

A SALA DE AULA INVISÍVEL: DADOS, ALGORITMOS E DECISÕES QUE MOLDAM A EDUCAÇÃO

THE INVISIBLE CLASSROOM: DATA, ALGORITHMS AND DECISIONS SHAPING EDUCATION

**Thiago Cosin, Doutorando em
Educação em Ciências e Matemática
pela Universidade Federal do Paraná
(UFPR). Mestre em Educação pela
Universidade Estadual Paulista
(UNESP), cosin.tc@gmail.com¹**

Resumo: A crescente incorporação de plataformas digitais e sistemas algorítmicos à educação amplia não apenas as possibilidades de ensino e aprendizagem, mas também os processos de coleta, classificação e interpretação de dados sobre estudantes. Este artigo objetiva analisar como a dataficação, a analítica da aprendizagem, a classificação, a recomendação e a predição introduzem novas mediações nas decisões educacionais, propondo a noção de sala de aula invisível como lente teórico-analítica para compreender esses processos. Trata-se de uma pesquisa qualitativa, bibliográfica e teórico-conceitual, desenvolvida por meio de revisão narrativa de produções sobre platformização, Learning Analytics, predição de desempenho, personalização, vieses e mediação docente. A análise evidenciou um percurso no qual registros digitais podem ser convertidos em indicadores, perfis, classificações, previsões, recomendações e intervenções. Os resultados indicam que tais processos podem favorecer acompanhamento e intervenções precoces, mas também produzir opacidade, vieses e naturalização de classificações como verdades pedagógicas. Conclui-se que dados e algoritmos podem apoiar decisões educacionais, porém seus resultados devem permanecer submetidos à interpretação, à contextualização e ao julgamento humano, preservando a possibilidade de revisão e contestação das classificações produzidas.

Palavras-chave: Dataficação. Learning Analytics. Plataformização. Personalização da aprendizagem. Mediação docente.

Abstract: The growing incorporation of digital platforms and algorithmic systems into

education expands not only teaching and learning possibilities but also the processes of collecting, classifying, and interpreting student data. This article aims to analyze how datafication, learning analytics, classification, recommendation, and prediction introduce new forms of mediation into educational decision-making, proposing the concept of the invisible classroom as a theoretical and analytical lens for understanding these processes. This is a qualitative, bibliographic, and theoretical-conceptual study developed through a narrative review of publications addressing platformization, learning analytics, performance prediction, personalization, algorithmic bias, and teacher mediation. The analysis revealed a process in which digital records can be transformed into indicators, profiles, classifications, predictions, recommendations, and interventions. The findings indicate that these processes may support student monitoring and early intervention, while also generating opacity, bias, and the risk of treating classifications as unquestionable pedagogical truths. The study concludes that data and algorithms can support educational decisions, but their outputs must remain subject to interpretation, contextualization, and human judgment, preserving the possibility of reviewing and challenging the classifications produced.

Keywords: Datafication. Learning Analytics. Platformization. Learning personalization. Teacher mediation.

1 INTRODUÇÃO

A presença das tecnologias digitais na educação não pode mais ser compreendida apenas pela utilização de computadores, plataformas, aplicativos ou sistemas de Inteligência Artificial. À medida que parte crescente das experiências educacionais ocorre em ambientes digitais, ações realizadas por professores e estudantes deixam registros que podem ser coletados, organizados e analisados. Acessos,

respostas, tempo de interação, desempenho e padrões de navegação tornam-se dados capazes de subsidiar interpretações sobre os processos de aprendizagem.

Esse movimento relaciona-se à plataformização e à dataficação da educação. Plataformas digitais não funcionam somente como suportes para atividades pedagógicas, pois suas arquiteturas estabelecem formas de registro, organização e visualização das interações. No contexto brasileiro, pesquisas apontam implicações relacionadas à gestão orientada por dados, às avaliações algoritmizadas, à privacidade das informações e à autonomia pedagógica (Matta; Ribeiro; Pamplona, 2025; Costa; Silva, 2026; Andrade; Gobbi, 2026).

