



DESENVOLVIMENTO E APLICAÇÕES DE PROMPTS INTERATIVOS PARA O APOIO AO ENSINO DE FÍSICA NA ENGENHARIA

DOI: 10.37702/2175-957X.COBENGE.2025.6448

Autores: GUILHERME CARVALHO DE ALMEIDA, KENYA APARECIDA ALVES

Resumo: Modelos de Linguagem de Grande Escala (LLMs) inovam o ensino de engenharia, mas seu uso eficaz exige prompts pedagogicamente estruturados. Este trabalho desenvolve e valida uma metodologia para a criação de prompts interativos para o ensino de Física, baseada em quatro funções pedagógicas (solucionador, tutor, analista, direcionador) e na técnica Chain of Thought (CoT). Foram desenvolvidos dez modelos de prompts, cuja análise demonstrou superioridade significativa frente a comandos simples, resultando em respostas com maior clareza, coerência lógica e profundidade pedagógica. A combinação de funções permite adaptar a IA a múltiplos objetivos de aprendizagem. A principal contribuição é um modelo replicável para o design de prompts, que transforma LLMs em ferramentas formativas para fomentar a autonomia e o pensamento crítico do estudante.

Palavras-chave: Física, Engenharia, Inteligência Artificial, Engenharia de Prompts, Chain of Thought, Aprendizagem Ativa., Física, Engenharia, Inteligência Artificial, Engenharia de Prompts, Chain of Thought

DESENVOLVIMENTO E APLICAÇÕES DE PROMPTS INTERATIVOS PARA O APOIO AO ENSINO DE FÍSICA NA ENGENHARIA

1 INTRODUÇÃO

O avanço dos Modelos de Linguagem de Grande Escala (LLMs), como o ChatGPT e o Gemini, oferece uma oportunidade transformadora para a inovação no ensino de engenharia. Por meio de comandos textuais, ou prompts, torna-se possível orientar estes sistemas de Inteligência Artificial (IA) para gerar respostas precisas, contextualizadas e didaticamente relevantes, especialmente em disciplinas de base que exigem raciocínio lógico e análise conceitual, como a Física no curso de Engenharia.

A técnica Chain of Thought (CoT), proposta por Wei. (2022), aprimora os resultados dos LLMs ao estruturar as respostas em etapas intermediárias, promovendo explicações mais completas e compreensíveis. Essa abordagem é particularmente útil no ensino de Física, onde a compreensão dos processos e a justificação dos procedimentos são essenciais para a aprendizagem significativa.

Porém, a jornada de um estudante de engenharia envolve desafios multifacetados que vão além da resolução de um único problema. A aprendizagem eficaz requer um apoio diversificado, que abrange desde a resolução guiada de exercícios e a explicação de conceitos teóricos até a análise de dados experimentais e a exploração de novos tópicos de estudo. A aplicação pontual do CoT, embora poderosa, não aborda de forma estruturada essa diversidade de necessidades pedagógicas.

Diante do exposto, o presente trabalho tem como objetivo desenvolver e validar um conjunto de prompts interativos, baseados em funções pedagógicas distintas e na técnica de Chain of Thought, para apoiar o processo de ensino-aprendizagem em Física. A contribuição central desta pesquisa reside na proposição de um modelo replicável para a criação de prompts multifuncionais que visam não apenas fornecer respostas corretas, mas também promover o raciocínio crítico e a autonomia do estudante de engenharia.

2 FUNDAMENTAÇÃO TEÓRICA

A construção de prompts eficazes — comandos textuais para orientar modelos de linguagem (LLMs) — exige mais do que a simples formulação de perguntas. Para gerar resultados que sejam não apenas tecnicamente corretos, mas também pedagogicamente relevantes, é necessário estruturar os comandos com clareza de escopo, contexto disciplinar e especificação da resposta esperada. Essa engenharia de prompts permite que os modelos de IA processem a informação de maneira precisa e adaptada à complexidade das tarefas propostas, o que é fundamental em domínios como a Engenharia e a Educação.

