

IA na Educação Básica: um estudo descritivo-exploratório com *Google Teachable Machine* e *MIT RAISE Playground*

José Nilson¹, Fabrizio Honda¹, Márcia Lima¹, Fernanda Pires¹, Marcela Pessoa¹

¹Escola Superior de Tecnologia – Universidade do Estado do Amazonas (EST/UEA)
ThinkTED Lab - Pesquisa, Desenvolvimento e Inovação em Tecnologias Emergentes

{jnbds.lic21,msllima,fpires,mspessoa}@uea.edu.br

fabrizio.honda@icom.ufam.edu.br

Abstract. *Artificial Intelligence (AI) techniques, such as Machine Learning (ML), contribute to the development of logic and Computational Thinking (CT) in Basic Education. This paper describes a descriptive-exploratory study aimed at (i) analyzing the cognitive profile of students regarding logic and CT, (ii) assessing their self-perception of motivation, engagement, and difficulties in using ML technologies, and (iii) investigating possible relationships between these aspects. The results indicate good performance in logic, positive reception and understanding of ML concepts and technologies, and a relationship between low performance in the diagnostic assessment and mastery of ML content, reinforcing the interconnection between logic/CT and ML.*

Resumo. *Técnicas de Inteligência Artificial (IA), como Machine Learning (ML), contribuem para desenvolvimento da lógica e do Pensamento Computacional (PC) na Educação Básica. Nesse contexto, este paper descreve um estudo descritivo-exploratório para: (i) analisar o perfil cognitivo de estudantes em relação à lógica e PC; (ii) avaliar sua autopercepção de motivação, engajamento e dificuldades no uso de tecnologias de ML; e (iii) investigar possíveis relações entre esses aspectos. Os resultados indicam um bom desempenho em lógica, boa recepção e entendimento de conceitos e das tecnologias de ML, além de uma relação entre baixo desempenho na avaliação diagnóstica e domínio dos conteúdos de ML, reforçando o entrelaçamento entre lógica/PC e ML.*

1. Introdução

A Inteligência Artificial (IA) consolida-se como uma das tecnologias mais promissoras da atualidade, impactando em áreas como saúde, indústria, comunicação e educação [Kamalov et al. 2023]. Dadas suas contribuições e aplicabilidade, países como China, Emirados Árabes Unidos e Estônia já tornaram obrigatória a inserção da IA na Educação Básica [Insider 2025, Times 2025b, Times 2025a]. No Brasil, há projetos em tramitação para instaurar essa política [Brasil 2025, Brasil 2023, Brasil 2024]. A introdução da IA no âmbito escolar traz benefícios diversos, incluindo a formação de competências digitais críticas, como análise de dados, lógica computacional e pensamento preditivo, fundamentais para a inserção dos estudantes no mercado atual [Jiang and Jiang 2024].

Além disso, a inserção de técnicas de IA pode contribuir para fomentar o PC, uma habilidade que auxilia a resolver problemas complexos de formas mais simples,

fundamental para todos e não apenas para cientistas da computação [Wing 2006]. Essa contribuição é relevante, pois estudantes apresentam dificuldades em lógica, especialmente no desenvolvimento do PC, competências essenciais no contexto educacional contemporâneo [Caruso and Cavalheiro 2021]. Conforme Wing [2006], o PC facilita a aprendizagem de disciplinas como matemática e ciências exatas, pois envolve habilidades como abstração, decomposição e construção de algoritmos. No entanto, estudantes enfrentam desafios nessas áreas, o que impacta diretamente o desempenho escolar, como evidenciado por pesquisas [Andrade et al. 2024, França and Tedesco 2015, Montuori et al. 2023].

Nesse contexto, o uso de IA pode fomentar o PC oferecendo ferramentas interativas que apoiam a resolução de problemas complexos, como plataformas adaptativas, agentes conversacionais e sistemas de recomendação. Ferramentas de IA oferecem *feedback* instantâneo, orientações personalizadas e simulam situações práticas, tornando o aprendizado mais envolvente e acessível [Nascimento et al. 2024]. Além disso, o campo de ML, que envolve o desenvolvimento de algoritmos capazes de aprender e serem otimizados com base em dados, também traz contribuições ao desenvolvimento do PC [Lopes et al. 2020, Morais 2019], reforçando os aspectos positivos da aplicação da IA.

Diante disso, este trabalho tem como objetivos: (i) caracterizar o perfil cognitivo de estudantes de Ensino Médio de uma escola privada em relação à lógica e ao PC, por meio de avaliação diagnóstica; (ii) analisar a percepção dos estudantes sobre motivação e engajamento no uso de tecnologias de IA, especificamente ML, bem como identificar as principais dificuldades relatadas; e (iii) investigar as relações entre o perfil cognitivo e os critérios autoavaliados. Para atingir esses objetivos, realizou-se um estudo descritivo-exploratório. Os resultados indicam que as ferramentas de ML contribuíram para a motivação e diversão dos estudantes. O perfil cognitivo apresenta competências bem desenvolvidas de raciocínio sequencial, representação visual e aplicação de algoritmos simples, relacionadas à lógica e ao PC. O baixo desempenho nas notas apresentou relação à dominância “neutra” dos conteúdos e ao “pouco” entendimento sobre ML.