Uma das manifestações desse processo encontra-se na Learning Analytics, que utiliza dados provenientes das atividades educacionais para identificar padrões, construir perfis, acompanhar desempenhos e subsidiar intervenções. Suas aplicações incluem personalização, classificação e modelos preditivos capazes de estimar dificuldades ou desempenhos futuros (Gonçalves; Nunes, 2022; Gonzalez; Chiappe, 2024). Pesquisas brasileiras já

demonstram aplicações destinadas à identificação precoce de estudantes em risco de reprovação e à predição de desempenho a partir de registros produzidos em ambientes digitais (Souza; Dutra; Fernandes, 2022; Coelho *et al.*, 2023).

Essas possibilidades podem contribuir para o acompanhamento dos estudantes e para intervenções pedagógicas mais precoces. Entretanto, introduzem uma questão que ultrapassa a eficiência técnica dos sistemas: o que acontece quando dados produzidos sobre um estudante passam a participar das decisões tomadas a respeito de seu percurso educacional? A questão torna-se particularmente relevante diante da possibilidade de vieses nos dados e nos processos automatizados, bem como da pouca transparência dos critérios empregados por determinadas plataformas (Heggler; Szmoski; Miquelin, 2025; Costa; Ojeda; Lopes, 2025).

A relevância dessa discussão está no fato de que a mediação algorítmica pode ocorrer sem assumir a forma explícita de uma decisão. Ao ordenar informações, estabelecer categorias ou indicar possibilidades consideradas mais adequadas a determinado perfil, sistemas digitais

participam das condições em que escolhas educacionais são realizadas. Assim, compreender a presença dessas tecnologias exige examinar não apenas aquilo que aparece nas interfaces, mas também os critérios e processos que operam em sua infraestrutura.

Nesse contexto, este artigo propõe a noção de sala de aula invisível como lente analítica para compreender o conjunto de processos de coleta, classificação, recomendação e predição mediados por sistemas digitais que podem interferir nas experiências educacionais sem necessariamente se apresentarem aos sujeitos como decisões pedagógicas. Ao lado da sala de aula visível, constituída por professores, estudantes, currículos, atividades e avaliações, configura-se uma camada menos perceptível formada por dados, métricas, perfis, classificações, recomendações e previsões.

Diante disso, o estudo é orientado pela seguinte questão: quais decisões educacionais passam a ser mediadas por sistemas digitais e algorítmicos sem que professores e estudantes necessariamente percebam essa mediação? O objetivo é analisar como processos de dataficação, classificação, recomendação e predição

introduzem novas mediações nas decisões educacionais e propor a sala de aula invisível como lente conceitual para sua compreensão. Não se pretende rejeitar dados ou sistemas algorítmicos, mas discutir criticamente como aquilo que produzem passa a participar da interpretação dos estudantes e das possibilidades educacionais que lhes são oferecidas.

2 APORTE TEÓRICO

2.1 Da experiência educacional à dataficação

A dataficação corresponde ao processo pelo qual acontecimentos, comportamentos e interações podem ser convertidos em informações digitais rastreáveis e analisáveis. Na educação, ambientes digitais ampliam essa possibilidade ao registrar diferentes ações realizadas pelos estudantes. Esses rastros podem subsidiar estratégias educacionais, mas também exigem competências para compreender como os dados foram produzidos, o que representam e quais limites possuem (Silva, 2025).

A plataformação intensifica esse processo ao incorporar infraestruturas digitais ao cotidiano das instituições. Nesse contexto,

plataformas não constituem ambientes neutros, pois participam da organização das interações, dos mecanismos de registro e das formas pelas quais determinadas informações se tornam visíveis e mensuráveis. Estudos brasileiros relacionam esse fenômeno à gestão orientada por dados, à dependência de métricas e algoritmos, ao monitoramento e à necessidade de proteção das informações educacionais (Costa; Silva, 2026; Costa; Ojeda; Lopes, 2025; Andrade; Gobbi, 2026).

A produção desses registros também amplia a capacidade de acompanhamento dos sujeitos pelas plataformas. Na Educação Superior, Balieiro e Azevedo (2026) observam que dados comportamentais produzidos nas interações digitais podem alimentar processos de monitoramento e construção de informações sobre desempenho, hábitos e comportamentos. Embora essa discussão esteja situada em outro nível de ensino, ela evidencia uma característica relevante da educação dataficação: quanto mais atividades são mediadas digitalmente, maior se torna a possibilidade de transformar experiências cotidianas em informações processáveis pelos sistemas (Balieiro; Azevedo, 2026).

