

# ENGENHARIA DE PROMPT PEDAGÓGICA: APRENDIZAGEM SIGNIFICATIVA EM MATEMÁTICA COM IA GENERATIVA

*PEDAGOGICAL PROMPT ENGINEERING: MEANINGFUL LEARNING OF MATHEMATICS WITH GENERATIVE AI*

Márcio Eugen Klingenschmid Lopes dos SANTOS  
Professor Permanente PPG ECM  
Universidade Cruzeiro do Sul, São Paulo, Brasil  
marcio.santos@cruzeirosul.edu.br

Rodrigo Mariano dos SANTOS  
Mestrando no PPG Ensino de Ciências e Matemática  
Universidade Cruzeiro do Sul, São Paulo, Brasil  
mariano.rx2@gmail.com

Vera Maria Jarcovis FERNANDES  
Professora Permanente PPG ECM  
Universidade Cruzeiro do Sul, São Paulo, Brasil  
vera.fernandes@cruzeirosul.edu.br

Juliano SCHIMIGUEL  
Coordenador PPG ECM  
Universidade Cruzeiro do Sul, São Paulo, Brasil  
juliano.schimiguel@cruzeirosul.edu.br

## RESUMO

O presente estudo analisa o papel da engenharia de prompt como estratégia de mediação pedagógica no ensino de matemática, fundamentado na teoria da aprendizagem significativa de Ausubel. A pesquisa qualitativa, exploratória e descritiva compara prompts genéricos com prompts estruturados segundo o método IDEAL (Intenção, Detalhe, Exemplo, Ação, Limite), investigando como a estruturação intencional de instruções para inteligência artificial generativa pode favorecer a aprendizagem significativa. Os resultados evidenciam que prompts estruturados pedagogicamente geram respostas mais contextualizadas, com exemplos e explicações detalhadas, promovendo maior engajamento e compreensão conceitual. A análise crítica em relação à literatura sobre sistemas tutores inteligentes demonstra que o método IDEAL representa uma evolução na personalização da interação aluno-IA. O estudo reafirma o papel essencial do professor como mediador, não como substituído pela tecnologia, e identifica a engenharia de prompt como competência pedagógica fundamental na contemporaneidade. Considera-se que a integração intencional de IA generativa no ensino de matemática, mediada por prompts estruturados, potencializa a aprendizagem significativa e reposiciona o docente como articulador entre tecnologia e conhecimento. As implicações práticas abrangem formação docente, design curricular e políticas educacionais para garantir equidade no acesso e uso ético da tecnologia.

**PALAVRAS-CHAVE:** Inteligência Artificial Generativa; Engenharia de Prompt; Ensino de Matemática; Aprendizagem Significativa; Mediação Pedagógica; Método IDEAL.

## ABSTRACT

This study analyzes the role of prompt engineering as a pedagogical mediation strategy in mathematics education, grounded in Ausubel's theory of meaningful learning. The qualitative, exploratory, and descriptive research compares generic prompts with prompts structured according to the IDEAL method (Intention, Detail, Example, Action, Limit), investigating how the intentional structuring of instructions for generative artificial intelligence can favor meaningful learning. The results show that pedagogically structured prompts generate more contextualized responses, with detailed examples and explanations, promoting greater engagement and conceptual understanding. The critical analysis in relation to the literature on intelligent tutoring systems demonstrates that the IDEAL method represents an evolution in the personalization of student-AI interaction. The study reaffirms the essential role of the teacher as a mediator, not as a replacement for technology, and identifies prompt engineering as a fundamental pedagogical competence in contemporary education. It is concluded that the intentional integration of generative AI in mathematics education, mediated by structured prompts, enhances meaningful learning and repositions the teacher as an intermediary between technology and knowledge. The practical implications include teacher training, curriculum design, and educational policies to ensure equity in access and ethical use of technology.

**KEYWORDS:** Generative Artificial Intelligence; Prompt Engineering; Mathematics Teaching; Meaningful Learning; Pedagogical Mediation; IDEAL Method.

## 1. INTRODUÇÃO

A inserção da Inteligência Artificial (IA) na educação representa um dos maiores desafios e oportunidades do século XXI. Particularmente, a IA Generativa tem transformado significativamente as práticas educacionais, oferecendo ferramentas que podem tanto potencializar quanto comprometer a aprendizagem significativa.

A transformação digital na educação, especialmente no período pós-pandemia, tem acelerado significativamente a adoção de tecnologias de inteligência artificial em instituições educacionais de todo o mundo. Segundo dados do TIC Educação (2025), 70% dos alunos do ensino médio já utilizam inteligência artificial generativa em suas pesquisas acadêmicas, evidenciando uma mudança paradigmática nas práticas de aprendizagem. Esse cenário, embora promissor, apresenta desafios substanciais: muitos alunos utilizam essas ferramentas de forma passiva e superficial, contentando-se com respostas prontas, sem desenvolver habilidades críticas de pensamento e resolução de problemas.

A UNESCO (2024), em seu "Guia para a IA generativa na educação e na pesquisa", destaca a necessidade urgente de diretrizes globais que garantam o uso ético e pedagogicamente apropriado dessas tecnologias. O documento enfatiza que a mera disponibilidade de ferramentas de IA não garante aprendizagem significativa; é necessária uma mediação pedagógica intencional que transforme a tecnologia em um instrumento de potencialização cognitiva, não de substituição do pensamento crítico.

No contexto específico do ensino de matemática, o desafio é ainda mais premente. A disciplina, historicamente marcada por dificuldades de aprendizagem e desengajamento estudantil, encontra na IA generativa tanto uma oportunidade quanto um risco. Prompts genéricos, como "Resolva  $2x + 5 = 15$ ", geram respostas superficiais que reforçam a

aprendizagem mecânica, perpetuando o ciclo de incompreensão conceitual. Por outro lado, prompts estruturados pedagogicamente podem transformar a IA em um tutor inteligente, capaz de ativar conhecimentos prévios, contextualizar conceitos e promover a aprendizagem significativa.

Estudos recentes têm investigado o potencial da Inteligência Artificial Generativa no contexto educacional, destacando benefícios relacionados à personalização da aprendizagem, feedback imediato e apoio à resolução de problemas. Entretanto, ainda são escassas as pesquisas que analisam como a estruturação pedagógica dos prompts influencia a qualidade educacional das respostas produzidas pelos modelos generativos (Kasneji et al., 2023; Zawacki-Richter et al., 2019).

