



UNIVERSIDADE FEDERAL DO TOCANTINS
CÂMPUS UNIVERSITÁRIO DE PALMAS
PROGRAMA DE MESTRADO PROFISSIONAL EM MATEMÁTICA
EM REDE NACIONAL – PROFMAT

WESLEY NUNES DA SILVA

MATEMAI
INTELIGÊNCIA ARTIFICIAL E MACHINE LEARNING COMO MOTORES DA
GAMIFICAÇÃO ADAPTATIVA NO ENSINO DE MATEMÁTICA

PALMAS (TO)

2026

WESLEY NUNES DA SILVA

MATEMAI

**INTELIGÊNCIA ARTIFICIAL E MACHINE LEARNING COMO MOTORES DA
GAMIFICAÇÃO ADAPTATIVA NO ENSINO DE MATEMÁTICA**

Dissertação apresentada ao Programa de Mestrado Profissional em Matemática em Rede Nacional - PROFMAT da Universidade Federal do Tocantins como requisito parcial para a obtenção do título de Mestre - Área de Concentração: Matemática.

Orientador: Profa. Dra. Betty Clara Barraza De La Cruz.

PALMAS (TO)

2026

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal do Tocantins

S586m Silva, Wesley Nunes da.
MatemAI: Inteligência Artificial e Machine Learning como Motores da
Gamificação Adaptativa no Ensino de Matemática. / Wesley Nunes da Silva.
– Palmas, TO, 2026.
92 f.

Dissertação (Mestrado Profissional) - Universidade Federal do Tocantins
– Câmpus Universitário de Palmas - Curso de Pós-Graduação (Mestrado)
Profissional em Matemática, 2026.

Orientadora : Betty Clara Barraza De La Cruz Cruz

1. Inteligência Artificial na Educação. 2. Sistemas Tutores Inteligentes. 3.
Gamificação Adaptativa. 4. Ensino de Matemática. I. Título

CDD 510

TODOS OS DIREITOS RESERVADOS – A reprodução total ou parcial, de qualquer
forma ou por qualquer meio deste documento é autorizado desde que citada a fonte.
A violação dos direitos do autor (Lei nº 9.610/98) é crime estabelecido pelo artigo 184
do Código Penal.

**Elaborado pelo sistema de geração automática de ficha catalográfica da
UFT com os dados fornecidos pelo(a) autor(a).**

WESLEY NUNES DA SILVA

MATEMAI: INTELIGÊNCIA ARTIFICIAL E MACHINE LEARNING COMO MOTORES DA GAMIFICAÇÃO ADAPTATIVA NO ENSINO DE MATEMÁTICA

Dissertação apresentada ao programa de Mestrado Profissional em Matemática em Rede Nacional – PROFMAT, foi avaliada para obtenção do título de Mestre e aprovada em sua forma final pela Orientadora e Banca Examinadora.

Aprovada em: 11 / 06 / 2026

BANCA EXAMINADORA

Documento assinado digitalmente
 **BETTY CLARA BARRAZA DE LA CRUZ**
Data: 19/06/2026 19:20:37-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Betty Clara Barraza De La Cruz, Orientadora, UFT

Documento assinado digitalmente
 **ROGERIO AZEVEDO ROCHA**
Data: 19/06/2026 14:30:05-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Rogério Azevedo Rocha, Examinador Interno, UFT

Documento assinado digitalmente
 **Jorge Cassio Costa Nobrega**
Data: 18/06/2026 19:19:05-0300
CPF: ***.922.771-**
Verifique as assinaturas em <https://v.ufsc.br>

Prof. Dr. Jorge Cássio Costa Nóbriga, Examinador Externo, UFSC

*À minha família, pelo apoio e pela compreensão
durante as horas de ausência dedicadas a este sonho.*

AGRADECIMENTOS

À Universidade Federal do Tocantins (UFT) e à Sociedade Brasileira de Matemática (SBM), pela oportunidade, pelos recursos e pela excelência na condução deste programa (PROF-MAT).

À minha orientadora, Prof^a. Dra. Betty Clara Barraza De La Cruz, pela eficiência, segurança e alta qualidade nos conhecimentos transmitidos. Sua condução foi o alicerce para o rigor deste trabalho.

À coordenadora, Prof^a. Dra. Hellena Christina Fernandes Apolinário, pelas orientações precisas e pelo apoio constante ao longo do curso.

À Pró-Reitora de Graduação, Prof^a. Dra. Valdirene Gomes dos Santos de Jesus, reservo um destaque especial. São anos de parceria forjada na trincheira de diversos projetos educacionais. Foi o seu incentivo direto e inabalável que me encorajou a abraçar esta jornada no mestrado. A gratidão que carrego por essa mentoria transcende este texto.

À Prof^a. Dra. Ana Cláudia Macedo Sampaio, pelo incentivo e apoio institucional decisivo para a viabilização desta pesquisa.

À Prof^a. Bárbara Pereira de Sousa, pela minuciosa revisão da língua portuguesa e pelas conversas essenciais sobre os meandros do meio acadêmico. Suas partilhas foram fundamentais.

À Prof^a. Lucivânia Carvalho Barcelo, pela competência e pelo rigor técnico na revisão da versão em língua inglesa deste trabalho.

À minha diretora, Maria Aparecida Ramalho dos Passos (Escola Estadual Vila Guaracy), pela compreensão e pelo apoio humano indispensável durante este período.

Ao amigo Melquesedeque Alves dos Anjos, pelas exaustivas horas de estudo e reuniões via Meet. Foram momentos essenciais para a nossa aprovação e êxito neste curso.

Ao meu tio Elias Saldanha Nunes, pelo apoio constante e pelo incentivo em cada uma das minhas decisões.

À minha mãe, Maria Alzira Saldanha Nunes, pelo colo e pelo refúgio nas horas difíceis. À minha irmã, Lidyanne Nunes da Silva, elo de confiança que cuidou com dedicação dos meus filhos em minha ausência. Sem vocês, o caminho seria impossível.

À minha esposa, Carla Pereira Loureiro, pela total compreensão e pela paciência nos momentos de ausência dedicados a esta pesquisa.

Aos meus filhos, Raphael Nunes Loureiro e Heloísa Nunes Loureiro, razões de todo o meu esforço. Mesmo tão jovens, compreenderam a falta do pai para a realização deste sonho.

A todos os familiares e amigos que, direta ou indiretamente, contribuíram para esta conquista.

*"O uso da tecnologia na educação, em lugar de reduzir,
pode expandir a capacidade crítica e criadora de nossos alunos.
Depende de quem a usa, a favor de que e de quem, e para quê."
(Paulo Freire)*

RESUMO

A instrução matemática no Ensino Fundamental II vive um impasse crônico. A persistência de modelos pedagógicos padronizados, que negligenciam a heterogeneidade das turmas, acaba por cristalizar o desinteresse e alimentar a ansiedade matemática. É neste cenário que a inteligência artificial e as tecnologias adaptativas surgem como uma promessa de personalização em larga escala. Contudo, há um problema latente: a maioria das plataformas contemporâneas foca-se estritamente na adaptação do conteúdo, deixando a motivação entregue a mecânicas de gamificação frias e estáticas. Essa lacuna é fatal. Ela falha ao não reconhecer a pluralidade dos perfis discentes, impedindo que o aluno alcance o tão necessário “Estado de Fluxo”. O *MatemAI* nasce para romper este ciclo. Este estudo detalha o desenvolvimento e a avaliação de um sistema tutor inteligente que utiliza a inteligência artificial generativa para moldar não só o nível de desafio, mas a própria narrativa e as recompensas de acordo com o perfil do utilizador. A investigação, de natureza aplicada e exploratória, seguiu o rigor da pesquisa baseada em design. A intervenção prática ocorreu na Escola Estadual Vila Guaracy, em Gurupi (TO), com uma amostra de 57 estudantes do 9º ano. A arquitetura do software assenta no modelo *Google Gemini*. Através de uma engenharia de *prompt* restritiva e do método de Cadeia de Pensamento, o sistema atua como um agente socrático focado na oferta de andaimes cognitivos na zona de desenvolvimento proximal de Vygotsky. A telemetria digital não mente: os dados evidenciaram um salto progressivo no engajamento voluntário e na resiliência dos alunos. A validação por pares atestou a segurança pedagógica do artefato, destacando a erradicação de alucinações matemáticas e a precisão da inteligência artificial em traduzir abstrações para o cotidiano. Conclui-se que o *MatemAI* democratiza a tutoria individualizada na escola pública, posicionando-se como um mediador que fortalece a atuação docente por meio da análise de aprendizagem.

Palavras-chave: Inteligência Artificial na Educação; Sistemas Tutores Inteligentes; Gamificação Adaptativa; Zona de Desenvolvimento Proximal; Ensino de Matemática.

ABSTRACT

Mathematics instruction in middle school faces a chronic deadlock. The persistence of one-size-fits-all pedagogical models, which neglect classroom heterogeneity, ultimately cements disinterest and fuels math anxiety. Against this backdrop, artificial intelligence and adaptive technologies emerge as a promise for large-scale personalization. However, a latent problem remains: most contemporary platforms focus strictly on adapting content, leaving motivation to rely on cold, static gamification mechanics. This gap is critical. By failing to recognize the plurality of student profiles, it prevents learners from reaching the much-needed “Flow State”. MatemAI was born to break this cycle. This study details the development and evaluation of an intelligent tutoring system that leverages generative artificial intelligence to tailor not only the level of challenge, but also the narrative and rewards according to the user’s profile. The research, applied and exploratory in nature, followed the rigorous framework of Design-Based Research. The practical intervention took place at the Vila Guaracy State School in Gurupi (TO), involving a sample of 57 ninth-grade students. The software architecture is powered by the Google Gemini model. Through restrictive prompt engineering and the Chain-of-Thought method, the system acts as a Socratic agent focused on providing cognitive scaffolding within Vygotsky’s zone of proximal development. The digital telemetry speaks for itself: the data revealed a progressive leap in voluntary engagement and student resilience. Peer validation affirmed the pedagogical safety of the artifact, highlighting the eradication of mathematical hallucinations and the AI’s precision in translating abstract concepts into everyday contexts. Ultimately, MatemAI democratizes individualized tutoring in the public school system, positioning itself as a mediating tool that empowers teaching practice through learning analytics.

Keywords: Artificial Intelligence in Education; Intelligent Tutoring Systems; Adaptive Gamification; Zone of Proximal Development; Mathematics Teaching.

LISTA DE ILUSTRAÇÕES

Figura 1 – Esquema comparativo entre o processamento direto e o processamento estruturado via <i>Chain-of-Thought</i> acoplado à maiêutica socrática.	28
Figura 2 – Arquitetura tetradimensional clássica de um Sistema Tutor Inteligente (STI)	30
Figura 3 – Dinâmica do Estado de Fluxo e regulação algorítmica do Tutor Inteligente .	35
Figura 4 – Ciclo de retroalimentação contínua da Aprendizagem Adaptativa em Larga Escala mediado por <i>Learning Analytics</i> e intervenção docente direta	37
Figura 5 – Distribuição dos vetores de motivação lúdica na amostra de usuários-piloto.	46
Figura 6 – Ciclo de Pesquisa Baseada em Design (DBR) aplicado ao desenvolvimento iterativo do tutor <i>MatemAI</i>	48
Figura 7 – Arquitetura <i>Cloud-Native</i> do MatemAI e o fluxo de dados em tempo real. . .	51
Figura 8 – Interface de gamificação demonstrando a progressão sequencial de missões (Trilha de Aprendizagem).	54
Figura 9 – Tela de tutoria evidenciando a mediação pedagógica da IA (<i>Scaffolding</i>) em substituição à entrega da resposta direta.	55
Figura 10 – Interface de <i>feedback</i> gamificado e injeção de <i>XP</i> após a conclusão bem-sucedida de uma missão.	56
Figura 11 – Visão da infraestrutura de <i>backend</i> e painel de <i>Learning Analytics</i> armazenado na nuvem.	57
Figura 12 – Monitoramento do progresso coletivo e <i>ranking</i> de engajamento gamificado da turma.	58
Figura 13 – Fluxograma de verificação interna (<i>Chain-of-Thought</i>) para garantia de precisão matemática	60
Figura 14 – Árvore de decisão algorítmica para personalização da mecânica de jogo e da persona do tutor.	61
Figura 15 – Curva de telemetria evidenciando a sustentação do engajamento voluntário.	65
Figura 16 – Estudantes em atividade prática no laboratório de informática.	89
Figura 17 – Interação individualizada e navegação pelas trilhas do MatemAI.	89
Figura 18 – Acompanhamento da evolução do perfil de aprendizagem (<i>Cold Start</i>). . . .	90

LISTA DE QUADROS

Quadro 1 – Síntese da Fundamentação Teórica Nacional (PROFMAT)	42
Quadro 2 – Matriz SWOT da Implementation de IA Generativa no Ensino de Matemática	45
Quadro 3 – Algoritmo de Mediação	52
Quadro 4 – Diretrizes de Mediação Pedagógica Implementadas no <i>System Prompt</i> . . .	60
Quadro 5 – Matriz de Mediação Semântica: Exemplos de Contextualização	62
Quadro 6 – Transcrição de <i>Log</i> do Backend: O Caso da Música	63

LISTA DE TABELAS

Tabela 1 – Caracterização Demográfica da Amostra Experimental (n=57)	46
Tabela 2 – Caracterização do Corpo Docente na Validação por Pares	64

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ASCII	American Standard Code for Information Interchange
BNCC	Base Nacional Comum Curricular
CSV	Comma-Separated Values
EBIA	Estratégia Brasileira de Inteligência Artificial
GOF AI	Good Old-Fashioned Artificial Intelligence
GPT	Generative Pre-trained Transformer
IA	Inteligência Artificial
IMPA	Instituto de Matemática Pura e Aplicada
ITS	Sistemas Tutores Inteligentes
LGPD	Lei Geral de Proteção de Dados
LLM	Grandes Modelos de Linguagem (Large Language Models)
ML	Aprendizado de Máquina (Machine Learning)
NBR	Norma Brasileira
PROFMAT	Mestrado Profissional em Matemática em Rede Nacional
RNA	Redes Neurais Artificiais
SBM	Sociedade Brasileira de Matemática
SI	Sistema Internacional
STEM	Science, Technology, Engineering, and Mathematics
TALE	Termo de Assentimento Livre e Esclarecido
TCAM	Teoria Cognitiva da Aprendizagem Multimídia

TCC	Teoria da Carga Cognitiva
TCLE	Termo de Consentimento Livre e Esclarecido
TCT	Teoria Clássica dos Testes
UFNT	Universidade Federal do Norte do Tocantins
UFT	Universidade Federal do Tocantins
UNESCO	Organização das Nações Unidas para a Educação, a Ciência e a Cultura
XP	Experiência (Experience Points)
ZDP	Zona de Desenvolvimento Proximal

SUMÁRIO

1	INTRODUÇÃO	18
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Inteligência Artificial	21
2.1.1	Evolução da Inteligência Artificial	22
2.1.2	Inteligência Artificial na Educação	24
2.1.2.1	O Consenso de Pequim sobre a Inteligência Artificial e a Educação	24
2.1.2.2	Estratégia Brasileira de Inteligência Artificial	25
2.1.3	Inteligência Artificial Generativa	26
2.1.3.1	Modelos de Linguagem de Larga Escala	27
2.1.4	Sistema de Tutores Inteligentes	29
2.2	Neurociência Cognitiva e Aprendizagem Matemática	31
2.2.1	Neurociência e Modelos Cognitivos	32
2.2.1.1	Teoria da Carga Cognitiva e Aprendizagem Multimídia	33
2.2.1.2	Zona de Desenvolvimento Proximal e Estado de Fluxo	34
2.2.2	Aprendizagem Personalizada e Adaptativa em Larga Escala	36
2.3	Gamificação no Ensino da Matemática	37
2.3.1	Gamificação como Vetor de Engajamento e Motivação	38
2.3.2	Gamificação Adaptativa Potencializada pela Inteligência Artificial	39
2.3.3	Inteligência Artificial e Gamificação: Diálogos com a Produção Acadêmica Nacional	40
2.3.3.1	Gamificação e Engajamento: Do Modelo Estático à Adaptabilidade Computacional . .	41
2.3.3.2	Cenário das Políticas Públicas e Ética Algorítmica no Brasil	41
2.3.3.3	Síntese das Convergências Teóricas	42
3	METODOLOGIA	43
3.1	Delineamento Metodológico	43
3.1.1	Natureza, Abordagem e Classificação da Pesquisa	43
3.1.2	Levantamento Bibliográfico e Matriz de Viabilidade (SWOT)	44
3.1.3	Fase Diagnóstica e Perfilamento Computacional do Usuário	45
3.2	Pesquisa Baseada em Design e Estruturação das Etapas da Pesquisa	47
3.2.1	Fundamentos do Design Educacional e a Metodologia DBR	47

3.2.2	Ciclos Iterativos e Fases da Investigação	48
3.2.3	Considerações Éticas, LGPD e Responsabilidade Algorítmica	49
3.3	O Produto Educacional: Engenharia de Software e Desenvolvimento do MatemAI	49
3.3.1	Engenharia de Software e Infraestrutura <i>Cloud-Native</i>	50
3.3.2	O Motor Cognitivo: Engenharia de Prompt e o Agente Socrático	50
3.3.3	Mitigação de “Alucinações”: A Cadeia de Pensamento (<i>Chain-of-Thought</i>) . . .	52
3.3.4	Interface Gamificada e <i>Feedback</i> Contínuo	53
3.3.5	Arquitetura Visual e Trilhas de Aprendizagem Não-Lineares	53
3.3.6	O Ciclo de Tutoria na Prática: <i>Scaffolding</i> Socrático	54
3.3.7	Economia de <i>Tokens</i> e Reforço Positivo Imediato	55
3.3.8	Telemetria Docente, <i>Learning Analytics</i> e a Dinâmica de Socialização (<i>Ranking</i>)	56
3.3.8.1	O Professor como Gestor de Aprendizagem via <i>Dashboard</i>	56
3.3.8.2	A Psicologia do <i>Ranking</i> : De Notas Punitivas à Recompensa por Esforço	57
4	RESULTADOS E DISCUSSÃO: O PRODUTO MATEMAI	59
4.1	Arquitetura Cognitiva e Engenharia de Prompt	59
4.1.1	O Agente Socrático: <i>Scaffolding</i> via System Prompt	59
4.1.2	Camadas de Validação: Mitigação de Inconsistências Matemáticas	59
4.2	Gamificação Adaptativa: Mecanismos de Engajamento	61
4.2.1	Modelagem Algorítmica dos Perfis de Usuário	61
4.2.2	Personalização Semântica e Contextualização do Conteúdo	62
4.3	Validação Técnica e Telemetria de Engajamento	63
4.3.1	Validação Docente: Revisão por Pares e Avaliação de Usabilidade	63
4.3.2	Telemetria de Engajamento e a Dinâmica do Fluxo	65
5	CONSIDERAÇÕES FINAIS	67
	REFERÊNCIAS	69
	APÊNDICES	74
	APÊNDICE A – QUESTIONÁRIO DE PESQUISA SOBRE MATEMÁTICA E NOVAS TECNOLOGIAS	75
	APÊNDICE B – QUESTIONÁRIO DE ESCUTA ATIVA COM OS DOCENTES (VALIDAÇÃO POR PARES)	88

APÊNDICE C – REGISTRO FOTOGRÁFICO DA APLICAÇÃO DO PRO- DUTO EDUCACIONAL	89
APÊNDICE D – DECLARAÇÃO SOBRE O USO DE INTELIGÊNCIA ARTIFICIAL	91

1 INTRODUÇÃO

O ensino de Matemática no Ensino Fundamental II permanece como um dos desafios centrais do cenário educacional brasileiro. Trata-se de uma problemática histórica e multifacetada, na qual a densidade abstrata e lógica da disciplina frequentemente converge para obstáculos pedagógicos significativos, tais como o desengajamento crônico e a ansiedade matemática. Embora a Base Nacional Comum Curricular (BNCC) reitere o letramento matemático como pilar do pensamento crítico e abstrato, a prática pedagógica contemporânea ainda se depara com modelos de instrução padronizada que tendem a desconsiderar a subjetividade do aprendiz.

