

Revista Ubiquidade

Revista Ubiquidade

Data de publicação Julho/2026

Copyright © 2026 UniAnchieta

Expediente

A revista Ubiquidade é uma publicação semestral vinculada ao Curso de Bacharelado em Ciência da Computação do UniAnchieta, exclusivamente eletrônica, que pretende divulgar contribuições originais, teóricas ou empíricas, relacionadas às áreas de Tecnologia de Informação e Comunicação (TICs) e está aberta para trabalhos científicos de pesquisadores nacionais ou internacionais.

O envio de trabalhos para apreciação, assim como o pedido de informações, pode ser feito por meio do endereço: ubiquidade@anchieta.br

Editor-Chefe

Prof. Dr. Juliano Schimiguel (UniAnchieta)

Conselho Editorial

Prof.a Dra. Aline Brum Loreto, Universidade Federal de Santa Maria-Campus Cachoeira do Sul (UFSM-CS)/RS

Prof.a Dra. Cecília Sosa Arias Peixoto, Pontifícia Universidade Católica de Campinas (PUC), Campinas/SP

Prof. Dr. Carlos Adriano Martins, Unilogos University International, Miami, Flórida/USA

Prof. Dr. Hélio Rosetti Júnior, Instituto Federal do Espírito Santo, Vitória/ES

Prof. Dra. Jane Garcia de Carvalho, Unid - Universidade Cidade de São Paulo, São Paulo/SP

Prof. Dr. Josney Freitas Silva, UEMG - Universidade do Estado de Minas Gerais - UEMG, Frutal/MG

Prof. Dr. Juliano Schimiguel, UniAnchieta e Univ. Cruzeiro do Sul

Prof. Me. Juliano Silva Marçal, Centro Universitário Anchieta, Jundiaí/SP

Prof. Dr. Luciano Soares Pedroso, Universidade Federal dos Vales do Jequitinhonha e Mucuri - UFVJM, Teófilo Otoni/MG

Prof.a Dra. Lucy Mirian Campos Tavares Nascimento, Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Formosa/GO

Prof. Dr. Pedro Isaías (Universidade Aberta, Lisboa/Portugal)

Prof. Dr. Marcelo Eloy Fernandes, Faculdade de Tecnologia (FATEC), Barueri/SP

Prof. Ma. Nádia Vilela Pereira, IFTO — Instituto Federal do Tocantins, Campus Palmas

Prof. Dr. Vivaldo José Breternitz, Universidade Paulista (Unip), Jundiaí/SP

Prof.a Dra. Viviane Sartori, Universidad Europea del Atlántico (Uniatlantico), Salamanca, Espanha

Ubiquidade / Centro Universitário Anchieta – V.9, N.1, 2026 – Jundiaí: Unianchieta, 2026.

Semestral

ISSN 2236-9031

1. Ciência da Computação. 2. Sistemas de Informação. 3. Sistemas de Computação e Teleinformática.

CDU: 004(05)

Catálogo na Publicação

Bibliotecária Responsável – Elizabete Alves – CRB-8/3589.

Todos os direitos reservados e protegidos pela Lei 9.610 de 19/02/1998. É permitida a reprodução e distribuição desta obra, desde que para fins educacionais e integralmente mantidas as informações autorais. É vedado seu uso comercial, sem prévia autorização, por escrito, dos autores e da Editora.

Prefácio

Dando continuidade à sua trajetória de difusão científica, a Revista Ubiquidade publica em seu V. 9, N. 1 (2026) artigos expressivos que refletem a excelência de pesquisadores e professores atuantes na área. Podemos destacar autores destas instituições: Universidade Cruzeiro do Sul (São Paulo/SP), Universidade Cidade de São Paulo (Unicid), Centro Universitário Anchieta (Unianchieta), Faculdade de Tecnologia do Estado de São Paulo, FATEC, Itu, São Paulo, Brasil, entre outros.

No artigo “Mapeamento e Análise da Intensidade de Sinais Wi-Fi Utilizando Técnicas de Geolocalização e Visualização de Dados”, os autores Ruzza, Roveri, Valdo e lenne, investigam, aplicam e validam técnicas de análise e mapeamento da intensidade de sinais Wi-Fi, medida pelo Indicador de Força do Sinal Recebido (RSSI), através da sua correlação direta com dados de geolocalização. Para tanto, foi realizada uma pesquisa abrangente sobre os padrões IEEE 802.11 operando em 2,4 GHz e 5 GHz, as métricas de sinal e os fenômenos de propagação, como atenuação e reflexão. Foi explorada a utilização dos sistemas de navegação global (GNSS) e, especificamente do A-GPS para viabilizar uma localização rápida e precisa, mesmo em ambientes internos ou semi-internos. A plataforma Android foi escolhida como base de desenvolvimento, explorando sua arquitetura sobre o kernel Linux e suas APIs nativas do sistema operacional.

O artigo “Engenharia de Prompt Pedagógica: Aprendizagem Significativa em Matemática com IA Generativa”, de Santos, Santos, Fernandes e Schimiguel, analisa o papel da engenharia de prompt como estratégia de mediação pedagógica no ensino de matemática, fundamentado na teoria da aprendizagem significativa de Ausubel. A pesquisa qualitativa, exploratória e descritiva compara prompts genéricos com prompts estruturados segundo o método IDEAL (Intenção, Detalhe, Exemplo, Ação, Limite), investigando como a estruturação intencional de instruções para inteligência artificial generativa pode favorecer a aprendizagem significativa. Os resultados evidenciam que prompts estruturados pedagogicamente geram respostas mais contextualizadas, com exemplos e explicações detalhadas, promovendo maior engajamento e compreensão conceitual.

O artigo “A Inteligência Artificial sob uma Perspectiva Humana: Motivações, Adoção e Inovatividade entre Estudantes Tecnológicos”, de Soares e Lui, analisa a influência das dimensões motivacionais (hedônica, social, cognitiva e funcional) no comportamento inovativo de estudantes tecnólogos frente à Inteligência Artificial (IA). Realizou-se uma pesquisa quantitativa e explicativa com 110 graduandos da FATEC e de outras instituições de ensino superior, utilizando modelagem por regressão linear múltipla no SPSS. Os resultados indicam que o Domínio Específico de Inovatividade (DSI) é explicado

exclusivamente pela motivação social. Já a Inovação Inata (II) sofre influência simultânea das motivações social e cognitiva.

Já no artigo intitulado “Inteligência Artificial e Aprendizagem Baseada em Problemas (PBL): Possibilidades e Desafios no Ensino Superior”, de Lança, Prezotto e Ienne, discute-se a utilização da inteligência artificial no ensino superior. Foram analisados alguns casos envolvendo o uso do modelo IA *Gemini* e discutiu-se possibilidades e limitações do seu uso. Além disso, foi proposto o uso de IA também como uma metodologia ativa (especificamente PBL), que pode ser utilizada no ensino superior e adaptada para EaD.

Finalmente, o artigo “O Poder das Big Techs e da IA: no Oceano de Cursos Gratuitos, como Encontrar o seu Norte?”, de Ferreira, analisa o papel estratégico das grandes empresas de tecnologia nesse novo ecossistema educacional, traçando um paralelo com a disrupção das fintechs no mercado financeiro e apresentando um guia crítico das principais iniciativas gratuitas de onze organizações: Anthropic, OpenAI, Google, Microsoft, NVIDIA, DeepLearning.AI, Meta, AWS, IBM, Hugging Face e Stanford. Ao final, propõe trilhas de aprendizagem orientadas por perfil profissional, argumentando que o verdadeiro diferencial não está em acumular certificados, mas em aprender a aprender.

Sumário

MAPEAMENTO E ANÁLISE DA INTENSIDADE DE SINAIS WI-FI UTILIZANDO TÉCNICAS DE GEOLOCALIZAÇÃO E VISUALIZAÇÃO DE DADOS (Nicolas RUZZA, Vinícius Eduardo ROVERI, Clayton Augusto VALDO, Vanderlei IENNE) 7

ENGENHARIA DE PROMPT PEDAGÓGICA: APRENDIZAGEM SIGNIFICATIVA EM MATEMÁTICA COM IA GENERATIVA (Márcio Eugen Klingenschmid Lopes dos SANTOS, Rodrigo Mariano dos SANTOS, Vera Maria Jarcovis FERNANDES, Juliano SCHIMIGUEL) 31

A INTELIGÊNCIA ARTIFICIAL SOB UMA PERSPECTIVA HUMANA: MOTIVAÇÕES, ADOÇÃO E INOVATIVIDADE ENTRE ESTUDANTES TECNOLÓGICOS (Samuel Felipe de Oliveira SOARES, Márcio de La Cruz LUI) 52

INTELIGÊNCIA ARTIFICIAL E APRENDIZAGEM BASEADA EM PROBLEMAS (PBL): POSSIBILIDADES E DESAFIOS NO ENSINO SUPERIOR (Tatiana LANÇA, Rômulo PREZOTTO, Vanderlei IENNE) 72

O PODER DAS BIG TECHS E DA IA: NO OCEANO DE CURSOS GRATUITOS, COMO ENCONTRAR O SEU NORTE? (Alessandro Silva FERREIRA) 90

MAPEAMENTO E ANÁLISE DA INTENSIDADE DE SINAIS WI-FI UTILIZANDO TÉCNICAS DE GEOLOCALIZAÇÃO E VISUALIZAÇÃO DE DADOS

WI-FI SIGNAL STRENGTH MAPPING AND ANALYSIS THROUGH GEOLOCATION AND DATA VISUALIZATION

Nícolas RUZZA

nic.ruzza@gmail.com

Ciência da Computação, Unianchieta

Vinícius Eduardo ROVERI

viroveri117@gmail.com

Ciência da Computação, Unianchieta

Clayton Augusto VALDO

clayton.valdo@anchieta.br

Ciência da Computação, Unianchieta

Vanderlei IENNE

vanderlei.ienne@anchieta.br

Ciência da Computação, Unianchieta

Resumo

O Wi-Fi, baseado no padrão IEEE 802.11, consolidou-se como uma tecnologia fundamental na comunicação digital contemporânea, mas sua eficácia é frequentemente comprometida por interferências, atenuação de sinal e áreas de sombra, problemas cuja identificação é comumente realizada de forma empírica e imprecisa. Diante da massiva adoção de dispositivos móveis e de IoTs no Brasil, a otimização da cobertura de redes sem fio torna-se crucial. Este trabalho teve como objetivo principal investigar, aplicar e validar técnicas de análise e mapeamento da intensidade de sinais Wi-Fi, medida pelo Indicador de Força do Sinal Recebido (RSSI), através da sua correlação direta com dados de geolocalização. Para tanto, foi realizada uma pesquisa abrangente sobre os padrões IEEE 802.11 operando em 2,4 GHz e 5 GHz, as métricas de sinal e os fenômenos de propagação, como atenuação e reflexão. Foi explorada a utilização dos sistemas de navegação global (GNSS) e, especificamente do A-GPS para viabilizar uma localização rápida e precisa, mesmo em ambientes internos ou semi-internos. A plataforma Android foi escolhida como base de desenvolvimento, explorando

sua arquitetura sobre o kernel Linux e suas APIs nativas do sistema operacional. O método de interpolação espacial de Estimção de Densidade por Kernel (KDE), foi utilizado como técnica estatística para transformar pontos de dados discretos em uma superfície contínua e visualmente interpretável. Com intuito de realizar uma avaliação prática, foi desenvolvido uma aplicação em Java, no qual permite ao usuário realizar a coleta de dados fornecidos pelo ponto de acesso sem fio e localização atual em tempo real, e renderizar um mapa de calor correlacionando essas métricas.

Palavras-Chave

Wi-Fi; RSSI; Geolocalização; Kernel Density Estimation; Mapas de calor.

Abstract

Wi-Fi, based on the IEEE 802.11 standard, has established itself as a fundamental technology in contemporary digital communication, but its effectiveness is often compromised by interference, signal attenuation, and shadow areas, problems whose identification is commonly carried out empirically and imprecisely. In view of the massive adoption of mobile devices and IoTs in Brazil, optimizing wireless network coverage becomes crucial. The main objective of this project was to investigate, apply, and validate techniques for analyzing and mapping the intensity of Wi-Fi signals, measured by the Received Signal Strength Indicator (RSSI), through its direct correlation with geolocation data. To this end, comprehensive research was conducted on the IEEE 802.11 standards operating at 2.4 GHz and 5 GHz, signal metrics, and propagation phenomena such as attenuation and reflection. The use of global navigation systems (GNSS), and specifically A-GPS, was explored to enable fast and accurate location, even in indoor or semi-indoor environments. The Android platform was chosen as the development base, exploring its architecture on the Linux kernel and its native operating system APIs. The spatial interpolation method of Kernel Density Estimation (KDE), used as a statistical technique to transform discrete data points into a continuous and visually interpretable surface. Aiming to carry out a practical evaluation, an application was developed in Java, which allows the user to collect data provided by the wireless access point and current location in real time, and render a heat map correlating these metrics.

Keywords

Wi-Fi; RSSI; Geolocation; Kernel Density Estimation; Heat Maps.

1. INTRODUÇÃO

Desde os primeiros desenvolvimentos das redes sem fio baseadas no padrão IEEE 802.11 até as modernas infraestruturas que operam nas faixas de 2,4 GHz, 5 GHz e 6 GHz, o Wi-Fi consolidou-se como uma das tecnologias mais importantes da comunicação digital contemporânea.

Segundo a organização WI-FI ALLIANCE (2018), o Wi-Fi consolidou-se como elemento essencial para viabilizar a mobilidade, a alta largura de banda e a conectividade ubíqua, transformando a forma como indivíduos, empresas e instituições acessam e compartilham informações. Mais do que apenas permitir acesso à internet, essa tecnologia passou a sustentar aplicações avançadas, como realidade aumentada, realidade virtual, vídeo em alta definição, jogos colaborativos e Internet das Coisas, ampliando seu papel estratégico no cenário digital contemporâneo. Entretanto, junto a tais benefícios, permanecem limitações relacionadas à interferência entre dispositivos, à fragmentação de canais e às variações abruptas na qualidade do sinal, fatores que impactam diretamente a confiabilidade e a experiência de uso. Tais aspectos tornam

imprescindível o monitoramento sistemático da intensidade do sinal e sua análise espacial como ferramentas para compreender e otimizar a cobertura das redes sem fio.

Nesse cenário, é importante destacar a dimensão do uso de dispositivos móveis no Brasil, que intensifica a dependência por redes sem fio de qualidade. Em 2024, o país contava com 167,5 milhões de pessoas com 10 anos ou mais de idade utilizando celular, o que correspondia a 88,9% da população nessa faixa etária (IBGE, 2024).

Em ambientes residenciais, empresariais e públicos, regiões com baixa intensidade de sinal, falhas de conectividade e áreas de sombra são problemas comuns, pois o concreto, metal e a topografia dificultam a propagação das ondas (Moraes et al., 2025). Na maioria das vezes, a identificação desses pontos críticos ocorre de forma empírica, por meio da percepção subjetiva, sem embasamento técnico consistente. Essa abordagem limita a capacidade de realizar diagnósticos precisos e, consequentemente, restringe o planejamento de soluções mais estruturadas para otimizar o desempenho das redes. Embora existam ferramentas para coleta e visualização de redes Wi-Fi, muitas são limitadas ou requerem um desembolso, e por vezes não integram os dados de geolocalização com precisão, o que dificulta análises mais detalhadas da infraestrutura.

Segundo Peres (2010, p. 12), os sinais de micro-ondas podem atravessar paredes e sofrer diferentes tipos de interferências, como atenuação, reflexão, refração, difração e dispersão, o que dificulta a definição precisa dos limites de alcance de uma rede sem fio.

O presente estudo propõe-se a investigar a intensidade de sinais Wi-Fi por meio da correlação entre valores de RSSI e dados de localização geográfica, de forma a produzir representações visuais como mapas de calor. Para tanto, serão desenvolvidos procedimentos de coleta automatizada que associam medições a coordenadas, bem como aplicadas técnicas de interpolação espacial, como o Kernel Density Estimation (KDE) explorado por Silverman (1986), visando representar com fidelidade as variações de sinal nos ambientes analisados.

Este trabalho tem como objetivo investigar e aplicar técnicas de análise e mapeamento da intensidade de sinais Wi-Fi, integrando informações de geolocalização para geração de representações visuais. Busca-se compreender os desafios técnicos envolvidos na coleta de dados de rede sem fio, no tratamento das medições de intensidade de sinal e na construção de mapas de calor que auxiliem a análise da cobertura e do desempenho de redes Wi-Fi.

2. FUNDAMENTAÇÃO TEÓRICA


Esta seção detalha os conceitos essenciais que sustentam o desenvolvimento prático de uma aplicação que utiliza o celular para realização de mapeamento e análise de sinais Wi-Fi. A abordagem explora as tecnologias de redes sem fio, junto a sistemas de geolocalização, fingerprint, a plataforma Android e técnicas de interpolação de dados. Formando uma solução que contribui para novas oportunidades exploratórias a tecnologia Wi-Fi e os futuros desafios sobre a interferência deste tipo de comunicação sem fio. Conforme Tanenbaum, Feamster e Wetherall (2021) “Computadores móveis, como notebooks, tablets e smartphones, constituem um dos segmentos de mais rápido crescimento do setor de informática.

2.1 Redes sem fio padrão IEEE 802.11

A comunicação de uma rede local sem fio (WLAN) é realizada por meio de sinais de micro-ondas, que ao se propagarem, podem sofrer fenômenos como atenuação, reflexão, refração e difração, tornando a delimitação da área de cobertura uma tarefa complexa, sendo necessário o uso de tecnologias para visualização do efeito causado por estes fenômenos. A antena dos celulares é responsável pela captura e envio dessas ondas (Moraes et al., 2025, p. 19). Para padronização dos equipamentos que se comunicam em uma rede sem fio foi criado o padrão IEEE 802.11, estabelecido em 1997, ele define as especificações para

as camadas física e de enlace de dados do modelo OSI, conforme ilustrado na Figura 1, para redes sem fio. A Anatel é responsável por aprovar o uso deste padrão no Brasil, fazendo com que todos dispositivos aprovados legalmente utilizem ele. (Anatel, 2019)

Figura 1. Modelo OSI (Cisco, 2023)



As tecnologias de rede sem fio padrão 802.11 podem operar em bandas de frequência distintas, como 2,4 GHz e 5 GHz. Cada uma possui vantagens e desvantagens relacionadas à interferência, alcance, capacidade de penetração em obstáculos e canais disponíveis, conforme ilustram a Figura 2 e Figura 3. Sobre essas características, Tanenbaum, Feamster e Wetherall (2021, p. 201) explicam que:

Todas as técnicas do 802.11 utilizam rádios de curto alcance para transmitir sinais nas bandas de frequência ISM de 2,4 GHz ou 5 GHz. Essas bandas têm a vantagem de não ser licenciadas e, portanto, estar disponíveis gratuitamente a qualquer transmissor que queira cumprir algumas restrições, como a potência irradiada de no máximo 1 W (embora 50 mW seja mais comum para rádios de LAN sem fio). Infelizmente, esse fato também é conhecido pelos fabricantes de aparelhos de abertura automática de garagem, telefones sem fio, fornos de micro-ondas e diversos outros dispositivos, todos competindo com os notebooks e smartphones pelo mesmo espectro. A banda de 2,4 GHz costuma ser mais sobrecarregada do que a de 5 GHz, de modo que esta pode ser melhor para algumas aplicações, embora tenha um alcance mais curto, em virtude da frequência mais alta. Infelizmente, as ondas de rádio mais curtas a 5 GHz não penetram em paredes tão bem quanto as de 2,4 GHz, de modo que 5 GHz não é uma vantagem definitiva.

Desde a sua criação, o padrão IEEE 802.11 evoluiu significativamente. A versão original (802.11) operava em 2,4 GHz, com taxas de até 2 Mbps. O padrão 802.11b introduziu o espalhamento espectral de alta taxa (HR-DSSS), alcançando 11 Mbps na mesma frequência. Posteriormente, os padrões 802.11a e 802.11g adotaram a multiplexação por divisão de frequência ortogonal (OFDM), permitindo taxas de até 54 Mbps. As gerações mais recentes, como o 802.11n (Wi-Fi 4), 802.11ac (Wi-Fi 5) e 802.11ax (Wi-Fi 6), continuaram a aprimorar a velocidade e a eficiência no uso do espectro. (IEEE, 2023)

Figura 2. Canais disponíveis na banda 2,4 GHz (Coleman, 2012)





Figura 3. Canais disponíveis banda 5 GHz (Vitanova, 2017)




2.1.1 Potência e Atenuação

Para analisar a qualidade de uma conexão sem fio, utilizam-se métricas como o Indicador de Força do Sinal Recebido (RSSI) e a Relação Sinal-Ruído (SNR). O RSSI representa a potência do sinal captado por um dispositivo, geralmente expressa em decibéis-miliwatts (dBm), conforme visível no índice de atenuação na Figura 4. Já o SNR compara a potência do sinal recebido com o nível de ruído de fundo do ambiente. No Android, não é possível obter diretamente o valor SNR, sendo o RSSI a principal ferramenta de análise para o mapeamento da intensidade e qualidade do sinal Wi-Fi. (Google, 2025d)

Como qualquer sinal enviado em um meio de comunicação, os sinais de microondas sofrem atenuação, ou seja, perda de potência de sinal devido à transmissão. No caso da propagação de microondas, dois fatores influenciam na perda desta potência: a distribuição do sinal no espaço durante a transmissão; e a capacidade da antena de recepção de captar o sinal. Sempre que o sinal é propagado, espalha-se no espaço conforme o ângulos de abertura da antena de transmissão. A potência do sinal é distribuída na área de propagação até atingir a antena de recepção (Peres 2010, p. 20).

Figura 4. Índice de atenuação em dB por metro para micro-ondas a 2,4GHz e 5,7GHz (Peres, 2010)



2.2 Sistema Global de Navegação por Satélite (GNSS)

Conforme dito por Hofmann-Wellenhof, Lichtenegger e Wasle (2008), GNSS (Global Navigation Satellite System) é um termo definido como um sistema de posicionamento por rádio baseado no espaço, que pode incluir uma ou mais constelações de satélites (eventualmente com sistemas de aumento/auxílio), com a função de fornecer informações de posição tridimensional, velocidade e tempo, 24 horas por dia, a usuários adequadamente equipados em qualquer lugar da superfície terrestre.

O ponto central é que o GNSS não se limita a um único sistema, mas sim a um conjunto de sistemas globais de navegação por satélite. Exemplos incluem o GPS, o GLONASS, e o Galileo. (Hofmann-Wellenhof; Lichtenegger; Wasle. 2008)

2.2.1 Assistance - GPS (A-GPS)

O Assisted Global Positioning System (A-GPS) foi desenvolvido para superar limitações do GPS convencional, que apresenta tempo de inicialização elevado, em torno de um minuto, e baixa confiabilidade em aplicações

civis que exigem posicionamento imediato, inclusive em ambientes internos. Tais restrições decorrem da fraca intensidade dos sinais de satélite e do tempo necessário para localizar e decodificar as informações orbitais de cada um deles. O A-GPS mitiga esse problema ao fornecer dados de assistência, como posições de satélite e frequências previstas, por meio de canais de comunicação rápidos, como redes celulares, o que não substitui a recepção dos sinais, mas acelera sua aquisição, reduzindo o tempo para a primeira fixação de minutos para segundos e aumentando a sensibilidade do sistema, possibilitando seu funcionamento em cenários mais desafiadores. (Diggelen, 2009)

Existem duas abordagens principais para o GPS assistido, conhecidas como GPS assistido por MS e GPS baseado em MS. "MS" significa estação móvel, ou seja, o receptor GPS. No GPS assistido por MS, a posição é calculada em um servidor, e a função do receptor GPS é apenas adquirir os sinais e enviar as medições para o servidor. No GPS baseado em MS, a posição é calculada pelo próprio receptor. Essa distinção primária leva a outras distinções. Se o receptor não for calcular a posição, ele não precisa necessariamente de dados de órbita de satélite (como um almanaque ou efemérides). É possível mantê-los no servidor, e o servidor pode calcular diretamente os dados de assistência de aquisição e enviá-los ao receptor. (Diggelen, 2009, p. 43, tradução própria "1")

2.2.2 Aplicação da Geolocalização na Coleta de Dados Espaciais

O método de posicionamento absoluto, no qual o receptor calcula suas coordenadas de forma autônoma a partir dos sinais recebidos de, no mínimo, quatro satélites da constelação GNSS. Conforme detalhado por Hofmann-Wellenhof, Lichtenegger e Wasle (2008), este princípio baseia-se na medição das pseudodistâncias aos satélites para determinar uma posição tridimensional na superfície terrestre.


2.3 Arquitetura Android baseada no kernel Linux

O Android adota o kernel Linux como a camada fundamental de sua arquitetura de software, a qual pode ser observada na Figura 5, atuando como uma camada de abstração entre o hardware do dispositivo e o restante da pilha de softwares. Essa base Linux é responsável por gerenciar componentes essenciais do sistema, como gerenciamento de memória, processos, segurança e, crucialmente para este projeto, os drivers de rede, incluindo o da interface Wi-Fi. Acima do kernel, a Camada de Abstração de Hardware (HAL) fornece uma interface padrão que expõe os recursos de hardware para o framework de aplicativos, independentemente das particularidades do hardware. (Google, 2025a).

