

**TECNOLOGIAS
EDUCACIONAIS: ANÁLISE
DOS DADOS
EDUCACIONAIS (LEARNING
ANALYTICS) PARA
ACOMPANHAMENTO DA
APRENDIZAGEM**

**EDUCATIONAL TECHNOLOGIES: ANALYSIS OF EDUCATIONAL DATA
(LEARNING ANALYTICS) FOR MONITORING LEARNING**

Ciências Humanas, Ciências Sociais Aplicadas • 15/08/2026

REGISTRO DOI: [10.70773/revistatopicos/786808026](https://doi.org/10.70773/revistatopicos/786808026)

Tatiana Maria de Souza
Allan Willian Lustosa Teles
Camila Peres de Oliveira
Fabrício Fini Michelis
Ivoney da Silva Oliveira
Jeferson Borges de Moura
Rafaelina Maria Ferraz

RESUMO

A expansão das tecnologias educacionais e dos ambientes digitais de aprendizagem ampliou a quantidade de dados produzidos durante as atividades acadêmicas, tornando possível acompanhar trajetórias, padrões de participação, desempenho, dificuldades e riscos de evasão de forma mais sistemática. Nesse contexto, o Learning Analytics destaca-se como campo voltado à coleta, organização, análise e interpretação de dados educacionais para apoiar decisões pedagógicas e institucionais. Este estudo tem como objetivo discutir as contribuições do Learning Analytics para o acompanhamento da aprendizagem, considerando possibilidades de avaliação formativa, identificação precoce de dificuldades, personalização de intervenções e apoio ao planejamento docente. A pesquisa caracteriza-se como bibliográfica e qualitativa, fundamentada em produções brasileiras recentes, publicadas entre 2021 e 2026, com DOI verificável. A análise evidencia que o uso pedagógico dos dados pode favorecer intervenções mais oportunas, ampliar a compreensão sobre o percurso dos estudantes e subsidiar ações de permanência e sucesso acadêmico. Entretanto, a efetividade dessas práticas depende de maturidade institucional, formação docente, qualidade dos dados, transparência dos modelos analíticos e proteção da privacidade. Conclui-se que o Learning Analytics possui maior valor educacional quando os indicadores são interpretados de maneira contextualizada e convertidos em ações pedagógicas, evitando que a aprendizagem seja reduzida a métricas isoladas.

Palavras-chave: Learning Analytics; dados educacionais; tecnologias educacionais; acompanhamento da aprendizagem; avaliação formativa.

ABSTRACT

The expansion of educational technologies and digital learning environments has increased the amount of data generated during academic activities, making it possible to monitor trajectories, participation patterns, performance, difficulties, and dropout risks more systematically. In this context, Learning Analytics stands out as a field focused on collecting, organizing, analyzing, and interpreting educational data to support pedagogical and institutional decision-making. This study aims to discuss the contributions of Learning Analytics to learning monitoring, considering possibilities for formative assessment, early identification of difficulties, personalization of interventions, and support for teaching planning. The research is bibliographic and qualitative, grounded in recent Brazilian studies published between 2021 and 2026 with verifiable DOIs. The analysis indicates that the pedagogical use of data can support more timely interventions, broaden understanding of students' learning paths, and inform actions for academic persistence and success. However, the effectiveness of these practices depends on institutional maturity, teacher education, data quality, model transparency, and privacy protection. It is concluded that Learning Analytics has greater educational value when indicators are interpreted contextually and converted into pedagogical actions, preventing learning from being reduced to isolated metrics.

Keywords: Learning Analytics; educational data; educational technologies; learning monitoring; formative assessment.

1. INTRODUÇÃO

As transformações promovidas pelas tecnologias digitais têm repercutido diretamente na organização do ensino, nas formas de

acesso ao conhecimento e nas relações estabelecidas entre professores, estudantes e conteúdos. A inserção de plataformas educacionais, ambientes virtuais de aprendizagem, recursos multimídia, sistemas digitais de avaliação e ferramentas de inteligência artificial tem ampliado as possibilidades pedagógicas, mas também tem exigido dos docentes novas competências para atuar de maneira consciente e adequada nesse cenário. Desse modo, não basta conhecer ou saber operar diferentes recursos tecnológicos, sendo necessário compreender suas possibilidades pedagógicas, seus limites e sua adequação aos diferentes contextos de aprendizagem.