Nesse contexto, a abordagem de “tamanho único” (*one-size-fits-all*) negligencia a profunda heterogeneidade das turmas de escolas públicas. Essa uniformização resulta em lacunas de aprendizagem que se consolidam ao longo do ciclo escolar, distanciando o estudante da compreensão da Matemática como uma linguagem essencial de interpretação do mundo (Cotič; Doz; Jenko; Žakelj, 2024). É nesse hiato, entre a necessidade de uma personalização efetiva e as limitações estruturais do ensino em larga escala, que a Inteligência Artificial (IA) emerge não apenas como um recurso complementar, mas como um mecanismo capaz de reconfigurar o ecossistema de aprendizagem e promover a equidade pedagógica (Brasil, 2018).

A trajetória da IA no campo educacional reflete uma transição paradigmática: evoluiu de sistemas simbólicos baseados em regras rígidas para a atual sofisticação do Aprendizado de Máquina (*Machine Learning*) e das Inteligências Artificiais Generativas, fundamentadas em Modelos de Linguagem de Larga Escala (LLMs). Essa evolução tecnológica permitiu que o suporte digital transcendesse a mera exposição de conteúdos estáticos, passando a atuar como um “andaime cognitivo” (*scaffolding*), capaz de simular a flexibilidade do raciocínio e a mediação dialógica característica de um tutor humano (Russell; Norvig, 2020).

Atualmente, os Sistemas Tutores Inteligentes (STI) representam o estado da arte dessa convergência, proporcionando *feedback* imediato e adaptabilidade algorítmica ao ritmo de cada indivíduo, premissas que encontram respaldo nas diretrizes da Estratégia Brasileira de Inteligência Artificial (EBIA) (Brasil, 2021). Contudo, ao analisar a intersecção entre o ensino matemático e as estratégias de engajamento, como a Gamificação, identifica-se uma lacuna metodológica: a maioria das plataformas vigentes utiliza a IA para adaptar o conteúdo da aprendizagem, mas mantém as mecânicas de motivação e de recompensa de forma estática e

indiferenciada para todos os perfis de estudantes (Niño-Rojas *et al.*, 2024).

Essa dicotomia constitui o cerne da problemática investigada nesta dissertação. Ao desconsiderar que cada discente possui arquétipos de interação e vetores motivacionais distintos — que variam entre a busca por conquista, exploração ou socialização —, as ferramentas atuais apresentam limitações para induzir e sustentar o “Estado de Fluxo”. Sem a calibração dinâmica do estímulo lúdico, o processo educacional oscila entre a subutilização cognitiva e a frustração decorrente de desafios desconexos da realidade do aluno (Csikszentmihalyi, 1990).

Diante deste cenário, o presente trabalho introduz o *MatemAI*, um produto educacional desenvolvido no âmbito do programa PROFMAT da Universidade Federal do Tocantins (UFT), concebido para superar as limitações da gamificação padronizada. O objetivo geral da pesquisa consiste em desenvolver e validar um sistema de Gamificação Adaptativa, no qual algoritmos modulam, em tempo real, a narrativa, as recompensas e o sistema de *feedback*. Para a materialização desta arquitetura, o percurso metodológico desdobra-se nos seguintes objetivos específicos: i) mapear as competências da BNCC para o 9º ano do Ensino Fundamental, com foco direto nos descritores que apresentam os maiores índices de defasagem; ii) identificar e modelar uma taxonomia de interesses juvenis — englobando cultura *pop*, esportes e jogos eletrônicos — capaz de contextualizar as instruções (*prompts*) da IA Generativa e estruturar situações-problema alinhadas à realidade do adolescente; iii) implementar o protótipo da plataforma *MatemAI*, integrando processamento de linguagem natural a uma estrutura de “Economia de Fichas”, que orchestra níveis de experiência (XP), classificações e recompensas virtuais; iv) executar uma intervenção pedagógica na rede estadual de ensino do Tocantins, utilizando a ferramenta como suporte ao ensino regular; e v) avaliar a eficácia da proposta por meio de uma análise qualitativa sobre os fatores que influenciam a motivação discente.

A premissa central deste estudo defende que a IA Generativa demonstra capacidade para atuar como mediadora na Zona de Desenvolvimento Proximal (ZDP), ajustando a demanda cognitiva da Matemática e fornecendo, simultaneamente, um suporte motivacional adaptado ao perfil do usuário (Vygotsky, 1978). Destaca-se que a tecnologia não visa à substituição do professor; tal perspectiva é terminantemente refutada. O projeto tem como finalidade o fortalecimento da prática docente. Por meio de ferramentas de *Learning Analytics* e telemetria de precisão, o educador é provido de um painel analítico que viabiliza intervenções pedagógicas direcionadas e fundamentadas em dados no cotidiano da escola pública. Para apresentar essa investigação com o devido rigor metodológico, a dissertação organiza-se em cinco capítulos

principais.

Após esta introdução, o segundo capítulo estabelece a fundamentação teórica, abordando a evolução da IA na educação, a Teoria da Carga Cognitiva e os princípios da psicologia da gamificação aplicados às ciências exatas. O terceiro capítulo detalha a metodologia da pesquisa, estruturada na Pesquisa Baseada em Design (DBR), descrevendo as fases de desenvolvimento do software e as diretrizes éticas de proteção de dados. No quarto capítulo, realiza-se a análise dos resultados obtidos na Escola Estadual Vila Guaracy, localizada em Gurupi - TO, triangulando os ganhos de aprendizagem com as métricas de engajamento geradas pelo sistema. Por fim, o quinto capítulo sintetiza as considerações finais, discutindo as contribuições do *MatemAI* para a inovação educacional no estado do Tocantins e indicando perspectivas para a expansão de tutores inteligentes que contemplem o estudante em suas dimensões cognitiva e afetiva.

2 FUNDAMENTAÇÃO TEÓRICA

O desenvolvimento de tecnologias educacionais que promovam impactos efetivos no ensino da Matemática constitui uma tarefa de complexidade significativa. Requer a articulação consistente entre os processos cognitivos da aprendizagem humana e os avanços da computação. O presente capítulo estabelece as bases dessa interseção, delineando o arcabouço teórico que alicerça esta investigação.

Por um lado, discute-se o desafio de viabilizar uma aprendizagem personalizada e adaptativa em larga escala. Por outro, analisa-se a arquitetura dos Sistemas Tutores Inteligentes (STI) como a resposta tecnológica a essa demanda.

Nos tópicos subsequentes, explora-se a dinâmica dessa integração, evidenciando como a Inteligência Artificial (IA), quando vinculada aos pressupostos da neurociência cognitiva e ao design de gamificação, atua para superar a passividade do ensino tradicional, promovendo ecossistemas de aprendizagem responsivos e centrados no estudante.

2.1 Inteligência Artificial

A tentativa de mecanizar o raciocínio e emular capacidades cognitivas por meios artificiais não constitui um advento exclusivo da era contemporânea. Anteriormente ao estabelecimento da tecnologia digital como alicerce infraestrutural da sociedade, a filosofia e a matemática pura já debatiam os limites da lógica formal, da dedução e da automação do pensamento. O propósito de construir entidades capazes de mimetizar o intelecto remonta, sob uma ótica epistemológica, aos esforços de pensadores como Gottfried Wilhelm Leibniz, com sua proposição do *calculus ratiocinator* — um arcabouço teórico que visava reduzir o raciocínio humano a uma álgebra de conceitos estruturados —, e, posteriormente, à álgebra booleana, que forneceu a sintaxe binária indispensável para a computação moderna.

Atualmente, a Inteligência Artificial (IA) transcendeu a automação de tarefas puramente mecânicas ou a execução de cálculos aritméticos de força bruta. Consolidou-se como um campo científico multidisciplinar, cujos desdobramentos reconfiguram as estruturas de produção, as dinâmicas das interações sociais e os paradigmas de aquisição e processamento do conhecimento. Para a compreensão do impacto dessas tecnologias em ambientes educacionais e de mediação pedagógica, torna-se imperativo desconstruir o conceito de IA, afastando-o de abordagens

especulativas e ancorando-o em suas bases algorítmicas, probabilísticas e matemáticas.

A literatura acadêmica de referência frequentemente categoriza as abordagens de IA a partir de duas dimensões: sistemas que pensam em contraposição a sistemas que agem, e sistemas baseados no desempenho humano em relação a sistemas pautados na racionalidade ideal (Russell; Norvig, 2020). Sob uma perspectiva computacional, compreende-se o campo como o estudo, o design e o desenvolvimento de agentes autônomos que percebem os estímulos do ambiente circundante e executam ações calculadas para maximizar as probabilidades de sucesso na consecução de um objetivo predeterminado.

No escopo desta pesquisa, a IA não é interpretada como uma entidade substitutiva do educador, tampouco como um repositório dinâmico de informações. Ela atua como um motor de processamento lógico capaz de mapear conexões cognitivas complexas, identificar lacunas de aprendizagem por meio da análise de grandes volumes de dados (*Big Data*) e adaptar-se ao ritmo individual do aprendiz. A convergência entre o rigor da matemática aplicada, a teoria da computação e a neurociência cognitiva fundamenta as aplicações contemporâneas da IA, demandando uma análise detida sobre a evolução dessa arquitetura lógica ao longo das últimas décadas.

2.1.1 Evolução da Inteligência Artificial

O percurso histórico da IA não se caracteriza como uma trajetória linear e ascendente de sucessos tecnológicos ininterruptos. A formalização do campo emergiu em meados do século XX, intrinsecamente ligada à teoria da computabilidade e à criptografia matemática. O marco filosófico inicial é amplamente atribuído a Alan Turing, cuja publicação seminal, em 1950, propôs o questionamento fulcral: “As máquinas podem pensar?” (Turing, 1950). Ao propor o “Jogo da Imitação” (posteriormente denominado Teste de Turing), o matemático britânico transferiu o debate da abstração filosófica para um desafio pragmático e observável de processamento de informação.

Contudo, a gênese institucional da IA como disciplina acadêmica autônoma ocorreu em 1956, durante a Conferência de Dartmouth. Sob a liderança de John McCarthy, Marvin Minsky, Nathaniel Rochester e Claude Shannon, um grupo de pesquisadores reuniu-se com a premissa de que cada aspecto da aprendizagem ou qualquer outra característica da inteligência pode, em princípio, ser descrito de forma tão precisa que uma máquina pode ser construída para simulá-lo (McCarthy; Minsky; Rochester; Shannon, 1955). Nesse período de otimismo conceitual,

surgiram os primeiros programas capazes de realizar tarefas que demandavam processamento complexo. Um exemplo notório dessa fase embrionária foi o *Logic Theorist*, desenvolvido por Allen Newell e Herbert Alexander Simon, um software capaz de demonstrar teoremas do *Principia Mathematica* de Russell e Whitehead, evidenciando o potencial das máquinas para operar no campo da lógica formal e da matemática pura (Newell; Simon, 1956).

Nas décadas seguintes, a área vivenciou ciclos de investimentos significativos intercalados por períodos de ceticismo e redução de recursos, fenômenos que a historiografia tecnológica convencionou denominar como “Invernos da IA”. Durante os primeiros anos, o paradigma dominante foi o da Inteligência Artificial Simbólica (frequentemente referida pela sigla GOFAI - *Good Old-Fashioned AI*). Essa vertente apoiava-se na premissa de que a inteligência poderia ser reduzida à manipulação de símbolos e à aplicação de regras lógicas estritas e encadeadas de forma dedutiva (sistemas especialistas). Embora esses sistemas tenham alcançado desempenho notável em domínios restritos e altamente estruturados, como a resolução de equações ou jogos de tabuleiro limitados, eles esbarravam na limitação imposta pelo fenômeno da explosão combinatória. O poder de processamento da época revelava-se insuficiente para analisar árvores de busca complexas, e as regras rígidas apresentavam limitações diante da ambiguidade, das incertezas e do ruído inerentes ao mundo real e à linguagem natural.

A inflexão metodológica e a consequente superação das limitações dos modelos simbólicos clássicos ocorreram com o amadurecimento e a ascensão das técnicas de Aprendizado de Máquina (*Machine Learning*) e do Conexionismo (redes neurais artificiais). Essa transição representou uma mudança paradigmática no desenvolvimento algorítmico. Em vez de exigir que um programador humano codificasse exaustivamente todas as regras lógicas (*top-down*), os sistemas passaram a ser arquitetados para inferir padrões latentes e correlações matemáticas diretamente a partir da exposição a grandes conjuntos de dados (*bottom-up*).

No início do século XXI, o aprimoramento do algoritmo de retropropagação (*backpropagation*) aliado ao uso de arquiteturas de Aprendizado Profundo (*Deep Learning*) expandiu as capacidades da IA (LeCun; Bengio; Hinton, 2015). A convergência sinérgica entre o aumento da capacidade de processamento por meio de Unidades de Processamento Gráfico (*Graphics Processing Units* - GPUs) e a ampla disponibilidade de dados digitais permitiu que as redes neurais artificiais com múltiplas camadas ocultas superassem os antigos limites de desempenho.

Este momento de maturidade computacional — no qual algoritmos evoluem de executores de comandos lógicos estáticos para sistemas dinâmicos baseados em probabilidade inferencial

avançada — fundamenta a viabilidade técnica de aplicações contemporâneas. Essa evolução serve de base para as inovações que permeiam o reconhecimento de voz e a visão computacional, além de possibilitar a modelagem de sistemas educacionais adaptativos.

2.1.2 Inteligência Artificial na Educação

A integração da IA no contexto educacional constitui um eixo central de pesquisas avançadas sobre o futuro da aprendizagem. Uma revisão da literatura nas bases de dados *Scopus* e *Web of Science* revela uma reorientação temática ao longo das últimas duas décadas. A produção científica superou a digitalização básica de materiais didáticos, concentrando-se atualmente na modelagem de ambientes educacionais que respondem à cognição do estudante em tempo real (Chen; Chen; Lin, 2020; Zawacki-Richter; Marín; Bond; Gouverneur, 2019).

O propósito da IA na educação contemporânea não consiste na substituição do educador, mas sim na utilização da capacidade computacional para compreender as dinâmicas da aprendizagem humana. Autores como Luckin *et al.* (2016) e Holmes *et al.* (2019) apontam que o potencial da IA reside no processamento de volumes expressivos de dados de interação (o *Big Data* educacional). A partir desse rastreamento, o sistema infere o nível de domínio do estudante, monitora oscilações no engajamento e identifica lacunas no percurso lógico (Holmes; Bialik; Fadel, 2019; Luckin; Holmes; Griffiths; Forcier, 2016). Na Matemática, disciplina caracterizada pela complexidade de conceitos abstratos e históricos índices de reprovação, a IA na educação atua como um recurso para mitigar a padronização do ensino tradicional — superando o modelo de “tamanho único” — e fornecer intervenções pedagógicas direcionadas e ajustadas ao ritmo de cada estudante.

A transposição de algoritmos concebidos para o ambiente corporativo diretamente para o ecossistema escolar, no entanto, impõe desafios éticos e metodológicos. A implementação tecnológica requer a formulação de diretrizes que preservem a autonomia cognitiva dos estudantes e assegurem a transparência algorítmica. Diante dessa necessidade, organismos internacionais e governos têm estruturado orientações estratégicas de regulação.

2.1.2.1 O Consenso de Pequim sobre a Inteligência Artificial e a Educação

No âmbito da regulação ética da tecnologia educacional, o Consenso de Pequim (2019), chancelado pela UNESCO, constitui um marco regulatório essencial. O documento estabelece que o avanço da IA na educação deve alinhar-se aos Objetivos de Desenvolvimento Sustentável

(ODS), especificamente ao ODS 4¹, garantindo uma oferta educacional que alie inovação, qualidade e equidade (UNESCO, 2019).

A formulação de políticas de IA, de acordo com o Consenso, deve pautar-se por uma abordagem humanista. O documento preconiza que a função docente é insubstituível, posicionando a tecnologia como um recurso de suporte pedagógico. Seu papel consiste em reduzir as demandas burocráticas e administrativas e municiar o educador com dados analíticos, permitindo que o profissional se concentre na mediação dialógica, na orientação crítica e no desenvolvimento de competências socioemocionais (Miao; Holmes; Huang; Zhang, 2021; UNESCO, 2019).

Adicionalmente, o documento apresenta um alerta quanto à ampliação da desigualdade digital (*digital divide*). Preconiza-se o investimento em iniciativas de “IA para todos”, estabelecendo que desenvolvedores e governos compartilham a responsabilidade de assegurar que a personalização da aprendizagem não se restrinja a contextos privilegiados, excluindo populações vulneráveis. A estruturação do ensino público sob essa ótica demanda arquiteturas computacionais resilientes e adaptadas às especificidades e pluralidades regionais (Holmes; Bialik; Fadel, 2019; UNESCO, 2019).

2.1.2.2 Estratégia Brasileira de Inteligência Artificial

Alinhado aos debates globais promovidos pela UNESCO, o Brasil instituiu, em 2021, a Estratégia Brasileira de Inteligência Artificial (EBIA). Elaborado pelo Ministério da Ciência, Tecnologia e Inovações (MCTI), o documento define as diretrizes para a adoção ética da IA no cenário nacional. No escopo da estratégia, a Educação é identificada com dupla relevância: constitui tanto um campo de aplicação prática quanto o pilar fundamental para assegurar o desenvolvimento e a autonomia tecnológica do país a longo prazo (Brasil, 2021).

O diagnóstico da EBIA evidencia demandas educacionais em duas frentes. Por um lado, a necessidade de promover o letramento digital e o entendimento da lógica computacional por parte dos cidadãos. Por outro, o uso da IA como ferramenta de apoio à gestão e ao ensino. O texto normativo reconhece que a implementação de tutores adaptativos e de mecanismos de monitoramento inteligente oferece subsídios para o delineamento de políticas públicas fundamentadas em evidências (*data-driven policy making*).

A aplicação das diretrizes da EBIA, contudo, depara-se com disparidades infraestruturais e regionais de conectividade que caracterizam o território nacional. Para que a adoção da IA nas

¹ O Objetivo de Desenvolvimento Sustentável 4 (ODS 4) visa assegurar a educação inclusiva, equitativa e de qualidade, e promover oportunidades de aprendizagem ao longo da vida para todos até 2030.

redes estaduais de ensino não se restrinja a iniciativas isoladas, a engenharia de software deve priorizar arquiteturas otimizadas, capazes de assegurar escalabilidade com baixo consumo de processamento nos dispositivos dos estudantes.

