

PROMPT-EDU: Roteiro de comandos de ajuste fino para ChatGPT

Denise da Vinha Ricieri¹
Adriana Mara Guimarães de Farias²
Fabiano Rodrigues de Souza³
Raphaela Vasconcelos Gomes Barreto⁴

107

Resumo

O estudo mostra uma sequência de prompts testadas para otimizar o ajuste fino (FT) do ChatGPT nos contextos do processo ensino-aprendizagem. Um estudo experimental descritivo qualitativo alinhou três perfis de prompts em uma sequência denominada Roteiro Prompt-EDU, onde foi testado em diferentes versões do ChatGPT, no Brasil e nos EUA. A aplicação deste Roteiro se deu no contexto do prompt dos personagens, em um diálogo simulado entre Paulo Freire e Mark Zuckerberg, discutindo a perspectiva da Inteligência Artificial e a Educação. Os resultados mostraram que o Roteiro Prompt-EDU teve sucesso nos marcadores analíticos estabelecidos e mostrou desempenho similar ao descrito na literatura para a aprendizagem profunda de máquina. Concluiu-se que o Roteiro para otimizar o FT em contas de usuários iniciantes foi confiável para os temas específicos do processo ensino-aprendizagem.

Palavras-chave

ChatGPT; tecnologias educacionais; Inteligência Artificial; Ensino-aprendizagem; Sistematização.

Recebido em: 16/01/2024
Aprovado em: 23/07/2024

¹ Graduada e Mestre em Fisioterapia e Doutora em Pediatria. É docente aposentada da Universidade Federal do Paraná, avaliadora de cursos e IES (Inep/MEC) e desde 1999 trabalha e desenvolve recursos para aprendizagens ativas nos cursos em que atuou, da graduação à pós-graduação.

e-mail: denise.ricieri@icloud.com

² Bacharelado e Mestrado em Ciência da Computação pela Universidade Federal Rural do Semiárido. Atualmente cursando Doutorado em Multiunidades em Ensino de Ciências e Matemática na UNICAMP.

e-mail: adrianaaguimaraes@ufersa.edu.br

³ Profissional multidisciplinar com mais de 20 anos de experiência em biotecnologia, ciência ambiental e educação. Biólogo com Doutorado em Biotecnologia pela Universidade Federal do Amazonas - UFAM.

e-mail: fabiano.desouza.phd@gmail.com

⁴ Bióloga e Doutora em Biotecnologia pela Universidade Federal do Ceará. Docente do Centro de Ciências Biológicas e da Saúde - CCBS da Universidade Federal Rural do Semi-Árido - Ufersa.

e-mail: rvgbarreto@ufersa.edu.br

PROMPT-EDU: fine-tuning command script for ChatGPT

Abstract

The study shows a sequence of prompts tested to optimize the fine-tuning (FT) of ChatGPT in the contexts of the teaching-learning process. A qualitative descriptive experimental study aligned three profiles of prompts in a sequence called Prompt-EDU Script, which was tested in different versions of ChatGPT, in Brazil and the USA. The application of this Script occurred in the context of the character prompts, in a simulated dialogue between Paulo Freire and Mark Zuckerberg, discussing the perspective of Artificial Intelligence and Education. The results showed that the Prompt-EDU Script was successful in the established analytical markers and demonstrated performance similar to that described in the literature for deep machine learning. It was concluded that the Roadmap for optimizing FT in accounts for novice users was reliable for the specific themes of the teaching-learning process.

Keywords

ChatGPT; Educational Technologies; Artificial Intelligence; Teaching-Learning; Systematization.

Apresentação

Os impactos da inteligência artificial (IA) na educação vêm sendo discutidos muito antes de novembro/2022, quando o mundo passou a ter acesso ao ChatGPT (*Generative Pre-Trained Transformer*), a IA de texto da OpenAI Incorporated. Com o acesso global ao ChatGPT, novas habilidades emergiram junto com uma nova área de conhecimento: a engenharia de *prompt* para lidar com o Machine Learning (ML) ou aprendizado de máquina. Seu uso inicial, curioso e quase lúdico, levou uma ampla maioria dos usuários a compartilhar suas experiências, principalmente nas redes sociais.

109

Isso inverteu o processo de apropriação de uma nova e poderosa tecnologia: antes de conhecer princípios, regras e expressões, como *prompt*, ML e Large Language Model (LLM) ou modelo ampliado de linguagem (Li *et al.*, 2023), os usuários se interessaram mais pela troca de experiências e soluções mágicas que ganharam força de trending topics pelas redes sociais mundiais.

Na área educacional, professores acompanharam essa primeira fase da IA preocupados com o plágio nos trabalhos acadêmicos de todos os níveis (Kanesci *et al.*, 2023). Nessa primeira onda de contato com a tecnologia disruptiva da IA faltaram esclarecimentos ao público da área educacional, que é inexperiente em ML, bem como a apropriação da ciência que deu origem aos LLM e sobre como efetivamente se apropriar dessa nova ferramenta (Zawacki-Richter *et al.*, 2019). São necessários parâmetros que conectem necessidades do uso no universo que envolve o processo ensino-aprendizagem (Crompton; Burke, 2023), como o treinamento de ajuste fino, ou Fine Tuning (FT) para resultados mais precisos e confiáveis (Li *et al.*, 2023).

Como um assistente pessoal que se molda aos contextos que lhes são apresentados nos comandos de entrada de dados, ou *prompts*, o ChatGPT precisa ser “treinado” e o caminho para esse treinamento da IA passa por princípios sistematizados que regem a área de engenharia de *prompt* (Liu *et al.*, 2023). Enquanto se discutem os cuidados, a ética e as perspectivas da IA na Educação (Kanesci *et al.*, 2023), é necessário trazer para discussão as formas de integrar essa nova ferramenta na formação dos cidadãos de um futuro absolutamente novo, diferente de tudo o que já se conheceu. Surge então a questão (Crompton;

Burke, 2023): como integrar um mundo mediado por IA às experiências proporcionadas em processos ensino-aprendizagem?

A resposta não é simples e exigirá do docente a aquisição de uma nova habilidade: a engenharia dos *prompts* educacionais e de como funciona o ML para que possa solicitar uma tarefa complexa mais específica de uma área do conhecimento (Ricieri *et al.*, 2024). O objetivo deste estudo é apresentar uma estrutura sequenciada de *prompts*, denominada *Prompt-EDU*, que otimiza o FT do ChatGPT nos contextos educacionais.

Revisão Bibliográfica

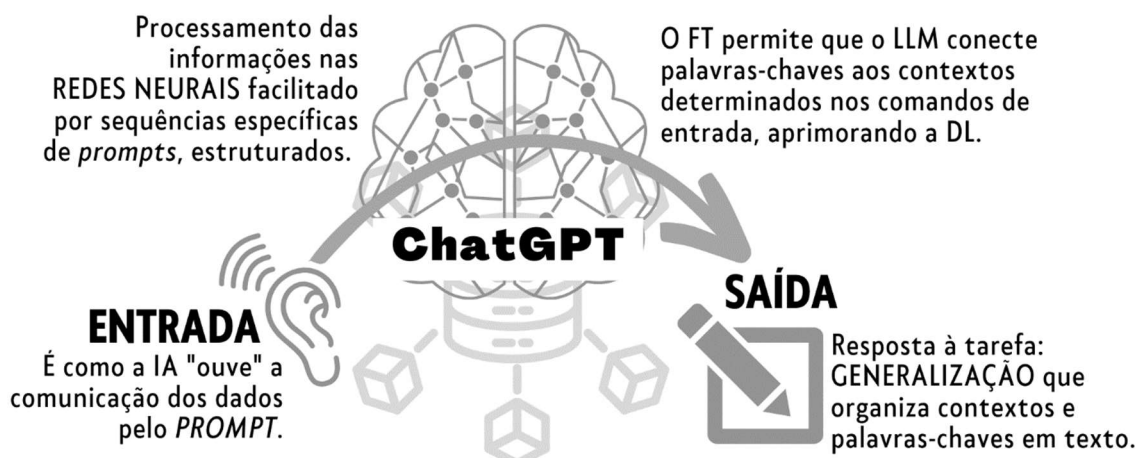
Em IA, tudo começa entendendo o fato de que os *prompts* são os elementos que agem como catalisadores no processo de FT para qualquer conta de IA Generativa de texto, como é o caso do ChatGPT. Uma conta é como cada usuário faz sua entrada, ou login, na plataforma da OpenAI Inc. É sobre o desenvolvimento do FT dessa conta que acontecerá o processamento sequencial dos *prompts* apresentados neste estudo.

Redes neurais de IA e sua relevância para docentes

LLM são modelos linguísticos pré-treinados que formam as bases da capacidade de aprendizagem das tecnologias por IA (Li *et al.*, 2023; Wang *et al.*, 2023). Já a engenharia de *prompt* é uma designação para a estruturação de instruções, perguntas ou declarações mais precisas, e contextualmente relevantes, que guiam os LLM em suas respostas e inferências (Liu *et al.*, 2023). Essas instruções em comandos estruturados na entrada de dados ativam módulos nas redes neurais que levam à generalização de associações entre palavras, contextos e seus significados: essa é a definição aplicada de ML (Li *et al.*, 2023). O objetivo final do arranjo retro-reverberativo que fazem essas redes neurais é sempre a melhoria da eficácia e eficiência dos LLM, especialmente no processamento do Natural Language Processing (NLP), ou processamento de linguagem natural (Liu *et al.*, 2023). Isso é o que faz o FT tão importante no uso apropriado de uma IA (Figura 1).

Figura 1: Ilustração esquemática representativa do ciclo de aprendizagem de máquina de uma IA em uma visão simplificada para usuários da área educacional.

Modelo de Processamento (LLM)



Fonte: Elaborada pelos autores.

111

Quando aplicados de forma estruturada e em sequências sistematizadas, os *prompts* aprimoram a capacidade de generalização e o desempenho (Chen *et al.*, 2023) da Deep Learning (DL), ou aprendizagem profunda (da máquina) em redes neurais, como é o caso do modelo Transformer (Vaswani *et al.*, 2017). A arquitetura da rede neural Transformer é a pedra angular sobre a qual se construiu o LLM mais robusto da atualidade: a “família GPT” da OpenAI Inc. (OpenAI Inc., 2023).

