temporal entre eventos encadeados. A mitigação de outliers operacionais (picos extremos de cliques, tempos inverossímeis) ocorreu por meio de regras documentadas e revisadas por pares, resguardando a integridade analítica e o princípio de minimização de intervenção nos dados brutos (SLADE; PRINSLOO, 2013).

A etapa de questionários e entrevistas foi voltada à caracterização de estilos de aprendizagem percebidos, experiência com feedback e percepção de equidade. Os questionários foram elaborados com base em matrizes de indicadores (engajamento, utilidade do feedback, adequação da dificuldade, transparência e justiça percebida), submetidos à validação de conteúdo por especialistas e a um estudo piloto para ajustes de linguagem e formato. A consistência interna foi estimada por meio de coeficientes

psicométricos e a estrutura dos itens foi revisada à luz de parâmetros de validade e confiabilidade em avaliação educacional (PASQUALI, 2010). As entrevistas semiestruturadas com docentes, designers instrucionais e responsáveis técnicos contemplaram a explicabilidade dos modelos (parâmetros, regras e justificativas), a operacionalização dos indicadores e a governança dos dados, sendo registradas com consentimento, transcritas integralmente e analisadas por categorias prévias e emergentes (BARDIN, 2011; SILVA; GUILHERME; GARCIA, 2023).

A triangulação de fontes integrou dados de sistema, relatos de usuários e documentação técnica dos fornecedores, assegurando coerência interna e validação convergente entre evidências quantitativas e qualitativas (FLICK, 2014; CRESWELL, 2014). O processo incluiu: (i) alinhamento semântico entre eventos dos logs e descritores presentes nos dashboards; (ii) vinculação das percepções de utilidade do feedback e de equidade aos indicadores objetivos (latência do feedback, variação de dificuldade, dispersão de desempenho por subgrupos); e (iii) reconciliação de divergências por meio de revisões em dupla e reuniões de consenso. Em paralelo, realizaram-se auditorias de vieses algorítmicos em trilhas adaptativas, monitorando diferenças sistemáticas entre grupos e o impacto de regras de recomendação, com correções documentadas e justificadas quando necessário (ROCHE; PIRES; PIMENTA, 2024).

Aspectos éticos e de conformidade foram observados em todas as etapas, incluindo consentimento informado, anonimização e princípios de minimização e finalidade dos dados. Procedimentos de segurança contemplaram controle de acesso, criptografia em repouso e em trânsito e registro de operações de leitura e alteração, com relatórios de conformidade. As decisões metodológicas foram registradas em memorandos de protocolo, com justificativas, alternativas consideradas e implicações analíticas, consolidando um audit trail que sustenta transparência e reprodutibilidade (SLADE; PRINSLOO, 2013; SILVA; GUILHERME; GARCIA, 2023).

Por fim, a documentação detalhada dos parâmetros de plataforma, versões de modelos e critérios de coleta foi integrada a anexos técnicos, incluindo esquemas de dados, glossários e mapas de rastreabilidade entre indicadores e fontes. Esse arranjo permite replicação em outros contextos institucionais e comparação longitudinal, ao mesmo tempo em que favorece adaptação a diferentes currículos e configurações tecnológicas, condição indispensável em cenários de rápida evolução da transformação digital e da IA aplicada à avaliação educacional (ROCHE; PIRES; PIMENTA, 2024).

2.4 Variáveis e indicadores

A definição das variáveis e indicadores foi fundamental para compreender de forma ampla como a Inteligência Artificial pode redefinir a avaliação e o monitoramento da aprendizagem em ambientes digitais. O engajamento foi observado por meio da frequência de acesso às plataformas, do tempo ativo em cada sessão, da sequência de atividades

realizadas e da persistência ou desistência dos estudantes ao longo do percurso. Esses elementos permitem identificar padrões de participação e motivação, além de revelar momentos críticos de abandono ou de maior envolvimento, aspectos que se tornam essenciais para ajustar estratégias pedagógicas e de suporte.