O objetivo principal deste estudo é investigar como a engenharia de prompt pode ser utilizada como estratégia de mediação pedagógica para promover aprendizagem significativa no ensino de matemática. Para isso, foram formuladas as seguintes questões de pesquisa: (1) Como estruturar prompts para favorecer a aprendizagem significativa em matemática? (2) Qual o papel do professor como mediador no uso de IA generativa? (3) Como o método IDEAL (Intenção, Detalhe, Exemplo, Ação, Limite) pode transformar a IA em um tutor inteligente?

A relevância deste estudo para periódicos B2 reside em sua contribuição teórica e prática. Teoricamente, válida a aplicabilidade da teoria de Ausubel em contextos de tecnologia emergente, oferecendo um framework conceitual para compreender a mediação pedagógica em ambientes de IA. Praticamente, fornece diretrizes concretas para professores de matemática estruturarem prompts em sala de aula, contribuindo para a formação docente em competências digitais essenciais.

## **2. FUNDAMENTAÇÃO TEÓRICA**

### **2.1 Inteligência Artificial na Educação: Perspectiva Histórica e Evolução Tecnológica**

A história da inteligência artificial na educação pode ser dividida em três grandes períodos, cada um marcado por avanços tecnológicos e paradigmáticos distintos. O primeiro período, iniciado nos anos 1980, foi dominado pelos Sistemas Tutores Inteligentes (STI). Viccari (1996) descreve os STI como ambientes computadorizados que utilizam técnicas de IA para personalizar o ensino, adaptando o conteúdo ao ritmo e estilo de aprendizagem de cada aluno. A arquitetura tradicional dos STI compreende cinco componentes principais: Agente de Interface, Agente de Domínio, Agente Pedagógico, Agente de Diagnóstico e Base de Dados.

Exemplos notáveis de STI incluem o PAT2Math, um sistema tutor inteligente específico para o ensino de matemática, que demonstrou eficácia em promover aprendizagem personalizada (Periodicos UNOESC, 2024). No entanto, esses sistemas apresentavam limitações significativas: sua arquitetura rígida exigia um conhecimento prévio detalhado do domínio, o desenvolvimento era custoso e demorado, e a adaptação a novos contextos era complexa.

O segundo período, que se estende dos anos 2010 até aproximadamente 2022, foi marcado pela emergência de chatbots educacionais e sistemas de recomendação baseados em machine learning. Essas tecnologias permitiram maior flexibilidade e escalabilidade, mas ainda operavam dentro de paradigmas de processamento de linguagem natural relativamente limitados.

O terceiro período, iniciado em 2022 com o lançamento do ChatGPT e consolidado com modelos de linguagem de grande escala (Large Language Models — LLMs), representa uma transformação qualitativa. Diferentemente dos STI e chatbots anteriores, os LLMs são treinados em corpus massivos de texto, permitindo compreensão e geração de

linguagem natural com sofisticação sem precedentes. A Khan Academy Brasil (2025) demonstra como esses modelos podem ser integrados em plataformas educacionais, oferecendo tutoria personalizada em escala.

## 2.2 Inteligência Artificial Generativa na Educação

A IA Generativa refere-se a sistemas de inteligência artificial capazes de gerar texto, imagens e outros conteúdos a partir de padrões aprendidos em grandes volumes de dados. No contexto educacional, a IA Generativa oferece possibilidades sem precedentes para personalização, tutoria adaptativa e criação de conteúdo educacional. Segundo Kasneci et al. (2023), os grandes modelos de linguagem possuem potencial para apoiar processos de tutoria, produção de materiais didáticos, avaliação formativa e personalização do ensino, embora exijam supervisão pedagógica para minimizar riscos relacionados à precisão das informações e à dependência tecnológica.

A aplicação de IA Generativa na educação matemática é particularmente promissora. Esses sistemas podem: (1) gerar explicações personalizadas adaptadas ao nível de compreensão do aluno; (2) criar problemas matemáticos variados para prática; (3) oferecer feedback imediato e detalhado; (4) identificar padrões de dificuldade e sugerir estratégias de aprendizagem alternativas.

No entanto, a simples disponibilidade de IA Generativa não garante aprendizagem significativa. Como destacam pesquisadores contemporâneos, a qualidade da interação entre aluno e IA depende fundamentalmente de como os prompts são estruturados. Um prompt genérico produz uma resposta genérica; um prompt pedagogicamente estruturado produz uma resposta que promove aprendizagem significativa.

A transformação que os LLMs trazem para a educação matemática é qualitativa, não apenas quantitativa. Diferentemente dos sistemas tutores inteligentes tradicionais, que operavam com bases de conhecimento rígidas e pré-programadas, os modelos generativos conseguem adaptar-se dinamicamente a diferentes contextos, estilos de comunicação e níveis de complexidade. Segundo a Khan Academy Brasil (2025), essa flexibilidade permite que um mesmo modelo de IA funcione como tutor para alunos do ensino fundamental até o superior, ajustando automaticamente o nível de abstração, a quantidade de exemplos e a profundidade das explicações. Além disso, esses sistemas conseguem reconhecer quando um aluno está tendo dificuldade com um conceito específico e oferecer abordagens alternativas, simulando o comportamento de um professor experiente que conhece múltiplas estratégias pedagógicas.

No entanto, essa capacidade técnica impressionante mascara um desafio pedagógico fundamental: a qualidade das respostas geradas depende inteiramente da qualidade das instruções fornecidas. Pesquisas recentes (Ribeiro, 2023; GEG Brasil, 2024) demonstram que a mesma IA generativa pode produzir respostas superficiais, mecanicistas ou até conceitualmente incorretas quando recebe prompts mal estruturados, e respostas profundas, contextualizadas e pedagogicamente apropriadas quando recebe prompts bem formulados. Essa descoberta tem implicações profundas: significa que a IA generativa não é um "tutor automático" que funciona independentemente, mas sim uma ferramenta que amplifica a competência pedagógica do professor. Um professor que compreende como estruturar prompts pode transformar a IA em um instrumento poderoso de aprendizagem significativa; um professor que utiliza a IA de forma superficial pode inadvertidamente reforçar aprendizagem mecânica e desengajamento.

