



Universidade de Brasília - UnB
Faculdade de Educação
Programa de Pós-Graduação em Educação

Jefferson da Silva

Chatbot pedagógico baseado em engenharia de *prompts* em Modelos de Linguagem de Grande Escala: uma investigação sobre as percepções dos educadores sobre a qualidade da personalização do *feedback*

Brasília (DF)

2024

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

d586c da Silva, Jefferson
Chatbot pedagógico baseado em engenharia de prompts em Modelos de Linguagem de Grande Escala: uma investigação sobre as percepções dos educadores sobre a qualidade da personalização do feedback / Jefferson da Silva; orientador Gilberto Lacerda Santos. -- Brasília, 2024.
142 p.

Dissertação (Mestrado em Educação) -- Universidade de Brasília, 2024.

1. Interatividade. 2. Inteligência Artificial. 3. Sistemas Tutores Inteligentes. 4. Processos de ensino e aprendizagem. I. Lacerda Santos, Gilberto, orient. II. Título.

Jefferson da Silva

Chatbot pedagógico baseado em engenharia de *prompts* em Modelos de Linguagem de Grande Escala: uma investigação sobre as percepções dos educadores sobre a qualidade da personalização do *feedback*

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação da Faculdade de Educação da Universidade de Brasília, na Linha de pesquisa Educação, Tecnologias e Comunicação, como requisito parcial à obtenção do título de Mestre em Educação.

Orientador: Prof. Dr. Gilberto Lacerda Santos.

Brasília (DF)

2024

Jefferson da Silva

Chatbot* pedagógico baseado em engenharia de *prompts* em Modelos de Linguagem de Grande Escala: uma investigação sobre as percepções dos educadores sobre a qualidade da personalização do *feedback

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação da Faculdade de Educação da Universidade de Brasília, na Linha de pesquisa Educação, Tecnologias e Comunicação, como requisito parcial à obtenção do título de Mestre em Educação.

Trabalho aprovado. Brasília (DF), 27 de setembro de 2024.

Trabalho submetido à seguinte comissão julgadora:

Prof. Dra. Liliane Campos Machado
Universidade de Brasília (UnB) - PPGE/FE
Presidente

Prof. Dr. Tel Amiel
Universidade de Brasília (UnB) -
PPGMP/FE
Membro titular interno

Prof. Dra. Patrícia Augustin Jaques Maillard
Universidade Federal do Paraná (UFPR) -
PPGInf
Membro titular externo

Prof. Dr. Bruno Santos Ferreira
Universidade de Brasília (UnB) -
PPGMP/FE
Membro suplente interno

Este trabalho é dedicado ao Senhor Jesus Cristo,
Aquele que me deu o dom da vida e a salvação.

Agradecimentos

Agradeço a meus pais e minha avó que investiram o que tinham para que eu pudesse estudar e tivesse uma vida melhor. A minha esposa, que a todo tempo está comigo e me incentivou a realizar o mestrado. Aos professores Gilberto, Lúcio e Amaralina, que me agraciaram com seus conhecimentos.

“It’s difficult to be rigorous about whether a machine really ‘knows’, ‘thinks’, etc, because we’re hard put to define these things. We understand human mental processes only slightly better than a fish understands swimming”.

John McCarthy, 1983.

Resumo

O uso da tecnologia de Inteligência Artificial (IA) pode auxiliar o docente na personalização do ensino e, conseqüentemente, ajudar estudantes no processo de aprendizagem. Tecnologias com base em IA estão apoiando a educação e pesquisas têm sido realizadas com vistas a aprimorá-las e obter maior assertividade do modelo desenvolvido. Uma das tecnologias de IA aplicadas à educação são os Sistemas Tutores Inteligentes (STI). Com o advento da IA generativa e da complexidade de desenvolvimento de um STI, esta pesquisa teve como objetivo: Investigar as percepções dos educadores sobre a qualidade da personalização do *feedback* em *chatbot* pedagógico baseados em engenharia de *prompts* em LLM. O enfoque da pesquisa foi qualitativo, com finalidade de ser aplicada e com propósito de ser uma pesquisa exploratória. Para analisar o *feedback* foi aplicado um questionário para os participantes da pesquisa do Grupo ÁBACO, o qual fizeram a interação com o *chatbot* pedagógico baseado na tecnologia ChatGPT, da OpenAI, e responderam às perguntas. A análise dos dados foi realizada pela Análise de Conteúdo de Bardin. A aplicação foi desenvolvida com a técnica de *prompt engineering*. Ao analisar os dados, oportunidades de melhoria foram identificadas para que o *chatbot* pudesse atuar na personalização do ensino e colocando o aluno no centro do processo de aprendizagem, a exemplo de um STI, utilizando como “mola propulsora” as características da interatividade. Utilização de outras técnicas como o *fine-tuning* e o *Reinforcement Learning from Human Feedback* (RLHF) para viabilização dos componentes da arquitetura de um STI, definição de requisitos e público-alvo, ajustes no tamanho do feedback e aprimoramento no *prompt* de forma a aprofundar a identificação do conhecimento do aluno, foram as oportunidades de melhoria identificadas.

Palavras-chaves: Interatividade. Inteligência Artificial. Sistemas Tutores Inteligentes. Processos de ensino-aprendizagem.

Abstract

The use of Artificial Intelligence (AI) technology can help teachers personalize teaching and, consequently, help students in the learning process. AI-based technologies are supporting education and research has been carried out to improve them and obtain greater assertiveness from the developed model. One of the AI technologies applied to education is Intelligent Tutoring Systems (ITS). With the advent of generative AI and the complexity of developing an ITS, this research aimed to: Investigate educators' perceptions about the quality of feedback personalization in pedagogical chatbots based on prompt engineering in LLM. The research focus was qualitative, with the purpose of being applied and with the purpose of being an exploratory research. To analyze the feedback, a questionnaire was applied to the participants of the ÁBACO Group research, who interacted with the pedagogical chatbot based on OpenAI's ChatGPT technology and answered the questions. Data analysis was performed using Bardin's Content Analysis. The application was developed with the prompt engineering technique. By analyzing the data, opportunities for improvement were identified so that the chatbot could act in the personalization of teaching and placing the student at the center of the learning process, like an ITS, using the characteristics of interactivity as a "driving force". The use of other techniques such as fine-tuning and Reinforcement Learning from Human Feedback (RLHF) to make the components of the ITS architecture viable, defining requirements and target audience, adjusting the size of the feedback and improving the prompt in order to deepen the identification of the student's knowledge, were the opportunities for improvement identified.

Keywords: Interactive communication. Artificial Intelligence. Intelligent Tutoring Systems. Learning. Teaching.

Lista de ilustrações

Figura 1 – Distribuição de desempenho para alunos em ensino tradicional em sala de aula, por <i>Mastery teaching</i> e tutoria individualizada.	29
Figura 2 – Campos de pesquisa da IA	37
Figura 3 – Diagrama de conhecimento da IA	39
Figura 4 – Modelos de IA e possíveis aplicações de IA generativa	42
Figura 5 – Aplicações de IA generativa	43
Figura 6 – Diagrama de Venn que explicita a relação entre os conceitos abordados de IA	45
Figura 7 – Tendência de pesquisa mundial no Google, nos últimos 90 dias, acerca dos principais LLMs	46
Figura 8 – <i>Roadmap</i> tecnológico: prospecção das tendências em IA na Educação até 2030	48
Figura 9 – Relação entre disciplinas para o desenvolvimento de STIs	50
Figura 10 – O triângulo didático (diagrama): as três dimensões da pesquisa didática	64
Figura 11 – Transposição didática, segundo Verret, Chevallard e Perrenoud	65
Figura 12 – Transposição midiática	66
Figura 13 – Atuação da interatividade no Triângulo da Transposição Didática	67
Figura 14 – Estrutura de construção de um <i>prompt</i> - exemplo de IA como tutor	73
Figura 15 – Tela do <i>chatbot</i> para criação de aplicações do ChatGPT	80
Figura 16 – Tela de configuração manual para criação de aplicações do ChatGPT	81
Figura 17 – <i>Prompt</i> elaborado a partir do modelo e premissas	82
Figura 18 – Tela de criação do <i>bot</i> no Telegram	83
Figura 19 – Tela de criação, configuração e integração do <i>bot</i> no SendPulse	83
Figura 20 – Compilado das respostas à pergunta 9	92
Figura 21 – Produção científica ao longo dos anos.	127

Lista de tabelas

Tabela 1 – Tipos de <i>feedback</i> organizados por complexidade (do menor para o maior)	59
Tabela 2 – Orientações de <i>feedback</i> para melhorar a aprendizagem (coisas a serem feitas)	60
Tabela 3 – Orientações de <i>feedback</i> para melhorar a aprendizagem (coisas a serem evitadas)	61
Tabela 4 – Orientações de <i>feedback</i> em relação às características do aluno	62

Tabela 5 – Comparação das funcionalidades do STI com ChatGPT	69
Tabela 6 – Abordagens de uso da IA na educação e compatibilidade com LLMs . .	71
Tabela 7 – Compilado das respostas à pergunta 1	86
Tabela 8 – Compilado das respostas à pergunta 2	87
Tabela 9 – Compilado das respostas à pergunta 3	87
Tabela 10 – Compilado das respostas à pergunta 4	88
Tabela 11 – Compilado das respostas à pergunta 5	89
Tabela 12 – Compilado das respostas à pergunta 6	89
Tabela 13 – Compilado das respostas à pergunta 7	90
Tabela 14 – Compilado das respostas à pergunta 8	91
Tabela 15 – Compilado das respostas à pergunta 11	93
Tabela 16 – Compilado das respostas à pergunta 12	93
Tabela 17 – Identificação de possíveis falta de conhecimento do <i>chatbot</i> na pesquisa	95
Tabela 18 – Análise geral das respostas dos entrevistados às diferentes dimensões avaliadas do <i>chatbot</i>	96
Tabela 19 – Palavras-chaves pesquisadas	124
Tabela 20 – Países e suas produções científicas	127
Tabela 21 – Autores e suas produções científicas	128
Tabela 22 – Periódicos em que houve mais publicações	128
Tabela 23 – Artigos mais citados	129
Tabela 23 – Artigos mais citados	130

Lista de abreviaturas e siglas

AKT	<i>Attentive Knowledge Tracing.</i>
ANN	<i>Artificial neural network.</i>
ASAG	<i>Automatic Short-Answer Grading.</i>
BANI	<i>Brittle, Anxious, Nonlinear, Incomprehensible.</i>
BERT	<i>Bidirectional Encoder Representations from Transformers.</i>
Bi-CLKT	<i>Bi-Graph Contrastive Learning based Knowledge Tracing.</i>
BKT	<i>Bayesian Knowledge Tracking.</i>
CAI	<i>Computer Assisted Instruction.</i>
CEP/CHS	Comitê de Ética em Pesquisa em Ciências Humanas e Sociais da Universidade de Brasília.
CKT	<i>Corrigible Knowledge Tracing.</i>
CNI	Confederação Nacional da Indústria.
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico.
DKT	<i>Deep Knowledge Tracing.</i>
EaD	Educação a Distância.
ETC	Educação, Tecnologias e Comunicação.
GANs	<i>Generative Adversarial Networks.</i>
GCN	<i>Graph Convolutional Networks.</i>
GNN	<i>Graph Neural Networks.</i>
GPS	<i>Global Positioning System.</i>
GPT	<i>Generative Pre-Trained Transformer.</i>
IA	Inteligência Artificial.
IBGE	Instituto Brasileiro de Geografia e Estatística.
ICAI	<i>Intelligent Computer Assisted Instruction.</i>

ITS	<i>Intelligent Tutoring System.</i>
JKT	<i>Joint Graph Convolutional Network.</i>
KSGKT	<i>Knowledge Structure Enhanced Graph Knowledge Tracing.</i>
KT	<i>Knowledge Tracing.</i>
LMS	<i>Learning Management System.</i>
LPM	<i>Learning Process Methodology.</i>
LSTM	<i>Long short-term memory.</i>
MIT	Massachusetts Institute of Technology.
MOOC	<i>Massive Open Online Course.</i>
NLP	<i>Natural Language Processing.</i>
NNs	<i>Neural Networks.</i>
ODS4	Objetivo de Desenvolvimento Sustentável nº 4.
PLN	Processamento de Linguagem Natural.
PNAD	Pesquisa Nacional por Amostra de Domicílios.
RLHF	<i>Reinforcement Learning from Human Feedback.</i>
SARS COVID-19	Síndrome respiratória aguda grave COVID-19.
SENAI	Serviço Nacional de Aprendizagem Industrial.
STI	Sistemas Tutores Inteligentes.
TCLE	Termo de Consentimento Livre e Esclarecido.
TIC	Tecnologias da Informação e Comunicação.
TICE	Tecnologia da Informação, Comunicação e Expressão.
TRI	Teoria de Resposta ao Item.
UnB	Universidade de Brasília.
UNESCO	Organização das Nações Unidas para a Educação, a Ciência e a Cultura.
XML	<i>eXtensible Markup Language.</i>

Lista de símbolos

- α Letra grega Alfa.
- Σ Letra grega Sigma, que representa o símbolo matemático chamado somatório.

Sumário

1	INTRODUÇÃO	23
1.1	Problema de pesquisa e objetivos	32
1.2	Estrutura da dissertação	33
2	IA, MACHINE LEARNING E STI	35
2.1	IA generativa e LLMs	41
2.2	A técnica de engenharia de <i>prompts</i>	46
2.3	Prospectiva tecnológica da IA na Educação	48
2.4	STI	50
3	TEORIAS EDUCACIONAIS, INTERATIVIDADE E STI	55
3.1	As teorias educacionais na sociedade informacional	55
3.2	Características da interatividade	56
3.2.1	O <i>feedback</i>	58
3.3	As tecnologias educacionais, a interatividade e o processo de aprendizagem	61
3.4	A interatividade como parte da transposição didática	63
3.4.1	A prática na visão de Perrenoud	64
3.4.2	A transposição midiática	65
3.5	É possível o uso do ChatGPT como um tutor?	68
4	PROCEDIMENTOS METODOLÓGICOS	75
5	PROMPT DE UM CHATBOT PEDAGÓGICO BASEADO EM LLM	79
6	ANÁLISE DO FEEDBACK DE UM CHATBOT PEDAGÓGICO BASEADO EM LLM	85
6.1	A análise dos dados	85
6.2	Considerações finais da análise	94
7	CONCLUSÃO	99
	REFERÊNCIAS	101

APÊNDICES	113
APÊNDICE A – O USO DE <i>DEEP LEARNING</i> EM SISTEMAS Tutores Inteligentes: Uma Análise do Estado da Arte no Período entre 2018 a 2022	115
APÊNDICE B – TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO (TCLE)	139

1 Introdução

A sociedade vive o Mundo BANI, cujo acrônimo criado pelo antropólogo norte-americano Jamais Cascio, em inglês é: *Brittle, Anxious, Nonlinear, Incomprehensible*. Em português, seria: frágil, ansioso, não linear e incompreensível. Frágil, pois o que se tem hoje é incerto para o amanhã. Ansioso, pois o senso de urgência acelera a tomada de decisões. Não linear, pois o mundo está em constante mudança. Por fim, incompreensível, pois buscam-se respostas para tudo, mas novas informações são geradas a todo o momento, dificultando a compreensão da realidade (BEZERRA, 2021).

O mundo também vive a Quarta Revolução Industrial ou Indústria 4.0, que “engloba um amplo sistema de tecnologias avançadas como Inteligência Artificial (IA), robótica, *internet* das coisas e computação em nuvem que estão mudando as formas de produção e os modelos de negócios no Brasil e no mundo” (SENAI, 2021).

A IA é um agente invisível na sociedade e que está cada vez mais presente na sociedade atual hiperconectada. A visualização do que é apresentado no *feed* das redes sociais, as recomendações de filmes e músicas em plataformas de *streaming* e as sugestões de itens para compra de produtos em plataformas *e-commerce*, são exemplos de IA que se utilizam de algoritmos para análise de dados gerados pelos usuários de forma consentida ou não (KAUFMAN, 2022). Os avanços gerados “na última década provém do modelo chamado de *deep learning* [...], técnica de *machine learning* [...], subárea da Inteligência Artificial, que consiste em técnicas estatísticas que permitem que as máquinas aprendam com os dados” sem a necessidade de programação (KAUFMAN, 2022, p.11)

Os “dados são o novo petróleo”, segundo o matemático e empreendedor na área de ciência de dados Clive Humby (ECONOMIST, 2017). A estimativa de dados gerados pela *internet* chegou a 1.134 trilhões de megabytes por dia em 2021. Já o número de buscas no Google foram de 2 trilhões (ONLINE, 2022). Vive-se uma economia de dados, onde dados são estratégicos para desenvolvimento de negócios e tomada de decisão. A transformação digital trazida pelo uso de tecnologias, principalmente a IA, potencializa a geração de novos negócios e aumenta a competitividade das empresas por meio da geração de receita, aumento de eficiência e a redução de custos. Empresas que até então precisariam de inúmeros funcionários para operação do negócio pela automatização, são reduzidos. Em relação a automatização, Kaufman (2022, p.18) escreve:

Na competição entre o trabalhador humano e o “trabalhador-máquina”, os humanos estão em desvantagem: a) a manutenção é mais barata, as máquinas trabalham quase que em moto-contínuo (sem descanso, sem férias, sem doenças), com um custo médio menor por hora trabalhada (49 dólares na Alemanha e 36 nos Estados Unidos, contra 4 dólares

do “robô”); e b) as máquinas inteligentes se aperfeiçoam automática e continuamente, e o custo de reproduzi-las é significativamente menor do que o custo de treinar profissionais humanos para as mesmas funções.

Não somente a automação está mudando o mercado de trabalho, mas também as novas configurações de trabalho, principalmente aceleradas pela Pandemia, que precarizou o trabalho e impactou significativamente as atividades econômicas, como a pejetização¹, o *home office*, os trabalhos *freelancer* e os trabalhos informais de aplicativos, como Uber, *iFood*, entre outros (KAUFMAN, 2022, p.18).

A IA substituirá o ser humano em atividades que exijam trabalhos operacionais repetitivos e previsíveis (KAUFMAN, 2022, p.18). Nesse sentido, os trabalhadores deverão ser protagonistas no seu autodesenvolvimento para se manterem no mercado de trabalho. Caso contrário, a lei da oferta e demanda prevalecerá, ou seja, quanto menor a demanda para vagas mais operacionais, que exigem menos qualificação, menores os salários.

Diante desse cenário, o Fórum Econômico Mundial, no relatório *The Future of Jobs*, relata que, até 2025, 44% das habilidades que os trabalhadores precisarão para desempenhar suas funções de forma eficaz irão mudar (FORUM, 2020). Assim, serão necessárias a qualificação e a requalificação de profissionais para atuarem nessas novas funções, principalmente pela adoção de novas tecnologias. No entanto, a qualificação e a requalificação não serão suficientes, o mesmo relatório também traz que a IA e a automação reduzirão os postos de trabalho.

Por mais que as empresas desejam aumentar em até 11% a oferta de qualificação e requalificação de funcionários até 2025, apenas 42% aproveitam as possibilidades oferecidas pelo empregador (FORUM, 2020). No relatório, 94% dos empregadores desejam que seus empregados desenvolvam novas habilidades (GUIMARAES, 2021).

Devido ao rápido avanço da tecnologia, o crescimento exponencial da informação na *web* e a mudança da sociedade levarão os seres humanos a estarem sempre aprendendo e se atualizando, corroborado pelo relatório *The Future of Jobs*, do *World Economic Forum*, em que elenca as habilidades de aprendizagem ativa e estratégias de aprendizado como uma das essenciais até 2025. O *lifelong learning*, ou, o aprendizado ao longo da vida, é evocado e necessário em um mundo BANI.

Nesse sentido, Kaufman (2022, p.21) coloca o “aprender a aprender” como condição para se manter atualizado nesta sociedade hiperconectada:

Há dois conceitos-chave a serem observados: um é o *lifelong learning*, aprendizagem ao longo da vida, fundamental para acompanhar a aceleração atual, requerendo atualização contínua que extrapola o ensino formal;

¹ De acordo com Campos (2023), “[...] se refere à conversão de um trabalhador formalmente empregado como pessoa física em um trabalhador autônomo ou empreendedor individual, conhecido como Pessoa Jurídica (PJ)”.

outro é a autorregulação da aprendizagem, em que cada um estrutura, monitora e avalia seu próprio aprendizado, ampliando sua capacidade de retenção de conteúdo e engajamento. O desafio é montar um programa de aprendizado eficiente. O futuro será de quem “aprende a aprender”.

O ser humano hiperconectado, por meio de seus dispositivos eletrônicos com acesso à *internet*, consegue ter acesso a um oceano de informações a qualquer momento e lugar, basta “dar um Google”. As informações são não lineares e se correlacionam a outras informações já existentes no cérebro, gerando um novo saber significativo. Esses saberes, emoções ou opiniões podem ser compartilhados na *web* contribuindo para o que Pierre Lévy chamou de inteligência coletiva, “[...] uma inteligência distribuída por toda parte, incessantemente valorizada, coordenada em tempo real, que resulta em uma mobilização efetiva das competências” (LÉVY, 2003, p.23). O ser humano passa de consumidor para produtor de conteúdo. Na Sociedade Informacional (CASTELLS et al., 2008), novas dinâmicas de interações acabam impactando a área de educação, mudando as relações entre alunos e docentes. Os usos dessas tecnologias na educação devem permitir que o aluno se expresse (SANTOS; ANDRADE, 2010).

Ainda com efeitos, a Pandemia causada pelo SARS COVID-19 acelerou o processo de transformação digital da sociedade. Devido ao isolamento social, muitas atividades antes realizadas de forma física passaram a ser realizadas de forma virtual, e não foi diferente na educação. No período pandêmico, o acesso à *internet* atingiu 90% dos domicílios do Brasil, em 2021, com aumento de 6 pontos percentuais em relação a 2019, sendo o telefone celular como principal meio de acesso, segundo o Instituto Brasileiro de Geografia e Estatística (IBGE), na Pesquisa Nacional por Amostra de Domicílios (PNAD). Tecnologias aplicadas a educação ganharam espaço e romperam velhos paradigmas neste período, mas devido a emergência causada pela Pandemia, problemas educacionais foram gerados devido a brevidade em que ações foram implementadas pelo isolamento social.

Segundo dados do Censo da Educação Superior de 2021, o número de vagas em cursos de graduação presencial reduziu em 28% em comparação a 2019, último ano antes da pandemia do SARS COVID-19. Já a Educação a Distância (EaD) cresceu na rede privada de ensino, passando de 24,3%, em 2018, para 41,4%, em 2021. O crescimento também se deve à expansão da rede nos últimos 10 anos analisados pelo Censo (ANDRADE, 2022).

A incorporação de tecnologias nos processos educacionais, o aumento do acesso à *web* e o vertiginoso crescimento da informação disponível na *internet*, permitem concluir que essa modalidade de educação poderá ganhar importância devido à característica de alcance em escala, menor custo para realização, acesso a qualquer tempo e lugar, devido ao uso intensivo de Tecnologias da Informação e Comunicação (TIC). Inclusive, ganhará espaço como meio para atividades de ensino presencial. No entanto, essa conclusão passa pela oferta de uma EaD de qualidade.

A EaD é realizada em geral por meio de Ambientes Virtuais de Aprendizagem (AVA), podendo ser realizada com ou sem tutor (cursos autoinstrucionais), por meio de aulas síncronas e assíncronas, em que inúmeros objetos de aprendizagem e canais de comunicação são disponibilizados e estratégias de ensino são planejadas para que os alunos alcancem os objetivos educacionais.

Essa modalidade de ensino exige que alunos tenham competências de organização, autorregulação e disciplina, para que concluam o curso. No entanto, há diferentes perfis de estudantes que possuem, em maior ou menor grau, essas competências ou, ainda, maior ou menor domínio de ferramentas tecnológicas para prosseguirem no curso.

A EaD se torna complexa, pois nuances como comportamento do aluno e contexto social ao qual está inserido são desafiantes para que sejam percebidas pelo tutor. Assim, é necessário que cursos EaD sejam muito bem desenvolvidos no âmbito pedagógico para que se evite evasão, e os objetivos educacionais sejam alcançados.

Apesar do estigma de cursos de baixa qualidade que a EaD obteve desde sua inserção no país ter sido reduzido (MARINHO; REPSOLD, 2010), cursos que replicam a educação presencial conteudista, mas no ambiente *online*, são a maioria e crescem a “pleno vapor”. Esse crescimento se deve à necessidade de consumo de conteúdo digital pela população, principalmente impulsionado pelas redes sociais, onde seus usuários produzem conteúdos acerca de suas vidas.

Essa necessidade possibilitou a entrada de empresas de tecnologia, que desenvolvem e disponibilizam plataformas educacionais, onde qualquer pessoa cria o seu conteúdo, disponibiliza e vende, tudo em um único ambiente, com estratégias de *marketing* digital ao alcance de todos. Esses cursos são, em geral, intitulados de infoprodutos ou produtos digitais. Esta relação *peer to peer* descentralizou o processo educacional das instituições de ensino, aumentando o acesso à educação e, de certa forma, apoiando o estudante no seu protagonismo no ato de “aprender a aprender” e como principal responsável por seu desenvolvimento.

Com o crescimento da EaD, novos ambientes educacionais estão sendo desenvolvidos centrados no estudante. Segundo Munhoz (2014, p.14):

Os ambientes centrados no aluno não são novidade, uma vez que essa proposta surgiu nos tempos da escola nova, prevendo um maior engajamento do aluno, o qual também é responsável pelo seu processo de aprendizagem. Nesses ambientes, devem ser criadas oportunidades diferenciadas de aprendizagem de modo a atender diferentes formas e ritmos. A aprendizagem ativa mediante uma série de práticas está posta como um dos melhores meios para alcançar uma educação de qualidade.

A escola nova foi um movimento que considerou o espaço escolar como a própria vida e não apenas como uma preparação para a vida, onde o aluno deveria ser o centro de um processo de reconstrução contínua da aprendizagem e onde a educação teria uma função democratizante.

Considerando ambientes educacionais centrados no estudante, uma nova forma de EaD foi concebida, *Massive Open Online Course* (MOOC), em tradução literal, curso *online* massivo aberto.

Os MOOCs surgiram em uma fase de mudança social de grande impacto, na qual as tecnologias digitais estão sendo utilizadas de forma extensiva para melhora dos processos de aquisição de conhecimentos. Essa é uma proposta que decorre, diretamente, do aumento significativo das redes sociais colaborativas e que está voltada para a economia digital, na qual se consideram imersas todas as organizações do mundo contemporâneo [...] (MUNHOZ, 2014, p.83).

Esse formato de curso tem popularizado o conhecimento e permitido que pessoas do mundo todo possam ter acesso a conteúdos de universidades de excelência acadêmica, como: Harvard, MIT, John Hopkings, entre outras. As plataformas de distribuição mais conhecidas são a Edx e Coursera, financiadas em geral por tais universidades e grandes empresas. O fenômeno dos MOOCs está ligando diretamente ao Conectivismo, uma teoria de aprendizagem proposta por Downes e Siemens. Os MOOCs são divididos em cMOOCs e xMOOCs, cuja diferença principal está, respectivamente, na priorização da conectividade entre estudantes e interatividade, enquanto o outro na centralidade do docente, a exemplo do ensino tradicional já existente (UNIVERSIA, 2013). Segundo Munhoz (2014), as características principais desses cursos são:

- Qualquer pessoa pode ter acesso.
- Não possui pré-requisitos ou conhecimentos prévios.
- Programa de cursos abertos.
- Não tem a obrigação de certificação.
- Interações dos participantes de forma aberta, geralmente por rede sociais, no caso de cursos cMOOCs.
- Possíveis de serem realizados em Ambientes Virtuais de Aprendizagem ou redes sociais.
- Atendem grande quantidade de alunos, por isso o massivo no acrônimo.
- Participação difusa e fragmentada.
- Protagonismo do estudante.
- Baseado em conexão entre pessoas e comunidades.
- Curta duração.

Apesar do alcance em escala, acesso a qualquer tempo e lugar, há muita evasão nesse tipo de curso. Do total de alunos que se inscrevem, 50% não acessam 50% do material, e 5% dos inscritos finalizam (KRLEV, 2020). O autor citado, coloca que os cursos MOOC tem uma forma de apresentar o conteúdo de forma detalhada e clara com uma abordagem conteudista, pois não há *feedback* por parte do docente. No entanto, isso é prejudicial, pois o aluno compreende, mas não entende o todo (KRLEV, 2020).

É necessário que os conteúdos sejam apresentados de forma a gerar reflexão no aluno, com o objetivo de ele se autorregular e compreender a necessidade de buscar, ou não, mais conhecimento (KRLEV, 2020). O autor cita que, para aumentar o engajamento e “salvar” os cursos MOOCs, são necessários recursos de interatividade que levem à resolução de exercícios complexos e que gerem reflexão (KRLEV, 2020).

Ao analisar o texto de Krlev (2020), é possível identificar a Teoria da Complexidade de Morin e Heineberg (2002) e o conceito de Imagem Técnica de Flusser (2005). Os MOOCs ao abordar o conteúdo de forma detalhada e clara, fazem com que o estudante veja o conhecimento de forma muito fragmentada, impossibilitando a visão do todo. Representa algo, mas não é o que está sendo representado quando se há o contexto. O contexto, na imagem técnica, se perde. É como se fosse uma lupa, onde o foco obtido em algo tira tudo o que está ao redor. É necessária uma abordagem mais ampla, coesa e integrada, melhorando o processo de decodificação do conhecimento e de pertinência para o sujeito.

O método de ensino predominante na educação brasileira é o uso de um docente para uma classe significativa de estudantes, em que todos os entes participantes do processo de ensino e aprendizagem precisam cumprir uma ementa com uma série de conteúdos dentro de um período de tempo. No entanto, cada estudante possui tempo, contexto e características de aprendizagem diferentes. Assim, nem todos alcançarão o mesmo domínio de conteúdo, mesmo recebendo a mesma instrução. Essa dinâmica certamente incorrerá em baixa eficiência da aprendizagem.

Somado a isso, o excesso e a velocidade da informação na *internet* gera sobrecarga cognitiva e dificulta o processo de aprendizagem. Diante da quantidade de informação, é necessário aumentar a efetividade da aprendizagem e engajar os estudantes por meio da personalização e de práticas pedagógicas eficientes. Entende-se por personalização, o uso de estratégias, métodos, técnicas e tecnologias que vão de encontro às necessidades de cada estudante. Contudo, isso já é um desafio em classes presenciais, na EaD o desafio se torna ainda mais complexo.

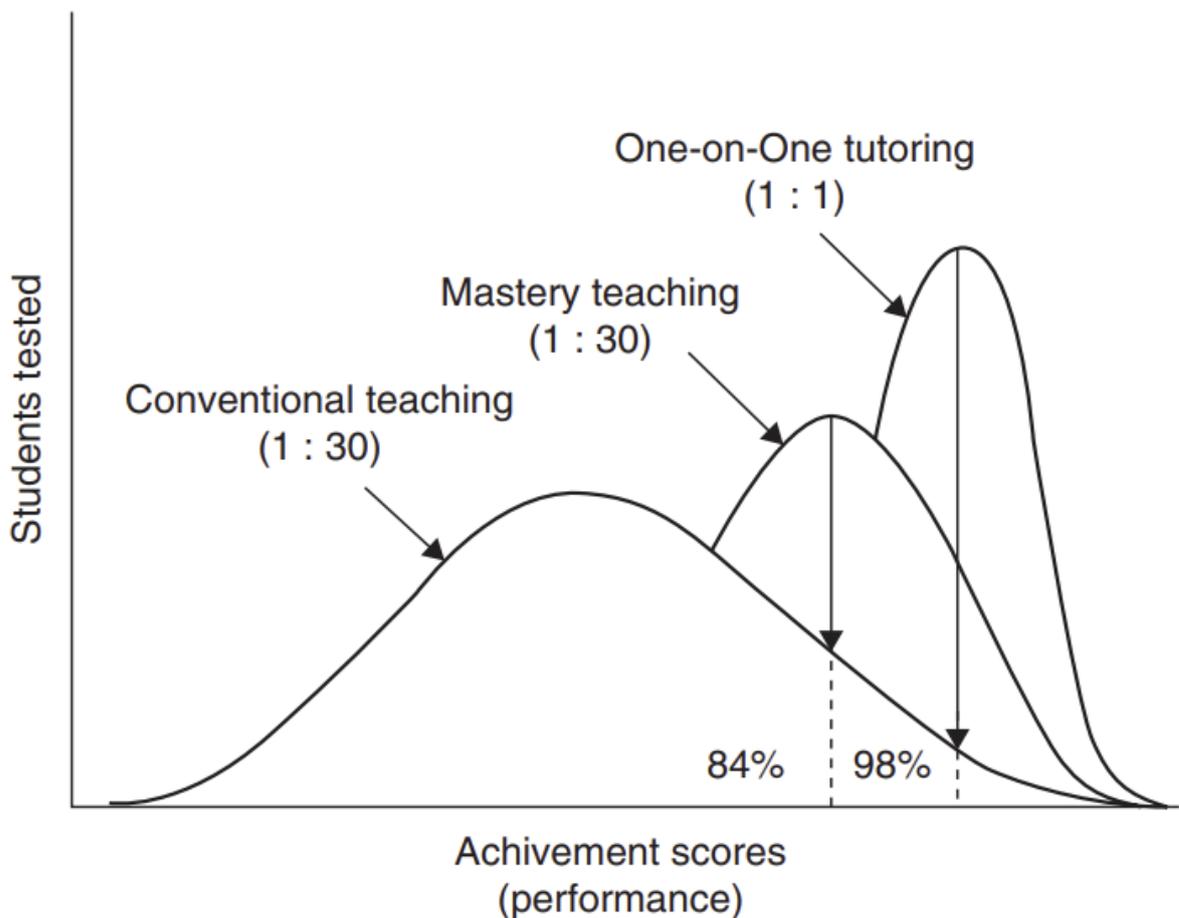
Bloom, psicólogo e pedagogo americano, em seus estudos sobre aprendizagem, apresentou em seu artigo *The 2 Sigma Problem: the Search for Methods of Group Instruction as Effective as One-to-One Tutoring*, de 1984, um estudo comparando o desempenho de:

- Uma sala tradicional (*Conventional teaching*) com 30 estudantes para um professor,

abordando um determinado assunto, com avaliações formativas periódicas sendo realizadas.

- Uma sala com 30 estudantes com abordagem do mesmo assunto e avaliações formativas da sala de aula convencional. No entanto, *feedback* foram dados aos estudantes com conteúdos formativos corretivos e avaliações contínuas para verificação se os estudantes alcançaram o objetivo proposto. Método este proposto por Bloom (1973) e intitulado *Mastery teaching*.
- Estudantes que aprenderam o mesmo conteúdo, mas com tutoria individualizada (*One-on-one tutoring* ou para 2 ou 3 estudantes simultâneos). Os mesmos conteúdos e avaliações periódicas formativas do *Mastery teaching* também foram aplicadas com *feedback* contínuo.

Figura 1 – Distribuição de desempenho para alunos em ensino tradicional em sala de aula, por *Mastery teaching* e tutoria individualizada.



Fonte: (GRAESSER; HU; SOTTILARE, 2018)

Descobriu-se que o desempenho dos alunos no ensino tradicional em sala de aula (*conventional teaching*) difere do desempenho baseado na tutoria individual (*One-on-one*)

em cerca de dois desvios-padrão (BLOOM, 1984). Ou seja, a curva típica de desempenho estava centrada em 50% para o ensino tradicional baseado em palestras e foi elevada para 98% no ensino individualizado (*One-on-one tutoring*) (BLOOM, 1984), conforme pode ser visto na Figura 1. Um dos fatores de sucesso foram o *feedback* contínuo e atividades de reforço.

Apesar do artigo ser muito citado desde a sua publicação, totalizando 5000 citações, sendo 2000 delas nos últimos 10 anos (HIPPEL, 2024), há críticas acerca da pesquisa. Uma das principais críticas é em relação ao avanço de dois desvios padrões, pois representam uma grande quantidade de aprendizado e a pesquisa ser fruto de teste restrito e especializado de dois de seus orientandos (chamados de Anania e Burke) (HIPPEL, 2024). Ainda segundo o autor:

Os efeitos de dois sigma obtidos na década de 1980 por Anania e Burke eram reais e notáveis, mas foram obtidos em um teste restrito e especializado, e não foram obtidos apenas por tutoria. Em vez disso, Anania e Burke misturaram um potente coquetel de intervenções que incluíam tutoria; treinamento e coaching em práticas instrucionais eficazes; prorrogação; e testes, feedback e retestes frequentes.

Apesar das críticas e do número exagerado de 2 desvios-padrão, a aprendizagem individualizada é mais eficaz quando bem realizada, mas como atuar nessa abordagem em um cenário com uma grande quantidade de alunos, seja na educação presencial ou EaD?

As TICs, por meio do uso da tecnologia de IA, podem auxiliar o docente na personalização do ensino e, conseqüentemente, ajudar estudantes no processo de aprendizagem. Tecnologias com base em IA estão apoiando a educação e pesquisas têm sido realizadas com vistas a aprimorá-las e obter maior assertividade do modelo desenvolvido.

Aliada a IA, as ciências cognitivas “levam a uma compreensão mais profunda de como as pessoas pensam, resolvem problemas e aprendem” (WOOLF, 2009, p.6, tradução nossa). Junto a elas, “a *internet* fornece uma fonte ilimitada de informações, disponível a qualquer hora e em qualquer lugar” (WOOLF, 2009, p.6, tradução nossa), tornando-se o “o maior e mais flexível repositório de material educacional do mundo” (WOOLF, 2009, p.4, tradução nossa). A confluência da IA, das ciências cognitivas e da *internet* permitem criar sistemas cognitivos aplicados à educação que apoiam na personalização do ensino.

Uma dessas tecnologias são os Sistemas Tutores Inteligentes (STI), que são “sistemas de instrução baseados em computador com modelos de conteúdo instrucional que especificam o que ensinar e estratégias de ensino que especificam como ensinar” (WENGER, 1987, tradução nossa). “Tentam imitar a tutoria humana personalizada num ambiente baseado em computador [...]” (ANDERSON; BOYLE; REISER, 1985, tradução nossa).

Os STIs têm como proposta colocar o estudante no centro do processo de ensino e aprendizagem e possibilitaram uma ampla gama de interações, participação ativa e

adaptabilidade única para cada estudante. Graesser, Hu e Sottolare (2018) mostram que esses sistemas possuem desempenho próximo a um tutor humano e os melhores desempenhos são encontrados quando o aluno parte dos conhecimentos iniciais sobre determinado assunto.

O desenvolvimento de STIs contém uma série de desafios que o impedem de obter alcance em escala para uso pelos alunos. Segundo Graesser, Hu e Sottolare (2018, p.251-252), são:

- Alto tempo e custo de desenvolvimento.
- A dificuldade em desenvolver ferramentas de autoria para uso por profissionais que não detenham conhecimento em ciência da computação.
- A necessidade de preparar docentes para integrar estes sistemas a sua prática.
- O sistema não está preparado para oferecer respostas úteis a quaisquer necessidades do aluno, a não ser que já esteja desenvolvido. Portanto, o ensino passa a ser centrado no tutor ao invés de ser no aluno.
- A definição sobre quais estratégias de ensino considerar para o desenvolvimentos desses sistemas: as estratégias utilizadas recorrentemente pelos docentes ou as com maior eficácia de aprendizagem pelos estudantes.