Nessa perspectiva, Silva e Minuzi (2025) assinalam que a competência digital docente constitui uma construção mais complexa do que o simples domínio de ferramentas, pois envolve a articulação entre conhecimentos tecnológicos, escolhas pedagógicas e consciência acerca dos efeitos sociais decorrentes do uso das tecnologias. Assim, a formação continuada precisa superar propostas centradas exclusivamente na aprendizagem operacional de aplicativos e avançar para experiências formativas que auxiliem o professor a selecionar, adaptar e avaliar tecnologias de acordo com os objetivos curriculares, as características dos estudantes e as condições concretas de ensino.

Cardoso et al. (2022) identificam que o campo de Learning Analytics vem ampliando suas aplicações em ambientes de aprendizagem online, articulando processos de medição, coleta, análise e comunicação de dados sobre estudantes e seus contextos. Essa perspectiva desloca o foco do simples armazenamento de informações para a construção de evidências que possam orientar professores, estudantes e gestores. Assim, o acompanhamento da

aprendizagem passa a incorporar indicadores que ajudam a perceber tendências e dificuldades que nem sempre se tornam visíveis apenas pela observação cotidiana ou pelas avaliações pontuais.

A utilização de dados educacionais pode contribuir para uma compreensão mais contínua da aprendizagem, pois permite reunir evidências produzidas em diferentes momentos e atividades. A adoção institucional dessas práticas, conforme Scheneider et al. (2023), ainda apresenta níveis distintos de maturidade nas instituições brasileiras, o que demonstra que o potencial analítico depende de infraestrutura, governança, integração entre setores e clareza sobre as finalidades pedagógicas. Portanto, não basta possuir plataformas capazes de gerar relatórios; é necessário construir processos que convertam informações em intervenções educacionais coerentes.

O uso de tecnologias analíticas também exige cuidado para que a aprendizagem não seja reduzida a números, rankings ou classificações automatizadas. Dados educacionais representam apenas parte de uma realidade que envolve aspectos cognitivos, sociais, emocionais e contextuais, razão pela qual a leitura dos indicadores precisa permanecer vinculada ao julgamento pedagógico e à participação dos sujeitos envolvidos. A discussão ética torna-se especialmente importante quando os sistemas coletam grandes volumes de informações pessoais, produzem perfis ou orientam decisões que podem afetar a trajetória acadêmica dos estudantes (Menezes et al., 2023).

Coelho et al. (2023) demonstram, em experiências brasileiras de Learning Analytics aplicadas a cursos introdutórios de programação,

que os dados podem ser empregados para prever desempenho, analisar a dificuldade de atividades e apoiar estratégias de ensino. Embora essas aplicações estejam ligadas a um contexto específico, elas evidenciam uma característica central do campo: o valor dos dados está na possibilidade de compreender padrões e agir antes que dificuldades se consolidem. Diante disso, este estudo tem como objetivo discutir as contribuições do Learning Analytics para o acompanhamento da aprendizagem, enfatizando seus usos pedagógicos, possibilidades de intervenção, desafios institucionais e implicações éticas.

2. METODOLOGIA

A pesquisa caracteriza-se como bibliográfica, de abordagem qualitativa e natureza analítico-discursiva. O levantamento priorizou produções brasileiras recentes relacionadas a Learning Analytics, mineração de dados educacionais, acompanhamento do desempenho e evasão, adoção institucional e ética no uso de dados. A opção por reunir estudos com diferentes aplicações permite observar o campo não apenas como solução tecnológica, mas como prática educacional que articula coleta de dados, interpretação e tomada de decisão, movimento também presente no mapeamento sistemático realizado por Cardoso et al. (2022).

Foram considerados estudos publicados entre 2021 e 2026, com autoria vinculada a instituições brasileiras, selecionados pela relação direta com o tema. Entre os trabalhos analisados estão pesquisas sobre maturidade institucional, modelos preditivos, experiências em ambientes de programação, evasão na educação a distância, ética e uso de dados para acompanhamento educacional. Essa delimitação busca privilegiar contribuições recentes e contextualizadas na

realidade nacional, na qual a implementação de Learning Analytics ainda ocorre de maneira heterogênea entre instituições e projetos (Scheneider et al., 2023).