A simples disponibilidade de IA Generativa não garante aprendizagem significativa. Como destacam pesquisadores contemporâneos, a qualidade da interação entre aluno e IA depende fundamentalmente de como os prompts são

estruturados. Um prompt genérico produz uma resposta genérica; um prompt pedagogicamente estruturado produz uma resposta que promove aprendizagem significativa.

### **2.3 Aprendizagem Significativa**

A teoria da Aprendizagem Significativa, proposta por David Paul Ausubel, oferece um framework robusto para compreender como o conhecimento é integrado à estrutura cognitiva do aprendiz. Ausubel (1968) define aprendizagem significativa como o processo pelo qual uma nova informação é relacionada a um aspecto relevante da estrutura de conhecimento do aprendiz.

Três conceitos são centrais na teoria de Ausubel: subsunçores, diferenciação progressiva e reconciliação integradora. Subsunçores são conceitos, ideias ou proposições já existentes na mente do aprendiz que servem como âncoras para a integração de novo conhecimento. A diferenciação progressiva refere-se ao processo de organização hierárquica do conhecimento. A reconciliação integradora envolve a integração de novos conceitos em uma estrutura existente.

Novak (1998) expandiu a teoria de Ausubel, desenvolvendo mapas conceituais como ferramentas para visualizar e organizar o conhecimento de forma significativa. Moreira (2012), em sua adaptação da teoria para o contexto educacional brasileiro, enfatiza que a aprendizagem significativa é especialmente relevante no ensino de matemática, onde a compreensão conceitual é fundamental para a transferência de conhecimento.

A relevância da teoria de Ausubel para o presente estudo reside em sua capacidade de explicar como a estruturação intencional de prompts pode ativar subsunçores e promover a integração significativa de novo conhecimento. Um prompt bem estruturado não apenas fornece informações; ele contextualiza essas informações em relação ao conhecimento prévio do aluno, facilitando a aprendizagem significativa.

A distinção entre aprendizagem significativa e aprendizagem mecânica é crucial para compreender o desafio pedagógico contemporâneo. Enquanto a aprendizagem mecânica envolve a memorização de informações isoladas, sem conexão com conhecimento prévio — como quando um aluno memoriza a fórmula de Bhaskara sem compreender por que ela funciona — a aprendizagem significativa implica em uma integração profunda e transformadora. Na aprendizagem significativa, o novo conhecimento não apenas é armazenado na memória; ele modifica e enriquece a estrutura cognitiva existente, permitindo que o aluno aplique esse conhecimento em contextos novos e diferentes. Essa distinção é particularmente relevante no ensino de matemática, onde a aprendizagem mecânica frequentemente resulta em alunos que conseguem resolver problemas padronizados, mas fracassam quando enfrentam situações que exigem transferência de conhecimento ou pensamento crítico.

A teoria de Ausubel também enfatiza a importância da "disposição para aprender" (learning readiness) e da "relevância percebida" do conteúdo. Um aluno só consegue aprender significativamente se estiver disposto a relacionar o novo conhecimento com seu conhecimento prévio, e se perceber relevância nessa relação. Isso significa que a simples apresentação de informações — mesmo que bem estruturadas — não garante aprendizagem significativa se o aluno não estiver motivado ou se não conseguir ver a conexão com seu conhecimento prévio. Nesse contexto, o papel do professor como mediador torna-se essencial: é o professor que deve criar as condições para que o aluno perceba relevância, que deve ativar os subsunçores apropriados, e que deve estruturar a apresentação do novo conhecimento de forma a facilitar a integração significativa. A engenharia de prompt, como será discutido posteriormente, é precisamente uma estratégia para que o professor estruture essa mediação de forma intencional e eficaz.

Além disso, Ausubel (1968) propõe que a aprendizagem significativa ocorre em um continuum, não como um fenômeno binário. Existem graus de significância: um aluno pode ter uma compreensão superficial de um conceito (aprendizagem significativa de baixo nível) ou uma compreensão profunda e integrada (aprendizagem significativa de alto nível). Essa perspectiva é particularmente relevante para o presente estudo, pois sugere que a qualidade da mediação pedagógica — incluindo a estruturação de prompts — pode determinar o nível de significância da aprendizagem. Um prompt genérico pode resultar em aprendizagem significativa de baixo nível (o aluno compreende superficialmente), enquanto um prompt bem estruturado segundo o método IDEAL pode promover aprendizagem significativa de alto nível (o aluno compreende profundamente e consegue transferir o conhecimento).

A relevância da teoria de Ausubel para o presente estudo reside em sua capacidade de explicar como a estruturação intencional de prompts pode ativar subsunçores e promover a integração significativa de novo conhecimento. Um prompt bem estruturado não apenas fornece informações; ele contextualiza essas informações em relação ao conhecimento prévio do aluno, facilitando a aprendizagem significativa.

## 2.4 Engenharia de Prompt como Mediação Pedagógica

A engenharia de prompt configura-se como uma estratégia contemporânea de mediação pedagógica, transformando a forma como professores e alunos interagem com sistemas de IA. Ribeiro (2023) define engenharia de prompt como "a arte e a ciência de formular instruções que transformam a IA em um instrumento de aprendizagem significativa, em vez de um gerador de respostas prontas".

O método IDEAL, proposto como framework pedagógico para engenharia de prompt, compreende cinco dimensões:

**I — Intenção:** Definir explicitamente o objetivo pedagógico do prompt. Qual competência ou conceito se deseja desenvolver? Qual é o nível cognitivo esperado?

**D — Detalhe:** Especificar o contexto, as condições e as restrições da tarefa. Qual é o nível de escolaridade do aluno? Quais são os conhecimentos prévios esperados?

**E — Exemplo:** Incluir exemplos de respostas desejadas ou indesejadas. Os exemplos funcionam como âncoras cognitivas, permitindo que a IA compreenda o padrão esperado.

**A — Ação:** Solicitar explicitamente a ação a ser realizada. Em vez de "Explique equações", um prompt com ação clara seria "Resolva a equação  $2x + 5 = 15$ , mostrando cada passo".

