

## “A IA sabe tudo?”: um caso sobre letramento crítico em Inteligência Artificial no Ensino Fundamental

Cristiana Pedrosa<sup>1</sup>, Jeniffer Macena<sup>1,2</sup>, José Brito<sup>1,2</sup>, Fernanda Pires<sup>1</sup>,  
Marcela Pessoa<sup>1</sup>

<sup>1</sup> Universidade do Estado do Amazonas - Escola Superior de Tecnologia (UEA/EST)  
ThinkTED Lab - Pesquisa, Desenvolvimento e Inovação em tecnologias emergentes

<sup>2</sup>Programa de Pós-Graduação em Informática (PPGI)  
Instituto de Computação – Universidade Federal do Amazonas (IComp-UFAM)  
{cdnp.lic23, fpires, mspessoa}@uea.edu.br  
jeniffer.souza@icomp.ufam.edu.br

**Abstract.** *The use of Artificial Intelligence tools has grown rapidly among students of Basic Education, but do they have a critical understanding about this? This work reports a pedagogical intervention with 9th-grade students from a public school aiming to evaluate the level of knowledge of the students about AI. During the intervention, reported as a case study with an exploratory qualitative approach, unplugged activities, activities with Google Teachable Machine and the reflection about the perceptions of the students were performed. Evaluation indicates that the students migrate from utilitarian patterns to reflective ones as they understand better its mechanisms, recognize that AI makes mistakes and explain it by data and algorithms.*

**Resumo.** *O uso de ferramentas de Inteligência Artificial (IA) tem crescido rapidamente entre estudantes da Educação Básica, entretanto, o que se busca entender é qual o nível de compreensão crítica eles têm sobre isso. Este trabalho relata uma intervenção pedagógica com estudantes do 9º ano de uma escola pública visando avaliar o nível do conhecimento dos estudantes sobre IA. Durante a intervenção, relatada como estudo de caso com abordagem qualitativa exploratória, foram realizadas atividades desplugadas, atividades com Google Teachable Machine e a reflexão sobre as percepções dos estudantes. Avaliação indica que os estudantes migram de padrões utilitários para reflexivos à medida que compreendem melhor seus mecanismos, reconhecem que a IA erra e a explicam por dados e algoritmos.*

### 1. Introdução

A popularização das ferramentas de Inteligência Artificial (IA) transformou de forma acelerada a relação de estudantes e professores com a produção e o acesso ao conhecimento [Sousa and Cruz 2024]. Segundo a pesquisa TIC Educação 2024, 39% dos estudantes dos anos finais do Ensino Fundamental já utilizaram ferramentas como *ChatGPT*<sup>1</sup>, *Copilot*<sup>2</sup> e *Gemini*<sup>3</sup> para pesquisas escolares, mas apenas 19% receberam orientação de professores sobre seu uso adequado [NIC.br 2024]. Essa situação traz grandes desafios para a

<sup>1</sup>Disponível em <https://chat.openai.com>.

<sup>2</sup>Disponível em <https://copilot.microsoft.com>.

<sup>3</sup>Disponível em <https://gemini.google.com>.

educação, pois estudantes que usam IA sem entender seu funcionamento, como os processos de treinamento de dados, inferência e geração de respostas, tendem a aceitar todas as respostas sem pensar e prejudicam o próprio desenvolvimento do pensamento crítico e da tomada de decisão [Zhai et al. 2024].

No Brasil, o letramento digital evoluiu de uma competência instrumental para uma dimensão crítica, reflexiva e ética [Martins and Kersch 2023]. Letrar criticamente em IA significa desenvolver no estudante a capacidade de compreender esses sistemas, avaliar suas limitações e implicações e utilizá-los de forma autônoma e responsável [Valério and Santos Filho 2024].

Apesar do respaldo da Lei nº 14.533/2023, do Complemento à BNCC para Computação e do Referencial da IA na Educação, lançado pelo MEC em 2026 [BRASIL. Ministério da Educação 2026], sua aplicação efetiva nas escolas ainda é um desafio, pois mais de 40% dos professores não têm preparo para usar recursos digitais em sala [Pereira and Moura 2023, Amemasor et al. 2025]. Por exemplo, no estado do Amazonas, o problema se agrava pela precariedade da infraestrutura, na qual apenas 66,7% das escolas possuem internet e somente 43,4% a utilizam no processo de aprendizagem, evidenciando que o acesso não garante uso pedagógico [INEP 2026].

Diante desse cenário, sequências didáticas estruturadas, que consistem em atividades de aprendizagem conectadas passo a passo para atingir um objetivo específico, emergem como abordagem capaz de organizar intervenções pedagógicas de forma progressiva e avaliável, adequada para introduzir conceitos de IA de forma prática e reflexiva, sem pressupor conhecimentos prévios de programação [Rodríguez-García et al. 2021, Pereira and Moura 2023].

