

# *PLEIADE*

**Publicação Técnico-Científica do Centro Universitário Descomplica UniAmérica**

VOL. 19 – N. 49 – OUT. / DEZ. - 2025

---

- 03     Editorial: Inteligência Artificial e Processos Educacionais:  
Perspectivas e Desafios**  
Ruminiki Pavei Schmoeller e Gildomiro Bairros
- 05     Perfil Socioeconômico e Desempenho no ENADE: Análise Causal Aplicada  
aos Cursos de Tecnologia da Informação**  
*Socioeconomic Profile and Performance in ENADE: Applied Causal Analysis  
to Information Technology Courses*  
Emílio Anastácio de Paula Correa, Ruminik Schmoeller e Isabel Fernandes
- 19     Detecção de Intrusão em Redes Modernas: Estudo com Método Híbrido  
de Redes Neurais**  
*Intrusion Detection in Modern Networks: A Study Using a Hybrid Neural  
Network Method*  
Laércio Bubiak da Cruz e Wagner Jorcuvich
- 28     Abordagem Multimodal com Inteligência Artificial para Diagnóstico  
Precoce de Alzheimer**  
*Multimodal Approach with Artificial Intelligence for Early Diagnosis of  
Alzheimer's Disease*  
Bouchra Assad Akl, Wellington de Oliveira e Isabel Fernandes
- 42     Desempenho Acadêmico na Previsão da Evasão no Ensino Superior: Compara-  
ção entre Modelos Bagging, Boosting e Ensemble de Votação Majoritária**  
*Influence of Academic Performance on Predicting Dropout Rates in Higher  
Education: A Comparison of Combined Models*  
Ruminiki Pavei Schmoeller, Vanessa Demarchi Peron e Walter Mesquita Filho

- 56 **Análise Comportamental de Textos Argumentativos em Sistemas Tutores Inteligentes: Estudo de Caso no Exército Brasileiro**  
*Behavioral Analysis of Argumentative Texts in Intelligent Tutoring Systems: A Case Study in the Brazilian Army*  
Cláudia Rödel Bosaipo Sales da Silva, Alberto Sulaiman Sade Junior, Sarah Vitória Luiz Vanderei e Ronaldo Ribeiro Goldschmidt
- 65 **Integrando Coleta e Mineração de Dados sobre Uso de Jogos Educacionais Digitais para Capacitação Discente na Identificação de Fake News em Português**  
*Integrating Data Collection and Mining on the Use of Digital Educational Games for Student Training in Identifying Fake News in Portuguese*  
Angelo C. S. Paolino, Cláudia S. da Silva, Isabel Fernandes, Cláudio Passos, Paulo Cesar Coelho e Ronaldo R. Goldschmidt
- 79 **A Utilização da Inteligência Artificial na Educação da Enfermagem: Inovação, Limites e Responsabilidades Éticas**  
*The Use of Artificial Intelligence in Nursing Education: Innovation, Limitations, and Ethical Responsibilities*  
Yasminne Corrêa Lopes, William da Costa Moreira e Gabriela Pereira da Silva
- 88 **Aplicação da Inteligência Artificial Generativa no Gerenciamento de Riscos de Projeto: Revisão Sistemática da Literatura**  
*Application of Generative Artificial Intelligence in Project Risk Management: A Systematic Literature Review*  
Peterson Carlos Zimmermann Mai, Eduardo Cesar Dechechi e Claudio Alexandre de Souza
- 102 **Perícia Grafotécnica e Inteligência Artificial: Inovações Tecnológicas na Análise de Escritas**  
*Handwriting Expertise and Artificial Intelligence: Technological Innovations in Handwriting Analysis*  
Maria Suzie de Oliveira
- 107 **Literatura Infantil: O Cativar que Ensina**  
*Children's Literature: The Captivating Spirit that Teaches*  
Amanda Sabino Jandrey e Terezinha Corrêa Lindino

# PLEIADE

Publicação Técnico-Científica do Centro Universitário Descomplica UniAmérica

VOLUME 19    NÚMERO 49    Out./Dez., 2025



## Editorial

### A Alvorada da Inteligência Artificial na Educação

É com imensa satisfação que apresentamos o Volume 19, Número 49 da *Revista Pleiade*, intitulado **“Inteligência Artificial e Processos Educacionais: Perspectivas e Desafios”**. Esta edição se dedica a discutir as complexas relações e reflexões críticas que emergem da convergência entre a Inteligência Artificial (IA) e os processos educacionais, cuja relevância redefine o papel do humano diante da tecnologia.

A Educação 5.0 representa significativa evolução no campo educacional, promovendo a integração profunda entre tecnologia e aprendizagem, sem deslocar o ser humano do centro desse processo. Diferentemente da Educação 4.0, centrada no uso instrumental da tecnologia, a abordagem 5.0 busca o desenvolvimento integral do estudante, incorporando dimensões cognitivas, socioemocionais e éticas.

Essa definição amplia o alcance da educação, indo além da aquisição de habilidades técnicas, ao incentivar a criatividade, o pensamento crítico, a empatia, a colaboração e a inteligência emocional, competências essenciais para a formação verdadeiramente humanizada e inclusiva.

Neste cenário, a aplicação da IA traz impactos concretos e transformadores. Observamos a personalização da aprendizagem com algoritmos adaptativos que oferecem materiais e ritmos de aprendizado sob medida. No horizonte é possível vislumbrar tutores virtuais inteligentes capazes de acompanhar o estudante fora do horário de aula; simuladores baseados em IA que possibilitam experimentação segura em áreas como física, medicina ou engenharia; além de sistemas preditivos que identificam precocemente dificuldades de aprendizagem, permitindo intervenções pedagógicas mais precisas e eficazes.

Entretanto, o entusiasmo diante das novas possibilidades deve ser acompanhado de prudência e reflexão crítica. São vários os desafios, destacamos três:

**Viés algorítmico e perpetuação de desigualdades:** modelos de IA são treinados a partir de dados que refletem a realidade social, muitas vezes marcada por desigualdades históricas. Sem mecanismos de auditoria e correção, tais sistemas podem reforçar exclusões, reproduzindo padrões discriminatórios.

**Privacidade de dados e vigilância:** o uso da IA na educação implica o tratamento de grandes volumes de dados sensíveis. É imprescindível adotar protocolos rígidos de proteção e governança, assegurando soberania informacional e transparência no uso das informações.

**Opacidade dos algoritmos:** o aprendizado deve permanecer um processo de compreensão, e não de submissão a modelos cujo processo de tomada de decisão não é transparente. A criação de sistemas explicáveis e auditáveis é essencial para que educadores e alunos compreendam as razões por trás de cada recomendação.

Paralelo a isso, a dependência excessiva da tecnologia pode atrofiar habilidades essenciais, como a interação social complexa e a capacidade de aprender a partir do erro e da frustração. O desafio contemporâneo consiste, portanto, em promover a integração consciente e humanizada da Inteligência Artificial no processo educativo. O imperativo é claro: empregar a IA para enriquecer a experiência educativa, tornando-a mais humana, e nunca o contrário. Para isso, é essencial:

**Focar nas competências humanas essenciais:** A IA deve assumir tarefas repetitivas e analíticas, liberando tempo e energia para o desenvolvimento de habilidades inerentemente humanas, como criatividade, empatia, colaboração e pensamento crítico.

**Centrar a aprendizagem na curiosidade:** A IA deve ser parceira dialógica, não fonte de respostas absolutas. O papel da educação é fomentar o questionamento e o espírito investigativo, transformando a IA em instrumento de descoberta, não de dependência.

**Valorizar o educador:** O professor permanece como protagonista da experiência de aprendizagem mediada pela tecnologia. É fundamental investir em sua formação contínua para que possa criar experiências pedagógicas inovadoras e éticas com apoio da IA.

Em última instância, a aplicação da **Inteligência Artificial na educação é espelho de nossa sociedade**. Ela refletirá nossos valores, prioridades e visões de futuro. Se conduzida com discernimento, ética e compromisso com o potencial de cada indivíduo, será possível vislumbrar, com esperança, **o verdadeiro amanhecer da sabedoria na era digital**.

Ruminiki Pavei Schmoeller e Gildomiro Bairros  
Professores do Colegiado de Engenharia de Software da UniAmérica  
*ruminikis@gmail.com*

# Perfil Socioeconômico e Desempenho no ENADE: Análise Causal Aplicada aos Cursos de Tecnologia da Informação

*Socioeconomic Profile and Performance in ENADE: Applied Causal Analysis  
to Information Technology Courses*

**Emílio Anastácio de Paula Correa, Ruminik Schmoeller e Isabel Fernandes**

1. Acadêmico concluinte do curso de Bacharelado em Engenharia de Software do Centro Universitário Descomplica UniAmérica. 2. Mestre Tecnologias Computacionais para o Agronegócio. Docente do curso de Bacharelado em Engenharia de Software do Centro Universitário Descomplica UniAmérica e orientador do presente trabalho. <https://orcid.org/0009-0006-5046-4390> 3. Computação. Doutora em Ciências. Enga. da Produção. Professora Projeto Final de Curso e coordenadora do curso de Engenharia de Software, Centro Universitário Descomplica UniAmérica. <https://orcid.org/0000-0002-6906-5756>  
*emilioanastacio@gmail.com e isabel.souza@descomplica.com.br*

## Palavras-chave

Desempenho Acadêmico  
ENADE  
Inferência Causal  
Machine Learning  
Propensity Score Matching  
Regressão Linear

## Keywords

Academic Performance  
Brazilian National Student  
Performance Exam  
Causal Inference  
Machine Learning  
Propensity Score Matching  
Linear Regression

## Resumo:

Este estudo analisa, no nível curso-ano, a relação entre o perfil socioeconômico médio dos estudantes (índice SES\_INDEX construído a partir de respostas do Questionário do Estudante) e o desempenho no ENADE (NT\_GER\_mean) em cursos de TI (2014, 2017, 2021). Como variáveis institucionais, consideram-se o tipo de IES (pública/pri- vada) e um índice de metodologias ativas percebidas. Metodologicamente, imple- menta-se em Python um pipeline CRISP-DM com regressão ponderada (WLS com pes- sos pelo tamanho da turma e erros-padrão clusterizados por IES) e uma etapa de inferência causal para o efeito de IES pública: PSM (ATT), IPTW (ATE) e AIPW/DR (ATE). Os resultados indicam associação positiva entre IES pública e maior NT\_GER\_mean, condicionada ao perfil socioeconômico agregado do curso, e um efei- to médio causal positivo de ser curso em IES pública, sob os pressupostos de ignorabi- lidade. As conclusões são estritamente no nível de curso-ano.

## Abstract:

This study analyzes, at the course-year level, the relationship between the average soci- oeconomic profile of students (SES\_INDEX constructed from responses to the Student Questionnaire) and performance on the ENADE exam (NT\_GER\_mean) in IT courses (2014, 2017, 2021). Institutional variables considered include the type of higher educa- tion institution (public/private) and an index of perceived active learning methodologi- es. Methodologically, a CRISP-DM pipeline with weighted regression (WLS weighted by class size and standard errors clustered by higher education institution) and a causal inference step for the effect of public higher education institutions were implemented in Python: PSM (ATT), IPTW (ATE), and AIPW/DR (ATE). The results indicate a po- sitive association between public higher education institutions and higher NT\_GER\_mean, conditioned on the aggregate socioeconomic profile of the course, and a positive average causal effect of being a course in a public higher education insti- tution, under the assumptions of ignorability. The conclusions are strictly at the course- year level.

Artigo recebido em: 15.10.2025.

Aprovado para publicação em: 07.11.2025.

## INTRODUÇÃO

A educação sempre desempenhou um processo crucial no desenvolvimento da sociedade humana. Desde a Grécia Antiga, onde a sofística trouxe um alto significado à educação, trazendo uma abordagem mais consciente e racional, foi em decorrência das contribuições dos sofistas que hoje temos nossos próprios fundamentos da pedagogia moderna (ARAÚJO, 2013).

O SINAES (Sistema Nacional da Avaliação da Educação Superior) foi instituído pela lei nº 10.861, com o objetivo de “melhorar a qualidade da educação superior, a expansão da sua oferta e o aumento de sua eficiência como instituição e efetividade social e acadêmica” (BRASIL, 2004). Integrante desse sistema, o ENADE (Exame Nacional de Desempenho dos Estudantes) é uma avaliação periódica trienal do desempenho dos estudantes dos cursos de graduação, com a finalidade de mapear a evolução aos conteúdos programáticos previstos da grade curricular dos cursos das IES (Instituições de Ensino Superior). Além disso, busca a reunião de informações pessoais relacionadas às características socioeconômicas dos estudantes (LIMANA; BRITO, 2005). Não se limita a avaliar a performance final dos alunos, mas também a coletar informações socioeconômicas, permitindo que fatores externos à prova sejam analisados e proporcionando uma visão mais ampla sobre a qualidade das IES.

O ENADE, em conjunto com a avaliação institucional e a avaliação de cursos de graduação são os três pilares que garantem e reconhecem a qualidade das IES, sendo uma fonte importante de dados que permite identificar diferenças entre instituições públicas e privadas e as metodologias de ensino que empregam. Nessa discussão podemos observar um objetivo em comum das IES, promover uma educação de qualidade que seja capaz de formar pessoas competentes ao mercado de trabalho.

A literatura recente sobre ENADE em cursos de TI tem priorizado descrições e predição de desempenho (mineração de dados e modelos supervisionados), com menor ênfase na identificação causal dos efeitos institucionais e socioeconômicos sobre os resultados, especialmente quando se usam os microdados do Questionário do Estudante e agregações por curso-ano. Exemplos incluem análises exploratórias e preditivas em Ciência da Computação (VISTA; FIGUEIRÓ; CHICON, 2017; SOUZA et al., 2017), evidências sobre determinantes institucionais como composição do corpo docente (BRITO, 2016) e estudos metodológicos de análise de exames no contexto brasileiro (BARBOSA et al., 2024), enquanto a base teórica de inferência causal reforça a necessidade de estratégias de identificação para separar associação de efeito (PEARL, 2010). Nesse contexto, a questão central desta pesquisa é: o perfil socioeconômico agregado dos cursos, o tipo de IES (pública/privada) e a adoção de metodologias ativas causam variações significativas no desempenho médio dos cursos de TI no ENADE (2014, 2017 e 2021)?

Para responder a essa questão, o estudo parte de duas hipóteses orientadoras: H1: A intervenção socioeconômica — representada pelas características socioeconômicas dos estudantes (renda familiar, escolaridade dos pais, situação de trabalho) — afeta significativamente o desempenho no ENADE, sendo que o tipo de IES (pública ou privada) atua como um tratamento moderador, com expectativa de desempenho superior para cursos de IES públicas, especialmente entre aqueles com perfis socioeconômicos agregados mais baixos. H2: A intervenção socioeconômica dos alunos afeta diretamente o desempenho no ENADE e a adoção de metodologias ativas de ensino nas IES funciona como um tratamento moderador, potencializando o desempenho de cursos com perfil socioeconômico agregados mais desfavorecidos.

Em coerência com essas hipóteses, o objetivo deste estudo é analisar o desempenho dos cursos de Ciência da Computação e Análise e Desenvolvimento de Sistemas no ENADE (ENADE, 2022; ITCG, 2010), nos

anos de 2014, 2017 e 2021. A partir dos microdados do ENADE, busca-se identificar como o tipo de IES — pública ou privada — a metodologia de ensino adotada — ativa ou tradicional — e as características socioeconômicas dos estudantes influenciam os resultados avaliativos, utilizando análise estatística com ênfase em inferência causal.

Esta pesquisa se justifica pela escassez de análises atuais e aprofundadas sobre os cursos de Tecnologia da Informação (TI) no ENADE, apesar de o exame ser uma das principais ferramentas de avaliação da educação superior no Brasil. Em um contexto de demanda crescente por profissionais qualificados, é crucial que as IES alinhem formação, qualidade pedagógica e resultados acadêmicos. Persiste uma lacuna específica: faltam estudos que integrem, de forma sistemática, o tipo de IES (pública ou privada), a metodologia de ensino (tradicional ou ativa) e os dados socioeconômicos dos estudantes na explicação do desempenho no ENADE, especialmente em TI. O cenário institucional reforça a relevância do tema: o Censo da Educação Básica de 2023 (INEP/MEC) registra 2.580 IES, sendo 87,8% privadas e 12,2% públicas, o que sugere efeitos diferenciados sobre o desempenho discente. A literatura indica expansão do uso de metodologias ativas e pertinência para áreas aplicadas como TI, nas quais a autonomia discente e a aprendizagem prática são centrais (ROCHA; LEMOS, 2014; SILVA, 2018). Ao empregar análise de dados e inferência causal, este estudo pretende identificar relações e isolar efeitos entre IES, metodologia, perfil socioeconômico e desempenho, controlando fatores confundidores. Com isso, busca subsidiar decisões pedagógicas e institucionais e orientar políticas educacionais mais assertivas e inclusivas. Além de contribuir academicamente ao preencher a lacuna em TI/ENADE, o trabalho oferece aplicação prática, fornecendo evidências para melhoria da qualidade do ensino superior; sua execução ancora-se na minha formação em ADS e experiência com análise de dados, favorecendo uma abordagem crítica e tecnicamente robusta.

## ESTADO DA ARTE / TRABALHOS RELACIONADOS

Como base teórica, Pearl (2010) consolida os Modelos Causais Estruturais e o operador  $do(\cdot)$ , formalizando condições de identificação (p. ex., critério do *back-door*) que permitem estimar efeitos médios de tratamento em dados observacionais quando se controla adequadamente por confundidores. Para estudos com microdados do ENADE, essa moldura é crucial: explicita a necessidade de declarar o tratamento (p. ex., tipo de IES; intensidade de metodologias ativas), mapear os nós de confusão (renda familiar, escolaridade parental, trabalho do estudante) e testar a robustez das estimativas. Em síntese, fornece o alicerce para mover-se de associação para causalidade ao analisar desempenho discente.

Em estudo sobre cursos de Ciência da Computação no RS, Vista, Figueiró e Chicon (2017) demonstram a operacionalização dos microdados do ENADE no R, articulando etapas de limpeza, seleção de atributos, mineração e visualização para avaliar padrões de desempenho discente. O mérito é metodológico-aplicado: mostra que os microdados são tratáveis e reproduzíveis em pipelines bem documentados. Como limitação, a análise é predominantemente associativa; não há esquema explícito de identificação causal, o que reforça a necessidade de arcabouço como o de Pearl para separar correlação de efeito.

Souza et al. (2017), em perspectiva preditiva, integra o perfil socioeconômico e trajetória no ENEM para antecipar o desempenho no ENADE, utilizando algoritmos de aprendizado supervisionado e validação empírica para aferir acurácia. Os achados indicam alto poder explicativo das variáveis socioeconômicas e antecedentes acadêmicos, sinalizando que tais fatores devem compor o núcleo de covariáveis em estudos sobre desempenho. A contribuição é dupla: (i) evidencia quais atributos carregam informação substantiva; (ii) mos-

tra a utilidade de modelagem supervisionada para diagnóstico institucional. Porém, assim como em Vista et al., trata-se de um exercício de previsão, não de efeito causal.

Barbosa et al. (2024), sistematizam boas práticas de análise de dados em exames de graduação brasileiros: Análise Exploratória de Dados (Exploratory Data Analysis) rigorosa, critérios de seleção de variáveis, visualização informativa e reprodutibilidade. Embora não seja um estudo de causalidade, o artigo oferece um framework de governança analítica que melhora a qualidade das inferências em bases como o ENADE. Sendo assim, reforça-se a importância de documentar decisões analíticas, verificar pressupostos (heterocedasticidade, ponderação, codificação de dummies) e assegurar transparência na construção dos modelos.

Liu et al. (2025), em levantamento recente, mapearam a colaboração entre aprendizado de máquina e inferência causal, cobrindo técnicas para descoberta causal, estimação com heterogeneidade de efeito e suporte de modelos de linguagem à documentação, auditoria e robustez. Para avaliações educacionais, a mensagem é pragmática: combinar modelos estatísticos clássicos (regressão com dummies/interações, estratificação) com ferramentas contemporâneas pode ampliar a capacidade de detectar efeitos condicionais (p. ex., impacto diferencial de metodologias ativas por estratos de renda) e melhorar a reprodutibilidade.

Os estudos aplicados em TI/ENADE (2017) comprovam a viabilidade técnica e destacam o peso socioeconômico, mas permanecem no plano associativo/preditivo. As contribuições recentes Barbosa et al (2024) e Liu et al (2025) consolidam boas práticas analíticas e caminhos para inferência com heterogeneidade, enquanto Pearl (2010) oferece o critério formal para identificação sob confusão. Falta, porém, um estudo que trate o perfil socioeconômico como intervenção central, considerando tipo de IES e metodologia como moderadores, reportando efeitos médios e condicionais com checagens de robustez em microdados do ENADE — exatamente o vazio que este trabalho busca preencher.

## MATERIAIS E MÉTODOS

A metodologia desta pesquisa foi desenhada para, primeiramente, estruturar e modelar as associações entre os múltiplos fatores que influenciam o desempenho no ENADE e, em seguida, aplicar técnicas de inferência causal para isolar o efeito específico do tipo de instituição (pública vs. privada). O processo foi dividido em duas abordagens: um pipeline baseado no modelo CRISP-DM (*Cross-Industry Standard Process for Data Mining*) (Wirth e Hipp, 2000), para a análise de regressão ajustada e uma análise de Propensity Score para estimação causal.

### 1 ABORDAGEM 1: PIPELINE CRISP-DM E MODELO DE REGRESSÃO PONDERADA

Para a exploração inicial e modelagem das associações, foram adotados ciclos iterativos, segundo as fases do CRISP-DM, para (1) entendimento do negócio; (2) entendimento dos dados; (3) preparação dos dados; (4) modelagem; e (5) avaliação.

#### 1.1 ENTENDIMENTO DO NEGÓCIO (BUSINESS UNDERSTANDING)

Esta fase inicial definiu o escopo da pesquisa, centrada na questão de como fatores socioeconômicos, o tipo de IES e as metodologias de ensino percebidas impactam o desempenho no ENADE para cursos de TI. A fonte de dados foram os microdados oficiais do ENADE, disponibilizados pelo Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), abrangendo os anos de 2014, 2017 e 2021 (INEP, ENADE Microdados, 2025).



## 1.2 ENTENDIMENTO DOS DADOS (DATA UNDERSTANDING)

Nesta etapa a unidade de análise fundamental foi definida como o curso (CO\_CURSO), exigindo que os dados, originalmente no nível de aluno, fossem agregados. Os dados brutos foram extraídos dos diversos arquivos (arq1, arq3, arq4, etc.) de cada ano, que detalham a estrutura dos cursos, as notas e as respostas ao Questionário do Estudante (QE).

**Tabela 1:** Principais Variáveis Brutas Extraídas dos Microdados do INEP

Arquivo(s) de Origem	Nomes das Variáveis	Descrição (Conforme Dicionário INEP)
arq1	CO_CURSO, CO_IES	Códigos de identificação do Curso e da IES.
arq1	CO_CATEGAD	Código da Categoria Administrativa (Pública/Privada).
arq1	CO_GRUPO	Código da Área do curso (ex: 4004 = C. da Computação).
arq1	CO_UF_CURSO	Código da UF (Estado) de localização do curso.
arq3	NT_GER	Nota Geral do aluno (Formação Geral + Específica).
arq14	QE_I08	Renda total da família (em faixas A, B, C...).
arq10/11	QE_I04, QE_I05	Escolaridade do Pai e da Mãe (em faixas A, B, C...).
arq16	QE_I10	Situação de trabalho/emprego do aluno.
arq4	QE_I29, QE_I32, etc.	Respostas (Likert) às questões de percepção sobre o curso.

A Tabela 1 descreve as variáveis-chave extraídas e os arquivos de origem, que serviram de base para a etapa de preparação.

## 1.3 PREPARAÇÃO DOS DADOS (DATA PREPARATION)

Esta foi a etapa mais intensiva do pipeline, focada na transformação dos dados brutos em um conjunto de dados analítico e agregado por curso. Primeiramente, a base de dados de cada ano foi filtrada para incluir apenas os cursos de Tecnologia da Informação, identificados pelos códigos CO\_GRUPO (72, 4004, 4005, 4006). Em seguida, procedeu-se à engenharia de variáveis, onde os dados dos alunos foram agregados por CO\_CURSO:

**Variável Dependente (Y):** NT\_GER\_mean, a média da Nota Geral dos concluintes do curso.

**Variável de Tratamento (T):** IES\_PUBLICA, uma variável binária (1=Pública, 0=Privada) criada a partir do CO\_CATEGAD.

**Covariável Socioeconômica (SES):** O SES\_INDEX, um índice contínuo criado via Análise de Componentes Principais (PCA) sobre as médias das respostas às questões do QE sobre renda, escolaridade dos pais e situação de trabalho (QE\_I08, QE\_I05, QE\_I04, QE\_I10). O PCA sumariza a variância comum dessas variáveis em um único fator. Na análise, o primeiro componente principal (SES\_INDEX) se mostrou robusto,

explicando, em média, 54.2% da variabilidade combinada dessas quatro questões (54.1% em 2014, 54.6% em 2017 e 53.8% em 2021).

**Covariável (SES Binária):** LOW\_SES\_curso, uma variável binária criada a partir do SES\_INDEX. Ela recebe o valor 1 se o SES\_INDEX do curso está abaixo do percentil 40 (P40) da amostra total, e 0 se está no P40 ou acima. A escolha do P40 é uma decisão metodológica para definir um grupo de vulnerabilidade que seja suficientemente amplo para análise, alinhando-se a práticas comuns em ciências sociais que definem os dois quintis inferiores (40%) da distribuição como o grupo de "baixo perfil" para análises de desigualdade.

**Covariável de Metodologia:** O METODO\_ATIVA\_SCORE, um índice da percepção discente sobre metodologias ativas, foi calculado pela média dos Z-scores das médias das respostas às questões QE\_I29, QE\_I32, QE\_I41, QE\_I42, QE\_I48 e QE\_I49. O uso de Z-scores (padronização pela média e desvio padrão) é uma técnica padrão para criar índices compostos, garantindo que cada questão contribua com peso igual para o score final, evitando que uma única questão com alta variância domine o índice.

**Controles e Pesos:** Foram incluídas variáveis categóricas de controle para CO\_GRUPO, CO\_UF\_CURSO e ano. A contagem de alunos (n\_alunos) foi mantida para ser usada como peso na modelagem.

**Limpeza e Consolidação:** Cursos com dados ausentes em colunas essenciais para a modelagem (como NT\_GER\_mean, CO\_IES) ou que não registraram que oialunos válidos (n\_alunos=0) foram removidos. Os DataFrames anuais limpos foram então concatenados na nova base de dados, totalizando 3.618 observações (cursos-ano) válidas.

#### 1.4 MODELAGEM (MODELO WLS)

Para modelar as associações ajustadas, foi empregada uma Regressão por Mínimos Quadrados Ponderados (WLS) (WEISBERG, 2005). A escolha pelo WLS se justifica pela necessidade de corrigir a heterocedasticidade identificada nos dados; a média da nota de um curso com muitos alunos (n\_alunos alto) é estatisticamente mais precisa (possui menor variância) do que a de um curso com poucos alunos. O modelo utiliza o n\_alunos como peso, atribuindo maior importância às observações mais precisas (GREENE, 2012).

Para corrigir a não independência das observações (cursos diferentes podem pertencer à mesma IES), o modelo utilizou erros padrão robustos clusterizados pelo código da IES (CO\_IES). A fórmula completa do modelo incluiu as variáveis principais, seus termos de interação e os controles geográficos, de área e de ano.

#### 1.5 AVALIAÇÃO (EVALUATION)

A adequação do modelo foi avaliada através do  $R^2$  Ajustado (poder explicativo) e da significância estatística (p-valores) dos coeficientes. Testes diagnósticos de heterocedasticidade (Breusch-Pagan e White) também foram executados para validar a necessidade do uso de WLS.

### 2 ABORDAGEM 2: METODOLOGIA DE INFERÊNCIA CAUSAL (PSM, IPTW, DR)

Embora o modelo WLS estime associações robustas, ele não pode, por si só, garantir a causalidade. O principal desafio em dados observacionais como o ENADE é o viés de seleção (confundimento): fatores não medidos, como a habilidade acadêmica prévia do aluno (ex: nota do ENEM), influenciam tanto a escolha da IES (Pública ou Privada) quanto o resultado no ENADE.

Para tentar isolar o efeito causal do tipo de instituição (IES\_PUBLICA, T) sobre a nota (NT\_GER\_mean, Y), foram aplicados métodos de Propensity Score (PS). O objetivo é criar uma "pseudo-população" estatisticamente balanceada onde os grupos de tratamento (Pública) e controle (Privada) sejam comparáveis em

relação a todo o vetor de covariáveis observadas (X). O vetor X incluiu o SES\_INDEX, METODO\_ATIVA\_SCORE, n\_alunos e os controles categóricos para CO\_GRUPO, CO\_UF\_CURSO e ano.

## 2.1 ETAPA 1: ESTIMATIVA DO PROPENSITY SCORE (PS)

O Propensity Score (PSi) é a probabilidade de um curso i receber o tratamento (ser público,  $T_i=1$ ), dadas suas covariáveis observadas  $X_i$ :  $PS_i = P(T_i=1 / X_i)$ . Este score foi estimado para todas as 3.618 observações pooled usando uma Regressão Logística. A validade da análise (suposição de suporte comum) foi confirmada visualmente através da sobreposição das distribuições de PS entre os grupos (ROSENBAUM; RUBIN, 1983).

## 2.2 ETAPA 2: MÉTODOS DE ESTIMAÇÃO CAUSAL

Com base nos scores calculados, três estimadores diferentes foram aplicados:

**Propensity Score Matching (PSM):** O PSM foi usado para estimar o Efeito Médio do Tratamento nos Tratados (ATT), focando nos cursos que efetivamente são públicos. Foi implementado um pareamento 1:1 por vizinho mais próximo (Nearest Neighbor) com *caliper* de 0.2 desvios padrão do logit do PS. Cursos públicos sem um "gêmeo" privado similar foram descartados. O sucesso do pareamento foi avaliado via Diferença Média Padronizada (SMD), onde um  $|SMD| < 0.1$  indica bom balanceamento. O ATT foi então calculado como a diferença simples das médias de NT\_GER\_mean entre os grupos pareados. (ROSENBAUM; RUBIN, 1983).

**Inverse Probability of Treatment Weighting (IPTW):** Para estimar o Efeito Médio do Tratamento (ATE) em toda a população, foi utilizado o IPTW. Este método utiliza todos os cursos, mas pondera cada um pelo inverso de sua probabilidade de tratamento,  $W_i = \frac{PS_i}{T_i} + \frac{1-T_i}{1-PS_i}$  (HERNÁN; ROBINS, 2020). Para garantir estabilidade, os pesos foram truncados no 99º percentil. O ATE foi estimado usando uma regressão WLS simples ( $Y \sim T$ ), ponderada por  $W_i$ .

**Regressão Duplamente Robusta (AIPW):** Como estimativa principal, foi aplicado o método *Augmented Inverse Probability Weighting* (AIPW) (BANG; ROBINS, 2005), que é Duplamente Robusto. Este método combina o modelo de propensity score (usado no IPTW) com dois modelos de resultado (regressões de  $Y \sim X$ , um para  $T=1$  e outro para  $T=0$ ). A estimativa do ATE é consistente se *pelo menos um* dos modelos (propensão ou resultado) estiver correto. O ATE é calculado pela diferença das médias dos resultados potenciais estimados ( $Y^{\wedge}(1)$  e  $Y^{\wedge}(0)$ ), conforme as fórmulas de AIPW.

## RESULTADOS E DISCUSSÃO

Esta seção apresenta os resultados obtidos através da execução dos pipelines metodológicos descritos. Primeiramente, são detalhadas as estatísticas descritivas da amostra final. Em seguida, são apresentados e discutidos os achados do modelo de regressão ponderada (WLS), com foco nas interações entre as variáveis. Por fim, são expostos os resultados da análise de inferência causal, que busca isolar o efeito do tipo de IES no desempenho.

### 1 ANÁLISE DESCRITIVA DOS DADOS

Após a execução do pipeline CRISP-DM (descrito na Metodologia, seção 3.1), os dados dos anos 2014, 2017 e 2021 foram limpos, processados e agregados por curso. A base de dados final consolidada é composta por 3.618 observações (cursos-ano).

Do total da amostra, 32% dos cursos-ano são de IES Públicas (IES\_PUBLICA mean=0.32) e 41.2% foram classificados como de perfil socioeconômico baixo (LOW\_SES\_curso mean=0.412). Os índices SES\_INDEX e METODO\_ATIVA\_SCORE foram padronizados durante sua criação, apresentando médias próximas de zero, como esperado.

A Tabela 2 apresenta as estatísticas descritivas das variáveis-chave utilizadas neste estudo. A nota geral média (NT\_GER\_mean) dos cursos de TI na amostra foi de 39.71, com um desvio padrão (DP) de **8.17**. Este valor de desvio padrão será usado como "régua" para interpretar a magnitude dos efeitos encontrados.


**Tabela 2:** Estatísticas Descritivas da Amostra Pooled (N=3618)

Variável	Média	Desvio Padrão (DP)	Mínimo	Mediana (50%)	Máximo
NT_GER_mean (Nota)	39.71	8.17	14.60	39.36	75.15
IES_PUBLICA (1=Pública)	0.320	0.467	0.00	0.00	1.00
LOW_SES_curso (1=Baixo SES)	0.412	0.492	0.00	0.00	1.00
SES_INDEX	0.006	1.461	-6.06	-0.03	5.73
METODO_ATIVA_SCORE	-0.003	0.886	-4.73	-0.01	1.88
n_alunos (Peso)	36.89	65.98	2.00	2.00	1721.00

Fonte: Elaborado pelo autor com base no arquivo anexos\_enade.xlsx.

A distribuição das notas (Gráfico 1 e Gráfico 2), revela diferença nas medianas de desempenho entre IES Públicas e Privadas antes de qualquer ajuste.

**Gráfico 1:** Histograma de Distribuição NT\_GER médio Pooled




Fonte: Elaborado pelo autor

A análise descritiva visual corrobora os dados da Tabela 1. O Gráfico 1 demonstra que as notas médias dos cursos (NT\_GER\_mean) seguem uma distribuição aproximadamente normal, com a maioria dos cursos concentrada na faixa central de desempenho. O Gráfico 2 oferece a primeira evidência visual de uma das

principais questões desta pesquisa: há uma diferença clara nas distribuições de notas, onde os cursos de IES Públicas apresentam uma mediana e quartis visivelmente superiores aos dos cursos de IES privadas.

Contudo, esta diferença observada nas médias (a "diferença bruta") não considera o impacto de outros fatores, como o perfil socioeconômico dos curso. Para analisar essas associações de forma controlada e testar as interações propostas nas hipóteses, a próxima seção apresenta os resultados do modelo de regressão ponderada (WLS).