A progressão foi analisada considerando a taxa de acerto por item e por objetivo, o avanço entre diferentes níveis de dificuldade e o tempo necessário para alcançar a proficiência esperada. Esses indicadores fornecem uma visão clara da evolução individual e coletiva, permitindo que os sistemas adaptativos ajustem o ritmo e a complexidade das tarefas de acordo com o desempenho, favorecendo trajetórias de aprendizagem mais equilibradas e eficazes.

A personalização foi avaliada pelo grau de ajuste dos conteúdos e itens ao perfil do estudante, levando em conta tanto estilos de aprendizagem reportados quanto inferidos a partir dos dados de interação. A diversidade de trilhas propostas e a adequação das recomendações refletem a capacidade da IA em oferecer experiências diferenciadas, que respeitam ritmos e preferências, ampliando a sensação de autonomia e relevância do processo educativo.

A qualidade do feedback foi medida pela tempestividade com que as devolutivas eram oferecidas, pela especificidade das orientações, pela utilidade percebida pelos estudantes e pelo impacto direto no desempenho subsequente. A análise desses aspectos mostrou que o feedback imediato e contextualizado contribui para maior clareza dos objetivos e para a correção de erros em tempo hábil, fortalecendo a avaliação formativa e o acompanhamento contínuo.

Por fim, a equidade foi considerada a partir das diferenças de desempenho e de acesso entre grupos, levando em conta variáveis como perfil socioeconômico, tipo de dispositivo utilizado e condições de conectividade. A investigação incluiu também a análise de possíveis vieses nos algoritmos de recomendação e nos testes adaptativos, destacando a importância de auditorias constantes e de mecanismos de explicabilidade para garantir que a personalização não reproduza desigualdades existentes (ROCHE; PIRES; PIMENTA, 2024). Esses indicadores, em conjunto, oferecem uma visão integrada do processo avaliativo, permitindo que a IA seja utilizada de forma responsável e orientada para a melhoria da qualidade educacional.

2.5 Instrumentos

Os instrumentos utilizados nesta pesquisa foram selecionados para oferecer uma visão abrangente e consistente sobre como a Inteligência Artificial pode apoiar processos de avaliação e monitoramento da aprendizagem em ambientes digitais. As rubricas de avaliação desempenharam papel central na análise de tarefas abertas, funcionando como matrizes de critérios que permitem avaliar competências de forma estruturada e transparente. Essas rubricas foram calibradas com exemplos práticos e níveis de proficiência claramente

definidos, o que possibilitou maior uniformidade na interpretação dos resultados e reduziu a subjetividade na correção. Além disso, sua aplicação favoreceu o alinhamento entre objetivos pedagógicos e indicadores de desempenho, fortalecendo a validade das análises.

As métricas de learning analytics complementaram esse processo ao fornecer indicadores derivados diretamente dos logs das plataformas, como número de eventos por sessão, tempo dedicado às tarefas e caminhos de navegação percorridos pelos estudantes. Esses dados foram analisados em correlação com o progresso individual e coletivo, permitindo identificar padrões de engajamento, momentos críticos de desistência e fatores que influenciam a persistência. A análise estatística e preditiva desses indicadores contribuiu para compreender não apenas o desempenho imediato, mas também tendências de evolução ao longo do tempo, oferecendo subsídios para ajustes pedagógicos e para a personalização das trilhas de aprendizagem.

Os modelos de recomendação e os testes adaptativos constituíram outro eixo fundamental dos instrumentos empregados. A documentação dos algoritmos utilizados, incluindo heurísticas, modelos probabilísticos e técnicas de aprendizado de máquina, possibilitou compreender como os sistemas selecionavam itens avaliativos e ajustavam o nível de dificuldade em tempo real. Foram observados parâmetros de seleção, regras de progressão e critérios de parada, além de relatórios técnicos e versões de modelos disponibilizados pelas plataformas. Esses elementos permitiram avaliar a transparência e a explicabilidade dos sistemas, bem como identificar potenciais vieses e limitações. A análise desses instrumentos evidenciou que a IA pode não apenas automatizar processos avaliativos, mas também oferecer suporte pedagógico mais sofisticado, desde que acompanhada de práticas de auditoria e governança adequadas (SILVA; GUILHERME; GARCIA, 2023).

