

Uso da Multimodal Learning Analytics (MMLA) no Ensino Superior e seus Impactos Pedagógicos: Uma Revisão Integrativa da Literatura

Jeffté L. Mendes¹, Gabriel O. Albuquerque¹, Daniel L. Dantas², Manoela M. O. da Silva¹

¹Instituto de Informática – Universidade de Pernambuco (UPE)
Rua Professor Amaro Maltez, 201 Centro – Nazaré da Mata – PE CEP 55800-000 – Brasil

²Departamento de Computação – Universidade Federal Rural de Pernambuco (UFRPE)
Avenida Dom Manoel de Medeiros, Dois Irmãos, Recife - PE, CEP 52171-900 – Brasil

{jeffte.lucas, gabriel.oliveirab, manoela.milena}@upe.br, daniel.ldantas@ufrpe.br

Abstract. *This research aims to explore how Multimodal Learning Analytics (MMLA) has been used in higher education, as well as its pedagogical impacts, the technologies associated with its use, the teacher's role, and the support provided to teachers in the teaching and learning process. To this end, an integrative literature review of articles published between 2020 and 2025 was conducted, resulting in 39 studies retrieved from the ACM Digital Library database. Preliminary results revealed MMLA applications focused on monitoring engagement, performance, and collaboration through multimodal technologies, with limited attention given to teachers' roles and support.*

Resumo. *Esta pesquisa tem como objetivo explorar como a Multimodal Learning Analytics (MMLA) vem sendo utilizada na educação superior, seus impactos pedagógicos, as tecnologias associadas ao seu uso, bem como o papel e o suporte oferecidos aos docentes nos processos de ensino e aprendizagem. Para tanto, foi conduzida uma revisão integrativa da literatura de artigos publicados entre 2020 e 2025, resultando em 39 estudos recuperados da base de dados ACM Digital Library. Resultados preliminares apontam aplicações da MMLA voltadas ao acompanhamento do engajamento, do desempenho e da colaboração, mediadas por tecnologias multimodais, embora com atenção limitada ao papel e ao suporte docente.*

1. Introdução

A Multimodal Learning Analytics (MMLA) tem se consolidado como uma abordagem promissora para compreender atividades humanas em contextos educacionais, impulsionada pelo avanço de tecnologias como dispositivos vestíveis, inteligência artificial e técnicas de analytics. A MMLA utiliza múltiplas fontes de dados, como vídeos, áudios, gestos, registros de interação e biossensores, para analisar processos de aprendizagem em ambientes realistas e socialmente interativos [Blikstein 2013]. Sua aplicação pode contribuir para prever comportamentos estudantis, orientar intervenções

pedagógicas e auxiliar professores na compreensão dos fatores que influenciam a aprendizagem [Cukurova et al. 2020].

Entretanto, sua adoção ainda enfrenta desafios teóricos, metodológicos e éticos. Professores demonstram preocupações quanto à precisão e à interpretação dos dados [Kollom et al. 2021], enquanto a falta de visualizações claras e de integração com outras ferramentas dificulta o uso dessas soluções. Na MMLA, essas limitações são ampliadas pela complexidade e heterogeneidade dos dados, além de questões relacionadas à privacidade, ao consentimento, à transparência e à governança [Cukurova et al. 2020].

Revisões anteriores abordaram aspectos específicos do campo. [Wang et al. 2020] analisaram tecnologias, técnicas e aplicações da MMLA, mas dedicaram menor atenção aos impactos pedagógicos e ao papel do docente. [Deng e Zhao 2022] apresentaram uma análise bibliométrica da área, sem aprofundar-se em seus contextos educacionais. [Gan et al. 2022] investigou ferramentas de Internet das Coisas aplicadas à coleta de dados multimodais, identificando usos relacionados ao comportamento, à afetividade, à colaboração, ao desempenho e ao feedback, embora tenha constatado a predominância de protótipos pouco aplicados em situações reais.

Diante dessa lacuna, este estudo busca mapear e catalogar as tecnologias empregadas em pesquisas de MMLA no ensino superior, escolhido pela maior viabilidade ética de estudos com participantes adultos. A investigação considera os países e contextos de aplicação, as métricas, tecnologias e modalidades de coleta, os impactos pedagógicos e de aprendizagem, o papel docente e os mecanismos de suporte oferecidos aos professores. Assim, pretende-se ampliar a compreensão sobre o estado da arte da MMLA no ensino superior, destacando suas aplicações, potencialidades e desafios em contextos educacionais reais.

2. Metodologia

Este estudo consiste em uma revisão integrativa da literatura, uma abordagem que reúne evidências teóricas, empíricas, experimentais e não experimentais para proporcionar uma compreensão abrangente do fenômeno investigado [Souza et al. 2010].

A busca foi realizada na ACM Digital Library, entre fevereiro e junho de 2026, utilizando a string: (("Multimodal Learning Analytics" OR MMLA) AND ("Higher Education" OR "University" OR "Undergraduate" OR "College")). Os termos foram selecionados para ampliar a recuperação de estudos relacionados ao ensino superior. Embora tenham sido realizadas buscas exploratórias na IEEE Xplore e na Scopus, a análise concentrou-se na ACM devido à sua relevância para a área de computação, à concentração de estudos sobre o tema e às limitações de escopo e de prazo da pesquisa.