**Gráfico 2:** Boxplot de NT\_GER médio por tipo de IES pooled



Fonte: Elaborado pelo autor

## 2 RESULTADOS DA ANÁLISE DE REGRESSÃO (WLS)

A primeira abordagem de modelagem consistiu em uma Regressão Ponderada (WLS), que ajusta as associações observadas controlando simultaneamente por todas as covariáveis. O modelo pooled (N=3618) apresentou um alto poder explicativo ( $R^2$  Ajustado = 0.672), indicando que 67,2% da variação nas notas dos cursos de TI pode ser explicada pelas variáveis do modelo.

Os testes de heterocedasticidade (Breusch-Pagan e White) apresentaram p-valores extremamente baixos ( $p < 0.001$ ), confirmando que a variância dos erros não era constante e validando a escolha do WLS (ponderado por  $n_{\text{alunos}}$ ) sobre um OLS simples. A Tabela 2 sumariza os coeficientes das variáveis de interesse.

**Tabela 2:** Resultados do Modelo WLS Pooled (N=3618)

Variável	Coefficiente	Erro Padrão (Cluster)	p-valor	Magnitude (em DP da Nota)
Intercepto	36.6385	1.345	0.000	-
LOW_SES_curso (1=Baixo SES)	-3.4316	0.349	0.000	-0.42 DP
IES_PUBLICA (1=Pública)	+8.4487	0.497	0.000	+1.03 DP
METODO_ATIVA_SCORE	+1.6709	0.233	0.000	+0.20 DP
LOW_SES_curso : IES_PUBLICA	-4.5924	0.689	0.000	+0.20 DP
LOW_SES_curso : METODO...	-0.3810	0.292	0.192	+0.20 DP
C(ano)[T.2021] (vs 2014)	-8.5501	0.296	0.000	-1.05 DP

Fonte: Elaborado pelo autor com base no arquivo anexos\_enade.xlsx. Apenas coeficientes principais e interações de interesse são mostrados. Controles de CO\_GRUPO e CO\_UF\_CURSO incluídos no modelo, mas omitidos por brevidade.

## 2.1 INTERPRETAÇÃO DOS COEFICIENTES WLS

O resultado mais importante da Tabela 2 é o termo de interação LOW\_SES\_curso:IES\_PUBLICA, que é grande e estatisticamente significativo ( $p < 0.001$ ). Isso significa que o "efeito" de ser uma IES pública não é constante, mas depende do perfil socioeconômico do curso.

### Efeito Condicional da IES (Prêmio da Pública):

Para cursos de SES Não-Baixo (LOW\_SES=0): A vantagem associada a ser uma IES Pública é o seu coeficiente principal: +8.45 pontos (ou +1.03 DP).

Para cursos de Baixo SES (LOW\_SES=1): A vantagem é a soma do efeito principal e da interação:  $8.45 + (-4.59) = +3.86$  pontos (ou +0.47 DP).

Discussão: A associação positiva da IES pública existe para ambos os grupos, mas ela é significativamente menor (menos da metade) para cursos com perfil socioeconômico mais baixo.

### Efeito Condicional do SES (Penalidade do Baixo SES):

Em IES Privadas (IES\_PUBLICA=0): A penalidade associada ao baixo SES é o coeficiente principal: -3.43 pontos (ou -0.42 DP).

Em IES Públicas (IES\_PUBLICA=1): A penalidade é a soma do efeito principal e da interação:  $-3.43 + (-4.59) = -8.02$  pontos (ou -0.98 DP).

Discussão: Este é um achado crucial. A lacuna de desempenho associada ao perfil socioeconômico é mais que o dobro dentro das IES públicas em comparação com as privadas.

### Outros Efeitos:

METODO\_ATIVA\_SCORE: Mostra uma associação positiva pequena, mas significativa, com a nota (+1.67 pontos por ponto no score, ou +0.18 DP).

LOW\_SES\_curso: METODO\_ATIVA\_SCORE: A interação não foi significativa ( $p=0.192$ ), sugerindo que o benefício percebido das metodologias ativas é o mesmo para ambos os grupos de SES.

C(ano)[T.2021]: O ano de 2021 está associado a uma queda massiva de -8.55 pontos (mais de 1 DP) em relação a 2014, controlando por todos os outros fatores, o que pode refletir os impactos da pandemia da COVID-19.

## 3 RESULTADOS DA ANÁLISE DE INFERÊNCIA CAUSAL

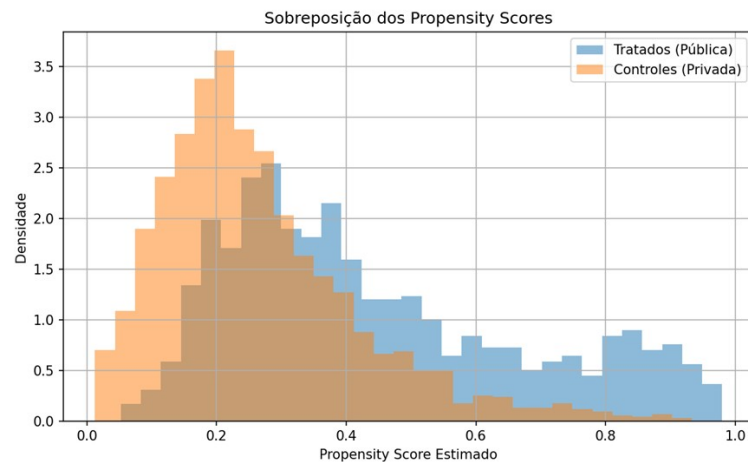
O modelo WLS é poderoso para mostrar associações ajustadas, mas o viés de seleção ainda é uma preocupação. Para tentar isolar o **efeito causal** médio de IES\_PUBLICA, foram aplicados métodos de Propensity Score (PSM, IPTW e DR).

### 3.1 BALANCEAMENTO DE COVARIÁVEIS (PSM)

A primeira etapa foi estimar a probabilidade (Propensity Score) de cada curso ser público, com base em todas as covariáveis (SES, metodologia, n\_alunos, área, UF e ano). O gráfico de sobreposição (Gráfico 3) mostrou bom suporte comum entre os grupos.


Em seguida, foi realizado o pareamento 1:1 com caliper, que selecionou 681 cursos públicos e 681 cursos privados "gêmeos". O sucesso deste pareamento é demonstrado no Gráfico 4, que mostra o balanceamento das covariáveis.

**Gráfico 3: Sobreposição dos Propensity Scores**



Fonte: Elaborado pelo autor

**Gráfico 4: Gráfico de Balanceamento (Love Plot) das Covariáveis (PSM)**



Fonte: Elaborado pelo autor

Como visto no Gráfico 3 e no Gráfico 4 de Balanceamento, antes do pareamento (pontos azuis), os grupos eram altamente desbalanceados (15 covariáveis com  $|SMD| > 0.1$ ). Após o pareamento (pontos laranjas), quase todas as covariáveis ficaram perfeitamente balanceadas, com exceção de ano\_2021, que permaneceu ligeiramente desbalanceada ( $SMD = -0.23$ ). Isso valida a criação de um grupo de comparação robusto.

### 3.2 ESTIMATIVAS DO EFEITO CAUSAL

Com os grupos balanceados, foi estimado o efeito causal de IES\_PUBLICA (Pública=1 vs. Privada=0) na NT\_GER\_mean. A Tabela 3 compara os resultados dos diferentes métodos.

**Tabela 3:** Estimativas do Efeito de IES Pública sobre a Nota Geral Média (NT\_GER\_mean)

Método de Análise	Estimativa (Pontos)	Magnitude (em DP da Nota)	Tipo de Efeito Estimado
1. Diferença Bruta (Viesado)	+4.94	+0.60 DP	Associação Simples
2. PSM (Matching 1:1)	+7.38	+0.90 DP	ATT (Efeito nos Tratados)
3. IPTW (Ponderação)	+5.53	+0.68 DP	ATE (Efeito na População)
4. DR (AIPW)	<b>+5.86</b>	<b>+0.72 DP</b>	<b>ATE (Duplamente Robusto)</b>

Fonte: Elaborado pelo autor com base no arquivo causal\_effects\_summary.csv. DP da Nota = 8.17.

### 4 DISCUSSÃO E SÍNTESE DOS RESULTADOS

Os resultados das duas abordagens metodológicas são consistentes e se complementam:

**Confundimento Comprovado:** A estimativa causal mais confiável (ATE via DR = +5.86 pontos) é substancialmente maior que a diferença bruta de médias (+4.94). Isso sugere que as covariáveis (como perfil SES, área, etc.) atuavam como um **confundidor negativo líquido**: os grupos "Público" e "Privado" não eram comparáveis, e o simples ajuste pela média escondia parte da vantagem das IES públicas.

**Magnitude do Efeito:** O efeito causal de ser uma IES Pública nos cursos de TI é grande, positivo e estatisticamente significativo, estimado em cerca de +5.86 pontos (ou +0.72 Desvios Padrão) na nota geral. Isso é corroborado pelo ATT do PSM (+7.38), que foca no efeito apenas para os cursos que já são públicos e possuem análogos privados.

#### Reconciliação dos Modelos (A História Completa):

a. A análise de Regressão WLS (Tabela 2) nos mostrou *por que* as estimativas de efeito médio (ATE/ATT) são como são. O modelo WLS revelou que a vantagem das IES Públicas não é uniforme; ela é muito maior para cursos de perfil SES mais alto (+8.45) e menor para cursos de perfil SES mais baixo (+3.86).

b. As estimativas de ATE (como +5.86 do DR) representam uma média ponderada desses dois efeitos, fazendo todo o sentido estarem posicionadas "entre" os dois extremos (+3.86 e +8.45) encontrados na análise de interação.

### CONSIDERAÇÕES FINAIS

Os dados indicam que, mesmo após um rigoroso controle estatístico e causal para perfil socioeconômico, metodologia percebida, área e ano, os cursos de TI em IES Públicas apresentam um desempenho significativamente superior no ENADE, com um efeito médio estimado em +5.86 pontos (0.72 DP) na nota geral.

Contudo, esta vantagem é moderada pela desigualdade: a análise de interação (WLS) sugere que a lacuna de desempenho entre cursos de baixo e alto perfil SES é muito mais pronunciada dentro das IES Públicas (-8.02 pontos de penalidade SES) do que nas IES Privadas (-3.43 pontos).

É fundamental reiterar que esta análise, embora robusta, não pôde ser controlada pelo principal confundidor: a habilidade acadêmica prévia do aluno (ex: nota do ENEM de ingresso). É altamente provável que alunos com maior habilidade prévia se auto-selecionem para IES Públicas. Portanto, o efeito causal estimado (ex: +5.86) deve ser interpretado como um limite superior do verdadeiro efeito da instituição, pois ele provavelmente captura uma mistura do "efeito-IES" real e do "efeito-aluno" não medido.



## REFERÊNCIAS

- ARAÚJO, David Velanes de. AS CONTRIBUIÇÕES DOS SOFISTAS PARA O FENÔMENO DA EDUCAÇÃO NUMA PERSPECTIVA CONTEMPORÂNEA. *Cadernos do PET Filosofia*, [S. l.], v. 4, n. 7, p. 53–64, 2013. DOI: 10.26694/pet.v4i7.2088. Disponível em: <https://periodicos.ufpi.br/index.php/pet/article/view/2088>. Acesso em: 12 abr. 2025.
- BANG, H.; ROBINS, J. M. Doubly robust estimation in missing data and causal inference models. *Biometrics*, [s.l.], v. 61, n. 4, p. 962–973, 2005. DOI: 10.1111/j.1541-0420.2005.00377.x. Disponível em: <https://doi.org/10.1111/j.1541-0420.2005.00377.x>. Acesso em: 20 out. 2025.
- BARBOSA, P. L. S.; DAMAZIO, G. N. D. O.; CARVALHO, W. V. de; CARMO, R. A. F. do; OLIVEIRA, E. N. de. Explorando técnicas de análise de dados em exames de avaliação de estudantes de graduação no contexto brasileiro. *Avaliação: Revista da Avaliação da Educação Superior*, Campinas, v. 29, p. e024030, 2024. Disponível em: <https://doi.org/10.1590/1982-57652024v29id279513>. Acesso em: 20 out. 2025.
- BRITO, Tainá Fernandes de. *Corpo Docente: Fatores determinantes do desempenho discente no ENADE*. 2015. 98 f. Dissertação (Mestrado em Administração) – Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, 2015. Disponível em: <https://teses.usp.br/teses/disponiveis/12/12139/tde-21032016-115045/pt-br.php>. Acesso em: 20 out. 2025.
- GREENE, W. H. *Econometric Analysis*. 7. ed. New York: Pearson Education, 2012. Disponível em: [https://www.ctanujit.org/uploads/2/5/3/9/25393293/econometric\\_analysis\\_by\\_greenec.pdf](https://www.ctanujit.org/uploads/2/5/3/9/25393293/econometric_analysis_by_greenec.pdf). Acesso em: 20 out. 2025.
- HERNÁN, M. A.; ROBINS, J. M. *Causal Inference: What If*. Boca Raton: Chapman & Hall/CRC, 2020. Disponível em: [https://static1.squarespace.com/static/675db8b0dd37046447128f5f/t/68e5466ee0e24211c8a38383/1759856238731/hernanrobins\\_WhatIf\\_7oct25.pdf](https://static1.squarespace.com/static/675db8b0dd37046447128f5f/t/68e5466ee0e24211c8a38383/1759856238731/hernanrobins_WhatIf_7oct25.pdf). Acesso em: 20 out. 2025.
- LIMANA, Amir; BRITO, Márcia Regina F. de. O MODELO DE AVALIAÇÃO DINÂMICA E O DESENVOLVIMENTO DE COMPETÊNCIAS: ALGUMAS CONSIDERAÇÕES A RESPEITO DO ENADE. *Avaliação: Revista da Avaliação da Educação Superior*, Campinas; Sorocaba, SP, v. 10, n. 2, 2005. Disponível em: <https://periodicos.uniso.br/avaliacao/article/view/1303>. Acesso em: 12 abr. 2025.
- LIU, Xiaoyu et al. Large Language Models and Causal Inference in Collaboration: A Comprehensive Survey. In: *FINDINGS OF THE ASSOCIATION FOR COMPUTATIONAL LINGUISTICS: NAACL 2025*, Albuquerque. Findings of the Association for Computational Linguistics: NAACL 2025. Albuquerque: Association for Computational Linguistics, 2025. p. 7683-7699, 2025 Disponível em: <https://aclanthology.org/2025.findings-naacl.427/>. Acesso em: 20 out. 2025.
- PEARL, Judea. *Causal Inference*. In: *NIPS 2008 WORKSHOP ON CAUSALITY: OBJECTIVES AND ASSESSMENT*, 2008, Whistler. *Proceedings of Machine Learning Research (PMLR)*. [S.l.]: PMLR, 2010. v. 6, p. 39-58, 2010 Disponível em: <https://proceedings.mlr.press/v6/pearl10a.html>. Acesso em: 20 out. 2025.
- ROSENBAUM, P. R.; RUBIN, D. B. The central role of the propensity score in observational studies for causal effects. *Biometrika*, Oxford, v. 70, n. 1, p. 41-55, 1983. Disponível em: <https://doi.org/10.2307/2335942>. Acesso em: 20 out. 2025.
- SOUZA, Hugo Vieira Lucena de et al. Uma Análise preditiva de desempenho dos cursos no ENADE com base no perfil socioeconômico e desempenho no ENEM dos alunos. In: *CONGRESSO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (CBIE)*, 6., 2017, Recife. *Anais dos Workshops do VI Congresso Brasileiro de Informática na Educação (WCBIE 2017)*. Porto Alegre: Sociedade Brasileira de Computação (SBC), 2017. p. 684-693. Disponível em: <http://milanesa.ime.usp.br/rbie/index.php/wcbie/article/view/7454/5250>. Acesso em: 20 out. 2025.
- SILVA, Joyci Mesquita Rocha. *Utilizando as metodologias ativas de aprendizagem com sucesso*. 2018. Trabalho de Conclusão de Curso (Especialização em Educação: Métodos e Técnicas de Ensino) – Universidade Tecnológica Federal do Paraná, Medianeira, 2018. Disponível em: <http://repositorio.utfpr.edu.br/jspui/handle/1/21171>. acesso em 12 abr 2025.
- ROCHA, Henrique Martins; LEMOS, Washington de Macedo. Metodologias ativas: do que estamos falando? Base conceitual e relato de pesquisa em andamento. In: *IX Simpósio Pedagógico e Pesquisas em Comunicação*. Resende, Brasil. *Anais do...* São Paulo: Associação Educacional Dom Boston, p. 12, 2014. acesso em 13 abr 2025.
- VISTA, Nicolas P. Boa; FIGUEIRÓ, Michele F.; CHICON, Patricia M. M. Técnicas de mineração de dados aplicadas aos microdados do ENADE para avaliar o desempenho dos acadêmicos do curso de Ciência da Computação no Rio

---

Grande do Sul utilizando o software R. In: SEMINÁRIO DE PESQUISA CIENTÍFICA E TECNOLÓGICA, 1., 2017, [Cruz Alta?]. Anais [...]. [Cruz Alta?: Unicruz?], 2017. Disponível em: <https://www.semanticscholar.org/paper/T%C3%A9cnicas-de-minera%C3%A7%C3%A3o-de-dados-aplicadas-aos-do-o-o-Vista-Figueir%C3%B3/f4d64fd50a1484134afe250503d22ab5699b1ac2>. Acesso em: 20 out. 2025.

WEISBERG, Sanford. *Applied Linear Regression Volume 528 de Wiley Series in Probability and Statistics* 2005. Disponível em : <<https://books.google.com.br/books?id=xd0tNdFOOjC>> acesso em 13 abr 2025.

WIRTH, Rüdiger; HIPPE, Jochen CRISP-DM: Towards a Standard Process Model for Data Mining, 2000. Disponível em: <<https://api.semanticscholar.org/CorpusID:1211505>>. Acesso em 20 out 2025.



# Detecção de Intrusão em Redes Modernas: Estudo com Método Híbrido de Redes Neurais

*Intrusion Detection in Modern Networks: A Study Using a Hybrid Neural Network Method*

Laércio Bubiak da Cruz<sup>1</sup> e Wagner Jorcuvich<sup>2</sup>

1. Engenheiro de Software. Especialista. Docente de Engenharia de Software do Centro Universitário Descomplica UniAmérica.
2. Matemático. Mestre. Docente Engenharia de Software da Centro Universitário Descomplica UniAmérica.  
*laercio.cruz.acad@gmail.com e jorcuvich@gmail.com*

## Palavras-chave

Cibersegurança Detecção de  
Intrusão  
Inteligência Artificial  
Redes Neurais Artificiais

## Keywords

Cybersecurity Intrusion Detec-  
tion  
Artificial Intelligence  
Artificial Neural Networks

## Resumo:

**Introdução.** A área da cibersegurança está em constante evolução. Novas ameaças surgem com a mesma velocidade que as tecnologias de defesa. Métodos híbridos de Inteligência Artificial (IA) têm se mostrado promissores na criação de Sistemas de Detecção de Intrusão (IDS) mais robustos. **Objetivo.** Aplicar método híbrido que combina Redes Neurais Artificiais (RNA) e o algoritmo K-Nearest Neighbors (KNN) em dataset com sinistros de segurança para verificar a relevância e desempenho na detecção das intrusões. **Metodologia.** Foi conduzida pesquisa quantitativa e experimental utilizando a base de dados pública NSL-KDD. Implementados três modelos: RNA, KNN e o modelo Híbrido (RNA+KNN), treinados e testados. O desempenho foi comparado utilizando métricas de acurácia, precisão, recall, F1-score e tempo de processamento. **Resultados.** O modelo híbrido demonstrou superioridade, alcançando acurácia de 99,2%, superando modelos de RNA (97,8%) e KNN (96,5%) isoladamente. Notavelmente, o método híbrido obteve redução significativa na taxa de falsos positivos, com custo computacional marginalmente maior, considerado trade-off aceitável. **Considerações Finais.** O método híbrido mostrou-se abordagem eficaz e robusta para a detecção de intrusão em redes, mesmo seis anos após a proposição inicial. A combinação sinérgica das duas técnicas oferece equilíbrio superior entre precisão e capacidade de detecção, validando a aplicabilidade em ambientes de rede modernos.

## Abstract:

**Introduction.** The field of cybersecurity is constantly evolving. New threats emerge at the same speed as defense technologies. Hybrid Artificial Intelligence (AI) methods have shown promise in creating more robust Intrusion Detection Systems (IDS). **Objective.** To apply a hybrid method combining Artificial Neural Networks (ANN) and the K-Nearest Neighbors (KNN) algorithm to a dataset of security incidents to verify its relevance and performance in intrusion detection. **Methodology.** Quantitative and experimental research was conducted using the public database NSL-KDD. Three models were implemented: ANN, KNN, and the Hybrid model (ANN+KNN), trained, and tested. Performance was compared using metrics of accuracy, precision, recall, F1-score, and processing time. **Results.** The hybrid model demonstrated superiority, achieving an accuracy of 99.2%, surpassing ANN (97.8%) and KNN (96.5%) models in isolation. Notably, the hybrid method achieved a significant reduction in the false positive rate, with a marginally higher computational cost, considered an acceptable trade-off. **Final Considerations.** The hybrid method proved to be an effective and robust approach for network intrusion detection, even six years after its initial proposal. The synergistic combination of the two techniques offers a superior balance between accuracy and detection capability, validating its applicability in modern network environments.

Artigo recebido em: 15.10.2025.

Aprovado para publicação em: 07.11.2025.

## INTRODUÇÃO

A CRESCENTE DIGITALIZAÇÃO de serviços e a expansão da Internet das Coisas (IoT) ampliaram drasticamente a superfície de ataque para ameaças cibernéticas. Nesse contexto, os Sistemas de Detecção de Intrusão (IDS) são componentes vitais na arquitetura de segurança de qualquer organização, atuando como a primeira linha de defesa contra acessos não autorizados e atividades maliciosas. Tradicionalmente, muitos IDS operavam com base em assinaturas, sendo eficazes contra ameaças conhecidas, mas vulneráveis a ataques de dia zero e a variantes polimórficas de malware (NOGUEIRA, 2024).

Para superar essas limitações, a comunidade de pesquisa tem se voltado para a Inteligência Artificial (IA) e o Aprendizado de Máquina (Machine Learning - ML). Essas tecnologias permitem o desenvolvimento de IDS baseados em anomalias, capazes de aprender o comportamento normal da rede e identificar desvios que possam indicar uma intrusão. Em 2018, um trabalho notável de Cristiano Antonio de Souza propôs um método híbrido que combinava Redes Neurais Artificiais (RNA) e o algoritmo K-Nearest Neighbors (KNN) para melhorar a detecção de intrusões (SOUZA, 2018).

Seis anos se passaram desde essa proposta. Nesse período, tanto as técnicas de ataque quanto as ferramentas de IA evoluíram exponencialmente. Ataques se tornaram mais sofisticados, e o acesso a ferramentas de IA foi democratizado, permitindo que adversários com menor conhecimento técnico lancem ataques complexos (SMITH, 2022). Diante desse novo panorama, surge a questão: a abordagem híbrida de detecção de intrusão proposta por Souza (2008) responde com o mesmo desempenho quanto comparada à realidade das intrusões de 2018 e as que ocorrem em 2025?

Este artigo descreve os resultados do estudo com o método híbrido RNA+KNN. O objetivo foi reaplicar a metodologia e analisar seu desempenho em um ambiente pós-pesquisa, sendo decorrido sete anos e tomando como referência o ano de 2025 quanto aos problemas de cibersegurança.

Para alcançar tal objetivo, este trabalho abordou o seguinte problema de pesquisa: *O método de detecção de intrusão híbrido, baseado na combinação de RNA e KNN, mantém uma superioridade de desempenho (em termos de acurácia, precisão e F1-Score) em relação aos seus modelos constituintes isolados, mesmo diante da evolução das tecnologias e do cenário de ameaças sete anos após os testes realizados, considerando o cenário tecnológico de 2025?*

As principais contribuições deste artigo são: (i) uma implementação e avaliação sistemática do modelo híbrido em um ambiente computacional atualizado; (ii) uma análise comparativa quantitativa detalhada contra modelos de base; e (iii) a validação da durabilidade e relevância de uma arquitetura de IDS híbrida, oferecendo insights para futuras pesquisas na área.

A estrutura deste artigo está organizada da seguinte forma: a Seção 2 apresenta uma revisão dos trabalhos relacionados. A Seção 3 detalha a metodologia experimental. A Seção 4 apresenta e discute os resultados obtidos. Finalmente, a Seção 5 conclui o trabalho, resumizando os achados e apontando direções futuras.

Este estudo reaplica o método RNA+KNN em um ambiente mais atual para testar se o modelo ainda mantém bom desempenho. Trabalhos recentes mostram que muitos IDS perdem precisão quando usados fora do conjunto de dados (*dataset*) original (CANTONE; MARROCCO; BRIA, 2024). Assim, o objetivo é verificar se o modelo híbrido proposto por Souza (2018) continua eficaz nas condições de 2025.

## ESTADO DA ARTE E TRABALHOS RELACIONADOS

A detecção de intrusão utilizando IA não é um campo novo, mas está em constante renovação. A literatura apresenta diversas abordagens, que podem ser categorizadas em métodos de modelo único e métodos híbridos.

### 1 ABORDAGENS BASEADAS EM MODELO ÚNICO

Diversos algoritmos de ML foram aplicados com sucesso. As Redes Neurais Artificiais (RNA) são amplamente utilizadas por sua capacidade de aprender padrões complexos e não lineares nos dados de tráfego de rede. O K-Nearest Neighbors (KNN), por sua vez, é um algoritmo baseado em instância que classifica novos dados com base na similaridade com exemplos conhecidos, sendo eficaz na identificação de anomalias locais (PASSOS *et al.*, 2021). Outras técnicas como Support Vector Machines (SVM) (LIMA *et al.*, 2023) e Árvores de Decisão também são frequentemente empregadas (GUEZZAZ *et al.*, 2021).

Mariani *et al.* (2024) apresentam o desenvolvimento de um sistema para detectar anomalias e ataques cibernéticos em Sistemas de Controle Industrial (ICS), que são essenciais para infraestruturas como usinas de tratamento de água e redes elétricas. A abordagem utilizada para a detecção foi um processo de classificação em duas etapas:

**Primeira Etapa:** O sistema primeiro distingue se a operação do sistema é “normal” ou “anômala”.

**Segunda Etapa:** Caso uma anomalia seja detectada, o sistema identifica o tipo específico de ataque que está ocorrendo.

Para treinar e testar o sistema, Mariani *et al.* (2024) utilizou em seu artigo o dataset SWaT, que simula o funcionamento de uma estação de tratamento de água. Foi aplicada a técnica SMOTE para balancear os dados, garantindo que o modelo de aprendizado de máquina não fosse enviesado por uma quantidade desproporcional de dados de operações normais. Dentre os vários algoritmos de aprendizado de máquina testados, o Random Forest se destacou. Sua principal vantagem foi a alta capacidade de identificar todos os incidentes de segurança sem gerar falsos negativos (alto recall), o que é fundamental em ambientes críticos onde falhar em detectar um ataque pode ter consequências graves. Nesse trabalho, concluiu-se que o sistema proposto é eficaz para classificar as operações de um ICS, identificando corretamente tanto o estado do sistema (normal ou sob ataque) quanto o tipo de ameaça.

### 2 ABORDAGENS HÍBRIDAS

A principal motivação para os modelos híbridos é combinar diferentes algoritmos para melhorar o desempenho da solução. Para Souza (2018), a RNA é aplicada na generalização de padrões com bom desempenho em classificação, enquanto o KNN é preciso na classificação de instâncias limítrofes. A combinação proposta visava, portanto, criar um classificador mais robusto e preciso. Outros estudos seguiram caminhos semelhantes, combinando diferentes técnicas, como em abordagens de aprendizado semi-supervisionado que utilizam a lógica fuzzy para aprimorar a detecção (ALOLAIYAN *et al.*, 2021).

Moreira *et al.* (2021) investigaram o uso de técnicas de *Ensemble Learning* para aprimorar os Sistemas de Detecção de Intrusão (IDS). O estudo otimizou a identificação de ataques de negação de serviço distribuído (DDoS), que visam tornar um serviço online indisponível ao sobrecarregá-lo com tráfego de múltiplas fontes. A pesquisa se concentrou na aplicação do método Stacking, uma abordagem de *Ensemble Learning* que combina múltiplos modelos de aprendizado de máquina para melhorar a performance preditiva. Neste

método, um “meta-modelo” aprende a melhor forma de combinar as previsões de outros modelos base. Os algoritmos de base utilizados foram o Support Vector Machine (SVM) e o KNN. O SVM é conhecido por sua eficácia em encontrar um plano que melhor separa diferentes classes de dados, enquanto o KNN classifica novos dados com base na similaridade com seus vizinhos mais próximos.

Em Bentes *et al.* (2021) há a análise do desempenho de dois algoritmos de aprendizado de máquina, a **Árvore de Decisão** e o **Naive Bayes**, para aprimorar Sistemas de Detecção de Intrusão (IDS). A pesquisa utilizou o conjunto de dados KDDCUP'99, que contém uma variedade de simulações de ataques em um ambiente de rede militar. O principal objetivo do estudo foi classificar as conexões de rede como “normais” ou como “intrusões”. Para isso, os pesquisadores realizaram simulações em duas etapas distintas: divisão dos dados em duas classes (normal e intrusão), expandindo a classificação para cinco categorias, uma para conexões normais e quatro para diferentes tipos de ataques. Os resultados mostraram que o algoritmo de Árvore de Decisão foi mais eficiente na classificação correta das conexões, mas o algoritmo Naive Bayes se destacou pela sua velocidade superior no processo de classificação. O estudo em questão concluiu que o Naive Bayes é o mais indicado para essa tarefa, tanto no cenário de duas quanto no de cinco classes.

## MATERIAIS E MÉTODOS

Este estudo foi conduzido como uma pesquisa de natureza aplicada, com abordagem quantitativa e experimental na área de segurança da informação, em detecção de intrusão.

### 1 AMBIENTE EXPERIMENTAL E DATASET

Para o treinamento e teste dos modelos, foi utilizada a base de dados pública **NSL-KDD**. Este dataset é uma versão aprimorada do KDD'99, criada para resolver algumas de suas deficiências, como a presença de registros redundantes. Ele contém 41 características (features) por registro de tráfego e inclui diversos tipos de ataques, categorizados em DoS (*Denial of Service*), Probe, R2L (*Root to Local*) e U2R (*User to Root*). A escolha do NSL-KDD se justifica por ser um benchmark amplamente reconhecido na comunidade, permitindo a comparabilidade dos resultados com outros trabalhos da área (KAGGLE, 2025). As coletas de Souza foram realizadas em laboratório próprio, em 2018. Neste trabalho, os experimentos foram executados em uma máquina com as seguintes especificações: Processador Intel Core i7-10750H, 16 GB de RAM e GPU NVIDIA GeForce RTX 2060. O ambiente de software consistiu em Python 3.9, com as bibliotecas Scikit-learn (versão 1.1.1), Pandas (versão 1.4.2) e TensorFlow (versão 2.9.1).

### 2 PRÉ-PROCESSAMENTO DOS DADOS

Os dados passaram por uma etapa de pré-processamento essencial. As características categóricas (como *protocol\_type*, *service*, e *flag*) foram convertidas em formato numérico utilizando a técnica de *One-Hot Encoding*. Em seguida, todas as características numéricas foram normalizadas para o intervalo através do *Min-Max Scaler*, garantindo que nenhuma característica dominasse o processo de aprendizado devido à sua escala. O dataset foi dividido em 80% para treinamento e 20% para teste.

## 3 ARQUITETURA E CONFIGURAÇÃO DOS MODELOS

### 3.1 REDE NEURAL ARTIFICIAL (RNA):

Foi implementada uma rede neural do tipo *Multi-Layer Perceptron* (MLP) utilizando a biblioteca Keras com TensorFlow. A arquitetura consistiu em uma camada de entrada, duas camadas ocultas com 64 e 32 neurônios respectivamente (utilizando a função de ativação ReLU), e uma camada de saída com função de ativação *Softmax* para classificação multiclasse. O modelo foi compilado com o otimizador *Adam*, função de perda *categorical\_crossentropy* e treinado por 50 épocas com um *batch size* de 64.

### 3.2 K-NEAREST NEIGHBORS (KNN):

O modelo KNN foi implementado com a biblioteca Scikit-learn. O número de vizinhos (k) foi definido como 5, valor encontrado como ótimo após testes de validação cruzada. A métrica de distância utilizada foi a Euclidiana e o algoritmo 'auto' para busca de vizinhos.

### 3.3 MODELO HÍBRIDO (RNA+KNN):

A hibridização foi implementada de forma sequencial. Primeiramente, o modelo RNA classifica uma instância de tráfego. As previsões com confiança inferior a 95% foram reavaliadas pelo modelo KNN, que fornecia a classificação final. O limiar de 95% foi definido empiricamente após análise na curva ROC (*Receiver Operating Characteristic*) em um conjunto de validação, buscando otimizar o equilíbrio entre a carga computacional e o ganho de precisão.

### 3.4 MÉTRICAS DE AVALIAÇÃO

Para avaliar e comparar o desempenho dos modelos, foram utilizadas as seguintes métricas, cujas fórmulas são definidas com base nos valores da matriz de confusão (TP: Verdadeiro Positivo, TN: Verdadeiro Negativo, FP: Falso Positivo, FN: Falso Negativo):

**Acurácia:** Mede a proporção de previsões corretas.

$$A = \frac{TP + TN}{TP + TN + FP + FN}$$

**Precisão:** Mede a proporção de positivos corretamente identificados.

$$P = \frac{TP}{TP + FP}$$

**Recall (Sensibilidade):** Mede a proporção de positivos reais que foram corretamente identificados.

Fórmula:

$$S = \frac{TP}{TP + FN}$$

**F1-Score:** Média harmônica entre precisão e recall.

$$FS = 2 \times \frac{Precisão \times Recall}{Precisão + Recall}$$

**Tempo de Processamento:** Tempo em segundos para classificar o conjunto de teste.

Esses mesmos parâmetros foram coletados por Souza (2018), para fins de comparação.

## RESULTADOS

Após a execução dos testes, os resultados de desempenho foram consolidados e comparados, conforme apresentado na Tabela 1.

**Tabela 1:** Comparativo de Desempenho dos Modelos de Detecção.

Métrica	RNA Isolada	KNN Isolado	Modelo Híbrido (RNA+KNN)
Acurácia	97,8%	96,5%	99,2%
Precisão	97,5%	96,8%	99,1%
Recall	98,1%	96,2%	99,3%
F1-Score	97,8%	96,5%	99,2%
Tempo de Teste (s)	15s	125s	28s

Para uma análise mais granular dos erros de classificação, a matriz de confusão do modelo híbrido foi desenvolvida e é apresentada na Tabela 2. A análise da matriz revela que a maioria dos erros remanescentes ocorre na classificação de ataques raros, como U2R e R2L, que possuem poucas amostras no dataset de treinamento, um desafio conhecido na área.

