

# Justiça, Responsabilidade, Transparência e Ética em Learning Analytics: Um Mapeamento Sistemático da Literatura

**Title: Justice, Accountability, Transparency, and Ethics in Learning Analytics: A Systematic Literature Mapping**

**Título: Justicia, rendición de cuentas, transparencia y ética en el análisis del aprendizaje: un mapeo sistemático de la literatura**

Letícia Rocha de Oliveira  
Universidade Federal de Alagoas  
ORCID: [0009-0002-6947-8283](https://orcid.org/0009-0002-6947-8283)  
lro@ic.ufal.br

Diego Dermeval Medeiros da  
Cunha Matos  
Universidade Federal de Alagoas  
ORCID: [0000-0002-8415-6955](https://orcid.org/0000-0002-8415-6955)  
diego.matos@famed.ufal.br

Luiz Antônio Lima Rodrigues  
Universidade Tecnológica Federal  
do Paraná  
ORCID: [0000-0003-0343-3701](https://orcid.org/0000-0003-0343-3701)  
luiz.rodrigues@nees.ufal.br

Maria Luiza Correia Oliveira Lima  
Universidade Federal de Alagoas  
ORCID: [0009-0006-7734-0638](https://orcid.org/0009-0006-7734-0638)  
maria.correia@arapiraca.ufal.br

Bárbara de Lima  
Universidade Federal de Alagoas  
ORCID: [0009-0000-8252-8543](https://orcid.org/0009-0000-8252-8543)  
barbara.lima@arapiraca.ufal.br

## Resumo

*Este mapeamento sistemático da literatura analisa a integração dos princípios de Justiça, Responsabilidade, Transparência e Ética (FATE) em Learning Analytics (LA), abordando sua aplicação em ambientes educacionais. O estudo identificou as ferramentas utilizadas, os principais desafios éticos e técnicos, além dos stakeholders mais impactados. Foram analisados 50 estudos, selecionados com base em critérios rigorosos de inclusão e qualidade, que evidenciam como práticas éticas podem promover um uso mais equitativo e responsável dos dados educacionais. Os resultados destacam a importância de personalizar o ensino, proteger a privacidade dos dados e garantir a transparência nos sistemas de LA. Conclui-se que a adoção bem-sucedida dessas tecnologias requer práticas de governança, auditorias regulares e maior atenção às necessidades de populações sub-representadas.*

**Palavras-Chave:** *Análise de Aprendizagem; Justiça; Responsabilidade; Transparência; Ética; Educação; Personalização.*

## Abstract

*This systematic literature review analyzes the integration of the principles of Fairness, Accountability, Transparency, and Ethics (FATE) into Learning Analytics (LA), addressing their application in educational settings. The study identified the tools used, the main ethical and technical challenges, and the most impacted stakeholders. Fifty studies were analyzed, selected based on rigorous inclusion and quality criteria, which demonstrate how ethical practices can promote more equitable and responsible use of educational data. The results highlight the importance of personalizing learning, protecting data privacy, and ensuring transparency in LA systems. It concludes that the successful adoption of these technologies requires governance practices, regular audits, and greater attention to the needs of underrepresented populations.*

**Keywords:** *Learning Analytics; Fairness; Accountability; Transparency; Ethics; Education; Personalization.*

Cite as: Oliveira, L. R.; Matos, D. D. M. C.; Rodrigues, L. A. L.; Lima, M. L. C. O.; Lima, B. Justiça, Responsabilidade, Transparência e Ética em Learning Analytics: Um Mapeamento Sistemático da Literatura. Revista Brasileira de Informática na Educação, vol. 33, pp. 773-798.  
<https://doi.org/10.5753/rbie.2025.5840>

## Resumen

*Esta revisión sistemática de la literatura analiza la integración de los principios de Equidad, Responsabilidad, Transparencia y Ética (FATE) en la Analítica del Aprendizaje (AL), abordando su aplicación en entornos educativos. El estudio identificó las herramientas utilizadas, los principales desafíos éticos y técnicos, y las partes interesadas más afectadas. Se analizaron cincuenta estudios, seleccionados con base en rigurosos criterios de inclusión y calidad, que demuestran cómo las prácticas éticas pueden promover un uso más equitativo y responsable de los datos educativos. Los resultados destacan la importancia de personalizar el aprendizaje, proteger la privacidad de los datos y garantizar la transparencia en los sistemas de AL. Se concluye que la adopción exitosa de estas tecnologías requiere prácticas de gobernanza, auditorías periódicas y una mayor atención a las necesidades de las poblaciones subrepresentadas.*

**Palabras clave:** Analítica del Aprendizaje; Equidad; Responsabilidad; Transparencia; Ética; Educación; Personalización.

## 1 Introdução

Com o avanço das tecnologias digitais em contextos educacionais, surgiram novas ferramentas para apoiar a aprendizagem dentro e fora da sala de aula. À adoção em larga escala dos Ambientes Virtuais de Aprendizagem (AVA) permitiu que docentes e gestores aproveitem os dados gerados por esses sistemas para observar, avaliar e compreender melhor os estudantes (Van Barneveld et al., 2012). Dessa forma, à análise e mineração de grandes volumes de dados e o uso de ferramentas analíticas tornou-se uma tendência global para aprofundar os processos educacionais. Quando aplicadas à educação, essas metodologias são conhecidas como *Learning Analytics* (LA) e se associam à Mineração de Dados Educacionais (EDM) (Elias, 2019). Essas tecnologias possibilitam compreender o comportamento dos estudantes, prever dificuldades e apoiar a tomada de decisões pedagógicas.

Segundo Verbet et al. (2013), a LA é reconhecida por sua capacidade de melhorar os resultados educacionais, tornando os ambientes de aprendizagem mais personalizados e eficientes. Ferramentas como dashboards educacionais permitem que professores visualizem dados em tempo real sobre engajamento e desempenho, auxiliando na identificação de padrões que indicam dificuldades ou lacunas no aprendizado (Verbet et al., 2013). Os sistemas adaptativos como o ALEKS (*Assessment and Learning in Knowledge Spaces*) e o Knewton utilizam algoritmos preditivos para recomendar conteúdos específicos, enquanto plataformas como o Coursera implementam ferramentas analíticas que personalizam trilhas de aprendizado com base no comportamento dos estudantes. Essas tecnologias proporcionam experiências mais dinâmicas e centradas no estudante, promovendo maior efetividade no processo de ensino-aprendizagem (Siemens, 2013). A motivação desta pesquisa surge da indispensabilidade de alinhar os avanços tecnológicos aos princípios éticos fundamentais de Justiça, Responsabilidade, Transparência e Ética, do inglês *Fairness, Accountability, Transparency, and Ethics*. Embora os sistemas de LA ofereçam oportunidades para aprimorar práticas pedagógicas, a falta de padrões claros para a integração de FATE em ambientes educacionais diversificados ainda representa uma barreira considerável (Khalil et al., 2023). Por exemplo, enquanto algumas ferramentas de LA promovem maior inclusão, outras podem perpetuar vieses e desigualdades, especialmente em populações sub-representadas (Sha et al., 2023). Essa dualidade exige uma abordagem crítica e bem fundamentada para asseverar que o impacto dessas tecnologias seja positivo e equitativo.

A literatura atual aponta para uma lacuna significativa na aplicação prática de FATE em *Learning Analytics*. Khalil et al. (2023) revelam que a transparência nos processos de análise de dados é relevante para manter a confiança dos estudantes e educadores, mas muitos sistemas ainda operam como "caixas-pretas", dificultando a compreensão de como decisões são tomadas.

Da mesma forma, Sha et al. (2023) indicam que a mitigação de vieses nos algoritmos continua sendo um desafio técnico e ético. Nesse contexto, esta pesquisa busca explorar, por meio de um mapeamento sistemático da literatura, como os métodos, abordagens e ferramentas de LA da literatura incorporam os princípios de Justiça, Responsabilidade, Transparência e Ética de maneira próspera, oferecendo diretrizes para práticas mais éticas e responsáveis.

Diante dessa circunstância, o objetivo deste artigo é investigar, por meio de um mapeamento sistemático da literatura, de que forma os estudos na área de *Learning Analytics* incorporam os princípios de Justiça, Responsabilidade, Transparência e Ética, identificando lacunas, boas práticas e desafios emergentes que podem subsidiar o desenvolvimento de ferramentas e políticas educacionais mais equitativas.

Esta pesquisa considera os desafios técnicos e éticos das intervenções automatizadas, enfatizando a importância de respeitar a privacidade, segurar transparência e criar sistemas que atendam às necessidades de todos os estudantes, especialmente os mais vulneráveis. Ao preencher essas lacunas, espera-se contribuir para o desenvolvimento de ferramentas que não apenas melhorem o desempenho acadêmico, mas também fortaleçam valores éticos fundamentais.

## 2 Trabalhos Relacionados

O campo de *Learning Analytics* de grandes volumes de dados educacionais e pelo avanço de tecnologias analíticas. Entretanto, a abordagem crítica que considera os princípios de Justiça, Responsabilidade, Transparência e Ética ainda é relativamente recente e pouco sistematizada. Diversos trabalhos têm buscado suprir essa lacuna por meio de análises sobre os impactos éticos das tecnologias educacionais.

Um estudo de destaque é o de Memarian e Doleck (2023), que realizaram uma revisão sistemática sobre os riscos éticos na adoção de sistemas de LA em ambientes universitários. Os autores salientam que, embora tais ferramentas promovam personalização e eficiência, podem também reforçar desigualdades se não forem criteriosamente desenhadas. Outro exemplo relevante é a revisão realizada por Kitto e Knight (2019), que propuseram diretrizes práticas para o desenvolvimento de sistemas de LA com base em princípios éticos, relevando a importância da participação ativa de professores e estudantes nos processos de decisão algorítmica.

Slade e Prinsloo (2013) também são frequentemente citados como referência fundacional sobre os dilemas éticos do uso de dados educacionais. Em sua análise crítica, os autores discutem as implicações da vigilância algorítmica, defendendo a implementação de políticas institucionais claras que garantam o consentimento informado e a proteção da privacidade dos alunos. De forma semelhante, Khalil, Prinsloo e Slade (2023) ampliam essa discussão ao proporem o conceito de Responsible *Learning Analytics*, que articula as dimensões de confiança, equidade e governança no uso de dados.

Savi et al. (2023) exploram o impacto da personalização algorítmica na motivação e no desempenho de estudantes, apontando que a eficácia dessas abordagens depende diretamente da transparência dos critérios utilizados.

Gedrimiene et al. (2023) introduzem uma abordagem voltada à transparência percebida, propondo métricas para avaliar como os usuários compreendem os sistemas analíticos, o que se alinha diretamente ao objetivo deste estudo. Da mesma forma, Sha, Gašević e Chen (2023) propõem estratégias de mitigação de viés em modelos preditivos, com foco em justiça algorítmica e impacto educacional equitativo.