Foram recuperados 178 artigos, organizados na plataforma Rayyan¹. Após a análise de títulos, resumos e palavras-chave, 56 estudos permaneceram. Nos casos em que essas informações foram insuficientes, foram examinadas as seções de metodologia e de conclusão, resultando na seleção de 39 artigos².

O processo seguiu as seis etapas da revisão integrativa: elaboração da pergunta norteadora, busca na literatura, coleta de dados, análise crítica dos estudos, discussão dos

resultados e apresentação da revisão [Souza et al. 2010]. Após a aplicação dos critérios de inclusão e exclusão (Tabela 1), os 39 artigos foram lidos integralmente para responder à questão: “De que maneira a *Multimodal Learning Analytics* vem sendo utilizada no contexto da educação superior?”. Subperguntas complementares foram elaboradas para analisar contextos, tecnologias, impactos pedagógicos e implicações para a atuação docente.

Os estudos foram organizados em uma planilha com os seguintes campos: título, ano, autoria, filiação institucional, país de origem, contexto de uso, público-alvo, métricas, tecnologias, impactos pedagógicos, papel do docente e suporte oferecido ao professor.

Tabela 1. Critérios de inclusão e exclusão para a seleção dos artigos.

Critérios de Inclusão	Critérios de Exclusão
Artigos publicados entre 2020–2025	Estudos que abordem aplicações de MMLA em contextos não educacionais, em níveis de ensino diferentes do ensino superior ou em níveis não especificados.
Artigos que tratem de MMLA no ensino superior	Estudos cujo foco principal não seja ensino-aprendizagem, mesmo que utilizem MMLA
Artigos primários completos	Resumos estendidos, short papers (2–4 páginas), pôsteres, editoriais e artigos em andamento
Idiomas Português e Inglês	Estudos secundários ou terciários (revisões, mapeamentos, surveys)
Artigos completos	Livros, capítulos de livros, teses, dissertações, relatórios técnicos e outros tipos de literatura cinzenta.
Estudos que apresentem aplicação, avaliação ou proposta de MMLA em contextos de ensino-aprendizagem.	Artigos duplicados ou indisponíveis para acesso ao texto completo.

1

¹ Rayyan: <https://www.rayyan.ai/>

² Materiais complementares: https://drive.google.com/drive/folders/107Db-wgBXlrCatnNPUWfdCAQsY_VuPt6?usp=sharing

3. Resultados e Discussão

Esta seção apresenta os resultados com base nos aspectos analisados em cada um dos trabalhos selecionados, a saber: título, ano de publicação, autoria, filiação institucional, país de origem, contexto de aplicação, público-alvo, métricas adotadas, tecnologias empregadas, impactos pedagógicos, papel docente e suporte oferecido aos docentes.

3.1 Contextos do Uso da MMLA no Ensino Superior

Os estudos analisados mostram que a MMLA tem sido empregada principalmente para apoiar atividades colaborativas por meio de *dashboards* e *frameworks* baseados em Inteligência Artificial, capazes de integrar dados multimodais e fornecer informações para estudantes e professores. As abordagens diferem quanto ao momento da intervenção, contemplando tanto feedback após as atividades quanto suporte em tempo real, o que demonstra que a efetividade dessas estratégias ainda está em investigação [Echeverria et al. 2024; Alfredo et al. 2025].

Também foi observado que a maior parte das pesquisas concentra esforços no desenvolvimento e na validação de novas soluções tecnológicas, como *dashboards* e *frameworks*, em vez de avaliar seus impactos na aprendizagem e na prática pedagógica em contextos reais [Zhao et al. 2024; Echeverria et al. 2025]. Embora os avanços em IA tenham ampliado a capacidade de análise de dados multimodais, ainda são escassas as evidências sobre seus efeitos na tomada de decisão docente, no engajamento dos estudantes e nos resultados de aprendizagem ao longo do tempo. Esses achados reforçam a necessidade de estudos longitudinais e de aplicações em diferentes contextos educacionais, aproximando o desenvolvimento tecnológico de sua efetiva adoção no ensino superior.

3.2 Público-alvo

Em relação ao público-alvo das pesquisas analisadas, observou-se que os principais participantes foram pesquisadores de MMLA, professores e alunos de graduação. Entre os estudantes, houve predominância de alunos da área de enfermagem, além de diversos estudos nos quais o perfil acadêmico dos participantes não foi explicitado. Esse cenário sugere que muitos trabalhos priorizaram a descrição das atividades desenvolvidas e dos mecanismos de análise empregados, em detrimento da caracterização detalhada do contexto acadêmico dos participantes. Alunos dos cursos de engenharia e de computação demonstram menor uso, porém ainda há uma participação significativa. Em contraste, estudos sociais, artes, inglês e cultura apresentam baixo uso da MMLA. Esse resultado sugere que, salvo o curso de enfermagem, o uso de MMLA na educação ocorre mais em cursos de exatas do que em cursos de humanas (Figura 1).




Figura 1. Artigos classificados de acordo com o perfil acadêmico dos participantes.