Este trabalho apresenta uma intervenção educacional desenvolvida no Estágio Supervisionado em Computação 1, na Escola Estadual de Tempo Integral Altair Severiano Nunes no município de Manaus (AM). O objetivo é investigar as percepções de estudantes do 9º ano do Ensino Fundamental sobre IA e analisar como esses entendimentos se modificam ao longo de uma sequência didática de três aulas. Na primeira, os estudantes discutiram o que é IA e seus limites a partir de uma atividade baseada no Teste de Turing. Na segunda, simularam como a IA aprende com exemplos, construindo árvores de decisão com cartas. Na terceira, treinaram e testaram seus próprios modelos de reconhecimento de imagens no *Google Teachable Machine*<sup>4</sup> (GTM), observando na prática quando e por que a IA erra.

Os resultados indicam que, ao final, as respostas da turma passaram a descrever a IA com mais frequência pelo seu funcionamento interno, mencionando dados e algoritmos, e não apenas pelo que ela faz no cotidiano.

## 2. Referencial Teórico

Estudos recentes indicam que estudantes tendem a tratar respostas de assistentes virtuais como verdades absolutas, enquanto escolas ainda focam no uso técnico da tecnologia sem debater questões éticas [Alfarwan 2025, Gouseti et al. 2025]. Para mitigar esse cenário, a literatura propõe o desenvolvimento do Letramento em IA, conjunto de competências que permite conhecer seu funcionamento, aplicá-lo e avaliar criticamente suas

<sup>4</sup>Disponível em <https://teachablemachine.withgoogle.com/>.

implicações éticas [Long and Magerko 2020, Ng et al. 2021, Veldhuis et al. 2025]. A facilidade do uso de interfaces, porém, esconde a ausência de compreensão conceitual [Reid et al. 2023, Mertala et al. 2024], levando estudantes a aceitar soluções de forma passiva [Zhai et al. 2024].

Para enfrentar esse desafio, a Teoria da Aprendizagem Significativa de Ausubel conecta novos conteúdos ao conhecimento prévio do estudante [Ausubel 1982], partindo de experiências cotidianas, como redes sociais, para discutir IA em sala de aula [Iqbal et al. 2025, Chiu et al. 2024]. Diante da falta de infraestrutura nas escolas [Oliveira et al. 2021], a Computação Desplugada viabiliza a compreensão de conceitos computacionais sem equipamentos [Grebogoy et al. 2025].

Complementarmente, o Construcionismo de Papert sustenta que atividades práticas de criação aprofundam a aprendizagem [Soffner 2022], e ferramentas como o GTM permitem que estudantes treinem modelos e visualizem como a máquina aprende [Dwivedi et al. 2021], desmistificando a tecnologia e promovendo um olhar mais crítico sobre ela [Vicari et al. 2023, Azambuja and Silva 2024]. A seguir, detalham-se estudos que utilizam ferramentas práticas de IA na Educação Básica para o desenvolvimento do Letramento em IA e do Pensamento Computacional.

### 3. Trabalhos Relacionados

Rodríguez-García et al. (2021) investigaram se estudantes de 10 a 16 anos aprendem conceitos de *Machine Learning* (ML) por meio de atividades práticas com a plataforma *LearningML*. A intervenção, realizada on-line com 135 participantes e avaliada por pré e pós-teste, mostrou melhoria significativa na compreensão de ML, sobretudo entre estudantes com menos conhecimento prévio, além de uma mudança de percepção, onde a IA deixou de ser associada a robôs e passou a ser relacionada à resolução de problemas.

Nilson et al. (2025) investigaram o uso de ML na educação básica em um estudo descritivo-exploratório com o GTM e o *MIT RAISE Playground*<sup>5</sup>, aplicado a estudantes do 1º ano do Ensino Médio de uma escola privada de Manaus/AM. Os resultados indicaram bom desempenho em raciocínio sequencial e boa compreensão dos conceitos de ML, além de uma relação entre baixo desempenho no diagnóstico e menor domínio dos conteúdos de ML, sugerindo interconexão entre lógica, Pensamento Computacional (PC) e ML.

Liu et al (2024) desenvolveram um currículo escolar de IA para o Ensino Médio, por meio de aulas expositivas e aprendizagem baseada em projetos, abrangendo módulos de ML, Redes Neurais e programação em *Python*. Os resultados de um quase-experimento confirmaram melhorias significativas no PC dos estudantes, especialmente em pensamento algorítmico e resolução de problemas.

Os trabalhos relacionados são comparados com essa proposta na Tabela 1, a partir de quatro aspectos: Letramento em IA (LIA), Computação Desplugada (CD), *Google Teachable Machine* (GTM) e Educação Básica (EB). Embora todos abordem ML na Educação Básica, nenhum deles reúne os quatro aspectos simultaneamente. O diferencial desta proposta está em combiná-los com foco no desenvolvimento do pensamento crítico sobre IA na Educação Básica.

---

<sup>5</sup>Disponível em <https://playground.raise.mit.edu/>.