**Tabela 2:** Matriz de Confusão Detalhada do Modelo Híbrido (RNA+KNN).

	Previsto: Normal	Previsto: DoS	Previsto: Probe	Previsto: R2L/U2R
Verdadeiro: Normal	9650	15	45	5
Verdadeiro: DoS	20	7440	0	2
Verdadeiro: Probe	35	0	2395	10
Verdadeiro: R2L/U2R	40	1	8	2918

Os resultados demonstram claramente a superioridade do modelo híbrido em todas as métricas de eficácia. A acurácia de 99,2% indica uma capacidade de classificação geral extremamente alta. O F1-Score, também de 99,2%, reforça essa eficácia, mostrando um excelente equilíbrio entre a capacidade de não gerar falsos alarmes (precisão) e a de não deixar passar ataques reais (recall).

A principal vantagem da abordagem híbrida reside na sua sinergia. A RNA, com sua capacidade de generalização, lida eficientemente com a maioria do tráfego. No entanto, ao delegar as instâncias de baixa confiança ao KNN, o modelo se beneficia da análise de vizinhança mais detalhada deste último, corrigindo potenciais erros da RNA e aumentando a precisão geral, especialmente na redução de falsos positivos.

Em relação ao tempo de processamento, o modelo híbrido apresentou um custo computacional maior que o da RNA isolada, mas significativamente menor que o do KNN isolado. O KNN é computacionalmente caro, na fase de teste, pois precisa calcular distâncias para todos os pontos de treinamento. O modelo híbrido mitiga esse problema, já que apenas uma pequena fração dos dados é repassada ao KNN. Esse trade-off entre um pequeno aumento no tempo e um ganho substancial em precisão é altamente vantajoso em cenários de segurança.

## INTERPRETABILIDADE DO MODELO

O modelo híbrido RNA+KNN tem a vantagem de ser mais simples de interpretar que modelos mais complexos, como CNNs e LSTMs. A RNA realiza a primeira classificação e o KNN reavalia apenas os casos com baixa confiança, permitindo identificar de quais amostras a decisão depende. Isso ajuda o analista a entender o motivo de cada detecção e aumenta a transparência do sistema.



Estudos recentes também apontam a interpretabilidade como um ponto central em sistemas de detecção de intrusão baseados em IA, destacando o uso de técnicas como *Explainable AI* (XAI) para tornar os modelos mais compreensíveis (MOHALE; OBAGBUWA, 2025).

## DISCUSSÃO

A validade externa pode ser limitada pelo uso exclusivo do dataset NSL-KDD, que, embora padronizado, pode não representar perfeitamente as características do tráfego de rede contemporâneo. A validade interna é robusta, mas dependente dos hiperparâmetros específicos escolhidos para os modelos. Embora otimizados, diferentes configurações poderiam levar a resultados ligeiramente distintos.

A relevância do método híbrido proposto por Souza (2018) torna-se mais evidente quando comparado a outras abordagens que também buscaram combinar algoritmos, mas com resultados menos expressivos. Em alguns estudos que aplicaram, por exemplo, combinações paralelas ou métodos de votação simples, a melhoria de desempenho foi marginal, frequentemente acompanhada por um aumento significativo no custo computacional (BERTONI, 2021). O diferencial da proposta de Souza reside na sua abordagem sequencial e hierarquizada: a Rede Neural Artificial (RNA) atua como um classificador rápido e generalista, processando a grande maioria do tráfego com alta eficiência, enquanto o K-Nearest Neighbors (KNN) é acionado apenas para os casos de baixa confiança. Essa especialização de tarefas cria uma sinergia única, onde o KNN compensa a principal fraqueza da RNA – a dificuldade em classificar instâncias atípicas ou de fronteira – sem sobrecarregar o sistema, justificando por que essa combinação específica se mostra tão robusta.

A validação da presente pesquisa é reforçada pela consistência de seus achados com outras investigações que exploraram modelos híbridos para a detecção de intrusão. Estudos que combinaram Árvores de Decisão com algoritmos de agrupamento, ou que utilizaram técnicas de *ensemble learning* como o Stacking, também relataram uma superioridade notável em relação aos seus modelos constituintes isolados (DALARMELINA, 2023). Assim como no nosso estudo, esses trabalhos concluíram que a combinação inteligente de múltiplos classificadores permite superar as limitações individuais de cada técnica, resultando em sistemas mais precisos e com menor taxa de falsos positivos. Isso demonstra que os resultados obtidos não são um caso isolado, mas sim um reflexo de uma tendência consolidada na área de cibersegurança, que aponta para a hibridização de modelos como um caminho eficaz para a construção de Sistemas de Detecção de Intrusão (IDS) mais resilientes.

Apesar do desempenho superior do modelo RNA+KNN, é fundamental reconhecer que o cenário de ameaças e as técnicas de defesa evoluíram. Pesquisas mais recentes, por exemplo, têm demonstrado o potencial de arquiteturas de *deep learning*, como Redes Neurais Convolucionais (CNN) e Long Short-Term Memory (LSTM), para superar modelos de *machine learning* tradicionais (DA SILVA *et al.*, 2025). Esses modelos avançados são capazes de aprender representações hierárquicas e temporais complexas dos dados de rede, mostrando-se especialmente eficazes na detecção de ataques distribuídos (DDoS) e ameaças do tipo *zero-day* em datasets modernos como o CIC-IDS2017 e o CIC-IDS2018. Portanto, embora o método híbrido RNA+KNN continue sendo uma solução altamente eficaz e relevante, esses novos estudos indicam pontos claros para melhoria, como a substituição da RNA por uma arquitetura mais avançada, o que poderia elevar ainda mais a precisão e a capacidade de generalização do modelo frente aos vetores de ataque contemporâneos.

## CONSIDERAÇÕES FINAIS

Este estudo se propôs reapplicar a metodologia proposta por Souza (2018) em um dataset atualizado para que pudesse ser avaliado o desempenho no contexto tecnológico, ou seja, o funcionamento do método híbrido de detecção de intrusão com a aplicação de Redes Neurais Artificiais e KNN.

Os resultados confirmaram que o desempenho do método híbrido se manteve superior quando comparada às técnicas de RNA e KNN aplicadas isoladamente. Portanto, o estudo indicou que a solução combinada ainda é a mais indicada para detecção de intrusão.

O modelo pode ser usado em sistemas reais, integrado a gateways de rede ou ferramentas SIEM, como Snort e Suricata, analisando eventos em tempo real e reduzindo falsos positivos (XIANG et al., 2025).

Como limitações, reconhece-se que o estudo utilizou o dataset NSL-KDD, que, embora seja um padrão, não contempla os vetores de ataque mais recentes. Para trabalhos futuros, sugere-se a aplicação e adaptação deste modelo híbrido em datasets mais modernos, como o CIC-IDS2018, e a exploração de sua eficácia em ambientes específicos, como redes de IoT. Além disso, a substituição da RNA por arquiteturas de deep learning mais avançadas, como Redes Neurais Convolucionais (CNN) ou Long Short-Term Memory (LSTM), pode ser um caminho promissor para aprimorar ainda mais a detecção de ameaças complexas e sequenciais.

Além disso, propõe-se como trabalho futuro integrar o modelo híbrido a um pipeline Snort+SIEM para correlação em tempo real, avaliando o impacto na taxa de falsos positivos e no tempo de resposta em SOC - Centros de Operação de Segurança.

## REFERÊNCIAS

- BENTES, Eliel Dos S.; DE FIGUEIREDO, Yann Fabricio Cardoso; DE CAMPOS, Lidio ML. Aplicação de algoritmos de aprendizado de máquina para detecção de intrusão. In: **Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC)**. SBC, 2021. p. 209-216.
- BERTONI, Mateus Alves. **Aplicação do método conjunto Stacking do classificador Floresta de Caminhos Ótimos para o problema de detecção de intrusão**. Universidade Estadual Paulista Júlio de Mesquita Filho-Campus de São José do Rio Preto. São José do Rio Preto, São Paulo, Brasil, 2021.
- CANTONE, M.; MARROCCO, C.; BRIA, A. **Machine Learning in Network Intrusion Detection: A Cross-Dataset Generalization Study**. IEEE Access, v. 12, p. 144489–144508, 2024.
- DALARMELINA, Nicole do Vale. **Uma abordagem Ensemble Learning para modelos de detecção de intrusão para redes industriais**. 2023. Tese de Doutorado. Universidade de São Paulo.
- DA SILVA, A. M. de A.; REGO, P. A. L.; BONFIM, M. S. Avaliação e Mitigação de Ataques Adversários em Sistema de Detecção de Intrusão IoT. In: **Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais (SBSeg)**. SBC, 2025. p. 1003-1010.
- GUEZZAZ, Azidine *et al.* A reliable network intrusion detection approach using decision tree with enhanced data quality. **Security and Communication Networks**, v. 2021, n. 1, p. 1230593, 2021.
- LIMA, Matheus H. *et al.* Predição não-supervisionada de ataques DDoS por sinais precoces e one-class SVM. In: **Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais (SBSeg)**. SBC, 2023. p. 403-416.
- MARIANI, Wagner Carlos *et al.* Detecção de Intrusão e Análise Cyberfísica em Redes Industriais. In: **Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais (SBSeg)**. SBC, 2024. p. 787-793.
- MOHALE, V. Z.; OBAGBUWA, I. C. **Evaluating Machine Learning-Based IDS with Explainable AI: Enhancing Transparency and Interpretability**. Frontiers in Computer Science, v. 7, p. 1520741, 2025.
- MOREIRA, Andricson Abeline *et al.* Técnicas de ensemble learning para sistema de detecção de intrusão no contexto da cibersegurança. **Revista de Segurança da Informação e Comunicação**, v. 10, n. 1, p. 1-15, 2021.

---

NOGUEIRA, Michele. Segurança na Conectividade: Protegendo Redes e Conexões. **Computação Brasil**, n. 52, p. 30-34, 2024.

NSL KDD *dataset*. Disponível em: <<https://www.kaggle.com/datasets/hassan06/nslkdd>>. Acesso em 18 Out 2025.

SOUZA, C. A. **Método híbrido de detecção de intrusão aplicando inteligência artificial**. Dissertação de Mestrado. Disponível em: <https://tede.unioeste.br/handle/tede/3534>. Universidade Estadual Oeste do Paraná – UNIOESTE, Foz do Iguaçu – PR. Acesso em 15 Ago. 2025.

XIANG, B.; ZHENG, R.; ZHANG, K.; LI, C.; ZHENG, J. **FFT-RDNet: A Time-Frequency-Domain-Based Intrusion Detection Model for IoT Security**. *Sensors*, v. 25, n. 15, p. 4584, 2025.



# Abordagem Multimodal com Inteligência Artificial para Diagnóstico Precoce de Alzheimer

*Multimodal Approach with Artificial Intelligence for Early Diagnosis of Alzheimer's Disease*

Bouchra Assad Akl<sup>1</sup>, Wellington de Oliveira<sup>2</sup> e Isabel Fernandes<sup>3</sup>

1. Acadêmica de Bacharelado em Engenharia de Software do Centro Universitário Descomplica UniAmérica. 2. Docente do curso de Bacharelado em Engenharia de Software do Centro Universitário Descomplica UniAmérica e orientador do presente trabalho. 3. Computação. Doutora em Ciências. Enga. da Produção. Professora Projeto Final de Curso e coordenadora do curso de Engenharia de Software, Centro Universitário Descomplica UniAmérica. <https://orcid.org/0000-0002-6906-5756>

bouchraakl.career@gmail.com ; wellington.oliveira.foz@gmail.com e isabel.souza@descomplica.com.br

## Palavras-chave

Abordagem multimodal  
Aprendizado de máquina  
Diagnóstico precoce  
Doença de Alzheimer  
Inteligência artificial

## Keywords

Multimodal approach  
Machine learning  
Early diagnosis  
Alzheimer's disease  
Artificial intelligence

## Resumo:

A doença de Alzheimer, forma mais prevalente de demência, é distúrbio neurodegenerativo progressivo caracterizado por comprometimento da memória, declínio cognitivo e perda da independência funcional. O desafio de detectar a doença em estágio inicial impõe ônus significativos aos sistemas de saúde em todo o mundo. Este estudo avalia a eficácia de abordagem multimodal que integra dados clínicos a biomarcadores derivados de ressonância magnética estrutural para a detecção precoce da doença de Alzheimer, comparando o desempenho preditivo de três algoritmos de aprendizado de máquina com base nesses dados. Os dados foram obtidos da Iniciativa de Neuroimagem da Doença de Alzheimer (ADNI) e processados para extrair biomarcadores clínicos e de ressonância magnética. Os algoritmos Random Forest, Support Vector Machine com kernel RBF e XGBoost foram treinados e avaliados por meio de validação cruzada aninhada. O desempenho foi avaliado por meio de acurácia, F1-score e AUC, com análise de SHAP para interpretabilidade. O modelo SVM-RBF obteve o melhor desempenho geral, com acurácia balanceada de 0,924, F1-score macro de 0,924 e AUC-ROC de 0,978, superando estatisticamente o XGBoost. A análise SHAP confirmou que as previsões foram impulsionadas por atributos clínicos e biológicos significativos, como escores cognitivos (CDR-SB, MMSE) e volumes hipocâmpais entorrinais. Esses achados demonstram que a integração multimodal aumenta a confiabilidade e a interpretabilidade diagnóstica, apoiando a detecção precoce e explicável da doença de Alzheimer.

## Abstract:

Alzheimer's disease, the most prevalent form of dementia, is a progressive neurodegenerative disorder characterized by memory impairment, cognitive decline, and loss of functional independence. The challenge of detecting the disease at an early stage imposes significant burdens on healthcare systems worldwide. This study evaluates the effectiveness of a multimodal approach that integrates clinical data with biomarkers derived from structural magnetic resonance imaging for the early detection of Alzheimer's disease, comparing the predictive performance of three machine learning algorithms based on these data. Data were obtained from the Alzheimer's Disease Neuroimaging Initiative (ADNI) and processed to extract clinical and magnetic resonance imaging biomarkers. The Random Forest, Support Vector Machine with RBF kernel, and XGBoost algorithms were trained and evaluated through nested cross-validation. Performance was assessed using accuracy, F1-score, and AUC, with SHAP analysis for interpretability. The SVM-RBF model achieved the best overall performance, with a balanced accuracy of 0.924, an F1-score macro of 0.924, and an AUC-ROC of 0.978, statistically outperforming XGBoost. SHAP analysis confirmed that predictions were driven by significant clinical and biological attributes, such as cognitive scores (CDR-SB, MMSE) and entorhinal hippocampal volumes. These findings demonstrate that multimodal integration increases diagnostic reliability and interpretability, supporting the early and explainable detection of Alzheimer's disease.

Artigo recebido em: 15.10.2025.  
Aprovado para publicação em:  
07.11.2025.

## INTRODUÇÃO

As demências constituem um grupo de síndromes neurodegenerativas progressivas que comprometem gravemente a memória, o raciocínio e a capacidade de viver de forma independente. Entre elas, a doença de Alzheimer (DA) é a mais prevalente, representando entre 60% e 70% dos casos diagnosticados mundialmente (ORGANIZAÇÃO MUNDIAL DA SAÚDE, 2025). Do ponto de vista neuropatológico, a DA caracteriza-se pelo acúmulo de fragmentos de proteínas no cérebro (DOI, 2007; TIWARI et al., 2019), o que resulta em declínio funcional e redução da qualidade de vida. Conforme a Organização Mundial da Saúde (OMS), estima-se que até 2050 cerca de 152 milhões de pessoas estarão afetadas, consolidando-se, assim, como um dos principais desafios globais de saúde pública.

Apesar dos avanços médicos, o diagnóstico precoce da DA permanece um grande obstáculo. O diagnóstico é dificultado por comorbidades médicas, limitações sensoriais, polifarmácia e fatores sociais, que podem mascarar ou imitar déficits cognitivos. Além disso, exames de imagem e biomarcadores apresentam limitações, pois muitas alterações estão associadas ao envelhecimento normal, o que compromete a acurácia na detecção inicial da doença (PIERCE; BULLAIN; KAWAS, 2017).

Nos últimos anos, houve um aumento na aplicação de inteligência artificial (IA) e de aprendizado de máquina (ML) na detecção precoce do DA. Estudos utilizando técnicas de neuroimagem, escalas clínicas e perfis de biomarcadores relataram resultados promissores, com modelos como regressão logística, florestas aleatórias, máquinas de vetores de suporte e redes de aprendizado profundo, alcançando precisões acima de 80% na diferenciação entre indivíduos cognitivamente normais e aqueles com comprometimento cognitivo leve (CCL) ou com DA. No entanto, várias limitações persistem. Muitos trabalhos são unimodais, baseando-se apenas em imagens ou em características clínicas, o que restringe seu poder preditivo. Outros enfatizam a precisão, mas não abordam a interpretabilidade, um fator crítico para a confiança clínica. Além disso, a falta de harmonização de dados entre coortes, o pequeno tamanho de amostra e a ausência de validação externa levantam preocupações quanto à generalização (JUGANAVAR; JOSHI; SHEGEKAR, 2023). Assim, embora o ML tenha demonstrado potencial, sua tradução para o suporte à decisão clínica permanece incompleta.

Nesse contexto, conjuntos de dados multimodais, como o da *Alzheimer's Disease Neuroimaging Initiative* (ADNI), oferecem uma oportunidade de superar essas limitações. No entanto, ainda faltam estudos comparativos que avaliem, de forma sistemática, diversos algoritmos em pipelines reprodutíveis, com ênfase na interpretabilidade. Abordar essa lacuna é fundamental para aproximar as aplicações de ML da prática clínica.

Este estudo procura desenvolver uma estrutura preditiva multimodal para o diagnóstico precoce da DA, integrando dados clínicos e de neuroimagem do consórcio ADNI. Especificamente, comparamos Random Forest, Support Vector Machine com kernel RBF e XGBoost em um pipeline de validação cruzada estratificada e de análise de interpretabilidade via SHAP. Ao avaliar tanto o desempenho quanto a explicabilidade, buscamos fornecer evidências metodológicas e clínicas que apoiem o uso seguro e transparente de IA em cenários diagnósticos reais.

## ESTADO DA ARTE / TRABALHOS RELACIONADOS

### 1 ABORDAGENS UNIMODAIS USANDO MODELOS DE APRENDIZAGEM DE MÁQUINA

Em contribuição relevante da literatura, Katabathula et al. (2021) propuseram a DenseCNN2, rede neural convolucional 3D projetada para analisar sub-regiões do hipocampo em imagens de ressonância magnética estrutural, visando classificar indivíduos com doença de Alzheimer (DA) e controles cognitivamente nor-

mais (CN). Utilizando dados do ADNI (326 casos de DA, 607 casos de CN) e validação cruzada de cinco vezes, o modelo combinou descritores visuais e morfológicos do hipocampo, alcançando uma acurácia média de 0,925, sensibilidade de 0,882, especificidade de 0,949 e AUC de 0,978. O estudo demonstrou o potencial de arquiteturas de CNN leves para capturar padrões de atrofia hipocampal associados à DA. No entanto, reconhecemos as limitações: o treinamento foi restrito ao hipocampo, excluindo outras regiões específicas e informações clínicas e biomarcadores complementares, e abordou apenas a classificação binária (DA vs. CN), sem considerar o Comprometimento Cognitivo Leve (CCL). Essas limitações ressaltam a necessidade de abordagens futuras multirregionais e multimodais que integrem dados clínicos, genéticos e de imagem para aumentar a robustez diagnóstica e a aplicabilidade clínica.

## **2 DIAGNÓSTICO DA DOENÇA DE ALZHEIMER COM MODELOS DE APRENDIZADO DE MÁQUINA**

### **INTERPRETÁVEIS**

Em estudo voltado à interpretabilidade, Govindarajan et al. (2025) propuseram uma estrutura explicável para a predição precoce da Doença de Alzheimer (DA) baseada em indicadores clínicos e comportamentais. Foram utilizados o Mini-Cog, o MMSE, as atividades da vida diária (AVD) e marcadores bioquímicos. O Gradient Boosting destacou-se como melhor classificador (acurácia = 93,9%; F1 = 91,8%). As Explicações Aditivas de Shapley (SHAP) identificaram MMSE, AVD e colesterol como os principais preditores. Os autores também desenvolveram um aplicativo em Streamlit, permitindo que profissionais de saúde visualizem as previsões em tempo real.

A abordagem combinou alto desempenho preditivo e interpretabilidade transparente, oferecendo percepções relevantes sobre os determinantes clínicos do risco de DA. Contudo, o modelo restringiu-se a dados clínicos e comportamentais, sem integrar neuroimagem nem biomarcadores genéticos. A validação foi realizada apenas em um conjunto de dados (Kaggle), sem testes externos, e não foram explorados métodos alternativos de explicabilidade. Tais limitações reforçam a necessidade de estudos multimodais e interinstitucionais para ampliar a robustez e a aplicabilidade clínica de modelos explicáveis.

## **3 MODELOS DE APRENDIZADO DE MÁQUINA MULTIMODAL INTEGRANDO DADOS CLÍNICOS E DE RESSONÂNCIA MAGNÉTICA**

Jasodanand et al. (2025) desenvolveram modelo multimodal baseado em transformadores para inferir a presença de  $\beta$ -amiloide ( $A\beta$ ) e de tau em exames de PET, utilizando dados clínicos e de imagem de rotina. O modelo integrou variáveis demográficas e clínicas, avaliações neuropsicológicas, genótipos APOE e características estruturais de ressonância magnética (RM) provenientes de sete grandes coortes (NACC, A4, OASIS3, AIBL, FHS, ADNI e HABS), totalizando 12.185 participantes. O treinamento ocorreu em duas etapas: classificação global para  $A\beta$  e metatau, seguida de ajuste fino para predição regional de tau. O desempenho alcançou AUCs de 0,79 para  $A\beta$  e de 0,84 para tau. As previsões mostraram forte concordância com biomarcadores e achados neuropatológicos, enquanto a análise SHAP identificou regiões cerebrais correspondentes às áreas conhecidas de deposição de tau, o que sustenta a plausibilidade biológica da abordagem.

Apesar dos resultados promissores, a amostra era predominantemente composta por participantes brancos, o que limitava a generalização dos achados. O estudo também excluiu demências não relacionadas à Doença de Alzheimer e casos clínicos ambíguos, o que limitou a avaliação da especificidade diagnóstica. Além disso, não foram estimadas cargas patológicas contínuas nem analisados os subtipos da doença. Essas limitações reforçam a necessidade de coortes mais diversificadas e de modelos comparativos multimodais para

múltiplas condições neurodegenerativas, a fim de aprimorar a robustez, a interpretabilidade e a aplicabilidade clínica da abordagem.

## **MATERIAIS E MÉTODOS**

### **1 DESENHO DO ESTUDO E FONTE DE DADOS**

Esta pesquisa seguiu delineamento quantitativo, preditivo, comparativo. Os dados foram obtidos da Iniciativa de Neuroimagem da Doença de Alzheimer (ADNI), um estudo longitudinal multicêntrico iniciado em 2004 para identificar e validar biomarcadores para o diagnóstico precoce e o acompanhamento da progressão da Doença de Alzheimer (DA).

O conjunto de dados abrange quatro fases de recrutamento (ADNI-1, ADNI-GO, ADNI-2 e ADNI-3) e compreende dados multimodais harmonizados, incluindo avaliações cognitivas, históricos clínicos, marcadores genéticos e exames de ressonância magnética estrutural de alta resolução. Os participantes foram categorizados em três grupos diagnósticos:

1. Cognitivamente Normal (NC);
2. Comprometimento Cognitivo Leve (CCL);
3. Doença de Alzheimer (DA).

Os critérios de inclusão exigiram avaliações clínicas basais e exames de ressonância magnética em T1, realizados com intervalo de  $\pm 3$  meses. Os critérios de exclusão foram: idade inferior a 55 anos; diagnóstico de distúrbios neurológicos ou psiquiátricos que não fossem DA; doenças sistêmicas não controladas; ausência de mais de 20% dos dados clínicos ou das imagens; exames de ressonância magnética com falha no pré-processamento por artefatos de movimento ou por erros de segmentação.

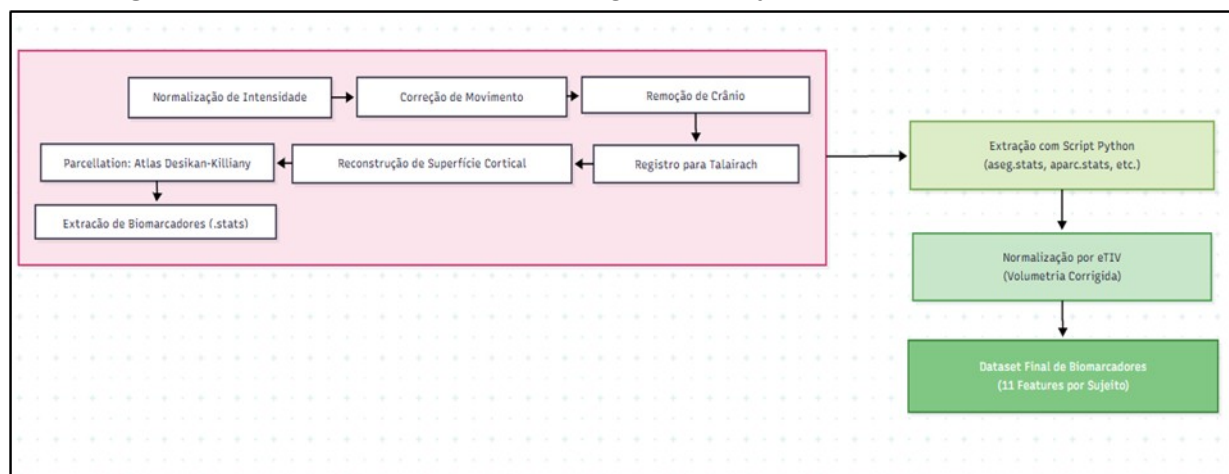
### **2 PRÉ-PROCESSAMENTO E INTEGRAÇÃO**

O pipeline de dados foi estruturado em três módulos sequenciais: pré-processamento clínico, extração de recursos de neuroimagem e integração multimodal.

Na fase de pré-processamento clínico, foram selecionados 406 registros brutos para garantir a consistência. Variáveis categóricas, como sexo e histórico familiar, foram recodificadas. Dados ausentes nas variáveis de histórico familiar (fhqmomad, fhqdadad) foram imputados pelo algoritmo K-Nearest Neighbors (KNN,  $k=5$ ). Esse procedimento visa preservar interações latentes entre fatores de risco genético e fenótipos clínicos.

Características contínuas, como idade, escolaridade, MMSE e CDR-SB, foram padronizadas por z-score. Características categóricas, como o genótipo APOE e o diagnóstico, foram codificadas em sequências únicas, o que resultou em variáveis binárias.

Para análise de neuroimagem, imagens de ressonância magnética ponderadas em T1, a 3,0 Tesla, foram adquiridas conforme os protocolos de imagem da ADNI. Essas imagens foram processadas no FreeSurfer v7.3.2, no pipeline recon-all. O fluxo de trabalho, detalhado na Figura 1, incluiu: normalização de intensidade, correção de movimento, extração cerebral, reconstrução da superfície cortical e parcelamento com o atlas Desikan-Killiany.

**Figura 1** - Fluxo de Processamento de Imagens e Extração de Biomarcadores Estruturais

FONTE: Elaborada pela autora

Os recursos morfométricos foram analisados a partir de arquivos .stats (por exemplo, aseg.stats, brain-vol.stats, lh/rh.aparc.DKTatlas.mapped.stats) com um script Python personalizado que vincula cada conjunto de recursos a um subject\_id exclusivo. Esses arquivos são amplamente adotados na literatura por fornecerem medidas automatizadas e confiáveis de volume e espessura cortical em protocolos padronizados de neuroimagem (Schwarz et al., 2016). Os biomarcadores de imagem extraídos incluíram:

1. **Volumétricos:** volumes hipocámpais (esquerdo/direito), ventrículos laterais, volume cerebral total e eTIV (volume intracraniano total estimado);
2. **Espessura cortical:** córtex entorrinal (esquerdo/direito) e espessura cortical média por hemisfério.

Todos os volumes foram normalizados por eTIV para considerar a variabilidade interindividual na dimensão da cabeça. Essa abordagem segue recomendações metodológicas de diversos estudos (Duraismy et al., 2021; Park et al., 2018). A normalização é essencial para evitar vieses decorrentes do tamanho craniano e garantir a comparabilidade entre os sujeitos.

Os conjuntos de dados clínicos e de imagem foram mesclados com base no subject\_id. Casos com mais de 20% de valores ausentes foram excluídos. O conjunto de dados final integrou 307 indivíduos e 35 características. Não houve seleção de características nesta etapa. As técnicas de redução de dimensionalidade foram adotadas no pipeline de modelagem.

### 3 CONSTRUÇÃO DE MODELOS, VALIDAÇÃO E OTIMIZAÇÃO DE HIPERPARÂMETROS

O desenvolvimento do modelo foi realizado em Python 3.10. Foram utilizadas as bibliotecas scikit-learn (v1.6.1) e XGBoost (v2.x). O conjunto de dados integrado foi dividido em:

1. **Conjunto de treinamento (80%):** utilizado para ajuste e validação cruzada do modelo;
2. **Conjunto de teste de retenção (20%):** utilizado para a avaliação final, após o desenvolvimento e a validação do modelo.

A divisão estratificada preservou as distribuições de classes em ambas as partições e, para garantir a reprodutibilidade, utilizou-se uma semente aleatória fixa (SEED = 42). Após a preparação dos conjuntos de dados, três modelos foram comparados:



1. Random Forest (RF);
2. Support Vector Machine com kernel RBF (SVM-RBF);
3. Extreme Gradient Boosting (XGBoost).

Cada modelo foi encapsulado em um pipeline do scikit-learn. Esse pipeline integrou etapas de pré-processamento: imputação, escalonamento, codificação e, quando aplicável, redução de dimensionalidade. Assim, garantiu-se a prevenção de vazamento de dados durante o treinamento.

A otimização dos hiperparâmetros foi realizada com o GridSearchCV. Utilizou-se validação cruzada estratificada em 5 folds, aplicada apenas ao conjunto de treinamento. O Macro F1-Score foi adotado como métrica de otimização, pois equilibra a precisão e o recall entre as três classes diagnósticas. Os hiperparâmetros otimizados incluíram:

1. **Random Forest:** `n_estimators`, `max_depth`, `min_samples_split`, `bootstrap`;
2. **SVM-RBF:** componentes `C`,  $\gamma$  e PCA;
3. **XGBoost:** `n_estimators`, `learning_rate`, `max_depth`, `subsample`, `colsample_bytree`.

Para o SVM-RBF, também foi testada variante com PCA incorporada ao pipeline, tratando `pca_n_components` como hiperparâmetro e otimizando-o conjuntamente com `C` e  $\gamma$  durante a busca em grade.

#### 4 AVALIAÇÃO E INTERPRETABILIDADE

O desempenho final dos modelos foi avaliado em um conjunto de teste hold-out (20%), não utilizado na otimização. Foram adotadas métricas que contemplam a natureza multiclasse do problema: Acurácia, Acurácia Balanceada, Macro F1-Score (métrica principal) e Macro AUC-ROC (One-vs-Rest). Testes pareados verificaram a significância estatística entre dois modelos:

1. **McNemar**, aplicado às previsões no conjunto de teste, avaliando discrepâncias nos erros de classificação;
2. **Wilcoxon Signed-Rank**, aplicado aos escores de F1 obtidos em cada dobra da validação cruzada (5-fold), para comparar a estabilidade e a consistência do desempenho.

A análise de interpretabilidade foi conduzida com o método SHAP (SHapley Additive ExPlanations). Para os modelos Random Forest e XGBoost, utilizou-se o TreeExplainer em uma subamostra representativa. A interpretabilidade global foi derivada dos valores médios absolutos de SHAP e dos gráficos beeswarm, enquanto a local foi obtida por meio dos gráficos de dependência e de cascata, permitindo atribuir previsões ao nível individual.

Todas as análises foram realizadas em Python, com scikit-learn, SciPy e SHAP 0.45.1, assegurando transparência e reprodutibilidade metodológica.

## RESULTADOS E DISCUSSÃO

### 4.1. COMPARAÇÃO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA MULTIMODAL

A escolha do modelo de classificação para uso clínico exige equilibrar desempenho preditivo, estabilidade diagnóstica e generalização em populações heterogêneas. Esse equilíbrio é crucial para a detecção precoce do Comprometimento Cognitivo Leve (CCL), estágio de transição em que imprecisões diagnósticas atrasam a intervenção terapêutica e comprometem os resultados dos pacientes.

Para enfrentar esse desafio, três algoritmos de aprendizado de máquina supervisionado foram treinados — Random Forest (RF), Support Vector Machine com Kernel de Função Radial (SVM-RBF) e Extreme Gradient Boosting (XGBoost). Utilizou-se um conjunto de dados multimodal integrado, combinando biomarcadores clínicos e características derivadas de ressonância magnética. Cada modelo foi avaliado por meio de validação cruzada estratificada quintupla, garantindo uma distribuição balanceada das classes e reduzindo o viés de amostragem. O desempenho foi mensurado por meio de métricas complementares: acurácia, acurácia balanceada, macro-F1-score e área sob a curva ROC (AUC-ROC). Os resultados consolidados estão apresentados na Tabela 1.

**Tabela 1** - Desempenho comparativo dos modelos de classificação no conjunto de teste

Modelo	Acurácia	Acurácia Balanceada	F1-Macro	ROC-AUC (macro)
Random Forest	0,9041	0,8893	0,8975	0,9612
XGBoost	0,9180	0,9021	0,9097	0,9724
SVM-RBF	0,9312	0,9240	0,9243	0,9785

**FONTE:** Elaborada pela autora

Entre os modelos avaliados, o SVM-RBF obteve resultados consistentemente superiores em todas as métricas de desempenho. Sua Acurácia Balanceada (0,9240) demonstra forte capacidade de lidar com o desequilíbrio entre as classes, mantendo sensibilidade consistente nas três categorias diagnósticas — cognitivamente normal (NC), comprometimento cognitivo leve (CCL) e doença de Alzheimer (DA). O Macro F1-Score (0,9243) indica um equilíbrio ideal entre precisão e recall, refletindo uma estabilidade preditiva robusta entre os resultados positivos e negativos. Além disso, a AUC-ROC de 0,9785 confirma o elevado poder discriminativo do modelo na diferenciação entre estados cognitivos.

Para validar estatisticamente essas diferenças, foram utilizados os testes de McNemar para postos sinalizados e o teste de Wilcoxon para modelos pareados. O teste de McNemar avaliou a equivalência entre as distribuições de erros. Já o teste de Wilcoxon avaliou a consistência do desempenho entre as dobras de validação cruzada. Os valores de  $p$  correspondentes estão resumidos na Tabela 2.