3.3. Ano de Publicação

A evolução do uso da *Multimodal Learning Analytics* (MMLA) no Ensino Superior revela uma trajetória de crescimento com oscilações entre 2020 e 2025. Após uma queda significativa em 2021, observa-se uma forte recuperação em 2022, uma nova redução em 2023 e um pico em 2024, seguido de um leve declínio em 2025 (Figura 2). Esses dados indicam a consolidação gradual da MMLA como um campo de pesquisa emergente. Em termos pedagógicos, esse movimento reflete o crescente reconhecimento do potencial da MMLA para apoiar práticas educacionais mais personalizadas, ampliar a compreensão dos processos de aprendizagem e subsidiar decisões pedagógicas baseadas em múltiplas fontes de dados.




Figura 2. Artigos classificados por ano de publicação.

3.4 País de Origem

A produção científica sobre MMLA no Ensino Superior concentra-se principalmente na Austrália, nos Estados Unidos e em países da região Ásia-Pacífico, enquanto nações europeias apresentam menor participação (Figura 3). Esses resultados sugerem que a pesquisa em MMLA no Ensino Superior está mais consolidada em países com tradição em inovação educacional e em tecnologias de aprendizagem, o que reflete o reconhecimento do potencial da abordagem para compreender processos de aprendizagem, apoiar práticas pedagógicas e orientar decisões educacionais baseadas em dados multimodais. A ausência de estudos na América do Sul evidencia uma lacuna regional, associada a limitações tecnológicas e financeiras, reforçando a necessidade de ampliar as pesquisas sobre MMLA em contextos latino-americanos.




Figura 3. Artigos classificados por país de publicação.

3.5 Autores e filiação

Dos 39 artigos, foram identificados 34 autores primários únicos nos estudos analisados. Entre eles, Linxuan Zhao e Vanessa Echeverria, ambos da Monash University (Austrália), destacaram-se como os pesquisadores mais produtivos, com 3 e 2 publicações, respectivamente. Em seguida, Jeremy T. D. Ng, da Faculty of Education, da The University of Hong Kong, também apresentou duas publicações. Os demais autores identificados contribuíram com apenas um estudo, o que indica uma produção científica ainda dispersa e com poucos pesquisadores recorrentes na área.

Em relação às instituições, observou-se forte concentração da produção científica em um número reduzido de universidades. A Monash University destacou-se amplamente, com dez estudos publicados, seguida pela Faculty of Education da The University of Hong Kong, com quatro estudos. A Carnegie Mellon University (Estados Unidos) e a University of Colorado Boulder (Estados Unidos) contribuíram com dois estudos cada, enquanto as demais instituições apresentaram apenas uma publicação.

Esses resultados evidenciam a liderança da Monash University no desenvolvimento da MMLA aplicada ao ensino superior, sugerindo que a instituição atua como um dos principais polos de pesquisa da área. De forma semelhante, a Faculty of Education da The University of Hong Kong também demonstra participação consistente, reforçando a concentração da produção científica em poucos grupos de pesquisa internacionalmente consolidados. Esse cenário sugere que o avanço da MMLA ainda depende fortemente de centros de excelência com infraestrutura tecnológica e expertise especializada, o que pode limitar a diversificação geográfica da produção científica.

3.6 Métricas usadas

As métricas identificadas nos estudos analisados tendiam a se organizar em duas categorias inter-relacionadas, embora uma delas geralmente se destacasse conforme o foco do artigo: (1) análise da ferramenta implementada ou (2) verificação do impacto pedagógico sob a perspectiva de professores e estudantes.

Esses dois cenários manifestavam-se de maneiras distintas. Em atividades realizadas tanto em sala de aula quanto em ambientes externos, frequentemente, em cenários de simulação voltados a experiências imersivas, eram utilizados diversos equipamentos para monitorar fatores não diretamente observáveis, como batimento cardíaco, carga cognitiva, temperatura corporal, atividade eletrodérmica e volume sanguíneo no pulso, entre outros. Esses dados eram integrados a sistemas de análise capazes de apoiar diferentes objetivos de investigação.

Quando o foco recaía sobre a análise da ferramenta implementada, os estudos buscavam avaliar a eficácia da correlação entre os dados coletados e a precisão da capacidade de generalização dos modelos empregados. Em casos de análise do desempenho grupal, a validação frequentemente ocorria por meio da observação em tempo real realizada pelo docente, complementada pela análise posterior de registros em vídeo pelos pesquisadores. Um exemplo é o trabalho de Echeverria, que apresentou o TeamSlides, um dashboard desenvolvido para facilitar a compreensão docente de *Multimodal Learning Analytics* (MMLA) [Echeverria et al. 2024]. Contudo, o estudo

também evidenciou uma limitação crítica do sistema: em determinada situação, a ferramenta identificou quatro estudantes próximos a uma maca como participantes de uma mesma atividade colaborativa; entretanto, embora ocupassem o mesmo espaço captado pela visão computacional, nem todos estavam efetivamente envolvidos na mesma tarefa.

Por outro lado, os estudos voltados à verificação do impacto pedagógico, sob a perspectiva de professores e estudantes, adotavam uma abordagem distinta, priorizando a experiência educacional em detrimento da avaliação exclusiva da ferramenta tecnológica. Nesses casos, eram frequentes instrumentos como questionários de satisfação relacionados à atividade [Pankaj et al. 2024] e entrevistas sobre a experiência de uso do MMLA [Echeverria et al. 2025]. O foco deslocava-se, assim, para a relação entre docentes, estudantes e práticas pedagógicas, em vez da análise de uma tecnologia específica. Existem, contudo, exceções a essa tendência, como os trabalhos do grupo de pesquisa da Universidade de Monash, na Austrália, que procuram equilibrar análises estatísticas de dados com entrevistas com estudantes e educadores sobre a satisfação com o uso de novos *dashboards* e *frameworks* [Maldonado et al. 2020].