Conforme define a Google (2025a) na documentação oficial do Android:

Uma camada de abstração de hardware (HAL) é um tipo de camada de abstração com uma interface padrão para implementação por fornecedores de hardware. Um HAL permite que os fornecedores de hardware implementem recursos de nível mais baixo e específicos do dispositivo sem afetar ou modificar o código em camadas de nível mais alto.

Figura 5. Arquitetura Android (Google, 2025b)



Embora utilize o kernel Linux, o Android não é uma distribuição Linux tradicional. Desenvolvido pela Open Handset Alliance, liderada pelo Google, e mantido pelo Android Open Source Project (AOSP), o sistema foi otimizado para dispositivos móveis. Diferentemente das distribuições de desktop, o Android não incorpora o sistema X Window nem as bibliotecas GNU padrão, como a Glibc. Em seu lugar, utiliza sua própria biblioteca C, chamada Bionic, e um ambiente de execução otimizado (ART) para os aplicativos que são majoritariamente escritos em Java ou Kotlin. (Al-Rayes, 2012).

2.3.1 Interface Wi-Fi no Android


A base Linux do Android oferece vantagens significativas para tarefas que envolvem análise de rede, possibilitando acesso de baixo nível às interfaces de rede e fornecendo uma base flexível para o monitoramento e gerenciamento de conexões, a arquitetura e as camadas de acesso podem ser visualizadas na Figura 6 (Google, 2025b).

Isto é reforçado pelo modo como é estruturada a comunicação da API em Java com a camada em C/C++ e HAL, como descrito por Tanenbaum e Bos, (2016, p. 558):

Uma parte significativa do sistema operacional Android é escrita em uma linguagem de alto nível, a linguagem de programação Java. O núcleo e um grande número de bibliotecas de baixo nível são escritos em C e C++. No entanto, uma grande parte do sistema é escrita em Java e, com algumas poucas exceções, toda a API para aplicações é escrita e publicada em Java também. As partes do Android escritas em Java tendem a seguir um projeto bastante orientado a objetos como encorajado por aquela linguagem.

O framework de aplicativos do Android disponibiliza APIs ricas que permitem aos desenvolvedores acessar informações detalhadas sobre a conexão Wi-Fi, como o RSSI, SSID, BSSID, canal, largura do canal, método de segurança, geração do padrão IEEE, entre outras. (Google, 2025d).

Figura 6. Arquitetura Wi-Fi Android (Google, 2025c)



2.4 Interpolação de Dados Espaciais para Estimativa de Valores

Câmara, Davis e Monteiro (2001) definem a interpolação espacial como um conjunto de técnicas para estimar valores em locais não amostrados a partir de um conjunto de pontos conhecidos, o que é fundamental para a criação de superfícies contínuas.

A coleta de dados produz um conjunto de pontos discretos, onde cada ponto é definido por uma coordenada (x, y) e um valor de intensidade de sinal (z). A interpolação espacial é uma técnica estatística utilizada para estimar os valores de sinal em locais não amostrados, gerando uma superfície contínua a partir dos pontos discretos. Esse processo é vital para gerar uma visualização completa da cobertura de sinal em toda a área de interesse, e não apenas nos locais onde as medições foram realizadas. (Câmara; Davis; Monteiro, 2001):

Um 15spect central no uso da tecnologia de Geoprocessamento advém da característica lógico-matemática de sistemas de informação; para ser representada em ambiente computacional, temos de associar a cada tipo de informação geográfica uma escala de medida e de referência, que será utilizada pelo GIS para caracterizá-lo. (Câmara; Davis; Monteiro, 2001).

2.4.1 Método de estimação de densidade: Kernel Density Estimation (KDE)


A Estimação de Densidade por Kernel (KDE), introduzida por Parzen (1962), é uma metodologia não-paramétrica consagrada para estimar a função de densidade de probabilidade de um conjunto de dados. Por ser não-paramétrica, essa abordagem não assume uma distribuição subjacente específica para os dados, baseando-se no uso de uma função kernel para construir uma estimativa suave e consistente. Conforme destacado por Turlach (1999), uma de suas aplicações mais importantes é a suavização de dados.

Assim como o estimador ingênuo pode ser considerado uma soma de 'caixas' centradas nas observações, o estimador kernel é uma soma de 'lombadas' posicionadas nas observações. A função kernel K determina o formato das lombadas, enquanto a largura da estimativa h determina a sua largura. [...], na qual são mostradas tanto as lombadas individuais $\frac{1}{n}K\{(x - X_i)/h\}$ quanto a estimativa final construída pela soma delas. (Silverman, 1986).

A Figura 7 ilustra as lombadas individuais descritas por Silverman (1986), onde o cálculo da somatória dos Kernels pode ser representada da seguinte maneira:

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right)$$

Figura 7. Estimativa do kernel mostrando kernels individuais (Silverman, 1986)



O KDE apresenta propriedades de suavidade superiores aos estimadores discretos, permitindo a análise de estruturas locais da distribuição com maior sensibilidade matemática. Conforme detalhado por Scott (2015), o uso de kernels diferenciáveis garante a obtenção de derivadas contínuas da densidade estimada, o que viabiliza aplicações mais avançadas, tais como análise de curvatura, identificação de máximos locais e estimativas do gradiente de densidade. Esses atributos tornam a técnica particularmente adequada para problemas em que a topologia da distribuição desempenha papel central, permitindo a refinação acerca de modos de concentração e regiões de rarefação de eventos observados.

Silverman (1986) demonstra que a utilização de kernels com suporte infinito, como o Gaussiano, tende a produzir estimativas com propriedades assintóticas desejáveis, convergindo pontualmente para a verdadeira densidade conforme o tamanho amostral cresce. Além disso, sob determinadas condições de suavidade, o KDE é consistente, ou seja, a probabilidade de a estimativa se afastar da densidade real converge para zero à medida que o número de observações aumenta (Wand; Jones, 1995). Esse comportamento evidencia a robustez do estimador, tornando-o aplicável tanto em contextos exploratórios quanto inferenciais.

2.4.2 Mapas de calor como ferramenta de visualização


Mapas de calor são amplamente utilizados como ferramenta para representar a amplitude de valores em espaços bidimensionais, onde cores são empregadas para indicar intensidades relativas. Essa abordagem facilita a identificação de padrões, clusters e tendências em conjuntos de dados complexos, sendo útil em áreas como análise geoespacial, epidemiologia, astrofísica, engenharia e monitoramento ambiental. Ao traduzir grande volume de informação numérica em gradientes colorimétricos, o mapa de calor permite uma interpretação intuitiva, reduzindo a carga cognitiva do observador (Tuft, 2007).

Para geração dessa representação contínua, um dos métodos mais consolidados é a Estimção de Densidade por Kernel (KDE), responsável por suavizar a distribuição de pontos discretos em uma superfície rasterizada. O KDE calcula a densidade de valores em regiões específicas, reduzindo ruídos locais e destacando tendências de amplitude ao longo de uma superfície. Após a geração do raster, aplica-se uma paleta cromática para realçar visualmente variações, produzindo camadas que podem ser sobrepostas a mapas ou modelos espaciais, permitindo análises rápidas e consistentes (Silverman, 1986).

A escolha do mapa de calor exerce impacto significativo na interpretação dos resultados. Por décadas, gradientes do tipo rainbow, espalhados por diversos matizes, foram amplamente adotados, porém, estudos demonstram que suas transições abruptas e variação irregular de luminância podem introduzir erros interpretativos, induzindo o observador a perceber limites inexistentes ou hierarquias distorcidas (Borland; Li, 2007). Entretanto, quando projetados com cuidados perceptuais, esses mapas de cores podem ser eficazes para tarefas específicas, como segmentação visual e detecção de fronteiras (Ware; Stone; Szafir, 2023).

Em resposta às limitações perceptuais do rainbow, foram propostos mapas de calor cientificamente calibrados, como o magma, inferno, plasma, viridis e cividis. Pode-se visualizar cada gradiente na Figura 8, desenvolvidos com luminância monotônica e ordenação perceptual estável. Esses gradientes são resultado de estudos em psicofísica e percepção humana, reduzindo ambiguidades entre níveis próximos e aumentando a acessibilidade para indivíduos com daltonismo (Nuñez; Anderton; Renslow, 2018). Sua construção é guiada por modelos perceptuais avançados, como o CIECAM02 proposto pela Comissão Internacional de Iluminação (CIE), que aproximam a visualização da resposta humana real (Tasht et al., 2005).

Figura 8. Gradiente de cores (Czaplicki, 2018)

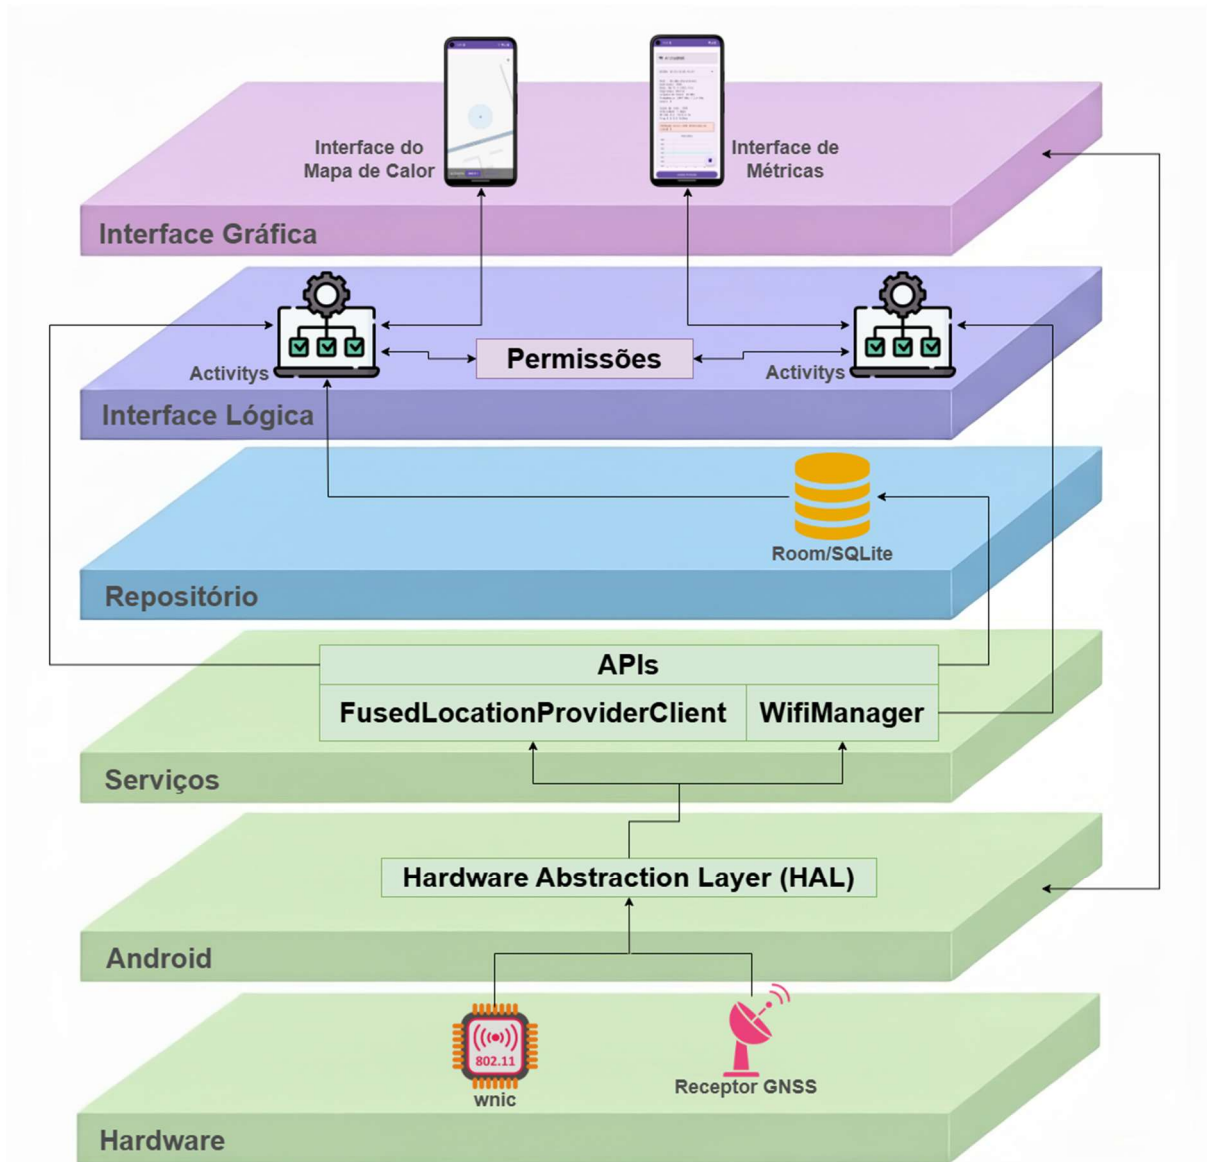


3. RESULTADOS E DISCUSSÃO

A fim de facilitar o diagnóstico da má qualidade de sinal para a população brasileira como um todo, foi desenvolvida uma aplicação que, ao utilizar recursos presentes em qualquer celular android, consegue exibir dados, gráficos e mapas de calor que podem ser facilmente analisados e transformados em informações precisas para detectar pontos de sombra e atenuação do sinal em ambientes residenciais, agropecuários ou industriais.

O sistema foi construído baseado nos princípios de separação de responsabilidade, conforme diagramado na Figura 9. As classes de serviço realizam requisições para o HAL, que retorna os dados às classes lógicas para processamento e, posteriormente, para a interface gráfica. Esta utiliza as informações tanto para gerar medições e gráficos quanto para plotá-las no mapa e produzir o mapa de calor. Paralelamente, os dados são armazenados no banco de dados Room para consultas futuras. Essa arquitetura modular possibilita que a aplicação execute duas funcionalidades distintas: um diagnóstico instantâneo das métricas e um mapeamento contínuo, de forma organizada e reaproveitando componentes essenciais. Dessa forma, é possível estruturar a aplicação em três camadas principais.

Para o desenvolvimento da aplicação, utilizou-se a IDE Android Studio. A linguagem de programação adotada foi o Java, selecionada devido à sua robustez e ampla consolidação internacional.

Figura 9. Arquitetura da aplicação

3.4 Interfaces

O aplicativo possui 2 interfaces principais, Métricas e Mapa de Calor, sendo imprescindivelmente necessário passar pela interface de métricas em sua inicialização, pois neste momento será avaliado qual SSID e BSSID estão próximos do aparelho celular e as informações que eles recebem provenientes dos pontos de acesso, sendo liberado a interface do mapa de calor apenas após esta validação.


3.4.1 Interface de Métricas

A interface de Métricas oferece uma análise detalhada do ambiente de radiofrequência local. Ela permite ao usuário inspecionar redes vizinhas (SSIDs e BSSIDs) e avaliar profundamente a conexão atual. São exibidos parâmetros técnicos essenciais, como a força do sinal (RSSI), o modo Wi-Fi, o tipo de segurança, a frequência,

o canal e sua largura. Além disso, a interface fornece métricas de desempenho, como a velocidade da rede (Mbps), e informações de diagnóstico de conectividade, incluindo o IP do dispositivo e um teste de verificação de acesso ao DNS do Google (8.8.8.8).

Através de fórmulas a aplicação calcula a Qualidade e Saúde da rede, e automaticamente analisa possíveis colisões de canais, é possível verificar de maneira dinâmica e gráfica a velocidade da rede e o RSSI. Isto tudo está organizado em lista, como exibido na Figura 10, para facilitar o uso do sistema.


Figura 10. Layout interface de métricas



3.4.2 Interface de Mapa de Calor

A interface de Mapa de Calor, a funcionalidade central deste trabalho, é o módulo de mapeamento, ilustrado na Figura 11. Esta tela é dominada por um componente interativo do Google Maps. A interface permite ao usuário carregar uma imagem da planta baixa, visualizar sua localização em tempo real via A-GPS e controlar a coleta de dados através dos botões "Iniciar" e "Parar". Após a coleta, o mapa de calor é renderizado e sobreposto ao mapa base e à planta baixa, fornecendo a visualização do mesmo.

Figura 11. Layout interface de mapa de calor



3.2 Camada Interface Lógica

A Camada de Interface Lógica orquestra o fluxo de dados entre a Interface Gráfica (View) e as camadas inferiores de Repositório e de Serviços. Esta camada é implementada seguindo o padrão de arquitetura MVVM (Model-View-ViewModel), que desacopla a lógica de negócio da interface do usuário, resultando em um código mais modular, testável e de fácil manutenção.

3.2.1 Lógica do Mapa de Calor

As classes centrais são a *SurveyActivity* e o *SurveyViewModel*. A *SurveyActivity* desempenha o papel de controlador da Interface de Usuário (View), assumindo a responsabilidade por inflar o layout, gerenciar o ciclo de vida da atividade e renderizar o mapa do Google Maps. Além disso, ela captura as interações diretas do usuário.

Em contrapartida, o *SurveyViewModel* constitui o núcleo lógico da tela. Este componente é encarregado de manter o estado da aplicação, possuindo a capacidade de sobreviver a mudanças de configuração, como a rotação do dispositivo. É o *SurveyViewModel* que orquestra as operações de segunda plano, comunicando-se diretamente com o *LocationProvider* para a obtenção de coordenadas e com o *WifiService* para a leitura do RSSI, assegurando, assim, que a *SurveyActivity* permaneça estritamente focada na camada de apresentação dos dados.

3.2.2 Lógica de Métricas

A MetricsActivity constitui o segundo pilar da Interface Lógica, atuando como a View, responsável por exibir as informações, enquanto a MetricsViewModel se encarrega de buscar e preparar os dados. A lógica de obtenção dos dados é centralizada na classe de serviço WifiService.

O fluxo de trabalho para a exibição das métricas inicia-se com a requisição de dados ao abrir a MetricsActivity, momento em que o ViewModel é instruído a carregar as informações de rede mais recentes. Para compilar um relatório de diagnóstico completo, o ViewModel invoca uma série de métodos específicos do WifiService. A chamada primária é feita através de wifiService.getCurrentConnection(), utilizada para obter um objeto WifiInfo que agrega dados essenciais das camadas física e de enlace, tais como a intensidade do sinal (RSSI), a velocidade do link, o SSID e o BSSID do ponto de acesso.

Por fim, a etapa de apresentação na interface gráfica consolida o padrão de arquitetura reativa. O ViewModel expõe as informações processadas através de objetos LiveData, os quais são observados continuamente pela MetricsActivity. Ao detectar qualquer alteração nos dados emitidos, a Activity atualiza os gráficos na tela.

3.2.3 Gerenciamento de Permissões

A funcionalidade central do aplicativo depende do acesso a dados sensíveis do dispositivo: a localização precisa e as informações da rede Wi-Fi. O sistema operacional Android, por questões de privacidade e segurança, exige que o usuário conceda permissão explícita em tempo de execução para esses acessos. As permissões necessárias são declaradas no AndroidManifest.xml, seguindo as diretrizes da arquitetura Android.

As permissões ACCESS_FINE_LOCATION, ACCESS_WIFI_STATE, ACCESS_NETWORK_STATE são necessárias para que o FusedLocationProviderClient acesse os dados do receptor GNSS, e que o WifiManager, em versões mais recentes do Android, possa retornar informações detalhadas como o RSSI da conexão atual.

O gerenciamento dessas permissões é tratado na SurveyActivity através de uma abordagem moderna utilizando ActivityResultLauncher. O método checkLocationPermission() verifica se a permissão já foi concedida. Caso contrário, ele lança o requestPermissionLauncher, que exibe a caixa de diálogo padrão do Android para o usuário.

3.2.4 Plotagem dos Dados

Os dados brutos coletados pelas APIs não possuem valor informativo direto até serem processados, correlacionados e organizados visualmente. O processo se inicia na coleta, onde a cada atualização de localização recebida do FusedLocationProviderClient, a camada lógica da interface gráfica executa duas ações imediatas: captura as coordenadas (latitude e longitude) do telemóvel e invoca o WifiService para obter o RSSI da rede conectada naquele exato instante.

Esses três dados, latitude, longitude e RSSI, são então encapsulados em uma entidade e enviados ao banco de dados Room/SQLite utilizando persistência assíncrona para não bloquear a execução do programa.

Após a finalização da coleta de dados, o processo de renderização visual é iniciado. A primeira etapa consiste em consultar a base de dados Room para recuperar a lista completa de todos os pontos de medição

associados ao survey atual. A aplicação executa um algoritmo de interpolação espacial. Este método calcula os limites geográficos da coleta e cria uma grade de alta resolução. O valor de cada célula nesta grade é então determinado como uma média ponderada do RSSI dos pontos de dados reais mais próximos, conferindo maior peso aos mesmos.

Com a grade interpolada, é invocada uma função para traduzir essa matriz de valores em um bitmap pixelado, onde cada valor de RSSI é mapeado para uma cor ARGB específica. Para transformar esta grade de blocos em uma superfície suave e contínua, são aplicados os conceitos de Estimativa de Densidade por Kernel (KDE). Esta etapa utiliza o `ScriptIntrinsicBlur` do Android para aplicar um filtro de kernel gaussiano sobre o bitmap, criando uma estimativa de densidade sobre a influência de cada ponto, assim suavizando as transições.

Observando a Figura 12, é possível visualizar o mapa de calor gerado pela aplicação. O círculo roxo indica a posição do ponto de acesso, servindo como referência para interpretação. Nota-se que o pilar ao lado atua como obstáculo físico, atenuando o sinal. Na área oposta ao ponto de acesso, o nível de potência aproximou-se de -80 dBm, caracterizando baixa intensidade, enquanto nas regiões mais próximas da fonte os valores ficaram em torno de -30 dBm, evidenciando forte recepção.

Figura 12. Plotagem mapa de calor



3.3 Camada de Repositório


A Camada de Repositório, posicionada entre a Camada Lógica e a fonte de dados persistente, é a espinha dorsal da estratégia de gerenciamento de dados da aplicação. Ela implementa o padrão de projeto `Repository`, que atua como um mediador entre o domínio da aplicação e as fontes de dados. Conforme o diagrama de arquitetura, seu papel principal é abstrair o acesso ao banco de dados `Room/SQLite`, fornecendo uma interface de dados limpa e coesa para a Camada Lógica.

Ao fazer isso, o repositório estabelece o princípio da "Fonte Única de Verdade" (`Single Source of Truth`) para todos os dados persistidos. Isso significa que a Camada Lógica não precisa se preocupar com os detalhes de como os dados são armazenados, consultados ou atualizados, ela apenas se comunica com o repositório. A Figura 13 representa as tabelas e os relacionamentos utilizados para armazenar nossos dados.

A persistência de dados no projeto é gerenciada pela biblioteca `Room`, que é a camada de abstração recomendada pelo Google sobre o `SQLite`. O `Room` simplifica o trabalho com o banco de dados, fornecendo verificação de consultas em tempo de compilação e convertendo objetos Java em registros do banco de dados com o mínimo de código boilerplate.

A implementação da Camada de Repositório é materializada na classe SurveyRepository. Esta classe não interage diretamente com o SQLite, mas sim com os DAOs (Data Access Objects) definidos pela biblioteca Room. Os DAOs são interfaces que mapeiam chamadas de método para consultas SQL.

Figura 13. Diagrama de relacionamentos das tabelas do aplicativo



3.4 Camada de Serviços

A Camada de Serviços atua como uma interface direta para as APIs do sistema operacional e os serviços Google. Esta camada é a de mais baixo nível dentro da lógica da aplicação, sendo sua principal responsabilidade isolar o restante do código da complexidade de interagir com o hardware do dispositivo, como o módulo Wi-Fi (WNIC) e o receptor GNSS.

Toda interação com o hardware é mediada pelo sistema através da Camada de Abstração de Hardware (HAL). As duas APIs consumidas por esta camada são o FusedLocationProviderClient e a WifiManager.

3.4.1 Abstração do Posicionamento Geográfico

A implementação desta funcionalidade está encapsulada na classe LocationProvider. Esta classe serve como um wrapper e simplificador para a complexa API de localização.

A inicialização do componente ocorre no construtor da classe, onde uma instância do FusedLocationProviderClient é obtida através de LocationServices.getFusedLocationProviderClient(). O comportamento dessa coleta é, então, finamente ajustado por meio de um objeto LocationRequest. No código, utiliza-se o método new LocationRequest.Builder() para definir parâmetros críticos ao levantamento, como o Priority.PRIORITY_HIGH_ACCURACY, que instrui o sistema a priorizar o GNSS para garantir a precisão necessária ao mapeamento de calor. Adicionalmente, são configurados filtros de otimização como o setMinUpdateIntervalMillis(), que evita a sobrecarga do sistema, e o setMinUpdateDistanceMeters(), um parâmetro crucial que restringe a entrega de novas coordenadas apenas quando o dispositivo se desloca uma distância mínima, eliminando redundâncias na coleta.

A operação principal reside na chamada `fusedLocationClient.requestLocationUpdates()`. Este método registra um `LocationCallback` junto ao sistema operacional, que passa a ser invocado de forma assíncrona sempre que uma nova localização satisfaz os critérios definidos no `LocationRequest`. Esse modelo garante que a aplicação não precise solicitar ativamente a posição, mas sim reagir a eventos do sistema.

3.4.2 Interface com o Hardware Wi-Fi

A classe `WifiService` atua como uma fachada (Facade Pattern), provendo um conjunto de métodos diretos e coesos que ocultam os detalhes de implementação do `WifiManager`.