2. Fundamentação e trabalhos relacionados

A IA possibilita que sistemas realizem tarefas humanas, como reconhecimento de padrões e tomada de decisões. Na educação, permite personalizar o aprendizado, oferecendo *feedback* em tempo real e maior eficiência [Caruso and Cavalheiro 2021]. Já ML é subcampo da IA que utiliza algoritmos para que os sistemas “aprendam” com dados [Raschka and Mirjalili 2019]. Entre as ferramentas recentes de ML voltadas à educação, destacam-se o *Google Teachable Machine*, que favorece o aprendizado ativo ao permitir que estudantes construam modelos preditivos a partir de imagens, sons ou gestos, compreendendo conceitos como treino de dados, inferência e classificação [Zhang et al. 2024], e o *MIT Raise Playground*, que oferece um ambiente de programação em blocos em que os estudantes manipulam variáveis, sensores e modelos predefinidos por meio de uma interface gráfica amigável [Williams et al. 2024]. Trabalhos correlatos que utilizam essas e outras tecnologias de IA são detalhados a seguir.

Pujari *et al.* [2022] investigaram a implementação do *Google Teachable Machine* em ambientes de educação infantil para introduzir conceitos básicos de aprendizado de máquina. O problema abordado foi a dificuldade em auxiliar na aprendizagem de IA a crianças pequenas. A metodologia consistiu na utilização da plataforma para criar e

treinar modelos de aprendizado de máquina de forma visual e interativa. Os resultados mostraram que a ferramenta facilitou a compreensão de conceitos fundamentais de IA, promovendo um aprendizado ativo e engajamento nas crianças, mesmo sem conhecimentos prévios de programação.

Rodríguez-García et al. [2021] desenvolveram a plataforma *LearningML*, que integra conceitos de ML em um ambiente de Programação em Blocos, visando auxiliar na aprendizagem de IA para estudantes de 10 a 16 anos. A metodologia adotada envolveu uma intervenção *online* que permitiu aos estudantes treinar e testar modelos de ML, aplicando-os em projetos práticos. A avaliação da aprendizagem foi realizada por meio de testes antes e depois da intervenção, além de observações qualitativas. Os resultados indicaram uma melhoria significativa na compreensão dos conceitos de IA e ML pelos estudantes, evidenciando a eficiência da abordagem adotada.

Webber et al. [2022] propuseram um modelo de Experiência Computacional para integrar conceitos de IA às disciplinas de Ciências e Matemática na Educação Básica. A proposta utiliza ferramentas gratuitas, como *Machine Learning for Kids* e *Teachable Machine*, permitindo que os estudantes desenvolvam projetos com programação em blocos. Os resultados apontaram maior engajamento dos estudantes e avanços na compreensão de IA e PC, mesmo em contextos com recursos limitados.

A Tabela 1 apresenta uma comparação entre os trabalhos e esta proposta. As siglas correspondem a: Programação em Blocos (PB), *Machine Learning* (ML) e Ensino Médio (EM). Todos os trabalhos apresentam a ML como foco, mas não investigam PB no contexto do EM. O trabalho de Rodríguez-García et al. [2021] destaca-se, atendendo a todos os aspectos, mas seu foco está somente na ferramenta *LearningML*. O diferencial deste trabalho está no foco em lógica e PC, relacionados à PB e ML, com uma aplicação no EM por meio das tecnologias *Google Teachable Machine* e *MIT RAISE Playground*.

Tabela 1. Comparação entre os trabalhos relacionados e o presente trabalho.

Trabalho	PB	ML	EM	Tecnologias utilizadas
Pujari et al. (2022)	-	X	-	<i>Google Teachable Machine</i>
Rodríguez-García et al. (2021)	X	X	X	<i>LearningML</i>
Webber et al. (2022)	-	X	X	<i>Machine Learning for Kids, Teachable Machine</i>
Este Trabalho	X	X	X	<i>Google Teachable Machine, MIT Raise Playground</i>

3. Metodologia

Conduziu-se um estudo descritivo-exploratório para atingir os objetivos do trabalho, cujas etapas podem ser visualizadas na Figura 1 e descritas a seguir.




Figura 1. Etapas do estudo descritivo-exploratório realizadas neste trabalho.

3.1. Definição do tipo de pesquisa

Neste trabalho, optou-se pela realização de um estudo descritivo-exploratório, composto por duas dimensões principais: (i) descritiva – tem foco no registro, observação, descrição, análise e ordenação de dados sem a interferência do pesquisador. Sua finalidade está na compreensão de características, padrões e relações presentes no fenômeno estudado; e (ii) exploratória – proporciona uma investigação aprofundada do problema, facilitando a delimitação do tema e pesquisa, orientando a formulação dos objetivos e permitindo a descoberta de novos aspectos sobre o assunto [Prodanov and De Freitas 2013].