A análise foi organizada em eixos temáticos: fundamentos e usos do Learning Analytics; coleta e interpretação de dados educacionais; acompanhamento e avaliação formativa; predição de dificuldades e evasão; visualização e apoio à decisão; maturidade institucional; e ética, privacidade e equidade. A organização por eixos favorece a comparação entre diferentes aplicações e permite relacionar recursos analíticos a finalidades pedagógicas, evitando que a discussão se limite às técnicas computacionais empregadas nos estudos, preocupação coerente com a abordagem de integração entre análise de dados e intervenção educacional descrita por Andrade et al. (2023a).

3. LEARNING ANALYTICS E A TRANSFORMAÇÃO DE DADOS EM EVIDÊNCIAS PEDAGÓGICAS

Costa et al. (2026) apresentam o Learning Analytics como campo interdisciplinar que aproxima educação, ciência de dados e análise de processos de aprendizagem. Essa articulação é relevante porque as informações produzidas por plataformas digitais não possuem significado pedagógico automático. Um número elevado de acessos, por exemplo, pode indicar engajamento, dificuldade ou apenas repetição de tentativas; da mesma forma, pouco tempo em uma atividade pode representar domínio do conteúdo ou abandono precoce. A interpretação educacional exige, portanto, relacionar indicadores às características das tarefas, aos objetivos de aprendizagem e às condições dos estudantes.

O avanço do campo também está relacionado à diversidade de dados disponíveis em ambientes online. Registros de navegação, entregas de atividades, resultados de avaliações, interações em fóruns, tentativas de resolução e padrões de uso de ferramentas podem ser combinados para formar uma visão mais ampla do percurso acadêmico. No mapeamento de Cardoso et al. (2022), observa-se que as aplicações de Learning Analytics se distribuem por diferentes problemas educacionais, demonstrando que a análise pode assumir caráter descritivo, diagnóstico ou preditivo, conforme a finalidade definida pelo projeto.

A qualidade das evidências produzidas depende diretamente da qualidade dos dados e das perguntas que orientam a análise. Informações incompletas, registros descontextualizados ou indicadores escolhidos apenas por facilidade técnica podem conduzir a interpretações frágeis. Nesse sentido, Scheneider et al. (2023) mostram que a adoção de Learning Analytics exige maturidade organizacional e articulação entre dimensões técnicas, administrativas e educacionais, pois a institucionalização do uso de dados pressupõe processos estáveis de coleta, tratamento, acesso e aplicação das informações.

O potencial pedagógico aparece quando os dados deixam de funcionar apenas como registros retrospectivos e passam a apoiar decisões sobre o que fazer a seguir. Em cursos de programação, por exemplo, Coelho et al. (2023) evidenciam aplicações que permitem identificar dificuldades de desempenho e características das atividades, oferecendo subsídios para ajustes na organização do ensino. Essa lógica pode ser estendida a outros contextos, desde que os indicadores sejam escolhidos de acordo com as competências e aprendizagens que se deseja acompanhar.

3.1. Acompanhamento Contínuo e Avaliação Formativa

O acompanhamento da aprendizagem por meio de dados educacionais amplia a possibilidade de avaliação contínua, pois permite observar tendências ao longo do processo, e não apenas resultados finais. Lima et al. (2021) demonstram que atributos extraídos automaticamente de atividades de programação podem auxiliar na classificação da dificuldade de questões, oferecendo um exemplo de como registros de desempenho podem produzir informações úteis para o planejamento avaliativo. Em termos pedagógicos, isso significa que a análise pode apoiar a construção de tarefas mais equilibradas e adequadas ao nível de complexidade esperado.

A avaliação formativa depende da capacidade de utilizar evidências para orientar intervenções enquanto a aprendizagem ainda está em curso. Nesse sentido, os indicadores gerados pelas plataformas podem sinalizar redução de participação, repetição de erros, atrasos ou alterações no padrão de desempenho. O valor dessas informações, conforme discutido por Costa et al. (2026), está em sua associação com decisões pedagógicas que ajudem a personalizar o apoio, oferecer devolutivas e reorganizar estratégias didáticas, em vez de utilizar os dados apenas para classificar estudantes.

Cardoso et al. (2022) destacam a variedade de métodos e objetivos presentes nas pesquisas sobre Learning Analytics em ambientes online, o que reforça a necessidade de definir previamente quais perguntas pedagógicas serão respondidas. Um painel que apresenta dezenas de indicadores pode ser menos útil do que um conjunto reduzido de informações diretamente relacionado às metas de aprendizagem. Para o professor, a seleção de indicadores

relevantes reduz a sobrecarga informacional e favorece intervenções mais claras; para o estudante, pode contribuir para a compreensão do próprio progresso.