A inicialização da classe `WifiService` ocorre mediante a obtenção de uma instância do `WifiManager`, acessada através do serviço de sistema `context.getSystemService(Context.WIFI_SERVICE)`. Dentre as funcionalidades implementadas, destaca-se o método `getCurrentRssi()`, considerado crítico para a geração do mapa de calor. Internamente, este método executa a chamada síncrona `wifiManager.getConnectionInfo().getRssi()`, que acessa a Camada de Abstração de Hardware (HAL) para consultar diretamente o driver da interface WNIC. O retorno é a intensidade do sinal recebido (RSSI) em dBm (decibel-miliwatt) da rede conectada, sendo este procedimento invocado a cada nova coordenada geográfica registrada durante o levantamento.

Além da medição pura de sinal, o serviço fornece suporte essencial à interface de diagnósticos de rede por meio de métodos complementares. O `getCurrentConnection()`, utilizado primariamente pela interface de Métricas, retorna o objeto `WifiInfo` completo, um agregado de dados que inclui não apenas o RSSI, mas também a velocidade do link, o SSID, o BSSID o endereço IP do dispositivo e o endereço do gateway.

3.5 Camada Android

A Camada de Abstração de Hardware (HAL) representa o elo de conexão entre o código do sistema operacional e as especificidades proprietárias dos fabricantes, garantindo assim a portabilidade da aplicação. O Android, através do AOSP (Android Open Source Project), define apenas as interfaces padrão, conhecidas como HIDL ou AIDL, estabelecendo um contrato de software que determina quais funções de Wi-Fi e GPS devem ser expostas.

Cabe a cada fabricante de dispositivo ou fornecedor de chipset desenvolver a implementação concreta dessa HAL para seu respectivo hardware. É dentro dessas bibliotecas compartilhadas, construídas pelos fabricantes, que residem os comandos específicos para acionar os drivers proprietários do kernel Linux.

Essa arquitetura é fundamental, pois isola a lógica do aplicativo das variações de implementação de hardware. Embora a sensibilidade física da antena varie, a camada HAL assegura que a entrega dos objetos de dados para o framework Java siga estritamente o protocolo definido pelo Google. Isso permite que a aplicação execute as chamadas de API sem necessitar de adaptações de código para diferentes modelos de celular, confiando que a fabricante implementou corretamente as diretrizes da interface de varredura e localização do Android.

3.5.1 APIs Android

A interação da camada lógica com os recursos do sistema ocorre por meio de APIs nativas, escolha que impactou diretamente a performance e a precisão dos dados visualizados.

Para a análise de redes, a utilização da classe `WifiManager` do android de forma nativa permitiu acesso direto aos objetos `ScanResult`. O funcionamento dessa API é assíncrono e sujeito às políticas de economia de energia do Android, uma limitação conhecida como Wi-Fi Scan Throttling. Isso significa que a atualização do mapa de calor não é contínua em tempo real, mas sim discreta, baseada na frequência de varreduras permitidas pelo sistema operacional. O aplicativo foi desenvolvido respeitando esses intervalos para garantir que cada ponto plotado no mapa representasse uma leitura de espectro válida e atualizada, evitando a repetição de dados em cache.

Quanto ao posicionamento, optou-se pelo `FusedLocationProviderClient` do Google Play Services, em detrimento do antigo `LocationManager`. Esta escolha técnica é a responsável pela viabilidade do uso da ferramenta em ambientes indoor. Enquanto o `LocationManager` tradicional depende quase exclusivamente da visibilidade direta de satélites, a API `FusedLocationProviderClient` implementa algoritmos de fusão de sensores. Ela combina os dados brutos do GNSS com sinais de radiofrequência (triangulação de antenas celulares e pontos Wi-Fi conhecidos) e sensores inerciais, como o acelerômetro e o giroscópio. O resultado é uma convergência de posição mais rápida e uma estabilidade maior do marcador no mapa, reduzindo o jitter da localização durante o deslocamento para a coleta das métricas, permitindo que o aplicativo registre coordenadas de latitude e longitude válidas mesmo em zonas de sombra de GPS.

3.6 Camada Hardware

A aplicação desenvolvida não recorre a simulações estocásticas ou modelos preditivos teóricos para inferir a cobertura de sinal. Para que os resultados apresentados nas seções anteriores fossem gerados, houve uma interação contínua entre a camada de software e os componentes físicos do dispositivo móvel.

Todos os dados brutos de radiofrequência originam-se na Wireless Network Interface Controller (WNIC). A WNIC atua não apenas como interface de comunicação, mas também como um sensor de espectro. Ao receber a solicitação de scan via `WifiManager`, na camada de Serviços, o hardware alterna entre os canais das frequências de 2.4GHz e 5GHz definidos pelo padrão IEEE 802.11. Durante esse processo de varredura, a WNIC captura os Pacotes de Sinalização emitidos pelos Access Points. O valor de RSSI exibido no aplicativo é uma representação digital da energia de radiofrequência medida pelo circuito de rádio no preâmbulo do pacote recebido. É importante notar que a conversão dessa energia física para uma unidade inteira (por exemplo, -65 dBm) ocorre no firmware do chipset e é exposta ao Android via HAL, garantindo que o mapa de calor reflita a sensibilidade real da antena do dispositivo utilizado no levantamento.

Paralelamente, a captura de geolocalização envolve o uso de um receptor Global Navigation Satellite System (GNSS). Para a plotagem dos pontos no mapa, o receptor realiza cálculos de trilateração baseados no tempo de voo dos sinais de satélites. No entanto, ambientes indoor impõem barreiras físicas que atenuam o sinal de satélite.

É reconhecido que limitações inerentes ao hardware, como variações no design da antena, na sensibilidade do chipset (Rsens) entre diferentes fabricantes ou a degradação da precisão do GNSS em ambientes fechados, são fatores presentes que influenciam a coleta. Contudo, tais variações validam o propósito da ferramenta: aferir a experiência real do dispositivo cliente naquele ambiente específico, ao invés de projetar um cenário idealizado.

4. CONSIDERAÇÕES FINAIS

A problemática investigada foi desenvolvida com a aplicação de técnicas de mapeamento da intensidade de sinais Wi-Fi, integrando dados de geolocalização para gerar representações visuais que solucionassem a dificuldade do diagnóstico empírico de cobertura, através de um método proposto que correlacionasse valores de RSSI com coordenadas geográficas para produzir mapas de calor, substituindo a percepção subjetiva do usuário por uma análise técnica.

A aplicação demonstrou ser capaz de renderizar mapas de calor que identificaram com sucesso as zonas de sombra e a atenuação causada por obstáculos físicos, distinguindo áreas de recepção forte de áreas fracas. Resultando em uma ferramenta funcional que transforma a análise subjetiva da qualidade do sinal em um diagnóstico técnico, visual e georreferenciado. Também oferece também uma análise micro sobre o ambiente de radiofrequência, a qual permite ao usuário inspecionar o cenário local, exibindo redes vizinhas (SSIDs e BSSIDs), enquanto aprofunda a avaliação da conexão ativa através de parâmetros técnicos essenciais.

Para futuras versões do projeto, vislumbra-se um conjunto de melhorias focadas em aumentar a precisão tanto da geolocalização quanto da coleta de dados e do mapeamento ambiental. Considera-se a substituição da biblioteca de mapeamento, visto que o Google Maps se mostrou impreciso em certos pontos, uma alternativa viável seria a migração para a biblioteca osmdroid, uma solução open-source que utiliza o OpenStreetMap. Embora em testes iniciais tenha ofertado menos recursos, garante maior precisão e possibilita contribuições para sua melhoria. Além disso, para um enriquecimento significativo dos resultados, a incorporação de um sensor LiDAR, potencialmente integrada a bibliotecas de SLAM como o Google Cartographer, possibilitaria o mapeamento ao vivo da estrutura interna do ambiente, adicionando um grande nível de detalhe ao mapa e permitindo uma compreensão muito mais precisa de como a distribuição do sinal Wi-Fi é afetada por obstáculos físicos. Em paralelo, para a extração de dados de rede, avalia-se que, apesar da capacidade da arquitetura Android, ferramentas dedicadas como o Kali Linux ARM integrado a uma placa Raspberry Pi com módulos de antena devidamente configurados, entregaria uma medição precisa a nível de Jitter, conseguindo diagnosticar problemas de rede avançados e mantendo a mesma portabilidade que o aparelho celular no proporciona.

REFERÊNCIAS BIBLIOGRÁFICAS

AGÊNCIA NACIONAL DE TELECOMUNICAÇÕES. Resolução nº 715, de 23 de outubro de 2019. Resolução nº 715, de 23 de outubro de 2019 Aprova o Regulamento de Avaliação da Conformidade e de Homologação de Produtos para Telecomunicações. Resolução nº 715, de 23 de outubro de 2019, Brasil, 24 out. 2019. Disponível em: <https://informacoes.anatel.gov.br/legislacao/resolucoes/2019/1350-resolucao-715>. Acesso em: 1 set. 2025.

AL-RAYES, Hadeel Tariq. Studying Main Differences between Android & Linux Operating Systems. International Journal of Electrical & Computer Sciences, [S. l.], v. 12, n. 05, p. 46-49, out. 2012. Disponível em: https://www.researchgate.net/profile/Hadeel-Al-Rayes/publication/328125274_Studying_Main_Differences_between_Android_Linux_Operating_Systems/links/5c7424c8299bf1268d25999b/Studying-Main-Differences-between-Android-Linux-Operating-Systems.pdf?origin=publication_detail&_tp=eyJjb250ZXh0Ijp7ImZpcnN0UGFnZSI6InB1YmxpY2F0aW9uliwicGFnZSI6InB1YmxpY2F0aW9uRG93bmxxYVWQILCJwcmV2aW91c1BhZ2UiOiJwdWJsaWNhdGlvbiJ9fQ&__cf_chl_tk=ltpc88iNVj0PV8WFCFmqll0pefmRLB2RDnVw4zjqNLI-1759286758-1.0.1.1-aOdq6WwRy9BTfdted8m8zGiDwlJTqdBLsDfinNHPO_0. Acesso em: 23 set. 2025.

BORLAND, David; II, Russell M. Taylor. Rainbow Color Map (Still) Considered Harmful. IEEE Computer Graphics and Applications, [s. l.], v. 27, ed. 2, p. 14-17, maio-abril 2007. DOI 10.1109/MCG.2007.323435. Disponível em: <https://ieeexplore.ieee.org/abstract/document/4118486>. Acesso em: 27 out. 2025.

CÂMARA, Gilberto; DAVIS, Clodoveu. MONTEIRO, Antônio Miguel Vieira Introdução à ciência da geoinformação. Brasil: [s. n.], 2001. 345 p. Disponível em: <http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2004/04.22.07.43/doc/publicacao.pdf>. Acesso em: 26 set. 2025.

CISCO. Protocolos básicos de rede na compreensão do modelo OSI. 2023. Disponível em: <https://community.cisco.com/t5/artigos-gerais/protocolos-básicos-de-rede-na-compreensão-do-modelo-osi/ta-p/4802414>. Acesso em: 26 sep. 2025.

COLEMAN, David. 2.4 GHz Channel Planning. 2012. Disponível em: <https://www.extremenetworks.com/resources/blogs/2-4-ghz-channel-planning>. Acesso em: 20 sep. 2025.

CZAPLICKI, Evan. Elm Colormaps. Elm Packages, 2018. Disponível em: <https://package.elm-lang.org/packages/2mol/elm-colormaps/latest>. Acesso em: 28 out. 2025.

DIGGELEN, Frank Van. A-GPS: Assisted GPS, GNSS, and SBAS. Boston: [s. n.], 2009. 380 p. ISBN 978-1-59693-374-3. Disponível em: https://www.academia.edu/40813112/A_GPS_Assisted_GPS_GNSS_and_SBAS_By_Frank_van_Diggelen. Acesso em: 1 out. 2025.

GOOGLE. Visão geral da camada de abstração de hardware (HAL). In: GOOGLE. AOSP. [S. l.], 27 jul. 2025a. Disponível em: <https://source.android.com/docs/core/architecture/hal?hl=pt-br>. Acesso em: 23 set. 2025.

GOOGLE. Visão geral da arquitetura. In: GOOGLE. AOSP. [S. l.], 2 out. 2025b. Disponível em: <https://source.android.com/docs/core/architecture?hl=pt-br>. Acesso em: 24 jul. 2025.

GOOGLE. Wi-Fi. In: GOOGLE. AOSP. [S. l.], 27 jul. 2025c. Disponível em: <https://source.android.com/docs/core/ota/modular-system/wifi?hl=pt-br>. Acesso em: 23 set. 2025.

GOOGLE. WifiManager. In: GOOGLE. Android Developers. [S. l.], 20 ago. 2025d. Disponível em: https://developer.android.com/reference/android/net/wifi/WifiManager#ACTION_PICK_WIFI_NETWORK. Acesso em: 23 set. 2025.

GOV.BR (Brasil). IBGE; BELLO, Luiz. No Brasil, 88,9% da população de 10 anos ou mais tinha celular em 2024. Brasil: Luiz Bello, 24 jul. 2024. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/44032-no-brasil-88-9-da-populacao-de-10-anos-ou-mais-tinha-celular-em-2024>. Acesso em: 10 set. 2025.

HOFMANN-WELLENHOF, Bernhard. LICHTENEGGER, Herbert. WASLE, Elmar. GNSS – Global Navigation Satellite Systems: GPS, GLONASS, Galileo, and more. Áustria: [s. n.], 2008. 516 p. ISBN 978-3-211-73012-6. Disponível em: <https://sciarium.com/file/78994>. Acesso em: 25 set. 2025.

IEEE STANDARDS ASSOCIATION. The Evolution of Wi-Fi Technology and Standards. [S. l.], 16 maio 2023. Disponível em: <https://standards.ieee.org/beyond-standards/the-evolution-of-wi-fi-technology-and-standards>. Acesso em: 15 ago. 2025.

MORAES, Filipe; SILVA, Thiago; CEOLIN, Simone Regina; AZEVEDO, Renato Preigschadt. Análise e Otimização de Rede Wi-Fi num Ambiente Corporativo. RETEC - Revista de Tecnologias, Ourinhos-SP, ano 2024, v. 17, n. 2,

p. 53-71, 10 mar. 2025. Disponível em: <https://retec.fatecourinhos.edu.br/index.php/retec/issue/view/42>. Acesso em: 11 set. 2025.

NUÑEZ, Jamie R.; ANDERTON, Christopher R.; RENSLOW, Ryan S. Optimizing Colormaps with Consideration of Color Vision Deficiency to Enable Accurate Interpretation of Scientific Data. *PLOS One*, [s. l.], v. 13, n. 7, 1 ago. 2018. DOI <https://doi.org/10.1371/journal.pone.0199239>. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0199239>. Acesso em: 10 dez. 2025.

PARZEN, Emanuel. On Estimation of a Probability Density Function and Mode. *Project Euclid*, [S. l.], v. 33, p. 1065-1076, 1 set. 1962. DOI [10.1214/aoms/1177704472](https://doi.org/10.1214/aoms/1177704472). Disponível em: <https://projecteuclid.org/journals/annals-of-mathematical-statistics/volume-33/issue-3/On-Estimation-of-a-Probability-Density-Function-and-Mode/10.1214/aoms/1177704472.full?tab=ArticleFirstPage>. Acesso em: 16 set. 2025.

PERES, André. Mecanismo de Autenticação Baseado na Localização de Estações Sem Fios Padrão IEEE 802.11. Orientador: Raul Fernando Weber. 2010. 87 p. Tese (Doutorado em Ciência da Computação) - Universidade Federal do Rio Grande do Sul Instituto de Informática, Porto Alegre, 2010.

SCOTT, David. *Multivariate Density Estimation: Theory, Practice, and Visualization*. 2. ed. [S. l.]: Wiley, 2015. 305 p. ISBN 928-0-471-69755-8.

SILVERMAN, Bernard. *Density Estimation for Statistics and Data Analysis*. In: *MONOGRAPHS on Statistics and Applied Probability*. London: [s. n.], 1986. Disponível em: <https://ned.ipac.caltech.edu/level5/March02/Silverman/paper.pdf>. Acesso em: 30 set. 2025.

TANENBAUM, Andrew. BOS, Herbert. *Sistemas operacionais modernos*. 4. ed. Brasil: Pearson, 2016. 758 p. ISBN 978-85-4301-818-8. Disponível em: <https://www.kufunda.net/publicdocs/Sistemas%20Operacionais%20Modernos%20%28Andrew%20S.%20Tanenbaum,%20Herbert%20Bos%29.pdf>. Acesso em: 23 set. 2025.

TANENBAUM, Andrew. FEAMSTER, Nick. WETHERALL, David. *Redes de computadores*. 6. ed. Brasil: Bookman, 2021. 568 p. ISBN 9780135408001. Disponível em: <https://dn721905.ca.archive.org/0/items/tanenbaum-rede-de-computadores-6a/Tanenbaum%20Rede%20de%20Computadores%206a.pdf>. Acesso em: 30 set. 2025.

TASTL, Ingeborg; BHACHECH, Miheer; MORONEY, Nathan; HOLM, Jack. ICC Color Management and CIECAM02. *Color and Imaging Conference*, [s. l.], v. 13, ed. 1, p. 217-223, janeiro 2005. DOI [10.2352/CIC.2005.13.1.art00040](https://doi.org/10.2352/CIC.2005.13.1.art00040). Disponível em: <https://library.imaging.org/cic/articles/13/1/art00040>. Acesso em: 23 out. 2025.

TUFTE, Edward. *The visual display of quantitative information*. 2. ed. Connecticut: Graphic Press, 2007. 197 p. Disponível em: <https://kyl.neocities.org/books/%5BTEC%20TUF%5D%20the%20visual%20display%20of%20quantitative%20information.pdf>. Acesso em: 2 out. 2025.

TURLACH, Berwin A. Bandwidth Selection in Kernel Density Estimation. In: *HANDBOOK of Systemic Autoimmune Diseases*. [S. l.: s. n.], 1999. Disponível em: https://www.researchgate.net/publication/2316108_Bandwidth_Selection_in_Kernel_Density_Estimation_A_Review. Acesso em: 28 set. 2025.

VITANOVA, Mirjana Kocaleva et al. *Self-Organized Networks*. 2017. Disponível em: https://www.researchgate.net/publication/328064410_Self-Organized_Networks. Acesso em: 1 out. 2025.

WAND, M. P.; JONES, M. C. Kernel Smoothing. 1. ed. Londres: [s. n.], 1995. Disponível em: <https://annas-archive.org/md5/112544f4c17e4eb6c717360d04c8a333>. Acesso em: 22 out. 2025.

WARE, Colin; STONE, Maureen; SZAFIR, Danielle Albers. Rainbow Colormaps Are Not All Bad. IEEE Computer Graphics and Applications, [s. l.], v. 43, ed. 3, p. 88-93, maio-junho 2023. DOI 10.1109/MCG.2023.3246111. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10128890>. Acesso em: 29 out. 2025.

WI-FI ALLIANCE (EUA). Wi-Fi® delivers the future of connectivity: Wi-Fi evolves, maintains core strengths for next generation use cases. Estados Unidos, Texas, Austin: Andrea Torres, 18 dez. 2018. Disponível em: <https://www.wi-fi.org/news-events/newsroom/wi-fi-delivers-the-future-of-connectivity>. Acesso em: 3 set. 2025.

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

PEDAGOGICAL PROMPT ENGINEERING: MEANINGFUL LEARNING OF MATHEMATICS WITH GENERATIVE AI

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

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

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

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

RESUMO

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

práticas abrangem formação docente, design curricular e políticas educacionais para garantir equidade no acesso e uso ético da tecnologia.

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

ABSTRACT

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

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

1. INTRODUÇÃO

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

A transformação digital na educação, especialmente no período pós-pandemia, tem acelerado significativamente a adoção de tecnologias de inteligência artificial em instituições educacionais de todo o mundo. Segundo dados do TIC Educação (2025), 70% dos alunos do ensino médio já utilizam inteligência artificial generativa em suas pesquisas acadêmicas, evidenciando uma mudança paradigmática nas práticas

de aprendizagem. Esse cenário, embora promissor, apresenta desafios substanciais: muitos alunos utilizam essas ferramentas de forma passiva e superficial, contentando-se com respostas prontas, sem desenvolver habilidades críticas de pensamento e resolução de problemas.

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

No contexto específico do ensino de matemática, o desafio é ainda mais premente. A disciplina, historicamente marcada por dificuldades de aprendizagem e desengajamento estudantil, encontra na IA generativa tanto uma oportunidade quanto um risco. Prompts genéricos, como "Resolva $2x + 5 = 15$ ", geram respostas superficiais que reforçam a aprendizagem mecânica, perpetuando o ciclo de incompreensão conceitual. Por outro lado, prompts estruturados pedagogicamente podem transformar a IA em um tutor inteligente, capaz de ativar conhecimentos prévios, contextualizar conceitos e promover a aprendizagem significativa.

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

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

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

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Inteligência Artificial na Educação: Perspectiva Histórica e Evolução Tecnológica

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

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

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

O terceiro período, iniciado em 2022 com o lançamento do ChatGPT e consolidado com modelos de linguagem de grande escala (Large Language Models — LLMs), representa uma transformação qualitativa. Diferentemente dos STI e chatbots anteriores, os LLMs são treinados em corpus massivos de texto, permitindo compreensão e geração de linguagem natural com sofisticação sem precedentes. A Khan Academy Brasil (2025) demonstra como esses modelos podem ser integrados em plataformas educacionais, oferecendo tutoria personalizada em escala.

2.2 Inteligência Artificial Generativa na Educação

A IA Generativa refere-se a sistemas de inteligência artificial capazes de gerar texto, imagens e outros conteúdos a partir de padrões aprendidos em grandes volumes de dados. No contexto educacional, a IA Generativa oferece possibilidades sem precedentes para personalização, tutoria adaptativa e criação de conteúdo educacional. Segundo Kasneci et al. (2023), os grandes modelos de linguagem possuem potencial

para apoiar processos de tutoria, produção de materiais didáticos, avaliação formativa e personalização do ensino, embora exijam supervisão pedagógica para minimizar riscos relacionados à precisão das informações e à dependência tecnológica.

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

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

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

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

A simples disponibilidade de IA Generativa não garante aprendizagem significativa. Como destacam pesquisadores contemporâneos, a qualidade da interação entre aluno e IA depende fundamentalmente de como os prompts são estruturados. Um prompt genérico produz uma resposta genérica; um prompt pedagogicamente estruturado produz uma resposta que promove aprendizagem significativa.

2.3 Aprendizagem Significativa

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

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

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

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

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

matemática, onde a aprendizagem mecânica frequentemente resulta em alunos que conseguem resolver problemas padronizados, mas fracassam quando enfrentam situações que exigem transferência de conhecimento ou pensamento crítico.

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

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

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

2.4 Engenharia de Prompt como Mediação Pedagógica

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

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

- I — Intenção:** Definir explicitamente o objetivo pedagógico do prompt. Qual competência ou conceito se deseja desenvolver? Qual é o nível cognitivo esperado?
- D — Detalhe:** Especificar o contexto, as condições e as restrições da tarefa. Qual é o nível de escolaridade do aluno? Quais são os conhecimentos prévios esperados?
- E — Exemplo:** Incluir exemplos de respostas desejadas ou indesejadas. Os exemplos funcionam como âncoras cognitivas, permitindo que a IA compreenda o padrão esperado.
- A — Ação:** Solicitar explicitamente a ação a ser realizada. Em vez de "Explique equações", um prompt com ação clara seria "Resolva a equação $2x + 5 = 15$, mostrando cada passo".
- L — Limite:** Estabelecer limites para a resposta. Quantas palavras? Qual é o nível de formalidade esperado?

Tabela 1: Prompt Estruturado Pedagogicamente (Método IDEAL)

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

Fonte: Elaborado pelos autores

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

Problemas pedagógicos:

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

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

Potencial pedagógico:

- Favorece aprendizagem significativa ao conectar com conhecimento prévio
- Promove metacognição (reflexão sobre o próprio processo)
- Estimula pensamento crítico e questionamento
- Desenvolve autonomia intelectual
- Transforma IA em tutor inteligente, não em gerador de respostas prontas

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

2.5 Desafios Éticos, Limitações e Perspectivas Críticas

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

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

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

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

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

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

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

3. METODOLOGIA

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

3.1 Contexto da Pesquisa e Participantes

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

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

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

3.2 Delineamento da Pesquisa

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

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

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

3.3 Produção dos Dados

Os dados analisados foram constituídos por:

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

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

3.4 Instrumento de Análise

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

A rubrica contemplou cinco dimensões:

Tabela II – Rubrica Analítica

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

Fonte: Elaborado pelos autores

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

3.5 Procedimentos de Análise

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

A análise concentrou-se especialmente em elementos relacionados à aprendizagem significativa, tais como: explicitação do raciocínio matemático;

- contextualização dos conceitos;
- estabelecimento de relações entre conhecimentos;
- incentivo à reflexão sobre procedimentos;
- presença de explicações conceituais além da simples apresentação de respostas.

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

3.6 Aspectos Éticos

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

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

4. RESULTADOS E DISCUSSÃO

4.1 Análise Comparativa de Prompts

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

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

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

A pesquisa analisou um total de 15 tópicos matemáticos representativos, distribuídos em três domínios: álgebra (equações lineares, sistemas de equações, inequações), funções (funções lineares, quadráticas, exponenciais) e geometria (cálculo de áreas, volumes, teorema de Pitágoras). Para cada tópico, foram formulados dois prompts: um genérico (média de 8-12 palavras, sem contexto pedagógico) e um estruturado segundo o método IDEAL (média de 60-80 palavras, com especificação clara de intenção, detalhe, exemplo, ação e limite). Os prompts foram submetidos a um modelo de linguagem de grande escala (GPT-4, versão de

março de 2025) em condições idênticas. Cada prompt foi executado três vezes para garantir consistência das respostas, e as respostas foram analisadas por dois avaliadores independentes utilizando uma rubrica de avaliação com cinco critérios: (1) profundidade conceitual (0-5 pontos), (2) clareza da explicação (0-5 pontos), (3) conexão com conhecimento prévio (0-5 pontos), (4) estímulo ao pensamento crítico (0-5 pontos), e (5) adequação pedagógica ao nível de escolaridade (0-5 pontos).