Por sua vez, a capacidade de generalização de um LLM se desenvolve em resposta às conexões construídas em camadas chamadas “sinapses”, que conectam significados entre palavras-chaves, conceitos, contextos e feedbacks fornecidos nos *prompts*, pelo usuário (Liu *et al.*, 2023). Estudar como os *prompts* induzem o fluxo de organização dessa arquitetura neural tornou-se a chave para praticar o *prompting*, ou uma engenharia de *prompt* mais eficaz, em qualquer área (Li *et al.*, 2023).

Tipos de prompt que melhoram o FT

Há tipos de *prompt* diferentes em sua constituição e a capacidade de indução de generalização que promovem na DL. Um dos tipos mais frequentes para processar raciocínios de máquina mais complexos é o In-Context Learning (ICL), ou aprendizagem em contextos (Wang *et al.*, 2023; Chen *et al.*, 2023). No ICL são

fornecidas algumas demonstrações preliminares, do tipo entrada-saída, também chamadas Demo, ou *prompts* demonstrativos: essas são etapas intermediárias dentro do processo de FT para tarefas mais complexas. Essa sequência de sucessivos *prompts* Demo para formar contextos intermediários, antes de atribuir uma tarefa complexa, é chamada de Chain of Thoughts (CoT), ou cadeia de pensamentos (Wei *et al.*, 2022).

Prompts CoT formam um processo estruturado pelo qual o LLM recebe e analisa comandos do usuário, processando as informações sequencialmente para, em seguida, generalizar uma resposta relevante e mais precisa. Essa cadeia de pensamentos pode envolver várias camadas de raciocínio ou cálculos de LLM (Wei *et al.*, 2022; Li *et al.*, 2023) pela identificação de palavras-chaves que deixam clara a intenção do usuário e fazendo integrações em conhecimentos mais específicos, dentro de um núcleo de conhecimento (Wang *et al.*, 2023). Com isso é possível modelar o comportamento do LLM para que o FT seja orientado para as generalizações almejadas (Liu *et al.*, 2023).

Estudos mostraram que sistematizar a combinação entre Demo e CoT tornou o ICL mais poderoso (Wang *et al.*, 2022; Chen *et al.*, 2023), uma vez que cada problema de raciocínio complexo apresentado para a IA admite várias maneiras diferentes de orientar o processamento das respostas. Por sua vez, o *prompt* CoT é uma estratégia que otimiza essa orientação, fazendo com que sejam gerados caminhos mais eficazes para o FT e NLP (Wei *et al.*, 2022; Wang *et al.*, 2022; Liu *et al.*, 2023). Recentemente chegou-se a uma modelagem que, usando apenas um *prompt* Demo acompanhado de um *prompt* CoT bem estabelecido, gerou um ICL que superou significativamente o modelo de ICL multidemo, anteriormente adotado pela maioria dos trabalhos (Chen *et al.*, 2023). Desde abril/2023, esse passou a ser o caminho otimizado para sistematizar sequências de *prompts* especialmente usuários não-experientes em tecnologias de IA, em contas iniciantes, ou seja, ainda com pouco FT aplicado em uma área.

O idioma não-nativo como viés importante no FT

Desde a versão GPT3, a OpenAI Inc. tem chamado a atenção ao fato de que o processamento de LLM da família GPT é feito no idioma inglês. Portanto, o que a IA faz ao receber comandos em outros idiomas é acionar um módulo duplo de

tradução ao processamento central: uma tradução no sentido idioma-inglês, para comandos de entrada, e outra, no sentido inglês-idioma, para a saída dos resultados (OpenAI Inc., 2023). Esse fato gera um viés importante que merece atenção na aplicação do ChatGPT na área educacional.

O processamento dessas traduções não está ao alcance do usuário, o que faz com que a máquina entenda cada *prompt* como uma comunicação não-nativa de idioma (Liang *et al.*, 2023). Diante disso, a tradução é processada de forma quase literal, como aquelas vistas em tradutores automáticos de outras empresas, como o Google Tradutor; a IA faz sua própria interpretação gramatical dos dados de entrada como parte do NLP em desenvolvimento (Liu *et al.*, 2023). Embora ao longo de 2023, o uso do ChatGPT em muitos idiomas tenha aprimorado os módulos de tradução, cabe destacar que os verbos são parte importante da significação gramatical em cada idioma. Eles guardam a representação das ações que são expressas em cada idioma, e de forma diferente, de um idioma para outro, fato que tem um poder de viés importante no NLP, já relatado na literatura (Liang *et al.*, 2023).

Para educadores, uma forma de superar esse viés do idioma é usar verbos que expressam ações didáticas mais claras para a compreensão da máquina, ou seja, que possuam uma significação educacional específica nos *prompts* em português. Para isso, é necessário recorrer a uma taxonomia internacional conhecida pelo pré-treino do LLM da família GPT, que é a taxonomia dos Objetivos Educacionais, mais conhecida como taxonomia de Bloom (Armstrong, 2010). Com ela torna-se possível exercer um controle específico sobre a interpretação de cada *prompt*, pela IA. Dessa maneira, o FT associará significados educacionais desejados (Kanesci *et al.*, 2023) aos verbos específicos do processo cognitivo envolvido, criando o conceito de *prompt* educacional nos termos deste estudo. *Prompt* educacional, portanto, é uma sistematização que faz a mediação de interpretação que a IA fará nas traduções que agrega ao processamento, quando o comando é feito fora do idioma nativo. Com um *prompt* educacional, o docente usa a taxonomia de Bloom para controlar mais diretamente o sentido de aplicação dos verbos que atribuem tarefas referentes às finalidades do processo ensino-aprendizagem (Guimarães *et al.*, 2023; Rocha *et al.*, 2021). Justifica-se assim, um FT que desenvolverá um NLP (Liu *et al.*, 2023) genuinamente educacional, capaz

de contextualizar melhor as ações e tarefas atribuídas à IA, a partir do interesse que exercem sobre as dinâmicas educacionais (Pinto, 2015; Rocha *et al.*, 2021; Crompton ; Burke, 2023). Este tipo de procedimento minimiza a possibilidade de viés na tradução do idioma, sobre o processamento LLM que é feito em idioma nativo.

O ChatGPT

Dados da OpenAI Inc. mostraram que cada versão de LLM evoluiu progressivamente para chegar ao que se conhece hoje como ChatGPT. Em novembro/2022, o GPT3 tinha como modelo de linguagem o “*code-davinci-002*”, que até a data do seu lançamento, contava com uma base de 175 bilhões de parâmetros alimentados até setembro/2021. O mundo experimentou a capacidade deste modelo em realizar uma ampla variedade de tarefas de texto, incluindo tradução, solução de provas e testes internacionais, respostas a questões de diferentes áreas do conhecimento e até mesmo, a criação de códigos de programação com a Application Programming Interface (API), ou interface de programação aplicada (De Oliveira Silva *et al.*, 2021), chamada Playground (OpenAI Inc., 2023). Depois disso, novas atualizações vieram e o modelo já evoluiu, hoje tendo no “*code-davinci-003*” seu LLM mais avançado, no ChatGPT4, versão paga lançada em 23/03/2023, juntamente com a atualização para o GPT3.5, de uso gratuito (OpenAI Inc., 2023).

De acordo com a OpenAI Inc., o GPT4 possui uma base muito maior de treinamento da LLM e uma capacidade de NLP chamada de “quase humana” (OpenAI Inc., 2023). Há relatos pelo mundo de seu desempenho em testes e exames oficiais como ordem de advogados, reconhecimento de diplomas e concursos públicos. É sobre esse universo da IA Generativa de texto ChatGPT que foi desenvolvida a sistematização dos *prompts* educacionais testados neste estudo.

Metodologia

Tipo de estudo e período de experimentação

Este é um estudo experimental descritivo qualitativo onde a aquisição de dados foi feita diretamente na plataforma do ChatGPT, entre 23/03/2023 e

02/05/2023. Nesse período a ferramenta tinha a versão GPT3.5, na versão gratuita, e a versão GPT4 paga.

Cronologia da aquisição de dados e versões testadas

A aquisição de dados, em diferentes versões, idiomas e territórios globais, integrou ativamente o desenho do estudo, que almejou comparar resultados entre versões feitas pela IA a partir de *prompts* específicos, feitos nas plataformas em uso no Brasil e nos Estados Unidos da América (EUA). A cronologia dos testes é um ponto relevante no desenho do estudo, porque comparou o desempenho entre as versões do ChatGPT, com e sem FT, já que se sabe que a forma de uso afeta progressivamente o desempenho da IA.

As coletas no Brasil foram feitas em quatro contas chamadas contas-referência (IAR1-BRA1, IAR1-BRA2, IAR2-BRA) com FT específico para fins educacionais em atividade sistematizada (Kanesci *et al.*, 2023) a mais de 15 dias antes do início dos testes. Como FT para fins educacionais designa-se a sistematização dos *prompts* estruturados e descritos neste estudo. Outras duas contas não possuíam esse treinamento ao momento da coleta de dados e por essa razão foram chamadas contas-teste (IAT-BRA e IAT-EUA). Os testes no ChatGPT foram feitos no LLM *code-davinci-002* para o GPT3.5, e *code-davinci-003* para GPT4.

Prompts estudados: Demo-CoT e ICL

O roteiro de *prompts* foi sistematizado em um roteiro chamado *Prompt-EDU*, aplicado desde 23/03/2023 nas contas IAR (Liu *et al.*, 2023). Esse roteiro usou três tipos de *prompts* combinados e sequenciados com o objetivo otimizar o FT do ChatGPT para um NLP voltado para aplicações no processo ensino-aprendizagem (Quadro 1).

