



ACESSANDO E ENDEREÇANDO A APRENDIZAGEM SIGNIFICATIVA NA ERA DOS GRANDES MODELOS DE LINGUAGEM

ACCESSING AND ADDRESSING MEANINGFUL LEARNING IN THE ERA OF LARGE LANGUAGE MODELS

Felipe José Coelho Pedroso

Mestrado em Engenharia Elétrica pela Universidade Federal do Espírito Santo

felipejcpedroso@gmail.com

Susiléa Abreu dos Santos Lima

Doutoranda em Administração pela FGV

sabreu@uvv.br

Emerson Scheidegger

Doutorando em Finanças na FGV-RJ

emerson.scheidegger@uvv.br

Resumo – Os avanços técnicos e tecnológicos associados aos recursos de hardware e software impulsionaram significativos avanços na área de Inteligência Artificial, Aprendizagem de Máquina e Processamento de Linguagem Natural. A partir de 2017 observamos a popularização e adoção dos grandes modelos de linguagem (LLM) em diversos contextos e aplicações, com o Chat GPT se posicionando como maior expoente. Em 2023 já são inúmeros desenvolvedores, modelos, propósitos e abordagens apresentados à comunidade científica e com perspectiva de persistência do aquecimento de pesquisas nessa área. As mudanças trazidas por esses modelos possuem características de inovação de ruptura e sua adoção pode beneficiar estudantes e professores no processo de ensino aprendizagem. Os LLMs se entrelaçam com a Teoria da Aprendizagem Significativa (TAS) à medida em que contribuem para colocar o aluno como protagonista do processo de aprendizagem permitindo que esse estabeleça relações de novos conteúdos com os conteúdos adquiridos previamente. Os LLMs impactam a aprendizagem representacional, a aprendizagem de conceitos e a aprendizagem proposicional, permitindo uma customização e

individualização do ensino. Os modelos podem ser aplicados em tarefas como tutor e assistente virtual, tradução, pesquisa, análise gramatical e ortográfica, resumo e sumarização de conteúdos, geração e correção de tarefas e interações e feedbacks em tempo real. Portanto, é possível acessar e endereçar a aprendizagem significativa fazendo uso dos grandes modelos de linguagem. Apesar dos inúmeros pontos positivos, a adoção dos LLMs no ensino possui limitações e desafios.

Palavras-chave: Aprendizagem Significativa; Inteligência Artificial; Processamento de Linguagem Natural; Grandes Modelos de Linguagem; Chat GPT.

Abstract – Artificial intelligence, machine learning, and natural language processing continue to advance due to technical and technological developments related to hardware and software resources. By 2017, we had observed large language models (LLM) becoming a growing trend in a variety of contexts and applications, with Chat GPT emerging as the main example. The scientific community has already been presented with a vast number of developers, models, purposes, and approaches in 2023, and research in this area is projected to keep increasing heat up. These models' changes exhibit disruptive innovation traits, and their adoption can benefit students and teachers in the teaching-learning process. LLMs are intertwined with the Theory of Meaningful Learning as they contribute to placing the student as the protagonist of the learning process, allowing him to establish new content relationships with previously learned material. By enabling customization and individualization of teaching, LLMs have an impact on representational learning, concept learning and propositional learning. The models can be applied to a variety of tasks, including tutoring and virtual assistance, translation, research, grammar and spelling analysis, content summarization, task generation and correction, and real-time interactions and feedback. Therefore, it is possible to access and address meaningful learning by making use of the large language models. Despite the numerous strengths, the adoption of LLMs in teaching has limitations and challenges.

Keywords: Meaningful Learning; Artificial Intelligence; Natural Language Processing; Large Language Models; Chat GPT.

1. Introdução

Os processos de ensino aprendizagem estão em constante alteração visando acompanhar as transformações tecnológicas, sociais e culturais de seus participantes. Com esse propósito, busca-se alinhamento entre as metodologias, tecnologias, espaços educacionais, recursos e equipamentos de modo a atingir os

resultados pretendidos no processo de ensino aprendizagem. Nesse sentido, a aceleração exponencial percebida no desenvolvimento, disponibilização e acesso às novas capacidades de software e hardware exigem um olhar diferente, rápido e assertivo para inserção e utilização desses novos recursos no ensino. Com isso, pretende-se garantir que esses novos elementos sejam utilizados em consonância com os objetivos de aprendizagem e que sejam utilizados desde já, maximizando e capitaneando as possibilidades e aproveitando as janelas de oportunidade trazidas por inovações com características de ruptura, isto é, que apresentam mudança radical de funcionalidade, descontinuidade dos padrões técnicos anteriores e redefinição nas expectativas dos usuários (NAGY; SCHUESSLER; DUBINSKY, 2016). Podemos enxergar esses novos elementos como agentes impactantes no processo de ensino aprendizagem, uma vez que esse é responsável pela aquisição ou modificação de um comportamento a partir de experiências e, as tecnologias são facilitadoras de novas experiências.

A aprendizagem é regida por nove princípios (ALEXANDER; SCHALLERT; REYNOLDS, 2009): é mudança; é inevitável, essencial e ubíqua; pode sofrer resistência; pode ser desvantajosa; pode ser tanto tácita e acidental quanto consciente e intencional; é delimitada pela nossa humanidade; se refere tanto a um processo quanto a um produto; é diferente em diferentes pontos no tempo e; é interacional. Esse processo de mudança da compreensão e do comportamento ocorre nos ambientes familiares, escolares, no trabalho e outros contextos (ORMROD, 2014). Ademais, conhecimentos, habilidades e atitudes podem ser adquiridos, modificadas, reforçados, desenvolvidos e/ou aprofundados em processos de aprendizagem por meio de orientações, observações e experiências. Portanto, a construção de valores está diretamente relacionada ao processo de aprendizagem.

O ensino está em constante mudança e a Inteligência Artificial (IA) se posiciona como um dos grandes agentes de transformação tecnológico no ensino contemporâneo. Sua capilaridade e capacidade de atuar como produto ou componente, como meio ou fim, a insere como ferramenta relevante tanto para os discentes quanto para os docentes. Em particular, os grandes modelos de linguagem (ou, do inglês, *Large Language Models* – LLMs), trouxeram uma ruptura

na transição entre os anos 2022 e 2023. Os LLMs são, em essência, programas de computador capazes de processar, entender e gerar linguagem humana a partir da utilização de técnicas de IA. Esses modelos se diferem dos anteriores porque foram construídos utilizando um grande volume de dados e, como consequência, conseguem operar de forma mais complexa e com textos mais coerentes, coesos e relevantes. Dessa maneira, são capazes de realizarem e interagirem em uma ampla gama de tarefas relacionadas à linguagem, tais como, processos de conversação, tradução, resumo, sumarização, classificação e resposta a perguntas. Há uma grande expectativa por parte dos usuários em razão das funcionalidades e das possibilidades latentes nessa área. Como ferramenta de ensino aprendizagem, os LLMs também podem ser utilizados como tutores e assistentes virtuais, capazes de interagir e ofertar feedbacks em tempo real de forma individualizada e customizada em atendimento as particularidades demandadas ou apresentadas pelo ser humano em interação.

Diante desse cenário favorável à inserção de novas tecnologias relacionadas à IA no contexto educacional e nas metodologias e processos de ensino aprendizagem, esse artigo busca discutir e endereçar os desdobramentos dos LLMs na aprendizagem significativa. Sua organização se dá na seguinte forma: na próxima seção apresentamos uma revisão da literatura sobre aprendizagem significativa e grandes modelos de linguagem, considerando a IA e sua utilização na educação. A terceira seção discute o acesso e o endereçamento da aprendizagem significativa utilizando os grandes modelos de linguagem sob as perspectivas dos alunos e professores. A quarta seção apresenta as conclusões.