O ponto de partida para elaboração de prompts complexos é a técnica Chain of Thought Prompting (CoT), conforme evidenciado por Wei (2022). Essa abordagem consiste em induzir o modelo de linguagem a resolver um problema por meio de um raciocínio passo a passo, reproduzindo o modo como especialistas humanos abordam tarefas analíticas. Estudos como os de Kojima (2022) demonstraram que mesmo modelos menos treinados

em raciocínio lógico podem alcançar níveis elevados de desempenho quando orientados por prompts CoT, o que reforça seu valor educativo.

Essa técnica tem sido particularmente eficaz em aplicações que exigem explicações estruturadas, como no ensino de exatas, onde o aluno não deve apenas obter uma resposta, mas compreender o processo que a gerou. Conforme argumentado por Creswell (2022), esse tipo de prompt facilita não só a resolução de problemas, mas também a construção de argumentos científicos, a visualização de fenômenos e a formação de hipóteses. Adicionalmente, contribuições recentes como as de Browning & Liu (2023) destacam a necessidade de incorporar elementos de diálogo interativos aos prompts, ampliando seu uso para contextos como tutoria virtual e ensino personalizado.

Essa visão é complementada pelo conceito de Chain of Touch ao enfatizar a interação multimodal e contínua entre o usuário e a IA, sugerindo que a construção de prompts eficazes deve considerar também aspectos de navegabilidade, resposta adaptativa e refinamento progressivo, principalmente em ambientes digitais de aprendizagem (CHAIN OF TOUCH, 2023). Dessa forma a interação não deve ser única, mas um processo contínuo entre usuário e IA.

Portanto, a fundamentação deste trabalho reside na síntese de duas abordagens complementares: a estrutura lógico-sequencial do Chain of Thought e os princípios de interatividade e personalização pedagógica. Conforme argumentado por Creswell (2022), essa união facilita não só a resolução de problemas, mas também a construção de argumentos e a formulação de hipóteses pelo aluno. A eficácia máxima é alcançada ao adicionar uma camada final de personalização ao prompt, incluindo instruções explícitas sobre a metodologia desejada (ex: análise vetorial, simulação numérica), o formato de saída (ex: gráfico, tabela) e exemplos prévios, garantindo que o rigor técnico e didático da tarefa seja plenamente compreendido pelo modelo de IA. Essa arquitetura de prompt compõe a base para o desenvolvimento proposto neste estudo.

3 METODOLOGIA

Foram identificadas e definidas quatro categorias de funções de prompts, cada uma projetada para abordar um aspecto específico do aprendizado. A escolha dessas categorias baseou-se em desafios comuns enfrentados por estudantes de graduação e nas demandas de aplicação prática de conceitos de ciências exatas ou humanas.

Os Prompts desenvolvidos neste estudo foram concebidos com base em quatro funções pedagógicas centrais, cada uma voltada a uma dimensão específica do processo de ensino-aprendizagem assistido por inteligência artificial. A definição dessas funções foi fundamentada em pesquisas recentes sobre a interação humano-IA no contexto educacional, como apresentado por Brown. (2023), Kojima. (2022) e na abordagem interativa do Chain of Touch (2023). Essas quatro funções são:

Solucionador de problemas: Essa função tem como objetivo auxiliar na resolução detalhada de problemas matemáticos e físicos fornecidos pelo usuário, com base nas informações contextuais inseridas. Os prompts dessa categoria empregam a técnica Chain of Thought Prompting (Wei et al., 2022) para induzir o modelo a apresentar o raciocínio em etapas, promovendo maior clareza e aprendizado processual. Essa abordagem é especialmente útil para problemas de múltiplas etapas, nos quais o processo de solução é tão importante quanto o resultado final.

Tutor especializado: Projetado para atuar como um agente pedagógico, essa função organiza e explica conteúdos teóricos relacionados a uma determinada região conceitual da disciplina (como termodinâmica, eletromagnetismo, ou cinemática). O modelo atua como um

tutor virtual, explicando conceitos, reforçando pré-requisitos e propondo exercícios. Segundo Zhu. (2023), a simulação de tutoria com IA pode gerar benefícios significativos na retenção de conteúdo e no engajamento dos estudantes.

