

MINERAÇÃO DE DADOS EDUCACIONAIS E INTELIGÊNCIA ARTIFICIAL APLICADAS À ADAPTAÇÃO CURRICULAR EM CONTEXTOS INCLUSIVOS

EDUCATIONAL DATA MINING AND ARTIFICIAL INTELLIGENCE APPLIED TO
CURRICULUM ADAPTATION IN INCLUSIVE CONTEXTS

Ciências Humanas, Ciências Sociais Aplicadas • 19/04/2026

REGISTRO DOI: [10.70773/revistatopicos/776517243](https://doi.org/10.70773/revistatopicos/776517243)

Thalita Oliveira Da Silva¹

Jean Mark Lobo de Oliveira²

Carlos Alberto Farias Jennings³

RESUMO

A adaptação de avaliações para estudantes neurodivergentes é exigência pedagógica e legal nas escolas brasileiras, mas permanece dependente de processos manuais que sobrecarregam docentes e geram inconsistência metodológica. O presente artigo descreve o desenvolvimento e a avaliação exploratória do sistema PinGO, uma arquitetura computacional que articula Mineração de Dados Educacionais (EDM), regras adaptativas determinísticas e princípios da Experiência de Aprendizagem Mediada (EAM) de Feuerstein para automatizar, de forma supervisionada, a adaptação de instrumentos avaliativos. A pesquisa adota o paradigma da *Design Science Research* (DSR), combinada a estudo de caso quali-quantitativo conduzido no Colégio Connexus (Manaus-AM) com turmas do Ensino Fundamental II durante o ano letivo de 2026. A amostra exploratória envolveu dois docentes e dois estudantes com Plano Educacional Individualizado (PEI). Os resultados indicam redução de aproximadamente 75% no tempo médio de adaptação (de mais de 120 minutos no processo manual para cerca de 30 minutos com o sistema), melhora parcial nos indicadores de resistência comportamental e percepção docente favorável quanto à consistência e à economia de tempo. Os achados sugerem que a integração entre mineração de dados e mediação pedagógica estruturada pode contribuir para a ampliação da equidade avaliativa em ambientes inclusivos.

Palavras-chave: mineração de dados educacionais; aprendizagem adaptativa; educação inclusiva; inteligência artificial; design science research.

ABSTRACT

The adaptation of assessments for neurodivergent students is a pedagogical and legal requirement in Brazilian schools, yet it

remains dependent on manual processes that overburden teachers and produce methodological inconsistency. This paper describes the development and exploratory evaluation of the PinGO system, a computational architecture that combines Educational Data Mining (EDM), deterministic adaptive rules, and Feuerstein's Mediated Learning Experience (MLE) principles to automate, in a supervised manner, the adaptation of assessment instruments. The research adopts the Design Science Research (DSR) paradigm, combined with a qualitative-quantitative case study conducted at Colégio Connexus (Manaus, Brazil) with lower secondary classes during the 2026 academic year. The exploratory sample comprised two teachers and two students with Individualized Educational Plans (IEPs). Results indicate an approximate 75% reduction in average adaptation time (from over 120 minutes manually to approximately 30 minutes with the system), partial improvement in behavioral resistance indicators, and favorable teacher perception regarding consistency and time savings. The findings suggest that the integration of data mining and structured pedagogical mediation can contribute to enhancing assessment equity in inclusive settings.

Keywords: educational data mining; adaptive learning; inclusive education; artificial intelligence; design science research.

1. INTRODUÇÃO

A educação inclusiva impõe desafios estruturais à organização curricular contemporânea, todos os anos temos visto um aumento enorme de casos de crianças diagnosticadas com os espectros autistas (TEA), demonstrando uma fragilidade no ensino não só na educação básica mais como também na educação de nível superior, exigindo uma melhor adaptação a essa nova realidade dos estudantes. O professor precisa adaptar instrumentos avaliativos

para diferentes perfis cognitivos enfrentando a tarefa de reformular enunciados, modular graus de abstração, reorganizar comandos e inserir apoios visuais, procedimento que se repete para cada estudante com Plano Educacional Individualizado (PEI). O resultado é um aumento considerável do tempo operacional e uma redução do tempo disponível para mediação pedagógica qualitativa.