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

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

Tabela III – Análise Comparativa

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

Fonte: Elaborado pelos autores

Entre os aspectos analisados, destacou-se especialmente a capacidade dos prompts estruturados de promover a ativação e a mobilização dos conhecimentos prévios dos aprendizes. As respostas produzidas nesse contexto demonstraram maior preocupação em relacionar novos conteúdos a conceitos já presentes na estrutura cognitiva do estudante, favorecendo a atribuição de significado às novas informações. Tal resultado encontra respaldo nos pressupostos da Teoria da Aprendizagem Significativa de David Ausubel, segundo a qual a aprendizagem ocorre de forma mais efetiva quando novos conhecimentos são ancorados em conceitos previamente estabelecidos, denominados subsunçores.

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

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

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

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

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

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

4.2 Discussão Crítica

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

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

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

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

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

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

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

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

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

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

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

4.3 Implicações Práticas

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

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

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

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

5. CONSIDERAÇÕES FINAIS

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

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

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

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

Apesar dos resultados positivos, a presente pesquisa apresenta limitações que devem ser consideradas. Primeiramente, a amostra reduzida e o contexto único limitam a generalização dos achados (Yin, 2014). Além disso, a dependência de LLMs, apesar da estruturação dos prompts, não elimina o risco de alucinações, especialmente em conteúdos matemáticos. A eficácia do método IDEAL também está condicionada à competência dos professores em engenharia de prompt, o que reforça a necessidade de formação específica.

Por fim, a desigualdade no acesso à tecnologia (digital divide) pode limitar a aplicação do método em contextos socioeconômicos desiguais.

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

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

REFERÊNCIAS BIBLIOGRÁFICAS

AGÊNCIA BRASIL. Sete em cada 10 alunos do ensino médio usam IA generativa em pesquisas. 2025. Disponível em: <https://agenciabrasil.ebc.com.br/educacao/noticia/2025-09/sete-em-cada-10-alunos-do-ensino-medio-usam-ia-generativa-em-pesquisas>. Acesso em: 7 jun. 2026.

AUSUBEL, D. P. The psychology of meaningful verbal learning. New York: Grune & Stratton, 1968.

GEG BRASIL. Educação 5.0: Pedagogia de Prompt Vs Engenharia de Prompt em Sala de Aula. 2024. Disponível em: <http://comunidadegegbrasil.blogspot.com/2024/04/educacao-50-pedagogia-de-prompt-vs.html>. Acesso em: 7 jun. 2026.

GOOGLE CLOUD. Prompt Engineering for AI Guide. 2025. Disponível em: <https://cloud.google.com/discover/what-is-prompt-engineering>. Acesso em: 7 jun. 2026.

HOLMES, W.; BIALIK, M.; FADEL, C. Artificial Intelligence in Education: Promises and Implications for Teaching and Learning. Boston: Center for Curriculum Redesign, 2022.

INTERNATIONAL INTEGRALIZE SCIENTIFIC. Os desafios de ensinar matemática na era da inteligência artificial. 2025. Disponível em: <https://iiscientific.com/artigos/811842/>. Acesso em: 7 jun. 2026.

- KASNECI, E. et al. ChatGPT for Good? On Opportunities and Challenges of Large Language Models for Education. *Learning and Individual Differences*, v. 103, 2023.
- KHAN ACADEMY BRASIL. The basics of prompt engineering. 2025. Disponível em: <https://www.youtube.com/watch?v=InFyEDZNtds>. Acesso em: 7 jun. 2026.
- LUCKIN, R. et al. *Intelligence Unleashed: An Argument for AI in Education*. London: Pearson Education, 2016.
- MOREIRA, M. A. *Aprendizagem significativa: a teoria e prática*. São Paulo: Editora Moreira, 2012.
- NOVAK, J. D. *Learning, creating, and using knowledge*. Mahwah: Lawrence Erlbaum Associates, 1998.
- PERIODICOS UNOESC. Sistema Tutor Inteligente PAT2Math. 2024. Disponível em: <https://periodicos.unoesc.edu.br/acet/article/view/12666/pdf>. Acesso em: 7 jun. 2026.
- PROMPT ENGINEERING GUIDE. Prompt Engineering Guide. 2025. Disponível em: <https://www.promptingguide.ai/>. Acesso em: 7 jun. 2026.
- REVISTA DCS. Engenharia de Prompt e Gestão de Pessoas: IA a Serviço da Coordenação Pedagógica. 2025. Disponível em: <https://ojs.revistadcs.com/index.php/revista/article/view/1032>. Acesso em: 7 jun. 2026.
- RIBEIRO, T. A. Transformando o aprendizado na era da IA. *Educação e Engenharia de Prompt*. 2023.
- SELWYN, N. *Tecnologia e educação: questões críticas*. São Paulo: Pimenta Cultural, 2019.
- SOUTH AMERICAN DEVELOPMENT SOCIETY JOURNAL. Inteligência Artificial Generativa na Educação e Pesquisa: Reflexões sobre o Guia da UNESCO. 2024. Disponível em: <https://www.sadsj.org/index.php/revista/article/view/747>. Acesso em: 7 jun. 2026.
- UNESCO. Guia para a IA generativa na educação e na pesquisa. 2024. Disponível em: <https://www.unesco.org/pt/articles/guia-para-ia-generativa-na-educacao-e-na-pesquisa>. Acesso em: 7 jun. 2026.
- VICCARI, R. M. *Sistemas Tutores Inteligentes como recurso didático no ensino da matemática*. 1996.
- WHITE, J. et al. A Prompt Pattern Catalog to Enhance Prompt Engineering with ChatGPT. *arXiv*, 2023.
- WILLIAMSON, B. *Big data in education: the digital technologies of data-driven learning*. London: SAGE Publications, 2017.
- ZAWACKI-RICHTER, O.; MARÍN, V.; BOND, M.; GOUVERNEUR, F. Systematic Review of Research on Artificial Intelligence Applications in Higher Education. *International Journal of Educational Technology in Higher Education*, v. 16, n. 39, 2019.

A INTELIGÊNCIA ARTIFICIAL SOB UMA PERSPECTIVA HUMANA: MOTIVAÇÕES, ADOÇÃO E INOVATIVIDADE ENTRE ESTUDANTES TECNÓLOGOS

ARTIFICIAL INTELLIGENCE FROM A HUMAN PERSPECTIVE: MOTIVATIONS, ADOPTION, AND INNOVATIVENESS AMONG STUDENTS IN TECHNOLOGY PROGRAMS

Samuel Felipe de Oliveira SOARES

samuel.soares@cps.sp.gov.br

Bolsista de Iniciação Científica CEPE (Câmara de Ensino, Pesquisa e Extensão),
Faculdade de Tecnologia do Estado de São Paulo, FATEC, Itu, São Paulo, Brasil

Marcio de La Cruz LUI

marcio.lui@cps.sp.gov.br

Orientador de Iniciação Científica CEPE (Câmara de Ensino, Pesquisa e Extensão),
Faculdade de Tecnologia do Estado de São Paulo, FATEC, Itu, São Paulo, Brasil

Resumo

Este estudo analisa a influência das dimensões motivacionais (hedônica, social, cognitiva e funcional) no comportamento inovativo de estudantes tecnólogos frente à Inteligência Artificial (IA). Realizou-se uma pesquisa quantitativa e explicativa com 110 graduandos da FATEC e de outras instituições de ensino superior, utilizando modelagem por regressão linear múltipla no SPSS. Os resultados indicam que o Domínio Específico de Inovatividade (DSI) é explicado exclusivamente pela motivação social. Já a Inovação Inata (II) sofre influência simultânea das motivações social e cognitiva. Conclui-se que os fatores sociais desempenham papel central na inovatividade dos estudantes, evidenciando que a adoção da IA transcende aspectos puramente técnicos e envolve processos de interação e reconhecimento coletivo no ambiente acadêmico.

Palavras-Chave

Inteligência Artificial; Inovatividade; Motivação; Estudantes Tecnólogos; Ensino Superior.

Abstract

This study analyzes the influence of motivational dimensions (hedonic, social, cognitive, and functional) on the innovative behavior of technology students regarding Artificial Intelligence (AI). A quantitative and explanatory study was conducted with 110 undergraduate students from FATEC and other higher education institutions, using multiple linear regression modeling in SPSS. The results indicate that the Domain-Specific Innovativeness (DSI) is explained exclusively by social motivation. Innate Innovation (II), on the other hand, is simultaneously influenced by social and cognitive motivations. It is concluded that social factors play a central role in students' innovativeness, highlighting that the adoption of AI transcends purely technical aspects and involves processes of interaction and collective recognition in the academic environment.

Keywords

Artificial Intelligence; Innovativeness; Motivation; Technology Students; Higher Education.

INTRODUÇÃO

A ampliação da presença da Inteligência Artificial (IA) no cotidiano acadêmico estabelece às instituições de ensino superior novos desafios quanto à dinâmica de aprendizagem e à formação dos estudantes. Nesse cenário, Yan et al. (2025) demonstram que os agentes proativos de IA generativa, quando corretamente utilizados, podem melhorar a compreensão discente na análise visual de dados, evidenciando que essa tecnologia atua como um elemento ativo no ecossistema educativo. Por outro lado, estudos como o de Netland et al. (2025) reforçam que, embora os recursos digitais apresentem resultados expressivos, a mediação humana permanece essencial para o engajamento e a empatia na formação acadêmica. Diante dessa realidade, torna-se imperativo investigar não apenas o uso da ferramenta, mas quais fatores motivacionais impulsionam a adoção e o comportamento inovativo dos discentes.

Para compreender como fatores individuais e contextuais influenciam a adesão a essa tecnologia, a literatura sobre inovação oferece conceitos fundamentais. O Domínio Específico de Inovatividade (DSI), a Inovação Inata (II) e o Consumo Inovativo, conforme discutidos por Araujo et al. (2016), Salhieh & Al-Abdallat (2022) e Kim et al. (2025), fornecem a base para analisar as nuances da inovatividade dos estudantes e como estas se traduzem em comportamento. Além disso, modelos teóricos consolidados como o *Technology Acceptance Model* (TAM), traduzido como Modelo de Adoção da Tecnologia (DAVIS et al., 1992) e a *Unified Theory of Acceptance and Use of Technology* (UTAUT), traduzida como Teoria Unificada de Adoção e Uso da Tecnologia (VENKATESH et al., 2003), complementados pelas dimensões motivacionais propostas por Lui (2021), oferecem parâmetros para analisar aspectos como utilidade percebida, facilidade de uso e motivações intrínsecas e extrínsecas. Tal arcabouço amplia o entendimento sobre os fatores que guiam a adoção e a inovatividade dos discentes frente à IA.

Por conseguinte, a pesquisa tem como pergunta norteadora: “De que maneira as dimensões motivacionais (hedônica, social, cognitiva e funcional) influenciam a adoção da Inteligência Artificial por meio do Domínio Específico de Inovatividade (DSI) e da Inovação Inata (II) dos estudantes tecnólogos?”.

O estudo fundamenta-se na hipótese de que as dimensões motivacionais exercem influência positiva tanto sobre o DSI em IA quanto sobre a II dos alunos, atuando como antecedentes centrais para a adoção tecnológica.

Portanto, esta pesquisa tem como objetivo analisar a influência das dimensões motivacionais no comportamento inovativo dos estudantes tecnólogos frente à Inteligência Artificial. O estudo desenvolve-se com base em uma abordagem descritivo-explicativa na revisão da literatura, coleta empírica e análise estatística inferencial, com o propósito de fornecer resultados que auxiliem gestores educacionais, professores e estudantes a compreenderem os determinantes do comportamento inovativo no ensino superior tecnológico.

REVISÃO DE LITERATURA E HIPÓTESES

Comportamento inovativo com IA na aprendizagem

O uso da Inteligência Artificial (IA) no ensino superior permite compreender a interação entre discentes e tecnologias emergentes. Segundo Yan et al. (2025), a IA deve ser vista como um agente ativo na aprendizagem, e não apenas suporte. O estudo demonstra que agentes generativos proativos, que guiam o aluno com recomendações, melhoram a compreensão de visualizações analíticas de aprendizagem (VLA), promovendo conhecimento duradouro. Complementarmente, Netland et al. (2025) observam que, embora o desempenho acadêmico com IA seja equivalente ao de produções docentes, a mediação humana permanece superior em empatia. Assim, a experiência de uso depende da integração pedagógica focada em engajamento, superando a mera funcionalidade técnica.

O consumo inovativo acadêmico envolve busca ativa por informação e experimentação. Alba & Hutchinson (1987) argumentam que a *expertise* do consumidor é pré-requisito para processar inovações. Nessa linha, Kim et al. (2025) revelam que dimensões motivacionais (social, hedônica e cognitiva) influenciam o comportamento inovador quando mediadas pela aprendizagem. Assim, a adoção da IA é potencializada quando professores atuam como facilitadores, validando a utilidade da ferramenta. Portanto, a inovatividade é um comportamento socialmente construído e educacionalmente suportado.

Neste sentido, a adoção tecnológica é explicada pelos modelos TAM (DAVIS et al., 1992), focado em utilidade e facilidade percebidas, e UTAUT (VENKATESH et al., 2003), que inclui influência social e condições facilitadoras. A Teoria da Autodeterminação (SDT) complementa esses modelos ao focar nas necessidades psicológicas. Conforme Chiu (2021), o engajamento discente é impulsionado pela satisfação de autonomia, relacionamento e competência. O suporte digital eficaz atende a esses requisitos através de interatividade e *design* emocional, conectando a técnica à satisfação do usuário. A partir destas discussões destacam-se dois construtos relacionados ao comportamento inovativo: a) Domínio Específico de Inovatividade (DSI) é central para entender a adoção tecnológica. Araujo et al. (2016) explicam que indivíduos com alto DSI possuem maior inclinação ao novo e atuam como “líderes de opinião”, influenciando seus pares na disseminação de tecnologias acadêmicas. Essa perspectiva une-se à b) Inovação Inata (II), tratada por Salhieh & Al-Abdallat (2022) como um traço de personalidade que impulsiona a intenção tecnológica. Para os autores, indivíduos inovadores desenvolvem intenções de uso mesmo sem alta autoconfiança técnica inicial, buscando proativamente superar desafios. Como reforça Schumpeter (1934), a inovação reside na combinação criativa de recursos, dependendo da ação proativa do estudante frente às oportunidades.

Dimensões motivacionais e comportamento inovativo

A proposição de Lui (2021) delinea quatro dimensões motivacionais para a adoção de serviços inteligentes: (1) hedônica (prazer e curiosidade); (2) social (*status* e influência); (3) cognitiva (estímulo intelectual); e (4) funcional (utilidade prática e desempenho). Essa estrutura explica por que estudantes manifestam níveis distintos de inovatividade. A integração dessas dimensões, sustentada por Araujo et al. (2016) e Salhieh & Al-Abdallat (2022), fundamenta a hipótese central deste estudo: o engajamento com a IA resulta da combinação dessas motivações, que atuam como antecedentes do DSI e da Inovação Inata.

Desenvolvimento das hipóteses

O presente capítulo dedica-se à construção dos argumentos teóricos que sustentam as relações propostas neste estudo, fundamentando-se no modelo UTAUT de Venkatesh et al. (2003) e na sua extensão UTAUT2 (VENKATESH et al., 2012). A análise estrutura-se em dois eixos centrais de investigação: o primeiro explora como as motivações influenciam no Domínio Específico de Inovatividade (DSI) do estudante frente à Inteligência Artificial (IA), enquanto o segundo investiga como as motivações influenciam a Inovação Inata do estudante frente à Inteligência Artificial (IA). Esta base teórica articula a tradição dos estudos de adoção tecnológica com as dinâmicas disruptivas emergentes nos últimos cinco anos, validando a atualidade das premissas comportamentais frente às novas interfaces digitais.

A motivação hedônica, definida pela busca por prazer e satisfação emocional, atua como um dos pilares centrais para a compreensão do comportamento do usuário. Segundo o modelo UTAUT2, consolidado por Venkatesh et al. (2012), a percepção de entretenimento e o prazer derivado do uso são determinantes cruciais para a adoção de tecnologias, especialmente em ambientes onde a interação é voluntária e enriquecedora.

No contexto atual de proliferação da IA, o engajamento lúdico atua como um catalisador para a exploração de funcionalidades complexas. Netland et al. (2025) demonstram que a experiência do usuário com vídeos gerados por IA e interfaces inteligentes altera a percepção de aprendizado, tornando o entretenimento uma porta de entrada para a competência técnica. Alinhado a isso, Lui (2021) enfatiza que a dimensão hedônica reduz barreiras psicológicas, facilitando a adesão, sustentando a **H1: A motivação hedônica influencia positivamente o DSI do estudante na adoção de IA nas práticas acadêmicas.**

Em paralelo, a motivação social está diretamente ligada à percepção de influência dos pares e ao desejo de pertencimento a um grupo. De acordo com o modelo original de Venkatesh et al. (2003), a “influência social” é um determinante direto da intenção de uso, pois os indivíduos tendem a adotar comportamentos valorizados pelo seu grupo de referência, consolidando normas de conduta tecnológica dentro de suas redes sociais.

Esta dimensão ganha novos contornos com a ascensão da IA, onde o uso da tecnologia se torna um marcador de alinhamento com as práticas acadêmicas modernas. Estudos recentes, como os de Dwivedi et al. (2023), destacam que a disseminação dessas ferramentas no ambiente universitário é fortemente mediada pela pressão social e pelo desejo de se manter atualizado perante os pares, impulsionando a experimentação técnica. Lui (2021) reforça que o engajamento em serviços digitais é amplificado por essa necessidade de validação, transformando a adoção de IA em uma norma coletiva que sinaliza competência acadêmica, validando a **H2: A motivação social influencia positivamente o DSI do estudante na adoção de IA nas práticas acadêmicas.**

Quanto à motivação cognitiva, caracterizada pela curiosidade intelectual e pelo desejo de dominar competências, esta é essencial para o estudante encarar a tecnologia não apenas como uma ferramenta de tarefa, mas como um objeto de estudo. Davis et al. (1992) estabelecem que a motivação intrínseca ao aprendizado, o prazer de compreender o funcionamento de um sistema, é um fator determinante que reduz a resistência à mudança tecnológica, permitindo que o usuário explore as funcionalidades de forma autônoma e profunda, superando a visão meramente utilitária.

No cenário atual de expansão da Inteligência Artificial, essa exploração intelectual ganha novos contornos, pois a tecnologia exige uma interação ativa e um refinamento constante do usuário. Pesquisas recentes, como as de Netland et al. (2025), indicam que o engajamento com ferramentas baseadas em IA estimula processos de aprendizagem profundos quando o estudante é instigado a analisar e processar criticamente

os resultados gerados. Lui (2021) argumenta que essa satisfação cognitiva promove um estado de fluxo, onde o aprendizado se torna contínuo, transformando a relação com o sistema e impulsionando a experimentação técnica, conduzindo à **H3: A motivação cognitiva influencia positivamente o DSI do estudante na adoção de IA nas práticas acadêmicas.**

Por sua vez, a motivação funcional baseia-se na percepção de utilidade e eficiência prática da ferramenta. Na base teórica do UTAUT (Venkatesh et al., 2003), a “expectativa de desempenho” é o principal fator de adoção: se o estudante percebe que a IA economiza tempo ou melhora a qualidade do seu trabalho acadêmico, ele se sente impelido a inovar em seus métodos para garantir essa vantagem competitiva.

Este comportamento utilitário atua como motor de produtividade, conectando a funcionalidade do serviço à satisfação do usuário. Salhieh & Al-Abdallat (2022) observam que as intenções empreendedoras tecnológicas e a autoeficácia acadêmica são fortalecidas quando a tecnologia entrega ganhos práticos reais. Lui (2021) complementa que a entrega de valor funcional é o que sustenta a retenção, validando a **H4: A motivação funcional influencia positivamente o DSI do estudante na adoção de IA nas práticas acadêmicas.**

Alterando a perspectiva para o perfil de Inovação Inata, observa-se que este conceito, conforme Goldsmith & Hofacker (1991), reflete a propensão psicológica de buscar o novo antes da maioria. Segundo Rogers (2003), indivíduos que encontram experiências gratificantes ao interagir com tecnologias emergentes desenvolvem uma abertura mental superior, reduzindo a percepção de risco.

Essa abertura mental é impulsionada por vivências que associam tecnologia ao prazer e à descoberta. Lui (2021) valida que a experiência prévia satisfatória atua como um catalisador para o usuário sair de sua zona de conforto intelectual, mitigando o medo da obsolescência. Ao associar a IA ao prazer hedônico, reforça-se o traço inato de busca pela novidade, sustentando a **H5: A motivação hedônica influencia positivamente a Inovação Inata do estudante na adoção de IA nas práticas acadêmicas.**

No que tange à dimensão social, a necessidade de reconhecimento atua como um motor da identidade de inovador. A Teoria de Difusão de Inovações de Rogers (2003) aponta que os indivíduos buscam na inovação uma forma de se destacar dentro de suas redes sociais, utilizando o pioneirismo tecnológico como um sinalizador de posição e competência acadêmica perante seus pares. Para o estudante, ser identificado como alguém que domina ferramentas de IA confere um capital social que reforça sua inclinação para a busca de novas tecnologias.

Essa dinâmica é fortalecida quando a inovação é vista como um caminho para o sucesso. Ao investigar as intenções empreendedoras tecnológicas, Salhieh & Al-Abdallat (2022) demonstram que a Inovação Inata do estudante é diretamente impulsionada por fatores que reforçam sua eficácia e autoimagem em ambientes acadêmicos. Quando o grupo de referência valoriza o domínio tecnológico, essa necessidade de validação social retroalimenta a tendência inata de inovar. Lui (2021) corrobora que a adoção tecnológica é moldada pela percepção social, sendo que a validação dos pares atua como um reforçador da personalidade inovadora, validando a **H6: A motivação social influencia positivamente a Inovação Inata do estudante na adoção de IA nas práticas acadêmicas.**


Quanto à motivação cognitiva, o desejo de compreender a lógica da ferramenta é um componente essencial da Inovação Inata. Conforme a teoria social cognitiva de Bandura (1986), a crença do indivíduo em sua própria capacidade, ou autoeficácia, é o que permite enfrentar desafios desconhecidos e a experimentação contínua de novas tecnologias sem o receio do erro. Estudantes movidos por essa curiosidade não apenas adotam a IA por conveniência, mas a integram profundamente em sua rotina, tratando-a como um desafio de domínio técnico constante que expande suas fronteiras de conhecimento.

Essa relação entre engajamento cognitivo e desenvolvimento de competências é reforçada pela literatura recente. Netland et al. (2025) demonstram que a interação com ferramentas de IA, quando mediada pela curiosidade intelectual, potencializa os efeitos de aprendizagem e a capacidade do estudante de processar informações complexas, consolidando-o como um aprendiz ativo. Lui (2021) corrobora que essa satisfação intelectual retroalimenta a propensão a buscar novas soluções, cristalizando a inovação como um traço de personalidade permanente, levando à **H7: A motivação cognitiva influencia positivamente a Inovação Inata do estudante na adoção de IA nas práticas acadêmicas.**

Por fim, a motivação funcional fundamenta-se na busca por eficiência e otimização de processos. Bhattacharjee (2001) estabelece que, quando a expectativa de utilidade é confirmada após a adoção (modelo de confirmação de expectativas), o usuário tende a repetir o comportamento, tornando a inovação uma prática habitual de melhoria de desempenho. No caso do estudante de tecnologia, a constatação de que a IA resolve problemas complexos eficientemente consolida sua personalidade como alguém que busca constantemente novas formas de otimização pragmática.

Essa trajetória de confirmação de utilidade é vital para o desenvolvimento da Inovação Inata. Salhieh & Al-Abdallat (2022) observam que a autoeficácia acadêmica, potencializada pela entrega de resultados práticos das tecnologias, é um preditor direto da intenção de inovar. Quando a IA entrega valor constante, o estudante desenvolve a confiança necessária para buscar novas ferramentas, transformando a funcionalidade em um traço de personalidade inovadora. Lui (2021) destaca que essa entrega de valor funcional é a base para que o usuário se sinta seguro em inovar, transformando a tecnologia em um aliado estratégico constante, formulando assim a **H8: A motivação funcional influencia positivamente a Inovação Inata do estudante na adoção de IA nas práticas acadêmicas.**

Em suma, o conjunto de hipóteses aqui delineado oferece uma estrutura explicativa robusta, conectando as dimensões motivacionais do usuário tanto à competência técnica específica quanto à formação de um perfil inovador inato. Ao integrar as contribuições clássicas de Venkatesh et al. (2003), Rogers (2003) e Bandura (1986) com a visão contemporânea de autores como Netland et al. (2025) e Salhieh & Al-Abdallat (2022), além da perspectiva de Lui (2021), este conjunto teórico fornece as bases necessárias para a análise empírica subsequente, permitindo compreender como as motivações individuais convergem para o comportamento inovativo no uso de Inteligência Artificial no ensino superior pelos estudantes tecnólogos. A Figura 1 apresenta os modelos teóricos estruturais propostos para esta pesquisa, sintetizando as relações entre as variáveis motivacionais e os construtos de inovatividade analisados.