2. Revisão de Literatura

A aprendizagem significativa se entrelaça cada vez mais com a IA à medida em que a tecnologia oferece oportunidades para individualização e personalização do ensino, tornando o processo de ensino aprendizagem mais aderente às necessidades dos alunos e expandindo as possibilidades das práticas docentes. Diante desse cenário, os grandes modelos de linguagem se posicionam como

verdadeiros catalizadores para o processo de aprendizagem.

2.1. Aprendizagem Significativa

A Teoria da Aprendizagem Significativa (TAS) origina no pensamento do psicólogo norte-americano David Paul Ausubel. Sua teoria tem como foco os processos mentais que ocorrem na aprendizagem e fornece uma contraposição ao aprendizado puramente conteudista e mecanicista. Para Ausubel, a apreensão de um novo conhecimento se dá quando o aprendiz relaciona o conteúdo novo com os conteúdos adquiridos previamente. A este processo Ausubel dá o nome de aprendizagem significativa. O processo de aprendizagem é dito “significativo”, segundo o autor, devido a interação entre o conhecimento prévio e o conhecimento novo que ajudará a apreensão de conhecimentos do aprendiz a partir de um entendimento do porquê se está aprendendo algo (MOREIRA; MASINI, 1982).

A abordagem da TAS é calcada em um processo ativo, cumulativo e centrado no aluno pois a aprendizagem torna-se significativa na medida em que implica necessariamente em modificar e expandir conceitos que já estão consolidados na cognição do sujeito. Desta forma, agindo ativamente na construção de novos saberes, o sujeito estabelece novas relações que envolve a ativação de conhecimentos prévios para a fixação de novos conhecimentos. Isso permite a descoberta de relações entre os novos conceitos e a sua aplicação na resolução de problemas. Devido a este papel de centralidade, o sujeito carece de três condições básicas, nas quais se destacam a questão lógica, a auto disposição e a automotivação (NUNES; SILVEIRA, 2011).

Em relação a lógica, entende-se que o conteúdo a ser aprendido deve possuir uma lógica que lhe forneça significado. Em relação a disposição, o sujeito precisa agir de forma consciente e não arbitrária para relacionar o conteúdo novo com os conteúdos que já fazem parte previamente de sua estrutura cognitiva, que consiste em uma rede de conceitos organizados de modo hierárquico de acordo com o grau de abstração e generalização. E, finalmente, o sujeito necessita de vontade de aprender ou automotivação para o aprendizado. Afinal, nas palavras do autor:

[...]o conhecimento é significativo por definição. É o produto significativo de um processo psicológico cognitivo (“saber”) que envolve a interação entre ideias “logicamente” (culturalmente) significativas, ideias anteriores (“ancoradas”) relevantes da estrutura cognitiva particular do aprendiz (ou estrutura dos conhecimentos deste) e o “mecanismo” mental do mesmo para aprender de forma significativa ou para adquirir e reter conhecimentos (AUSUBEL, 2003, s/p).

Ausubel (2003), destaca três tipos de aprendizagem significativa: representacional; de conceitos e; proposicional. A aprendizagem representacional é relativa à atribuição de significados a símbolos. Ela ocorre quando o sujeito estabelece uma relação de familiaridade a um símbolo referente, não conhecendo o seu conceito. Já a aprendizagem de conceitos ocorre a partir da aprendizagem representacional. É neste tipo de aprendizagem que há o estabelecimento de relações do símbolo com um evento, com um objeto ou suas características, formando assim, a representação de algo. Por fim, na aprendizagem proposicional ocorre a ressignificação dos conceitos, gerando novas ideias a partir de novas proposições.

Para da Silva Ruas & Maciel (2020), há um entendimento de que a aprendizagem significativa tem um papel importante no ponto de vista emancipatório do aluno porque ela trabalha tanto no enriquecimento de sua estrutura cognitiva como do ponto de vista da memorização posterior e sua utilização para experimentar novas aprendizagens, já que o aluno se encontra neste processo como um protagonista. Assim, trabalha tanto para a autonomia do pensamento quanto para ação.

Sob a perspectiva da aprendizagem significativa, as tecnologias digitais de informação e comunicação (TDIC) podem ser uma importante ferramenta dentro do contexto das metodologias ativas que privilegiam a autonomia do sujeito tendo como princípio a imersão no processo de aprendizagem, mesmo que assistida pelo professor (DA SILVA RUAS; MACIEL, 2020).

O uso de novas tecnologias, que instigam a participação ativa, gera possibilidades temáticas integrativas. Isso promove a organização e a elaboração das informações e permite a aplicação de instrumentos cognitivos como a analogia, a comparação, a síntese e a generalização. Neste sentido, podemos entender este uso da mesma forma como nos propõe da Silva Ruas & Maciel (2020): como o sujeito encontra-se envolvido, imerso no processo e o seu papel é ativo, a abordagem com uso de tecnologias novas permite a interação entre o aluno e a sua construção de conhecimento. Portanto, mostra-se pertinente à construção da autonomia e à formação de caráter emancipatório.

Dentre as tecnologias emergente, esse artigo busca discutir os impactos dos grandes modelos de linguagem no processo da aprendizagem significativa.

2.2. Grandes Modelos de Linguagem

O período entre o final do ano 2022 e início de 2023 marcou a expansão da utilização dos grandes modelos de linguagem com o lançamento do Chat GPT pela OpenAI, uma empresa de pesquisa e implantação de IA (OpenAI, 2022). O Chat GPT é um modelo de linguagem natural com capacidade de criar e estabelecer diálogos coerentes e com respostas relevantes decorrente da aprendizagem de padrões e nuances no processo de comunicação. O modelo registrou 100 milhões de usuários ativos com apenas dois meses de lançamento, tornando-se o aplicativo de consumo com, até então, o maior crescimento da história (HU, 2023). A popularização do Chat GPT transcendeu as fronteiras de usuários da academia e pesquisa científica, impactando um público heterogêneo e fomentando sua adoção em diferentes contextos. E assim, tornou-se relevante e posicionou os grandes modelos de linguagem como importantes meios ou fins. Isto é, os modelos podem ser a solução para atingir um objetivo final ou podem ser um dos componentes de uma solução.

Os LLMs são aplicações de IA, termo cunhado no Workshop de Dartmouth, em 1956, para discussão de temas relacionados a computadores automáticos, redes neurais e utilização da linguagem pelas máquinas (MCCARTHY et al., 2006). Dessa

forma, a discussão incluiu especialistas de áreas multidisciplinares como Ciência da Computação, Engenharia, Física, Matemática, Psicologia, dentre outras. Existem diversas definições para IA que perpassam desde definições formais por meio de equação matemática (LEGG; HUTTER, 2007) até escopos mais amplos que tratam a IA como a capacidade da máquina de pensar e/ou agir como ser humano (NILSSON, 1998; RUSSELL; NORVIG; DAVIS, 2010). Face as distintas abordagens, optamos por definir a IA em função das suas características relacionadas à: capacidade de aprender com o meio e seu contexto, habilidades para resolução de problemas, desenvolvimento de estruturas cognitivas e organização em torno de objetivos (MEDEIROS, 2018). Ou seja, a IA é capaz de interagir em ambientes complexos por meio do processamento de informações e comunicação com outros humanos e/ou máquinas. Além disso, espera-se que os resultados das interações passadas sejam utilizados para aprimoramento nas novas interações. A IA também pode ser percebida como um termo guarda-chuva e, conseqüentemente, pode ser dividida em diversas subáreas. Dentre essas, temos particular interesse na Aprendizagem de Máquina (ou, do inglês, *Machine Learning* – ML) e no Processamento de Linguagem Natural - PLN (ou, do inglês, *Natural Language Processing* - NLP), as bases fundamentais dos grandes modelos de linguagem.