Comparando-se às revisões anteriores, o presente artigo se diferencia por oferecer não apenas uma análise das tecnologias e métricas, mas também por propor um quadro interpretativo específico com base nos princípios FATE, integrando dimensões técnicas e políticas da análise de dados educacionais.

### 3 Métodos

A metodologia adotada para o estudo foi o Mapeamento Sistemático da Literatura (MSL), que visa identificar, avaliar e sintetizar evidências relevantes sobre uma questão de pesquisa, com o objetivo de fornecer um resumo imparcial e transparente das evidências disponíveis, além de identificar lacunas ou inconsistências na literatura, conforme descrito por Kitchenham et al. (2009) e adaptado por Klock (2018). A condução da MSL foi realizada em etapas bem definidas, iniciando-se pela formulação da questão de investigação, passando pela definição de termos-chave para busca nas bases de dados, critérios de inclusão e exclusão, seleção de estudos, avaliação de qualidade, extração de dados e, por fim, a sintetização dos resultados para responder à questão de pesquisa.

#### 3.1 Formulação da Questão de Pesquisa

A questão central definida para a investigação foi: "Como os princípios de *Fairness*, *Accountability*, *Transparency* e *Ethics* são aplicados e avaliados em *Learning Analytics* em contextos educacionais?". Essa questão orientou todo o processo do mapeamento.

#### 3.2 Questões de Pesquisa

As questões que orientaram o mapeamento sistemático foram elaboradas para captar diferentes dimensões da aplicação de FATE em *Learning Analytics*. São elas:

- **Q1:** Como ferramentas de análise de aprendizado podem ser utilizadas para identificar padrões de desempenho e participação dos estudantes, promovendo análises justas e equitativas?
- **Q2:** Como as soluções baseadas em LA podem ser implementadas de forma ética, garantindo a privacidade e a equidade de estudantes e educadores?
- **Q3:** Quais são os indicadores-chave nos dados de LA que podem sinalizar à insuficiência de intervenções para assegurar uma metodologia de sala de aula justa e transparente?

Essas questões nortearam tanto a seleção dos estudos quanto à análise qualitativa dos dados extraídos, contribuindo para a estruturação das categorias de resultados.

#### 3.3 Estratégia de Busca

Para o levantamento dos estudos relevantes, foram utilizadas combinações de termos como "*Learning Analytics*", "*FATE*", "*Fairness*", "*Transparency*", "*Ethics*" e "*Accountability*", com o auxílio de operadores booleanos *AND* e *OR* para potencializar os resultados nas bases de dados. Esses termos foram ajustados após testes preliminares para confirmar a obtenção de resultados relevantes e alinhados à questão de pesquisa. A string de pesquisa final utilizada foi: ("*Learning*

*Analytics" OR "Educational Data Mining") AND ("FATE" OR "Fairness" OR "Accountability" OR "Transparency" OR "Ethics") AND ("education" OR "educational context").*

### 3.4 Extração de Dados

As informações relevantes foram extraídas por meio de um formulário padronizado, preenchido de forma independente pelos revisores da equipe. O formulário incluía os seguintes campos:

- Título do estudo e ano de publicação;
- Contexto educacional e país de origem;
- Princípios de FATE abordados;
- Ferramentas e tecnologias utilizadas;
- Principais resultados e desafios relatados;
- Métodos de avaliação ética;
- Identificação dos stakeholders impactados.

A sistematização desses dados possibilitou a síntese dos achados e a construção de categorias temáticas, com o objetivo de responder às questões de pesquisa e identificar lacunas para investigações futuras.

### 3.5 Critérios de Inclusão e Exclusão

Foram definidos critérios rigorosos para selecionar os estudos que comporiam o mapeamento sistemático. Tais critérios buscaram assegurar que os artigos analisados estivessem alinhados à questão de pesquisa proposta e contribuíssem efetivamente para a discussão sobre FATE em *Learning Analytics*.

Critérios de Inclusão:

- i. Estudos disponíveis em texto completo e revisados por pares;
- ii. Trabalhos relacionados à aplicação dos princípios FATE em *Learning Analytics*;
- iii. Pesquisas realizadas em contextos educacionais formais, como ensino básico, superior ou profissionalizante.

Critérios de Exclusão:

- i. Estudos duplicados;
- ii. Publicações fora do escopo temático (como contextos corporativos ou comerciais);
- iii. Trabalhos que não abordassem explicitamente os princípios de FATE ou que não apresentassem avaliações éticas ou metodológicas correlatas.

Após a aplicação desses critérios, realizou-se uma triagem inicial com base em títulos e resumos. Os artigos que se mostraram potencialmente elegíveis foram lidos integralmente para confirmação do alinhamento com os objetivos da pesquisa.

Tabela 1: Critérios de inclusão e exclusão utilizados no estudo.

Categoria	Critérios
Inclusão	<ul style="list-style-type: none"> <li>i. Estudos com texto completo disponível e revisão por pares.</li> <li>ii. Trabalhos que abordem a aplicação de FATE em <i>Learning Analytics</i>.</li> <li>iii. Estudos desenvolvidos em contextos educacionais formais (escolas, universidades, EAD).</li> </ul>
Exclusão	<ul style="list-style-type: none"> <li>i. Artigos duplicados;</li> <li>ii. Estudos desenvolvidos em contextos não educacionais, tais como ambientes corporativos, comerciais ou industriais;</li> <li>iii. Trabalhos que não abordassem diretamente os princípios de <i>Fairness, Accountability, Transparency e Ethics</i> (FATE), ou que não apresentassem discussões relacionadas à avaliação ética ou metodológica de soluções em <i>Learning Analytics</i>.</li> </ul>

A definição clara dos critérios de inclusão e exclusão foi substancial para reiterar a consistência e a validade do mapeamento sistemático, assim como demonstrado na Tabela 1. Esses critérios permitiram selecionar apenas estudos diretamente alinhados ao escopo da pesquisa, assegurando que as evidências analisadas estivessem focadas na aplicação dos princípios de FATE no contexto educacional. Também, a exclusão criteriosa de trabalhos duplicados, fora do escopo ou metodologicamente frágeis evitou vieses na análise e fortaleceu a robustez dos achados. Essa seleção rigorosa assegura que os resultados apresentados estejam embasados em literatura qualificada, coerente com os objetivos do estudo.

## 4 Resultados

Esta seção apresenta os resultados obtidos após a condução do Mapeamento Sistemático da Literatura (MSL). São descritos os dados quantitativos referentes à triagem dos artigos, as categorias identificadas nas análises, os principais desafios éticos relacionados ao uso de *Learning Analytics* e os *stakeholders* mais impactados pelas práticas avaliadas. A Figura 1 ilustra as etapas de filtragem dos estudos, e as Tabelas subsequentes organizam os achados por critérios temáticos.

A condução do MSL foi realizada conforme o planejamento estabelecido na metodologia. As buscas pelos estudos mais relevantes ocorreram em cinco bases de dados amplamente reconhecidas no meio acadêmico: Compendex (Engineering Village), IEEE Digital Library, ISI Web of Science, ScienceDirect e Scopus. Essas bases foram escolhidas devido à sua ampla abrangência em publicações sobre tecnologia educacional e *Learning Analytics*.

A ferramenta Parsifal foi utilizada para gerenciar os artigos identificados durante o mapeamento. Essa ferramenta auxiliou na eliminação de duplicatas, na organização dos artigos por categorias e no monitoramento do progresso de triagem e análise.

A Tabela 2 apresenta os resultados detalhados das buscas em cada base de dados, incluindo o número total de artigos encontrados, duplicados, rejeitados, lidos na íntegra e os que foram incluídos na análise final.

Tabela 2: Variáveis a serem consideradas na avaliação de técnicas de interação.

Base de dados	Total	Duplicados	Rejeitados	Leitura na íntegra	Artigos incluídos
Compendex (Engineering Village)	25	21	3	1	1
IEEE Digital Library	24	14	9	1	0
ISI Web of Science	121	84	30	6	5
Science@Direct	415	0	380	32	26
Scopus	271	0	238	23	18
<b>Total</b>	<b>856</b>	<b>119</b>	<b>660</b>	<b>63</b>	<b>50</b>

O Mapeamento Sistemático da Literatura (MSL) começou com a análise de 856 artigos (ver Fluxo na Figura 1) encontrados nas bases de dados mencionadas, relacionados ao campo de estudo. Desse total, 119 artigos duplicados foram removidos, deixando 737 trabalhos para avaliação. Utilizando critérios de inclusão e exclusão previamente definidos, identificamos as pesquisas relevantes para este mapeamento. A seleção inicial baseou-se na análise de títulos, resumos e palavras-chave dos artigos, o que resultou na exclusão de 660 estudos que tratavam de assuntos fora do escopo deste trabalho.




Figura 1: Diagrama PRISMA Adaptado.

Após essa triagem inicial, 77 artigos foram selecionados para a segunda rodada de avaliação, na qual foi realizada a análise completa dos textos. Nesta etapa, priorizamos a aplicação prática dos princípios de *Fairness*, *Accountability*, *Transparency* e *Ethics em Learning Analytics*, com foco no contexto educacional. Verificamos também a qualidade metodológica dos estudos, considerando aspectos como clareza nos objetivos, robustez na aplicação de métodos analíticos e alinhamento com os princípios de FATE. Durante essa análise, 14 artigos foram excluídos por apresentarem limitações significativas. Essas limitações incluíram a falta de

alinhamento com o escopo do estudo, como artigos que abordaram *Learning Analytics* de maneira genérica sem explorar os princípios de FATE; fragilidade metodológica, como à ausência de descrição clara dos métodos utilizados ou baixa replicabilidade; e foco em contextos não aplicáveis, como áreas fora do ambiente educacional, como análise de dados corporativos ou marketing. A triagem dos estudos foi conduzida por três revisores de forma independente, assegurando à aplicação rigorosa dos critérios de inclusão e exclusão. Em casos de discordância quanto à elegibilidade de um artigo, foi realizado um processo de discussão entre os revisores, buscando o consenso.

Quando a discordância persistia, um terceiro revisor atuava como mediador para a decisão final. Essa abordagem colaborativa contribuiu para a confiabilidade e a transparência do processo de seleção.

Como resultado, 63 artigos foram selecionados para análise detalhada, dos quais 50 atenderam plenamente aos critérios finais e foram incluídos na síntese dos resultados. Esse processo garantiu que os estudos analisados fossem relevantes e diretamente relacionados aos objetivos deste trabalho, reforçando a validade e a qualidade do mapeamento sistemático. A Figura 2 demonstra as fases de condução da pesquisa.



Figura 2: Fases de condução do mapeamento sistemático.