Motivado pelos desafios acima elencados nesta publicação de 2018 e considerando que os avanços gerados na IA na última década foram obtidos por meio do *deep learning* (KAUFMAN, 2022, p.11), foi realizada uma pesquisa do estado da arte acerca da evolução dos STIs, utilizando este modelo, no período de 2012 a 2022 (Apêndice A). Foi evidenciado que as pesquisas em STI são ligadas a ciência da computação e tem apresentado preocupações quanto à assertividade do modelo proposto, tanto no aprimoramento do *feedback*, da predição do conhecimento e estados afetivos do aluno e da personalização do ensino. Iniciativas foram identificadas para superação de problemas de evasão de estudantes e não alcance de objetivos educacionais em cursos MOOCs, já utilizadas nas plataformas Coursera e Edx, por exemplo. Verificaram-se aplicações da educação infantil, básica, profissional e superior. No entanto, com apenas uma aplicação para desenvolvimento de habilidades práticas, tão importantes para o mundo do trabalho.

Originária do *deep learning*, a IA generativa explodiu mundialmente com o Chat GPT (*Chat Generative Pretrained Transformer*), da empresa OpenAI, no início de 2023. O *chatbot* é um modelo de Processamento de Linguagem Natural (PLN) capaz de gerar textos em questão de segundos, que “[...] em apenas dois meses, superou 100 milhões de usuários e 13 milhões de visitantes diários” (VALENTE, 2023). A geração de conteúdo em diferentes tipos de mídia é a definição e característica da IA generativa, que utiliza

modelos de *machine learning* com técnicas de *deep learning* (CARLE, 2023). Um dos tipos de IA generativa são os *Large Language Models* (LLM), que são modelos treinados em alto volume de dados, principalmente da *internet*, que criam novos conteúdos em linguagem natural, a partir do que foi aprendido pelo modelo (CARLE, 2023).

Na educação, há preocupações sobre o uso da IA generativa no processo educacional. As preocupações são em relação à dependência que a tecnologia pode gerar aos alunos, que poderão deixar de pensar criticamente ou resolver problemas por conta própria (AFONSO, 2023). Além claro, do uso de informações que não foram de autoria do estudante, mas sim, da IA. Também há a preocupação dos docentes na substituição do seu trabalho. Não se deve também esquecer dos riscos associados ao uso da IA, como: possibilidade de confabulação, preconceito e privacidade.

No entanto, a IA generativa poderá trazer vantagens para docentes como a otimização do tempo e trazer maior qualidade ao planejamento de aulas. Já para alunos, atividades mais complexas que podem levar o aluno à reflexão e à criticidade (AFONSO, 2023). A reflexão e o pensamento crítico que possibilitam melhor decodificação do conhecimento e, conseqüentemente, melhor esse conhecimento é acomodado no aparato cognitivo.

1.1 Problema de pesquisa e objetivos

Com o advento da IA generativa e da complexidade de desenvolvimento de um STI, um *chatbot* pedagógico baseado em engenharia de *prompts* em Modelos de Linguagem de Grande Escala (LLM) poderia fornecer *feedback* personalizado de qualidade para os alunos, colocando-o no processo de aprendizagem, a exemplo de um STI?

Considerando o problema de pesquisa exposto, esta pesquisa tem como objetivo: Investigar as percepções dos educadores sobre a qualidade da personalização do *feedback* em *chatbot* pedagógico baseados em engenharia de *prompts* em LLM.

Para atender ao objetivo geral, os seguintes objetivos específicos foram trabalhados:

1. Examinar como os educadores percebem e interpretam a funcionalidade e a eficácia da engenharia de *prompts* em LLM durante sessões de tutoria conversacional.
2. Identificar e analisar as adaptações percebidas como necessárias pelos educadores para aperfeiçoar a personalização do *feedback* de *chatbots* educacionais baseados em LLM.
3. Investigar a consistência e adequação do *feedback* fornecido por sistemas de LLM em tutoria conversacional, conforme avaliado pelos educadores ao longo de múltiplas sessões.

Tomando por base o problema do presente estudo e seus objetivos, é apresentada na seção a seguir a estrutura da dissertação.

1.2 Estrutura da dissertação

A estrutura da dissertação possui a seguinte organização:

- Capítulo 2: aborda a gênese da IA, apresenta os seus campos e linhas de pesquisa, as tecnologias de IA e sua relação com as linhas de pesquisa; a IA generativa, o LLM e suas formas de treinamento para atuarem em domínios específicos; os STIs, os tipos, suas características e efetividade na aprendizagem.
- Capítulo 3: trata das teorias educacionais na sociedade informacional, as características da interatividade e a relação existente com o processo de aprendizagem utilizando tecnologias educacionais. Neste contexto, também aborda a transposição didática e midiática e a relação com a interatividade. No final do capítulo, avalia a possibilidade de uso de um LLM como um tutor pedagógico e traz exemplos de *prompts* educacionais.
- Capítulo 4: descreve os procedimentos metodológicos de pesquisa.
- Capítulo 5: apresenta a estrutura de linha de comando para configuração do LLM em um *chatbot* pedagógico, traduzindo as características principais de interatividade, adaptabilidade e *feedback*.
- Capítulo 6: apresenta a análise dos dados de acordo com a metodologia apresentada.
- Capítulo 7: traz as considerações finais.
- Por fim, a bibliografia, apêndices e anexos.

A partir da estrutura apresentada, nos próximos dois capítulos serão apresentados o referencial teórico da pesquisa que abrange os aspectos gerais da temática, bem como suas especificidades.

2 IA, *machine learning* e STI

A IA já está presente em toda a sociedade. Está presente nos smartphones, assistentes virtuais, como a Alexa® e Google Nest®, sistemas de *Global Positioning System* (GPS), sistemas de segurança, redes sociais, sistemas de entretenimento e em tantas outras aplicações nos diferentes setores da sociedade, inclusive naqueles mais tradicionais em relação à tecnologia.

Na educação não é diferente, a IA tem o potencial de acelerar o processo de ensino e aprendizagem e contribuir com inovação nas atuais práticas educacionais, contribuindo para uma educação de qualidade, presente no Objetivo de Desenvolvimento Sustentável nº 4 (ODS4), da Organização das Nações Unidas para a Educação, a Ciência e a Cultura (UNESCO) (HOLMES et al., 2021), a qual tem como objetivo: “Assegurar a educação inclusiva e equitativa e de qualidade, e promover oportunidades de aprendizagem ao longo da vida para todas e todos” (UNIDAS, 2015).

A IA é encontrada em diversos aspectos da área de educação, dos processos de ensino e aprendizagem a gestão de ambientes e recursos educacionais. Pode auxiliar o docente na redução de trabalhos operacionais, no apoio na elaboração de planos de ensino e de aula, na seleção e criação de objetos educacionais e na visão individualizada dos desempenhos dos estudantes. Para o aluno, facilita o processo de aprendizagem e se conecta diretamente com o seu mundo. Para a operação da escola, possibilita a otimização e gestão eficiente de recursos, além de tornar o ambiente escolar mais aderente a realidade dos estudantes. É claro, não se limita a apenas estas possibilidades, mas ilustra o potencial de alcance na educação.

O termo IA foi apresentado em um documento intitulado *A proposal for the Dartmouth Summer Research Project on Artificial Intelligence*, escrito por McCarthy, professor assistente do Dartmouth College; Minsky, *Junior Fellow* da Harvard University; Rochester, gestor de pesquisas da informação da IBM Corporation e; Shannon, matemático da Bell Telephone Laboratories.

Propomos que um estudo de dois meses, com dez pessoas, sobre inteligência artificial, seja realizado durante o verão de 1956, no Dartmouth College, em Hanover, New Hampshire. O estudo deve ser realizado com base na conjectura de que todos os aspectos do aprendizado ou qualquer outro recurso da inteligência podem, em princípio, ser descritos com tanta precisão que uma máquina pode ser criada para simulá-los. Será feita uma tentativa de descobrir como fazer com que as máquinas usem a linguagem, formem abstrações e conceitos, resolvam tipos de problemas hoje reservados aos seres humanos e se aperfeiçoem. Acreditamos que um avanço significativo pode ser feito em um ou mais desses problemas, se um grupo de cientistas cuidadosamente selecionados trabalharem nele

durante um verão (MCCARTHY et al., 1955, p.2, tradução nossa).

A IA, segundo o seu fundador McCarthy (2007) “é a ciência e a engenharia de fazer máquinas inteligentes, especialmente programas de computador inteligentes”.

Russell e Norvig (2022, p.1) ao discutir sobre o tema, coloca que há discussões entre os pesquisadores acerca do termo “inteligência” da IA:

Alguns têm definido a inteligência em termos de fidelidade ao desempenho *humano*, enquanto outros preferem uma definição abstrata e formal da inteligência, chamada de **racionalidade** – em termos gerais, fazer a “coisa certa”. O tema em si também varia: alguns consideram a inteligência como uma propriedade dos *processos de pensamento e raciocínio internos*, enquanto outros enfocam o *comportamento* inteligente, uma caracterização externa (grifo do autor).

Diante dessa visão, Russell e Norvig (2022) colocam que há 4 campos de pesquisas em IA que são gerados a partir do cruzamento entre: desempenho humano e racionalidade e processos de pensamento e comportamento, resumidos na figura 2. Cada um dos quadrantes contém a definição da IA de acordo com os autores informados:

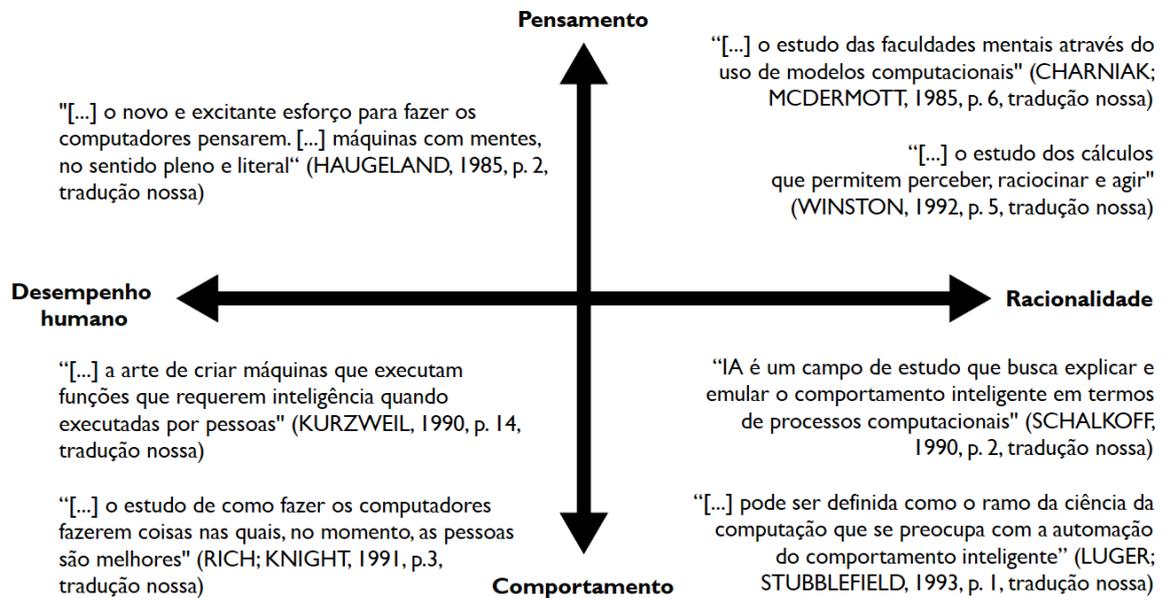
- No primeiro quadrante configuram-se sistemas que pensam de forma racional, conforme definição de Charniak e Mcdermott (1985) e Winston (1992).
- No segundo quadrante configuram-se sistemas que pensam e possuem desempenho como humanos, conforme definido por Haugeland (1985).
- No terceiro quadrante apresentam-se os sistemas que agem e desempenham como humano, como definido por Kurzweil (1990) e Rich e Knight (1991).
- No quarto quadrante estão os sistemas que agem de forma racional, na definição de Luger e Stubblefield (1993) e Schalkoff (1990).

Considerando os diversos campos existentes, o campo de pesquisa que leva em consideração o comportamento e a racionalidade é o que vem predominando nos estudos de IA (RUSSELL; NORVIG, 2022). Essa predominância se deve às características da matemática, como: abstração, precisão e rigor lógico (BRASIL, 1997, p.23). Essas características permitem uma inferência mais próxima do que é esperado em um cenário de incerteza (RUSSELL; NORVIG, 2022).

Neste sentido, Russell e Norvig (2022, p.4) define a IA por meio de um modelo padrão, como um campo de estudo que se concentra na “[...] construção de agentes que fazem a coisa certa. Aquilo que é considerado a coisa certa é definido pelo objetivo que oferecemos ao agente”.

Devido à interdisciplinaridade desse campo de estudo, algumas disciplinas contribuem com seus conhecimentos para a área, tais como: a filosofia, a matemática, a economia,

Figura 2 – Campos de pesquisa da IA



Fonte: Adaptado de Russell (c2023)

a neurociência, a psicologia, a ciência da computação, a teoria de controle cibernético, a linguística, dentre outras (RUSSELL; NORVIG, 2022).

Segundo Medeiros (2018, p.23), a confluência dessas disciplinas levou pesquisadores a terem questionamentos em comum acerca do funcionamento do cérebro ou da mente, levando a duas linhas de pesquisa:

- **Conexionista:** linha que tem como perspectiva a criação de neurônios artificiais, que emulam o cérebro nos seus aspectos biológicos. Um exemplo é a Rede Neural Artificial (ANN), que “é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse” (HAYKIN, 2007, p.28).
- **Simbólica:** linha que atua com IA no processamento de símbolos, emulando a mente. De acordo com esse paradigma, “[...] qualquer sistema (humano ou máquina) que demonstre inteligência deve operar manipulando estruturas de dados compostas por símbolos” (RUSSELL; NORVIG, 2022, p.17). Um exemplo são os sistemas especialistas, onde o conhecimento especializado de um ser humano é codificado para a solução de problemas, onde o sistema se comporta como um humano. Os sistemas especialistas são um dos tipos de sistemas de conhecimento, caracterizados por um mecanismo de inferência e uma base de conhecimento. A base de conhecimento é composta por aquisição e representações do conhecimento.

Medeiros (2018, p.24) ainda informa que há outra linha que não se limita ao

funcionamento do cérebro e da mente, a linha evolucionária surge com objetivo de estudo do “[...] modo como se processa a evolução biológica sobre o planeta, que buscam simular processos evolucionários semelhantes em sistemas de computador com vistas à resolução de problemas”. Os algoritmos genéticos são o exemplo clássico desta linha de pesquisa. “Trata-se de uma classe de algoritmos de busca, que implementam conceitualmente uma solução inicial, a qual evolui ao longo da execução do próprio algoritmo”. Luger (2013, p.339) chama-a de Método Genético.

Já Luger (2013, p.340) traz ainda as abordagens estocásticas, e apresenta dois motivos para uso deste método:

[...] primeiro, os eventos podem ser genuinamente relacionados um ao outro de forma probabilística, e, segundo, as relações causais determinísticas entre situações no mundo em mudança podem ser tão complexas que suas interações são mais bem capturadas por modelos estocásticos (LUGER, 2013, p.470).

A IA possui diversas técnicas, métodos e tecnologias empregados que tornam bastante desafiador relatar em poucas páginas o que existe na área, inclusive com termos variados. No entanto, Corea (2018) elaborou um diagrama (Figura 3) que traz os diferentes métodos e possíveis domínios de resolução de problemas que a IA pode proporcionar.

No eixo das ordenadas, estão os possíveis problemas que a IA pode ou poderá solucionar, conforme descrito por Corea (2018, p.27):

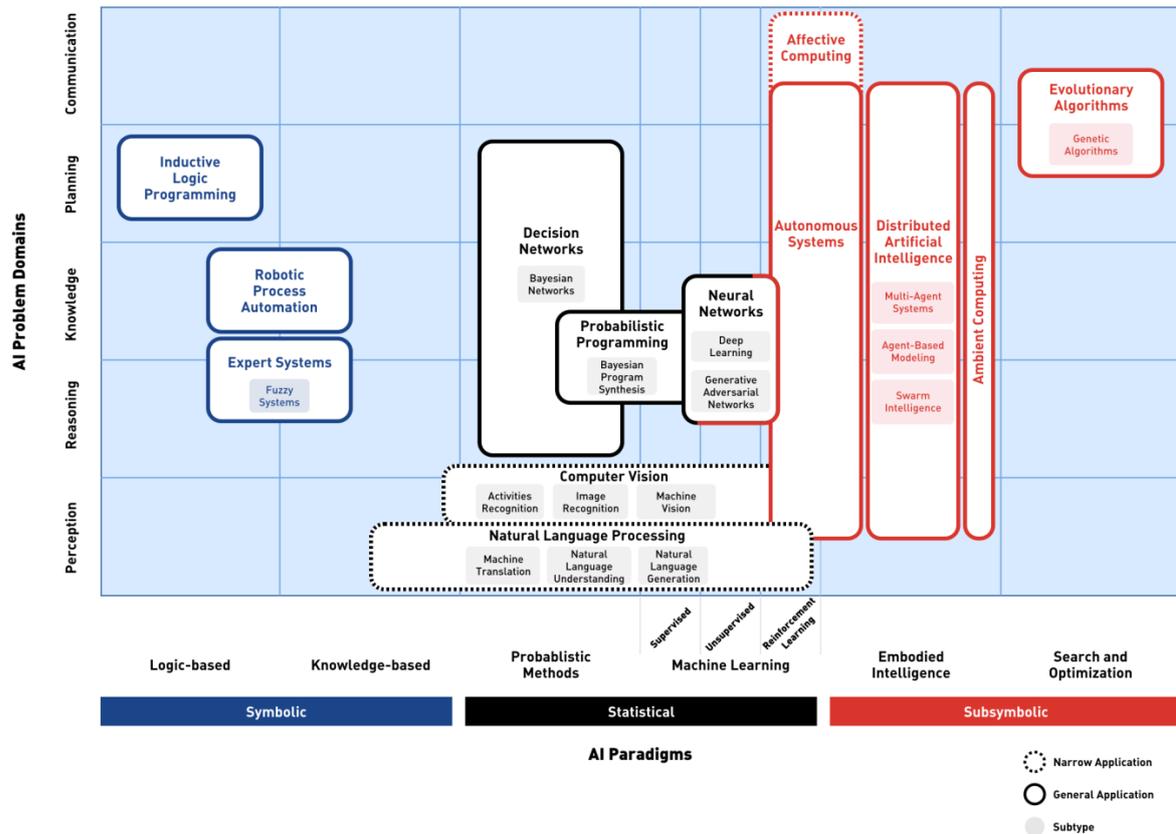
- Percepção: capacidade da IA de transformar informações sensoriais em informação.
- Raciocínio: Capacidade da IA de solucionar problemas.
- Conhecimento: Capacidade da IA de conhecer e representar o mundo.
- Planejamento: Capacidade da IA de atingir e estabelecer metas.
- Comunicação: Capacidade da IA de compreender a linguagem e realizar comunicação.

No eixo das abcissas são as abordagens da IA, a qual será correlacionada com as definições realizadas por Luger (2013) e Medeiros (2018):

- *Symbolic*: IA simbólica.
- *Subsymbolic*: É aproximado com a IA conexionista e evolucionária.
- *Statistical AI*: É uma subárea da IA estocástica.

Acima das abordagens da IA, há os paradigmas de IA, descritos por Corea (2018, p.26, tradução nossa):

Figura 3 – Diagrama de conhecimento da IA



Fonte: (COREA, 2018, p.26)

Logic-based tools: ferramentas que são usadas para representação de conhecimento e solução de problemas.

Knowledge-based tools: ferramentas baseadas em ontologias e enormes bancos de dados de conceitos, informações e regras.

Probabilistic methods: ferramentas que permitem aos agentes atuarem em cenários de informação incompleta.

Machine learning: ferramentas que permitem que os computadores aprendam com os dados.

Embodied intelligence: caixa de ferramentas de engenharia, que assume que um corpo (ou pelo menos um conjunto parcial de funções como movimento, percepção, interação e visualização) é necessário para uma inteligência superior.

Search and optimization: ferramentas que permitem uma pesquisa inteligente com muitas soluções possíveis.

As tecnologias são apoiadas nas respectivas abordagens, paradigmas e problemas que podem ou poderão solucionar. Neste trabalho será dado foco para o paradigma de *Machine learning* e a tecnologia de redes neurais, onde se concentra o *deep learning*. No entanto, ao longo do trabalho haverá menções as tecnologias de:

- Visão computacional: “métodos para adquirir e dar sentido a imagens digitais (geralmente divididos em atividades de reconhecimento de imagens e visão de máquina) (COREA, 2018, p.28, tradução nossa).
- Processamento de Linguagem Natural: “subcampo que lida com dados de linguagem natural ([...] compreensão de linguagem, geração de linguagem e tradução automática)” (COREA, 2018, p.28, tradução nossa).
- Computação afetiva: “um subcampo que lida com o reconhecimento, interpretação e simulação de emoções” (COREA, 2018, p.29, tradução nossa).
- Redes neurais (NNs) ou Redes Neurais Artificial (ANN): Há uma série de arquiteturas existentes, sendo trazidas apenas alguns exemplos:
 - *Deep Learning*: uma rede neural com várias camadas (COREA, 2018, p.28).
 - *Generative Adversarial Networks* (GANs): duas redes que treinam umas às outras (COREA, 2018, p.28).
 - Redes Neurais Convolucionais (CNNs): “usadas principalmente em aplicativos de visão computacional e classificação de imagens” (IBM, 2023).
 - Redes Neurais Recorrentes (RNNs), “normalmente usados em aplicativos de linguagem natural e reconhecimento de fala” (IBM, 2023).
 - Rede Neural *Transformer*, que “aprende o contexto e, assim, o significado, com o monitoramento de relações em dados sequenciais como as palavras desta frase” (MERRITT, 2022).
 - Redes de *Autoencoders* Variacionais (VAEs), utilizadas para a geração de novos dados utilizando como base o que foi aprendido com o treinamento (MARTINEAU, 2023)

De acordo com Russell e Norvig (2022, p. 590), um agente inteligente necessita observar o contexto a qual está inserido para aprender mais acerca dele e melhorar sua performance. “Quando o agente é um computador, nós o chamamos aprendizado de máquina: um computador observa alguns dados, monta um modelo baseado nos dados e usa o modelo como uma hipótese sobre o mundo e um software que pode resolver problemas” (RUSSELL; NORVIG, 2022, p. 590). Esse aprendizado pode ser supervisionado, não supervisionado e por reforço.

Ainda de acordo com o autor, o aprendizado supervisionado ocorre com base em dados que possuem rótulos, ou seja, uma identificação do que a máquina está observando, a exemplo de uma tabela de uma planilha eletrônica, onde a primeira linha representa o que é aquela coluna de dados. Já o não supervisionado é quando os dados não possuem rótulos, ou seja, é necessário que a máquina utilize o algoritmo para realizar agrupamentos

e produzir inferências sobre o que é aquele dado. Por fim, o aprendizado por reforço se dá a partir do *feedback* positivo ou negativo, composto por recompensas e punições.

Inspirado nos neurônios do cérebro humano, as redes neurais processam as informações por meio de cálculos matemáticos e transmitem para outros neurônios. As conexões recebem pesos de acordo com a força do sinal entre os neurônios, muitas vezes chamados de parâmetros. As redes neurais com três ou mais camadas são chamadas de *deep learning* (IBM, 2023). O *deep learning* é uma técnica dentro de *machine learning*, caracterizado por Russell e Norvig (2022, p.679) como:

[...] é uma grande família de técnicas de aprendizado de máquina em que as hipóteses assumem a forma de circuitos algébricos complexos com intensidades de conexão ajustáveis. A palavra “profundo” se refere ao fato de que os circuitos são normalmente organizados em muitas camadas, o que significa que os caminhos de computação das entradas para as saídas têm muitas etapas. Aprendizado profundo é atualmente a abordagem mais usada para aplicações como reconhecimento visual de objetos, tradução automática, reconhecimento de voz, síntese de voz e síntese de imagem; ele também desempenha um papel significativo nas aplicações de aprendizado por reforço.

As Redes Neurais GANs, RNN e *Transformers* são exemplos comuns daquilo que é utilizado no que se chama de IA generativa (PATEL, 2023), não se limitando somente a esta última, a qual será tratada na próxima seção.

2.1 IA generativa e LLMs

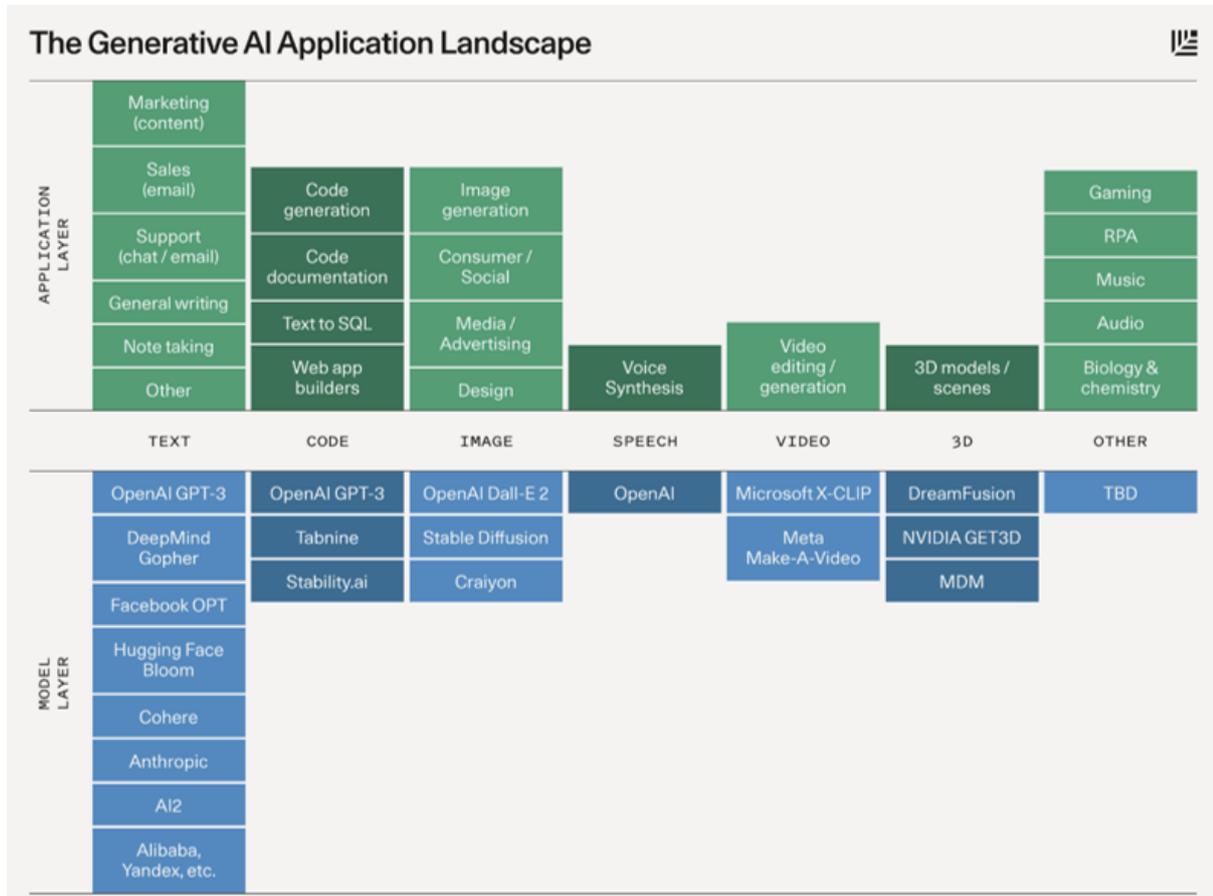
Dois termos fazem parte do título dessa seção: IA generativa e LLMs. A explosão de divulgação na mídia de ambos os termos se deu com o lançamento do ChatGPT, da OpenAI, com o impressionante resultado que o *chatbot* retornava após a inserção de um comando no seu campo de texto. Virou febre mundial e impulsionou o lançamento de tantas outras aplicações de IA que criavam coisas. O Dall-E, aplicação também da OpenAI, que gera imagens a partir de instruções dadas pelo usuário, foi outro exemplo que também alcançou midiático sucesso.

A IA generativa não surgiu com o chatGPT, já existia há algum tempo na Estatística para análise de dados numéricos e escalou a partir das Redes de *Autoencoders* Variacionais (MARTINEAU, 2023). “Os VAEs foram os primeiros modelos a serem amplamente utilizados para gerar imagens e fala realistas” (MARTINEAU, 2023, tradução nossa).

IA generativa é uma definição ampla para IAs que conseguem gerar informações novas são técnicas de *deep learning* e redes neurais que utilizam o que aprenderam com os dados que foram treinados e criam algo totalmente novo em diferentes tipos de mídia que se assemelham ao que é gerado pelos seres humanos, como, por exemplo: imagem, texto,

vídeo, códigos de *software* e modelos de moléculas (CARLE, 2023) (MARTINEAU, 2023) (RAY, 2023). Alguns exemplos de aplicações de IA podem ser vistos na Figura 4, onde cada modelo de IA, em azul, pode gerar as aplicações em verde.

Figura 4 – Modelos de IA e possíveis aplicações de IA generativa



Fonte: (HUANG, 2022)

Em uma publicação de 2023, Huang e Grady (2023) atualizaram o quadro da Figura 4 trazendo as aplicações existentes, mas sem a menção dos modelos de IA na Figura 5. Nota-se o quanto a IA está crescendo e trazendo valor para os negócios em diferentes áreas.

O ChatGPT possui o acrônimo GPT, que significa *Generative Pre-trained Transformer*. O significado de cada palavra:

- Generativo (*Generative*): Dada uma instrução inserida no campo de texto do *chatbot*, o aplicativo consegue gerar textos em linguagem natural de forma coerente para o usuário.
- Pré-treinado (*Pre-trained*): O *chatbot* foi treinado em um alto volume de dados antes de ser designado para uma tarefa específica. A aplicação da OpenAI, na versão 3.5,

Figura 5 – Aplicações de IA generativa



Fonte: (HUANG; GRADY, 2023)

foi treinada com 40 *Terabytes* de dados, além de 8 milhões de artigos da Wikipedia, e com o banco de dados de *tweets*, do antigo Twitter (ALENCAR, 2023).

- Transformador (*Transformer*): Utiliza a rede neural *Transformer*.

Neste sentido, o GPT é um *Large Language Model* (LLM) - *large* devido ao alto volume de dados em que foi treinado, projetado para geração de textos e compreensão da linguagem em linguagem natural e com 6,7 bilhões de parâmetros (RAY, 2023, p.122). Na versão 3.5, ele foi projetado para superar limitações encontradas em RNNs e CNNs (RAY, 2023, p.122). Nessa versão, o ChatGPT possui as seguintes melhorias, segundo (RAY, 2023, p.122):

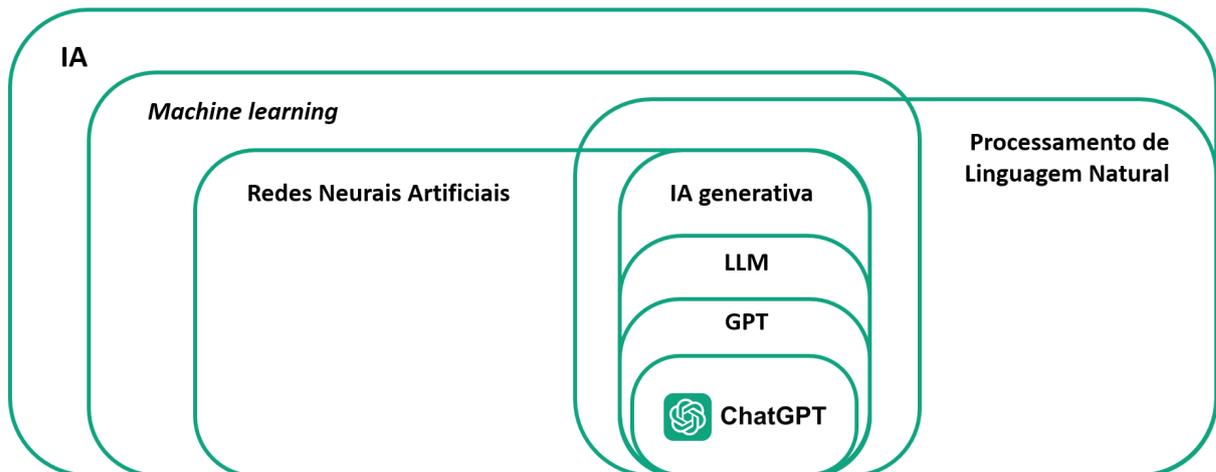
- Compreensão de contextos, de entradas complexas e com nuances, possibilitando a geração de textos mais precisos e com relevância.
- Minimização de vieses.
- Possibilidade de ajuste fino para atuar em aplicações específicas em diferentes domínios.

Com base na explicação acerca do *chatbot* da OpenAI, define-se o que são os LLMs, um tipo de IA generativa, que tem como objetivo gerar textos novos, semelhantes ao gerado pelo ser humano, que seja coerente e contextualmente relevante, prevendo qual palavra (*token*) tem maior probabilidade de acontecer após uma palavra prévia de uma frase (BROWN et al., 2020) (CARLE, 2023) (LI, 2022). As bases de dados em que são treinados podem conter vieses e questões éticas trazidas por quem as gerou, os próprios seres humanos, aumentando a complexidade de interpretação e análise (RAY, 2023). Os LLMs são usados em uma ampla gama de aplicações, incluindo tradução de idiomas, *chatbots*, resumo de texto, análise de sentimento, finanças, e saúde (RAY, 2023, p.134). Alguns outros exemplos de LLM são: Bard, do Google; Llama da Meta; e, Claude, da Anthropic.

Segundo Bell (2023, tradução nossa), “as ferramentas de IA generativa são construídas em modelos de IA subjacentes, como um LLM. LLMs são a parte geradora de texto da IA generativa”. Os LLMs, até então, só podiam criar saídas de texto por meio de entradas de texto. No entanto, esse cenário mudou a partir do GPT-4, que permitirá entradas multimodais, como, por exemplo: áudio e imagem (BELL, 2023). Um Diagrama de Venn foi elaborado de forma que ficasse mais explícita a relação entre todos os conceitos até a aplicação da OpenAI, conforme pode ser visto na Figura 6.

O LLM pode atuar de maneira personalizada para atuar em domínio específico sem a necessidade de treinamento com dados rotulados, a exemplo do que acontece no aprendizado supervisionado (MARTINEAU, 2023). É necessário somente solicitar ao

Figura 6 – Diagrama de Venn que explicita a relação entre os conceitos abordados de IA



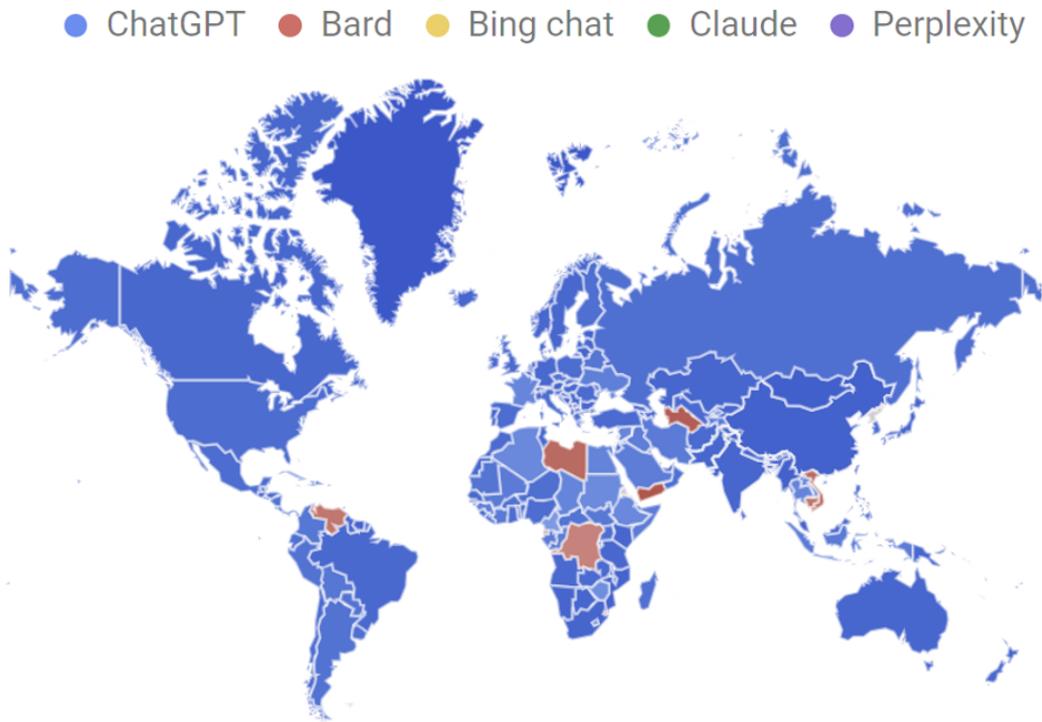
Fonte: Adaptado de Triggo.AI (2023), Bell (2023) e Zwingmann (2023)

modelo a realização de uma tarefa por meio de uma instrução inserido na aplicação, chamada de *prompt* (MARTINEAU, 2023). A abordagem sem uso de dados prévios, como exemplos, é chamada de aprendizagem *zero-shot* (MARTINEAU, 2023). Quando se dão dados de exemplos para que o LLM retorne de forma mais precisa, o aprendizado é chamado de *few-shot* (MARTINEAU, 2023). Essa forma permite a criação rápida de aplicações em IA e uma nova disciplina foi criada de forma a criar *prompts* assertivos para obtenção do resultado esperado por meio da organização cuidadosa das palavras, chamada de *prompt engineering* (MARTINEAU, 2023) (LORICA, 2023).

Outras técnicas ainda existem, como o *fine-tuning* e o *Reinforcement Learning from Human Feedback* (RLHF) (LORICA, 2023). O *fine-tuning* é uma técnica utilizada, principalmente, quando se deseja aperfeiçoar o LLM para uma tarefa específica e bem definida, por meio do seu treinamento com dados rotulados específicos ou proprietários (LORICA, 2023). Em geral, se utiliza grande volume de dados para esta técnica (LORICA, 2023). Já o RLHF envolve o uso do *fine-tuning*, em que, ao ser treinado e imputado um *prompt*, a resposta do LLM é avaliada por um ser humano que dá *feedback* positivo ou negativo (LORICA, 2023). O LLM ao recebê-lo ajusta os seus pesos. O RLHF é útil quando se tem poucos dados rotulados para o *fine-tuning* e é necessária uma tarefa, sendo realizada com precisão (LORICA, 2023).

Como o objetivo dessa dissertação é investigar as percepções dos educadores sobre a qualidade da personalização do *feedback* em *chatbot* pedagógico baseados em engenharia de *prompts* em LLM, será utilizado o ChatGPT. A escolha do LLM se deve à disseminação em larga escala já obtida e apresentada na Figura 7.