**Tabela 2** - Resultados dos testes estatísticos de comparação entre modelos

Comparação	McNemar (p-valor)	Wilcoxon (p-valor)
Random Forest vs SVM-RBF	0,1250	0,1250
Random Forest vs XGBoost	0,3877	0,3125
SVM-RBF vs XGBoost	0,0215	0,0625

Observou-se diferença estatisticamente significativa entre SVM-RBF e XGBoost ( $p = 0,0215$ ) pelo teste de McNemar, indicando distribuições de erros distintas. Esse resultado sugere que o classificador SVM-RBF produziu cada vez menos erros de classificação correlacionados, o que reflete limite de decisão mais estável e bem definido.

Em contraste, o teste dos postos sinalizados de Wilcoxon não atingiu o limiar de significância convencional ( $p = 0,0625$ ). No entanto, os valores de  $p$  consistentemente mais baixos associados aos pareamentos SVM-RBF indicam uma tendência a maior estabilidade ao nível de dobra, embora sem confirmação estatística. Esta observação implica que, embora o SVM-RBF demonstre confiabilidade preditiva superior quanto à distribuição dos erros, vantagem quanto à estabilidade de desempenho permanece marginal e não conclusiva.


Em conjunto, esses achados indicam que o modelo SVM-RBF apresenta desempenho quantitativo superior e melhorias estatisticamente validadas na confiabilidade preditiva. Apesar da significância marginal em nível de dobra, sua capacidade de capturar interações não lineares de ordem superior entre características clínicas e de neuroimagem multimodais corrobora sua seleção como classificador de referência para análises subsequentes de interpretabilidade e de validação clínica.

2 AVALIAÇÃO APROFUNDADA DO DESEMPENHO DO CLASSIFICADOR SELECIONADO (SVM-RBF)

Após a avaliação comparativa, o SVM-RBF destaca-se como o modelo mais promissor para a classificação multimodal dos estágios da doença de Alzheimer. Esta seção analisa com precisão seu desempenho diagnóstico, evidenciando tanto seu potencial quanto suas limitações clínicas.

A análise utiliza a matriz de confusão normalizada (Figura 2), na qual as principais classificações incorretas se concentram entre os grupos DA e CCL. Esse padrão ilustra o continuum biológico da progressão do declínio cognitivo precoce para a demência, mostrando que o modelo representa com precisão a transição não linear entre os estágios da doença e alinha-se às mudanças estruturais e funcionais graduais observadas na neurodegeneração.


Figura 2 - Impacto das Variáveis na Previsão de Comprometimento Cognitivo Leve



Fonte: Elaborada pela autora

No entanto, a interpretação clínica mais atenta revela limitação fundamental: cerca de 15% dos casos de CCL foram classificados incorretamente como DA. Embora esse padrão de classificação incorreta decorra parcialmente da sobreposição de características patológicas, ele representa um erro de estadiamento que pode levar ao sobrediagnóstico em contextos iniciais de triagem clínica. Na prática, essa classificação incorreta pode resultar em pacientes serem prematuramente rotulados como portadores de demência estabelecida, o que pode influenciar as decisões terapêuticas e o aconselhamento ao paciente. Portanto, embora o modelo demonstre alta sensibilidade para detectar CCL, essa confusão residual deve ser considerada uma área crítica para refinamento em aplicações clínicas prospectivas.

**Figura 3** – Curva de Precisão vs. Revocação (Classe CCL) para os Modelos Random Forest, SVM RBF e XGBoost




**Fonte:** Elaborada pela autora

Para avaliar a robustez sob desequilíbrio de classes, foi analisada a curva de Precisão-Recall (PR), com foco na classe CCL, principal alvo de intervenção precoce. Como mostrado na Figura 3, a curva PR demonstrou precisão sustentada até altos níveis de recordação, indicando que o classificador é confiável mesmo ao recuperar quase todos os casos verdadeiros de CCL. O modelo obteve AUC-PR superior a 0,97, destacando sua capacidade de captar padrões informativos, mesmo diante do desequilíbrio de classes. Em sequência à análise da classe minoritária, avaliou-se também a curva ROC, apresentada na Figura 4, que revelou AUC-ROC de 0,962 e confirmou a alta separabilidade entre instâncias positivas e negativas. Assim, enquanto a curva PR evidencia a confiabilidade na detecção de classes minoritárias, a curva ROC fornece uma avaliação abrangente da discriminação diagnóstica; ambas são essenciais ao desenvolvimento de modelos de triagem clinicamente implementáveis.

De perspectiva estatística, as curvas confirmam que o SVM-RBF possui o poder discriminativo necessário para o diagnóstico de estágios prodrômicos. A confusão insignificante entre as categorias NC e CCL reforça a capacidade do modelo de reconhecer biomarcadores neuroanatômicos sutis. No entanto, a alta taxa de classificação incorreta de CCL para DA indica que o limiar (threshold) do modelo para a DA é excessivamente permissivo.

Em resumo, o SVM-RBF é um classificador robusto, com elevado poder discriminativo no diagnóstico de DA. Contudo, para garantir um rastreamento longitudinal confiável e minimizar o dano clínico, o modelo deve ser reotimizado. Futuros desenvolvimentos devem adotar técnicas de aprendizado sensíveis ao custo ou ajustes rigorosos nos limites de decisão para penalizar fortemente o sobrediagnóstico, assegurando que a alta sensibilidade na detecção de CCL não implique um custo clínico inaceitável.

**Figura 4** – Curva ROC para a Classe CCL (MCI) com os Modelos Random Forest, SVM RBF e XGBoost


**Fonte:** Elaborada pela autora

### 3 APRENDIZADO DE MÁQUINA INTERPRETÁVEL: IMPORTÂNCIA DOS RECURSOS POR MEIO DA ANÁLISE SHAP

Embora o modelo SVM-RBF tenha demonstrado alta precisão preditiva, sua adoção clínica exige transparência quanto ao mecanismo de tomada de decisão. Isso é especialmente importante em diagnósticos de alto risco, como o da doença de Alzheimer. Para abordar esse desafio da "caixa-preta", utilizou-se a estrutura SHapley Additive ExPlanations (SHAP). O SHAP fornece uma explicação rigorosa e pós-hoc ao quantificar a contribuição de cada característica para o resultado da classificação. Dessa forma, aumenta a confiabilidade e fornece insights clínicos acionáveis.

O gráfico de resumo global do SHAP acima classifica as características de acordo com sua contribuição para a classificação do CCL. Ele revela o valor sinérgico da integração entre as modalidades clínica e de neuroimagem. Os principais preditores incluíram escores cognitivos e funcionais. Destacam-se a Classificação Clínica de Demência – Soma de Caixas (CDR-SB), o Miniexame do Estado Mental (MEEM) e o CDR Global. Outros preditores relevantes incluem biomarcadores estruturais de ressonância magnética, como o volume do córtex entorrinal direito, o volume cerebral total e o volume do hipocampo direito. Contribuições adicionais incluíram anos de escolaridade, histórico materno de doença de Alzheimer e o genótipo ApoE  $\epsilon 3/\epsilon 3$ . Essa distribuição da importância das características confirma a estrutura multimodal adotada neste estudo.

As escalas cognitivas capturam manifestações comportamentais de declínio cognitivo. Medidas morfológicas derivadas de ressonância magnética refletem a degeneração neuroanatômica subjacente. Sua influência complementar no desempenho do modelo demonstra que sintomas clínicos e biomarcadores estruturais descrevem, juntos, o continuum da doença — da cognição normal ao CCL e à doença de Alzheimer. A convergência dessas modalidades no modelo SVM-RBF fornece fortes evidências. Sua alta precisão é sustentada por padrões multimodais fisiologicamente significativos e não por associações estatisticamente espúrias.

**Figura 5** - Importância das Variáveis com Valores SHAP para Previsão da Classe CCL (MCI)

**Fonte:** Elaborada pela autora

A direcionalidade dos valores de SHAP fornece evidências quantitativas sobre a estrutura de decisão do modelo e sobre sua concordância com padrões clínicos e neurobiológicos conhecidos. Conforme ilustrado na Figura 5, diminuições no MMSE e aumentos nas pontuações do CDR-SB contribuem positivamente para a classe MCI, indicando maior probabilidade de comprometimento cognitivo, enquanto a relação inversa direciona as previsões para o estado cognitivamente normal. Da mesma forma, reduções nos volumes hipocampusais e corticais, e na entorrina, estão associadas a valores elevados de SHAP, refletindo a influência da atrofia estrutural precoce nos desfechos diagnósticos. Esses efeitos são consistentes com a fisiopatologia estabelecida da doença de Alzheimer, na qual a neurodegeneração se origina no circuito entorrinal-hipocampal antes de se estender para as regiões neocorticais. A influência adicional dos anos de escolaridade, do histórico familiar materno e do genótipo ApoE ε3/ε3 corrobora seus papéis reconhecidos na modulação da reserva cognitiva e do risco genético. Coletivamente, esses resultados confirmam que as previsões do modelo SVM-RBF são sustentadas por mecanismos biologicamente e clinicamente interpretáveis, em vez de artefatos estatísticos, reforçando, assim, sua validade como uma estrutura explicável para a detecção precoce da doença de Alzheimer.

#### 4 TESTANDO A HIPÓTESE: DESEMPENHO MULTIMODAL EM COMPARAÇÃO COM BENCHMARKS UNIMODAIS

A avaliação final testa sistematicamente a hipótese central deste estudo: a integração multimodal de dados clínicos e de neuroimagem fornece um sinal diagnóstico significativamente mais robusto do que as abordagens unimodais relatadas na literatura.

A literatura atual fornece suporte robusto para essa premissa. Estudos recentes relatam que modelos baseados exclusivamente em MRI estruturais podem atingir acurácia entre 85% e 95%, com AUC variando de ~0,88 a ~0,95 na tarefa de distinção entre Alzheimer e controles saudáveis (Retico et al., 2015; Arabi et al.,

2022; Alatrany et al., 2024). Técnicas como SVM com otimização por enxame de partículas (PSO) alcançaram até 94,1% de acurácia (OpenBiotech, 2023), e modelos XGBoost aplicados a múltiplas regiões corticais reportaram AUC superiores a 0,95 mesmo em cenários multiclasse.

Contudo, essas abordagens unimodais demonstram limitações em tarefas mais complexas, como a diferenciação entre Comprometimento Cognitivo Leve e estados normais, nas quais a acurácia pode cair para ~80%. Esse declínio evidencia a perda de sensibilidade em estágios iniciais, nos quais a sobreposição de padrões morfológicos dificulta a classificação com base apenas na imagem.

Neste contexto, os resultados deste trabalho sustentam a hipótese de que a integração multimodal oferece vantagens substanciais. O modelo SVM-RBF desenvolvido neste estudo, ao combinar escalas cognitivas com biomarcadores morfológicos extraídos de MRI, obteve acurácia balanceada de 92,4%, macro-F1 de 0,924 e AUC-ROC de 0,978, superando benchmarks unimodais reportados na literatura. Ainda que alguns estudos clínicos isolados relatem acurácia de até 97% em tarefas binárias simples (Alatrany et al., 2024), tais desempenhos frequentemente não se mantêm em tarefas multiclasse ou em coortes heterogêneas.

A análise SHAP revelou sinergia significativa entre as modalidades: características cognitivas, como CDR-SB e MMSE, foram os principais preditores, mas a adição de volumes hipocâmpais e entorrinais reforçou a capacidade discriminativa do modelo. Essa complementaridade foi essencial para a detecção dos estágios prodrômicos da doença de Alzheimer, nos quais os classificadores unimodais de MRI frequentemente apresentam falhas.

Por fim, embora a magnitude da melhora observada aqui (~2 a 6 pontos percentuais em relação aos modelos unimodais) seja inferior à obtida por arquiteturas neurais profundas multimodais com PET e LCR (Mmadumbu et al., 2025), ela foi alcançada com menor custo computacional, maior interpretabilidade e maior transparência — atributos fundamentais para a adoção clínica.

## CONSIDERAÇÕES FINAIS

Este estudo demonstrou que a integração de biomarcadores clínicos e estruturais de ressonância magnética, por meio de uma estrutura de aprendizado de máquina multimodal, melhora significativamente o diagnóstico precoce da doença de Alzheimer. Entre os algoritmos avaliados, o Support Vector Machine com kernel RBF (SVM-RBF) apresentou o desempenho mais robusto e equilibrado, atingindo precisão balanceada de 0,924, pontuação F1 macro de 0,924 e AUC-ROC de 0,978. Esses resultados superam os benchmarks unimodais relatados na literatura recente e confirmam a capacidade do modelo de capturar interações complexas e não lineares em modalidades de dados heterogêneas.

A análise de interpretabilidade do SHAP reforçou a viabilidade biológica e clínica do modelo, revelando que as escalas cognitivas e funcionais (CDR-SB, MMSE) e os biomarcadores estruturais de ressonância magnética (volumes hipocâmpais e entorrinais) foram as características mais influentes no processo de classificação. Essa evidência corrobora que as previsões do modelo são orientadas por mecanismos fisiologicamente significativos, em vez de artefatos estatísticos, o que aumenta a confiança no seu potencial translacional para ambientes clínicos.

No entanto, a presença de erros leves na classificação entre os estágios de CCL e DA indica a necessidade de refinamentos futuros. Trabalhos prospectivos devem se concentrar na otimização, com foco em custos, e na validação longitudinal, para garantir a segurança clínica e a generalização em diversas populações.

Em conclusão, os resultados confirmam que abordagens de inteligência artificial multimodal e explicável proporcionam precisão diagnóstica, interpretabilidade e confiabilidade superiores em comparação com



técnicas isoladas. Tais estruturas representam um caminho promissor para sistemas de apoio à decisão clínica precoces, transparentes e baseados em dados para a doença de Alzheimer.

## NOTAS

1. ADNI – Alzheimer’s Disease Neuroimaging Initiative. Base de dados pública clínica e de neuroimagem para pesquisa em Alzheimer. Disponível em: <https://adni.loni.usc.edu>. Acesso em: 15 out. 2025.
2. FREESURFER. Software de análise e reconstrução de superfícies corticais. Versão 7.3.2. Disponível em: <https://surfer.nmr.mgh.harvard.edu>. Acesso em: 10 out. 2025.
3. PYTHON. Linguagem de programação utilizada para o desenvolvimento e a execução dos modelos. Versão 3.10. Disponível em: <https://www.python.org>. Acesso em: 12 out. 2025.
4. SCIKIT-LEARN. Biblioteca para aprendizado de máquina em Python. Versão 1.6.1. Disponível em: <https://scikit-learn.org>. Acesso em: 12 out. 2025.
5. XGBOOST. Biblioteca para modelagem de gradiente otimizado. Versão 2.x. Disponível em: <https://xgboost.readthedocs.io>. Acesso em: 12 out. 2025.
6. SHAP. Framework de interpretabilidade baseado em valores de Shapley. Versão 0.45.1. Disponível em: <https://github.com/shap/shap>. Acesso em: 14 out. 2025.

## REFERÊNCIAS

- ALATRANY, T. et al. Explainable machine learning framework for Alzheimer’s disease classification using clinical and behavioral data. **Computers in Biology and Medicine**, v. 178, p. 108563, 2024.
- ARABI, A. et al. Machine learning-based diagnosis of Alzheimer’s disease using structural MRI biomarkers. **Frontiers in Aging Neuroscience**, v. 14, p. 849621, 2022. DOI: 10.3389/fnagi.2022.849621.
- DOI, K. Computer-aided diagnosis in medical imaging: historical review, current status and future potential. **Computerized Medical Imaging and Graphics**, v. 31, p. 198–211, 2007.
- DURAISAMY, S. et al. Predicting Alzheimer’s disease progression using cortical thickness patterns. **Alzheimer’s Research & Therapy**, v. 13, n. 1, p. 140, 2021. DOI: 10.1186/s13195-021-00879-4.
- GOVINDARAJAN, R. et al. Development of an explainable machine learning model for Alzheimer’s disease prediction using clinical and behavioural features. **MethodsX**, v. 15, p. 103491, 2025. DOI: 10.1016/j.mex.2025.103491.
- HIGH ACCURACY diagnosis for MRI imaging of Alzheimer’s disease using XGBoost. **The Open Biotechnology Journal**, v. 16, p. e187407072208300, 2023. Disponível em: <https://openbiotechnologyjournal.com/VOLUME/16/ELOCATOR/e187407072208300/FULLTEXT/>. Acesso em: 11 out. 2025.
- JASODANAND, V. H. et al. AI-driven fusion of multimodal data for Alzheimer’s disease biomarker assessment. **Nature Communications**, v. 16, p. 7407, 2025. DOI: 10.1038/s41467-025-62590-4.
- JUGANAVAR, A.; JOSHI, A.; SHEGEKAR, T. Navigating early Alzheimer’s diagnosis: a comprehensive review of diagnostic innovations. **Cureus**, v. 15, n. 9, p. e44937, 2023. DOI: 10.7759/cureus.44937.
- KATABATHULA, S.; WANG, Q.; XU, R. Predicting Alzheimer’s disease using hippocampus MRI data: a lightweight 3D deep convolutional network model with visual and global shape representations. **Alzheimer’s Research & Therapy**, v. 13, n. 1, p. 104, 2021. DOI: 10.1186/s13195-021-00837-0.
- LEE, G. et al. Predicting Alzheimer’s disease progression using a multi-modal deep learning approach. **Scientific Reports**, v. 9, p. 1952, 2019. DOI: 10.1038/s41598-018-37769-0.
- MMADUMBU, M. et al. Deep multimodal neural architecture for Alzheimer’s disease diagnosis: combining MRI, PET and cognitive measures. **NeuroImage: Clinical**, v. 45, p. 103950, 2025. DOI: 10.1016/j.nicl.2025.103950.
- ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS). **Dementia: fact sheet**. Genebra, 2025. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/dementia>. Acesso em: 23 ago. 2025.



ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS). World failing to address dementia challenge. Genebra: WHO, 2021. Disponível em: <https://www.who.int/news/item/02-09-2021-world-failing-to-address-dementia-challenge>. Acesso em: 23 ago. 2025.

PARK, J. et al. Intracranial volume estimation in older adults: comparison of automated methods with manual measurements. **Journal of the International Neuropsychological Society**, v. 24, n. 9, p. 1004–1016, 2018. DOI: 10.1017/S1355617717001167.

PIERCE, A. L.; BULLAIN, S. S.; KAWAS, C. H. Late-onset Alzheimer disease. **Neurologic Clinics**, v. 35, n. 1, p. 283–293, 2017.

RETICO, A. et al. Support vector machines: whole-brain versus regional analysis of structural MRI in Alzheimer's disease. **Journal of Alzheimer's Disease**, v. 44, n. 4, p. 999–1013, 2015.

SCHWARZ, C. G. et al. A large-scale comparison of cortical thickness and volume methods for measuring Alzheimer's disease neurodegeneration. **NeuroImage: Clinical**, v. 11, p. 802–812, 2016. DOI: 10.1016/j.nicl.2016.05.017.

TIWARI, S. et al. Alzheimer's disease: pathogenesis, diagnostics, and therapeutics. **International Journal of Nanomedicine**, v. 14, p. 5541–5564, 2019. DOI: 10.2147/IJN.S202537.

TSIPRAS, N. et al. Kernel-based multimodal learning for early Alzheimer's disease detection using ADNI clinical and MRI data. **Frontiers in Artificial Intelligence**, v. 8, p. 112735, 2025.



# Desempenho Acadêmico na Previsão da Evasão no Ensino Superior: Comparação entre Modelos Bagging, Boosting e Ensemble de Votação Majoritária

*Academic Performance in Predicting Dropout Rates in Higher Education: A Comparison Between Bagging, Boosting, and Majority Voting Ensemble Models*

Ruminiki Pavei Schmoeller, Vanessa Demarchi Peron e Walter Mesquita Filho

1. Mestre em Tecnologias Computacionais para o Agronegócio (UTFPR). Docente do curso de Bacharelado em Engenharia de Software do Centro Universitário Descomplica UniAmérica. ORCID: <https://orcid.org/0009-0006-5046-4390> 2. Mestre em Tecnologias, Gestão e Sustentabilidade (Unioeste). ORCID: <https://orcid.org/0000-0002-1516-7693> 3. Mestre em Entomologia (UNESP) e Doutor em Entomologia (USP). ORCID: <https://orcid.org/0000-0003-4695-9471>  
[ruminikis@gmail.com](mailto:ruminikis@gmail.com)

## Palavras-chave

Ensino Superior  
Evasão Escolar  
LightGBM  
Machine Learning  
Random Forest  
XGBoosting

## Keywords

Higher Education  
School Dropout  
LightGBM  
Machine Learning  
Random Forest  
XGBoosting

## Resumo:

A pesquisa comparou modelos de machine learning para predição da evasão no ensino superior, utilizando atributos de desempenho acadêmico, demográficos e socioeconômicos. Quatro modelos foram avaliados (Random Forest, XGBoost, LightGBM e Ensemble). Os resultados da validação cruzada indicaram a superioridade dos algoritmos baseados em Gradient Boosting. O LightGBM apresentou o melhor desempenho geral, com acurácia de 91,05% e AUC-ROC de 0,9694. A análise da matriz de confusão do LightGBM revelou Taxa de Falsos Negativos de 9,82% e Taxa de Falsos Positivos de 7,27%. O estudo dos erros revelou que os falsos negativos, estudantes que cancelaram e não foram identificados, abandonaram o curso apesar do desempenho acadêmico semelhante ao dos ativos, sugerindo evasão motivada por fatores não acadêmicos e não capturados pelo modelo. A importância dos atributos, medida pelo SHAP, estabeleceu que a eficiência acadêmica, principalmente média de aprovações por período e taxa de carga horária de sucesso no último semestre são os preditores dominantes. Concluiu-se: modelos de boosting são eficazes para sistemas de alerta precoce e baixo desempenho é forte indicador de risco. A limitação em captar fatores não acadêmicos aponta para a necessidade de incorporar dados mais abrangentes para previsão de maior impacto nas estratégias de retenção.

## Abstract:

This research compared machine learning models for predicting dropout rates in higher education, using academic performance, demographic, and socioeconomic attributes. Four models were evaluated (Random Forest, XGBoost, LightGBM, and Ensemble). Cross-validation results indicated the superiority of Gradient Boosting-based algorithms. LightGBM showed the best overall performance, with an accuracy of 91.05% and an AUC-ROC of 0.9694. Analysis of the confusion matrix of LightGBM revealed a False Negative Rate of 9.82% and a False Positive Rate of 7.27%. The error study revealed that false negatives—students who dropped out and were not identified—abandoned their courses despite academic performance similar to that of active students, suggesting dropout motivated by non-academic factors not captured by the model. The importance of attributes, as measured by SHAP, established that academic efficiency, mainly average pass rates per semester and the rate of successful coursework in the last semester, are the dominant predictors. It was concluded that boosting models are effective for early warning systems, and low performance is a strong indicator of risk. The limitation in capturing non-academic factors points to the need to incorporate more comprehensive data for predicting a greater impact on retention strategies.

Artigo recebido em: 15.10.2025.  
Aprovado para publicação em:  
07.11.2025.

## INTRODUÇÃO

A evasão no ensino superior é um fenômeno persistente e multifatorial, com impactos profundos nas instituições de educação superior, nas trajetórias individuais dos estudantes e nas políticas públicas educacionais (Behr, 2020). Embora a decisão de abandonar um curso resulte de uma complexa interação de fatores pessoais e institucionais (Minhoto, Smaili e Arantes, 2023), o desempenho acadêmico é um indicativo da adaptação do estudante, com influência inclusive sobre sua motivação para continuar o curso (Fior et al, 2024; Goren; Galve-González, 2024; Apumayta, 2024; Cabezas, 2022).

A busca por compreender quais características levam o estudante a abandonar o curso tem sido tema de diversos estudos. As primeiras teorias começaram a ser desenvolvidas na década de 1970 a partir dos trabalhos de Spady (1970), Tinto (1975), Bean (1980) e Pascarella e Terenzini (1980), que destacaram fatores como integração social, expectativas e satisfação dos estudantes, aspectos acadêmicos e organizacionais. Pesquisas recentes apontam para causas semelhantes, reforçando dificuldades financeiras, baixo desempenho acadêmico, falta de motivação e engajamento, não identificação e falta de perspectiva com o curso, circunstâncias pessoais e fatores institucionais (Schuhardt et al., 2024).

A compreensão das causas da evasão ganha ainda mais relevância diante do contexto de expansão do ensino superior no Brasil. No período de 2010 a 2024 houve um aumento de 51% na oferta de vagas em Instituições Federais de Ensino, chegando a 586.246 vagas. Apesar disso, a taxa de ingresso não acompanhou o crescimento, mantendo-se no mesmo patamar, com uma média de 339 mil ingressos anuais (INEP, 2025).

A ociosidade inicial, decorrente do descompasso entre a oferta de vagas e a taxa de ingresso, é agravada pela evasão, que chega a 30% nos dois primeiros anos e a 60% após o período regular do curso, com apenas 40% de estudantes diplomados (INEP, 2025). Como comparação, nos países da Organização para a Cooperação e Desenvolvimento Econômico, a taxa de diplomados é de 39% no tempo apropriado do curso e sobe para 68% após o tempo regular (OECD, 2022).

Apesar do avanço teórico, o paradoxo da expansão do acesso desacompanhada da ocupação das vagas e a dificuldade de retenção, reforça a necessidade de novos estudos. A análise do desempenho acadêmico se mostra relevante para identificar o risco de abandono. A disponibilidade de modelos preditivos permite às instituições adotar uma postura preventiva e concentrar esforços no sucesso do estudante desde o início de sua trajetória, por meio da implementação de mecanismos de alertas em seus sistemas informatizados (USP, 2025).

Tem-se, portanto, um problema prático relevante: a dificuldade das instituições de implementar intervenções preventivas eficazes, direcionadas e em tempo hábil. A ausência de ferramentas preditivas acuradas, com foco em dados obtidos desde o início da jornada acadêmica, limita a capacidade de identificar proativamente os discentes com maior probabilidade de abandonar os estudos, resultando em estratégias de retenção frequentemente reativas e de menor impacto.

Neste contexto, a presente pesquisa busca responder à seguinte questão: o desempenho acadêmico, medido a partir dos semestres iniciais, pode ser um indicador do risco de evasão estudantil? O objetivo é identificar um conjunto de atributos relevantes para a predição da evasão e desenvolver modelos de aprendizado supervisionado capazes de antecipar o risco de abandono de matrícula. Será conduzida uma etapa de seleção e engenharia de atributos a fim de otimizar a generalização e interpretabilidade dos modelos. Ao integrar técnicas de ciência de dados com a literatura educacional, espera-se contribuir para a formulação de estratégias mais eficazes de combate à evasão e de promoção da permanência estudantil.

## ESTADO DA ARTE / TRABALHOS RELACIONADOS

A evasão universitária é reconhecida como um fenômeno multifacetado e complexo, raramente dependente de um fator isolado, mas sim do resultado da inter-relação de múltiplos determinantes (Behr, 2020; Galve-González, 2024). Com alguma variação, os estudos têm aplicado majoritariamente modelos de aprendizado supervisionado, avaliados atributos demográficos, socioeconômicos e de desempenho acadêmico (Alvarado-Uribe et al., 2022; Vilorio et al., 2019; Alvarez, Callejas e Griol, 2020; Aulck et al., 2017; Niyogisubizo et al., 2022; Flores et al., 2022; Gonçalves et al., 2018; Perez et al., 2018; Sara et al., 2015). Alguns, no entanto, avançaram para estudar atributos familiares, como ocupação e escolaridade dos pais (Pedroza et al., 2019).

De La Cruz-Campos et al. (2023), Lorenzo-Quiles et al. (2023), Behr et al. (2020) e Da Silva (2021), identificaram que características pessoais e sociais (90,4%), acadêmicas (76,1%), demográficas (57,1%) e socioeconômicas (42,8%) são as mais comumente analisadas na busca de identificação de grupos de risco para a evasão.

Galve-González (2024), aponta que problemas de desempenho acadêmico e dificuldades de aprendizado estão diretamente relacionados a condições inadequadas de estudo e a uma gestão de tempo deficiente, que se referem a aspectos socioeconômicos e comportamentais do estudante. Niyogisubizo et al. (2022), reforçam que a dificuldade financeira se configura como fator crítico para o desempenho e a continuidade dos estudos.

Demetriou e Schmitz-Sciborski (2011), destacaram a relevância da integração social, motivação, forças pessoais e otimismo. Variáveis como satisfação com a escolha do curso, engajamento acadêmico e a aplicação de estratégias de autorregulação da aprendizagem são consideradas fundamentais. Por sua vez, o desinteresse pelo conteúdo curricular tem sido apontado como um fator chave na previsão da evasão (Galve-González, 2024).

Dada a complexidade do fenômeno da evasão, diversos estudos têm focado em abordagens quantitativas para investigar suas causas e possíveis intervenções (Flores et al., 2022; Apumayta, 2024). Alvarado-Uribe et al. (2022) observaram que a maior parte da literatura utiliza algoritmos tradicionais de aprendizado de máquina, como regressão logística, kNN e modelos baseados em árvores de decisão. Vilorio et al. (2019), Flores et al. (2022) e Tete et al. (2022), observam que o método Random Forest é comumente o mais utilizado na predição da evasão, seguido de redes bayesianas e Regressão Logística.

Estudos mais recentes apontam para a tendência crescente no uso de modelos de conjunto (*ensemble*) e técnicas de otimização, visando superar desafios persistentes como o desequilíbrio de classes — situação em que a maioria dos estudantes não abandona o curso. Niyogisubizo et al. (2022) propuseram um modelo de conjunto empilhado (*stacked ensemble*) de duas camadas, combinando Random Forest (RF), Extreme Gradient Boosting (XGBoost), Gradient Boosting (GB) e Redes Neurais de Alimentação Direta (FNN). Esse método superou os modelos isolados, alcançando uma acurácia de teste de 92,18% e uma AUC de 0,983.

Novos estudos, conduzidos por Villar e Andrade (2024), reafirmam a superioridade dos algoritmos de *boosting*, especialmente quando combinados com a otimização de hiperparâmetros. Os achados indicaram que LightGBM e CatBoost, após a otimização, apresentaram desempenho superior aos algoritmos convencionais.

Apesar de ainda ser um desafio complexo, a previsão da evasão vem apresentando avanços com o emprego de técnicas modernas de aprendizado de máquina. A relevância dos diferentes estudos reside em iden-

tificar e confirmar variáveis importantes para a previsão da evasão, levando em conta o seu treinamento em diferentes contextos e conjuntos de dados.

## MATERIAIS E MÉTODOS

Para a realização desta pesquisa, foram utilizados dados anonimizados de estudantes de uma Universidade Federal do Brasil, relacionados ao desempenho acadêmico, características demográficas e socioeconômicas. As atividades foram organizadas segundo a metodologia *Cross Industry Standard Process for Data Mining* (CRISP-DM), desenvolvidas em ciclos iterativos para (1) entendimento do negócio; (2) entendimento dos dados; (3) preparação dos dados; (4) modelagem; e (5) avaliação (Wirth e Hipp, 2000).

Na etapa de entendimento do negócio e entendimento dos dados foram compreendidas as questões relacionadas à evasão escolar e como elas são tratadas na Universidade. Foram avaliadas normas referentes aos processos de matrícula e registro acadêmico do discente, considerando os procedimentos relativos aos cancelamentos e trancamentos. A amostra selecionada teve 14.800 registros e 26 atributos, cuja relação é apresentada no Quadro 1.

Quadro 1: Relação dos atributos do conjunto de dados

Campo	
idade_ingresso_curso	acompanhamentos_pedagogicos_por_periodo
forma_ingresso	carga_horaria_matriculada_por_periodo
carga_horaria_integralizada_por_periodo	carga_horaria_total_primeiro_semestre
turno	taxa_cobertura_auxilio_alimentacao
tempo_ensino_medio_e_ingresso	taxa_cobertura_auxilio_transporte
total_faltas_primeiro_semestre	taxa_engajamento_em_projetos
total_faltas_ultimo_semestre	carga_horaria_sucesso_por_periodo
media_notas	carga_horaria_insucesso_por_periodo
media_percentual_frequencia	carga_horaria_sucesso_primeiro_semestre
media_numero_faltas	carga_horaria_insucesso_primeiro_semestre
aprovacoes_por_periodo	carga_horaria_sucesso_ultimo_semestre
reprovacoes_por_periodo	carga_horaria_insucesso_ultimo_semestre
trancamentos_por_periodo	situacao

Na fase de preparação dos dados, foram removidos registros de estudantes que não tiveram pelo menos um semestre consolidado e desconsiderados os estudantes que tiveram a matrícula cancelada por transferência para outra instituição; decisão judicial; falecimento; e desistência antes do início do curso (Andifes, 1996; Coimbra, Silva e Costa, 2021).

Atributos somatórios e de contagem que continham valores faltantes foram atualizados para zero. As demais variáveis foram proporcionalizadas em relação ao total de períodos cursados. Uma etapa de engenharia de atributos (*feature engineering*) foi realizada. Nesse processo foram combinados atributos quantitativos de forma a gerar taxas associadas ao desempenho acadêmico.

A situação do estudante foi categorizada em duas classes: ativos e cancelados. Segundo as normas da Universidade, foram classificados como cancelados os estudantes que estavam com o vínculo inativo e aqueles que atingiram o limite de trancamentos e não estavam matriculados em nenhuma disciplina.

Uma etapa de seleção de características foi realizada, com objetivo de encontrar um número reduzido de atributos, suficiente para uma boa previsão da variável resposta e que favoreça a definição de um modelo mais compacto e de melhor interpretabilidade (Hall, 1999; Becher et al., 2000; Genuer et al., 2010; Li et al., 2017). Neste trabalho foi utilizado o método de avaliação da informação mútua (Peng et al., 2005), uma medida da dependência entre duas variáveis aleatórias, usada para quantificar a quantidade de informação compartilhada entre um atributo (*feature*) e a variável alvo (*target*). Ao final da etapa de preparação, o conjunto consolidado teve 9.430 observações com 33 atributos. Desses, 4.950 identificados como **ativos** e 4.480 identificados como **cancelados**.

Na etapa de modelagem foram treinados modelos Random Forest (Breiman, 2001), XGBoosting (Chen e Guestrin, 2016), LightGBM (Ke et al. 2017) e em seguida um modelo *ensemble* por votação majoritária que combina a classificação gerada pelos três modelos. A escolha dos modelos está alinhada aos principais estudos na área que reforçam o uso de modelos de árvores, e a tendência recente para o uso de modelos de boosting.