#### 4.1 Processo de Mapeamento Sistemático

Este mapeamento visa identificar lacunas e analisar os impactos dos princípios de *Fairness*, *Accountability*, *Transparency* e *Ethics*, garantindo embasamento teórico sólido para as evidências apresentadas. As questões que nortearam a pesquisa abordam aspectos essenciais para a compreensão e aplicação de LA em contextos educacionais.

À avaliação destacou a importância de ferramentas tecnológicas em LA, como painéis de controle e sistemas adaptativos, que facilitam o uso de dados para melhorar os processos de ensino e aprendizagem. Essas ferramentas foram analisadas quanto à sua capacidade de promover justiça, responsabilidade, transparência e ética, contribuindo para um ambiente educacional mais equitativo. A clareza na definição dos métodos e métricas utilizados, bem como a validação empírica das evidências, assegurou a confiabilidade e a relevância dos resultados.

Essa abordagem visou assegurar que os artigos selecionados apresentassem rigor metodológico, relevância para as questões de pesquisa e potencial de aplicação em diferentes contextos educacionais. Essa etapa contribuiu para uma síntese vigorosa dos resultados, fornecendo subsídios para o avanço do campo de estudo e à implementação prática dos princípios de FATE em *Learning Analytics*.

A Tabela 3 apresenta as respostas às três questões de pesquisa estabelecidas para a análise do tema, revelando aspectos cruciais para atestar uma prática ética e eficaz na utilização dessas ferramentas.



Tabela 3: Questões de Pesquisa.

QP	Questão de Pesquisa	Resposta
QP1	Como as ferramentas de análise de aprendizado podem ser usadas para identificar padrões de desempenho e participação dos estudantes, promovendo uma análise justa e equitativa?	Ferramentas de LA, especialmente na categoria de "Tutoria e Aprendizagem Adaptativa, "permitem personalizar o ensino, identificando padrões de desempenho e participação. Isso facilita intervenções justas e equitativas, promovendo uma metodologia de sala de aula adaptada às necessidades individuais dos estudantes.
QP2	Como as soluções baseadas em LA podem ser implementadas de maneira ética, garantindo a privacidade e à equidade de estudantes e educadores?	À implementação ética de LA exige conformidade com regulamentos de privacidade, como o GDPR, e à adoção de práticas de anonimização. É de extrema importância ter políticas institucionais claras e medidas de governança para assegurar à equidade, transparência e segurança no manejo dos dados dos estudantes e educadores.
QP3	Quais são os indicadores-chave nos dados de LA que podem sinalizar a necessidade de intervenções para assegurar uma dinâmica de sala de aula justa e transparente?	Indicadores-chave incluem a transparência dos sistemas, auditorias algorítmicas regulares, e à análise de vieses e equidade nos dados. Esses indicadores são essenciais para corroborar intervenções que promovam uma sala de aula justa, transparente e ética, assegurando que os resultados dos sistemas de LA sejam equitativos e que os dados dos estudantes sejam tratados de maneira responsável.

As questões utilizadas no processo de Avaliação de Qualidade estão sistematizadas na Tabela 4. Essas questões foram elaboradas com o objetivo de aferir a consistência metodológica, a relevância teórica e à aderência dos estudos selecionados aos objetivos do mapeamento. Além disso, permitiram identificar o grau de alinhamento dos trabalhos aos princípios de *Fairness*, *Accountability*, *Transparency* e *Ethics* (FATE), assegurando maior rigor na análise e seleção dos dados. À aplicação dessas questões de qualidade contribuiu, portanto, para refinar a amostra final e sustentar a validade dos achados apresentados.

Tabela 4: Questões de Avaliação de Qualidade.

Q	Questão	Pontuação
Q1	O artigo descreve qual software ou ferramenta tecnológica foi utilizada na pesquisa? (Dermeval <i>et al.</i> , 2016)	S = 1.0, P = 0.5, N = 0.0
Q2	Existe uma definição clara do problema ou desafio central investigado no estudo e como ele se relaciona com as questões de equidade, responsabilidade, transparência e ética na análise de dados educacionais? (Dermeval <i>et al.</i> , 2016)	S = 1.0, P = 0.5, N = 0.0
Q3	Os principais beneficiários ou partes interessadas envolvidas na pesquisa, como professores e/ou estudantes, são identificados e é discutido como a análise de aprendizagem impacta suas práticas ou resultados? (Dermeval <i>et al.</i> , 2016)	S = 1.0, P = 0.5, N = 0.0
Q4	Existe uma definição clara de quais métodos e/ou métricas foram empregados para avaliar a aderência aos princípios de justiça, responsabilidade, transparência e ética (FATE) na análise de aprendizagem, e como esses métodos são operacionalizados na prática? (Dermeval <i>et al.</i> , 2016)	S = 1.0, P = 0.5, N = 0.0
Q5	Existe alguma validação empírica ou estudos de caso que suportam os achados do artigo? (Dermeval <i>et al.</i> , 2016)	S = 1.0, P = 0.5, N = 0.0

A Tabela 5 apresenta a versão final da avaliação de qualidade utilizada neste estudo para cada artigo.

Tabela 5: Estudos Seleccionados Pós Avaliação da Qualidade dos Estudos.

ID	Autor	Q1	Q2	Q3	Q4	Q5	Pontuação
S01	(Rachha & Seyam, 2023)	1.0	1.0	1.0	1.0	1.0	5.0
S02	(Howell et al., 2018)	1.0	1.0	1.0	0.5	0.5	4.0
S03	(Ranjeeth et al., 2020)	1.0	1.0	1.0	0.5	1.0	4.5
S04	(Cox, 2022)	0.5	1.0	0.5	0.5	0.5	3.0
S05	(Mathrani et al., 2021)	1.0	1.0	1.0	1.0	0.0	4.0
S06	(Sharma & Giannakos, 2021)	1.0	1.0	1.0	0.5	1.0	4.0
S07	(Pargman et al., 2023)	0.0	1.0	0.5	1.0	0.5	3.0
S08	(Leeuwen et al., 2014)	1.0	1.0	1.0	0.0	0.5	3.5
S09	(Lee & Gargroetzi, 2023)	1.0	1.0	1.0	1.0	1.0	5.0
S10	(Leeuwen & Janssen, 2019)	1.0	1.0	1.0	1.0	1.0	5.0
S11	(L. Zhang et al., 2020)	0.5	1.0	1.0	0.5	1.0	4.0
S12	(Andersen, 2020)	1.0	1.0	1.0	0.0	0.5	3.5
S13	(Shiyan et al., 2023)	1.0	0.5	1.0	0.0	1.0	3.5
S14	(Shibani et al., 2020)	1.0	1.0	1.0	0.5	1.0	4.5
S15	(Duin & Tham, 2020)	1.0	1.0	1.0	0.5	1.0	4.5
S16	(Khosravi et al., 2022)	0.5	1.0	1.0	1.0	1.0	4.5
S17	(Herodotou et al., 2021)	1.0	1.0	1.0	0.5	0.5	4.0
S18	(K. Zhang & Aslan, 2021)	1.0	1.0	1.0	1.0	1.0	5.0
S19	(Cheng & Wang, 2023)	1.0	1.0	1.0	0.0	1.0	4.0
S20	(Fan et al., 2022)	1.0	1.0	0.5	0.5	1.0	4.0
S21	(Tumilty et al., 2022)	0.0	1.0	1.0	0.0	1.0	3.0
S22	(Yang et al., 2021)	0.0	1.0	1.0	1.0	0.0	3.0
S23	(Nasir et al., 2022)	0.0	1.0	1.0	0.0	1.0	3.0
S24	(Haderer & Ciolacu, 2022)	1.0	1.0	1.0	1.0	0.0	4.0
S25	(Hooshyar et al., 2020)	1.0	1.0	1.0	0.5	0.0	3.5
S26	(Hertweck et al., 2022)	0.0	1.0	1.0	1.0	1.0	4.0
S27	(Vasquez Verdugo et al., 2022)	1.0	1.0	1.0	1.0	1.0	5.0
S28	(Sha et al., 2023)	1.0	1.0	1.0	0.5	1.0	4.5
S29	(Savi et al., 2023)	1.0	1.0	1.0	0.5	1.0	4.0
S30	(Ouyang & Jiao, 2021)	1.0	1.0	1.0	1.0	1.0	5.0
S31	(May et al., 2017)	1.0	1.0	1.0	0.0	1.0	4.0
S32	(Gedrimiene et al., 2023)	1.0	0.0	0.0	1.0	1.0	3.0
S33	(Wise et al., 2021)	1.0	1.0	1.0	0.0	1.0	4.0
S34	(Marras et al., 2022)	0.0	1.0	1.0	1.0	0.0	3.0
S35	(Veljanova et al., 2023)	0.5	1.0	1.0	1.0	0.0	3.5
S36	(Kurilovas, 2020)	0.0	0.5	1.0	1.0	1.0	3.5
S37	(Bayer et al., 2021)	1.0	1.0	0.5	1.0	1.0	4.5
S38	(Krupiy, 2020)	1.0	1.0	0.0	0.5	1.0	3.5
S39	(Hakimi et al., 2021)	1.0	1.0	0.5	1.0	1.0	4.5
S40	(Slade & Prinsloo, 2013)	0.5	1.0	0.5	0.5	0.5	3.0
S41	(Tambouris et al., 2018)	1.0	0.0	1.0	0.5	0.5	3.0
S42	(Prinsloo & Slade, 2017)	0.5	1.0	0.5	1.0	0.5	3.5
S43	(Kwong et al., 2017)	1.0	1.0	1.0	1.0	1.0	5.0
S44	(Hakami & Hernandez-Leo, 2021)	1.0	1.0	1.0	1.0	1.0	5.0
S45	(Kitto & Knight, 2019)	1.0	1.0	1.0	1.0	1.0	5.0

ID	Autor	Q1	Q2	Q3	Q4	Q5	Pontuação
S46	(Gedrimiene et al., 2020)	1.0	1.0	1.0	0.5	1.0	4.5
S47	(Parsons, 2021)	0.5	1.0	1.0	1.0	1.0	4.5
S48	(Chen & Poquet, 2022)	1.0	1.0	0.5	0.5	1.0	4.0
S49	(Lee & Gargroetzi, 2023)	1.0	1.0	1.0	1.0	1.0	5.0
S50	(Khalil et al., 2023)	0.0	1.0	1.0	0.0	0.5	2.5

Após a conclusão das etapas do MSL, foi realizada a extração de dados, que consistiu na leitura integral dos artigos selecionados. Esse processo contou com a participação de uma equipe composta por três pesquisadores, que foram responsáveis por analisar os 50 estudos incluídos no mapeamento. Cada pesquisador utilizou um formulário de extração padronizado para comprovar a uniformidade e consistência entre a avaliação de qualidade previamente realizada e a extração dos dados.