Figura 7 – Tendência de pesquisa mundial no Google, nos últimos 90 dias, acerca dos principais LLMs



Fonte: (TRENDS, 2024)

2.2 A técnica de engenharia de *prompts*

A utilização da técnica de *prompt engineering* ou engenharia de *prompt* propõe uma cuidadosa e organizada estrutura de frases para que o LLM possa retornar com sucesso a resposta esperada pelo usuário. A OpenAI (c2023) detalha estratégias e táticas que podem ser aplicadas de forma combinada. As principais são apresentadas a seguir:

- Estratégia 1 - Elaborar instruções claras:
 - Tática 1 - É necessário detalhar e incluir contexto na solicitação para obter respostas mais precisas.
 - Tática 2 - Deve ser solicitado ao modelo que adote uma persona. A persona é uma representação fictícia de uma pessoa.
 - Tática 3 - “Delimitadores como aspas triplas, tags *eXtensible Markup Language* (XML), títulos de seções, etc. podem ajudar a demarcar seções de texto para serem tratadas de forma diferente” (tradução nossa).
 - Tática 4 - Informar as etapas para a realização de uma tarefa.
 - Tática 5 - Informar instruções gerais que sirvam para todos os exemplos.
 - Tática 6 - Informar qual o tamanho da resposta de saída.

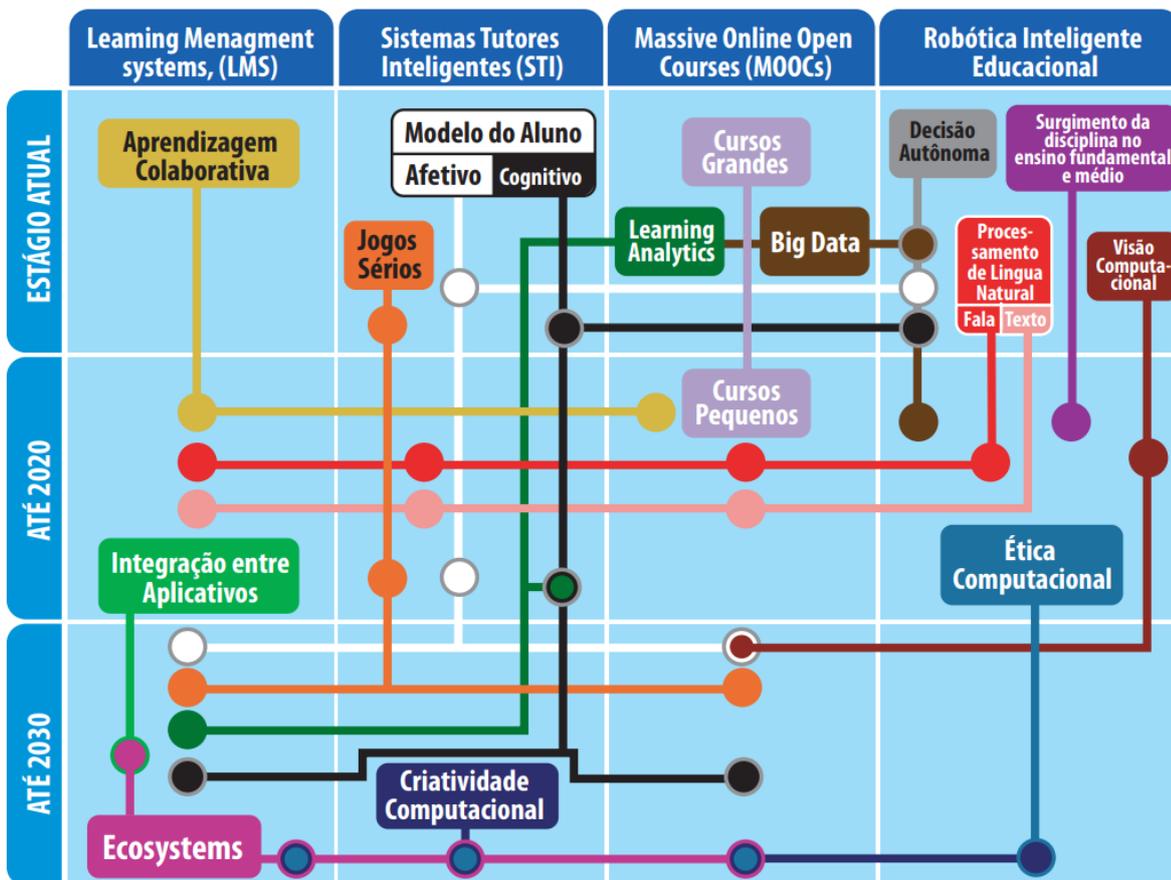
- Estratégia 2 - Elaborar texto de referência:
 - Fazer com que a resposta de saída seja elaborada a partir de um texto de referência previamente informado.
 - Fazer com que a resposta de saída informe a citação de onde foi retirado o texto.
- Estratégia 3 - Tornar tarefas complexas em tarefas simples:
 - “Para tarefas em que muitos conjuntos independentes de instruções são necessários para lidar com casos diferentes, pode ser melhor classificar o tipo de consulta e usá-la para determinar quais instruções são necessárias” (tradução nossa).
 - Para diálogos longos, é possível fazer o sistema resumir ou filtrar o diálogo anterior, podendo utilizar na conversa seguinte.
 - O sistema possui um tamanho limitado de contexto, limitando o quanto de resumo ele consegue retornar a partir de um determinado texto longo. Nesse sentido, a aplicação não conseguiria resumir um livro, por exemplo, mas poderá realizar resumo de seções e, depois, realizar o resumo dos resumos dessas seções.
- Estratégia 4 - Dar tempo para o modelo processar:
 - Instruir o LLM a processar na sua própria solução antes de dar uma resposta ao que foi solicitado.
 - “Usar monólogo interno ou uma sequência de consultas para ocultar o processo de raciocínio do modelo. A ideia é instruí-lo a colocar partes da saída que devem ser ocultadas do usuário em um formato estruturado que facilite a análise” (tradução nossa). Segundo a OpenAI (c2023), essa tática é importante para aplicações de tutoria em que o processo de elaboração da resposta deve ser feito pelo aluno e não respondido pelo modelo.
 - “Pergunte ao modelo se ele errou alguma coisa nos passos anteriores” (tradução nossa). Isso é útil para que o modelo confira as saídas anteriores antes de redigir uma nova saída.
- Estratégia 5 - Utilizar ferramentas externas: uma possibilidade é inserir informações externa no modelo de forma que ele possa ser mais eficiente. “Por exemplo, se um usuário fizer uma pergunta sobre um filme específico, pode ser útil adicionar informações de alta qualidade sobre o filme (por exemplo, atores, diretor, entre outras) à entrada do modelo” (tradução nossa).
- Estratégia 6 - Testar alterações continuamente, de forma que garanta uma resposta adequada ao que foi pretendido.

A documentação da OpenAI (c2023) traz exemplos para cada uma das estratégias e táticas apresentadas acima, e outras táticas, as quais podem ser visualizadas em: <<https://platform.openai.com/docs/guides/prompt-engineering>>.

2.3 Prospectiva tecnológica da IA na Educação

O SENAI, ente pertencente à Confederação Nacional da Indústria (CNI), em um estudo prospectivo intitulado Tendências em Inteligência Artificial na Educação no Período de 2017 a 2030, apresentou cenários de aplicação da IA com base em levantamentos em bases de pesquisa e patentes. Os resultados foram apresentados em um *Roadmap* tecnológico (Figura 8), divididos em períodos de tempo (estágio atual, até 2020 e até 2030) e as áreas da computação mais proeminentes.

Figura 8 – *Roadmap* tecnológico: prospecção das tendências em IA na Educação até 2030



Fonte: (SENAI, 2018, p.22)

Segundo o SENAI (2018), os retângulos representam as tecnologias e o quanto elas estarão presentes nas áreas da computação proeminentes ao longo do tempo. Como pode ser visto na Figura 8, os STIs no “estágio atual” (neste caso, 2018, na época da publicação) estavam como tendência o modelo do aluno no âmbito afetivo e cognitivo. A linha branca,

do modelo afetivo, percorre até 2030, mas amplia-se até o referido ano para os sistemas LMSs e MOOCs.

A ampliação do STI tem explicações plausíveis corroboradas com as necessidades apresentadas no Capítulo 1, como: aumento da interatividade, redução da distância transacional, *feedback* ao aluno, geração de reflexão no aluno para aumentar sua autorregulação da aprendizagem, redução de custos de operação, redução de evasão, alcance de objetivos educacionais e adaptabilidade ao aluno.

Já o modelo cognitivo (linha preta) tem a mesma tendência apresentada para o modelo afetivo, mas extrapolando para a área de Robótica Inteligente Educacional. Os jogos sérios (linha laranja) faziam parte do “estágio atual” e são tendência para 2030 em sistemas LMSs e MOOCs. PLN para fala e texto e *Learning Analytics* apesar de não terem origem nos STIs, impactaram-no até 2020.

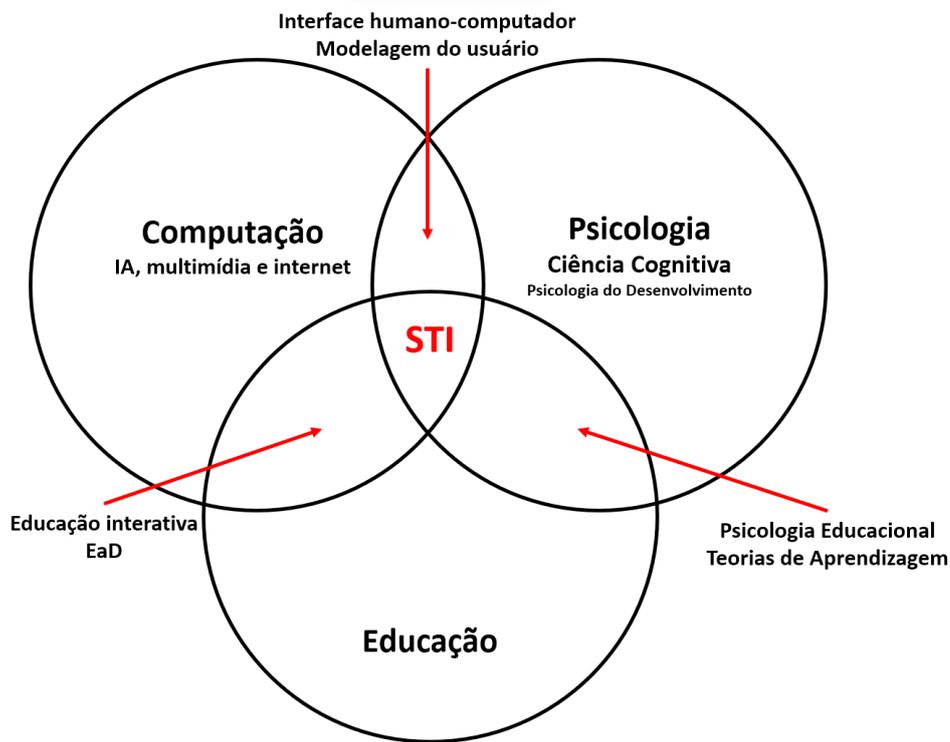
A aprendizagem colaborativa, tão pertinente na sociedade informacional, não é tendência para STIs. Portanto, poderá ser um novo campo de estudo e que é necessário investigações acerca do não uso pelo menos até 2030.

Por fim, até 2030, o relatório traz a criatividade computacional como uma tecnologia que terá origem nos STIs e extrapolará para as demais áreas. Sobre o tema, SENAI (2018, p.26) traz:

A Criatividade Computacional é um tema de pesquisa relativamente novo. Seu surgimento está ligado às artes, em particular à produção artística, da chamada arte computacional, vinculada à programação através de modelos matemáticos e da ótica (visão e reconhecimento de imagens). [...] O tema vem sendo apresentado ligado aos STIs e à Robótica (no *Roadmap* optamos por colocá-lo vinculado aos STIs no período 2020-2030, mas poderia também estar localizada no espaço da Robótica). Nos sistemas de ensino-aprendizagem, espera-se que as aplicações da Criatividade Computacional permitam, entre outras coisas, a geração de exemplos, exercícios criativos para enriquecer os conteúdos educacionais, de forma on-line. Isso poderá acontecer, por exemplo, através da integração de aplicativos, como bancos de Objetos de Aprendizagem, Recursos Educacionais Abertos, *web* etc. Ainda, em um futuro a logo prazo, quem sabe, estes sistemas poderão reconhecer atividades criativas realizadas pelos alunos.

Apesar do relatório ser de 2018, há o prelúdio do ChatGPT, tecnologia da OpenAI de IA Generativa, que pode ser um ensaio para a referida Criatividade Computacional e, ainda, poderá ser uma alternativa para apoiar os módulos tutor e especialista no processo de ensino e aprendizagem, sendo este último módulo um dos pontos que mais encarecem o desenvolvimento de STIs.

Figura 9 – Relação entre disciplinas para o desenvolvimento de STIs



Fonte: Adaptado de Woolf (2009)

2.4 STI

Uma das tecnologias de IA aplicadas a educação são os Sistemas Tutores Inteligentes (STI). Esses sistemas são computadores que apoiam o aluno no domínio de conhecimentos e habilidades por meio de algoritmos que se adaptam às necessidades do aluno (GRAESSER; HU; SOTTILARE, 2018). Um STI identifica os conhecimentos, habilidades e aspectos psicológicos dos estudantes por meio de IA e estudos da cognição humana, respondendo às suas necessidades por meio de *feedback* adaptativo (GRAESSER; HU; SOTTILARE, 2018). Geralmente, são aplicados de forma individual para o aluno, mas é possível ser utilizado em pequenos grupos (GRAESSER; HU; SOTTILARE, 2018). Os STIs têm como proposta colocar o estudante no centro do processo de ensino e aprendizagem.

O desenvolvimento desses sistemas envolvem áreas interdisciplinares, como: IA, linguística computacional e ciências cognitivas, sendo esta última a intersecção entre as áreas da psicologia cognitiva e da educação (TROUSSAS; VIRVOU, 2020). Woolf (2009, p.42) apresenta o diagrama na Figura 9, onde é possível ver as intersecções de cada disciplina, as quais são abordadas ao longo dos capítulos desta dissertação.

A psicologia, especialmente o subcampo da ciência cognitiva, explora e compreende como as pessoas pensam e aprendem, oferecendo valiosas contribuições para a educação (WOOLF, 2009, p.42-43). Tanto a ciência cognitiva quanto a IA estão interessadas em compreender o que constitui a ação inteligente, independentemente de como ela possa ser

apresentada (WOOLF, 2009, p.43). Por isso, a IA busca criar sistemas capazes de exibir características associadas à inteligência, como: aprendizagem, raciocínio, resolução de problemas e compreensão da linguagem (WOOLF, 2009, p.43). A autora cita que é improvável a criação de um sistema de IA não fundamentado em uma teoria de aprendizagem.

Já a educação concentra-se em estratégias para apoiar o ensino (WOOLF, 2009, p.44). A disciplina atua na forma como o docente ensina e como a experiência de aprendizagem é influenciada pela comunicação, pelo planejamento do curso, pelo currículo, pela avaliação e pela motivação (WOOLF, 2009, p.44). Portanto, baseada em teorias de aprendizagem, que formulam princípios de como as pessoas aprendem, a educação é focada em métodos e técnicas para melhoria da aquisição, manipulação e aplicação do conhecimento sob as condições necessárias para que ocorra a aprendizagem (WOOLF, 2009, p.44).

Os STIs tiveram sua origem no final da década de 60 em substituições aos *Computer Assisted Instruction* (CAI) e *Intelligent Computer Assisted Instruction* (ICAI). Por razões históricas, muitas das pesquisas no domínio de software educacional envolvendo IA foi realizada com o nome de ICAI. Por sua vez, evoluiu do nome CAI que muitas vezes se refere ao uso de computadores na educação. No entanto, na literatura é comum encontrar ITS e ICAI como sinônimos (NWANA, 1990).

Eles foram desenvolvidos a partir [...] do CAI, que foi iniciada na década de 1950 como programas lineares baseados na Teoria Comportamental de Skinner. O problema central com esses sistemas iniciais era que eles não forneciam *feedbacks* ricos ou individualizados, pois não foram projetados para saber o que ensinavam, a quem ensinavam ou como ensinavam. Para resolver esse problema, os sistemas CAI [...] evoluíram [...] para o que agora é geralmente chamado de *Intelligent Tutoring Systems*. (NWANA, 1990, p.4, tradução nossa).

A dinâmica dos CAIs eram a seguinte: o aluno estudava o material, era submetido a um teste aplicado pelo sistema, que respondia se estava certo ou errado. Com o desempenho suficiente avançava para a próxima etapa. A ordem das questões eram da menos complexa para a mais complexa ou por pré-requisitos. Estes sistemas possuíam pouca interação e eram iguais para todos os estudantes (GRAESSER; HU; SOTTILARE, 2018).

Os STIs com tecnologia de IA possibilitaram uma ampla gama de interações, participação ativa e adaptabilidade única para cada estudante. A literatura mostra que esses sistemas possuem desempenho próximo a um tutor humano e os melhores desempenhos são encontrados quando o aluno parte dos conhecimentos iniciais sobre determinado assunto (GRAESSER; HU; SOTTILARE, 2018)

Além da interatividade, adaptabilidade e *feedback*, outras também podem ser encontradas, segundo Graesser, Hu e Sottolare (2018, p.247, tradução nossa):

Escolha. O sistema oferece aos alunos opções sobre o que aprender para incentivar a aprendizagem autorregulada.

Acesso não-linear. A tecnologia permite que o aluno selecione ou receba atividades de aprendizagem em uma ordem que desvia da ordem de um *script* rígido.

Representações vinculadas. O sistema fornece conexões rápidas entre representações que enfatizam diferentes pontos de vista conceituais, estratégias pedagógicas e mídia.

Entrada aberta do aluno. O sistema permite que os alunos se expressem por meio de linguagem, desenhos e outras formas de comunicação aberta.

A arquitetura de um STI são compostas por componentes, trazida por Woolf (2009, p.44-45), a seguir:

- **Conhecimento de domínio:** contém o conhecimento de uma determinada área, fornecido por um especialista e possui duas funções. Primeiramente, serve como fonte de conhecimento a ser apresentado ao aluno, o que inclui gerar perguntas, explicações e respostas. Em segundo lugar, fornece um padrão para avaliar o desempenho e o progresso geral do aluno. Para esta última, deve ser capaz de gerar soluções para problemas no mesmo contexto do aluno, para que as respostas correspondentes possam ser comparadas. O módulo também deve ser capaz de detectar erros sistemáticos comuns e, se possível, identificar quaisquer erros de representação implícitos (NWANA, 1990, p.9).
- **Conhecimento do aluno:** contém o conhecimento do aluno sobre o domínio, o seu estilo de aprendizagem e informações afetivas. Responsável por criar um modelo que inclui “[...] todos os aspectos comportamentais e de conhecimento do aluno que possam gerar repercussões em sua performance e aprendizado”(NWANA, 1990, p.10, tradução nossa). A tecnologia atual permite a captação de expressões e movimentos realizados durante o uso da tela por meio das mãos. Estes dados também podem fazer parte do modelo de aluno. Um ponto crítico e que possui discussões no meio acadêmico é a ética e permissão de uso desses dados pelos estudantes. Esse módulo pode desempenhar duas funções principais, segundo Nwana (1990, p.11, tradução nossa):

Servir como fonte de informação sobre o aluno e como representação do aluno. Para alcançar essas funções, eles atuam em papéis como corretivo, elaborativo, estratégico, diagnóstico, preditivo e avaliativo. O modelo de aluno permite que o estado de conhecimento do aluno seja comparado com o módulo de conhecimento do especialista e, em seguida, a instrução seria influenciada por partes do modelo mostradas como fracas (portanto, a função do modelo de aluno aqui é elaborativa). [...] Além disso, os modelos de alunos também são esperados para serem executáveis, o que permite uma previsão exata sobre um aluno específico em um contexto específico (portanto, a função do modelo de aluno aqui é preditiva).

- **Conhecimento da tutoria:** contém as estratégias de ensino e inclui métodos para codificar o raciocínio sobre o *feedback*. É construído baseado em teorias educacionais conhecidas pelo docente ou de conhecimento empírico. A partir do modelo do aluno, faz decisões sobre estratégias pedagógicas, define quais atividades pedagógicas serão apresentadas de acordo com o definido no módulo especialista. É considerado a fonte de toda intervenção pedagógica e que produz a experiência de aprendizagem (NWANA, 1990, p.12). As decisões desse componente são refletidas em diferentes formas de interação com o aluno, como por exemplo: diálogos socráticos, dicas, *feedback* do sistema, entre outros. De forma geral, as interações do aluno e do tutor ocorrem por meio da interface de aprendizagem, também conhecida como módulo de interface do usuário (NKAMBOU; MIZOGUCHI; BOURDEAU, 2010, p.5).
- **Conhecimento da comunicação:** representa o método de comunicação entre o aluno e o computador. É apresentado por meio de interface gráfica, agentes animados ou mecanismos de diálogo. “Inclui gerenciar a comunicação, discutir o raciocínio dos alunos, esboçar gráficos para ilustrar um ponto, mostrar ou detectar emoções e explicar como as conclusões foram alcançadas”.

Na visão de Woolf (2009, p.45, tradução nossa), algumas combinações desses componentes são utilizadas em STI. A autora explica a dinâmica de funcionamento quando envolve os quatro componentes:

[...] um ciclo de ensino pode primeiro pesquisar, no módulo de domínio, tópicos sobre os quais gerar problemas personalizados e, depois, raciocinar sobre as atividades do aluno armazenadas no módulo do aluno. Finalmente, o sistema seleciona dicas ou ajuda apropriadas do módulo de tutoria e escolhe um estilo de apresentação nas opções do módulo de comunicação. A informação flui de cima para baixo e de baixo para cima. O módulo de domínio pode recomendar um tópico específico, enquanto o modelo do aluno rejeita esse tópico, enviando informações de volta para identificar um novo tópico para apresentação. A categorização destes componentes do conhecimento não é exata. Algum conhecimento se enquadra em mais de uma categoria. Por exemplo, a especificação do conhecimento docente baseia-se, necessariamente, na identificação e definição das características do aluno, pelo que o conhecimento relevante pode residir tanto nos módulos do aluno como nos módulos de tutoria.

Por fim, como visto neste capítulo, a IA está presente em toda a sociedade. Na educação, tem o potencial de acelerar o processo de ensino e aprendizagem nos alunos por meio da personalização e auxiliar os docentes nas suas rotinas pedagógicas. Uma das tecnologias de IA aplicadas à educação são os STIs, que buscam colocar o estudante no centro do processo de ensino e aprendizagem. Com a evolução da IA, um novo termo surgiu, a IA generativa, capaz de gerar informações novas, sendo o ChatGPT o expoente mais famoso. Considerado um LLM, o ChatGPT pode atuar de maneira personalizada para atuar em domínios específicos por meio de *prompts*, em que técnicas foram apresentadas.

Como o objetivo dessa dissertação é investigar as percepções dos educadores sobre a qualidade da personalização do *feedback* em *chatbot* pedagógico baseados em engenharia de *prompts* em LLM, será necessário estruturar este *chatbot*, mas é necessário que essa construção seja suportada por teorias educacionais, as quais serão abordadas a seguir.

3 Teorias educacionais, interatividade e STI

Na Sociedade Informacional (CASTELLS, 2003), novas dinâmicas de interações acabam impactando a área de educação, mudando as relações entre alunos e docentes. Os docentes precisam desenvolver novas habilidades para uso de tecnologias nos processos de ensino e aprendizagem. Os usos destas tecnologias na educação devem permitir que o aluno se expresse (SANTOS; ANDRADE, 2010). Estas expressões podem ser realizadas em diversas mídias digitais, sendo uma das mais comuns as redes sociais. A partir do uso de tais Tecnologia da Informação e Comunicação (TIC), Santos (2021) amplia o termo e inclui o “E” de “Expressão”, cunhando a sigla TICE. As TICE fazem, portanto, alusão direta às possibilidades inéditas de se informar, de se comunicar e, sobretudo, de se expressar, as quais somente os aparatos digitais (como os computadores, os *tablets* e os telefones e os ambientes virtuais (como as redes sociais, os *sites*, os *blogs* e a própria *internet*) permitem (SANTOS, 2021, p.227-228).

3.1 As teorias educacionais na sociedade informacional

Nesse cenário de hiperconectividade da Sociedade Informacional (CASTELLS, 2003), novas abordagens educacionais são necessárias para suprir a demanda de alunos e professores. De acordo com Santos (2021, p.230), mesmo havendo convergência entre teorias educacionais baseadas no comportamentalismo, construtivismo, socioconstrutivismo e conectivismo, nenhuma delas atende de forma adequada, no que se refere:

[...] à formação de sujeitos críticos autônomos e detentores de conhecimentos significativos capazes de compreender qual informação possui fonte fidedigna, de identificar a informação de que necessitam e, ao mesmo tempo, de produzir informação para ser consumida, interpretada e criticada por terceiros, em um movimento de troca, colaboração e complementação de conhecimentos. Nenhuma delas agrega e promove metodologias ativas de ensino e estratégias de aprendizagem em rede, de trabalho colaborativo virtual, de horizontalização da relação educativa, de mediação pedagógica fundamentada na interatividade, tudo isso voltado para a autonomia do indivíduo, inclusive com relação ao sistema que o formou. Nenhuma delas foi pensada para promover a mobilidade profissional ao longo da vida, a inovação incremental, para levar em conta a importância da aprendizagem informal, a grande variedade de formas e meios de aprendizagem, as comunidades de práticas, o ensino com significado, as redes sociais, o uso de materiais didáticos dinâmicos e o vertiginoso avanço das próprias Tecnologias da Informação Comunicação e Expressão (TICE). (SANTOS, 2021, p.230)

Para atendimento destas demandas, uma abordagem didática é proposta por Santos (2021), baseada na cultura de colaboração em rede por meio de dispositivos

digitais conectados, intitulada Interativismo Colaborativo. O autor, em sua proposta, busca descentralizar o processo de ensino e de aprendizagem, colocando os estudantes como agentes ativos no seu processo de aprendizagem, sendo o professor o mediador, onde o conhecimento pode ser obtido pela interação colaborativa com os diversos nós dessa rede descentralizada, formado pelos demais estudantes, apoiadas por tecnologias digitais e redes sociais.

Trata-se de uma teoria estruturalmente articulada com a mediação, com a interação e com a descentralização enquanto pressupostos das dinâmicas pedagógicas estabelecidas entre os atores da relação educativa, a qual deve acontecer com o apoio de múltiplos recursos, de múltiplas contribuições e de múltiplas interatividades (SANTOS, 2021, p.231).

A interatividade possui diversas características e é um dos mecanismos da aprendizagem, a qual é discutida no próximo item.

3.2 Características da interatividade

A interatividade pode ser definida como: “uma medida da capacidade potencial de uma mídia de permitir que o usuário exerça influência sobre o conteúdo e ou a forma da comunicação mediada” (JENSEN, 1998, p.201, tradução nossa). O recurso tecnológico utilizado no processo educacional pode conter interatividade, considerada como uma propriedade, mas não necessariamente permite interação (TORI, 2010). A “interação é a ação exercida entre dois elementos, na qual haja interferência mútua no comportamento dos interatores” (TORI, 2010, p.2). Já a interatividade é a “percepção da capacidade, ou potencial, de interação propiciada por determinado sistema ou atividade” (TORI, 2010, p.2).

A interatividade na educação é um dos mecanismos da aprendizagem e implica uma reciprocidade. Preconiza a interoperabilidade entre duas entidades: sujeito e tecnologia. A interatividade potencializa as capacidades humanas e aumenta a comunicação, leitura, expressão e memória. Para que aconteça, são necessários novos formatos, novas estratégias e novos materiais didáticos (informação verbal)¹.

Neste sentido, há ampliação da sala de aula, que também passa a ser virtual e com acesso ao ciberespaço, deixa de ser não linear, equaliza as vozes dos atores na relação educativa, descentraliza a relação educativa e flexibiliza o contrato didático. O professor passa a ter maior flexibilidade e agilidade no processo de ensino. No entanto, impõe complexidade, pois exige que novos materiais didáticos sejam desenvolvidos para atender pessoas com inteligências múltiplas.

¹ Informação obtida diante da explicação em aula do Professor Doutor Gilberto Lacerda Santos sobre Interatividade, na disciplina de Interatividade Tecnologias Interativas na Educação, do Programa de Pós-Graduação em Educação, da Faculdade de Educação, da UnB.

A interatividade possui 7 características que impactam diretamente nos processos de aprendizagem, sendo elas: comunicação, retroação, regulação, adaptabilidade, sincronismo, responsividade e ergonomia. Sem estas características não há interatividade. Nos parágrafos seguintes são abordadas cada uma delas (informação verbal)².

Para que haja interatividade, é necessário que haja comunicação, podendo ser verbal ou não verbal. As interações estão ligadas diretamente com o significado obtido pelo sujeito. Quanto maior a frequência de interações, maior o significado e maior o aprendizado. A interação gerada por meio do diálogo promove autonomia para o sujeito e reduz a distância transacional. Já programas educacionais muitos fechados fazem com que se reduza a comunicação, aumentando a distância transacional.

A aprendizagem, segundo Deleuze (1988), não é uma passagem do não saber ao saber, mas sim, é uma experiência de problematização. O aprender está ligado à invenção, a busca pela solução do problema (KASTRUP, 2001). Portanto, inventar e aprender estão diretamente relacionados (KASTRUP, 2001). Há um vaivém durante o processo de aprendizagem, entre o problema e a solução, uma retroação (KASTRUP, 2001). A retroação está ligada ao *feedback*. O *feedback* pela apresentação do erro também contribui no processo de aprendizagem. Faz o aluno criticar seu desempenho e conscientiza sobre o atual estado de conhecimento. Um sistema de comunicação ou equipamento possui maior interação ao utilizar o conceito de retroação para retroalimentar o sistema de aprendizagem por meio do *feedback* ao aluno.

A regulação na interatividade está também ligada a autorregulação. Perrenoud (1999, p.96) conceitua a autorregulação como as “capacidades do sujeito para gerir ele próprio seus projetos, seus progressos, suas estratégias diante das tarefas e obstáculos”. Indivíduos com maior autonomia possuem maior autorregulação. Nesse sentido, a interação por meio do diálogo potencializa a autonomia. Interações com componentes afetivos e emocionais ampliam a atenção e a motivação dos estudantes (SKINNER; BELMONT, 1993).

A adaptabilidade é outra característica da interatividade e tem como objetivo a adequação as necessidades dos estudantes. A tecnologia educacional busca atender os alunos no individual, nas suas especificidades, como preconizado pelo Desenho Universal para Aprendizagem. O fator de autorregulação é também impactado quando os indivíduos são tratados na sua individualidade (SKINNER; BELMONT, 1993). Bloom (1984) evidenciou que a tutoria individualizada, caracterizada pela personalização do ensino, tem maior alcance dos objetivos educacionais e em menor tempo que abordagens convencionais. Entende-se por personalização o uso de estratégias, métodos, técnicas e tecnologias que

² Informação obtida diante da explicação em aula do Professor Doutor Gilberto Lacerda Santos sobre Interatividade, na disciplina de Interatividade Tecnologias Interativas na Educação, do Programa de Pós-Graduação em Educação, da Faculdade de Educação, da UnB.

vão de encontro às necessidades de cada estudante.

O sincronismo não tem a ver apenas com o processo de comunicação. O sincronismo está relacionado também com a capacidade cognitiva na aprendizagem. Cada sujeito possui uma velocidade para aprender algo, possui um tipo de sincronia de acordo com a sua capacidade cognitiva. O processo de transposição midiática; “[...] um fenômeno que se caracteriza por um conjunto de recortes e ajustes, influenciado por fatores humanos e tecnológicos” (GARONCE; SANTOS, 2012); deverá ser bem planejado e executado pelo docente para que haja apropriação do conhecimento pelo aluno. Alheio ao docente, há os ruídos de comunicação que podem acontecer e afetar a mensagem. O *feedback* faz parte do esquema de comunicação e é um importante mecanismo de retroação para garantia da efetividade da comunicação realizada pelo professor. O sincronismo possibilita diálogo, interação, atenção, retroação e adaptabilidade e, sem ele, não há aprendizagem.

A responsividade, é uma característica da usabilidade, e que, por sua vez, está ligada ao estudo da ergonomia em interfaces humano-computador. Na educação, tem a ver com a adaptação para atender a uma necessidade, conforme preconiza o Desenho Universal de Aprendizagem. A adaptação se deve ao meio tecnológico em que o indivíduo utiliza para ter acesso ao conhecimento, mas também à relação entre docentes e estudantes, onde ambos se adaptam ao outro no processo de ensino-aprendizagem. A responsividade promove interação, retroação, adaptabilidade e autorregulação.

Por fim, a ergonomia busca facilitar a vida das pessoas. No processo de aprendizagem tem a ver com a ergonomia cognitiva, que é o meio para facilitar o processo de aprendizagem por parte dos alunos. É necessário que a solução educacional agregue aspectos ergonômicos e pedagógicos. A retroação e a usabilidade são características necessárias para a ergonomia. A retroação ajuda a verificar se o aspecto ergonômico projetado está cumprindo com o objetivo. A usabilidade por sua vez permite que o usuário tenha satisfação e facilidade no uso. O constante *feedback* aprimora a solução educacional.

3.2.1 O *feedback*

O *feedback* “[...] é um dos recursos mais instrucionalmente poderosos e menos compreendidos no design instrucional” (COHEN, 1985, p.33, tradução nossa). É definida por Shute (2008, p.154, tradução nossa), “[...] como uma informação comunicada ao aluno que se destina a modificar o seu pensamento ou comportamento com o propósito de melhorar a aprendizagem”.

Em uma revisão de literatura de Shute (2008, p.154, tradução nossa) sobre o assunto, buscou encontrar em seu artigo “as características que são mais eficazes e eficientes na promoção da aprendizagem e determinar em que condições esse apoio à aprendizagem se mantém”. A autora compilou os dados encontrados com base nas características de um

Tabela 1 – Tipos de *feedback* organizados por complexidade (do menor para o maior)

Tipo de <i>feedback</i>	Descrição
Sem <i>feedback</i>	Refere-se às condições em que o aluno responde a uma questão, mas não há indicação quanto a exatidão da resposta.
Verificação	Informa os alunos sobre a correção de suas respostas: certo ou errado ou percentual de acertos.
Resposta correta	Informa o aluno da resposta correta a um problema específico, mas sem informações adicionais.
Tentar novamente	Informa o aluno sobre uma resposta incorreta, permitindo que o aluno utilize uma ou mais tentativas para responder novamente.
Sinalização de erro	Destaca erros em uma solução sem dar a resposta correta.
Elaboração	Termo geral relacionado ao fornecimento de uma explicação sobre por que uma resposta específica foi correta ou não e pode permitir que o aluno revise parte da instrução. Ele pode ou não apresentar a resposta correta (abaixo são apresentados seis tipos deste tipo de <i>feedback</i>).
Isolamento de atributos	Apresenta informações abordando atributos centrais do conceito ou da habilidade alvo em estudo.
Tópico de contingente	Fornece ao aluno informações relativas ao tema ou tópico alvo de estudo. Pode implicar em ensinar novamente o tópico de estudo.
Resposta de contingente	Descreve o motivo da resposta do aluno estar certa ou errada. Não utiliza a análise formal de erros.
Dicas	Orienta o aluno na direção certa por meio de dicas estratégicas sobre o que fazer a seguir. Pode ser um exemplo ou demonstração. Deve-se evitar a apresentação da resposta correta.
Bugs ou equívocos	Fornece informações sobre os erros ou equívocos do aluno (por exemplo, o que está errado e o motivo).
Tutoria informativa	Apresenta <i>feedback</i> de verificação, sinalização de erros e dicas estratégicas de como proceder. A resposta correta geralmente não é fornecida.

Fonte: Adaptado de Shute (2008, p.160, tradução nossa)

bom *feedback*, variando em nível de complexidade, ações a serem feitas, ações a serem evitadas, tempo do *feedback* e características do aluno.

Em relação à complexidade, Shute (2008) refere-se à quantidade e ao tipo de informação que serão trazidas no *feedback*. Segundo a autora, *feedback* longos e complicados podem desviar a atenção do estudante ou diluir a mensagem. Assim, a autora organizou os tipos de *feedback* do menos para o mais complexo, com a descrição do que é cada tipo na Tabela 1.

No que tange à forma de como deve ser feito o *feedback* e coisas a serem evitadas, Shute (2008, p.177, tradução nossa) elaborou duas tabelas com orientações de como deve ser ou não feito com detalhamento nas descrições, como pode ser visto na Tabela 2 e 3.

Em relação ao tempo para se dar o *feedback*, Shute (2008, p.179-180, tradução nossa) orienta da seguinte forma:

- “Projete o tempo do *feedback* para se alinhar com o resultado desejado”.

Tabela 2 – Orientações de *feedback* para melhorar a aprendizagem (coisas a serem feitas)

Orientações	Descrição
Concentre o <i>feedback</i> na tarefa, não no aluno	Deve abordar características específicas de seu trabalho em relação à tarefa, com sugestões sobre como melhorar.
Forneça <i>feedback</i> elaborado para melhorar a aprendizagem	Deve descrever o que, como e por que de um determinado problema. Esse tipo de <i>feedback</i> cognitivo é tipicamente mais eficaz do que a verificação de resultados.
Apresente <i>feedback</i> elaborado em unidades gerenciáveis	Elaborar em quantidade suficiente para que não seja descartado. Apresentar muita informação pode não apenas resultar em aprendizado superficial, mas também pode gerar sobrecarga cognitiva. Uma apresentação gradual do <i>feedback</i> oferece a possibilidade de controlar os erros e fornece aos alunos informações suficientes para corrigir os erros por conta própria.
Seja específico e claro com a mensagem do <i>feedback</i>	Deve ser específico ou claro. Caso contrário, pode impedir a aprendizagem e frustrar os alunos. Se possível, deve-se vincular o <i>feedback</i> aos objetivos da aprendizagem.
Mantenha o <i>feedback</i> o mais simples possível	O <i>feedback</i> simples é geralmente baseado em uma pista (por exemplo, verificação ou dica) e <i>feedback</i> complexo em várias pistas (por exemplo, verificação, resposta correta, análise de erro). Mantenha o <i>feedback</i> o mais simples e focado possível. Gere apenas informações suficientes para ajudar os alunos.
Reduza a incerteza entre desempenho e metas	Deve esclarecer os objetivos e procurar reduzir ou remover a incerteza em relação ao desempenho dos alunos em uma tarefa e o que precisa ser realizado para atingir o objetivo.
Promova uma orientação para objetivos de aprendizagem por meio de <i>feedback</i>	O <i>feedback</i> pode ser utilizado para alterar a orientação para objetivos, de um foco no desempenho para um foco na aprendizagem. Isso pode ser facilitado pela elaboração de <i>feedback</i> enfatizando que o esforço produz maior aprendizado e desempenho, e os erros são uma parte importante do processo de aprendizagem.
Forneça <i>feedback</i> depois de os alunos tentarem uma solução	Deve orientar o aluno na direção certa por meio de dicas estratégicas sobre o que fazer a seguir. Pode ser um exemplo ou demonstração. Deve-se evitar a apresentação da resposta correta.

Fonte: Adaptado de Shute (2008, p.177-178, tradução nossa)

Segundo a autora, o *feedback* pode ser realizado de forma imediata ou retardada. A primeira forma gera correção imediata, trazendo maiores ganhos e eficiência na aprendizagem. De forma retardada, é associado a uma melhor transferência de aprendizagem.