Analista de dados e resultados: Essa função orienta o modelo a interpretar tabelas, gráficos, simulações e resultados experimentais fornecidos pelo usuário, aplicando metodologias como inferência estatística, análise dimensional ou cálculo de incertezas. Prompts estruturados para essa função ajudam o estudante a compreender a lógica por trás das medições e dos fenômenos físicos, como discutido em Creswell. (2022).

Direcionador de áreas de estudo: Esse tipo de prompt tem a função de identificar e sugerir caminhos possíveis para aprofundamento dentro de um tema específico. O modelo atua indicando tópicos complementares, interconexões com outras áreas da Física e sugestões de leitura ou simulações relevantes. Essa função baseia-se no conceito de exploration-based learning (Si et al., 2023), promovendo a autonomia intelectual e o pensamento interdisciplinar.

Cada uma dessas funções foi associada a tipos específicos de prompts, testados e refinados com base em seu desempenho didático e clareza metodológica. A integração dessas funções visa oferecer um conjunto versátil de ferramentas educativas baseadas em IA, adequadas às diferentes demandas do ensino de Física no nível superior, promovendo não apenas a obtenção de respostas corretas, mas também o desenvolvimento do raciocínio crítico, da autonomia e da capacidade de investigação científica, como demonstra a Tabela 1, com o esboço para a criação dos prompts.

Tabela 1: descrição das funções para criação dos prompts

Função do Prompt	Descrição	Exemplo Real de Prompt Utilizado
1.Solucionador de Problemas	Resolve os problemas já fornecidos pelo usuário, utilizando Chain of Thought para apresentar o raciocínio passo a passo.	“Resolva o seguinte problema de Física passo a passo: Um bloco de 2 kg está sobre um plano inclinado de 30°. Calcule a força paralela ao plano.”
2.Tutor Especializado	Explica conteúdos de uma região específica da disciplina, estruturando o ensino com base em objetivos pedagógicos.	“Explique o conceito de trabalho na Física com base na segunda lei de Newton. Use exemplos práticos e equações.”
3.Analista de Dados	Interpreta gráficos, tabelas ou resultados experimentais	“Analise os dados da tabela abaixo que relacionam tensão e

	fornecidos, indicando tendências e relações físicas.	corrente em um LED. Determine o limiar de condução e descreva a curva característica.”
4.Direcionador de Áreas	Sugere novos caminhos de estudo, tópicos correlatos ou aprofundamentos a partir de um conceito inicial.	“Quero conseguir estudar movimento harmônico simples. Que outros tópicos da Física estão relacionados? Sugira livros ou simulações interativas.”

Fonte: Autoria própria

A elaboração de cada prompt seguiu uma estrutura que integra o Chain of Thought (CoT), garantindo que a resposta do modelo de IA não apenas forneça uma solução, mas também guie o usuário por um processo de raciocínio lógico e sequencial. Para cada tipo de prompt, foi desenvolvido um exemplo genérico que serve como modelo e um exemplo aplicado a um contexto específico de ensino abordado, demonstrando a versatilidade da abordagem.

Cada exemplo genérico foi desenvolvido com o pensamento de que qualquer resultado obtido, possa conter o solucionador de problemas, tutor da região abordada desenvolvendo o conteúdo, analista de dados e direcionador de área de abordagem do tema. Para cada caso, há uma abordagem específica para cada tema, sendo o direcionamento para o público alvo, para que o entendimento e a relação com a explicação seja coerente ao público relacionado. contendo também informações adicionais para que possa ser melhor solucionado, essas demonstrações foram organizadas conforme a Tabela 2, onde foi dado um exemplo de como foi construído.