Os dados extraídos incluíram informações como o título dos estudos, que facilitou a identificação e categorização no contexto de *Learning Analytics*, e o país de origem dos estudos, possibilitando compreender os contextos geográficos e culturais, além de avaliar variações nos desafios relacionados aos princípios de Justiça, Responsabilidade, Transparência e Ética vindo do termo em inglês *Fairness, Accountability, Transparency e Ethics* em diferentes regiões. O ano de publicação também foi considerado, indicando o grau de atualidade dos estudos e sua conexão com o estado da arte em LA, fornecendo uma perspectiva sobre a evolução das práticas na área.

Outro aspecto analisado foi o uso de softwares e ferramentas tecnológicas, permitindo identificar as tecnologias aplicadas nos estudos e suas contribuições para a análise de desempenho e tomada de decisões. Também foram apontados os problemas e desafios abordados nos artigos, proporcionando insights sobre como os princípios de FATE são aplicados para enfrentar questões de equidade e ética. A identificação dos principais favorecidos ou *stakeholders* dos estudos revelou grupos diretamente impactados pelas aplicações de LA, como estudantes, professores ou gestores, evidenciando potenciais desigualdades ou benefícios decorrentes dessas práticas. Nesse contexto, Cheng e Wang (2023) ressaltam que a liderança digital exerce papel fundamental para a adoção eficaz de tecnologias baseadas em IA no ambiente escolar. Os autores demonstram que barreiras internas aos professores, como insegurança no uso de tecnologias, e barreiras externas, como ausência de infraestrutura e apoio institucional, dificultam a implementação de práticas inovadoras.

A atuação de líderes educacionais engajados e bem-preparados pode atenuar esses obstáculos, promovendo uma cultura escolar mais propensa à inovação ética e à integração dos princípios de FATE na tomada de decisão pedagógica. Foram examinados os métodos e métricas utilizados para avaliar os aspectos de FATE, fornecendo detalhes sobre as abordagens metodológicas específicas para medir justiça, responsabilidade e transparência. A validação empírica ou estudos de caso mencionados nos artigos foi cuidadosamente verificada para assegurar que as recomendações fossem fundamentadas em evidências práticas e confiáveis.

## 4.2 Desafios por Grupo e Estudos

À análise dos desafios enfrentados no uso de ferramentas de *Learning Analytics* em contextos educacionais revelou um conjunto consistente de obstáculos que limitam a efetividade, a ética e a aplicabilidade dessas tecnologias. Os dados obtidos evidenciam que, embora haja avanços consideráveis na implementação de LA, ainda persistem barreiras estruturais, técnicas e sociais

que precisam ser enfrentadas para que essas ferramentas cumpram seu potencial transformador de forma justa, responsável e transparente.

O principal desafio identificado refere-se às questões de ética e privacidade, mencionadas em 34 estudos. Essa recorrência salienta a preocupação com a coleta, o armazenamento e o uso de dados sensíveis de estudantes e educadores. Estudos como os de Hakimi et al. (2021), Khalil et al. (2023) e Kitto e Knight (2019) apontam que a ausência de mecanismos robustos de proteção de dados pode comprometer a confiança no sistema e expor vulnerabilidades institucionais, além de desrespeitar diretrizes regulatórias como o GDPR.

Outro obstáculo de grande relevância foi o problema com os próprios dados utilizados nos sistemas, identificado em 23 estudos. Trata-se de limitações relacionadas à qualidade, incompletude e viés dos dados coletados. Sha et al. (2023), Marras et al. (2022) e Rachha e Seyam (2023) demonstram que informações parciais ou enviesadas comprometem a análise, podendo reforçar desigualdades já existentes no ambiente educacional.

A dificuldade de aplicação pedagógica dos resultados gerados por LA apareceu como desafio em 15 estudos. Mesmo quando as ferramentas oferecem dados úteis, muitos professores encontram barreiras técnicas ou de formação para traduzir essas informações em práticas concretas. Leeuwen e Janssen (2019) e Shibani et al. (2020) enfatiza a necessidade de formação contínua e de soluções mais intuitivas para atestar o uso efetivo dos sistemas no cotidiano escolar.

Também foi possível perceber que, em 10 estudos, a falta de transparência e explicabilidade dos algoritmos, o que dificulta a compreensão sobre como são tomadas as decisões ou geradas as recomendações automatizadas. Gedrimiene et al. (2023) e Veljanova et al. (2023) enfatizam que, sem clareza sobre o funcionamento das ferramentas, professores e estudantes podem desconfiar do sistema e recusar sua utilização.

A robustez e a replicabilidade das metodologias foram apontadas como insuficientes em 8 estudos. À ausência de descrições claras de métodos e de modelos que possam ser aplicados em diferentes contextos educacionais gera dificuldades para generalizar os resultados. Mathrani et al. (2021) e Prinsloo e Slade (2017) salientam a importância de padronizações metodológicas e da construção de protocolos mais rigorosos para garantir a validade das análises.

A confiança e aceitação das ferramentas de LA foi outro desafio relevante, mencionado em 5 estudos. Howell et al. (2018) e Hakimi e Hernandez-Leo (2021) apontam que a resistência à adoção tecnológica decorre, em muitos casos, da falta de percepção de valor imediato, da complexidade das interfaces e da ausência de suporte institucional adequado.

Finalmente, o tópico diversidade e inclusão surgiu como desafio em apenas 2 estudos, revelando uma lacuna notável na literatura. Pargman et al. (2023) e Bayer et al. (2021) chamam a atenção para o fato de que as soluções baseadas em LA frequentemente desconsideram as especificidades de grupos sub-representados, como estudantes com deficiência ou pertencentes a minorias sociais, o que pode ampliar desigualdades educacionais se não forem cuidadosamente endereçadas. Para sintetizar visualmente a frequência com que cada um desses desafios foi identificado na literatura analisada, apresenta-se a seguir a Figura 3.

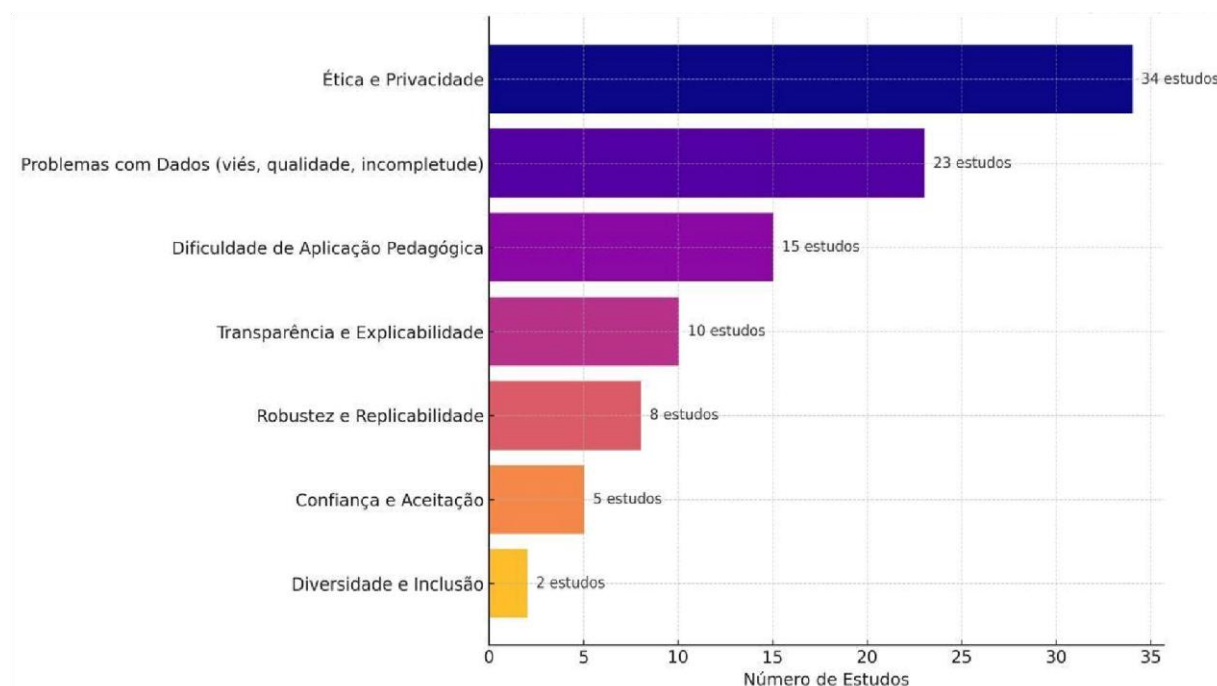


Figura 3: Desafios Identificados no Uso de Ferramentas de *Learning Analytics*.

À análise gráfica evidencia-se que os temas de ética e privacidade são amplamente predominantes, mencionados em mais de dois terços dos estudos, o que reforça a urgência de desenvolver políticas claras de governança de dados no uso de *Learning Analytics*. Em seguida, os desafios relacionados à qualidade e viés dos dados ganham destaque, indicando uma fragilidade estrutural que impacta diretamente a confiabilidade dos sistemas. A menor frequência de estudos que abordam diversidade e inclusão (apenas dois), revela uma lacuna significativa na produção científica, evidenciando a necessidade de incorporar perspectivas mais amplas e representativas nos projetos que envolvem análise de dados educacionais.

### 4.3 Principais Stakeholders

A análise dos estudos selecionados revelou três grupos centrais de stakeholders impactados diretamente pelas aplicações de ferramentas de *Learning Analytics*: estudantes, professores e gestores educacionais. Esses grupos representam os principais beneficiários e, ao mesmo tempo, os mais vulneráveis aos efeitos da coleta, análise e aplicação dos dados educacionais.

O grupo mais citado foi o dos estudantes, presentes em 45,5% dos estudos analisados. Esse dado reforça o protagonismo discente na era dos dados educacionais. Ferramentas de LA têm sido amplamente empregadas para monitorar desempenho, engajamento, permanência e evolução de estudantes em diversos contextos de ensino. Estudos como os de Sha et al. (2023), Leeuwen e Janssen (2019) e Howell et al. (2018) apontam como os sistemas baseados em dados permitem oferecer suporte individualizado, identificar riscos precocemente e planejar intervenções pedagógicas mais eficazes.

Os professores aparecem como stakeholders em 38,4% dos estudos. Embora em proporção menor do que os estudantes, o corpo docente tem papel importantíssimo na mediação entre os sistemas automatizados e a aplicação pedagógica prática. Gedrimiene et al. (2023), Shibani et al. (2020) e Mathrani et al. (2021) demonstram que a apropriação adequada das ferramentas por parte dos docentes depende de fatores como formação continuada, usabilidade

dos sistemas e clareza nos relatórios gerados. Em ambientes onde esses fatores estão ausentes, o uso de LA tende a ser limitado ou superficial.