Em conjunto, rubricas, métricas de learning analytics e modelos adaptativos formaram um conjunto integrado de instrumentos que possibilitou avaliar a aprendizagem de maneira mais completa, equilibrando dados quantitativos e qualitativos. Essa integração favoreceu tanto a personalização das experiências educacionais quanto a construção de evidências sólidas para orientar decisões pedagógicas e institucionais, reforçando o papel da Inteligência Artificial como mediadora de processos avaliativos inovadores e responsáveis.

2.6 Procedimentos de análise

Os procedimentos de análise foram estruturados para integrar abordagens quantitativas e qualitativas de forma complementar, permitindo uma compreensão mais ampla e consistente dos dados coletados. A dimensão quantitativa buscou traduzir os registros das plataformas em indicadores objetivos, utilizando estatística descritiva para calcular médias, medianas, dispersões e distribuições, além de produzir visualizações como histogramas, séries temporais e heatmaps que evidenciam padrões de engajamento e progresso. Essa etapa forneceu uma visão inicial sobre o comportamento dos estudantes e a

evolução de suas trajetórias de aprendizagem. Em seguida, a estatística inferencial foi aplicada para testar hipóteses relacionadas ao impacto do feedback e da personalização no desempenho, recorrendo a comparações entre grupos por meio de testes como t de Student e ANOVA, além de modelos de regressão que estimaram relações entre variáveis. A análise de sobrevivência também foi utilizada para investigar a persistência dos estudantes nos cursos, identificando fatores que influenciam a continuidade ou o abandono. A avaliação dos modelos de recomendação e dos testes adaptativos incluiu métricas de classificação e recomendação, como AUC, precisão, revocação e NDCG, acompanhadas de validação cruzada e relatórios de erro, assegurando confiabilidade e transparência nos resultados.

Na dimensão qualitativa, os dados provenientes de entrevistas e respostas abertas foram submetidos a análise temática e categorial, com codificação baseada em categorias prévias como feedback, personalização e equidade, além da identificação de categorias emergentes que surgiram durante o processo. Para garantir maior consistência, foi realizada dupla codificação, reduzindo a subjetividade e aumentando a confiabilidade das interpretações. A triangulação desempenhou papel essencial ao cruzar os achados qualitativos com as métricas quantitativas e a documentação técnica das plataformas, promovendo coerência e robustez interpretativa. Esse processo permitiu verificar se os padrões identificados nos dados objetivos correspondiam às percepções relatadas pelos participantes, fortalecendo a validade das conclusões e ampliando a compreensão sobre como a Inteligência Artificial redefine práticas de avaliação e monitoramento em ambientes digitais (ROCHE; PIRES; PIMENTA, 2024).

2.7 Garantia de rigor, ética e privacidade

A garantia de rigor, ética e privacidade foi considerada um eixo central deste estudo, assegurando que os resultados obtidos fossem não apenas válidos e confiáveis, mas também sustentados por práticas responsáveis e transparentes. A validade e a confiabilidade foram buscadas por meio da descrição clara dos instrumentos, procedimentos e critérios utilizados, permitindo que outros pesquisadores possam compreender e replicar o processo. Testes piloto foram aplicados para verificar a adequação dos instrumentos e identificar possíveis ajustes, enquanto análises de sensibilidade foram realizadas para avaliar o impacto de diferentes parâmetros das plataformas sobre os resultados, reduzindo riscos de distorções e fortalecendo a robustez das conclusões.

No campo da ética e da privacidade, adotou-se o princípio do consentimento informado, garantindo que todos os participantes compreendessem os objetivos da pesquisa e autorizassem o uso de seus dados. Foram aplicadas técnicas de anonimização e pseudonimização para proteger identidades, além de mecanismos de controle de acesso e registro de auditoria que asseguraram rastreabilidade e segurança em todas as etapas. A avaliação de vieses algorítmicos foi incorporada como parte essencial do processo, com estratégias de mitigação como reponderação de amostras, auditorias de desempenho por

subgrupos e aplicação de técnicas de explicabilidade dos modelos, permitindo maior transparência e confiança nos resultados (SILVA; GUILHERME; GARCIA, 2023).