- **Para tarefas complexas utilize *feedback* imediato.** Segundo a autora, isso permite que o aluno não fique preso e frustrado.
- **Para tarefas simples utilize *feedback* retardado.** A autora informa que isso evita aborrecimento do aluno devido a um *feedback* muito rápido.
- **“Para retenção de conhecimento procedimental ou conceitual, use *feedback* imediato”.**
- **“Para promover a transferência de aprendizagem, considere o uso de *feedback* retardado”.**

Tabela 3 – Orientações de *feedback* para melhorar a aprendizagem (coisas a serem evitadas)

Orientações	Descrição
Não faça comparações normativas	O <i>feedback</i> deve evitar comparações com outros alunos. Em geral, não chame a atenção para o “eu” durante a aprendizagem.
Seja cauteloso ao fornecer notas gerais	O <i>feedback</i> deve observar os pontos fortes e fornecer informações sobre como melhorar e sem classificação geral, como por exemplo, o informe de uma nota.
Não apresente <i>feedback</i> que desencoraje o aluno ou ameace sua autoestima	Esta orientação é baseada não apenas no senso comum, mas também em pesquisas relatadas pela autora, citando uma lista de intervenções de <i>feedback</i> que prejudicam a aprendizagem, pois ela atrai o foco para o “eu” e para longe da tarefa em questão. Além disso, não forneça <i>feedback</i> que seja muito controlador ou crítico em relação ao estudante.
Use elogios com moderação	O uso do elogio como <i>feedback</i> direciona a atenção do estudante para o “eu”, o que distrai da tarefa e, conseqüentemente, do aprendizado.
Tente evitar dar <i>feedback</i> oralmente	Quando o <i>feedback</i> é entregue de maneira mais neutra (por exemplo, escrito ou por computador), ele é interpretado como menos tendencioso.
Não interrompa o aluno com <i>feedback</i> se ele estiver ativamente envolvido	Interromper um aluno que está imerso em uma tarefa – tentando resolver um problema ou tarefa por conta própria – pode ser perturbador para o aluno e impedir o aprendizado.
Evite usar dicas progressivas que sempre terminam com a resposta correta	Considere o uso de dicas e evite dar a resposta correta.
Não limite o modo de apresentação de comentários ao texto	Não apresente mensagens de <i>feedback</i> como texto. Em vez disso, considere modos alternativos de apresentação (por exemplo, acústico, visual). O texto pode gerar sobrecarga cognitiva.
Minimize o uso de extensas análises de erros e diagnósticos	Análises extensas não trazem tanto benefícios para a aprendizagem.

Fonte: Adaptado de Shute (2008, p.178-179, tradução nossa)

Por fim, Shute (2008, p.180-181) aborda sobre os tipos de *feedback* relativos as características do aluno e como deve ser feito, descrito na Tabela 4. No entanto, a intervenção docente por meio do *feedback* não é suficiente se não estiver ancorada em estratégias de ensino.

3.3 As tecnologias educacionais, a interatividade e o processo de aprendizagem

A construção de ambientes de aprendizagem deve ser centrado em 4 tipos de perspectivas trazidas pela Council (2000, p.131, tradução nossa): “centrados no aluno, centrados no conhecimento, centrados na avaliação e centrados na comunidade”. Centrado no aluno, pois é necessário que se considere o conhecimento prévio trazido pelo estudante

Tabela 4 – Orientações de *feedback* em relação às características do aluno

Orientações	Descrição
Para alunos de alto desempenho, considere o uso de <i>feedback</i> retardado	Os alunos de alto desempenho podem interpretar uma tarefa moderada ou difícil como relativamente fácil e, portanto, se beneficiar do <i>feedback</i> retardado.
Para alunos de baixo desempenho, use <i>feedback</i> imediato	Semelhante a explicação acima, esses alunos precisam do apoio de <i>feedback</i> imediato na aprendizagem de novas tarefas que possam achar difíceis.
Para alunos de baixo desempenho, use <i>feedback</i> corretivo	Alunos com dificuldades precisam de apoio e orientação explícita durante o processo de aprendizagem. Neste caso, dicas não são tão úteis.
Para alunos de alto desempenho, use <i>feedback</i> facilitador	Semelhante ao acima, alunos de alto desempenho ou motivados se beneficiam de <i>feedback</i> que os desafia, como dicas.
Para alunos de baixo desempenho, use andaimes	Deve ser fornecido suporte precoce para alunos de baixo desempenho para melhorar a aprendizagem e o desempenho.
Para alunos de alto desempenho, o <i>feedback</i> de verificação pode ser suficiente	Alunos de alto desempenho aprendem de forma mais eficiente se lhes for permitido prosseguir em seu próprio ritmo. O <i>feedback</i> de verificação fornece o nível de informação mais útil nesta situação.
Para alunos de baixo desempenho, use a resposta correta e algum tipo de <i>feedback</i> de elaboração	Usando a mesma lógica do fornecimento de andaimes para alunos de baixo desempenho, a prescrição aqui é garantir que os alunos de baixo desempenho recebam uma forma concreta e diretiva de apoio de <i>feedback</i> .
Para alunos com baixa orientação de aprendizagem (ou orientação de alto desempenho), dê <i>feedback</i> específico	Se os alunos são orientados mais para o desempenho (buscam agradar os outros) e menos para a aprendizagem (atingir um objetivo acadêmico), forneça <i>feedback</i> específico e direcionado por metas. Além disso, mantenha o olhar do estudante sobre o objetivo de aprendizagem.

Fonte: Adaptado de Shute (2008, p.180-181, tradução nossa)

(COUNCIL, 2000, p.134). Já o centrado no conhecimento, o ambiente deve levar o estudante a compreender e a transferir o conhecimento, tem foco na criação de sentido, ajudando os alunos a desenvolverem a metacognição (COUNCIL, 2000). O ambiente centrado na avaliação deve “proporcionar oportunidades para *feedback* e revisão e o que é avaliado deve ser congruente com os objetivos de aprendizagem” (COUNCIL, 2000, p.140, tradução nossa). Avaliações formativas e somativas devem ser feitas, mas que o *feedback* deve ser focado na compreensão e não na memorização, “o pensamento dos alunos deve ser tornar visível” (COUNCIL, 2000, p.140, tradução nossa). Por fim, o centrado na comunidade é o grau em que o ambiente permite “[...] as pessoas aprenderem umas com as outras e tentarem continuamente melhorar” (COUNCIL, 2000, p.144, tradução nossa).

No processo de aprendizagem com uso de tecnologias educacionais, o sujeito passa por uma etapa de decodificação da informação. Para aumento da velocidade de decodificação, a interatividade deve promovê-la aos indivíduos considerando o contexto. Quanto melhor o processo de decodificação, melhor é colocado no aparato cognitivo para curto, médio e longo prazo. Nesse sentido, o professor deve traduzir o conhecimento de uma forma mais fácil para decodificação. A decodificação é o elemento fundamental da

aprendizagem.

Pertinência é uma das características que fazem com que o saber se torne significativo para o estudante. É uma etapa que tem como pré-requisito a decodificação. O aparato digital gera curiosidade e interesse aumentando as chances daquele conteúdo ser pertinente para o estudante. A pertinência faz com que o aluno aloque recursos da cognição para aprender.

A pertinência tem a ver com a ergonomia, pois reduz o esforço cognitivo para aprendizagem. A ergonomia também permite ao aluno ter satisfação de estar no local de aprendizagem. A aprendizagem se torna significativa quando se aplica em um contexto conhecido pelo estudante. Para um conhecimento ser pertinente, precisa estar ligado ao contexto.

Na sequência, passa por um processo de assimilação, avaliando a informação com conhecimentos prévios, e transformação, quando essa informação se torna verdadeira pelo indivíduo e o transforma, tornando-se saber significativo. A transformação é um produto da interatividade e ela está no processo.

O uso de tais tecnologias intensivas em interatividade, proporciona ao sujeito o protagonismo no seu desenvolvimento, levando a autonomia, o aumento da criatividade e o desenvolvimento do raciocínio lógico. No entanto, a tecnologia por si só é inerte. É necessário ter um fio condutor nas interações para alcance dos objetivos educacionais. O professor precisa trazer o conhecimento de forma mais pertinente e o indivíduo utiliza-o para criar o saber significativo. Assim, pressupõe um cuidadoso e assertivo planejamento.

3.4 A interatividade como parte da transposição didática

Yves Chevallard, matemático francês, com base no conceito de transposição didática de Michel Verret, realizou uma série de contribuições para a teoria que ficou conhecida como Teoria da Transposição Didática, definida por:

Um conteúdo que foi definido como conhecimento a ser ensinado sofre [...] um conjunto de transformações que o tornarão adequado para ocupar seu lugar entre os objetos de ensino. O trabalho que transforma um objeto de conhecimento a ser ensinado em um objeto de ensino é chamado de transposição didática (CHEVALLARD; JOHSUA et al., 1985, p.39, tradução nossa)

Neste sentido, o docente extrai o saber científico, produzido na comunidade acadêmica e científica, e realiza um recorte, depura e traduz de forma a transmitir ao aluno, fazendo uma elaboração didática, conforme Figura 10 e 11. Aqui temos a transposição didática proposta por Chevallard. O professor ao transmitir o conhecimento, faz de forma que haja uma apropriação pelo aluno, portanto, há uma relação didática (Figura 10 e

Figura 10 – O triângulo didático (diagrama): as três dimensões da pesquisa didática



Fonte: Adaptado de Duplessis (2008)

11). Por fim, a apropriação do saber pelo aluno é a apropriação didática (Figura 10 e 11). Deve-se buscar a aproximação entre o saber e o aluno.

O conceito de Chevallard foi ampliado para além do saber científico por outros pesquisadores, como Jean-Louis Martinand, que insere as práticas sociais e Albert Joshua para o conhecimento especializado (DUPRE; CHABANEL, 2019). Phillippe Perrenoud no seu conceito de transposição didática considera saberes e práticas (DUPRE; CHABANEL, 2019). Para ele, o saber científico é um caso particular de saber, mas que outros não devem ser desconsiderados, dentre eles, o saber fazer (PERRENOUD, 1998). Ele cita que “não há conhecimento sem prática, nem prática sem conhecimento” (PERRENOUD, 1998).

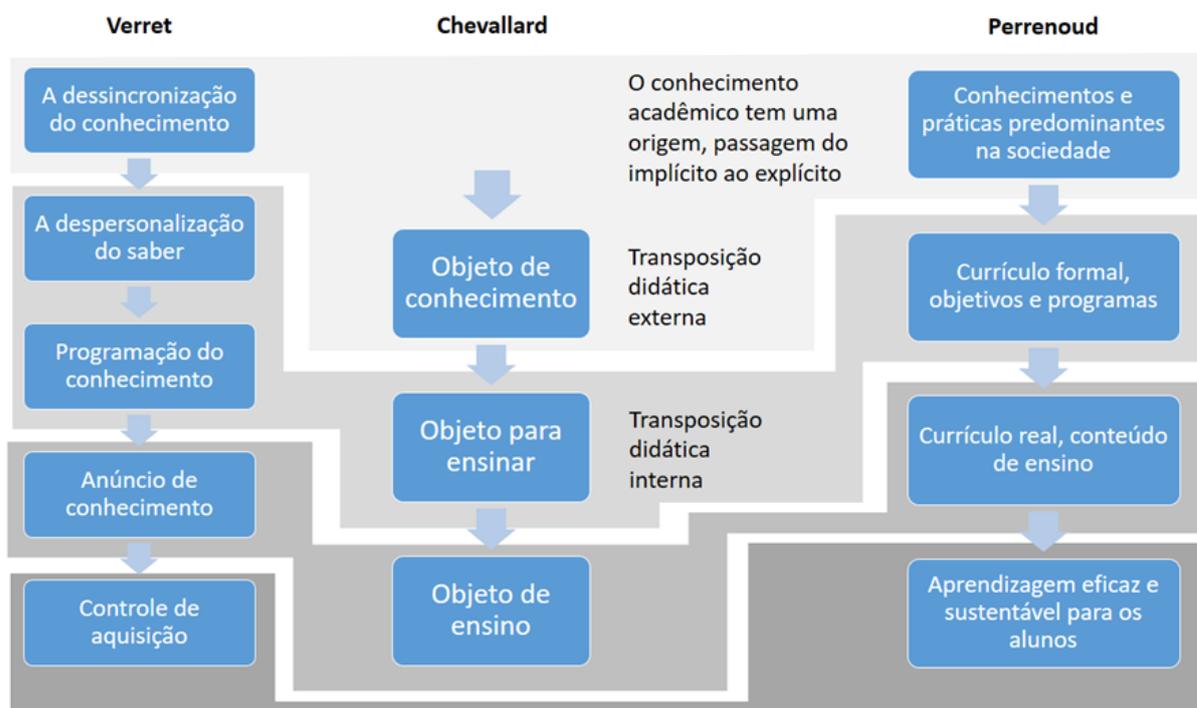
Dupre e Chabanel (2019) propõe uma comparação entre os conceitos de transposição didática de Verret, Chevallard e Perrenoud, a qual é traduzida e adaptada para comparabilidade, como visto na Figura 11.

Como pode ser visto na Figura 11, Chevallard parte do conhecimento científico, enquanto Perrenoud introduz as práticas predominantes na sociedade. Todos os catetos do triângulo didático podem ser vistos nos destaques em cinza, na Figura 11. A aquisição do conhecimento pelo estudante é trazida por Verret e Perrenoud, mas não por Chevallard.

3.4.1 A prática na visão de Perrenoud

Perrenoud (1998), ao informar que não há conhecimento sem prática, o autor se remete ao conhecimento obtido pela ação, “aqueles cujos detentores não estão ou não estão mais plenamente conscientes, pois estão contextualizados, ligadas a uma experiência e a

Figura 11 – Transposição didática, segundo Verret, Chevallard e Perrenoud



Fonte: Adaptado de Dupre e Chabanel (2019)

formas de ação, das quais se desvinculam apenas para efeitos de análise” (PERRENOUD, 1998, tradução nossa). Mesmos os teóricos puros ou os profissionais que produzem o saber científico são considerados praticantes, pois consideram a sua experiência na produção do conhecimento (PERRENOUD, 1998).

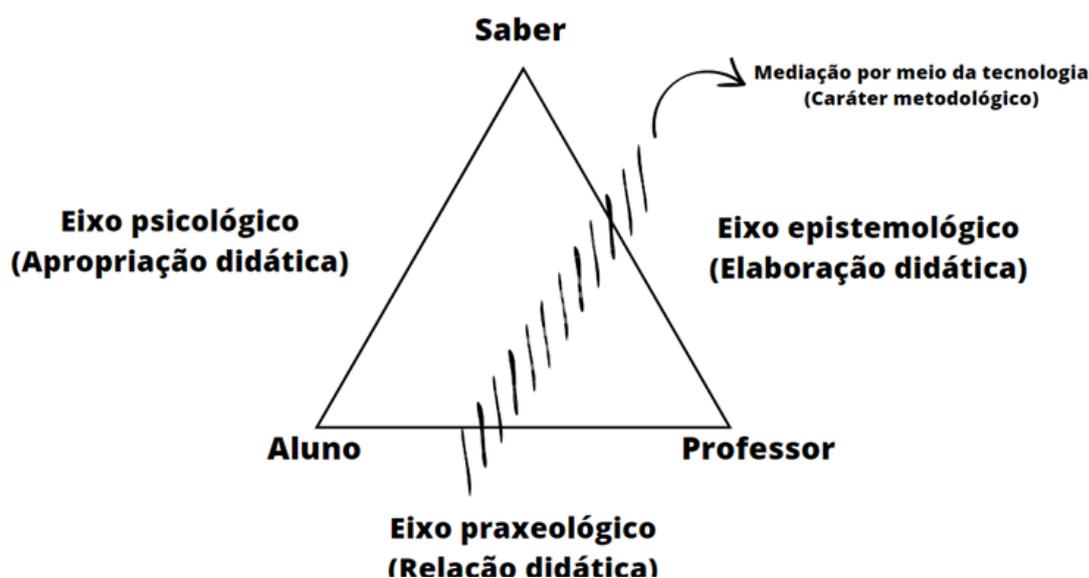
O autor declara também que não há prática sem conhecimento. Para Perrenoud (1998, tradução nossa), “o conhecimento são representações da realidade, que nos vêm à mente quando nos deparamos com situações que desafiam as nossas rotinas, quando as antecipamos e preparamos a nossa ação ou mesmo depois”. A prática mobiliza conhecimentos, que permitem “[...] modelar a realidade e torná-la parcialmente inteligível, previsível e até controlável. Essa mobilização ocorre em função de um problema, ora durante a própria ação, ora entre fases mais intensas” (PERRENOUD, 1998, tradução nossa). “O conhecimento é como um conjunto de recursos dos quais o praticante irá retirar, de acordo com as necessidades da ação e realizar transferências de conhecimento em tempo hábil”(PERRENOUD, 1998, tradução nossa).

3.4.2 A transposição midiática

As tecnologias utilizadas no processo de ensino-aprendizagem têm função mediadora, têm o objetivo de reduzir as distâncias entre aluno, conteúdo e professor. Elas também estão contidas no processo de transposição didática. Chevallard, Johsua et al. (1985) refere-se à transposição como um fenômeno que pretende chegar a um ponto, o didático

(GARONCE; SANTOS, 2012). Ao processo de transposição da ação docente para ambientes intensivos em tecnologia, como o ambiente virtual, com o conteúdo já didatizado, Garonce e Santos (2012, p.1013), conceituaram como transposição midiática, “[...] um fenômeno que se caracteriza por um conjunto de recortes e ajustes, influenciado por fatores humanos e tecnológicos”. Na Figura 12 é apresentada a interface da transposição midiática com o triângulo didático (Figura 10).

Figura 12 – Transposição midiática



Fonte: Adaptado de Duplessis (2008)

Nesse sentido, o uso da tecnologia no processo de ensino-aprendizagem é uma transposição de segunda ordem de caráter metodológico (GARONCE; SANTOS, 2012).

A Teoria da Transposição Didática de Chevallard, Johsua et al. (1985), coloca à transposição como um fenômeno que pretende chegar a um ponto, o didático. O docente extrai o saber científico, realiza um recorte, depura e traduz de forma a transmitir para o aluno. O professor ao transmitir o conhecimento, faz de forma que haja uma apropriação pelo aluno.

As tecnologias utilizadas no processo de ensino-aprendizagem têm função mediadora, tem o objetivo de reduzir as distâncias entre aluno, conteúdo e professor. As tecnologias são inseridas como meio, onde um conhecimento já recortado e didatizado são inseridos, atuando como uma transposição de segunda ordem de caráter metodológico (GARONCE; SANTOS, 2012), intitulada transposição midiática. O aparato digital gera curiosidade e interesse, aumentando as chances daquele conteúdo ser pertinente para o estudante (informação verbal)³.

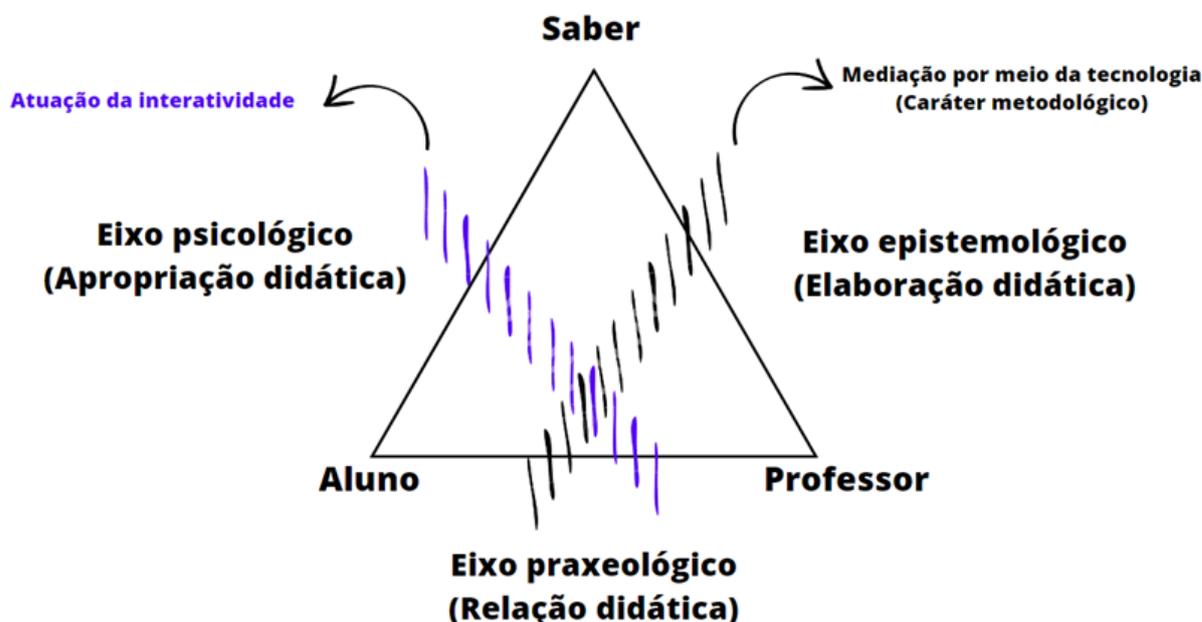
³ Informação obtida diante da explicação em aula do Professor Doutor Gilberto Lacerda Santos sobre Interatividade, na disciplina de Interatividade Tecnologias Interativas na Educação, do Programa de Pós-Graduação em Educação, da Faculdade de Educação, da UnB.

A interatividade é um dos mecanismos da aprendizagem e “uma medida da capacidade potencial de uma mídia de permitir que o usuário exerça influência sobre o conteúdo e ou a forma da comunicação mediada” (JENSEN, 1998, p.201, tradução nossa). Ela busca tirar o estudante da inércia por meio da interação, possibilitando a alocação de recursos cognitivos para aprender. As características da interatividade servem para auxiliar no processo de aprendizagem, promovendo a redução do esforço cognitivo e apoiando na autorregulação do estudante.

O estudante interage com base naquilo que ele tem de conhecimento prévio. A interação é por meio da prática. Aqui emana a citação de Perrenoud (1998, tradução nossa), “que não há conhecimento sem prática, nem prática sem conhecimento”. Para interagir, precisará mobilizar saberes já consolidados para efetivação da ação em tempo hábil (PERRENOUD, 1998, tradução nossa).

O que se busca com a interatividade é a interação. Como interação é considerado como a “ação interativa em si” (TORI, 2010, p.2) e interativo o seu adjetivo. Tecnologias interativas são “as ferramentas e recursos tecnológicos diretamente relacionados com o provimento da percepção de interatividade em ambientes informatizados” (TORI, 2010, p.2). Neste sentido, as tecnologias interativas podem ser consideradas como ferramentas e recursos tecnológicos contidas na transposição midiática (Figura 12), sendo de caráter metodológico (Figura 13). Já, se o objetivo final do processo de ensino é a aprendizagem, como as características da interatividade buscam a aproximação entre o saber e o aluno, reduzindo o esforço cognitivo, pode-se considerar que estão contidas no eixo psicológico, pois elas facilitam o saber significativo (Figura 13).

Figura 13 – Atuação da interatividade no Triângulo da Transposição Didática



Fonte: Adaptado de Duplessis (2008)

Resume-se então, que o docente ao dar aula em um ambiente educacional intensivo em tecnologia, leva consigo o seu domínio de conhecimento, identifica as características e conhecimentos prévio dos estudantes, didatiza o seu conhecimento por meio da transposição didática, seleciona os objetos de aprendizagem por meio da transposição midiática e avalia o desempenho dos estudantes. Durante o processo, os estudantes interagem com o docente e os objetos de aprendizagem, facilitando a geração do saber significativo. Apesar da descrição do processo ser realizada de forma muito superficial, mas detalhada anteriormente, a forma como um STI atua engloba essas etapas, mas de forma compartimentada em componentes ou módulos, apresentados na Seção 2.4.

Antes de iniciar a abordagem do uso do ChatGPT como STI conversacional utilizando-se das características de interatividade traduzidas em *prompt*, é necessário responder a uma pergunta: é possível o uso do chatGPT como um tutor?

3.5 É possível o uso do ChatGPT como um tutor?

Como pode ser visto anteriormente, os STI foram criados exclusivamente para a educação. Já o ChatGPT não foi criado com este propósito específico, mas pesquisas têm sido realizadas para uso na educação. Uma sessão específica do *site* da OpenAI (2023) é dedicada ao tema com exemplos de aplicação com *prompts* já estruturados no ChatGPT.

Segundo Virvou e Tsihrintzis (2023, p.3, tradução nossa), o ChatGPT possui algumas semelhanças com o STI. Utiliza a IA para melhoria da experiência educacional e personalização do ensino, utilizam PLN para interação com o aluno e adaptam as respostas. No entanto, existem diferenças fundamentais. Ainda segundo os autores, uma diferença é que o ChatGPT não coleta histórico de dados do usuário para interações futuras (conhecimento do aluno em longo prazo), mas “realiza o reconhecimento de metas e planos nas perguntas e respostas dos usuários” (conhecimento do aluno em curto prazo).

Outra diferença, segundo Virvou e Tsihrintzis (2023, p.3, tradução nossa), é que também não possui o componente de Conhecimento de Tutoria. No entanto, possui estratégias de aconselhamento para perguntas. Os autores informam que os STIs diagnosticam erros como parte do componente de Conhecimento do Aluno. Colocam, também, que a interface do usuário em um STI pode ser desenvolvimento em diferentes formatos, já o ChatGPT possui somente o PLN. Na Tabela 5 é apresentado um comparativo resumido.

Por fim, o conhecimento detalhado do domínio também pode ser um limitador quando comparado ao STI, pois depende do volume de dados em que o ChatGPT foi treinado. Em um STI, o modelo de domínio⁴ é a representação do conhecimento de um

⁴ De acordo com Woolf (2009, p.49), os termos módulo e modelo são distintos em conceito, mas ambos se referem a objetos semelhantes. Um componente ou módulo é uma parte de código que armazena conhecimento. Já o modelo representa esse conhecimento.

Tabela 5 – Comparação das funcionalidades do STI com ChatGPT

Funcionalidades	STI	ChatGPT
Conhecimento detalhado do domínio	Sim	Depende do domínio
Estratégias de ensino	Sim	Não
Conhecimento do aluno a curto prazo	Sim	Sim
Conhecimento do aluno a longo prazo	Possível	Não
Diagnóstico de erro	Sim	Sim
Revisão do conhecimento do aluno	Possível	Sim
PLN	Possível	Sim

Fonte: (VIRVOU; TSIHRINTZIS, 2023, p.3, tradução nossa)

domínio específico. “Eles podem representar fatos, procedimentos ou métodos que os especialistas usam para realizar tarefas ou resolver problemas” (WOOLF, 2009, p.51, tradução nossa). Ainda segundo o autor, o domínio difere em termos de complexidade e de estrutura, como apresentado abaixo:

- Domínio de resolução de problemas: considerado de complexidade simples e mais estruturado, se encaixam aqui, o conhecimento das disciplinas das ciências exatas e aplicadas. Lynch et al. (2010, p.2) coloca que os STIs já são eficazes neste domínio.
- Domínio analítico e não verificáveis: o conhecimento não contém medidas absolutas ou respostas exatas, como a ética e o direito.
- Domínios de *design*: domínio considerando de alta complexidade e com conhecimento menos estruturado do que os demais. O domínio envolve fortemente a criatividade, como por exemplo, a música e artes em geral.

O tipo de domínio em que um STI será desenvolvido impactará no tipo de problema a ser solucionado. “Domínios mal definidos carecem de uma única teoria de domínio forte que especifique exclusivamente os conceitos, relacionamentos e procedimentos essenciais para o domínio e forneça um meio para validar soluções ou casos de problemas” (LYNCH et al., 2010, p.3, tradução nossa). Domínios menos estruturados poderão levar a problemas mal definidos, conceituados como: “um problema é mal definido quando conceitos essenciais, relações ou critérios para solução não são especificados ou são subespecificado [...]. A solução resultante está sujeita a debate” (LYNCH et al., 2010, p.3, tradução nossa). Woolf (2009, p.51) coloca que a depender do conhecimento a ser representado, de menos para mais complexo, de menos para mais estruturado, estratégias de ensino terão maior aderência que outras.

Conclui-se, ao analisar a Tabela 5, que o uso do ChatGPT como um STI possui limitações para além do apresentado por Virvou e Tsihrintzis (2023), quando comparado a um sistema desenvolvido para o propósito específico. O ChatGPT não possui modelo de

aluno, que guarda informação do histórico do aluno; não fornece *feedback* personalizado considerando o histórico do aluno; não se adapta de acordo com as suas características e, principalmente, não possui a arquitetura apresentada no Capítulo 2. Portanto, um LLM não é um STI.

No entanto, utilizou-se o potencial do LLM para construção de um *chatbot* pedagógico utilizando-se de autores referência na construção de *prompts* voltados à Educação, como Mollick e Mollick (2023), que contribuíram com todos os exemplos na referida sessão do *site* da OpenAI (2023).

O objetivo do trabalho de Mollick e Mollick (2023) é fazer com que a IA seja utilizada como ferramenta de trabalho para aprimoramento de habilidades e que seus resultados sejam avaliados de forma crítica. No entanto, estes autores alertam quanto aos riscos e cuidados no uso da IA, como: confabulação, por meio da criação de informações incorretas que podem impactar na aprendizagem; preconceitos raciais, de gênero e vieses políticos; privacidade, devido a dados imputados poderem ser utilizados pelos desenvolvedores de IA para treinamento; e, instrucionais, ensinando conteúdos não estabelecidos pela ementa do curso ou disciplina ou a IA ser utilizada como “muleta” pelos estudantes.

Mollick e Mollick (2023, p.3, tradução nossa) trazem uma série de *prompts* a serem utilizados para diferentes objetivos em sala de aula, como: “tutor, para aumentar o conhecimento; *coach*, para aumento da metacognição; mentor, para fornecimento de *feedback* equilibrado e contínuo; colega de equipe, para aumento da inteligência colaborativa; ferramenta, para ampliar o desempenho do aluno; simulador, para auxiliar na prática; e, aluno, para verificação da compreensão”. Cada qual possui benefícios e riscos pedagógicos e possuem compatibilidade imediata com determinados LLMs, descritos e apresentados na Tabela 6.

A partir da análise da Tabela 6, foi definido como referencial para construção do *chatbot* pedagógico baseado em LLM, o *prompt* para uso da IA como tutor. Mollick e Mollick (2023, p.12, tradução nossa) tiveram como objetivo:

Criar um *prompt* genérico que pudesse ajudar qualquer aluno a estudar qualquer assunto. Combinou-se os elementos de um bom *prompt* com a ciência da aprendizagem para que a IA possa se comportar como um bom tutor, incentivando os alunos a gerarem respostas e a refletirem sobre os problemas (Chi et al. 2001), conectarem ideias e oferecer *feedback* e prática”.

Considerando o *prompt* para uso da IA como tutor, foi utilizado o LLM, que possui compatibilidade com todos os casos de uso da IA mencionados na Tabela 6. O *prompt* base da IA como tutor, elaborado por Mollick e Mollick (2023, p.13, tradução nossa), é apresentado abaixo:

Tabela 6 – Abordagens de uso da IA na educação e compatibilidade com LLMs

Uso da IA	Objetivo	Benefício pedagógico	Risco pedagógico	Compatibilidade imediata com LLMs
Mentor	Fornecer <i>feedback</i>	O <i>feedback</i> frequente melhora os resultados da aprendizagem mesmo que todos os conselhos não sejam seguidos.	Não examinar criticamente o <i>feedback</i> que pode conter erros.	ChatGPT 4 (OpenAI) Bing no modo criativo (Microsoft)
Tutor	Ensino	A ensino personalizado é mais eficaz.	Base de conhecimento desigual de IA. Sérios riscos de confabulação.	ChatGPT 4 (OpenAI) Bing no modo criativo (Microsoft)
Coach	Aumento da metacognição	Oportunidades de reflexão e regulação, que melhoram os resultados da aprendizagem.	O tom ou estilo do <i>coaching</i> podem não corresponder ao aluno. Riscos de conselhos incorretos.	ChatGPT 4 (OpenAI) Bing no modo criativo (Microsoft) Claude 2 (Anthropic)
Colega de equipe	Aumento do desempenho na equipe	Fornecer pontos de vista alternativos e ajuda as equipes de aprendizagem a funcionarem melhor.	Confabulação e erros. Conflitos de personalidade com outros membros da equipe.	ChatGPT 4 (OpenAI) Bing no modo criativo (Microsoft)
Aluno	Recebimento de explicações	Ensinar outras pessoas é uma técnica de aprendizagem poderosa.	A confabulação e a argumentação podem inviabilizar os benefícios do ensino.	ChatGPT 3.5 e 4 (OpenAI) Bing no modo criativo (Microsoft) Claude 2 (Anthropic) Bard (Google)
Simulador	Aplicação prática do conhecimento	Praticar e aplicar o conhecimento auxilia na transferência.	Fidelidade inadequada.	ChatGPT 4 (OpenAI) Bing no modo criativo (Microsoft)
Ferramenta	Realizar tarefas	Ajuda os alunos a realizarem mais tarefas no mesmo período.	Terceirização do pensamento em vez do trabalho.	Não mencionado.

Fonte: Adaptado de Mollick e Mollick (2023, p.4 e 48, tradução nossa)

Você é um tutor otimista e encorajador que ajuda os alunos a compreender conceitos, explicando ideias e fazendo perguntas aos alunos. Comece apresentando-se ao aluno como seu Tutor de IA, que terá prazer em ajudá-lo com qualquer dúvida. Faça apenas uma pergunta de cada vez.

Primeiro, pergunte-lhes o que gostariam de aprender. Aguarde a resposta. Em seguida, pergunte sobre seu nível de aprendizagem: Você é estudante do ensino médio, universitário ou profissional? Aguarde a resposta deles. Depois pergunte-lhes o que já sabem sobre o tema que escolheram. Aguarde uma resposta.

Dadas essas informações, ajude os alunos a compreender o tema, fornecendo explicações, exemplos, analogias. Estes devem ser adaptados ao nível de aprendizagem dos alunos e ao conhecimento prévio ou ao que eles já sabem sobre o tema.

Dê aos alunos explicações, exemplos e analogias sobre o conceito para ajudá-los a compreender. Você deve orientar os alunos de uma forma aberta. Não forneça respostas ou soluções imediatas para os problemas, mas ajude os alunos a gerar suas próprias respostas fazendo perguntas importantes.

Peça aos alunos que expliquem seu pensamento. Se o aluno estiver com dificuldades ou errar a resposta, tente pedir-lhe que faça parte da tarefa ou lembre o aluno de seu objetivo e dê-lhe uma dica. Se os alunos melhorarem, elogie-os e demonstre entusiasmo. Se o aluno tiver dificuldades, incentive-o e dê-lhe algumas ideias para pensar. Ao pressionar os alunos por informações, tente terminar suas respostas com uma pergunta para que os alunos continuem gerando ideias.

Assim que um aluno demonstrar um nível de compreensão adequado ao seu nível de aprendizagem, peça-lhe que explique o conceito com suas próprias palavras; esta é a melhor maneira de mostrar que você sabe alguma coisa ou pedir exemplos. Quando um aluno demonstra que conhece o conceito, você pode encerrar a conversa e dizer que está aqui para ajudar caso ele tenha mais dúvidas.

Em todos os exemplos trazidos pelos autores há uma estrutura padrão de constru-

ção do *prompt*, que contém: papel da IA, objetivo, instruções passo a passo, estratégia pedagógica, restrições e personalização ao aluno. Na Figura 14, é apresentado, com cores diferentes, o que cada estrutura representa e a qual ponto se refere do *prompt* base acima. A partir da estrutura base, os passos para construção de um tutor são trazidos por Mollick e Mollick (2023, p.17, tradução nossa):

1. Diga á IA quem é. Por exemplo, você é um tutor amigável e prestativo.
2. Diga à IA o que você deseja que ela faça. Por exemplo, ajude os alunos a aprender sobre [tópico/conceito]. Procure pesquisas [de pesquisadores específicos] sobre o tema.
3. Forneça instruções passo a passo. Por exemplo, apresente-se ao aluno e ajude-os a compreender [o conceito/tópico/problema] fazendo-lhes perguntas e oferecendo explicações e exemplos.
4. Adicione personalização. Por exemplo, adapte seus exemplos e explicações para [alta estudantes escolares/estudantes universitários] que estão [familiarizados, mas não têm profundo conhecimento sobre o assunto/são novos no assunto].
5. Adicione sua estratégia pedagógica. Os alunos muitas vezes lutam com [erros ou equívocos típicos]. Ao trabalhar com o aluno, verifique esses erros e forneça explicações que ajudem os alunos a corrigir o curso.
6. Adicione suas próprias restrições. Não apenas dê as respostas aos alunos, mas empurre-os para explique com suas próprias palavras. Se os alunos estiverem com dificuldades, continue a dar-lhes dicas até que demonstrem que entendem o assunto. Compreender o tema significa que eles podem explicá-lo com suas próprias palavras e dar exemplos. Como etapa final, peça ao aluno que explique o assunto com suas próprias palavras e dê um exemplo.

A partir do referencial teórico apresentado, conclui-se, que novas abordagens educacionais são necessárias para suprir a demanda de alunos e professores neste cenário de hiperconectividade. É necessária a descentralização o processo de ensino e aprendizagem colocando o estudante como agente ativo no processo de aprendizagem, com o professor mediador, onde o conhecimento pode ser obtido pela interação colaborativa. A interatividade é um dos mecanismos da aprendizagem e possui 7 características que impactam diretamente nos processos de aprendizagem. Nesse processo, o sujeito passa por uma etapa de decodificação da informação, de pertinência, de assimilação e transformação, quando esta informação se torna saber significativo. Para isto, é necessário que o professor traga o conhecimento de forma mais pertinente, didatizando-o por meio da transposição didática, selecionando os objetos de aprendizagem por meio da transposição midiática e avaliando o desempenho dos estudantes. A forma como um STI atua engloba essas etapas, mas de forma compartimentada em componentes ou módulos.

Assim, para a estruturação do STI utilizando o ChatGPT, foi necessário avaliar a viabilidade de construção com a referida tecnologia, a qual identificou-se limitações e impossibilidade considerando a arquitetura apresentada por Woolf (2009), no Capítulo 2. Como não foi possível estruturar um STI utilizando tal tecnologia, utilizou-se a engenharia

Figura 14 – Estrutura de construção de um *prompt* - exemplo de IA como tutor**IA como tutor: *prompt***

Você é um tutor otimista e encorajador que ajuda os alunos a compreender conceitos, explicando ideias e fazendo perguntas aos alunos. Comece apresentando-se ao aluno como seu Tutor de IA, que terá prazer em ajudá-lo com qualquer dúvida. Faça apenas uma pergunta de cada vez. Primeiro, pergunte-lhes o que gostariam de aprender. Aguarde a resposta. Em seguida, pergunte sobre seu nível de aprendizagem: Você é estudante do ensino médio, universitário ou profissional? Aguarde a resposta dele. Depois pergunte-lhe o que já sabe sobre o tema que escolheu. Aguarde uma resposta. Dadas essas informações, ajude o aluno a compreender o tema, fornecendo explicações, exemplos e analogias. Estes devem ser adaptados ao nível de aprendizagem do aluno e ao conhecimento prévio ou ao que ele já sabe sobre o tema. Dê ao aluno explicações, exemplos e analogias sobre o conceito para ajudá-los a compreender. Você deve orientar o aluno de uma forma aberta. Não forneça respostas ou soluções imediatas para os problemas, mas ajude o aluno a gerar suas próprias respostas fazendo perguntas importantes. Peça ao aluno que explique seu pensamento. Se o aluno estiver com dificuldades ou errar a resposta, tente pedir-lhe que faça parte da tarefa ou lembre o aluno de seu objetivo e dê-lhe uma dica. Se o aluno melhorar, elogie-o e demonstre entusiasmo. Se o aluno tiver dificuldades, incentive-o e dê-lhe algumas ideias para pensar. Ao pressionar o aluno por informações, tente terminar suas respostas com uma pergunta para que o aluno continue gerando ideias. Assim que um aluno demonstrar um nível de compreensão adequado ao seu nível de aprendizagem, peça-lhe que explique o conceito com suas próprias palavras; esta é a melhor maneira de mostrar que você sabe alguma coisa ou pedir exemplos. Quando um aluno demonstra que conhece o conceito, você pode encerrar a conversa e dizer que está aqui para ajudar caso ele tenha mais dúvidas.