Foi estabelecida uma *pipeline* com etapas de pré-processamento dos dados com a codificação de variáveis categóricas usando a técnica de *one hot encoding* e padronização de variáveis numéricas pela transformação dos dados em *z-score* para que cada característica se assemelhe a uma distribuição normal padrão (Cabello-Solorzano, 2023). Os conjuntos foram divididos aleatoriamente em treinamento (com 80% das observações) e teste (com 20% das observações). Em todos os modelos foi aplicada a estratégia de validação cruzada com dez dobras (*10 k-fold cross-validation*).

Os modelos foram avaliados de forma comparativa por meio das métricas de acurácia, precisão, revocação, F1-Score e área sob a curva ROC, que são adequadas para problemas de classificação (Fawcett, 2006; Fávero, 2017). Além das métricas de desempenho, o resultado dos modelos foi comparado pelo teste McNemar (McNemar, 1947). O teste é usado para determinar se existe uma diferença estatisticamente significativa entre as taxas de erro de dois modelos quando eles são aplicados no mesmo conjunto de dados. Diferente de outros testes, o teste de McNemar foca especificamente nas instâncias em que os modelos discordam.

A importância dos atributos e interpretabilidade do modelo foi avaliada pelo método SHAP (*SHapley Additive exPlanations*). O SHAP calcula a importância dos atributos, quantificando o impacto que cada atributo tem na predição final do modelo. Fornece uma forma consistente e aditiva de decompor a predição de uma instância em contribuições individuais dos seus atributos. Permite a interpretabilidade de uma instância específica e a importância geral dos atributos para o modelo (Lundberg e Lee, 2017).

## RESULTADOS E DISCUSSÃO

### MODELOS DE CLASSIFICAÇÃO

A análise dos resultados da validação cruzada revela um desempenho muito próximo entre os modelos, com superioridade para modelos baseados em *Gradient Boosting* (LightGBM, XGBoost). O modelo *ensemble* também apresentou desempenho semelhante (Tabela 1).

A Tabela 2, exibe os resultados da análise comparativa dos modelos Random Forest, LightGBM, XGBoost e *ensemble*, empregando o teste de McNemar para avaliar suas performances. O modelo Random Forest apresentou um desempenho estatisticamente inferior aos demais modelos. Não houve diferença significativa no desempenho entre LightGBM, XGBoost e o *Ensemble*, mostrando que os erros que esses modelos cometem são muito semelhantes.

Tabela 1: Desempenho dos modelos com o método de validação cruzada

Modelo	Acurácia	Precisão	Recall	F1-Score	AUC-ROC
LightGBM	0,9105 ± 0,0073	0,9132 ± 0,0102	0,8970 ± 0,0067	0,9050 ± 0,0075	0,9694 ± 0,0035
XGBoost	0,9093 ± 0,0115	0,9115 ± 0,0169	0,8965 ± 0,0095	0,9039 ± 0,0116	0,9690 ± 0,0043
Ensemble	0,9099 ± 0,0078	0,9132 ± 0,0131	0,8956 ± 0,0099	0,9042 ± 0,0080	0,9676 ± 0,0044
Random Forest	0,8900 ± 0,0094	0,8916 ± 0,0177	0,8753 ± 0,0059	0,8832 ± 0,0089	0,9545 ± 0,0060

Tabela 2: Comparação do desempenho dos modelos pelo teste McNemar

Modelo 1	Modelo 2	Estatística McNemar	Valor-p	Significante (p<0,05)	Melhor Modelo
Random Forest	LightGBM	18,0	0.0000	Sim	LightGBM
Random Forest	XGBoost	25,0	0.0003	Sim	XGBoost
Random Forest	Ensemble	14,0	0.0000	Sim	Ensemble
LightGBM	XGBoost	16,0	0.0725	Não	N/A
LightGBM	Ensemble	9,0	0.1221	Não	N/A
XGBoost	Ensemble	11,0	0.5572	Não	N/A

A taxa de revocação de 89,70% sugere que o LightGBM tem maior capacidade de identificar os alunos que estão em risco real de abandonar o curso - que é o principal objetivo de um sistema de alerta precoce. Ao mesmo tempo, demonstrou maior precisão e acurácia. Quando o modelo classifica um aluno como risco de evasão, ele está correto em 91,32% das vezes, minimizando o risco de falsos positivos, e consequentemente, que os recursos de intervenção sejam desperdiçados em alunos que não precisam.

Em relação à área sob a curva ROC, os modelos Light GBM, XGBoost e Ensemble apresentam curvas bastante próximas, com vantagem para o LightGBM que apresentou AUC de 96,94%, sugerindo que o modelo tem alto poder de discriminação entre as classes positivas e negativas. Os modelos divergiram pouco, em apenas 5,6% dos casos. Isso reforça a compreensão do teste McNemar, ao apresentar que as divergências entre os modelos de boosting e ensemble não foram significativas.

### ANÁLISE DA MATRIZ DE CONFUSÃO

A partir do resultado do desempenho dos modelos, o LightGBM foi escolhido para análise. Observa-se bom desempenho na classificação do conjunto de testes, com acurácia de 90,91%. Dos 1.886 casos avaliados, 1.726 foram corretamente classificados, com 918 verdadeiros negativos (alunos ativos) e 808 verdadeiros positivos (previsão de cancelamento), conforme pode ser visto na Tabela 3.

A taxa de falso positivo (erro Tipo I) é 7,27%, ou seja, cerca de 7% dos alunos que continuariam ativos foram classificados como em risco de evasão. A taxa de erro Tipo II, que corresponde aos falsos negativos, é maior, atingindo aproximadamente 9,82%, com 88 alunos cancelados classificados como ativos. Esse tipo de erro é mais crítico nesse contexto, pois representa alunos em risco de evasão não identificados pelo modelo, comprometendo a eficiência das ações de retenção. Falsos positivos podem levar a gastos desnecessários com alunos que não precisam de ajuda, enquanto falsos negativos deixam alunos em risco sem atendimento.

A análise dos erros, especificamente dos Falsos Positivos (FP) e Falsos Negativos (FN), revela os perfis atípicos que o modelo não conseguiu capturar (Tabela 4 e Tabela 5). Quanto aos falsos positivos, observa-se que o perfil de desempenho deste grupo é inferior ao do aluno ativo e semelhante ao de um aluno que cancelou a matrícula. Esse grupo apresentou dificuldade acadêmica e de engajamento, no entanto, se manteve ativo. A sua manutenção pode estar relacionada ao apoio pedagógico recebido, que foi superior.

Tabela 3: Análise da matriz de confusão

Métrica	Valor	Descrição / Interpretação
Total de Instâncias	1886	Número total de alunos na amostra de teste.
Verdadeiros Negativos (TN)	918	Alunos ATIVOS que o modelo previu corretamente como ATIVOS.
Falsos Positivos (FP)	72	Alunos ATIVOS que o modelo previu erroneamente como CANCELADOS.
Falsos Negativos (FN)	88	Alunos CANCELADOS que o modelo previu erroneamente como ATIVOS.
Verdadeiros Positivos (TP)	808	Alunos CANCELADOS que o modelo previu corretamente como CANCELADOS.
Taxa de Erro Tipo I (Falso Alarme)	7,27%	Indica que 7,27% dos alunos ativos foram classificados de forma errada como evadidos.
Taxa de Erro Tipo II (Falso Negativo)	9,82%	Indica que 9,82% dos alunos evadidos não foram identificados pelo modelo.

Tabela 4: Análise dos falsos positivos (alunos ativos classificados como cancelados)

Característica	Padrão Encontrado (Falso Positivo)	Comparação com Ativos	Comparação com Cancelados
Taxa de Sucesso (Último Semestre)	27%	44%	27%
Média de Notas	5,47	7,12	5,23
Reprovações por Período	1,44	0,51	1,46
Frequência Média	83%	93%	83%
Evolução do Desempenho	-0,48	-0,05	-0,45
Engajamento Extracurricular	0,018	0,05	0,01
Carga Horária Matriculada	271	207	284
Carga Horária Integralizada	166	322	160
Acompanhamento Pedagógico	0,52	0,37	0,40
Cobertura de Auxílios	18%	37%	17%

Quanto aos falsos negativos (Tabela 5), são alunos com desempenho intermediário que apesar do elevado número de acompanhamentos pedagógicos, decidiram abandonar o curso. A opção pelo abandono, nesse caso, pode ter sido influenciada por fatores externos, não captados pelo conjunto de dados.

Tabela 5: Análise dos falsos negativos (alunos cancelados classificados como ativos)

Característica	Padrão Encontrado (Falso Negativo)	Comparação com Ativos	Comparação com Cancelados
Taxa de Sucesso (Último Semestre)	66%	81%	27%
Média de Notas	7,12	7,66	5,23
Reprovações por Período	0,83	0,51	1,46
Frequência Média	92%	93%	83%
Evolução do Desempenho	-0,19	-0,05	-0,45
Engajamento Extracurricular	0,04	0,05	0,01
Carga Horária Matriculada	263	207	284
Carga Horária Integralizada	262	322	160
Acompanhamento Pedagógico	0,57	0,37	0,40
Cobertura de Auxílios	26%	37%	17%




A análise dos Falsos Positivos e Falsos Negativos revela a complexidade da predição de evasão, mostrando que o modelo, embora eficaz, apresenta desafios importantes.

### ANÁLISE DA IMPORTÂNCIA DOS ATRIBUTOS

A importância dos atributos, obtida pela média do valor absoluto de SHAP, apresenta o impacto individual de cada variável na previsão final do modelo LightGBM. A análise fornece uma compreensão granular de como cada atributo se comporta e se associa ao risco de evasão (valores SHAP positivos) ou à permanência (valores SHAP negativos), ilustrando a intensidade e a direção da influência de cada característica (Gráfico 1).

Gráfico 1: Importância dos atributos pelo método SHAP



No Gráfico 1, é possível observar que as variáveis de desempenho acadêmico contribuem positivamente para a classificação e portanto, são um bom indicador da separação entre as classes, com o menor desempenho acadêmico associado a estudantes com risco de evasão.

A análise revelou que 11 das 15 variáveis mais importantes para predizer o risco de evasão se relacionam à eficiência acadêmica, três ao suporte institucional e duas ao comportamento do estudante. No nível superior ( $SHAP > 0,5$ ), o modelo prioriza o desempenho acadêmico e a busca por suporte institucional como preditores dominantes (Tabela 6).

A quantidade de aprovações no curso e a taxa de carga horária de sucesso no último semestre são os principais preditores do sucesso acadêmico, a incapacidade de progredir leva à evasão. O acompanhamento pedagógico, com impacto superior a métricas de desempenho, surge como forte indicador, possivelmente agindo como *proxy* para alunos de alto risco. A vulnerabilidade financeira, indicada pela taxa de cobertura de auxílio alimentação, também é um forte indicador socioeconômico de retenção.

No segundo nível de relevância ( $SHAP$  entre 0,25 e 0,5), o modelo incorpora variáveis de desempenho acadêmico, como taxa de aprovação, carga horária de sucesso por período e carga horária integralizada, que indicam a progressão do estudante e sua capacidade de concluir disciplinas. A carga horária de sucesso no último semestre reforça a importância dos dados mais recentes para a capacidade preditiva do modelo.

Tabela 6: Nível de importância dos atributos

Variável	SHAP Value	Contexto
aprovacoes_por_periodo	0,950	Eficiência Acadêmica
taxa_ch_sucesso_ultimo_semestre	0,912	Eficiência Acadêmica
acompanhamentos_pedagogicos_por_periodo	0,846	Suporte Institucional
taxa_cobertura_auxilio_alimentacao	0,509	Suporte Institucional
taxa_aprovacoes_por_periodo	0,432	Eficiência Acadêmica
carga_horaria_sucesso_por_periodo	0,423	Eficiência Acadêmica
carga_horaria_integralizada_por_periodo	0,274	Eficiência Acadêmica
carga_horaria_sucesso_ultimo_semestre	0,264	Eficiência Acadêmica
taxa_cobertura_auxilio_transporte	0,258	Suporte Institucional
total_faltas_ultimo_semestre	0,191	Comportamental
media_notas	0,188	Eficiência Acadêmica
taxa_trancamentos_por_periodo	0,175	Eficiência Acadêmica
taxa_ch_sucesso_por_periodo	0,160	Eficiência Acadêmica
taxa_engajamento_em_projetos	0,154	Comportamental
evolucao_desempenho	0,134	Eficiência Acadêmica

O terceiro nível ( $\text{SHAP} < 0,25$ ) inclui sinais menos influentes, como notas e comportamento. A média das notas tem menos peso que as taxas de aprovação, indicando que o modelo prioriza a aprovação sobre a qualidade da nota. Faltas e trancamentos sinalizam desengajamento como fator de risco, embora menor que o fracasso acadêmico direto. Atributos como engajamento em projetos extracurriculares (fator protetivo, possivelmente por vínculos mais sólidos) e a evolução do desempenho (diferença entre o primeiro e o último período) refinam a previsão, reforçando a evasão estar mais ligada à reprovação do que ao desempenho médio.

O teste t de Welch (Tabela 7), confirmou a significância das diferenças entre as médias dos atributos mais relevantes.

Tabela 7: Comparação da média dos atributos de estudantes identificados como ativos e cancelados

Variável	Estatística T	p-valor	Média Ativos	Média Cancelados
aprovacoes_por_periodo	64,98	0,00E+00*	4,79	2,44
taxa_ch_sucesso_ultimo_semestre	85,76	0,00E+00*	0,84	0,27
acompanhamentos_pedagogicos_por_periodo	-2,94	3,25E-03*	0,38	0,41
taxa_cobertura_auxilio_alimentacao	27,32	5,26E-158*	0,37	0,18
taxa_aprovacoes_por_periodo	76,92	0,00E+00*	0,82	0,49
carga_horaria_sucesso_por_periodo	25,13	6,72E-135*	72,61	67,93
carga_horaria_integralizada_por_periodo	70,54	0,00E+00*	322,51	160,15
carga_horaria_sucesso_ultimo_semestre	59,72	0,00E+00*	314,71	99,90
taxa_cobertura_auxilio_transporte	6,29	3,37E-10*	0,18	0,14
total_faltas_ultimo_semestre	-38,14	3,39E-290*	18,71	46,26
media_notas	66,77	0,00E+00*	7,66	5,23
taxa_trancamentos_por_periodo	-23,44	6,02E-117*	0,09	0,15
taxa_ch_sucesso_por_periodo	39,52	0,00E+00*	0,45	0,29
taxa_engajamento_em_projetos	29,02	1,20E-175*	0,05	0,01
evolucao_desempenho	53,03	0,00E+00*	-0,05	-0,45


Nota: \*Diferença significativa ao nível de significância de 1% ( $p < 0,01$ ).

A análise das médias revela diferenças estatisticamente significativas entre os estudantes ativos e cancelados em todas as variáveis. O grupo cancelado apresentou médias significativamente mais altas em indicadores de insucesso, como *total\_faltas\_ultimo\_semestre* e *taxa\_trancamentos\_por\_periodo*, reforçando a hipótese de que o baixo desempenho, a frequência insuficiente e a maior taxa de trancamentos são sintomas importantes para o abandono.

As variáveis socioeconômicas, taxa de cobertura de auxílio alimentação e taxa de cobertura de auxílio transporte apresentaram menor cobertura no grupo cancelado. Já a quantidade de acompanhamentos pedagógicos foi semelhante. Por um lado, reforça a importância do apoio institucional para manter estudantes ativos, e por outro, revela limitações na capacidade de retenção.

O aprofundamento sobre os acompanhamentos pedagógicos, revela que a variável atua como um *proxy* para estudantes em risco de evasão (Gráfico 2). A relação linear indica que mais acompanhamentos se associam a pior desempenho (menor sucesso em carga horária e menos aprovações). Contudo, a presença de pontos azuis em valores mínimos de acompanhamento sugere que alguns estudantes em risco não estão sendo identificados pelas ações de suporte institucional.

Gráfico 2. Gráfico de dependência de acompanhamentos pedagógicos em relação às aprovações e a carga horária de sucesso no último semestre



Os resultados confirmam a relação entre desempenho acadêmico e evasão, a exemplo de Fior et al. (2022), que mostraram que evadidos tinham notas significativamente mais baixas ( $M = 4,31$ ) que os matriculados ( $M = 6,41$ ). Um melhor desempenho acadêmico está ligado a um menor risco de abandono, evidenciando o impacto do rendimento na decisão dos estudantes.

Considerando o desempenho uma variável dinâmica e preditora, os autores sugerem que as intervenções institucionais foquem no fortalecimento da autoeficácia estudantil. Ações diretas para aumentar as notas, como monitorias e reestruturação curricular, podem ser eficazes na melhoria da permanência, a exemplo dos acompanhamentos pedagógicos evidenciados neste trabalho.

Também o estudo de Vaarma e Li (2024), reforça que o desempenho acadêmico é o fator preditivo mais poderoso. Para os autores, "créditos acumulados" e "número de reprovações" são as variáveis mais importantes. Neste trabalho, se assemelham a baixa carga horária integralizada (créditos acumulados) e baixo número de aprovações, que caracterizam o grupo de estudantes cancelados.

Goren et al. (2024), corroboram com o ponto de vista e afirmam que o desempenho acadêmico é o dado mais preditivo de abandono. Embora a qualidade da predição (AUC) melhore com dados de exames parciais

e ao final do semestre, os autores apontam um paradoxo temporal: esses indicadores, apesar de melhores, são tardios, limitando o tempo para intervenções eficazes. Isso gera um *trade-off* entre capacidade preditiva e intervenção precoce. Essa limitação esteve presente neste trabalho, que considerou apenas estudantes com, no mínimo, um semestre concluído.

O baixo desempenho acadêmico se configura, portanto, como um sintoma claro e consistente de risco para evasão. A principal contribuição dos estudos (Fior et al., 2022; Goren et al., 2024) está em evidenciar que, embora o desempenho seja o melhor preditor do abandono, ele é condicionado por fatores psicológicos, como a autoeficácia, e decisões pessoais, como a escolha do curso.

## CONSIDERAÇÕES FINAIS

A análise realizada neste estudo confirmou a capacidade preditiva associada a variáveis de desempenho acadêmico e demonstrou que estudantes que possuem melhor desempenho têm menor risco para a evasão. Os modelos desenvolvidos apresentaram alta capacidade preditiva, com destaque para os algoritmos de *boosting*, em especial ao LightGBM, com acurácia acima de 90% e área sob a curva ROC próxima de 97%. O modelo *ensemble*, que combina a predição dos modelos, reforçou a semelhança entre eles. A partir da análise dos erros e da importância das variáveis pelo método SHAP, foi possível traçar um perfil entre os grupos ativos e cancelados.

Academicamente, o aluno em risco de evasão, demonstra baixo rendimento, com menor taxa de aprovação, menor capacidade de cumprimento da carga horária matriculada, notas mais baixas. Comportamentalmente apresenta alto absenteísmo, matrícula excessiva em disciplinas e baixo engajamento extracurricular. Institucionalmente possui menor cobertura de auxílios estudantis, sugerindo por um lado a importância do auxílio para a manutenção dos estudantes ativos, e por outro, a necessidade de aprofundamento institucional para verificar se a decisão pelo abandono foi influenciada pela falta de assistência. Os acompanhamentos pedagógicos emergiram como variável importante para o modelo, no entanto, as médias próximas entre estudantes ativos e cancelados indica a necessidade de aprofundamento para verificar a efetividade das ações ou as limitações institucionais, quando a decisão pelo abandono não pode ser revertida.

Esses achados fornecem à instituição um roteiro para possíveis ações de retenção que levem em conta a intervenção precoce baseada no desempenho desde o primeiro semestre. A identificação precoce de quedas no rendimento permite intervenções oportunas, evitando que o baixo desempenho se torne um fator irreversível. O acompanhamento pelo setor pedagógico se mostra essencial também para a compreensão dos diversos sinais que o estudante possa emitir em relação a sua decisão futura.

## REFERÊNCIAS

- ALVARADO-URIBE, J. et al. Student Dataset from Tecnológico de Monterrey in Mexico to Predict Dropout in Higher Education. **Data**, v. 7, n. 9, p. 119, set. 2022. Disponível em: <https://doi.org/10.3390/data7090119>. Acesso em 10 mar. 2024.
- ALVAREZ, N. L.; CALLEJAS, Z.; GRIOL, D. Predicting Computer Engineering Students' Dropout In Cuban Higher Education With Pre-Enrollment and Early Performance Data. **Journal of Technology and Science Education**, v. 10, n. 2, p. 241–258, 2020. Disponível em: <https://doi.org/10.3926/jotse.922>. Acesso em 05 mar. 2025.
- ANDIFES. **Diplomação, retenção e evasão nos cursos de graduação em IES públicas**: Comissão Especial de Estudos sobre a Evasão nas Universidades Públicas Brasileiras. Brasília, DF: [s. n.], 1996. Disponível em:
- 
- SCHMOELLER, R.P.; PERON, V.D.; MESQUITA FILHO, W. Desempenho Acadêmico na Previsão da Evasão no Ensino Superior: Comparação entre Modelos Bagging, Boosting e Ensemble de Votação Majoritária. **Pleiade**, 19(49): 42-55, Out.-Dez., 2025  
DOI: 10.32915/pleiade.v19i49.1195

[http://www.andifes.org.br/wp-content/files\\_flutter/Diplomacao\\_Retencao\\_Evasao\\_Graduacao\\_em\\_IES\\_Publicas-1996.pdf](http://www.andifes.org.br/wp-content/files_flutter/Diplomacao_Retencao_Evasao_Graduacao_em_IES_Publicas-1996.pdf). Acesso em 29 mar. 2024.

APUMAYTA, Raul Quincho; CAYLLAHUA, Javier Carrillo; PARI, Abraham Ccencho et al. University dropout: a systematic review of the main determinant factors (2020–2024). **F1000Research**, v. 13, p. 942, 2024. Disponível em: <https://doi.org/10.12688/f1000research.154263.2>. Acesso em 08 out. 2025.

AULCK, L.; VELAGAPUDI, N.; BLUMENSTOCK, J.; WEST, J. Predicting student dropout in higher education. 2017. Disponível em: <http://arxiv.org/abs/1606.06364>. Acesso em 15 mar. 2024.

BEAN, John P. Dropouts and turnover: the synthesis and test of a causal model of student attrition. **Research in Higher Education**, v. 12, p. 155–187, 1980.

BEHR, A.; GIESE, M.; TEGUIM KAMDJO, H. D.; THEUNE, K. Dropping out of university: a literature review. **Review of Education**, v. 8, n. 2, p. 614–652, 2020. Disponível em: <https://doi.org/10.1002/rev3.3202>. Acesso em 06 out. 2023.

BOEHMKE, Bradley. Hands-on machine learning with R. Disponível em: <https://bradleyboehmke.github.io/HOML/index.html>. Acesso em: 14 out. 2023.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.

CABELLO-SOLORZANO, K.; ORTIGOSA DE ARAUJO, I.; PEÑA, M.; CORREIA, L. J.; TALLÓN-BALLESTEROS, A. Impact of data normalization on the accuracy of machine learning algorithms: a comparative analysis. **18th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2023)**. Disponível em: [https://doi.org/10.1007/978-3-031-42536-3\\_33](https://doi.org/10.1007/978-3-031-42536-3_33). Acesso em 10 out. 2024.

CHEN, T.; GUESTRIN, C. XGBoost: a scalable tree boosting system. 2016. Disponível em: <https://doi.org/10.1145/2939672.2939785>. Acesso em 22 set. 2024.

COIMBRA, C. L.; SILVA, L. B.; COSTA, N. C. Evasion in higher education: definitions and trajectories. **Educação e Pesquisa**, v. 47, p. 1–18, 2021. Disponível em: <https://doi.org/10.1590/S1678-4634202147228764>. Acesso em 25 ago. 2024.

DE LA CRUZ-CAMPOS, J.; VICTORIA-MALDONADO, J.; MARTÍNEZ-DOMINGO, J.; CAMPOS-SOTO, M. Causes of academic dropout in higher education in Andalusia and proposals for its prevention at university: a systematic review. **Frontiers in Education**, v. 8, 2023. Disponível em: <https://doi.org/10.3389/feduc.2023.1130952>. Acesso em 17 ago. 2024.

FÁVERO, L. P. Manual de análise de dados: estatística e modelagem multivariada com Excel®, SPSS® e Stata®. São Paulo: **GEN LTC**, 2017.

FAWCETT, Tom. An introduction to ROC analysis. **Pattern Recognition Letters**, v. 27, n. 8, p. 861–874, 2006.

FIORE, Camila Alves et al. Impacto da autoeficácia e do rendimento acadêmico no abandono de estudantes do ensino superior. **Psicologia Escolar e Educacional**, v. 26, e235218, Campinas, SP, 2022. Disponível em: <https://doi.org/10.1590/2175-3539202235218>. Acesso em 10 out. 2025.

FLORES, Vaneza; HERAS, Stella; JULIAN, Vicente. Comparison of predictive models with balanced classes using the SMOTE method for the forecast of student dropout in higher education. **Electronics**, v. 11, n. 3, p. 457, 2022. Disponível em: <https://doi.org/10.3390/electronics11030457>. Acesso em 6 set. 2024.

GALVE-GONZÁLEZ, C.; BERNARDO, A. B.; CASTRO-LÓPEZ, A. Understanding the dynamics of college transitions between courses: uncertainty associated with the decision to drop out studies among first and second year students. **European Journal of Psychology of Education**, v. 39, n. 2, p. 959–978, 2024. Disponível em: <https://doi.org/10.1007/s10212-023-00732-2>. Acesso em 8 set. 2024.

GENUER, Robin; POGGI, Jean-Michel; TULEAU-MALOT, Christine. Variable selection using random forests. **Pattern Recognition Letters**, v. 31, n. 14, p. 2225–2236, 2010.

GONÇALVES, T. C.; SILVA, J. C. da; CORTES, O. A. C. Técnicas de mineração de dados: um estudo de caso da evasão no ensino superior do Instituto Federal do Maranhão. **Revista Brasileira de Computação Aplicada**, v. 10, n. 3, p. 11–20, 2018. Disponível em: <https://doi.org/10.5335/rbca.v10i3.8427>. Acesso em 20 set. 2024.

GORE, Or; COHEN, Liron; RUBINSTEIN, Amir. Early prediction of student dropout in higher education using machine learning models. In: PAASSEN, B.; EPP, C. D. (eds.). **Proceedings of the 17th International Conference on Edu-**

**cational Data Mining. Atlanta: International Educational Data Mining Society**, 2024. p. 349–359. Disponível em: <https://doi.org/10.5281/zenodo.12729834>. Acesso em 6 out. 2024.

HENRIQUEZ CABEZAS, N.; VARGAS ESCOBAR, D. Predictive models of academic achievement and dropout of first year students of a Chilean public university. **Revista de Estudios y Experiencias en Educación**, v. 21, n. 45, p. 299–316, 2022.

HSU, Hui-Huang et al. Feature selection via correlation coefficient clustering. **Journal of Software**, v. 5, n. 12, p. 1371–1377, 2010.

INEP. Relatório do 5º ciclo de monitoramento das metas do Plano Nacional de Educação – 2024. 2. ed. Brasília, DF: **INEP**, 2024. 625 p. ISBN 978-65-5801-074-6 (impresso); 978-65-5801-071-5 (on-line).

INEP. Censo da Educação Superior, 2025. Disponível em: <https://app.powerbi.com/view?r=eyJrIjoiMGJiMmNiNTAtOTY1OC00ZjUzLTg2OGUtMjAzYzNiYTA5YjliIiwidCI6IjI2ZjczODk3LWM4YWMTNGI4ZS05NzhmLWVhNGMwNzc0MzRiZiJ9&pageName=ReportSection4036c90b8a27b5f58f54>. Acesso em: 5 set. 2025.

KE, G. et al. LightGBM: a highly efficient gradient boosting decision tree. **Advances in Neural Information Processing Systems**, 2017.

LI, J. et al. Feature selection: a data perspective. **ACM Computing Surveys**, v. 50, n. 6, 2017. Disponível em: <https://doi.org/10.1145/3136625>. Acesso em 10 fev. 2024.

LORENZO-QUILES, O.; GALDÓN-LÓPEZ, S.; LENDÍNEZ-TURÓN, A. Dropout at university: variables involved on it. **Frontiers in Education**, v. 8, 2023. Disponível em: <https://doi.org/10.3389/feduc.2023.1159864>. Acesso em 15 mar. 2024.

LUNDBERG, S. M.; LEE, S.-I. A unified approach to interpreting model predictions. **Advances in Neural Information Processing Systems**, v. 30, 2017.

MCNEMAR, Q. Note on the sampling error of the difference between correlated proportions or percentages. **Psychometrika**, v. 12, n. 2, p. 153–157, 1947.

MINHOTO, Maria Angélica; SMAILI, Soraya; ARANTES, Pedro. 2,3 milhões abandonaram curso superior em 2021. **Folha de São Paulo**, 23 fev. 2023. Disponível em: <https://www1.folha.uol.com.br/blogs/sou-ciencia/2023/02/23-milhoes-abandonaram-curso-superior-em-2021.shtml>. Acesso em: 15 fev. 2024.

NIYOGISUBIZO, Jovial et al. Predicting student's dropout in university classes using two-layer ensemble machine learning approach: a novel stacked generalization. **Computers and Education: Artificial Intelligence**, v. 3, p. 100066, 2022. Disponível em: <https://doi.org/10.1016/j.caeai.2022.100066>. Acesso em 15 set. 2024.

NOGUEIRA, C. M. M.; NONATO, B. F.; RIBEIRO, G. M.; FLONTINO, S. R. D. Promessas e limites: o Sisu e sua implementação na Universidade Federal de Minas Gerais. **Educação em Revista**, v. 33, 2017. Disponível em: <https://doi.org/10.1590/0102-4698161036>. Acesso em 15 out. 2024.

OECD. Education at a Glance 2022: OECD Indicators. Paris: **OECD Publishing**, 2022. Disponível em: <https://doi.org/10.1787/3197152b-en>. Acesso em 25 set. 2025.

PASCARELLA, Ernest T.; TERENSINI, Patrick T. Predicting freshman persistence and voluntary dropout decisions from a theoretical model. **The Journal of Higher Education**, v. 51, n. 1, p. 60–75, 1980.

PENG, H.; LONG, F.; DING, C. Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 27, n. 8, p. 1226–1238, 2005.

PEREZ, B.; CASTELLANOS, C.; CORREAL, D. Applying data mining techniques to predict student dropout: a case study. 2018.

SARA, Nicolae-Bogdan; HALLAND, Rasmus; IGEL, Christian; ALSTRUP, Stephen. High-school dropout prediction using machine learning: a Danish large-scale study. In: **Proceedings. ESANN 2015: 23rd European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning**, p. 319–324, 2015.

SCHUHARDT, Oscar Luiz et al. A evasão no ensino superior brasileiro na percepção dos alunos evadidos: motivos e fatores apontados nos estudos entre os anos de 2014 e 2023. **SIMPPA – Simpósio de Pós-Graduação e Pesquisa em Administração**, 4., 2024 p. 1–13. Disponível em: <https://ppa.uem.br/iv-simppa2024x/anais>. Acesso em: 25 nov. 2024.

SPADY, William G. Dropouts from higher education: an interdisciplinary review and synthesis. **Interchange**, v. 1, n. 1, p. 64–85, 1970.

SCHMOELLER, R.P.; PERON, V.D.; MESQUITA FILHO, W. Desempenho Pleiade, 19(49): 42-55, Out.-Dez., 2025 Acadêmico na Previsão da Evasão no Ensino Superior: Comparação entre Modelos Bagging, Boosting e Ensemble de Votação Majoritária. DOI: 10.32915/pleiade.v19i49.1195



- TETE, M. et al. Predictive models for higher education dropout: a systematic literature review. **Education Policy Analysis Archives**, v. 30, p. 149, 2022.
- TINTO, Vincent. Dropout from higher education: a theoretical synthesis of recent research. **Review of Educational Research**, v. 45, n. 1, p. 89–125, 1975.
- USP. USP desenvolve ferramenta para monitorar probabilidade de aluno não concluir o curso. **Jornal da USP**, São Paulo, 16 out. 2025. Disponível em: <https://jornal.usp.br/institucional/usp-desenvolve-ferramenta-para-monitorar-probabilidade-de-aluno-nao-concluir-o-curso/>. Acesso em: 2 nov. 2025.
- VAARMA, Matti; LI, Hongxiu. Predicting student dropouts with machine learning: an empirical study in Finnish higher education. **Technology in Society**, v. 76, p. 102474, 2024. Disponível em: <https://doi.org/10.1016/j.techsoc.2024.102474>. Acesso em: 15 mar. 2025.
- VILORIA, Amelec; LEZAMA, Omar Bonerge Pineda; VARELA, Noel. Bayesian classifier applied to higher education dropout. **Procedia Computer Science**, v. 160, p. 573–577, 2019.
- VILLAR, A.; DE ANDRADE, C. R. V. Supervised machine learning algorithms for predicting student dropout and academic success: a comparative study. **Discover Artificial Intelligence**, v. 4, n. 1, 2024. Disponível em: <https://doi.org/10.1007/s44163-023-00079-z>. Acesso em: 16 mar. 2025.
- WIRTH, Rüdiger; HIPPE, Jochen. CRISP-DM: towards a standard process model for data mining. **Proceedings of the 4th International Conference on the Practical Applications of Knowledge Discovery and Data Mining**, 2000. p. 29–39.
- YANG, S.; BERDINE, G. The receiver operating characteristic (ROC) curve. **The Southwest Respiratory and Critical Care Chronicles**, v. 5, n. 19, p. 34, 2017. Disponível em: <https://doi.org/10.12746/swrccc.v5i19.391>. Acesso em: 15 ago. 2025.



# Análise Comportamental de Textos Argumentativos em Sistemas Tutores Inteligentes: Estudo de Caso no Exército Brasileiro

*Behavioral Analysis of Argumentative Texts in Intelligent Tutoring Systems: A Case Study in the Brazilian Army*

Cláudia Rödel Bosaipo Sales da Silva<sup>1</sup>, Sarah Vitória Luiz Vanderei<sup>2</sup>, Alberto Sulaiman Sade Junior<sup>3</sup>, Ronaldo Ribeiro Goldschmidt<sup>4</sup>

1. Doutoranda de Engenharia de Defesa do Instituto Militar de Engenharia (PGED-IME). ORCID: [0000-0002-6694-6750](https://orcid.org/0000-0002-6694-6750). 2. Mestranda em Engenharia, Sistemas e Computação do Instituto Militar de Engenharia (PGSC-IME). ORCID: [0009-0006-5493-795x](https://orcid.org/0009-0006-5493-795x). 3. Pós-doutorando de Sistemas e Computação do Instituto Militar de Engenharia (PGSC-IME). ORCID: [0009-0007-3510-9531](https://orcid.org/0009-0007-3510-9531). 4. Doutor em Engenharia Elétrica. Docente do curso de Pós-Graduação de Engenharia de Defesa do IME. [0000-0003-1688-0586](https://orcid.org/0000-0003-1688-0586).  
[rodel.claudia@ime.eb.br](mailto:rodel.claudia@ime.eb.br)

## Palavras-chave

Aprendizagem Baseada em Competências  
Inteligência Artificial  
Modelos de Linguagem de Grande Porte  
Sistemas Tutores Inteligentes

## Keywords

Competency-Based Learning  
Artificial Intelligence  
Large-Scale Language Models  
Intelligent Tutoring Systems

## Resumo:

A Aprendizagem Baseada em Competências (AC) visa promover o desenvolvimento integrado dos conhecimentos, habilidades e atitudes dos alunos, todos essenciais para a prática profissional. Embora os Sistemas Tutores Inteligente (STI) tenham apoiado a AC, fornecendo instrução personalizada, a maioria das pesquisas nessa área tem se concentrado nas dimensões de conhecimento e habilidade, deixando a dimensão atitudinal amplamente inexplorada. Embora alguns estudos tenham investigado a inferência de atitudes e comportamentos a partir de dados não estruturados, como textos argumentativos, nenhum o fez no contexto dos STI aplicados à AC. Neste contexto, o presente estudo analisa os resultados preliminares do feedback comportamental gerado por Modelos de Linguagem de Grande Porte (LLM) com base em textos argumentativos escritos por alunos militares em um curso técnico de aviação oferecido pelo Exército Brasileiro. Os resultados sugerem que os LLM são promissores como possíveis ferramentas para apoiar a avaliação atitudinal em ambientes STI por meio da análise da escrita dos alunos.