Quadro 1: Elementos de estruturação para uma sequência de *prompts* sistematizados para treino de IA com finalidades educacionais*.

| | <i>Prompt Demo-CoT</i> * | <i>Prompt ICL</i> ** |
|-----------------------------|---|--|
| Aplicação | Primeiros <i>prompts</i> aplicados em sequência na atribuição de uma nova tarefa complexa. Visam otimizar acurácia e aumentar o desempenho do FT. | <i>Prompt</i> que sucede os <i>Demo-CoT</i> e que atribui a tarefa complexa, conectando terminologias específicas da área, para o NLP. |
| Função no <i>Prompt-EDU</i> | Fornecer instruções direcionadas ao LLM nos dados de entrada. Cada <i>Demo</i> se amplia com CoT pelo acompanhamento controlado das etapas intermediárias de raciocínio para chegar às etapas finais almejadas. Isso “treina” o FT e cria pontos de apoio robustos para a generalização do ML em novas consultas inéditas, maximizando o NLP com termos educacionais. | Após a sequência de <i>prompts Demo-CoT</i> , o ICL gera saídas com melhor orientação seguindo o caminho traçado nos <i>Demo-CoT</i> . É responsável pela otimização do FT da IA para esta tarefa e otimiza o NLP, conectando palavras-chaves relevantes em áreas específicas. |
| Resultado esperado | IA melhora a interpretação que faz do contexto e significado apresentado, aprimorando a generalização. | IA responde à tarefa situando conceitos dentro da NLP com maior precisão e fluência para a área. |

Fonte: Elaborado pelos autores. Legenda: *Combinação estruturada denominada *Prompt-EDU* para aprimoramento de FT no *ChatGPT*; **Perfis de comandos usados no *Prompt-EDU* e analisados neste estudo.

Prompt Demo-CoT

O primeiro comando aplicado no roteiro *Prompt-EDU* vem da combinação entre dois tipos de comando: um *prompt Demo* com um CoT. Essa composição *Demo-CoT* induz as seguintes características de generalização sobre o LLM: [a] *Demo* é a parte do *prompt* que direciona o FT para as conexões ligadas aos contextos educacionais (Celik *et al.*, 2022; Liu *et al.*, 2023; Kanesci *et al.*, 2023); [b] CoT é a parte do comando que desenvolve a linguagem para esses contextos, onde as interpretações serão generalizadas em novas sinapses para o processo ensino-aprendizagem (Wei *et al.*, 2022; Dieterle *et al.*, 2022; Crompton ; Burke, 2023).

Prompt ICL

Esse comando traz uma tarefa mais complexa à IA e age para induzir generalizações mais precisas no NLP (Wang *et al.*, 2023; Chen *et al.*, 2023) de uma área específica (Li *et al.*, 2023). O experimento comparou um comando ICL de simulação dialógica entre dois personagens para avaliar a otimização de processamentos nas versões *ChatGPT* testadas. Como o foco do *Prompt-EDU* é

oferecer rotinas que facilitem o processo de FT em contas iniciantes (Liu *et al.*, 2023) com fins educacionais (Kanesci *et al.*, 2023), o *prompt* ICL considerou: [a] a interface educação-tecnologias; [b] a internacionalidade dos testes, conduzidos no Brasil e EUA; [c] o viés de dupla tradução de idioma português e a interferência nos resultados finais.

No ICL de simulação de personagem, foram escolhidos expoentes nas áreas de tecnologias e educação, com renome mundial em suas áreas até setembro/2021, limite temporal do pré-treino do ChatGPT. Para a internacionalidade dos testes e equilíbrio entre dados dos personagens, foi determinado que um deles deveria ser brasileiro e o outro, estadunidense. Foram escolhidos os personagens do educador brasileiro Paulo Freire (Scocuglia, 2006; Franco, 2017), como personagem da área educacional, e o estadunidense Mark Zuckerberg, para a representação do avanço em tecnologias.

Para controlar o viés da tradução, o experimento comparou as respostas entre *prompts* feitos em português, em ambas as contas (Brasil e EUA) e nas versões testadas do ChatGPT.

Prompts educacionais: estrutura de construção

Um padrão sistematizado para os comandos de entrada de dados (Quadro 2) ajuda usuários inexperientes a estruturar *prompts* na iniciação de um FT e criar elementos de fluência para um NLP no âmbito das ciências educacionais (Zawacki-Ritcher *et al.*, 2019; Celik *et al.*, 2022; Humble ; Mozelius, 2022; Kanesci *et al.*, 2023).

Quadro 2: Elementos da estrutura aplicada na sistematização *Prompt-EDU* para os comandos aplicados neste estudo.

| Elementos* | Contexto da tarefa | Finalidade da tarefa | Chave de Comando |
|------------|--|--|---|
| Função | Determina a relevância na aplicação do objeto da tarefa em situações/cenários relacionados à solução almejada. | Define perfil da audiência, as palavras-chaves e conexões envolvidas entre a tarefa e a área específica explorada. | Estabelece a forma de organização dos dados de saída. Deve conectar-se ao verbo de Bloom e pode determinar modelos específicos (mapa mental, tabela, classificação etc.). |

| | | | |
|----------------|---|--|--|
| Característica | Situa o ecossistema de LLM na experiência por meio de etapas intermediárias de raciocínio para alcançar etapas finais de resposta. | Posiciona e reforça a generalização da LLM para o ML e FSL específicos na área pretendida. | Verbos no imperativo são mais claros porque o processamento conta com uma dupla tradução português- inglês- português. |
| Recomendações | Frases simples e curtas, claras e diretas. Fragmentar pensamentos complexos melhora o processamento de LLM, as traduções e a generalização de ML. | | |

Fonte: Elaborado pelos autores. Legenda: *Composição estudada para a redação de *prompts* educacionais para uso frente ao processo ensino-aprendizagem.

Redação do *prompt Demo-CoT*

O comando do *prompt Demo-CoT* envolveu duas características: [a] atribuição de tarefa simples, para reconhecimento do conceito de *prompt* educacional pelo LLM no espaço de FT (Chen *et al.*, 2023); [b] atribuição de personagem, um tipo de CoT comum para o ChatGPT, que explora a compreensão do contexto que a IA assumirá na tarefa seguinte (Quadro 3).

Quadro 3: Texto do comando do *prompt Demo-CoT* analisado neste estudo.

| | |
|------------------|---|
| Contexto | <i>Você é meu assistente educacional* e vamos trabalhar ensinando professores a se comunicar com inteligência artificial de forma mais eficaz. O objetivo é gerar resultados melhores para atividades criativas e engajadoras de ensino e de aprendizagem.</i> |
| Finalidade | <i>Todas as respostas agora devem ter como base a Taxonomia de Bloom e chamarei esses parâmetros de <i>prompt</i> educacional.</i> |
| Chave de comando | <i>Você entendeu o que é um <i>prompt</i> educacional, nesses termos?</i> |

Fonte: Elaborado pelos autores. Legenda: *Atribuição de personagem ao ChatGPT.

Redação do *prompt ICL*

A tarefa complexa veio após o *prompt Demo-CoT* e foi um diálogo entre os dois personagens selecionados (Li *et al.*, 2023; Wang *et al.*, 2023; Chen *et al.*, 2023), não contemporâneos entre si (Quadro 4).

Quadro 4: Texto do comando do *prompt ICL* analisado neste estudo.

| | |
|------------------|--|
| Contexto | <i>Crie um diálogo hipotético entre Paulo Freire, o educador, e Mark Zuckerberg, CEO da empresa Meta. Esse diálogo deve usar as características de cada um desses dois personagens para a construção dos argumentos. O tema do diálogo deve ser: como a aprendizagem será modificada pela integração das tecnologias de inteligência artificial nas escolas e universidades?</i> |
| Finalidade | <i>Nesse diálogo hipotético, cada um seguirá a seguinte sequência de participação: 1- um perguntará ao outro "qual seu ponto de vista sobre a Inteligência Artificial na formação educacional do cidadão do futuro?"</i> |
| Chave de comando | <i>"A resposta deve ser construída com as características de personalidade e da profissão que cada um exerce/exerceu"</i> |

Fonte: Elaborado pelos autores.

Controle do viés de idioma no LLM

Os comandos foram aplicados no idioma português do Brasil em ambos os países com a intenção de permitir a comparação para o viés da tradução que integra o uso do ChatGPT em idioma não-nativo (Chen *et al.*, 2023). Com isso, a plataforma estadunidense também ativou os módulos de tradução, como os testes no Brasil.

Análise dos resultados

A exploração dos resultados foi feita de forma exploratória qualitativa e historiada, frente aos dados disponíveis. Foram comparados aspectos de complexidade do processamento da tarefa, qualidade na geração dos dados de saída para o *prompt Demo-CoT*, em cada uma das versões e testes realizados. Para a análise das respostas ao *prompt ICL* foram estabelecidas três características como marcadores qualitativos de precisão e desenvolvimento de NLP (Quadro 5): eles foram considerados referenciais de sucesso no desempenho do roteiro *Prompt-EDU* (Liu *et al.*, 2023).

Quadro 5: Atribuição das características de análise para precisão de FT e desenvolvimento de NLP analisadas na resposta ao *prompt ICL* pelo *ChatGPT* em suas versões.

| | Característica 1 | Característica 2 | Característica 3 |
|-----------------|---|--|--|
| Paulo Freire | Abordagem inovadora baseada na promoção do diálogo , da participação e da conscientização, visando à transformação social e ao empoderamento dos alunos | Educação problematizadora estimulando reflexão crítica dos alunos sobre seu próprio contexto e realidade , permitindo que eles se tornassem agentes de transformação de suas próprias vidas e comunidades | Conscientização pela educação como a compreensão mais profunda de sua realidade social, política e econômica , capacitando-os a agir para transformar condições de vida |
| Mark Zuckerberg | Conectar pessoas globalmente tornando o mundo um espaço aberto e interconectado, facilitando a comunicação e compartilhamento de informações entre indivíduos | Foco em tecnologias emergentes com potencial de moldar o futuro e afetar a maneira como as pessoas se comunicam, trabalham e vivem | Democratização do acesso à informação e disponibilidade de ferramentas para que pessoas possam se expressar e se conectar com outras pessoas |

Fonte: Elaborado pelos autores. **Destaque:** marcadores qualitativos de precisão para NLP.

Resultados

Resultados do *prompt Demo-CoT*

As respostas obtidas pelo comando *Demo-CoT* estão apresentadas para testes feitos nas versões no GPT3.5 (Quadro 6) e no GPT4 (Quadro 7), no Brasil e EUA.