A aprendizagem de máquina se dá por meio de algoritmos e técnicas que visam conferir à máquina (e.g. computador, robô) a aprendizagem necessária para realizar tarefas e/ou atingir objetivos. Na máquina, a aprendizagem ocorre quando há uma melhora de performance em variáveis mensuráveis (RAY, 2019). Os principais tipos de aprendizagem de máquina são: supervisionada, não supervisionada e por reforço. Na aprendizagem supervisionada a máquina produz padrões e hipóteses a partir de um conjunto de dados de treinamento, tornando-se capaz de realizar a classificação de novos dados de entrada a partir das inferências decorrentes da etapa de treinamento (SINGH; THAKUR; SHARMA, 2016). Por isso, depende de um conjunto de dados pré-rotulados, isto é, com suas classes previamente conhecidas. Em contraste, a aprendizagem não supervisionada, não requer informações prévias sobre os dados, pois a máquina deve aprender a representar e organizar os dados de maneira a refletir seus padrões estatísticos (WILSON; KEIL, 1999). Por fim, a aprendizagem por reforço utiliza interações

dinâmicas entre um agente inteligente e o meio para moldar a tomada de decisão (KAELBLING; LITTMAN; MOORE, 1996). A cada interação, o agente recebe estímulos positivos (recompensas) ou negativos (penalidades) pelo seu comportamento visando a maximização da recompensa acumulada ao longo do tempo. A aprendizagem de máquina possibilita armazenamento de informações, aquisição de habilidades, conhecimento e reconhecimento de padrões. Portanto, confere à máquina a capacidade de tomar decisões, de responder a estímulos e de realizar previsões.

O PLN lida com problemas no domínio da linguagem humana-computador, sendo uma extensão dos campos de IA e linguística. Tanto as áreas de computação e processamento de sinais, quanto a área de linguística possuem uma longa trajetória até a era dos grandes modelos de linguagem. No entanto, os grandes modelos de linguagem começaram a surgir a partir de 2017 com a apresentação de uma nova arquitetura baseada em mecanismos de atenção denominada *Transformer* (VASWANI et al., 2017). Os mecanismos de atenção trabalham de forma dinâmica onde cada elemento (e.g. palavra) apresentado à entrada da rede é ponderado de acordo com sua relevância para a tarefa proposta. O processamento de cada palavra leva em consideração tanto o contexto trazido pelas demais palavras quanto as suas posições (*encoding*). Dessa forma, “presta-se atenção” nos elementos-chave de acordo com o objetivo almejado (e. g. tradução, sumarização, classificação ou resposta a pergunta). O modelo de atenção apresenta uma importante ruptura em relação às técnicas anteriores, pois permite que sejam consideradas dependências de longo alcance entre as palavras. Outro ponto fundamental é que a estrutura da rede, composta pelos Transformers, é paralelizável computacionalmente. Ou seja, além da arquitetura proposta possuir uma abordagem técnica inovadora, ela é ideal para utilização das GPUs (Unidades de Processamento Gráfico). Isso confere ao modelo proposto maior velocidade de processamento e flexibilidade em relação aos modelos anteriores. A arquitetura *Transformer* foi um catalisador para aquecimento da área.

A partir de 2018 surgiram vários LLMs em sequência que implicaram em significativos avanços para a área de PLN. Por isso, torna-se apropriado considerar

que esse ano marcou a transição dos modelos anteriores para os LLMs. O ELMo - Embeddings from Language Models, trouxe uma representação vetorial para as palavras que consideram tanto o contexto das palavras que aparecerem antes (à esquerda) quanto as que aparecem depois (à direita) da palavra em análise (PETERS et al., 2018). Para isso, utiliza uma rede neural bidirecional, um grande volume de dados de treinamento e uma aprendizagem profunda, isto é, com arquitetura mais complexa e com mais parâmetros. Esse estágio de PLN é um importante avanço em relação a modelos anteriores como o Word2Vec, que eram baseados em contagens de palavras/expressões. Ademais, o ELMo se posiciona como um modelo pré-treinado, isto é, um modelo com uma visão e representação generalista dos dados podendo, posteriormente, ter um ajuste fino (ou, do inglês, *fine tuning*) para realizar tarefas específicas. O ajuste fino se dá por meio de alterações dos parâmetros das camadas finais das redes neurais pré-treinadas ao serem apresentados novos dados de treinamento para fins específicos. Então, torna-se possível realizar tarefas que não são generalistas como, por exemplo, classificar sentenças ou sentimentos. Destaca-se que essa abordagem permite a especialização do modelo em uma tarefa sem a necessidade de treinar o modelo por completo, o que demanda a maior parte do esforço computacional e exige a grande base de dados. O ELMo atingiu estado da arte em diferentes problemas de PLN e bases de dados.

Ainda em 2018, foi apresentado o GPT (Generative Pre-trained Transformer), um modelo de linguagem baseado em Transformer com 117 milhões de parâmetros (RADFORD et al., 2018). O modelo generativo também é generalista e treinado com uma base de dados não rotulada no intuito de formar uma base de conhecimento das palavras e suas relações e contextos. Sua robustez permite uma geração de textos capaz de manter coesão e coerência. Em seguida, o modelo foi ajustado para realizar tarefas específicas. Essa consciência de orientação à tarefa torna o GPT flexível e adaptável, provendo respostas mais precisas e coerentes. Em sua apresentação, o GPT atingiu estado da arte em 9 das 12 tarefas e bases testadas (OPENIA, 2018).

O modelo seminal BERT (*Bidirectional Encoder Representations from*

Transformers) também foi apresentado no ano de 2018 (DEVLIN et al., 2019) e, tal como os dois modelos anteriores, trouxe significativo avanço para o PLN ao introduzir uma nova arquitetura. O BERT considera tanto as palavras à esquerda quanto à direita de cada palavra em análise nos mecanismos de atenção. Os modelos anteriores utilizavam apenas o contexto à esquerda. Duas tarefas estratégicas são empregadas para melhorar o modelo durante o pré-treinamento: uso de máscara de palavras e classificação de próxima sentença. No primeiro são apresentadas sentenças ao modelo com palavras ocultas (mascaradas) e o modelo deve ser capaz de preencher as lacunas corretamente. Na segunda, são apresentadas duas sentenças ao modelo e, esse, deve ser capaz de inferir se as frases são sequenciais ou não. Observe que as estratégias e arquitetura proposta conferem ao modelo uma compreensão semântica e sintática mais profunda. O BERT estabeleceu estado da arte em 11 diferentes tarefas de NLP, incluindo classificação de sentimentos e pergunta-resposta. Os autores apresentam dois modelos BERT com diferentes tamanhos. O BERT_{BASE} possui 110 milhões de parâmetros, 12 cabeças de atenção e 12 blocos de Transformers enquanto o BERT_{LARGE} possui 340 milhões de parâmetros, 16 cabeças de atenção e 24 blocos de Transformers. O código fonte do BERT é de acesso livre (GOOGLE RESEARCH, 2018) e a base de dados de treinamento possui 3,3 bilhões de palavras.

O GPT-2, com seus 1,5 bilhões de parâmetros na arquitetura Transformer, foi apresentado em 2019 com significativos avanços em relação aos demais modelos de linguagem (RADFORD et al., 2019). O estado da arte foi alcançado em 7 dos 8 bancos de dados testados e o modelo foi capaz de realizar tarefas como sumarização, compreensão de texto e resposta a perguntas mesmo sendo treinado de forma não supervisionada. No ano seguinte, surge o GPT-3 com 175 bilhões de parâmetros (BROWN et al., 2020), valor superior a dez vezes o praticado em qualquer modelo anterior. Destaca-se que esse modelo apresentou avanços na capacidade de realizar tarefas mesmo sem fazer uso de ajustes finos. O GPT-3 conseguiu performar em atividades avançadas em PLN como, no teste de Cloze, desembaralhando palavras e realizando operações aritméticas de três dígitos. Tal como o GPT-2, o GPT-3 avança na capacidade de elaboração de textos, criando sequências que apresentam uma grande dificuldade de serem distinguidas de textos

criados por humanos.