3.7 Tecnologias Utilizadas

Os estudos analisados mostram que a MMLA é sustentada pela integração de tecnologias para a aquisição, o processamento e a visualização de dados multimodais. A coleta de dados baseia-se principalmente em sensores capazes de registrar aspectos fisiológicos, comportamentais e cognitivos dos estudantes, como movimentos corporais, direção do olhar, expressões faciais, voz e sinais neurofisiológicos. Essas soluções são aplicadas tanto em ambientes virtuais de aprendizagem quanto em contextos imersivos, como a realidade virtual e as simulações, demonstrando a versatilidade da abordagem.

Observou-se, ainda, o predomínio de técnicas de inteligência artificial e de visão computacional, apoiadas por frameworks como PyTorch e TensorFlow, que possibilitam a análise integrada de dados multimodais em tempo real. Além disso, a consolidação do Python como principal ambiente de desenvolvimento e o crescente uso de dashboards e de plataformas de apoio à decisão indicam uma evolução da MMLA rumo a soluções cada vez mais integradas, capazes de transformar grandes volumes de dados em informações úteis para apoiar o ensino, a aprendizagem e a tomada de decisão pedagógica.

3.8 Impactos Pedagógicos Identificados

No conjunto dos artigos analisados, os impactos pedagógicos identificados estão majoritariamente associados ao uso da análise comportamental como recurso para potencializar e personalizar os processos de ensino e de aprendizagem. Nesse contexto, observam-se dois grupos principais de impactos: os relacionados ao agente aplicador, predominantemente o docente, e os relacionados ao agente receptor, predominantemente o discente.

Os impactos identificados concentram-se, sobretudo, na ampliação da personalização do ensino, frequentemente apoiada pelo uso de inteligência artificial e de

sensores capazes de captar dados provenientes de múltiplas fontes, como vídeo, áudio, linguagem corporal, expressões faciais e gestos. Essa abordagem possibilita uma compreensão mais aprofundada das condições de aprendizagem dos estudantes, permitindo ao docente acessar indicadores relacionados, por exemplo, à carga cognitiva, aos níveis de engajamento ou aos sinais de sobrecarga e desinteresse durante as atividades educacionais.

Outro impacto recorrente refere-se ao aprimoramento das dinâmicas de trabalho colaborativo. Por meio da análise multimodal dos comportamentos individuais e coletivos, é possível identificar padrões de participação em grupos, distinguindo estudantes efetivamente engajados daqueles com menor envolvimento nas atividades. Esse tipo de monitoramento contribui para uma compreensão mais detalhada da colaboração entre pares e para intervenções pedagógicas mais direcionadas.

Adicionalmente, os estudos apontam para uma maior responsividade do processo educativo, caracterizada pela possibilidade de oferecer feedback mais rápido, mais específico e fundamentado em evidências. Nesse cenário, a utilização de dados biométricos e comportamentais pode contribuir para reduzir vieses associados à avaliação exclusivamente observacional do educador, favorecendo análises mais sistemáticas e orientadas por dados sobre o desempenho e a experiência de aprendizagem dos estudantes.

3.9 Papel do docente

Com base nos artigos revisados, observa-se uma redefinição do papel do docente no contexto do *Multimodal Learning Analytics* (MMLA). O professor deixa de atuar exclusivamente como transmissor de conteúdo para assumir funções associadas à curadoria de dados, à interpretação comportamental e à mediação pedagógica responsiva. Nesse cenário, o docente passa a desempenhar o papel de “leitor” dos comportamentos, das emoções e dos padrões de interação dos estudantes.

Por meio das tecnologias de MMLA, o professor torna-se capaz de identificar aspectos que frequentemente escapam à observação convencional em ambientes educacionais, como expressões faciais, sinais emocionais, níveis de engajamento, indícios de dúvida, frustração, desconforto ou desmotivação apresentados pelos estudantes durante aulas e atividades, tanto individuais quanto colaborativas. A análise desses indicadores amplia a compreensão do docente sobre as experiências de aprendizagem dos alunos.

Além disso, o professor assume a função de mediador adaptativo, utilizando os *feedbacks* gerados pelos sistemas de análise multimodal para ajustar suas estratégias pedagógicas. Isso pode envolver a adaptação do ritmo das aulas, a reformulação de abordagens didáticas ou a oferta de suporte adicional conforme as necessidades demonstradas pelos estudantes em áreas específicas de dificuldade.

Essa atuação favorece uma mudança de enfoque na avaliação educacional, deslocando a atenção da exclusividade dos resultados finais, como índices de acertos e erros, para uma consideração mais ampla dos processos cognitivos, emocionais e comportamentais envolvidos na aprendizagem. Como consequência, os estudos sugerem

o fortalecimento da dimensão socioemocional do ensino, possibilitando ao docente promover ambientes de aprendizagem potencialmente mais acolhedores, responsivos e favoráveis ao desenvolvimento integral dos estudantes.