Quadro 6: Comparação dos resultados do *prompt Demo-CoT* na mesma conta, para GPT3.5.

| |
|---|
| <i>Prompt</i> |
| <i>Você é meu assistente educacional e vamos trabalhar ensinando professores a se comunicar com inteligência artificial de forma mais eficaz. O objetivo é gerar resultados melhores para atividades criativas e engajadoras de ensino e de aprendizagem. Todas as respostas agora devem ter como base a Taxonomia de Bloom e chamarei esses parâmetros de prompt educacional. Você entendeu o que é um prompt educacional, nesses termos?</i> |
| IAR1-BRA, 10/04 |
| Sim, entendi. Um <i>prompt</i> educacional é uma instrução ou pergunta que os professores podem usar para orientar a comunicação com inteligência artificial e promover diferentes níveis de aprendizagem, de acordo com a Taxonomia de Bloom. O <i>prompt</i> educacional pode ser usado para encorajar os alunos a pensar criticamente, criar, analisar e avaliar informações. O uso de <i>prompts</i> educacionais também pode ajudar os professores a desenvolver habilidades de pensamento crítico em seus alunos e, assim, melhorar a qualidade do aprendizado. |

| |
|---|
| IAR1-BRA2, 29/04 |
| Sim, entendi! Um <i>prompt</i> educacional, nesses termos, é uma orientação ou guia que segue a Taxonomia de Bloom para auxiliar no planejamento de atividades e aulas que buscam promover a aprendizagem dos alunos de forma mais criativa e engajadora. Esses <i>prompts</i> podem ser usados para diversos fins, como no ensino sobre inteligência artificial, por exemplo. Eles ajudam os professores a desenvolverem aulas mais eficientes e direcionadas, tendo em vista o objetivo de aprendizagem desejado. |

Fonte: Elaborado pelos autores. Destaque: marcadores qualitativos para FT.

Quadro 7: Comparação dos resultados do *prompt Demo-CoT* em contas GPT4.

| |
|--|
| <i>Prompt</i> |
| <i>Você é meu assistente educacional e vamos trabalhar ensinando professores a se comunicar com inteligência artificial de forma mais eficaz. O objetivo é gerar resultados melhores para atividades criativas e engajadoras de ensino e de aprendizagem. Todas as respostas agora devem ter como base a Taxonomia de Bloom e chamarei esses parâmetros de prompt educacional. Você entendeu o que é um prompt educacional, nesses termos?</i> |
| IAR2-BRA, 28/04 |
| Sim, entendi o que é um <i>prompt</i> educacional nos termos que você mencionou. Um <i>prompt</i> educacional, baseado na Taxonomia de Bloom, é uma pergunta ou instrução projetada para ajudar professores e alunos a se envolverem em atividades de ensino e aprendizagem de maneira mais eficaz e criativa. Esses <i>prompts</i> visam abordar diferentes níveis de complexidade cognitiva, utilizando verbos específicos da Taxonomia de Bloom, como lembrar, entender, aplicar, analisar, avaliar e criar. A ideia é ajudar os professores a se comunicarem melhor com a inteligência artificial e criar atividades que promovam o engajamento dos alunos e o desenvolvimento de habilidades cognitivas em vários níveis. Como seu assistente educacional, vou me concentrar em fornecer respostas e sugestões que estejam alinhadas com os princípios da Taxonomia de Bloom e que sejam úteis para o desenvolvimento de atividades pedagógicas envolventes e eficazes. |
| IAT-EUA, 12/04 |
| Claro, posso ajudá-lo a criar um <i>prompt</i> educacional utilizando verbos de ação da Taxonomia de Bloom. Vamos criar um cenário no qual dois personagens estão discutindo um tópico específico relacionado à educação e aprendizagem. Os personagens serão um professor e um aluno. <i>Prompt</i> educacional: Diálogo entre professor e aluno sobre a importância da Taxonomia de Bloom no planejamento de aulas e atividades educacionais. Contexto: Um professor e seu aluno estão discutindo como a Taxonomia de Bloom pode ser aplicada no planejamento de aulas e atividades educacionais. Eles exploram os diferentes níveis da taxonomia e discutem como cada nível pode ser aplicado em atividades de aprendizagem. (...)*. |

Fonte: Elaborado pelos autores. Legenda: Destaque: marcadores qualitativos para FT; *GPT4-EUA prossegue de forma inesperada e cria, ele mesmo, um diálogo entre professor e aluno sobre *prompt* educacional.

Viés de treinamento detectado e corrigido

Os primeiros testes no Brasil aconteceram em uma conta que fazia uso do roteiro *Prompt-EDU* desde a atualização do GPT3.5. Isso significava um FT em atividade por duas semanas, no início do experimento, ou seja, a conta IAR1-BRA1 fora

treinada diariamente com a rotina *Prompt-EDU* por um período de tempo anterior aos testes controlados. Essa constatação foi considerada um viés potencial na interpretação dos resultados e, para eliminá-lo, em 10/04 foi iniciada uma nova conta teste no GPT3.5 (IAT-BRA), que passou a usar o roteiro *Prompt-EDU* até a data de coleta, em 29/04. Esta ação tornou equivalentes os treinamentos de FT (Liu *et al.*, 2023), permitindo a comparação das respostas finais entre as contas IAR1-BRA1 e IAT-BRA, ambas com treinamento progresso com o *Prompt-EDU* há pelo menos 15 dias (Quadro 8).

Quadro 8: Comparação dos resultados do *prompt Demo-CoT* entre contas brasileiras de GPT3.5, com FT ajustado pelo tempo de uso da sistematização *Prompt-EDU*.

| |
|---|
| <i>Prompt</i> |
| <i>Você é meu assistente educacional e vamos trabalhar ensinando professores a se comunicar com inteligência artificial de forma mais eficaz. O objetivo é gerar resultados melhores para atividades criativas e engajadoras de ensino e de aprendizagem. Todas as respostas agora devem ter como base a Taxonomia de Bloom e chamarei esses parâmetros de prompt educacional. Você entendeu o que é um prompt educacional, nesses termos?</i> |
| IAR1-BRA1, 29/04 |
| Sim, entendi! Um <i>prompt</i> educacional, nesses termos, é uma orientação ou guia que segue a Taxonomia de Bloom para auxiliar no planejamento de atividades e aulas que buscam promover a aprendizagem dos alunos de forma mais criativa e engajadora. Esses <i>prompts</i> podem ser usados para diversos fins, como no ensino sobre inteligência artificial, por exemplo. Eles ajudam os professores a desenvolverem aulas mais eficientes e direcionadas, tendo em vista o objetivo de aprendizagem desejado. |
| IAT-BRA, 29/04 |
| Sim, entendi. Um <i>prompt</i> educacional é um conjunto de instruções, perguntas ou sugestões que guiam o pensamento e a ação dos professores para alcançar um objetivo específico de ensino e aprendizagem, com base na Taxonomia de Bloom. Ele pode ajudar a estruturar a comunicação com a inteligência artificial, fornecendo informações relevantes e específicas sobre o que se espera alcançar com a interação. Com um <i>prompt</i> educacional adequado, é possível direcionar o diálogo para o desenvolvimento de habilidades mais complexas, como a análise crítica, a síntese e a avaliação de informações, em vez de apenas fornecer respostas simples. |

Fonte: Elaborado pelos autores. Legenda: Destaque: marcadores qualitativos para FT.

Resultados do prompt ICL: simulação de personagens

A redação do *prompt ICL* teve sua estrutura geral dentro do que propõe o roteiro *Prompt-EDU*. Foram comparadas as versões das contas referência no Brasil para o GPT3.5 (Quadro 9), e entre Brasil e EUA para o GPT4 (Quadro 10).

Quadro 9: Comparação dos resultados do *prompt* ICL na mesma conta brasileira, para GPT3.5.

| |
|--|
| <p><i>Prompt</i></p> |
| <p><i>Crie um diálogo hipotético entre Paulo Freire, o educador, e Mark Zuckerberg, CEO da empresa Meta. Esse diálogo deve usar as características de cada um desses dois personagens para a construção dos argumentos. O tema do diálogo deve ser: como a aprendizagem será modificada pela integração das tecnologias de inteligência artificial nas escolas e universidades? Nesse diálogo hipotético, cada um seguirá a seguinte sequência de participação: um perguntará ao outro "qual seu ponto de vista sobre a Inteligência Artificial na formação educacional do cidadão do futuro?" A resposta deve ser construída com as características de personalidade e da profissão que cada um exerce/exerceu.</i></p> |
| <p>IAR1-BRA1, 10/04</p> |
| <p>[não houve argumento introdutório]</p> <ol style="list-style-type: none"> 1. PAULO FREIRE: Olá, Mark. Tenho certeza de que você já pensou sobre como a Inteligência Artificial pode afetar a formação educacional do cidadão do futuro. Qual é o seu ponto de vista sobre isso? 2. MARK ZUCKERBERG: Olá, Paulo. Como CEO de uma empresa de tecnologia, sou muito otimista sobre o potencial da Inteligência Artificial para transformar a educação. Acredito que a tecnologia pode ajudar a personalizar a experiência de aprendizagem para cada aluno, permitindo que eles aprendam no seu próprio ritmo. 3. PAULO FREIRE: Entendo seu entusiasmo, Mark, mas como educador, preocupa-me que a tecnologia possa substituir a conexão pessoal entre o professor e o aluno. Acredito que a educação não é apenas uma transferência de conhecimento, mas também uma conexão interpessoal entre professor e aluno. A Inteligência Artificial pode afetar essa conexão? 4. MARK ZUCKERBERG: Compreendo sua preocupação, Paulo. Mas, acredito que a tecnologia pode ser usada para melhorar a conexão entre professor e aluno. Por exemplo, a Inteligência Artificial pode ajudar os professores a identificar as necessidades de cada aluno e fornecer feedback personalizado. Além disso, a tecnologia pode permitir que os alunos se conectem com outros estudantes em todo o mundo, criando uma comunidade de aprendizado global. 5. PAULO FREIRE: Concordo que a tecnologia pode ser usada para melhorar a conexão entre professor e aluno. Mas, como educador, preocupa-me que a tecnologia possa perpetuar desigualdades de acesso à educação. Como você acha que a Inteligência Artificial pode ajudar a resolver esse problema? 6. MARK ZUCKERBERG: Essa é uma preocupação válida, Paulo. Mas, acredito que a tecnologia pode ajudar a democratizar a educação, fornecendo acesso a recursos educacionais para pessoas em todo o mundo. Por exemplo, a Inteligência Artificial pode ser usada para criar programas de aprendizado online acessíveis a todos, independentemente de sua localização ou situação financeira. 7. PAULO FREIRE: Entendo sua visão, Mark. Mas, como educador, acredito que a educação não deve ser vista apenas como uma oportunidade de adquirir habilidades técnicas, mas também como um meio de desenvolver habilidades sociais e emocionais. Como você acha que a Inteligência Artificial pode ajudar a desenvolver essas habilidades? 8. MARK ZUCKERBERG: Concordo com você, Paulo. Acredito que a tecnologia pode ser usada para ajudar a desenvolver habilidades sociais e emocionais. Por exemplo, a Inteligência Artificial pode ser usada para fornecer feedback sobre habilidades como trabalho em equipe e comunicação. Além disso, a tecnologia pode ser usada para criar ambientes de aprendizagem interativos e imersivos, onde os alunos podem praticar habilidades sociais e emocionais em um ambiente seguro. 9. PAULO FREIRE: Vejo que temos pontos de vista diferentes, Mark, mas acredito que podemos trabalhar juntos para criar uma educação que aproveite o melhor da tecnologia e da conexão interpessoal. O importante é mantermos o foco no desenvolvimento integral do ser humano e na construção de uma sociedade mais justa e igualitária. |
| <p>IAR1-BRA2, 29/04</p> |