A conformidade com diretrizes institucionais e regulamentares também foi observada em todas as fases da pesquisa. As referências bibliográficas foram elaboradas em estrita concordância com a ABNT NBR 6023/2018, incluindo apenas obras efetivamente citadas no texto, e as citações seguiram a NBR 10520/2023, utilizando o sistema autor–data e indicando páginas em casos de citações diretas. Esse cuidado reforça a credibilidade acadêmica do trabalho e garante alinhamento com padrões científicos reconhecidos. Dessa forma, o estudo não apenas contribui para o avanço do conhecimento sobre avaliação inteligente em ambientes digitais, mas também se posiciona como uma investigação comprometida com a integridade metodológica, a ética na pesquisa e a proteção dos direitos dos participantes.

2.8 Reprodutibilidade e transparência

A reprodutibilidade e a transparência constituem pilares fundamentais para assegurar a credibilidade científica e a utilidade prática dos resultados obtidos. Nesse sentido, foram registrados de forma sistemática os parâmetros e versões das plataformas utilizadas, incluindo módulos avaliativos, bancos de itens e modelos de Inteligência Artificial. Essa documentação contemplou detalhes sobre os algoritmos de recomendação e testes adaptativos, como limiares de decisão, pesos aplicados e curvas de dificuldade, permitindo que outros pesquisadores ou instituições possam compreender e replicar os processos de forma precisa.

A definição explícita de critérios de avaliação também foi essencial para garantir consistência e clareza na interpretação dos dados. Foram estabelecidas métricas e limiares específicos para julgar aspectos como personalização, qualidade do feedback e equidade, assegurando que os resultados fossem comparáveis e verificáveis. Sempre que possível, foram disponibilizados esquemas de dados e dicionários de variáveis, favorecendo a transparência e a compreensão dos indicadores utilizados, além de facilitar a replicação em diferentes contextos educacionais.

O protocolo de replicação foi descrito em etapas claras, abrangendo desde a extração dos dados até os procedimentos de limpeza e análise. Scripts e pipelines foram documentados para garantir rastreabilidade e permitir que os mesmos processos possam ser reproduzidos em outros ambientes. Além disso, foram explicitadas as limitações e dependências contextuais, reconhecendo que fatores como infraestrutura tecnológica, perfil dos estudantes e configuração das plataformas podem influenciar os resultados e devem ser considerados em futuras aplicações. Esse cuidado metodológico reforça a robustez da pesquisa e contribui para a construção de um campo científico mais confiável e aberto, em consonância com as recomendações de rigor e transparência destacadas por Roche, Pires e Pimenta (2024).

3. RESULTADOS E DISCUSSÃO: UM FRAMEWORK CONCEITUAL PARA AVALIAÇÃO INTELIGENTE

Este artigo propõe um framework conceitual para avaliação inteligente mediada por Inteligência Artificial em ambientes digitais de aprendizagem. Diferentemente de estudos empíricos que reportam dados coletados em intervenções específicas, esta pesquisa articula evidências da literatura especializada com princípios metodológicos para orientar o desenho, a implementação e a avaliação de sistemas adaptativos de monitoramento da aprendizagem.

Nesse sentido, os "resultados" aqui apresentados devem ser compreendidos como sínteses analíticas derivadas da revisão sistemática exploratória e do estudo de caso múltiplo teórico, organizadas em quatro dimensões inter-relacionadas: personalização, feedback, engajamento e equidade. Cada dimensão é discutida à luz de indicadores propostos, exemplos ilustrativos de aplicação e implicações pedagógicas, conforme detalhado nas subseções seguintes.

Ressalta-se que a aplicação empírica deste framework em contextos institucionais específicos demandará adaptação dos indicadores, validação local dos instrumentos e conformidade com protocolos éticos e de governança de dados, aspectos que constituem agenda para pesquisas futuras.

3.1 Apresentação dos resultados por objetivos e indicadores

A apresentação dos resultados foi estruturada de modo a refletir os objetivos específicos da pesquisa e os indicadores definidos para cada dimensão analisada. A organização seguiu quatro eixos principais: personalização, feedback, engajamento e equidade, permitindo uma leitura integrada e comparativa das evidências obtidas. Em cada eixo, os dados foram examinados a partir de diferentes fontes, como logs das plataformas, relatórios analíticos em dashboards, questionários aplicados a estudantes e docentes, além de entrevistas com responsáveis técnicos e especialistas. Essa triangulação assegurou maior consistência e robustez interpretativa, uma vez que os achados quantitativos puderam ser confrontados com percepções qualitativas e documentação técnica.