A Mineração de Dados Educacionais (*Educational Data Mining – EDM*) consolidou-se como campo interdisciplinar voltado à extração de padrões em dados produzidos durante interações pedagógicas (Romero, Ventura, 2020). Revisões recentes indicam, porém, que as aplicações de EDM concentram-se no ensino superior e em métricas quantitativas de desempenho, com lacuna expressiva na educação básica e em contextos inclusivos (Adeniji, Ajayi, 2024). A maioria dos sistemas adaptativos não incorpora fundamentos de mediação cognitiva estruturada, como os propostos pela teoria da Experiência de Aprendizagem Mediada (EAM) de Feuerstein, cujos critérios de intencionalidade, significado e transcendência oferecem parâmetros qualitativos para organização da experiência de aprendizagem (Tzuriel, 2021).

O presente estudo descreve o desenvolvimento e a avaliação exploratória do sistema PinGO, artefato de *Design Science Research* (Hevner et al., 2004, Vom Brocke, Hevner Maedche, 2020) concebido para automatizar, de forma supervisionada, a adaptação de avaliações em contextos inclusivos. O sistema integra dados pedagógicos, psicopedagógicos e comportamentais por meio de regras adaptativas determinísticas fundamentadas nos princípios da EAM. A questão que orienta a investigação indaga se a aplicação de técnicas de EDM, combinadas a parâmetros da EAM, pode fundamentar um sistema interpretável, passível de verificação, capaz

de reduzir a sobrecarga docente e melhorar indicadores de engajamento avaliativo. A pesquisa foi conduzida no Colégio Connexus (Manaus-AM), instituição de educação básica com política ativa de inclusão, durante o período letivo de 2026.

2. REFERENCIAL TEÓRICO

A consolidação do campo de mineração de dados educacionais é representada por iniciativas, como a International Educational Data Mining Society, que enfatizam modelagem preditiva e suporte a decisão pedagógica baseada em evidências. Diretrizes internacionais, como as da UNESCO, defendem a equidade e acesso pleno ao currículo. O Desenho Universal para Aprendizagem (DUA) propõe flexibilidade desde a concepção do material didático, convergindo com a lógica preventiva do sistema desenvolvido.

2.1. Mineração de Dados Educacionais

A EDM é um subcampo da Ciência de Dados direcionado à descoberta de regularidades em conjuntos de dados oriundos de ambientes educacionais. As técnicas empregadas incluem classificação, clusterização, detecção de anomalias e mineração de regras de associação, voltadas à modelagem de processos de aprendizagem em ambientes formais e digitais (Romero, Ventura, 2020). A revisão sistemática de Adeniji e Ajayi (2024), publicada na *Quality Education for All*, analisou 113 artigos do período 2017–2023 e demonstrou que a EDM está fortemente concentrada no ensino superior. A educação básica, que constitui a base do percurso formativo, recebe atenção insuficiente. Os autores argumentam que essa concentração compromete a capacidade do campo de

promover equidade educacional desde as etapas iniciais da escolarização.

A análise bibliométrica de Nikolaidis et al. (2025), que revisou 793 artigos indexados na Scopus entre 2000 e 2024, confirma o crescimento exponencial do campo e identifica tendências emergentes, a ética no uso de dados educacionais, equidade em sistemas automatizados e integração de modelagem preditiva com abordagens pedagógicas inclusivas. O volume de publicações atingiu 107 trabalhos somente em 2024, o que mostra a importância crescente da área, mas também a necessidade de direcionar esforços para contextos que permanecem sub-representados na literatura.

A interpretabilidade dos modelos é requisito ético e pedagógico central quando a EDM é aplicada à educação inclusiva. Arquiteturas puramente preditivas baseadas em redes neurais profundas oferecem alta acurácia, mas funcionam como “caixas-pretas” cujas decisões não podem ser rastreadas nem auditadas pelo docente. O sistema PinGO, por essa razão, privilegia modelos determinísticos baseados em regras explicitáveis, garantindo que cada adaptação gerada possa ser atribuída a parâmetros identificáveis.

2.2. Learning Analytics e Suporte à Decisão Pedagógica

Learning Analytics é campo correlato à EDM que enfatiza a aplicação prática dos dados analisados para suporte à decisão institucional. A definição consolidada na literatura refere-se à medição, coleta, análise e comunicação de dados sobre aprendizes e seus contextos com o objetivo de compreender e otimizar a aprendizagem (Romero, Ventura, 2020). A EDM concentra-se no

desenvolvimento de métodos e modelos. *Learning Analytics* concentra-se na utilização institucional dos resultados por meio de *dashboards*, relatórios e sistemas de monitoramento. A combinação dos dois campos permite estruturar sistemas de alerta precoce, ferramentas de acompanhamento longitudinal e mecanismos de intervenção personalizada.