3.10 Suporte oferecido para o docente

Em relação ao suporte oferecido ao docente, a análise dos artigos indica que, na maioria dos estudos, não há descrição explícita de mecanismos estruturados de apoio ao professor ou que tal suporte está ausente. Nos casos em que algum tipo de apoio foi identificado, este esteve geralmente associado às tecnologias empregadas nos experimentos de MMLA.

Entre os exemplos observados, destacam-se sensores vestíveis utilizados para capturar dados de posicionamento e de interação dos participantes [Fernandez-Nieto et al. 2022]. De modo semelhante, alguns estudos reportam o uso de ferramentas de MMLA, como câmeras, gravadores de áudio e softwares especializados, como o CoTrack, como recursos de apoio à observação, ao monitoramento e à análise das dinâmicas educacionais [Chejara et al. 2024].

Outro exemplo de destaque é o software TeamVision que é usado para uma sessão de *debrief* para recapitular pontos importantes e gerar *insights* após uma atividade. Usando um sistema de posicionamento em ambientes internos e microfones de lapela sem fio, capturaram dados multimodais de equipes de alunos que participavam de uma simulação clínica. O TeamVision foi alimentado com esses dados para um melhor entendimento da dinâmica das equipes durante a simulação. Posteriormente, em sessões de *debrief*, a ferramenta apresentou uma interface flexível e de fácil entendimento para os professores. O TeamVision ajudou os professores a guiar o processo de *brief* sistematicamente, focando nos objetivos gerais, além de permitir diferentes visualizações do que foi feito e de ajudar a rever conceitos fundamentais para práticas [Echeverria et al. 2025].

Os resultados sugerem que o suporte ao docente, quando presente, tende a ocorrer predominantemente por meio da mediação tecnológica, em vez de envolver estratégias pedagógicas, formativas ou institucionais especificamente direcionadas ao docente.

3.11 Aplicabilidade

Os estudos analisados indicam que a MMLA tem potencial de aplicação prática em diferentes contextos educacionais. *Dashboards* e sistemas de *Learning Analytics* podem apoiar professores no monitoramento de atividades colaborativas, fornecendo indicadores de participação, engajamento e desempenho que auxiliam na identificação de dificuldades e na tomada de decisões pedagógicas baseadas em evidências [Echeverria et al. 2024; Zhao et al. 2024]. Além disso, a oferta de feedback em tempo real ou após as atividades favorece a autorregulação dos estudantes e o aprimoramento das estratégias de ensino, especialmente em metodologias ativas [Echeverria et al. 2024; Echeverria et al. 2025].

Os resultados também mostram que, embora parte das soluções dependa de sensores especializados, diversas aplicações podem ser implementadas com recursos mais

acessíveis, como webcams, microfones e registros de interação em Ambientes Virtuais de Aprendizagem, ampliando as possibilidades de adoção da MMLA em instituições com recursos limitados [Li et al. 2023; Patidar et al. 2024]. Por outro lado, a literatura ainda prioriza a validação técnica das ferramentas em detrimento de sua integração às práticas pedagógicas. Assim, o desenvolvimento de plataformas mais intuitivas, transparentes e compatíveis com as infraestruturas existentes representa uma direção promissora para ampliar a adoção da MMLA e aproximar o desenvolvimento tecnológico das necessidades reais do ensino [Maldonado et al. 2020; Ngoon et al. 2023; Echeverria et al. 2025].

4. Conclusão

Esta revisão integrativa permitiu mapear o uso da MMLA no ensino superior entre 2020 e 2025, evidenciando um campo em crescimento, fortemente apoiado por tecnologias como sensores, inteligência artificial, visão computacional, *dashboards* e *frameworks* analíticos. Os estudos analisados mostram aplicações voltadas principalmente ao monitoramento do desempenho, do engajamento e das dinâmicas colaborativas entre os estudantes.

Os resultados indicam que a MMLA tem potencial para ampliar a personalização do ensino, apoiar intervenções pedagógicas mais responsivas e aprofundar a compreensão de aspectos cognitivos, emocionais e comportamentais da aprendizagem. Entretanto, observou-se predominância de pesquisas focadas no desenvolvimento de ferramentas, com atenção limitada à integração dessas soluções às práticas pedagógicas, ao papel do docente e aos mecanismos de suporte ao professor.

4.1 Barreiras à Implementação da MMLA no Ensino Superior

Os resultados mostram que a pesquisa em MMLA concentra-se em universidades de países com maior capacidade de investimento, como Austrália, Estados Unidos e China, devido à disponibilidade de infraestrutura e de grupos de pesquisa especializados. A dependência de sensores, dispositivos vestíveis e equipamentos de alto custo limita a adoção desses dispositivos em instituições com menos recursos, especialmente no Brasil e em outros países sul-americanos. Nesse sentido, soluções acessíveis e escaláveis, baseadas em webcams, smartphones e plataformas de código aberto, podem reduzir barreiras econômicas e tecnológicas e ampliar a aplicação da MMLA em diferentes contextos educacionais.

4.2 Próximos Passos

Como próximos passos, pretende-se ampliar a revisão a outras bases de dados, como a IEEE Xplore e a Scopus, a fim de aumentar a abrangência e a diversidade dos estudos considerados.

5. Declaração de Uso de Inteligência Artificial

Neste artigo, o ChatGPT (OpenAI) foi utilizado exclusivamente para apoiar a revisão textual. Os autores revisaram integralmente o conteúdo e assumem total responsabilidade pelo manuscrito final.