No contexto da escola pública, observa-se que as dificuldades no aprendizado da Matemática frequentemente se associam a limitações estruturais de acompanhamento individualizado em turmas numerosas. A proposição subjacente à EBIA busca mitigar esse gargalo por meio do desenvolvimento de ecossistemas capazes de converter os registros de desempenho discente em diagnósticos pedagógicos precisos. Em substituição à avaliação exclusivamente somativa, o algoritmo visa subsidiar o professor com o mapeamento da Zona de Desenvolvimento Proximal (ZDP) de cada estudante.

2.1.3 Inteligência Artificial Generativa

A última década registrou uma mudança paradigmática significativa na arquitetura do aprendizado profundo (*Deep Learning*), caracterizada pela transição de modelos predominantemente discriminativos para modelos generativos. Historicamente, as aplicações de IA na educação operavam de forma classificatória, voltadas a prever índices de evasão ou categorizar o desempenho discente a partir de bases de dados estáticas (Baker; Inventado, 2014). A Inteligência Artificial Generativa altera essa dinâmica, deixando de apenas estabelecer delimitações entre as informações para decodificar a matriz de probabilidade subjacente aos dados, o que viabiliza a síntese de conteúdos inéditos e contextuais (Goodfellow; Pouget-Abadie; Mirza *et al.*, 2014).

A fundamentação matemática da IA Generativa baseia-se na maximização da verossimilhança. Treinadas em amplos conjuntos de dados digitais, as redes neurais assimilam os padrões estatísticos da linguagem, de imagens e de estruturas formais, tais como códigos de programação e notações matemáticas (Bommasani; Hudson; Adeli *et al.*, 2021). No ambiente escolar, essa capacidade generativa permite estruturar cenários de aprendizagem personalizados, elaborar questões com parâmetros variáveis em tempo real e fornecer feedbacks adaptados à Zona de Desenvolvimento Proximal (ZDP) do estudante (Kasneci; Keßler; Buzza *et al.*, 2023).

A obtenção desse desempenho avançado demandou um salto na engenharia de software, voltado a processar cadeias extensas de informação sem perda de coerência semântica. Essa demanda impulsionou o desenvolvimento dos Modelos de Linguagem de Larga Escala.

2.1.3.1 Modelos de Linguagem de Larga Escala

O campo do Processamento de Linguagem Natural (PLN) obteve avanços significativos com o desenvolvimento dos Modelos de Linguagem de Larga Escala (*Large Language Models* - LLMs). A arquitetura subjacente a esses modelos baseia-se no conceito de *Transformer*, introduzido por Vaswani *et al.* (2017), o qual substituiu as tradicionais Redes Neurais Recorrentes (*Recurrent Neural Network* - RNN) pelo mecanismo de “Atenção Própria” (*Self-Attention*) (Vaswani; Shazeer; Parmar *et al.*, 2017).

Esse mecanismo permite que o modelo calcule o peso de cada termo (*token*) em relação aos demais de forma simultânea. O LLM supera o processamento estritamente linear da sentença, assimilando o contexto de maneira global por meio de vetores de alta dimensão que mapeiam as nuances sintáticas e semânticas do discurso (Brown *et al.*, 2020). Com a incorporação de bilhões de parâmetros a essa estrutura, observou-se a manifestação de habilidades emergentes, capacitando a máquina a realizar tarefas como tradução de idiomas sem treinamento prévio (*zero-shot*), sumarização de textos e resolução de problemas discursivos para os quais não foi explicitamente programada (Wei; Tay; Bommasani *et al.*, 2022).

A aplicação dessa capacidade ao ensino da Matemática requer, contudo, rigor epistemológico, haja vista as limitações estruturais documentadas na literatura como inconsistências informacionais (“alucinações”) (Frieder *et al.*, 2023). Dado o caráter probabilístico do LLM, focado na previsão do termo subsequente mais verossímil, o sistema pode gerar resultados incorretos sob uma articulação textual convincente. Em problemas que demandam rigor dedutivo, o modelo pode apresentar falhas em operações elementares ou na articulação de demonstrações geométricas.


A fim de mitigar essa limitação, as pesquisas na área recorrem a técnicas de engenharia de *prompt*, com destaque para o protocolo *Chain-of-Thought* (Cadeia de Pensamento) (Wei; Wang; Schuurmans *et al.*, 2022). Essa estratégia baseia-se em induzir o modelo a explicitar seu percurso analítico, decompondo a resolução em passos intermediários antes da formulação do resultado final.

A Figura 1 esquematiza como a aplicação da *Chain-of-Thought* altera o fluxo tradicional de inferência, convertendo o processamento direto em um percurso analítico estruturado.

O direcionamento do LLM por meio do encadeamento lógico (Figura 1) fraciona a demanda computacional e reduz os índices de erro matemático. Sob a perspectiva do design educacional, essa fragmentação viabiliza a integração da lógica da maiêutica socrática ao núcleo

do algoritmo² (Chang *et al.*, 2023).

Figura 1 – Esquema comparativo entre o processamento direto e o processamento estruturado via *Chain-of-Thought* acoplado à maiêutica socrática.



Fonte: Elaborado pelo autor.

Sob esses parâmetros, o tutor virtual deixa de atuar como um mecanismo que fornece respostas diretas, assumindo a função de um facilitador do aprendizado. Internamente, o sistema processa a resolução completa do problema para assegurar a consistência da operação, enquanto na interface discente são exibidas apenas indagações direcionadas e pistas cognitivas estruturadas (*scaffolding*). Essa engenharia metodológica visa mitigar a passividade intelectual, estimulando o protagonismo do estudante por meio de uma mediação dialógica e adaptativa.

² O método socrático ou maiêutica (do grego *maieutiké*, arte de partejar) refere-se à técnica de interrogação que busca levar o interlocutor ao conhecimento por meio de seus próprios recursos mentais. No contexto do *MatemAI*, esta lógica é transposta para o algoritmo de modo que a IA não forneça respostas prontas, mas sim questionamentos e pistas que estimulem o discente a "dar à luz" à resolução do problema.

2.1.4 Sistema de Tutores Inteligentes

A instrução mediada por telas não nasceu inteligente. Nas décadas de 1970 e 1980, os sistemas de Instrução Assistida por Computador (IAC) dominavam o cenário educacional digital sob uma ótica estritamente comportamentalista. A dinâmica era mecânica: o software disparava um estímulo, aguardava a resposta do usuário e devolvia um veredito binário de acerto ou erro. Falhar significava, na melhor das hipóteses, ser redirecionado para o mesmo bloco de texto estático. Faltava a essa arquitetura a habilidade mais elementar da práxis docente: compreender os fatores determinantes do erro discente (Wenger, 1987).

A superação desse gargalo metodológico ocorreu com a integração de técnicas de IA, dando origem aos Sistemas Tutores Inteligentes (STI). Conforme assinala VanLehn (2011), um STI se diferencia de um repositório estático por buscar simular a capacidade heurística de um educador, interpretando as respostas do estudante para estruturar um ambiente de aprendizagem dinâmico (VanLehn, 2011). O sistema realiza diagnósticos contínuos, ajusta o percurso pedagógico e fornece suportes cognitivos graduais (*scaffolding*), reduzindo a assistência à medida que o estudante desenvolve autonomia (Nkambou; Mizoguchi; Bourdeau, 2010).

A área de Matemática constituiu um dos principais campos para a aplicação inicial e extensiva dos STIs, em virtude de sua estrutura axiomática estável e regras de produção lógicas bem delimitadas. Projetos pioneiros, como os *Cognitive Tutors* desenvolvidos na Universidade Carnegie Mellon, forneceram evidências empíricas sobre a eficácia da tecnologia. O monitoramento detalhado das etapas de resolução do estudante (*step-tracking*) demonstrou impactos positivos no desempenho em álgebra e geometria, atuando como um mecanismo relevante para a redução de disparidades de aprendizagem associadas a fatores socioeconômicos (Anderson; Corbett; Koedinger; Pelletier, 1995; Koedinger; Brunskill; Baker *et al.*, 2013).


A literatura clássica estrutura os STIs a partir de uma arquitetura composta por quatro módulos interdependentes: o Modelo do Domínio, o Modelo do Aluno, o Modelo Pedagógico e o Modelo de Interface (Corbett; Koedinger; Anderson, 1997).

A Figura 2 mapeia essa topologia clássica e expõe a circulação de dados entre as engrenagens do sistema.

O Modelo do Domínio (*Expert Model*, em inglês) não é um mero banco de questões anestesiado. Ele guarda a essência procedimental e declarativa da matemática. Dentro dele habitam os axiomas, os teoremas e as infinitas rotas lógicas que levam à solução de um problema geométrico. A máquina usa esse acervo para gerar soluções impecáveis, criando um padrão-ouro

(*gold standard*) que servirá de régua para medir os tropeços do estudante (Wenger, 1987).

Figura 2 – Arquitetura tetradimensional clássica de um Sistema Tutor Inteligente (STI)



Fonte: Corbett, Koedinger e Anderson (1997). Adaptado pelo autor.

O Modelo do Aluno (*Student Model*, em inglês) pulsa como o coração diagnóstico da plataforma. Trata-se de uma radiografia computacional em tempo real das emoções e da cognição do aprendiz. Alimentado por técnicas pesadas de estatística, como o Rastreamento de Conhecimento Bayesiano (RCB) ou Redes Neurais Profundas (RNP), o módulo devora dados de latência e tipologia de erro para calcular a exata probabilidade de um conceito ter sido absorvido (Piech; Bassen; Huang *et al.*, 2015). Aqui, a teoria do psicólogo russo Lev Vygotsky ganha corpo algorítmico. O sistema mapeia matematicamente a Zona de Desenvolvimento Proximal (ZDP), caçando a linha tênue entre o que o aluno faz sozinho e o que ele só alcança com um “empurrão” pedagógico.

O Modelo Pedagógico (*Tutor Model*, em inglês) assume o papel de maestro. Ele processa o abismo entre o domínio perfeito e a lacuna do aluno para disparar decisões em milissegundos. É ele quem julga se o momento exige uma correção seca, uma dica cifrada ou um salto de

complexidade para forçar o aluno a entrar em estado de fluxo (*flow*, em inglês). Turbinado pela atual IA Generativa, esse módulo ganha o poder da fala articulada, trocando a instrução robótica por uma investigação de dados apresentados pelo usuário.

2.2 Neurociência Cognitiva e Aprendizagem Matemática

Abandonar o velho paradigma transmissivo em favor de uma aprendizagem verdadeiramente adaptativa cobra um preço: precisamos, antes de tudo, decifrar o maquinário biológico da cognição. Durante décadas, o desenho de currículos matemáticos guiou-se pelo instinto pedagógico e pela mera observação do comportamento. Esse cenário mudou. A fusão entre neurociência, psicologia experimental e educação — hoje consolidada sob o guarda-chuva da Neuroeducação — entregou à academia o substrato empírico que faltava para entender como o cérebro humano codifica e retém os números (Ansari, 2008).

Ao contrário da linguagem falada, que conta com um “hardware” evolutivo pré-instalado na nossa espécie, a matemática formal é um artefato cultural recente. O cálculo avançado e a álgebra abstrata não nasceram conosco. Para dar conta desse abismo cronológico, o neurocientista Stanislas Dehaene cunhou a tese da “reciclagem neuronal”. Ele argumenta que, para aprender matemática, o cérebro é obrigado a sequestrar e reconfigurar circuitos corticais originalmente desenhados para outras missões primárias, como o rastreamento espacial e o reconhecimento visual de formas (Dehaene, 1997).

A complexidade dessa solução improvisada fica evidente no modelo do “Código Triplo” (*Triple-Code Model*, em inglês), também formulado por Dehaene. O processamento de um simples número engatilha três redes neurais simultâneas: a visão do algarismo arábico, a vocalização da palavra-número e a intuição analógica da quantidade (o nosso “senso numérico” de fábrica). Exige-se do aluno um esforço monumental para traduzir essas linguagens em milissegundos. Ler o símbolo “ $\frac{1}{2}$ ”, resgatar mentalmente o termo “metade” e visualizar a fatia geométrica da fração é uma operação de altíssimo custo metabólico.

Sob a lente da neurobiologia, o fracasso crônico nas aulas de exatas ganha um novo contorno. Não lidamos necessariamente com uma deficiência de aptidão inata, mas com o sintoma clássico de um sistema nervoso forçado a operar no limite do seu teto de processamento simbólico. Projetar tecnologias educacionais contemporâneas exige respeitar essa biologia. O *design* das plataformas precisa parar de lutar contra a anatomia cerebral e começar a orquestrar a instrução no exato compasso da mente do aprendiz.

2.2.1 Neurociência e Modelos Cognitivos

Mapear disparos de neurônios no córtex não preenche, por si só, um plano de aula. Para que os achados de laboratório desaguem em arquiteturas de software e táticas didáticas, dependemos de uma ponte epistemológica fundamental: os Modelos Cognitivos.

Trata-se de abstrações teóricas criadas para mapear o tráfego de informações dentro da mente. Esses modelos traduzem o caos celular em engrenagens operacionais claras, isolando mecanismos como atenção, percepção e arquivamento (Anderson, 2007). Quando olhamos para a matemática, a cartografia mais decisiva legada pela psicologia cognitiva é a arquitetura do processamento humano de dados. Seu pilar central sustenta-se na tensão funcional entre a Memória de Trabalho e a Memória de Longo Prazo.

A Memória de Trabalho é a nossa bancada mental de operações. É nela que a informação estaciona de forma efêmera para ser manipulada no calor da resolução de um problema. O modelo clássico de Alan Baddeley (1992) a descreve como um sistema liderado por um executivo central que terceiriza tarefas para circuitos menores — como a alça fonológica e o esboço visuoespacial. Ambos fervem de atividade quando o aluno tenta equilibrar os dois lados de uma equação (Baddeley, 1992). O grande gargalo dessa estrutura é a sua fragilidade arquitetônica. O cérebro humano só consegue equilibrar um punhado de informações simultâneas nessa bancada por poucos segundos. Se a complexidade do desafio estourar esse limite, ocorre o apagão cognitivo: a tarefa é abandonada ou o erro procedimental torna-se inevitável.

No extremo oposto, a Memória de Longo Prazo opera como um disco rígido de fronteiras virtualmente inesgotáveis. A verdadeira expertise matemática floresce quando o aluno domina a arte de transferir blocos de conhecimento da vulnerável Memória de Trabalho para esse arquivo definitivo, fundindo-os em esquemas mentais blindados (*schemas*). Diante de um polinômio de segundo grau, o cérebro treinado não entra em pânico tentando processar cada variável isolada; ele saca um esquema unificado de resolução instantaneamente, poupando combustível cognitivo para voos analíticos de ordem superior (Sweller, 1988).

Conceber ambientes virtuais de aprendizagem que funcionem exige, portanto, controle absoluto sobre as variáveis de trânsito entre essas duas memórias. Entender essa dinâmica neurológica evidencia a porta para o *design* instrucional de excelência. A urgência em proteger a Memória de Trabalho contra a saturação nos empurra diretamente para a Teoria da Carga Cognitiva e para o desenho multimídia. Paralelamente, a busca milimétrica pelo nível ideal de desafio amarra a neurobiologia à clássica Zona de Desenvolvimento Proximal (ZDP) de Lev

Vygotsky e ao Estado de Fluxo. É exatamente a dissecação dessa engenharia pedagógica que ancorará as próximas seções desta pesquisa.

2.2.1.1 Teoria da Carga Cognitiva e Aprendizagem Multimídia

A fragilidade da Memória de Trabalho não é apenas um detalhe biológico. Ela é a pedra angular da Teoria da Carga Cognitiva (TCC) (Sweller, 1988). A premissa de Sweller é rígida. A aprendizagem real — traduzida aqui como a gravação definitiva de esquemas na Memória de Longo Prazo — só acontece quando a exigência mental da tarefa respeita o teto de processamento do aluno.

Quando levamos essa métrica para a aula de matemática, o cenário atinge nível crítico. Resolver uma equação algébrica, provar um axioma ou decifrar um gráfico trigonométrico exige equilibrar pratos simultaneamente: símbolos, regras de sinais e hierarquia de operações colidem na mente do estudante. Para mapear e conter esse gargalo, a TCC fatiou o esforço mental em três blocos independentes, porém cumulativos: a carga Intrínseca, a Extrínseca e a Relevante (ou Germânica) (Sweller; Merrienboer; Paas, 1998).

A Carga Cognitiva Intrínseca nasce da própria natureza do conteúdo. Na matemática, quem dita essa métrica é a “interatividade dos elementos”. Olhe para a equação $x + 3 = 5$. A interatividade é baixíssima; logo, a carga intrínseca despenca. Tente, agora, resolver um sistema de equações diferenciais. O cérebro não consegue isolar uma variável sem calcular imediatamente o impacto no resto do sistema. Essa complexidade não pode ser apagada por mágica tecnológica. Ela só pode ser domada se fracionarmos o seu aglomerado em degraus sequenciais.

Já a Carga Cognitiva Extrínseca é o verdadeiro vilão do *design* instrucional. Trata-se da energia inútil. Telas educacionais poluídas, excesso de texto ou o consequente Efeito da Atenção Dividida — quando o aluno precisa olhar uma tabela no topo da página e ler a pergunta no rodapé — drenam a Memória de Trabalho sem gerar um miligrama de conhecimento matemático. É no combate frontal a esse ruído que a TCC se funde à Teoria Cognitiva da Aprendizagem Multimídia (Mayer, 2014). Princípios como o da “Contiguidade Espacial” (colar o texto explicativo exatamente ao lado da fração) e o da “Coerência” (limar qualquer som, cor ou palavra que não resolva o problema) deixam de ser luxo estético. Tornam-se regras de sobrevivência para tutores digitais.

A Carga Cognitiva Relevante é o esforço que realmente importa. É a queima de combustível cognitivo dedicada exclusivamente a ancorar a informação nova no conhecimento prévio do

estudante. A proposta central do algoritmo educacional resume-se a esta equação: minimizar a carga extrínseca, modular a carga intrínseca conforme a bagagem do aluno e impulsionar a carga relevante ao máximo (Paas; Renkl; Sweller, 2003).

Ignorar essa calibração fina gera desastres documentados, como o “Efeito da Reversão da Expertise” (*Expertise Reversal Effect*) (Kalyuga; Ayres; Chandler; Sweller, 2003). Entregar o passo a passo mastigado (*worked examples*) funciona com perfeição para um novato. Aplique a mesma técnica a um aluno avançado e o resultado vira pura sobrecarga extrínseca. O cérebro proficiente pede autonomia para resolver o problema, não tutoriais redundantes. Essa montanha-russa cognitiva prova que sistemas estáticos de “tamanho único” estão fadados à obsolescência. O algoritmo precisa ler o limiar de competência do aluno no milissegundo em que ele clica na tela. Entramos, assim, no território socioconstrutivista da Zona de Desenvolvimento Proximal.

2.2.1.2 Zona de Desenvolvimento Proximal e Estado de Fluxo

A Teoria da Carga Cognitiva (TCC) nos ensina “como” blindar a memória do aprendiz. A Zona de Desenvolvimento Proximal (ZDP), concebida pelo soviético Lev Vygotsky, orienta “o que” e “quando” ensinar. Vygotsky (1978) mapeou a ZDP como a terra de ninguém entre o domínio absoluto (o que o aluno resolve de olhos fechados) e o inatingível (o que ele só consegue destrinchar se escorado por um mentor ou por pares mais afiados).