**Tabela 1. Tabela comparativa entre os trabalhos relacionados e esta proposta.**

| Trabalho                       | LIA | CD | GTM | EB |
|--------------------------------|-----|----|-----|----|
| Rodríguez-García et al. (2021) | ✓   | –  | –   | ✓  |
| Nilson et al. (2025)           | –   | –  | ✓   | ✓  |
| Liu et al. (2024)              | –   | –  | –   | ✓  |
| <b>Este Trabalho</b>           | ✓   | ✓  | ✓   | ✓  |

#### 4. Metodologia

Nesta seção, descreve-se a metodologia adotada para avaliar o nível de conhecimento dos estudantes sobre IA e o desenvolvimento de seu letramento crítico, por meio de uma sequência didática aplicada a uma turma do 9º ano do Ensino Fundamental em uma escola pública de Manaus. O trabalho caracteriza-se como um estudo de caso com abordagem qualitativa exploratória com apoio de dados quantitativos descritivos, cujo objetivo é acompanhar como as concepções dos estudantes sobre IA se modificam antes e após a intervenção. A investigação apoia-se em três fontes de dados:

- i) **Observação participante**, realizada pela estagiária-pesquisadora ao longo das três aulas;
- ii) **Dados qualitativos e quantitativos**, obtidos do questionário diagnóstico (pré-teste) e do pós-teste, compostos por questões abertas e fechadas sobre concepções de IA;
- iii) **Dados de engajamento afetivo**, coletados pelo instrumento *Emoti-SAM*.

A Figura 1 ilustra as etapas do estudo, do diagnóstico inicial à análise dos dados.



**Figura 1. Etapas da Pesquisa.**

A intervenção integrou o Estágio Supervisionado em Computação 1, disciplina da Licenciatura em Computação, e contou com o acompanhamento de uma professora tutora na escola e de uma orientadora na universidade. O estágio se organizou em três etapas. Na primeira, de caráter diagnóstico, a estagiária-pesquisadora acompanhou a rotina da turma, sobretudo nas aulas de Língua Portuguesa, devido à ausência na instituição de docentes que tratem de temas relacionados à computação, documentando, por meio de diário de bordo e registros, a dinâmica das aulas, o uso de tecnologias, as falas dos estudantes consideradas relevantes e as dificuldades vivenciadas no cotidiano escolar.

Foi nessa fase que se identificou o uso de IA sem mediação pedagógica, inclusive em tarefas de baixa complexidade. Em uma das situações observadas, por exemplo, os estudantes recorreram a uma ferramenta de IA para gerar o *design* de um *post* sobre o Dia

das Mães e o apresentaram como produção própria, em vez de explorarem os recursos disponíveis na plataforma proposta pela professora e desenvolverem a atividade com base na própria criatividade. Em outros momentos, alguns afirmavam que não realizariam determinadas tarefas, pois poderiam recorrer à IA posteriormente. A partir desse diagnóstico, a sequência didática foi planejada na segunda etapa e aplicada na terceira.

O diagnóstico apoiou-se em um questionário aplicado via *Google Forms*, com 19 itens fechados e abertos, que serviu como levantamento do perfil da turma e como pré-teste das concepções prévias sobre IA. As respostas estão disponíveis em uma planilha do *Google Sheets*<sup>6</sup>. A turma do 9º ano era composta por 33 estudantes, dos quais 31 responderam ao questionário, sendo a maioria meninos (58,1%) e com 14 anos (80,6%). A escola possui infraestrutura tecnológica limitada e de acesso restrito (com poucos equipamentos e frequentemente inoperantes). Por isso, as aulas 1 e 3 ocorreram na biblioteca utilizando uma televisão, e a aula 2 em sala de aula com um projetor emprestado. Em todas elas os estudantes ficaram organizados em grupos. Mesmo nesse contexto de poucos recursos, a IA já fazia parte da rotina da turma, sendo que a maioria a utilizava como primeira fonte de pesquisa escolar, conforme detalhado na Seção 6.1.

A sequência didática foi baseada nas atividades desplugadas do projeto *AI Unplugged*, uma iniciativa que propõe o ensino de conceitos de IA por meio de dinâmicas físicas, sem o uso de computadores [Lindner et al. 2019]. As três aulas partiram do conceito de IA, passaram pelo seu funcionamento e chegaram à avaliação crítica de seus resultados, e cada aula trabalhou habilidades de computação da BNCC para o 9º ano. A primeira (50 minutos) foi uma atividade desplugada baseada no Teste de Turing, abordou o conceito de IA, o reconhecimento de padrões e as alucinações dos modelos de linguagem, trabalhando a habilidade EF09CO07 (avaliar aplicações e implicações políticas, socioambientais e culturais das tecnologias digitais para propor alternativas aos desafios do mundo contemporâneo, incluindo aqueles relativos ao mundo do trabalho).

A segunda aula (120 minutos, o dobro do previsto, para dar mais tempo à turma) foi a atividade desplugada “Classificando Macacos”, que usou árvores de decisão para mostrar como a IA aprende com exemplos e discutir o viés algorítmico. A turma foi dividida em sete grupos, com cartas impressas, e material para registrar suas árvores. Ela trabalhou as habilidades EF69CO01 (classificar informações, agrupando-as em coleções (conjuntos) e associando cada coleção a um “tipo de dado”) e EF09CO08 (discutir como a distribuição desigual de recursos de computação em uma economia global levanta questões de equidade, acesso e poder).