Em 2021, a OpenAI lança o DALL-E, outro modelo de linguagem Transformer, mas que foi treinado utilizando pares de imagens e textos, conferindo-lhe a capacidade de gerar imagens de saída a partir de textos de entrada (OPENAI, 2021). Dessa forma, o DALL-E é capaz de gerar imagens inéditas a partir de uma descrição textual por meio das relações aprendidas em seu treinamento (Figura 1).



Figure 1 - Imagens criadas com o DALL-E (OPENAI, 2021) utilizando como principal argumento de entrada (prompt) “inteligência artificial auxiliando um aluno a aprender na sala de aula”.

Entre o final do ano de 2022 e início do ano 2023, os LLMs se popularizaram e atingiram níveis de utilização em larga escala e inclusão de usuários fora da área acadêmica e pesquisa com o lançamento do Chat GPT (OPENAI, 2022). Seu funcionamento é baseado no InstructGPT (OUYANG et al., 2022) que promove um maior alinhamento entre a resposta do modelo e a resposta esperada pelo usuário. Para tal, é realizado um ajuste fino utilizando aprendizagem por reforço e por meio do feedback – resposta – do humano no processo de treinamento. Ou seja, durante a fase de treinamento o Chat GPT utilizou a avaliação do usuário humano as respostas geradas para adequar o comportamento nas próximas respostas geradas.

O GPT-4 foi lançado em 2023 como um modelo multimodal, pois é capaz de receber imagens de entrada, além de textos, para a geração dos textos de saída (OPENAI, 2023). O modelo foi utilizado em mais de 30 testes desenvolvidos para

avaliar conhecimentos acadêmicos ou profissionais de humanos em diversas áreas (e. g. matemática, biologia, física, economia, química, estatística, história e programação) e teve desempenho equivalente a humanos na maioria. Em alguns testes atingiu performance superior a 90% dos humanos.

Apesar do Chat GPT ter sido o modelo que popularizou a utilização dos grandes modelos de linguagem, outros desenvolvedores e outros modelos tem surgido nos últimos anos incluindo, mas não limitados a: LaMDA, BARD e PaLM (Google); Gato, Gopher e Sparrow (DeepMind); LLaMA, OPT-IML e BlenderBot-3 (Meta); Megatron-Turing NLG (NVIDIA); Ernie 3.0 Titan e ERNIE Bot (Baidu); PanGu-Alpha (Huawei); Bing e BioGPT (Microsoft); WuDao 2.0 (Beijing Academy of Artificial Intelligence); BLOOM (Hugging Face); AlexaTM (Amazon); Tongyi Qianwen (Alibaba); Jurassic-2 (AI21 Labs); Claude (Anthropic). Há um elevado número de desenvolvedores de LLMs, indicando um forte aquecimento da área e uma tendência a novas inovações de ruptura.

Avaliando o histórico e o estágio atual da IA no contexto de NLP, podemos detectar uma transição de uma era inicial com foco em desenvolvimento técnico e tecnológico para a era dos grandes modelos de linguagem. Nessa última, o desenvolvimento é continuado, mas há uma maior orientação para as aplicações dado suas características inovadoras.

2.3. IA como ferramentas educacionais

A utilização da IA no contexto educacional tem crescido bastante nos últimos anos, principalmente depois de 2012. O crescente interesse deve-se principalmente ao aumento das conquistas dos efeitos da IA no desempenho e nos resultados da aprendizagem. Entre os temas mais estudados estão: mineração de dados educacionais, tutoria inteligente para escrita e leitura, tutoria inteligente para K12 e educação especial, redes neurais artificiais e representação gráfica e conexão do conhecimento (CHEN et al., 2022). O K12 é uma expressão norte-americana para designar o intervalo, em anos, abrangido pelo ensino primário e secundário na educação dos EUA

O avanço da IA no cotidiano das pessoas, alerta sobre a importância de educar os alunos sobre o funcionamento dessas tecnologias desde as séries iniciais. Apesar dos desafios da complexidade do domínio, países como China e Austrália estão integrando IA no currículo obrigatório do ensino fundamental e médio, levando para sala de aula assuntos como como aprendizado de máquina e reconhecimento de padrões. Para alcançar alunos em séries iniciais, é fundamental envolver os professores no processo para identificar estratégias pedagógicas adequadas ao desenvolvimento (OTTENBREIT-LEFTWICH et al., 2022).

Quando se fala no avanço de tecnologias de IA para educação, pode-se destacar: (1) incorporação da tecnologia aos aplicativos para facilitar o ensino e aprendizagem e (2) mineração de dados educacionais, processamento em linguagem natural, redes neurais artificiais e computação afetiva para analisar dados em grande escala de vários cenários educacionais, tais como ensino de idiomas, educação especial e salas de aulas invertidas. Para Chen et al. (2022), as oito áreas promissoras dentro da inteligência artificial aplicada na educação são:

1. linguagem natural para ensino de idiomas
2. robôs educacionais para educação em IA
3. mineração de dados educacionais para previsão de desempenho
4. redes neurais para avaliação de ensino
5. Sistemas de recomendação para aprendizagem personalizada
6. aprendizagem colaborativa com suporte computacional para análise do discurso
7. computação afetiva para detecção de emoções do aluno
8. sistemas tutores inteligentes para educação especial

Chen et al. (2022) destacam que, para que seja possível evolução da IA na educação, principalmente para realização de um aprendizado personalizado, é necessário utilização dos dados do aluno de maneira clara, para não colocar em risco a proteção de dados confidenciais do alunado e aumentar a consideração da

IA pelos professores fornecendo suporte para que os instrumentos pedagógicos com base em IA possam ser utilizados de maneira eficiente.

3. Acessando e Endereçando a TAS com LLM

Os LLMs possuem interseções em todos os nove princípios que regem a aprendizagem elencados por Alexander, Schallert, Reynolds (2009) porque são vetores para promoção de mudança; são inevitáveis no contexto tecnológico; possuem resistência em sua adoção; trazem desvantagens e limitações; são utilizados de forma explícita ou implícita; é treinado com uma base de dados geradas por humanos; podem ser meios ou fins; são mutáveis e flexíveis e; são capazes de estabelecer relações coesas e continuadas (Quadro 1).

Princípios que regem a aprendizagem		Interseções com os Grandes Modelos de Linguagem
1	É mudança	São vetores para promoção de mudança
2	É inevitável, essencial e ubíqua	São inevitáveis no contexto tecnológico
3	Pode sofrer resistência	Possuem resistência em sua adoção
4	Pode ser desvantajosa	Possuem desvantagens e limitações
5	Pode ser tanto tácita e acidental quanto consciente e intencional	São utilizados de forma explícita ou implícita
6	É delimitada pela nossa humanidade	São treinados com bases de dados geradas por humanos
7	Se refere tanto a um processo quanto a um produto	Podem ser meios ou fins
8	É diferente em diferentes pontos no tempo e	São mutáveis e flexíveis
9	É interacional	São capazes de estabelecer relações coesas e continuadas

Quadro 1 – Interseções entre os princípios que regem a aprendizagem e os grandes modelos de linguagem.

Professores e alunos podem ter as atividades de ensino aprendizagem impactadas pelo desenvolvimento técnico e tecnológico apresentados pelas ferramentas de IA e PLN nos últimos anos. E, em especial, os grandes modelos de linguagem podem ser aplicados no contexto educacional e contribuir diante da perspectiva da TAS.

3.1. LLMs: perspectiva do discente

Segundo a OCDE - Organização para a Cooperação e Desenvolvimento Econômico, as oportunidades de aprendizagem diversificadas com o aprendiz como protagonista do processo de aprendizagem podem melhorar a qualidade da educação (OECD, 2021). Quando o indivíduo é posto no centro do processo, contribui-se com seu empoderamento e motivação para uma aprendizagem continuada. Dentre as principais habilidades desejadas para o século XXI podemos destacar as habilidades transversais que incluem capacidade de comunicação, trabalho em equipe, organização, pensamento crítico, resolução de problemas complexos, liderança e apresentação, além das habilidades de tecnologia da informação ou tecnologias digitais. Nesse cenário podemos incluir os grandes modelos de linguagem como ferramentas (coadjuvantes) para os alunos (protagonistas) utilizarem no desenvolvimento de sua trilha de aprendizagem.