A interpretação dos dados também pode fortalecer processos de autorregulação quando o estudante recebe informações compreensíveis sobre seu percurso. A experiência descrita por Coelho et al. (2023) evidencia que dados de desempenho podem ser analisados em relação a tarefas, dificuldade e evolução ao longo das atividades. Quando devolvidos de maneira pedagógica, esses dados podem apoiar a identificação de pontos fortes, conteúdos que exigem retomada e estratégias de estudo que precisam ser revistas.

3.2. Predição de Dificuldades, Evasão e Intervenções Precoces

Oliveira et al. (2022) investigaram a seleção de atributos para classificadores de evasão a partir de dados da Plataforma Nilo Peçanha e demonstraram a possibilidade de utilizar técnicas preditivas para identificar estudantes com risco de abandono. A relevância educacional desse tipo de abordagem não está em rotular previamente o aluno, mas em criar condições para que equipes pedagógicas reconheçam sinais de vulnerabilidade e possam oferecer apoio antes da ruptura do vínculo acadêmico.

A mineração de dados educacionais também tem sido empregada para analisar fatores relacionados à evasão em instituições brasileiras. Salaberri et al. (2024) testaram diferentes algoritmos em dados de uma universidade pública do Sul do Brasil e encontraram desempenho promissor do Random Forest na identificação de estudantes em risco. Esse tipo de resultado evidencia que modelos preditivos podem contribuir para a gestão da permanência, mas sua

utilização precisa ser acompanhada de critérios de interpretação e mecanismos de intervenção humana.

Andrade et al. (2023a) relacionam Learning Analytics, mineração de dados educacionais e metodologias ativas à discussão sobre mitigação da evasão em educação a distância. A combinação entre identificação de risco e estratégias pedagógicas é especialmente relevante porque a previsão, isoladamente, não modifica a trajetória do estudante. O processo torna-se educacionalmente significativo quando a informação desencadeia ações como acompanhamento individual, reorganização de atividades, contato pedagógico, oferta de recursos de apoio ou adaptação de estratégias de ensino.

A avaliação de um sistema de recomendação voltado a estudantes identificados como propensos à evasão mostra outra possibilidade de fechamento do ciclo analítico. No estudo de Andrade et al. (2023b), o uso de técnicas de mineração de dados foi integrado a estratégias pedagógicas e a um protótipo de recomendação, evidenciando a importância de conectar diagnóstico e ação. Esse modelo de funcionamento ajuda a superar uma limitação frequente dos sistemas analíticos: produzir alertas sem definir quais respostas educativas podem ser desencadeadas a partir deles.

3.3. Visualização de Dados e Apoio à Tomada de Decisão Docente

Os dados educacionais tornam-se mais úteis quando podem ser visualizados de maneira inteligível e vinculada a perguntas concretas do processo de ensino. Coelho et al. (2023) reúnem experiências em que informações de desempenho e características de exercícios foram analisadas para apoiar decisões em disciplinas introdutórias de programação. Essa abordagem mostra que a

visualização não deve ser tratada como recurso meramente estético; sua função é reduzir a complexidade dos registros e tornar padrões relevantes perceptíveis aos usuários.

Painéis e relatórios de acompanhamento precisam evitar a apresentação excessiva de métricas que não resultem em ações pedagógicas. A literatura mapeada por Cardoso et al. (2022) demonstra que Learning Analytics envolve diferentes formas de análise e comunicação dos dados, o que exige considerar quem utilizará a informação e com qual finalidade. Para professores, podem ser prioritários indicadores de progresso, participação e dificuldade; para gestores, dados agregados de permanência e desempenho; para estudantes, informações claras sobre evolução e próximos passos.

A tomada de decisão baseada em dados não substitui a experiência docente, mas pode ampliar sua capacidade diagnóstica. Ao interpretar indicadores, o professor precisa considerar características da turma, condições de acesso, natureza das atividades e elementos que não aparecem nos registros digitais. Scheneider et al. (2023) ressaltam que o avanço institucional de Learning Analytics depende da participação de diferentes atores, aspecto que reforça a necessidade de aproximar equipes técnicas, gestores e docentes na definição de indicadores, visualizações e formas de uso.