A terceira aula (50 minutos) foi uma atividade prática com o GTM, voltada ao treino e teste de modelos de reconhecimento de imagens. Como os *notebooks* não estavam disponíveis, a proposta de trabalho em pequenos grupos foi adaptada para uma demonstração coletiva, conduzida no computador da estagiária com a televisão da biblioteca. Ela trabalhou a habilidade EF09CO10 (avaliar a veracidade, a credibilidade e a relevância da informação em seus diferentes formatos, identificando o propósito pelo qual foi disseminada).

O *Emoti-SAM* [Hayashi et al. 2016] foi adotado por ser um instrumento pictórico e de aplicação rápida, adequado a estudantes da Educação Básica, permitindo registrar a

<sup>6</sup>Respostas disponíveis em <https://doi.org/10.6084/m9.figshare.32521215>

perspectiva da experiência dos estudantes ao final de cada aula sem comprometer o tempo da atividade principal. Baseado no *Self-Assessment Manikin* [Bradley and Lang 1994], mede três dimensões em escalas de cinco pontos: valência (de agradável a desagradável), alerta (de animado a calmo) e compreensão, esta última substituindo a dimensão de dominância do SAM original, por ser mais pertinente aos objetivos pedagógicos. Após a terceira aula, aplicou-se o pós-teste individual, com questões paralelas às do pré-teste.

A análise concentrou-se nas percepções dos estudantes sobre IA. As respostas abertas do pré e do pós-teste foram submetidas à análise de conteúdo temática [Bardin 1977], com o apoio do *software* de planilhas *Google Sheets* para a organização e codificação dos dados, seguindo suas três fases: pré-análise (leitura flutuante das 31 respostas do (pré-teste), exploração do material (codificação das unidades de contexto em categorias temáticas) e tratamento dos resultados (comparação das distribuições categoriais entre os dois momentos). As categorias foram definidas após a leitura das respostas do pré-teste e documentadas em material complementar<sup>7</sup>, com base na recorrência de ideias, atendendo aos critérios de exaustividade e de exclusão mútua relativa, resultando em nove categorias. A mudança nas concepções foi medida comparando a distribuição das categorias entre os dois momentos, no nível da turma. As questões fechadas do pré-teste e o *Emoti-SAM*, dados quantitativos, foram analisados por estatística descritiva, e os registros da observação participante foram usados de forma complementar.

Por se tratar de análise exploratória, três delimitações devem ser explicitadas. Primeiro, a análise não é pareada e as comparações têm natureza grupal, descrevendo deslocamentos na distribuição das categorias no conjunto da turma, sem vinculação de respostas a um mesmo estudante. Segundo, a turma não foi exatamente a mesma nos dois momentos (31 respostas no pré-teste e 30 no pós-teste), o que recomenda cautela na leitura das diferenças. Terceiro, a codificação foi conduzida unicamente pela estagiária-pesquisadora, de modo que o sistema de nove categorias constitui uma primeira aproximação interpretativa.

## 5. Cuidados Éticos

Este estudo foi realizado no Estágio Supervisionado, a partir de uma atividade pedagógica conduzida na rotina da escola e autorizada pela direção. Os instrumentos foram aplicados de forma anônima e os dados analisados apenas de modo agregado, no nível da turma, sem identificação individual dos estudantes. Por essas características, considerou-se que o estudo se enquadra nas situações de dispensa de registro no sistema CEP/CONEP previstas no Art. 1º da Resolução CNS nº 510/2016.

## 6. Resultados e discussões

Nesta seção, são apresentados os resultados obtidos a partir dos instrumentos aplicados antes, durante e após a intervenção pedagógica, indicando as percepções dos estudantes sobre IA, as mudanças observadas ao longo da sequência didática e o engajamento afetivo registrado durante as atividades.

### 6.1. Análise do pré-teste

O questionário diagnóstico caracterizou o contexto digital da turma e sua relação com a IA. O acesso à internet em casa é amplo, com 96,8% dos estudantes conectados por *Wi-Fi*

<sup>7</sup> A análise completa das categorias está disponível em <https://doi.org/10.6084/m9.figshare.32521149>

e 87,1% com dispositivo próprio, o que contrasta com a infraestrutura limitada da escola descrita na Seção 4 e indica que o principal obstáculo não é o acesso, mas a mediação pedagógica. A IA já era a principal fonte de pesquisa escolar, citada por 54,8% dos estudantes, à frente do Google (29,0%), e havia sido usada por 93,5% deles, sobretudo para tirar dúvidas (80,6%) e fazer tarefas (77,4%).

Apesar do uso intenso, a postura crítica era frágil (Tabela 2). Apenas 35,5% dos estudantes verificavam sempre as respostas da IA e somente 38,7% reconheciam que ela erra com frequência, enquanto 19,4% não sabiam se ela erra ou acreditavam que ela sempre acerta. Na questão aberta, predominaram concepções utilitárias. A maioria definiu a IA como ferramenta de auxílio genérico (C1, com 16 menções) ou como meio de pesquisar e tirar dúvidas (C3, com 11 menções), e poucas respostas citaram seu funcionamento técnico (C5, com 4 menções). Essa distribuição é comparada com o pós-teste na Seção 6.3.