Em primeiro lugar, é oportuno pontuar que os modelos de linguagem se apresentam uma solução com diversas qualidades, dentre as quais podemos destacar: flexibilidade; adaptabilidade; capacidade de lidar com particularidades e capacidade de interagir com individualidades. Isso confere aos LLMs uma diversa gama de possibilidades e cenários para suas aplicações. Destacamos a aplicação dos LLMs como assistentes virtuais de estudo em diferentes propósitos: tradutor, corretor ortográfico e gramatical, ferramenta de resumo e sumarização, geração de insights, análise de dados, pesquisa, programação e geração de apresentações. Além disso, os LLMs são escaláveis, ou seja, cada aluno pode ter um se houver recursos e estrutura.

Os LLMs, em geral, são treinados com base de dados que incluem diferentes idiomas e nos quais o modelo consegue interagir. Com isso, a barreira do idioma pode ser superada. O modelo pode operar como um eficiente tradutor para o aluno, além de permitir acesso aos conhecimentos que advém de diferentes idiomas que, a princípio, não estariam acessíveis para quem não compreendesse o idioma no qual foi documentado. Um aluno do Brasil poderá, por exemplo, ter uma resposta baseada em um padrão treinado com fontes escritas em alemão, coreano, chinês, japonês, russo, espanhol etc., sem que o aluno seja letrado nesses idiomas. Os modelos também são capazes de lidar com barreiras relacionadas a gramática considerando aspectos sintáticos e gramaticais. O computador ou a máquina são capazes de transpor dificuldades potenciais geradas por erros no processo de comunicação causados por inadequação de apresentação de forma ou conteúdo.

O processo de pesquisa também é impactado pelos LLMs, pois o grande volume de dados e parâmetros utilizados permite geração de conteúdo sobre diferentes tópicos. Ressalta-se, no entanto, que os modelos são geradores de textos baseados em dados e padrões estatísticos e, portanto, não compreendem e raciocinam acerca de um texto como um ser humano. Ainda que a máquina gere respostas coerentes e coesas, ainda não constitui uma inteligência na concepção humana. Ou seja, no estágio atual não devem ser fontes de pesquisa, mas sim ferramentas de suporte a pesquisa. A máquina poderá fornecer, por exemplo, nomes de artigos, periódicos, anos de publicação, autores, DOI e até mesmo links (falsos) para acesso ao artigo, pois, na verdade, ela gera um padrão de palavras e estrutura coerente e coeso em relação ao conteúdo da base de treinamentos. No entanto, não há compromisso com a veracidade. A coerência e coesão são resultados do conhecimento adquirido no treinamento, onde aprende-se que um DOI tem uma sequência de números e um link inicia com “www”, por exemplo. Existem modelos treinados com bases de dados especificamente proveniente de trabalhos científicos, como o Consensus, um “mecanismo de pesquisa educacional especializado e que usa processamento de linguagem natural para fornecer instantaneamente *insights* científicos agregados de fontes revisadas por pares” (OLSON, 2022). Nesse caso, os LLMs podem acessar conteúdo com validade.

Todas as interações podem ocorrer de forma personalizada, a depender do

estímulo fornecido pelo aluno. Os estímulos personalizados podem incluir restrições ou comandos como “explique de forma simples” ou “explique como se eu fosse um especialista”. Também podem fazer parte do escopo do comando o tamanho do texto de saída gerado: “explique de forma simples em dois parágrafos”. Essa particularização permite uma abordagem gradual e visões múltiplas, se assim for conveniente. Portanto, os modelos de linguagem podem se adaptar as necessidades do usuário. Por exemplo, alguns alunos possuem melhor experiência no ensino através de conteúdos apresentados de forma direta e/ou sucinta.

Assistentes virtuais com LLMs possuem uma capacidade muito além de responder a perguntas, pois sua capacidade de memória e manutenção do contexto em uma interação permite que suas respostas sejam forjadas baseadas no histórico das interações e, não somente na última. Isso confere contexto e coerência na relação homem-máquina.

Outra possibilidade para os modelos de linguagem se dá na correção e geração de tarefas. O aluno pode demandar questões relativas ao conteúdo que se deve avaliar a aprendizagem, pode avaliar a profundidade de seu entendimento ao interagir com a máquina e, ainda, poderá extrapolar para conteúdo não abordado.

A produtividade e organização dos estudos também podem se beneficiar dos LLMs à medida em que esses oferecem procedimentos e estruturação para as estratégias de aprendizagem. Pode-se estabelecer, por exemplo, ordem cronológica para conteúdos e elaboração de itens.

Também podemos utilizar os LLMs no contexto de conteúdos técnicos e específicos. Os modelos são treinados com diferentes bases e dados, aprendendo as relações dos seus elementos. Os LLMs que foram treinados com conteúdos técnicos como programação de computadores, possuem capacidade de aprender as relações lógicas e estruturas estabelecidas nos programas. Com isso, o aluno também poderá fazer uso de LLMs nesses conteúdos técnicos. Nesse caso, poderá criar códigos, tirar dúvidas sobre erros e fazer consultas a utilização de funções e bibliotecas de forma ágil, interativa e produtiva.

Por fim, mas não limitado a esses itens, podemos aplicar os LLMs para inferir relacionamento entre temas e conteúdo, condição essencial para a aprendizagem

significativa. A seguir, apresentaremos os resultados de aplicações utilizando o Chat GPT em sua arquitetura GPT-3.5.

i) Tradução e orientação para tarefas multi-idiomas

Comando: Traduza para o português: "*A transistor is a semiconductor device used to amplify or switch electrical signals and power.*"

Resposta: Um transistor é um dispositivo semicondutor usado para amplificar ou alternar sinais elétricos e energia (OPENAI, 2023).

ii) Pesquisa com considerações específicas para saída

Comando: Fale mais sobre os transistores em 200 caracteres

Resposta: Os transistores são dispositivos semicondutores que amplificam ou comutam sinais elétricos e de potência. Eles são essenciais para circuitos eletrônicos avançados e foram fundamentais para a revolução tecnológica do século XX (OPENAI, 2023).

iii) Customização de dificuldade adaptada ao usuário

Comando: Explique, sucintamente, o que é um transistor como se eu fosse uma criança.

Resposta: Um transistor é como um botão mágico que ajuda os brinquedos eletrônicos a funcionarem melhor, como se fosse um botãozinho que liga e desliga a luz da sua lanterna, por exemplo. Sem ele, muitos brinquedos eletrônicos não funcionariam direito (OPENAI, 2023)!

Comando: Explique, com o menor número de palavras possível, o que é um transistor. Explique como se eu fosse um estudante de pós-graduação.

Resposta: Dispositivo semicondutor amplificador/chaveador elétrico. Fundamental em circuitos eletrônicos avançados (OPENAI, 2023).

iv) Análise gramatical e ortográfica

Comando: Verifique a ortografia e gramática de: "amanhã eu fui na loja".

Resposta: A frase contém dois erros de gramática e ortografia. A forma correta seria: "Amanhã eu vou à loja". A correção envolve as seguintes mudanças:

O tempo verbal foi deve ser alterado para o futuro, no caso o verbo ir, ficando "eu vou".

A palavra "loja" não existe na língua portuguesa, o correto seria "loja".

Utilização da preposição adequada, no caso "à" para indicar a direção (OPENAI, 2023).

v) Resumo e sumarização

Comando: Resuma [texto sobre transistores com 319 palavras e extraído da Wikipedia

Resposta: [91 palavras] O transistor é um dispositivo semicondutor usado para amplificar ou trocar sinais eletrônicos e potência elétrica. É composto de material semicondutor com pelo menos três terminais para conexão a um circuito externo. Julius Edgar Lilienfeld patenteou um transistor de efeito de campo em 1926, mas o primeiro dispositivo praticamente implementado foi um transistor de contato pontual inventado em 1947 pelos físicos estadunidenses John Bardeen, Walter Brattain e William Shockley. O transistor revolucionou o campo da eletrônica e abriu caminho para rádios, calculadoras e computadores menores e mais baratos, entre outras coisas (OPENAI, 2023).

vi) Geração de tarefas

Comando: Quero aprender mais sobre transistores. Me apresente uma lista com 5 itens, em ordem crescente de dificuldade, que devo responder para testar meus conhecimentos.