Tabela 2: tabela para exemplificar como ficou o processo de criação de prompt

Exemplo genérico:	Exemplo aplicado:
Com base nos conhecimentos em <Tema abordado> para <público alvo>, explique o <conceito ou subtópico selecionado>, conforme <informação adicional(podendo ser uma imagem)>. <comando à imagem >. insira também <informação adicional(se necessária)>.	Com base nos conhecimentos em ciências dos materiais para ensino superior, explique o conceito de expansão térmica e alterações dimensionais pequenas com base na temperatura, conforme a imagem anexada. traduza a imagem também para que se possa fazer uma análise conjunta a explicação fornecida. insira também relações entre distâncias atômicas, uma variação dessa distância e a nova distância de equilíbrio correspondente ao aumento igual da energia Inter atômica

Fonte: Autoria própria

Para validar o modelo, foram realizados testes utilizando as plataformas de IA generativa ChatGPT (versão GPT-4) e Gemini. A validação não se baseou em um número fixo de testes, mas sim na aplicação dos prompts a uma série de cenários representativos do ensino de Física. Estes cenários foram selecionados por sua relevância curricular e complexidade adequada ao nível superior de engenharia, cobrindo diferentes domínios da disciplina.

A eficácia dos prompts foi avaliada por meio de uma análise qualitativa sistemática das respostas geradas pelos LLMs. Esta análise foi guiada por um conjunto de critérios predefinidos:

1. Execução Funcional: Verificação se a resposta da IA cumpriu com as funções pedagógicas solicitadas no prompt.
2. Qualidade do Raciocínio: Análise da clareza, coerência lógica e precisão conceitual da explicação, especialmente na aplicação do Chain of Thought.
3. Adequação Pedagógica: Avaliação da linguagem e da profundidade do conteúdo, verificando sua adequação ao público-alvo (estudantes de engenharia).

A integração das funções foi inspirada por abordagens anteriores, como as de Kojima et al. (2022), que demonstraram a amplificação de capacidades analíticas dos LLMs mediante prompts compostos, e Creswell et al. (2022), que destacaram o papel da IA na análise de dados científicos. Além disso, os princípios de interação e refinamento contínuo descritos no conceito de Chain of Touch (2023) reforçaram a importância de avaliar a resposta gerada não apenas como produto final, mas como processo pedagógico completo.

Este procedimento permitiu avaliar o desempenho dos LLMs em tarefas que simulam situações reais de aprendizagem e a capacidade de transformar comandos de texto em ferramentas pedagógicas eficazes, capazes de gerar respostas que são não apenas corretas, mas também estruturadas e didaticamente ricas.

4 RESULTADOS E DISCUSSÕES

A aplicação da metodologia descrita culminou na fase experimental, que consistiu no desenvolvimento e validação de dez modelos distintos de prompts. Estes foram sistematicamente criados combinando as quatro funções pedagógicas (solucionador, tutor, analista e direcionador) em diferentes arranjos para atender a necessidades específicas de complexidade e público-alvo. Fundamentados nas técnicas de raciocínio sequencial de Wei et al. (2022) e Kojima et al. (2022), e refinados com princípios de interação contínua (Chain of Touch, 2023), os prompts foram testados nos LLMs ChatGPT e Gemini quanto à sua capacidade de promover compreensão, raciocínio lógico e autonomia do estudante.

Cada modelo é apresentado a seguir com um template genérico, visando a replicabilidade, e um exemplo prático aplicado ao contexto da Engenharia. Para ilustrar a análise, começamos com um prompt que integra as funções de Solucionador + Tutor Especializado, cujo objetivo é resolver um problema enquanto contextualiza a teoria subjacente. O Quadro 1 detalha a estrutura deste tipo de prompt.

Quadro 1: Função: Solucionador + Tutor Especializado

Exemplo genérico	Exemplo prático
Resolva os exercícios de <disciplina> na parte de <tema>, onde o foco é a <pedido> para	Resolva os exercícios de física clássica na parte de eletricidade, onde o foco é a resolução de

<público>, onde o tema abordado é < especificação do tema>.

questões para nível superior, onde o tema abordado é distribuições contínuas de carga elétrica

Fonte: Autoria própria

Para conectar a teoria à evidência visual, foi desenvolvido um prompt que integra as funções de Tutor Especializado + Analista de Dados. O objetivo é capacitar o LLM a explicar um conceito teórico com base em uma imagem ou dado fornecido, preenchendo a lacuna entre o abstrato e o concreto, como detalhado no Quadro 2.