**Tabela 2. Postura crítica da turma diante da IA no pré-teste ( $n = 31$ )**

| Verifica as respostas da IA |           | Acha que a IA pode errar |           |
|-----------------------------|-----------|--------------------------|-----------|
| Resposta                    | n (%)     | Resposta                 | n (%)     |
| Sempre                      | 11 (35,5) | Sim, frequentemente      | 12 (38,7) |
| Às vezes                    | 7 (22,6)  | Sim, raramente           | 13 (41,9) |
| Raramente                   | 7 (22,6)  | Não sabe                 | 4 (12,9)  |
| Nunca                       | 6 (19,4)  | Não, sempre acerta       | 2 (6,5)   |

## 6.2. Análise da intervenção

A sequência didática evidenciou um desenvolvimento conceitual consistente ao longo dos três encontros, com recepção afetiva positiva em cada um e com cada atividade preparando os estudantes para a seguinte. Na primeira aula, o Teste de Turing revelou que os estudantes já tinham critérios próprios para distinguir uma resposta humana de uma resposta gerada por computador, mesmo sem saber nomeá-los, eles identificaram o “computador” pelas respostas “secas e frias” (registro da observação participante, alinhado à categoria C6 - Imitação da mente humana, que contrasta características humanas e mecânicas) e participaram ativamente do debate. Um momento de destaque foi o relato de uma estudante que disse preferir conversar com a IA a interagir com pessoas, o que gerou uma discussão espontânea sobre dependência tecnológica.

O tema das alucinações também gerou reconhecimento imediato, com vários estudantes citando situações em que a IA havia dado informações erradas em tarefas escolares. Além disso, os estudantes participaram ativamente da discussão e relacionaram os exemplos apresentados a experiências próprias de uso dessas ferramentas. Os exemplos partiram de experiências que os estudantes já tinham com IA, o que, segundo Ausubel [Ausubel 1982], auxilia a introdução de novos conceitos. O *Emoti-SAM* aplicado ao final ( $n=22$ ) registrou valência média de 4,00 ( $DP=0,82$ ). O alto desvio padrão na dimensão de alerta ( $DP=1,37$ ) era esperado para uma primeira aula sobre um tema novo.

A segunda aula, com a atividade “Classificando Macacos”, foi a mais difícil para a turma e também a que produziu resultados relevantes. Nela, as cartas mostram rostos de macacos com diferentes variáveis visuais (olhos e boca), recebendo o rótulo “Morde”

ou “Não morde”. A tarefa dos grupos é descobrir a regra que combina esses atributos e representá-la como uma árvore de decisão.

As doze cartas de treinamento já vêm separadas nas duas classes e são a base para montar a árvore. As oito cartas de teste aparecem depois, com o rótulo correto, e servem só para conferir se a árvore acerta casos novos. A maioria dos grupos construiu estruturas simples demais e misturou as cartas de treino com as de teste, alguns chegaram a treinar o modelo com as oito cartas de teste em vez das doze de treinamento, o que reduziu a base de exemplos e prejudicou o desempenho, indicando que a distinção entre dados de treino e teste ainda não estava clara.

Mesmo assim, todos os sete grupos perceberam que seu modelo cometeu erros. Em cinco grupos, esses erros foram associados ao modo como os dados foram usados na atividade, principalmente à confusão entre cartas de treino e cartas de teste. A discussão final levou esse raciocínio para situações reais, como vieses em sistemas de reconhecimento facial. O *Emoti-SAM* (n=29) registrou valência de 4,24 (DP=0,79). A leve queda na média de compreensão, de 3,73 para 3,62, acompanhada da alta no desvio padrão, de 0,63 para 1,08 mostra diferentes níveis de compreensão da atividade entre os grupos: alguns compreenderam a lógica da árvore de decisão, enquanto outros ainda tentavam entender a diferença entre treino e teste.

Na terceira aula, devido à indisponibilidade de *notebooks*, a prática em pequenos grupos precisou ser convertida em uma demonstração conduzida pela estagiária. Embora tenha perdido seu caráter prático para se tornar uma análise guiada, o novo formato permitiu que a turma acompanhasse a atividade ao mesmo tempo e discutisse como as escolhas de imagens influenciam os acertos e erros da IA. O engajamento ficou evidente durante a demonstração de um modelo treinado com poucas imagens, momento em que os estudantes notaram, de forma autônoma, que variações de luz e ângulo afetam o desempenho da IA, relacionando o conceito às árvores de decisão da aula anterior.

Essa dinâmica tornou-se ainda mais clara no teste coletivo com um modelo treinado com uma base maior de imagens, que obteve 100% de precisão ao analisar os participantes, mas apresentou falhas ao avaliar indivíduos fora da base de treinamento original. Assim, o relato dos estudantes sugere que conceitos abordados em uma aula foram retomados nas atividades subsequentes, o que caracteriza a aprendizagem significativa em andamento.