Resposta: Claro! Aqui está uma lista com 5 perguntas em ordem crescente de dificuldade para testar seus conhecimentos sobre transistores: O que é um

transistor? Qual é a diferença entre um transistor NPN e um transistor PNP? O que é ganho de corrente em um transistor e como é calculado? O que é polarização de um transistor e por que é importante? Quais são as principais aplicações dos transistores na eletrônica (OPENAI, 2023)?

vii) Correção de tarefas

Comando: Para a pergunta 2 (da resposta anterior “Qual é a diferença entre um transistor NPN e um transistor PNP?”), avalie a resposta: tipo de material utilizado no processo de dopagem.

Resposta: A resposta está parcialmente correta, mas é um pouco simplista. A diferença entre um transistor NPN e um transistor PNP não se limita apenas ao tipo de material utilizado no processo de dopagem, mas também envolve a disposição dos materiais dopados e das camadas de material semicondutor. Em um transistor NPN, há duas camadas de material semicondutor tipo N dopado com uma camada de material semicondutor tipo P no meio. Em um transistor PNP, ocorre o oposto, com duas camadas de material semicondutor tipo P dopado e uma camada de material semicondutor tipo N no meio. Dessa forma, a resposta pode ser considerada parcialmente correta, mas seria mais completa se incluísse informações adicionais sobre a disposição dos materiais dopados e das camadas de material semicondutor nos transistores NPN e PNP (OPENAI, 2023).

viii) Relacionamento entre diferentes variáveis e/ou conteúdos

Comando: Qual a relação entre transistores e GPUs?

Resposta: As GPUs (Graphics Processing Units) modernas, assim como outros componentes eletrônicos, utilizam transistores como blocos de construção fundamentais. Os transistores são usados para amplificar e controlar sinais elétricos que permitem que as GPUs realizem cálculos complexos necessários para renderização de imagens e outras tarefas gráficas intensivas. As GPUs modernas contêm milhões e até bilhões de transistores, tornando possível o desempenho avançado que esses dispositivos oferecem (OPENAI, 2023).

ix) Organização e produtividade

Comando: Apresente uma lista com a sequência cronológica a ser estudada para se aprender os principais pontos sobre transistores de junção bipolar.

Resposta: Segue abaixo uma lista com a sequência cronológica sugerida para o estudo dos principais pontos sobre transistores de junção bipolar:

1. Introdução à eletrônica básica e teoria de semicondutores
2. Estudo dos materiais semicondutores (silício, germânio) e dopagem
3. Características dos materiais semicondutores dopados (tipo P e tipo N)
4. Compreensão do funcionamento de um diodo semicondutor
5. Introdução ao transistor bipolar de junção (BJT)
6. Teoria básica do BJT (regiões de operação, características elétricas)
7. Configurações básicas de amplificadores com BJT (emissor comum, base comum e coletor comum)
8. Análise e projeto de amplificadores com BJT
9. Modelos de pequenos sinais para transistores BJT
10. Aplicações práticas de transistores BJT em eletrônica analógica e digital

Esta sequência pode variar de acordo com o nível de conhecimento prévio do estudante e o objetivo do estudo (por exemplo, se é para fins acadêmicos ou profissionais). É importante lembrar que o estudo de transistores de junção bipolar requer conhecimentos prévios em eletrônica básica e teoria de semicondutores (OPENAI, 2023).

x) Avaliação de resultados mantendo coerência e coesão

Comando: Na sequência, vou apresentar uma "pergunta" e a "resposta" que formulei. Avalie criticamente o resultado.

Resposta: Claro, pode enviar a pergunta e a resposta para que eu possa avaliar (OPENAI, 2023).

Comando: Pergunta: "Quais as principais aplicações dos transistores de junção bipolar?" Resposta: "operar como chave aberta e fechada nos modos de corte e saturação."

Resposta: A resposta apresentada é correta, já que os transistores de junção bipolar são amplamente utilizados em eletrônica para operar como chave em diferentes modos. No modo de corte, o transistor opera como uma chave aberta, enquanto no modo de saturação, ele opera como uma chave fechada. Além disso, os transistores de junção bipolar também podem ser utilizados como amplificadores de sinais, entre outras aplicações (OPENAI, 2023).

xi) Elaboração de perguntas

Comando: Elabore 3 perguntas para avaliar minha compreensão sobre o assunto "dopagem de semicondutores".

Resposta:

1. O que é dopagem em semicondutores e qual é o seu objetivo?
2. Quais são os dois tipos de dopagem que podem ser realizados em semicondutores?
3. Como a dopagem afeta as propriedades eletrônicas de um semicondutor? (OPENAI, 2023).

xii) Interação em conteúdos técnicos de Programação de Computadores

Comando: Apresente um código em python capaz de verificar se um número é par. Chame a variável de numero_entrada e a função de testa_se_par. Apresente e avalie um exemplo.

Resposta: Claro! Segue abaixo o código em Python para verificar se um número é par:

```
def testa_se_par(numero_entrada):  
    if numero_entrada % 2 == 0:  
        return True  
    else:  
        return False  
  
# Exemplo de uso  
  
numero = 4  
if testa_se_par(numero):  
    print(f"{numero} é par")  
else:  
    print(f"{numero} é ímpar")
```

Neste exemplo, definimos uma função chamada `testa_se_par` que recebe um número como entrada. Dentro da função, verificamos se o número é divisível por 2 (ou seja, se é par) utilizando o operador módulo `%`. Se o resultado da divisão for 0, o número é par e a função retorna `True`. Caso contrário, o número é ímpar e a função retorna `False`.

Em seguida, utilizamos a função `testa_se_par` para verificar se o número 4 é par ou ímpar. Como o número é par, o código imprimirá a mensagem "4 é par" (OPENAI, 2023).

É importante ressaltar que a capacidade de trabalhar em tempo real torna os LLMs ainda mais eficientes no processo de ensino-aprendizagem. O constante alinhamento e relacionamento de conteúdos novos com os anteriores tendo o aluno como protagonista torna o processo de aprendizagem significativo e duradouro, pois oferece soluções personalizadas e individualizadas.

3.2. LLMs: Perspectiva do docente

De acordo com Campello et al (2023), a capacidade de integrar novos conteúdos às informações anteriores e aplicar criativamente o conhecimento será

uma habilidade cada vez mais importante para o sucesso escolar e acadêmico. Isso terá implicações nas atividades em sala de aula, nos procedimentos de avaliação dos alunos, nos instrumentos utilizados, no estudo individual e em muitos outros aspectos da educação. A capacidade de acessar e processar informações não será mais suficiente, pois a aplicação criativa do conhecimento será cada vez mais valorizada.

Por outro lado, a extraordinária capacidade dos LLMs para realizar tarefas complexas no campo da educação tem gerado sentimentos conflitantes entre os educadores. Alguns o veem como o futuro do ensino e da aprendizagem, bem como da pesquisa educacional, enquanto outros o enxergam como uma ameaça e um potencial fim para a maioria das atividades educacionais, que poderia tornar professores e alunos preguiçosos e com pouca ou nenhuma habilidade analítica (BAIDOO-ANU; OWUSU ANSAH, 2023).