Quadro 2: Função: Tutor Especializado + Analista de dados

Exemplo genérico	Exemplo prático
Com base nos conhecimentos em <Tema abordado> para <público alvo>, explique o <conceito ou subtópico selecionado>, conforme <informação adicional(podendo ser uma imagem)>. <comando à imagem >.	Com base nos conhecimentos em ciências dos materiais para ensino superior, explique o conceito de expansão térmica e alterações dimensionais pequenas com base na temperatura, conforme a imagem anexada. traduza a imagem também para que se possa fazer uma análise conjunta a explicação fornecida. insira também relações entre distâncias atômicas, uma variação dessa distância e a nova distância de equilíbrio correspondente ao aumento igual da energia Inter atômica

Fonte: Autoria própria

De forma complementar, quando o foco se desloca da explicação conceitual para a resolução de um problema, a função do Tutor é substituída pela do Solucionador + Analista de Dados. Este modelo orienta a IA a resolver um problema específico cuja formulação está contida em uma imagem, uma tarefa comum em avaliações e livros-texto (Quadro 3).

Quadro 3: Função: Solucionador + Analista de Dados

Exemplo genérico	Exemplo prático
Em problemas relacionados a <área de aplicação>, solucione o problema na imagem anexada de <conteúdo e a ênfase em um tema específico >. tendo em base, explicações de conceitos para <Nível de atuação>, <método de como que a explicação do problema pode ser	Em problemas relacionados a Engenharia Mecânica, Química e física, solucione o problema na imagem anexada de Potencial elétrico que estão inseridas no conteúdo de mecânica clássica. tendo em base, explicações de conceitos para nível de graduação ou nível

solucionado e apresentado a quem pede o comando>.

superior, além de imagens para ajudar na compreensão do problema abordado

Fonte: Autoria própria

Visando o desenvolvimento da autonomia intelectual, o modelo seguinte combina Tutor + Direcionador de Áreas. A meta aqui é guiar o aluno desde a explicação de um conceito inicial até a exploração de tópicos correlatos e aplicações práticas, incentivando a curiosidade (Quadro 4).

Quadro 4: Função: Tutor + direcionador de Área

Exemplo genérico	Exemplo prático
Explique-me o que é <Tema abordado>, na área de <área atuante> no modelo de <formato de resposta> no foco em solução de problemas para <Região para o tema abordado>, de um modelo que tenha exemplos de problemas que possam ser explicados de formas atenciosas e com aplicação de conceitos.	Explique-me o que é encapsulamento, na área de engenharia mecânica e de engenharia da computação no modelo de programação de c++ no foco em solução de problemas para ensino superior, de um modelo que tenha exemplos de problemas que possam ser explicados de formas atenciosas e com aplicação de conceitos

Fonte: Autoria própria

Uma variação importante no processo de resolução é a exploração de diferentes abordagens. O prompt que une Solucionador + Tutor (Quadro 5) foi desenhado para não apenas resolver um problema, mas também explicar o processo e, crucialmente, propor métodos ou resoluções alternativas.

Quadro 5: Função: Solucionador + tutor

Exemplo genérico	Exemplo prático
Resolva o problema a seguir, tendo como base o <tema> de <Tópico ou área de atuação> em ênfase com o <Público alvo ou foco para quem vai visualizá-lá >, explicando o processo detalhadamente, onde possa ter a compreensão do conteúdo e a resolução do problema. <método >, além de propor outras resoluções para o mesmo problema: <Processo e apresentação do problema>.	Resolva o problema a seguir, tendo como base o tema encapsulamento de programação de computadores em ênfase com o ensino superior, explicando o processo detalhadamente, onde possa ter a compreensão do conteúdo e a resolução do problema. A linguagem de programação a ser utilizada é a de C++, além de propor outras resoluções para o mesmo problema:

Fonte: Autoria própria

A capacidade de analisar dados experimentais brutos é outra habilidade essencial. Para este fim, o prompt que combina Analista de Dados + Tutor foi projetado para não

apenas interpretar os dados, mas também explicar os conceitos subjacentes e a importância daquele experimento, como exemplificado no Quadro 6.