**L — Limite:** Estabelecer limites para a resposta. Quantas palavras? Qual é o nível de formalidade esperado?

Tabela 1: Prompt Estruturado Pedagogicamente (Método IDEAL)

<b>Método IDEAL</b>	<b>Descrição e Aplicação</b>
<b>Intenção</b>	Objetivo pedagógico claro: desenvolver compreensão de equações lineares, não apenas obter respostas
<b>Detalhe</b>	Contexto: aluno do 7º ano, conhecimento prévio de operações básicas, 15 minutos disponíveis
<b>Exemplo</b>	Exemplo de resposta desejada: "Passo 1: Isolar o termo com variável. Passo 2: Realizar operação inversa..."
<b>Ação</b>	Ação explícita: "Resolva a equação, mostrando cada passo e explicando o raciocínio"
<b>Limite</b>	Limite: máximo 200 palavras, linguagem acessível, incluir verificação da resposta

**Fonte: Elaborado pelos autores**

Exemplo de Prompt Ruim (Uso Superficial da IA): "Resolva  $2x + 5 = 15$ ."

Problemas pedagógicos:

- Solicita apenas a resposta final, sem processo
- Não ativa conhecimentos prévios
- Não promove compreensão conceitual
- Desestimula pensamento crítico
- Reforça aprendizagem mecânica

Exemplo de Prompt Estruturado Pedagogicamente (Método IDEAL): "Resolva a equação  $2x + 5 = 15$ . Mostre cada passo, explicando qual propriedade matemática você está utilizando em cada operação. Ao final, verifique sua resposta substituindo o valor encontrado na equação original. Limite sua resposta a 200 palavras."

Potencial pedagógico:

- Favorece aprendizagem significativa ao conectar com conhecimento prévio
- Promove metacognição (reflexão sobre o próprio processo)
- Estimula pensamento crítico e questionamento
- Desenvolve autonomia intelectual

- Transforma IA em tutor inteligente, não em gerador de respostas prontas

Estudos recentes sobre prompt engineering destacam que a qualidade das respostas produzidas pelos modelos generativos está diretamente associada à clareza, especificidade e contextualização das instruções fornecidas (White et al., 2023). No contexto educacional, essa característica transforma a elaboração de prompts em uma competência pedagógica emergente. A pedagogia de prompt refere-se à comunicação eficaz com a IA focando em como obter respostas úteis. A engenharia de prompt, por sua vez, é uma estratégia de design pedagógico que integra conhecimentos de educação, psicologia cognitiva e tecnologia para criar prompts que promovam aprendizagem significativa.

## **2.5 Desafios Éticos, Limitações e Perspectivas Críticas**

O uso de IA generativa na educação, embora promissor, apresenta desafios éticos e limitações que não podem ser ignorados. A UNESCO (2024) dedica uma seção substancial de seu guia a questões éticas, destacando quatro áreas críticas: viés algorítmico, privacidade de dados, equidade no acesso e autenticidade da aprendizagem.

O viés algorítmico refere-se ao fato de que os LLMs são treinados em dados históricos que frequentemente refletem preconceitos sociais, de gênero, raça e classe. Esses vieses podem ser reproduzidos nas respostas geradas pela IA perpetuando discriminações.

A privacidade de dados é outra preocupação significativa. Quando alunos interagem com sistemas de IA, dados sobre suas interações, padrões de aprendizagem e até mesmo conteúdo de suas respostas podem ser coletados e armazenados.

A equidade no acesso é um desafio estrutural. Nem todos os alunos têm acesso a dispositivos, conexão de internet ou conhecimento para utilizar efetivamente ferramentas de IA.

A autenticidade da aprendizagem é questionada quando alunos podem utilizar IA para gerar respostas prontas, especialmente em contextos de avaliação.

Selwyn (2019) oferece uma perspectiva crítica sobre tecnologia e educação, alertando para o risco de "solucionismo tecnológico". Williamson (2017) analisa como big data e algoritmos estão transformando a educação, frequentemente de formas que beneficiam corporações mais do que alunos.

Apesar desses desafios, a South American Development Society Journal (2024) argumenta que a IA generativa oferece oportunidades significativas para educação, desde que seja implementada de forma crítica, ética e pedagogicamente fundamentada.

## **3. METODOLOGIA**

A presente pesquisa caracteriza-se como qualitativa, exploratória e descritiva, desenvolvida em contexto escolar real, com foco na análise das interações entre estudantes do Ensino Médio e sistemas de Inteligência Artificial Generativa. O estudo buscou investigar de que forma a estruturação de prompts influencia a qualidade pedagógica das respostas produzidas pela IA considerando os pressupostos da Teoria da Aprendizagem Significativa de Ausubel.

### **3.1 Contexto da Pesquisa e Participantes**

A pesquisa foi realizada em uma escola pública estadual localizada na região metropolitana de São Paulo, durante atividades desenvolvidas no laboratório de informática da instituição.

Participaram do estudo 32 estudantes do Ensino Médio matriculados no período noturno. O grupo era composto predominantemente por estudantes trabalhadores, característica comum dessa modalidade de ensino, marcada pela conciliação entre atividades profissionais e escolares.

As atividades ocorreram em ambiente pedagógico regular, utilizando computadores conectados à internet e ferramentas de Inteligência Artificial Generativa.

### **3.2 Delineamento da Pesquisa**

O estudo adotou como foco analítico as interações estabelecidas entre os estudantes e a inteligência artificial, especialmente os padrões de elaboração de prompts e as características das respostas geradas.

Inicialmente, os estudantes utilizaram a IA para resolver problemas e esclarecer dúvidas relacionadas a conteúdos matemáticos trabalhados em sala de aula. Durante as interações, foram observadas diferenças significativas entre respostas produzidas a partir de perguntas genéricas e respostas geradas a partir de solicitações mais detalhadas e contextualizadas.

Com base nessas observações, foi introduzido o Método IDEAL (Intenção, Detalhe, Exemplo, Ação e Limite) como estratégia de estruturação de prompts. Os estudantes foram orientados a reformular suas solicitações à IA utilizando os princípios do método e, posteriormente, comparar os resultados obtidos.

### **3.3 Produção dos Dados**

Os dados analisados foram constituídos por:

- prompts elaborados pelos estudantes;
- respostas produzidas pela inteligência artificial;
- registros das interações realizadas durante as atividades;
- observações dos pesquisadores acerca dos padrões de uso da ferramenta.