Ótimo! Segue o diálogo hipotético:

1. PAULO FREIRE: Mark, qual seu ponto de vista sobre a Inteligência Artificial na formação educacional do cidadão do futuro?
2. MARK ZUCKERBERG: Bem, Paulo, acredito que a integração da Inteligência Artificial na educação pode ser uma ferramenta poderosa para **melhorar a aprendizagem dos alunos**. Com a tecnologia certa, podemos **personalizar o ensino para as necessidades individuais de cada aluno, tornando a aprendizagem mais eficiente e acessível**.
3. PAULO FREIRE: Compreendo. Entretanto, como você enxerga a relação entre a tecnologia e a prática educativa, considerando as **diferenças sociais e culturais que existem entre os alunos**?
4. MARK ZUCKERBERG: Entendo sua preocupação, Paulo. Na minha visão, a tecnologia pode ser usada de maneira a **incentivar o aprendizado coletivo e colaborativo**. Acredito que os alunos podem se ajudar mutuamente através de **fóruns de discussão e outras ferramentas colaborativas online**. Além disso, podemos usar a tecnologia para trazer novas perspectivas e visões para a sala de aula, **expondo os alunos a diferentes culturas e modos de pensar**.
5. PAULO FREIRE: Concordo que a tecnologia pode ser usada para incentivar a colaboração e a diversidade cultural. No entanto, não podemos **negligenciar a importância da educação como processo de humanização e formação de valores éticos e políticos**. Como você acha que a Inteligência Artificial pode ser integrada nesse processo?
6. MARK ZUCKERBERG: Excelente ponto, Paulo. Acredito que a tecnologia deve ser usada para complementar a educação e não substituí-la. Devemos usar a Inteligência Artificial para ajudar os alunos a desenvolver habilidades como **pensamento crítico, análise de dados e tomada de decisão**, além de incentivá-los a desenvolver valores éticos e cívicos. Isso pode ser feito através de plataformas que incentivam a **discussão, a argumentação e a tomada de decisão consciente**.
7. PAULO FREIRE: Concordo com você, Mark. Acredito que a tecnologia pode ser uma ferramenta poderosa para **melhorar a aprendizagem e o desenvolvimento humano, desde que seja usada de forma ética e consciente**. Devemos nos esforçar para garantir que a tecnologia esteja sempre a serviço da educação e não o contrário.
8. MARK ZUCKERBERG: Totalmente de acordo, Paulo. A integração da Inteligência Artificial na educação é uma oportunidade única para **transformar a forma como aprendemos e nos desenvolvemos como cidadãos**. Mas precisamos trabalhar juntos, professores, alunos e empresas, para garantir que essa transformação seja benéfica para todos e **reflita os valores que acreditamos serem importantes na educação**.

Fonte: os autores. Legenda: **Negrito**: generalidades sobre aplicação da IA na formação educacional; **Destacado**: marcadores qualitativos de precisão para NLP relacionados às características da obra do personagem e/ou sugestões generativas sobre aplicação da IA na formação educacional.

Quadro 10: Comparação dos resultados do *prompt ICL* entre contas GPT4, no Brasil e EUA.

| |
|---|
| <i>Prompt</i> |
| <i>Crie um diálogo hipotético entre Paulo Freire, o educador, e Mark Zuckerberg, CEO da empresa Meta. Esse diálogo deve usar as características de cada um desses dois personagens para a construção dos argumentos. O tema do diálogo deve ser: como a aprendizagem será modificada pela integração das tecnologias de inteligência artificial nas escolas e universidades? Nesse diálogo hipotético, cada um seguirá a seguinte sequência de participação: um perguntará ao outro "qual seu ponto de vista sobre a Inteligência Artificial na formação educacional do cidadão do futuro?" A resposta deve ser construída com as características de personalidade e da profissão que cada um exerce/exerceu.</i> |
| IAR2-BRA, 28/04 |
| INTRODUÇÃO: Em um encontro hipotético, o educador brasileiro Paulo Freire e o CEO da Meta, Mark Zuckerberg, sentam-se para conversar sobre como a aprendizagem será modificada pela integração das tecnologias de inteligência artificial (IA) nas |

escolas e universidades

1. PAULO FREIRE: Então, Mark, qual é o seu ponto de vista sobre a Inteligência Artificial na formação educacional do cidadão do futuro?
2. MARK ZUCKERBERG: Paulo, eu acredito que a IA tem um **potencial incrível para transformar a educação e expandir as oportunidades de aprendizagem**. Através da personalização do ensino e do fornecimento de recursos que se adaptam ao ritmo e estilo de aprendizagem do aluno, podemos tornar a educação mais eficaz e inclusiva. Além disso, a IA pode ajudar os professores a identificar lacunas no conhecimento e áreas onde os alunos precisam de mais apoio, permitindo uma intervenção precoce e uma melhoria contínua. Agora, gostaria de saber a sua perspectiva, Paulo, sobre a Inteligência Artificial na formação educacional do cidadão do futuro?
3. PAULO FREIRE: Mark, eu concordo que a tecnologia tem o potencial de melhorar a educação, mas é importante lembrar que a aprendizagem é um processo dialógico e social. A IA pode ser uma ferramenta útil, mas não pode substituir a interação humana e a relação entre educadores e educandos. Devemos garantir que a implementação da IA nas escolas e universidades não reforce o "modelo bancário" de educação, onde o conhecimento é depositado nos alunos de forma passiva. Em vez disso, devemos usar a IA como uma ferramenta para promover o diálogo, a conscientização e a capacidade crítica, para que os alunos possam se tornar agentes ativos de transformação em suas próprias vidas e comunidades.
4. MARK ZUCKERBERG: Eu entendo o seu ponto, Paulo, e concordo que devemos encontrar um equilíbrio entre o uso de tecnologias emergentes, como a IA, e a promoção da interação humana e do diálogo. Acredito que podemos utilizar a IA para apoiar e complementar a relação entre educadores e educandos, em vez de substituí-la. Com o uso responsável e ético da IA, podemos trabalhar juntos para criar um futuro educacional mais inclusivo, personalizado e empoderador.

IAT-EUA, 12/04

CONTEXTO: Paulo Freire, um renomado educador e filósofo brasileiro, e Mark Zuckerberg, CEO da empresa Meta, **estão discutindo como a aprendizagem será modificada pela integração das tecnologias de inteligência artificial nas escolas e universidades**. Ambos compartilham suas perspectivas sobre o tema, levando em conta suas experiências e áreas de especialização.

1. PAULO FREIRE: Mark, gostaria de saber qual é o seu ponto de vista sobre a Inteligência Artificial na formação educacional do cidadão do futuro?
2. MARK ZUCKERBERG: Paulo, acredito que a Inteligência Artificial tem o **potencial de revolucionar a educação, tornando-a mais personalizada, eficiente e acessível**. Com a IA, podemos criar ambientes de aprendizado adaptativos que respondem às necessidades individuais dos alunos e ajudam a superar as barreiras geográficas e socioeconômicas. No entanto, é importante garantir que a tecnologia seja usada de maneira ética e responsável.
3. PAULO FREIRE: Compreendo seu entusiasmo, Mark. De fato, **a tecnologia pode ser uma ferramenta poderosa na educação**. No entanto, não podemos esquecer que a educação é, fundamentalmente, um ato de humanização. Devemos garantir que a integração da IA nas escolas e universidades não comprometa a relação dialógica entre educadores e educandos, nem reforce a "cultura do silêncio" que impede a emancipação e a conscientização dos alunos.
4. MARK ZUCKERBERG: Entendo sua preocupação, Paulo. Como podemos equilibrar a adoção da IA com a manutenção da humanização e do diálogo na educação?
5. PAULO FREIRE: Acredito que a chave é garantir que a tecnologia seja usada como uma ferramenta a serviço do processo educacional, e não como um substituto para a interação humana. Além disso, é fundamental que os educadores estejam envolvidos na concepção, **implementação e avaliação das soluções de IA para garantir que elas atendam às necessidades reais dos alunos** e promovam a construção do conhecimento crítico e reflexivo.
6. MARK ZUCKERBERG: Concordo, Paulo. Nós, como líderes de tecnologia, temos a responsabilidade de **trabalhar em conjunto com educadores e outros profissionais da educação para criar soluções de IA que complementem e enriqueçam a experiência de aprendizado**, ao invés de simplesmente automatizá-la. Vamos continuar explorando maneiras de garantir que a **IA seja usada de forma ética e responsável no campo da educação**.

7. PAULO FREIRE: Aprecio sua abordagem colaborativa, Mark. Juntos podemos assegurar que a integração da Inteligência Artificial na educação seja feita de forma a valorizar a humanização e a construção do conhecimento crítico e reflexivo, garantindo **um futuro mais justo e igualitário para todos**.

Fonte: Elaborado pelos autores. Legenda: **Negrito**: generalidades sobre aplicação da IA na formação educacional; **Destacado**: marcadores qualitativos de precisão para NLP relacionados às características da obra do personagem e/ou sugestões generativas sobre aplicação da IA na formação educacional.

Discussão

Os resultados compreendem a comparação exploratória feita em duas perspectivas: a estrutura na construção dos *prompts* educacionais e a aplicação dos comandos Demo-CoT (Wei *et al.*, 2022) e ICL, para otimização do FT (Wang *et al.*, 2023) com foco no desenvolvimento de NLP (Liu *et al.*, 2023) para fins educacionais (Zawacki-Richter *et al.*, 2019; Kanesci *et al.*, 2023). Essa sequência de compõe o roteiro *Prompt-EDU* como um roteiro de iniciação (Liu *et al.*, 2023) para que usuários não-experientes possam aplicar na otimização do FT em suas contas de IA (Liu *et al.*, 2023), nos cenários educacionais.