A experiência educacional passa, assim, a possuir também uma representação produzida a partir de dados. Essa representação pode ampliar as possibilidades de acompanhamento, mas não equivale à totalidade do estudante nem das circunstâncias de sua aprendizagem. A questão adquire maior importância quando os registros deixam de apenas descrever acontecimentos e passam a sustentar classificações, recomendações e previsões.

Essa distinção impede que a representação produzida pelo sistema seja confundida com o próprio sujeito. Dados sobre frequência, respostas, desempenho ou interação descrevem dimensões específicas da experiência educacional, condicionadas pelos mecanismos de registro disponíveis. Desse modo, ampliar a quantidade de informações sobre o estudante não significa, necessariamente, ampliar na mesma proporção a compreensão de sua aprendizagem.

2.2 Analítica da aprendizagem, classificação e predição

A *Learning Analytics* utiliza a coleta e a análise de dados sobre estudantes e seus contextos para compreender e otimizar processos de

aprendizagem. Entre suas aplicações encontram-se monitoramento, construção de perfis, personalização, intervenção e modelos preditivos (Gonçalves; Nunes, 2022; Gonzalez; Chiappe, 2024).

No Brasil, diferentes pesquisas demonstram essa passagem do registro à inferência. Souza, Dutra e Fernandes (2022) utilizaram dados provenientes do Google Sala de Aula e do SUAP para identificar precocemente estudantes com elevada probabilidade de reprovação. Coelho *et al.* (2023) apresentam experiências envolvendo predição de desempenho e classificação da dificuldade de exercícios, enquanto Gonçalves e Nunes (2022) evidenciam possibilidades de utilização de modelos preditivos para identificar dificuldades e orientar intervenções.

Nesse sentido, a analítica da aprendizagem estabelece uma relação entre observação e intervenção. O valor atribuído aos registros digitais decorre justamente da possibilidade de utilizá-los para reconhecer padrões e produzir informações que subsidiem ações educacionais. Gonçalves e Nunes (2022) destacam que a análise desses dados pode oferecer evidências para decisões e intervenções, enquanto

Gonzalez e Chiappe (2024) relacionam a analítica à construção de perfis, ao acompanhamento e à personalização. O dado, portanto, não permanece necessariamente como memória do que aconteceu: pode adquirir função prospectiva na organização do que será feito posteriormente (Gonçalves; Nunes, 2022; Gonzalez; Chiappe, 2024).

A predição pode favorecer ações pedagógicas antes que dificuldades se consolidem. Contudo, há diferença entre registrar um desempenho já ocorrido e estimar um desempenho futuro. Uma previsão constitui uma inferência probabilística e não uma descrição definitiva do estudante. Quando classificações e previsões passam a orientar recomendações, intervenções ou oportunidades, aquilo que inicialmente representava a experiência anterior pode começar a participar das condições em que experiências futuras serão construídas.

Essa passagem exige cautela porque modifica o estatuto da informação produzida. Enquanto um indicador descreve determinado aspecto registrado, a predição trabalha com probabilidades construídas a partir de padrões identificados nos dados. Pedagogicamente, isso significa que a categoria atribuída ao estudante deve

permanecer provisória e revisável, sobretudo quando dela decorrerem intervenções que possam alterar seu percurso educacional.

2.3 Algoritmos, vieses e decisões educacionais

A utilização de sistemas algorítmicos requer considerar que classificações e previsões não são necessariamente neutras. Vieses podem estar presentes nos dados, na codificação e no processamento automatizado, produzindo consequências para estudantes e podendo reproduzir desigualdades existentes (Heggler; Szmoski; Miquelin, 2025).

Além disso, a opacidade das plataformas dificulta compreender como determinados conteúdos são selecionados, ordenados ou recomendados. Sistemas algorítmicos podem reorganizar visibilidades e oportunidades ao registrar ações, hierarquizar conteúdos e classificar desempenhos (Santos *et al.*, 2026). Em outros ambientes digitais, algoritmos também participam da seleção daquilo que os usuários acessam e consomem, evidenciando que a mediação pode ocorrer antes mesmo da escolha consciente do sujeito (Macedo; Borges,

2025).