Quadro 6: Função: Analista de dados + tutor

Exemplo genérico	Exemplo prático
Análise os seguintes dados voltados para a área de <Área escolhida>, em um <a partir do modelo que conduza os dados> realizado no tema de <especificação do Tema> e explique-me os conceitos e a importância para a utilização de dados para <a partir do modelo que conduza os dados> de um <saída de dados ou resultado que foi obtido>, além de me explicar a linha de pensamento.	Análise os seguintes dados voltados para a área de engenharia mecânica, em um experimento realizado no tema de eletricidade e física clássica 3 e explique-me os conceitos e a importância para a utilização de dados para o experimento de elementos de um circuito com o foco principal em LED's, além de me explicar a linha de pensamento

Fonte: Autoria própria

Para cenários de formação técnica mais abrangentes, como a preparação para concursos, a combinação Tutor + Direcionador é utilizada para fornecer uma explicação exaustiva sobre um tema, cobrindo conceitos, exemplos e aplicações relevantes, como detalha o Quadro 7.

Quadro 7: Função: Tutor Especializado + direcionador de dados

Exemplo genérico	Exemplo prático
Me explique o que é <Tema solicitado>, onde a área de atuação é a <área que se encaixa o conceito>, tal que esteja relacionado ao <Local de atuação das áreas>, onde irá precisar conter conceitos, exemplos práticos, aplicações e o que pode ser extraído para um <para o que o usuário quer >. não esqueça de deixar as áreas de atuações bem detalhadas e explicadas.	Me explique o que é Estática, onde a área de atuação é a engenharia, tal que esteja relacionado ao ensino superior, onde irá precisar conter conceitos, exemplos práticos, aplicações e o que pode ser extraído para um concurso de ensino superior. não esqueça de deixar as áreas de atuações bem detalhadas e explicadas.

Fonte: Autoria própria

Uma aplicação direta dessa análise é o cálculo de grandezas a partir de dados experimentais. O modelo Solucionador + Analista de Dados (Quadro 8) foca nesta tarefa prática, instruindo a IA a realizar cálculos específicos com base em circuitos ou outros sistemas representados.

Quadro 8: Função: Solucionador + Analista de Dados

Exemplo genérico	Exemplo prático
Com base em conceitos de <Tema abordado> para <área envolvida> voltado ao <Público alvo>, Para os <dados > anexados , calcule a <De qual forma é necessária>, <especificação de como os usuário propõe>	Com base em conceitos de eletrônica para Engenharia mecânica voltado ao ensino superior, Para os circuitos anexados , calcule a resistência equivalente, a queda de tensão em cada um dos componentes bem como ainda, a corrente e a potência nos respectivos componentes.

Fonte: Autoria própria

De maneira similar, para uma abordagem pedagógica completa sobre um novo tópico, o modelo de Introdução, Conceituação e Exercício Aplicado (Quadro 9) também utiliza a dupla Tutor + Direcionador, estruturando o aprendizado de forma didática e progressiva.

Quadro 9: Função: Tutor Especializado + direcionador

Exemplo genérico	Exemplo prático
Introduza, explique e aplique conceitos com exercícios sobre a <Região abordada > para o ramo da <área de atuação> para o <Público Alvo>. faça de maneira detalhada e atenciosa, tendo em mente a preparação para concursos e para o melhor entendimento do assunto	Introduza, explique e aplique conceitos com exercícios sobre a matéria de mecânica dos fluidos para o ramo da engenharia mecânica para o ensino superior. faça de maneira detalhada e atenciosa, tendo em mente a preparação para concursos e para o melhor entendimento do assunto

Fonte: Autoria própria

Finalmente, o modelo mais avançado simula uma Tutoria Pessoal em Níveis Progressivos. Este prompt utiliza uma função de Tutor Personalizado, que integra elementos de todas as outras para criar uma experiência de aprendizagem contínua e adaptativa. Ele modela o ensino em níveis, da teoria básica à aplicação prática, e oferece feedback constante, representando o maior grau de complexidade pedagógica deste estudo (Quadro 10).