Essa abordagem é pertinente a este trabalho, visto que seu foco está na compreensão das percepções dos estudantes em relação à motivação, engajamento e aprendizagem com as tecnologias de ML (dimensão descritiva). Além disso, o trabalho também possui como foco o mapeamento das dificuldades desse processo, auxiliando a sistematizar os dados coletados (dimensão descritiva) e identificar aspectos que possam ampliar a compreensão do fenômeno e guiar pesquisas futuras (dimensão exploratória).

3.2. Contexto, Seleção de Participantes e Instrumentos

O contexto da pesquisa envolve um estudante de graduação da Universidade do Estado do Amazonas (UEA), que estava regularmente matriculado na disciplina de “Estágio Supervisionado em Computação II” (obrigatória) do curso de Licenciatura em Computação. Nesta disciplina, os estudantes: (i) comunicam-se com uma escola que possua Ensino Médio ou Técnico (no caso de Estágio II); (ii) realizam os procedimentos burocráticos universidade-escola para providenciar a documentação e iniciar o estágio; (iii) acompanham um professor ou uma determinada turma, a fim de localizar um problema de aprendizagem dos estudantes; (iv) realizam aplicações de pré-teste como avaliação diagnóstica para mensurar o aprendizado dos estudantes; (v) propõem e aplicam uma intervenção; e (vi) aplicam um pós-teste para verificar se a intervenção trouxe resultados positivos.

Nesta pesquisa, o estudante de graduação realizou seu estágio em uma escola privada localizada em Manaus/AM. A instituição oferece aulas desde a Educação Infantil até o Ensino Médio, no turno matutino, e proporciona diversos itinerários formativos aos estudantes, permitindo que escolham aqueles que mais correspondam aos seus interesses. Um desses itinerários é o de Robótica, no qual os estudantes têm a oportunidade de desenvolver conhecimentos relacionados à programação, eletrônica e robótica. Nesse aspecto, o critério de seleção dos participantes para este estudo foi por conveniência, considerando estudantes que estavam matriculados nesse itinerário. O grupo era composto por nove estudantes, sendo sete meninas (78%) e dois meninos (22%), dos quais 100% estavam no 1º ano do Ensino Médio (idades entre 13 e 14 anos). Todos os estudantes possuíam conhecimentos prévios com programação em blocos por conta do itinerário, mas não tinham experiência com conceitos ou práticas de IA, como ML.

Conforme os objetivos do estudo, três instrumentos foram utilizados: **i) Bebras:** para auxiliar na caracterização do perfil cognitivo dos estudantes (primeiro objetivo), na versão de 2024, por ser mais recente, disponibilizada por meio da plataforma Brasil¹. O objetivo é avaliar habilidades iniciais em lógica e PC. Considerando que os participantes do estudo eram estudantes do 1º ano do Ensino Médio, o nível de prova selecionado foi

¹<https://www.bebasbrasil.com.br/>

o *Juniors* – a segunda maior categoria da plataforma, abaixo apenas do nível *Seniors*. As questões do Bebras, conforme sua regulamentação, são organizadas em três categorias sequenciais: fáceis (questões 1 a 4), médias (5 a 8) e difíceis (9 a 12). Para refletir essa gradação, o sistema de correção utiliza pesos distintos para as questões: 3 pontos (fáceis), 4 pontos (médias) e 5 pontos (difíceis);

ii) Emoti-SAM [Hayashi et al. 2016]: aplicado para coletar a percepção dos estudantes do EM quanto à diversão e motivação das atividades desenvolvidas (segundo objetivo). Esse instrumento é uma versão adaptada do *Self-Assessment Manikin* (SAM), que avalia aspectos de valência, excitação e dominância. Ele incorpora escalas de *emojis/emotes* (figurinhas) para substituir as figuras tradicionais – tidas como “feias” e pouco compreensíveis, segundo o *feedback* de crianças. Desse modo, o *emoti-SAM* inclui três questões com uma escala de cinco pontos representados por *emojis*, cujas dimensões incluem: um rosto feliz até um rosto bravo (dimensão de valência); um rosto dormindo até um rosto com corações e lâmpada (dimensão de excitação); e *emoticon* com capelo (chapéu de formatura) até um rosto desapontado (dimensão de dominância);

iii) Instrumento autoral: seu uso está relacionado à autoavaliação dos estudantes quanto ao engajamento, aprendizagem e dificuldades nas atividades realizadas de ML, bem como o mapeamento das dificuldades atreladas (segundo objetivo). Como seu uso é especificamente direcionado ao domínio de ML na educação básica, contemplando também os desafios percebidos pelos estudantes, nenhum instrumento validado na literatura que atendesse a tais características foi localizado. Desse modo, houve a necessidade de elaboração desse instrumento autoral, que contém sete questões: seis quantitativas em escalas variadas de 3 a 4 pontos e uma questão qualitativa relacionada à dificuldade – ilustradas na Tabela 2. Os resultados de aplicação desse instrumento serão cruzados com os dados do diagnóstico do Bebras (terceiro objetivo).