A opacidade possui, nesse sentido, uma implicação pedagógica particular. Quando os critérios de ordenação, classificação ou recomendação não são suficientemente compreensíveis, professores e estudantes podem ter acesso ao resultado de uma operação sem conhecer integralmente o processo que o produziu. A literatura sobre plataformização chama atenção justamente para a falta de transparência das decisões algorítmicas e para os efeitos de estruturas orientadas por métricas sobre a educação (Costa; Ojeda; Lopes, 2025; Andrade; Gobbi, 2026). A questão da transparência, portanto, não se restringe ao funcionamento técnico do sistema, mas alcança a possibilidade de compreender e questionar os resultados que passam a circular no contexto educacional.

A questão educacional, portanto, não se limita a verificar se determinado algoritmo apresenta precisão técnica. É necessário considerar como seus resultados serão interpretados e utilizados. Uma probabilidade não constitui, por si mesma, uma decisão pedagógica. Entre aquilo que o sistema identifica e aquilo que será feito com essa informação permanece um espaço

de interpretação e responsabilidade humana. A literacia de dados torna-se relevante justamente para que professores possam compreender indicadores, interrogar seus limites e atribuir sentido pedagógico às informações disponibilizadas (Silva, 2025).

3 PERCURSO METODOLÓGICO

Este estudo caracteriza-se como pesquisa qualitativa, bibliográfica e teórico-conceitual, desenvolvida por meio de revisão narrativa da literatura. A escolha decorre do objetivo de analisar criticamente como dados, classificações, recomendações e previsões passam a integrar experiências educacionais e, a partir dessa articulação, delimitar a noção de sala de aula invisível.

O corpus foi constituído pelos documentos selecionados intencionalmente para a investigação em razão de sua aderência ao problema estudado, contemplando produções sobre dataficação, Learning Analytics, plataformização, personalização, predição de desempenho, governança algorítmica, vieses e mediação pedagógica. O material autoral da palestra A sala de aula invisível: dados, algoritmos e as

decisões que já estão moldando a educação foi utilizado como ponto de partida para a problematização e construção da categoria proposta.

A leitura ocorreu em duas etapas. Inicialmente, foram identificados objetivos, conceitos e resultados centrais das produções. Posteriormente, realizou-se análise interpretativa das relações entre produção de dados, construção de indicadores e perfis, classificação, predição, recomendação e intervenção. Também foram consideradas as tensões relacionadas à opacidade, aos vieses e à necessidade de interpretação humana.

A partir dessa análise, a sala de aula invisível foi construída como síntese conceitual para nomear uma camada de mediações formada por dados, métricas, perfis, classificações, previsões e recomendações que pode participar das experiências educacionais sem necessariamente ser percebida como parte da decisão pedagógica.

4 ANÁLISE E DISCUSSÃO

4.1 A sala de aula invisível como camada de mediação

Os estudos analisados permitem

observar uma transformação importante na presença das tecnologias na educação. A questão não se limita ao uso visível de determinada plataforma ou ferramenta, mas alcança processos que ocorrem em sua infraestrutura. Ao utilizar um ambiente digital, o estudante realiza ações que podem ser registradas e posteriormente transformadas em informações sobre seu comportamento ou desempenho. A dataficação, portanto, estabelece as condições para que parte da experiência educacional se torne mensurável (Silva, 2025).

A noção de sala de aula invisível procura nomear justamente essa camada. Ela não constitui outro espaço educacional, mas uma dimensão da própria experiência conectada na qual registros são transformados em interpretações capazes de participar das decisões. A invisibilidade não significa ausência de efeitos. Refere-se ao fato de que professores e estudantes podem visualizar a interface de uma plataforma sem necessariamente conhecer os processos de coleta, classificação e ordenamento que ocorrem em sua infraestrutura.