## Abstract:

Competency-Based Learning (CBL) aims to foster the integrated development of students' knowledge, skills, and attitudes, all of which are essential for professional practice. Although Intelligent Tutoring Systems (ITS) have supported CBL by providing personalized instruction, most research in this area has focused on the knowledge and skill dimensions, leaving the attitudinal dimension largely unexplored. While some studies have investigated the inference of attitudes and behaviors from unstructured data, such as argumentative texts, none have done so within the context of ITS applied to CBL. In this context, the present study analyzes preliminary results of behavioral feedback generated by Large Language Models (LLM) based on argumentative texts written by military students in a technical aviation course offered by the Brazilian Army. The findings suggest that LLM hold promise as possible tools to support attitudinal assessment within ITS environments through the analysis of student writing.

Artigo recebido em: 15.10.2025.

Aprovado para publicação em: 07.11.2025.



## INTRODUÇÃO

A aprendizagem baseada em competências (AC) vai além da simples assimilação de conteúdos ao buscar desenvolver junto aos alunos, de forma integrada, as dimensões de Conhecimentos (o quê se conhece), Habilidades (o saber fazer) e Atitudes (o saber ser), essenciais à atuação profissional nos dias atuais (PERRENOUD, 1999). Essa perspectiva é sintetizada pelo acrônimo CHA, que destaca a interdependência dessas três dimensões na formação integral dos estudantes (ZABALA; ARNAU, 2020). Para potencializar essa abordagem, o uso de Tecnologias da Informação e Comunicação (TIC) tem se mostrado promissor (ELIAS et al., 2020; SANTIAGO et al., 2018; MELO, 2018). Entre elas, destacam-se os Sistemas Tutores Inteligentes (STI), que fazem uso de inteligência artificial (IA) para proporcionar um ensino personalizado (GAVIDIA; ANDRADE, 2003), podendo usar diferentes mídias, tais como textos (GRAESSER et al., 2004; SILVA et al., 2024), áudios (WOOLF, 2010), imagens (AZEVEDO et al., 2009) ou mapas mentais (SILVA et al., 2024).

A maior parte dos estudos sobre STI se concentra no desenvolvimento de conhecimentos e habilidades junto aos alunos. Em geral, a dimensão atitudinal é pouco explorada. Neste cenário, é comum o uso de informações estruturadas extraídas de ambientes virtuais de aprendizagem como, por exemplo, datas de entrega de atividades e acesso aos recursos computacionais oferecidos. Tais informações são utilizadas como insumos para inferir acerca de aspectos comportamentais, tais como pontualidade e engajamento (HECKMAN; KAUTZ, 2013; ANDRADE; DU, 2007). Por outro lado, embora existam trabalhos voltados à inferência de atitudes e comportamentos a partir de dados não estruturados como textos dissertativo-argumentativos (GILARDI; ALIZADEH; KUBLI, 2023; HENKLAIN; CARMO, 2013; IMAMOVIC et al., 2024; YU et al., 2024), nenhum deles investigou tal possibilidade no contexto de STI na AC.

Diante do exposto, o presente trabalho teve como objetivo analisar os resultados preliminares obtidos a partir de *feedbacks* sobre aspectos comportamentais inferidos por um STI na AC do EB, com base em textos dissertativo-argumentativos escritos por discentes. Obtidos a partir da aplicação de Modelos de Linguagem (LLMs), tais resultados foram comparados com os *feedbacks* providos por instrutores humanos a partir de interações presenciais junto aos discentes do estudo de caso realizado. Tal estudo envolveu um curso técnico da área de Aviação do Exército Brasileiro (EB). A escolha por um curso neste contexto deveu-se ao fato de que o EB trabalha com AC em seus cursos/estágios desde o ano de 2012 (Comando do Exército, 2012).

Também foi determinante para a escolha do referido curso, o fato de que os autores da pesquisa sobre o EBTutor, um STI na AC do EB, disponibilizaram, para fins de pesquisa e aprimoramento, o código fonte do sistema (SILVA et al., 2024). Os resultados preliminares obtidos no estudo de caso apontaram para o potencial dos LLMs, como ferramentas de apoio, que podem ser integradas ao STI na avaliação de atitudes e aspectos comportamentais dos discentes, a partir de textos discursivos, em ambientes educacionais.

Este artigo se encontra organizado em mais quatro seções. O EBTutor encontra-se resumido na Seção 2. A Seção 3 aborda a metodologia empregada no presente estudo, detalhando o protocolo adotado. A seguir, na Seção 4 são apresentados os experimentos e os resultados obtidos a partir da pesquisa realizada. As considerações finais são, por último, relatadas na Seção 5.

## EBTUTOR

O EBTutor é um sistema tutor inteligente, baseado na arquitetura WEB, para a AC do EB. Foi implementado como um *plugin*<sup>1</sup>, integrado ao ambiente virtual de aprendizagem da Instituição, o EBAula, e hospedado na intranet do EB (EBNet). Desenvolvido em PHP (ULLMAN, 2009), utilizou o *framework* Adianti (DALL’OGLIO, 2012) e adotou o PostgreSQL (MILANI, 2008).

A arquitetura do EBTutor foi projetada a partir de uma adaptação do modelo típico de um sistema de *feedback* automatizado, proposto por (DEEVA et al., 2021). Os componentes da arquitetura do EBTutor são apresentados na Figura 1 e resumidos a seguir. Mais detalhes sobre o EBTutor e seu funcionamento podem ser obtidos em (SILVA et al., 2024).

**Modelo do Domínio:** Responsável por organizar o conhecimento de uma determinada área de estudo, sendo composto por três elementos principais. O primeiro é o conjunto de assuntos a serem aprendidos, definidos conforme os conteúdos da área em questão. Para cada assunto, o modelo inclui o conjunto de habilidades que o aluno deve desenvolver. Além disso, o Modelo de Domínio contempla um conjunto ordenado de questionários, com itens com respostas do tipo múltipla-escolha ou dissertativas. Estes avaliam tanto o domínio de conceitos quanto a capacidade de execução de habilidades específicas exigidas para sua resolução. Cabe ressaltar que, conforme (SILVA et al., 2024), o EBTutor se concentra nas dimensões de conhecimentos e habilidades, caracterizando sua limitação quanto à dimensão atitudinal.

**Modelo do Aluno:** Componente responsável por registrar o histórico de evidências de aprendizagem de cada aluno ao longo da trajetória formativa. Considera-se evidência de aprendizagem qualquer informação fornecida pelo aluno diretamente ao sistema, como respostas a questionários ou postagens em fóruns, além de dados observados a partir das interações com as plataformas, como frequência de acesso e cumprimento de prazos.

**Modelo de *Feedback* Automatizado:** Responsável por gerenciar todas as interações entre o aluno e o EBTutor. Sempre que deseje, o aluno pode solicitar um *feedback* indicando o questionário sobre o qual deseja receber informações. A partir dessa solicitação, o EBTutor consulta o EBAula para obter as evidências de aprendizagem necessárias à formulação do *feedback*, enviando-as para o modelo de Geração de *Feedback*.


**Modelo de Geração de *Feedback*:** Elabora o *feedback* a ser fornecido ao aluno, com base em uma solicitação feita após a realização de um questionário no EBAula. No que diz respeito aos conhecimentos e habilidades, o modelo analisa as respostas fornecidas pelo aluno a cada item do questionário. Caso o aluno necessite de auxílio, o modelo identifica os conceitos necessários, bem como as habilidades que deveriam ser dominadas. Com essas informações, o *feedback* é construído fornecendo orientações de estudo, incluindo os conceitos e habilidades relacionados, com o objetivo de ajudar o aluno a superar suas dificuldades. Após sua geração, o *feedback* é encaminhado ao Modelo de *Feedback* Automatizado, que o apresenta ao aluno. É neste modelo que podem ser incorporados os LLMs. Diferente dos demais *feedbacks* (conhecimentos e habilidades) providos pelo EBTutor, os *feedbacks* sobre os aspectos comportamentais podem ser dados com o apoio dos LLM, ao analisar as respostas discursivas na forma dissertativa-argumentativa.

**Modelo Pedagógico:** O Modelo Pedagógico é o componente do EBTutor que incorpora o conhecimento pedagógico necessário à avaliação da aprendizagem e à formulação de *feedbacks* personalizados para os alunos. Para tanto, fundamenta-se em abordagens educacionais como, por exemplo, o *Feedback-Based Learning* (HATTIE; TIMPERLEY, 2007).

## METODOLOGIA

O estudo de caso foi realizado em curso da Aviação do EB, na disciplina “Liderança e Gestão”, ofertada para 14 alunos militares. O curso tem como objetivo desenvolver nos discentes militares atitudes e valores tais quais: Comunicação, Decisão, Responsabilidade e Coragem Moral. Vale a pena ressaltar, no estudo de caso realizado, os *feedbacks* não foram fornecidos aos alunos. Eles foram gerados, analisados e comparados com as avaliações providas pelos instrutores humanos. Tal decisão foi tomada para preservar os discentes, evitando expô-los a possíveis alucinações e resultados indesejáveis gerados pelos modelos de linguagem.

Figura 1: Visão Macro-Funcional do EBTutor.



Fonte (SILVA et al., 2024). Arquitetura do EBTutor

O LLM aplicado no estudo de caso foi o ChatGPT 4.0, escolhido por sua capacidade de identificar padrões linguísticos que podem indicar traços comportamentais e atitudes (PETERS; MATZ, 2024). Além disso, este LLM demonstrou familiaridade com o contexto da AC (MICHALON; CAMACHO-ZUÑIGA, 2023), o que o torna apto a aprender os princípios das *Normas para Desenvolvimento e Avaliação dos Conteúdos Atitudinais* (NDACA)<sup>2</sup>, empregadas no EB (Departamento de Educação e Cultura do Exército, 2019).

Assim sendo, o LLM escolhido teve condições de interpretar e classificar os padrões comportamentais/atitudinais dos alunos, por meio dos textos dissertativos por eles produzidos. O processo envolveu a elaboração de uma metodologia estruturada em 5 (cinco) fases descritas a seguir:

**Fase 1 - Estruturação e Preparação do Corpus.** Os dados brutos, compostos pelas respostas abertas dos 14 estudantes militares a oito perguntas do curso de “Liderança e Gestão”, foram estruturados e preparados. As respostas foram reorganizadas em um formato com identificadores anônimos (*'userid'*, *'coluna'* e *'response-text'*) para garantir a análise adequada pelo LLM, respeitando a LGPD.

**Fase 2 - Mapeamento de Avaliação Humana.** Paralelamente, dois avaliadores experientes avaliaram de forma independente as atitudes dos alunos com base na observação longitudinal e na interação presencial durante o curso. Cada avaliador atribuiu pontuações de 1,0 a 10,0 para quatro construtos: Comunicação, Decisão, Responsabilidade (atitudes) e Coragem Moral (valor). Devido à alta qualidade do desempenho dos alunos, as pontuações se concentraram entre 8,0 e 10,0. As avaliações foram registradas em planilhas separadas para comparação posterior.

**Fase 3 - Engenharia de Prompt e configuração do LLM.** Foram desenvolvidos dois *prompts zero-shot* para o GPT-4, baseados nas descrições do NDACA: um para o valor Coragem Moral e outro focado nas três atitudes. Cada *prompt* foi estruturado para obter uma única pontuação por construto para cada aluno, com resultados em formato tabular ordenado por *'userId'*. Para assegurar a independência total entre as análises humanas e da máquina, o LLM analisou apenas as respostas textuais, sem acesso a dados de treinamento ou avaliações humanas.

**Fase 4 - Execução, calibração e mapeamento conceitual do LLM.** Os *prompts* foram executados e os resultados iniciais revelaram maior dispersão do que nas avaliações humanas, o que levou a um processo de recalibração. Para garantir a comparabilidade, os *prompts* foram ajustados para restringir os resultados do modelo em um intervalo mais focado - de 8,0 a 10,0, melhorando a consistência da pontuação e o alinhamento com a distribuição observada.

Após a geração da pontuação, os resultados foram normalizados e mapeados em três faixas conceituais para melhorar a interpretabilidade e apoiar a comparação categórica entre os avaliadores: A (9,3–10,0): Excelente alinhamento atitudinal / B (8,6–9,2): Desempenho bom, mas não excelente / C (8,0–8,5): Expressão satisfatória, mas limitada.

**Fase 5 - Estruturação dos resultados.** A fase final concentrou-se na consolidação dos dados da avaliação em formatos estruturados para apoiar a análise comparativa apresentada na próxima seção. Foram produzidas duas tabelas de resumo para refletir a natureza dupla dos resultados da avaliação: Tabela 1, que exibe as pontuações numéricas brutas atribuídas pelo Avaliador Humano 1 (H1), Avaliador Humano 2 (H2) e LLM para cada um dos quatro construtos; e Tabela 2, que apresenta os mesmos dados em um formato discretizado, usando o *framework* conceitual A-B-C.

Para promover a rastreabilidade e a consistência na interpretação dos resultados entre dimensões e avaliadores, os cabeçalhos das colunas seguem o formato X-Y, em que X denota o construto e Y identifica o avaliador.

Tabela 1: Pontuações numéricas brutas atribuídas pelos Avaliadores Humanos 1 e 2 e o LLM

Aluno	C-H1	C-H2	C-LLM	D-H1	D-H2	D-LLM	R-H1	R-H2	R-LLM	MC-H1	MC-H2	MC-LLM
1	10,00	9,00	8,70	9,67	9,67	8,40	10,00	10,00	9,20	9,67	9,67	8,70
2	10,00	9,33	9,90	9,80	9,80	8,40	10,00	9,00	8,10	9,67	9,67	9,90
3	9,33	10,00	9,50	9,50	9,50	8,60	9,33	10,00	9,20	9,67	9,67	9,50
4	10,00	10,00	9,20	9,67	9,67	9,00	9,33	8,67	8,30	10,00	10,00	9,20
5	9,67	10,00	8,30	9,33	9,33	8,90	9,33	10,00	8,10	10,00	10,00	8,30
6	9,00	10,00	8,30	9,50	9,50	8,60	10,00	10,00	9,90	9,50	9,50	8,30
7	10,00	9,33	8,10	9,67	9,67	9,20	10,00	9,33	9,90	9,67	9,67	8,10
8	9,67	9,67	9,70	9,67	9,67	8,30	9,33	10,00	9,60	10,00	10,00	9,70
9	9,00	8,67	9,20	8,50	8,50	8,60	10,00	10,00	8,60	9,50	9,50	9,20
10	10,00	9,00	9,40	9,67	9,67	8,70	10,00	10,00	8,20	9,67	9,67	9,40
11	9,33	10,00	8,00	9,67	9,67	8,90	9,33	10,00	9,40	9,67	9,67	8,00
12	10,00	9,33	9,90	9,50	9,50	9,60	10,00	9,67	8,90	9,67	9,67	9,90
13	9,67	10,00	9,70	9,50	9,50	8,40	9,33	10,00	8,20	10,00	10,00	9,70
14	10,00	10,00	8,40	9,67	9,67	9,00	9,67	9,00	9,00	9,67	9,67	8,40

Tabela 2: Dados discretizados nas categorias A–B–C

Aluno	C-H1	C-H2	C-LLM	D-H1	D-H2	D-LLM	R-H1	R-H2	R-LLM	MC-H1	MC-H2	MC-LLM
1	A	B	B	A	A	C	A	A	B	A	A	B
2	A	A	A	A	A	C	A	B	C	A	A	A
3	A	A	A	A	A	B	A	A	B	A	A	A
4	A	A	B	A	A	B	A	B	C	A	A	B
5	A	A	C	A	A	B	A	A	C	A	A	C
6	B	A	C	A	A	B	A	A	A	A	A	C
7	A	A	C	A	A	B	A	A	A	A	A	C
8	A	A	A	A	A	C	A	A	A	A	A	A
9	B	B	B	C	C	B	A	A	B	A	A	B
10	A	B	A	A	A	B	A	A	C	A	A	A
11	A	A	C	A	A	B	A	A	A	A	A	C
12	A	A	A	A	A	A	A	A	B	A	A	A
13	A	A	A	A	A	C	A	A	C	A	A	A
14	A	A	C	A	A	B	A	B	B	A	A	C


## RESULTADOS E DISCUSSÃO

Esta seção está organizada em duas subseções. A primeira compara as pontuações dos avaliadores numericamente, e a segunda analisa a concordância com base nas categorias conceituais.

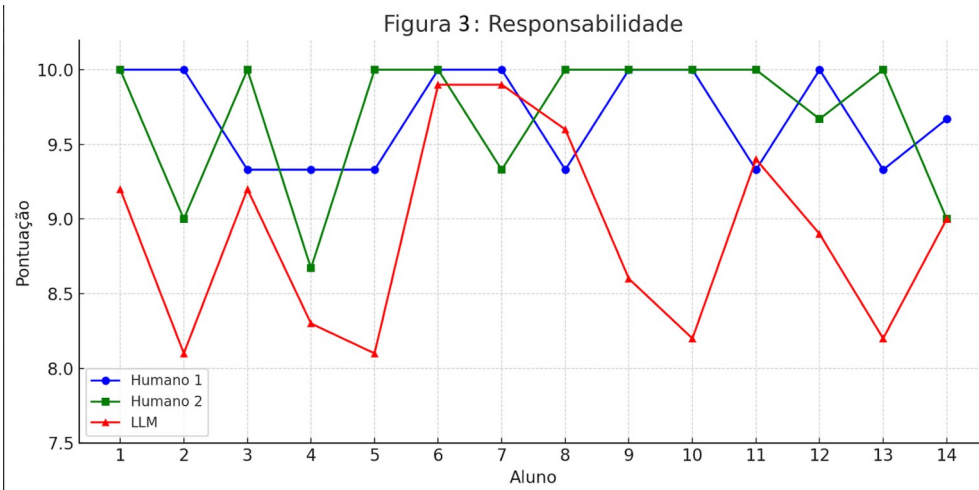
### COMPARAÇÃO DO NÍVEL DE PONTUAÇÃO

As Figuras 2 a 5 mostram as tendências das pontuações dos alunos para cada construto. Os avaliadores Humanos são mostrados em azul e verde e o LLM em vermelho.

A Figura 2 (Comunicação) revela um alinhamento próximo entre os dois avaliadores humanos, com pontuações altas e estáveis. O LLM atribui pontuações mais baixas em geral, especialmente para os alunos 1, 5, 6, 7 e 11, demonstrando um padrão de pontuação mais conservador.



A Figura 3 (Responsabilidade) ilustra forte alinhamento entre os avaliadores humanos, enquanto o LLM diverge em vários casos, notadamente para os alunos 2, 4, 5 e 13, aos quais atribui pontuações mais baixas.




A Figura 4 (Coragem Moral) confirma uma alta concordância entre os seres humanos e destaca a tendência do LLM de obter pontuações mais baixas, particularmente para os alunos 1, 5, 7 e 11.

Em suma, as Figuras 2 e 3 ilustram graficamente os resultados apresentados na Tabela 1. Para quantificar essas relações, foram calculados os coeficientes de correlação de *Pearson* entre os três avaliadores. A Tabela 3 apresenta esses coeficientes por dimensão. Como esperado, as correlações mais fortes ocorrem entre o Humano 1 e o Humano 2. Em contrapartida, as correlações entre o LLM e os avaliadores humanos são geralmente baixas, sugerindo uma concordância linear limitada.

Tabela 3: Coeficientes de correlação de Pearson por construto

Dimensão	H1 vs H2	H1 vs LLM	H2 vs LLM
Comunicação	-0,134	0,202	-0,251
Decisão	1	0,04	0,04
Responsabilidade	-0,06	0,129	0,202
Coragem Moral	1	0,22	0,22

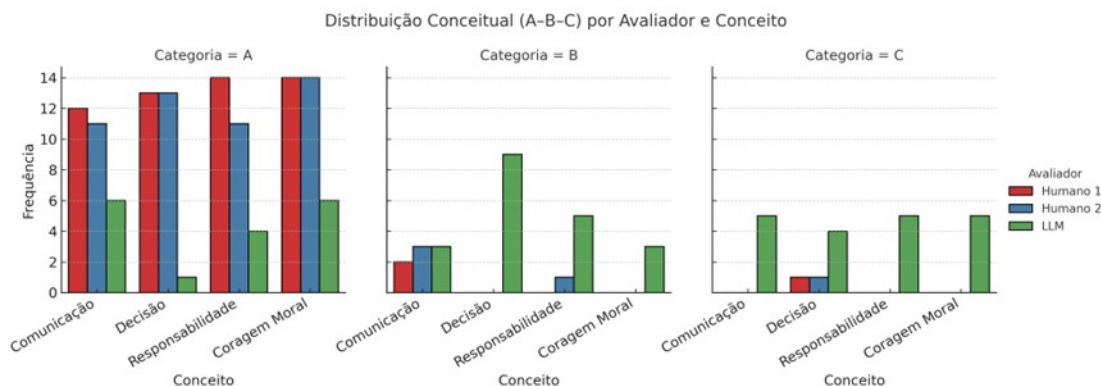
Esses resultados destacam uma diferença metodológica fundamental entre a avaliação baseada em observação e a avaliação baseada em texto. Enquanto os avaliadores humanos mostram alta consistência — particularmente em construções com expressão comportamental clara — o LLM demonstra maior variabilidade e uma tendência para pontuações médias.



### COMPARAÇÃO EM NÍVEL CONCEITUAL (A-B-C)

Para facilitar a comparação categórica, as pontuações originais foram transformadas em níveis conceituais usando o esquema A-B-C descrito na Seção 3: A Figura 5 apresenta a distribuição das etiquetas conceituais entre os quatro constructos. Os avaliadores humanos mostram forte convergência nas categorias A e B, particularmente em Decisão e Coragem Moral. O LLM, em contraste, favorece as categorias B e C, reforçando seu comportamento conservador na pontuação.

Figura 5: Distribuição conceitual (A-B-C) por avaliador e construto



Para avaliar a concordância categórica, calculamos a porcentagem de alunos aos quais cada par de avaliadores atribuiu o mesmo conceito, conforme ilustrado na Tabela 4. Observou-se concordância total entre os avaliadores humanos em Decisão e Coragem Moral. A concordância entre o LLM e qualquer um dos avaliadores humanos foi consistentemente menor, particularmente em Comunicação e Responsabilidade.

Tabela 4: Concordância entre avaliadores (%) por categoria conceitual

Dimensão	H1 = H2	H1 = LLM	H2 = LLM	% H1 = H2	% H1 = LLM	% H2 = LLM
Comunicação	11	7	7	78,6	50	50
Decisão	14	1	1	100	7,1	7,1
Responsabilidade	11	4	5	78,6	28,6	35,7
Coragem Moral	14	6	6	100	42,9	42,9

Esses resultados indicam que, embora o LLM possa se aproximar das categorizações humanas em determinados contextos, particularmente em conceitos como Responsabilidade, que são mais baseados no comportamento, ele apresenta limitações perceptíveis em domínios que exigem sensibilidade afetiva ou raciocínio moral.

## CONSIDERAÇÕES FINAIS

Foi identificada uma carência de estudos quanto à inferência de atitudes e comportamentos discente a partir de dados não estruturados, como textos argumentativos, especialmente no contexto de Sistemas Tutores Inteligentes aplicados à Aprendizagem Baseada em Competências.

Diante desse cenário, este artigo apresentou os resultados preliminares obtidos a partir da análise de textos dissertativos-argumentativos escritos por alunos de um curso técnico da área de Aviação do EB. A análise foi conduzida por meio do Modelo de Linguagem ChatGPT 4.0, e seus resultados foram comparados com os *feedbacks* elaborados por instrutores humanos, que acompanharam presencialmente os discentes ao longo do curso. Cabe destacar que foi utilizado o referencial NDACA como base normativa para ambas as avaliações.

O LLM demonstrou ser ferramenta promissora de apoio à avaliação formativa, ao gerar *feedbacks* personalizados e contextualizados, sem a identificação de alucinações. Os resultados revelaram um padrão conservador nas respostas, indicando robustez suficiente para sua incorporação junto aos STIs. Como sua contribuição principal, este estudo pode demonstrar a viabilidade da utilização de LLM para inferência de atitudes, a partir da produção escrita dos alunos.

Atualmente, estão sendo realizados experimentos para integrar os LLMs aos STIs que forneçam *feedback* em tempo real aos alunos. Paralelamente, está em andamento a coleta das percepções dos estudantes sobre a utilidade e eficácia desses *feedbacks*, visando validar e aprimorar o modelo.

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível superior - Brasil (CAPES) - Código de financiamento 001 (bolsa de mestrado - proc. 88887.196477/2025-00).

## NOTAS

1. Software que adiciona funcionalidade específica a programa ou sistema maior.
2. Estas Normas se destinam aos cursos e estágios gerais das Linhas de Ensino Militar Bélico, Complementar e de Saúde, realizados nos Estabelecimentos de Ensino (Estb Ens) e Organizações Militares (OM) com encargos de ensino subordinados e/ou vinculados ao Departamento de Educação e Cultura do Exército (DECEX), com exceção da Diretoria de Educação Preparatória e Assistencial (DEPA), com legislação própria.

## REFERÊNCIAS

- ANDRADE, H.; DU, Y. Student responses to criteria-referenced self-assessment. *Assessment & evaluation in higher education*, **Taylor & Francis**, v. 32, n. 2, p. 159–181, 2007.
- AZEVEDO, R. et al. **Metatutor**: A metacognitive tool for enhancing self-regulated learning. In: *AAAI fall symposium: Cognitive and metacognitive educational systems*. [S.l.: s.n.], 2009. p. 14–19.
- SILVA, C.R.B.S. et al. Análise Comportamental de Textos Argumentativos em Sistemas Tutores Inteligentes: Estudo de Caso no Exército Brasileiro. *Pleiade*, 19(49): 56-64, Out.-Dez., 2025  
DOI: 10.32915/pleiade.v19i49.1197



COMANDO DO EXÉRCITO. **Portaria nº 137**, de 28 de fevereiro de 2012: Aprova a Diretriz para o Projeto de Implantação do Ensino por Competências no Exército Brasileiro. 2012. Disponível em: <https://www.eb.mil.br> [Acesse conforme aplicável]. Publicado no Diário Oficial da União, 2012.

DALL'OGGIO, P. **Adianti framework para php**. Lajeado: Edição do autor, 2012.

DEEVA, G. et al. A review of automated feedback systems for learners: Classification framework, challenges and opportunities. **Computers & Education**, Elsevier, v. 162, p. 104094, 2021.

DEPARTAMENTO DE EDUCAÇÃO E CULTURA DO EXÉRCITO. **Normas para Desenvolvimento e Avaliação de Conteúdos Atitudinais**. 2019. EB60-N-05.013.

ELIAS, A. et al. Avaliar: **Sistema para autoria e acompanhamento de recursos avaliativos**. In: SBC. *Simpósio Brasileiro de Sistemas Multimídia e Web (WebMedia)*. [S.l.], 2020. p. 97–101.

GAVIDIA, J. J. Z.; ANDRADE, L. C. V. d. **Sistemas tutores inteligentes**. *Trabalho de Conclusão da Disciplina de IA, Universidade Federal do Rio de Janeiro*. Rio de Janeiro–RJ: UFRJ, 2003.

GILARDI, F.; ALIZADEH, M.; KUBLI, M. Chatgpt outperforms crowd workers for text-annotation tasks. *Proceedings of the National Academy of Sciences*, **National Academy of Sciences**, v. 120, n. 30, p. e2305016120, 2023.

GRAESSER, A. C. et al. Autotutor: A tutor with dialogue in natural language. **Behavior Research Methods, Instruments, & Computers**, Springer, v. 36, n. 2, p. 180–192, 2004.

HATTIE, J.; TIMPERLEY, H. The power of feedback. **Review of educational research**, Sage Publications Sage CA: Thousand Oaks, CA, v. 77, n. 1, p. 81–112, 2007.

HECKMAN, J. J.; KAUTZ, T. **Fostering and measuring skills**: Interventions that improve character and cognition. National Bureau of economic research, 2013.

HENKLAIN, M. H. O.; CARMO, J. d. S. Contributions of behavior analysis to education: an invitation for dialogue. **Cadernos de Pesquisa**, SciELO Brasil, v. 43, p. 704–723, 2013.

IMAMOVIC, M. et al. **Using chatgpt for annotation of attitude within the appraisal theory**: Lessons learned. In: *Proceedings of The 18th Linguistic Annotation Workshop (LAW-XVIII)*. [S.l.: s.n.], 2024. p. 112–123.

MELO, G. A. M. S. **Ballgorithm** - uma ferramenta introdutória para conceitos de programação. Universidade Federal do Maranhão, 2018.

MICHALON, B.; CAMACHO-ZUÑIGA, C. Chatgpt, a brand-new tool to strengthen timeless competencies. In: FRONTIERS MEDIA SA. **Frontiers in Education**. [S.l.], 2023. v. 8, p. 1251163.

MILANI, A. **Postgresql-guia do programador**. [S.l.]: Novatec Editora, 2008.

PERRENOUD, P. Construir competências é virar as costas aos saberes. **Revista Pátio**, Porto Alegre: ARTMED, ano, v. 3, p. 15–19, 1999.

PETERS, H.; MATZ, S. C. Large language models can infer psychological dispositions of social media users. **PNAS nexus**, Oxford University Press US, v. 3, n. 6, p. pgae231, 2024.

SANTIAGO, J. M. S. et al. **Mathquiz**: A game app for m-learning. In: SBC. *Simpósio Brasileiro de Sistemas Multimídia e Web (WebMedia)*. [S.l.], 2018. p. 69–72.

SILVA, C. S. da et al. Ebtutor: **Uma proposta de sistema tutor inteligente na aprendizagem baseada em competências no exército brasileiro**. In: SBC. *Simpósio Brasileiro de Informática na Educação (SBIE)*. [S.l.], 2024. p. 1674–1688.

ULLMAN, L. **PHP for the Web: Visual QuickStart Guide**. [S.l.]: Peachpit Press, 2009.

WOOLF, B. P. **Building intelligent interactive tutors: Student-centered strategies for revolutionizing e-learning**. [S.l.]: Morgan Kaufmann, 2010.

YU, D. et al. Assessing the potential of llm-assisted annotation for corpus-based pragmatics and discourse analysis: The case of apology. **International Journal of Corpus Linguistics**, John Benjamins Publishing Company Amsterdam/Philadelphia, v. 29, n. 4, p. 534–561, 2024.

ZABALA, A.; ARNAU, L. **Métodos para ensinar competências**. [S.l.]: Penso Editora, 2020.



# Integrando Coleta e Mineração de Dados sobre Uso de Jogos Educacionais Digitais para Capacitação Discente na Identificação de *Fake News* em Português

*Integrating Data Collection and Mining on the Use of Digital Educational Games for Student Training in Identifying Fake News in Portuguese*

Angelo C. S. Paolino<sup>1</sup>, Cláudia Rödel Bosaipo Sales da Silva<sup>2</sup>, Isabel Fernandes<sup>3</sup>, Cláudio Passos<sup>4</sup>, Paulo Cesar Coelho<sup>5</sup> e Ronaldo R. Goldschmidt<sup>6</sup>

1. Cientista da Computação. Mestrando em Sistemas e Computação pelo Instituto Militar de Engenharia (IME). ORCID: <https://orcid.org/0009-0001-3394-5444>. 2. Mestre em Engenharia de Sistemas e Computação pela UFRJ. Doutora de Engenharia de Defesa do Instituto Militar de Engenharia (PGED-IME). ORCID: <https://orcid.org/0000-0002-6694-6750>. 3. Doutora em Ciências pelo Programa de Pós-graduação em Engenharia de Produção da COPPE/UFRJ. Coordenadora do Projeto JEDi Educa. ORCID: <https://orcid.org/0000-0002-6906-5756>. 4. Doutor pela UFRJ em Algoritmos Complexos. Pós-doutorado em Inteligência Computacional e Jogos no Instituto Militar de Engenharia (IME). ORCID: <https://orcid.org/0000-0001-7508-6070>. 5. PhD em Systèmes Informatiques pela Université Paris Sorbonne. Consultor em Produtos Inovadores no Projeto JEDi Educa. 6. Doutor pela PUC-RJ em Engenharia Elétrica em Métodos de Apoio à Decisão. Atua como docente em instituições públicas no Brasil. ORCID: <https://orcid.org/0000-0003-1688-0586>.

[rodel.claudia@ime.eb.br](mailto:rodel.claudia@ime.eb.br) ; [profa.isabel.fernandes@gmail.com](mailto:profa.isabel.fernandes@gmail.com) e [ronaldo.rgold@ime.eb.br](mailto:ronaldo.rgold@ime.eb.br)

## Palavras-chave

Educação digital  
Fake news  
Jogos educacionais digitais  
Mineração de dados

## Keywords

Digital education  
Fake news  
Digital educational games  
Data mining

## Resumo:

O uso de jogos educacionais digitais (JED) para capacitação discente na identificação de *Fake News* tem se mostrado promissor. Entretanto, reunir dados sobre a utilização dos JED para buscar padrões que auxiliem neste tipo de capacitação é uma tarefa que exige conhecimento técnico para manipulação e análise desses dados, além de ser sujeita a falhas que podem ocorrer mediante o uso de ferramentas como planilhas e softwares de análises de dados. Assim sendo, este artigo propõe um módulo de mineração automática de dados sobre o comportamento de alunos no uso do JEDi, um jogo voltado à capacitação na identificação de *Fake News* escritas em Língua Portuguesa. O módulo foi integrado à base do JEDi, permitindo mineração de dados com reduzida intervenção humana. Um estudo de caso com três turmas do ensino médio evidenciou a adequação do módulo proposto.