O acompanhamento por dados também pode favorecer revisões no desenho das atividades. Lima et al. (2021) mostram que características das soluções podem ser utilizadas para estimar a dificuldade de questões de programação, informação que pode auxiliar na composição de avaliações e sequências de exercícios. Em outros campos, raciocínio semelhante pode ser aplicado à

identificação de tarefas com alta taxa de erro, conteúdos que geram abandono ou atividades cuja complexidade não corresponde aos objetivos previstos.

3.4. Maturidade Institucional e Formação para o Uso Pedagógico dos Dados

Schneider et al. (2023) identificam que a adoção de Learning Analytics em instituições brasileiras de ensino superior ocorre com diferentes níveis de maturidade, revelando que iniciativas isoladas não são suficientes para consolidar uma cultura de decisão baseada em evidências. Para que os dados sejam utilizados de forma contínua, as instituições precisam estabelecer responsabilidades, integrar sistemas, definir objetivos, assegurar recursos e criar condições para que professores e gestores compreendam o significado dos indicadores produzidos.

A formação docente é componente essencial desse processo porque a interpretação pedagógica não pode ser delegada integralmente aos sistemas computacionais. Costa et al. (2026) ressaltam que o Learning Analytics precisa permanecer conectado às teorias de aprendizagem e à mediação educacional, evitando que a sofisticação técnica se torne um fim em si mesma. Isso implica desenvolver competências para ler visualizações, questionar padrões, reconhecer limitações dos modelos e transformar informações em estratégias didáticas adequadas aos estudantes.

A implementação institucional também requer definição clara dos problemas que se pretende enfrentar. Coelho et al. (2023) mostram que projetos de Learning Analytics podem ser construídos a partir de desafios específicos, como reprovação, previsão de desempenho

e dificuldade das atividades. Esse princípio é importante para outras instituições: antes de selecionar ferramentas ou algoritmos, é necessário identificar quais decisões precisam ser qualificadas e quais dados são realmente pertinentes para apoiar essas decisões.

A consolidação de uma cultura analítica depende ainda da avaliação dos próprios projetos. Se indicadores são utilizados para recomendar intervenções, é necessário verificar se essas intervenções produziram melhoria na participação, no desempenho ou na permanência. A proposta analisada por Andrade et al. (2023b) ilustra a importância de avaliar funcionalidade e aceitação de soluções que combinam mineração de dados e recomendação pedagógica, indicando que a qualidade de um sistema deve ser julgada também por sua utilidade no processo de ensino e aprendizagem.

3.5. Ética, Privacidade, Transparência e Equidade

Menezes et al. (2023) destacam que o uso de Learning Analytics precisa ser orientado por princípios éticos capazes de proteger os sujeitos e garantir rigor científico. A coleta de dados educacionais envolve informações que podem revelar desempenho, comportamento, frequência, dificuldades e trajetórias pessoais, de modo que sua utilização exige finalidade definida, proporcionalidade e cuidado no acesso. A existência de capacidade técnica para coletar determinado dado não significa, por si só, que sua coleta seja pedagogicamente necessária ou eticamente justificável.

A transparência deve abranger tanto a coleta quanto a interpretação dos dados. Estudantes e professores precisam compreender quais informações são registradas, por que são analisadas e como podem

influenciar decisões. Conforme Menezes et al. (2023), a discussão brasileira sobre ética em Learning Analytics se relaciona à proteção de dados e às particularidades das pesquisas em Ciências Humanas e Sociais, reforçando a necessidade de procedimentos que respeitem privacidade, autonomia e segurança informacional.

Modelos preditivos também podem produzir riscos quando suas classificações são tratadas como verdades definitivas. Salaberri et al. (2024) mostram que algoritmos podem alcançar resultados relevantes na identificação de risco de evasão, mas a previsão deve ser entendida como apoio à decisão, e não como sentença sobre o futuro acadêmico do estudante. Falsos positivos, dados históricos enviesados e mudanças de contexto podem alterar o significado das estimativas, tornando indispensável a supervisão humana.

A equidade exige atenção às condições desiguais de acesso e participação nos ambientes digitais. Indicadores de baixa atividade podem refletir dificuldades de aprendizagem, mas também problemas de conectividade, responsabilidades familiares, limitações de equipamento ou outras condições externas ao conteúdo escolar. A perspectiva de maturidade institucional discutida por Scheneider et al. (2023) sugere que projetos de Learning Analytics precisam considerar dimensões organizacionais mais amplas, de modo que as interpretações não culpabilizem estudantes por padrões que podem estar associados às condições institucionais e sociais.