Já os gestores educacionais foram identificados em 16% das pesquisas analisadas. Esse número menor não indica pouca importância, mas sim uma ênfase ainda incipiente na atuação institucional no uso estratégico dos dados. Khalil et al. (2023), Prinsloo e Slade (2017) e Bayer et al. (2021) apontam que, quando bem utilizados, os dados de LA podem subsidiar decisões em larga escala, como políticas de retenção, alocação de recursos e planejamento curricular. Entretanto, a literatura ainda carece de estudos mais aprofundados sobre como os gestores interpretam, utilizam ou influenciam a infraestrutura dos sistemas de LA. Apresenta-se a seguir a Figura 4, que sintetiza graficamente os percentuais de ocorrência nos estudos analisados.

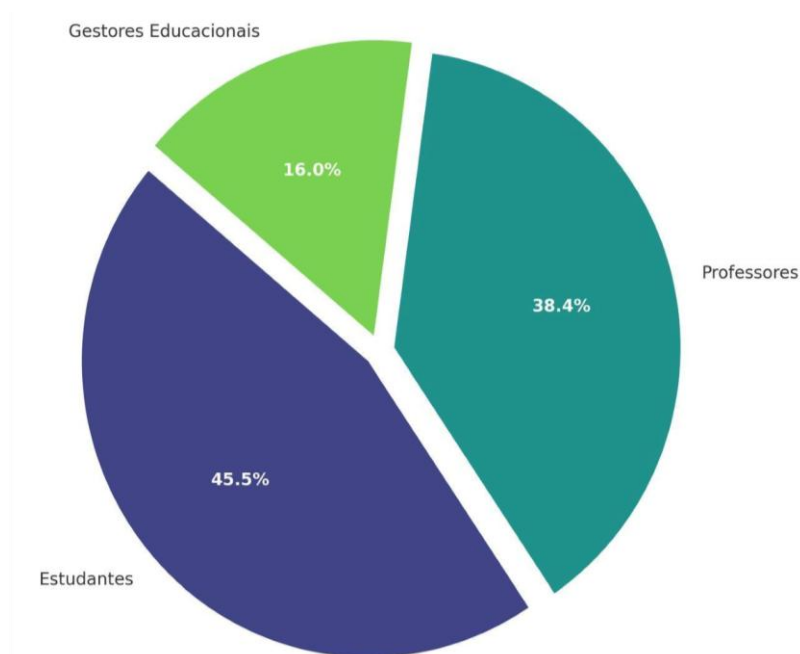


Figura 4: Distribuição dos Stakeholders no Uso de *Learning Analytics*.

A análise gráfica reforça que os estudantes são o público mais diretamente impactado pelas ferramentas de LA, sendo também o grupo mais estudado. Em compensação, a baixa incidência de gestores entre os *stakeholders* pode indicar uma sub-exploração das possibilidades institucionais dos dados educacionais. Este achado sugere a necessidade de pesquisas que considerem mais amplamente a atuação estratégica da gestão escolar e universitária, promovendo um ecossistema de dados mais articulado, transparente e inclusivo para todos os envolvidos no processo educacional.

#### 4.4 Métodos ou Métricas de FATE

A investigação sobre os métodos e métricas utilizados para avaliar os princípios de *Fairness*, *Accountability*, *Transparency* e *Ethics* nos estudos analisados demonstrou uma diversidade de abordagens e níveis de profundidade. Embora muitos estudos reconheçam a importância desses princípios, nem todos propõem métodos concretos para mensurá-los, o que evidencia um campo em construção e com lacunas metodológicas significativas.

O estudo de Sha et al. (2023) apresenta uma das abordagens mais detalhadas ao propor métricas para avaliar a equidade em algoritmos de recomendação educacional. Entre as

ferramentas destacadas estão o *Disparate Impact Ratio*, que mede a proporção entre a taxa de recomendação para diferentes grupos demográficos, e o *Equalized Odds*, que verifica se a precisão das recomendações é semelhante entre os grupos analisados. Os resultados apontaram para a presença de viés nos algoritmos, reforçando a importância de ajustes nos modelos para minimizar desigualdades. Khalil et al. (2023) abordaram a responsabilidade (*Accountability*) por meio de indicadores como o *Traceability Index*, que quantifica o grau de rastreabilidade das decisões tomadas pelos sistemas de LA, e o *Justification Score*, que avalia se há justificativas explícitas e compreensíveis para as recomendações geradas. A ausência de justificativas claras e a opacidade dos algoritmos comprometeram a confiança institucional nos sistemas, demonstrando a urgência de mecanismos de governança mais transparentes.

No campo da transparência, Gedrimiene et al. (2023) propuseram métricas como o *Explainability Score*, que mede a facilidade com que os usuários compreendem os critérios das recomendações, e o *User Perceived Transparency*, voltado à percepção dos educadores e estudantes sobre a clareza das informações disponibilizadas pelas ferramentas. Os dados indicam que quanto maior a transparência percebida, maior a adesão dos usuários e a confiabilidade atribuída ao sistema.

Outros estudos, como os de Leeuwen e Janssen (2019) e Kitto e Knight (2019), reconheceram a importância de FATE, mas sem apresentar métricas específicas para sua mensuração. Essa tendência foi observada em diversas publicações, que abordam os princípios de forma descritiva ou normativa, porém sem operacionalizá-los de forma empírica ou quantitativa. Nesses casos, a presença de FATE nos textos configura-se mais como um referencial ético do que como uma dimensão técnica mensurável.

Também foram identificadas referências indiretas aos princípios de FATE. Marras et al. (2022), por exemplo, discutem a necessidade de redução de viés nos dados, o que se alinha à noção de justiça, embora sem detalhamento metodológico. Mathrani et al. (2021) abordam a transparência em termos de clareza nos processos analíticos, mas não propõem formas práticas de mensuração.

Em síntese, os estudos mais robustos adotaram indicadores quantitativos que permitiram avaliar concretamente os princípios de FATE em diferentes níveis, enquanto parte da literatura ainda carece de métricas sistematizadas. Essa heterogeneidade metodológica reforça a necessidade de desenvolvimento de instrumentos padronizados que permitam não apenas a análise ética e justa de sistemas de LA, mas também a comparação entre diferentes contextos e populações educacionais.

#### 4.5 Indicadores-Chave em *Learning Analytics*

A análise dos estudos selecionados permitiu identificar um conjunto de indicadores-chave frequentemente utilizados para monitorar e avaliar a aplicação ética, justa e responsável das ferramentas de *Learning Analytics* no contexto educacional. Esses indicadores operam como instrumentos fundamentais para a operacionalização dos princípios de *Fairness*, *Accountability*, *Transparency* e *Ethics*, assegurando que os sistemas baseados em dados não reproduzam desigualdades ou práticas excludentes.

A equidade (*Fairness*) tem sido mensurada por meio de métricas específicas que avaliam o impacto das análises sobre diferentes grupos de estudantes. Destacam-se, nesse aspecto, a análise de viés algorítmico, o cruzamento de dados por marcadores sociodemográficos e a justiça preditiva (*predictive fairness*), que busca certificar que os modelos não favoreçam ou prejudiquem sistematicamente certos perfis de usuários. Esses indicadores têm sido essenciais

para que pesquisadores e gestores consigam identificar possíveis distorções nos dados e implementar correções orientadas à inclusão e à justiça social.

No campo da responsabilidade (*Accountability*), diversos estudos indicam a importância da rastreabilidade das decisões algorítmicas, permitindo que os caminhos de análise e recomendação sejam auditáveis. Indicadores como o *Traceability Index* e o *Justification Score* demonstraram ser úteis para evidenciar a coerência das decisões produzidas por sistemas de LA e sua conformidade com as metas educacionais estabelecidas. A responsabilização institucional pelo uso desses dados tem sido medida por meio da existência de protocolos internos e da clareza sobre quem responde por decisões automatizadas.

Em relação à transparência (*Transparency*), os estudos apontam para a adoção de auditorias algorítmicas regulares, o fornecimento de relatórios explicativos compreensíveis por professores e estudantes e a disponibilização de informações sobre os critérios utilizados pelas ferramentas. Nesse sentido, Khosravi et al. (2022) argumentam que a Inteligência Artificial Explicável (XAI) representa um dos caminhos mais promissores para promover a confiança e a compreensão dos usuários, ao tornar mais claras as decisões tomadas por sistemas baseados em IA no contexto educacional. Indicadores como o *Explainability Score* e o *User Perceived Transparency* vêm sendo aplicados com o objetivo de tornar as análises mais acessíveis e compreensíveis, ampliando a confiança no uso dos sistemas e promovendo um diálogo mais ético entre tecnologia e prática pedagógica.

No que diz respeito à ética (*Ethics*), os principais indicadores dizem respeito à conformidade com legislações como o GDPR (Regulamento Geral de Proteção de Dados), à adoção de mecanismos de anonimização e à realização de avaliações de impacto ético antes da implementação de sistemas de LA. Alguns estudos destacaram a análise do impacto epistêmico, político e social do uso dessas ferramentas, incluindo a percepção de consentimento, a integridade acadêmica e o respeito aos direitos fundamentais dos estudantes.

É relevante focar que a validação empírica desses indicadores foi um critério central na análise dos estudos. Aqueles que apresentaram evidências práticas a partir da aplicação dos indicadores mostraram-se mais confiáveis e relevantes para o avanço do campo. A presença de auditorias, testes controlados e relatórios sistematizados demonstrou um compromisso não apenas metodológico, mas também ético com a produção de conhecimento em ambientes mediados por dados.

Em síntese, os indicadores-chave em LA não apenas mensuram a eficácia técnica das ferramentas, mas também operam como mecanismos de controle ético e social. A sua correta aplicação pode transformar o uso de dados educacionais em uma prática mais equitativa, transparente e orientada ao bem-estar dos sujeitos envolvidos. Investir na consolidação desses indicadores e em sua padronização representa, portanto, um passo primordial para atestar a legitimidade das análises de aprendizagem e para promover ambientes educacionais que respeitem os direitos humanos e a diversidade dos sujeitos.

Ao organizar esses achados em categorias específicas, foi possível observar que os indicadores de FATE aparecem, com maior ou menor frequência, articulados entre si. A transparência dos algoritmos, por exemplo, mostra-se diretamente relacionada à confiabilidade percebida por educadores e discentes, influenciando a aceitação e o uso contínuo das ferramentas. Da mesma forma, os aspectos ligados à justiça, como a redução de viés e o tratamento equitativo, caminham lado a lado com o cuidado com a qualidade dos dados, sem lacunas ou distorções que possam comprometer análises e decisões pedagógicas.