Referências

- Alfredo, R. et al. (2025). “TeamTeachingViz: Benefits, Challenges, and Ethical Considerations of Using a Multimodal Analytics Dashboard to Support Team Teaching Reflection - Proceedings of the 15th International Learning Analytics and Knowledge Conference”. In LAK '25: Proceedings of the 15th International Learning Analytics and Knowledge Conference, March 3 - 7, 2025, Dublin Ireland, ACM, New York, NY, United States, p. 58 - 69.
- Alfredo, R. D. et al. (2023). “That Student Should be a Lion Tamer!” StressViz: Designing a Stress Analytics Dashboard for Teachers”. In LAK2023: LAK23: 13th International Learning Analytics and Knowledge Conference, March 13 - 17, 2023, Arlington TX USA, ACM, New York, NY, United States, p. 57 – 67.
- Blikstein, P. (2013). “Multimodal Learning Analytics”. In: Proceedings of the Third International Conference on Learning Analytics and Knowledge (LAK '13), Leuven, Belgium, Association for Computing Machinery, p. 102–106.
- Chejara, P. et al. (2024). “Bringing Collaborative Analytics using Multimodal Data to Masses: Evaluation and Design Guidelines for Developing a MMLA System for Research and Teaching Practices in CSCL - Proceedings of the 14th Learning Analytics and Knowledge Conference”. In LAK '24: Proceedings of the 14th Learning Analytics and Knowledge Conference, March 18 - 22, 2024, Kyoto Japan, ACM, New York, NY, United States, p. 800 - 806.
- Ciordas-Hertel, G.-P. et al. (2022). “How can Interaction Data be Contextualized with Mobile Sensing to Enhance Learning Engagement Assessment in Distance Learning?”. In LAK '22: Proceedings of the 12th Learning Analytics and Knowledge Conference, March 21–25, 2022, Online, ACM, New York, NY, United States, p. 177–188.
- Cukurova, M. et al. (2020). “Modelling Collaborative Problem-solving Competence with Transparent Learning Analytics: Is Video Data Enough?”. In LAK '20: Proceedings of the Tenth International Conference on Learning Analytics & Knowledge, March 23 - 27, 2020, Frankfurt Germany, ACM, New York, NY, United States, p. 270 - 275.
- Deng, J.; Zhao, Y. (2023). “A Literature Review of Data-Driven Multimodal Learning Analytics in Education Based on Citespace”. In LAK '23: Proceedings of the 13th Learning Analytics and Knowledge Conference, March 13–17, 2023, Arlington, TX, United States, ACM, New York, NY, United States, p. 390–397.

- Echeverria, V. et al. (2024). “TeamSlides: a Multimodal Teamwork Analytics Dashboard for Teacher-guided Reflection in a Physical Learning Space - Proceedings of the 14th Learning Analytics and Knowledge Conference”. In LAK '24: Proceedings of the 14th Learning Analytics and Knowledge Conference, March 18 - 22, 2024, Kyoto Japan, ACM, New York, NY, United States, p. 112 - 122.
- Echeverria, V. et al. (2025). “TeamVision: An AI-powered Learning Analytics System for Supporting Reflection in Team-based Healthcare Simulation”. In CHI '25: Proceedings of the 2025 CHI Conference on Human Factors in Computing Systems, April 26-May 1, 2025, Yokohama Japan, ACM, New York, NY, United States, Article No.: 309, p. 1 - 22.
- Emerson, A. et al. (2023). “Multimodal Predictive Student Modeling with Multi-Task Transfer Learning.”. In LAK2023: LAK23: 13th International Learning Analytics and Knowledge Conference, March 13 - 17, 2023, Arlington TX USA, ACM, New York, NY, United States, p. 333 - 344.
- Feng, S. et al. (2024). “Heterogenous Network Analytics of Small Group Teamwork: Using Multimodal Data to Uncover Individual Behavioral Engagement Strategies - Proceedings of the 14th Learning Analytics and Knowledge Conference.”. In LAK '24: The 14th Learning Analytics and Knowledge Conference, March 18 - 22, 2024, Kyoto Japan, ACM, New York, NY, United States, p. 587 - 597.
- Fernandez-Nieto, G. et al. (2022). “Classroom Dandelions: Visualising Participant Position, Trajectory and Body Orientation Augments Teachers’ Sensemaking”. In CHI '22: Proceedings of the 2022 CHI Conference on Human Factors in Computing Systems, 29 April - 5 May, 2022, New Orleans LA USA, ACM, New York, NY, United States, Article No.: 564, p. 1 - 17.
- Gan, W. et al. (2022). “IoT-based Multimodal Analysis for Smart Education: Current Status, Challenges and Opportunities”. In ICDAR '22: Proceedings of the 3rd ACM Workshop on Intelligent Cross-Data Analysis and Retrieval, June 27–30, 2022, Newark, NJ, United States, ACM, New York, NY, United States, p. 32–40.
- Heilala, V. et al. (2024). “Toward Scalable and Transparent Multimodal Analytics to Study Standard Medical Procedures: Linking Hand Movement, Proximity, and Gaze Data”. In SAC '24: Proceedings of the 39th ACM/SIGAPP Symposium on Applied Computing, April 8 - 12, 2024, Avila Spain, ACM, New York, NY, United States, p. 3 - 10.
- Joshi, V. et al. (2024). “Enhancing Collaboration and Performance Among EMS Students Through Multimodal Learning Analytics”. In ICMI '24: Proceedings of the 26th International Conference on Multimodal Interaction, November 4 - 8, 2024, San Jose Costa Rica, ACM, New York, NY, United States, p. 607 - 611.
- Klein, C. et al. (2019). “Technological Barriers and Incentives to Learning Analytics Adoption in Higher Education: Insights from Users”. *Journal of Computing in Higher Education*, 31(3), p. 604–625.