Quando injetamos IA nesse ecossistema, o Sistema Tutor se apropria da cadeira do “par mais capaz” *More Knowledgeable Other* (MKO). O mapeamento da ZDP abandona o terreno do palpite pedagógico e vira matemática pura e rastreável. O algoritmo detecta, por meio do Rastreamento de Conhecimento (*Knowledge Tracing*), que o adolescente domina a fatoração básica. Imediatamente, lança a próxima bateria de exercícios na exata linha de fronteira da sua ignorância, construindo os andaimes cognitivos (*scaffolding*) (Wood; Bruner; Ross, 1976). No silício, essa andaimagem ganha vida em forma de orientações, correções em tempo real e perguntas maiêuticas amparadas pela lógica de *Chain-of-Thought*.

Manter o estudante equilibrado na corda bamba da sua ZDP dispara efeitos que extrapolam a aritmética. O impacto atinge o núcleo duro da motivação. Acertar a proporção exata entre a competência matemática do jovem e a pedreira do problema gera o Estado de Fluxo (*Flow State*) (Csikszentmihalyi, 1990).

O fluxo é o nirvana da imersão. O aprendiz mergulha tão fundo no raciocínio que a ansiedade cede e o relógio desaparece. A Figura 3 traduz visualmente essa arquitetura de

engajamento: o estado de fluxo só sobrevive na fenda milimétrica entre o desafio imposto e a habilidade instalada.

Figura 3 – Dinâmica do Estado de Fluxo e regulação algorítmica do Tutor Inteligente



Fonte: Csikszentmihalyi (1990). Adaptado pelo autor.

A dinâmica representada na Figura 3 demanda precisão algorítmica. A proposição de tarefas com carga intrínseca significativamente superior à proficiência de base do estudante tende a direcioná-lo para a zona de ansiedade, sobrecarregando a memória de trabalho. Inversamente, caso a complexidade do desafio seja excessivamente reduzida, desconsiderando o nível de proficiência por meio de revisões redundantes, o usuário é direcionado para a zona de tédio.

A inteligência artificial atua como um mecanismo de regulação contínua, ajustando a complexidade das atividades em tempo real com base em análises probabilísticas de desempenho. O propósito consiste em manter o estudante no canal de fluxo, otimizando o percurso de aprendizagem matemática e fornecendo a base estrutural para a aplicação de estratégias de Gamificação Adaptativa, nas quais os elementos lúdicos operam alinhados ao nível de desafio

adequado.

2.2.2 Aprendizagem Personalizada e Adaptativa em Larga Escala

O delineamento de metodologias para o ensino da Matemática depara-se historicamente com a limitação metodológica conhecida na literatura como o “Problema dos 2 Sigmas” (Bloom, 1984). Em seu estudo clássico, o psicólogo Benjamin Bloom evidenciou uma disparidade estatística significativa: estudantes submetidos à tutoria individualizada, combinada com avaliações formativas contínuas, apresentaram desempenho médio equivalente a dois desvios padrão (dois sigmas) acima daqueles inseridos em turmas tradicionais de ensino massificado. Esse distanciamento indica que a mediação individualizada possui capacidade de elevar o desempenho de um estudante mediano aos percentis superiores da curva de distribuição convencional.


A limitação apontada por Bloom residia na viabilidade logística e econômica de fornecer tutoria individual em larga escala no âmbito da educação pública, o que historicamente concorreu para a consolidação de modelos de instrução padronizados (*one-size-fits-all*). Sob essa abordagem uniforme, o ritmo pedagógico tende a ser balizado pela média da turma, cenário que pode gerar desinteresse em estudantes avançados e sobrecarga cognitiva naqueles que apresentam lacunas conceituais de base.

A superação desse impasse logístico delineou-se com os avanços tecnológicos recentes, notadamente na computação em nuvem, em dispositivos móveis e em algoritmos de IA. As Tecnologias de Aprendizagem Adaptativa (*Adaptive Learning Technologies*) viabilizaram a oferta de instrução personalizada em larga escala. Diferenciando-se de abordagens estáticas de diferenciação pedagógica, a aprendizagem adaptativa opera como um sistema dinâmico alimentado pelo fluxo contínuo de dados de interação (Kerr, 2016).

Em redes de ensino caracterizadas por elevada densidade discente por turma, a escalabilidade da personalização apoia-se na convergência entre a Mineração de Dados Educacionais (*Educational Data Mining* - EDM) e a Análise de Aprendizagem (*Learning Analytics* - LA) (Romero; Ventura, 2010). Enquanto a EDM aplica algoritmos de agrupamento (*clustering*) e árvores de decisão para identificar padrões latentes nas interações dos usuários (Baker; Inventado, 2014), a Análise de Aprendizagem processa essas informações para otimizar o ambiente digital e fornecer painéis analíticos (*dashboards*) estruturados para o corpo docente (Siemens; Dawson, 2013). Variáveis como o tempo de hesitação antes da resposta, a recorrência na solicitação de pistas e a natureza conceitual ou procedimental do erro são convertidas em indicadores de

proficiência.

Figura 4 – Ciclo de retroalimentação contínua da Aprendizagem Adaptativa em Larga Escala mediado por *Learning Analytics* e intervenção docente direta



Fonte: Siemens (2013) Adaptado pelo autor.

A Figura 4 sintetiza o fluxo algorítmico que fundamenta a personalização em larga escala. O processamento de grandes volumes de dados (*Big Data* educacional) atua como um instrumento de diagnóstico cognitivo, permitindo mapear a ZDP de múltiplos estudantes simultaneamente (Cope; Kalantzis, 2016).

Ao delegar ao sistema automatizado o fardo do diagnóstico exaustivo de rotina, o docente dispõe de maior disponibilidade para atuar nos níveis superiores da Taxonomia de Bloom. O tempo ganha qualidade para a mediação socioemocional, a coordenação de projetos interdisciplinares e a intervenção pontual nos grupos que a plataforma sinaliza como críticos. É nesse encontro entre o rigor da matemática e a precisão algorítmica que a equidade se consolida como prática pedagógica inclusiva e de excelência em escala populacional.

2.3 Gamificação no Ensino da Matemática

No ecossistema da educação matemática contemporânea, a gamificação caracteriza-se como a aplicação deliberada e estratégica de elementos de design de jogos — incluindo sua estética, dinâmicas e estruturas de engajamento — em ambientes alheios ao entretenimento puramente lúdico (Bacich; Moran, 2018; Moran; Bacich, 2015). O objetivo consiste em estimular

a resolução de problemas e fortalecer a persistência discente diante de demandas cognitivas complexas (Bacich; Moran, 2018). Essa abordagem alinha-se às competências preconizadas pela Base Nacional Comum Curricular (BNCC), estimulando o letramento digital, o pensamento crítico e o protagonismo discente no processo de investigação.

A resistência histórica e os impactos gerados pela ansiedade matemática encontram nas estratégias gamificadas um mecanismo de atenuação. A principal contribuição dessa abordagem reside na ressignificação do erro, que deixa de exercer uma função estritamente punitiva ou estigmatizante para ser incorporado como uma variável regular do processo de aprendizagem, análoga às mecânicas de nova tentativa presentes em jogos eletrônicos. Essa alteração na percepção do erro visa favorecer o desenvolvimento do que Dweck (2017) conceitua como mentalidade de crescimento (*growth mindset*) (Dweck, 2017).

2.3.1 Gamificação como Vetor de Engajamento e Motivação

A literatura recente produzida no próprio Programa de Mestrado Profissional em Matemática em Rede Nacional (PROFMAT) da Universidade Federal do Tocantins ratifica essa urgência por curadoria algorítmica. Moraes (2024), em sua dissertação, analisou a aplicação direta do ChatGPT como tutor virtual para estudantes do Ensino Médio. A conclusão da pesquisa expôs um cenário de contrastes. Por um lado, o autor documentou um salto expressivo no desempenho discente: as médias da turma saltaram de 4,8 para 6,0 após a intervenção com a máquina (Moraes, 2024).

O risco, contudo, mora na instabilidade da Inteligência Artificial Generativa não supervisionada. Moraes (2024) documentou falhas críticas de processamento. Ao testar a resolução de problemas envolvendo funções quadráticas, a plataforma entrou em processo de alucinação matemática. A máquina entregou resultados incorretos repetidas vezes. Exigiu sete comandos corretivos do pesquisador até conseguir formular a resposta exata para o custo mínimo do problema (Moraes, 2024).

É precisamente neste vácuo metodológico que o *MatemAI* ancora a sua relevância. Entregar a interface pura do *ChatGPT* a um adolescente é expô-lo ao risco da assimilação de equívocos algorítmicos. O nosso sistema resolve esta falha estrutural ao envelopar o motor de linguagem numa arquitetura de *Chain-of-Thought*. O rigor matemático da máquina é testado nos bastidores, blindando o discente contra a alucinação generativa.

A fundamentação psicológica da gamificação apoia-se nos pressupostos da Teoria da

Autodeterminação (TAD), a qual estabelece que o engajamento ideal ocorre mediante o atendimento de três necessidades psicológicas básicas: autonomia, competência e pertencimento (Deci; Ryan, 2000). Na estrutura do *MatemAI*, essas necessidades correlacionam-se às seguintes mecânicas:

- **Autonomia:** O estudante atua de forma ativa no delineamento de sua trilha de aprendizagem, exercendo a escolha sobre a ordem de execução das missões propostas (Moran; Bacich, 2015).
- **Competência:** O sistema fornece feedback visual contínuo por meio de indicadores de nível e barras de progresso, visando evidenciar a evolução conceitual em álgebra e geometria e mitigar a percepção de estagnação acadêmica.
- **Pertencimento:** A implementação de classificações e mecanismos de interação visa constituir uma comunidade de aprendizagem coletiva, reduzindo o isolamento cognitivo associado aos modelos tradicionais de ensino (Bacich; Moran, 2018).

Para assegurar a sustentabilidade do engajamento, o design lúdico deve contemplar a heterogeneidade dos perfis de usuários. A taxonomia de Richard Bartle identifica arquétipos de jogadores aplicáveis ao ambiente educacional, subdivididos entre: Conquistadores (focados em pontuações e insígnias), Exploradores (voltados à descoberta de novos cenários), Socializadores (pautados na interação com os pares) e Competidores (estimulados por desafios diretos e posicionamento em classificações) (Bartle, 1996). A eficácia da gamificação depende do equilíbrio desses elementos, evitando a monotonia ou a indução de pressões excessivas sobre os usuários.

2.3.2 Gamificação Adaptativa Potencializada pela Inteligência Artificial

A inovação metodológica desta investigação reside na integração entre estruturas lúdicas e processamento algorítmico, denominada Gamificação Adaptativa. Diferenciando-se dos sistemas lineares estáticos, que aplicam os mesmos estímulos e recompensas uniformemente, a abordagem adaptativa utiliza técnicas de Aprendizado de Máquina (*Machine Learning*) para modular as mecânicas de jogo em tempo real com base no comportamento e no desempenho individual.

O propósito central consiste na manutenção do estudante no Estado de Fluxo (*Flow State*). No cenário da escola pública, que apresenta turmas marcadas por acentuada heterogeneidade nos níveis de proficiência de base, a inteligência artificial atua na gestão dinâmica do ambiente.

Ao detectar que um usuário soluciona as atividades de forma célere, sugerindo risco de tédio, o sistema eleva a complexidade do desafio ou insere elementos narrativos complexos. Inversamente, diante de sinais de retenção ou frustração na resolução de um sistema linear, o algoritmo introduz missões de suporte focadas na redução da carga cognitiva, fornecendo o suporte (*scaffolding*) necessário para a recuperação da confiança e a continuidade do percurso de aprendizagem.

2.3.3 Inteligência Artificial e Gamificação: Diálogos com a Produção Acadêmica Nacional

A integração de recursos tecnológicos no ensino de Matemática no cenário brasileiro tem evoluído do uso de softwares auxiliares de cálculo para a estruturação de ecossistemas integrados de interação. Como fundamentação para o desenvolvimento do *MatemAI*, realizou-se uma imersão na produção científica do Mestrado Profissional em Matemática em Rede Nacional (PROFMAT), analisando as abordagens de pesquisadores nacionais frente ao desafio do engajamento escolar mediado por Inteligência Artificial (IA).

Um dos eixos identificados refere-se à capacidade da IA de atuar na Zona de Desenvolvimento Proximal. Conforme analisa Silva (2023) no âmbito da Universidade Federal do Oeste do Pará (UFOPA), o emprego de Modelos de Linguagem de Larga Escala (LLMs) possibilita uma reconfiguração da avaliação formativa:

A Inteligência Artificial Generativa oferece ao docente a possibilidade de criar itens de matemática que se adaptam à realidade do aluno, permitindo que a revisão de conteúdos ocorra de forma personalizada e instantânea, mitigando lacunas de aprendizagem antes que se tornem bloqueios cognitivos intransponíveis (Silva, 2023, p. 54).

De forma complementar, o estudo de Marques (2020) na Universidade Federal do Amapá (UNIFAP) assinala que a eficácia da IA no ensino de Matemática vincula-se à sua capacidade de simular o comportamento de um tutor humano. O autor argumenta que os Sistemas Tutores Inteligentes (STIs) devem ser projetados para interpretar o erro discente não como uma falha somativa, mas como um dado de entrada para a recalibragem do percurso pedagógico, diretriz que fundamenta a estrutura de feedback socrático adotada nesta pesquisa.

No contexto da rede pública de ensino, a personalização via Aprendizado de Máquina responde à heterogeneidade das turmas de Ensino Fundamental II, atuando como um mecanismo indutor de equidade ao permitir que cada estudante progrida conforme seu ritmo individual, em consonância com as competências da BNCC.

2.3.3.1 Gamificação e Engajamento: Do Modelo Estático à Adaptabilidade Computacional

A gamificação tem constituído objeto de investigação recorrente no PROFMAT como estratégia de enfrentamento à ansiedade matemática. Meneses (2025), em dissertação desenvolvida na Universidade Federal Rural do Rio de Janeiro (UFRRJ), ao avaliar a utilização de aplicativos matemáticos, constatou que abordagens de gamificação estática, baseadas unicamente no acúmulo de pontos, tendem a apresentar redução em sua eficácia motivacional após o contato inicial. Conforme discute o autor:

Para que o engajamento seja sustentável, é imperativo que a mecânica de jogo seja adaptativa. O sistema deve ser capaz de reconhecer o nível de proficiência do jogador e ajustar os desafios em tempo real, mantendo o estudante no estado de *Flow* (Meneses, 2025, p. 78).

O presente estudo expande a proposição de Meneses (2025) ao integrar o Aprendizado de Máquina como componente coordenador dessa adaptabilidade. Em relação ao trabalho de Carvalho (2025), que propõe a aplicação de IA no Ensino Médio para a otimização de trilhas de aprendizagem, esta pesquisa concentra-se no Ensino Fundamental II, etapa crítica para a consolidação da base conceitual matemática. Carvalho (2025) aponta que a IA Generativa, diferentemente de sistemas tradicionais baseados estritamente em questões de múltipla escolha, viabiliza uma interação dialógica na qual o estudante explicita seu percurso de raciocínio, permitindo à ferramenta executar o suporte pedagógico (*scaffolding*) por meio de orientações textuais personalizadas.

2.3.3.2 Cenário das Políticas Públicas e Ética Algorítmica no Brasil

A fundamentação teórica contempla ainda o panorama regulatório e as diretrizes normativas nacionais. Silva (2025), em análise de propostas governamentais, destaca que o Brasil, por meio da Estratégia Brasileira de Inteligência Artificial (EBIA), incentiva o desenvolvimento de artefatos voltados à promoção da alfabetização digital. Contudo, o autor ressalta a relevância da responsabilidade algorítmica:

A implementação de IA nas escolas estaduais deve ser acompanhada de uma curadoria pedagógica rigorosa, garantindo que os algoritmos sejam transparentes e que os dados discentes sejam protegidos conforme as diretrizes da LGPD (Silva, 2025, p. 92).

O estudo de Gomes (2024) no âmbito do PROFMAT complementa essa discussão ética ao defender a desmistificação dos processos de IA. O autor propõe que o ensino de Matemática

incorpore a análise da lógica subjacente às redes neurais, convertendo o recurso tecnológico em objeto de estudo. No ecossistema do *MatemAI*, esse processo realiza-se por meio do recurso *Chain-of-Thought*, no qual a IA expõe o encadeamento lógico adotado, auxiliando o estudante na estruturação do pensamento matemático de forma transparente.

2.3.3.3 Síntese das Convergências Teóricas

Visando sistematizar a base teórica nacional que fundamenta este Produto Educacional, o Quadro 1 apresenta a síntese das principais intersecções bibliográficas no âmbito do PROFMAT.

Quadro 1 – Síntese da Fundamentação Teórica Nacional (PROFMAT)

Conceito Chave	Autor (Ano)	Aplicação no MatemAI
IA Generativa	Silva (2023)	Elaboração de problemas contextualizados e <i>feedback</i> imediato.
Sistemas Tutores	Marques (2020)	Estruturação do Agente Socrático para mediação dialógica.
Gamificação Adaptativa	Meneses (2025)	Uso de XP e classificações baseados em resiliência e esforço contínuo.
Personalização	Carvalho (2025)	Desenvolvimento de trilhas de aprendizagem não lineares via Aprendizado de Máquina.
Ética e LGPD	Silva (2025)	Governança de dados e transparência nos comandos de instrução (<i>prompts</i>).

Fonte: elaborado pelo autor

A partir desse diálogo com a produção nacional, observa-se que o *MatemAI* se posiciona como uma evolução natural das pesquisas desenvolvidas no âmbito do PROFMAT, unindo a robustez técnica da inteligência artificial à sensibilidade pedagógica demandada pelo contexto das instituições públicas de ensino.

3 METODOLOGIA

Visando compreender de que maneira a convergência entre IA Generativa e Gamificação Adaptativa pode influenciar o processo de ensino-aprendizagem da Matemática no Ensino Fundamental II, estruturou-se um percurso metodológico de caráter sistemático. O presente capítulo detalha o delineamento da pesquisa, o levantamento bibliográfico que fundamentou o desenvolvimento do artefato e o design educacional adotado. Descrevem-se, outrossim, as etapas de desenvolvimento técnico da plataforma *MatemAI*, abrangendo o percurso desde a fundamentação teórica até a implementação prática junto a estudantes do 9º ano (turmas 92.01 e 92.02) da Escola Estadual Vila Guaracy, em Gurupi - TO, durante o ano letivo de 2025.

3.1 Delineamento Metodológico

A concepção de uma tecnologia educacional voltada a mitigar o desengajamento discente requer uma fundamentação metodológica consistente. Sob essa premissa, esta seção descreve o desenho da pesquisa, o mapeamento da literatura em repositórios científicos e os procedimentos adotados para a coleta de dados primários.

3.1.1 Natureza, Abordagem e Classificação da Pesquisa

A presente investigação caracteriza-se, quanto à sua natureza, como uma pesquisa aplicada, cujo escopo direciona-se à geração de conhecimentos e ao desenvolvimento de ferramentas voltadas à resolução de problemas identificados no contexto escolar. No cenário empírico delimitado, o foco concentra-se em mitigar o desengajamento e a ansiedade matemática no Ensino Fundamental II (Gil, 2019).