Para a definição dessas categorias, foi adotada uma abordagem dedutiva, orientada pelos princípios de FATE previamente descritos no referencial teórico. Cada indicador identificado



nos revisados foi analisado em junção à sua declarada, à dimensão ética predominante e à forma como estudos contribuíram para práticas mais justas, transparentes e responsáveis. A categorização manteve os seguintes critérios: (i) se o indicador de impacto de mídia distributivo entre grupos (Equidade), (ii) se evidenciasse a rastreabilidade ou prestação de contas (Responsabilidade), (iii) se promovesse a compreensão acessível dos dados e modelos (Transparência), ou (iv) se abordasse a conformidade legal, valores institucionais ou direitos dos estudantes (Ética). Quando um indicador se relacionava com mais de uma dimensão, sua classificação principal foi atribuída com base na ênfase do estudo original. Essa abordagem segue os fundamentos teóricos propostos por Slade e Prinsloo (2013) e aprofundados por Khalil et al. (2023), que sinalizam a importância da incorporação de valores éticos nas fases de design, implementação e avaliação de sistemas baseados em dados educacionais.

A análise integrada dos dados permite concluir que a presença de indicadores de FATE é mais significativa nos estudos que abordam desafios como ética, privacidade e qualidade dos dados. Esses desafios não são meramente técnicos: refletem disputas éticas e políticas sobre o que se valoriza em ambientes educacionais mediados por dados. A recorrência desses indicadores revela uma tensão latente entre inovação tecnológica e responsabilidade social, que exige atenção contínua da comunidade científica, dos desenvolvedores e dos formuladores de políticas.

Dessa forma, compreende-se que a efetividade das ferramentas de *Learning Analytics* não pode ser dissociada da incorporação deliberada e consistente de princípios de FATE. Os dados sugerem que, embora já existam iniciativas promissoras, ainda há um caminho relevante a ser trilhado para que tais tecnologias sejam, de fato, justas, transparentes e benéficas para todos os envolvidos no processo educacional. A Figura 5 a seguir resume o número de indicadores identificados para cada dimensão.




Figura 5. Número de indicadores-chave por dimensão FATE em *Learning Analytics*

Como se observa, a dimensão ética concentra o maior número de indicadores distintos (4), refletindo a complexidade dos aspectos legais, sociais e epistemológicos envolvidos. As demais dimensões (equidade, responsabilidade e transparência) também apresentam indicadores robustos e recorrentes, evidenciando a demanda de abordagens integradas para assegurar práticas educacionais justas, auditáveis e compreensíveis. Dessa forma, os indicadores-chave não apenas

qualificam as ferramentas de *Learning Analytics* sob o ponto de vista técnico, mas também revelam o grau de compromisso ético apresentado nos estudos analisados, funcionando como elementos fundamentais para orientar práticas educacionais mais justas, transparentes e responsáveis.

#### **4.6 Decisões Pedagógicas Baseadas em *Learning Analytics* e seus Efeitos para Stakeholders**

A análise dos estudos revelou que as decisões pedagógicas informadas por sistemas de *Learning Analytics* afetam diretamente múltiplos stakeholders no contexto educacional. Para os professores, o uso de dashboards e relatórios pode apoiar ajustes metodológicos, identificação de dificuldades e intervenções direcionadas, desde que os dados sejam contextualizados e compreensíveis Andersen (2020); Gedrimiene et al. (2020). Entretanto, quando os sistemas carecem de explicabilidade ou operam com dados invejados, há riscos de reforço de estereótipos ou decisões equivocadas sobre o desempenho discente (Khalil, Prinsloo & Slade, 2023; Bayer, Hlosta & Fernandez, 2021).

Os estudantes também são fortemente impactados, já que especificamente o foco principal das interpretações oriundas dos dados. Quando bem inovadoras, as ferramentas de LA podem apoiar recomendações personalizadas e promover trajetórias mais equitativas. Além disso, experiências com tecnologias educacionais, como as trilhas de aprendizagem com Realidade Aumentada planejadas por Kwong, Wong e Yue (2017), mostram que decisões éticas tomadas pelos estudantes em cenários simulados direcionados para a internalização prática de conceitos abstratos de integridade, promovendo ações mais conscientes no ambiente educacional. No entanto, estudos como o de Sha, Gašević e Chen (2023) alertam para os riscos de vidas preditivas caso os dados não considerem as múltiplas dimensões da desigualdade. Estudos mostram que, mesmo partindo de estados iniciais de baixa produtividade, os alunos tendem a evoluir de forma estável quando engajados em atividades colaborativas abertas com apoio analítico, o que reforçam o papel dos dados no mapeamento de trajetórias de aprendizagem (Nasir et al., 2022). Resultados semelhantes foram identificados por Fan et al. (2022), que ao analisar o comportamento de estudantes que refizeram um MOOC, identificaram mudanças estratégicas associadas a melhorias significativas no desempenho, representam o potencial do uso de *Learning Analytics* para apoiar a regulação das estratégias de aprendizagem.

Já os gestores educacionais utilizam dados analíticos para decisões administrativas, como alocação de recursos, revisão de políticas internacionais e planejamento institucional. Para que essas decisões promovam maior equidade e justiça educacional, é necessário que se baseiem em indicadores éticos sólidos e na participação dos usuários na definição de critérios (Pargman et al., 2023; Gedrimiene et al., 2023).

Assim, a literatura revisada nos mostra a importância de se envolver professores, estudantes e gestores na concepção, uso e avaliação das ferramentas de LA, promovendo uma construção coletiva das decisões pedagógicas e garantindo alinhamento com os princípios de justiça e responsabilidade (Khalil, Prinsloo & Slade, 2023; Knight et al., 2025).

## **5 Discussão**

A partir dos resultados obtidos no Mapeamento Sistemático da Literatura, foram identificados insumos importantes sobre a implementação ética de ferramentas de LA em contextos educacionais. ao cruzar esses resultados, percebe-se que a implementação das ferramentas de LA

está diretamente ligada aos desafios de Justiça, Responsabilidade, Transparência e Ética, afetando de maneira distinta estudantes, professores e gestores, sendo que a privacidade e a ética foram as maiores preocupações identificadas, seguidas por dificuldades tecnológicas e desafios na equidade e inclusão. Slade e Prinsloo (2013) acentuam a importância da transparência e da explicabilidade nos processos, pois sem essas práticas a proteção dos dados dos estudantes pode ser comprometida, ao mesmo tempo, Verbert et al. (2013) sugerem auditorias algorítmicas regulares para confirmar que os sistemas de LA não reforcem desigualdades e favoreçam apenas determinados grupos de alunos.

Os estudantes são os mais impactados pelo uso dessas ferramentas, e a equidade se reflete diretamente no acesso e na adequação dos sistemas às diferentes realidades educacionais, sendo que algumas abordagens analisadas no mapeamento apontam para estratégias de mitigação de viés e aprimoramento da justiça nas recomendações algorítmicas, no entanto, ainda há uma lacuna na adoção generalizada dessas práticas, o que pode comprometer a imparcialidade das análises e ampliar as desigualdades no aprendizado. Professores e educadores também são afetados, já que a forma como interpretam e aplicam os dados gerados pelos sistemas influencia diretamente suas práticas pedagógicas e a tomada de decisão em sala de aula, sendo essencial que tenham acesso a informações claras e ferramentas que lhes permitam agir de forma crítica sobre os resultados apresentados.

A transparência das ferramentas foi apontada como um fator essencial para testificar que os professores compreendam como as análises são realizadas e quais critérios orientam as recomendações feitas aos alunos, permitindo que utilizem os sistemas com mais segurança e autonomia. Han, Wei e Zhang (2015) salientam que a clareza na apresentação dos dados é fundamental para que os docentes possam confiar nas ferramentas e aplicá-las de forma eficaz no planejamento das aulas, todavia, a falta de transparência pode gerar insegurança e limitar a aceitação dessas tecnologias no ambiente escolar, tornando-se um obstáculo para sua adoção em larga escala.

A responsabilidade na gestão dos dados educacionais foi uma preocupação recorrente, especialmente em associação à privacidade dos estudantes e ao cumprimento de regulamentações como o GDPR, sendo que muitos professores apresentaram a relevância de políticas institucionais bem definidas que garantam um uso seguro e ético dos dados coletados. Tumilty et al. (2022) reforça a importância de mecanismos de anonimização para proteger as informações dos alunos e evitar o uso indevido dos dados, enquanto Yang et al. (2021) citam que a implementação de medidas de governança claras pode evitar abusos e assegurar que as ferramentas de LA sejam utilizadas de maneira alinhada com princípios éticos e pedagógicos. A análise dos indicadores-chave mostrou a necessidade de assegurar a qualidade da literatura utilizada, a relevância dos modelos de IA aplicados e a transparência dos sistemas implementados. Han, Wei e Zhang (2015) enfatizam a importância de uma literatura de qualidade e a relevância dos modelos de IA e assim atestar a eficácia dos sistemas de LA.

No contexto brasileiro, aponta-se o trabalho de Kelvin et al. (2021), que investiga as percepções de estudantes sobre o uso de dados educacionais em uma instituição pública. Os autores evidenciam que a aceitação de sistemas de *Learning Analytics* depende diretamente da transparência na gestão das informações e da existência de políticas institucionais claras, que assegurem a responsabilidade pelo uso ético dos dados. Esse estudo contribui para a compreensão de que a implementação dos princípios de FATE requer não apenas aspectos técnicos, mas também um compromisso institucional com a escuta ativa dos sujeitos impactados, especialmente em realidades educacionais marcadas pela diversidade e pela desigualdade.

Destacamos também a importância de certificar a responsabilidade no manejo de dados e algoritmos, assegurando que os resultados produzidos sejam justos e equitativos, e que os dados

dos estudantes estejam devidamente protegidos. Vasquez Verdugo et al. (2022) sugerem que a responsabilidade no manejo de dados é essencial para segurar justiça e a equidade nos resultados dos sistemas de LA.

Os dados também revelaram uma preocupação significativa com a proteção da privacidade dos estudantes. Muitos professores mencionaram a demanda de conformidade estrita com regulamentos de proteção de dados, como o GDPR, e defenderam práticas de anonimização dos dados. Tumilty et al. (2022) destacam a importância dessas práticas para proteger a privacidade dos estudantes quanto à conformidade com os regulamentos de proteção de dados. A questão da responsabilidade foi fortemente ligada à necessidade de haver políticas institucionais claras e medidas de governança para gerenciar os dados educacionais de maneira ética e segura. Yang et al. (2021) enfatizam a precisão de políticas institucionais claras para assegurar a governança ética dos dados educacionais.

O presente artigo se sobressai em comparação a outras revisões recentes ao abordar de maneira detalhada os aspectos de Justiça, Responsabilidade, Transparência e Ética em LA. Diferente de trabalhos como o de Tsai et al. (2019), que aborda questões éticas de forma mais ampla, este artigo se concentra especificamente nos quatro pilares de FATE, explorando seu impacto direto em professores e estudantes. Ademais, a metodologia rigorosa, com critérios de avaliação de qualidade e consistência entre revisores, representa outro diferencial em comparação a revisões anteriores, que frequentemente tratam esses aspectos de forma mais subjetiva. O artigo oferece uma análise crítica das ferramentas e métodos tecnológicos usados nos estudos, apresentando suas aplicações em diferentes contextos educacionais e as implicações éticas associadas. Assim, este artigo avança na discussão sobre práticas éticas em LA ao integrar e detalhar esses princípios de maneira inovadora. Assim, este artigo contribui de forma significativa para o avanço das discussões sobre ética em Learning Analytics ao articular, com base empírica e crítica, os quatro pilares de FATE.