Figura 1. Modelos teóricos

Fonte: Elaborado pelos autores (2026)

METODOLOGIA

Natureza da pesquisa

Esta pesquisa caracteriza-se como quantitativa, uma vez que busca analisar estatisticamente as relações entre diferentes construtos relacionados à adoção e ao uso da Inteligência Artificial (IA) por estudantes de cursos superiores de tecnologia. A abordagem quantitativa permite a mensuração objetiva das variáveis investigadas e a identificação de relações de dependência entre elas por meio de técnicas estatísticas multivariadas (HAIR et al., 2019; MALHOTRA, 2019).

Quanto aos objetivos, a pesquisa possui caráter explicativo, pois procura compreender em que medida diferentes motivações influenciam o comportamento inovador dos estudantes, representado pelos construtos Domínio Específico de Inovatividade (DSI) e Inovação Inata (II).

População e amostra

A população-alvo da pesquisa foi composta por estudantes tecnólogos de cursos superiores da Faculdade de Tecnologia do Estado de São Paulo (FATEC) e outras instituições de ensino. A escolha desse público justifica-se pelo elevado grau de exposição desses estudantes às tecnologias digitais emergentes, especialmente às ferramentas baseadas em Inteligência Artificial, tornando-os um grupo relevante para a investigação dos fatores associados à adoção tecnológica.

A coleta de dados foi realizada entre os dias 4 e 24 de maio de 2026, por meio da aplicação de um questionário eletrônico disponibilizado na plataforma *Google Forms*. A participação foi voluntária e os respondentes foram informados sobre os objetivos acadêmicos da pesquisa.

Ao final do período de coleta, obteve-se uma amostra válida composta por 110 respondentes, número considerado adequado para a aplicação da técnica de regressão linear múltipla empregada neste estudo.

Caracterização da amostra

Como citado anteriormente, a amostra foi composta por 110 estudantes de cursos superiores de tecnologia. Observou-se predominância de respondentes com até 23 anos de idade, seguida pelas faixas etárias de 24 a 35 anos e de 36 a 50 anos. Em relação ao gênero, verificou-se maior participação de estudantes do sexo masculino, seguida pelo sexo feminino e por uma resposta classificada como outra identificação de gênero.

No que se refere aos cursos, destacaram-se Gestão da Tecnologia da Informação, Gestão Empresarial e Análise e Desenvolvimento de Sistemas. A categoria “Outros” reúne cursos tecnológicos distintos daqueles explicitamente apresentados no questionário, contemplando formações ofertadas tanto pela FATEC quanto por outras instituições de ensino superior incluídas na amostra.

Verificou-se ainda ampla utilização de ferramentas de Inteligência Artificial entre os participantes, sendo que a grande maioria declarou utilizar recursos de IA em suas atividades acadêmicas, profissionais ou pessoais. Entre os principais objetivos de utilização, destacaram-se os estudos, seguidos por tarefas cotidianas e atividades profissionais.

Quanto à frequência de uso, observou-se que a maior parte dos respondentes utiliza ferramentas de Inteligência Artificial diariamente ou semanalmente, indicando elevado grau de familiaridade com essas tecnologias.

Por fim, o *ChatGPT* destacou-se como a ferramenta preferida pelos participantes, seguido pelo Gemini, evidenciando a predominância das plataformas de IA generativa no contexto acadêmico investigado. A caracterização da amostra encontra-se apresentada nas Tabelas 1 e 2.

Tabela 1. Caracterização da amostra dos respondentes (n = 110)

Variável	Categoria	Frequência	Percentual (%)
Idade	Até 23 anos	59	53,64
	24 a 35 anos	32	29,09
	36 a 50 anos	12	10,91
	Mais de 50 anos	7	6,36
Gênero	Masculino	64	58,18
	Feminino	45	40,91
	Outro	1	0,91
Utiliza IA?	Sim	105	95,45
	Não	5	4,55
Frequência de uso	Diariamente	54	49,09
	Semanalmente	44	40,00
	Raramente	10	9,09
	Sem resposta	2	1,82
	ChatGPT	64	58,18
Ferramenta preferida	Gemini	29	26,36
	Outras	11	10,00
	Copilot	5	4,55
	Sem resposta	1	0,91

Fonte: Elaborado pelos autores com base nos dados da pesquisa (2026).

Tabela 2. Distribuição dos respondentes por curso (n = 110)

Curso	Frequência
Gestão da Tecnologia da Informação	31
Gestão Empresarial	30
Outros	29
Análise e Desenvolvimento de Sistemas	13
Mecatrônica Industrial	3
Gestão de Eventos	2
Processos Gerenciais	2

Fonte: Elaborado pelos autores com base nos dados da pesquisa (2026).

Instrumento de coleta de dados

Os dados foram coletados por meio de um questionário estruturado desenvolvido na plataforma *Google Forms*. O instrumento contemplou questões destinadas à mensuração dos construtos relacionados às

motivações para utilização de Inteligência Artificial e aos níveis de inovatividade dos respondentes. As variáveis foram mensuradas por meio de escala *Likert* de cinco pontos, variando de 1 (discordo totalmente) a 5 (concordo totalmente).

As variáveis independentes foram compostas por quatro dimensões motivacionais estruturadas com base no modelo de serviços inteligentes proposto por Lui (2021):

- Motivação Funcional;
- Motivação Social;
- Motivação Hedônica;
- Motivação Cognitiva.

Essas dimensões representam diferentes razões que podem influenciar o uso e a adoção de ferramentas de Inteligência Artificial pelos estudantes.

Além das variáveis motivacionais, foram mensurados dois construtos relacionados à inovatividade dos indivíduos, operacionalizados a partir das métricas de Goldsmith & Hofacker (1991) e Agarwal & Prasad (1998):

- Domínio Específico de Inovatividade (DSI);
- Inovação Inata (II).

Os escores médios de cada construto foram calculados para utilização nas análises estatísticas subsequentes.

Procedimentos de Análise de Dados

Após a coleta, os dados foram organizados e processados no software *Statistical Package for the Social Sciences* (SPSS). Inicialmente, realizou-se a análise exploratória dos dados para identificação de inconsistências, valores ausentes e adequação dos pressupostos estatísticos necessários à aplicação da regressão linear múltipla.

Posteriormente, foram estimados dois modelos de regressão linear múltipla pelo método *Enter*, no qual todas as variáveis independentes são inseridas simultaneamente na equação de regressão.

O Modelo 1 teve como variável dependente o Domínio Específico de Inovatividade (DSI), enquanto as motivações funcional, social, hedônica e cognitiva foram utilizadas como variáveis independentes.

O Modelo 2 teve como variável dependente a Inovação Inata (II), mantendo-se as variáveis independentes utilizadas no Modelo 1.

A regressão linear múltipla foi escolhida por permitir avaliar simultaneamente a influência de múltiplas variáveis preditoras sobre uma variável dependente, possibilitando identificar quais fatores apresentam maior capacidade explicativa sobre os construtos de inovatividade analisados.

Para avaliação dos modelos foram considerados os coeficientes de determinação (R^2 e R^2 ajustado), o teste F da ANOVA para verificação da significância global dos modelos, os coeficientes padronizados (β) para análise da contribuição individual das variáveis independentes e os respectivos níveis de significância estatística ($p < 0,05$).

Adicionalmente, foram examinados os pressupostos da regressão linear múltipla, incluindo independência dos resíduos por meio da estatística de *Durbin-Watson*, normalidade dos resíduos por meio de histogramas e gráficos P-P Normal, bem como a ausência de multicolinearidade entre as variáveis independentes através dos indicadores de Tolerância e *Variance Inflation Factor* (VIF).

Especificação dos Modelos

Com o objetivo de compreender os fatores associados à adoção e ao uso da Inteligência Artificial pelos estudantes dos cursos de tecnologia da FATEC e de outras instituições de ensino, foram estimados dois modelos econométricos.

O Modelo 1 foi especificado da seguinte forma:

$$DSI = \beta_0 + \beta_1(\text{Motivação Funcional}) + \beta_2(\text{Motivação Social}) + \beta_3(\text{Motivação Hedônica}) + \beta_4(\text{Motivação Cognitiva}) + \varepsilon$$

No Modelo 2, a variável dependente passou a ser a Inovação Inata:

$$II = \beta_0 + \beta_1(\text{Motivação Funcional}) + \beta_2(\text{Motivação Social}) + \beta_3(\text{Motivação Hedônica}) + \beta_4(\text{Motivação Cognitiva}) + \varepsilon$$

Em ambos os modelos, buscou-se verificar quais dimensões motivacionais exercem influência significativa sobre os níveis de inovatividade dos estudantes.

Os resultados obtidos demonstraram que os dois modelos apresentaram significância estatística global. No Modelo 1, apenas a Motivação Social apresentou influência significativa sobre o Domínio Específico de Inovatividade. Já no Modelo 2, verificou-se que tanto a Motivação Social quanto a Motivação Cognitiva apresentaram efeitos positivos e estatisticamente significativos sobre a Inovação Inata dos respondentes.

ANÁLISE DOS RESULTADOS

Análise do modelo 1 – Domínio Específico de Inovatividade (DSI)

O primeiro modelo de regressão linear múltipla teve como objetivo verificar a influência das motivações funcional, social, hedônica e cognitiva sobre o Domínio Específico de Inovatividade (DSI) dos estudantes dos cursos de tecnologia, como evidenciado na Tabela 3.

Tabela 3. Resumo do modelo 1

Indicador	Valor
R	0,52
R ²	0,27
R ² Ajustado	0,24
Erro Padrão da Estimativa	0,74
Durbin-Watson	2,1

Fonte: Elaborado pelos autores com base nos resultados do SPSS (2026).

Os resultados demonstram que o modelo apresentou coeficiente de correlação múltipla de $R = 0,517$, indicando associação moderada entre as variáveis independentes e o DSI. O coeficiente de determinação ($R^2 = 0,267$) indica que aproximadamente 26,7% da variância observada no Domínio Específico de Inovatividade é explicada pelas quatro dimensões motivacionais consideradas no modelo. Após o ajuste pelo número de preditores, o R^2 ajustado permaneceu em 23,9%, evidenciando capacidade explicativa satisfatória para estudos comportamentais.

O valor de *Durbin-Watson* (2,099) sugere independência dos resíduos, atendendo ao pressuposto de ausência de autocorrelação.

Tabela 4. ANOVA do modelo 1

Fonte de Variação	SQ	gl	QM	F	p
Regressão	20,646	4	5,162	9,558	<0,001
Resíduo	56,702	105	0,54		
Total	77,349	109			

Fonte: Elaborado pelos autores com base nos resultados do SPSS (2026).

O teste F, demonstrado na Tabela 4, revelou que o modelo é globalmente significativo ($F = 9,558$; $p < 0,001$), indicando que o conjunto das motivações analisadas contribui significativamente para explicar o Domínio Específico de Inovatividade dos estudantes.

Tabela 5. Coeficientes de regressão do modelo 1

Variável	B	β	t	p
Constante	1,392	–	4,551	<0,001
Motivação Social	0,423	0,45	3,824	<0,001
Motivação Funcional	0,159	0,177	1,608	0,111
Motivação Hedônica	-0,161	-0,185	-1,487	0,14
Motivação Cognitiva	0,106	0,122	1,241	0,217

Fonte: Elaborado pelos autores com base nos resultados do SPSS (2026).

A análise dos coeficientes, representados na Tabela 5, demonstra que apenas a Motivação Social apresentou efeito positivo e estatisticamente significativo sobre o Domínio Específico de Inovatividade ($\beta = 0,450$; $p < 0,001$). Esse resultado sugere que estudantes motivados por fatores relacionados à interação social, reconhecimento e influência de grupos tendem a apresentar maior predisposição para adotar e utilizar tecnologias inovadoras.

As motivações funcional, hedônica e cognitiva não apresentaram significância estatística ao nível de 5%, indicando que seus efeitos não foram suficientemente fortes para explicar o DSI quando consideradas simultaneamente no modelo.

A equação estimada para o Modelo 1 foi:

$$\text{DSI} = 1,392 + 0,423(\text{Social}) + 0,159(\text{Funcional}) - 0,161(\text{Hedônica}) + 0,106(\text{Cognitiva})$$

Em relação aos pressupostos estatísticos, não foram identificados problemas de multicolinearidade. Os valores de VIF variaram entre 1,385 e 2,226, substancialmente abaixo dos limites críticos normalmente aceitos pela literatura.

Análise do Modelo 2 – Inovação Inata (II)

O segundo modelo investigou a influência das mesmas motivações sobre a Inovação Inata (II), entendida como uma predisposição individual mais ampla para comportamentos inovadores, como evidenciado na Tabela 6.

Tabela 6. Resumo do modelo 2

Indicador	Valor
R	0,70
R ²	0,49
R ² Ajustado	0,47
Erro Padrão da Estimativa	0,41
Durbin-Watson	1,77

Fonte: Elaborado pelos autores com base nos resultados do SPSS (2026).

Os resultados demonstram um ajuste substancialmente superior ao observado no Modelo 1. O coeficiente de determinação ($R^2 = 0,485$) indica que 48,5% da variância da Inovação Inata é explicada pelas variáveis motivacionais incluídas na análise. Trata-se de um poder explicativo considerado elevado para pesquisas na área de comportamento e adoção tecnológica.

O valor de *Durbin-Watson* (1,774) permaneceu dentro dos limites recomendados, indicando independência dos resíduos.

Tabela 7. ANOVA do modelo 2

Fonte de Variação	SQ	gl	QM	F	p
Regressão	16,723	4	4,181	24,727	<0,001
Resíduo	17,753	105	0,169		
Total	34,476	109			

Fonte: Elaborado pelos autores com base nos resultados do SPSS (2026).

O teste F, demonstrado na Tabela 7, revelou significância estatística elevada ($F = 24,727$; $p < 0,001$), confirmando que as variáveis independentes explicam conjuntamente a Inovação Inata dos respondentes.

Tabela 8. Coeficientes de regressão do modelo 2

Variável	B	β	t	p
Constante	1,901	–	11,105	<0,001
Motivação Social	0,262	0,417	4,228	<0,001
Motivação Funcional	0,044	0,074	0,801	0,425
Motivação Hedônica	0,093	0,16	1,531	0,129
Motivação Cognitiva	0,106	0,182	2,212	0,029

Fonte: Elaborado pelos autores com base nos resultados do SPSS (2026).

Os resultados, representados na Tabela 8, demonstram que duas variáveis apresentaram influência estatisticamente significativa sobre a Inovação Inata.

A Motivação Social foi o principal preditor do modelo ($\beta = 0,417$; $p < 0,001$), indicando que indivíduos influenciados por fatores sociais tendem a apresentar maiores níveis de predisposição à inovação.

Além disso, a Motivação Cognitiva apresentou efeito positivo e significativo ($\beta = 0,182$; $p = 0,029$), sugerindo que a busca por conhecimento, aprendizado e exploração intelectual favorece o desenvolvimento de características inovadoras.

Por outro lado, as motivações funcional e hedônica não apresentaram significância estatística, indicando que fatores relacionados à utilidade prática ou ao prazer de utilização da tecnologia não explicam diretamente a Inovação Inata quando analisados conjuntamente com as demais dimensões.

A equação estimada para o Modelo 2 foi:

$$II = 1,901 + 0,262(\text{Social}) + 0,044(\text{Funcional}) + 0,093(\text{Hedônica}) + 0,106(\text{Cognitiva})$$

Da mesma forma que no Modelo 1, os indicadores de multicolinearidade mostraram-se adequados, com valores de VIF inferiores a 2,3, não havendo evidências de colinearidade excessiva entre os preditores.

Síntese Comparativa dos Modelos

Os resultados evidenciam diferenças importantes entre os dois construtos de inovatividade analisados.

Enquanto o Domínio Específico de Inovatividade (DSI) foi explicado exclusivamente pela Motivação Social, a Inovação Inata (II) apresentou influência simultânea das motivações Social e Cognitiva.

Além disso, o Modelo 2 apresentou maior capacidade explicativa ($R^2 = 48,5\%$) quando comparado ao Modelo 1 ($R^2 = 26,7\%$), sugerindo que os fatores motivacionais investigados estão mais fortemente associados à predisposição geral à inovação do que à inovatividade relacionada a um domínio específico.

De forma geral, os achados indicam que a dimensão social constitui o principal antecedente da adoção e utilização de Inteligência Artificial entre estudantes dos cursos de tecnologia. Adicionalmente, a dimensão cognitiva contribui para explicar a Inovação Inata, reforçando a importância da curiosidade intelectual, da

busca por conhecimento e da aprendizagem contínua na formação de comportamentos inovadores. A Tabela 9 apresenta uma síntese dos resultados obtidos para as hipóteses propostas nesta pesquisa.

Tabela 9. Síntese dos resultados das hipóteses

Hipótese	Resultado
H1	Rejeitada
H2	Confirmada
H3	Rejeitada
H4	Rejeitada
H5	Rejeitada
H6	Confirmada
H7	Confirmada
H8	Rejeitada

Fonte: Elaborado pelos autores (2026).

CONSIDERAÇÕES FINAIS

O presente estudo teve como objetivo analisar a influência das motivações funcional, social, hedônica e cognitiva sobre a adoção e o uso da Inteligência Artificial por estudantes dos cursos superiores de tecnologia da Faculdade de Tecnologia do Estado de São Paulo (FATEC) e outras instituições, utilizando os construtos de Domínio Específico de Inovatividade (DSI) e Inovação Inata (II).

Para atingir esse objetivo, foi conduzida uma pesquisa quantitativa com aplicação de questionário eletrônico junto a 110 estudantes, cujos dados foram analisados por meio da técnica de regressão linear múltipla utilizando o *software* SPSS. Foram estimados dois modelos analíticos, permitindo avaliar a influência das diferentes dimensões motivacionais sobre dois construtos distintos de inovatividade.

Os resultados evidenciaram que ambos os modelos apresentaram significância estatística global, demonstrando que as motivações analisadas contribuem para a compreensão do comportamento inovador dos estudantes. No entanto, observou-se que a influência das motivações não ocorre de maneira homogênea.

No Modelo 1, que utilizou o Domínio Específico de Inovatividade (DSI) como variável dependente, apenas a Motivação Social apresentou influência positiva e estatisticamente significativa. Esse resultado sugere que fatores relacionados à interação social, reconhecimento, pertencimento a grupos e influência de pares exercem papel relevante na disposição dos estudantes para adotar tecnologias inovadoras em contextos específicos.

Já no Modelo 2, que utilizou a Inovação Inata (II) como variável dependente, verificou-se que tanto a Motivação Social quanto a Motivação Cognitiva apresentaram influência significativa. Esse achado indica que indivíduos mais motivados pela busca de conhecimento, aprendizagem e exploração intelectual tendem a apresentar maior predisposição geral para comportamentos inovadores. Ao mesmo tempo, reforça-se a relevância dos fatores sociais como elemento central na formação e manifestação da inovatividade.

Um dos resultados mais relevantes da pesquisa consiste na identificação da Motivação Social como o principal antecedente da inovatividade em ambos os modelos analisados. Tal evidência sugere que a adoção

e o uso da Inteligência Artificial entre estudantes de tecnologia não dependem exclusivamente de fatores utilitários ou técnicos, mas também de elementos relacionados à influência social, à troca de experiências e à percepção de reconhecimento dentro dos grupos aos quais os indivíduos pertencem.

Contrariando parte da literatura tradicional de adoção tecnológica, os resultados indicam que fatores sociais apresentaram maior capacidade explicativa da inovatividade do que fatores funcionais relacionados à utilidade percebida da tecnologia. Esse achado sugere que, no contexto investigado, a interação entre os estudantes e a validação social associada ao uso da IA podem exercer papel mais relevante do que os benefícios operacionais proporcionados pela ferramenta.

Adicionalmente, verificou-se que as motivações funcional e hedônica não apresentaram efeitos estatisticamente significativos em nenhum dos modelos. Embora a literatura frequentemente associe utilidade percebida e prazer de uso à adoção tecnológica, os resultados encontrados indicam que, para o contexto investigado, esses fatores não são suficientes para explicar os níveis de inovatividade dos estudantes quando analisados conjuntamente com as demais motivações.

Uma possível explicação para a ausência de significância da Motivação Funcional reside no fato de que a utilidade das ferramentas de Inteligência Artificial já pode ser amplamente reconhecida entre estudantes de cursos de tecnologia. Nesse contexto, a percepção de utilidade deixa de atuar como um fator diferenciador entre indivíduos mais ou menos inovadores, uma vez que seus benefícios práticos tendem a ser considerados pressupostos pelos usuários.

De maneira semelhante, a não significância da Motivação Hedônica sugere que aspectos relacionados ao prazer e ao entretenimento proporcionados pelo uso da tecnologia possuem menor relevância em ambientes acadêmicos orientados para desempenho e aprendizagem.

Sendo assim, os estudantes podem perceber a Inteligência Artificial predominantemente como uma ferramenta de apoio às suas atividades educacionais e profissionais, reduzindo a influência de fatores lúdicos sobre seus comportamentos inovadores.

Contribuições Teóricas e Empíricas

Do ponto de vista teórico, a pesquisa contribui para ampliar a compreensão dos fatores que influenciam a adoção de tecnologias baseadas em Inteligência Artificial no ambiente educacional.

Por outro lado, do ponto de vista empírico, a pesquisa oferece evidências obtidas junto a estudantes de cursos superiores de tecnologia, contribuindo para a compreensão do comportamento de adoção da Inteligência Artificial em um contexto acadêmico ainda pouco explorado pela literatura nacional. Os resultados permitem identificar quais dimensões motivacionais apresentam maior relevância para a inovatividade dos estudantes, fornecendo subsídios para futuras investigações quantitativas sobre o tema.

Os resultados reforçam a importância das dimensões sociais e cognitivas na explicação do comportamento inovador, oferecendo evidências empíricas para o desenvolvimento de futuros estudos sobre inovação e adoção tecnológica.

Adicionalmente, o estudo apresenta evidências de que fatores sociais possuem maior capacidade explicativa da inovatividade dos estudantes investigados do que fatores tradicionalmente associados à utilidade percebida da tecnologia. Tal resultado amplia as discussões sobre adoção tecnológica ao demonstrar que a interação social e o reconhecimento entre pares podem exercer papel mais relevante do que aspectos puramente funcionais no contexto da Inteligência Artificial aplicada ao ensino superior.

Em síntese, conclui-se que os fatores sociais desempenham papel central na explicação da inovatividade dos estudantes investigados, enquanto os fatores cognitivos contribuem especificamente para a formação da Inovação Inata. Esses resultados evidenciam que a adoção e o uso da Inteligência Artificial transcendem aspectos puramente tecnológicos, envolvendo processos sociais e cognitivos que influenciam diretamente o comportamento inovador dos indivíduos.

Implicações Práticas

Os resultados sugerem que instituições de ensino superior interessadas em ampliar a adoção inovadora da Inteligência Artificial devem priorizar estratégias colaborativas em detrimento de abordagens exclusivamente técnicas. A criação de comunidades de prática, grupos de estudo, *hackathons*, projetos interdisciplinares e espaços de compartilhamento de experiências pode potencializar a influência social observada neste estudo. Além disso, iniciativas que estimulem a curiosidade intelectual e a experimentação tecnológica podem contribuir para o fortalecimento da Inovação Inata dos estudantes.

Primeiramente, para os professores, os achados indicam a importância de promover atividades que incentivem a colaboração entre os alunos no uso da IA, como projetos em grupo, debates sobre aplicações da tecnologia, desafios práticos e momentos de compartilhamento de experiências. Essas estratégias podem fortalecer tanto a aprendizagem quanto o reconhecimento social associado ao uso inovador dessas ferramentas.

Paralelamente a isso, para os estudantes, os resultados evidenciam que o desenvolvimento de comportamentos inovadores não depende apenas do domínio técnico da Inteligência Artificial, mas também da participação em redes de aprendizagem e da busca contínua por novos conhecimentos. Assim, recomenda-se o envolvimento em grupos de estudo, eventos acadêmicos, projetos extracurriculares e atividades que favoreçam a troca de experiências e a experimentação de novas aplicações da IA.

Por fim, sob a perspectiva dos gestores educacionais, os resultados sugerem a necessidade de criar ambientes institucionais que favoreçam a interação entre estudantes, docentes e tecnologias emergentes. Investimentos em laboratórios de inovação, programas de capacitação, eventos temáticos, competições acadêmicas e políticas de incentivo ao uso responsável da Inteligência Artificial podem contribuir para o fortalecimento de uma cultura de inovação alinhada às demandas contemporâneas do ensino superior.

Limitações e Pesquisas Futuras

Como toda pesquisa, este estudo apresenta limitações. A amostra foi composta por estudantes de cursos de tecnologia da FATEC e de outras instituições de ensino superior, o que limita a generalização dos resultados para outros contextos educacionais ou profissionais de forma abrangente. Além disso, os dados foram coletados em um único momento no tempo, caracterizando um recorte transversal do fenômeno investigado, o que impossibilita estabelecer relações de causalidade de forma definitiva entre as variáveis analisadas.

Outra limitação refere-se ao uso de dados obtidos por meio de autorrelato dos participantes, estando os resultados sujeitos a possíveis vieses de percepção individual e desejabilidade social. Adicionalmente, considerando a rápida evolução das tecnologias de Inteligência Artificial generativa, os achados refletem um contexto tecnológico específico, podendo sofrer alterações à medida que novas ferramentas, funcionalidades e formas de utilização se consolidem no ambiente acadêmico.