Tabela 2. Questões do formulário de autopercepção aplicado aos estudantes


Nº	Questão	Opções
1	Você entendeu melhor o que é <i>Machine Learning</i> depois da atividade?	Sim, bastante / Um pouco / Não muito / Não entendi nada
2	O que você acha que é <i>Machine Learning</i> ?	Um robô que aprende sozinho / Um jeito de ensinar o computador a aprender com exemplos / Um tipo de jogo no computador / Não sei
3	Para que serve o <i>Machine Learning</i> ?	Para ajudar o computador a reconhecer coisas e tomar decisões / Para fazer desenhos no computador / Para jogar jogos mais legais / Não sei
4	Você lembra das coisas que viu sobre programação em blocos antes e durante a atividade?	Sim, tudo! / Só um pouco / Quase nada / Não me lembro
5	O que você pode fazer com programação em blocos no <i>Playground.raise</i> ?	Criar histórias e jogos juntando blocos de código / Desenhar só no papel / Usar blocos de montar brinquedo / Não sei
6	Você conseguiu fazer a atividade usando o <i>Teachable Machine</i> e o <i>Playground.raise</i> ?	Sim, deu tudo certo! / Tive um pouco de dificuldade, mas consegui / Não consegui fazer
7	Teve alguma parte da atividade que foi difícil para você? Qual?	Resposta aberta

3.3. Procedimentos

As atividades desenvolvidas na escola “Dom Bosco Leste”, no contexto do estágio supervisionado, contemplam três etapas: (i) aplicação de avaliação diagnóstica; (ii) introdução ao *Google Teachable Machine*; e (iii) programação no *MIT Raise Playground*. A intervenção foi realizada no turno da manhã durante o horário do itinerário de Robótica, que ocorre nas segundas e quartas-feiras, das 11h30 às 12h20, com duração de 50 minutos por encontro. Alguns registros dessas etapas podem ser consultados na Figura 2.



(a) Momento inicial da etapa 2.



(b) Interação com o *Teachable Machine*.



(c) Interação com o *Playground*.

Figura 2. Momentos das fases 2 e 3 da intervenção didática.

Aplicação de avaliação diagnóstica: a primeira etapa consistiu na aplicação da prova do Bebras, nível *Juniors*. Seu objetivo foi identificar o nível de conhecimento dos estudantes em lógica e avaliar habilidades de PC antes da intervenção, aspectos relevantes no contexto de ML e programação em blocos. Diante disso, a aplicação ocorreu de forma presencial na escola, com duração aproximada de 50 minutos – equivalente a um tempo de aula. Dentre os nove matriculados no itinerário de Robótica, somente seis puderam participar do estudo: cinco meninas (83%) e um menino (17%). Em decorrência da limitação de tempo, os estudantes conseguiram responder somente 8 das 12 questões propostas.

Introdução ao *Google Teachable Machine*: em seguida, a ferramenta foi aplicada. Por meio de uma apresentação de slides², os participantes foram contextualizados sobre conceitos de ML, com questões como “*O que é ML?*”, “*Como funciona?*” e “*Para que servem os modelos?*”, além de exemplos de uso em diferentes áreas. Após essa explicação, a ferramenta foi demonstrada por meio da criação e treinamento de um modelo capaz de reconhecer direções (cima, baixo, direita e esquerda) a partir de movimentos das mãos, ilustrando na prática seu funcionamento e motivando os estudantes. Formaram-se dois trios entre os seis participantes, já que apenas três máquinas tinham câmeras – requisito para a atividade. Concluída a introdução, os estudantes foram orientados a explorar livremente a ferramenta, escolhendo modelos e tipos de dados para treinamento. Por fim, explicou-se que, na etapa seguinte, a programação em blocos seria utilizada para integrar os modelos treinados.

Programação no *MIT Raise Playground*: essa atividade ocorreu em uma aula posterior, envolvendo o uso do *MIT Raise Playground*, uma ferramenta de programação em blocos. Iniciou-se com uma breve explicação da plataforma, dando ênfase nos blocos *Use Model* (Usar modelo), que possibilitam a inserção da URL dos modelos treinados

²<https://doi.org/10.6084/m9.figshare.29361683.v1>

previamente no *Google Teachable Machine*. Na sequência, a integração dos modelos de ML com o ambiente do *Playground* foi demonstrada, utilizando a extensão do *Google Teachable Machine*. A demonstração incluiu um exemplo, possibilitando que os gestos dos estudantes fossem reconhecidos e utilizados para mover um personagem. Após isso, no tempo restante da aula, os participantes foram liberados para inserir seus modelos no *Playground* e programar livremente, aplicando os conhecimentos adquiridos.