Ao contrário de revisões que tratam o tema de forma abstrata ou prescritiva, o presente estudo oferece uma análise integrada e situada, instruindo como justiça, transparência e responsabilidade podem (ou não) ser operacionalizadas em práticas pedagógicas concretas.

## 6 Limitações e Ameaças à Validade

Este estudo contribui para a compreensão das interseções entre *Learning Analytics* e os princípios de Justiça, Responsabilidade, Transparência e Ética, mas apresenta limitações que devem ser consideradas. A principal delas é a abrangência e representatividade das fontes no mapeamento sistemático da literatura, uma vez que a seleção foi restrita a cinco bases de dados principais, podendo excluir estudos relevantes de outros repositórios ou idiomas. Dessa maneira o processo de exclusão de artigos, baseado na aderência aos critérios de inclusão, pode ter deixado de fora trabalhos que, embora não diretamente relacionados, poderiam oferecer insights consideráveis sobre a aplicação de FATE em LA. Para amenizar esse risco, foram adotadas revisões por pares e a avaliação de um terceiro pesquisador em caso de divergência, assegurando maior rigor e imparcialidade na seleção.

Outra limitação é a dependência de palavras-chave específicas na busca, que pode ter restringido a identificação de estudos com abordagens éticas sob outras denominações ou *frameworks*, resultando em uma sub-representação de perspectivas alternativas. Finalmente, a evolução contínua do campo de LA representa uma ameaça à validade externa, já que mudanças tecnológicas e novas diretrizes éticas podem tornar os achados deste estudo obsoletos.

rapidamente. Sendo assim, aconselha-se a replicação do estudo com a atualização das práticas e diretrizes mais recentes para manter sua relevância.

## 7 Considerações Finais

As considerações finais deste mapeamento sistemático apontam para a relevância das pesquisas e iniciativas na área de *Learning Analytics* e sua conexão com os princípios de “Justiça, Responsabilidade, Transparência e Equidade”. O objetivo central foi mapear o estado atual das práticas de LA, oferecendo subsídios para que educadores e pesquisadores integrem questões éticas e operacionais em suas abordagens.

Os resultados mostram que os sistemas de LA têm potencial para melhorar o processo de ensino e aprendizagem, mas ainda enfrentam desafios relacionados aos princípios éticos. A implementação de auditorias, maior transparência nos processos analíticos e proteção dos dados são medidas fundamentais para minimizar preocupações. Estudos como os de L. Zhang et al. (2020) evidenciam a necessidade de práticas sistemáticas para uma aplicação responsável e ética das ferramentas de LA. Com isso, a análise realizada possibilitou responder às três questões de pesquisa, contribuindo com insights sobre como essas ferramentas podem promover ambientes educacionais mais justos, éticos e eficazes.

Uma das principais contribuições deste mapeamento está na ênfase ao papel dos professores no uso de LA. É essencial que esses profissionais sejam apoiados para que tomem decisões pedagógicas alinhadas aos princípios de FATE. A formação e o suporte técnico adequados podem fortalecer a capacidade dos professores de interpretar dados e ajustar suas práticas de ensino com base em análises responsáveis e transparentes. Essa perspectiva também dialoga com a proposta do trabalho de mestrado, que busca aprofundar a conexão entre o uso de LA e a promoção de práticas pedagógicas mais justas e éticas.

Embora a maioria dos estudos analisados reconheça a importância dos princípios de Justiça, Responsabilidade, Transparência e Ética, observou-se que poucos apresentam uma análise sistemática dos impactos concretos decorrentes de sua implementação. Em grande parte, as contribuições permanecem no nível descritivo ou normativo, sem evidências empíricas consistentes sobre mudanças reais em práticas pedagógicas, políticas institucionais ou percepções dos usuários. Essa lacuna evidencia a importância de futuras investigações que não apenas proponham diretrizes éticas, mas também avaliem seus efeitos no cotidiano educacional, contribuindo para uma aplicação mais eficaz e responsiva dos princípios de FATE em ambientes de *Learning Analytics*.

Para avançar neste campo, é fundamental adaptar as práticas de LA às especificidades de diferentes disciplinas e contextos educacionais. Personalizar os ambientes de aprendizagem e alinhar os objetivos pedagógicos às carências dos estudantes pode maximizar o impacto positivo dessas ferramentas. Pesquisas futuras devem explorar como as metodologias de LA podem ser aplicadas em diferentes realidades e investigar suas implicações éticas de maneira mais aprofundada. Também é significativo examinar o impacto dessas ferramentas no comportamento de estudantes e professores, promovendo uma integração mais efetiva no ambiente educacional.

Explorar a influência de estereótipos nas práticas pedagógicas com o uso de LA e inteligência artificial é um caminho próspero. Essa abordagem pode contribuir para práticas educacionais mais inclusivas e equitativas, alinhadas aos princípios de FATE, proporcionando um impacto positivo na construção de uma educação mais justa e ética.

## Referências

- Andersen, I. G. (2020). What went wrong? Examining teachers' data use and instructional decision making through a bottom-up data intervention in Denmark. *International Journal of Educational Research*, 102, 101585. <https://doi.org/10.1016/j.ijer.2020.101585>. [GS Search]
- Bayer, V., Hlosta, M., & Fernandez, M. (2021). Learning Analytics and Fairness: Do Existing Algorithms Serve Everyone Equally? *Lecture Notes in Computer Science (including sub-series Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12749 LNAI, 71–75. [https://doi.org/10.1007/978-3-030-78270-2\\_12](https://doi.org/10.1007/978-3-030-78270-2_12). [GS Search]
- Chen, B., & Poquet, O. (2022). Networks in Learning Analytics: Where Theory, Methodology, and Practice Intersect. *Journal of Learning Analytics*, 9, 1–12. <https://doi.org/10.18608/jla.2022.7697>. [GS Search]
- Cheng, E. C. K., & Wang, T. (2023). Leading digital transformation and eliminating barriers for teachers to incorporate artificial intelligence in basic education in Hong Kong. *Computers and Education: Artificial Intelligence*, 5, 100171. <https://doi.org/10.1016/j.caeai.2023.100171>. [GS Search]
- Cox, A. (2022). The Ethics of AI for Information Professionals: Eight Scenarios. *Journal Of The Australian Library And Information Association*, 71, 201–214. <https://doi.org/10.1080/24750158.2022.2084885>. [GS Search]
- Dermeval, D., Vilela, J., Bittencourt, I. I., Castro, J., Isotani, S., Brito, P., & Silva, A. (2016). Applications of ontologies in requirements engineering: a systematic review of the literature. *Requirements Engineering*, 21, 405–437. <https://doi.org/10.1007/s00766-015-0222-6>. [GS Search]
- Dillenbourg, P. (1999). What do you mean by collaborative learning? Collaborative- learning: Cognitive and computational approaches., 1–19. [GS Search]
- Duin, A. H., & Tham, J. (2020). The Current State of Analytics: Implications for Learning Management System (LMS) Use in Writing Pedagogy. *Computers and Composition*, 55, 102544. <https://doi.org/10.1016/j.compcom.2020.102544>. [GS Search]
- Fan, Y., Jovanović, J., Saint, J., Jiang, Y., Wang, Q., & Gašević, D. (2022). Revealing the regulation of learning strategies of MOOC retakers: A learning analytic study. *Computers & Education*, 178, 104404. <https://doi.org/10.1016/j.compedu.2021.104404>. [GS Search]
- Gedrimiene, E., Celik, I., Mäkitalo, K., & Muukkonen, H. (2023). Transparency and Trustworthiness in User Intentions to Follow Career Recommendations from a Learning Analytics Tool. *Journal of Learning Analytics*, 10, 54–70. <https://doi.org/10.18608/jla.2023.7791>. [GS Search]
- Gedrimiene, E., Silvola, A., Pursiainen, J., Rusanen, J., & Muukkonen, H. (2020). Learning Analytics in Education: Literature Review and Case Examples From Vocational Education. *Scandinavian Journal of Educational Research*, 64, 1105–1119. <https://doi.org/10.1080/00313831.2019.1649718>. [GS Search]
- Haderer, B., & Ciolacu, M. (2022). Education 4.0: Artificial Intelligence Assisted Task and Time Planning System. *Procedia Computer Science*, 200, 1328–1337. <https://doi.org/10.1016/j.procs.2022.01.334>. [GS Search]

- Han, Y., Wei, S., & Zhang, S. (2015). Analysis of online learning behavior from a tutor's perspective: Reflections on interactive teaching and learning in the era of big data. *Asian Association of Open Universities Journal*, 10(2), 29–48. <https://doi.org/10.1108/AAOUJ-10-02-2015-B004>. [GS Search]
- Hakami, E., & Hernandez-Leo, D. (2021). Teachers' views about the impact of Learning Design Community platforms on Well-being. SIIE 2021 - 2021 International Symposium on Computers in Education. <https://doi.org/10.1109/SIIE53363.2021.9583651>. [GS Search]
- Hakimi, L., Eynon, R., & Murphy, V. A. (2021). The Ethics of Using Digital Trace Data in Education: A Thematic Review of the Research Landscape. *REVIEW OF EDUCATIONAL RESEARCH*, 91, 671–717. <https://doi.org/10.3102/00346543211020116>. [GS Search].
- Herodotou, C., Maguire, C., McDowell, N., Hlosta, M., & Boroowa, A. (2021). The engagement of university teachers with predictive learning analytics. *Computers Education*, 173, 104285. <https://doi.org/10.1016/j.compedu.2021.104285>. [GS Search]
- Hertweck, C., Castillo, C., & Mathioudakis, M. (2022). Designing Affirmative Action Policies under Uncertainty. *Journal Of Learning Analytics*, 9, 121–137. <https://doi.org/10.18608/jla.2022.7463>. [GS Search]
- Hooshyar, D., Pedaste, M., Saks, K., Leijen, Ä., Bardone, E., & Wang, M. (2020). Open learner models in supporting self-regulated learning in higher education: A systematic literature review. *Computers Education*, 154, 103878. <https://doi.org/10.1016/j.compedu.2020.103878>. [GS Search]
- Howell, J. A., Roberts, L. D., & Mancini, V. O. (2018). Learning analytics messages: Impact of grade, sender, comparative information and message style on student affect and academic resilience. *Computers in Human Behavior*, 89, 8–15. <https://doi.org/10.1016/j.chb.2018.07.021>. [GS Search]
- Khalil, M., Prinsloo, P., & Slade, S. (2023). Fairness, Trust, Transparency, Equity, and Responsibility in Learning Analytics. *Journal of Learning Analytics*, 10, 1–7. <https://doi.org/10.18608/jla.2023.798>. [GS Search]
- Khosravi, H., Shum, S. B., Chen, G., Conati, C., Tsai, Y.-S., Kay, J., Knight, S., Maldonado, R. M., Sadiq, S., & Gašević, D. (2022). Explainable Artificial Intelligence in education. *Computers and Education: Artificial Intelligence*, 3, 100074. <https://doi.org/10.1016/j.caeai.2022.100074>. [GS Search]
- Kitto, K., & Knight, S. (2019). Practical ethics for building learning analytics. *British Journal of Educational Technology*, 50, 2855–2870. <https://doi.org/10.1111/bjet.12868>. [GS Search]
- Kelvin, T., Leandro, F., Fagundes, R., & Freitas, E. (2021). Políticas para Adoção de Learning Analytics: Uma Proposta Baseada nas Opiniões dos Estudantes. *Anais do XXXII Simpósio Brasileiro de Informática na Educação (SBIE 2021)*, p. 885–896. <https://doi.org/10.5753/sbie.2021.218599>. [GS Search]
- Krupiy, T. (2020). A vulnerability analysis: Theorising the impact of artificial intelligence decision-making processes on individuals, society and human diversity from a social justice perspective. *Computer Law Security Review*, 38, 105429. <https://doi.org/10.1016/j.clsr.2020.105429>. [GS Search]
- Kurilovas, E. (2020). On data-driven decision-making for quality education. *Computers in Human Behavior*, 107, 105774. [GS Search]