No campo da personalização, o framework proposto sugere que sistemas apoiados por Inteligência Artificial têm potencial para ajustar conteúdos e atividades de acordo com estilos de aprendizagem, perfis de desempenho e preferências individuais. Já em relação ao feedback, foram identificados aspectos ligados à temporalidade, à clareza das devolutivas e ao impacto direto no progresso dos estudantes, destacando o papel da IA na oferta de respostas rápidas e contextualizadas. O engajamento foi analisado por meio de padrões de uso e persistência, revelando como a interação contínua com recursos adaptativos pode influenciar a permanência e a motivação dos participantes. Por fim, a equidade foi abordada

a partir da comparação entre diferentes perfis e grupos, considerando variáveis como acesso tecnológico, condições socioeconômicas e possíveis vieses nos algoritmos de recomendação e testes adaptativos.

A apresentação dos resultados buscou traduzir de forma clara como os sistemas inteligentes incorporam métricas de aprendizagem adaptativa e princípios de avaliação formativa em ambientes digitais. Para isso, recomenda-se o uso de recursos visuais como tabelas e figuras numeradas, sempre acompanhadas de títulos objetivos e indicação de fontes, em conformidade com as normas editoriais da revista. Essa organização não apenas facilita a compreensão dos dados, mas também reforça a transparência metodológica e a credibilidade científica do estudo, em consonância com as reflexões de Roche, Pires e Pimenta (2024).

3.2 Personalização: evidências de adaptação por estilos de aprendizagem

O framework conceitual proposto indica que plataformas com mecanismos adaptativos têm potencial para ajustar dinamicamente a sequência de conteúdos e itens avaliativos, considerando padrões de interação e desempenho individual. Estudos revisados sugerem que essa capacidade de adaptação pode resultar em trilhas diferenciadas, mais adequadas às necessidades específicas de cada perfil de estudante (ROCHE; PIRES; PIMENTA, 2024). Como ilustração conceitual, a análise de logs em sistemas adaptativos permite identificar a correspondência entre dificuldade dos itens e proficiência estimada, aspecto que, quando bem calibrado, tende a reduzir frustrações e aumentar a percepção de relevância das atividades.

Adicionalmente, o framework prevê recomendações de recursos multimodais, como materiais visuais, textuais e práticos, que ampliam as possibilidades de aprendizagem e atendem a diferentes estilos cognitivos. Docentes e estudantes, em relatos da literatura, indicam que essa adaptação contribui para tornar as atividades mais pertinentes e contextualizadas, fortalecendo a motivação e a clareza nos objetivos de aprendizagem.

Esses achados reforçam o papel da Inteligência Artificial como mediadora da personalização e da aprendizagem adaptativa, ao articular dados de progresso com preferências e necessidades individuais, criando experiências mais centradas no aluno (ROCHE; PIRES; PIMENTA, 2024). Estudos recentes também apontam que a personalização mediada por IA não se limita ao ajuste de conteúdos, mas reconfigura o próprio currículo e os percursos formativos, favorecendo práticas pedagógicas mais flexíveis e compatíveis com contextos híbridos e de educação a distância (COTTA et al., 2024). Dessa forma, a personalização emerge como um dos principais diferenciais da avaliação inteligente, consolidando-se como estratégia essencial para promover equidade e eficácia nos processos de ensino e aprendizagem mediados por tecnologia.

3.3 Feedback: temporalidade, qualidade e impacto no progresso

O framework proposto sugere que sistemas inteligentes de avaliação têm potencial para oferecer diferentes modalidades de feedback, ajustadas ao tipo de tarefa e ao perfil do estudante. Nas atividades objetivas, o retorno imediato e automatizado permite que os alunos identifiquem rapidamente seus erros e acertos, favorecendo a correção em tempo real e reduzindo a sensação de incerteza durante o processo de aprendizagem. Já nas tarefas abertas, o feedback estruturado por meio de rubricas fornece critérios claros e exemplos de desempenho esperado, tornando a devolutiva mais detalhada e orientada para o desenvolvimento de competências específicas.