Para apreender a complexidade das interações entre os discentes e o agente socrático fundamentado em inteligência artificial, adotou-se uma abordagem mista (qualiquantitativa) (Creswell, 2014). O componente quantitativo permite a análise de variáveis de telemetria, como o desempenho em testes pedagógicos e o acúmulo de pontos de experiência (XP). Simultaneamente, o componente qualitativo baseia-se no exame das narrativas discentes e na análise das interações textuais registradas nos relatórios de conversação (*logs*) do sistema. A investigação foi conduzida *in loco* na Escola Estadual Vila Guaracy, assegurando a validade ecológica do estudo.

Quanto aos objetivos, a pesquisa classifica-se como exploratória, justificando-se pela inserção articulada de Modelos de Linguagem de Larga Escala (LLMs), da Teoria da Carga Cognitiva e de mecânicas de Gamificação Adaptativa no âmbito da rede pública de ensino do estado do Tocantins.

3.1.2 Levantamento Bibliográfico e Matriz de Viabilidade (SWOT)

O desenvolvimento estrutural e pedagógico do *MatemAI* baseou-se em um mapeamento prévio da literatura conduzido por meio de revisão sistemática. O levantamento concentrou-se nas bases de dados *Scopus* e *Web of Science*, visando identificar o estado da arte em Sistemas Tutores Inteligentes (STI) e as tendências contemporâneas da aplicação de IA no ensino de Matemática. Essa revisão proporcionou o embasamento teórico necessário acerca do potencial dos Modelos de Linguagem de Larga Escala (LLMs) para a personalização do ensino, bem como sobre as diretrizes éticas que norteiam a utilização dessas tecnologias.

No cenário nacional, a fundamentação foi complementada pela análise da produção científica no âmbito do PROFMAT. Esse levantamento evidenciou a evolução das abordagens tecnológicas no contexto escolar brasileiro. Enquanto estudos iniciais tratavam as ferramentas digitais prioritariamente como recursos de suporte visual (Marques, 2020), investigações recentes apontam para a transição em direção ao uso da IA Generativa como agente ativo de mediação e avaliação formativa. Esse panorama inclui aplicações dialógicas orientadas ao ensino de conceitos matemáticos (Carvalho, 2025) e a validação de modelos de linguagem para a contextualização de problemas algébricos (Silva, 2023). Adicionalmente, a eficácia das mecânicas de gamificação adaptativa para a promoção do engajamento discente encontra respaldo em Meneses (2025), enquanto as diretrizes regulatórias e de políticas públicas para a implementação de IA na educação básica são analisadas por Breno Silva (2025).

Visando fundamentar a inserção da inteligência artificial no ambiente escolar sob uma perspectiva analítica e segura, adotou-se o modelo estrutural de avaliação sugerido por Şahin e Teke (2025) relativo à integração da IA na educação matemática. A análise de viabilidade do *MatemAI* estruturou-se por meio de uma Matriz SWOT (Forças, Fraquezas, Oportunidades e Ameaças) adaptada ao escopo do projeto (Quadro 2).

O diagnóstico estruturado a partir da matriz de viabilidade (Quadro 2) norteou o estabelecimento dos requisitos do sistema. Deste modo, o *MatemAI* foi projetado para potencializar os fatores indutores de engajamento discente (gamificação adaptativa) e mitigar os riscos técnicos

identificados, mediante a implementação do protocolo *Chain-of-Thought* para preservação da precisão matemática e a adoção de rotinas de anonimização para conformidade com a LGPD.

Quadro 2 – Matriz SWOT da Implementation de IA Generativa no Ensino de Matemática

Forças (<i>Strengths</i>)	Fraquezas (<i>Weaknesses</i>)
• <i>Feedback</i> instantâneo e tutoria personalizada em tempo real (Scaffolding). • Capacidade de traduzir abstrações algébricas para o centro de interesse do aluno (futebol, música). • Disponibilidade em múltiplos dispositivos (smartphones).	• Risco de dependência cognitiva se a IA fornecer a resposta final (necessidade de travas via Prompt). • Limitações de processamento de contexto matemático complexo (alucinações).
Oportunidades (<i>Opportunities</i>)	Ameaças (<i>Threats</i>)
• Integração e alinhamento automatizado às competências da Base Nacional Comum Curricular (BNCC). • Indução do aluno ao "Estado de Fluxo", reduzindo a ansiedade matemática histórica.	• Desigualdade na infraestrutura de rede da escola pública inviabilizando acessos simultâneos. • Privacidade de dados e riscos éticos relacionados à Lei Geral de Proteção de Dados (LGPD).

Fonte: Sahin e Teke (2025). Adaptado pelo autor

3.1.3 Fase Diagnóstica e Perfilamento Computacional do Usuário

O desenvolvimento de um sistema adaptativo pressupõe a superação do modelo instrucional padronizado (*one-size-fits-all*). A operação das mecânicas de personalização do *MatemAI* requereu o mapeamento prévio das variáveis de entrada (*inputs*) destinadas a calibrar o algoritmo de recomendação. A coleta inicial de dados realizou-se por meio de um questionário de sondagem aplicado a uma amostra de 57 estudantes na Escola Estadual Vila Guaracy (Apêndice A).

O instrumento avaliou três dimensões principais: (a) perfil sociodemográfico, (b) indicadores de ansiedade e autoeficácia matemática, e (c) tipologias de comportamento lúdico dos usuários. A Tabela 1 apresenta a caracterização demográfica da amostra.

Os dados demonstram a concentração da faixa etária entre 11 e 15 anos (98,2%), período correlacionado ao desenvolvimento cognitivo de transição para as operações formais, etapa em que se observa, recorrentemente, a manifestação de defasagens conceituais no raciocínio lógico-abstrato.


Tabela 1 – Caracterização Demográfica da Amostra Experimental (n=57)

Variável Descritiva	Frequência (n)	Percentual (%)
<i>Identidade de Gênero</i>		
Feminino	35	61,4%
Masculino	22	38,6%
<i>Faixa Etária (Ciclo de Desenvolvimento)</i>		
11 a 12 anos	23	40,3%
13 a 15 anos	33	57,9%
18 anos ou mais	01	1,8%

Fonte: elaborado pelo autor

Adicionalmente, as informações coletadas subsidiaram a definição dos parâmetros de *game design* da plataforma. A partir da aplicação da taxonomia de perfis de jogadores de Bartle (1996), analisou-se a estrutura de incentivos digitais adequada para favorecer o engajamento intrínseco. Os resultados obtidos (Figura 5) evidenciaram a heterogeneidade no perfil motivacional da amostra.

Figura 5 – Distribuição dos vetores de motivação lúdica na amostra de usuários-piloto.



Fonte: Bartle (1996). Adaptado pelo autor

A predominância dos arquétipos Conquistador e Socializador direcionou o desenvolvimento de uma arquitetura de software flexível e não linear. O diagnóstico evidenciou que a inserção de uma classificação genérica seria insuficiente para sustentar a motivação discente, definindo a necessidade de o agente inteligente processar os perfis no acesso inicial. A partir dessa classificação, a plataforma passou a modular as interações, alternando entre dinâmicas baseadas em restrições temporais (para usuários com perfil Conquistador) e percursos fundamentados em

contextualização narrativa (direcionados ao perfil Explorador). Esse procedimento metodológico conferiu fundamentação pedagógica às rotinas de programação do *MatemAI*.

3.2 Pesquisa Baseada em Design e Estruturação das Etapas da Pesquisa

A integração de tecnologias baseadas em IA Generativa no ambiente escolar requer uma abordagem metodológica que supere o escopo do desenvolvimento puramente técnico de software. Visando assegurar que o produto educacional *MatemAI* respondesse de forma consistente às demandas identificadas na Escola Estadual Vila Guaracy, a estruturação desta pesquisa pautou-se nos pressupostos do Design Educacional e, centralmente, na metodologia da Pesquisa Baseada em Design (*Design-Based Research* - DBR).

3.2.1 Fundamentos do Design Educacional e a Metodologia DBR

O Design Educacional consiste no planejamento sistemático e fundamentado para o desenvolvimento e a aplicação de métodos, técnicas e atividades didáticas mediadas por tecnologias, com foco na otimização dos processos de aprendizagem (Filatro, 2008). No âmbito de um mestrado profissional da envergadura do PROFMAT — cujo escopo central envolve a concepção de um produto educacional aplicável e replicável —, o modelo tradicional de design instrucional beneficia-se da associação a um arcabouço investigativo iterativo.


Adotou-se, portanto, la Pesquisa Baseada em Design (DBR), abordagem inicialmente proposta na década de 1990 por Brown (1992) e Collins (1992) e posteriormente consolidada no campo das tecnologias educacionais por pesquisadores como Reeves (2006) e McKenney e Reeves (2012).

A DBR caracteriza-se como uma metodologia de intervenção com duplo foco: visa o desenvolvimento de soluções práticas (produtos educacionais tangíveis) para problemas complexos em contextos reais de ensino-aprendizagem e, simultaneamente, a formulação de princípios de design transferíveis a outros cenários, diferenciando-se de abordagens estritamente laboratoriais ou de observação passiva (Reeves, 2006). Sob esse prisma, a presente pesquisa propôs uma intervenção ativa frente às dificuldades de engajamento identificadas na Escola Estadual Vila Guaracy, em Gurupi - TO, por meio da implementação e avaliação do ecossistema gamificado *MatemAI*.

3.2.2 Ciclos Iterativos e Fases da Investigação

A operacionalização da DBR organizou-se em um percurso iterativo, alinhado ao ciclo de desenvolvimento de softwares educacionais. Com base na estrutura macro proposta por Reeves (2006), a investigação foi dividida em quatro fases interdependentes (Figura 6).

Figura 6 – Ciclo de Pesquisa Baseada em Design (DBR) aplicado ao desenvolvimento iterativo do tutor *MatemAI*.



Fonte: Reeves (2006). Adaptado pelo autor

O detalhamento das referidas etapas estruturou-se conforme os seguintes procedimentos:

- **Análise e Exploração do Problema (Diagnóstico):** Fase inicial voltada à compreensão do contexto escolar, compreendendo o mapeamento empírico dos arquétipos de jogador da amostra de estudantes. Essa etapa forneceu os subsídios empíricos e os requisitos pedagógicos necessários para a modelagem do algoritmo de personalização.
- **Concepção e Desenvolvimento do Artefato:** A partir dos requisitos identificados, procedeu-se ao projeto de engenharia de software, abrangendo a definição da infraestrutura de tecnologia (Python, Streamlit, Firebase), o design de interface e a engenharia de *prompt* do sistema. O artefato foi estruturado para atuar na Zona de Desenvolvimento Proximal (Vygotsky, 1978), requerendo validações prévias de funcionamento lógico.
- **Implementação e Imersão Guiada (Fase Empírica):** Compreendeu a validação do sistema no ambiente escolar por meio de sessões práticas no laboratório de informática ou em dispositivos móveis. Durante os períodos de imersão (50 minutos), os discentes interagiram autonomamente com as missões de álgebra e geometria propostas pela plataforma, viabilizando a observação participante direta dos percursos lógicos adotados.
- **Avaliação, Reflexão e Refinamento:** Fase focada na mensuração do impacto pedagógico e na estabilidade técnica da aplicação. Realizou-se a triangulação das métricas de teleme-

tria digital (pontuação acumulada, indicadores de engajamento e relatórios de mediação socrática) com a avaliação de usabilidade realizada pelo corpo docente, com o propósito de consolidar os resultados e sistematizar os princípios de design obtidos.

3.2.3 Considerações Éticas, LGPD e Responsabilidade Algorítmica

Considerando a coleta de dados de telemetria e o envolvimento de estudantes menores de idade, os procedimentos metodológicos adotados observaram integralmente as diretrizes da Resolução nº 510/2016 do Conselho Nacional de Saúde (Brasil, 2016), que regulamenta a ética na pesquisa em Ciências Humanas e Sociais no Brasil.

O protocolo ético assegurou a aplicação do Consentimento Informado. Previamente ao início da fase diagnóstica, obteve-se a anuência formal por meio da assinatura do Termo de Consentimento Livre e Esclarecido (TCLE) pelos pais ou responsáveis, bem como do Termo de Assentimento Livre e Esclarecido (TALE) preenchido pelos próprios discentes de forma autônoma.

Em conformidade com as exigências da Lei Geral de Proteção de Dados Pessoais (LGPD - Lei nº 13.709/2018), implementou-se um protocolo de governança de dados e responsabilidade algorítmica. Realizou-se a anonimização completa dos registros de identificação pessoal no banco de dados (*Firebase*), garantindo que as informações de desempenho fossem analisadas de maneira agregada. O conteúdo das interações textuais entre os estudantes e a inteligência artificial foi submetido à metodologia de Análise de Conteúdo (Bardin, 2016), resguardando a privacidade dos participantes e assegurando a conformidade legal da instituição de ensino.

3.3 O Produto Educacional: Engenharia de Software e Desenvolvimento do MatemAI

Os ciclos iterativos da DBR resultaram no desenvolvimento do *MatemAI*, caracterizado como um Sistema Tutor Inteligente (STI). Enquanto abordagens tradicionais na literatura frequentemente utilizam recursos digitais como repositórios estáticos de exercícios (Marques, 2020), o presente produto educacional integra modelos de linguagem de larga escala para a geração contextualizada de conteúdos e dinamização lúdica das atividades (Carvalho, 2025; Silva, 2023).

Esta seção analisa a engenharia do software, demonstrando a transposição dos conceitos pedagógicos para rotinas de programação, infraestrutura de banco de dados e comandos de sistema.

3.3.1 Engenharia de Software e Infraestrutura *Cloud-Native*

Visando assegurar a escalabilidade do *MatemAI* e a estabilidade técnica sob acessos simultâneos no contexto escolar, o desenvolvimento adotou o paradigma de arquitetura nativa em nuvem (*cloud-native*). O sistema foi estruturado para operar com baixa latência e alta responsividade, parâmetros técnicos relevantes para favorecer a imersão discente e a manutenção do estado de fluxo (Csikszentmihalyi, 1990).

A infraestrutura tecnológica da aplicação foi selecionada conforme os seguintes componentes:


- **Linguagem e Interface (Front-end):** A plataforma foi programada em *Python 3*, utilizando a biblioteca *Streamlit* para o desenvolvimento de uma *Single Page Application* (SPA). Essa escolha viabilizou um design responsivo com abordagem *mobile-first*, assegurando a compatibilidade técnica com telas de aparelhos móveis, identificados na fase de diagnóstico como os principais dispositivos de acesso à internet pelos discentes.
- **Processamento de Linguagem Natural (Módulo de IA):** A capacidade generativa do sistema foi estruturada por meio da API *google.generativeai*, utilizando os modelos fundacionais Google Gemini. Esses modelos foram selecionados em virtude da precisão apresentada em tarefas de raciocínio lógico-matemático e da eficiência no processamento de comandos, garantindo a sustentabilidade operacional do projeto.
- **Persistência de Dados e Telemetria:** O armazenamento de dados foi gerenciado via *Firebase (Firestore)*, banco de dados não relacional (NoSQL) que permite sincronização em tempo real. O módulo foi responsável pelo registro contínuo dos logs de interação, controle dos pontos de experiência (XP) acumulados e gerenciamento dos perfis lúdicos mapeados.

A Figura 7 ilustra a topologia do fluxo de dados da aplicação, desde o *input* do aluno até o processamento em nuvem.

3.3.2 O Motor Cognitivo: Engenharia de Prompt e o Agente Socrático

A contribuição metodológica do *MatemAI* associa-se ao condicionamento pedagógico do modelo de inteligência artificial. Modelos de linguagem de larga escala são estruturados para fornecer de forma direta resultados baseados em estimativas estatísticas de probabilidade.

Figura 7 – Arquitetura *Cloud-Native* do MatemAI e o fluxo de dados em tempo real.



Fonte: elaborado pelo autor

No entanto, no cenário do ensino da Matemática, o fornecimento imediato da resolução de problemas pode comprometer o esforço cognitivo necessário para a construção de esquemas conceituais.

Visando reconfigurar essa diretriz operacional, o *backend* do sistema implementou uma engenharia de *prompt* baseada em regras (*Rule-based Prompting*). O *System Prompt* — comando de sistema oculto que regula o comportamento do modelo — foi estruturado para simular os pressupostos da maiêutica socrática e orientar as interações estritamente no escopo da Zona de Desenvolvimento Proximal do estudante (Vygotsky, 1978).

O Quadro 3 apresenta a estrutura reduzida do código de injeção de comportamento, evidenciando a ponte entre a teoria da aprendizagem e a computação:

Quadro 3 – Algoritmo de Mediação

Algoritmo de Mediação: Extrato do *System Prompt* (*ai_agent.py*)

```
def construir_prompt_pedagogico(perfil_aluno, interacao_atual, nivel_xp):
    system_instruction = f"""
    VOCÊ É O MATEMAI: Um tutor especialista em didática matemática
    para o Ensino Fundamental II.

    O perfil do aluno é: {perfil_aluno['arquetipo']}
    com interesse em {perfil_aluno['tema_interesse']}.

    REGRAS INEGOCIÁVEIS DE MEDIAÇÃO:
    1. PROIBIÇÃO DE RESPOSTA DIRETA: Nunca forneça o resultado final
       do cálculo. Seu papel é atuar como um 'andaime' (scaffolding).

    2. DIAGNÓSTICO DO ERRO: Se o aluno errar, analise se o erro foi de
       desatenção (procedimental) ou falta de base (conceitual). Forneça
       apenas a próxima pista lógica.

    3. PERSONALIZAÇÃO SEMÂNTICA: Crie metáforas usando o interesse do
       aluno ({perfil_aluno['tema_interesse']}) para explicar o conceito
       matemático abstrato.

    4. PRECISÃO BNCC: O conteúdo gerado deve estar alinhado à Base
       Nacional Comum Curricular.

    5. ESTADO DE FLUXO: Se o aluno acertar rapidamente, aumente a
       complexidade da próxima pergunta (ajuste de dificuldade dinâmico).
    """
    return system_instruction
```

Fonte: elaborado pelo autor

A partir da parametrização do modelo com essas diretrizes restritivas de controle, o *MatemAI* mitiga a ocorrência de passividade cognitiva — situação em que o estudante apenas replica o resultado fornecido pelo sistema —, estimulando a mobilização de suas próprias estruturas intelectuais e validando a aplicação pedagógica dos STIs no ensino contemporâneo (Niño-Rojas *et al.*, 2024).

3.3.3 Mitigação de “Alucinações”: A Cadeia de Pensamento (*Chain-of-Thought*)

Um dos principais desafios documentados na literatura acerca da utilização de IA Generativa nas Ciências Exatas refere-se à ocorrência de inconsistências conceituais denominadas alucinações, em que o modelo pode apresentar equações ou resultados incorretos sob uma estrutura textual formal e coerente (Silva, 2023).

A fim de atenuar esse risco estrutural na plataforma *MatemAI*, a arquitetura lógica integrou o protocolo de Cadeia de Pensamento (*Chain-of-Thought*). Previamente à exibição de qualquer conteúdo na interface discente (*front-end*), o modelo executa rotinas de processamento em duas etapas internas: inicialmente, realiza-se a resolução analítica da tarefa em um estágio

intermediário para, subsequentemente, verificar a consistência lógica do percurso antes da formulação da pista pedagógica. Esse mecanismo de validação cruzada assegurou o rigor conceitual das atividades propostas durante a intervenção prática na instituição escolar.

3.3.4 Interface Gamificada e *Feedback* Contínuo

O projeto de interface gráfica do sistema fundamentou-se em diretrizes de Design Centrado no Usuário. Distanciando-se do formato linear e puramente somativo das plataformas de avaliação convencionais, o design gráfico do *MatemAI* buscou otimizar a ergonomia cognitiva por meio de recursos de interatividade similares aos de plataformas consolidadas de aprendizagem baseada em jogos.