3.4. Coleta e análise de dados

Os dados coletados apresentam naturezas distintas: (i) dados da avaliação diagnóstica, referentes às questões de múltipla escolha da prova do Bebras, obtidos a partir das provas em papel dos estudantes; (ii) avaliações de percepção de valência, excitação e dominância, provenientes do teste emoti-SAM; (iii) dados de autopercepção dos estudantes quanto à aprendizagem dos conteúdos de ML e as dificuldades identificadas, compostos por escalas de três a quatro pontos e por uma questão qualitativa aberta. Os dados do emoti-SAM e do instrumento autoral foram coletados de forma conjunta mediante um Google Forms.

Quanto à análise dos dados, fez-se uso de análise descritiva a partir da pontuação total dos estudantes na avaliação diagnóstica e o percentual de acertos por questões, criando gráficos de barras. Para as avaliações de autopercepção, envolvendo o emoti-SAM e o instrumento autoral, realizaram-se análises das questões fechadas por meio de frequências absolutas e relativas para sintetizar a distribuição das respostas. Para a questão qualitativa aberta sobre as dificuldades, utilizou-se análise de conteúdo [Bardin 2015]. O processo envolveu uma leitura inicial das respostas para identificar ideias centrais, com base nas quais foram definidas categorias temáticas. Em seguida, as respostas foram agrupadas conforme essas categorias e analisadas com o objetivo de reconhecer padrões e destacar pontos relevantes dentro de cada grupo.

4. Resultados e Discussões

Nesta seção, os resultados dos três objetivos desta pesquisa são apresentados: (i) caracterizar o perfil cognitivo dos estudantes em relação ao PC por meio da avaliação diagnóstica das questões do Bebras Brasil; (ii) analisar a percepção dos estudantes sobre motivação e engajamento ao utilizar tecnologias de ML, assim como identificar as principais dificuldades enfrentadas; e (iii) investigar as possíveis relações dos critérios autoavaliados com o perfil cognitivo desses estudantes.

Dessa forma, relacionado ao perfil cognitivo dos estudantes do EM – item (i), os gráficos de barras (Figura 3) ilustram a pontuação total dos estudantes na prova do Bebras, considerando as notas ponderadas e o percentual de acerto por questão. Cada questão relaciona-se a uma habilidade cognitiva de lógica e PC, sendo: Q1 – raciocínio sequencial e interpretação de trajetórias; Q2 – planejamento, otimização de caminhos e raciocínio lógico; Q3 – interpretação de símbolos, raciocínio espacial e mapeamento de movimentos; Q4 – ordenação, organização de sequências e simulação de processos; Q5 – estratégia em jogos matemáticos, pensamento lógico e análise de possibilidades; Q6 – otimização de tempo e recursos, decomposição de problemas e planejamento estratégico; Q7 – raciocínio quantitativo, planejamento e uso eficiente de recursos; e Q8 – aplicação de regras, reconhecimento de padrões e operações matemáticas envolvendo soma e módulo.

A análise dos resultados do diagnóstico Bebras, associada ao exame dos enunciados, revela que os estudantes apresentaram bom desempenho nas questões de raciocínio

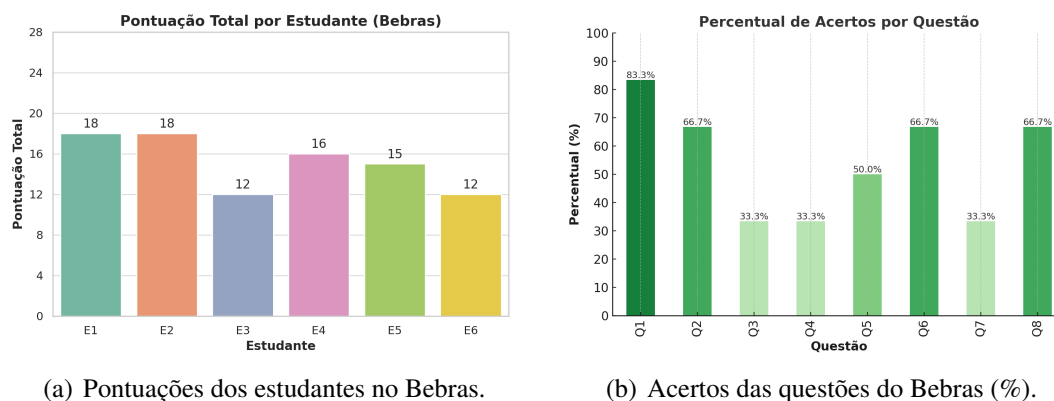


Figura 3. Gráficos relacionados à prova do Bebras.

sequencial, trajetórias, planejamento de caminhos e solução de problemas com menor número de variáveis simultâneas (Q1, Q2, Q6 e Q8). Por outro lado, demonstraram maiores dificuldades nas tarefas que exigem raciocínio lógico mais complexo, especialmente quando envolvem múltiplas regras, abstrações matemáticas e planejamento com restrições combinatórias (Q3, Q4 e Q7). Um exemplo atípico é o estudante E6, que errou as questões simples (menores pesos), mas acertou questões de dificuldade média. O bom desempenho nas questões mais simples contribuiu para pontuações mais altas, com destaque para os estudantes E1 e E2, que alcançaram 18 pontos ao acertar tanto as questões iniciais quanto as intermediárias.