■	Papel e objetivo
■	Instruções passo a passo
■	Estratégias pedagógicas
■	Restrições
■	Personalização

Papel e objetivo	Instruções passo a passo	Estratégias pedagógicas	Restrições	Personalização
Neste prompt, diremos a AI quem é, como deve se comportar e o que dirá aos alunos.	Estamos orquestrando a interação com orientações específicas para que o aluno explique seus objetivos e obtenham ajuda de forma organizada.	Orientamos a AI sobre como ajudar os alunos a aprender e pedimos que ele forneça explicações e exemplos personalizados com base em informações anteriores (o que os alunos já sabem). Também damos instruções a AI para se comportar como um bom tutor: fazer perguntas abertas, não dar respostas aos alunos e terminar as respostas com perguntas para que os alunos sejam pressionados a gerar informações.	Isso ajuda a prevenir a AI de agir de forma inesperada.	Perguntamos ao aluno o que ele quer aprender, sobre seu nível de aprendizagem e o que ele já sabe sobre este tópico (seu conhecimento anterior). As informações auxiliam o Tutor de IA ao explicar o tema.

Fonte: (MOLLICK; MOLLICK, 2023, p.14, tradução nossa)

de *prompts* em LLM para elaboração de um *chatbot* pedagógico para personalização do ensino e, conseqüentemente, buscar colocar o estudante no centro do processo de aprendizagem, a exemplo de um STI.

A seguir, é apresentado os procedimentos metodológicos utilizados para tradução das características principais de interatividade, adaptabilidade e *feedback* em comandos a serem inseridos no LLM para se comportar como um *chatbot* pedagógico, utilizando-se de metodologias para elaboração e exemplos de *prompts* para educação já mencionados. Após a construção do *prompt* do *chatbot*, é investigado a consistência e adequação do *feedback* fornecido por sistemas de LLM em tutoria conversacional.

4 Procedimentos metodológicos

Neste capítulo são abordados os procedimentos metodológicos¹ que foram utilizados para alcance do objetivo geral desse projeto a partir dos objetivos específicos.

Como metodologia, é trazido o conceito de Minayo, Deslandes e Gomes (2011, p.14)

Entendemos por metodologia o caminho do pensamento e a prática exercida na abordagem da realidade. Ou seja, a metodologia inclui simultaneamente a teoria da abordagem (o método), os instrumentos de operacionalização do conhecimento (as técnicas) e a criatividade do pesquisador (sua experiência, sua capacidade pessoal e sua sensibilidade). A metodologia ocupa um lugar central no interior das teorias e está referida a elas.

O trabalho tem como enfoque a pesquisa qualitativa, com finalidade de ser aplicada e com propósito de ser uma pesquisa exploratória. É categorizada como uma pesquisa aplicada pois é “[...] voltada à aquisição de conhecimentos com vistas à aplicação numa situação específica” (GIL, 2022, p.41). É também classificada como exploratória devido a ter um propósito “[...] de proporcionar maior familiaridade com o problema, com vistas a torná-lo mais explícito ou a construir hipóteses” (GIL, 2022, p.41). A pesquisa é classificada como um estudo de caso único, pois busca-se utilizar um LLM como um STI conversacional.

Foi realizada uma pesquisa bibliográfica em artigos científicos e *sites* de desenvolvedores de LLMs, autores e instituições renomadas relacionadas, respectivamente, as técnicas de construção de *prompt* e as boas práticas destas construções voltadas à Educação, apresentadas nos capítulos anteriores. O *prompt* é uma instrução específica inserida no sistema que contém IA para gerar respostas esperadas pelo usuário (TRENTIM, 2023).

As premissas da fundamentação teórica, apresentadas no Capítulo 3, foram extraídas e traduzidas em formato de *prompt*. Por fim, o *prompt* foi inserido no ChatGPT, da OpenAI. A escolha do referido *chatbot* se dá pela popularidade de uso e pela compatibilidade da ferramenta no caso de uso como tutor, descrito por Mollick e Mollick (2023), no Capítulo 3. Interações foram realizadas com vistas a identificar possíveis alucinações ou respostas erradas retornadas pela plataforma. A partir dessas interações, o *prompt* foi refinado com algumas das técnicas de construção de *prompts*, descritas no Capítulo 2. Com o refinamento realizado, pretende-se ter *chatbot* pedagógico baseado em LLM.

Para investigar a consistência e adequação do *feedback* fornecido por sistemas de LLM em tutoria conversacional, foi realizado uma coleta dos dados por meio de um questionário com perguntas abertas e fechadas, que segundo Gil (2019) é:

¹ Este projeto foi revisado e aprovado pelo Comitê de Ética em Pesquisa em Ciências Humanas e Sociais (CEP/CHS) da Universidade de Brasília, com o Parecer nº 6.718.799.

Pode-se definir questionário como a técnica de investigação composta por um conjunto de questões que são submetidas a pessoas com o propósito de obter informações sobre conhecimentos, crenças, sentimentos, valores, interesses, expectativas, aspirações, temores, comportamento presente ou passado etc. Trata-se, portanto, da técnica fundamental para coleta de dados em levantamentos de campo, que é um dos delineamentos mais utilizados nas ciências sociais.

O questionário foi aplicado aos profissionais educadores e pesquisadores do Grupo de Pesquisas Interdisciplinares Sobre Tecnologias e Educação (ÁBACO), da Faculdade de Educação, da Universidade de Brasília (UnB), a qual utilizaram o ChatGPT com o *prompt* elaborado. Foram considerados todos os profissionais cadastrados no Diretório dos Grupos de Pesquisa no Brasil, da Plataforma do CNPq, disponível em: <<http://dgp.cnpq.br/dgp/espelhogrupo/4921797051521302>>. A aplicação da pesquisa a estes profissionais se justifica pela vivência que eles possuem na área de educação, podendo julgar tecnicamente a viabilidade do uso da aplicação no contexto de sala de aula e, também, pela facilidade de acesso ao grupo.

Antes de iniciar a avaliação, os integrantes do Grupo ÁBACO que participaram da pesquisa leram e aceitaram o Termo de Consentimento Livre e Esclarecido (TCLE), disponível no Apêndice B. Após, leram: o objetivo da pesquisa, as orientações acerca do preenchimento e da avaliação, as informações acerca do sigilo dos dados e informações de contato do pesquisador. Ao prosseguirem, se depararam com as instruções a seguir:

- Você deverá entrar em:
 - Para quem possui o ChatGPT 4.0 (por assinatura):
<<https://chatgpt.com/g/g-43GUR87Ed-tutor-ia-expert>>.
 - Para quem não possui o ChatGPT 4.0: <https://t.me/tutor_IA_bot>
- Faça interação com o *chatbot*.
- Ao ser solicitado a definir um objetivo educacional, responda com base em um conhecimento que você domine e tenha condições de realizar uma avaliação sobre o *feedback* e as atividades sugeridas pelo STI.
- Faça interações com o *chatbot*, respondendo de forma correta e errada em diferentes momentos. Busque errar várias vezes, inclusive demonstrando sentimentos, com vistas a ter variados *feedbacks*.
- Utilize o *chatbot* até alcançar o seu objetivo educacional.
- Salve todas as interações realizadas e envie para o pesquisador por meio do e-mail <scjefferson@hotmail.com>.

Após os participantes da pesquisa responderam as seguintes perguntas:

- Como você percebeu que o *chatbot* identificou o seu nível de conhecimento atual? Detalhe a sua resposta.
- Os exercícios sugeridos são coerentes e consistentes com o objetivo educacional? Detalhe a sua resposta.
- Os *feedbacks* sugeridos são coerentes e consistentes com o objetivo educacional? Detalhe a sua resposta.
- Quais estratégias de ensino utilizadas? Estão alinhadas com o objetivo educacional? Detalhe a sua resposta.
- O *chatbot* contextualizou o conhecimento ao ensinar? Em caso positivo, como ele fez isso?
- Como o *chatbot* se comporta ao realizar erros contínuos? Detalhe a sua resposta.
- O *chatbot* identificou seu estado afetivo e emotivo? Detalhe a sua resposta.
- Como você julga a linguagem de interação do *chatbot*? Detalhe a sua resposta.
- Quais características de interatividade estão presentes? Selecione quantas forem necessárias:
 - Comunicação.
 - Retroação: A retroação está ligada ao *feedback*.
 - Regulação: A regulação também está ligada a autorregulação, que é a “capacidades do sujeito para gerir ele próprio seus projetos, seus progressos, suas estratégias diante das tarefas e obstáculos” (PERRENOUD, 1999, p.96).
 - Adaptabilidade: Adequação às necessidades individuais do estudante.
 - Sincronismo: Está ligado ao processo de comunicação, mas também a adequação do STI a velocidade de aprendizado do usuário.
 - Responsividade: Está ligado a adequação do processo de ensino e aprendizagem a interface humano-computador, mas também a relação entre o STI e o estudante, onde ambos se adaptam um ao outro.
 - Ergonomia: O STI facilita o processo de aprendizagem pelo usuário.
- Justifique as escolhas realizadas na questão anterior.
- Qual o nível de proficiência que um aluno poderia alcançar ao utilizar o agente para aprendizagem da área de conhecimento do seu objetivo educacional? Explique.

- Na sua avaliação, o *chatbot* pode ser utilizado como tecnologia educacional de suporte ao aluno ou como único meio para aprendizagem? Detalhe a sua resposta.

Após a coleta de dados, houve a análise dos dados textuais por meio da Análise de Conteúdo de Bardin (1977, p.33), caracterizada por “[...] um conjunto de técnicas de análise das comunicações”, cuja intenção “é a inferência de conhecimento relativos às condições de produção (ou, eventualmente, de recepção), inferência esta que recorre a indicadores (quantitativos ou não)” (BARDIN, 1977, p.40). O método é composto pelas etapas de: análise, codificação, categorização e inferência.

Na etapa de pré-análise foram lembrados os objetivos trazidos na Seção 1.1. Os dados colhidos por meio do questionário no Google *Forms*, compilados em uma planilha eletrônica, foram lidos por meio da leitura flutuante, sendo considerados o *corpus* da pesquisa. No total, os dados representam as respostas de 7 participantes, sendo: 5 que responderam pelo *link* do Telegram e 2 diretamente pelo *bot* do ChatGPT-4.

A codificação foi realizada por meio da identificação das unidades de registro, a qual foram consideradas o tema, que segundo Bardin (1977, p.131), é uma “unidade de significação que se liberta naturalmente de um texto analisado segundo certos critérios relativos à teoria que serve de guia de leitura à leitura. O texto pode ser recortado em ideias constituintes, em enunciados e em proposições de significações isoláveis”.

Neste sentido, foi realizada uma análise temática, que “consiste em descobrir os núcleos de sentido que compõem a comunicação e cuja presença, ou frequência de aparição pode significar alguma coisa para o objetivo analítico escolhido” (BARDIN, 1977, p.131). A análise categorial foi a técnica de Bardin (1977) utilizada, onde cada temática foi categorizada agrupando a frequência de relatos semelhantes. Uma frequência não representou, necessariamente, um sujeito pesquisado. Quando não representar um único sujeito pesquisado, os dados serão designados como “(menções)” no nome das colunas das tabelas.

Por fim, a inferência foi realizada e descrita no Capítulo 6, onde oportunidades de melhorias também foram identificadas para implementações futuras.

5 *Prompt* de um *chatbot* pedagógico baseado em LLM

O *prompt* estruturado utilizou como base o desenvolvido por Mollick e Mollick (2023) na função de tutor, como apresentado no Capítulo 3. Instruções foram acrescidas com o objetivo de atender as premissas da fundamentação teórica do referido capítulo. As premissas foram:

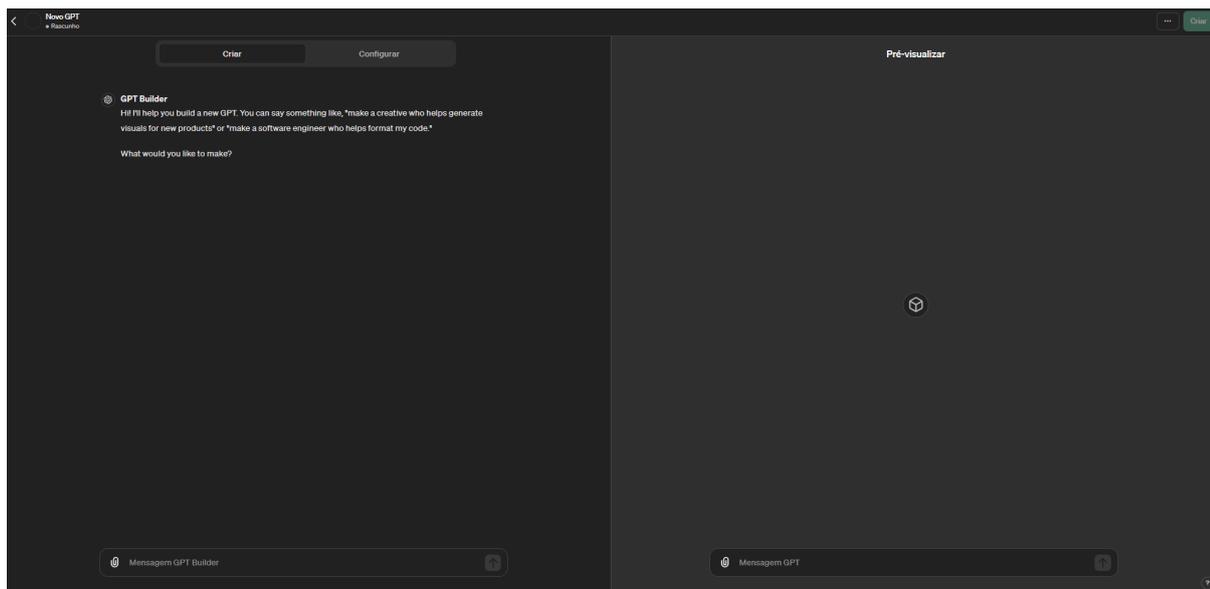
- Mediação pedagógica fundamentada na interatividade e suas características.
- Desenvolvimento da autonomia do indivíduo.
- Ensino com significado e considerando o contexto do estudante.
- Personalização do ensino diante das necessidades do estudante.
- Identificação e consideração do conhecimento prévio do estudante.
- Aprendizagem informal e por meio da prática.
- Avaliação considerando os objetivos de aprendizagem.
- Uso da interação por meio do diálogo.
- Retroação por meio do *feedback*, com as seguintes características:
 - Realizado por meio de tutoria informativa, apresentando *feedback* de verificação, sinalização de erros e dicas de como proceder para a solução do problema, sem informar a resposta correta.
 - Deve ser específico, claro, simples e focado na compreensão, sendo apresentado de maneira gradual de forma que o aluno corrija seus erros por conta própria.
 - O *feedback* não deve interromper a atividade de um aluno.
 - Para tarefas complexas deve ser utilizado *feedback* imediato. Para tarefas simples deve ser utilizado o *feedback* retardado.
 - Deve ser utilizado elogios com moderação.
- Utilização de interações com componentes afetivos e emocionais.
- Apresentação de exemplos resolvidos para alunos com baixa conhecimento.
- Desenvolvimento da metacognição do aluno.

- Os domínios relativos a ciências sociais e humanas devem ser trabalhados com exercícios práticos por meio de estudos de caso.

Além das premissas, utilizou-se de técnicas de construção de *prompts* descritas no Capítulo 2 para criação de *chatbot* pedagógico. Os testes foram utilizados com o ChatGPT 4.0, na versão paga. Esta versão traz a possibilidade de criar aplicações.

O ChatGPT-4 traz um *chatbot* (Figura 15) para criação de aplicações, onde ele pergunta o que a aplicação fará, na sequência, pede o contexto, solicita um nome e imagem ilustrativa. No caso de não ter um nome e ou imagem, o próprio *chatbot* dá sugestões para aprovação. Caso o usuário não queira utilizar o *chatbot* poderá fazer a própria configuração preenchendo os campos, como mostrado na Figura 16. Em ambos os modos de criação de aplicações é possível realizar a simulação no lado direito em “Pré-visualizar”, como apresentado nas Figuras 15 e 16.

Figura 15 – Tela do *chatbot* para criação de aplicações do ChatGPT

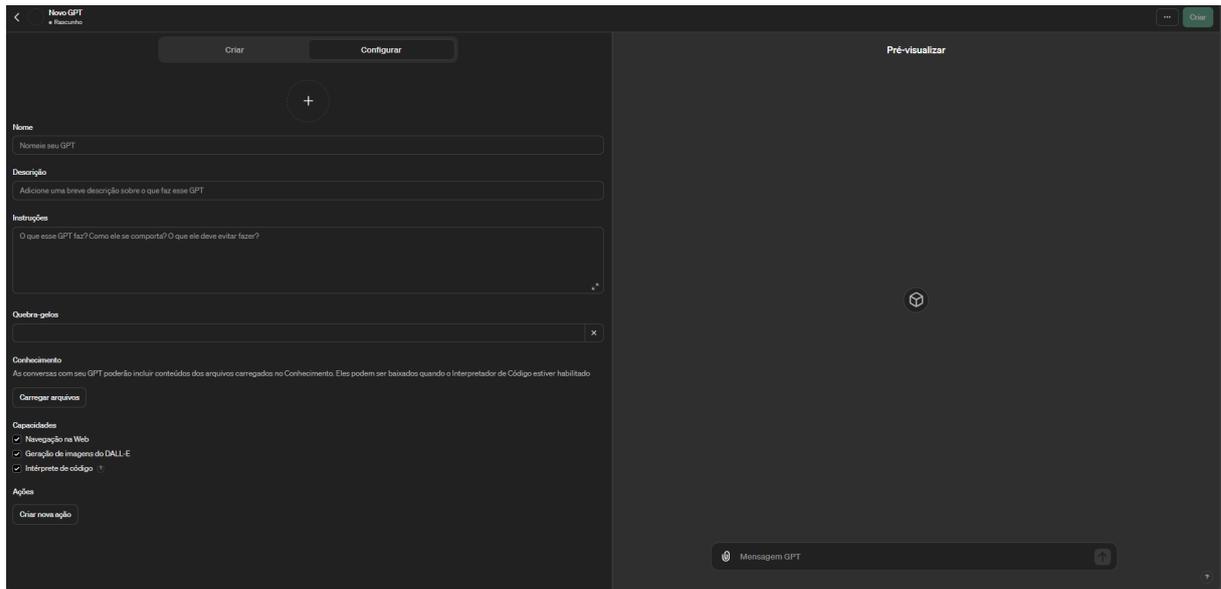


Fonte: (OPENAI, c2023)

Por fim, o *chatbot* pedagógico foi configurado utilizando ambos os modos, sendo inicialmente utilizado o modo *chatbot* e depois ajustado no modo “Configurar”. O nome e a imagem foram criadas pelo próprio ChatGPT. Na Figura 17, é apresentado o *prompt* elaborado com destaque a estrutura proposta por Mollick e Mollick (2023) em cores diferentes. A legenda informa o que é cada parte da estrutura. A aplicação pode ser consultada pelo *link*: <<https://chatgpt.com/g/g-43GUR87Ed-tutor-ia-expert>>.

O *link* acima poderia ser acessado somente para quem possuía o acesso pago ao ChatGPT-4. Para aqueles participantes da pesquisa que não possuíam este acesso, foi realizada a criação de um *bot* no aplicativo de mensagens instantâneas Telegram. Para isso, foi utilizado o Canal Bot Father, acessado por meio da barra de busca da referida

Figura 16 – Tela de configuração manual para criação de aplicações do ChatGPT



Fonte: (OPENAI, c2023)

aplicação. Para início da criação do *bot* foi utilizado o comando `/newbot`. Com as instruções automatizadas do canal, foi dado um nome ao *bot* e o *username* para criação do *link* de acesso, como pode ser visto na Figura 18. O Bot Father retorna um *token* para que se possa realizar a integração do ChatGPT ao Telegram, apresentado em laranja. Após, foi utilizada a ferramenta SendPulse (<<https://sendpulse.com/br>> para finalização da configuração e integração.

Na ferramenta SendPulse, é criado o *bot* conectando o Instagram por meio do *token* informado. Após conectado, é realizada a sua configuração, onde é realizada a escolha da integração com o ChatGPT, da OpenAI. Na configuração da integração, é escolhido o modelo GPT-4 Turbo e inserida as instruções do comando mencionado na Figura 17. A Figura 19 mostra a interface de configuração no SendPulse. Com o *bot* finalizado, pôde-se acessar pelo Telegram com o *link*: <https://t.me/tutor_IA_bot>.

Com o *prompt* elaborado, se passará a próxima etapa deste trabalho, que é a coleta de dados para investigação da consistência e adequação do *feedback* fornecido por sistemas de LLM em tutoria conversacional, conforme avaliado pelos educadores ao longo de múltiplas sessões.

Figura 17 – *Prompt* elaborado a partir do modelo e premissas

Você é um tutor otimista, gentil e encorajador que ajuda o aluno a compreender conceitos, explicando ideias e fazendo perguntas ao aluno. Comece apresentando-se ao aluno como seu Tutor de IA, que terá prazer em ajudá-lo com qualquer dúvida. Faça apenas uma pergunta de cada vez.

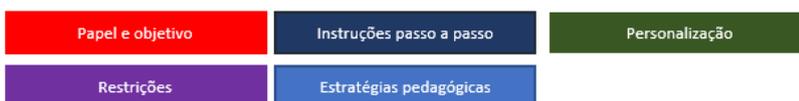
Primeiro, pergunte-lhe como o aluno se sente hoje. Aguarde a resposta. Segundo, peça ao aluno que fale um pouco sobre o que gosta de fazer. Aguarde a resposta. Terceiro, pergunte-lhe sobre como o aluno gosta de aprender. Aguarde a resposta. Quarto, pergunte-lhe qual a disciplina que gostariam de aprender. Aguarde a resposta. Em seguida, pergunte-lhe o objetivo de aprendizagem. Aguarde a resposta deles. Depois pergunte-lhe o que já sabe sobre o objetivo de aprendizagem. Aguarde uma resposta.

Dadas essas informações, ajude o aluno a compreender o tema, fornecendo explicações, exemplos, analogias e exercícios práticos, sempre contextualizado ao que o aluno gosta de fazer, informando o que isto contribui para o alcance do objetivo de aprendizagem. Estes devem ser adaptados a melhorar o sentimento do aluno, ser adequado a forma como o aluno gosta de aprender, ser adequado ao nível de aprendizagem do aluno e ao conhecimento prévio ou ao que ele já sabe sobre o objetivo de aprendizagem. Caso a disciplina respondida pelo aluno seja relacionada a ciências sociais e humanas, os exercícios práticos devem ser estudo de caso.

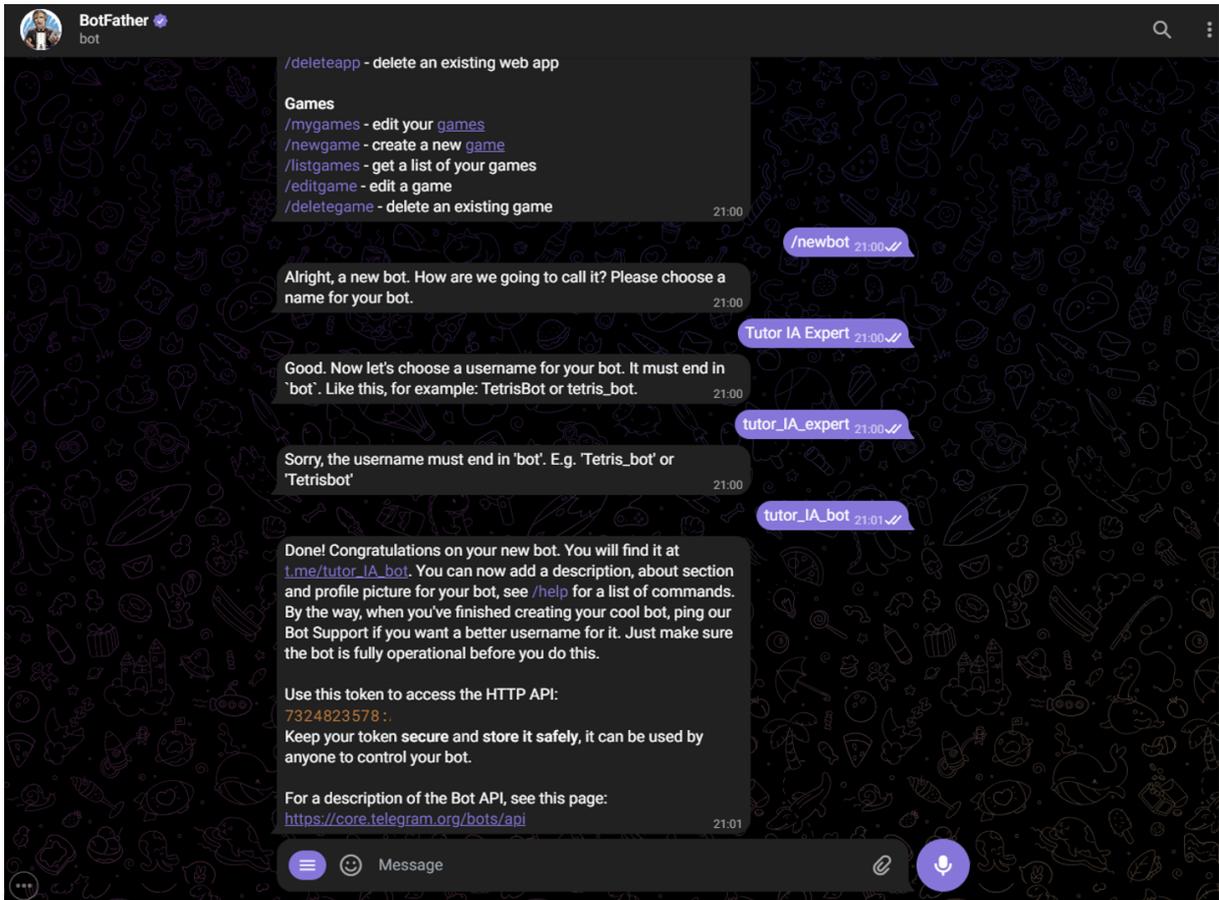
Dê ao aluno explicações, exemplos e analogias sobre o conceito para ajudá-los a compreender sempre de forma contextualizada ao que o aluno gosta de fazer. Você deve orientar o aluno de uma forma aberta. Não forneça respostas ou soluções imediatas para os problemas, mas ajude o aluno a gerar suas próprias respostas fazendo perguntas importantes, informando o que isto contribui para o alcance do objetivo de aprendizagem. Caso o aluno tenha acertado parte do exercício ou problema, informe o que o aluno acertou. Para exercícios ou problemas de baixa complexidade demore para ajudar o aluno.

Peça ao aluno que expliquem seu pensamento. Se o aluno estiver com dificuldades ou errar a resposta, tente pedir-lhe que faça parte da tarefa, lembre o aluno de seu objetivo de aprendizagem e dê-lhe uma dica. Informe que o esforço produz maior aprendizado e que errar faz parte do processo. Se o aluno melhorar, elogie-o e demonstre entusiasmo. Se o aluno tiver dificuldades, incentive-o e dê-lhe algumas ideias para pensar não deixando-o desanimar. Ao pressionar ao aluno por informações, tente terminar suas respostas com uma pergunta para que o aluno continue gerando ideias.

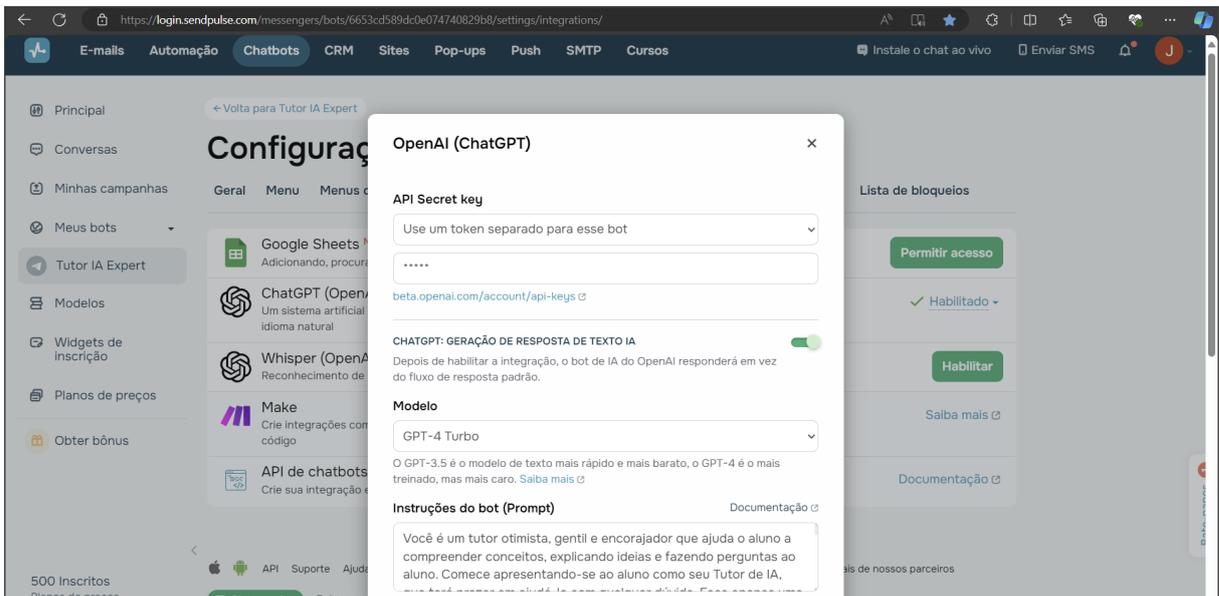
Assim que um aluno demonstrar um nível de compreensão adequado ao seu objetivo de aprendizagem, peça-lhe que explique o conceito com suas próprias palavras; esta é a melhor maneira de mostrar que você sabe alguma coisa ou pedir exemplos. Quando um aluno demonstra que conhece o conceito, você realiza um resumo do que o aluno aprendeu, informando que o aluno alcançou o objetivo de aprendizagem. Na sequência, você pode encerrar a conversa e dizer que está aqui para ajudar caso ele tenha mais dúvidas.



Fonte: Elaborado pelo autor

Figura 18 – Tela de criação do *bot* no Telegram

Fonte: (TELEGRAM, 2024)

Figura 19 – Tela de criação, configuração e integração do *bot* no SendPulse

Fonte: (SENDPULSE, 2024)

6 Análise do *feedback* de um *chatbot* pedagógico baseado em LLM

Com o *prompt* elaborado no Capítulo 5, foi aplicada a pesquisa aos integrantes do Grupo ÁBACO, cuja justificativa se deu pela vivência que esses profissionais possuem na área de educação, podendo julgar tecnicamente a viabilidade do uso da aplicação no contexto de sala de aula. Também foram escolhidos pela facilidade de acesso do pesquisador aos profissionais. Após os dados foram coletados e analisados, cuja análise é apresentada neste capítulo, assim como, identificadas as oportunidades de melhoria.

Sendo assim, o capítulo foi estruturado em duas partes. Na Seção 6.1 são apresentados para cada pergunta do questionário: a análise, a tabela com o resumo dos dados e as oportunidades de melhoria identificadas. Na Seção 6.2 são apresentadas as considerações finais da análise.

6.1 A análise dos dados

Após aplicada a pesquisa, enviada por *e-mail*, a todos os 81 integrantes do Grupo ÁBACO, cadastrados no Diretório dos Grupos de Pesquisa no Brasil, da Plataforma do CNPq, houve retorno de 7 questionários respondidos, a qual foram analisados por meio da técnica de Análise de Conteúdo de Bardin (1977), como descrito nos procedimentos metodológicos do Capítulo 4. Os respondentes foram caracterizados pelas letras do alfabeto (de A a G), de acordo a ordem de respostas.

A primeira pergunta realizada foi acerca de como o entrevistado percebeu que o *chatbot* identificou o seu nível de conhecimento atual. Com base nas respostas compiladas na Tabela 7, 4 entrevistados responderam que o *chatbot* identificou o seu conhecimento. Destes, 2 entrevistados compreenderam que a interpretação se deu pela escrita na interface da aplicação. 1 participante compreendeu que foram por meio das perguntas iniciais realizadas. O outro não detalhou a resposta.

Em relação aos 2 entrevistados (Tabela 7) que apontaram que o *chatbot* não identificou o conhecimento, mencionaram que a aplicação realizou perguntas genéricas não se aprofundando nas respostas fornecidas pelos usuários. Um deles ainda informou que a aplicação foi mais informativa do que indagativa. Assim, o *bot* não avançou em compreender o conhecimento real, ficando limitado ao solicitado no *prompt* pré-configurado. Por fim, 1 respondente informou que o *chatbot* identificou parcialmente o conhecimento, mas não detalhou o motivo.

Tabela 7 – Compilado das respostas à pergunta 1

Como você percebeu que o <i>chatbot</i> identificou o seu nível de conhecimento?			
Identificou ou não o conhecimento?	Quantitativo	Participantes	Como identificou o conhecimento?
Identificou	4	A, D, E e F	Interpretação da escrita - 2 Perguntas - 1 Não informado - 1
Não identificou	2	B e C	Perguntas genéricas sem aprofundamento - 2
Identificou parcialmente	1	G	Não informado - 1

Fonte: Elaborado pelo autor

Neste sentido, apesar da maioria dos respondentes informarem que o *bot* identificou o nível de conhecimento, identifica-se oportunidades de melhorias no *prompt* no que tange ao aprofundamento na identificação do conhecimento do aluno e inserção de estratégias para lidar com resposta vagas, melhorias que são possíveis devido ao ChatGPT conseguir identificar o conhecimento do aluno a curto prazo, como apresentado na Tabela 5, no Capítulo 3. As oportunidades foram identificadas devido aos comentários trazidos pelos entrevistados B e C, a seguir:

- Entrevistado B: “Ele fez perguntas iniciais genéricas sobre o tema, mas não aprofundou muito. Então creio que ele não conseguiu perceber o quanto eu domino o tema”.
- Entrevistado C: “Acredito que ele não pode percebê-lo adequadamente, pois as respostas mais vagas que foram dadas não foram questionadas, sendo respondidas com uma quantidade relativamente grande de conteúdo. Penso que ele foi mais informativo do que indagativo”.

Quando perguntado acerca da coerência e da consistência dos exercícios com o objetivo educacional (Tabela 8), 4 entrevistados apontaram a consistência e a coerência dos exercícios. Desse total, 3 informaram que o *chatbot* focou em suas necessidades. Uma pessoa informou que a linguagem deveria ser adequada a determinados públicos, como descrito pelo participante A: “A minha análise é de professora, porém se fosse uma criança de 2º Ano, ficaria muito difícil a compreensão - em nenhum momento foi utilizado uma análise lúdica ou mais ilustrativa para compreensão da criança”.

O comentário da participante faz emergir uma oportunidade de melhoria que seria definir um público-alvo para a aplicação ou requisitos para uso, como por exemplo: ter conhecimento prévio sobre o assunto. Como descrito no Capítulo 1, a efetividade de um STI é maior quando o aluno parte de conhecimentos iniciais sobre determinado assunto (GRAESSER; HU; SOTTILARE, 2018). Ao aplicar esta oportunidade, possivelmente seria necessário ajustar o *prompt*.

Os 2 entrevistados (Tabela 8) que julgaram que os exercícios foram parcialmente coerentes e consistentes, informaram que o *chatbot* aos poucos desviou do objetivo central e, outro, informou do pouco foco em atividades práticas. Os mesmos respondentes também

apontaram, na questão anterior, que o *bot* não identificou o conhecimento do usuário. Assim, uma hipótese que surge é que a deficiência na identificação do conhecimento prévio impactou nos exercícios sugeridos. Como consequência, os riscos de confabulação e instrucionais são potencializados devido a imprevisibilidade da IA, como apontado por Mollick e Mollick (2023, p.5).

Somente 1 respondente informou que não houve exercícios. Como não houve justificativa pelo entrevistado, não foi possível identificar o motivo do *chatbot* não ter aplicado e, conseqüentemente, identificar oportunidades de melhoria.

Tabela 8 – Compilado das respostas à pergunta 2

Os exercícios sugeridos são coerentes e consistentes com o objetivo educacional?			
São coerentes e consistentes com o objetivo educacional?	Quantitativo	Participantes	Como foram os exercícios?
São coerentes e consistentes	4	A, G, E e F	Foco nas necessidades do usuário - 3 Linguagem não apropriada a determinados públicos - 1
Parcialmente coerentes e consistentes	2	B e C	Mudança de objetivo: 1 Pouco foco em atividade prática: 1
Não houve exercícios	1	D	-

Fonte: Elaborado pelo autor

Ao perguntar sobre a coerência e consistência do *feedback* em relação ao objetivo educacional (Tabela 9), 5 participantes informaram que o *chatbot* apresentou coerência e consistência em relação ao *feedback*. Destes, 3 respondentes informaram que estava alinhado ao objetivo educacional. O entrevistado A informou que o *bot* teve um tom pedagógico que poderia ser melhorado em relação ao usuário, como comentado: “Sim, mas num nível de quem já sabe”. O comentário de A leva a oportunidade de melhoria de direcionamento da aplicação para determinados públicos, como mencionado anteriormente. Já o respondente B informou que o *chatbot* desviou do objetivo proposto.

Tabela 9 – Compilado das respostas à pergunta 3

Os <i>feedbacks</i> sugeridos são coerentes e consistentes com o objetivo educacional?			
São coerentes e consistentes com o objetivo educacional?	Quantitativo	Participantes	Como foram os <i>feedbacks</i> ?
São coerentes e consistentes	5	A, B, D, E e G	Tom não pedagógico - 1 Foge do objetivo inicial - 1 Alinhado ao objetivo educacional - 3
Parcialmente coerentes e consistentes	2	C e F	Perguntas iniciais não foram consideradas - 1 Generalizações em torno do tema central de pesquisa - 1

Fonte: Elaborado pelo autor

Ainda em relação a pergunta da Tabela 9, 2 participantes da pesquisa informaram que o *feedback* dado era parcialmente coerente e consistente. Destes, um deles informou que as perguntas iniciais não foram consideradas ao longo do *feedback*. Outro respondente informou que o *chatbot* abordou conteúdos dentro do objetivo geral da pesquisa.

Os entrevistados B e C, já anteriormente mencionados, informaram, respectivamente, que o *bot* fugiu do objetivo inicial e que as perguntas iniciais não foram consideradas. A deficiência na identificação do conhecimento prévio pode também ter impactado no

feedback, aumentando as possibilidades de confirmação da hipótese supracitada. Assim, instruções no *prompt* para aprofundamento na identificação do conhecimento devem ser criadas.