- Kwong, T., Wong, E., & Yue, K. (2017). Bringing Abstract Academic Integrity and Ethical Concepts into Real-Life Situations. *Technology, Knowledge and Learning*, 22, 353– 368. <https://doi.org/10.1007/s10758-017-9321-7> [GS Search]
- Lee, H. H., & Gargroetzi, E. C. (2023). It's like a double-edged sword? Mentor Perspectives on Ethics and Responsibility in a Learning Analytics-Supported Virtual Mentoring Program. *Journal Of Learning Analytics*, 10, 85–100. <https://doi.org/10.18608/jla.2023.7787>. [GS Search]
- Leeuwen, A. v., & Janssen, J. (2019). A systematic review of teacher guidance during collaborative learning in primary and secondary education. *Educational Research Review*, 27, 71–89. <https://doi.org/10.1016/j.edurev.2019.02.001>. [GS Search]
- Leeuwen, A. v., Janssen, J., Erkens, G., & Brekelmans, M. (2014). Supporting teachers in guiding collaborating students: Effects of learning analytics in CSCL. *Computers Education*, 79, 28-39. <https://doi.org/10.1016/j.compedu.2014.07.007>. [GS Search]
- Marras, M., Boratto, L., Ramos, G., & Fenu, G. (2022). Equality of Learning Opportunity via Individual Fairness in Personalized Recommendations. *International Journal of Artificial Intelligence in Education*, 32, 636–684. <https://doi.org/10.1007/s40593-021-00271-1>. [GS Search]
- Mathrani, A., Susnjak, T., Ramaswami, G., & Barczak, A. (2021). Perspectives on the challenges of generalizability, transparency and ethics in predictive learning analytics. *Computers and Education Open*, 2, 100060. <https://doi.org/10.1016/j.cao.2021.100060>. [GS Search]
- May, M., Iksal, S., & Usener, C. A. (2017). The side effect of learning analytics: An empirical study on e-learning technologies and user privacy. *Communications in Computer and Information Science*, 739, 279–295. [GS Search]
- Memarian, B., & Doleck, T. (2023). Fairness, Accountability, Transparency, and Ethics (FATE) in Artificial Intelligence (AI) and Higher Education: A systematic review. *Computers and Education: Artificial Intelligence*, 5, 100152. <https://doi.org/10.1016/j.caeai.2023.100152>. <https://doi.org/10.1016/j.caeai.2023.100152>. [GS Search]
- Nasir, J., Abderrahim, M., Kothiyal, A., & Dillenbourg, P. (2022). Temporal pathways to learning: How learning emerges in an open-ended collaborative activity. *Computers and Education: Artificial Intelligence*, 3, 100093. <https://doi.org/10.1016/j.caeai.2022.100093>. [GS Search]
- Ouyang, F., & Jiao, P. (2021). Artificial intelligence in education: The three paradigms. *Computers and Education: Artificial Intelligence*, 2, 100020. <https://doi.org/10.1016/j.caeai.2021.100020>. [GS Search]
- Pargman, T. C., McGrath, C., Viberg, O., & Knight, S. (2023). New Vistas on Responsible Learning Analytics: A Data Feminist Perspective. *Journal of Learning Analytics*, 10, 133-148. <https://doi.org/10.18608/jla.2023.7781>. [GS Search]
- Parsons, T. D. (2021). Ethics and educational technologies. *Educational Technology Research and Development*, 69, 335–338. <https://doi.org/10.1007/s11423-020-09846-6>. [GS Search]
- Prinsloo, P., & Slade, S. (2017). Building the learning analytics curriculum: Should we teach (a code of) ethics? *CEUR Workshop Proceedings*, 1915. [GS Search]
- Rachha, A., & Seyam, M. (2023). Explainable AI In Education: Current Trends, Challenges, And Opportunities. *Conference Proceedings - IEEE SOUTHEASTCON*, 2023-April, 232–239. <https://doi.org/10.1109/SoutheastCon51012.2023.10115140>. [GS Search]



- Ranjeeth, S., Latchoumi, T., & Paul, P. V. (2020). A Survey on Predictive Models of Learning Analytics. *Procedia Computer Science*, 167, 37–46. [GS Search]
- Savi, A. O., van Klaveren, C., & Cornelisz, I. (2023). Combating effort avoidance in computer adaptive practicing: Does a problem-skipping restriction promote learning? *Computers Education*, 206, 104908. <https://doi.org/10.1016/j.compedu.2023.104908>. [GS Search]
- Sha, L., Gašević, D., & Chen, G. (2023). Lessons from debiasing data for fair and accurate predictive modeling in education. *Expert Systems with Applications*, 228, 120323. <https://doi.org/10.1016/j.eswa.2023.120323>. [GS Search]
- Sharma, K., & Giannakos, M. (2021). Sensing technologies and child computer interaction: Opportunities, challenges and ethical considerations. *International Journal of Child Computer Interaction*, 30, 100331. <https://doi.org/10.1016/j.ijcci.2021.100331> [GS Search]
- Shibani, A., Knight, S., & Buckingham Shum, S. (2020). Educator perspectives on learning analytics in classroom practice. *The Internet and Higher Education*, 46, 100730. <http://dx.doi.org/10.1016/j.iheduc.2020.100730>. [GS Search]
- Shiyan, P., Lai, S., Zhang, A., Yang, Y., & Sun, D. (2023). Graph convolutional network for automatic detection of teachers' nonverbal behavior. *Computers and Education: Artificial Intelligence*, 100174. <https://doi.org/10.1016/j.caeai.2023.100174>. [GS Search]
- Siemens, G., & Baker, R. S. (2012). Learning analytics and educational data mining: towards communication and collaboration. *Proceedings of the 2nd international conference on learning analytics and knowledge*, 252–254. <https://doi.org/10.1145/2330601.2330661>. [GS Search]
- Slade, S., & Prinsloo, P. (2013). Learning Analytics: Ethical Issues and Dilemmas. *American Behavioral Scientist*, 57, 1510–1529. <https://doi.org/10.1177/0002764213479366>. [GS Search]
- Tambouris, E., Hermans, P., Tarrant, D., Zotou, M., & Tarabanis, K. (2018). Using problem-based learning and learning analytics in open data education. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3209281.3209342>. [GS Search]
- Tumilty, E., Spratt, H., Cestone, C., Wooten, K., Aronson, J., Hommel, J., Hellmich, M. R., & Chao, C. (2022). Developing future translational scientists through authentic learning and assessments. *International Journal of Educational Research Open*, 3, 100151. <https://doi.org/10.1016/j.ijedro.2022.100151>. [GS Search]
- Tsai, Yi-Shan & Perrotta, Carlo & Gasevic, Dragan. (2019). Empowering learners with personalised learning approaches? Agency, equity and transparency in the context of learning analytics. *Assessment & Evaluation in Higher Education*. 45. 1-14. <https://doi.org/10.1080/02602938.2019.1676396>. [GS Search]
- Van Barneveld, A., Arnold, K. E., & Campbell, J. P. (2012). Analytics in higher education: Establishing a common language. *EDUCAUSE learning initiative*, 1(1), 1–11. [GS Search]
- Vasquez Verdugo, J., Gitiaux, X., Ortega, C., & Rangwala, H. (2022). FairEd: A Systematic Fairness Analysis Approach Applied in a Higher Educational Context. *12th Annual International Conference on Learning Analytics and Knowledge (LAK)*, 271–281. <https://doi.org/10.1145/3506860.3506902>. [GS Search]
- Veljanova, H., Barreiros, C., Gosch, N., Staudegger, E., Ebner, M., & Lindstaedt, S. (2023). Operationalising Transparency as an Integral Value of Learning Analytics Systems - From Ethical and Data Protection to Technical Design Requirements. *Lecture Notes in Computer*

- Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 14040 LNCS, 546–562. [https://doi.org/10.1007/978-3-031-34411-4\\_37](https://doi.org/10.1007/978-3-031-34411-4_37). [GS Search]
- Verbert, K., Duval, E., Klerkx, J., Govaerts, S., & Santos, J. L. (2013). Learning analytics dashboard applications. *American Behavioral Scientist*, 57(10), 1500–1509. <https://doi.org/10.1177/0002764213479363>. [GS Search]
- Wise, A. F., Knight, S., & Ochoa, X. (2021). What Makes Learning Analytics Research Matter. *Journal of Learning Analytics*, 8, 1–9. <https://doi.org/10.18608/jla.2021.7647>. [GS Search]
- Yang, S. J., Ogata, H., Matsui, T., & Chen, N.-S. (2021). Human-centered artificial intelligence in education: Seeing the invisible through the visible. *Computers and Education: Artificial Intelligence*, 2, 100008. <https://doi.org/10.1016/j.caeai.2021.100008>. [GS Search]
- Zhang, K., & Aslan, A. B. (2021). AI technologies for education: Recent research future directions. *Computers and Education: Artificial Intelligence*, 2, 100025. <https://doi.org/10.1016/j.caeai.2021.100025>. [GS Search]
- Zhang, L., Basham, J. D., & Yang, S. (2020). Understanding the implementation of personalized learning: A research synthesis. *Educational Research Review*, 31, 100339. <https://doi.org/10.1016/j.edurev.2020.100339>. [GS Search]