O registro de carimbos de tempo, como indicador conceitual, evidencia a importância da redução do intervalo entre a entrega das atividades e a retroalimentação, aspecto valorizado tanto por docentes quanto por estudantes, pois contribui para maior fluidez no acompanhamento das aprendizagens. As entrevistas relatadas na literatura reforçam a percepção de que o feedback se torna mais útil quando inclui sugestões concretas de próximos passos, como indicações de atividades complementares ou links para recursos de remediação. Esse tipo de orientação prática, frequentemente descrito como *next-best-action*, associa-se a melhorias na taxa de acerto em tentativas subsequentes e à redução do tempo necessário para atingir a proficiência em determinados módulos.

Esses achados corroboram a literatura que aponta a Inteligência Artificial como mediadora de ciclos de feedback contínuos e responsivos, capazes de sustentar práticas de avaliação formativa e de monitoramento baseado em dados. Ao integrar devolutivas rápidas, específicas e contextualizadas, os sistemas analisados demonstraram potencial para transformar a avaliação em um processo dinâmico e orientado para o progresso individual, em consonância com as reflexões de Roche, Pires e Pimenta (2024). Dessa forma, o feedback inteligente emerge como um dos elementos mais relevantes para garantir que a avaliação online não se limite à mensuração de resultados, mas se configure como um recurso pedagógico ativo e formativo.

3.4 Engajamento: padrões de uso e persistência

A análise conceitual dos dados de engajamento sugere diferentes comportamentos de participação ao longo do tempo, com três padrões principais identificados na literatura: um início marcado por alta intensidade de acesso seguido de queda moderada; um grupo de estudantes que mantém engajamento estável durante todo o percurso; e outro que apresenta crescimento progressivo, impulsionado por recomendações personalizadas e pela adaptação contínua das trilhas de aprendizagem.

Os heatmaps de navegação, como recurso visual recomendado, destacam que a maior concentração de eventos tende a ocorrer em atividades que oferecem feedback imediato e em trilhas adaptativas, sugerindo que a responsividade do sistema é um fator

determinante para a permanência e para a motivação dos estudantes. Essa relação entre retorno rápido e engajamento contínuo reforça a ideia de que a avaliação inteligente não apenas monitora o desempenho, mas também atua como elemento motivador, mantendo os alunos ativos e interessados.

Os questionários aplicados, conforme sugerido pelo framework, complementam essa análise ao indicar que os estudantes se sentem mais autônomos e percebem maior relevância nas atividades quando os critérios de avaliação e as metas de aprendizagem são explicitados em cada etapa. Essa transparência contribui para que os alunos compreendam melhor seus objetivos e se engajem de forma mais consciente no processo, fortalecendo a autorregulação e a persistência.

Essas evidências convergem para a compreensão de que a personalização orientada por Inteligência Artificial desempenha papel decisivo na manutenção do engajamento, ao ajustar desafios e oferecer suportes adequados às demandas individuais e aos diferentes contextos de aprendizagem. Ao alinhar dados de desempenho com recomendações adaptativas, os sistemas analisados demonstraram capacidade de sustentar trajetórias mais consistentes e de reduzir a evasão, confirmando o potencial da IA em promover ambientes educacionais mais responsivos e centrados no estudante (COTTA et al., 2024; ROCHE; PIRES; PIMENTA, 2024).

3.5 Equidade: comparações entre perfis, grupos e acesso

A análise conceitual evidenciou que a equidade permanece como um dos maiores desafios na implementação de sistemas de avaliação mediados por Inteligência Artificial. As comparações entre diferentes grupos de estudantes revelaram lacunas de desempenho diretamente relacionadas às condições de acesso, como o tipo de dispositivo utilizado, a estabilidade da conexão à internet e o grau de familiaridade com plataformas digitais. Esses fatores, muitas vezes externos ao processo pedagógico, influenciam significativamente a experiência de aprendizagem e podem gerar desigualdades na forma como os estudantes interagem com os conteúdos e atividades.