O *Emoti-SAM* (n=30) registrou os maiores valores da sequência, com valência de 4,50 (DP=0,82), alerta de 3,90 e compreensão de 4,13 (DP=0,90). A redução no desvio padrão de compreensão, de 1,08 (Aula 2) para 0,90 (Aula 3), sugere que a prática com o GTM ajudou a turma a consolidar o que havia sido introduzido na aula anterior. A valência manteve-se estável e positiva nos três encontros (DP em torno de 0,82), indicando que a turma respondeu bem à sequência como um todo.



**Tabela 3. Estatísticas descritivas do *Emoti-SAM* por aula, em escala de 1 a 5**


| Dimensão    | Aula 1 ( <i>n</i> = 22) |         |      | Aula 2 ( <i>n</i> = 29) |         |      | Aula 3 ( <i>n</i> = 30) |         |      |
|-------------|-------------------------|---------|------|-------------------------|---------|------|-------------------------|---------|------|
|             | Média                   | Mediana | DP   | Média                   | Mediana | DP   | Média                   | Mediana | DP   |
| Valência    | 4,00                    | 4       | 0,82 | 4,24                    | 4       | 0,79 | 4,50                    | 5       | 0,82 |
| Alerta      | 3,45                    | 4       | 1,37 | 3,48                    | 4       | 1,24 | 3,90                    | 4       | 1,03 |
| Compreensão | 3,73                    | 4       | 0,63 | 3,62                    | 4       | 1,08 | 4,13                    | 4       | 0,90 |

De forma geral, os dados do *Emoti-SAM* (Tabela 3) refletem a sequência didática: a primeira aula abriu o debate a partir do que os estudantes já sabiam, a segunda gerou um desafio real, com respostas mais dispersas, e a terceira consolidou os conceitos na prática, com os maiores índices de valência e compreensão. Como o número de respondentes variou entre as aulas (*n*=22, 29 e 30), os valores de cada encontro devem ser lidos como registros independentes da reação a cada atividade.

### 6.3. Análise do pós-teste

O pós-teste foi aplicado individualmente ao final da Aula 3, com 30 estudantes presentes e codificado com o mesmo sistema categorial do pré-teste, permitindo comparar as distribuições entre os dois momentos, apresentadas na Figura 2.

A categoria C1 (Ferramenta/auxílio genérico) permaneceu dominante, mas as respostas passaram a combiná-la com C5 com mais frequência, como em “*é uma inteligência criada a partir de dados fornecidos por nós*” (E6). C5 (Sistema técnico) foi a categoria que mais cresceu, de 4 para 7 menções, resultado compatível com a indicação de que as atividades práticas aproximaram a turma do funcionamento interno da tecnologia. C6 (Imitação da mente humana) também cresceu, de 1 para 3 menções, enquanto C2 (Aplicação no cotidiano) teve a queda mais expressiva, de 8 para 2, indicando que menos estudantes definiram a IA apenas pelo que ela faz no dia a dia.

**Figura 2. Distribuição das categorias no pré e pós-teste**

Em conjunto, os dados mostram retração nas categorias utilitárias e crescimento nas que refletem compreensão do funcionamento da tecnologia, resultado coerente com a Teoria de Ausubel, em que o conhecimento prévio não é substituído, mas refinado. A permanência de C1 como categoria dominante não indica falta de aprendizagem, C1 foi a âncora sobre a qual C5 se apoiou, e a queda de C2 reforça que essa âncora foi reorganizada, pois a turma deixou de definir a IA pelo que ela faz e passou a explicar

como ela funciona. Cabe ressaltar que os resultados a seguir descrevem tendências gerais do grupo, dado que a análise não foi pareada e a codificação foi conduzida por uma única pesquisadora. As respostas à questão aberta sobre o aprendizado mais importante reforçam essa mudança. A maioria destacou a possibilidade de erro da IA como principal aprendizado, com respostas como “*eu descobri que a IA pode errar e eu não sabia*” (E22) e “*a IA não deve ser confiável por ser um banco de dados abertos*” (E19). Alguns foram além, mencionando o funcionamento da tecnologia: “*como ela obtém nossas respostas e aprende a se comportar*” (E25) e “*aprendi sobre a árvore de decisão*” (E7). A atividade da Aula 2 foi a mais citada como difícil, com quatro estudantes mencionando a árvore de decisão com as cartas dos macacos. Quanto ao engajamento, 19 dos 30 estudantes atribuíram nota máxima ao quanto seu conhecimento aumentou, e 8 afirmaram se sentir seguros para explicar o que aprenderam a outra pessoa.

## 7. Considerações finais

Este trabalho investigou como as concepções de estudantes do 9º ano sobre IA se transformam ao longo de uma sequência didática de letramento crítico. Após três aulas que combinaram atividades desplugadas e prática com o *Google Teachable Machine*, as respostas da turma migraram de definições centradas no que a IA faz para menções ao seu funcionamento interno, sobretudo ao papel dos dados e dos algoritmos. A noção de que a IA pode errar emergiu espontaneamente como o aprendizado mais lembrado, sugerindo um discurso coletivo mais crítico. No engajamento afetivo, a Aula 3, centrada em uma ferramenta real, registrou as maiores médias de valência (4,50) e de compreensão (4,13). Apesar da variação de respondentes, os valores indicam uma recepção consistentemente positiva em todos os encontros, e a dificuldade com as árvores de decisão, na Aula 2, atuou como desafio mobilizador, não como obstáculo.