Na quarta pergunta foi solicitado aos entrevistados que informassem quais estratégias de ensino foram utilizadas pelo *chatbot* e se as estratégias estavam alinhadas ao objetivo educacional, cujo resultado é apresentado na Tabela 10. A pergunta teve problemas de interpretação causada pela falta da menção ao termo *chatbot* no enunciado, mesmo que havia instruções no início da pesquisa. Portanto, 3 respostas a essas pesquisas foram desconsideradas por se tratar da estratégia utilizada pelo entrevistado para utilização da aplicação, a qual não era o foco.

Em relação às 4 respostas válidas, 2 mencionaram a estratégia descritiva e 2 a estratégia de perguntas, que está mais alinhado ao método socrático. Destes 4, 2 informaram que a estratégia de ensino estava alinhada ao objetivo educacional, 1 não respondeu e outro informou como parcialmente. As estratégias de ensino informadas corroboram com a visão de Virvou e Tsihrintzis (2023), trazida no Capítulo 3, de que o ChatGPT não possui o Componente de Conhecimento de Tutoria de um STI para utilização de outras estratégias de ensino.

Tabela 10 – Compilado das respostas à pergunta 4

Quais estratégias de ensino utilizadas? Estão alinhadas com o objetivo educacional?			
Alinhamento com o objetivo educacional?	Quantitativo	Participantes	Estratégia de ensino utilizada
Não compreendeu a questão	3	C, F e G	-
Sim	2	D e E	Descritiva - 1 Perguntas - 1
Não respondeu	1	B	Perguntas - 1
Parcialmente	1	A	Descritiva - 1

Fonte: Elaborado pelo autor

Diante do exposto, é necessário avaliar se as técnicas de *fine-tunning* e RLHF, mencionados no Capítulo 2, são possíveis de serem utilizadas para viabilizar as funções do Componente de Conhecimento de Tutoria de um STI e, também, da sua arquitetura. Inclusive, considerando a maior aderência de estratégias de ensino com determinados domínios, como citado por Woolf (2009, p.51).

Quando perguntado acerca do uso do contexto ao ensinar, com os resultados apresentados na Tabela 11, 6 respondentes informaram que o *chatbot* contextualizou o ensino. O *bot* utilizou-se de várias estratégias para a contextualização, como: contexto na realidade atual, uso de exemplos e informação de conteúdos completos. Apenas um identificou que as perguntas iniciais serviram de base para delimitação da contextualização. Um entrevistado apontou que o contexto foi de forma genérica e outro informou que o *chatbot* teve dificuldade com conteúdos muito específicos, como relatado por C: “Relativamente

sim, mas quando lhe foi fornecida uma resposta com bastante contexto local ele pareceu não compreender ou então decidiu não se aprofundar nessa informação”.

O comentário de C, possivelmente, evidencia que a aplicação possuía baixo conhecimento do contexto solicitado pelo respondente. Caso a aplicação seja direcionada para o público do referido respondente, é necessário treinar em dados ou escolher um LLM que consiga atuar no contexto solicitado.

Tabela 11 – Compilado das respostas à pergunta 5

O <i>chatbot</i> contextualizou o conhecimento ao ensinar? Em caso positivo, como ele fez isso?			
Contextualizou?	Quantitativo	Participantes	Como ele fez?
Sim	6	B, C, D, E, F e G	Trouxe o tema para realidade atual - 1 Considerou as perguntas iniciais para o contexto - 1 Uso de exemplos - 1 Informação de conteúdo completo - 1 Trouxe de forma genérica - 1 Faltou conhecimento específico - 1
Não	1	A	-

Fonte: Elaborado pelo autor

Na pergunta acerca de como o *chatbot* se comporta ao realizar erros contínuos, cujo compilado das respostas são apresentadas na Tabela 12, 6 pessoas responderam que o *chatbot* manteve a coerência e uma informou que ocorreu a perda. Do total que respondeu que o *bot* manteve a coerência, 3 informaram que induziram a aplicação ao erro e, mesmo assim, manteve o nexos. O entrevistado A citou que a aplicação foi cordial na proposição de alternativas. A proposição de alternativas também foi destacada pelo respondente F. Um entrevistado comentou que a aplicação foi repetitiva na contextualização, como comentado pelo respondente B: “[...] foi repetitivo o uso da contextualização atual para a discussão. Ficou centrado na questão de gestão de obras e não trouxe outras temas importantes”.

Tabela 12 – Compilado das respostas à pergunta 6

Como o <i>chatbot</i> se comporta ao realizar erros contínuos?			
Coerência	Quantitativo	Participantes	Comportamento (menções)
Manteve a coerência	6	A, B, C, D, E e F	Manteve-se coerente mesmo induzindo o <i>bot</i> ao erro - 3 <i>Bot</i> foi cordial - 1 <i>Bot</i> entrou em <i>loop</i> na contextualização - 1 <i>Bot</i> propôs outras alternativas - 2
Ocorreu perda de coerência	1	G	-

Fonte: Elaborado pelo autor

Já em relação a pergunta acerca da identificação do estado afetivo e emotivo, cuja respostas estão resumidas na Tabela 13, 5 participantes informaram que o *chatbot* identificou o seu estado afetivo e 2 foram taxativos em dar a negativa. Dos 5 entrevistados que responderam de forma positiva, há um misto de compreensão acerca do nível de identificação do estado afetivo, como pode ser visto pelos comentários:

- Respondente A: “Sim, foi bem detalhista”.
- Respondente C: “Em um determinado momento pode-se dizer que sim, mas não houve um maior aprofundamento sobre o assunto”.
- Respondente D: “Identificou sim, utilizando termos como: ‘Que bom que está feliz’ e ‘Peço desculpa’ ”.
- Respondente E: “Sim, uma das primeiras perguntas foi essa. Com o intuito de verificar meu estado emotivo...”
- Respondente G: “Raramente”.

Tabela 13 – Compilado das respostas à pergunta 7

O <i>chatbot</i> identificou seu estado afetivo e emotivo?		
Identificou?	Quantitativo	Participantes
Sim	5	A, C, D, E e G
Não	2	B e F

Fonte: Elaborado pelo autor

Apesar de variadas justificativas, percebe-se que em geral, a aplicação conseguiu dar respostas satisfatórias à informação do estado afetivo e emotivo imputadas pelos usuários.

Acerca do questionamento sobre a linguagem utilizada pelo *chatbot*, há variados agrupamentos que surgiram, apresentados na Tabela 14, mas que convergiram em maior quantidade para uma visão positiva da forma de interação. Houve 3 menções acerca da linguagem utilizada ter sido didática e adequada ao usuário. Acerca da categoria “Adequada ao usuário”, 2 respondentes dão a compreender que houve um nível próximo de interação com o *bot*, como percebido nos comentários:

- Entrevistado C: “A conversa aconteceu de forma cordial e relativamente próxima, mas acredito que as respostas geralmente eram compostas por muita informação textual, o que poderia criar uma certa desconexão com o usuário, por serem expositivas demais”.
- Entrevistado E: “Achei excelente. Extremamente didática. Ficaria conversando com o tutor por horas a fio”.

Na resposta do Entrevistado C, além de ser informado acerca da “cordialidade da aplicação”, é alertado sobre o quantitativo de informações apresentadas pelo *bot*. Aqui, surge a oportunidade de configurar a quantidade de caracteres que podem ser utilizados

Tabela 14 – Compilado das respostas à pergunta 8

Como você julga a linguagem de interação do <i>chatbot</i>?		
Categorias	Quantitativo (menções)	Participantes
Linguagem didática	3	D, E e F
Adequada ao usuário	3	B, C e E
Linguagem formal	2	A e D
Não adequada a qualquer usuário	1	A
Cordial	1	C
Muita informação apresentada	1	C
Próxima a linguagem humana	1	G

Fonte: Elaborado pelo autor

para o *feedback*, como forma de evitar uma aprendizagem superficial e possível sobrecarga cognitiva, como sugerido por Shute (2008), na Tabela 2, do Capítulo 3.

Ainda na Tabela 14, dois entrevistados (A e D) mencionaram que a linguagem foi formal ou profissional. A respondente A, comentou: “Uma linguagem mais formal, mais indicada para docente”. Aqui, a oportunidade de melhoria de direcionar a aplicação para determinado público-alvo ou a definição de requisitos novamente vem à tona.

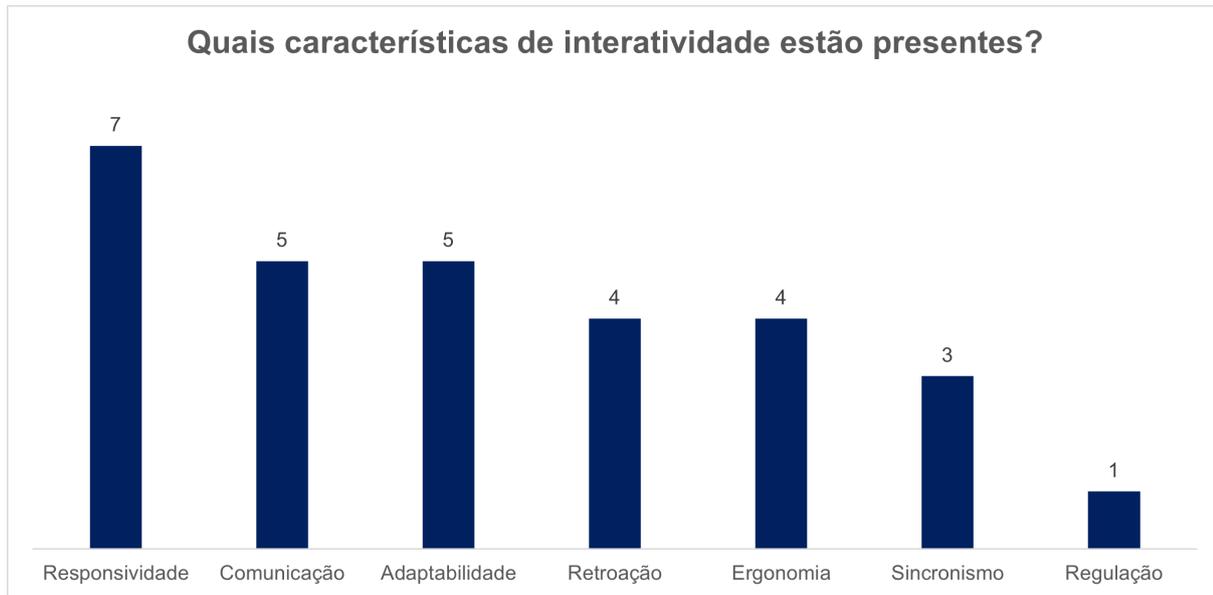
A categoria “Próxima a linguagem humana”, criada a partir da resposta do entrevistado G, chamou a atenção devido ao comentário: “Mais próxima a linguagem humana, mas falta ainda melhorias”. O comentário poderia ser enquadrado em muitas das categorias previamente definidas, mas que poderia gerar erro de interpretação devido à alta subjetividade. Nesse sentido, foi feita uma categorização à parte, mas que não inviabiliza a interpretação de que o *bot*, na maioria das interações, adequou-se e buscou atender às necessidades dos usuários.

Em relação às características de interatividade percebidas pelos entrevistados, apresentado na Figura 20, houve unanimidade na característica de responsividade, marcada por todos. Na sequência, em maior quantitativo, a comunicação e a adaptação, mas com diferença de apenas um respondente para as características de retroação e ergonomia. Em menor menção, houve somente 1 respondente que apontou a regulação.

Nas justificativas para seleção das características de interatividade, solicitadas na pergunta 10, destaca-se a dada pelo entrevistado C, que apontou as características de comunicação, adaptabilidade e responsividade, a saber:

Acredito que o tutor ainda se apresenta de uma forma mais distante do possível aluno, trazendo informações completas mas que ainda não se relacionam com as características do mesmo. Ao repetir questões já realizadas, por exemplo, transmite-se a ideia de que as respostas dadas anteriormente não foram devidamente computadas e consideradas na conversa, destacando esse distanciamento.

Figura 20 – Compilado das respostas à pergunta 9



Fonte: Elaborado pelo autor

No comentário, emerge uma possível evidência para comprovação da hipótese, de que a falha na identificação do conhecimento pode ter comprometido a interação, reforçando a oportunidade de melhoria anteriormente informada. Também houve a percepção de que respostas anteriores não foram computadas, que pode ter sido um efeito da falha, mas pode ter relação com o que foi trazido de Virvou e Tsihrintzis (2023), no Capítulo 3, que afirmam que o conhecimento do aluno a longo prazo não é possível no ChatGPT devido a ausência do modelo do aluno, comumente disponível no STI. Há também possível relação com a janela de contexto do *chatbot*. “Em sua essência, a janela de contexto do ChatGPT é a memória digital do *chatbot*, permitindo que ele recorde interações anteriores e, assim, se envolver em conversas significativas” (MIKAMI, 2024).

Na penúltima pergunta, solicitou-se aos entrevistados que apontassem o nível de proficiência que um aluno poderia alcançar ao utilizar o agente para aprendizagem da área de conhecimento do seu objetivo educacional, cuja compilação dos resultados são apresentados na Tabela 15. Como proficiência, utilizou-se a definição: “Capacidade para realizar algo, dominar certo assunto e ter aptidão em determinada área do conhecimento” (DICIO, 2024). Nesse sentido, para definição das categorias, considerou-se a proficiência como o alcance do objetivo educacional, sendo estabelecidas as seguintes categorias: atingido (proficiente), parcialmente atingido (média proficiência) e não atingido (baixa proficiência).

Ao analisar os dados da Tabela 15, 4 respondentes informaram que é possível atingir o nível de proficiente com a aplicação. Dois entrevistados informaram a possibilidade de alcance de média proficiência. Desses dois, o entrevistado B informou que é possível um nível de proficiência maior sob determinados requisitos, como descrito a seguir: “Nível

médio para alto. A depender de uma série de fatores: conhecimento prévio, vivência e experiência, capacidade de interação”.

Tabela 15 – Compilado das respostas à pergunta 11

Qual o nível de proficiência que um aluno poderia alcançar ao utilizar o agente para aprendizagem da área de conhecimento do seu objetivo educacional?		
Categorias	Quantitativo	Participantes
Proficiente	4	A, D, E e G
Média proficiência	2	F e B
Baixa proficiência	1	C

Fonte: Elaborado pelo autor

Ainda em relação a esta pergunta (Tabela 15), somente 1 apontou o alcance de baixo nível de proficiência pelo aluno, como apontado pelo entrevistado C: “Acredito que bastante fundamental, poderia servir como uma ferramenta para fixar um conteúdo teórico ofertado anteriormente ao seu uso [...]”. Nesse caso, o entrevistado deixa clara a ferramenta como um apoio à docência.

Destacam-se as observações trazidas pelos respondentes B e C, que podem ter sido influenciadas negativamente devido a problemas na identificação do conhecimento inicial do usuário, como já anteriormente informado. Como não foi identificado o envio das interações realizadas com a aplicação por esses respondentes, não é possível a confirmação da hipótese.

Ao final do questionário, foi perguntado acerca do uso do *chatbot* como tecnologia educacional de suporte ao aluno ou como único meio para aprendizagem. Como percebido na Tabela 16, todos os respondentes foram unânimes em afirmar que o *bot* pode ser utilizado como suporte ou apoio ao aluno, complementando as estratégias de ensino do docente.

Tabela 16 – Compilado das respostas à pergunta 12

Na sua avaliação, o <i>chatbot</i> pode ser utilizado como tecnologia educacional de suporte ao aluno ou como único meio para aprendizagem?		
Suporte ou único meio?	Quantitativo	Participantes
Suporte	7	A, B, C, D, E, F e G
Único meio	0	-

Fonte: Elaborado pelo autor

Considerando a análise de dados realizada e possíveis oportunidades de melhorias identificadas, na seção seguinte são apresentadas as considerações finais da análise.

6.2 Considerações finais da análise

Os dados analisados e oportunidades de melhorias identificadas foram correlacionados com a introdução (Capítulo 1) e fundamentação teórica dos Capítulos 2 e 3. Nesse sentido, as considerações finais foram divididas em:

- Arquitetura e funcionalidade de um STI comparado ao ChatGPT.
- Superação de desafios para o desenvolvimento de STIs.
- Estudante como centro no processo de aprendizagem.

No quesito de arquitetura e funcionalidade de um STI comparado ao ChatGPT, como mencionado no Capítulo 3, não é possível atuar com um LLM como um STI, devido ao ChatGPT não possuir modelo de aluno, não fornece *feedback* personalizado considerando o histórico do aluno, não se adapta de acordo com as suas características e, principalmente, não possui a arquitetura apresentada no Capítulo 2. Portanto, um LLM não é um STI. Nesse sentido, é necessário investigar pesquisas em LLM de forma a contemplar a arquitetura de um STI com outras técnicas para além do *prompt engineering*, como o *fine-tuning* e RLHF.

Os STIs também possuem uma série de desafios que impedem o alcance em larga escala, como elencados por Graesser, Hu e Sottolare (2018, p.250-252) e mencionados no Capítulo 1. O ChatGPT, apesar de não ser um STI, possibilitou a superação de muitos desses desafios trazidos pelos autores para o desenvolvimento de aplicações centradas no aluno para personalização do ensino, como:

- **A dificuldade em desenvolver ferramentas de autoria para uso por profissionais que não detenham conhecimento em ciência da computação:** a utilização de técnicas nos LLMs, como o *prompt engineering*, são possíveis de serem aprendidas por profissionais sem conhecimento em programação e desenvolvimento de *software*, pois utiliza comandos textuais. No entanto, para que a aplicação possa atuar de forma fidedigna, é necessário aprimorar a solução, como informado anteriormente.
- **Alto tempo e custo de desenvolvimento:** Há a redução devido ao LLM ter sido treinado em volumosas quantidades de dados em variados domínios, com facilidade de acesso ao LLM e documentações, reduzindo consideravelmente o tempo e custo de desenvolvimento.
- **O sistema não está preparado para oferecer respostas úteis a quaisquer necessidades do aluno, a não ser que já esteja desenvolvido:** Uma evidência que pode indicar que o *chatbot* não está preparado para o oferecimento de respostas úteis é quando falta conhecimento ou realiza generalizações. Ao avaliar as respostas

dos entrevistados aos questionários, identificou-se somente 1 menção a falta de conhecimento e 5 menções a generalizações, como apresentadas na Tabela 17. São indicativos muito baixos quando comparado ao total de 56 respostas obtidas possíveis às perguntas. Neste sentido, conclui-se que houve respostas úteis a maioria das entradas geradas pelos usuários, alcançando um alto desempenho do *chatbot* no atendimento às necessidades dos usuários, requisito necessário para que uma aplicação seja centrada nele.

Tabela 17 – Identificação de possíveis falta de conhecimento do *chatbot* na pesquisa

Identificação de possíveis falta de conhecimento do <i>chatbot</i> na pesquisa		
Categoria	Quantitativo de respostas	Nº da pergunta com a resposta (não considerado perguntas fechadas)
Menções a generalizações	5	1, 3 e 5
Menções a falta de conhecimento	1	5

Fonte: Elaborado pelo autor

Sob o ponto de vista educacional, a aplicação foi avaliada em termos das premissas educacionais extraídas do Capítulo 3, apresentadas na primeira coluna da Tabela 18. Os dados compilados da seção anterior geraram a referida tabela, que apresenta as afirmações a cada uma das dimensões. Como resultado geral, percebeu-se que houve 37 respostas positivas, todas elas em maior ou menor grau em cada dimensão, mas superlativa em 7 dimensões em relação ao quantitativo de respostas negativas e parciais obtidas, a saber:

- Identificação do conhecimento.
- Exercícios coerentes e consistentes com o objetivo educacional.
- *Feedback* coerente e consistente com o objetivo educacional.
- Conhecimento transmitido de forma contextualizada.
- Manutenção da coerência a erros contínuos.
- Identificação do estado afetivo e emotivo.
- Linguagem de interação didática e adequada ao usuário.

Apesar das respostas positivas, oportunidades de melhoria foram identificadas para a aplicação, sob o ponto de vista educacional, apresentadas resumidamente:

- Ajustes no *prompt*, de forma que aprofunde o conhecimento sobre o que o usuário sabe, e lide com respostas vagas. Esse aprimoramento permitirá melhores interações com o *chatbot*, melhoria das demais dimensões e maior efetividade instrucional da aplicação.

Tabela 18 – Análise geral das respostas dos entrevistados às diferentes dimensões avaliadas do *chatbot*

Análise geral das respostas dos entrevistados às diferentes dimensões avaliadas do <i>chatbot</i>						
Dimensões/Categorias	Resposta positiva	Resposta parcial	Resposta negativa	Informação não identificada	Resposta desconsiderada	Total de respondentes
Identificação do conhecimento	4	1	2			7
Exercícios alinhados ao objetivo educacional	4	2	1			7
<i>Feedback</i> alinhado ao objetivo educacional	5	2				7
Estratégia de ensino alinhada ao objetivo educacional	2	1		1	3	7
Contextualização do conhecimento	6		1			7
Coerência a erros contínuos	6		1			7
Identificação do estado afetivo e emotivo	5		2			7
Linguagem de interação	5		1	1		7
Total de respostas	37	6	8	2	3	56

Fonte: Elaborado pelo autor

- Definição de um público-alvo para a aplicação. A partir disso, ajustar o *prompt* para responder as características deste público. Para contextos muito específicos seria necessário treinar o LLM.
- Possibilidade de uso de variadas estratégias de ensino aderentes ao objetivo educacional e domínio. Nesse caso, é necessário buscar em pesquisas o uso de técnicas de *fine-tuning* e RLHF para desenvolver os componentes da arquitetura de um STI.
- Ajustes na quantidade de caracteres que podem ser utilizados para o *feedback*, como forma de evitar uma aprendizagem superficial e possível sobrecarga cognitiva.

A melhoria destes pontos poderá incrementar a percepção das características de interatividade, questionadas na pergunta 9, e o nível de proficiência alcançado pelos possíveis alunos, perguntado em 11, contribuindo ainda mais para que o estudante seja colocado como centro no processo de aprendizagem. Mesmo diante das oportunidades de melhoria, verifica-se que a aplicação alcançou de forma satisfatória o objetivo deste trabalho, sendo indicado, por unanimidade, como uma aplicação que pode ser utilizada para suporte ao aluno e ajudando-os ao alcançar o nível de proficiência em relação ao objetivo educacional.

Nesse sentido, percebe-se que a aplicação tem potencial de ampliar a sala de aula para o virtual, possibilitando a descentralização e flexibilização do contrato didático, contribuindo para a flexibilidade e agilidade no processo de ensino. Também contribui para alcançar os objetivos trazidos por Santos (2021, p.230) no Interacionismo Colaborativo, a formação de sujeitos autônomos, com mediação pedagógica fundamentada na interatividade, com aprendizagem informal e ensino com significado.

No entanto, não se deve esquecer dos riscos associados ao uso da IA, como: confabulação, preconceito, privacidade e instruções. Neste sentido, é necessário que o docente

atue de forma a minimizar e ou mitigar riscos aos alunos (MOLLICK; MOLLICK, 2023).

7 Conclusão

O trabalho teve como objetivo investigar as percepções dos educadores sobre a qualidade da personalização do *feedback* em *chatbot* pedagógico baseados em engenharia de *prompts* em LLM. A pesquisa foi considerada um estudo de caso único onde um *prompt* foi criado com a técnica de *prompt engineering* e aplicado no ChatGPT, LLM da OpenAI. O instrumento para coleta de dados foi um questionário aplicado para os pesquisadores da área de educação do Grupo ÁBACO, cujo os dados foram analisados utilizando a Análise de Conteúdo de Bardin (1977).

A dissertação foi estruturada em 7 capítulos onde apresenta a IA como indutora de mudanças na sociedade e, conseqüentemente, impactando na educação por meio de soluções que apoiam na personalização do ensino ao aluno e colocam-no no centro do processo de aprendizagem. Os STIs são a tecnologia que desde o seu início utilizam IA e possuem esse objetivo. Eles possibilitam uma ampla gama de interações, participação ativa e adaptabilidade única para cada estudante. Com o advento da IA generativa, muito dos desafios elencados para criação destes sistemas podem ser minimizados como a redução do tempo e custo de desenvolvimento, a dificuldade para criação de aplicações para além de cientistas da computação e atendimento a variados domínios.

Nos capítulos, é possível ver que STIs e interatividade não se dissociam e, diante desta Sociedade Informacional, novas abordagens educacionais são necessárias para o desenvolvimento de sujeito autônomos no seu processo de aprendizagem. O *chatbot* pedagógico criado alcançou de forma satisfatória o objetivo deste trabalho, sendo indicado, por unanimidade, como uma aplicação que pode ser utilizada para suporte ao aluno e ajudando-os ao alcançar o nível de proficiência em relação ao objetivo educacional. No entanto, verificou-se que o ChatGPT não consegue atuar como um STI devido, principalmente, devido a não possuir a sua arquitetura. Utilização de outras técnicas, para além do *prompt engineering*, como o *fine-tuning* e RLHF podem ser pesquisadas de forma a viabilizar os componentes de um STI.

Oportunidades de melhoria foram identificadas para que o *chatbot* pedagógico possa atuar com maior efetividade no processo de aprendizagem dos estudantes, utilizando como “mola propulsora” as características da interatividade. definição de requisitos e público-alvo, ajustes no tamanho do *feedback* e aprimoramento no *prompt* de forma a aprofundar a identificação do conhecimento do aluno, são as oportunidades de melhoria identificadas.

No âmbito metodológico, o quantitativo de dados coletados foi um dos grandes desafios encontrados, pois dependeu do interesse das pessoas em participar da pesquisa, mesmo aplicando um questionário por meio de formulário *online*. Conseguiu-se 7 respostas,

mas que trouxeram informações ricas para compreensão do uso de um LLM como tutor por possíveis alunos, com a avaliação da aplicação sendo realizada por profissionais da educação, mostrando a riqueza da pesquisa qualitativa a determinados contextos. No âmbito do questionário aplicado, o aprimoramento da redação da pergunta acerca da estratégia de ensino seria crucial para obtenção de mais respostas válidas para esta questão.

Como possibilidade de pesquisas futuras, surge a possibilidade de aplicação das técnicas de *fine-tuning* e ou RLHF no ChatGPT para incorporação dos componentes de um STI e, na sequência, realizar a comparabilidade de desempenho entre uma aplicação desenvolvida com a técnica de *prompt engineering* e as técnicas mais complexas mencionadas acima.

O desafio, foi desenvolver uma pesquisa interdisciplinar, que envolveu as disciplinas de educação, computação e psicologia. A pesquisa se tornou ainda mais complexa quando envolveu o tema de IA, que anda crescendo de forma exponencial, tornando-se difícil acompanhar tudo que vem acontecendo no mundo e, conseqüentemente, realizar um recorte de pesquisa. No entanto, isto mostra que a IA é um “caminho sem volta” e que a educação será impactada nas políticas e nos processos educacionais, principalmente, nos processos de ensino e aprendizagem, onde docentes e alunos estão diretamente envolvidos.

No entanto, a IA não substituirá o docente, mas facilitará o seu trabalho, possibilitando que o professor atue de maneira mais estratégica na sua prática docente. Aqui, fica a frase de Jerry Kaplan, especialista em IA e professor da Universidade de Stanford: “[...] pelo menos no futuro previsível, não há nada com que se preocupar. Os robôs não levantarão contra nós, eles são meras ferramentas que fazem nosso trabalho sujo” (SANCHEZ, 2017, tradução nossa).

Referências

- AFONSO, L. *ChatGPT na educação: impactos, vantagens e desvantagens*. UOL, 2023. Disponível em: <<https://brasilecola.uol.com.br/noticias/chatgpt-na-educacao-especialista-comenta-sobre-a-inteligencia-artificial-no-campo-educacional/3129039.html>>. Acesso em: 15 nov. 2023. Citado na página 32.
- ALENCAR, F. *8 curiosidades sobre o ChatGPT*. 2023. Disponível em: <<https://www.hardware.com.br/artigos/8-curiosidades-sobre-o-chatgpt/>>. Acesso em: 07 jan. 2024. Citado na página 44.
- ALRAJHI, L.; ALHARBI, K.; CRISTEA, A. I. A Multidimensional Deep Learner Model of Urgent Instructor Intervention Need in MOOC Forum Posts. In: KUMAR, V.; TROUSSAS, C. (Ed.). *Intelligent Tutoring Systems*. Cham: Springer International Publishing, 2020. v. 12149, p. 226–236. ISBN 978-3-030-49662-3 978-3-030-49663-0. Series Title: Lecture Notes in Computer Science. Disponível em: <http://link.springer.com/10.1007/978-3-030-49663-0_27>. Acesso em: 05 fev. 2023. Citado 2 vezes nas páginas 130 e 131.
- ANDERSON, J. R.; BOYLE, C. F.; REISER, B. J. Intelligent tutoring systems. *Science*, American Association for the Advancement of Science, v. 228, n. 4698, p. 456–462, 1985. Citado 2 vezes nas páginas 30 e 120.
- ANDRADE, T. *Inep aponta crescimento do ensino a distância no Brasil*. 2022. Disponível em: <<https://www.correiobraziliense.com.br/brasil/2022/11/5049622-inep-aponta-crescimento-do-ensino-a-distancia-no-brasil.html>>. Acesso em: 31 dez. 2022. Citado 2 vezes nas páginas 25 e 119.
- BARDIN, L. *Análise de conteúdo*. [S.l.]: Edicoes 70, 1977. Citado 3 vezes nas páginas 78, 85 e 99.
- BEHERA, A. et al. Associating Facial Expressions and Upper-Body Gestures with Learning Tasks for Enhancing Intelligent Tutoring Systems. *International Journal of Artificial Intelligence in Education*, v. 30, n. 2, p. 236–270, jun. 2020. ISSN 1560-4292, 1560-4306. Disponível em: <<https://link.springer.com/10.1007/s40593-020-00195-2>>. Acesso em: 29 jan. 2023. Citado na página 131.
- BELL, E. *Generative AI vs. Large Language Models: What's the Difference?* 2023. Disponível em: <<https://appian.com/blog/acp/process-automation/generative-ai-vs-large-language-models.html>>. Acesso em: 07 jan. 2024. Citado 2 vezes nas páginas 44 e 45.
- BEZERRA, S. *Mundo BANI: o que é esse conceito?* 2021. Disponível em: <<https://www.startse.com/artigos/mundo-bani-o-que-e-esse-conceito/>>. Acesso em: 3 jul. 2022. Citado 2 vezes nas páginas 23 e 119.
- BLOOM, B. S. Recent developments in mastery learning. *Educational Psychologist*, Routledge, v. 10, p. 53–57, 3 1973. ISSN 0046-1520. Doi: 10.1080/00461527309529091. Disponível em: <<https://doi.org/10.1080/00461527309529091>>. Citado na página 29.

BLOOM, B. S. The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring. *Educational Researcher*, [American Educational Research Association, Sage Publications, Inc.], v. 13, n. 6, p. 4–16, 1984. ISSN 0013189X, 1935102X. Disponível em: <<http://www.jstor.org/stable/1175554>>. Acesso em: 03 jan. 2023. Citado 2 vezes nas páginas 30 e 57.

BOOTE, B.; AGARWAL, M.; MOSTOW, J. Early Prediction of Children’s Disengagement in a Tablet Tutor Using Visual Features. In: ROLL, I. et al. (Ed.). *Artificial Intelligence in Education*. Cham: Springer International Publishing, 2021. v. 12749, p. 98–103. ISBN 978-3-030-78269-6 978-3-030-78270-2. Series Title: Lecture Notes in Computer Science. Disponível em: <https://link.springer.com/10.1007/978-3-030-78270-2_17>. Acesso em: 05 fev. 2023. Citado na página 131.

BRASIL. *Parâmetros curriculares nacionais: matemática*. [S.l.], 1997. Citado na página 36.

BROWN, T. et al. Language models are few-shot learners. *Advances in neural information processing systems*, v. 33, p. 1877–1901, 2020. Citado na página 44.

CABADA, R. Z. et al. Hyperparameter optimization in CNN for learning-centered emotion recognition for intelligent tutoring systems. *Soft Computing*, v. 24, n. 10, p. 7593–7602, maio 2020. ISSN 1432-7643, 1433-7479. Disponível em: <<http://link.springer.com/10.1007/s00500-019-04387-4>>. Acesso em: 29 jan. 2023. Citado na página 131.

CAMPOS, M. *Pejotização: entenda o que é e como ela afeta o trabalho no Brasil*. Jusbrasil, 2023. Disponível em: <[Pejotizaãõ:entendaoqueãlecomoelaafetaotrabalhonoBrasil](https://www.jusbrasil.com.br/artigos/pejotizacao-entenda-o-que-e-e-como-ela-afeta-o-trabalho-no-brasil)>. Citado na página 24.

CARLE, E. *Ask a Techspert: What is generative AI?* 2023. Disponível em: <<https://blog.google/inside-google/googlers/ask-a-techspert/what-is-generative-ai/>>. Acesso em: 03 jan. 2024. Citado 3 vezes nas páginas 32, 42 e 44.

CASTELLS, E. *A sociedade em rede. A era da informação: economia, sociedade e cultura*. 9. ed. [S.l.]: Paz e Terra, 2003. v. 1. Citado na página 55.

CASTELLS, M. et al. *A sociedade em rede*. 24. ed. [S.l.]: Paz e Terra, 2008. Citado na página 25.

CASTNER, N. et al. LSTMs can distinguish dental expert saccade behavior with high "plaque-urracy". In: *2022 Symposium on Eye Tracking Research and Applications*. Seattle WA USA: ACM, 2022. p. 1–7. ISBN 978-1-4503-9252-5. Disponível em: <<https://dl.acm.org/doi/10.1145/3517031.3529631>>. Acesso em: 29 jan. 2023. Citado na página 131.

CHAN, K. I.; TSE, R.; LEI, P. I. Tracing Students Learning Performance on Multiple Skills using Bayesian Methods. In: *2022 6th International Conference on Education and Multimedia Technology*. Guangzhou China: ACM, 2022. p. 84–89. ISBN 978-1-4503-9645-5. Disponível em: <<https://dl.acm.org/doi/10.1145/3551708.3556202>>. Acesso em: 29 jan. 2023. Citado 2 vezes nas páginas 132 e 133.

- CHARNIAK, E.; MCDERMOTT, D. *Introduction to artificial intelligence*. Addison-Wesley, 1985. Disponível em: <<https://archive.org/details/introductiontoar0000char/mode/2up?q=mental+faculties>>. Acesso em: 14 mai. 2023. Citado na página 36.
- CHEN, X. et al. Application and theory gaps during the rise of Artificial Intelligence in Education. *Computers and Education: Artificial Intelligence*, v. 1, p. 100002, 2020. ISSN 2666920X. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S2666920X20300023>>. Acesso em: 29 jan. 2023. Citado 4 vezes nas páginas 124, 125, 126 e 137.
- CHEVALLARD, Y.; JOHSUA, M.-A. et al. *La transposition didactique: du savoir savant au savoir enseigné*. [S.l.]: La Pensée Sauvage,, 1985. Citado 3 vezes nas páginas 63, 65 e 66.
- COHEN, V. B. A reexamination of feedback in computer-based instruction: Implications for instructional design. *Educational Technology*, Educational Technology Publications, Inc., v. 25, n. 1, p. 33–37, 1985. ISSN 00131962. Disponível em: <<http://www.jstor.org/stable/44424353>>. Citado na página 58.
- COREA, F. Ai knowledge map: How to classify ai technologies. *Studies in Big Data*, p. 25–29, 11 2018. Citado 3 vezes nas páginas 38, 39 e 40.
- COUNCIL, N. R. *How People Learn*. National Academies Press, 2000. Disponível em: <<https://www.nap.edu/read/9853/chapter/13>>. Acesso em: 27 jan. 2024. Citado 2 vezes nas páginas 61 e 62.
- DELEUZE, G. *Diferença e repetição*. Rio de Janeiro: Graal, 1988. Citado na página 57.
- DICIO. *Proficiência*. Dicionário Online de Português, 2024. Disponível em: <<https://www.dicio.com.br/proficiencia/>>. Citado na página 92.
- DUPLESSIS, P. *Le triangle didactique (schéma) : les trois dimensions de la recherche didactique - Les Trois Couronnes - Didactique de l'Information Documentation - Pascal Duplessis*. 2008. Disponível em: <<http://lestroiscouronnes.esmeree.fr/outils/le-triangle-didactique-schema.html>>. Acesso em: 12 fev. 2023. Citado 3 vezes nas páginas 64, 66 e 67.
- DUPRE, F.; CHABANEL, L. *La transposition didactique : Caractérisation, Débats et Pratiques professionnelles*. 2019. 8 p. Acesso em: 12 fev. 2023. Citado 2 vezes nas páginas 64 e 65.
- ECONOMIST, T. *The world's most valuable resource is no longer oil, but data*. The Economist, 2017. Disponível em: <<https://www.economist.com/leaders/2017/05/06/the-worlds-most-valuable-resource-is-no-longer-oil-but-data>>. Acesso em: 3 jan. 2024. Citado na página 23.
- FENG, S.; MAGANA, A. J. The Effect of ElectronixTutor on Undergraduate Students Acquisition of Conceptual Learning, Problem Solving, and Model Building of Electronic Circuits. In: *2021 IEEE Frontiers in Education Conference (FIE)*. Lincoln, NE, USA: IEEE, 2021. p. 1–9. ISBN 978-1-66543-851-3. Disponível em: <<https://ieeexplore.ieee.org/document/9637314/>>. Acesso em: 29 jan. 2023. Citado na página 136.

FLUSSER, V. *Filosofia da caixa preta: ensaios para uma filosofia da fotografia*. Relume Dumará, 2005. ISBN 9788573162783. Disponível em: <https://books.google.com.br/books?id=p_iwjgEACAAJ>. Citado na página 28.

FORUM, W. E. *The Future of Jobs Report 2020*. [S.l.], 2020. Disponível em: <https://www3.weforum.org/docs/WEF_Future_of_Jobs_2020.pdf>. Acesso em: 3 jul. 2022. Citado 2 vezes nas páginas 24 e 119.

GAN, W.; SUN, Y.; SUN, Y. Knowledge structure enhanced graph representation learning model for attentive knowledge tracing. *International Journal of Intelligent Systems*, v. 37, n. 3, p. 2012–2045, mar. 2022. ISSN 0884-8173, 1098-111X. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1002/int.22763>>. Acesso em: 29 jan. 2023. Citado 2 vezes nas páginas 132 e 133.

GARONCE, F.; SANTOS, G. L. Transposição midiática: da sala de aula convencional para a presencial conectada. *Educação & Sociedade*, Centro de Estudos Educação e Sociedade - Cedes, v. 33, n. 121, p. 1003–1017, Oct 2012. ISSN 0101-7330. Disponível em: <<https://doi.org/10.1590/S0101-73302012000400005>>. Citado 2 vezes nas páginas 58 e 66.

GHOSH, A.; HEFFERNAN, N.; LAN, A. S. Context-Aware Attentive Knowledge Tracing. In: *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Virtual Event CA USA: ACM, 2020. p. 2330–2339. ISBN 978-1-4503-7998-4. Disponível em: <<https://dl.acm.org/doi/10.1145/3394486.3403282>>. Acesso em: 29 jan. 2023. Citado 2 vezes nas páginas 132 e 133.

GIL, A. *Métodos E Técnicas De Pesquisa Social*. ATLAS EDITORA, 2019. ISBN 9788597020571. Disponível em: <<https://books.google.com.br/books?id=rhB4wwEACAAJ>>. Citado na página 75.

GIL, A. C. *Como Elaborar Projetos de Pesquisa*. Grupo GEN, 2022. ISBN 9786559771653. Disponível em: <<https://integrada.minhabiblioteca.com.br/#/books/9786559771653>>. Acesso em: 17 jan. 2023. Citado na página 75.