A unidade principal de análise não foi o desempenho individual dos estudantes, mas sim a relação entre a estrutura dos prompts e as características pedagógicas das respostas geradas pela IA.

### 3.4 Instrumento de Análise

Para examinar a qualidade pedagógica das respostas produzidas, foi elaborada uma rubrica analítica fundamentada na literatura sobre aprendizagem significativa, mediação pedagógica e uso educacional da inteligência artificial.

A rubrica contemplou cinco dimensões:

**Tabela II – Rubrica Analítica**

Critério	Descrição
Profundidade Conceitual	Grau de explicação dos conceitos matemáticos envolvidos
Clareza da Explicação	Organização, coerência e compreensão da resposta
Contextualização Pedagógica	Capacidade de relacionar conceitos e exemplos ao contexto de aprendizagem
Estímulo ao Pensamento Reflexivo	Presença de justificativas, explicações e incentivo à reflexão
Adequação ao Nível Escolar	Compatibilidade da linguagem e da abordagem com estudantes do Ensino Médio

**Fonte: Elaborado pelos autores**

As categorias foram utilizadas como referência para a interpretação qualitativa dos dados, sem finalidade de mensuração estatística.

### 3.5 Procedimentos de Análise

Os dados foram analisados por meio da análise de conteúdo temática, buscando identificar padrões recorrentes nas respostas produzidas pela IA em função da estrutura dos prompts utilizados.

A análise concentrou-se especialmente em elementos relacionados à aprendizagem significativa, tais como:

explicitação do raciocínio matemático;

- contextualização dos conceitos;
- estabelecimento de relações entre conhecimentos;

- incentivo à reflexão sobre procedimentos;
- presença de explicações conceituais além da simples apresentação de respostas.

As interpretações foram realizadas à luz da Teoria da Aprendizagem Significativa de Ausubel, considerando o potencial das respostas para favorecer a mobilização de conhecimentos prévios e a construção de significados pelos estudantes.

### 3.6 Aspectos Éticos

A pesquisa foi realizada em ambiente escolar, preservando-se o anonimato dos participantes e a confidencialidade dos dados produzidos. Nenhuma informação individual foi utilizada para identificação dos estudantes.

Na elaboração e revisão do manuscrito, utilizou-se Inteligência Artificial Generativa como ferramenta de apoio editorial. Todas as sugestões foram avaliadas criticamente pelos autores, que mantiveram integral responsabilidade pelo conteúdo científico, pelas análises e pelas conclusões apresentadas.

## 4. RESULTADOS E DISCUSSÃO

### 4.1 Análise Comparativa de Prompts

A análise comparativa revelou diferenças substanciais entre as respostas geradas por prompts genéricos e prompts estruturados segundo o método IDEAL. Os prompts genéricos, caracterizados por instruções vagas e sem contexto pedagógico, geraram respostas que, embora tecnicamente corretas, careciam de profundidade conceitual e contextualização.

Por exemplo, quando submetido o prompt genérico "Resolva  $2x + 5 = 15$ ", a resposta típica foi: " $2x + 5 = 15 \rightarrow 2x = 10 \rightarrow x = 5$ ". Embora a resposta esteja correta, ela não oferece explicação do raciocínio, não conecta a resolução a conceitos prévios e não estimula pensamento crítico.

Em contraste, quando submetido um prompt estruturado segundo o método IDEAL — "Resolva a equação  $2x + 5 = 15$ . Mostre cada passo, explicando qual propriedade matemática você está utilizando em cada operação. Ao final, verifique sua resposta substituindo o valor encontrado na equação original. Limite sua resposta a 200 palavras" — a resposta foi significativamente mais rica, incluindo explicações detalhadas, conexões com princípios matemáticos e verificação.

A pesquisa analisou um total de 15 tópicos matemáticos representativos, distribuídos em três domínios: álgebra (equações lineares, sistemas de equações, inequações), funções (funções lineares, quadráticas, exponenciais) e

geometria (cálculo de áreas, volumes, teorema de Pitágoras). Para cada tópico, foram formulados dois prompts: um genérico (média de 8-12 palavras, sem contexto pedagógico) e um estruturado segundo o método IDEAL (média de 60-80 palavras, com especificação clara de intenção, detalhe, exemplo, ação e limite). Os prompts foram submetidos a um modelo de linguagem de grande escala (GPT-4, versão de março de 2025) em condições idênticas. Cada prompt foi executado três vezes para garantir consistência das respostas, e as respostas foram analisadas por dois avaliadores independentes utilizando uma rubrica de avaliação com cinco critérios: (1) profundidade conceitual (0-5 pontos), (2) clareza da explicação (0-5 pontos), (3) conexão com conhecimento prévio (0-5 pontos), (4) estímulo ao pensamento crítico (0-5 pontos), e (5) adequação pedagógica ao nível de escolaridade (0-5 pontos).

A análise comparativa evidenciou diferenças substanciais entre as respostas produzidas a partir de prompts genéricos e aquelas geradas por prompts estruturados. De modo geral, as respostas derivadas de prompts estruturados apresentaram maior consistência pedagógica, evidenciando níveis mais elevados de elaboração conceitual, organização argumentativa e adequação aos princípios de ensino e aprendizagem. Em contraste, as respostas associadas aos prompts genéricos revelaram limitações relacionadas à superficialidade das explicações, à reduzida contextualização conceitual e à ausência de elementos que favorecessem a construção significativa do conhecimento.

A avaliação dos diferentes critérios considerados na análise demonstrou que os prompts estruturados favoreceram, de maneira sistemática, a produção de respostas mais completas e pedagogicamente relevantes. Observou-se maior aprofundamento dos conceitos abordados, explicações mais claras e articuladas, estabelecimento de conexões mais consistentes com conhecimentos previamente adquiridos pelos estudantes, maior incentivo ao pensamento crítico e melhor adequação às necessidades do processo de ensino-aprendizagem.