A permanência da visão utilitária (C1) ao lado do crescimento das categorias técnicas (C5 e C6) é coerente com Ausubel [Ausubel 1982], já que a intervenção reorganizou o conhecimento prévio em vez de substituí-lo, o que sugere que o letramento crítico em IA funciona melhor quando parte das concepções que a turma já traz. Em conjunto, os achados sugerem que combinar atividades desplugadas e prática em ferramentas reais é viável para desenvolver o letramento crítico em IA na educação básica pública, mesmo com infraestrutura limitada, embora três aulas sejam apenas um ponto de partida que sequências mais longas poderiam aprofundar.

## 8. Limitações e Trabalhos Futuros

No aspecto prático, a adaptação da Aula 3, de construção em grupos para demonstração coletiva, afastou-se do caráter construcionista planejado, ainda que tenha preservado o debate crítico. Por fim, a amostra restringe-se a uma única turma de uma única escola, e características locais podem ter influenciado os achados de modo não replicável.

O estudo apresenta limitações. Os instrumentos não permitiram análise pareada, de modo que as comparações descrevem tendências do grupo e não a mudança conceitual individual, ressalva reforçada pela variação de presença entre os encontros. A codificação das respostas abertas, feita por uma única pesquisadora, torna as nove categorias uma leitura interpretativa. Sua validação por concordância entre juízes está planejada como próximo passo da pesquisa, mediante a recodificação das respostas por um segundo avaliador independente e o cálculo do respectivo índice de concordância.

## 9. Agradecimentos

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (AUXPE-CAPES-PROEX) - Código de Financiamento 001. Adicionalmente, foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado do Amazonas - FAPEAM - por meio do projeto PDPG-CAPES. Por fim, agradecemos à UEA, por meio do Programa de Produtividade Acadêmica 01.02.011304.026472/2023-87, ao laboratório NEXUS, prédio base do Grupo de Pesquisa ThinkTed.

## Declaração sobre uso de Inteligência Artificial

Este trabalho utilizou Inteligência Artificial Generativa apenas como apoio. O Gemini gerou as ilustrações da Figura 1. A concepção e a organização dessa figura são de autoria dos pesquisadores. O *Claude* auxiliou exclusivamente na formatação das tabelas. O *NotebookLM* revisou a gramática e a ortografia do texto original. Nenhuma ferramenta de IA coletou, analisou ou interpretou os dados da pesquisa. Todas as etapas práticas e os resultados apresentados foram conduzidos integralmente pelos autores. As ferramentas não são listadas como autoras. Os pesquisadores revisaram todo o conteúdo e assumem total responsabilidade pelo material e por sua originalidade.

## Referências

- Alfarwan, A. (2025). Generative ai use in k-12 education: A systematic review. In *Frontiers in Education*, volume 10, page 1647573. Frontiers Media SA.
- Amemasor, S. K., Oppong, S. O., Ghansah, B., Benuwa, B.-B., and Essel, D. D. (2025). A systematic review on the impact of teacher professional development on digital instructional integration and teaching practices. *Frontiers in Education*, Volume 10 - 2025.
- Ausubel, D. P. (1982). A aprendizagem significativa. *São Paulo: Moraes*.
- Azambuja, C. C. d. and Silva, G. F. d. (2024). Novos desafios para a educação na era da inteligência artificial. *Filosofia Unisinos*, 25(1):e25107.
- Bardin, L. (1977). *Análise de conteúdo*. Edições 70.
- Bradley, M. M. and Lang, P. J. (1994). Measuring emotion: The self-assessment manikin and the semantic differential. *Journal of Behavior Therapy and Experimental Psychiatry*, 25(1):49–59.
- BRASIL. Ministério da Educação (2026). Referencial para o desenvolvimento e uso responsáveis de inteligência artificial na educação. Technical report, Ministério da Educação (MEC), Brasília, DF.
- Chiu, T. K., Ahmad, Z., Ismailov, M., and Sanusi, I. T. (2024). What are artificial intelligence literacy and competency? a comprehensive framework to support them. *Computers and Education Open*, 6:100171.
- Dwivedi, U., Gandhi, J., Parikh, R., Coenraad, M., Bonsignore, E., and Kacorri, H. (2021). Exploring machine teaching with children. In *Proceedings. IEEE Symposium on Visual Languages and Human-Centric Computing*, volume 2021, pages 10–1109.