- Kollom, K. et al. (2021). “A Four-Country Cross-Case Analysis of Academic Staff Expectations About Learning Analytics in Higher Education”. *The Internet and Higher Education*, 49, 100788.
- Lewis, A. et al. (2023). “Instructor-in-the-Loop Exploratory Analytics to Support Group Work”. In *LAK '23: Proceedings of the 13th Learning Analytics and Knowledge Conference*, March 13–17, 2023, Arlington, TX, United States, ACM, New York, NY, United States, p. 284–292.
- Li, X. et al. (2023). “CVPE: A Computer Vision Approach for Scalable and Privacy Preserving Socio-spatial, Multimodal Learning Analytics - LAK23: 13th International Learning Analytics and Knowledge Conference”. In *LAK2023: LAK23: 13th International Learning Analytics and Knowledge Conference*, March 13 - 17, 2023, Honolulu HI USA, ACM, New York, NY, United States, p. 175 - 185.
- Maldonado, R. M. et al. (2020). “From Data to Insights: A Layered Storytelling Approach for Multimodal Learning Analytics - Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems”. In *CHI '20: Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, April 25 - 30, 2020, Honolulu HI USA, ACM, New York, NY, United States, p. 1 - 15.
- Méndez, G. G. et al. (2025). “The Hidden Workload: Student Data Work in Multimodal Algorithmic Evaluations.”. In *Proceedings of the ACM on Human-Computer Interaction*, Volume 9, Issue 7, November, 2025, ACM, New York, NY, United States, Article No.: CSCW491, p. 1 - 30.
- Ng, J. T. D. et al. (2022). “Needs Analysis and Prototype Evaluation of Student facing LA Dashboard for Virtual Reality Content Creation”. In *LAK22: LAK22: 12th International Learning Analytics and Knowledge Conference*, March 21 - 25, 2022, Online, USA, ACM, New York, NY, United States, p. 444 - 450.
- Ng, J. T. D. et al. (2022). “Towards Multimodal Evaluation of Eye-tracked Virtual Heritage Environment”. In *AK22: LAK22: 12th International Learning Analytics and Knowledge Conference*, March 21 - 25, 2022, Online, USA, ACM, New York, NY, United States, p. 451 - 457.
- Ngoon, T. J. et al. (2023). “An Instructor is [already] able to keep track of 30 students”: Students’ Perceptions of Smart Classrooms for Improving Teaching & Their Emergent Understandings of Teaching and Learning”. In *DIS '23: Proceedings of the 2023 ACM Designing Interactive Systems Conference*, July 10 - 14, 2023, Pittsburgh PA USA, ACM, New York, NY, United States, p. 1277 – 1292.
- Pastushenko, O. et al. (2020). “A Methodology for Multimodal Learning Analytics and Flow Experience Identification within Gamified Assignments - Extended Abstracts of the 2020 CHI Conference on Human Factors in Computing Systems”. In *CHI EA '20: Extended Abstracts of the 2020 CHI Conference on Human Factors in Computing Systems*, April 25 - 30, 2020, Honolulu HI USA, ACM, New York, NY, United States, p. 1 - 9.

- Patidar, P. et al. (2024). “ClassID: Enabling Student Behavior Attribution from Ambient Classroom Sensing Systems”. In *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Volume 8, Issue 2, June, 2024, ACM, New York, NY, United States, Article No.: 55, p. 1 - 28.
- Praharaj, S. et al. (2022). “Towards Collaborative Convergence: Quantifying Collaboration Quality with Automated Co-located Collaboration Analytics”. In *LAK22: 12th International Learning Analytics and Knowledge Conference*, March 21 - 25, 2022, Online, USA, ACM, New York, NY, United States, Article No.: 309, p. 358 - 369.
- Pugh, S. L. et al. (2022). “Do Speech-Based Collaboration Analytics Generalize Across Task Contexts?”. In *LAK22: 12th International Learning Analytics and Knowledge Conference*, March 21 - 25, 2022, Online, USA, ACM, New York, NY, United States, p. 208 - 218.
- Que, Y. et al. (2024). “Using Multimodal Learning Analytics to Examine Learners’ Responses to Different Types of Background Music during Reading Comprehension - Proceedings of the 14th Learning Analytics and Knowledge Conference”. In *LAK '24: Proceedings of the 14th Learning Analytics and Knowledge Conference*, March 18 - 22, 2024, Kyoto Japan, ACM, New York, NY, United States, p. 749 – 756.
- Saqr, M. et al. (2020). “High resolution temporal network analysis to understand and improve collaborative learning”. In *LAK '20: Proceedings of the Tenth International Conference on Learning Analytics & Knowledge*, March 23 - 27, 2020, Frankfurt Germany, ACM, New York, NY, United States, p. 314 - 319.
- Sharma, K. et al. (2020). “Predicting learners’ effortful behaviour in adaptive assessment using multimodal data”. In *LAK '20: Proceedings of the Tenth International Conference on Learning Analytics & Knowledge*, March 23 - 27, 2020, Frankfurt Germany, ACM, New York, NY, United States, p. 480 - 489.
- Shen, Y. (2025). “AI-Driven Scaffolding and Affective Support in ESL Argumentative Writing: A Multimodal Analytics Approach - Proceedings of the 2025 6th International Conference on Education, Knowledge and Information Management”. In *ICEKIM '25: Proceedings of the 2025 6th International Conference on Education, Knowledge and Information Management*, June 20 - 22, 2025, Cambridge United Kingdom, ACM, New York, NY, United States, p. 604 - 608.
- Souza, M. T., Silva, M. D., & Carvalho, R. (2010). “Revisão integrativa: O que é e como fazer.” *Einstein (São Paulo)*, 8(1, Pt. 1), 102–106.
- Sun, T. et al. (2025). “A Video-Based Action Recognition Intelligent Assessment System for Art Education: A Case Study on Fundamentals of Sketching - Proceedings of the 2025 2nd International Symposium on Artificial Intelligence for Education”. In *ISAIE '25: Proceedings of the 2025 2nd International Symposium on Artificial Intelligence for Education*, September 19 - 21, 2025, Changsha China, ACM, New York, NY, United States, p. 662 - 667.