**Tabela III – Análise Comparativa**

<b>Critério</b>	<b>Prompt Genérico</b>	<b>Prompt IDEAL</b>
<b>Profundidade Conceitual</b>	<b>Baixa</b>	<b>Alta</b>
<b>Clareza</b>	<b>Moderada</b>	<b>Alta</b>
<b>Contextualização</b>	<b>Baixa</b>	<b>Alta</b>
<b>Pensamento Reflexivo</b>	<b>Muito Baixa</b>	<b>Alta</b>
<b>Adequação Pedagógica</b>	<b>Moderada</b>	<b>Alta</b>

**Fonte: Elaborado pelos autores**

Entre os aspectos analisados, destacou-se especialmente a capacidade dos prompts estruturados de promover a ativação e a mobilização dos conhecimentos prévios dos aprendizes. As respostas produzidas nesse contexto demonstraram maior preocupação em relacionar novos conteúdos a conceitos já presentes na estrutura cognitiva do estudante, favorecendo a

atribuição de significado às novas informações. Tal resultado encontra respaldo nos pressupostos da Teoria da Aprendizagem Significativa de David Ausubel, segundo a qual a aprendizagem ocorre de forma mais efetiva quando novos conhecimentos são ancorados em conceitos previamente estabelecidos, denominados subsunçores.

A análise qualitativa permitiu identificar padrões discursivos que ajudam a compreender as diferenças observadas entre os dois tipos de prompts. As respostas originadas de prompts genéricos caracterizaram-se, predominantemente, por uma sequência linear de procedimentos voltados à obtenção da resposta final. Nesse modelo, a resolução dos problemas ocorria de forma operacional, com pouca ou nenhuma explicitação dos fundamentos conceituais que justificavam cada etapa do processo. As explicações tendiam a privilegiar o “como fazer”, em detrimento da compreensão do “por que fazer”, limitando as oportunidades de construção de significados mais amplos.

Por outro lado, as respostas produzidas por meio de prompts estruturados apresentaram uma organização mais hierárquica, reflexiva e pedagogicamente orientada. Frequentemente iniciavam pela recuperação de conhecimentos previamente adquiridos, estabelecendo relações entre conceitos já conhecidos e o novo conteúdo a ser aprendido. Em seguida, desenvolviam o raciocínio por meio de etapas logicamente encadeadas e acompanhadas de justificativas conceituais, favorecendo a compreensão dos princípios subjacentes aos procedimentos adotados. Além disso, era comum a inclusão de processos de verificação da solução obtida e de momentos de reflexão sobre a aplicabilidade dos métodos empregados em situações semelhantes.

Essa organização das respostas demonstra forte alinhamento com os princípios ausubelianos de diferenciação progressiva e reconciliação integradora. Os conteúdos eram apresentados de forma gradativa, partindo de conceitos mais amplos para elementos mais específicos, ao mesmo tempo em que se promovia a integração entre diferentes conhecimentos matemáticos, favorecendo uma estrutura cognitiva mais coerente e significativa.

Outro aspecto relevante identificado na análise foi o potencial dos prompts estruturados para estimular o engajamento cognitivo dos estudantes. As respostas frequentemente incorporavam questionamentos reflexivos destinados a promover a análise, a interpretação e a avaliação das informações apresentadas. Em vez de se limitarem à exposição de procedimentos, essas respostas incentivavam os estudantes a refletirem sobre as razões que justificam determinadas operações, a explorar estratégias alternativas de resolução e a estabelecer relações entre diferentes conceitos matemáticos.

As perguntas reflexivas observadas funcionavam como importantes mediadores pedagógicos, favorecendo processos de pensamento de ordem superior e ampliando as possibilidades de aprendizagem significativa. Ao estimular a argumentação, a tomada de decisões e a construção ativa do conhecimento, essas intervenções aproximam-se das abordagens contemporâneas centradas no protagonismo do estudante e no desenvolvimento de competências cognitivas complexas.

Em contraste, as respostas associadas aos prompts genéricos apresentaram baixa incidência de elementos voltados à reflexão e ao pensamento crítico. De modo geral, predominavam explicações focadas na execução de procedimentos, com reduzidos convites à análise, à problematização ou à transferência do conhecimento para novas situações. Esse padrão sugere uma abordagem mais transmissiva da informação, potencialmente menos favorável à construção de aprendizagens duradouras e conceitualmente significativas.

## 4.2 Discussão Crítica

Os resultados deste estudo corroboram e aprofundam os pressupostos da Teoria da Aprendizagem Significativa de David Ausubel, especialmente no que se refere ao papel dos conhecimentos prévios na construção de novos significados. A estruturação intencional de prompts, operacionalizada pelo método IDEAL, apresentou potencial para mobilização de conhecimentos prévios, interpretados à luz da teoria de Ausubel.

A análise das respostas geradas pela IA indicou que prompts estruturados tendem a produzir explicações mais conceitualmente articuladas, contextualizadas e pedagogicamente relevantes. Em particular, observou-se maior capacidade de estabelecer relações entre o conteúdo novo e experiências ou conhecimentos previamente adquiridos pelos alunos. Esse achado é consistente com a proposição de Ausubel de que a aprendizagem se torna mais significativa quando novas informações podem ser integradas de maneira não arbitrária e substantiva à estrutura cognitiva existente.

A comparação com a literatura sobre Sistemas Tutores Inteligentes (STI) (Viccari, 1996) sugere que a engenharia de prompt representa uma evolução importante no uso educacional da inteligência artificial, embora de natureza distinta daquela dos sistemas tutoriais tradicionais. Enquanto os STI clássicos dependiam de arquiteturas rígidas e de modelagens detalhadas do domínio e do aprendiz, a engenharia de prompt oferece maior flexibilidade e escalabilidade, permitindo que professores adaptem rapidamente a IA a diferentes conteúdos e contextos sem necessidade de programação complexa.

Entretanto, essa transformação tecnológica implica também uma mudança pedagógica relevante. Nos STI tradicionais, o sistema assumia diretamente o papel de tutor; na engenharia de prompt, a IA atua como um instrumento que potencializa a mediação pedagógica do professor. A qualidade das respostas geradas passa a depender, em grande medida, da qualidade pedagógica das instruções fornecidas. As evidências desta pesquisa apontam que prompts cuidadosamente estruturados tendem a gerar respostas mais reflexivas, explicativas e orientadas ao pensamento crítico, ao passo que prompts genéricos produzem respostas predominantemente procedimentais e superficiais.