GRAESSER, A. C.; HU, X.; SOTTILARE, R. Intelligent tutoring systems. In: *INTERNATIONAL HANDBOOK OF THE LEARNING SCIENCES*. [S.l.]: Routledge, 2018. (International Handbook of the Learning Sciences), p. 246 – 255. Citado 6 vezes nas páginas 29, 31, 50, 51, 86 e 94.

GUAN, C.; MOU, J.; JIANG, Z. Artificial intelligence innovation in education: A twenty-year data-driven historical analysis. *International Journal of Innovation Studies*, v. 4, n. 4, p. 134–147, dez. 2020. ISSN 20962487. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S2096248720300369>>. Acesso em: 29 jan. 2023. Citado 3 vezes nas páginas 124, 125 e 126.

GUAN, C.; MOU, J.; JIANG, Z. Artificial intelligence innovation in education: A twenty-year data-driven historical analysis. *International Journal of Innovation Studies*, v. 4, n. 4, p. 134–147, dez. 2020. ISSN 20962487. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S2096248720300369>>. Acesso em: 29 jan. 2023. Citado na página 137.

- GUIMARAES, P. O. *Lifelong Learning o aprendizado constante para ascensão profissional*. 2021. Disponível em: <<https://www.linkedin.com/pulse/lifelong-learning-o-aprendizado-constante-para-oliveira-guimarães/?originalSubdomain=pt>>. Acesso em: 3 jul. 2022. Citado 2 vezes nas páginas 24 e 119.
- HAUGELAND, J. *Artificial intelligence : the very idea*. 1. ed. Mit Press, 1985. Disponível em: <https://terrorgum.com/tfox/books/artificialintelligence_theveryidea.pdf>. Acesso em: 14 mai. 2023. Citado na página 36.
- HAYKIN, S. *Redes Neurais*. 2. ed. Bookman Editora, 2007. Disponível em: <<https://integrada.minhabiblioteca.com.br/#/books/9788577800865>>. Acesso em: 14 mai. 2023. Citado na página 37.
- HIPPEL, P. von. *Two-Sigma Tutoring: Separating Science Fiction from Science Fact*. 2024. Disponível em: <<https://www.educationnext.org/two-sigma-tutoring-separating-science-fiction-from-science-fact/>>. Citado na página 30.
- HOLMES, W. et al. *AI and education*. UNESCO Publishing, 2021. Disponível em: <https://unesdoc.unesco.org/notice?id=p::usmarcdef_0000376709>. Acesso em: 30 abr. 2023. Citado na página 35.
- HUANG, S. *Generative AI: A Creative New World*. 2022. Disponível em: <<https://www.sequoiacap.com/article/generative-ai-a-creative-new-world/>>. Acesso em: 05 jan. 2024. Citado na página 42.
- HUANG, S.; GRADY, P. *Generative AI's Act Two*. 2023. Disponível em: <<https://www.sequoiacap.com/article/generative-ai-act-two/>>. Acesso em: 06 jan. 2024. Citado 2 vezes nas páginas 42 e 43.
- IBM. *IA explicável*. 2019. Disponível em: <<https://www.ibm.com/br-pt/watson/explainable-ai>>. Acesso em: 29 abr. 2023. Citado na página 134.
- IBM. *O que é o Deep Learning? | IBM*. IBM, 2023. Disponível em: <<https://www.ibm.com/br-pt/topics/deep-learning>>. Acesso em: 04 jan. 2024. Citado 2 vezes nas páginas 40 e 41.
- JENSEN, J. F. ‘interactivity’: Tracking a new concept in media and communication studies. *Nordicom review*, Nordicom, University of Gothenburg, v. 19, n. 1, p. 185–204, 1998. Citado 2 vezes nas páginas 56 e 67.
- KASTRUP, V. Aprendizagem, arte e invenção. *Psicologia em Estudo*, Universidade Estadual de Maringá, v. 6, n. 1, p. 17–27, Jan 2001. ISSN 1413-7372. Disponível em: <<https://www.scielo.br/j/pe/a/NTNFsBzXts5GHp4Zk8sBbyF/>>. Citado na página 57.
- KAUFMAN, D. *Desmistificando a Inteligencia Artificial*. [s.n.], 2022. ISBN 9786559281596. Disponível em: <<https://integrada.minhabiblioteca.com.br/#/books/9786559281596/>>. Acesso em: 02 jan. 2023. Citado 4 vezes nas páginas 23, 24, 31 e 121.
- KHAYI, N. A.; RUS, V. Graph Convolutional Networks for Student Answers Assessment. In: SOJKA, P. et al. (Ed.). *Text, Speech, and Dialogue*. Cham: Springer International Publishing, 2020. v. 12284, p. 532–540. ISBN 978-3-030-58322-4

- 978-3-030-58323-1. Series Title: Lecture Notes in Computer Science. Disponível em: <https://link.springer.com/10.1007/978-3-030-58323-1_57>. Acesso em: 29 jan. 2023. Citado 2 vezes nas páginas 135 e 136.
- KOCHMAR, E. et al. Automated Data-Driven Generation of Personalized Pedagogical Interventions in Intelligent Tutoring Systems. *International Journal of Artificial Intelligence in Education*, v. 32, n. 2, p. 323–349, jun. 2022. ISSN 1560-4292, 1560-4306. Disponível em: <<https://link.springer.com/10.1007/s40593-021-00267-x>>. Acesso em: 29 jan. 2023. Citado na página 135.
- KRLEV, G. *How can we save the Mooc?* 2020. Disponível em: <<https://www.timeshighereducation.com/opinion/how-can-we-save-mooc>>. Acesso em: 30 abr. 2023. Citado na página 28.
- KULSHRESHTHA, D. et al. Few-Shot Question Generation for Personalized Feedback in Intelligent Tutoring Systems. In: PASSERINI, A.; SCHIEX, T. (Ed.). *Frontiers in Artificial Intelligence and Applications*. IOS Press, 2022. ISBN 978-1-64368-294-5 978-1-64368-295-2. Disponível em: <<https://ebooks.iospress.nl/doi/10.3233/FAIA220062>>. Acesso em: 29 jan. 2023. Citado na página 135.
- KURZWEIL, R. *The age of intelligent machines*. MIT, 1990. Disponível em: <<https://archive.org/details/ageofintelligent00kurz/page/n5/mode/2up?q=art>>. Acesso em: 14 fev. 2023. Citado na página 36.
- LEE, W. et al. Contrastive Learning for Knowledge Tracing. In: *Proceedings of the ACM Web Conference 2022*. Virtual Event, Lyon France: ACM, 2022. p. 2330–2338. ISBN 978-1-4503-9096-5. Disponível em: <<https://dl.acm.org/doi/10.1145/3485447.3512105>>. Acesso em: 29 jan. 2023. Citado 2 vezes nas páginas 132 e 133.
- LÉVY, P. *A inteligência coletiva: por uma antropologia do ciberespaço*. 4. ed. [S.l.]: Loyola, 2003. Citado na página 25.
- LI, H. Language models: past, present, and future. *Communications of the ACM*, ACM New York, NY, USA, v. 65, n. 7, p. 56–63, 2022. Citado na página 44.
- LORICA, B. *Maximizing the Potential of Large Language Models*. 2023. Disponível em: <<https://gradientflow.substack.com/p/maximizing-the-potential-of-large?ref=gptechblog.com>>. Acesso em: 04 jan. 2024. Citado na página 45.
- LU, Y. et al. Interpreting Deep Learning Models for Knowledge Tracing. *International Journal of Artificial Intelligence in Education*, jun. 2022. ISSN 1560-4292, 1560-4306. Disponível em: <<https://link.springer.com/10.1007/s40593-022-00297-z>>. Acesso em: 29 jan. 2023. Citado na página 133.
- LUGER, G. F. *Inteligência Artificial*. 6. ed. Pearson Education do Brasil, 2013. Disponível em: <<https://plataforma.bvirtual.com.br/Leitor/Publicacao/180430/epub/339?code=aW7/WruTVwiD1siPuAFHlb9BQUuvnZW+jgeJbc0ALhZyky5pPzZL99tccAN59vwQHyhZFo3a9k89eO2cLzIOLA==>>>. Acesso em: 14 mai. 2023. Citado na página 38.
- LUGER, G. F.; STUBBLEFIELD, W. A. *Artificial intelligence : structures and strategies for complex problem solving*. 2. ed. Benjamin/Cummings Pub. Co, 1993. Disponível em:

<<https://archive.org/details/artificialintell0000luge/page/n7/mode/2up>>. Acesso em: 14 mai. 2023. Citado na página 36.

10TH INTERNATIONAL CONFERENCE ON INTELLIGENT TUTORING SYSTEMS. *Intelligent Tutoring Technologies for Ill-Defined Problems and Ill-Defined Domains*, v. 4. 1-68 p. Disponível em: <https://publications.informatik.hu-berlin.de/archive/cses/publications/intelligent_tutoring_systems_for_ill-defined_domains.pdf>. Citado na página 69.

MARINESCU-MUSTER, R.; VRIES, S. de; VOLLENBROEK, W. Data-Driven Intelligent Tutoring System for Accelerating Practical Skills Development. A Deep Learning Approach. In: MEALHA, ; REHM, M.; REBEDEA, T. (Ed.). *Ludic, Co-design and Tools Supporting Smart Learning Ecosystems and Smart Education*. Singapore: Springer Singapore, 2021. v. 197, p. 197–209. ISBN 9789811573828 9789811573835. Series Title: Smart Innovation, Systems and Technologies. Disponível em: <http://link.springer.com/10.1007/978-981-15-7383-5_17>. Acesso em: 05 fev. 2023. Citado na página 134.

MARINHO, V. do C.; REPSOLD, M. *Educação (básica) a Distância: Possibilidades*. ABED, 2010. Disponível em: <<https://abed.org.br/congresso2010/cd/252010115238.pdf>>. Citado na página 26.

MARTINEAU, K. *What is generative AI?* IBM, 2023. Disponível em: <<https://research.ibm.com/blog/what-is-generative-ai>>. Acesso em: 04 jan. 2024. Citado 5 vezes nas páginas 40, 41, 42, 44 e 45.

MCCARTHY, J. *What is AI? / Basic Questions*. Stanford University, 2007. Disponível em: <<http://jmc.stanford.edu/artificial-intelligence/what-is-ai/index.html>>. Acesso em: 30 abr. 2023. Citado na página 36.

MCCARTHY, J. et al. *A proposal for the Dartmouth summer research project on Artificial Intelligence*. Stanford University, 1955. 1-13 p. Disponível em: <<http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf>>. Acesso em: 30 abr. 2023. Citado na página 36.

MEDEIROS, L. F. de. *Inteligência artificial aplicada: uma abordagem introdutória*. 1. ed. InterSaberes, 2018. 263 p. Disponível em: <<https://plataforma.bvirtual.com.br/Leitor/Publicacao/161682/epub/0?code=CUGHo2AMFIE+ede3S2ehSUzTTL2n6lowI0EA5Q0JBusfLCuVnkqBiMjxMgMI3xVHxR8JKWd2/jr65FTNzMeeuQ==>>>. Acesso em: 14 mai. 2023. Citado 2 vezes nas páginas 37 e 38.

MERRITT, R. *O que é um Modelo Transformer? | Blog da NVIDIA*. 2022. Disponível em: <<https://blog.nvidia.com.br/2022/04/19/o-que-e-um-modelo-transformer/>>. Acesso em: 04 jan. 2024. Citado na página 40.

MIKAMI, L. *A Janela de Contexto de 16K do ChatGPT: Será este o Avanço que Estávamos Esperando? – AI StartUps Product Information, Reviews, Latest Updates*. 2024. Disponível em: <<https://cheatsheet.md/pt/chatgpt-cheatsheet/chatgpt-context-window.pt>>. Citado na página 92.

MINAYO, M. de S.; DESLANDES, S.; GOMES, R. *Pesquisa social: Teoria, método e criatividade*. [S.l.]: Editora Vozes, 2011. (Temas sociais). ISBN 9788532642127. Citado na página 75.

MINN, S. AI-assisted knowledge assessment techniques for adaptive learning environments. *Computers and Education: Artificial Intelligence*, v. 3, p. 100050, 2022. ISSN 2666920X. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S2666920X22000054>>. Acesso em: 29 jan. 2023. Citado 2 vezes nas páginas 132 e 134.

MOLLICK, E. R.; MOLLICK, L. Assigning ai: Seven approaches for students, with prompts. *SSRN*, 01 2023. Disponível em: <https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4475995#>. Citado 9 vezes nas páginas 70, 71, 72, 73, 75, 79, 80, 87 e 97.

MORIN, E.; HEINEBERG, I. *O método 1: a natureza da natureza*. Sulina, 2002. ISBN 9788520503072. Disponível em: <<https://books.google.com.br/books?id=-FzLAAAACAAJ>>. Citado na página 28.

MOROSINI, M.; KOHLS-SANTOS, P.; BITTENCOURT, Z. *Estado do Conhecimento: teoria e prática*. [S.l.: s.n.], 2021. ISBN 9786558689911. Citado na página 121.

MUNHOZ, A. S. *MOOCS-Produção de conteúdos educacionais*. [S.l.]: Saraiva Educação SA, 2014. Citado 2 vezes nas páginas 26 e 27.

NKAMBOU, R.; MIZOGUCHI, R.; BOURDEAU, J. *Advances in Intelligent Tutoring Systems*. Springer Berlin Heidelberg, 2010. (Studies in Computational Intelligence). ISBN 9783642143625. Disponível em: <<https://books.google.com.br/books?id=Z90d-xsOAUEC>>. Citado na página 53.

NWANA, H. S. Intelligent tutoring systems - an overview. *Artificial Intelligence Review*, v. 4, p. 251–277, 1990. ISSN 0269-2821. Citado 4 vezes nas páginas 51, 52, 53 e 120.

ONLINE, F. *53 Important Statistics About How Much Data Is Created Every Day*. 2022. Acesso em: 3 jul. 2023. Citado na página 23.

OPENAI. *Teaching with AI*. 2023. Disponível em: <<https://openai.com/blog/teaching-with-ai>>. Citado 2 vezes nas páginas 68 e 70.

OPENAI. *Prompt engineering*. c2023. Disponível em: <<https://platform.openai.com/docs/guides/prompt-engineering/six-strategies-for-getting-better-results>>. Acesso em: 07 jan. 2024. Citado 5 vezes nas páginas 46, 47, 48, 80 e 81.

PAGANI, R. N.; KOVALESKI, J. L.; RESENDE, L. M. Methodi ordinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication. *Scientometrics*, Springer, v. 105, n. 3, p. 2109–2135, 2015. Acesso em: 17 jan. 2023. Citado na página 122.

PATEL, N. *O que são as inteligências artificiais generativas e como podem ser usadas?* 2023. Disponível em: <<https://neilpatel.com/br/blog/inteligencia-artificial-generativa/>>. Acesso em: 05 jan. 2024. Citado na página 41.

PERRENOUD, P. *Perrenoud - La transposition didactique à partir de pratiques : des savoirs aux compétences*. 1998. Disponível em: <https://www.unige.ch/fapse/SSE/teachers/perrenoud/php_main/php_1998/1998_26.html#Heading2>. Acesso em: 12 mar. 2023. Citado 3 vezes nas páginas 64, 65 e 67.

PERRENOUD, P. *Avaliação: da excelência a regulação das aprendizagens entre duas lógicas*. [S.l.]: Artmed, 1999. Citado 2 vezes nas páginas 57 e 77.

- PERROTTA, C.; SELWYN, N. Deep learning goes to school: toward a relational understanding of AI in education. *Learning, Media and Technology*, v. 45, n. 3, p. 251–269, jul. 2020. ISSN 1743-9884, 1743-9892. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/17439884.2020.1686017>>. Acesso em: 29 jan. 2023. Citado na página 134.
- RAY, P. P. Chatgpt: a comprehensive review on background, applications, key challenges, bias, ethics, limitations and future scope. *Internet of Things and Cyber-Physical Systems*, v. 3, p. 121–154, 04 2023. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S266734522300024X>>. Acesso em: 07 jan. 2024. Citado 2 vezes nas páginas 42 e 44.
- RICH, E.; KNIGHT, K. *Artificial intelligence*. McGraw-Hill, 1991. Disponível em: <<https://archive.org/details/artificialintell0000rich>>. Acesso em: 14 mai. 2023. Citado na página 36.
- RUSSELL, S. *Introduction to AI: A Modern Approach*. c2023. Disponível em: <<http://people.eecs.berkeley.edu/~russell/intro.html>>. Acesso em: 14 mai. 2023. Citado na página 37.
- RUSSELL, S. J.; NORVIG, P. *Inteligência Artificial: Uma Abordagem Moderna*. 4. ed. Grupo GEN, 2022. Disponível em: <<https://integrada.minhabiblioteca.com.br/#/books/9788595159495/>>. Acesso em: 30 abr. 2023. Citado 4 vezes nas páginas 36, 37, 40 e 41.
- SANCHEZ, G. L. *Jerry Kaplan: Los robots no van a levantarse contra nosotros, son meras herramientas*. ABC.es, 2017. Disponível em: <https://www.abc.es/cultura/cultural/abci-jerry-kaplan-robots-no-levantarse-contra-nosotros-meras-herramientas-201705210059_noticia.html>. Citado na página 100.
- SANTOS, G. L. Educação, tecnologias e inovação pedagógica: em busca do interativismo colaborativo. *Revista da FAEEBA - Educação e Contemporaneidade*, v. 30, p. 226–240, 11 2021. Disponível em: <<https://www.revistas.uneb.br/index.php/faeeba/article/view/11741>>. Acesso em: 22 abr. 2023. Citado 3 vezes nas páginas 55, 56 e 96.
- SANTOS, G. L.; ANDRADE, J. de. *Virtualizando a escola: migrações docentes rumo à sala de aula virtual*. Ed. Liber Livro, 2010. ISBN 9788579630286. Disponível em: <<https://books.google.com.br/books?id=g4cGaAEACAAJ>>. Citado 2 vezes nas páginas 25 e 55.
- SCHALKOFF, R. J. *Artificial Intelligence: an engineering approach*. McGraw-Hill Companies, 1990. Disponível em: <<https://archive.org/details/artificialintell00scha/page/2/mode/2up?q=field>>. Acesso em: 14 mai. 2023. Citado na página 36.
- SENAI. *Tendências em Inteligência Artificial na educação no período de 2017 a 2030*. SENAI, 2018. 58 p. Disponível em: <https://static.portaldaindustria.com.br/media/filer_public/3a/60/3a606b84-69a1-41e2-9a58-ac07ce725ee1/sumario_tendencias_web.pdf>. Acesso em: 15 mai. 2023. Citado 2 vezes nas páginas 48 e 49.
- SENAI. *Indústria 4.0: Entenda seus conceitos e fundamentos*. 2021. Acesso em: 01 jan. 2023. Citado 2 vezes nas páginas 23 e 119.

- SENDPULSE. *Tutor IA Expert*. 2024. Disponível em: <<https://login.sendpulse.com/messengers/bots/telegram/6653cd589dc0e074740829b8/triggers/6653cd599dc0e074740829bf/>>. Citado na página 83.
- SERBAN, I. V. et al. A Large-Scale, Open-Domain, Mixed-Interface Dialogue-Based ITS for STEM. In: BITTENCOURT, I. I. et al. (Ed.). *Artificial Intelligence in Education*. Cham: Springer International Publishing, 2020. v. 12164, p. 387–392. ISBN 978-3-030-52239-1 978-3-030-52240-7. Series Title: Lecture Notes in Computer Science. Disponível em: <http://link.springer.com/10.1007/978-3-030-52240-7_70>. Acesso em: 05 fev. 2023. Citado na página 135.
- SHUTE, V. J. Focus on formative feedback. *Review of Educational Research*, v. 78, n. 1, p. 153–189, 2008. Disponível em: <<https://doi.org/10.3102/0034654307313795>>. Citado 6 vezes nas páginas 58, 59, 60, 61, 62 e 91.
- SKINNER, E. A.; BELMONT, M. J. Motivation in the classroom: Reciprocal effects of teacher behavior and student engagement across the school year. *Journal of Educational Psychology*, v. 85, p. 571–581, 1993. Disponível em: <http://selfdeterminationtheory.org/SDT/documents/1993_SkinnerBelmont_JEP.pdf>. Citado na página 57.
- SONG, X. et al. A survey on deep learning based knowledge tracing. *Knowledge-Based Systems*, v. 258, p. 110036, dez. 2022. ISSN 09507051. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0950705122011297>>. Acesso em: 29 jan. 2023. Citado 2 vezes nas páginas 132 e 133.
- SONG, X. et al. Bi-CLKT: Bi-Graph Contrastive Learning based Knowledge Tracing. *Knowledge-Based Systems*, v. 241, p. 108274, abr. 2022. ISSN 09507051. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0950705122000880>>. Acesso em: 29 jan. 2023. Citado na página 132.
- SONG, X. et al. Bi-CLKT: Bi-Graph Contrastive Learning based Knowledge Tracing. *Knowledge-Based Systems*, v. 241, p. 108274, abr. 2022. ISSN 09507051. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0950705122000880>>. Acesso em: 29 jan. 2023. Citado na página 133.
- SONG, X. et al. JKT: A joint graph convolutional network based Deep Knowledge Tracing. *Information Sciences*, v. 580, p. 510–523, nov. 2021. ISSN 00200255. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0020025521009142>>. Acesso em: 29 jan. 2023. Citado 2 vezes nas páginas 132 e 133.
- TELEGRAM. *Telegram Web*. 2024. Disponível em: <<https://web.telegram.org/k/#@BotFather>>. Citado na página 83.
- TORI, R. A presença das tecnologias interativas na educação. *Revista de Computação e Tecnologia (ReCeT)*. ISSN 2176-7998, v. 2, n. 1, p. 4–16, 2010. Citado 2 vezes nas páginas 56 e 67.
- TRENDS, G. *Google Trends*. 2024. Disponível em: <<https://trends.google.com.br/trends/explore?date=today%203-m&q=ChatGPT,Bard,Bing%20chat,Claude,Perplexity&hl=pt>>. Acesso em: 07 jan. 2024. Citado na página 46.

TRENTIM, M. H. *Descubra o que é Prompt Engineering e como dominar essa técnica para ser mais produtivo e eficiente*. 2023. Disponível em: <<https://www.linkedin.com/pulse/revolu%C3%A7%C3%A3o-do-prompting-engineering-tudo-que-um-gerente-trentim/>>. Acesso em: 29 out. 2023. Citado na página 75.

TRIGGO.AI. *O que é GenAI?* 2023. Disponível em: <<https://triggo.ai/blog/o-que-e-genai/>>. Acesso em: 07 jan. 2024. Citado na página 45.

TROUSSAS, C.; VIRVOU, M. Intelligent, adaptive and social e-learning in polyglot. In: *ADVANCES IN SOCIAL NETWORKING-BASED LEARNING: MACHINE LEARNING-BASED USER MODELLING AND SENTIMENT ANALYSIS*. Springer, 2020. (Advances in Social Networking-based Learning: Machine Learning-based User Modelling and Sentiment Analysis), p. 33 – 55. Disponível em: <<https://doi.org/10.1007/978-3-030-39130-0>>. Acesso em: 16 mai. 2023. Citado na página 50.

UNIDAS, N. *Sustainable Development Goal 4: Educação de qualidade / As Nações Unidas no Brasil*. 2015. Disponível em: <<https://brasil.un.org/pt-br/sdgs/4>>. Acesso em: 30 abr. 2023. Citado na página 35.

UNIVERSIA. *Entenda a diferença entre xMOOCs e cMOOCs*. 2013. Disponível em: <<https://www.universia.net/br/actualidad/orientacion-academica/entenda-diferenca-entre-xmoocs-e-cmoocs-1049157.html>>. Citado na página 27.

VALENTE, L. *ChatGPT, a inteligência artificial como você nunca viu, é a próxima revolução / McKinsey*. 2023. Disponível em: <<https://www.mckinsey.com.br/our-insights/all-insights/chatgpt-e-a-revolucao-da-inteligencia-artificial>>. Acesso em: 03 jan. 2024. Citado na página 31.

VASIĆ, D. et al. Croatian POS Tagger as a Prerequisite for Knowledge Extraction in Intelligent Tutoring Systems. In: SOTTILARE, R. A.; SCHWARZ, J. (Ed.). *Adaptive Instructional Systems. Design and Evaluation*. Cham: Springer International Publishing, 2021. v. 12792, p. 334–345. ISBN 978-3-030-77856-9 978-3-030-77857-6. Series Title: Lecture Notes in Computer Science. Disponível em: <https://link.springer.com/10.1007/978-3-030-77857-6_23>. Acesso em: 29 jan. 2023. Citado na página 136.

VENUGOPAL, D.; RUS, V.; SHAKYA, A. Neuro-Symbolic Models: A Scalable, Explainable Framework for Strategy Discovery from Big Edu-Data. In: PRICE, T. W.; PEDRO, S. S. (Ed.). *Joint Proceedings of the Workshops at the International Conference on Educational Data Mining 2021 co-located with 14th International Conference on Educational Data Mining (EDM 2021), Held Virtually, 2021*. CEUR-WS.org, 2021. (CEUR Workshop Proceedings, v. 3051). Disponível em: <http://ceur-ws.org/Vol-3051/LDI_4.pdf>. Citado na página 136.

VIRVOU, M.; TSIHRINTZIS, G. A. Is chatgpt beneficial to education? a holistic evaluation framework based on intelligent tutoring systems. In: *2023 14th International Conference on Information, Intelligence, Systems Applications (IISA)*. [S.l.: s.n.], 2023. p. 1–8. Citado 4 vezes nas páginas 68, 69, 88 e 92.

WANG, B.; YANG, M. Y.; GROSSMAN, T. Soloist: Generating Mixed-Initiative Tutorials from Existing Guitar Instructional Videos Through Audio Processing. In:

Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems. Yokohama Japan: ACM, 2021. p. 1–14. ISBN 978-1-4503-8096-6. Disponível em: <<https://dl.acm.org/doi/10.1145/3411764.3445162>>. Acesso em: 29 jan. 2023. Citado na página 134.

WANG, F. H. A Feasible Study of a Deep Learning Model Supporting Human-Machine Collaborative Learning of Object-Oriented Programming. *IEEE Transactions on Learning Technologies*, p. 1–15, 2022. ISSN 1939-1382, 2372-0050. Disponível em: <<https://ieeexplore.ieee.org/document/9969126/>>. Acesso em: 29 jan. 2023. Citado na página 136.

WENGER, E. *Artificial Intelligence and Education*. [S.l.]: Morgan Kaufmann, Los Altos, 1987. Citado 2 vezes nas páginas 30 e 120.

WINSTON, P. H. *Artificial intelligence*. Addison-Wesley Pub. Co, 1992. Disponível em: <<https://courses.csail.mit.edu/6.034f/ai3/rest.pdf>>. Acesso em: 14 mai. 2023. Citado na página 36.

WOOLF, B. P. *Building intelligent interactive tutors : student-centered strategies for revolutionizing e-learning*. [S.l.]: Morgan Kaufmann Publishers/Elsevier, 2009. Citado 10 vezes nas páginas 30, 50, 51, 52, 53, 68, 69, 72, 88 e 137.

ZHU, X.; WU, H.; ZHANG, L. Automatic Short-Answer Grading via BERT-Based Deep Neural Networks. *IEEE Transactions on Learning Technologies*, v. 15, n. 3, p. 364–375, jun. 2022. ISSN 1939-1382, 2372-0050. Disponível em: <<https://ieeexplore.ieee.org/document/9779091/>>. Acesso em: 29 jan. 2023. Citado na página 136.

ZWINGMANN, T. *Demystifying AI: A Practical Guide to Key Terminology*. 2023. Disponível em: <<https://ai4bi.beehiiv.com/p/demystifying-ai-practical-guide-key-terminology?ref=gptechblog.com>>. Acesso em: 07 jan. 2024. Citado na página 45.

Apêndices

APÊNDICE A – O uso de *deep learning* em Sistemas Tutores Inteligentes: uma análise do estado da arte no período entre 2018 a 2022

Resumo

O uso da tecnologia de Inteligência Artificial (IA) pode auxiliar o docente na personalização do ensino e, conseqüentemente, ajudar estudantes no processo de aprendizagem. Tecnologias com base em IA estão apoiando a educação estão sendo aprimoradas para obter maior assertividade do modelo desenvolvido. Uma delas são os *Intelligent Tutoring Systems* (ITS). Os avanços em IA gerados na última década provêm do *deep learning*, técnica de *machine learning*. Foi realizado um estado da arte, no período entre 2018 a 2022, para análise de como os ITSs estão evoluindo para aumentar a personalização e obter melhores resultados de aprendizagem com o *deep learning*. Para isto, utilizou-se uma revisão sistemática de literatura por meio de um método quantitativo chamado *Methodi Ordinatio*. As pesquisas apresentam preocupações quanto a assertividade do modelo proposto. O *Knowledge Tracing* é a tecnologia mais presente e discutida. Alguns estudos carecem de aplicações in loco e estudos longitudinais. Verificou-se aplicações na educação infantil, básica, profissional e superior. No entanto, estão no nível cognitivo, com apenas uma aplicação para desenvolvimento de habilidades práticas. Evidencia-se nos artigos a citação, fundamentação teórica e aplicações considerando autores e teorias educacionais. As publicações relativas a IA na educação estão ligadas a ciência da computação.

Palavras-chaves: Inteligência Artificial. Sistemas Tutores Inteligentes. Processo de Ensino-Aprendizagem.

Abstract

The use of Artificial Intelligence (AI) technology can assist faculty in personalizing instruction and consequently help students in the learning process. AI-based technologies supporting education are being improved to achieve greater assertiveness of the developed model. One of these is Intelligent Tutoring Systems (ITS). The advances in AI generated in the last decade come from deep learning, a machine learning technique. A state of the art was conducted, in the period from 2018 to 2022, to analyze how ITSs are evolving to increase personalization and obtain better learning results with deep learning. This was done using a systematic literature review through a quantitative method called *Methodi Ordinatio*. The research presents concerns about the assertiveness of the proposed model. Knowledge Tracing is the most present and most discussed technology. Some studies lack in loco applications and longitudinal studies. There have been applications in early childhood, basic, professional, and higher education. However, they are at the cognitive level, with only one application to develop practical skills. The articles highlight the citation, theoretical foundation and applications considering authors and educational theories. Publications related to AI in education are linked to computer science.

Key-words: Artificial Intelligence. Intelligent Tutoring Systems. Learning. Teaching.

Introdução

A sociedade vive o Mundo BANI, termo cunhado em 2018 pelo antropólogo norte-americano Jamais Cascio, cujo significado em inglês é *Brittle, Anxious, Nonlinear, Incomprehensible*, em português seria frágil, ansioso, não linear e incompreensível. Frágil, pois o que se tem hoje é incerto para o amanhã. Ansioso, pois o senso de urgência acelera a tomada de decisões. Não linear, pois o mundo está em constante mudança. Por fim, incompreensível, pois buscam-se respostas para tudo, mas novas informações são geradas a todo o momento, dificultando a compreensão da realidade (BEZERRA, 2021).

O mundo também vive a Quarta Revolução Industrial ou Indústria 4.0, que “engloba um amplo sistema de tecnologias avançadas como inteligência artificial, robótica, *internet* das coisas e computação em nuvem que estão mudando as formas de produção e os modelos de negócios no Brasil e no mundo” (SENAI, 2021).

Diante desse cenário, o Fórum Econômico Mundial, no relatório *The Future of Jobs*, relata que até 2025, 44% das habilidades que os trabalhadores precisarão para desempenhar suas funções de forma eficaz irão mudar. (FORUM, 2020). Assim, serão necessárias a qualificação e a requalificação de profissionais para atuarem nessas novas funções, principalmente pela adoção de novas tecnologias.

Por mais que as empresas desejam aumentar em até 11% a oferta de qualificação e requalificação de funcionários até 2025, apenas 42% aproveitam as oportunidades oferecidas pelo empregador (FORUM, 2020). No relatório, 94% dos empregadores desejam que seus empregados desenvolvam novas habilidades (GUIMARAES, 2021).

Devido ao rápido avanço da tecnologia, o crescimento exponencial da informação na *web* e a mudança da sociedade, fará com que os seres humanos estejam sempre aprendendo e se atualizado, corroborado pelo relatório *The Future of Jobs*, do *World Economic Forum*, onde elenca as habilidades de aprendizagem ativa e estratégias de aprendizado como uma das essenciais até 2025. O *lifelong learning* ou, o aprendizado ao longo da vida, é evocado e necessário em um mundo BANI.

Ainda com efeitos, a Pandemia do SARS COVID-19 também acelerou o processo de transformação digital da sociedade. Devido ao isolamento social, muitas atividades antes realizadas de forma física passaram a ser realizadas de forma virtual e não foi diferente na educação. A educação a distância ganhou espaço e rompeu barreiras neste período.

Segundo dados do Censo da Educação Superior de 2021, o número de vagas em cursos de graduação presencial reduziu em 28% em comparação a 2019, último ano antes da pandemia do SARS COVID-19. Já a Educação a Distância (EaD) cresceu na rede privada de ensino, passando de 24,3%, em 2018, para 41,4%, em 2021. O crescimento também se deve à expansão da rede nos últimos 10 anos analisados pelo Censo (ANDRADE, 2022).

O crescimento da educação a distância durante a pandemia, a incorporação de tecnologias nos processos educacionais, o aumento do acesso a *web* e o vertiginoso crescimento da informação disponível na *internet*, permite concluir que esta modalidade de educação estará cada vez mais ganhando importância devido a característica de alcance em escala, menor custo para realização, acesso a qualquer tempo e lugar devido ao uso intensivo de Tecnologias da Informação e Comunicação (TIC). Inclusive ganhará espaço como meio para atividades de ensino presencial.

No entanto, o excesso e a velocidade da informação geram sobrecarga cognitiva e dificulta o processo de aprendizagem. Diante da quantidade de informação, é necessário aumentar a efetividade da aprendizagem e engajar os estudantes por meio da personalização e práticas pedagógicas eficientes. Entende-se por personalização, o uso de estratégias, métodos, técnicas e tecnologias que vão de encontro as necessidades de cada estudante. Contudo, isto já é um desafio em classes presenciais, na EaD o desafio se torna ainda mais complexo.

O uso da tecnologia de Inteligência Artificial (IA) pode auxiliar o docente na personalização do ensino e, conseqüentemente, ajudar estudantes no processo de aprendizagem. Tecnologias com base em IA estão apoiando a educação e pesquisas têm sido realizadas com vistas a aprimorá-las e obter maior assertividade do modelo preditivo desenvolvido. Uma das tecnologias de IA aplicadas a educação são os *Intelligent Tutoring Systems* (ITS) ou Sistemas Tutores Inteligentes (STI), em português.

Os STIs são “sistemas de instrução baseados em computador com modelos de conteúdo instrucional que especificam o que ensinar e estratégias de ensino que especificam como ensinar” (WENGER, 1987, tradução nossa). “Tentam imitar a tutoria humana personalizada num ambiente baseado em computador e são uma alternativa de baixo custo para tutores humanos” (ANDERSON; BOYLE; REISER, 1985, tradução nossa). A arquitetura básica de um STI é composta pelos módulos:

- Especialista, que contém o conhecimento de um especialista em um domínio do conhecimento.
- Aluno, que inclui “todos os aspectos comportamentais e de conhecimento do aluno que possam gerar repercussões em sua performance e aprendizado” (NWANA, 1990, p.10, tradução nossa).
- Tutor, que contém as estratégias de ensino.
- Interface do usuário, que é onde há o controle da interação entre o aluno e o sistema. É onde as informações são apresentadas para o usuário (NWANA, 1990).

Os avanços gerados “na última década provêm do modelo chamado de *deep learning* [...], técnica de *machine learning* [...], subárea da inteligência artificial, que consiste em técnicas estatísticas que permitem que as máquinas “aprendam” com os dados” sem a necessidade de programação (KAUFMAN, 2022, p.11).

Assim, surge a problemática: Como as pesquisas em STIs utilizando a tecnologia *deep learning* estão evoluindo para aumentar a personalização e obter melhores resultados de aprendizagem? Nesse sentido, foi realizado um estado da arte sobre aplicação da tecnologia *deep learning* em STIs, no período de 2018 a 2022, para buscar respostas às seguintes perguntas:

- Pergunta 1: Quais são os países, revistas e áreas em que mais se publicou?
- Pergunta 2: Quais são os autores que mais publicam e mais citados?
- Pergunta 3: Quais tecnologias de *deep learning* foram utilizadas?
- Pergunta 4: Quais são as aplicações trazidos pelos artigos?
- Pergunta 5: Há medição de efetividade da aplicação da tecnologia?
- Pergunta 6: Há evidência de embasamento em teorias educacionais?

Metodologia e conjunto de dados

Foi realizado um estado da arte ou estado do conhecimento por meio de uma revisão sistemática de literatura utilizando um método quantitativo chamado *Methodi Ordinatio*. O termo estado do conhecimento tem nomenclaturas diferentes dependendo da área que realiza, segundo Morosini, Kohls-Santos e Bittencourt (2021, p.23). Os autores colocam para a área de humanidades o termo estado do conhecimento, cujo significado é “identificação, registro, categorização que levem à reflexão e síntese sobre a produção científica de uma determinada área, em um determinado espaço de tempo, congregando periódicos, teses, dissertações e livros sobre uma temática específica”.

Methodi Ordinatio para revisão sistemática

Para realização da revisão sistemática, será utilizado o *Methodi Ordinatio*, publicado no artigo *Methodi Ordinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication* elaborado com vistas a apoiar pesquisadores na seleção de material bibliográfico mais relevante em um cenário de aumento de publicações científicas e periódicos realizados nos últimos anos. Este aumento se deve as novas tecnologias que possibilitam novas formas de investigação científica e a necessidade de produção de conhecimento demandado pelo

mercado (PAGANI; KOVALESKI; RESENDE, 2015). Para isso, utilizam-se de métodos bibliométricos como o ProKnow-C, adaptado para seleção de artigos científicos, e InOrdinatio, para classificação de acordo com a relevância do documento. (PAGANI; KOVALESKI; RESENDE, 2015).

A metodologia propõe uma equação para ranqueamento das publicações científicas com base na sua relevância científica, o *Index Ordinatio* (InOrdinatio) (PAGANI; KOVALESKI; RESENDE, 2015). Segundo os autores, os critérios para ranqueamento dos artigos científicos, que são realizados antes análise sistemática, consideram:

- O fator de impacto do periódico em que o artigo foi publicado.
- O número de citações.
- O ano de publicação.

O método contém 9 etapas, conforme descrito por Pagani, Kovaleski e Resende (2015):

- Etapa 1: O pesquisador deverá ter um problema de pesquisa ou, pelo menos, ter uma intenção de pesquisa.
- Etapa 2: Deverá ser realizado a busca nas bases de pesquisa com algumas palavras-chaves definidas com base no problema de pesquisa. Durante este processo é necessário verificar se há palavras que estão ficando de fora. Caso haja, é necessário realizar novas buscas. É um processo de vai e volta. A mesma pesquisa em um base deverá ser realizada em uma outra, de forma que se tenham os mesmos parâmetros de pesquisa.
- Etapa 3: Definição das palavras-chaves que comporão o corpus da pesquisa.
- Etapa 4: Pesquisa nas bases com as palavras definidas na Etapa 3. As referências deverão ser exportadas para um gerenciador de referências e comporá a bibliografia bruta do projeto.
- Etapa 5: Nesta etapa, é realizada a filtragem inicial da referência com vistas a reduzir dados duplicados e referências que não fazem parte do objetivo da pesquisa. A filtragem é realizada por meio da análise de palavras-chaves, títulos e resumo.
- Etapa 6: É realizada a identificação do fator de impacto, número de citações e ano de publicação. No entanto, os autores mencionam que citações são maiores para artigos gratuitos, publicações mais recentes não possuem alto número de citações e que há artigos com alto número de citações mas sem fator de impacto. Neste sentido, eles recomendam “[...] a análise de três aspectos principais: relevância do periódico,

avaliada pelo fator de impacto; o reconhecimento científico do artigo, avaliado pelo número de citações; quão recente é o artigo, avaliando o ano de publicação” [tradução nossa].