Esse padrão sugere que desafios que exigem organização espacial simples, lógica procedural e sequenciamento linear foram mais facilmente compreendidas, enquanto problemas que demandam abstração algébrica, múltiplas condicionais ou análise combinatória representaram maior obstáculo. Portanto, em relação ao primeiro objetivo, o perfil cognitivo dos estudantes evidencia competências bem desenvolvidas em raciocínio sequencial, representação visual de problemas e aplicação de algoritmos simples, que possuem relação com lógica e PC. Entretanto, também aponta fragilidades quando o problema exige manipulação de abstrações numéricas, formulação e controle de múltiplas regras simultâneas ou estratégias otimizadas sob restrições.

Quanto à autopercepção dos estudantes em relação à motivação, engajamento e dificuldades no uso das tecnologias de ML – item (ii), realizou-se uma análise dos resultados obtidos com o instrumento de avaliação emoti-SAM [Hayashi et al. 2016] e do instrumento autoral. **Emoti-SAM:** na dimensão de “valência”, relacionada à satisfação ao participar das atividades, observou-se uma alta concordância dos estudantes: 83% achou “agradável” e 17% ficou “satisfeito”. Quanto à dimensão de “excitação”, 50% se sentiu “animado” e 50% “totalmente acordado”. E na dimensão de “dominância”, que diz respeito à aprendizagem e/ou entendimento de algo novo com a intervenção, observa-se uma disparidade: 49% se sentiu “poderoso” e 17% “independente”. Em contrapartida, 17% manteve-se neutro e 17% se sentiu “dependente” – percepção de baixo controle sobre a atividade, sugerindo necessidade de apoio ou orientação externa para sua execução. As análises sugerem que as atividades foram divertidas e motivadoras, mas que nem todos os estudantes sentiram-se confiantes no entendimento do conteúdo. Esse ponto pode estar relacionado com a duração de ambas aplicações, realizadas em somente uma aula cada.

Em relação aos aspectos de aprendizagem avaliados por meio do formulário autoral, 67% dos estudantes relatou ter entendido ML com mais clareza após as atividades. Quanto à compreensão do conceito e finalidade de ML, 100% dos estudantes selecionou as opções corretas. Sobre os conhecimentos prévios de programação em blocos, 83% informou lembrar de tudo, enquanto 17% lembra o conteúdo em partes. Os participantes também demonstraram um bom entendimento da função da ferramenta *Playground*, apresentando 100% das respostas corretas. Já na realização das atividades com ambas ferramentas de ML, 83% apontou que “deu tudo certo” e 17% indicou não ter conseguido concluir. No que tange as dificuldades percebidas, 67% não apontou dificuldade nas atividades, enquanto um participante relatou ser “enxergar”, podendo ter relação com iluminação ou qualidade das telas dos dispositivos e não com as atividades em si. Outro estudante informou “a maioria das questões”, referindo-se ao teste diagnóstico do Bebras e não sobre ML. Dessa forma, especificamente em relação às ferramentas de ML, os estudantes não apontaram dificuldade quanto ao uso ou conceitos trabalhados na intervenção.

Em resposta ao segundo objetivo, unificando os resultados do emoti-SAM com o instrumento autoral, os estudantes avaliaram a atividade como motivadora e divertida. A maioria apontou ter entendido os conceitos de ML e não apontou dificuldades no uso das ferramentas – com exceção de um estudante quanto ao *Teachable Machine*. De modo geral, as ferramentas foram bem recebidas. Quanto ao terceiro objetivo, investigação de possíveis relações entre o perfil cognitivo e os critérios autoavaliados, construiu-se a Tabela comparativa 3. As colunas representam: E – Estudante; PB - Pontuação no Bebras; EX - Excitação; VL - Valência; DM - Dominância; ML – Entendimento de ML; LB – Lembrar dos blocos; CF – Conseguiu Fazer; e D – Dificuldade.

Tabela 3. Desempenho no Bebras e autopercepção dos estudantes.