Quadro 10: Função: Tutor Personalizado

Exemplo genérico	Exemplo prático
Atue como meu tutor pessoal de explicação de < O que o usuário necessita>. Ensine-me < Tema abordado> de forma progressiva, começando com exercícios básicos, aplicações do dia a dia e	Atue como meu tutor pessoal de explicação de matérias. Ensine-me Mecânica dos Fluidos de forma progressiva, começando com exercícios básicos, aplicações do dia a dia e mini conceitos

mini conceitos de forma correta. Modele o ensino em níveis, focando em conversação prática, compreensão de conceitos e aplicações na < Área de atuação>. Crie exercícios curtos a cada aula, incluindo aplicações, perguntas para praticar e mini trechos de livros para compreensão. Faça correções claras e dê dicas de memorização eficientes.

de forma correta. Modele o ensino em níveis, focando em conversação prática, compreensão de conceitos e aplicações na engenharia mecânica. Crie exercícios curtos a cada aula, incluindo aplicações, perguntas para praticar e mini trechos de livros para compreensão. Faça correções claras e dê dicas de memorização eficientes.

Fonte: Autoria própria

A análise dos resultados demonstra que a estruturação de prompts com base em funções pedagógicas, conforme proposto na metodologia, constitui uma abordagem robusta para aprimorar o uso de LLMs como ferramentas de apoio ao ensino de Engenharia. A discussão a seguir interpreta os principais achados, conectando-os aos critérios de avaliação e à fundamentação teórica.

A eficácia dos prompts foi consistentemente validada em relação aos critérios metodológicos. A comparação entre as respostas geradas com e sem os prompts estruturados revelou ganhos expressivos na qualidade e profundidade pedagógica. De fato, as respostas obtidas por meio dos prompts propostos atenderam de forma robusta e consistente aos três critérios centrais: (1) funcionalidade pedagógica, integrando as funções solicitadas; (2) clareza e coerência lógica, apresentando raciocínios bem definidos e de fácil compreensão; e (3) adequação ao público-alvo, utilizando linguagem e complexidade apropriadas ao ensino superior. Por exemplo, na resposta ao prompt de "Solucionador + Tutor", a IA não só resolveu o problema proposto (que envolvia derivadas e integrais), mas também contextualizou a teoria de forma didática, demonstrando a plena execução das funções. Em contraste, as respostas a comandos simples (sem a estrutura proposta) foram frequentemente incompletas, superficiais ou desconectadas do conteúdo pedagógico, mesmo quando o resultado final estava correto.

Uma análise mais aprofundada revela uma distinção importante entre os tipos de prompt. Modelos que integram múltiplas funções complexas (como os de Tutoria Personalizada ou Análise de Dados + Tutor) mostraram-se superiores na promoção do raciocínio crítico e na personalização da aprendizagem. Eles simulam um diálogo pedagógico mais rico e profundo. Por outro lado, prompts mais focados e com funções mais simples (como o Solucionador de Problemas isolado) foram mais eficazes para a organização conceitual e a resolução de tarefas diretas. Este achado sugere que não existe um "prompt único ideal", mas sim a necessidade de um conjunto versátil de ferramentas que o educador ou estudante pode selecionar de acordo com o objetivo de aprendizagem específico.

O sucesso desta abordagem está diretamente ligado à combinação sinérgica de técnicas da literatura. A alta coerência e clareza das respostas validam a importância do Chain of Thought (Wei et al., 2022) como a espinha dorsal para a decomposição lógica das tarefas. Adicionalmente, os princípios de interação contínua do Chain of Touch (2023) e de personalização dialógica (Browning & Liu, 2023; Zhu, 2023) foram cruciais para a eficácia dos prompts multifuncionais, que transformam a IA de um mero mecanismo de resposta em uma ferramenta formativa. Conforme apontado por Kojima (2022) e Creswell (2022), a

qualidade do comando de entrada determina diretamente a performance do modelo, especialmente em tarefas com múltiplas camadas de inferência, como as simuladas em nosso estudo.