## Abstract:

The use of digital educational games (DEG) to train students in identifying *Fake News* has shown promising results. However, collecting and analyzing data on DEG usage to identify patterns that support misinformation combat is a task that requires technical expertise in data handling and analysis. This paper proposes a module for the automatic mining of data on student behavior while using JEDi, a game designed to combat misinformation written in Portuguese. The module was integrated into the JEDi database, enabling data mining with reduced human intervention. A case study involving three high school classes demonstrated the adequacy of the proposed module. Keywords: educational games; data mining; fake news; digital education.

Artigo recebido em: 15.10.2025.

Aprovado para publicação em: 07.11.2025.

## INTRODUÇÃO

O crescimento do volume das *Fake News* (i.e., notícias falsas divulgadas propositalmente) nos diferentes meios digitais de divulgação de notícias tem preocupado os mais diversos segmentos sociais. Entre as principais iniciativas de combate a este tipo nocivo de notícia estão as ações de conscientização e capacitação da sociedade para identificar *Fake News* e, com isso, evitar sua propagação. Alinhados com a recomendação da UNESCO (UNESCO 2019), diversos jogos educacionais digitais (JED) voltados à capacitação de pessoas para identificar *Fake News* têm sido desenvolvidos e aplicados sobretudo junto a jovens estudantes do ensino médio no Brasil e no mundo (Passos et al. 2020), (Passos et al. 2021) e (Moreira et al. 2023).

Neste cenário, uma das principais questões de pesquisa em aberto diz respeito à avaliação do quanto a utilização dos JED favorece o aprendizado dos alunos (Colpani e Faria 2017). Diversos trabalhos voltados à investigação desta questão já foram desenvolvidos (Victal e Menezes 2015), (Ramos 2013), (Silva e Pires 2017) e (Cotonhoto e Rossetti 2016). A maioria deles consiste em estudos de caso onde o desempenho dos discentes é avaliado a partir da análise do comportamento dos alunos durante a utilização dos JED (e.g., tempo de exposição ao jogo, quantidades de notícias analisadas, erros e acertos, dentre outros) (Colpani e Faria 2017) e (Santos e Junior 2016).

Não raro, o pesquisador se encarrega de reunir em planilhas eletrônicas os dados de utilização do jogo e de rendimento acadêmico dos alunos a fim de realizar suas análises em busca de correlações. Em geral, a consolidação de dados é uma tarefa recorrente que demanda uma combinação de ações por parte do pesquisador e que, por ser realizada com intervenção humana, está sujeita a falhas (Victal e Menezes 2015), (Colpani e Faria 2017) e (Santos e Junior 2016).

Neste mesmo contexto, apesar do histórico de uso bem sucedido de JED na tarefa de formação de pessoas no reconhecimento de notícias falsas, o estudo do comportamento dos jogadores diante deste tipo de notícia em busca de padrões que auxiliem nesse combate é uma tarefa que exige conhecimento técnico para manipulação e análise desses dados, além de ser sujeita a falhas que podem ocorrer mediante o uso de ferramentas como planilhas e softwares de análises de dados.

Assim sendo, o presente artigo tem como objetivo propor um módulo que minimiza a intervenção humana no processo de coleta e análise de dados sobre o comportamento de alunos na utilização do JEDi, um JED para capacitação discente na identificação de *Fake News* escritas em Língua Portuguesa. Apresentado em (Passos et al. 2020) e (Passos et al. 2021), o JEDi foi escolhido como JED piloto para a pesquisa em desenvolvimento devido ao fato de que é um jogo em Língua Portuguesa cujo código fonte foi disponibilizado por seus autores, mediante solicitação. Alinhado com o modelo relacional adotado pelo JEDi, o módulo proposto foi desenvolvido e integrado à base de dados do JED de forma a permitir a realização automática de mineração dos dados sobre o comportamento de alunos de várias turmas ao utilizar o jogo. Denominado *MMD*, o referido módulo incorpora diferentes consultas que podem ser realizadas por diferentes níveis de granularidade (e.g., aluno, turma ou escola, por exemplo). Permite ainda a mineração de regras de associação (i.e. padrões) frequentes e válidas no conjunto de dados completo ou segmentado por nível de granularidade. A fim de comprovar a aplicabilidade do JEDi + *MMD* (i.e., JEDi integrado ao *MMD*), foi realizado um estudo de caso envolvendo três turmas de uma escola pública de ensino médio. Resultados do estudo ilustram tanto a adequação do módulo proposto quanto a efetividade do JED em contribuir para a formação de jovens para enfrentamento da desinformação.

Este artigo está organizado em mais cinco seções. A Seção I. apresenta os principais trabalhos sobre ferramentas educacionais de apoio à identificação de *Fake News*. A Seção II. resume as principais característi-

cas do JEDi. A Seção III. apresenta o módulo proposto e detalhes sobre o protótipo implementado. Os resultados do estudo de caso realizado com a aplicação do JEDi + MMD estão descritos na Seção IV. A Seção V. apresenta as considerações finais sobre os resultados e aponta para iniciativas de trabalhos futuros.

## I. TRABALHOS RELACIONADOS

A pesquisa por trabalhos relacionados ao presente estudo foi realizada nas seguintes bases: Scopus Elsevier, IEEE Xplore Digital Library, ERIC, Web of Science, Cambridge e EBSCO, com a *string* de busca indicada no Quadro 1.

Quadro 1 – *String* de busca utilizada

(“game based learning” OR “educational games”) AND  
 (“data mining” OR “data analysis” OR “knowledge discovery in data”)  
 AND (disinformation OR misinformation OR “fake news” OR “false information”)

Foram recuperados trinta e dois trabalhos. Após análise de títulos, resumos e palavras-chave, dezessete foram descartados por duplicação ou falta de relevância. Os quinze trabalhos restantes foram lidos e organizados em dois grupos. No primeiro estão os trabalhos voltados ao apoio educacional no combate às *Fake News* (Francesco e Leone 2020), (Auberry 2018), (Musgrove et al. 2018), (Nascimento 2020). Nenhum deles utilizou JED. O segundo grupo contém onze trabalhos que, assim como o presente estudo, utilizaram JED como ferramentas educacionais para o desenvolvimento da capacidade crítica das pessoas para identificação de notícias falsas. Esses trabalhos foram comparados, conforme descrito na Tabela 1, segundo os seguintes critérios: idioma português, incluindo as notícias (POR), base atualizável (BDA), e, se oferece suporte para mineração de dados automatizada (MDA). A seguir esses trabalhos estão resumidos.

Tabela 1 – Comparação entre trabalhos relacionados.

Jogos	POR	BDA	MDA
Bad News (ROOZENBEEK; LINDEN, 2019)	X		
BBC IReporter (JUNIOR, 2020)			
Factitious (JUNIOR, 2020)			
News Feed Defender (JUNIOR, 2020)			
Fake It to Make It (URBAN; HEWITT; MOORE, 2018)			
Escape the Fake (PARASCHIVOIU et al., 2021)		X	
The Fake News Detective (JUNIOR, 2020)		X	
Trustme! (YANG et al., 2021)		X	
MAThE the Game (KATSAOUNIDOU et al., 2019)	X		
Cheque Isso (ABREU; BERWANGER; COSTA, 2018)	X		
JEDi (PASSOS et al., 2021; MOREIRA et al., 2023)	X	X	
JEDi + MMD (Módulo de Mineração de Dados)	X	X	X

Baseado na teoria da inoculação, o jogo ‘*Bad News*’ visa familiarizar os jogadores com táticas de geração de desinformação, incentivando-os a se tornarem criadores de *fake news* (Roozenbeek e Linden 2019). Já o ‘*BBC IReporter*’ permite que os jogadores atuem como jornalistas de mídia social, estimulando a avaliação crítica das notícias antes de compartilhá-las (Junior 2020). Embora promova a conscientização sobre a confiabilidade das fontes, não é centrado na identificação de *fake news*. Nenhum dos dois jogos está disponível em português. Da mesma forma, o ‘*Factitious*’ apresenta notícias aos jogadores, desafiando-os a determinar

se são verdadeiras ou falsas (Junior 2020). Focado no desenvolvimento do pensamento crítico, o jogo oferece diferentes níveis de dificuldade. Outros trabalhos como o ‘*News Feed Defender*’ (Junior 2020), ‘*Fake It to Make It*’ (Urban, Hewitt e Moore 2018), e ‘*Escape the Fake*’ (Paraschivoiu et al. 2021), também contribuem para a compreensão do cenário atual de jogos educacionais voltados para a identificação de desinformações. Nenhum deles está disponível em Língua Portuguesa. Enquanto, o jogo ‘*The Fake News Detective*’ (Junior 2020) utiliza a pedagogia do pensamento crítico para ensinar os jogadores a identificar *Fake News*, o ‘*Trust-me!*’ (Yang et al. 2021), e o ‘*MAThE The Game*’ (Katsaounidou et al. 2019) desafiam os jogadores a identificar a confiabilidade de informações apresentadas. O ‘*Cheque Isso*’ (Abreu, Berwanger e Costa 2018) é composto por cartas e, diferentemente dos anteriores, apresenta um guia de checagem de fatos traduzidos para o português. O JEDi é o JED que mais se assemelha à iniciativa ora proposta. Trata-se de um jogo de perguntas e respostas no qual a pergunta consiste de um texto supostamente representando uma notícia sobre o qual o jogador deve indicar se é verdadeiro ou falso. Embora seja um JED que disponha de notícias escritas em língua portuguesa e possua uma base de dados atualizável, não possui recursos de suporte à mineração de dados integrado à base de dados do JED.

Em síntese, entre os trabalhos identificados, são poucos os que disponibilizam notícias em português e possuem bases de dados atualizáveis. Entretanto, diferente da iniciativa descrita no presente artigo, nenhum dos trabalhos identificados busca integrar um JED a um módulo de mineração de dados para apoiar a análise automatizada dos dados coletados durante as partidas jogadas com o JED. Esta foi a lacuna que se buscou suprir com o presente trabalho, conforme mostra a última linha da Tabela 1.

## II. O JEDi

O JEDi é um JED para capacitação na identificação de *Fake News* em Português, base para a solução proposta neste artigo. Esta seção fornece um resumo sobre o seu funcionamento.

Segundo (Passos et al. 2021), o JEDi se desenrola em um tabuleiro a ser percorrido pelos jogadores, conforme esses consigam discernir entre notícias verdadeiras e falsas. Vence a partida, o jogador que alcançar o fim do tabuleiro primeiro. O jogo é projetado para ser jogado de forma individual ou em equipe, permitindo a participação de mais de um jogador em rede. As notícias apresentadas durante o jogo são selecionadas de modo randômico. A ideia é que, na medida em que joguem diversas partidas, os jogadores desenvolvam a capacidade de reconhecer notícias falsas.

O JEDi permite analisar, com técnicas de mineração de dados, o desempenho longitudinal de cada jogador e, portanto, sua efetividade como jogo na capacitação para reconhecer *Fake News*. O item (a) da Figura 1 ilustra a interface do início da partida, onde os jogadores escolhem o avatar desejado, informam sua idade e uma autoavaliação quanto à sua capacidade de identificar *Fake News*. A Figura 1(b) ilustra o momento em que o jogador deve ler a notícia apresentada e, em seguida, marcar a qual classe (i.e. *fake* ou *real*) ele acredita que tal notícia pertença. Em caso de acerto, o jogador é parabenizado e, em seguida, deve clicar sobre o dado, a fim de sortear o número de casas a serem percorridas por ele. No caso de erro, o jogador é informado do fato, permanece em sua posição e deve aguardar o próximo jogador dar sequência à partida. No item (c) da figura, encontra-se ilustrada a interface do final de cada partida.

A base de dados  $D$  do JEDi contém as seguintes informações sobre cada notícia  $n \in D$ : um identificador ( $n.id$ ), a data da publicação ( $n.dt$ ), o texto da notícia ( $n.txt$ ), o rótulo ( $n.lbl$ , onde  $n.lbl \in \{fake, real\}$ ) e a categoria (i.e., sobre que assunto a notícia trata - e.g.: política, esporte, economia, etc) a que  $n$  pertence. Além das informações da notícia,  $D$  contém informações sobre os jogadores e as respostas por eles fornecidas para as

notícias apresentadas ao longo das partidas. A Figura 2 apresenta o modelo de dados conceitual de *D* com a organização das informações persistidas pelo JEDi. A Figura 3, por sua vez, mostra o Modelo de Casos de Uso do JEDi, ilustrando os principais módulos do jogo. Nele pode-se observar a necessidade de uma configuração prévia do JEDi em que o gestor educacional responsável (e.g.: professor, coordenador ou diretor) cadastra os alunos que poderão jogar o jogo. Tal configuração envolve ainda a possibilidade de cadastramento de novas notícias e suas rotulações como verdadeiras ou falsas. O aluno, além de jogar com o JEDi (*UC02*), pode preencher um instrumento de avaliação sobre o JED (*UC03*). Maiores detalhes sobre o funcionamento do JEDi podem ser obtidos em (Passos et al. 2020), (Passos et al. 2021) e (Moreira et al. 2023).

Figura 1 – (a) Início partida; (b) Jogador lê notícia e escolhe opção; (c) Fim partida.




Figura 2 – Modelo Conceitual da Base de Dados *D* do JEDi.

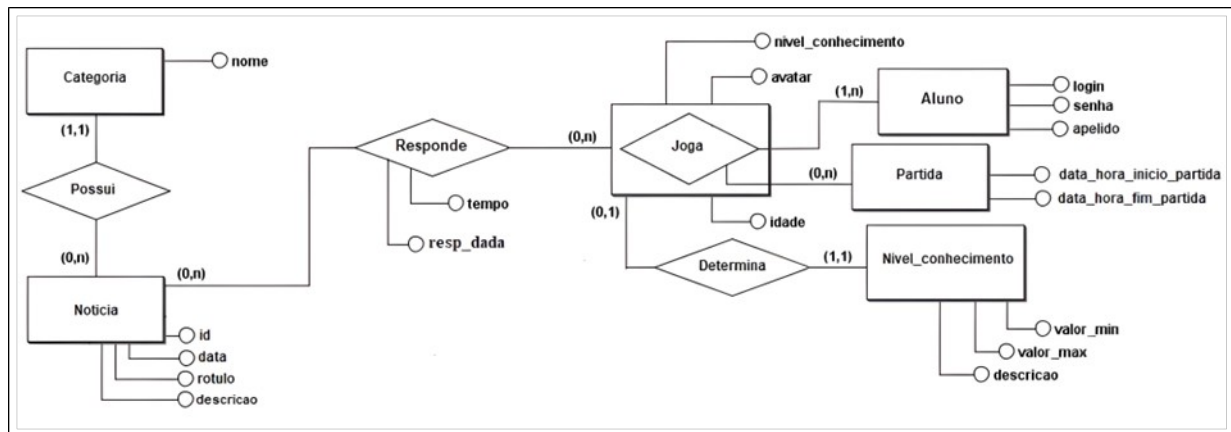



Figura 3 – Modelo de Casos de Uso do JEDi.

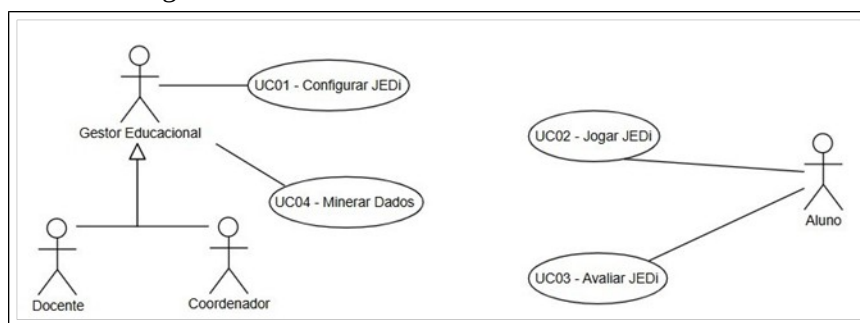


### III. JEDi + MMD

Esta seção tem como objetivo descrever a extensão realizada no JEDi a fim de incorporar o *MMD* (Módulo de Mineração de Dados). A Figura 4 apresenta o Diagrama de Caso de Uso do JEDi ajustado com a in-

clusão do *UC04 - Minerar Dados*. Em essência, o novo módulo tem como objetivo automatizar pesquisas antes executadas por meio da manipulação de planilhas eletrônicas e consultas *ad-hoc* realizadas ao banco de dados do JEDi. Com o MMD, reduz-se a necessidade de intervenção humana no processo de identificação de correlações entre os dados, facilitando investigações que busquem responder o quanto o uso do JEDi pode favorecer o aprendizado dos alunos, assim como apoiar gestores educacionais a identificar oportunidades de melhoria no processo de aprendizagem.

Figura 4 – Modelo de Casos de Uso: JEDi + MMD.



Na Figura 4, é possível observar que foram introduzidas as especializações do usuário do tipo *Gestor Educacional* nos subtipos *Docentes* e *Coordenadores*. Tais especializações foram feitas a fim de tornar explícitos os tipos de gestores educacionais que podem participar da elaboração, do acompanhamento e de avaliação de atividades envolvendo o jogo.

A fim de viabilizar o funcionamento do *MMD* foi necessário estender o *UC01 Configurar o JEDi* da versão original do JED. Antes restrita a rotinas de inclusão de novas notícias e jogadores no JEDi, a nova versão do caso de uso permite o cadastramento de escolas, turmas, docentes, coordenadores e gestores educacionais em geral. Tais ajustes têm como objetivo permitir que o JEDi possa ser utilizado simultaneamente tanto por diferentes turmas de uma mesma escola quanto em diferentes escolas. A Figura 5 mostra o Modelo Conceitual da Base de Dados *D<sub>Ext</sub>* do JEDi, estendida a partir da versão original, anteriormente apresentada pelo modelo conceitual da Figura 2. A Figura 6 apresenta um detalhamento do caso de uso *UC04 - Minerar Dados*. Ela contém seis casos de uso cujas respectivas descrições encontram-se nos próximos parágrafos.

Os dois primeiros casos de uso, *UC04.1* e *UC04.2*, apresentam perfis de notícias e de turmas, sem a vinculação com os resultados de partidas. Ambos permitem conhecer algumas das principais características dos protagonistas do jogo: os alunos e as notícias. Com relação a notícias, é possível consultar a distribuição delas por categorias (e.g. política, economia, saúde pública, etc), assim como por características textuais (e.g. número de caracteres, quantidade de palavras, dentre outras) e por classificação (notícias verdadeiras ou falsas). Sobre os estudantes, é possível visualizar, por turma, características de cunho social como média etária e distribuição por sexo, por exemplo.

Os próximos três casos de uso (*UC04.3*, *UC04.4* e *UC04.5*) buscam apresentar informações relacionadas ao desempenho dos discentes ao jogarem o jogo. Para tanto, consideram as informações coletadas durante cada partida jogada em um intervalo de tempo definido na respectiva consulta. Em cada um deles, o gestor educacional pode filtrar as consultas por turma ou ter a visão geral do desempenho de todos os alunos da escola que tenham jogado o JEDi.



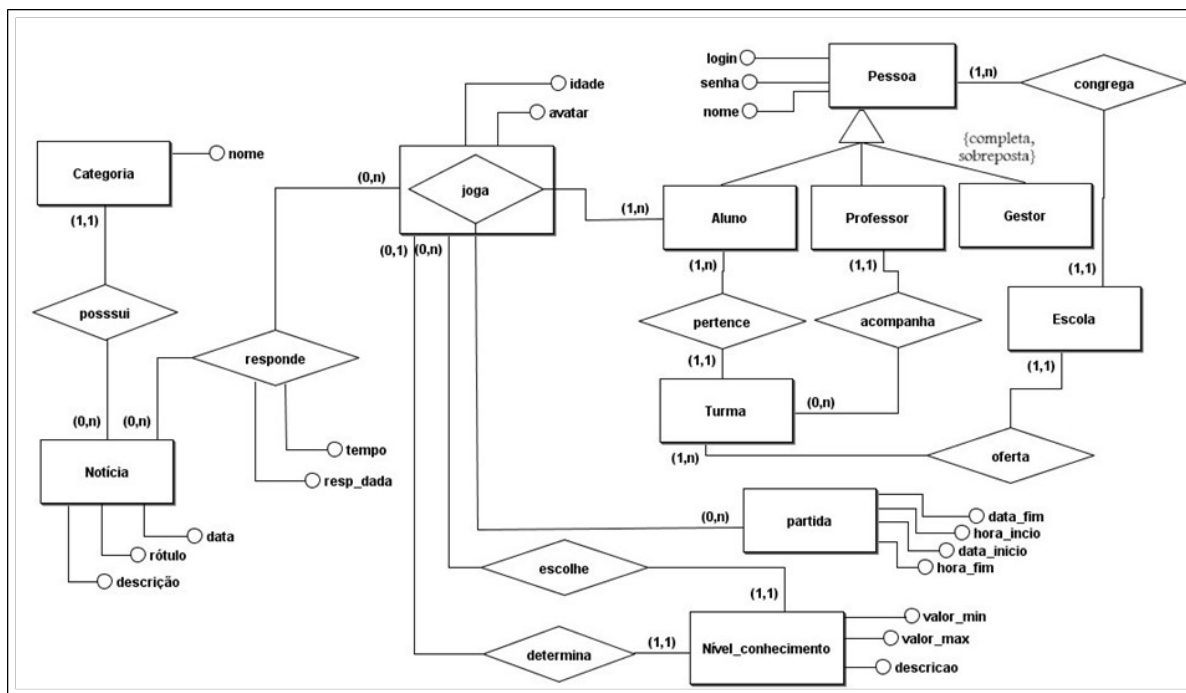
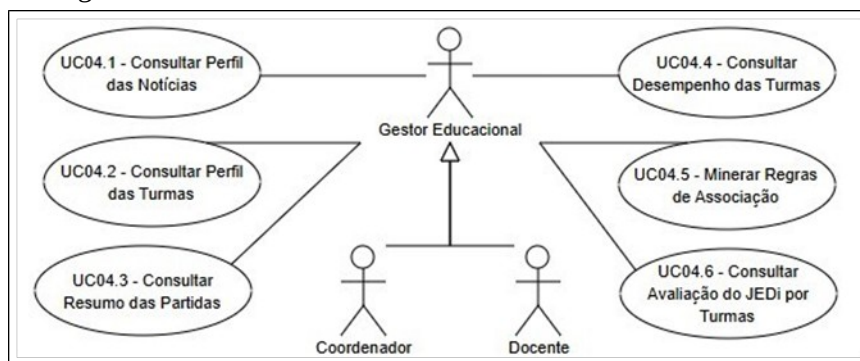
Figura 5 – Modelo Conceitual da Base de Dados  $D_{Ext}$  do JEDi + MMD.

Figura 6 – Modelo de Casos de Uso com Detalhamento do MMD.



O caso de uso *UC04.3 - Consultar Resumo de Partidas* apresenta um quadro resumido com estatísticas como, por exemplo: tempo de resposta médio por notícia analisada, tempo médio de duração das partidas e número de médio de acertos por partida, dentre outros. Por meio do caso de uso *UC04.4 - Consultar Desempenho de Turmas*, o usuário possui três alternativas de visualização dos resultados das consultas: por categoria de notícias, por nível de autoavaliação, e por evolução entre primeira e última partidas. Em todas elas, as consultas apresentam os percentuais de acertos e erros e o tempo médio de respostas às notícias. No caso da consulta por categorias de notícias, o caso de uso apresenta a distribuição dos resultados pelas categorias de notícias registradas na base de dados. A consulta por nível de autoavaliação tem como objetivo apresentar um cruzamento dos resultados em relação ao nível de autoavaliação informado pelo aluno antes de cada partida e o nível de avaliação alcançado por ele no final da partida. A ideia por trás desta consulta é permitir uma comparação entre as expectativas dos alunos com relação às suas capacidades em reconhecer notícias falsas e os resultados efetivamente alcançados por eles. Por fim, com relação ao terceiro tipo de consulta, o caso de uso permite visualizar a diferença entre os resultados obtidos pelos alunos nas primeiras e últimas partidas jogadas por eles. Desta forma, o gestor educacional pode ter uma noção da efetividade do JEDi em relação ao seu propósito, i.e., em capacitar alunos para identificar notícias falsas.

O caso de uso *UC04.5 - Minerar Regras de Associação* consiste em aplicar o *Apriori*, algoritmo de mineração de dados clássico na tarefa de mineração de regras de associação, a partir dos valores de suporte e confiança mínimos especificados pelo usuário. Por fim, o sexto e último caso de uso, *UC04.6 - Consultar Avaliação do JEDi por Turmas*, tem como objetivo apresentar de forma consolidada os *feedbacks* providos pelos alunos ao responder ao *UC03 - Avaliar JEDi*. Neste caso de uso, os resultados podem ser apresentados separadamente por turma ou agrupados por escola.

Visando facilitar a integração do MMD com o JEDi, optou-se por adotar, para implementação do protótipo do MMD, as mesmas ferramentas utilizadas no desenvolvimento do JED: Python e PHP como linguagens de programação e MySQL como SGBD. O banco de dados do JEDi foi estendido para incorporar as relações e demais recursos necessários ao funcionamento do MMD. O uso de um SGBD relacional como o MySQL viabilizou a construção de estruturas tabulares bidimensionais fornecidas como entradas para os casos de uso do *UC04* do MMD. Tais estruturas foram implementadas por meio de visões não materializadas geradas a partir de junções das relações do banco de dados do JEDi. Sempre que o referido caso de uso é executado, as visões apresentam os dados atualizados com todas as jogadas do JEDi pelos estudantes.

Ainda sobre o protótipo do MMD, é importante destacar que foi adotada uma implementação baseada em microsserviços<sup>1</sup> através de uma API que se integra ao JEDi, de forma desacoplada ao jogo. Tal API recebe como parâmetro os resultados produzidos pelas respectivas visões não materializadas, a fim de gerar saídas estruturadas dos dados que são interpretadas pelo MMD.

## IV. ESTUDO DE CASO

A fim de validar a adequação do MDD integrado ao JEDi, o presente trabalho realizou um estudo de caso com o JEDi + MDD. Ele foi realizado no 1º de semestre de 2025, em uma Escola Pública no estado do Rio de Janeiro. A instituição foi escolhida devido à disponibilidade de recursos (laboratório com computadores e acesso à internet) e à boa receptividade pela Direção e Docentes em realizar a pesquisa. O estudo de caso envolveu três turmas do 3º ano do ensino médio. Cada turma contava com um quantitativo em torno de 30 estudantes matriculados, totalizando um universo com 101 alunos. A decisão de trabalhar com estudantes do Ensino Médio foi motivada por dois fatores: (i) Uma maior efetividade do JEDi constatada junto a alunos do Ensino Médio, conforme estudo reportado em (Moreira et al. 2023); (ii) O fato de serem alunos próximos da conclusão da Educação Básica, público sujeito à influência de informações em mídias sociais.

### 1 METODOLOGIA ADOTADA

A metodologia adotada na realização do estudo de caso teve início com o contato realizado junto à Direção da referida Escola a fim de apresentar a pesquisa e formalizar a parceria com a instituição. Uma segunda reunião envolvendo as Direções Geral e Adjunta e um grupo de professores indicados pela Escola foi realizada, a fim de explicar os detalhes do projeto e planejar as atividades de execução do estudo de caso. Nesta reunião foram definidas as turmas cujos alunos poderiam participar voluntariamente da pesquisa. Em seguida, apresentou-se a pesquisa e o JEDi aos estudantes das três turmas, e um convite para participação no estudo. Os que optaram por participar, de forma voluntária, assinaram, em conjunto com seus responsáveis legais, os termos de consentimento e assentimento livre e esclarecido (TCLE e TALE) para autorização e participação na pesquisa. Do universo de 101 estudantes, 35 optaram por não participar ou não levaram o TCLE e TALE assinados, resultando em uma amostra com 66 alunos.



Após a coleta dos termos, iniciou-se a fase de uso do JEDi pelos discentes das turmas selecionadas. É importante destacar que os autores do presente trabalho não eram docentes dos estudantes e não influenciaram na seleção das turmas ou na participação dos alunos. Os recursos tecnológicos e a metodologia de ensino foram os mesmos para as três turmas. Ao final do processo, o MMD foi apresentado aos docentes, coordenadores e diretores. Esses puderam usar o módulo para executar as análises que julgassem importantes durante cerca de 1 mês. Posteriormente, esses docentes responderam a uma pesquisa de avaliação do JEDi + MMD. Ao final do processo, os resultados da pesquisa foram tabulados e analisados.

## 2 CONFIGURAÇÃO DO JEDi + MMD

O conjunto  $D_{ext}$  utilizado no estudo de caso continha um total de 1.213 notícias. Dessas, 1.187 foram coletadas de diversos meios digitais de divulgação de notícias e rotuladas por agências de checagem de fatos. Essas notícias foram importadas diretamente para o banco de dados do JEDi. Mais detalhes sobre o processo de coleta e rotulação de notícias podem ser obtidas em (Moreira *et al.*, 2024). As demais 26 notícias foram selecionadas e cadastradas no banco de dados pelos docentes envolvidos no estudo de caso. Para tanto, esses docentes utilizaram o Módulo de Configurações (*UC01 - Configurar JEDi*). É importante mencionar que, do total de notícias utilizadas no estudo de caso, 423 eram *Fake* e 790 não *Fake*. Além do cadastro de novas notícias, o Módulo de Configurações foi utilizado pelos gestores educacionais para o cadastramento de turmas, docentes e discentes. Ao todo, foram cadastrados 5 docentes, 3 coordenadores (incluindo a diretora), 66 discentes e as 3 turmas. A Figura 7 apresenta as categorias de autoavaliação configuradas pelo referido módulo.

Figura 7 – Intervalo de categorias para avaliar o desempenho dos estudantes.

	Categoria	Faixa de Acertos
►	Proplayer	80% a 100%
	Avançado	60% a 79%
	Casual	40% a 59%
	Iniciante	20% a 39%
	Noob	0% a 19%

## 3 PERFIS DE DISCENTES E NOTÍCIAS

A Figura 8 apresenta a distribuição das notícias utilizadas no estudo de caso, por categoria. Embora existisse um desbalanceamento na quantidade de notícias pelas categorias, optou-se por utilizar todas elas e avaliar o impacto deste desbalanceamento nos resultados. Por outro lado, a Figura 9 mostra um resumo das características textuais dessas notícias, indicando o número de caracteres e palavras presentes na base de dados do JEDi e utilizadas no estudo de caso. Ambas as tabelas sobre notícias são resultantes do *UC04.1*.

Figura 8 – Frequências absolutas (qt) e relativas (%) das notícias por tema.

	Categorias	Fake (Qt.)	Fake (%)	Não Fake (Qt.)	Não Fake (%)
►	Economia	47	11.11	323	40.89
	Educação	16	3.78	138	17.47
	Política	262	61.94	109	13.80
	Saúde Pública	50	11.82	51	6.46
	Segurança	39	9.22	18	2.28
	Tecnologia	9	2.13	151	19.11

O perfil social dos discentes que participaram do estudo de caso encontra-se retratado na Figura 10. O caso de uso *UC04.2* gerou a tabela em questão.

Figura 9 – Médias e desvios de características textuais das notícias.

Características Observadas	Fake (Média ± Desvio Padrão)	Não Fake (Média ± Desvio Padrão)
▶ Número de caracteres por artigo de notícias	144.55 ± 86.54	81.37 ± 16.11
Número de palavras por artigo de notícias	24.2 ± 15.76	14.05 ± 2.8

Figura 10 – Distribuição dos Estudantes pelas Turmas - Características Sociais.

Turma	Total	Idade (Média ± Desvio)	Localização Geográfica
▶ Turma A	36	16.50 ± 0.84	Rio de Janeiro (RJ - Brasil)
Turma B	14	16.00 ± 0.70	Rio de Janeiro (RJ - Brasil)
Turma C	16	15.50 ± 1.29	Rio de Janeiro (RJ - Brasil)

#### 4 DESEMPENHO DISCENTE

Esta seção apresenta os principais resultados sobre o desempenho discente apurado pelo MMD ao final do estudo de caso. Foram selecionados de consultas pelos gestores educacionais que participaram do estudo.

Gerada pelo caso de uso *UC04.3*, a Figura 11 mostra o resumo das partidas jogadas pelas turmas durante o período de realização do estudo de caso.

Figura 11 – Resumo dos dados coletados nas partidas, após pré-processamento.

Características Observadas	Turma A	Turma B	Turma C
▶ Tempo de resposta por questão (segundos)	8.61 ± 3.76	8.37 ± 3.88	11.06 ± 4.16
Tempo de resposta por partida (segundos)	341.86 ± 160.50	199.82 ± 112.58	221.26 ± 102.96
Percentual de Acertos por partida (%)	73.76 ± 23.99	74.93 ± 27.03	63.93 ± 25.55

As Figuras 12(a), 12(b) e 13, resultantes do caso de uso *UC04.4*, mostram, respectivamente, a distribuição dos resultados pelas categorias de notícia, pelos níveis de autoavaliação e pelos desempenhos obtidos pelos alunos nas primeiras e últimas partidas jogadas por eles. Ao observar especificamente a Figura 13 percebe-se que as três turmas apresentaram aumento no percentual de acertos nas últimas partidas em relação às primeiras partidas jogadas pelos alunos. Tal aumento sugere uma influência positiva do JEDi em capacitar os discentes para identificar notícias falsas corretamente.

A Figura 14 apresenta uma visão parcial de uma tela de retorno gerada pelo algoritmo *Apriori* do *UC04.5 - Minerar Regras de Associação* a partir dos seguintes valores de hiperpâmetros de suporte e confiança mínimos, respectivamente: 5% e 75%. A regra  $R_2$ , por exemplo, indica que todos os alunos da Turma C que se autoavaliaram como casuais, aumentaram o seu percentual de acerto em relação à primeira partida jogada, ou seja, melhoraram a sua capacidade de identificar notícias falsas.

Figura 12 – Percentual de Acertos por: (a) Turma/ Categoria; (b) (Auto)Avaliação.

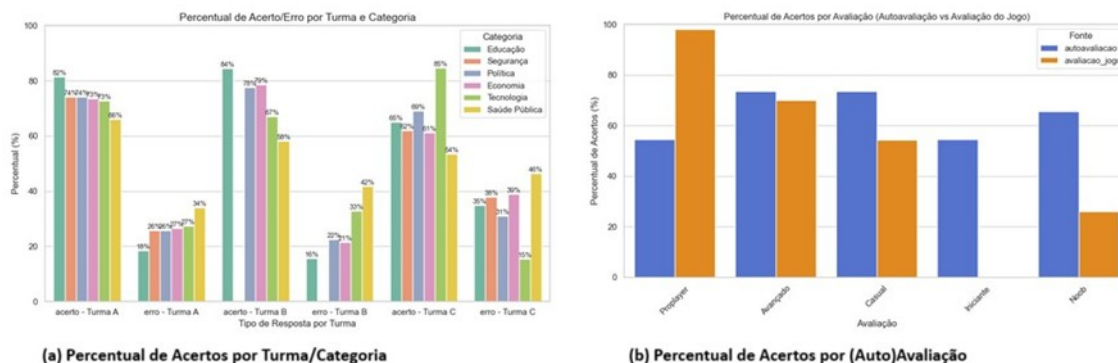


Figura 13 – Percentual de Acertos por Tipo da Partida e Turma




Figura 14 – Exemplo de regras de associação geradas pelo Apriori.