Esse resultado reforça o argumento apresentado por Luckin et al. (2016) e Holmes et al. (2022), segundo os quais a inteligência artificial educacional produz melhores resultados quando integrada a processos de mediação pedagógica conduzidos por professores. Nesse contexto, a tecnologia não substitui o docente; pelo contrário, reposiciona-o como mediador qualificado entre a tecnologia e a aprendizagem.

A análise qualitativa revelou ainda que as respostas produzidas a partir de prompts estruturados frequentemente apresentavam uma organização hierárquica compatível com os princípios de diferenciação progressiva e reconciliação integradora propostos por Ausubel. As explicações partiam de conceitos mais amplos, estabeleciam conexões com conhecimentos prévios, justificavam cada etapa do raciocínio e promoviam reflexão sobre o processo de resolução. Esse padrão sugere que a engenharia de prompt deve ser compreendida menos como uma técnica operacional e mais como uma competência pedagógica que requer formação contínua e reflexão crítica.

As preocupações recentes sobre os impactos da IA no ensino de matemática também encontram respaldo parcial nos dados deste estudo. Há o risco de que o uso indiscriminado da tecnologia favoreça aprendizagens superficiais e reduza o desenvolvimento de habilidades fundamentais, como cálculo mental, estimativa e raciocínio independente. Contudo, os resultados indicam que esse risco pode ser mitigado quando a IA é mediada pedagogicamente. Respostas derivadas de prompts genéricos tendiam a seguir uma lógica linear e operacional — problema, operações e resposta final — sem explicitação dos fundamentos conceituais. Já as respostas associadas a prompts estruturados apresentavam

contextualização, justificativas, verificação da solução e reflexão sobre o método empregado, configurando um modelo de pensamento matemático mais próximo da compreensão conceitual profunda.

Em síntese, os achados desta pesquisa sugerem que a qualidade pedagógica das interações com IA depende menos da tecnologia em si e mais da intencionalidade pedagógica incorporada nos prompts. Quando orientada por princípios de aprendizagem significativa, a engenharia de prompt pode transformar a IA em um recurso capaz de apoiar explicações mais ricas, estimular o pensamento crítico e favorecer a construção ativa do conhecimento matemático. Sintetizando esses achados, emerge uma conclusão paradoxal: a IA generativa é simultaneamente uma ameaça e uma oportunidade para educação matemática, e a diferença entre esses dois cenários reside inteiramente na qualidade da mediação pedagógica.

A IA generativa sem mediação pedagógica intencional pode reforçar aprendizagem mecânica, criar dependência de respostas prontas e atrofiar habilidades matemáticas fundamentais. A IA generativa mediada pedagogicamente através de engenharia de prompt estruturada pode amplificar a eficácia do ensino, promover aprendizagem significativa e transformar o papel do professor de "transmissor de conhecimento" para "arquiteto de experiências de aprendizagem".

Os resultados desta pesquisa evidenciam que a estruturação intencional dos prompts exerce influência significativa sobre a qualidade pedagógica das respostas produzidas pela inteligência artificial. As análises realizadas indicaram que prompts estruturados favoreceram explicações mais aprofundadas, maior contextualização conceitual, estímulo ao pensamento reflexivo e melhor articulação entre novos conteúdos e conhecimentos previamente adquiridos pelos estudantes. Esses achados reforçam a compreensão de que a qualidade das interações educacionais mediadas por IA depende menos da tecnologia em si e mais da intencionalidade pedagógica incorporada ao seu uso.

Tal conclusão possui importantes implicações para a formação docente, para o desenvolvimento de políticas educacionais e para futuras investigações na área, indicando que o desafio contemporâneo não consiste apenas em integrar a inteligência artificial à educação, mas em assegurar que essa integração ocorra por meio de práticas pedagógicas fundamentadas em teorias consistentes de aprendizagem e orientadas para a construção significativa do conhecimento.

### **4.3 Implicações Práticas**

Os achados do estudo têm implicações práticas significativas para três áreas: prática docente, design curricular e políticas educacionais.

Para a prática docente, o método IDEAL oferece um framework concreto para estruturar prompts em sala de aula. Professores de matemática podem utilizar o método para criar atividades que promovam aprendizagem significativa, desde exercícios de prática até projetos de investigação.

Para o design curricular, os achados sugerem que a integração de IA generativa deve ser planejada intencionalmente. Currículos devem incluir oportunidades para alunos aprenderem a estruturar prompts efetivamente, desenvolvendo não apenas habilidades matemáticas, mas também literacia digital crítica.

Para políticas educacionais, os achados indicam a necessidade de investimento em formação docente. Professores precisam de oportunidades de desenvolvimento profissional que os capacitem a utilizar IA generativa de forma pedagógica.

## 5. CONSIDERAÇÕES FINAIS

O estudo evidencia que a integração intencional de Inteligência Artificial Generativa no ensino de matemática, mediada por prompts estruturados segundo o método IDEAL, representa uma oportunidade significativa para potencializar a aprendizagem significativa. Os achados validam a aplicabilidade da teoria de Ausubel em contextos de tecnologia emergente, demonstrando que a estruturação intencional de prompts apresenta potencial para favorecer a mobilização de conhecimentos prévios, interpretados à luz da teoria de Ausubel como subsunçores, e facilita a integração significativa de novo conhecimento.

As contribuições teóricas do estudo incluem: (1) integração de teorias de aprendizagem estabelecidas (Ausubel) com tecnologias emergentes (IA generativa); (2) proposição do método IDEAL como framework pedagógico para engenharia de prompt; (3) demonstração de que a IA pode ser transformada de um gerador de respostas prontas em um tutor inteligente, desde que mediada pedagogicamente.

As contribuições práticas incluem: (1) diretrizes concretas para professores estruturarem prompts em sala de aula; (2) framework para avaliação da qualidade pedagógica de respostas geradas por IA; (3) identificação de competências docentes essenciais na era da IA generativa.

Apesar dos achados positivos, o estudo apresenta limitações que devem ser reconhecidas. Embora o estudo tenha contemplado conteúdos de álgebra, funções e geometria, a seleção de tópicos ainda representa apenas uma parcela do currículo matemático da Educação Básica. Pesquisas futuras devem expandir a análise para outros domínios matemáticos (geometria, cálculo, estatística) e outras disciplinas.