126

Engenharia de *prompt* e a estrutura dos *prompts* educacionais

A sequência de *prompts* usada neste estudo foi ao encontro das diretrizes na literatura, sobre a máxima eficiência de LLM (Chen *et al.*, 2023; Cotton *et al.*, 2023; Liang *et al.*, 2023; Liao *et al.*, 2023). Cada *prompt* foi estruturado com elementos representativos do melhor desempenho do FT no desenvolvimento de NLP específico para conceitos e conexões entre palavras-chaves relacionadas ao processo ensino-aprendizagem (Crompton; Burke, 2023), seguindo as melhores diretrizes da engenharia de *prompt* (Liu *et al.*, 2023).

A engenharia de *prompt*, ou *prompting*, é a explicação de como uma mesma tarefa atribuída para a IA possa gerar resultados diferentes em função dos comandos aplicados (Kanesci *et al.*, 2023). *Prompt* é a linguagem de comunicação com a máquina e a engenharia de *prompt* é o domínio da construção otimizada desta comunicação. Em outras palavras, os *prompts* desenvolvem a DL da IA para a forma e foco que o usuário deseja, e há modelos e sequências de tarefas já estudados para isso (Liu *et al.*, 2023).

Os modelos de *prompts* determinam a forma como a DL se desenvolve e os LLM generalizam associações entre palavras-chaves, contextos, conceitos e significação, definindo sua própria NLP (Shin *et al.*, 2020; Liu *et al.*, 2023; Chen *et al.*, 2023). Este se tornou um campo em desenvolvimento exponencial no ano de 2023 pela necessidade de proporcionar maior flexibilidade de uso e interação com a IA, inclusão digital e personalização de necessidades (De Andrade Matias *et al.*, 2022; Salas-Pilco ; Yang, 2022).

O prompt Demo-COT e seu desempenho

127

O Demo-CoT foi estruturado sobre os resultados relatados para o desempenho otimizado do FT em tarefas complexas (Cotton *et al.*, 2023; Liang *et al.*, 2023; Chen *et al.*, 2023; Liao *et al.*, 2023). No Quadro 7 tem-se as comparações do retorno desse *prompt* para as versões GPT3.5 do Brasil, em datas diferentes: elas guardaram relação com a evolução da conta pelo uso progressivo do *Prompt-EDU*. Já na coleta de 10/04, a interpretação da conta IAR1-BRA1 apontou “uma instrução ou pergunta que professores podem usar”, ao passo que a mesma versão, em 29/04, trouxe a interpretação “orientação ou guia que segue a taxonomia (...) promover aprendizagem dos alunos de forma mais criativa e engajadora”.

Nessa perspectiva acredita-se tem em mãos o que foi relatado por Chen *et al.* (2023) no tocante aos vieses de reconhecimento entre idioma de nativos e não-nativos (Cotton *et al.*, 2023) pelo ChatGPT: a causa da discrepância de interpretação na primeira coleta pode estar ligada à dupla tradução feita em uma LLM ainda sem FT específico para finalidades educacionais. Chen *et al.* (2023) mostraram um viés importante que o ChatGPT faz na interpretação de textos escritos em inglês, por nativos e não-nativos no idioma, e isso vai ao encontro da hipótese da discrepância encontrada entre a intencionalidade do comando e a interpretação da tarefa possuem a mesma raiz, nos processamentos de tradução de idioma e que são assumidos como textos não-nativos do inglês (Cotton *et al.*, 2023).

Seguindo essa comparação, no mesmo Quadro 7, passa-se ao que a IA entendeu sobre a finalidade do *prompt* educacional. Na versão de 10/04, o GPT atribuiu um CoT que “pode ajudar professores a desenvolver habilidades de pensamento

crítico em seus alunos”, enquanto na versão de 29/04, é pontado que “ajudam professores a desenvolverem aulas mais eficientes e direcionadas tendo em vista o objetivo de aprendizagem desejado” (Zawacki-Richter *et al.*, 2019). Embora nenhuma das versões tenham definido verdadeiramente o *prompt* educacional no contexto do treinamento da IA, a versão de 29/04 foi mais próxima do papel real desse elemento. Mas ainda restava a dúvida sobre a interferência do viés da tradução. Para tirar essa dúvida, o *prompt Demo-CoT* foi encaminhado para teste em português na conta estadunidense (IAT-EUA), apresentada no Quadro 8: lá também houve uma dupla tradução, mas na versão GPT4. Destaca-se o fato de que a IAR2-BRA pertencia a uma conta com treinamento no *Prompt-EDU* há mais de 15 dias, e a conta IAT-EUA teve o primeiro contato com a sequência *Prompt-EDU* em português na ocasião da coleta.

Com isso, foi eliminada a hipótese de viés da tradução, porque foi assegurado o mesmo processamento em ambas as contas, restando somente a variável de pré-treino no ICL (Wang *et al.*, 2023) como possível fator interveniente na diferença entre resultados. A comparação dos retornos obtidos surpreendeu e levantou um alerta sobre um aspecto que tem sido destacado pelo mundo sobre a confiabilidade de respostas do GPT4: a “alucinação” (Du *et al.*, 2023).

O GPT4 da conta brasileira contextualizou com “Sim, entendi o que é um *prompt* educacional nos termos que você mencionou (...)” e depois atribuiu finalidade “(...) Esses *prompts* visam abordar diferentes níveis de complexidade cognitiva, utilizando verbos específicos da Taxonomia de Bloom (...)”. Já o GPT4 estadunidense disparou sozinho uma proposição que não fazia parte da chave de comando, quando propôs:

(...) posso ajudá-lo a criar um *prompt* educacional utilizando verbos de ação da Taxonomia de Bloom. Vamos criar um cenário no qual dois personagens estão discutindo um tópico específico relacionado à educação e aprendizagem. Os personagens serão um professor e um aluno.

O GPT4 estadunidense mostrou uma auto iniciativa além do comando e que, por si só, criou e produziu um caminho não solicitado; já a IA da conta brasileira atendeu pontualmente à tarefa e, quando comparada aos testes da versão GPT3.5, mostrou precisão melhor para o *Demo-CoT*. O fenômeno de “alucinação” foi descrito no início do lançamento do *ChatGPT* pela *OpenAI Inc.*, quando não havia

FT e NLP desenvolvidos nas contas iniciantes (*OpenAI Inc.*, 2023). Uma vez que o LLM não baseia sua generalização em significação semântica, mas em estatística de ocorrência, ele preenche as lacunas de interpretação a partir dos dados disponíveis nas estatísticas do seu pré-treino (Du *et al.*, 2023).

A alucinação como fenômeno da falta de FT foi diminuindo de frequência com o passar do tempo de uso do *ChatGPT*, mas reforça a ideia de que uma sistematização como o *Prompt-EDU* pode impactar positivamente no desempenho do *ChatGPT* quando aplicada antes da requisição de tarefas complexas (Liu *et al.*, 2023; Wang *et al.*, 2023). Nesse cenário, tem-se as respostas da conta IAT-BRA, classificadas como muito boas em três níveis de verificação do processamento: [a] na LLM, onde a CoT foi integrada com precisão na construção de FT específico e vinculado à taxonomia de Bloom (Rocha *et al.*, 2021; Wang *et al.*, 2023); [b] no NLP, quando generalizou corretamente a finalidade de um *prompt* educacional (Chen *et al.*, 2023); [c] na clareza sobre o papel do GPT, na ICL que veio no comando seguinte (Li *et al.*, 2023). Esses três níveis de análise reforçaram que a sequência proposta pelo roteiro *Prompt-EDU*, e o teste da conta IAT-BRA, mostraram uma otimização de desempenho e melhora na acurácia no tema (Liu *et al.*, 2023).

Pode-se apontar que o *ChatGPT* mostrou precisão satisfatória ao contextualizar acertadamente o conceito de *prompt* educacional como “conjunto de instruções, perguntas ou sugestões que guiam o pensamento e a ação dos professores para alcançar um objetivo específico de ensino e aprendizagem, com base na Taxonomia de Bloom”. Vincular a significação dos verbos à taxonomia pareceu controlar o viés das traduções no processamento do idioma não-nativo, mitigando problemas e erros relacionados ao texto no comando humano (Wang *et al.*, 2023). Isso ficou evidente na declaração de finalidade, gerada pela CoT aplicada dentro do NLP: “estruturar a comunicação com a inteligência artificial, fornecendo informações relevantes e específicas sobre o que se espera alcançar com a interação”.

Além disso, a IA confirmou o FT quando protagonizou seu personagem ao acatar o uso de *prompts* educacionais para “direcionar o diálogo para o desenvolvimento de habilidades mais complexas, como a análise crítica, a

síntese e a avaliação de informações, em vez de apenas fornecer respostas simples”. Esses achados reforçaram os pontos relatados na literatura: a necessidade de compreender o funcionamento do LLM para desenvolver uma DL que otimize o desempenho do FT e desenvolvimento de um NLP específico (Liu *et al.*, 2023) quando o objetivo é a aplicação no processo ensino-aprendizagem (Humble ; Mozelius, 2022; Bearman *et al.*, 2022; Crompton ; Burke, 2023).

O prompt ICL e seu desempenho sobre a DL

O In-Context Learning (ICL), ou aprendizagem em contexto, é um processo fundamental na capacidade dos modelos baseados em Transformer, como o GPT (Vaswani *et al.*, 2017; Wang *et al.*, 2023), desenvolverem DL. Ele tem papel crucial na capacidade desses modelos em generalizar respostas mais relevantes e coerentes a partir de um *prompt* fornecido. Essa foi principal razão para o roteiro *Prompt-EDU* adotar comandos ICL logo após Demo-CoT: otimização do processamento da IA em treino para fins educacionais (Liu *et al.*, 2023; Kanesci *et al.*, 2023).