E	PB	VL	EX	DM	ML	LB	CF	D
E1	18	Agrad.	Anim.	Conf.	Sim, bast.	Sim, tudo	Sim	Nenhuma
E2	18	Agrad.	Anim.	Conf.	Sim, bast.	Sim, tudo	Sim	Enxergar (externo)
E3	12	Neutro	Neutro	Neutro	Pouco	Pouco	Sim	Nenhuma
E4	16	Agrad.	Anim.	Conf.	Sim, bast.	Sim, tudo	Sim	Nenhuma
E5	15	Agrad.	Anim.	Conf.	Sim, bast.	Sim, tudo	Não	Questões Bebras
E6	12	Neutro	Neutro	Neutro	Pouco	Pouco	Sim	Nenhuma

A análise cruzada dos dados sugere uma tendência de que estudantes com bom desempenho no Bebras (E1, E2 e E4) também apresentem percepções emocionais (colunas 3 e 4) e de aprendizagem (colunas 5 a 9) mais positivas. Já em estudantes com as menores pontuações (E3 e E6), observa-se que reportaram “um pouco” de entendimento sobre ML, que lembram parcialmente da programação em blocos e que apresentaram uma dominância “neutra” dos conteúdos. Embora não tenham relatado dificuldades no uso das ferramentas, pode sugerir que possuem dificuldade lógica, o que pode ter influenciado nas notas do Bebras e no entendimento dos conceitos da intervenção. Os resultados de E5 destacam-se pois, apesar de obter um desempenho intermediário (15) no Bebras e ter relatado compreender os conceitos, não conseguiu fazer a atividade com as ferramentas.

Embora o tamanho da amostra no estudo seja reduzido, impossibilitando inferências estatísticas robustas e limitando-se a análises descritivas e exploratórias, percebe-se uma relação entre o desempenho no diagnóstico do Bebras, a lembrança de conhecimentos prévios de programação em blocos e a percepção de dominância dos

conteúdos de ML. Isso pode sugerir uma relação de ML com habilidades de lógica e PC. Apesar de não poder generalizar os achados, visto que o estudo é de caráter exploratório, com amostra reduzida e contexto específico, os resultados indicam o potencial do uso de ferramentas práticas de ML para a aprendizagem de IA na Educação Básica, contribuindo também em aspectos emocionais e motivacionais. Os achados corroboram com a pesquisa de Rodríguez-García et al. [2021], que também indica que intervenções com IA podem gerar efeitos imediatos em dimensões afetivas e, em seu estudo, no engajamento. Além disso, os ganhos cognitivos possuem relação com tempo de exposição e aprofundamento dos conteúdos, o que pode ter influenciado o entendimento dos estudantes, considerando o tempo reduzido para aplicação da intervenção.

5. Considerações Finais

Este estudo teve como objetivo analisar o perfil cognitivo de estudantes do EM e suas percepções e dificuldades no uso de tecnologias de ML, assim como investigar possíveis relações entre esses aspectos. O trabalho consistiu de um estudo-exploratório, segmentado em cinco etapas: definição do tipo de pesquisa (estudo descritivo-exploratório), contexto e seleção de participantes (estudantes do EM de uma escola privada, que estavam matriculados em um itinerário formativo de robótica), instrumentação (prova Bebras, emoti-SAM e instrumento autoral), procedimentos (avaliação diagnóstica e uso de ferramentas de ML) e coleta e análise de dados (dados coletados com a aplicação dos instrumentos, análise descritiva, frequências absolutas/relativas e análise de conteúdo).

Quanto ao perfil cognitivo, os estudantes apresentaram bom desempenho em raciocínio sequencial, trajetórias, planejamento de caminhos, entre outros. Entretanto, houve dificuldades em tarefas de raciocínio lógico mais complexo. Quanto à autopercepção no uso das tecnologias de IA (ferramentas de ML), os estudantes apontaram diversão e motivação, sem indicação de dificuldades relacionadas. Todos os estudantes demonstraram entendimento nos conceitos de ML. Já na relação do perfil cognitivo com as autoavaliações, nota-se uma relação entre o baixo desempenho na avaliação diagnóstica, a dominância do conteúdo e o uso de programação em blocos. Desse modo, sugere-se uma dificuldade de alguns estudantes em lógica e PC, que podem ter influenciado no desempenho da prova e no entendimento dos conceitos de ML.

As contribuições incluem o uso de tecnologias de ML que podem motivar estudantes da Educação Básica. Professores podem utilizá-las para auxiliar no desenvolvimento da lógica e do PC, bem como no aprendizado dinâmico de ML. Também indica uma possível relação entre o perfil cognitivo em PC e o desempenho (ou percepção) em atividades de ML, motivo pelo qual se recomenda aplicar aulas e exercícios para estimular o raciocínio lógico. As limitações são: (i) amostra pequena, não possibilitando generalizar os resultados; (ii) uso de instrumentos não validados, construídos para o contexto da pesquisa; (iii) ausência de grupo de controle, devido às restrições da escola e condições do estágio; (iv) constructos distintos, inviabilizando pré e pós-teste, visto que o foco do diagnóstico foi somente caracterização inicial e não comparação; e (v) autoavaliação, focando apenas na percepção subjetiva dos estudantes, o que não reflete diretamente o desempenho real. Boa parte das limitações refere-se a condições não controláveis, as quais serão contornadas em estudos futuros, em que se pretende: (i) ampliar a amostra; (ii) aplicar pré e pós-teste que avaliem o constructo; (iii) coletar dados de naturezas distintas, principalmente qualitativos; e (iv) comparar grupos experimental e de controle.