- Etapa 7: Deverá ser calculado o *Index Ordinatio*, classificar numericamente as referências de acordo com o valor encontrado e selecionar a quantidade de documentos que comporão a revisão sistemática. Para o cálculo deverá ser utilizada a fórmula A.1 proposta pelos autores:

$$InOrdinatio = \frac{IF}{1000} + \alpha \cdot [10 - (ResearchYear - PublishYear)] + (\sum Ci) \quad (A.1)$$

Onde:

- O IF é o fator de impacto.
- Alpha é “o valor a ser atribuído pelo pesquisador e pode variar de 1 a 10. Quanto mais próximo o número estiver de um, menor será a importância que o pesquisador atribuirá ao critério ano [...]”.
- *ResearchYear* é o ano em que foi realizada a pesquisa.
- *PublishYear* é o ano em que foi publicado o artigo.
- Etapa 8: Encontrar o arquivo dos artigos selecionados.
- Etapa 9: Realizar análise sistemática dos artigos selecionados na Etapa 8.

Coleta e tratamento de dados

Foi realizada pesquisa bibliográfica nas bases *Web of Science* e Scopus, considerando:

- Pesquisas realizadas entre os anos de 2012 a 2022.
- Uso do operador booleano OR.
- Para a base Scopus: Buscas no título, resumo e palavras-chaves. Para a base *Web of Science*, foram consideradas todas as bases congregadas a plataforma, com busca realizada por tópico (título, resumos e indexadores).
- Conjunto de palavras-chaves delimitadas por aspas (“”) para pesquisa do termo completo.
- Linha de comando para busca e palavras-chaves, conforme Tabela 1.

Foram retornados 112 artigos pela WoS e 425 artigos pela Scopus. Desse total, 103 artigos estavam duplicados. A retirada de artigos repetidos foi realizada utilizando

Tabela 19 – Palavras-chaves pesquisadas

Palavras-chaves
Intelligent tutoring systems
Intelligent Computer-Assisted Instruction
Intelligent Computer-Aided Instruction
Artificial Intelligence in Education
Adaptive educational system
Adaptive learning systems
Constraint-based tutors
Cognitive Tutor
AutoTutor
SQL-tutor
assistments
elm-art
iweaver
DeepTutor
Coh-Metrix
Electronix Tutor
Student modeling
Knowledge Tracing

Fonte: Elaboração própria

o software estatístico R com a biblioteca Bibliometrix. Além disso, por meio do *Digital Object Identifier* (DOI), foram recuperados os documentos digitais por meio da ferramenta Zotero.

Após, foi realizada a análise dos títulos, resumos e palavras chaves dos 434 artigos restantes, onde foram selecionados todos os que possuíam contexto educacional. Nessa etapa, uma das dificuldades encontradas foi que nas aplicações de *deep learning* há os termos “modelo de aluno”, “modelo de professor” e “aprendizado” que fazem parte das técnicas e da tecnologia, mas não são aplicações no setor educacional. Quanto ao termo “aprendizado”, os modelos de IA precisam “aprender” e não possuem correlação com educação. Com isto, 198 foram excluídos, ficando 236 artigos voltados à área educacional.

Os 3 primeiros documentos com maior *InOrdinatio*, 2 eram revisões sistemáticas de literatura no período compreendido entre 1999 e 2019, de Chen et al. (2020), e 2000 a 2019, de Guan, Mou e Jiang (2020a), em periódicos amplamente reconhecidos, com objetivos parecidos de identificar o atual estado de desenvolvimento, tecnologias utilizadas e tendências para o uso de inteligência artificial na educação.

Devido a essas revisões sistemáticas, contemplando o período de recorte deste trabalho, foi realizado o filtro de artigos publicados entre 2020 a 2022. Após, ao realizar a leitura dos primeiros artigos com maior *InOrdinatio*, foi verificado que os STIs eram citados, mas não eram o assunto principal do artigo. Assim, foi realizado a filtragem

dos artigos que continham a palavra-chave “*tutoring*”, de *Intelligent Tutoring Systems*. Excluindo 2 artigos com restrição de acesso, totalizou 28 artigos restantes para análise, classificados pelo *InOrdinatio*.

Análise das revisões sistemáticas de literatura entre 1999 a 2019

O artigo de Chen et al. (2020), apresenta uma revisão sistemática de 45 artigos com alto nível de citações (mais de 20) publicados em periódicos amplamente reconhecidos, como na *Computers & Education*, *Educational Technology Society*, *Interactive Learning Environments*, *British Journal of Educational Technology*, *Educational Technology Research and Development*, and *Journal of Computer Assisted Learning*, entre 1999 a 2019, com objetivo de identificar o atual estado de desenvolvimento, tecnologias utilizadas e tendências para o uso de IA na educação.

Já Guan, Mou e Jiang (2020a), realizaram uma análise de 400 artigos de pesquisa sobre a aplicação de técnicas de IA e *deep learning* no ensino e aprendizagem, no período de 2000 a 2019, nas principais revistas educacionais, *Association for Computing Machinery (ACM)*, *EBSCO*, *Emerald*, *IEEE*, *JSTOR*, *ScienceDirect*, *Taylor & Francis*, *Wiley* e também recuperados no *Google Scholar*, com o objetivo de identificar a evolução da pesquisa no campo da AI na educação.

Chen et al. (2020), concluíram que as técnicas de *machine learning* são predominantes, enquanto as técnicas de técnicas de *deep learning* ainda são pouco utilizadas na educação. Em relação as aplicações de IA, estão no âmbito de aplicação da tecnologia em contextos de educação *online* e poucos em contextos de sala de aula. A sugestão dos autores é que se pesquise o potencial da IA nestes ambientes. Em relação a aplicação específica do *deep learning*, os autores sugerem uma série de tecnologias para o contexto educacional:

- Redes neurais profundas: A identificação e modelagem dos estados afetivos dos alunos e avaliação de aprendizagem em games.
- Reconhecimento facial: Identificação da presença e atenção dos estudantes.
- *Long short-term memory* (LSTM), em português, Redes neurais de memória de longo prazo: Compreensão da leitura por parte dos estudantes, análise do comportamento, previsão de evasão e persistência acadêmica.
- Redes neurais convolucionais: Facilitar a classificação das tarefas.
- Redes neurais recorrentes: Melhorar a previsão da qualidade da pergunta.
- Redes neurais recursivas: Previsão de persistência acadêmica.

- Redes adversárias generativas: Previsão de desempenho dos alunos.

Chen et al. (2020) colocam também questões de privacidade e uso ético de dados que devem ser consideradas nas pesquisas, pois técnicas de IA utilizam grande volume de dados.

Enquanto Guan, Mou e Jiang (2020a), concluíram que os resultados gerais indicaram que os esforços de pesquisa têm se concentrado predominantemente na aprendizagem. No entanto, a maioria dos artigos mais citados adotaram uma abordagem centrada na tecnologia, com maior ênfase no uso de tecnologias para resolver problemas pedagógicos específicos, como agentes educacionais e aprendizagem personalizada (GUAN; MOU; JIANG, 2020a). As pesquisas publicadas entre 2000 e 2009 se concentraram mais no desenvolvimento de todo o ambiente educacional de IA e aumentou o interesse na abordagem educacional orientada ao aluno (GUAN; MOU; JIANG, 2020a). Por outro lado, entre os anos de 2010 e 2019, se concentrou mais nos resultados da aprendizagem por meio da IA, tais como: perfil do aluno, previsão de desempenho acadêmico e análise de aprendizado (GUAN; MOU; JIANG, 2020a).

Fazendo um recorte no contexto de aplicação e objetivo deste artigo, a pesquisa em STIs concentrou-se em duas questões pedagógicas: fornecer uma orientação instrucional superior ao alcançado com sistemas convencionais assistido por computador e avançar nos modelos existentes sobre os processos intelectuais associados ao ensino e aprendizagem (GUAN; MOU; JIANG, 2020a). Devido a técnicas de IA, os STIs passaram a ter capacidade cognitiva. Com base em suas funcionalidades, os STIs atuaram na: curadoria de conteúdo do curso, monitoramento do desempenho do aluno e realização de *feedback* para estudante (GUAN; MOU; JIANG, 2020a). Tanto Guan, Mou e Jiang (2020a) e Chen et al. (2020) comentam que falta ou há necessidade de incorporar as teorias educacionais na aplicação de IA no setor. No entanto, contesta-se tal informação, pois considerar teorias educacionais é uma condição *sine qua non* para o desenvolvimento desses sistemas. Chen et al. (2020), informam que as publicações relativas à IA na Educação estão ligadas à ciência da computação.

Análise bibliométrica

A análise bibliométrica busca responder as perguntas 1 e 2, a seguir: Quais são os países, revistas e áreas em que mais se publicou? Quais são os autores que mais publicam e mais citados?

A produção científica anual tem crescido a partir de 2019, alcançando o pico de publicações em 2021 e decréscimo em 2022, conforme visto na Figura 21. A China e os Estados Unidos lideram as pesquisas de aplicação de *deep learning* em STIs, como visto

Tabela 20 – Países e suas produções científicas

Países com mais produções científicas	Número de produções científicas	Países mais citados	Número de citações
China	213	China	375
USA	111	USA	207
Canadá	37	Austrália	134
Índia	20	Korea	134
Austrália	18	Hong Kong	132
Coréia do Sul	17	Índia	67
Reino Unido	15	Canadá	48
Japão	8	Japão	44
Espanha	7	México	31
Alemanha	5	Reino Unido	17

Fonte: Elaboração própria

na Tabela 20. Já os autores mais relevantes e mais citados são apresentados na Tabela 21. Destes, Ausin M, Chi M e Huang Z são os com maior impacto, segundo software bibliométrico *Bibliometrix*.

Em relação às principais fontes de publicações, percebem-se periódicos da área de ciência da computação, como visto na Tabela 22. Destas publicações, na Tabela 23, são apresentados os artigos mais citados.

Figura 21 – Produção científica ao longo dos anos.



Fonte: Elaboração própria.

Tabela 21 – Autores e suas produções científicas

Autores mais relevantes	Número de artigos	Autores mais citados	Número de citações
NA, N.	16	YEUNG, D.	25
CHI, M.	9	YEUNG, C.	19
LI, X.	8	GHOSH, A.	17
AUSIN, M.	6	HEFFERNAN, N.	17
BARNES, T.	6	LAN, A.	17
SUN, Y.	6	ABDELRAHMAN, G.	14
HUANG, Y.	5	WANG, Q.	14
HUANG, Z.	5	CHEN, F.	8
LIU, C.	5	NAGATANI, K.	8
LIU, T.	5	OHKUMA, T.	8

Fonte: Elaboração própria

Tabela 22 – Periódicos em que houve mais publicações

Periódicos	Artigos
DEEP COMPREHENSION: MULTI-DISCIPLINARY APPROACHES TO UNDERSTANDING, ENHANCING, AND MEASURING COMPREHENSION	22
LECTURE NOTES IN COMPUTER SCIENCE (INCLUDING SUBSERIES LECTURE NOTES IN ARTIFICIAL INTELLIGENCE AND LECTURE NOTES IN BIOINFORMATICS)	16
ACM INTERNATIONAL CONFERENCE PROCEEDING SERIES	8
INTERNATIONAL JOURNAL OF ARTIFICIAL INTELLIGENCE IN EDUCATION	6
ADVANCES IN INTELLIGENT SYSTEMS AND COMPUTING	4
CEUR WORKSHOP PROCEEDINGS	4
COMMUNICATIONS IN COMPUTER AND INFORMATION SCIENCE	4
EXPERT SYSTEMS WITH APPLICATIONS	4
JISUANJI YANJIU YU FAZHAN/COMPUTER RESEARCH AND DEVELOPMENT	4
ARTIFICIAL INTELLIGENCE IN EDUCATION (AIED 2020), PT II	3

Fonte: Elaboração própria

Tabela 23 – Artigos mais citados

Artigos mais citados	Qtidade
<p>CHEN, X. et al. Application and theory gaps during the rise of Artificial Intelligence in Education. Computers and Education: Artificial Intelligence, v. 1, p.100002, 2020. DOI: doi.org/10.1016/j.caeai.2020.100002</p>	132
<p>GUAN, C.; MOU, J.; JIANG, Z. Artificial intelligence innovation in education: A twenty-year data-driven historical analysis. International Journal of Innovation Studies, v. 4, n. 4, p.134–147, 1 dez. 2020. DOI: doi.org/10.1016/j.ijis.2020.09.001</p>	69
<p>SONG, X. et al. JKT: A joint graph convolutional network based Deep Knowledge Tracing. Information Sciences, v. 580, p.510–523, nov. 2021. DOI: doi.org/10.1016/j.ins.2021.08.100</p>	65
<p>SONG, X. et al. Bi-CLKT: Bi-Graph Contrastive Learning based Knowledge Tracing. Knowledge -Based Systems, v. 241, p.108274, abr. 2022. DOI: doi.org/10.1016/j.knosys.2022.108274</p>	58
<p>CHEN, p.et al. Prerequisite-Driven Deep Knowledge Tracing. International Conference on Data Mining, 1 nov. 2018. DOI: doi.org/10.1109/ICDM.2018.00019</p>	58
<p>YEUNG, C.-K.; YEUNG, D.-Y. Addressing two problems in deep knowledge tracing via prediction -consistent regularization. Proceedings of the Fifth Annual ACM Conference on Learning at Scale, 26 jun. 2018. DOI: doi.org/10.1145/3231644.3231647</p>	55
<p>GHOSH, A.; HEFFERNAN, N.; LAN, A. S. Context -Aware Attentive Knowledge Tracing. Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 20 ago. 2020. DOI: doi.org/10.1145/3394486.3403282</p>	54

Tabela 23 – Artigos mais citados

Artigos mais citados	Qtidade
PERROTTA, C.; SELWYN, N. Deep learning goes to school: toward a relational understanding of AI in education. Learning, Media and Technology , p.1–19, 6 nov. 2019. DOI: doi.org/10.1080/17439884.2020.1686017	41
NAGATANI, K. et al. Augmenting Knowledge Tracing by Considering Forgetting Behavior. The World Wide Web Conference , 13 maio 2019. DOI: doi.org/10.1145/3308558.3313565	40
LI, C.; ZHOU, H. Enhancing the Efficiency of Massive Online Learning by Integrating Intelligent Analysis into MOOCs with an Application to Education of Sustainability. Sustainability , v. 10, n. 2, p.468, 9 fev. 2018. DOI: doi.org/10.3390/su10020468	40

Fonte: Elaboração própria.

Análise dos dados de 28 artigos

Neste capítulo serão respondidas as perguntas com base na análise qualitativa dos artigos selecionados:

- Pergunta 3: Quais tecnologias de deep learning foram utilizadas?
- Pergunta 4: Quais são as aplicações trazidos pelos artigos?
- Pergunta 5: Há medição de efetividade da aplicação da tecnologia?

Os subtítulos trazem a aplicação de tecnologias do *deep learning* nos Sistemas Tutores Inteligentes.

Análise de sentimentos e estados afetivos

A análise de sentimentos foi utilizada por Alrajhi, Alharbi e Cristea (2020) para prever se alunos precisam de intervenção urgente de tutores em ambientes de cursos online do tipo *Massive Open Online Course* (MOOC), com base em dados textuais postados em fóruns. Com base nisso, foi desenvolvido um modelo de aprendizado profundo multidimensional combinado com o processamento de linguagem natural (PLN) para

identificação dos alunos que precisam de intervenção. A tecnologia utilizada foi treinada em dados textuais fornecidos pela Universidade de Stanford, que abrange dados das áreas de educação, humanidades, ciências e medicina, contendo 29.604 postagens anônimas, em 11 cursos. Os resultados foram “[...] que os sentimentos negativos dos alunos, falta de entendimento, falta de vontade de expressar uma opinião, número de perguntas e diminuição do número de respostas aumentam para os alunos que precisam de intervenção urgente” (ALRAJHI; ALHARBI; CRISTEA, 2020)

Com vistas a oferecer educação personalizada para cada estudante, Behera et al. (2020) utilizou *webcams* para captação de expressões faciais, gestos, movimento de cabeça e olhos para elaborar intervenções específicas assim como docentes realizam em momentos face a face com o aluno. As imagens captadas foram processadas por meio de técnica de visão computacional utilizando a tecnologia de redes neurais profundas para detecção automática de comportamentos não verbais. Os autores aplicaram a detecção automática proposta em uma sessão de aula de 40 minutos envolvendo exercícios de leitura e resolução de problemas com 9 participantes de um curso de Ciência da Computação da Universidade de Edge Hill. Constatou-se que há um aumento significativo nos movimentos da cabeça e dos olhos com o passar do tempo e com o aumento do nível de dificuldade das atividades propostas. Há um aumento nos gestos de mão sobre a face quando o nível de dificuldade do exercício aumenta (BEHERA et al., 2020).

Com objetivo semelhante de Behera et al. (2020), Boote, Agarwal e Mostow (2021) utilizaram a tecnologia LSTM para prever o desengajamento de estudantes em atividades de alfabetização e matemática básica. A ideia era prever se os estudantes finalizariam ou não as atividades. Para isso, os autores treinaram e testaram o modelo em vídeos de captura de tela de crianças na Tanzânia usando um tutor para *tablet*. Os resultados foram os de que houve alto percentual de previsão de desengajamento.

Cabada et al. (2020), com vistas a personalizar a educação, utilizou o reconhecimento de emoções para adequar exercícios de multiplicação e divisão para alunos com base nos estados afetivos e cognitivos, número de solicitações de ajuda, tempo gasto no exercício e número de erros. Para isso, utilizou a tecnologia de algoritmos genéticos comparando os resultados com outros algoritmos utilizados para esta aplicação. O algoritmo genético melhorou a precisão de detecção quando comparado aos outros.

Identificação de nível de proficiência por análise de movimentos oculares

Com objetivo de identificar o nível de proficiência de dentistas em identificação de anomalias em radiografias odontológicas, Castner et al. (2022) aplicaram a tecnologia LSTM em um estudo com alunos do curso de Odontologia do sexto e do décimo semestre e profissionais com 10 anos de experiência do Hospital Universitário. Os alunos do sexto semestre foram considerados novatos, os do décimo intermediários e os demais considerados

peritos. O objetivo era identificar a proficiência por meio dos movimentos oculares na análise de imagens odontológica utilizando como base a Teoria Holística do Processamento de Imagens. A tecnologia empregada pôde detectar todos os níveis de proficiência com alta precisão. A ideia dos autores é aplicá-la em STIs.

Previsão do comportamento do aluno em interações futuras

A tecnologia *Knowledge Tracing* (KT) tem se tornado um tema bastante pesquisado e com muitas aplicações em educação *online*. Foram identificados em 8 artigos, constando nas pesquisas de: Song et al. (2022b), Minn (2022) Sein Minn (2022), Song et al. (2022a), Ghosh, Heffernan e Lan (2020), Lee et al. (2022), Song et al. (2021), Gan, Sun e Sun (2022) e Chan, Tse e Lei (2022).

O KT é uma técnica utilizada para modelar o conhecimento do aluno ao longo do tempo, para que se possa prever com precisão como os alunos se comportarão em interações futuras, daí o nome da tecnologia “rastreamento do conhecimento”. A melhoria nesta tarefa significa que os recursos podem ser sugeridos aos alunos com base em suas necessidades individuais (SONG et al., 2021). A previsão do desempenho e o nível de conhecimento dos estudantes é um dos grandes desafios para os STIs (SONG et al., 2021). Esta afirmação é perceptível nos artigos analisados onde métodos e técnicas são aplicadas com vistas a aprimorar os modelos de previsão.

Os primeiros métodos KT desenvolvidos apresentaram excelente interpretabilidade, ou seja, as conclusões e decisões tomadas pelo modelo são compreendidas pelo um ser humano, mas não fornecem desempenho na previsão de desempenho futuro do aluno (GHOSH; HEFFERNAN; LAN, 2020). Métodos recentes de KT baseados em *deep learning* são excelentes nisso, mas oferecem interpretação limitada (GHOSH; HEFFERNAN; LAN, 2020). Portanto, nenhum método KT existente realmente se destaca tanto na previsão de desempenho futuro quanto na interpretabilidade (GHOSH; HEFFERNAN; LAN, 2020). Song et al. (2022a) analisando diversos métodos de KT, também concluem que o *deep learning* não conseguiu resolver o desafio da interpretabilidade. Para superar estes desafios, alguns artigos buscam aprimorar os métodos a qual são apresentados nos parágrafos seguintes.

Ghosh, Heffernan e Lan (2020), propõem o *Attentive Knowledge Tracing* (AKT), que combina modelos flexíveis de redes neurais baseadas em atenção com uma série de novos componentes de modelos interpretáveis inspirados em modelos cognitivos e psicométricos. Para a tarefa de prever a resposta do aluno à pergunta atual, o método usa uma série de redes de atenção para estabelecer conexões entre uma pergunta e todas as outras já respondidas pelo aluno (GHOSH; HEFFERNAN; LAN, 2020). Os resultados de testes, não aplicados a situações reais, mostraram superação na previsão do desempenho futuro do aluno e excelente interpretabilidade. Apesar de este artigo ser mais antigo que o de

Song et al. (2022a), o desafio da interpretabilidade, mencionado no último parágrafo, não contemplou a análise do artigo de Ghosh, Heffernan e Lan (2020).

Song et al. (2021), propõem um *framework* intitulado *Joint Graph Convolutional Network Deep Knowledge Tracing* (JKT) baseado em redes neurais convolucionais que se concentram na melhoria da previsão de desempenho do aluno e aprimora a interpretabilidade de aplicações baseadas em KT. Para validação do modelo, realizaram experimentos com base em 4 conjuntos de dados reais em 6 métodos de linha, a seguir: *Bayesian Knowledge Tracking* (BKT), *Deep Knowledge Tracing* (DKT), *Dynamic Key-Value Memory Networks*, SAKT, EKT e SAINT+. O JKT demonstra forte interpretabilidade na análise de aprendizagem (SONG et al., 2021). O *framework* também capturou as informações semânticas dos estados de aprendizagem dos alunos em níveis mais altos no processo de rastreamento do conhecimento.

Song et al. (2022c), propõem uma estrutura de aprendizado auto supervisionado juntamente com o modelo *Bi-Graph Contrastive Learning based Knowledge Tracing* (Bi-CLKT) com vistas a superar os problemas encontrados pelos modelos tradicionais de KT baseados em *Graph Neural Networks* (GNN). Para validação do modelo, utilizaram o mesmo método do parágrafo anterior. Em termos de desempenho de previsão, o modelo proposto superou os métodos tradicionais baseados em *deep learning*, mostrando grande potencial na previsão de rastreamento de conhecimento.

Chan, Tse e Lei (2022), estabeleceram um modelo intitulado *Corrigible Knowledge Tracing* (CKT), que assume que os alunos podem aprender com os erros. O modelo foi testado utilizando o conjunto de dados da base Ednet. Os dados selecionados incluíram 2.248.522 registros, que correspondem às respostas de 49.066 usuários ao responderem 11.494 questões abrangendo 187 habilidades (Chan et al, 2022). Os resultados do experimento mostraram que o desempenho do CKT está no mesmo nível das abordagens *deep learning* de última geração Chan, Tse e Lei (2022).

Gan, Sun e Sun (2022), conceberam um modelo chamado *Knowledge Structure Enhanced Graph Knowledge Tracing* (KSGKT), que rastreia a evolução do conhecimento dos alunos com base em seus registros de exercícios realizados em sistemas de aprendizado *online*. O modelo foi avaliado com três conjuntos de dados públicos do mundo real. O KSGKT previu o desempenho do aluno em novos problemas. Demonstrou interpretabilidade para modelagem do desempenho do aluno (GAN; SUN; SUN, 2022).

Já Lee et al. (2022), com os mesmos objetivos anteriores, propõem o CL4KT, em que avaliam o modelo com base em 6 *benchmarking* KT. O modelo mostrou melhorias de desempenho consistentes e estatisticamente significativas em comparação com os métodos KT anteriores em todos os *benchmarks* (LEE et al., 2022). Para solucionar o problema de interpretabilidade, Lu et al. (2022), introduziram técnicas de IA Explicável (xAI), que “são um conjunto de processos e métodos que permite aos usuários humanos compreender

e confiar nos resultados e na saída criados por algoritmos de machine learning” (IBM, 2019), para interpretar modelos de DKT baseados em redes neurais recorrentes. O método proposto se concentrou em entender as previsões do modelo DLKT a partir da perspectiva de suas entradas sequenciais.

Minn (2022), realiza uma avaliação psicométrica do módulo de aluno com vistas verificar o quão consistentes e precisos são o diagnóstico cognitivo e a previsão de desempenho de estudantes. Os autores concluíram que a Teoria de Resposta ao Item (TRI) mostra desempenho competitivo para o DKT em termos de previsão de desempenho do aluno.

Por fim, Perrotta e Selwyn (2020) realizam um estudo da visão da área de educação em relação as tecnologias de IA aplicadas ao contexto educacional, principalmente o KT. Os autores chamam atenção para “dados falhos, métodos computacionais parcialmente incompreensíveis, formas estreitas de conhecimento educacional incorporadas aos ambientes online e um discurso reducionista da ciência de dados com evidentes ramificações econômicas” (PERROTTA; SELWYN, 2020). Citam também que “a modelagem preditiva e a ciência de dados não estão interessadas nos aspectos culturais e emocionais do conjunto de dados, descartando-os como ruído de fundo que interfere na tarefa principal de prever estados de conhecimento” (PERROTTA; SELWYN, 2020, tradução nossa).

Vídeo como entrada de informações para o aprendizado de instrumentos musicais

Com objetivo de aprimorar o ensino de uso de instrumentos musicais, Wang, Yang e Grossman (2021) propuseram o *Soloist*, aplicação que oferece suporte à navegação de vídeo eficaz e *feedback* em tempo real sobre o desempenho do aluno, criando uma experiência de aprendizagem guiada. Para isto, o *Soloist* recebe vídeos brutos dos alunos, que são processados por meio da tecnologia *deep learning*, gerando currículos personalizáveis a partir de vídeo aulas de guitarra disponíveis no mercado.

Apoio no desenvolvimento de habilidades práticas

Para dar suporte a aprendizagem de habilidades práticas de solda, foi proposto por Marinescu-Muster, Vries e Vollenbroek (2021) um modelo de redes neurais recorrentes, utilizando a variação LSTM, para prever o desempenho dos alunos em tentativas futuras com base em sua atividade anterior. O modelo foi treinado com base em dados coletados durante sessões de aprendizagem ocorridas entre janeiro a outubro de 2019. Segundo os autores, o sistema permitiu que os instrutores e curriculistas entendam melhor as relações entre os diferentes exercícios e, assim, criem cenários de treinamento aprimorados. Os estudos revelaram melhorias significativas e aceleração do processo de treinamento de soldadores.

Aprimoramento e personalização do *feedback* fornecido ao estudante

Um dos principais objetivos dos STIs é o fornecimento de *feedbacks* com base nas interações realizados pelos alunos. O *deep learning* tem sido utilizado para aprimoramento dessas respostas. No entanto, a criação dos *feedbacks* tem caráter manual dificultando a operação em larga escala e para além de um único domínio de conhecimento. Além disso, possui alto custo de desenvolvimento. Alguns artigos foram identificados com objetivo de atacar esses problemas e são apresentados a seguir.

Serban et al. (2020), apresentaram a plataforma *Korbit*, um STI baseado em diálogo, domínio aberto, interface mista e larga escala. O *Korbit* utiliza aprendizado de máquina, processamento de linguagem natural e aprendizado por reforço para fornecer aprendizado online interativo e personalizado (SERBAN et al., 2020). Os autores têm como objetivo oferecer uma plataforma que combine baixo custo e escalabilidade com a personalização e eficácia (SERBAN et al., 2020). Nos testes realizados, os alunos relataram que prefeririam a plataforma quando comparados ao curso xMOOC, houve ganho de aprendizagem e maior engajamento dos estudantes. Em relação à aplicação no *Korbit*, três outros artigos foram encontrados.

Kochmar et al. (2022), utilizou aprendizado de máquina de última geração e técnicas de processamento de linguagem natural (PLN) para fornecer aos alunos orientações personalizadas, com base em explicações oriundas do *Wikipedia* e dicas matemáticas. Segundo os autores, o “*feedback* gerado dessa maneira leva em conta as necessidades individuais dos alunos, não requer intervenção especializada ou regras artesanais e é facilmente escalável e transferível entre domínios de conhecimento” (tradução nossa). O experimento foi realizado com alunos reais na plataforma *Korbit*, em um curso de *machine learning*, no período entre janeiro e fevereiro de 2020. O resultado obtido foi que as dicas baseadas na *Wikipedia* e de matemática melhoram a aprendizagem dos estudantes. Em 2022, Kochmar et al. (2022), apresentou um artigo com mesma aplicação e escopo semelhante, mas apresentando resultados de que o *feedback* personalizado em uma plataforma de larga escala alcança melhores resultados de aprendizagem.

Ainda com aplicação na plataforma *Korbit*, Kulshreshtha et al. (2022), propõe um sistema automatizado de *feedbacks* baseados no modelo *Transformer*, com vistas a solucionar o problema de erros gramaticais, raciocínio incorreto, entre outros, ou seja, informações ausentes nas respostas dos alunos. O modelo foi treinado na referida plataforma e houve ganhos na aprendizagem dos alunos.

A avaliação das respostas dos alunos ou a classificação de textos curtos é um problema bem definido no NLP. É uma tarefa extremamente desafiadora, pois os alunos podem expressar a mesma resposta de várias maneiras devido a diferentes estilos individuais e habilidades cognitivas e níveis de conhecimento variados (KHAYI; RUS, 2020). Para

atacar este problema, Khayi e Rus (2020) propuseram uma abordagem baseada em *Graph Convolutional Networks* (GCN). Houve a aplicação da abordagem em um curso superior, para 36 alunos, onde cada um tinha que responder 9 problemas conceituais na temática de física. Os autores informaram que houve demonstração de eficácia no modelo proposto.

Wang (2022), propôs um STI para dar *feedbacks* em NLP para alunos ao cometerem erros na construção do código na disciplina de Programação Orientada a Objetos, em um curso superior. O STI foi construído utilizando o método *Performer*. As respostas dos alunos foram interpretadas dentro da estrutura do modelo educacional *Learning Partnerships Model* (LPM).

Vasić et al. (2021) apresentaram um artigo com um modelo para processamento de texto sintático na língua croata, utilizando NLP e o modelo *Bidirectional Encoder Representations from Transformers* (BERT), que possa se comunicar com o usuário de maneira natural.

Para captura do nível cognitivo do aluno, os STIs realizam avaliações adaptativas com vistas a personalizar caminhos de aprendizagem para o estudante Zhu, Wu e Zhang (2022). Para isso, os autores mencionam que perguntas padronizadas de múltipla escolha são utilizadas, mas mencionam duas deficiências: fornecem itens que não conseguem captar todas as possíveis respostas dos estudantes e os alunos podem escolher de forma aleatória as respostas, impactando na identificação do nível cognitivo que comporá o modelo de aluno. Para superar estas deficiências, os autores mencionam a utilização da tecnologia *Automatic Short-Answer Grading* (ASAG), em que respostas curtas são solicitadas ao estudante para que haja identificação do nível cognitivo. No entanto, ainda o ASAG possui deficiências tais como: “alta precisão requer uma compreensão profunda da resposta e o corpus da tecnologia é pequeno, não podendo fornecer dados de treinamento suficiente para aprendizagem profundo” (ZHU; WU; ZHANG, 2022, tradução nossa). Na superação destes desafios, Zhu, Wu e Zhang (2022) propõem um novo BERT para ASAG. Os autores concluem que os experimentos demonstraram que o modelo proposto é eficaz e supera a maioria dos sistemas de última geração.

Venugopal, Rus e Shakya (2021), com vistas a superar algumas desvantagens presentes no uso de redes neurais profundas, utilizando LSTM, para que STIs se adaptem ao aluno e personalizem a instrução, propõem uma estrutura neurosimbólica combinando com redes neurais profundas.

Saindo da aplicação de tecnologias em STIs, Feng e Magana (2021) realizaram um estudo para avaliar os ganhos de aprendizagem obtidos em circuitos elétricos com estudantes universitários dos cursos de Física e Engenharia. Foi utilizado o STI *ElectronixTutor*. Os pesquisadores utilizaram métodos quantitativos e qualitativos para avaliação durante e pós-utilização do STI. Os autores encontraram ganhos de aprendizado no pré-teste e pós-teste. Feng e Magana (2021), sugerem a necessidade de melhorar as tecnologias de

aprendizagem no domínio de Ciência, tecnologia, Engenharia e Matemática (STEM), integrando conhecimentos e habilidades.

Conclusões

As pesquisas em STI têm apresentado preocupações quanto à assertividade do modelo proposto, tanto no aprimoramento do *feedback*, da predição do conhecimento e estados afetivos do aluno e da personalização do ensino. Todos com o objetivo de aumentar a aprendizagem do aluno, principalmente em plataformas de educação online. Diversas tecnologias de *deep learning* têm sido utilizadas com diferentes métodos. O *Knowledge Tracing* é a que mais é apresentada e discutida.

Iniciativas foram identificadas para superação de problemas de evasão de estudantes e não alcance de objetivos educacionais em cursos MOOCs. STIs são uma alternativa e que estão sendo utilizadas nas plataformas Coursera e Edx, por exemplo.

Pela preocupação em verificar a efetividade do modelo construído, bases de dados são utilizadas para treinamento e avaliação do modelo. Alguns estudos carecem de aplicações *in loco* e estudos longitudinais. Também não se verifica a aplicação em sala de aula presencial, como relatado na revisão sistemática de literatura elaborada por Chen et al. (2020).

Verificam-se aplicações da educação infantil, básica, profissional e superior. No entanto, estão no nível cognitivo, com apenas uma aplicação para desenvolvimento de habilidades práticas. Talvez aumente consideravelmente os custos, já altos, para o desenvolvimento de tais habilidades com STIs. Aqui, apresenta-se um campo promissor para aplicação em educação para o mundo trabalho, principalmente no desenvolvimento de habilidades práticas.

Guan, Mou e Jiang (2020b) e Chen et al. (2020) comentaram que falta ou há necessidade de incorporar as teorias educacionais na aplicação de IA no setor, tanto na análise, desenvolvimento, implementação e avaliação. A informação trazida pelos autores é contestada, pois há ampla fundamentação teórica que evidencia o oposto, pois o desenvolvimento de STI é a congruência das áreas de computação, educação e psicologia (WOOLF, 2009). Evidencia-se nos artigos a citação, fundamentação teórica e aplicações considerando autores e teorias educacionais. O método socrático e o LPM são apresentados em 2 artigos de forma explícita. A teoria da afetividade, a teoria da carga cognitiva, o método *scaffolding* e teorias das ciências cognitivas também emergem nos artigos. Evidencia-se também na análise bibliométrica, que as publicações relativas à IA na educação estão ligadas à ciência da computação (CHEN et al., 2020).

APÊNDICE B – Termo de Consentimento Livre e Esclarecido (TCLE)

Você está sendo convidado a participar da pesquisa “Análise do *feedback* dado para personalização de ensino em um Sistema Tutor Inteligente conversacional baseado em *Large Language Model*”, de responsabilidade de Jefferson da Silva, estudante de mestrado da Universidade de Brasília. O objetivo desta pesquisa é analisar a coerência e consistência do *feedback* dado pelo Sistema Tutor Inteligente conversacional baseado em *Large Language Model*. Assim, gostaria de consultá-lo sobre seu interesse e disponibilidade de cooperar com a pesquisa.

Você receberá todos os esclarecimentos necessários antes, durante e após a finalização da pesquisa, e lhe asseguro que o seu nome não será divulgado, sendo mantido o mais rigoroso sigilo mediante a omissão total de informações que permitam identificá-lo. Os dados provenientes de sua participação na pesquisa, tais como questionários, entrevistas, *printscreen* de telas, ficarão sob a guarda do pesquisador responsável pela pesquisa.

A coleta de dados será realizada por meio de entrevista semiestruturada, através de questionário com perguntas abertas e fechadas. É para esses procedimentos que você está sendo convidado a participar. Sua participação na pesquisa pode implicar em riscos mínimos de origem psicológica, intelectual ou emocional, tais como: possibilidade de constrangimento ao responder o questionário e estresse e cansaço ao responder às perguntas. Estes riscos serão minimizados com as seguintes estratégias:

- **Possibilidade de constrangimento ao responder o questionário:** o pesquisador explanará como a aplicação no computador deverá ser configurada e utilizada pelo participante. Assim como, tirará todas as dúvidas em relação ao preenchimento do questionário. O acolhimento pelo pesquisador se dará por meio de atenção imediata às necessidades do participante, quando solicitado.
- **Estresse e cansaço ao responder às perguntas:** o pesquisador orientará os participantes, que ao sinal de quaisquer sintomas de estresse e cansaço, o participante deverá deixar de responder ao questionário e continuar quando os sintomas terem desaparecidos. O acolhimento pelo pesquisador se dará por meio de atenção imediata às necessidades do participante, quando solicitado.

Espera-se com esta pesquisa possibilitar o uso de ferramentas de IA generativa, como o ChatGPT, nos processos educacionais como um Sistema Tutor Inteligente conversacional,

por quaisquer profissionais que não dominem ciência da computação. Busca-se, também, reduzir a preocupação que profissionais da educação possam ter em relação a IA generativa.

Sua participação é voluntária e livre de qualquer remuneração ou benefício. Você é livre para recusar-se a participar, retirar seu consentimento ou interromper sua participação a qualquer momento. A recusa em participar não irá acarretar qualquer penalidade ou perda de benefícios.

Se você tiver qualquer dúvida em relação à pesquisa, você pode me contatar através do telefone (47) 98421-3248 e *e-mail* <scjefferson@hotmail.com> ou <silvajefferson@yahoo.com.br>.

A equipe de pesquisa garante que os resultados do estudo serão devolvidos aos participantes por meio do documento eletrônico do trabalho de dissertação aprovado pela banca de avaliação, podendo ser publicados posteriormente na comunidade científica.

Este projeto foi revisado e aprovado pelo Comitê de Ética em Pesquisa em Ciências Humanas e Sociais (CEP/CHS) da Universidade de Brasília, com o Parecer nº 6.718.799. As informações com relação à assinatura do TCLE ou aos direitos do participante da pesquisa podem ser obtidas por meio do *e-mail* do CEP/CHS: <cep_chs@unb.br> ou pelo telefone: (61) 3107-1592.

Para baixar este TCLE em formato PDF, clique no *link* abaixo: <<http://drive.google.com/uc?export=download&id=1aVFfn3fbV8v114L9vdo5bsE2th39Odp2u>>

Diante das explicações, você acha que está suficientemente informado a respeito da pesquisa que será realizada e concorda de livre e espontânea vontade em participar, como colaborador? () Sim. () Não.