2.3. Experiência de Aprendizagem Mediada e Modificabilidade Cognitiva Estrutural

A teoria da Modificabilidade Cognitiva Estrutural, formulada por Reuven Feuerstein, sustenta que o ser humano possui capacidade de transformação cognitiva contínua por meio da mediação intencional. O desempenho observado reflete a qualidade das experiências mediadas a que o sujeito foi exposto, e não limites estruturais imutáveis (Tzuriel, 2021). Pesquisas recentes reafirmam a eficácia de intervenções fundamentadas na EAM para populações com atraso no desenvolvimento e necessidades educacionais específicas. O ensaio clínico randomizado de Chua e Wong (2022) demonstrou ganhos cognitivos e linguísticos significativos em pré-escolares com atraso no desenvolvimento submetidos a programa de mediação estruturada.

A EAM organiza-se em três critérios universais. A intencionalidade e reciprocidade referem-se à necessidade de intenção explícita do mediador e de engajamento ativo do aprendiz, a mediação de significado envolve a atribuição de relevância subjetiva ao conteúdo, a mediação de transcendência busca promover generalização para além da tarefa imediata. A tradução computacional desses critérios no sistema PinGO ocorre, respectivamente, pela clareza estrutural dos comandos e organização progressiva de tarefas, pela inserção

contextual de elementos vinculados ao repertório e aos interesses do estudante, e pela progressão de complexidade com variação controlada de contexto. A aproximação entre EAM e tecnologias analíticas educacionais foi também explorada por Scheffel et al. (2022), que propuseram diretrizes para implementação de *Learning Analytics* em larga escala utilizando os critérios de Feuerstein como *framework* de pré-requisitos.

2.4. Educação Inclusiva e Desenho Universal para Aprendizagem

O Desenho Universal para Aprendizagem (DUA), sistematizado pelo CAST (2024), propõe três princípios estruturantes, múltiplos meios de representação, múltiplos meios de ação e expressão, e múltiplos meios de engajamento. O PinGO converge com o DUA ao possibilitar ajuste na forma de apresentação textual, modularização de comandos, inserção contextual significativa e personalização sem segregação curricular. A tecnologia atua como instrumento de aplicação prática do DUA, garantindo flexibilidade sem descaracterizar os objetivos pedagógicos centrais.

A contribuição teórica central deste estudo está na articulação entre EDM, EAM e educação inclusiva. A EDM fornece infraestrutura técnica para extração e modelagem de padrões, a EAM fornece fundamento teórico para qualificação pedagógica da adaptação. Essa integração enfrenta dois riscos comuns na literatura, o reducionismo algorítmico, em que a tecnologia opera sem fundamentação pedagógica, e o subjetivismo não estruturado, em que decisões pedagógicas carecem de sistematização técnica (Alves et al., 2024). O modelo proposto funciona como alternativa híbrida, interpretável, verificável e supervisionada.

3. METODOLOGIA

Esta investigação adota a abordagem *Design Science Research* (DSR), apropriada para pesquisas cujo objetivo central não se limita à descrição ou explicação de fenômenos, mas envolve a proposição, construção e avaliação de um artefato tecnológico destinado a resolução de um problema organizacional concreto. A DSR insere-se no campo das ciências do artificial, distinguindo-se epistemologicamente das abordagens positivistas tradicionais ao assumir caráter interventivo, construtivo e orientado à solução.

O Ciclo de Relevância identifica o problema no contexto organizacional do Colégio Connexus (Manaus-AM), instituição privada com política de inclusão ativa, a sobrecarga docente gerada pela adaptação manual de avaliações para estudantes com PEI, a inconsistência nos critérios adaptativos entre docentes e a inexistência de rastreabilidade institucional. O Ciclo de Rigor ancora a construção do artefato em quatro eixos teóricos: EDM (Romero, Ventura, 2020), EAM (Tzuriel, 2021), DUA (CAST, 2024) e diretrizes de educação inclusiva (Brasil, 2020, UNESCO, 2021). O Ciclo de *Design* compreende a modelagem, implementação, avaliação e refinamento iterativo do sistema.