A invisibilidade proposta neste estudo possui, portanto, caráter relacional. Um processo pode ser

tecnicamente existente e operacionalmente ativo, mas pedagogicamente pouco perceptível para quem utiliza o sistema. O estudante visualiza uma recomendação, mas pode desconhecer por que ela lhe foi apresentada; o professor recebe um indicador, mas nem sempre conhece todas as variáveis utilizadas para produzi-lo. A invisibilidade não está na ausência do processo, mas na distância entre sua operação técnica e sua percepção pedagógica.

Nessa perspectiva, invisível não deve ser compreendido como sinônimo de secreto. Parte desses processos pode estar descrita em termos de uso, políticas de privacidade, painéis ou funcionalidades das próprias plataformas e, ainda assim, permanecer pouco perceptível no cotidiano pedagógico. O conceito refere-se menos à impossibilidade absoluta de acesso à informação e mais à dificuldade de reconhecer que operações aparentemente técnicas também participam da organização das experiências educacionais. Essa distinção é importante para evitar uma interpretação conspiratória da categoria: a sala de aula invisível não pressupõe uma tecnologia deliberadamente oculta, mas chama atenção para mediações

que podem ser naturalizadas justamente porque estão incorporadas ao funcionamento cotidiano das plataformas.

Essa interpretação encontra respaldo nos estudos sobre plataformização. Santos *et al.* (2026) destacam que sistemas digitais podem registrar ações, hierarquizar conteúdos, classificar desempenhos e antecipar preferências. Andrade e Gobbi (2026), por sua vez, mostram que a governança algorítmica introduz métricas e sistemas orientados por dados em processos educacionais e de gestão. A mediação tecnológica passa, portanto, a participar não somente da execução das atividades, mas também das condições em que determinadas informações ganham relevância.

4.2 Coletar, classificar, recomendar e prever

A análise do corpus permite organizar a sala de aula invisível a partir de quatro operações relacionadas entre si: coleta, classificação, recomendação e predição. A coleta ocorre quando interações e desempenhos deixam registros digitais. A classificação aparece quando esses registros são organizados em categorias, indicadores ou perfis. A recomendação utiliza

informações disponíveis para priorizar conteúdos, atividades ou possibilidades. A predição, por sua vez, emprega padrões anteriores para estimar resultados futuros.

Essas operações não ocorrem necessariamente em todos os sistemas nem obedecem a uma sequência fixa. Sua organização possui finalidade analítica. Estudos de *Learning Analytics* mostram que dados educacionais podem ser utilizados tanto para acompanhamento quanto para personalização, recomendação e predição (Gonçalves; Nunes, 2022; Gonzalez; Chiappe, 2024). Pesquisas empíricas demonstram ainda que modelos podem classificar estudantes de acordo com probabilidades relacionadas ao desempenho futuro (Souza; Dutra; Fernandes, 2022).

As quatro operações também apresentam questões pedagógicas distintas. Na coleta, importa perguntar quais dimensões da experiência se tornam dados e quais permanecem fora do registro. Na classificação, torna-se necessário compreender os critérios pelos quais registros são convertidos em categorias ou perfis. Na recomendação, a questão desloca-se para aquilo que é priorizado ou deixa de ser apresentado. Na predição,

finalmente, o desafio consiste em impedir que uma probabilidade sobre o futuro seja recebida como definição antecipada do sujeito.

O ponto crítico aparece quando a informação produzida retorna à experiência educacional. Um indicador pode provocar uma intervenção; uma classificação pode orientar acompanhamento; uma previsão pode sinalizar necessidade de apoio; uma recomendação pode modificar aquilo que será apresentado ao estudante. Nesse momento, o sistema deixa de apenas representar a experiência e passa a participar das condições em que ela continuará acontecendo.

Isso não significa que tais operações sejam pedagogicamente indesejáveis. A identificação precoce de dificuldades pode ampliar as possibilidades de intervenção e acompanhamento. O problema emerge quando classificações probabilísticas são tratadas como definições do sujeito ou quando seus critérios não podem ser compreendidos e questionados.

4.3 Quando prever também pode interferir

A predição constitui uma das dimensões mais sensíveis da sala de aula invisível porque projeta

informações anteriores sobre acontecimentos ainda não realizados. Estudos mostram que modelos preditivos podem identificar estudantes com maior probabilidade de reprovação e oferecer subsídios para intervenções antecipadas (Souza; Dutra; Fernandes, 2022; Gonçalves; Nunes, 2022). Essa capacidade apresenta evidente potencial pedagógico.