- Tsai, Y.-S. et al. (2022). “Charting Design Needs and Strategic Approaches for Academic Analytics Systems through Co-Design”. In LAK '22: Proceedings of the 12th Learning Analytics and Knowledge Conference, March 21–25, 2022, Online, ACM, New York, NY, United States, p. 381–391.
- Vrzakova, H. et al. (2020). “Focused or Stuck Together: Multimodal Patterns Reveal Triads’ Performance in Collaborative Problem Solving”. In LAK '20: Proceedings of the Tenth International Conference on Learning Analytics & Knowledge, March 23 - 27, 2020, Frankfurt Germany, ACM, New York, NY, United States, p. 295 - 304.
- Wang, Y.; Lu, S.; Harter, D. (2020). “Eye Tracking and Learning Analytics for Promoting Proactive Teaching and Learning in Classroom: A Survey”. In LAK '20: Proceedings of the 10th International Conference on Learning Analytics & Knowledge, March 23–27, 2020, Frankfurt, Germany (Virtual Event), ACM, New York, NY, United States, p. 156–160.
- Wang, Z. et al. (2024). “Unveiling Synchrony of Learners’ Multimodal Data in Collaborative Maker Activities - Proceedings of the 14th Learning Analytics and Knowledge Conference”. In LAK '24: Proceedings of the 14th Learning Analytics and Knowledge Conference, March 18 - 22, 2024, Kyoto Japan, ACM, New York, NY, United States, p. 922 - 928.
- Yan, L. et al. (2025). “From Complexity to Parsimony: Integrating Latent Class Analysis to Uncover Multimodal Learning Patterns in Collaborative Learning - Proceedings of the 15th International Learning Analytics and Knowledge Conference”. In LAK '25: The 15th International Learning Analytics and Knowledge Conference, March 3 - 7, 2025, Dublin Ireland, ACM, New York, NY, United States, p. 70 - 81.
- Zhang, G. et al. (2025). “CPVis: Evidence based Multimodal Learning Analytics for Evaluation in Collaborative Programming”. In CHI '25: Proceedings of the 2025 CHI Conference on Human Factors in Computing Systems, April 26 - May 1, 2025, Yokohama Japan, ACM, New York, NY, United States, Article No.: 50, p. 1 - 26.
- Zhang, W. et al. (2025). “Research on a Machine Learning-Based Personalized Learning Path Generation Model for Accounting Education - Proceedings of the 2025 2nd International Symposium on Artificial Intelligence for Education.”. In ISAIE '25: Proceedings of the 2025 2nd International Symposium on Artificial Intelligence for Education, September 19 - 21, 2025, Changsha China, ACM, New York, NY, United States, p. 643 - 651.
- Zhao, L. et al. (2022). “Modelling Co-located Team Communication from Voice Detection and Positioning Data in Healthcare Simulation”. In LAK22: 12th International Learning Analytics and Knowledge Conference, March 21–25, 2022, Online, USA, ACM, New York, NY, USA, p. 370–380.
- Zhao, L. et al. (2023). “METS: Multimodal Learning Analytics of Embodied Teamwork Learning”. In LAK2023: LAK23: 13th International Learning Analytics and Knowledge Conference, March 13 - 17, 2023, Arlington TX USA, ACM, New York, NY, United States, p. 186 - 196.

- Zhao, L. et al. (2024). “Epistemic Network Analysis for End-users: Closing the Loop in the Context of Multimodal Analytics for Collaborative Team Learning”. In LAK '24: Proceedings of the 14th Learning Analytics and Knowledge Conference, March 18 - 22, 2024, Kyoto Japan, ACM, New York, NY, United States, p. 90 - 100.
- Zhou, Q. et al. (2024). “Harnessing Transparent Learning Analytics for Individualized Support through Auto detection of Engagement in Face-to-Face Collaborative Learning”. In LAK '24: Proceedings of the 14th Learning Analytics and Knowledge Conference, March 18 - 22, 2024, Kyoto Japan, ACM, New York, NY, United States, p. 392 – 403.