Para materializar a Gamificação Adaptativa, o software utiliza as seguintes mecânicas:


- **Trilhas de Aprendizagem Não Lineares:** Os conteúdos curriculares são organizados em missões modulares. O acesso a novas etapas realiza-se de forma dinâmica com base no desempenho do estudante em tempo real, visando mitigar a sobrecarga cognitiva extrínseca (Sweller, 1988).
- **Economia de Fichas (Pontuação XP):** A superação autônoma de desafios ou a correção orientada de erros resulta na concessão de Pontos de Experiência (XP). Essa dinâmica atua como mecanismo de reforço positivo contínuo para sustentar a motivação discente (Meneses, 2025).
- **Contextualização Narrativa Adaptativa:** O sistema adapta contextualmente os enunciados dos problemas matemáticos. Uma mesma operação de proporcionalidade pode ser configurada em torno do tempo de recarga em um jogo eletrônico para discentes com preferência por esportes digitais, ou ajustada à proporção de ingredientes em receitas culinárias para perfis distintos, ampliando a relevância semântica do objeto de estudo para o aprendiz.

3.3.5 Arquitetura Visual e Trilhas de Aprendizagem Não-Lineares

A interface visual do *MatemAI* foi estruturada em consonância com as premissas do Design Centrado no Usuário e da Teoria da Carga Cognitiva (Sweller, 1988). Visando atenuar o risco de saturação no processamento de dados (sobrecarga cognitiva), as habilidades curriculares

foram estruturadas em missões delimitadas. A Figura 8 ilustra o mapa de navegação que orienta o percurso formativo do estudante na plataforma.

Figura 8 – Interface de gamificação demonstrando a progressão sequencial de missões (Trilha de Aprendizagem).



Fonte: *MatemAI*. Extraído pelo autor da plataforma

A progressão pelas seções do sistema ocorre de maneira condicionada: a disponibilização de novas etapas requer a demonstração de proficiência nos conceitos anteriores, visando assegurar a consolidação das habilidades de base previamente à introdução de novas variáveis e níveis de complexidade matemática.

3.3.6 O Ciclo de Tutoria na Prática: *Scaffolding* Socrático

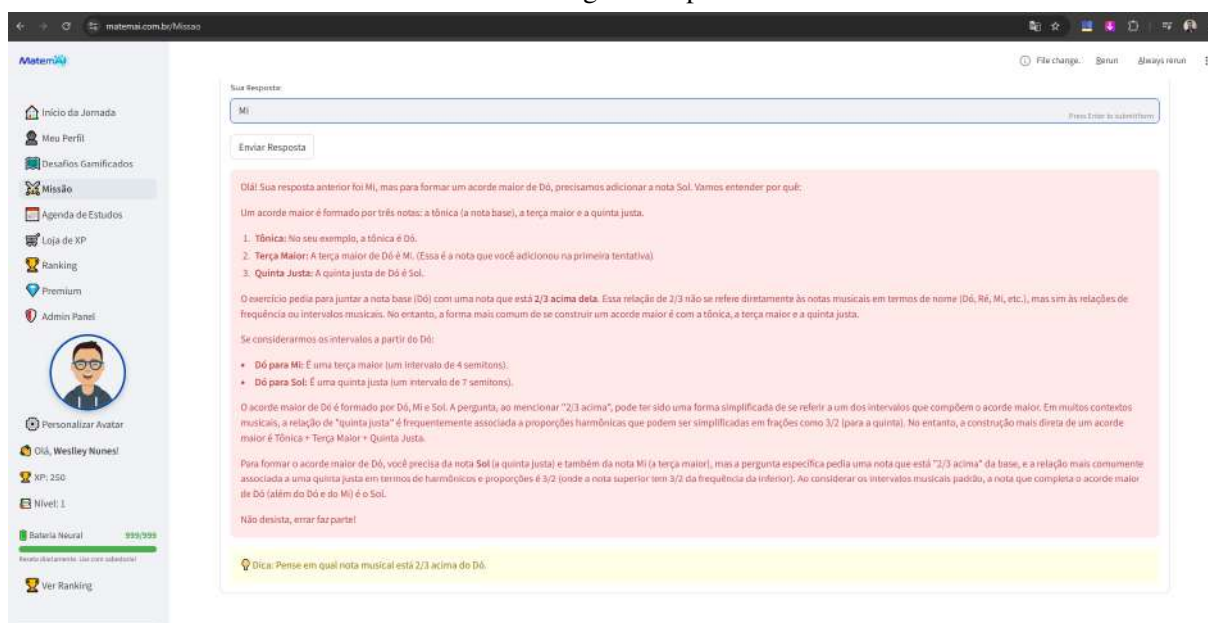
O núcleo da interação entre o usuário e o sistema realiza-se no escopo de execução das missões, etapa na qual as diretrizes pedagógicas codificadas no *backend* realizam a mediação. A abordagem destaca-se pelo tratamento metodológico do erro, em que o algoritmo converte a inconsistência em indicador para o fornecimento de suporte instrucional gradual.

Perante uma resposta incorreta ou retenção prolongada na atividade, o sistema restringe o acesso direto ao gabarito, iniciando o protocolo de suporte gradual (*scaffolding*). A Figura 9 exemplifica um registro real dessa mediação interativa.

Verifica-se na interface gráfica que o sistema identifica as características do erro procedimental cometido e gera uma pista contextualizada. Este ciclo de interações estimula a progressão

do discente no escopo de sua ZDP, preservando o protagonismo do raciocínio lógico-matemático com o estudante.

Figura 9 – Tela de tutoria evidenciando a mediação pedagógica da IA (*Scaffolding*) em substituição à entrega da resposta direta.



Fonte: *MatemAI*. Extraído pelo autor da plataforma

3.3.7 Economia de *Tokens* e Reforço Positivo Imediato

A continuidade da participação em atividades de elevada demanda cognitiva está correlacionada à tempestividade e à natureza das rotinas de feedback fornecidas pelo sistema (Deterding; Dixon; Khaled; Nacke, 2011). Com o intuito de favorecer a imersão e a manutenção do estado de fluxo (Csikszentmihalyi, 1990), o *MatemAI* integrou dinâmicas baseadas em Economia de Fichas (*Token Economy*).

Após a resolução autônoma de um problema ou a conclusão de uma tarefa orientada pelo suporte socrático, o algoritmo realiza a atualização dos pontos de experiência (XP) do usuário. Conforme ilustrado na Figura 10, a validação da resposta correta supera a emissão de indicadores binários, sendo acompanhada de elementos visuais de reforço positivo estruturados de forma dinâmica pela IA para valorizar o esforço empregado.

Figura 10 – Interface de *feedback* gamificado e injeção de XP após a conclusão bem-sucedida de uma missão.



Fonte: *MatemAI*. Extraído pelo autor da plataforma.

3.3.8 Telemetria Docente, *Learning Analytics* e a Dinâmica de Socialização (*Ranking*)

A validação de um Produto Educacional no escopo do Mestrado Profissional em Matemática em Rede Nacional (PROFMAT) requer que a tecnologia desenvolvida forneça suporte sistemático ao exercício da docência (Marques, 2020). No ecossistema do *MatemAI*, essa premissa implemente-se por meio do processamento integrado de dados de telemetria e de dinâmicas de classificação social.

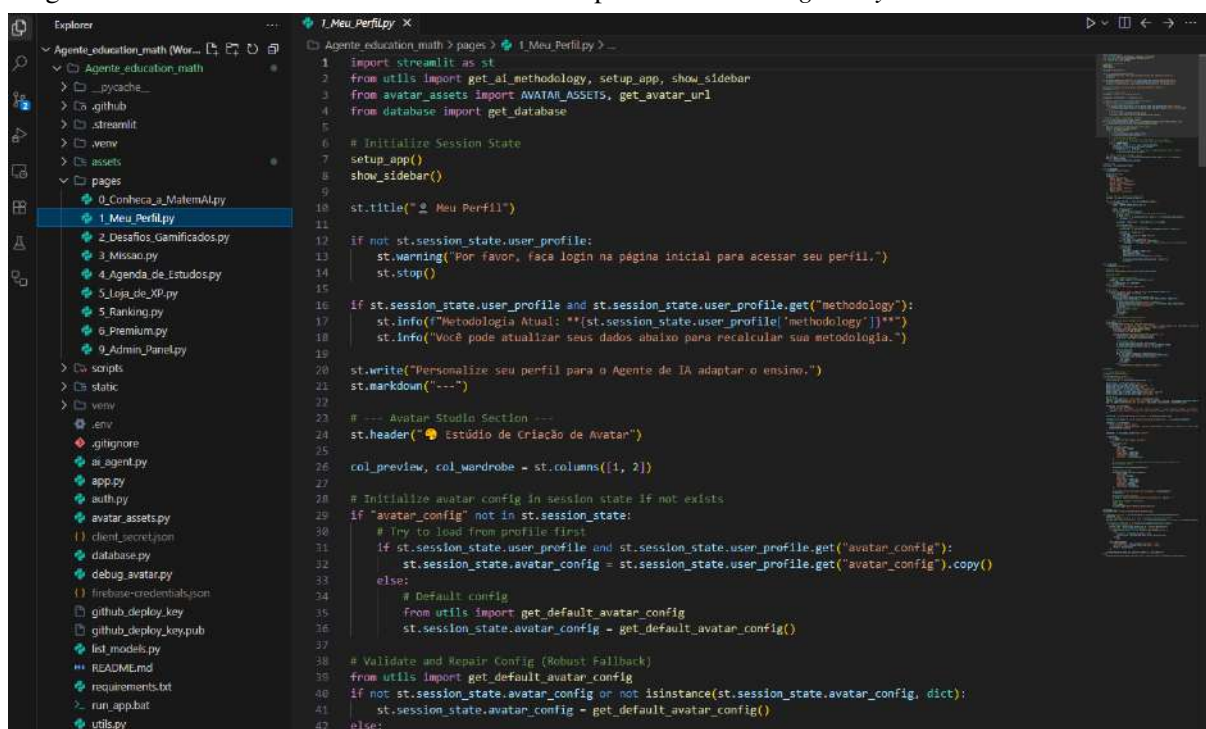
3.3.8.1 O Professor como Gestor de Aprendizagem via *Dashboard*

A literatura especializada indica que as soluções tecnológicas aplicadas à educação devem atuar como mecanismos auxiliares de suporte à ação mediadora do professor, e não em sua substituição (Carvalho, 2025; Silva, 2025). Para operacionalizar essa integração, a base de dados em nuvem (*Firebase*) do *MatemAI* foi configurada para fornecer subsídios de *Learning Analytics* (Análise de Aprendizagem).

O sistema realiza a coleta contínua de variáveis de interação, tais como a tipologia dos erros procedimentais, a frequência de solicitação de pistas, o tempo de latência nas respostas e o mapeamento das habilidades da BNCC em desenvolvimento. Esses indicadores brutos são processados e consolidados em um painel analítico (*dashboard*) com atualização em tempo real, cuja interface administrativa apresenta acesso restrito ao corpo docente e à coordenação

pedagógica (Figura 11).

Figura 11 – Visão da infraestrutura de *backend* e painel de *Learning Analytics* armazenado na nuvem.




Fonte: elaborado pelo autor

Por meio dessa ferramenta de acompanhamento, o educador atua como gestor estratégico do processo de ensino-aprendizagem. Ao constatar no painel analítico que um estudante ou um grupo de alunos apresenta dificuldades recorrentes na resolução de determinado descritor conceitual, o professor dispõe de subsídios para realizar intervenções pedagógicas diretas no ambiente presencial. Esse acompanhamento baseado em telemetria complementa a automação digital, reduzindo o risco de isolamento do estudante e assegurando a mediação pedagógica necessária nas etapas de ensino.

3.3.8.2 A Psicologia do *Ranking*: De Notas Punitivas à Recompensa por Esforço

A segunda vertente de aplicação dos dados coletados reflete-se na interface do usuário discente. Incorporando os resultados do diagnóstico inicial — que indicaram a predominância dos arquétipos Conquistador e Socializador em mais de 70% da amostra —, o sistema computa o progresso em pontos de experiência (XP), exibidos de forma consolidada em uma classificação geral (Figura 12).

Figura 12 – Monitoramento do progresso coletivo e *ranking* de engajamento gamificado da turma.



Fonte: *MatemAI*. Extraído pelo autor da plataforma.

A incorporação de painéis classificatórios (*leaderboards*) em plataformas digitais de ensino fundamenta-se em pressupostos da psicologia comportamental aplicada ao engajamento (Hamari; Koivisto; Sarsa, 2014). Diferenciando-se de dinâmicas avaliativas estritamente somativas que podem intensificar os níveis de ansiedade matemática, a classificação integrada ao *MatemAI* baseia-se nos princípios de reforço positivo contínuo (Meneses, 2025).

A modelagem da concessão de pontos na plataforma recompensa o esforço cognitivo e a persistência discente. O acúmulo de pontos de experiência (XP) está vinculado à utilização das pistas de suporte e à continuidade nas tentativas de resolução de problemas. Consequentemente, o posicionamento na classificação reflete o nível de dedicação e engajamento contínuo na plataforma, em detrimento de uma suposta aptidão inata estável.

Essa mecânica alinha-se aos pressupostos da Teoria da Autodeterminação (Deci; Ryan, 2000), a qual postula que a motivação intrínseca é favorecida quando as necessidades psicológicas básicas de competência e relacionamento social são atendidas. A classificação permite ao estudante monitorar visualmente seu progresso e interagir de forma indireta no ecossistema da turma.

Em síntese, a engenharia de software e o design educacional adotados no *MatemAI* articulam três níveis de interação complementares: a microinteração individual (estudante-sistema), a mesointeração social (interação indireta entre pares via classificação) e a macrointeração pedagógica (mediação docente subsidiada pelo painel de telemetria).

4 RESULTADOS E DISCUSSÃO: O PRODUTO MATEMAI

Este capítulo examina o desenvolvimento e a estruturação técnica do *MatemAI*. Compreendido como um ecossistema de personalização pedagógica mediado por IA Generativa, o sistema constitui o foco analítico desta investigação. Em virtude do curto período de exposição empírica, a análise distancia-se da avaliação restrita a métricas somativas externas, concentrando-se no exame da arquitetura do software enquanto constructo científico. A seguir, demonstra-se o processo de conversão de formulações teóricas cognitivas em algoritmos aplicados e rotinas de mediação pedagógica.

4.1 Arquitetura Cognitiva e Engenharia de Prompt

A materialização desta pesquisa encontra-se na arquitetura computacional do Sistema Tutor Inteligente. Estruturado com base em Modelos de Linguagem de Larga Escala (LLMs), o *MatemAI* foi concebido para superar a função de repositório estático de conteúdo. O algoritmo subjacente gerencia a interação ajustando, de maneira dinâmica, o fornecimento de suporte matemático rigoroso à condução lúdica orientada pela gamificação.

4.1.1 O Agente Socrático: Scaffolding via System Prompt

A precisão operacional do sistema não decorre exclusivamente da capacidade de processamento do modelo fundacional (Google Gemini), mas de uma Instrução de Sistema (*System Prompt*) desenvolvida especificamente para direcionar o comportamento da IA à mediação pedagógica, restringindo o fornecimento de respostas diretas.

Diferenciando-se de *chatbots* genéricos e de sistemas de avaliação binária, o *MatemAI* opera sob o protocolo da maiêutica socrática. O algoritmo diagnostica preliminarmente a natureza do erro discente (procedimental ou conceitual) para, em seguida, fornecer o suporte correspondente. O Quadro 4 apresenta a correlação entre os marcos teóricos da pesquisa e as restrições inseridas no comando da IA.

4.1.2 Camadas de Validação: Mitigação de Inconsistências Matemáticas

A literatura científica reporta a suscetibilidade dos Modelos de Linguagem à geração de inconsistências cognitivas (alucinações), fenômeno no qual cálculos incorretos são apresentados

sob uma articulação textual logicamente estruturada e convincente.


Quadro 4 – Diretrizes de Mediação Pedagógica Implementadas no *System Prompt*

Fundamentação Teórica	Diretriz de Prompt (Comando IA)	Objetivo no Software
Teoria da Carga Cognitiva	“NUNCA forneça a resposta final de imediato. Forneça pistas graduais.”	Garantir o papel de “andaime” (<i>scaffolding</i>) sem sobrecarregar a memória de trabalho.
Estado de Fluxo	“Se o aluno demonstrar domínio, aumente o desafio matemático.”	Ajustar a curva de dificuldade para evitar o tédio e manter o engajamento contínuo.
Aprendizagem Multimídia	“Use representações visuais (ASCII ou LaTeX) para explicar o conceito.”	Equilibrar o processamento cognitivo estimulando os canais visual e verbal simultaneamente.

Fonte: Elaborado pelo autor

Como solução técnica para atenuar essa vulnerabilidade, o *MatemAI* integrou o protocolo de *Chain-of-Thought* (Cadeia de Pensamento). Previamente à exibição do suporte gamificado na interface do usuário, o sistema executa um processamento analítico interno para verificar a validade algébrica do cálculo e sua conformidade com as diretrizes da Base Nacional Comum Curricular (Brasil, 2018).

Figura 13 – Fluxograma de verificação interna (*Chain-of-Thought*) para garantia de precisão matemática



Fonte: Elaborado pelo autor.

Essa arquitetura de validação permite que o *MatemAI* atue de forma consistente como um sistema mediador de competências matemáticas, conciliando o rigor do método dedutivo ao engajamento promovido pelo formato gamificado.

4.2 Gamificação Adaptativa: Mecanismos de Engajamento


A atenuação do desengajamento discente no Ensino Fundamental II requer a implementação de metodologias que superem a adoção superficial de elementos lúdicos. O avanço metodológico do *MatemAI* centra-se na aplicação da Gamificação Adaptativa. Em contraposição às plataformas de instrução linear que fornecem estímulos uniformes, o sistema desenvolvido modula as dinâmicas motivacionais com base na resposta individual do usuário, operando como um ambiente interativo adaptável (Carvalho, 2025).

4.2.1 Modelagem Algorítmica dos Perfis de Usuário

O percurso de adaptação inicia-se na fase de ambientação (*onboarding*) do sistema (`1_Meu_Perfil.py`). Por meio da coleta de informações declaratórias, o algoritmo identifica e classifica os arquétipos motivacionais do estudante. Essa classificação orienta a plataforma na seleção das mecânicas lúdicas adequadas para sustentar a atenção e o engajamento na tarefa matemática.

A Figura 14 demonstra a topologia da árvore de decisão integrada ao motor da IA, responsável por processar e adaptar a interface e a abordagem instrucional do tutor.

Figura 14 – Árvore de decisão algorítmica para personalização da mecânica de jogo e da persona do tutor.



Fonte: Elaborado pelo autor.

Para os usuários classificados no perfil Conquistador, a interface exibe dinâmicas fundamentadas em restrição de tempo e pontuações progressivas. Em relação ao perfil Explorador, o algoritmo encapsula a resolução algébrica em contextos de descoberta narrativa, reconfigu-

rando a percepção da avaliação matemática tradicional (Deterding; Dixon; Khaled; Nacke, 2011; Meneses, 2025).