O artefato foi estruturado em quatro camadas modulares, (a) ingestão de dados, integrando formulários diagnósticos, relatórios pedagógicos e dados administrativos, (b) processamento e regras adaptativas, com extração de atributos, parametrização por perfil cognitivo e regras determinísticas documentáveis, (c) geração de conteúdo adaptado, com reestruturação sintática, fragmentação de comandos, ajuste de densidade semântica e inserção contextual significativa, (d) visualização e monitoramento, com *dashboards* para

coordenação pedagógica e Atendimento Educacional Especializado (AEE). O fluxo operacional segue quatro etapas, inserção da avaliação original, preenchimento de questionário de especificidades do estudante, aplicação automática das regras e geração de versão adaptada para validação docente. A decisão final permanece sob responsabilidade humana. Um diferencial arquitetural do sistema está na construção de histórico longitudinal por estudante, cada adaptação realizada, cada observação docente registrada e cada documento ou laudo atualizado são incorporados à base de dados do aluno. Nas adaptações subsequentes, o sistema consulta automaticamente esse histórico acumulado, que inclui a evolução do perfil cognitivo e as novas informações clínico-pedagógicas, para ajustar os parâmetros adaptativos de forma progressiva. Essa funcionalidade permite que as adaptações acompanhem o desenvolvimento do estudante ao longo do tempo, em vez de operar sobre um perfil estático.

A fase exploratória envolveu dois docentes e dois estudantes com PEI ativo, pertencentes a turmas do Ensino Fundamental II, durante o primeiro ciclo avaliativo de 2026. Os instrumentos de coleta incluíram, (a) registros automáticos de *logs* do sistema, com registro de tempo de cada adaptação, (b) registros observacionais padronizados de comportamento avaliativo (recusa, interrupção, verbalização de frustração, abandono), (c) relato qualitativo dos docentes participantes sobre percepção de utilidade, consistência e economia de tempo, (d) dados administrativos de conclusão avaliativa.

4. RESULTADOS E DISCUSSÕES

A fase exploratória do sistema PinGO foi conduzida em ambiente escolar real durante o primeiro ciclo avaliativo de 2026, com a participação de dois docentes (identificados como D1 e D2) e dois estudantes com PEI ativo (identificados como E1 e E2). Os dados são exploratórios e descritivos, compatível com a fase inicial de avaliação do artefato no ciclo de *Design* da DSR. A amostra reduzida impede generalizações, mas permite identificar tendências e subsidiar o refinamento do sistema para ciclos posteriores.

4.1. Caracterização dos Participantes

O Quadro 1 apresenta a caracterização dos participantes da fase exploratória, sendo D1 e D2 professores docentes do ensino fundamental II, sendo os responsáveis pela disciplina do núcleo comum, neste caso, a matemática, com experiência prévia em adaptação manual de avaliações.

E1 e E2 são os estudantes do ensino fundamental II, neurodivergente com PEI ativo e acompanhados pelo setor de AEE.

Quadro 1: Caracterização dos participantes da fase exploratória

Participante	Função/Perfil	Descrição
D1	Docente	Professor(a) do Ensino Fundamental II, responsável por disciplina do núcleo comum, com experiência prévia em adaptação manual de avaliações
D2	Docente	Professor(a) do Ensino Fundamental II, responsável por disciplina do núcleo comum, com experiência prévia em adaptação manual de avaliações

E1	Estudante com PEI	Estudante neurodivergente do Ensino Fundamental II com PEI ativo e acompanhamento do AEE
E2	Estudante com PEI	Estudante neurodivergente do Ensino Fundamental II com PEI ativo e acompanhamento do AEE

Fonte: dados da pesquisa (2026)

O quadro e a caracterização dos participantes na fase exploratória do teste do sistema.

4.2. Tempo de Adaptação

O indicador primário de utilidade do artefato foi o tempo despendido pelo docente na adaptação de avaliações. O Quadro 2 apresenta a comparação entre o processo manual e o processo mediado pelo PinGO.

Quadro 2: Comparação do tempo de adaptação, processo manual versus sistema PinGO

Indicador	Processo manual	Processo com PinGO
Tempo médio por adaptação	Superior a 120 minutos	Aproximadamente 30 minutos
Redução estimada	N/A	~75%
Etapas automatizadas	Nenhuma	Fragmentação de comandos, simplificação sintática, parametrização de extensão, inserção contextual, adequação visual

Atividade residual do docente	Todas as etapas	Revisão, validação e ajustes pontuais da versão gerada
-------------------------------	-----------------	--

Fonte: registros de logs do sistema e relato dos docentes participantes (2026).