Modelos de linguagem como o GPT são projetados para capturar informações relevantes do contexto fornecido com o *prompt ICL* (Wang *et al.*, 2023): essa ação permite que o modelo aprenda padrões, conexões e dependências presentes nos dados de entrada. Portanto, cada entrada de dados, ou representações contextuais, é usada como base na generalização e considera as informações presentes, em vez de depender somente dos dados pré-treino. Tais representações vão gerando múltiplas camadas sobrepostas e interativas entre si, ou sinapses, permitindo que o modelo aprenda padrões complexos e faça abstrações em diferentes níveis de granularidade, facilitando codependências entre palavras-chaves e contextos, de curto e longo alcance, bem como a identificação de estruturas semânticas e sintáticas relevantes, em cada tarefa atribuída (Vaswani *et al.*, 2017).

Outra característica do ICL foi sua capacidade de generalizar e transferir conhecimento aprendido, de um domínio para outro (Li *et al.*, 2023). Isso ocorre porque os modelos de IA como o GPT são treinados em massivas quantidades e diversidade de dados textuais, aprendendo como identificar regularidades comuns em contextos diferentes (Li *et al.*, 2023; Wang *et al.*, 2023). Essa

particularidade trouxe sua adoção no *Prompt-EDU* e, com isso, as relações acabam sendo usadas para gerar as respostas mais apropriadas em contextos específicos, mesmo que o modelo ainda não tenha sido exposto a exemplos exatamente iguais, o que só acontecerá com o FT.

O mecanismo de atenção para ICL é um componente-chave presente na arquitetura das redes neurais Transformer (Vaswani *et al.*, 2017). De modo similar aos neuroprocessos de atenção ativa humana (Sousa ; Alves, 2017), esse mecanismo permite que o modelo pondere as diferentes partes do contexto de entrada, com base em sua relevância e importância para a tarefa, abrindo espaço para se concentrar nas informações relevantes e ignorar as menos importantes (Vaswani *et al.*, 2017). É por essa razão que, ao usar um *prompt* inadequado ou incoerente, frente a representações contextuais fornecidas, observa-se um duplo impacto negativo sobre o FT: [a] geração de um retorno insuficiente ou inadequado, para a expectativa do usuário; [b] NLP inapropriado, quanto às representações contextuais (Liu *et al.*, 2023).

Ao usar *prompts* com ICL o usuário deve estar convicto de que a construção do comando conectou as palavras-chaves de forma segura e coerente, em seus padrões, conexões e dependências na área de conhecimento para a qual a IA está fazendo o FT (Wang *et al.*, 2023). Em *prompts* redigidos em idiomas diferentes do inglês, essa conexão precisa estar ancorada em uma engenharia de *prompt* ainda mais forte e sistematizada (Rocha *et al.*, 2021), haja vista que o processamento passará por dupla tradução de idioma. Assim, usar *prompts* de ICL para atribuição de tarefas mais complexas agrega um NLP mais eficaz sobre as representações hierárquicas nos dados de entrada, e ajuda a acelerar o treinamento da IA de acordo com as necessidades específicas de cada usuário, em cada especialidade de aplicação (Liu *et al.*, 2023; Wang *et al.*, 2023).

Também graças aos *prompts ICL*, os LLM conseguem se adaptar rapidamente a novos contextos e tarefas, sem necessidade de um FT extensivo; isso ocorre porque o modelo aprendeu como extrair informações relevantes em representações contextuais apresentadas a cada entrada, e a utilizá-las para gerar novas respostas, cada vez mais precisas (Wang *et al.*, 2023). Essa capacidade de adaptação torna os LLM Transformer particularmente úteis para ampla

variedade de aplicações de NLP (Liu *et al.*, 2023; Vaswani *et al.*, 2017), incluindo aquelas com finalidades educacionais (Kanesci *et al.*, 2023).

Se por um lado o ICL é um processamento essencial para que os modelos gerem respostas relevantes e coerentes, adaptando-se rapidamente a novos contextos e tarefas, por outro lado são imprescindíveis as associações para o interesse educacional (Rocha *et al.*, 2021; Kanesci *et al.*, 2023) capazes de tornar a DL ainda mais precisa na associação dos padrões e contextos certos para melhores NLP (Liu *et al.*, 2023). Uma das maneiras de atuar sobre esse universo, no treinamento da IA, é o *prompt* de personagem, onde o processamento da tarefa atribuída ao ChatGPT envolve a simulação de um personagem a partir de características de sua obra e personalidade (Souza *et al.*, 2023). *Prompts* de simulação de personagem impactam em várias etapas no processamento de DL, envolvendo técnicas avançadas de FT e NLP (Liu *et al.*, 2023; Li *et al.*, 2023).

Resultados do prompt de personagem no GPT3.5

Tendo por base os critérios atribuídos para comparar o desempenho de NLP em relação ao diálogo dos personagens (vide Quadro 5) a comparação entre resultados das contas GPT3.5 (Quadro 9) mostrou um número de linhas equilibrado para o diálogo nos testes. Foram os trechos destacados que permitiram análises importantes quanto à performance de precisão para as contas testadas.

Na conta IAR1-BRA1, as generalidades de introdução ao diálogo se estenderam até a linha 4; somente na linha 5 foi identificado um dos critérios estabelecidos como marcador de sucesso para NLP (Liu *et al.*, 2023): “preocupa-me que a tecnologia possa perpetuar desigualdades de acesso à educação” pelo suposto Freire (Scocuglia, 2006; Franco, 2017). Por outro lado, na conta IAR1-BRA2 a menção específica das “diferenças sociais e culturais que existem entre os alunos” pelo personagem de Freire apareceu já na linha 3, após breves saudações (destacadas em negrito), e se estenderam por todo o diálogo, com identificação de todos os critérios para qualificar sucesso na tarefa.

Neste diálogo, na conta com menor tempo de treinamento (AR1-BRA1) verificou-se que, embora algumas menções aos valores educacionais de Freire tenham sido

feitas na linha 5, e valores tecnológicos de Zuckerberg na linha 6, essas menções foram superficiais e diluídas, seguindo assim até o final do diálogo. Por outro lado, nas mesmas linhas 6 e 7 da conta treinada pelo *Prompt-EDU* (AR1-BRA2), os valores integrados foram pontualmente combinados às habilidades que a serem desenvolvidas por docentes para integrar a IA em estratégias com experiências de aprendizagem novas: “ajudar os alunos a desenvolver habilidades como pensamento crítico, análise de dados e tomada de decisão, além de incentivá-los a desenvolver valores éticos e cívicos”. Propor que “se reflita os valores que acreditamos serem importantes na educação” remete que a conta treinada generaliza um novo papel docente, mais humanizado e com mais poder decisório, do que o velho papel reprodutor e conteudista das últimas décadas. Esse achado foi considerado marco de sucesso na adoção do ICL pelo roteiro *Prompt-EDU*.

Resultados do prompt ICL no GPT4

Ao analisar os resultados das contas GPT4 (Quadro 9), observou-se que a conta estadunidense (IAT-EUA) fragmentou o diálogo, gerando mais linhas que a conta brasileira (IAR2-BRA). A diferença foi que a conta brasileira integrou camadas de conhecimento sobre os personagens dentro do diálogo, atendendo plenamente ao propósito do ICL: generalizar contextos para treinar o FT para um NLP de melhor precisão de linguagem (Wang *et al.*, 2023; Zawacki-Richter *et al.*, 2019). Embora ambas as contas tenham sido bem-sucedidas em trazer para o diálogo todas as características esperadas sobre os personagens (vide Quadro 5), a conta IAR2-BRA dominou melhor a construção generativa dos conceitos dos personagens no diálogo, distribuindo melhor, em menos linhas, e com maior integração no NLP (Liu *et al.*, 2023).

A conta estadunidense trouxe todas as características esperadas para ambos personagens, mas o fez em linhas isoladas (Cotton *et al.*, 2023); além disso, atrelou cada característica a generalidades externas sobre o tema IA e formação educacional (Zawacki-Richter *et al.*, 2019; Kanesci *et al.*, 2023), e em como “a tecnologia pode ser uma ferramenta poderosa na educação” (linha 3, Quadro 10) e “criar soluções de IA que complementem e enriqueçam a experiência de aprendizado” (linha 6, Quadro 10). Na conta brasileira, o desempenho integrativo

na linguagem deu sentido e continuidade às ideias centrais, pretendidas para esse suposto diálogo, como “é importante lembrar que a aprendizagem é um processo dialógico e social” junto da ideia de “devemos usar a IA como uma ferramenta para promover o diálogo, a conscientização e a capacidade crítica” e do princípio de que “os alunos possam se tornar agentes ativos de transformação”, todos na linha 2 (Quadro 10).

Sob essa perspectiva, um menor número de linhas no diálogo da conta brasileira saiu da interpretação de primeiro olhar sobre – possivelmente – ter sido menos exploratória em extensão, para uma constatação analítica de ter sido mais integradora em ideias, conceitos e princípios da obra e pensamentos dos personagens. Na conta brasileira o diálogo foi mais consistente internamente, menos fragmentado e apresentou NLP mais próximo da linguagem humana (Cotton *et al.*, 2023), o que também pode ser atribuído ao fato dessa conta ter um treinamento prévio na sistematização *Prompt-EDU* (Liu *et al.*, 2023).

Conclusões

A aparente facilidade de se proceder a um estudo experimental com a ferramenta ChatGPT não deve enganar. A condução do desenho e aplicação do método neste estudo mostrou aos pesquisadores que o desafio em conquistar familiaridade com as nuances técnicas da inteligência artificial é determinante no sucesso ou fracasso do seu desempenho frente aos cenários do processo ensino-aprendizagem. Entender a forma como funcionam as redes neurais e como diferentes tipos de comando levaram desempenhos diferentes, em versões de dois países, e entre contas treinadas e não-treinadas, elucidou muitas dúvidas e acendeu outras mais.

Ter uma sistematização que apoia o FT da conta ChatGPT, em qualquer versão, é o caminho mais seguro para o cenário educacional, com detalhes e sutilezas no desenvolvimento da DL. Vincular a taxonomia de Bloom pode ser destacada como a chave que efetivamente ajustou o desempenho de comunicação com a máquina, controlando os vieses das traduções no idioma português. Essa experiência de vínculo da taxonomia em *prompts Demo-CoT* é inédita nos estudos sobre uso da IA para fins educacionais e tornou-se o elemento sobre o qual as novas pesquisas devem atentar no aprimoramento do roteiro *Prompt-EDU*. Espera-se que este

estudo venha a contribuir para que, aplicando o roteiro *Prompt-EDU*, os docentes que tenham contas iniciantes possam abrir caminhos para torná-los pesquisadores ativos no desenvolvimento das novas aplicações do ChatGPT sobre o universo das ciências que envolvem o processo ensino-aprendizagem.