- Gouseti, A., James, F., Fallin, L., and Burden, K. (2025). The ethics of using ai in k-12 education: A systematic literature review. *Technology, Pedagogy and Education*, 34(2):161–182.
- Grebogy, E. C., Santos, I., and Castilho, M. A. (2025). Computação desplugada: Um recurso para o estímulo de habilidades relacionadas ao pensamento computacional nos anos iniciais do ensino fundamental-resumo estendido. In *Anais do Simpósio Brasileiro de Informática na Educação (SBIE)*, pages 1846–1849. SBC.
- Hayashi, E. C., Posada, J. E. G., Maike, V. R., and Baranauskas, M. C. C. (2016). Exploring new formats of the self-assessment manikin in the design with children. In *Proceedings of the 15th Brazilian Symposium on Human Factors in Computing Systems*, pages 1–10.
- INEP (2026). Censo escolar da educação básica 2025: Microdados. Acesso em: 19 mai. 2026.
- Iqbal, M., Singh, K., Khan, S., Osho, O., Sidnam-Mauch, E., Bannister, N., Caine, K., and Knijnenburg, B. (2025). Teaching ai awareness in middle school classrooms: Design, implementation and evaluation of two education modules on algorithmic bias and filter bubbles. *Computers and Education: Artificial Intelligence*, 8:100425.
- Lindner, A., Seegerer, S., and Romeike, R. (2019). Unplugged activities in the context of ai. In *International conference on informatics in schools: Situation, evolution, and perspectives*, pages 123–135. Springer.
- Liu, J., Ma, J., and Li, S. (2024). Research on school-based ai curriculum design and practice for cultivating computational thinking in high school students. *Education and Information Technologies*, 30:7949–7993.
- Long, D. and Magerko, B. (2020). What is ai literacy? competencies and design considerations. In *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems (CHI)*, pages 1–16.
- Martins, A. P. S. and Kersch, D. F. (2023). Novos tempos, novas perspectivas: Res-significando a escrita reflexiva na formação inicial de professores na construção do letramento didático-digital. *Educação em Revista*, 39:e20700.
- Mertala, P., López-Pernas, S., Vartiainen, H., Saqr, M., and Tedre, M. (2024). Digital natives in the scientific literature: A topic modeling approach. *Computers in Human Behavior*, 152:108076.
- Ng, D. T. K., Leung, J. K. L., Chu, S. K. W., and Qiao, M. S. (2021). Conceptualizing ai literacy: An exploratory review. *Computers and Education: Artificial Intelligence*, 2:100041.
- NIC.br (2024). TIC educação 2024: pesquisa sobre o uso das tecnologias de informação e comunicação nos domicílios brasileiros. Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (Cetic.br). Tabela H4B — Alunos que receberam orientação e apoio dos professores sobre o uso de tecnologias digitais nos últimos três meses: privacidade e proteção de dados pessoais. Tabelas.

- Nilson, J., Honda, F., Lima, M., Pires, F., and Pessoa, M. (2025). IA na educação básica: um estudo descritivo-exploratório com Google Teachable Machine e MIT RAISE Playground. In *Anais do Workshop de Informática na Escola (WIE)*, pages 208–219. SBC.
- Oliveira, W., Cambraia, A., and Hinterholz, L. (2021). Pensamento computacional por meio da computação desplugada: Desafios e possibilidades. In *Anais do Workshop sobre Educação em Computação (WEI)*, pages 468–477, Porto Alegre, RS, Brasil. SBC.
- Pereira, I. d. S. D. and Moura, S. A. d. (2023). Explorações teóricas e oportunidades de integração curricular do letramento em inteligência artificial (ia) na educação básica. Preprint. Acessado em: 16 abr. 2026.
- Reid, L., Button, D., and Brommeyer, M. (2023). Challenging the myth of the digital native: A narrative review. *Nursing Reports*, 13(2):573–600.
- Rodríguez-García, J. D., Moreno-León, J., Román-González, M., and Robles, G. (2021). Evaluation of an online intervention to teach artificial intelligence with LearningML to 10-16-year-old students. In *Proceedings of the 52nd ACM Technical Symposium on Computer Science Education (SIGCSE)*, pages 177–183, New York, NY, USA. ACM.
- Soffner, R. K. (2022). Seymour papert, computadores e educação: uma revisão retrospectiva e propositiva.
- Sousa, H. and Cruz, D. (2024). Capacitando educadores com ia generativa: Implicações na educação. In *Anais do Simpósio Brasileiro de Informática na Educação (SBIE)*, pages 1931–1941, Porto Alegre, RS, Brasil. SBC.
- Valério, E. d. M. and Santos Filho, J. M. d. (2024). Letramento em inteligência artificial: Uma reflexão a partir do guia da UNESCO sobre competências em IA para professores. *Revista Tópicos*, 2(13):1–17. Qualis A2. Acessado em: 16 abr. 2026.
- Veldhuis, A., Lo, P. Y., Kenny, S., and Antle, A. N. (2025). Critical artificial intelligence literacy: A scoping review and framework synthesis. *International Journal of Child-Computer Interaction*, 43:100708.
- Vicari, R. M., Brackmann, C., Mizusaki, L., and Galafassi, C. (2023). *Inteligência artificial na educação básica*. Novatec Editora.
- Zhai, C., Wibowo, S., and Li, L. (2024). The effects of over-reliance on ai dialogue systems on students’ cognitive abilities: a systematic review. *smart learn. environ.* 11, 28 (2024).