Os dados apontam redução clara no tempo operacional. O processo manual, segundo relato de ambos os docentes, demandava regularmente mais de duas horas por avaliação adaptada, incluindo reformulação de enunciados, reorganização visual e revisão final. O tempo com o PinGO, incluindo a etapa de revisão e ajuste pelo professor, situou-se em torno de 30 minutos, o que representa redução de aproximadamente 75%. A diminuição não se restringiu à reescrita textual, a automatização da fragmentação de comandos, da simplificação sintática e da parametrização de extensão reduziu também o esforço de organização estrutural.

4.3. Taxa de Conclusão e Comportamento Avaliativo

A taxa de conclusão avaliativa foi definida como a proporção de avaliações finalizadas pelo estudante sem abandono impeditivo. O Quadro 3 sintetiza os dados observados.

Quadro 3: Indicadores de conclusão e comportamento avaliativo por estudante

Indicador	E1	E2
Avaliações finalizadas	Maioria das avaliações concluídas sem interrupção impeditiva	Maioria das avaliações concluídas; ocorrência de 1 a 2 episódios de abandono

Resistência comportamental	Redução parcial em relação ao histórico anterior; persistência de episódios pontuais de recusa inicial	Melhora observada, com diminuição de verbalizações de frustração; resistência residual em questões com figuras e cálculos com imagem
Observações qualitativas	Maior engajamento em avaliações com inserção contextual vinculada a interesses do estudante	Resposta positiva à fragmentação de comandos; maior dificuldade em questões com figuras, imagens e cálculos com suporte visual

Fonte: registros observacionais padronizados e dados administrativos de conclusão (2026).

A taxa de conclusão apresentou melhora em relação ao histórico institucional, embora não tenha sido integral: registraram-se de um a dois episódios de abandono durante o período de observação. A resistência comportamental, operacionalizada por indicadores como recusa inicial, interrupções e verbalizações de frustração, apresentou redução parcial. A melhora foi mais evidente em avaliações que utilizaram inserção contextual vinculada aos interesses do estudante e fragmentação de comandos complexos, em consonância com os critérios de intencionalidade e significado da EAM. A resistência residual concentrou-se em avaliações de maior extensão e em questões que envolviam figuras, imagens ou cálculos com suporte visual, cujo tratamento pelo sistema ainda apresenta limitações em processo de aperfeiçoamento.

4.4. Percepção Docente

A percepção dos docentes foi coletada por meio de relato qualitativo ao término do ciclo exploratório. O Quadro 4 sintetiza as categorias

temáticas identificadas nos relatos.

Quadro 4: Categorias temáticas do relato docente sobre o sistema PinGO

Categoria	Síntese dos relatos
Economia de tempo	Ambos os docentes apontaram redução significativa no tempo dedicado à adaptação, destacando que a automatização das etapas de fragmentação, simplificação e adequação visual liberou tempo para atividades de mediação direta
Consistência adaptativa	Os docentes relataram que as adaptações geradas pelo sistema apresentaram maior uniformidade de critérios em comparação ao processo manual, reduzindo a variabilidade entre diferentes avaliações para o mesmo estudante
Preservação da autonomia	Os participantes enfatizaram que o sistema não substituiu seu julgamento profissional, funcionando como ferramenta de organização de decisões que antes dependiam exclusivamente da experiência individual
Sugestões de melhoria	Os docentes apontaram dificuldades pontuais do sistema no tratamento de questões que envolvem figuras, imagens e cálculos com suporte visual. A adaptação textual funciona de forma satisfatória, mas a reorganização de elementos gráficos dentro da avaliação ainda apresenta limitações. Trata-se de aspecto parcial, em processo de aperfeiçoamento no ciclo iterativo de desenvolvimento do artefato

Fonte: relato qualitativo dos docentes participantes (2026).

5. CONSIDERAÇÕES FINAIS

Os indicadores exploratórios obtidos nesta investigação sugerem que a integração entre Mineração de Dados Educacionais,

Engenharia da Computação e princípios da Experiência de Aprendizagem Mediada é tecnicamente viável e pedagogicamente pertinente para a adaptação curricular avaliativa em contextos inclusivos. A redução de aproximadamente 75% no tempo operacional de adaptação, a melhora parcial nos indicadores de conclusão e resistência comportamental e a percepção docente favorável constituem evidências iniciais de que o artefato responde ao problema identificado no Ciclo de Relevância da DSR.