Dessa forma, recomenda-se que pesquisas futuras ampliem a amostra para uma variedade ainda maior de instituições de ensino, diferentes áreas do conhecimento e distintos perfis de usuários de Inteligência Artificial. Também são recomendados estudos longitudinais que permitam acompanhar a evolução da adoção dessas tecnologias ao longo do tempo, bem como investigações que utilizem métodos mistos ou abordagens qualitativas para aprofundar a compreensão dos fatores motivacionais associados ao comportamento inovativo.

Por fim, sugere-se a inclusão de novos construtos capazes de ampliar o entendimento dos determinantes da inovatividade e da adoção da IA em contextos educacionais e profissionais.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGARWAL, R. & PRASAD, J. *A Conceptual and Operational Definition of Personal Innovativeness in the Domain of Information Technology*. *Information Systems Research*, 9(2), 204–215, 1998. <http://www.jstor.org/stable/23010927>
- ALBA, J. W. & HUTCHINSON, J. W. *Dimensions of consumer expertise*. *Journal of Consumer Research*, v. 13, n. 4, p. 411-454, 1987. <https://doi.org/10.1086/209080>
- ARAUJO, C. F. et al. *Domain-specific innovativeness: a meta-analysis in business and consumer*. *RAI Revista de Administração e Inovação*, v. 13, n. 2, p. 99–106, 2016. <https://doi.org/10.1016/j.rai.2016.03.003>
- BANDURA, A. *Social Foundations of Thought and action: a Social Cognitive Theory*. Englewood Cliffs, NJ: Prentice-Hall, 1986.
- BHATTACHERJEE, A. *Understanding Information Systems Continuance: An Expectation-Confirmation Model*. *MIS Quarterly* 1 September 2001; 25 (3): 351–370. <https://doi.org/10.2307/3250921>
- CHIU, T. K. F. *Digital support for student engagement in blended learning based on self-determination theory*. *Computers in Human Behavior*, v. 124, art. 106909, 2021. <https://doi.org/10.1016/j.chb.2021.106909>
- DAVIS, F. D. et al. *Extrinsic and Intrinsic Motivation to Use Computers in the Workplace*. *Journal of Applied Social Psychology*, 22: 1111-1132, 1992. <https://doi.org/10.1111/j.1559-1816.1992.tb00945.x>
- DWIVEDI, Y. K. et al. “So what if ChatGPT wrote it?” *Multidisciplinary perspectives on opportunities, challenges and implications of generative conversational AI for research, practice and policy*. *International Journal of Information Management*, 71, Article 102642. <https://doi.org/10.1016/j.ijinfomgt.2023.102642>
- GOLDSMITH, R. E. & HOFACKER, C. F. *Measuring consumer innovativeness*. *JAMS* 19, 209–221 (1991). <https://doi.org/10.1007/BF02726497>
- HAIR, J. F. et al. *Multivariate data analysis*. 8. ed. Andover: Cengage Learning, 2019.
- KIM, W. B. et al. *Relationships among consumer innovativeness, learning, and global product purchases: store manager perspectives in retailing*. *Journal of Retailing and Consumer Services*, v. 82, p. 104084, 2025. <https://doi.org/10.1016/j.jretconser.2024.104084>
- LUI, M. L. C. *Serviços digitais inteligentes: a influência da motivação e da satisfação com a vida no comportamento inovativo e na usabilidade*. 211 f. Tese (Doutorado em Administração de Empresas) - Centro Universitário FEI, São Paulo, 2021. <https://doi.org/10.31414/ADM.2021.T.131686>
- MALHOTRA, N. K. *Pesquisa de marketing: uma orientação aplicada*. 7. ed. Porto Alegre: Bookman, 2019.

NETLAND, T. et al. *Comparing human-made and AI-generated teaching videos: An experimental study on learning effects*. Computers & Education, v. 224, p. 105164, 2025. <https://doi.org/10.1016/j.compedu.2024.105164>

ROGERS, E. M. *Diffusion of Innovations*. 5. ed. New York: Free Press, 2003.

SALHIEH, S. M. & AL-ABDALLAT, Y. *Technopreneurial Intentions: The Effect of Innate Innovativeness and Academic Self-Efficacy*. Sustainability, v. 14, n. 1, p. 238, 2022. <https://doi.org/10.3390/su14010238>

SCHUMPETER, J. *The theory of economic development*. Harvard Economic Studies, 1934.

VENKATESH, V. et al. *Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology*. MIS Quarterly, Vol. 36, No. 1, pp. 157-178, 2012. <https://doi.org/10.2307/41410412>

VENKATESH, V. et al. *User Acceptance of Information Technology: Toward A Unified View*. MIS Quarterly, 27, pp. 425-478, 2003. <https://doi.org/10.2307/30036540>

YAN, L. et al. *The effects of generative AI agents and scaffolding on enhancing students' comprehension of visual learning analytics*. Computers & Education, v. 234, p. 105322, 2025. <https://doi.org/10.1016/j.compedu.2025.105322>

AGRADECIMENTOS

Agradeço, primeiramente, ao meu orientador, Prof. Dr. Marcio de La Cruz Lui, pelo direcionamento preciso, paciência e valiosas contribuições que tornaram viável a realização e o amadurecimento científico desta pesquisa; em seguida, à minha família e aos meus amigos, pelo apoio incondicional, compreensão e incentivo nos momentos de maior dedicação e desafio ao longo desta jornada acadêmica; e, por fim, à Faculdade de Tecnologia do Estado de São Paulo (FATEC) de Itu, pelo espaço de constante aprendizado, infraestrutura e corpo docente que propiciaram minha formação e o desenvolvimento deste trabalho.

INTELIGÊNCIA ARTIFICIAL E APRENDIZAGEM BASEADA EM PROBLEMAS (PBL): POSSIBILIDADES E DESAFIOS NO ENSINO SUPERIOR

ARTIFICIAL INTELLIGENCE AND PROBLEM-BASED LEARNING (PBL): OPPORTUNITIES AND CHALLENGES IN HIGHER EDUCATION

Tatiana LANÇA

tatiana.lanca@anchieta.br

Ciência da Computação, Centro Universitário Padre Anchieta

Rômulo PREZOTTO

romulo.prezotto@anchieta.br

Gestão de Negócios, Centro Universitário Padre Anchieta

Vanderlei IENNE

vanderlei.ienne@anchieta.br

Ciência da Computação, Centro Universitário Padre Anchieta

Resumo

O uso de modelos de Inteligência artificial (IA) está a cada dia ganhando maior papel de destaque em diversos cenários, dentre os quais, a educação também passou a fazer parte. Nesse sentido, este trabalho tem como objetivo discutir a utilização da inteligência artificial no ensino superior. Analisamos alguns casos envolvendo o uso do modelo IA *Gemini* e discutimos possibilidades e limitações do seu uso. Além disso, foi proposto o uso de IA também como uma metodologia ativa (especificamente PBL) que pode ser utilizada no ensino superior e adaptada para EaD. Por outro lado, entendemos que é importante discutir que há muitos benefícios na utilização da metodologia PBL e a IA, mas, também encontramos algumas limitações, como por exemplo, a dificuldade em se conseguir um planejamento cuidadoso e a utilização de ferramentas adequadas para o ensino, em geral.

Palavras-Chave: Inteligência Artificial; PBL; Ensino Superior; Tecnologia.

Abstract

The use of Artificial Intelligence (AI) models has been gaining increasing prominence in several contexts, including education. In this regard, this study aims to discuss the use of Artificial Intelligence in higher education. We analyzed some cases involving the use of the Gemini AI model and discussed both the possibilities and limitations of its application. Furthermore, the study proposes the use of AI as part of an active learning methodology, specifically Problem-Based Learning (PBL), which can be implemented in higher education and adapted to distance education settings. On the other hand, while we recognize the many benefits associated with the use of PBL and AI, we also identified certain limitations, such as the challenges involved in developing careful instructional planning and selecting appropriate educational tools for teaching and learning processes in general.

Keywords: Artificial Intelligence; Problem-Based Learning (PBL); Higher Education; Technology.

INTRODUÇÃO

Para entender o contexto da inteligência artificial no ambiente acadêmico de ensino superior é de extrema relevância se pensar ao mesmo tempo no seu surgimento e também no seu uso enquanto ferramenta no ensino.

A inteligência artificial (IA), surgida na década de 1950, tem sua origem praticamente confundida com a própria origem do computador (SICHMAN, 2021).

Já nos anos 50, Alan Turing publica um artigo com o tema “Computing Machinery and Intelligence”, objetivando responder se as máquinas teriam a capacidade de pensar e conversar como se fosse um humano. Este artigo leva então a criação do Teste de Turing, onde era testada a capacidade de uma máquina se comportar da mesma maneira que um ser humano (COSTA; BRUNO, 2024, p.78).

Enquanto professores discutimos muito sobre “como” utilizar a IA e também o “deve” ou “pode” ser utilizada no ensino. Ou ainda, é possível se dificultar o uso da IA pelos alunos, por exemplo, em trabalhos ou em provas. Talvez seja importante também refletirmos sobre a questão: “e nós, professores, utilizamos a ferramenta? Se sim, de que maneira?”

Como podemos investigar os benefícios e os desafios trazidos pela inteligência artificial em diferentes áreas, como educação? Nesse sentido escolhemos alguns tópicos e pedimos ao modelo de IA *Gemini* para propor uma resolução.

O crescimento da IA e sua importância são fatores inegáveis atualmente.

A expansão da IA no campo educacional tem possibilitado novas formas de personalização da aprendizagem, apoiadas por recursos como machine learning, sistemas inteligentes e ambientes adaptativos (HOLMES; BIALIK; FADEL, 2019).

Ainda nesse sentido, podemos destacar alguns aspectos:

Aspectos positivos: produtividade, uso na medicina, educação, automação e inovação.

Aspectos negativos: desemprego tecnológico, vieses algorítmicos, privacidade e desinformação.

Questões éticas: responsabilidade, transparência e regulamentação.

Refletindo sobre estes aspectos, entendemos que existe a urgente necessidade de equilibrar inovação e uso responsável, pois, concordamos com Carvalho (2021) quando afirma que uso da inteligência artificial também está presente no marketing, onde mencionar o uso de IA em um produto é visto ou se pretende mostrar como uma garantia de qualidade, o que nem sempre é verdade.

Existem muitas notícias que expõe decisões preconceituosas tomadas por IA, como por exemplo em ferramentas de identificação de criminosos, onde a IA utilizava um algoritmo com informações raciais para a tomada de decisão e com isso, as pessoas com maior probabilidade de serem presas seriam de uma determinada raça. Por isso, uma IA justa ajuda na prevenção de modelos preconceituosos que levem em conta aspectos de classe social, renda, raça, orientação sexual etc (CARVALHO, 2021).

Especificamente tratando da área da educação, não se pode pensar em IA sem relacionar sua relação ao desenvolvimento da tecnologia e o ensino à distância.

Melhorar o acesso e a qualidade da educação requer liderança política, planejamento e ação. As tecnologias móveis têm a chave para transformar a exclusão digital que existe atualmente em dividendos digitais, trazendo consigo uma educação inclusiva e equitativa de qualidade para todos.

Nesse sentido, um exemplo de modelo educacional aberto vem da UNESCO, criada em 2002 e consolidados pela Declaração de Paris em 2012 e consiste em materiais de ensino, aprendizagem e investigação que estão no domínio público ou foram divulgados sob licença aberta, permitindo acesso, uso, adaptação e redistribuição gratuitos.

O compartilhamento de conhecimento por meio dos Recursos Educacionais Abertos (REA) representa um avanço significativo rumo à democratização da educação. Ao disponibilizar materiais didáticos, científicos e culturais com licenças abertas, os REA permitem que educadores, estudantes e instituições de todo o mundo acessem, adaptem, reutilizem e distribuam conteúdos gratuitamente. Essa abordagem contribui para reduzir desigualdades educacionais, fortalecer a colaboração entre comunidades acadêmicas e promover a inovação pedagógica. Segundo a UNESCO (2019), os REA são instrumentos estratégicos para garantir o acesso equitativo ao conhecimento, especialmente em contextos de escassez de recursos e exclusão digital (LANÇA, BRUNETTI, IENNE, 2026, p.287).

Ainda no que se refere ao ensino, podemos entender que o ensino tradicional e presencial, com centro no professor, muitas vezes compromete o pensamento crítico por parte do estudante, que tenta apenas “decorar” aquilo que está sendo ensinado. Este cenário vem passando por modificações ao longo dos anos.

Não podemos esquecer que aprendizagem móvel surge como uma das soluções para os desafios enfrentados pela educação. Melhorar o acesso e a qualidade da educação requer liderança política, planejamento e ação. As tecnologias móveis têm a chave para transformar a exclusão digital que existe atualmente em dividendos digitais, trazendo consigo uma educação inclusiva e equitativa de qualidade para todos.

Ainda de acordo com Lança (2018, p. 135):

É bastante válida a utilização de atividades diferentes das usuais quando de pretende promover a aproximação dos alunos com determinados conteúdos além de estimular sua participação. [...] O que entendemos é que essas aulas mais tradicionais podem ser mescladas com aulas que possam contar com a maior participação dos alunos, e neste caso, trazer elementos do cotidiano pode ser uma estratégia interessante.

A partir desta pesquisa podemos pensar que é possível propor metodologias diferentes das usuais no ensino superior, tentando descentralizar do professor o foco. Aqui, a leitura pode ser entendida como uma das ferramentas. É possível, a partir de outros trabalhos, compreender que há outras ferramentas possíveis. Outras metodologias de ensino, como sala de aula invertida, aprendizagem baseada em problemas. Aqui entra o uso da IA pelo professor e como pode auxiliar o uso com os alunos?

A inteligência artificial pode ser utilizada ao se pensar a metodologia ativa PBL, por exemplo. Diferentemente do que é comum no ensino tradicional, no método PBL, por outro lado, a aprendizagem é focada no envolvimento ativo do aluno que dele requer atividades colaborativas, construtivas e contextualizadas do conhecimento. Essa é uma metodologia ativa que pode ser adaptada para o ensino superior e também para EaD, pois, permite os alunos estudarem em grupos, desenvolvendo a colaboração e a análise crítica, por exemplo. Na educação a distância, o método PBL pode ser implementado através de plataformas online que oferecem ferramentas de colaboração, como fóruns de discussão, chats e videoconferências, para facilitar a interação entre os alunos e com o tutor. O uso de plataforma específica em cada instituição de ensino pode ser um grande aliado ao ensino neste contexto.

FUNDAMENTAÇÃO TEÓRICA

Autores como Russell e Norvig (2010) são principais referências para entender conceitos, aplicações e avanços da IA.

Atualmente, atravessamos novamente um período de euforia sobre os possíveis benefícios que a IA pode prover. Tal otimismo se justifica por uma conjunção de três fatores fundamentais: (i) o custo de processamento e de memória nunca foi tão barato; (ii) o surgimento de novos paradigmas, como as redes neurais profundas, possibilitados pelo primeiro fator e produzindo inegáveis avanços científicos; e (iii) uma quantidade de dados gigantesca disponível na internet em razão do grande uso de recursos tais como redes e mídias sociais. Tal entusiasmo, entretanto, vem sido acompanhado por uma série de temores, alguns dos quais fundados (SICHMAN, 2021, p.37).

Ainda de acordo com o que afirma Sichman, (2021),

cabe ressaltar que não existe uma definição acadêmica, propriamente dita, do que vem a ser IA. Trata-se certamente de um ramo da ciência/engenharia da computação, e portanto, visa desenvolver sistemas computacionais que solucionam problemas. Para tal, utiliza um número diverso de técnicas e modelos, dependendo dos problemas abordados.

Santos e Santos (2025) analisam o potencial da Inteligência Artificial (IA) como mediadora da aprendizagem em Educação Financeira (EF), fundamentado na Teoria da Aprendizagem Significativa e nas diretrizes da Base Nacional Comum Curricular (BNCC).

Segundo os autores, no ensino de EF, plataformas inteligentes como ChatGPT, Gemini ou Copilot permitem tanto a resolução de problemas financeiros quanto a simulação de cenários reais de tomada de decisão, favorecendo o pensamento crítico e a autonomia intelectual (MORAN; BACICH; TREVISANI, 2020)

Ainda de acordo com Santos e Santos (2025, p.8):

O estudo também identificou que o Brasil se encontra em estágio emergente na integração da IA ao ensino médio, enquanto países como Coreia do Sul e Finlândia já implementam políticas estruturadas de personalização curricular mediada por IA.

O contato com ferramentas de IA prepara os estudantes para um mercado de trabalho cada vez mais tecnológico. A escola deve ensinar não apenas conteúdos tradicionais, mas também o uso crítico e responsável das novas tecnologias. Nesse sentido, o uso da IA pode aparecer como metodologia ativa, por exemplo na utilização do método PBL.

Pensamos que é importante se atentar a questão: o uso de modelos de IA pode acontecer em formatos de ensino presencial ou EaD. pois, apesar das vantagens que sabemos que existe no que se refere ao ensino a distância, como alternativa para ampliar o acesso, também são encontrados problemas no que se refere, principalmente à formação de professores com habilidades específicas nesta área mais recente de ensino. Apesar disso, o uso de EaD em cursos presenciais de graduação é visto como uma possibilidade que, desde 2001, vem sendo regulamentada por diferentes normativas, as quais vêm alterando questões de nomenclatura, requisitos, bem como do percentual permitido. (FELCHER *et al.*, 2024)

Por outro lado, no que se refere aos estudos relativos ao ensino a partir de resolução de problemas (PBL), de acordo com Borochovcicius e Tassoni (2021, p.3):

A Aprendizagem Baseada em Problemas (ABP), conhecida na língua inglesa por Problem-Based Learning (PBL), é um método de ensino e aprendizagem que nasceu em 1965 na escola de medicina de McMaster, na cidade de Hamilton, província de Ontário, no Canadá. O objetivo era ampliar o conhecimento e o desenvolvimento das habilidades médicas dos alunos em trabalho coletivo, cooperativo e colaborativo, partindo de situações-problema hipotéticas e próximas daquilo que os futuros médicos encontrariam em suas vidas profissionais.

Focar o modo como a Aprendizagem Baseada na Resolução de Problemas coloca os estudantes e os jovens no centro da relação pedagógica de construção do saber com realização de direitos, permitindo compreender articulações da educação com o exercício da cidadania educacional. (MACEDO *et al.*, 2023).

Aliada à metodologia PBL, a IA pode auxiliar na resolução de problemas. Ainda na linha de resolução de problemas, Lança, Brunetti e Ienne (2026) discutiram a utilização do método PBL no ensino superior. Segundo os autores, quando nos propomos pensar o método PBL e sua relação com o ensino à distância, pode-se discutir alguns benefícios desta abordagem. A seguir, listamos alguns deles, destacados pelos autores (LANÇA; BRUNETTI; IENNE, 2026, p. 292):

- **Permite desenvolver habilidades de resolução de problemas:**
O PBL estimula a aplicação prática do conhecimento e o desenvolvimento de habilidades de pesquisa, análise crítica e tomada de decisão.
- **Engajamento e motivação dos alunos:**
Ao trabalhar com problemas reais e relevantes, os alunos se sentem mais envolvidos e motivados a aprender.
- **Poderem ser reutilizáveis e adaptáveis:**
Podem ser usados em diferentes contextos educacionais e podem ser modificados conforme as necessidades culturais, linguísticas ou pedagógicas do usuário.
- **Acessíveis Digitalmente:**
Em geral, estão disponíveis online, mas podem ser adaptados para formatos offline.
- **Aprendizagem mais significativa:**
Ao conectar o conteúdo teórico com situações práticas, o PBL torna o aprendizado mais significativo e duradouro.
- **Promoção da autonomia e da colaboração:**
A metodologia incentiva a autonomia do aluno no processo de aprendizagem e a colaboração entre os membros do grupo.

No entanto, vale ressaltar que a implementação do PBL na EAD, especialmente, exige um planejamento cuidadoso e a utilização de ferramentas adequadas, mas os resultados esperados em termos de aprendizado e desenvolvimento de habilidades são positivos. Além disso, a implementação do PBL aliado ao uso da IA também exige que aspectos éticos, sociais e sejam tratados de maneira cautelosa.

A IA pode permitir a personalização da aprendizagem. Além disso, também pode adaptar conteúdos, exercícios e explicações ao ritmo de cada aluno. Enquanto alguns precisam de reforço em determinados temas, outros podem avançar mais rapidamente.

Uma breve discussão sobre IA: escrita de um código (situação 1) e problema de circuito elétrico (situação 2)

Concordamos com Santos e Santos (2025) quando reforçam a relevância dos conhecimentos prévios para a aprendizagem significativa, e neste caso, a IA atuaria como uma aliada:

Segundo Ausubel (2003), a aprendizagem significativa ocorre quando novos conceitos se integram aos conhecimentos prévios de forma substantiva e não arbitrária. Para isso, organizadores prévios são fundamentais no processo de ancoragem cognitiva. A IA contribui diretamente para essa lógica ao diagnosticar conhecimentos prévios, adaptar atividades e oferecer recursos introdutórios contextualizados, funcionando como “organizadores prévios digitais” (SANTOS; SANTOS, 2025, p. 3).

Nesse sentido, pensando em conhecimento prévio e adaptações de atividades, propomos análises de duas situações no ensino superior. Na situação 1 analisamos os casos I e II. A seguir, analisamos a situação 2, com o caso I.

Caso I – Apresentação de uma proposta de algoritmo:

Um programador foi incumbido de realizar um algoritmo para coletar a quantidade de mulheres e de homens em um determinado evento, porém, algo deu errado. A variável que era para receber o número de mulheres acabou recebendo o número de homens e vice-versa. Agora, você precisa ajustar rapidamente esses valores.

Qual a forma mais adequada para realizar essa troca utilizando um algoritmo em pseudocódigo?

Apresente uma proposta de algoritmo que resolva o problema em questão.

No modelo de inteligência artificial, *Gemini*, foi escrita a situação exemplificada pelo Quadro 1, a seguir.

Quadro 1: texto que foi fornecido ao *Gemini*.

Olá! Tudo bem com você?

Como posso te ajudar hoje?

sou um aluno de análise e desenvolvimento de sistema e preciso resolver uma questão. Você pode me auxiliar?

Com certeza! Parabéns pela escolha do curso, ADS é uma área excelente e cheia de desafios instigantes.

Pode mandar a questão! Pode ser sobre lógica de programação, banco de dados, engenharia de software, estrutura de dados ou o que for.

Se quiser, além da resposta, posso te explicar o raciocínio passo a passo para te ajudar a fixar o conteúdo. Manda bala!

A questão é a seguinte:

Um programador foi incumbido de realizar um algoritmo para coletar a quantidade de mulheres e de homens em um determinado evento, porém, algo deu errado. A variável que era para receber o número de mulheres acabou recebendo o número de homens e vice-versa. Agora, você precisa ajustar rapidamente esses valores. Qual a forma mais adequada para realizar essa troca utilizando um algoritmo em pseudocódigo? Apresente uma proposta de algoritmo que resolva o problema em questão.

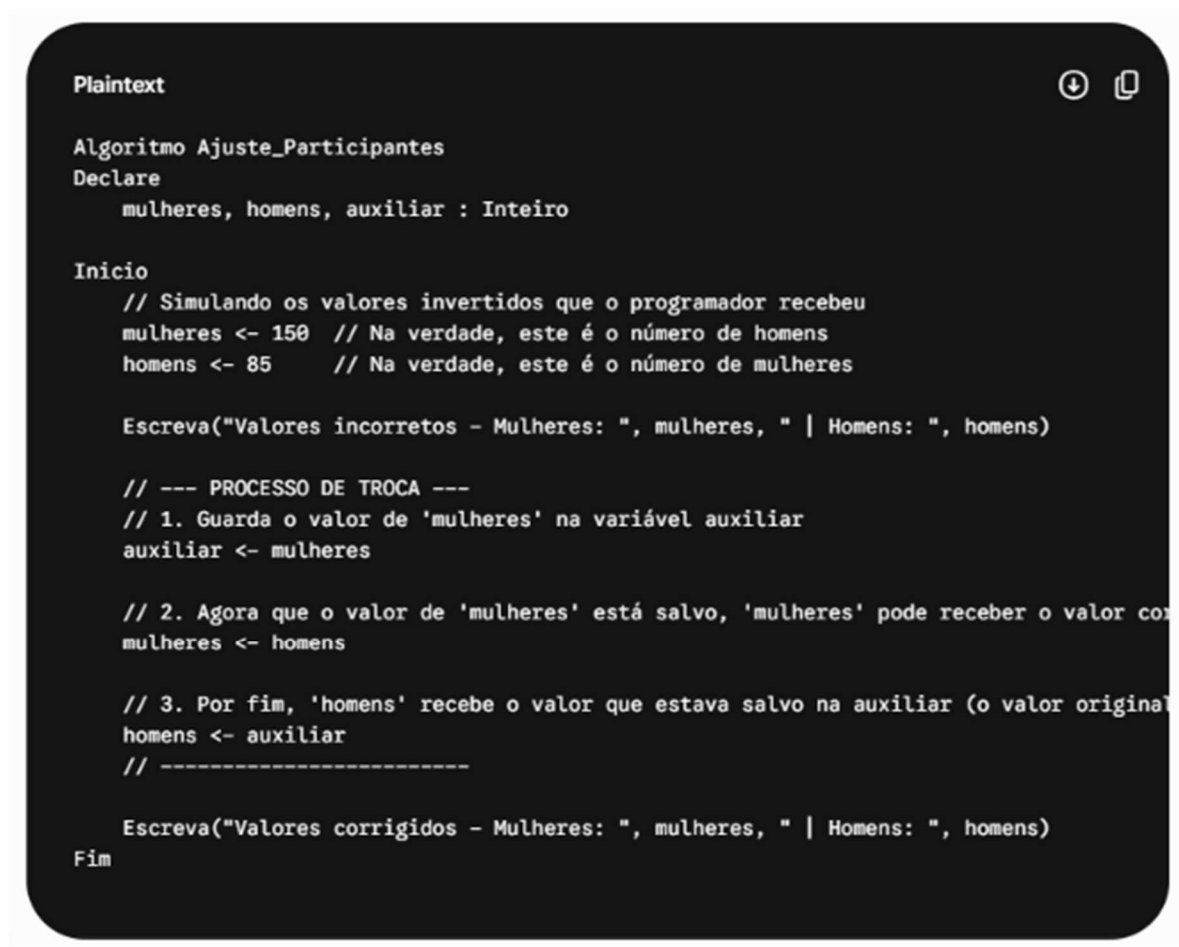
Para resolver esse problema, precisamos trocar os valores de duas variáveis. Em programação, se atribuírmos diretamente o valor de uma variável à outra (por exemplo, `mulheres = homens`), o valor original de `mulheres` será apagado e perdido.