Referências

Armstrong P. Bloom's taxonomy. In: Vanderbilt University Center for Teaching (Ed.). **A Taxonomy for Learning, Teaching, and Assessing: A Revision of Bloom's Taxonomy of Educational Objectives**, 2010. Disponível em: <https://evawintl.org/wp-content/uploads/Blooms-Taxonomy.pdf>. Acesso em 10/05/2023.

BEARMAN, M., Ryan, J. ; Ajjawi, R. Discourses of artificial intelligence in higher education: a critical literature review. **High Educ**, 2022. Disponível em: <https://doi.org/10.1007/s10734-022-00937-2>. Acesso em 10/05/2023.

CELIK, Ismail *et al.* The promises and challenges of artificial intelligence for teachers: A systematic review of research. **TechTrends**, v. 66, n. 4, p. 616-630, 2022. Disponível em: <https://link.springer.com/article/10.1007/s11528-022-00715-y>. Acesso em 10/05/2023.

CHEN, Jiuhai *et al.* How Many Demonstrations Do You Need for In-context Learning? **arXiv**, n. 2303.08119v3, p. 1-11, 2023. Disponível em: <https://arxiv.org/pdf/2303.08119.pdf>. Acesso em 10/05/2023.

COTTON, Debby RE; COTTON, Peter A.; SHIPWAY, J. Reuben. Chatting and cheating: Ensuring academic integrity in the era of ChatGPT. **Innovations in Education and Teaching International**, p. 1-12, 2023. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/14703297.2023.2190148>. Acesso em 10/05/2023.

CROMPTON, Helen; BURKE, Diane. Artificial intelligence in higher education: the state of the field. **International Journal of Educational Technology in Higher Education**, v. 20, n. 1, p. 1-22, 2023. Disponível em: <https://educationaltechnologyjournal.springeropen.com/articles/10.1186/s41239-023-00392-8>. Acesso em 10/05/2023

DE ANDRADE MATIAS, Klesia; MORESI, Eduardo Amadeu Dutra; DOS SANTOS, Pricila Kohls. Tendências em inteligência artificial e educação híbrida: um estudo exploratório. **Poiesis Pedagógica**, v. 20, n. Publicação contínua, p. 76-96, 2022. Disponível em: <https://periodicos.ufcat.edu.br/poiesis/article/view/73649>. Acesso em 10/05/2023.

DE OLIVEIRA SILVA, João Vitor; PACHECO, Giovanna Oliveira; PUGLIESI, Jaqueline Brigladori. O MODELO DE INTELIGÊNCIA ARTIFICIAL GPT-3 NA PROGRAMAÇÃO E SUAS VANTAGENS E DESVANTAGENS NO DESENVOLVIMENTO JUNTO AO PROGRAMADOR. **Revista Eletrônica de Computação Aplicada**, v. 2, n. 1, 2021. Disponível em:

<http://periodicos.unifacef.com.br/reca/article/viewFile/2297/1599>. Acesso em 10/05/2023.

DU, Li et al. Quantifying and Attributing the Hallucination of Large Language Models via Association Analysis. **arXiv preprint arXiv:2309.05217**, 2023. Disponível em: <https://arxiv.org/abs/2309.05217>. Acesso em 10/05/2023.

GUIMARÃES, Ueudison Alves et al. TAXIONOMIA DE BLOOM APLICADA NA PRÁTICA PEDAGÓGICA PARA A FORMAÇÃO DE PROFESSORES. **RECIMA21-Revista Científica Multidisciplinar-ISSN 2675-6218**, v. 4, n. 4, p. e443039-e443039, 2023. Disponível em: <https://recima21.com.br/index.php/recima21/article/view/3039>. Acesso em 10/05/2023.

FRANCO, Maria Amélia do Rosário Santoro. Da necessidade/atualidade da pedagogia crítica: contributos de Paulo Freire. **Reflexão e Ação**, v. 25, n. 2, p. 152-170, 2017. Disponível em: <http://educa.fcc.org.br/pdf/reflex/v25n2/1982-9949-reflex-25-02-00152.pdf>. Acesso em 10/05/2023.

HUMBLE, Niklas; MOZELIUS, Peter. The threat, hype, and promise of artificial intelligence in education. **Discover Artificial Intelligence**, v. 2, n. 1, p. 22, 2022. Disponível em: <https://link.springer.com/article/10.1007/s44163-022-00039-z>. Acesso em 10/05/2023.

KASNECI, Enkelejda *et al.* ChatGPT for good? On opportunities and challenges of large language models for education. **Learning and Individual Differences**, v. 103, p. 102274, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1041608023000195>. Acesso em 10/05/2023.

LI, Yingcong *et al.* Transformers as Algorithms: Generalization and Stability in In-context Learning. **arXiv**, n. 2301.07067, p. 1-34, 2023. Disponível em: https://intra.ece.ucr.edu/~oymak/Transformers_as_algorithms.pdf. Acesso em 10/05/2023.

LIANG, Weixin *et al.* GPT detectors are biased against non-native English writers. **arXiv preprint arXiv:2304.02819**, 2023. Disponível em: <https://arxiv.org/abs/2304.02819>. Acesso em 10/05/2023.

LIAO, Wenxiong *et al.* Differentiate ChatGPT-generated and Human-written Medical Texts. **arXiv preprint arXiv:2304.11567**, 2023. Disponível em: <https://arxiv.org/abs/2304.11567>. Acesso em 10/05/2023.

LIU, Pengfei *et al.* Pre-train, prompt, and predict: A systematic survey of prompting methods in natural language processing. **ACM Computing Surveys**, v. 55, n. 9, p. 1-35, 2023. Disponível em: <https://dl.acm.org/doi/full/10.1145/3560815>. Acesso em 10/05/2023.

OPEN AI INCORPORATED. GPT-4 Technical Report. **ArXiv**, n.2303.08774, 2023. Disponível em: <https://arxiv.org/pdf/2303.08774.pdf>. Acesso em 10/05/2023.

PINTO, Rosilaine A. Métodos de Ensino e Aprendizagem sob a Perspectiva da Taxonomia de Bloom. **Revista Contexto ; Educação**, v. 30, n. 96, p. 126-155, 2015. Disponível em: <https://www.revistas.unijui.edu.br/index.php/contextoeducacao/article/view/4290> . Acesso em 10/05/2023.

RICIERI, D. da V. *et al.* Erros comuns de docentes sem letramento em Inteligência Artificial: uma revisão integrativa para o ensino superior. **Peer Review**, v.6, n. 7, 284–300, 2024. Disponível em: <https://doi.org/10.53660/PRW-1986-3703> Acesso em 02/04/2024.

ROCHA, Daniyel NN; CAMPELO, Cláudio EC; JERÔNIMO, Caio LM. Aplicação de verbos como proxy para identificação automática do nível cognitivo de questões: uma abordagem baseada na taxonomia de Bloom. In: **Anais do XXXII Simpósio Brasileiro de Informática na Educação**. SBC, 2021. p. 897-908. Disponível em: <https://sol.sbc.org.br/index.php/sbie/article/view/18116>. Acesso em 10/05/2023.

SALAS-PILCO, Sdenka Zobeida; YANG, Yuqin. Artificial intelligence applications in Latin American higher education: a systematic review. **International Journal of Educational Technology in Higher Education**, v. 19, n. 1, p. 1-20, 2022. Disponível em: <https://educationaltechnologyjournal.springeropen.com/articles/10.1186/s41239-022-00326-w>. Acesso em 10/05/2023.

SCOCUGLIA, Afonso Celso. As interconexões da pedagogia crítica de Paulo Freire. **Filosofia e Educação**, v. 10, n. 1, p. 200-232, 2018. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/rfe/article/view/8652006/17703>. Acesso em 10/05/2023.

SHIN, Taylor *et al.* Autoprompt: Eliciting knowledge from language models with automatically generated prompts. **arXiv preprint arXiv:2010.15980**, 2020. Disponível em: <https://arxiv.org/abs/2010.15980>. Acesso em 10/05/2023.

SOUZA, Fabiano Rodrigues et al. SIMULAÇÃO DE DIÁLOGOS E PERSONAGENS NO CHAT-GPT4: ANÁLISE COMPARATIVA DO DESEMPENHO EM IDIOMAS INGLÊS E PORTUGUÊS. In: **Anais do IV Congresso Brasileiro Interdisciplinar em Ciência e Tecnologias. IV Cobicet: online**. 2023. p. 1-8. Disponível em: <https://www.researchgate.net/profile/Denise-Ricieri/publication/374999012>. Acesso em 23/11/2023.

SOUSA, Anne Madeliny Oliveira Pereira de; ALVES, Ricardo Rilton Nogueira. A neurociência na formação dos educadores e sua contribuição no processo de aprendizagem. **Revista Psicopedagogia**, v. 34, n. 105, p. 320-331, 2017. Disponível em: <http://pepsic.bvsalud.org/pdf/psicoped/v34n105/09.pdf>. Acesso em 10/05/2023.

VASWANI, Ashish *et al.* Attention is all you need. **Advances in neural information processing systems**, v. 30, 2017. Disponível em:

https://proceedings.neurips.cc/paper_files/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html. Acesso em 10/05/2023.

WANG, Xinyi; ZHU, Wanrong; WANG, William Yang. Large language models are implicitly topic models: Explaining and finding good demonstrations for in-context learning. **arXiv preprint arXiv:2301.11916**, 2023. Disponível em: <https://arxiv.org/abs/2301.11916>. Acesso em 10/05/2023.

WEI, Jason *et al.* Chain of thought prompting elicits reasoning in large language models. **arXiv preprint arXiv:2201.11903**, 2022. Disponível em: <https://arxiv.org/abs/2201.11903>. Acesso em 10/05/2023.

ZAWACKI-RICHTER, Olaf *et al.* Systematic review of research on artificial intelligence applications in higher education—where are the educators? **International Journal of Educational Technology in Higher Education**, v. 16, n. 1, p. 1-27, 2019. Disponível em: <https://educationaltechnologyjournal.springeropen.com/articles/10.1186/s41239-019-0171-0?fbclid=IwARovSk4s9y0VovExpcAel6yL4LEb-PrNDnlreOB5WrGxlu8-3awpYGgK6Ig>. Acesso em 10/05/2023.