Entretanto, uma previsão permanece uma estimativa. O estudante classificado como alguém com provável dificuldade ainda não realizou aquilo que o modelo antecipa. Se essa classificação for utilizada para limitar atividades, expectativas ou oportunidades, uma inferência construída a partir do passado poderá participar das condições de produção do desempenho futuro. Por isso, o problema não está exclusivamente na existência da predição, mas na autoridade atribuída a ela.

Há, portanto, uma diferença entre utilizar uma previsão para ampliar possibilidades e utilizá-la para delimitá-las. Identificar um estudante com maior probabilidade de dificuldade pode justificar a ampliação do acompanhamento e das oportunidades de aprendizagem. A mesma informação, contudo, torna-se problemática se for

utilizada para reduzir expectativas ou restringir previamente as experiências oferecidas. O dado pode ser o mesmo; pedagogicamente, são as decisões construídas a partir dele que definem suas consequências.

Considere-se, por exemplo, uma classificação que indique elevada probabilidade de dificuldade futura. A informação pode conduzir à oferta de acompanhamento adicional, diversificação de estratégias e ampliação do suporte ao estudante. Entretanto, também poderia sustentar expectativas reduzidas ou experiências previamente simplificadas. Em ambos os casos, a classificação inicial seria semelhante, mas sua tradução pedagógica produziria condições distintas de aprendizagem. É por essa razão que modelos voltados à identificação precoce de dificuldades devem ser compreendidos como instrumentos de apoio à intervenção, e não como determinações sobre aquilo que o estudante será capaz de realizar (Souza; Dutra; Fernandes, 2022; Gonçalves; Nunes, 2022).

Os vieses tornam essa questão ainda mais relevante. Heggler, Szmoski e Miquelin (2025) demonstram que distorções podem surgir nos dados e nos próprios processos algorítmicos.

Consequentemente, a precisão estatística não elimina a necessidade de examinar os critérios utilizados nem transforma automaticamente uma previsão em decisão educacional adequada.

4.4 Quem decide quando a decisão não parece uma decisão?

A sala de aula tradicional torna relativamente identificáveis muitos de seus processos decisórios. O professor seleciona atividades, organiza intervenções, avalia respostas e modifica estratégias. Nos ambientes digitais, parte dessa mediação pode tornar-se menos perceptível porque algumas escolhas são incorporadas à própria arquitetura tecnológica.

Uma recomendação aparentemente simples já estabelece uma ordem de visibilidade. Determinado conteúdo aparece antes de outro, uma atividade pode ser sugerida a partir de um perfil e um sistema pode destacar estudantes considerados em situação de risco. Estudos sobre plataformas mostram que algoritmos participam da seleção, organização e recomendação de conteúdos, produzindo formas de mediação que nem sempre revelam seus critérios aos usuários (Macedo; Borges, 2025; Santos *et al.*, 2026).

A pergunta “quem decide?” não pressupõe, portanto, que o algoritmo tenha substituído o professor. A decisão pode estar distribuída entre desenvolvedores, modelos, dados, parâmetros institucionais, plataformas e sujeitos que interpretam seus resultados. A sala de aula invisível torna-se problemática justamente quando essa distribuição desaparece da percepção e o resultado produzido pelo sistema passa a ser recebido como algo natural ou inevitável.

Desse modo, a questão da decisão não pode ser reduzida à oposição entre professor e algoritmo. Em ambientes educacionais plataformizados, a decisão pode resultar de uma cadeia de mediações na qual diferentes atores definem dados, parâmetros, categorias e possibilidades de ação. Tornar essa cadeia perceptível é condição para que resultados automatizados possam ser interpretados, questionados e, quando necessário, contrariados pedagogicamente.