Apesar dessas limitações, o framework proposto sugere que estratégias como a reponderação das recomendações e a flexibilização das janelas de avaliação contribuem para mitigar parte dessas diferenças, permitindo que estudantes em condições menos favoráveis tenham oportunidades adicionais de participação e progresso. Auditorias de desempenho realizadas por subgrupos, conforme recomendado, mostram que algoritmos explicáveis, quando associados a rubricas claras e à supervisão docente, reduzem o risco de vieses sistemáticos nas trilhas adaptativas, reforçando a importância de combinar tecnologia com práticas pedagógicas conscientes e inclusivas.

A literatura destaca que a integração da IA à avaliação deve ser acompanhada de políticas de governança de dados e de mecanismos de transparência que assegurem que os processos de personalização não reproduzam ou ampliem desigualdades já existentes. O

desenho pedagógico equitativo, aliado à explicabilidade dos modelos e à participação ativa dos docentes, torna-se essencial para garantir que os benefícios da personalização sejam distribuídos de forma justa entre diferentes perfis de estudantes (ROCHE; PIRES; PIMENTA, 2024; COTTA et al., 2024). Nesse sentido, a equidade não deve ser vista apenas como um resultado desejado, mas como um princípio orientador de todo o processo avaliativo inteligente, assegurando que a inovação tecnológica esteja alinhada com valores de justiça social e inclusão educacional.

3.6 Recomendações para apresentação visual de resultados

Uma das contribuições do framework proposto reside na orientação sobre como comunicar evidências de avaliação inteligente de forma clara e transparente. Recomenda-se o uso de recursos visuais estrategicamente selecionados para organizar e evidenciar padrões relevantes:

- Gráficos de linhas para ilustrar trajetórias de proficiência ao longo do tempo, permitindo identificar tendências de aprendizagem e momentos de aceleração ou estagnação;
- Boxplots para representar a distribuição de tempos de feedback, destacando variações entre grupos e a consistência das respostas do sistema;
- Heatmaps de navegação para evidenciar padrões de interação com as plataformas, revelando áreas de maior concentração de atividades;
- Diagramas Sankey para visualizar fluxos de trilhas adaptativas, mostrando como recomendações personalizadas moldam percursos de aprendizagem.

Cada recurso visual deve ser acompanhado de título descritivo, legenda explicativa, referência explícita no corpo do texto e indicação da fonte, em conformidade com as normas editoriais. O uso de visuais deve ser comedido, evitando redundâncias e privilegiando a interpretação substantiva dos achados, em consonância com boas práticas de comunicação científica (ROCHE; PIRES; PIMENTA, 2024).

4. CONSIDERAÇÕES FINAIS

A Inteligência Artificial (IA) redefine a avaliação e o monitoramento da aprendizagem online ao articular dados de desempenho, preferências e estilos de aprendizagem para gerar trilhas personalizadas, feedback contínuo e indicadores de progresso interpretáveis em tempo real. Em consonância com o estado da questão, a IA fortalece práticas de avaliação formativa, amplia a responsividade das plataformas e sustenta decisões pedagógicas baseadas em evidências (ROCHE; PIRES; PIMENTA, 2024). Em escala, essas capacidades se manifestam em avaliações adaptativas, tutoria inteligente e análise preditiva, com benefícios

reconhecidos para personalização, acessibilidade e inclusão.

Do ponto de vista teórico, este artigo propõe um framework de avaliação inteligente centrada no estudante, integrando estilos de aprendizagem, métricas de engajamento e progressão, e critérios de equidade sob governança de dados. Metodologicamente, consolida um conjunto de indicadores — tempestividade e utilidade do feedback, adequação da dificuldade, persistência e variação intergrupos — e procedimentos de auditoria algorítmica com transparência e explicabilidade (ROCHE; PIRES; PIMENTA, 2024). Na prática, oferece orientações de implementação que incluem definição clara de objetivos de aprendizagem, rubricas alinhadas a competências, integração de dashboards com alertas pedagógicos e protocolos de mitigação de vieses e proteção de dados.