De acordo com Baidoo-Anu e Owusu (2023), a utilização de LLMs oferece aos docentes uma série de benefícios, tais como: a avaliação automatizada de redações, que permite a identificação de características relevantes em redações bem escritas e o fornecimento de feedback semelhante ao de avaliadores humanos, permitindo que os professores se dediquem a outras atividades; a tradução de idiomas, possibilitando uma maior acessibilidade dos dados a um público mais amplo; a criação de experiências interativas de aprendizado, em que os alunos podem interagir com um tutor virtual em uma conversa, promovendo a aprendizagem interativa; e a criação de sistemas de aprendizagem adaptativos, que ajustam seus métodos de ensino de acordo com o progresso e desempenho do aluno, caracterizando a aprendizagem adaptativa.

Baidoo-Anu e Owusu (2023) relatam que os modelos generativos também apresentam limitações em relação à interação humana, compreensão limitada, viés nos dados de treinamento, falta de criatividade, dependência de dados, falta de compreensão contextual, capacidade limitada de personalizar a instrução e preocupações com privacidade e segurança de dados. Eles não conseguem fornecer o mesmo nível de interação pessoal que um professor ou tutor real, o que pode ser desvantajoso para alunos que necessitam de conexões mais pessoais com

seus professores. Além disso, os autores reforçam que os modelos generativos são baseados em padrões estatísticos e não têm uma verdadeira compreensão dos conceitos que estão sendo ensinados. Eles também são altamente dependentes dos dados nos quais são treinados e podem apresentar viés se os dados não forem diversos o suficiente. A falta de criatividade e a incapacidade de entender profundamente o contexto também são limitações, assim como a capacidade limitada de personalização da instrução. Ainda, há preocupações com a privacidade e segurança dos dados que são gerados e usados pelos modelos generativos na educação

4. Conclusões

Os grandes modelos de linguagem evoluíram em uma escala sem precedentes a partir de 2017 e não há sinais de que essa expansão de usuários e aplicações arrefecerá em um curto prazo. Ao mesmo tempo, a tecnologia construída até o momento possui elementos que trouxeram inovações e ruptura. Posto isso, os LLMs se posicionam como importantes ferramentas habilitadoras para a aprendizagem significativa. Os LLMs impactam a aprendizagem representacional, a aprendizagem de conceitos e a aprendizagem proposicional.

4.1. Entrelaçamento entre ATS e LLMs

Os LLMs democratizam o acesso à informação a alunos e professores ao romper as barreiras decorrente de diferenças de idiomas. Ao mesmo tempo, permite acesso a um grande volume de conhecimento intrínseco em seu modelo que foi treinado com uma grande e diversa base de dados. A aprendizagem significativa também pode ser atingida ao expor o usuário a diferentes pontos de vistas e com diferentes apresentações do mesmo conteúdo, além de permitir feedbacks e interações personalizadas e individualizadas em tempo real. Destaca-se que a capacidade de operar em tempo real confere aos LLMs uma importante característica: flexibilidade e adaptabilidade, tornando o contexto e o conteúdo

relevantes para o usuário, bem com apresentado de forma personalizada, individualizada e adequada ao usuário e propósito estabelecido.

Assim, o aluno pode acessar inicialmente os LLMS utilizando sua própria linguagem e conhecimentos e obter resultados iniciais que poderão ser refinados sob demanda em um processo ativo e cumulativo. Em um processo centrado no aluno, a cada iteração com o LLMS, ele utilizará os conhecimentos prévios como elemento de fixação de conhecimentos novos construindo-os colaborativamente com a ferramenta de forma dinamicamente engajada.

Esta interação focada no usuário contribui para sua autonomia pois permite a construção de conhecimentos de forma autônoma e lógica utilizando a auto disposição e automotivação do aluno para refinar e aprofundar temas de interesse começando de forma mais simples, como na construção de aprendizagem significativa representacional, por exemplo:

- O que é a gravidade?

Obtendo como resposta:

A gravidade é uma das quatro forças fundamentais da natureza, juntamente com a força eletromagnética, a força nuclear forte e a força nuclear fraca. Ela é a força que atrai corpos com massa um em direção ao outro. A gravidade é descrita pela teoria da relatividade geral de Albert Einstein, que propôs que a presença de massa e energia curva o espaço-tempo ao seu redor, criando uma força de atração que é percebida como gravidade.

De forma mais simples, podemos dizer que a gravidade é a força que faz com que os objetos caiam quando soltos no ar, mantém a Terra em órbita ao redor do Sol e mantém as estrelas em suas galáxias. A força da gravidade depende da massa dos objetos e da distância entre eles. Quanto maior a massa e menor a distância entre os objetos, maior será a força de atração gravitacional entre eles (OPENAI, 2023).

E, a partir desta representação inicial, evoluirmos para uma aprendizagem significativa conceitual, como por exemplo:

- O quanto a força da gravidade depende da massa dos objetos e da distância entre eles?

A força da gravidade entre dois objetos depende diretamente da massa dos objetos e inversamente do quadrado

da distância entre eles.

Isso significa que, quanto maior a massa dos objetos envolvidos, maior será a força de atração gravitacional entre eles. Por exemplo, a Terra tem uma massa muito maior do que uma pessoa, então a Terra exerce uma força gravitacional muito maior sobre a pessoa do que a pessoa exerce sobre a Terra.

Por outro lado, quanto maior a distância entre dois objetos, menor será a força gravitacional entre eles. Isso ocorre porque a força da gravidade diminui à medida que a distância entre os objetos aumenta. Por exemplo, a Lua exerce uma força gravitacional sobre a Terra, mas essa força é muito menor do que a força exercida pelo Sol, que está muito mais distante.

Em resumo, a força da gravidade entre dois objetos é diretamente proporcional à massa dos objetos e inversamente proporcional ao quadrado da distância entre eles (OPENAI, 2023).

Então, finalmente, o aluno pode utilizar a aprendizagem significativa proposicional, quando mediante a apreensão de conceitos ele pode propor novos significados. Como por exemplo, na proposição:

- Os buracos negros devem possuir uma enorme massa por isso os buracos negros atraem tudo para eles?

Obtendo pelo LLMS a seguinte resposta:

Sim, os buracos negros têm uma massa muito grande e, portanto, possuem uma força gravitacional muito intensa, que é a responsável por atrair tudo ao seu redor.

Devido à sua grande massa, os buracos negros são capazes de atrair estrelas, planetas, gases e outras matérias que estão próximas a eles. Na verdade, a força gravitacional dos buracos negros é tão forte que nada, nem mesmo a luz, consegue escapar de sua atração, o que é a razão pela qual eles são chamados de "buracos negros".

Os buracos negros se formam a partir do colapso de uma estrela muito massiva no final de sua vida. Quando a estrela esgota todo o seu combustível, ela não é mais capaz de sustentar a fusão nuclear em seu núcleo e começa a se contrair sob a ação da gravidade. Se a massa da estrela é grande o suficiente, ela pode se contrair para um ponto extremamente denso e compacto, conhecido como singularidade, que é cercado por um horizonte de eventos - a região do espaço a partir da qual nada pode escapar. O resultado é um buraco negro, cuja massa e força gravitacional são extremamente intensas (OPENAI, 2023).

4.2. Limitações e Desafios

Ainda é necessário um debate aberto e honesto sobre o papel da IA na educação e a melhor forma de integrá-la de forma responsável e eficaz no processo de ensino e aprendizagem. Apesar de todos os pontos positivos e benefícios que a IA e os grandes modelos de linguagem podem contribuir com a aprendizagem significativa existem muitos desafios e limitações que abrangem desde questões puramente técnicas até questões éticas. Devemos, a princípio, considerar que os LLMs podem não ser adequados para todos os tipos de aprendizagem e aprendizes. Em seguida, devemos considerar que o uso de LLMs pode se dar de forma indevida como na realização de plágios ou na geração de textos falsos ou sem embasamento científico, ainda que apresentem uma estrutura semântica e sintática com coerência.

Ademais, precisamos considerar que existirão, intrinsecamente, vieses inerentes aos próprios dados e vieses algorítmicos porque os modelos são treinados a partir de grandes bases de dados formada por textos gerados por humanos e por programas desenvolvidos por humanos. Ou seja, condutas inapropriadas podem emergir nas respostas da máquina caso estejam presentes na base de treinamento. Isso pode acarretar comportamentos discriminatórios e injustos e/ou perpetuar condutas e padrões inaceitáveis.