Essa perspectiva permite distinguir decisão algorítmica de decisão pedagogicamente informada por algoritmos. Na primeira, o resultado produzido pelo sistema tende a assumir caráter conclusivo ou a orientar

automaticamente a ação subsequente. Na segunda, indicadores, classificações ou previsões constituem elementos adicionais para o julgamento, permanecendo sujeitos à contextualização, à comparação com outras evidências e à revisão pelo professor. Para a educação, essa diferença é fundamental, pois preserva a informação produzida pelo sistema sem atribuir a ela autoridade suficiente para encerrar a interpretação do sujeito.

Defender essa distinção não significa reivindicar uma decisão docente desprovida de dados. Ao contrário, significa reconhecer que a ampliação das informações disponíveis pode qualificar a ação pedagógica quando acompanhada de capacidade interpretativa. A literacia de dados, nesse cenário, envolve não apenas saber ler indicadores, mas reconhecer sua origem, seus limites e as consequências das decisões construídas a partir deles (Silva, 2025). A mediação docente passa, assim, a incluir também a capacidade de decidir quando seguir, relativizar ou contrariar uma recomendação produzida pelo sistema.

Por essa razão, tornar visível essa camada implica reconhecer que dados podem informar decisões, mas

não devem encerrar a decisão pedagógica. Indicadores precisam ser contextualizados, classificações podem ser revistas e previsões devem permanecer abertas à contestação. A mediação docente não perde relevância diante da ampliação dos dados; ao contrário, passa a incluir também a capacidade de interpretar criticamente aquilo que os sistemas produzem sobre os estudantes.

5 CONSIDERAÇÕES FINAIS

Este estudo partiu da questão sobre quais decisões educacionais passam a ser mediadas por sistemas digitais e algorítmicos sem que professores e estudantes necessariamente percebam essa mediação. A análise indica que a crescente dataficação das experiências educacionais possibilita que registros produzidos em plataformas sejam transformados em indicadores, perfis, classificações, recomendações e previsões capazes de subsidiar diferentes formas de intervenção.

Como contribuição teórico-conceitual, propôs-se a noção de sala de aula invisível para designar essa camada de mediações. Sua invisibilidade não decorre da inexistência dos processos, mas da

difficuldade de percebê-los nas interfaces utilizadas cotidianamente. Enquanto professores e estudantes interagem com atividades e conteúdos visíveis, sistemas podem simultaneamente registrar, organizar, classificar e interpretar essas interações.

A contribuição da categoria está, portanto, em deslocar a atenção da ferramenta visível para as mediações que acompanham seu funcionamento. Mais do que perguntar quais tecnologias estão presentes na educação, a sala de aula invisível convida a investigar quais dados são produzidos, como estudantes são classificados, quais possibilidades lhes são recomendadas e de que maneira previsões passam a participar das decisões sobre seus percursos.

Os estudos analisados mostram que tais processos apresentam possibilidades relevantes, especialmente para acompanhamento, personalização e identificação precoce de dificuldades. Entretanto, também evidenciam desafios relacionados à opacidade, privacidade, vieses e governança algorítmica. O problema educacional não está, portanto, simplesmente em utilizar ou rejeitar algoritmos, mas em compreender os

limites daquilo que produzem e definir qual autoridade seus resultados terão sobre as decisões pedagógicas.

Nesse sentido, tornar visível a sala de aula invisível significa criar condições para que professores e estudantes possam compreender, questionar e contextualizar as mediações digitais que atravessam suas experiências. Dados podem ampliar aquilo que a escola consegue perceber sobre a aprendizagem, mas não substituem a compreensão do sujeito. Classificações podem sinalizar situações que merecem atenção, mas não devem transformar probabilidades em destinos.

A ampliação dessa discussão exige pesquisas empíricas que investiguem como classificações, recomendações e previsões são efetivamente incorporadas às práticas escolares e como professores e estudantes percebem essas mediações. Mais do que perguntar o que os algoritmos conseguem saber sobre quem aprende, torna-se necessário investigar o que a educação decide fazer com aquilo que os algoritmos dizem saber.

DECLARAÇÃO DE USO DE INTELIGÊNCIA ARTIFICIAL

Para a elaboração deste trabalho, foi utilizada a ferramenta ChatGPT (OpenAI) como apoio à organização textual e à revisão da redação. A seleção das fontes, a análise, a interpretação e a responsabilidade pelo conteúdo final são integralmente do autor.