Os resultados indicam que a utilização de LLMs no ensino pode evoluir de uma prática de "tentativa e erro" para um design pedagógico de interações com IA. O modelo de prompts de funções proposto oferece um modelo replicável para que educadores possam criar suas próprias ferramentas de ensino assistido por IA, alinhadas aos objetivos de suas disciplinas e às diretrizes de uma educação por competências. A combinação de estrutura lógica, contexto disciplinar e personalização é a chave para destravar o potencial dos LLMs como aliados efetivos na formação de futuros engenheiros.

5 Considerações FINAIS

Este trabalho teve como objetivo central desenvolver e validar a criação de prompts estruturados, baseados em funções pedagógicas e na técnica de Chain of Thought (CoT), como ferramentas de apoio ao ensino de Física em cursos de Engenharia. Através do desenvolvimento e da análise de dez modelos de prompts distintos, este objetivo foi plenamente alcançado.

Os resultados demonstraram de forma inequívoca que os prompts estruturados são significativamente superiores aos comandos simples, promovendo respostas com maior clareza, coerência lógica e profundidade pedagógica. Em nítido contraste, as respostas a comandos não estruturados apresentaram falhas conceituais e baixa personalização, reforçando a importância da mediação pedagógica intencional na interação humano-IA. A análise evidenciou, ainda, que prompts multifuncionais são mais eficazes para o desenvolvimento do raciocínio crítico, enquanto prompts mais focados auxiliam na organização conceitual.

A contribuição central desta pesquisa é a proposição de um modelo replicável para o design de interações pedagógicas com IA, adaptado à realidade da educação em Engenharia. Este prompt permite que educadores e estudantes evoluam de uma abordagem de "tentativa e erro" para a criação deliberada de prompts que transformam a maneira como se interage com os conteúdos, favorecendo o desenvolvimento da autonomia, do pensamento analítico e da aprendizagem ativa.

Como trabalhos futuros, vislumbra-se a aplicação deste prompt em outras disciplinas do ciclo básico de engenharia e, principalmente, a realização de estudos de caso com estudantes para avaliar quantitativamente o impacto dessas ferramentas no engajamento e no desempenho acadêmico. Tais investigações poderão solidificar ainda mais o uso estratégico da Inteligência Artificial como uma aliada efetiva na formação de engenheiros.

AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de Iniciação Científica que viabilizou a realização desta pesquisa. Agradecem, igualmente, ao Instituto Federal de São Paulo (IFSP) - Campus São José dos Campos por toda a infraestrutura e apoio institucional disponibilizados para o desenvolvimento deste trabalho.

REFERÊNCIAS

BROWNING, Clara; LIU, Fan. Pedagogical personalization through AI-driven dialogue systems. **Journal of Artificial Intelligence in Education**, 2023.

CHAIN OF TOUCH. **Prompt engineering for learning environments**. Educational Technology Research Series, 2023.

CRESWELL, Antonia et al. **Selection-inference: Exploiting large language models for interpretable logical reasoning**. [S. l.]: arXiv, 2022. Preprint. Disponível em: <https://arxiv.org/abs/2210.02022>. Acesso em: 22 jun. 2025.

KOJIMA, Takeshi et al. **Large language models are zero-shot reasoners**. [S. l.]: arXiv, 2022. Preprint. Disponível em: <https://arxiv.org/abs/2205.11916>. Acesso em: 22 jun. 2025.

DEVELOPMENT AND APPLICATIONS OF INTERACTIVE PROMPTS TO SUPPORT PHYSICS EDUCATION IN ENGINEERING

Abstract: *Large Language Models (LLMs) are transforming engineering education, yet their effective use demands pedagogically structured prompts. This paper develops and validates a methodology for creating interactive prompts for Physics teaching, based on four pedagogical functions (solver, tutor, analyst, director) and the Chain of Thought (CoT) technique. Ten prompt models were developed, and their analysis demonstrated a significant superiority over simple commands, yielding responses with greater clarity, logical coherence, and pedagogical depth. Combining functions allows the AI to be tailored to multiple learning objectives. The main contribution is a replicable model for prompt design that transforms LLMs into formative tools to foster student autonomy and critical thinking.*

Keywords: *Physics, Engineering, Artificial Intelligence, Prompt Engineering, Chain of Thought*