4. DISCUSSÃO: POTENCIALIDADES E LIMITES PARA O ACOMPANHAMENTO DA APRENDIZAGEM

O conjunto das pesquisas brasileiras analisadas indica que Learning Analytics possui potencial para ampliar a capacidade de observação dos processos de aprendizagem, sobretudo em ambientes nos quais grande parte das atividades deixa registros digitais. Cardoso et al. (2022) mostram a diversidade de aplicações do campo em ambientes online, permitindo compreender que a contribuição analítica não se restringe a prever notas ou evasão. Ela também pode apoiar diagnóstico, avaliação, personalização, organização de atividades e reflexão sobre o próprio desenho pedagógico.

A principal mudança de perspectiva está na passagem de uma avaliação episódica para um acompanhamento mais contínuo. Os estudos de Coelho et al. (2023) evidenciam que dados produzidos durante as atividades podem revelar padrões úteis para prever desempenho e compreender a dificuldade das tarefas. Isso permite que o professor identifique problemas durante o percurso, em vez de reconhecer dificuldades apenas ao final de uma unidade ou período letivo, quando algumas possibilidades de intervenção já foram perdidas.

Ao mesmo tempo, os trabalhos sobre evasão demonstram que a existência de um modelo preditivo não garante, por si só, melhoria da aprendizagem ou permanência. Andrade et al. (2023a) reforçam a necessidade de combinar técnicas analíticas com estratégias pedagógicas, indicando que a intervenção constitui etapa indispensável do processo. A análise de dados precisa, portanto, ser compreendida como parte de um ciclo que envolve identificar, interpretar, agir, acompanhar os efeitos e revisar as decisões adotadas.

A adoção sustentável de Learning Analytics depende de uma cultura institucional que reconheça limites técnicos e pedagógicos. Scheneider et al. (2023) mostram que o nível de maturidade das instituições interfere diretamente na capacidade de ampliar projetos e integrá-los aos diferentes setores. Sem governança, formação e objetivos compartilhados, os sistemas correm o risco de produzir relatórios pouco utilizados; com estrutura adequada, os dados podem funcionar como linguagem comum para apoiar decisões, identificar necessidades e orientar políticas de acompanhamento.

A dimensão ética atravessa todas as demais e não pode ser adicionada apenas ao final dos projetos. Menezes et al. (2023) defendem a necessidade de articular rigor científico e responsabilidade no tratamento dos dados, o que implica discutir privacidade, transparência e proteção dos participantes desde o planejamento. Para o acompanhamento da aprendizagem, isso significa utilizar apenas informações pertinentes, limitar acessos, comunicar finalidades e evitar práticas de vigilância que possam transformar ambientes educativos em espaços de controle excessivo.

5. CONSIDERAÇÕES FINAIS

O Learning Analytics amplia as possibilidades de acompanhamento da aprendizagem ao permitir que dados produzidos em ambientes digitais sejam organizados e interpretados como evidências do percurso dos estudantes. Seu potencial está especialmente relacionado à identificação de padrões de participação, dificuldades recorrentes, alterações de desempenho e situações que demandam intervenção pedagógica. A análise contínua pode complementar avaliações tradicionais e oferecer ao professor uma visão mais

detalhada sobre processos que se desenvolvem entre uma atividade e outra.

Entretanto, dados não constituem decisões prontas. Indicadores precisam ser interpretados à luz dos objetivos educacionais, das características das atividades, das condições de acesso e das particularidades dos estudantes. O uso pedagógico responsável exige que professores e equipes institucionais mantenham participação ativa na leitura dos resultados e na definição das ações decorrentes das análises. Dessa forma, a tecnologia atua como apoio à mediação, e não como substituta do julgamento profissional.

As aplicações relacionadas à previsão de desempenho e evasão demonstram que intervenções precoces podem ser favorecidas quando sinais de dificuldade são identificados antes do afastamento ou do fracasso acadêmico. Contudo, a efetividade desse processo depende da existência de estratégias concretas de apoio. Alertas, classificações e probabilidades precisam resultar em diálogo, orientação, feedback, revisão de atividades, oferta de recursos e outras medidas que respondam às necessidades detectadas.