Apesar dos resultados positivos, a presente pesquisa apresenta limitações que devem ser consideradas. Primeiramente, a amostra reduzida e o contexto único limitam a generalização dos achados (Yin, 2014). Além disso, a dependência de LLMs, apesar da estruturação dos prompts, não elimina o risco de alucinações, especialmente em conteúdos matemáticos. A eficácia do método IDEAL também está condicionada à competência dos professores em engenharia de prompt, o que reforça a necessidade de formação específica. Por fim, a desigualdade no acesso à tecnologia (digital divide) pode limitar a aplicação do método em contextos socioeconômicos desiguais.

A agenda de pesquisa futura deve abordar as seguintes questões: (1) Como o método IDEAL se aplica a outros domínios educacionais além de matemática? (2) Qual é o impacto a longo prazo da utilização de IA generativa mediada pedagogicamente na aprendizagem e retenção de conhecimento? (3) Como capacitar professores para engenharia de prompt pedagógica, considerando diferentes níveis de literacia digital? (4) Como garantir equidade no acesso a IA generativa, evitando que a tecnologia aprofunde desigualdades educacionais? (5) Como estabelecer diretrizes éticas robustas para o uso de IA em educação, protegendo privacidade e promovendo uso responsável?

Tudo indica que o papel do professor não é diminuído pela tecnologia; é reposicionado e potencializado. Na era da IA generativa, a competência pedagógica — a capacidade de estruturar aprendizagem significativa — torna-se ainda mais essencial. Essa conclusão encontra respaldo em investigações recentes que apontam a necessidade de desenvolvimento de competências docentes específicas para o uso pedagógico da inteligência artificial, incluindo curadoria de informações, avaliação crítica de respostas automatizadas e elaboração estratégica de prompts (UNESCO, 2024; Holmes et al., 2022).

## REFERÊNCIAS BIBLIOGRÁFICAS

- AGÊNCIA BRASIL. Sete em cada 10 alunos do ensino médio usam IA generativa em pesquisas. 2025. Disponível em: <https://agenciabrasil.ebc.com.br/educacao/noticia/2025-09/sete-em-cada-10-alunos-do-ensino-medio-usam-ia-generativa-em-pesquisas>. Acesso em: 7 jun. 2026.
- AUSUBEL, D. P. The psychology of meaningful verbal learning. New York: Grune & Stratton, 1968.
- GEG BRASIL. Educação 5.0: Pedagogia de Prompt Vs Engenharia de Prompt em Sala de Aula. 2024. Disponível em: <http://comunidadegegbrasil.blogspot.com/2024/04/educacao-50-pedagogia-de-prompt-vs.html>. Acesso em: 7 jun. 2026.
- GOOGLE CLOUD. Prompt Engineering for AI Guide. 2025. Disponível em: <https://cloud.google.com/discover/what-is-prompt-engineering>. Acesso em: 7 jun. 2026.
- HOLMES, W.; BIALIK, M.; FADEL, C. Artificial Intelligence in Education: Promises and Implications for Teaching and Learning. Boston: Center for Curriculum Redesign, 2022.
- INTERNATIONAL INTEGRALIZE SCIENTIFIC. Os desafios de ensinar matemática na era da inteligência artificial. 2025. Disponível em: <https://iiscientific.com/artigos/811842/>. Acesso em: 7 jun. 2026.
- KASNECI, E. et al. ChatGPT for Good? On Opportunities and Challenges of Large Language Models for Education. Learning and Individual Differences, v. 103, 2023.
- KHAN ACADEMY BRASIL. The basics of prompt engineering. 2025. Disponível em: <https://www.youtube.com/watch?v=InFyEDZNtds>. Acesso em: 7 jun. 2026.
- LUCKIN, R. et al. Intelligence Unleashed: An Argument for AI in Education. London: Pearson Education, 2016.
- MOREIRA, M. A. Aprendizagem significativa: a teoria e prática. São Paulo: Editora Moreira, 2012.
- NOVAK, J. D. Learning, creating, and using knowledge. Mahwah: Lawrence Erlbaum Associates, 1998.
- PERIODICOS UNOESC. Sistema Tutor Inteligente PAT2Math. 2024. Disponível em: <https://periodicos.unoesc.edu.br/acet/article/view/12666/pdf>. Acesso em: 7 jun. 2026.
- PROMPT ENGINEERING GUIDE. Prompt Engineering Guide. 2025. Disponível em: <https://www.promptingguide.ai/>. Acesso em: 7 jun. 2026.
- REVISTA DCS. Engenharia de Prompt e Gestão de Pessoas: IA a Serviço da Coordenação Pedagógica. 2025. Disponível em: <https://ojs.revistadcs.com/index.php/revista/article/view/1032>. Acesso em: 7 jun. 2026.
- RIBEIRO, T. A. Transformando o aprendizado na era da IA. Educação e Engenharia de Prompt. 2023.
- SELWYN, N. Tecnologia e educação: questões críticas. São Paulo: Pimenta Cultural, 2019.
- SOUTH AMERICAN DEVELOPMENT SOCIETY JOURNAL. Inteligência Artificial Generativa na Educação e Pesquisa: Reflexões sobre o Guia da UNESCO. 2024. Disponível em: <https://www.sadsj.org/index.php/revista/article/view/747>. Acesso em: 7 jun. 2026.

UNESCO. Guia para a IA generativa na educação e na pesquisa. 2024. Disponível em: <https://www.unesco.org/pt/articles/guia-para-ia-generativa-na-educacao-e-na-pesquisa>. Acesso em: 7 jun. 2026.

VICCARI, R. M. Sistemas Tutores Inteligentes como recurso didático no ensino da matemática. 1996.

WHITE, J. et al. A Prompt Pattern Catalog to Enhance Prompt Engineering with ChatGPT.arXiv, 2023.

WILLIAMSON, B. Big data in education: the digital technologies of data-driven learning. London: SAGE Publications, 2017.

ZAWACKI-RICHTER, O.; MARÍN, V.; BOND, M.; GOUVERNEUR, F. Systematic Review of Research on Artificial Intelligence Applications in Higher Education. *International Journal of Educational Technology in Higher Education*, v. 16, n. 39, 2019.