A contribuição do estudo distribui-se em dois planos. Do lado tecnológico, o artefato propõe uma arquitetura modular interpretável e auditável, distanciando-se de modelos opacos. Do lado epistemológico, a inovação consiste na formalização de critérios adaptativos que antes permaneciam implícitos e dependentes da experiência individual do docente, convertendo-os em parâmetros documentáveis e analisáveis. A construção de histórico longitudinal por estudante, com incorporação progressiva de laudos, observações e registros de evolução, faz com que o sistema opere de forma evolutiva, as adaptações não operam sobre um perfil estático, mas acompanham o desenvolvimento do estudante ao longo do tempo.

O caráter exploratório dos resultados é a principal limitação do trabalho. Pesquisas futuras deverão contemplar, (a) ampliação da amostra com inclusão de maior número de docentes e estudantes, (b) aplicação formal de instrumento quantitativo padronizado para mensuração da percepção docente, (c) delineamento quase-experimental com grupo controle, (d) análise de possíveis vieses algorítmicos, (e) avaliação longitudinal de impacto acadêmico e socioemocional. A tecnologia educacional, quando estruturada sob metodologia rigorosa e governança ética sólida, pode funcionar

como instrumento de fortalecimento da educação inclusiva baseada em evidências. O PinGO não pretende substituir o professor, pretende ampliar sua capacidade de mediação ao sistematizar decisões, organizar informações e liberar tempo para aquilo que permanece essencialmente humano na educação: a relação pedagógica intencional.

REFERÊNCIAS BIBLIOGRÁFICAS

ADENIJI, S. A., AJAYI, A. K. A critical review of data mining in education on the levels and aspects of education. *Quality Education for All*, v. 1, n. 2, p. 41–59, 2024.

ALVES, D. L. et al. Impacto da inteligência artificial na educação inclusiva. *Revista Ilustração*, v. 5, n. 7, p. 37–47, 2024.

BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). *Diário Oficial da União*, Brasília, DF, 15 ago. 2018.

BRASIL. Ministério da Educação. Política Nacional de Educação Especial, equitativa, inclusiva e com aprendizado ao longo da vida. Brasília: MEC/SEMESP, 2020.

CAST. Universal Design for Learning Guidelines. Version 3.0. Wakefield, MA, CAST, 2024. Disponível em: <https://udlguidelines.cast.org>. Acesso em, 10 mar. 2026.

CHUA, B. L., WONG, K. Y. Early cognitive intervention using mediated learning for preschoolers with developmental delay, a randomized controlled trial. *British Journal of Educational Psychology*, v. 92, n. 3, p. 1120–1143, 2022.

HEVNER, A. R. A three cycle view of design science research. *Scandinavian Journal of Information Systems*, v. 19, n. 2, p. 87–92, 2007.

HEVNER, A. R. et al. Design science in information systems research. *MIS Quarterly*, v. 28, n. 1, p. 75–105, 2004.

HEVNER, A. R. et al. Transparency in design science research. *Decision Support Systems*, v. 181, 114218, 2024.

INEP. Censo Escolar da Educação Básica 2023, resumo técnico. Brasília, Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira, 2024.

NIKOLAIDIS, G. et al. Educational data mining and predictive modeling in the age of artificial intelligence, an in-depth analysis of research dynamics. *Computers*, v. 14, n. 2, p. 68, 2025.

ROMERO, C., VENTURA, S. Educational data mining and learning analytics, an updated survey. *WIREs Data Mining and Knowledge Discovery*, v. 10, n. 3, e1355, 2020.

SCHEFFEL, M. et al. Mediating learning with learning analytics technology, guidelines for practice. *Teaching in Higher Education*, v. 29, n. 4, p. 1500–1520, 2022.

TZURIEL, D. *Mediated Learning and Cognitive Modifiability*. Cham, Springer, 2021.

UNESCO. *Recomendação sobre a ética da inteligência artificial*. Paris, UNESCO, 2021.

VOM BROCKE, J., HEVNER, A. R., MAEDCHE, A. Introduction to design science research. In, VOM BROCKE, J., HEVNER, A. R., MAEDCHE, A. (ed.). Design Science Research, Cases. Cham, Springer, 2020. p. 1-13.

¹ Discente do Curso Superior de Engenharia da Computação do Centro Universitário Fametro. E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Mestrando em Engenharia de Processos (UFPA – PA). E-mail: [acesse o artigo original para visualizar o e-mail.](#)

³ Doutor em Física pela Universidade Federal de São Carlos (UFScar). E-mail: [acesse o artigo original para visualizar o e-mail](#)