4.2.2 Personalização Semântica e Contextualização do Conteúdo

Um aspecto central no desenvolvimento do *MatemAI* consiste na Personalização Semântica. O sistema operacionaliza o conceito atuando como um tradutor de contextos: diante de bloqueios cognitivos, a IA altera a semântica do enunciado do problema, associando a abstração matemática a centros de interesse previamente informados pelo estudante.

O *MatemAI* realiza uma triagem pedagógica entre o erro do aluno e o seu interesse mapeado. Os quadros a seguir demonstram essa mediação em diferentes perfis de interesse:

Quadro 5 – Matriz de Mediação Semântica: Exemplos de Contextualização

Perfil	Conceito Matemático	Estratégia de Mediação (Scaffolding)
Futebol	Equações do 1º Grau	"Em um torneio, cada vitória vale 3 pontos e cada empate 1. Se o time somou 10 pontos em 4 jogos, quantas vitórias foram necessárias?"
Games (RPG)	Probabilidade	"Se a chance de obter um item épico é de 1 em 10, quantas tentativas, em média, você precisaria para garantir o <i>loot</i> ?"
Música	Frações Heterogêneas	"Para preencher um compasso quaternário, se você já usou uma mínima ($\frac{1}{2}$), quanto falta para completar o ritmo usando semínimas ($\frac{1}{4}$)?"

Fonte: Elaborado pelo autor.

Abaixo, detalhamos o fluxo de interação real, onde o sistema aplica a lógica do Quadro 5 para converter um erro em aprendizado:

A análise desses registros demonstra a capacidade do sistema de transpor operações algébricas para referenciais associativos consolidados pelo usuário (Dehaene, 2020). Esta intervenção orientada converte o erro de processamento — um gatilho comum de ansiedade matemática — em um percurso autônomo de instrução mediada, fortalecendo a autoeficácia do estudante.

Quadro 6 – Transcrição de *Log* do Backend: O Caso da Música

Desafio: Soma de Frações ($\frac{1}{2} + \frac{1}{4}$) Perfil: Música
MatemAI: Para completar o compasso, precisamos somar $\frac{1}{2} + \frac{1}{4}$. Qual o resultado? Aluno: Dá $\frac{2}{6}$. (<i>Erro: soma direta</i>)
MatemAI (Mediação): Segura o andamento, Maestro! Se você tocar uma Mínima ($\frac{1}{2}$) e depois uma Semínima ($\frac{1}{4}$), quanto tempo preencheu? Lembre-se: a Mínima dura o mesmo que duas Semínimas.
Aluno: Ah, 2 tempos mais 1 tempo... dá 3 tempos.
MatemAI: Exato! E 3 Semínimas ($\frac{1}{4}$ cada) representam qual fração?
MatemAI: Na mosca! O resultado é $\frac{3}{4}$. Você acabou de fazer o MMC sem perceber!

Fonte: Logs de telemetria da plataforma *MatemAI*.

4.3 Validação Técnica e Telemetria de Engajamento

A validação do produto *MatemAI* baseou-se em duas abordagens metodológicas complementares: a revisão estrutural e pedagógica conduzida por docentes especialistas, realizada após a configuração do sistema, e a análise de métricas de telemetria provenientes das interações reais dos estudantes. A triangulação qualitativa e quantitativa visou certificar a precisão conceitual do tutor e a eficácia das rotinas de manutenção do engajamento discente preconizadas pelas metodologias ativas (Bardin, 2016).

4.3.1 Validação Docente: Revisão por Pares e Avaliação de Usabilidade

Com a versão estável da plataforma desenvolvida, o sistema foi disponibilizado a um grupo de cinco docentes de Matemática da rede estadual para avaliação prática (Apêndice B). O protocolo de avaliação privilegiou a experimentação direta da interface, priorizando a análise de usabilidade e a consistência das diretrizes de mitigação de alucinações matemáticas da IA.

A Tabela 2 apresenta o perfil dos educadores participantes, estratificados com o objetivo de contemplar variáveis como o tempo de experiência no ensino e diferentes níveis de proficiência em tecnologias educacionais.

Durante os testes, os professores inseriram intencionalmente equações incorretas e simularam limitações de compreensão para tensionar as respostas do algoritmo. Os relatos coletados demonstraram convergência em relação à estabilidade pedagógica da ferramenta. A avaliação do Professor P4, docente com maior tempo de atuação e menor fluência digital, aponta a eficiência da diretriz restritiva de respostas:

“Minha maior preocupação era a IA simplesmente dar a resposta pronta ou ensinar algum conceito errado. Mas, testando o aplicativo pronto, vi que o sistema de ‘travas’ realmente funciona. Ele não entrega o jogo, ele obriga o aluno a pensar, o que respeita o nosso método de sala de aula” (Professor P4).

Tabela 2 – Caracterização do Corpo Docente na Validação por Pares

ID	Escola	Formação Acadêmica	Docência	Fluência Digital
P1	Escola Estadual Vila Guaracy (Local de Aplicação) - Gurupi - TO	Licenciatura em Matemática	2 anos	Alta
P2	Escola Estadual Rui Barbosa - Gurupi - TO	Licenciatura + Especialização	8 anos	Média
P3	Escola Estadual Rui Barbosa - Gurupi - TO	Mestre em Ensino	15 anos	Média
P4	Escola Estadual Vila Guaracy (Local de Aplicação) - Gurupi - TO	Licenciatura em Matemática	22 anos	Baixa
P5	Colégio Militar do Estado do Tocantins (CMTO) - Araguaína	Licenciatura + Especialização	10 anos	Alta

Fonte: Dados da pesquisa (2026).

A capacidade do algoritmo de estruturar suportes graduais na Zona de Desenvolvimento Proximal foi identificada como um fator positivo. O Professor P1 corroborou a pertinência da personalização semântica executada pela máquina:

“A interface ficou muito intuitiva. O fato de o *MatemAI* ler o perfil do aluno e usar o interesse dele, como música ou futebol, para explicar uma soma de frações é algo que eu tento fazer no quadro com a turma toda, mas a ferramenta consegue fazer isso de forma instantânea e individual para cada um” (Professor P1).

A aderência técnica do software ao ambiente escolar também foi avaliada. O Professor P5 destacou que o “tempo de resposta do sistema é satisfatório e a navegação não apresenta barreiras, o que é essencial para o uso em laboratórios com tempo limitado”. Adicionalmente, o Professor P2 pontuou que “o layout é limpo e as instruções são diretas, facilitando a adesão imediata dos estudantes sem necessidade de longos tutoriais”.

A precisão dos conteúdos em face do currículo nacional foi evidenciada nas considerações do Professor P3, reforçando a eficácia do processamento interno (*Chain-of-Thought*):

“Como professor, eu temia as chamadas ‘alucinações’ da IA. No entanto, ao interagir com o software, percebi que aquela validação oculta garante que as habilidades exigidas pela BNCC sejam respeitadas rigorosamente, sem inventar regras matemáticas no meio do caminho” (Professor P3).


O balanço qualitativo das validações sugere a adequação funcional do *MatemAI* enquanto recurso de mediação complementar, posicionado como um instrumento alinhado e extensivo ao planejamento das rotinas pedagógicas do professor.

4.3.2 Telemetria de Engajamento e a Dinâmica do Fluxo

O desempenho do *design* de Gamificação Adaptativa (Deterding; Dixon; Khaled; Nacke, 2011) foi mensurado por meio da análise quantitativa de telemetria originada nas interações dos usuários. Diferindo do comportamento frequentemente observado no ensino presencial tradicional de disciplinas exatas, o sistema registrou um incremento progressivo no volume de submissões voluntárias realizadas pelos estudantes.

A Figura 15 apresenta a evolução da média acumulada de Pontos de Experiência (XP) ao longo do período de oito semanas de intervenção escolar.

Figura 15 – Curva de telemetria evidenciando a sustentação do engajamento voluntário.



Fonte: Logs da plataforma *MatemAI*.

O comportamento ascendente verificado na curva de XP, com crescimento expressivo a partir da quarta semana, sustenta a premissa de que a adequação em tempo real do nível das

atividades contribui ativamente para a mitigação de quadros de evasão (Niño-Rojas *et al.*, 2024). O mapeamento dos usuários em suas respectivas ZDP viabilizou a personalização da dificuldade imposta a perfis heterogêneos simultaneamente.

A modulação algorítmica permitiu a indução de um Estado de Fluxo contínuo, fornecendo indícios concretos de que o Sistema Tutor atende ao seu escopo primário de estruturação como um agente mediador adaptativo e tecnologicamente sustentável (Carvalho, 2025).

5 CONSIDERAÇÕES FINAIS

A pesquisa desenvolvida nesta dissertação atingiu seu objetivo principal: conceber e validar o *MatemAI* não estritamente como um software, mas como um ecossistema de personalização pedagógica fundamentado em Inteligência Artificial Generativa. As evidências empíricas coletadas indicam que a tecnologia, quando alicerçada em construtos teóricos consistentes — com destaque para a Teoria da Carga Cognitiva e a Zona de Desenvolvimento Proximal —, supera a condição de ferramenta passiva, atuando como agente mediador no processo de cognição matemática.

A arquitetura desenvolvida no *framework Streamlit* e integrada aos modelos do Google Gemini demonstrou ser uma solução escalável e de baixo custo marginal, adequada à realidade infraestrutural da escola pública brasileira. A implementação piloto viabilizou o acompanhamento simultâneo e individualizado dos 57 discentes da Escola Estadual Vila Guaracy, ampliando o alcance da tutoria para além das limitações operacionais inerentes ao modelo presencial tradicional.

A despeito dos resultados positivos observados nos indicadores de engajamento, a análise metodológica requer o reconhecimento de limitações práticas. Os entraves tecnológicos, caracterizados pela instabilidade de conectividade e pela disparidade de *hardware* entre os dispositivos móveis dos estudantes, configuram-se como desafios estruturais à implementação integral de soluções baseadas em computação em nuvem na rede pública. Adicionalmente, o delineamento transversal desta pesquisa viabilizou a mensuração de fatores motivacionais imediatos, contudo, não dispôs de amplitude temporal necessária para avaliar o impacto longitudinal da ferramenta sobre o desempenho discente em avaliações padronizadas de larga escala.

As limitações identificadas no escopo desta pesquisa orientam a formulação de estudos futuros, com especial ênfase no aprimoramento da gestão pedagógica. Aponta-se a necessidade de investigar o desenvolvimento de módulos de Analítica Preditiva Docente, concebidos para ultrapassar a etapa de coleta de dados descritivos. Espera-se que essas ferramentas processem a telemetria gerada no *MatemAI* para fornecer diagnósticos preditivos acerca do processo de aprendizagem.

O intuito principal consiste em estabelecer um sistema de monitoramento capaz de sinalizar ao educador, em tempo real, padrões de retenção cognitiva correlacionados ao risco de

desengajamento ou evasão. Portanto, investigações subsequentes devem priorizar a formulação de indicadores de desempenho representativos do avanço individual e coletivo, viabilizando intervenções pedagógicas direcionadas. Com a consolidação da integração entre inteligência artificial e rotinas docentes, projeta-se que o sistema funcione como um instrumento de apoio à tomada de decisão para o professor de Matemática.

Conclui-se, portanto, que a implementação do *MatemAI* não pressupõe a substituição da figura docente, mas propõe a otimização de seu tempo e esforço laboral. Ao transferir ao algoritmo a execução de correções procedimentais de rotina, possibilita-se ao educador priorizar a mediação pedagógica de maior complexidade e o acompanhamento individualizado. O presente trabalho corrobora a perspectiva de que a tecnologia, ao atuar como recurso de adaptação instrucional, possui potencial para atenuar o caráter histórico excludente da Matemática, favorecendo a equidade e a acessibilidade no ambiente escolar.

REFERÊNCIAS

- ANDERSON, J. R. **How can the human mind occur in the physical universe?** New York: Oxford University Press, 2007.
- ANDERSON, J. R.; CORBETT, A. T.; KOEDINGER, K. R.; PELLETIER, R. Cognitive tutors: Lessons learned. **The Journal of the Learning Sciences**, Taylor & Francis, v. 4, n. 2, p. 167–207, 1995.
- ANSARI, D. Effects of development and enculturation on number representation in the brain. **Nature Reviews Neuroscience**, Nature Publishing Group, v. 9, n. 4, p. 278–291, 2008.
- BACICH, L.; MORAN, J. **Metodologias Ativas para a Educação Básica**. Porto Alegre: Penso, 2018.
- BADDELEY, A. Working memory. **Science**, American Association for the Advancement of Science, v. 255, n. 5044, p. 556–559, 1992.
- BAKER, R. S.; INVENTADO, P. S. Educational data mining and learning analytics. **Learning Analytics: From Research to Practice**, Springer, p. 61–75, 2014.
- BARDIN, L. **Análise de Conteúdo**. São Paulo: Edições 70, 2016.
- BARTLE, R. Hearts, clubs, diamonds, spades: Players who suit muds. **Journal of MUD research**, v. 1, n. 1, p. 19, 1996.
- BLOOM, B. S. The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring. **Educational Researcher**, Sage Publications, v. 13, n. 6, p. 4–16, 1984.
- BOMMASANI, R.; HUDSON, D. A.; ADELI, E. *et al.* On the opportunities and risks of foundation models. **arXiv preprint arXiv:2108.07258**, 2021.
- BRASIL. **Resolução nº 510, de 07 de abril de 2016**. Brasília, DF: [s.n.], 2016. Conselho Nacional de Saúde. Diário Oficial da União. Dispõe sobre as normas aplicáveis a pesquisas em Ciências Humanas e Sociais. Disponível em: <<http://conselho.saude.gov.br/resolucoes/2016/Reso510.pdf>>. Acesso em: 24 nov. 2025.
- _____. **Base Nacional Comum Curricular (BNCC): Educação é a Base**. Brasília, DF, 2018. Disponível em: <<http://basenacionalcomum.mec.gov.br/>>. Acesso em: 23 nov. 2025.
- _____. **Estratégia Brasileira de Inteligência Artificial (EBIA)**. Brasília, DF, 2021. Disponível em: <<https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/transformacaodigital/inteligencia-artificial>>. Acesso em: 13 jan. 2026.
- BROWN, T. B. *et al.* Language models are few-shot learners. **Advances in Neural Information Processing Systems**, v. 33, p. 1877–1901, 2020.
- CARVALHO, E. G. **A Inteligência Artificial no Ensino da Matemática**: Possibilidades de aplicações nas turmas de ensino médio. Dissertação (Mestrado Profissional em Matemática) — Universidade Estadual do Sudoeste da Bahia (UESB), PROFMAT, Vitória da Conquista, 2025. Disponível em: <https://sca.profmtat-sbm.org.br/busca_tcc.php>. Acesso em: 21 jan. 2026.

CHANG, J. *et al.* A prompt pattern catalog to enhance prompt engineering with chatgpt. **arXiv preprint arXiv:2302.11382**, 2023.

CHEN, L.; CHEN, P.; LIN, Z. Artificial intelligence in education: A review. **IEEE Access**, IEEE, v. 8, p. 75264–75278, 2020.

COPE, B.; KALANTZIS, M. **Big Data in Education**: The digital future of learning, policy and practice. New York: Routledge, 2016.

CORBETT, A. T.; KOEDINGER, K. R.; ANDERSON, J. R. Intelligent tutoring systems. In: **Handbook of human-computer interaction**. [S.l.]: Elsevier, 1997. p. 849–874.

COTIČ, M.; DOZ, D.; JENKO, M.; ŽAKELJ, A. Mathematics education: What was it, what is it, and what will it be? **International Electronic Journal of Mathematics Education**, v. 19, n. 3, p. em0783, 2024.

CRESWELL, J. W. **Projeto de pesquisa**: método qualitativo, quantitativo e misto. 3. ed. Porto Alegre: Penso, 2014.

CSIKSZENTMIHALYI, M. **Flow**: The psychology of optimal experience. New York: Harper & Row, 1990.

DECI, E. L.; RYAN, R. M. The "what" and "why" of goal pursuits: Human needs and the self-determination of behavior. **Psychological Inquiry**, v. 11, n. 4, p. 227–268, 2000.

DEHAENE, S. **The number sense**: How the mind creates mathematics. New York: Oxford University Press, 1997.

_____. **How We Learn**: Why brains learn better than any machine... for now. London: Penguin Books, 2020.

DETERDING, S.; DIXON, D.; KHALED, R.; NACKE, L. From game design elements to gamefulness: Defining "gamification". In: **Proceedings of the 15th International Academic MindTrek Conference**. New York, NY, USA: ACM, 2011. p. 9–15.

DWECK, C. S. **Mindset**: A nova psicologia do sucesso. Rio de Janeiro: Objetiva, 2017.

FILATRO, A. **Design instrucional na prática**. São Paulo: Pearson Education do Brasil, 2008.

FRIEDER, S.; PINNA, L.; BERESKA, J.; KOCH, A. *et al.* Mathematical capabilities of chatgpt. **arXiv preprint arXiv:2301.13867**, 2023.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 7. ed. São Paulo: Atlas, 2019.

GOODFELLOW, I.; POUGET-ABADIE, J.; MIRZA, M. *et al.* Generative adversarial nets. In: **Advances in Neural Information Processing Systems (NIPS)**. [S.l.: s.n.], 2014. v. 27.

HAMARI, J.; KOIVISTO, J.; SARSA, H. Does gamification work? – a literature review of empirical studies on gamification. In: **30th Hawaii International Conference on System Sciences (HICSS)**. [S.l.]: IEEE, 2014. p. 3025–3036.

HOLMES, W.; BIALIK, M.; FADEL, C. **Artificial Intelligence in Education**: Promises and implications for teaching and learning. Boston, MA: Center for Curriculum Redesign, 2019.

KALYUGA, S.; AYRES, P.; CHANDLER, P.; SWELLER, J. The expertise reversal effect. **Educational Psychologist**, Taylor & Francis, v. 38, n. 1, p. 23–31, 2003.

KASNECI, E.; KESSLER, K.; BUZZA, R. *et al.* Chatgpt for good? on opportunities and challenges of large language models for education. **Learning and Individual Differences**, Elsevier, v. 103, p. 102274, 2023.

KERR, P. **Adaptive Learning**. Cambridge: Parthenon Press, 2016.

KOEDINGER, K. R.; BRUNSKILL, E.; BAKER, R. S. J. d. *et al.* New potentials for data-driven intelligent tutoring system development and optimization. **AI Magazine**, v. 34, n. 3, p. 27–41, 2013.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.

LUCKIN, R.; HOLMES, W.; GRIFFITHS, M.; FORCIER, L. B. **Intelligence Unleashed: An argument for ai in education**. London: Pearson, 2016.

MARQUES, A. P. **Panorama do uso de Inteligência Artificial no ensino de Matemática no Brasil**. Dissertação (Mestrado Profissional em Matemática) — Universidade Federal do Amapá (UNIFAP), PROFMAT, Macapá, 2020. Disponível em: <https://sca.profmtat-sbm.org.br/busca_tcc.php>. Acesso em: 21 nov. 2025.

MAYER, R. E. **The Cambridge handbook of multimedia learning**. 2. ed. Cambridge: Cambridge University Press, 2014.

MCCARTHY, J.; MINSKY, M. L.; ROCHESTER, N.; SHANNON, C. E. **A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence**. [S.l.], 1955. Disponível em: <<http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf>>. Acesso em: 21 nov. 2025.