6. Agradecimentos

As pessoas autoras agradecem à Universidade do Estado do Amazonas (UEA) pelo apoio institucional e à PROPESP-UEA pelo suporte financeiro. Agradecemos também aos colegas do ThinkTEd Lab pelas contribuições e discussões que enriqueceram este trabalho.

Referências

- Andrade, J. C., Oliveira, M., and Battetin, V. (2024). Pensamento computacional e educação em inteligência artificial na educação steam: Explorando o ensino por investigação. In *Anais Estendidos do XIII Congresso Brasileiro de Informática na Educação*, pages 295–301, Porto Alegre, RS, Brasil. SBC.
- Bardin, L. (2015). *Análise de conteúdo (la reto & a. pinheiro, tradução)(6ª edição)*. Lisboa, Portugal: Edições, 70.
- Brasil (2023). Projeto de lei nº 3379/2023. <https://www.camara.leg.br/propostas-legislativas/2373379>. Acesso em: 17 jun. 2025.
- Brasil (2024). Projeto de lei nº 4758/2024. <https://www.camara.leg.br/propostas-legislativas/245758>. Acesso em: 17 jun. 2025.
- Brasil (2025). Projeto de lei nº 2051/2025. <https://www25.senado.leg.br/web/atividade/materias/-/materia/162434>. Acesso em: 17 jun. 2025.
- Caruso, A. and Cavalheiro, S. (2021). Integração entre pensamento computacional e inteligência artificial: uma revisão sistemática de literatura. In *Anais do XXXII Simpósio Brasileiro de Informática na Educação*, pages 1051–1062, Porto Alegre, RS, Brasil. SBC.
- França, R. and Tedesco, P. (2015). Desafios e oportunidades ao ensino do pensamento computacional na educação básica no brasil.
- 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.
- Insider, B. (2025). China’s capital city is making ai education mandatory, even for elementary schoolers. Accessed: 2025-06-17.
- Jiang, Z. and Jiang, M. (2024). Beyond answers: Large language model-powered tutoring system in physics education for deep learning and precise understanding.
- Kamalov, F., Calong, D. S., and Gurrib, I. (2023). New era of artificial intelligence in education: Towards a sustainable multifaceted revolution.
- Lopes, A., Isotani, S., and Toda, A. (2020). Explorando o pensamento computacional com aprendizado de máquina: Elaboração de um material didático para uma oficina introdutória. *Anais dos Trabalhos de Conclusão de Curso. Pós-Graduação em Computação Aplicada à Educação Instituto de Ciências Matemáticas e de Computação. Universidade de São Paulo*.
- Montuori, C., Gambarota, F., Altoè, G., and Arfe, B. (2023). The cognitive effects of computational thinking: A systematic review and meta-analytic study. *Computers Education*, 210:104961.

- Morais, M. D. d. (2019). Machine learning e pensamento computacional no ensino de matemática. In *Anais do XXIII Encontro Brasileiro de Estudantes de Pós-Graduação em Educação Matemática*, São Paulo, SP, Brasil. UNICSUL - Campus Anália Franco.
- Nascimento, E. S. d. O., Oliveira, C. H. S., and Castro, M. F. d. (2024). Uso da inteligência artificial no ensino e avaliação do pensamento computacional: um mapeamento sistemático da literatura. *RENOTE*, 22(1):295–307.
- Prodanov, C. C. and De Freitas, E. C. (2013). *Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico-2ª Edição*. Editora Feevale.
- Pujari, Y. P., Prasad, D., Malleswari, D. N., Shetty, M. N., and Gupta, N. (2022). Implementation of machine learning based google teachable machine in early childhood education. *International Journal of Early Childhood Special Education*, 14(3):4132–4138.
- Raschka, S. and Mirjalili, V. (2019). *Python Machine Learning - Third Edition*. Packt Publishing.
- 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 '21*, page 177–183, New York, NY, USA. Association for Computing Machinery.
- Times, F. (2025a). Estonia launches ai in high schools with us tech groups. Accessed: 2025-06-17.
- Times, F. (2025b). Uae to introduce ai classes for children as young as four. Accessed: 2025-06-17.
- Webber, C., Flores, D., and Fracasso, D. (2022). Inteligência artificial na escola: Rumo às novas experiências computacionais. 9:27.
- Williams, R., Ali, S., Alcantara, R., Burghleh, T., Alghowinem, S., and Breazeal, C. (2024). Doodlebot: An educational robot for creativity and ai literacy. In *Proceedings of the 2024 ACM/IEEE International Conference on Human-Robot Interaction, HRI '24*, page 772–780, New York, NY, USA. Association for Computing Machinery.
- Wing, J. (2006). Computational thinking. *Communications of the ACM*, 49:33–35.
- Zhang, Q.-W., Wang, H., Li, F., An, S., Qiao, L., Gao, L., Yin, D., and Sun, X. (2024). Cjeval: A benchmark for assessing large language models using chinese junior high school exam data.