Outro ponto relevante se dá no fato que muitos modelos não são transparentes em relação à base de dados utilizadas e/ou nos processos de tomada de decisão pela máquina, sendo verdadeiras caixas-pretas para o usuário. Alguns LLMs são proprietários e outros não fornecem acesso aos dados de treinamento. Isso levanta questões relacionadas à privacidade, uma vez que alguns modelos utilizam dados sensíveis e pessoais disponibilizados na internet e/ou em redes sociais durante o processo de treinamento dos modelos. Ainda, podemos ter questões relacionadas à violação de propriedade intelectual se os dados utilizados no treinamento não tiveram anuência de seus proprietários.

Por fim, o uso excessivo da tecnologia pode criar uma dependência de tecnologias digitais, o que pode limitar a atuação do aprendiz. E, em contraste, a inequidade digital pode limitar o uso de LLMs para estudantes com limitações sociais

e/ou geográficas que ocasionam limitações de recursos.

Agradecimentos

Expressamos nossos agradecimentos à Universidade Vila Velha (UVV) pelo incentivo à formação docente continuada em direção a melhores e inovadoras práticas educacionais. As opiniões expressas neste artigo representam os pontos de vista dos autores (e não de qualquer instituição). Conduzimos este trabalho sem relações comerciais ou financeiras que pudessem causar potenciais conflitos de interesses.

Referências

ALEXANDER, P. A.; SCHALLERT, D. L.; REYNOLDS, R. E. What Is Learning Anyway? A Topographical Perspective Considered. *Educational Psychologist*, v. 44, n. 3, p. 176–192, 24 jul. 2009.

AUSUBEL, D. P. *Aquisição e retenção de conhecimentos: Uma perspectiva cognitiva*. Editora Plátano, 2003.

BAIDOO-ANU, D.; OWUSU ANSAH, L. Education in the Era of Generative Artificial Intelligence (AI): Understanding the Potential Benefits of ChatGPT in Promoting Teaching and Learning. Rochester, NY, 25 jan. 2023. Disponível em: <<https://papers.ssrn.com/abstract=4337484>>. Acesso em: 30 abr. 2023

BROWN, T. B. et al. Language Models are Few-Shot Learners. *arXiv*, , 22 jul. 2020. Disponível em: <<http://arxiv.org/abs/2005.14165>>. Acesso em: 21 abr. 2023

CAMPELLO DE SOUZA, B.; ANDRADE NETO, A. S. D.; ROAZZI, A. ChatGPT, the Cognitive Mediation Networks Theory and the Emergence of Sophotechnic Thinking: How Natural Language AIs Will Bring a New Step in Collective Cognitive Evolution. *SSRN Electronic Journal*, 2023.

CHEN, X. et al. Two Decades of Artificial Intelligence in Education: Contributors, Collaborations, Research Topics, Challenges, and Future Directions. *Educational Technology & Society*, v. 25, n. 1, p. 28–47, 2022.

- DA SILVA RUAS, K. C.; MACIEL, C. E. Emancipação e aprendizagem significativa na educação: contribuição das TDIC. *Polyphonía* (Universidade Federal de Goiás. Centro de Ensino e Pesquisa Aplicada à Educação), v. 30, n. 2, p. 240–255, 2020.
- DEVLIN, J. et al. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *arXiv*, , 24 maio 2019. Disponível em: <<http://arxiv.org/abs/1810.04805>>. Acesso em: 7 abr. 2023
- GOOGLE RESEARCH. bert. Disponível em: <<https://github.com/google-research/bert/>>. Acesso em: 7 abr. 2018.
- HU, K. ChatGPT sets record for fastest-growing user base - analyst note. *Reuters*, 2 fev. 2023.
- KAEHLING, L. P.; LITTMAN, M. L.; MOORE, A. W. Reinforcement Learning: A Survey. *Journal of Artificial Intelligence Research*, v. 4, p. 237–285, 1 maio 1996.
- LEGG, S.; HUTTER, M. Universal Intelligence: A Definition of Machine Intelligence. *arXiv*, 20 dez. 2007. Disponível em: <<http://arxiv.org/abs/0712.3329>>. Acesso em: 23 abr. 2023
- MCCARTHY, J. et al. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine*, v. 27, n. 4, p. 12–12, 15 dez. 2006.
- MEDEIROS, L. F. DE. *Inteligência artificial aplicada: uma abordagem introdutória*. Curitiba: Editora Intersaberes, 2018.
- MOREIRA, M. A., MASINI, E. A. F. S. *Aprendizagem significativa: a teoria de David Ausubel*. São Paulo, Moraes, 1982. 112 p.
- NAGY, D.; SCHUESSLER, J.; DUBINSKY, A. Defining and identifying disruptive innovations. *Industrial Marketing Management*, v. 57, p. 119–126, 1 ago. 2016.
- NILSSON, N. J. *Artificial Intelligence: A New Synthesis*. [s.l.] Elsevier, 1998.
- NUNES, A. M. I. B. L.; SILVEIRA, R. DO N. *Psicologia da Aprendizagem: Processos, Teorias e Contextos*. 3a ed. [s.l.] Liber Livro, 2011.
- OECD. *OECD Skills Outlook 2021*. , 2021. Disponível em: <<https://www.oecd-ilibrary.org/content/publication/0ae365b4-en>>

OLSON, E. Introducing Consensus. Consensus - Evidence-Based Answers, Faster, 8 fev. 2022. Disponível em: <<https://consensus.app/home/blog/introducing-consensus/>>. Acesso em: 30 abr. 2023

OPENAI. DALL·E: Creating images from text. Disponível em: <<https://openai.com/research/dall-e>>. Acesso em: 21 abr. 2023.

_____. Introducing ChatGPT. Disponível em: <<https://openai.com/blog/chatgpt>>. Acesso em: 21 abr. 2023.

_____. GPT-4 Technical Report. arXiv, , 27 mar. 2023. Disponível em: <<http://arxiv.org/abs/2303.08774>>. Acesso em: 21 abr. 2023

_____. Improving language understanding with unsupervised learning. Disponível em: <<https://openai.com/research/language-unsupervised>>. Acesso em: 7 abr. 2023.

ORMROD, J. E. Human learning. 6th ed ed. Harlow, Essex: Pearson, 2014.

OTTENBREIT-LEFTWICH, A. et al. Lessons Learned for AI Education with Elementary Students and Teachers. International Journal of Artificial Intelligence in Education, 14 set. 2022.

OUYANG, L. et al. Training language models to follow instructions with human feedback. 2022.

PETERS, M. E. et al. Deep contextualized word representations. arXiv, , 22 mar. 2018. Disponível em: <<http://arxiv.org/abs/1802.05365>>. Acesso em: 7 abr. 2023

RADFORD, A. et al. Improving language understanding by generative pre-training. 2018.

RADFORD, A. et al. Language Models are Unsupervised Multitask Learners. 2019.

RAY, S. A Quick Review of Machine Learning Algorithms. 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon). Faridabad, India: IEEE, fev. 2019. Disponível em: <<https://ieeexplore.ieee.org/document/8862451/>>. Acesso em: 4 abr. 2023

RUSSELL, S. J.; NORVIG, P.; DAVIS, E. Artificial intelligence: a modern approach. 3rd ed ed. Upper Saddle River: Prentice Hall, 2010.

SINGH, A.; THAKUR, N.; SHARMA, A. A review of supervised machine learning algorithms. 2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom). mar. 2016.

VASWANI, A. et al. Attention Is All You Need. arXiv, 5 dez. 2017. Disponível em: <<http://arxiv.org/abs/1706.03762>>. Acesso em: 7 abr. 2023

WILSON, R. A.; KEIL, F. C. (EDS.). The MIT encyclopedia of the cognitive sciences. Cambridge, Mass: MIT Press, 1999.