MENESES, M. A. d. S. A. **A utilização do aplicativo "Matemáticas" no contexto da gamificação como proposta de ensino da matemática em uma turma do nono ano do ensino fundamental**. Dissertação (Mestrado Profissional em Matemática) — Universidade Federal Rural do Rio de Janeiro (UFRRJ), PROFMAT, Seropédica, 2025. Disponível em: <https://sca.profmtat-sbm.org.br/busca_tcc.php>. Acesso em: 21 jan. 2026.

MIAO, F.; HOLMES, W.; HUANG, R.; ZHANG, H. **AI and education: guidance for policy-makers**. Paris: UNESCO Publishing, 2021.

MORAES, R. d. S. **ChatGPT como um recurso no processo de ensino e aprendizagem da Matemática**. Dissertação (Mestrado Profissional em Matemática) — Universidade Federal do Tocantins (UFT), PROFMAT, Palmas, 2024. Disponível em: <https://sca.profmtat-sbm.org.br/busca_tcc.php>. Acesso em: 21 nov. 2025.

MORAN, J.; BACICH, L. **Metodologias Ativas para uma Educação Inovadora**. Porto Alegre: Penso, 2015.

NEWELL, A.; SIMON, H. A. The logic theory machine – a complex information processing system. **IRE Transactions on Information Theory**, IEEE, v. 2, n. 3, p. 61–79, 1956.

- NIÑO-ROJAS, F.; LANCHEROS-CUESTA, D.; JIMÉNEZ-VALDERRAMA, M. T. P.; MESTRE, G.; GÓMEZ, S. Systematic review: Trends in intelligent tutoring systems in mathematics teaching and learning. **International Journal of Education in Mathematics, Science, and Technology (IJEMST)**, v. 12, n. 1, p. 203–229, 2024.
- NKAMBOU, R.; MIZOGUCHI, R.; BOURDEAU, J. **Advances in Intelligent Tutoring Systems**. Berlin, Heidelberg: Springer, 2010.
- PAAS, F.; RENKL, A.; SWELLER, J. Cognitive load theory and instructional design: Recent developments. **Educational Psychologist**, Taylor & Francis, v. 38, n. 1, p. 1–4, 2003.
- PIECH, C.; BASSEN, J.; HUANG, J. *et al.* Deep knowledge tracing. In: **Advances in Neural Information Processing Systems (NIPS)**. [S.l.: s.n.], 2015. v. 28.
- REEVES, T. C. Design research from a technology perspective. **Educational Design Research**, Routledge, v. 1, n. 1, p. 52–66, 2006.
- ROMERO, C.; VENTURA, S. Educational data mining: A review of the state of the art. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, IEEE, v. 40, n. 6, p. 601–618, 2010.
- RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: A modern approach**. 4. ed. Hoboken: Pearson, 2020.
- SIEMENS, G.; DAWSON, S. Learning analytics: Envisioning a data-driven education system. **UNESCO Technology, Policy and Education**, UNESCO, Paris, 2013.
- SILVA, A. C. d. **Desafios e Possibilidades do Uso de Inteligência Artificial Generativa na Elaboração e Revisão de Itens de Matemática**. Dissertação (Mestrado Profissional em Matemática) — Universidade Federal do Oeste do Pará (UFOPA), PROFMAT, Santarém, 2023. Disponível em: <https://sca.profmtat-sbm.org.br/busca_tcc.php>. Acesso em: 21 dez. 2025.
- SILVA, B. E. S. d. **Inteligência Artificial na Educação: Uma abordagem comparativa das propostas dos governos por meio de análise documental**. Dissertação (Mestrado Profissional em Matemática) — Universidade do Estado do Amazonas (UEA), PROFMAT, Manaus, 2025. Disponível em: <https://sca.profmtat-sbm.org.br/busca_tcc.php>. Acesso em: 21 fev. 2026.
- SWELLER, J. Cognitive load during problem solving: Effects on learning. **Cognitive Science**, Wiley, v. 12, n. 2, p. 257–285, 1988.
- SWELLER, J.; MERRIENBOER, J. J. G. V.; PAAS, F. G. W. C. Cognitive architecture and instructional design. **Educational Psychology Review**, Springer, v. 10, n. 3, p. 251–296, 1998.
- TURING, A. M. Computing machinery and intelligence. **Mind**, Oxford University Press, v. 59, n. 236, p. 433–460, 1950.
- UNESCO. **Beijing Consensus on Artificial Intelligence and Education**. Paris: [s.n.], 2019. United Nations Educational, Scientific and Cultural Organization. Documento final da International Conference on Artificial Intelligence and Education.
- VANLEHN, K. The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. **Educational Psychologist**, Taylor & Francis, v. 46, n. 4, p. 197–221, 2011.

VASWANI, A.; SHAZEER, N.; PARMAR, N. *et al.* Attention is all you need. In: **Advances in Neural Information Processing Systems (NIPS)**. [S.l.: s.n.], 2017. v. 30.

VYGOTSKY, L. S. **Mind in Society**: The development of higher psychological processes. Cambridge, MA: Harvard University Press, 1978.

WEI, J.; TAY, Y.; BOMMASANI, R. *et al.* Emergent abilities of large language models. **Transactions on Machine Learning Research**, 2022.

WEI, J.; WANG, X.; SCHUURMANS, D. *et al.* Chain-of-thought prompting elicits reasoning in large language models. **Advances in Neural Information Processing Systems**, v. 35, p. 24824–24837, 2022.

WENGER, E. **Artificial intelligence and tutoring systems**: computational and cognitive approaches to the communication of knowledge. Los Altos, CA: Morgan Kaufmann, 1987.

WOOD, D.; BRUNER, J. S.; ROSS, G. The role of tutoring in problem solving. **Journal of Child Psychology and Psychiatry**, Wiley, v. 17, n. 2, p. 89–100, 1976.

ZAWACKI-RICHTER, O.; MARÍN, V. I.; BOND, M.; GOUVERNEUR, F. Systematic review of research on artificial intelligence applications in higher education – where are the educators? **International Journal of Educational Technology in Higher Education**, SpringerOpen, v. 16, n. 1, p. 1–27, 2019.

Apêndices

APÊNDICE A – QUESTIONÁRIO DE PESQUISA SOBRE MATEMÁTICA E NOVAS TECNOLOGIAS

Pesquisa sobre Matemática e Novas Tecnologias

Olá! Esta pesquisa é parte de um projeto de mestrado do PROFMAT/UFT. Queremos entender melhor sua opinião sobre matemática, jogos e tecnologia. Suas respostas são anônimas (seu nome não será usado) e muito importantes! Por favor, responda com honestidade.

* Indica uma pergunta obrigatória

1. Seção 1: Consentimento de Participação

*

Entendo que esta é uma pesquisa acadêmica voluntária e que **minha participação é totalmente gratuita, não havendo qualquer tipo de pagamento ou remuneração financeira envolvida.**

Estou ciente de que meus dados serão protegidos e anonimizados conforme determina a **LGPD (Lei nº 13.709/2018)**, sendo utilizados apenas para os objetivos deste estudo de Mestrado.

Marcar apenas uma oval.

☐ Sim, eu entendi e aceito participar.

Seção 2: Sobre Você

2. Nome: *

3. E-mail: *

4. Qual é a sua idade? *

Marcar apenas uma oval.

- ☐ 10 anos
- ☐ 11 anos
- ☐ 12 anos
- ☐ 13 anos
- ☐ 14 anos
- ☐ 15 anos
- ☐ 16 anos
- ☐ 17 anos
- ☐ 18 anos ou mais

5. Qual seu gênero? *

Marcar apenas uma oval.

- ☐ Masculino
- ☐ Feminino
- ☐ Prefiro não dizer
- ☐ Outro:

6. Qual o nome da sua escola? *

7. Qual desses equipamentos com acesso a internet você consegue utilizar no seu *
dia a dia?

Marque todas que se aplicam.

- ☐ celular
- ☐ Tablet
- ☐ Notebook
- ☐ Desktop - PC (Computador de mesa)
- ☐ Não possuo acesso a nenhum dispositivo com acesso a internet

Sua Relação com a MATEMÁTICA

8. O quanto você concorda ou discorda das frases abaixo? *

Marcar apenas uma oval por linha.

	Discordo Totalmente	Discordo	Neutro (Nem concordo, nem discordo)	Concordo	Concordo Totalmente
Eu gosto das aulas de matemática.	☐	☐	☐	☐	☐
Eu me considero bom(boa) em matemática.	☐	☐	☐	☐	☐
Eu acho a matemática divertida.	☐	☐	☐	☐	☐
Geralmente, eu acho a matemática chata e monótona.	☐	☐	☐	☐	☐
Eu fico nervoso(a) quando tenho que fazer uma prova de matemática.	☐	☐	☐	☐	☐
Acho fácil aprender novos assuntos de matemática.	☐	☐	☐	☐	☐

9. Com que frequência você joga (videogame, celular ou computador)? *

Marcar apenas uma oval.

- ☐ Quase todo dia
- ☐ Algumas vezes por semana
- ☐ Raramente (algumas vezes no mês)
- ☐ Quase nunca
- ☐ Não joga nenhum tipo de jogo digital

10. Quando você joga, o que você mais gosta de fazer? *

Marque todas que se aplicam.

- ☐ Competir com outros jogadores e vencer (subir no ranking).
- ☐ Completar 100% do jogo, colecionar recompensas, medalhas ou troféus.
- ☐ Explorar o mundo do jogo, descobrir segredos e acompanhar a história.
- ☐ Jogar junto com meus amigos e conversar com eles.
- ☐ Eu não costumo jogar.

11. Quanto você gasta por ano com jogos eletrônicos digitais?

Marcar apenas uma oval.

- ☐ Não gasto com jogos digitais
- ☐ Entre 0,01 e 50,00
- ☐ Entre 50,01 e 100,00
- ☐ Mais de 100,00
- ☐ Outro:

Sua Relação com TECNOLOGIA e I.A.

12. Você já usou uma Inteligência Artificial (como o ChatGPT, Gemini, Siri, Copilot, Duolingo ou outra) antes?

Marcar apenas uma oval.

- ☐ Sim, uso com frequência.
- ☐ Sim, já usei algumas vezes.
- ☐ Não, nunca usei.
- ☐ Não tenho certeza.

13. O quanto você concorda com as frases abaixo? *

Marcar apenas uma oval por linha.

	Discordo Totalmente	Discordo	Neutro	Concordo	Concordo Totalmente
Eu acho que um computador ou IA pode me ajudar a aprender coisas novas.	☐	☐	☐	☐	☐
Eu confio nas respostas que uma Inteligência Artificial dá para perguntas difíceis.	☐	☐	☐	☐	☐
Eu acho que usar IA para fazer uma lição de casa é uma forma de "trapaça".	☐	☐	☐	☐	☐
Eu gostaria de usar mais tecnologia nas aulas de matemática.	☐	☐	☐	☐	☐

14. Qual das Inteligências Artificiais - IAs você mais utiliza? *

Marque todas que se aplicam.

☐ Gemini

☐ Chat GPT

☐ Copilot

☐ Duolingo


☐ Siri

☐ Outro: _____


Este conteúdo não foi criado nem aprovado pelo Google.

Google Formulários


Seção 1: Consentimento de Participação Entendo que esta é uma pesquisa acadêmica voluntária e que minha participação é totalmente gratuita, não ...penas para os objetivos deste estudo de Mestrado.
57 respostas



Qual é a sua idade?
57 respostas




Qual seu gênero?
57 respostas




Qual o nome da sua escola?

57 respostas




Qual desses equipamentos com acesso a internet você consegue utilizar no seu dia a dia?

57 respostas




O quanto você concorda ou discorda das frases abaixo?




Com que frequência você joga (videogame, celular ou computador)?

57 respostas




Quando você joga, o que você mais gosta de fazer?

57 respostas




Quanto você gasta por ano com jogos eletrônicos digitais?

57 respostas




Você já usou uma Inteligência Artificial (como o ChatGPT, Gemini, Siri, Copilot, Duolingo ou outra) antes?

56 respostas




O quanto você concorda com as frases abaixo?



Qual das Inteligências Artificiais - IAs você mais utiliza?

57 respostas



APÊNDICE B – QUESTIONÁRIO DE ESCUTA ATIVA COM OS DOCENTES (VALIDAÇÃO POR PARES)

Este apêndice apresenta o roteiro de perguntas utilizado durante a fase de validação por pares do *MatemAI*. As questões foram elaboradas para avaliar a percepção docente quanto à segurança pedagógica, usabilidade e alinhamento curricular do sistema tutor inteligente.

1. **Segurança Pedagógica e Erros:** Durante a exploração livre, ao inserir erros propositais, como você avalia a reação da IA? O sistema consegue evitar a entrega direta da resposta e estimular o raciocínio clínico do aluno?
2. **Personalização e Engajamento:** Como você percebe a capacidade da ferramenta em converter os interesses pessoais dos alunos (perfilamento) em contextos para o ensino de frações e outros conteúdos matemáticos?
3. **Alinhamento Curricular:** Na sua percepção técnica, o sistema respeita as competências e habilidades previstas pela BNCC ou apresenta riscos de “alucinações” (geração de regras matemáticas incorretas)?
4. **Usabilidade e Interface:** Considerando o cotidiano da sala de aula, a interface do *MatemAI* é intuitiva o suficiente para ser utilizada por alunos com diferentes níveis de fluência digital sem a necessidade de intervenção constante do professor?
5. **Desempenho Técnico:** O tempo de resposta da plataforma e a estabilidade da navegação são compatíveis com o tempo disponível em uma aula regular no laboratório de informática?
6. **Papel do Professor:** Você percebe a ferramenta como um elemento que auxilia a mediação docente ou como algo que tenta substituir a explicação do professor?

APÊNDICE C – REGISTRO FOTOGRÁFICO DA APLICAÇÃO DO PRODUTO EDUCACIONAL


As figuras abaixo ilustram a fase de implementação do *MatemAI* com os estudantes da Escola Estadual Vila Guaracy. Os registros focam na interação com a interface gamificada e no engajamento durante a resolução das trilhas de aprendizagem.

Figura 16 – Estudantes em atividade prática no laboratório de informática.




Fonte: Autor (2025).

Figura 17 – Interação individualizada e navegação pelas trilhas do MatemAI.



Fonte: Autor (2025).

Figura 18 – Acompanhamento da evolução do perfil de aprendizagem (*Cold Start*).



Fonte: Autor (2025).

APÊNDICE D – DECLARAÇÃO SOBRE O USO DE INTELIGÊNCIA ARTIFICIAL

UNIVERSIDADE FEDERAL DO TOCANTINS – UFT PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO – PRPPG PROGRAMA DE MESTRADO PROFISSIONAL EM MATEMÁTICA EM REDE NACIONAL – PROFMAT

ANEXO I DECLARAÇÃO SOBRE O USO OU NÃO USO DE INTELIGÊNCIA ARTIFICIAL

Eu/Nós, **WESLEY NUNES DA SILVA**, responsável(is) pela obra **MATEMAI: INTELIGÊNCIA ARTIFICIAL E MACHINE LEARNING COMO MOTORES DA GAMIFICAÇÃO ADAPTATIVA NO ENSINO DE MATEMÁTICA**, declaro/declaramos que as informações prestadas refletem de forma verdadeira, transparente e completa o uso ou não uso de ferramentas de Inteligência Artificial (IA) generativa ou de qualquer outra natureza na concepção, análise ou redação desta produção. Declaro/declaramos assumir a responsabilidade integral por todo o conteúdo entregue, atestando o rigor metodológico e a honestidade intelectual da pesquisa, em estrita conformidade com a **Política de Integridade na Atividade Científica do CNPq (Portaria CNPq nº 2.664, de 6 de março de 2026)**.

SELECIONE UMA DAS OPÇÕES:

☐ NÃO HOUVE USO DE FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL

Declaro que não utilizei, em nenhuma etapa do desenvolvimento do presente trabalho, ferramentas de Inteligência Artificial, incluindo mas não se limitando a recursos de geração de texto, imagem, código, resumos, traduções ou análises. Assumo integral responsabilidade pelo conteúdo, conforme os princípios de integridade acadêmica e a legislação vigente.

(Se marcar esta opção, não é necessário preencher os campos 1 a 5 abaixo.)

☒ HOUVE USO DE FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL

(Preencher os campos obrigatórios abaixo.)

- Ferramenta(s) e versão(ões) predominante(s): Gemini 3.1 Pro (Google), Claude Code (Anthropic) e ChatGPT GO (OpenAI)
- Período de uso: Agosto de 2025 a Maio de 2026
- Finalidade(s) (marcar todas que se aplicam):
 - ☒ Exploração inicial de ideias
 - ☐ Busca/triagem de literatura
 - ☐ Leitura assistida/Resumos (com conferência humana)
 - ☒ Revisão linguística/Referências
 - ☒ Apoio reprodutível à análise/apresentação (restrito à geração automatizada e reprodutível de tabelas, gráficos, figuras ou visualizações a partir de dados previamente analisados e interpretados pelos autores, sem substituição da análise científica humana)
 - ☒ Programação (sugestão/depuração/documentação)
 - ☐ Transcrição (com anonimização): conversão literal, mediante autorização, de áudios ou vídeos em texto de entrevistas, aulas, reuniões ou palestras, com obrigatória revisão humana, anonimização e respeito aos direitos autorais, vedada a identificação de voz ou outros dados biométricos.
 - ☒ Tradução técnica (com revisão humana)
- Descrição sintética do uso / prompts-tipo: As ferramentas foram utilizadas como suporte técnico e redatorial em diferentes fases do projeto **MatemAI**. O **Claude Code** foi empregado na depuração e otimização de scripts em Python, bem como na estruturação de integrações com o Google Cloud Platform e Firebase. O **Gemini 3.1 Pro** e o **ChatGPT GO** auxiliaram na modelagem lógica da gamificação adaptativa voltada para alunos do 9º ano, na tradução técnica de documentação e na revisão sintática e gramatical do texto acadêmico, além de suporte na estruturação de tabelas e diagramas em LaTeX/Overleaf.
- Validação humana (checagens, testes, leitura crítica): Todo o código gerado foi rigorosamente testado, depurado e validado em ambiente de desenvolvimento, assegurando seu funcionamento na infraestrutura do projeto. As lógicas de gamificação e os conteúdos matemáticos foram revisados criticamente para garantir alinhamento pedagógico e adequação ao público-alvo do 9º ano. Todo o texto acadêmico gerado ou revisado por IA passou por leitura crítica contínua e validações periódicas em conjunto com a professora orientadora.

Declarações éticas (obrigatórias caso tenha havido uso de IA):

Todas as opções abaixo devem ser obrigatoriamente assinaladas para que o trabalho possa ser submetido à defesa/apresentação. O não preenchimento completo impedirá a continuidade do processo.

- ☒ Não houve geração de conteúdo original, ideias, interpretações ou análises pela IA;
- ☒ Não enviei dados inéditos ou sensíveis à serviços que utilizam conteúdos para treinamento de modelos, exceto em plataformas institucionais ou com garantias contratuais de confidencialidade e não retenção, assegurando conformidade com a LGPD (Lei nº 13.709/2018) e demais normas de proteção de dados;
- ☒ Respeitei direitos autorais, licenças, confidencialidade e políticas editoriais;
- ☒ Em transcrições, apliquei anonimização e não realizei identificação por voz/biometria;
- ☒ Assumo responsabilidade integral e exclusiva pelo conteúdo final desta obra.

Data: 18 de Maio de 2026

Nome(s) do(s) Autor(es): **Wesley Nunes da Silva**

Assinatura(s): _____