A forma mais clássica, segura e adequada de realizar essa troca é utilizando uma **variável auxiliar** (temporária) para guardar um dos valores enquanto a troca é feita. Pense nisso como ter dois copos cheios (um com água e outro com suco) e precisar trocar os líquidos de copo: você precisará de um terceiro copo vazio para ajudar no processo.

Fonte: gerada por inteligência artificial (IA – *Gemini*).

O Quadro 2 apresenta o print da resposta gerada pelo modelo de IA - *Gemini*.

Quadro 2: print da resposta gerada pela IA.



```

Plaintext

Algoritmo Ajuste_Participantes
Declare
    mulheres, homens, auxiliar : Inteiro

Início
    // Simulando os valores invertidos que o programador recebeu
    mulheres <- 150 // Na verdade, este é o número de homens
    homens <- 85    // Na verdade, este é o número de mulheres

    Escreva("Valores incorretos - Mulheres: ", mulheres, " | Homens: ", homens)

    // --- PROCESSO DE TROCA ---
    // 1. Guarda o valor de 'mulheres' na variável auxiliar
    auxiliar <- mulheres

    // 2. Agora que o valor de 'mulheres' está salvo, 'mulheres' pode receber o valor contido em 'homens'
    mulheres <- homens

    // 3. Por fim, 'homens' recebe o valor que estava salvo na auxiliar (o valor original de 'mulheres')
    homens <- auxiliar
    // -----

    Escreva("Valores corrigidos - Mulheres: ", mulheres, " | Homens: ", homens)
Fim
  
```

Fonte: gerada por inteligência artificial (IA – *Gemini*).

De acordo com o que se conhece em relação ao estudo de algoritmo e ao pseudocódigo (FORBELLONE; EBERSPACHER, 2025), entendemos que a proposta de resposta fornecida está de acordo com o esperado.

Discussão: o professor propõe um problema. Aluno coloca em um modelo de IA e obtém a resposta. O que essa situação acrescentou ao desenvolvimento intelectual do estudante? O modelo de IA foi bastante útil para fornecer a resposta, mas não promoveu a investigação. Uma pergunta que podemos fazer: em que situações o uso da IA pode ser benéfico no ensino?

No caso do professor, entendemos que a IA pode auxiliar na correção de atividades, elaboração de materiais didáticos, criação de exercícios e organização de planos de aula, desde que o seu uso esteja atrelado ao conhecimento técnico do professor. Ao automatizar tarefas repetitivas, os professores podem dedicar mais tempo ao acompanhamento pedagógico dos alunos, tornando o processo mais ágil.

No caso dos alunos, o contato com ferramentas de IA pode preparar os estudantes para um mercado de trabalho cada vez mais tecnológico, no entanto, é importante sempre se estar atento ao fato de que o seu uso pode impactar diretamente nos questionamentos que os alunos podem deixar de fazer.

Caso II – Apresentação de uma proposta de algoritmo:

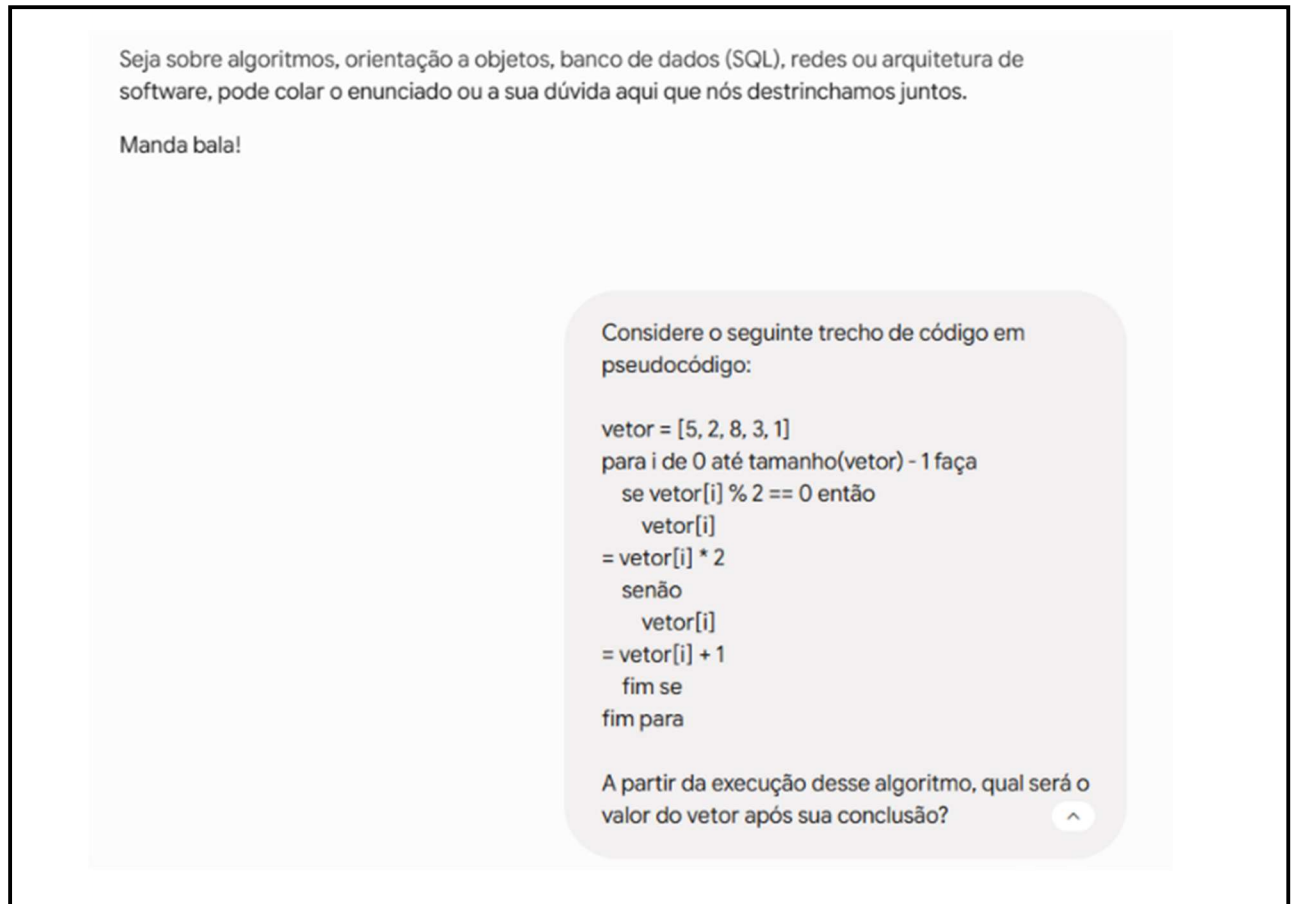
Considere o seguinte trecho de código em pseudocódigo:

```
vetor = [5, 2, 8, 3, 1]  
para i de 0 até tamanho(vetor) - 1 faça  
    se vetor[i] % 2 == 0 então  
        vetor[i] = vetor[i] * 2  
    senão  
        vetor[i] = vetor[i] + 1  
    fim se  
fim para
```

A partir da execução desse algoritmo, qual será o valor do vetor após sua conclusão?

A resposta fornecida pelo *Gemini* está representada no Quadro 3.

Quadro 3: texto informado ao Gemini.



Fonte: gerada por inteligência artificial (IA – Gemini).

A seguir, o Quadro 4 ilustra o resultado gerado pela IA.

Quadro 4: print do resultado fornecido pelo *Gemini*.

Para resolver essa questão, vamos acompanhar a execução do algoritmo passo a passo (fazer o famoso **teste de mesa**), analisando o que acontece com cada elemento do vetor.

A lógica do código avalia cada número usando o operador `% 2` (resto da divisão por 2):

- o Se o resto for igual a 0, o número é **par** e será **multiplicado por 2** (`vetor[i] * 2`).
- o Se o resto não for 0, o número é **ímpar** e será **somado a 1** (`vetor[i] + 1`).

Teste de Mesa (Passo a Passo)

O vetor inicial é: `[5, 2, 8, 3, 1]`

- o Índice `i = 0` (Valor: 5):
 - o 5 é ímpar.
 - o Operação: $5 + 1 = 6$
 - o Vetor atual: `[6, 2, 8, 3, 1]`
- o Índice `i = 1` (Valor: 2):
 - o 2 é par.
 - o Operação: $2 \times 2 = 4$
 - o Vetor atual: `[6, 4, 8, 3, 1]`
- o Índice `i = 2` (Valor: 8):
 - o 8 é par.
 - o Operação: $8 \times 2 = 16$
 - o Vetor atual: `[6, 4, 16, 3, 1]`
- o Índice `i = 3` (Valor: 3):
 - o 3 é ímpar.
 - o Operação: $3 + 1 = 4$
 - o Vetor atual: `[6, 4, 16, 4, 1]`
- o Índice `i = 4` (Valor: 1):
 - o 1 é ímpar.
 - o Operação: $1 + 1 = 2$
 - o Vetor atual: `[6, 4, 16, 4, 2]`

Resultado Final

Após a conclusão do laço de repetição, todos os números ímpares foram incrementados e todos os números pares foram duplicados.

O valor do vetor será:

`[6, 4, 16, 4, 2]`

Fonte: gerada por inteligência artificial (IA – *Gemini*).

A seguir, destacamos o feedback considerado geral para este tipo de questão:

Durante a execução do algoritmo, o laço "para" percorre cada elemento do vetor.

Se o elemento for par (verificado pela condição $\text{vetor}[i] \% 2 == 0$), o valor é multiplicado por 2. Caso contrário, o valor é incrementado em 1. No caso do vetor inicial $[5, 2, 8, 3, 1]$, o resultado será $[6, 4, 16, 4, 2]$.

Os elementos pares (2 e 8) são multiplicados por 2, resultando em 4 e 16, respectivamente. Os elementos ímpares (5, 3 e 1) são incrementados em 1, resultando em 6, 4 e 2, respectivamente.


Discussão: Neste caso II entendemos que, mais uma vez, o modelo de IA atendeu às expectativas. A resposta final coincide com a proposta de resposta que era esperada.

Refletindo sobre este aspecto, aqui podemos pensar, enquanto professor, que é possível construir uma atividade baseada em PBL, por exemplo. O professor pode pedir a resolução deste problema inicial e ir além. A partir da resposta fornecida pelo modelo de IA pode solicitar aos alunos uma análise da resposta dada.

Também pode acrescentar um novo pedido: “refaça a questão e altere os valores”. Qual a resposta esperada? A seguir, pode solicitar que a nova questão seja colocada em outros modelos de IA e propor a comparação entre as respostas fornecidas.

Neste ponto do texto, analisamos a situação 2. Aqui propomos a resolução de um circuito elétrico simples, exemplificado da Figura 1.

Figura 1: Representação de um circuito simples (associação mista de resistores).



Fonte: https://www.infoescola.com/wp-content/uploads/2018/10/img_5bc91845bf448.png

A imagem que representa o circuito da Figura 1 foi copiada diretamente no modelo de IA *Gemini*. Não fizemos uma pergunta específica e a resposta foi a apresentada no Quadro 6. Em geral, a pergunta que se faz no que se refere a essa figura é: qual o valor do resistor equivalente entre os pontos A e B?

Quadro 6: resolução da questão proposta.

Com certeza, esse também sai sem mistério! Vamos resolver este circuito por partes, dividindo em blocos para ficar bem fácil de visualizar.

Passo 1: Analisar o bloco central (Mistura de Série e Paralelo)

Olhando para a parte do meio, nós temos três caminhos paralelos que se dividem logo após o resistor de $3\ \Omega$ e se juntam novamente antes do resistor de $2,5\ \Omega$.

- 1 **Ramo de cima:** Tem um resistor de $18\ \Omega$.
- 2 **Ramo do meio:** Tem dois resistores em série ($4\ \Omega$ e $2\ \Omega$). Somando-os, temos:

$$R_{\text{meio}} = 4\ \Omega + 2\ \Omega = 6\ \Omega$$

- 3 **Ramo de baixo:** Tem um resistor de $9\ \Omega$.

Agora, esses três ramos ($18\ \Omega$, $6\ \Omega$ e $9\ \Omega$) estão em **paralelo**. Vamos calcular o resistor equivalente desse bloco central (R_{central}):

$$\frac{1}{R_{\text{central}}} = \frac{1}{18} + \frac{1}{6} + \frac{1}{9}$$

Para somar as frações, tiramos o MMC que é 18:

$$\frac{1}{R_{\text{central}}} = \frac{1 + 3 + 2}{18} = \frac{6}{18}$$

Invertendo os dois lados:

$$R_{\text{central}} = \frac{18}{6} = 3\ \Omega$$

Para somar as frações, tiramos o MMC que é 18:

$$\frac{1}{R_{\text{central}}} = \frac{1 + 3 + 2}{18} = \frac{6}{18}$$

Invertendo os dois lados:

$$R_{\text{central}} = \frac{18}{6} = 3\ \Omega$$

Passo 2: Analisar o bloco da direita (Paralelo)

Logo em seguida, o circuito se divide novamente em dois caminhos antes de chegar ao ponto B:

- O caminho de cima tem um resistor de $2,5 \Omega$.
- O caminho de baixo tem um resistor de 10Ω .

Como eles compartilham os mesmos nós de entrada e saída, estão em **paralelo**. Vamos calcular o equivalente desse bloco da direita (R_{direita}):

$$R_{\text{direita}} = \frac{2,5 \times 10}{2,5 + 10} = \frac{25}{12,5} = 2 \Omega$$

Passo 3: Juntar tudo no circuito final (Série)

Agora que simplificamos os blocos, imagine o circuito redesenhado do ponto A ao ponto B em uma única linha reta:

- 1 O primeiro resistor de 3Ω .
- 2 O bloco central que simplificamos para 3Ω .
- 3 O bloco da direita que simplificamos para 2Ω .

Como todos esses blocos estão em **série**, basta somar os valores para encontrar a resistência equivalente total (R_{AB}):

$$R_{AB} = 3 \Omega + 3 \Omega + 2 \Omega = 8 \Omega$$

Resposta Final

A resistência equivalente entre os pontos A e B é de 8Ω .

Fonte: gerada por inteligência artificial (IA – *Gemini*).

Discussão: Este tipo de questão tem o formato diferente das apresentadas na situação 1. Aqui, temos um problema de eletrodinâmica básica. Nele, temos que encontrar o valor do resistor equivalente. Uma das atividades que pode ser proposta pelo professor é solicitar que os alunos resolvam o circuito em sala de aula (presencialmente) sem utilização da IA. A seguir, pode sugerir que o circuito seja colocado em um modelo de IA e assim, comparar a resposta.

Uma questão que acreditamos que seja essencial pensar enquanto professor é: o modelo de questão é bastante simples. Como será que seria a resposta fornecida pela IA caso tivéssemos uma questão mais complexa? A IA sempre entende o conceito? Ou será que funciona muito bem quando se trata de algoritmo, apenas?

CONSIDERAÇÕES FINAIS

O trabalho teve como objetivo discutir a utilização da inteligência artificial (IA) no ensino superior. No que se refere ao contexto da inteligência artificial é interessante se pensar o estudo em relação ao ramo da tecnologia (código) e ao conceito (Engenharia).

Com o trabalho entendemos que a utilização da IA pode ser associada ao uso de metodologia ativa, como aplicação da metodologia PBL no ensino superior.

Ainda neste cenário, o trabalho enfatizou a relevância de se debater sobre as possibilidades de novos métodos no ensino superior, ainda que haja limitações quanto a um planejamento mais cuidadoso, por exemplo. Ressalta-se também, como uma grande contribuição, a agilidade na produção e correção de atividades, além de criação de exercícios e organização de planos de aula, desde que o seu uso esteja atrelado ao conhecimento técnico do professor.

Consideramos que a discussão que não se pode abandonar é aquela sobre o papel do professor e do aluno quando se faz uso mais frequente de modelos de inteligência artificial, sempre buscando a consolidação do aprendizado.

REFERÊNCIAS BIBLIOGRÁFICAS

BOROCHOVICIUS, E.; TASSONI, E. C. M.; Aprendizagem baseada em problemas: uma experiência no ensino fundamental, (2021, P.3). **Educação em Revista**, [S. l.], v. 37, n. 1, 2021. Disponível em: <<https://periodicos.ufmg.br/index.php/edrevista/article/view/20706>>. Acesso em: 21 jun. 2026.

COSTA, A. A.; BRUNO, D. R. IA- inteligência artificial: impactos, riscos e benefícios que desafiam a sociedade moderna. **Interface Tecnológica**, v. 21 n. 1 (2024) – ISSN (On-Line) 2447-0864.

CARVALHO, A. C. P. L. F. Inteligência Artificial: riscos, benefícios e uso responsável. **Estudos Avançados**, n. 35. 2021.

FELCHER, C. D. O. *et al.* EaD em Cursos de Graduação Presenciais: uma Revisão. **EaD em Foco**, v. 14, n. 2, e2235, 2024. DOI: <https://doi.org/10.18264/>. Acesso em: 12 jun. 2025.

FORBELLONE, A. L. V.; EBERSPACHER, H. F. **Lógica de Programação: A Construção de Algoritmos e Estruturas de Dados**. Editora Pearson/Prentice Hall. 3ed. 2025.

HOLMES, W.; BIALIK, M.; FADEL, C. **Artificial Intelligence in Education: Promises and Implications for Teaching and Learning**. Boston: Center for Curriculum Redesign, 2019.

LANÇA, T.; BRUNETTI, A.; IENNE, V. PBL aplicado ao contexto do EaD: uma análise no ensino superior. In: SCHIMIGUEL, Juliano (Org). **Educação a distância (EaD), metodologias ativas e a inteligência artificial**. Rio de Janeiro. Ciência moderna (LCM). 2026.

LANÇA, T. **Sentidos produzidos no desenvolvimento de uma unidade de ensino sobre termodinâmica num curso de Engenharia de Produção**. 199 f. Tese (Doutorado em Ensino de Ciências e Matemática) - Instituto de Física “Gleb Wataghin”. Universidade Estadual de Campinas, Campinas, 2018.

MACEDO, E.; TEIXEIRA, E.; CARVALHO, A.; ARAÚJO, H. C. Explorando a renovação da pedagogia: problem based learning como espaço de cidadania educacional jovem. **Educação e Pesquisa**, São Paulo, v. 49,

e269782, 2023. Disponível em: <<https://doi.org/10.1590/S1678-4634202349269782por>>. Acesso em: 12 jun. 2026.

MORAN, J.; BACICH, L.; TREVISANI, F. M. **Metodologias Ativas e Processos Formativos**. São Paulo: Penso, 2020.

RUSSELL, S. NORVIG, P. **Artificial Intelligence: A Modern Approach**. 3 ed. 2010.

SANTOS, R. M; SANTOS, M. E. K. L. Inteligência artificial na educação financeira: personalização, autonomia e alinhamento curricular no novo ensino médio. **Ubiquidade**, 2025. Disponível em: <<https://revistas.anchieta.br/index.php/RevistaUbiquidade/article/view/2317/1977>>. Acesso em: 16 jun. 2026.

SICHMAN, J. S. Inteligência Artificial e sociedade: avanços e riscos. **Estudos Avançados**, v.35 (101), 2021.

UNESCO. UNESCO destaca importância de jogo da política em educação aberta, disponível para download gratuito. UNESCO, 7 jun. 2024. Disponível em: <<https://www.unesco.org/pt/articles/unesco-destaca-importancia-de-jogo-da-politica-em-educacao-aberta-disponivel-para-download-gratuito>>. Acesso em: 12 jun. 2026.

UNESCO. The 2019 UNESCO Recommendation on Open Educational Resources (OER): supporting universal Access to information through quality open learning materials. Paris: UNESCO, 2019. Disponível em: <<https://unesdoc.unesco.org/ark:/48223/pf0000383205>>. Acesso em: 15 jun. 2026.

O PODER DAS BIG TECHS E DA IA: NO OCEANO DE CURSOS GRATUITOS, COMO ENCONTRAR O SEU NORTE?

THE POWER OF BIG TECHS AND AI: IN THE OCEAN OF FREE COURSES, HOW TO FIND YOUR NORTH?

Alessandro Ferreira

alessandro.ferreira@anchieta.br

Faculdade Anchieta (UniAnchieta)

Jundiaí, SP

Resumo

A explosão da Inteligência Artificial generativa abriu um paradoxo inédito na história da educação tecnológica: nunca houve tanto conhecimento de qualidade disponível gratuitamente — e nunca foi tão difícil saber por onde começar. As Big Techs responderam a essa corrida disponibilizando catálogos imensos de cursos gratuitos, democratizando o acesso ao conhecimento de ponta mas criando, ao mesmo tempo, um labirinto de opções que paralisa tanto o iniciante quanto o profissional experiente. Este artigo parte desse paradoxo para analisar o papel estratégico das grandes empresas de tecnologia no ecossistema educacional em IA, apresenta o referencial teórico que explica por que essas empresas investem em educação gratuita, descreve a metodologia de análise comparativa adotada e mapeia as principais iniciativas de onze organizações: Anthropic, OpenAI, Google, Microsoft, NVIDIA, DeepLearning.AI, Meta, AWS, IBM, Hugging Face e Stanford. Ao final, propõe trilhas de aprendizagem orientadas por perfil profissional, com o argumento de que o diferencial não está em acumular certificados, mas em aprender a aprender com estratégia e senso crítico.

Palavras-Chave

Big Techs; Inteligência Artificial; cursos gratuitos; trilha de aprendizagem; democratização do ensino; capitalismo de plataforma.

Abstract

The explosion of generative Artificial Intelligence has created an unprecedented paradox in the history of technology education: never has so much quality knowledge been freely available — and never has it been so difficult to know where to start. Big Techs responded to this race by making vast catalogs of free courses available, democratizing access to cutting-edge knowledge while simultaneously creating a maze of options that paralyzes both beginners and experienced professionals alike. This article starts from this paradox to analyze the strategic role of major technology companies in the AI educational ecosystem, presents the theoretical framework explaining why these companies invest in free education, describes the comparative

analysis methodology adopted, and maps the main initiatives of eleven organizations: Anthropic, OpenAI, Google, Microsoft, NVIDIA, DeepLearning.AI, Meta, AWS, IBM, Hugging Face, and Stanford. Finally, it proposes learning paths oriented by professional profile, arguing that the differentiator lies not in accumulating certificates, but in learning how to learn with strategy and critical thinking.

Keywords

Big Techs; Artificial Intelligence; free courses; learning path; democratization of education; platform capitalism.

1 INTRODUÇÃO

Imagine a cena: você abre o LinkedIn numa manhã de segunda-feira e, antes mesmo do café esfriar, já se deparou com três posts anunciando cursos gratuitos de IA, dois certificados que 'vão transformar sua carreira' e uma thread inteira debatendo qual modelo de linguagem é o melhor do momento. Você fecha o aplicativo com aquela sensação incômoda de que está ficando para trás — mesmo sem ter terminado o curso que começou na semana passada. Se isso soa familiar, saiba que você está em boa companhia.

Esse cenário não é exagero. O lançamento do ChatGPT em novembro de 2022 funcionou como um gatilho que transformou a Inteligência Artificial de assunto de nicho em tema de conversa de botequim. Em meses, o que era restrito a laboratórios de pesquisa e grandes corporações tornou-se pauta obrigatória em recursos humanos, salas de aula, consultórios médicos e escritórios de advocacia. E junto com essa popularização veio uma avalanche de conteúdo educacional: as Big Techs — Google, Microsoft, Amazon, Meta, NVIDIA — e as startups que lideram o setor abriram seus catálogos e passaram a oferecer cursos gratuitos em escala industrial.

A boa notícia é real: um estudante em Jundiaí, interior de São Paulo, tem hoje acesso ao mesmo conteúdo de machine learning que um aluno de Stanford. Isso é genuinamente revolucionário, e seria desonesto não reconhecer. Mas a má notícia também é real: a abundância virou um problema em si. A pergunta que antes era 'onde encontro conteúdo de qualidade sobre IA?' mudou completamente. Hoje a pergunta é outra, mais difícil e mais urgente: 'no meio de tanta oferta, qual direção eu devo seguir?'