REFERÊNCIAS

ANDRADE, Tiago Negrão; GOBBI, Maria Cristina. Plataformização da educação pública: governança algorítmica, formação docente e modelos de gestão. **Revista de Educação PUC-Campinas**, Campinas, v. 31, e15977, 2026.

BALIEIRO, Luan Tarlau; AZEVEDO, Mário Luiz Neves de. Capitalismo de plataforma e soberania digital: a Educação Superior sob vigilância algorítmica. **Revista Educação e Políticas em Debate**, v. 15, n. 1, p. 1-18, jan./abr. 2026.

COELHO, Flávio J. M.; OLIVEIRA, Elaine H. T.; PEREIRA, Filipe D.; OLIVEIRA, David B. F.; CARVALHO, Leandro S. G.; SOUTO, Eduardo J. P.; PESSOA, Marcela; MELO, Rafaela; LIMA, Marcos A. P.; NAKAMURA, Fabíola G. Learning Analytics in Introductory Programming Courses: a Showcase from the Federal University of Amazonas. **Revista Brasileira de Informática na Educação**, v. 31, p. 1089-1127, 2023.

COSTA, Carine Rodrigues da; OJEDA, Caroline Martins; LOPES, Rosemara Perpetua. Plataformização na educação superior pública e seus efeitos no

Brasil. **Colloquium Humanarum**, Presidente Prudente, v. 22, p. 1-18, 2025, e245047.

COSTA, Leandro Silva; SILVA, Lenina Lopes Soares. Panorama da plataforma de educação no Brasil: uma busca por recomendações para a integração das tecnologias digitais na educação. **ETD – Educação Temática Digital**, Campinas, v. 28, e026025, 2026.

GONÇALVES, Marluce Torquato Lima; NUNES, João Batista Carvalho. Analítica da aprendizagem aplicada à formação do pedagogo a distância na área da gestão escolar. **Revista da FAEEBA: Educação e Contemporaneidade**, Salvador, v. 31, n. 65, p. 338-354, jan./mar. 2022.

GONZALEZ, Nubia Andrea del Pilar; CHIAPPE, Andrés. Learning analytics and personalization of learning: a review. **Ensaio: Avaliação e Políticas Públicas em Educação**, Rio de Janeiro, v. 32, n. 122, p. 1-24, jan./mar. 2024, e0244234.

HEGGLER, João Marcos; SZMOSKI, Romeu Miqueias; MIQUELIN, Awdry Feisser. As dualidades entre o uso da inteligência artificial na educação e os riscos de vieses algorítmicos. **Educação & Sociedade**, Campinas, v. 46, e289323, 2025.

MACEDO, Fernanda Beatriz Ferreira de; BORGES, Martha Kaschny. Plataformas de redes sociais digitais e algoritmos: mudanças nas práticas sociais de adolescentes. **Inter-Ação, Goiânia**, v. 50, n. 1, p. 312-325, jan./abr. 2025.

MATTA, Cláudia Eliane da; RIBEIRO, Mariana Alves; PAMPLONA, Luciany Sacramento. Impactos da

plataformização na Educação Básica: desafios e implicações no contexto educacional. **Educação & Formação**, Fortaleza, v. 10, e15109, 2025.

SANTOS, Tatiana dos; KUHNEN, Camila do Nascimento; SILVA JÚNIOR, Edinaldo Enoque da; SCHÜTZ, Jenerton Arlan. Algoritmos e a fragmentação do mundo comum na educação: plataforma, realidades paralelas e resistência pedagógica. **Revista Ilustração**, Santo Ângelo, v. 7, n. 8, p. 517-533, 2026.

SILVA, Amanda Valeria. **Dataficação e literacia de dados**: análise do contexto docente em plataformas educacionais adaptativas. **Cenas Educacionais**, v. 8, e18900, 2025.

SOUZA, João Paulo Lopes de; DUTRA, Janderson Ferreira; FERNANDES, Damires Yluska de Souza. Predição precoce de problemas de desempenho de estudantes em modalidade de educação on-line: um estudo de caso no ensino médio integrado. **Revista Principia**, João Pessoa, v. 59, n. 3, p. 764-784, 2022.