Conclui-se que as tecnologias educacionais baseadas em Learning Analytics podem contribuir significativamente para o acompanhamento da aprendizagem quando integram qualidade dos dados, intencionalidade pedagógica, formação docente, maturidade institucional e princípios éticos. O desafio não consiste apenas em produzir análises mais sofisticadas, mas em construir usos educacionais capazes de transformar informações em decisões compreensíveis, justas e orientadas à aprendizagem.

REFERÊNCIAS BIBLIOGRÁFICAS

Andrade, T. L. de, Almeida, C. M. M. de, Barbosa, J. L. V., & Rigo, S. J. (2023a). A utilização de metodologias ativas com suporte de mineração de dados educacionais e Learning Analytics para a mitigação da evasão em EaD: um mapeamento sistemático da literatura. *Revista Brasileira de Informática na Educação*, 31, 1057–1088. <https://doi.org/10.5753/rbie.2023.3594>

Andrade, T. L. de, Almeida, C. M. M. de, Barbosa, J. L. V., & Rigo, S. J. (2023b). Avaliação de um modelo de sistema de recomendação que integra metodologias ativas e mineração de dados educacionais para mitigar a evasão na Educação a Distância. In *Anais do XXXIV Simpósio Brasileiro de Informática na Educação* (pp. 187–198). Sociedade Brasileira de Computação. <https://doi.org/10.5753/sbie.2023.234754>

Cardoso, M. M. R., Lima, J. V. F. S., Oliveira, M. H. V. de, & Paiva, R. O. A. (2022). O uso de Learning Analytics em ambientes de aprendizagem online: um mapeamento sistemático da literatura. *Revista Brasileira de Informática na Educação*, 30, 396–418. <https://doi.org/10.5753/rbie.2022.2664>

Coelho, F. J. M., Oliveira, E. H. T., Pereira, F. D., Oliveira, D. B. F., Carvalho, L. S. G., Souto, E. J. P., Pessoa, M., Melo, R., Lima, M. A. P. de, & Nakamura, F. G. (2023). Learning Analytics em cursos de introdução à programação: uma mostra da Universidade Federal do Amazonas. *Revista Brasileira de Informática na Educação*, 31, 1089–1127. <https://doi.org/10.5753/rbie.2023.3334>

Costa, L. C., Rodrigues, S. F. N., Paixão, J. L. da, Batista, R. V., Moraes, E. C., & Silva, E. N. (2026). Learning Analytics na educação contemporânea: fundamentos, aplicações e desafios

epistemológicos e éticos. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, 12(3), 1–14.
<https://doi.org/10.51891/rease.v12i3.24875>

Lima, M. A. P. de, Carvalho, L. S. G., Oliveira, E. H. T., Oliveira, D. B. F., & Pereira, F. D. (2021). Uso de atributos de código para classificar a dificuldade de questões de programação em juízes online. *Revista Brasileira de Informática na Educação*, 29, 1137–1157.
<https://doi.org/10.5753/RBIE.2021.29.0.1137>

Menezes, J. B. F. de, Almeida, A. C. A. de, Lima, M. V. de A., & Sousa, T. M. (2023). Ética e Learning Analytics: uma combinação necessária para o rigor científico. *Práxis Educativa*, 18, 1–11.
<https://doi.org/10.5212/PraxEduc.v18.21370.016>

Oliveira, I. S., Medeiros, F. P. A., & Andrade, F. G. (2022). Seleção de atributos para classificadores de evasão escolar com dados da Plataforma Nilo Peçanha. In *Anais do I Workshop de Aplicações Práticas de Learning Analytics em Instituições de Ensino no Brasil* (pp. 30–39). Sociedade Brasileira de Computação.
<https://doi.org/10.5753/wapla.2022.226769>

Salaberri, P., Piovesan, S., & Irala, V. (2024). Mineração de dados educacionais para a predição de evasão: experiência em uma universidade do Sul do Brasil. *Administração: Ensino e Pesquisa*, 25(1). <https://doi.org/10.13058/raep.2024.v25n1.2415>

Scheneider, T. F., Cechinel, C., Mello, R. F. L. de, Freitas, E. L. S. X., Falcão, T. P. da R., & Ramos, V. F. C. (2023). Análise do nível de maturidade na adoção de Learning Analytics em instituições de ensino superior do Sul e Sudeste brasileiro. *Revista Brasileira de*

Informática na Educação, 31, 1005–1030.
<https://doi.org/10.5753/rbie.2023.3058>