É exatamente essa pergunta que motiva este artigo. Não vamos listar cursos por listar — isso qualquer buscador faz. O objetivo aqui é mais ambicioso: entender a lógica por trás de por que essas empresas oferecem educação gratuita, o que cada plataforma representa de verdade, e como um profissional com objetivos claros pode montar uma trilha de aprendizagem que faça sentido para a sua carreira específica — e não para uma carreira genérica em 'IA' que não existe na prática.

Para isso, o artigo está estruturado da seguinte forma: primeiro, apresentamos o referencial teórico que situa o fenômeno educacional das Big Techs dentro de uma lógica econômica e social mais ampla. Em seguida, descrevemos a metodologia de análise adotada. Depois, mapeamos em detalhe as onze plataformas selecionadas, com exemplos concretos de quem usa cada uma e para quê. Por fim, nas considerações finais, reunimos tudo isso em orientações práticas e uma reflexão sobre o que realmente significa aprender na era da inteligência artificial.

2 REFERENCIAL TEÓRICO

2.1 Por Que as Big Techs Ensinam de Graça? A Lógica do Capitalismo de Plataforma

Antes de mergulhar nos cursos, vale parar um segundo para fazer uma pergunta incômoda: por que empresas avaliadas em trilhões de dólares distribuem conhecimento de graça? A resposta ingênua seria 'porque são bonzinhas'. A resposta honesta é mais interessante.

O economista Nick Srnicek (2017) cunhou o termo 'capitalismo de plataforma' para descrever o modelo de negócio que define empresas como Google, Amazon e Microsoft. Essas empresas não vendem apenas produtos; elas constroem a estrada por onde o mundo digital caminha e cobram pedágio de quem quiser passar. E para que essa estrada valha cada vez mais, é preciso que o máximo de pessoas a utilize. Educar desenvolvedores e profissionais para usar suas ferramentas é, portanto, um investimento estratégico: cada curso concluído é um futuro usuário fidelizado, uma empresa que vai escolher aquela nuvem específica, aquela API, aquele conjunto de ferramentas.

Shoshana Zuboff (2019) vai além e nos oferece outra camada de leitura com o conceito de 'capitalismo de vigilância'. Ao interagir com plataformas de ensino, o usuário fornece dados preciosos sobre suas dificuldades, seus interesses e seu ritmo de aprendizagem — dados que retroalimentam os modelos de negócio dessas empresas de formas que vão muito além da venda de cursos. Não é conspiração; é o modelo. E compreendê-lo não significa rejeitar as plataformas, mas usá-las com os olhos abertos.

Manuel Castells (2002), em sua análise da sociedade em rede, já havia antecipado que o controle sobre a infraestrutura de informação seria a nova forma de poder na economia do conhecimento. O que não estava claro à época é que as Big Techs se tornariam simultaneamente as donas da infraestrutura tecnológica e das principais escolas que ensinam a usá-la — uma concentração de poder educacional e econômico sem precedentes históricos. Chris Dede (2016) observa, com razão, que os ambientes proprietários de ensino dessas empresas hoje rivalizam de igual para igual com as maiores universidades do mundo em alcance e atualidade de conteúdo.

2.2 O Paradoxo da Escolha e o Choque do Futuro

Ter acesso a todo esse conhecimento gratuitamente é bom. Mas há um ponto onde 'bom demais' começa a virar problema — e a psicologia nos ajuda a entender por quê.

Andrew Ng, um dos pesquisadores mais respeitados do campo, gosta de comparar a IA à eletricidade (NG, 2018): assim como a eletrificação transformou absolutamente todas as indústrias no século XX, a IA fará o mesmo no XXI. É uma analogia poderosa que justifica a urgência de aprender. Mas Neil Selwyn (2013) nos lembra de algo igualmente importante: tecnologia, por si só, não resolve desigualdades. Barreiras de idioma — a maior parte dos cursos está em inglês —, de tempo, de infraestrutura e de capital cultural continuam determinando quem consegue de fato aproveitar essa oferta. A democratização é real, mas parcial.

Barry Schwartz (2004) demonstrou, em pesquisas sobre comportamento e bem-estar, que o aumento no número de opções disponíveis frequentemente leva não à maior satisfação, mas à paralisia. É o chamado

'paradoxo da escolha': com opções demais, o custo psicológico de decidir aumenta, a chance de arrependimento cresce e a tendência é ou não decidir nada ou decidir mal. Aplicado à educação em IA, o efeito é visível: profissionais que iniciam quatro cursos ao mesmo tempo sem concluir nenhum, acumulando certificados de módulos introdutórios repetidos em plataformas diferentes, sem nunca de fato aprofundar qualquer coisa.

Alvin Toffler (1970) descreveu, décadas antes da internet existir, o 'choque do futuro' — o estresse psicológico gerado pela aceleração tecnológica e pelo excesso de informação. O que era tendência virou realidade cotidiana: novos modelos de IA são lançados a cada semana, cursos ficam desatualizados em meses, e a sensação de estar permanentemente atrasado é quase universal entre profissionais que acompanham o campo. Reconhecer esse fenômeno é o primeiro passo para não ser dominado por ele.

2.3 A Lição das Fintechs: Como Navegar a Fragmentação

Para quem ainda está tentando entender como se orientar em meio a tanta oferta, um paralelo do mundo financeiro pode ajudar mais do que qualquer teoria acadêmica.

As fintechs — startups que aplicaram tecnologia para reinventar serviços financeiros — fizeram com os bancos tradicionais algo muito parecido com o que as plataformas educacionais das Big Techs estão fazendo com as universidades: desafiaram o modelo estabelecido, simplificaram o acesso, democratizaram o que antes era restrito a poucos (SCHINDLER et al., 2017). O resultado foi espetacular em termos de inclusão financeira. E também criou uma carteira cheia de aplicativos, regulamentações fragmentadas e usuários confusos sobre qual plataforma usar para quê.

A resposta do Banco Central do Brasil foi inteligente: em vez de tentar eliminar a fragmentação — impossível —, criou padrões de interoperabilidade como o open banking e o PIX (BACEN, 2021). Padrões que permitem ao usuário se beneficiar da diversidade sem precisar dominar cada sistema individualmente. Na educação tecnológica, o equivalente são os frameworks de competências digitais. O europeu DigComp (FERRARI, 2013), por exemplo, mapeia as habilidades digitais que todo profissional deveria desenvolver, funcionando como um 'mapa' que ajuda a identificar lacunas e priorizar aprendizagens. Iniciativas similares, específicas para IA, são cada vez mais necessárias — especialmente no Brasil, onde o Marco Legal da IA (2024) começa a criar demanda por profissionais com competências claramente definidas.

3 METODOLOGIA

Para mapear e comparar as plataformas educacionais das Big Techs, este artigo adotou uma abordagem qualitativa de natureza exploratória e descritiva. O objetivo não foi produzir estatísticas de uso ou rankings de popularidade — dados que as próprias plataformas não divulgam de forma padronizada —, mas oferecer uma análise crítica e orientada para o leitor que precisa tomar decisões práticas sobre onde investir seu tempo de estudo.

A seleção das onze plataformas analisadas combinou dois critérios objetivos: relevância organizacional — foram incluídas apenas empresas com papel reconhecido no desenvolvimento ou na difusão de tecnologias de IA em escala global — e disponibilidade real de conteúdo gratuito, excluindo plataformas cujo modelo é

exclusivamente baseado em assinatura paga. O levantamento foi realizado por meio de acesso direto aos portais oficiais de cada organização, complementado por revisão de literatura acadêmica e relatórios setoriais publicados entre 2017 e 2024.

Cada plataforma foi analisada a partir de um roteiro estruturado com seis dimensões: (1) perfil da organização e posicionamento no ecossistema de IA; (2) foco temático dos cursos gratuitos disponíveis; (3) público-alvo predominante — iniciantes, desenvolvedores, pesquisadores ou gestores; (4) metodologia de ensino — vídeo-aulas, projetos práticos, sandboxes, comunidades; (5) integração com certificações de mercado; e (6) aspectos de acessibilidade, incluindo idiomas disponíveis e pré-requisitos técnicos.

A revisão bibliográfica foi conduzida nas bases Google Scholar e Scopus, com os descritores 'platform capitalism and education', 'Big Tech free courses AI', 'democratization of AI education' e 'paradox of choice learning', com filtros de período (2002–2024) e idioma (inglês e português). É importante registrar a principal limitação desta pesquisa: os catálogos das plataformas são atualizados com frequência, de modo que algumas descrições específicas podem não refletir o estado mais recente das ofertas no momento da leitura. O que não muda — e é o foco desta análise — é o posicionamento estratégico de cada organização e o perfil de aprendiz para quem cada plataforma foi desenhada.

4 EXEMPLOS E APLICAÇÕES: AS 11 PLATAFORMAS EM PERSPECTIVA

Chegamos à parte prática. A seguir, cada plataforma é apresentada não como um item de lista, mas como um retrato — com foco em quem ela foi desenhada para atender e como profissionais reais a têm utilizado no dia a dia.

4.1 Anthropic Academy — anthropic.skilljar.com

A Anthropic nasceu de uma pergunta que seus fundadores — ex-pesquisadores da OpenAI — não conseguiam ignorar: e se a IA mais poderosa que estamos construindo for também a mais perigosa? Essa preocupação com segurança e alinhamento permeia tudo o que a empresa faz, inclusive sua plataforma educacional. Na Anthropic Academy, você não vai encontrar apenas tutoriais de 'como usar o Claude'. Vai encontrar discussões sérias sobre como construir sistemas de IA que se comportem de forma previsível, transparente e segura.

Na prática, profissionais de segurança da informação têm encontrado nessa plataforma um aliado inesperado: os cursos sobre o Model Context Protocol (MCP) e sobre construção de agentes autônomos são especialmente úteis para quem quer integrar IA em ambientes corporativos sensíveis, onde a rastreabilidade e o controle de comportamento do modelo são tão importantes quanto a eficiência. Para setores regulados — saúde, finanças, setor público —, a Anthropic Academy oferece uma perspectiva que a maioria das outras plataformas simplesmente ignora.

4.2 OpenAI Academy — academy.openai.com

Se a Anthropic faz você pensar sobre IA, a OpenAI faz você construir com ela. A OpenAI Academy é, antes de tudo, uma plataforma para quem quer colocar a mão na massa com as APIs do ChatGPT e do GPT-4. Os módulos cobrem desde os fundamentos de como modelos de linguagem funcionam até técnicas avançadas de fine-tuning — o processo de 'ensinar' um modelo a se comportar de forma específica para determinada aplicação.

Startups e equipes de produto de empresas médias têm utilizado os recursos da OpenAI Academy para acelerar o desenvolvimento de produtos com IA: chatbots de atendimento ao cliente, assistentes de redação, ferramentas de análise de contratos. A plataforma também aborda questões de governança e alinhamento — ainda que de forma menos profunda que a Anthropic —, oferecendo uma introdução adequada às responsabilidades éticas que acompanham o poder de construir com modelos de linguagem de grande escala.

4.3 Google AI Learning — grow.google/ai

O Google tem uma vantagem que nenhuma outra empresa desta lista possui: décadas de experiência em tornar tecnologia complexa acessível para bilhões de pessoas. Isso se reflete na plataforma Grow with Google, que é provavelmente a mais abrangente em termos de público atendido — de quem nunca escreveu uma linha de código na vida até engenheiros que querem trabalhar com modelos avançados no Vertex AI.

Um diferencial concreto são os Google Career Certificates: certificações reconhecidas por centenas de empregadores que podem ser conquistadas sem diploma universitário. Profissionais de marketing digital, por exemplo, têm usado a plataforma para entender e aplicar ferramentas de IA generativa em campanhas, sem precisar virar programadores. Para quem está em transição de carreira ou quer adicionar competências em IA ao seu perfil atual — seja qual for a área —, o Google costuma ser o melhor ponto de entrada.

4.4 Microsoft Learn — learn.microsoft.com/training

Se você trabalha em uma empresa que usa Microsoft 365, Teams ou qualquer produto do ecossistema Microsoft, o Microsoft Learn é provavelmente a plataforma mais estratégica que existe para você agora. Os 'learning paths' — sequências de módulos progressivos — são desenhados para levar o aprendiz do zero às certificações de mercado de forma estruturada, com ambientes de prática gratuitos (sandboxes) que permitem experimentar sem gastar nada em infraestrutura de nuvem.

Na prática corporativa, equipes de TI que precisam integrar IA aos processos da empresa encontram no Microsoft Learn o caminho mais direto: os módulos sobre Azure OpenAI Service, Copilot Studio e Power Platform com IA mostram como aplicar modelos de linguagem sem sair do ambiente que as organizações já conhecem. As certificações AI-900 (fundamentos) e AI-102 (implementação) são hoje requisitos em processos seletivos de grandes empresas — e o Microsoft Learn é o melhor caminho para conquistá-las.

4.5 NVIDIA Deep Learning Institute — developer.nvidia.com/training

Existe uma piada no setor de IA que diz que a empresa que mais lucrou com a corrida do ouro não foi quem achou ouro, mas quem vendeu as picaretas. A NVIDIA é exatamente isso: enquanto todo mundo debate qual modelo de IA é o melhor, ela vende as GPUs que fazem todos eles funcionar. Esse posicionamento único torna o Deep Learning Institute (DLI) diferente de todas as outras plataformas desta lista.

Aqui, o foco não é 'como usar IA', mas 'como fazer IA funcionar de forma eficiente no nível do hardware'. Os cursos gratuitos cobrem deep learning aplicado, visão computacional e computação acelerada por GPU usando CUDA — a linguagem de programação da NVIDIA. Para engenheiros de machine learning que precisam otimizar o treinamento ou a inferência de modelos — reduzindo custos e latência —, o DLI oferece conhecimentos que simplesmente não estão disponíveis em nenhuma outra fonte com a mesma profundidade técnica.

4.6 DeepLearning.AI — deeplearning.ai

Se você só puder escolher uma plataforma desta lista para começar, e tiver alguma base em programação, escolha esta. A DeepLearning.AI, fundada por Andrew Ng, é amplamente reconhecida como a melhor plataforma do mundo para aprender os fundamentos de IA de forma acessível — sem abrir mão do rigor. A didática de Ng é excepcional: ele tem uma habilidade rara de tornar conceitos matematicamente complexos compreensíveis para quem não tem doutorado em matemática.

Os cursos são disponibilizados via Coursera com opção de auditoria gratuita — você assiste a tudo sem pagar nada, e paga apenas se quiser o certificado. O catálogo vai de redes neurais básicas até arquiteturas Transformer, LLMs e MLOps. Médicos, advogados, engenheiros civis, jornalistas — profissionais das mais diversas áreas relatam consistentemente a DeepLearning.AI como o ponto de virada que fez a IA finalmente 'fazer sentido'. Para quem quer uma base sólida antes de se especializar, este é o lugar.

4.7 Meta AI Resources — ai.meta.com/resources

A Meta fez uma aposta que vai na contramão da tendência das outras Big Techs: em vez de guardar seus modelos como segredos comerciais, ela os disponibiliza como código aberto. A família LLaMA — o conjunto de modelos de linguagem da Meta — pode ser baixada, modificada e implantada por qualquer desenvolvedor, em qualquer servidor, sem depender de nenhuma API externa.

Isso não é só uma questão de filosofia. Tem implicações práticas enormes: um hospital que não pode enviar dados de pacientes para servidores externos pode rodar um modelo LLaMA internamente. Um escritório de advocacia preocupado com confidencialidade pode fazer o mesmo. Os recursos educacionais da Meta — tutoriais, guias e documentação técnica — ensinam exatamente como fazer isso, tornando a plataforma especialmente valiosa para desenvolvedores que trabalham em contextos onde privacidade de dados é inegociável.

4.8 AWS Skill Builder — skillbuilder.aws

A Amazon Web Services hospeda uma fração enorme da internet mundial — e da IA que roda nela. O AWS Skill Builder é a plataforma que ensina a trabalhar nessa infraestrutura, com mais de 500 conteúdos gratuitos cobrindo computação em nuvem, machine learning e os serviços de IA da AWS: SageMaker para treinar e implantar modelos, Rekognition para visão computacional, Comprehend para análise de texto e Bedrock para acessar modelos fundacionais de múltiplos provedores via API.

Para arquitetos de soluções e engenheiros de dados que trabalham — ou pretendem trabalhar — com a nuvem AWS, a plataforma é o caminho mais direto para a certificação AWS Certified Machine Learning Specialty, uma das credenciais mais valorizadas no mercado de cloud computing. Empresas que já operam na AWS encontram no Skill Builder o recurso mais alinhado às ferramentas que usam em produção, tornando o aprendizado imediatamente aplicável.

4.9 IBM SkillsBuild — skillsbuild.org

Entre todas as plataformas desta lista, o IBM SkillsBuild é a que mais explicitamente se preocupa com quem ficou de fora. A iniciativa foi desenhada para alcançar públicos sub-representados no setor tecnológico — mulheres, pessoas de baixa renda, jovens sem acesso ao ensino superior, trabalhadores em transição de carreira — e oferece cursos introdutórios em IA, análise de dados e cibersegurança com linguagem acessível e aplicação prática imediata.

O modelo de parcerias da IBM potencializa esse alcance: a plataforma colabora com universidades, ONGs e governos para integrar seu conteúdo em programas de capacitação profissional. No Brasil, iniciativas de inclusão digital financiadas por prefeituras e governos estaduais têm utilizado o SkillsBuild como base curricular. Para educadores que trabalham em contextos de educação profissional e tecnológica (EPT) e querem introduzir IA de forma acessível, esta é a plataforma com a abordagem mais adequada.

4.10 Hugging Face Learn — huggingface.co/learn

Se o GitHub é onde os programadores guardam e compartilham código, o Hugging Face é onde os pesquisadores e desenvolvedores de IA guardam e compartilham modelos. Com mais de 300.000 modelos disponíveis publicamente, a plataforma tornou-se o repositório central do ecossistema de IA de código aberto. E seu portal educacional — o Hugging Face Learn — é onde você aprende a navegar e usar esse repositório.

O diferencial pedagógico é a integração direta com a prática: você não estuda modelos em exemplos hipotéticos — você trabalha com modelos reais disponíveis no Hub, submete projetos e interage com uma comunidade ativa de pesquisadores e desenvolvedores do mundo todo. Para quem quer fazer a transição de 'usuário de IA' para 'desenvolvedor de IA', o Hugging Face Learn é frequentemente a ponte mais eficiente. É onde a teoria encontra a prática de forma mais direta e honesta.

4.11 Stanford Online — online.stanford.edu/free-courses

Stanford é, ao lado do MIT, o maior celeiro de pesquisadores de IA do mundo. Muitos dos avanços que definiram o campo — redes neurais convolucionais, word embeddings, a arquitetura Transformer — nasceram ou passaram pelos corredores desta universidade. Quando Stanford disponibiliza parte de seu conteúdo gratuitamente, é uma oportunidade rara de ter contato com o pensamento que está na fronteira do conhecimento.

A abordagem é rigorosa e matematicamente fundamentada — diferente de todas as plataformas corporativas desta lista, que privilegiam a aplicação prática. Isso torna Stanford Online mais adequado para quem já tem base sólida em cálculo, álgebra linear e probabilidade, e quer entender o 'porquê' por trás dos algoritmos, não apenas o 'como'. Há um valor inestimável nessa perspectiva: sem a pressão de vender produtos ou fidelizar usuários, Stanford pode discutir as limitações e os riscos da IA de forma que nenhuma empresa com interesse comercial consegue fazer com a mesma liberdade.

5 CONSIDERAÇÕES FINAIS

Chegamos ao final deste artigo com uma conclusão que pode parecer paradoxal: estudamos onze plataformas de ensino em IA para concluir que o problema não é falta de conteúdo. O problema nunca foi esse. O que falta — e o que este trabalho tentou contribuir para construir — é orientação. A capacidade de olhar para um oceano de opções e saber, com alguma segurança, qual direção nadar.

O referencial teórico mobilizado ao longo do artigo nos oferece uma lente crítica importante. Com Srnicek (2017) e Zuboff (2019), aprendemos que a gratuidade das plataformas não é altruísmo — é estratégia. Ao entender isso, não precisamos rejeitar os cursos, mas podemos usá-los de forma mais consciente, sem sermos capturados pela lógica de fidelização a um único ecossistema. Com Selwyn (2013), reconhecemos que a democratização é real mas parcial: as barreiras de idioma, infraestrutura e capital cultural continuam mediando quem de fato se beneficia dessa oferta. E com Schwartz (2004) e Toffler (1970), identificamos o paradoxo central que ameaça qualquer estratégia de aprendizagem em IA: a abundância de opções, sem um norte claro, produz paralisia, ansiedade e aprendizagem superficial — exatamente o oposto do que se busca.

O paralelo com as fintechs é mais do que uma analogia ilustrativa — é um modelo de solução. Assim como o open banking e o PIX criaram padrões que permitiram aos usuários se beneficiar da diversidade de serviços financeiros sem precisar dominar cada sistema, a educação tecnológica precisa de frameworks de competências que funcionem como mapas de aprendizagem. O DigComp europeu (FERRARI, 2013) e o Marco Legal da IA brasileiro (2024) são passos iniciais nessa direção. Mas iniciativas mais específicas para o mapeamento de competências em IA — que ajudem profissionais brasileiros a identificar onde estão e para onde precisam ir — ainda são uma lacuna urgente a preencher.

Das onze plataformas analisadas, cada uma representa uma visão particular sobre o que é a IA e para quem ela existe. A Anthropic ensina a construir com responsabilidade. A OpenAI ensina a construir com velocidade. O Google ensina a usar com amplitude. A Microsoft ensina a integrar com o que já existe. A NVIDIA ensina a fazer funcionar com eficiência. A DeepLearning.AI ensina a entender de verdade. A Meta ensina a ser independente. A AWS ensina a escalar. A IBM ensina a incluir. O Hugging Face ensina a colaborar. E Stanford

ensina a questionar. Uma trilha de aprendizagem bem construída não escolhe apenas uma dessas visões — ela as combina de acordo com os objetivos de cada profissional, em cada momento da sua trajetória.

Um ponto que atravessa todas as plataformas e que seria negligência não destacar: a ética deixou de ser optativa. Alinhadas com regulamentações crescentes — o EU AI Act na Europa, o Marco Legal da IA no Brasil, as diretrizes da UNESCO para IA na educação —, todas as plataformas analisadas incorporaram, em graus variados, discussões sobre viés algorítmico, transparência, privacidade e governança. Isso não é coincidência: é resposta a uma demanda real do mercado e da sociedade. Saber construir um modelo de IA tecnicamente eficiente é cada vez menos um diferencial. Saber avaliá-lo criticamente, identificar seus riscos e comunicar suas limitações com honestidade é o que define o profissional de IA maduro — e é o que as empresas e os reguladores estão começando a exigir.

Por fim, o argumento central deste artigo pode ser dito de forma simples: o futuro não pertence a quem tem mais diplomas na parede ou mais certificados no perfil do LinkedIn. Pertence a quem aprendeu a aprender — de forma estratégica, crítica e contínua. Em um campo onde o estado da arte muda a cada trimestre, a habilidade mais valiosa não é dominar uma ferramenta específica que pode ficar obsoleta em meses. É saber como se atualizar, como avaliar o que é sinal e o que é ruído, como construir conhecimento que se acumula em vez de se fragmentar. O banquete está servido, e é generoso como nunca foi antes. O segredo não é devorar tudo — é escolher com sabedoria os ingredientes que alimentam a sua jornada particular. Porque no final, a pergunta que importa não é qual curso fazer. É quem você quer ser capaz de fazer.

REFERÊNCIAS BIBLIOGRÁFICAS

BACEN — BANCO CENTRAL DO BRASIL. *Relatório de Economia Bancária 2021*. Brasília: BCB, 2021.

BRASIL. Lei n. 14.776, de 29 de dezembro de 2023. *Marco Legal da Inteligência Artificial*. Brasília: Diário Oficial da União, 2024.

CASTELLS, Manuel. *A sociedade em rede*. 6. ed. São Paulo: Paz e Terra, 2002.

DEDE, Chris. The 60-year curriculum: new models for lifelong learning in the digital economy. *EdTech Magazine*, 2016.

FERRARI, Anusca. *DIGCOMP: A Framework for Developing and Understanding Digital Competence in Europe*. Luxembourg: Publications Office of the EU, 2013.

NG, Andrew. AI is the new electricity. *Stanford Graduate School of Business Insights*, 2018.

PLANTIN, Jean-Christophe et al. Infrastructure studies meet platform studies in the age of Google and Facebook. *New Media & Society*, v. 20, n. 1, p. 293-310, 2018.

SCHINDLER, David et al. Fintech and financial inclusion. *IMF Working Paper*, WP/17/175, 2017.

SCHWARTZ, Barry. *The Paradox of Choice: Why More Is Less*. New York: Ecco, 2004.

SELWYN, Neil. *Distrusting Educational Technology: Critical Questions for Changing Times*. New York: Routledge, 2013.

SRNICEK, Nick. *Platform Capitalism*. Cambridge: Polity Press, 2017.

TOFFLER, Alvin. *Future Shock*. New York: Random House, 1970.

UNESCO. *Reimagining our futures together: A new social contract for education*. Paris: UNESCO, 2022.

ZUBOFF, Shoshana. *The Age of Surveillance Capitalism*. New York: PublicAffairs, 2019.

AGRADECIMENTOS

Um agradecimento especial ao UniAnchieta pelo incentivo contínuo à pesquisa, à produção acadêmica de valor e por abrir espaços tão ricos de debate crítico sobre tecnologia e educação em nossas salas de aula.