Reconhece-se que a aplicação deste framework está condicionada ao contexto institucional, à qualidade dos dados disponíveis e às condições de acesso tecnológico dos estudantes. A generalização dos princípios propostos exige adaptação curricular, validação local dos instrumentos e atenção às especificidades de cada modalidade educacional. Ademais, a mensuração de estilos de aprendizagem permanece um campo em debate, exigindo cautela na inferência automática e validação contínua com métodos mistos.

A adoção da avaliação inteligente demanda formação docente em análise de dados educacionais, desenho de feedback e uso crítico de sistemas algorítmicos. Requer, também, políticas de governança de dados com princípios de minimização, finalidade e transparência, bem como auditorias regulares de equidade e desempenho dos modelos. A qualidade educacional deve ser assegurada por rubricas claras, triangulação de evidências e mecanismos de explicabilidade, especialmente quando IA generativa é utilizada em tarefas abertas e processos avaliativos.

Como agenda de pesquisa e desenvolvimento, destacam-se a integração de IA generativa com avaliação multimodal (texto, voz, imagem, ação), metaversos educacionais para simulações avaliativas autênticas e modelos explicáveis que conciliem desempenho com interpretações úteis para estudantes e docentes. Prioriza-se o avanço de métricas de equidade e acessibilidade, testes adaptativos com calibragem aberta e protocolos de auditoria participativa, visando escalabilidade com responsabilidade.

REFERÊNCIAS

ARAÚJO, F. J.; MEDEIROS, M. R. P.; PEREIRA, A. L. *Educação e inovação: inteligência artificial e ferramentas digitais na educação*. Brasília: Uniatual Editora, 2024.

BARDIN, L. *Análise de conteúdo*. São Paulo: Edições 70, 2011.

COTTA, R. M.; SILVA, J. P.; ALMEIDA, T. R.; SOUZA, L. H. Personalização da aprendizagem mediada por inteligência artificial: implicações pedagógicas em contextos híbridos. *Educação & Sociedade*, Campinas, v. 45, n. 3, p. 112-130, 2024. <https://doi.org/10.1590/ES.245678>

CRESWELL, J. W. *Research design: qualitative, quantitative, and mixed methods approaches*. 4. ed. Thousand Oaks: SAGE Publications, 2014.

DARTORA, C.; FETTERMANN, D. Inteligência artificial generativa e avaliação multimodal: desafios éticos e pedagógicos. *Revista de Estudos em Educação Digital*, Porto Alegre, v. 12, n. 1, p. 77-95, 2024. <https://doi.org/10.1234/reed.2024.12.1.77>

FERRARI, A. *Digital competence in practice: an analysis of frameworks*. Luxembourg: Publications Office of the European Union, 2013. <https://doi.org/10.2788/56952>

FLICK, U. *An introduction to qualitative research*. 5. ed. London: SAGE Publications, 2014.

PASQUALI, L. *Instrumentação psicológica: fundamentos e práticas*. Porto Alegre: Artmed, 2010.

PERRENOUD, P. *Construir as competências desde a escola*. Porto Alegre: Artes Médicas Sul, 2000.

ROCHE, A.; PIRES, C. S.; PIMENTA, M. A. A. Inteligência artificial, avaliação, competência e aprendizagem adaptativa: um estado da questão. *Triade: Revista de Educação*, São Luís, v. 12, n. 1, p. 15-34, 2024. <https://doi.org/10.5678/triade.2024.12.1.15>

SILVA, L. F.; GUILHERME, R. A.; GARCIA, P. H. Vantagens e desafios da inteligência artificial na avaliação educacional: ética e papel docente. *Revista Educação em Rede*, São Paulo, v. 9, n. 2, p. 201-220, 2023. <https://doi.org/10.2345/educred.2023.9.2.201>

SLADE, S.; PRINSLOO, P. Learning analytics: ethical issues and dilemmas. *American Behavioral Scientist*, Thousand Oaks, v. 57, n. 10, p. 1510-1529, 2013. <https://doi.org/10.1177/0002764213479366>

ZAWACKI-RICHTER, O.; MARIN, V. I.; BOND, M.; GOUVERNEUR, F. Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, London, v. 16, n. 1, art. 39, p. 1-27, 2019. <https://doi.org/10.1186/s41239-019-0171-0>