Regra	Regras de Associação Identificadas	Suporte (%)	Confiância (%)
R1	Se {autoavaliação = "Proplayer"} então {capacidade_critica = "Aumentou"}	7,5	83
R2	Se {turma = "Turma C"} e {autoavaliação = "Casual"} então {capacidade_critica = "Aumentou"}	6	100

## 5 RESULTADOS DA AVALIAÇÃO DO JEDI PELOS ESTUDANTES

Ao final do estudo de caso, cada aluno respondeu, via o *UC03 - Avaliar JEDi*, a um instrumento de avaliação do JEDi análogo ao utilizado nos artigos seminais sobre o JED. Nesse instrumento, as perguntas (expressas por meio de afirmações) são organizadas em dimensões e foram adaptadas a partir da escala motivacional para materiais instrucionais utilizada por (Savi, Wangenheim e Borgatto 2011). As dimensões avaliadas encontram-se indicadas na primeira linha da Tabela 2. A fim de determinar o grau de concordância entre as afirmações das dimensões avaliadas, cada aluno atribuiu, para cada afirmação, uma nota da seguinte escala Likert: -2 (discordo fortemente), -1 (discordo parcialmente), 0 (não concordo nem discordo), +1 (concordo parcialmente), +2 (concordo totalmente). O resultado da avaliação de cada dimensão encontra-se resumido na segunda linha da Tabela 2. É importante destacar que todas as dimensões apresentaram uma avaliação média acima de zero, indicando, portanto, tendência de avaliação positiva quanto ao uso do JED.

Tabela 2 – Concordância nas dimensões do JEDi avaliadas: médias  $\pm$  desvios.

Dimensão	Atenção	Relevância	Imersão	Interação Social	Desafio	Divertimento	Competência
JEDi	0,35 $\pm$ 1,45	1,08 $\pm$ 0,94	1,16 $\pm$ 1,00	0,75 $\pm$ 1,31	1,05 $\pm$ 1,16	1,30 $\pm$ 0,87	1,68 $\pm$ 0,61

## 6 RESULTADOS DA AVALIAÇÃO DO MMD PELOS GESTORES EDUCACIONAIS

Participaram da avaliação do MMD, os 5 docentes e os 3 membros da equipe gestora da escola. Cada um respondeu a um questionário cujas perguntas (expressas por meio de afirmações) foram adaptadas a partir do Modelo de Aceitação de Tecnologia (*Technology Acceptance Mode*) proposto por (Davis 1993). Tal modelo foi escolhido por ser um dos mais aplicados para analisar a aceitação de tecnologias por parte dos usuários. As perguntas buscaram avaliar as dimensões *Facilidade de Uso Percebida*, *Utilidade Percebida*, *Atitude em Relação ao Uso* e *Intenção de Uso*, conforme ilustrado na Tabela 3. Para cada pergunta, o avaliador atribuiu uma nota da escala Likert análoga à utilizada na avaliação do JEDi pelos alunos. Além das dimensões, os avaliadores tiveram espaço no questionário para deixar observações sobre aspectos positivos e negativos quanto à aceitação do MMD.

Tabela 3 – Dimensões do MMD avaliadas - Modelo de (Davis 1993).

Dimensão	Descrição	Exemplo de pergunta
Facilidade de Uso Percebida	Quantifica a intensidade com que o especialista acredita que o uso do Módulo será feito sem dificuldade.	Módulo de fácil utilização.
Utilidade Percebida	Quantifica grau em que o especialista acredita que o uso do Módulo contribuirá para melhor desempenho na atividade profissional.	Módulo torna o trabalho docente ágil.
Atitude em Relação ao Uso	Aferição afetiva do especialista sobre o uso do Módulo.	A forma de exposição do conteúdo fez com que o Módulo capturasse a minha atenção.
Intenção de Uso	Aferição do especialista sobre o comportamento real de utilização do Módulo.	Pretendo utilizar o Módulo como a apoio à prática docente.

A Tabela 4 sumariza os dados coletados com o questionário. Na primeira linha são apresentadas as dimensões avaliadas. Na segunda, estão as médias e desvios apurados para cada dimensão, a partir das respostas dadas pelos avaliadores. É importante notar que todas as dimensões tiveram avaliação média acima de 4 e desvio padrão inferior a 0,35, retratando uma convergência à unanimidade na aceitação do MMD. Cabe destacar que a dimensão *Utilidade Percebida* foi a que apresentou maior média, indicando que os avaliadores acreditam que o uso do MMD contribuirá para um melhor desempenho na atividade docente. Em termos qualitativos, os comentários positivos apontaram para a adequação do MMD, em sintonia com as avaliações quantitativas. Como principal oportunidade de melhoria foram sugeridas interfaces mais atrativas e com configurações flexíveis.

Tabela 4 – Concordância nas dimensões do MMD avaliadas: médias  $\pm$  desvios.

Dimensão	Facilidade de Uso Percebida	Utilidade Percebida	Atitude em Relação ao Uso	Intenção de Uso
MMD	4,31 $\pm$ 0,21	4,87 $\pm$ 0,28	4,44 $\pm$ 0,34	4,44 $\pm$ 0,13

## CONSIDERAÇÕES FINAIS

De forma a reduzir a intervenção humana na manipulação de dados coletados em Jogos Educacionais Digitais (JED) voltados à capacitação de pessoas para identificar *Fake News*, o presente trabalho propôs e avaliou o MMD, um módulo de mineração de dados desenvolvido de forma integrada ao JEDi, um JED em Português para apoiar tal capacitação.

Um estudo de caso envolvendo o uso da ferramenta integrada JEDi + MMD por 66 discentes e 8 gestores educacionais de escola pública apresentou indícios não apenas de adequação do MMD, principal contribuição do trabalho, mas também da boa receptividade e do bom aproveitamento da comunidade escolar em relação ao JED.

Entre os trabalhos futuros, pretende-se desenvolver novos estudos de caso, com novas notícias, em outras escolas. Também estão planejados esforços na melhoria das interfaces do MMD a fim de torná-las mais naturais e atrativas aos gestores educacionais.

Em tais esforços, planeja-se o uso de LLMs para humanizar as interações entre o MMD e seus usuários.

## NOTAS

1. Uma arquitetura de microsserviços caracteriza-se por dividir o sistema em serviços autônomos e pequenos, organizados por capacidade de negócio, com governança descentralizada de dados e tecnologias, favorecendo escalabilidade independente, resiliência a falhas e implantação contínua automatizada. Nesta abordagem, a comunicação entre serviços ocorre por meio de APIs leves (e.g., HTTP/REST ou gRPC) ou mensagens assíncronas, proporcionando desacoplamento e flexibilidade (Lewis e Fowler 2014).

## REFERÊNCIAS

- ABREU, P. M. R.; BERWANGER, P. M.; COSTA, R. B. Gameificação e as fakenews: uma análise do jogo Cheque Isso! *Projeção e Docência*, v. 9(2), p. 166–177, 2018.
- AUBERRY, K. Increasing students' ability to identify fake news through information literacy education and content management systems. *The Reference Librarian*, Taylor & Francis, v. 59, n. 4, 2018.
- COLPANI, R.; FARIA, M. Joy e as letrinhas: um serious game como ferramenta de auxílio no processo de alfabetização de crianças do ensino fundamental. *Revista Brasileira de Informática na Educação*, v. 25, n. 02, p. 61, 2017.
- COTONHOTO, L. A.; ROSSETTI, C. B. Prática de jogos eletrônicos por crianças pequenas: o que dizem as pesquisas recentes? *Revista Psicopedagogia*, Associação Brasileira de Psicopedagogia, v. 33, n. 102, p. 346–357, 2016.
- DAVIS, F. D. User acceptance of information technology: system characteristics, user perceptions and behavioral impacts. *International Journal of Man-Machine Studies*, v. 38, n. 3, p. 475–487, 1993. ISSN 0020-7373. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0020737383710229>.
- FRANCESCO, N. N.; LEONE, S. D. Educação midiática contra "fake news". *Revista científica UMC*, v. 5, n. 1, 2020.
- JUNIOR, R. B. The fake news detective: A game to learn busting fake news as fact checkers using pedagogy for critical thinking. *School of Computer Science Graduate Student Publications*, v. 1(17), p. 17, 2020.
- KATSAOUNIDOU, A. et al. Mathe the game: A serious game for education and training in news verification. *Education Sciences*, v. 9, p. 155, 06 2019.
- LEWIS, J.; FOWLER, M. *A definition of this new architectural term*. 2014.
- MOREIRA, T. d. O. et al. Jedi-a digital educational game to support student training in identifying portuguese-written fake news: Case studies in high school, undergraduate and graduate scenarios. *Education and Information Technologies*, Springer, p. 1–31, 2023.
- MOREIRA, T. O. et al. **Aplicação de Sistema Tutor Inteligente em Jogo Educacional Digital para Capacitação na Identificação de Fake News em Português: Estudos de Caso no Ensino Médio**. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (SBIE), 35., 2024, Rio de Janeiro. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2024. p. 602-615. Disponível em: <https://sol.sbc.org.br/index.php/sbie/article/view/31271/31074>. Acesso em: [17/11/2025].
- MUSGROVE, A. T. et al. Real or fake? resources for teaching college students how to identify fake news. *College & Undergraduate Libraries*, Taylor & Francis, v. 25 (3), p. 243–260, 2018.
- NASCIMENTO, C. E. G. Fake news, mentira organizada e educação: uma reflexão a partir do pensamento de hannah arendt. *Revista Docência e Ciberultura*, v. 4, p. 243–263, 2020.
- PARASCHIVOIU, I. et al. Escape the fake: Development and evaluation of an augmented reality escape room game for fighting fake news. *CHI PLAY '21: The Annual Symposium on Computer-Human Interaction in Play*, ACM, v. 1, p. 320–325, 10 2021.
- PASSOS, C. A. et al. **Jogos educacionais digitais como ferramentas de apoio à capacitação discente na identificação de fake news escritas em língua portuguesa: Um estudo de caso**. In: SBC. *Anais do XXXI Simpósio Brasileiro de Informática na Educação*. [S.l.], 2020. p. 401–410.

- PASSOS, C. A. et al. Jedi—um jogo educacional digital para apoiar a capacitação discente na identificação de fake news escritas em língua portuguesa: Estudos de caso nos ensinos médio e superior. *Revista Brasileira de Informática na Educação*, v. 29, p. 634–661, 2021.
- RAMOS, D. K. Jogos cognitivos eletrônicos: contribuições à aprendizagem no contexto escolar. *Ciências & Cognição*, Instituto de Ciências Cognitivas, v. 18, n. 1, p. 19–32, 2013.
- ROOZENBEEK, J.; LINDEN, S. Fake news game confers psychological resistance against online misinformation. *Palgrave Communications*, v. 5(1), p. 65, 06 2019.
- SANTOS, W. O. dos; JUNIOR, C. G. da S. Virtualização de jogos educativos: Uma experiência no ensino de matemática. *Revista Brasileira de Informática na Educação*, v. 24, n. 02, p. 108, 2016.
- SAVI, R.; WANGENHEIM, C.; BORGATTO, A. **Um modelo de avaliação de jogos educacionais** na engenharia de software. *Anais do XXV Simpósio Brasileiro de Engenharia de Software (SBES 2011)*, São Paulo, 2011.
- SILVA, E.; PIRES, F. G. de S. **O uso do jogo educacional** "eu sei contar" como auxílio da matemática no ensino infantil. In: *Anais do Workshop de Informática na Escola*. [S.l.: s.n.], 2017. v. 23, n. 1, p. 520–527.
- UNESCO. *Jornalismo, fake news desinformação: Manual para Educação e Treinamento em Jornalismo*. 2019. 129 p. <https://unesdoc.unesco.org/ark:/48223/pf0000368647>. 14/10/2022. Disponível em: <https://unesdoc.unesco.org/ark:/48223/pf0000368647>.
- URBAN, A.; HEWITT, C.; MOORE, J. **Fake it to make it**, media literacy, and persuasive design: Using the functional triad as a tool for investigating persuasive elements in a fake news simulator. In: *Proceedings of the Association for Information Science and Technology*. [S.l.: s.n.], 2018. v. 55, p. 915–916.
- VICTAL, E. R. D. N.; MENEZES, C. S. **Avaliação para aprendizagem baseada em jogos**: Proposta de um framework. *XIV Simpósio Brasileiro de Jogos e Entretenimento Digital*, p. 970–977, 2015.
- YANG, S. et al. Can an online educational game contribute to developing information literate citizens? *Computers Education*, v. 161, p. 104057, 02 2021.





# A Utilização da Inteligência Artificial na Educação da Enfermagem: Inovação, Limites e Responsabilidades Éticas

*The Use of Artificial Intelligence in Nursing Education: Innovation, Limitations, and Ethical Responsibilities*

Yasminne Corrêa Lopes<sup>1</sup>, William da Costa Moreira<sup>2</sup> e Gabriela Pereira da Silva<sup>3</sup>

1. Acadêmica concluinte do curso Enfermagem do Centro Universitário Descomplica UniAmérica. 2. Docente do curso Enfermagem do Centro Universitário Descomplica Uniamérica. Mestre em Saúde Pública pela Universidade Estadual do Oeste do Paraná (Unioeste). <https://orcid.org/0000-0001-6685-3549> 3. Docente do Colegiado de Enfermagem do Centro Universitário Descomplica UniAmérica.

[yasminnecm05@gmail.com](mailto:yasminnecm05@gmail.com) e [william.moreira@descomplica.com.br](mailto:william.moreira@descomplica.com.br)

## Palavras-chave

Educação na Enfermagem  
Estudantes de Enfermagem  
Inteligência Artificial

## Keywords

Nursing Education  
Nursing Students  
Artificial Intelligence

## Resumo:

**Objetivo:** Analisar os efeitos da utilização da Inteligência Artificial (IA) na formação em Enfermagem, considerando contribuições ao ensino teórico prático, limites pedagógicos/institucionais e implicações éticas. **Metodologia:** Estudo observacional, exploratório e quantitativo realizado em uma Instituição de Ensino Superior (IES) de Foz do Iguaçu – PR com estudantes e docentes de Enfermagem. **Resultados:** Participaram 72 respondentes, de todos os períodos da IES; 97,2% relataram conhecer/usar IA com frequência ou ocasionalmente; destaque para acesso rápido à informação (92%), economia de tempo (86%) e apoio à aprendizagem (81%); uso como suporte à decisão clínica avaliado com cautela (47%); preocupações incluíram redução da autonomia (49%), dependência (44%) e dificuldade de avaliar confiabilidade (42%), com 93% já tendo encontrado informações incorretas; crença no uso ético (83,3%), interesse por mais formação (68,1%) e relatos de uso inadequado (65,3%). **Conclusão:** A IA encontra-se incorporada ao cotidiano formativo como aliada ao estudo e à organização do trabalho acadêmico, mas requer letramento digital, diretrizes de uso responsável e práticas de checagem que preservem o julgamento clínico. Recomendam-se incorporar trilhas sobre IA desde os períodos iniciais e instituir políticas de integridade em aprendizagem significativa.

## Abstract:

**Objective:** To analyze the effects of using Artificial Intelligence (AI) in Nursing education, considering contributions to theoretical and practical teaching, pedagogical/institutional limitations, and ethical implications. **Methodology:** An observational, exploratory, and quantitative study conducted at a Higher Education Institution (HEI) in Foz do Iguaçu – PR with Nursing students and faculty. **Results:** 72 respondents participated, from all periods of the HEI; 97.2% reported knowing/using AI frequently or occasionally; highlights included quick access to information (92%), time savings (86%), and support for learning (81%); use as support for clinical decision-making was evaluated with caution (47%); concerns included reduced autonomy (49%), dependence (44%), and difficulty in assessing reliability (42%), with 93% having already encountered incorrect information; belief in ethical use (83.3%), interest in further training (68.1%), and reports of inappropriate use (65.3%). **Conclusion:** AI is being incorporated into daily educational life as an ally to study and the organization of academic work, but it requires digital literacy, guidelines for responsible use, and verification practices that preserve clinical judgment. It is recommended to incorporate learning paths on AI from the initial stages and to institute integrity policies in meaningful learning.

Artigo recebido em: 03.10.2025.

Aprovado para publicação em:  
07.11.2025.

## INTRODUÇÃO

A Inteligência Artificial (IA) é o campo da informática que compreende a inteligência, o raciocínio e o aprendizado conduzidos por máquinas semelhantes ao raciocínio humano, procurando desenvolver sistemas especialistas capazes de simular o pensamento humano de maneira independente e autônoma. O uso da IA tem se expandido nos últimos anos, sobretudo, em decorrência de um avanço tecnológico sem precedentes em diversas linhas de pesquisa e desenvolvimento na área, bem como de um crescente aumento de capacidades de processamento e armazenamento nos dispositivos em geral (PRAXEDES, 2024).

A Enfermagem é a área da saúde que se dedica ao cuidado e à assistência ao ser humano no atendimento de suas necessidades básicas, abrangendo ações de prevenção, tratamento e reabilitação. O profissional da área, o enfermeiro, pode atuar em hospitais, programas de saúde pública, unidades de saúde, enfermagem do trabalho e atendimento domiciliar (BACKES; SOUSA; ERDMANN, 2009).

No campo da educação em enfermagem, simulações clínicas são utilizadas já há algum tempo para preparar os estudantes em ambientes controlados, simulando pacientes e facilitando a aplicação das práticas desenvolvidas em sala de aula (FERREIRA AYDOGDU, 2022). A utilização da IA na educação da enfermagem é um tema de crescente interesse na sociedade atual, dado o seu potencial em transformar o processo de ensino-aprendizagem (PEREIRA; RODRIGUES, 2024; SOARES et al., 2023; PINHEIRO; VALENTE, 2024; FERNANDES et al., 2024). O uso da IA como ferramenta de suporte no provimento de informações contribui para a identificação de padrões, definição de diagnósticos e comunicação entre docente e aluno, auxiliando na tomada de decisões (GONÇALVES et al., 2024).

Por outro lado, ferramentas como o ChatGPT, um chatbot desenvolvido pela OpenAI e lançado em 2022, passaram a ser amplamente utilizadas por estudantes em suas rotinas acadêmicas, tornando-se fonte de consultas e obtenção de conhecimento na elaboração de pesquisas e trabalhos. A democratização dos processadores de linguagem natural, especialmente o ChatGPT e similares, traz à tona uma preocupação com relação aos limites éticos na prática do ensino e da aprendizagem. A facilidade em que o processamento de linguagem natural de forma escrita, verbal e a produção de textos gerando saídas cada vez mais natural nos provoca questionar até onde seria possível aceitar os avanços tecnológicos nos ambientes de ensino sem que prejuízos e consequências negativas ocorram, sobretudo, em uma área de grande valor e importância ao ser humano, que é a enfermagem (PRAXEDES, 2024).

Diante das constantes transformações tecnológicas, sobretudo, o avanço da IA, é importante analisar como o ensino da enfermagem vem reagindo a estes avanços. A inserção de novas tecnologias no ensino da enfermagem suscita questionamentos sobre suas implicações na formação dos profissionais da área, especialmente nos aspectos éticos e humanísticos inerentes à prática de enfermagem (FLORENCIO et al., 2019; PERISSÉ et al., 2019; SÁ; NABAIS, 2020; SAMPAIO LUIZ; CASTRO, 2024). Ainda que o cuidado humano seja insubstituível, a incorporação de ferramentas inteligentes na prática de enfermagem nos provoca olhar mais atencioso sobre a área. Assim, o objetivo deste estudo foi analisar os efeitos da utilização da IA na formação acadêmica de enfermagem, considerando contribuições para o ensino teórico e prático, desafios e limitações pedagógicas e institucionais, e implicações éticas no desenvolvimento profissional.

## METODOLOGIA DA PESQUISA

Trata-se de estudo observacional, exploratório e quantitativo, realizado em uma instituição de ensino superior localizada em Foz do Iguaçu, Paraná, envolvendo professores e estudantes do curso de Enfermagem



que utilizam ferramentas de Inteligência Artificial no processo de ensino-aprendizagem. A cidade de Foz do Iguaçu, situada na tríplice fronteira com Argentina e Paraguai, apresenta um cenário acadêmico diversificado e dinâmico, que se configura como espaço relevante para o desenvolvimento da pesquisa.

A coleta de dados foi realizada por meio de questionário online estruturado no Google Formulários, composto por cerca de 30 questões, elaborado com base em revisão teórica prévia sobre IA aplicada à educação em enfermagem. O instrumento englobou informações sociodemográficas, nível de conhecimento sobre IA, uso de ferramentas digitais e percepção dos participantes quanto ao impacto da IA no ensino. As respostas foram obtidas de forma anônima, respeitando os princípios éticos. As perguntas do questionário apresentaram opções de resposta considerando a escala de Likert em escala de 5 pontos, a saber: 1 – Discordo totalmente; 2 – Discordo parcialmente; 3 – Neutro/Nem concordo nem discordo; 4 – Concordo parcialmente; 5 – Concordo totalmente.

Os critérios de inclusão definidos foram: estar matriculado como estudante ou vinculado como docente do curso de Enfermagem da instituição, ter idade mínima de 17 anos e concordar com o Termo de Consentimento Livre e Esclarecido. Foram excluídos questionários incompletos, duplicados ou de pessoas não vinculadas ao curso. A amostra foi calculada a partir da população de 171 indivíduos (166 estudantes e 5 docentes), estimando-se a necessidade mínima de 102 participantes, considerando nível de confiança de 95% e erro amostral de 5%.

Os dados coletados foram tabulados em planilhas do Microsoft Excel e Google Planilhas e, em seguida, exportados para análise estatística descritiva realizada com apoio do software Jamovi. Foram utilizadas frequências absolutas e relativas, além de medidas de tendência central, com apresentação dos resultados em tabelas e gráficos. O estudo foi desenvolvido após aprovação do Comitê de Ética em Pesquisa, com base no parecer N° 7.766.933, em consonância com a Resolução n° 466/2012 do Conselho Nacional de Saúde (BRASIL, 2012), assegurando a confidencialidade e o caráter voluntário da participação.

### **ANÁLISES REALIZADAS**

A análise dos dados coletados foi conduzida em duas etapas complementares: estatística descritiva e estatística inferencial.

#### **ESTATÍSTICA DESCRITIVA**

Foram calculadas frequências absolutas e relativas para variáveis categóricas (como curso, período acadêmico, familiaridade com IA, finalidades de uso e percepção de benefícios e riscos). Além disso, foram apresentados gráficos e tabelas que permitem visualizar o perfil da amostra, a distribuição do uso da IA e as percepções associadas.

#### **ESTATÍSTICA INFERENCIAL**

Foram aplicados testes para verificar relações entre variáveis e diferenças entre grupos:

**Teste do qui-quadrado de independência:** utilizado para verificar a associação entre o período acadêmico e a frequência de uso da IA.

**ANOVA de uma via e Kruskal–Wallis:** aplicados para comparar a percepção de benefícios entre os diferentes períodos acadêmicos.

**Correlação de Spearman:** utilizada para verificar associações entre variáveis ordinais.

**Confiabilidade interna (alfa de Cronbach):** utilizada para verificar a consistência dos blocos de itens que avaliaram percepção de benefícios ( $\alpha=0,81$ , considerado satisfatório) e preocupações ( $\alpha=0,73$ , considerado adequado).


A pesquisa contou com a participação de 72 respondentes, dos quais 69 eram estudantes de Enfermagem e três eram professores. Houve representação de todos os períodos da graduação, com maior concentração no segundo período, que correspondeu a 23,6% da amostra, e no oitavo período, com 19,4%. Os demais períodos apresentaram participação entre 1,4% e 12,5%. Esses dados asseguram a heterogeneidade da amostra e permitem analisar percepções tanto de estudantes em fases iniciais quanto em etapas mais avançadas da formação.

QUADRO 1 – Distribuição da amostra por período acadêmico

Período	N	%
1º	8	11,1
2º	17	23,6
3º	3	4,2
4º	9	12,5
5º	3	4,2
6º	8	11,1
7º	2	2,8
8º	14	19,4
9º	1	1,4
10º	4	5,6
Professores	3	4,2
<b>Total</b>	<b>72</b>	<b>100</b>

Fonte: Dados da pesquisa (2025).

GRÁFICO 1 - Frequência de uso de ferramentas de IA em atividades acadêmicas




Fonte: Dados da pesquisa (2025).

Em relação ao conhecimento e ao uso de Inteligência Artificial, 97,2% dos participantes (distribuídos entre 81,9% que responderam “Concordo totalmente” e 15,3% que responderam “Concordo parcialmente”) afirmaram já ter ouvido falar sobre o tema e mais de três quartos relataram utilizar ferramentas de IA de forma frequente ou ocasional em suas atividades acadêmicas.

A percepção de benefícios foi elevada. O índice construído a partir dos itens de concordância apresentou média de 4,05 (DP=0,69) e confiabilidade interna satisfatória ( $\alpha=0,82$ ). Entre os aspectos mais valorizados


destacaram-se o acesso rápido à informação (92%), a economia de tempo (86%) e o apoio à aprendizagem (81%). Por outro lado, o uso da IA como suporte para a tomada de decisão clínica foi avaliado com maior cautela, obtendo 47% de concordância.

GRÁFICO 2 - Benefícios percebidos pelos participantes



Fonte: Dados da pesquisa (2025).

GRÁFICO 3 – Estudantes que já encontraram informações incorretas em ferramentas de IA



Fonte: Dados da pesquisa (2025).

Em contrapartida, também emergiram preocupações relacionadas ao uso da IA. O índice de riscos apresentou média de 3,63 (DP=0,71) e confiabilidade interna baixa ( $\alpha=0,54$ ). Entre as principais preocupações, 49% afirmaram que a tecnologia pode reduzir a autonomia no pensamento, 44% apontaram risco de dependência e 42% relataram dificuldade em avaliar a confiabilidade das respostas. Um dado marcante foi que 93% dos participantes relataram já ter encontrado informações incorretas ao utilizar ferramentas de IA.

No campo ético e pedagógico, 83,3% dos respondentes declararam acreditar que a IA pode ser utilizada de forma ética e responsável no ensino. Além disso, 68,1% manifestaram interesse em receber mais conteúdos sobre o tema ao longo da graduação, e 65,3% afirmaram já ter presenciado ou ouvido relatos de usos inadequados dessas ferramentas em contextos acadêmicos.

O teste do qui-quadrado de independência não apontou associação significativa entre o período acadêmico e a frequência de uso da IA ( $\chi^2=33,36$ ; gl=36;  $p=0,595$ ), sugerindo que o padrão de utilização é homogê-

neo entre calouros e veteranos. A análise de variância (ANOVA) também não demonstrou diferenças estatisticamente significativas entre períodos quanto à percepção de benefícios ( $F=0,69$ ;  $p=0,714$ ), resultado confirmado pelo teste de Kruskal–Wallis ( $H=7,75$ ;  $p=0,560$ ). Em contrapartida, a correlação de Spearman evidenciou forte associação positiva entre a percepção de benefícios e a frequência de uso da IA ( $\rho=0,681$ ;  $p<0,001$ ), indicando que quanto maior a percepção de utilidade, maior a utilização da tecnologia. Por outro lado, não foi encontrada correlação significativa entre percepção de benefícios e preocupações ( $\rho=-0,014$ ;  $p=0,905$ ), o que demonstra que ambas as dimensões coexistem de maneira independente.

## DISCUSSÃO

Os resultados desta pesquisa indicam uma ampla inserção da IA no cotidiano formativo do curso de Enfermagem analisado. A elevada familiaridade (97,2% já ouviram falar e utilizam a IA de forma frequente ou ocasional) e a distribuição heterogênea dos 72 respondentes, com representação de alunos de todos os períodos e participação expressiva do 2º (23,6%) e do 8º (19,4%) períodos, sugerem que a adoção das ferramentas digitais não é um fenômeno restrito a nichos ou fases específicas do curso, mas uma prática disseminada desde calouros a veteranos. Esses achados fazem relação com a literatura que descreve a IA como tecnologia já incorporada às rotinas de formação e cuidado em Enfermagem, com potencial para reorganizar fluxos de estudo, acesso a conteúdo e práticas de raciocínio clínico (PRAXEDES, 2024; FERREIRA AYDOGDU, 2022). Ao mesmo tempo, reafirmam a percepção, já descrita por Gonçalves et al. (2024), de que os estudantes tendem a reconhecer a IA como parte natural do ecossistema pedagógico contemporâneo.

No que se refere aos benefícios percebidos, os respondentes valorizam sobretudo o acesso ágil à informação (92%), a economia de tempo (86%) e o apoio à aprendizagem (81%), resultando em média elevada no índice de benefícios (4,05; DP=0,69). Esta observação está alinhada ao que Soares et al. (2023) descrevem como promessa pedagógica da IA: ampliação de repertórios, personalização do estudo e dinamização de atividades, favorecendo maior autonomia discente. Praxedes (2024) reforça que, quando corretamente integrada a fluxos de trabalho educacionais e assistenciais, a IA pode atuar como catalisadora de produtividade e apoio à decisão, desde que ancorada em diretrizes de qualidade e segurança. A ênfase em “ganhos de tempo” e “amplitude de busca” também converge com experiências de implementação de tecnologias educacionais na graduação em Enfermagem (FLORÊNCIO et al., 2019), nas quais a mediação tecnológica, quando bem planejada, funciona como dinamizador do ensino e não como substituto do raciocínio profissional.

Por outro lado, o uso da IA como suporte direto à tomada de decisão clínica foi percebido com cautela (47% de concordância), o que evidencia prudência dos participantes frente a contextos de maior risco. Esse achado é coerente com o papel do enfermeiro descrito por Backes, Sousa e Erdmann (2009), para quem a tomada de decisão é sustentada por competências técnico-científicas, julgamento ético e responsabilização pelo cuidado e dimensões que a IA não substitui. Em termos pedagógicos, tal prudência sugere a necessidade de cenários de aprendizagem que explicitem limites e possibilidades da IA em casos clínicos, privilegiando a validação de evidências, a leitura crítica de resultados algorítmicos e o confronto entre recomendações automatizadas e protocolos institucionais. Sampaio Luiz e Castro (2024) argumentam que a excelência do cuidado emerge quando tecnologias e saberes profissionais se interligam de forma crítica e contextual, e não por mera delegação da decisão à ferramenta.

As preocupações dos participantes da pesquisa mostram que ética e letramento digital são temas importantes: quase metade teme redução da autonomia de pensamento (49%) e risco de dependência (44%), 42%

relatam dificuldade em avaliar a confiabilidade das respostas e um grande número (93%) afirma já ter encontrado informações incorretas ao usar IA. Esses dados confirmam o comportamento descrito por Fernandes et al. (2024) e por Pinheiro e Valente (2024), que discutem o “duplo movimento” da IA na educação: ao mesmo tempo em que potencializa a aprendizagem, pode induzir vieses, superficialidade e falta de autonomia, caso não haja mediação ética e didática.

A adesão à IA aparece acompanhada de expectativa formativa: 83,3% acreditam ser possível utilizá-la de forma ética e responsável, e 68,1% desejam receber mais conteúdos sobre o tema ao longo da graduação. Essa necessidade por formação específica encontra coerência com o disposto por Pereira e Rodrigues (2024), que identificam lacunas curriculares e heterogeneidade na integração didática da IA em cursos de Enfermagem. A literatura sobre tecnologias educacionais (FLORÊNCIO et al., 2019) indica que os ganhos pedagógicos dependem de planejamento instrucional, objetivos claros e avaliação formativa, e não de adesão espontânea a ferramentas.

Por fim, é importante reconhecer limites e implicações. Como a pesquisa foi feita numa só instituição e com dados autorrelatados, é prudente evitar uma ampla generalização sobre o tema; ainda assim, a homogeneidade de padrões entre períodos e a coexistência de benefícios e preocupações configuram tendências plausíveis para contextos semelhantes. Do ponto de vista institucional, os dados sustentam a implementação de políticas de ensino para letramento em IA e guias de uso responsável da IA, que são algumas medidas que vão de encontro às recomendações éticas e pedagógicas discutidas em parte da literatura referenciada neste artigo (PRAXEDES, 2024; PEREIRA; RODRIGUES, 2024; PINHEIRO; VALENTE, 2024; FERNANDES et al., 2024).

## CONSIDERAÇÕES FINAIS

Os achados desta pesquisa indicam que a IA já compõe o cotidiano da formação em Enfermagem na instituição analisada, com relevante familiaridade e uso entre estudantes e docentes. A amostra, composta por 72 respondentes e distribuída por todos os períodos, confirma a heterogeneidade do público e sustenta a leitura de que a adoção da IA é transversal ao longo do curso. Nesse cenário, a proporção de participantes que reconhecem e utilizam ferramentas de IA (97,2%) reforça a consolidação desse repertório tecnológico no ambiente acadêmico e sinaliza um movimento de incorporação que não se limita a perfis específicos de semestre ou experiência prévia.

No eixo dos benefícios, destacaram-se o acesso ágil à informação (92%), a economia de tempo (86%) e o apoio à aprendizagem (81%), compondo um índice de benefícios elevado e que variaram juntos e de forma coerente. Observou-se, ainda, forte associação entre perceber a utilidade da IA e utilizá-la com maior frequência, evidenciando um ciclo virtuoso no qual a experiência positiva retroalimenta o engajamento. Em paralelo, nota-se prudência do entrevistado quanto ao emprego da IA na tomada de decisão clínica (47% de concordância), o que sugere compreensão dos limites tecnológicos frente ao julgamento profissional e às responsabilidades inerentes ao cuidado. Em síntese, os resultados apontam para uma visão pragmática: a IA é bem-vinda como apoio ao estudo e à organização do trabalho acadêmico, sem que isso implique delegar e confiar processos críticos ao algoritmo.

No eixo dos riscos e responsabilidades, as preocupações mais frequentes envolveram a autonomia de pensamento (49%), o risco de dependência tecnológica (44%) e as dificuldades de aferir a confiabilidade das respostas (42%), além do dado expressivo de que 93% já se depararam com informações incorretas. Ainda

assim, prevalece a crença de que é possível utilizar a IA de forma ética e responsável (83,3%), acompanhada do desejo por maior formação específica (68,1%) e do relato de vivências ou relatos de uso inadequado (65,3%). Esses elementos, combinados, configuram uma demanda institucional clara para o desenvolvimento de competências digitais, diretrizes de integridade acadêmica e práticas pedagógicas que ensinem não apenas “como usar”, mas “quando, para quê e com quais critérios validar” o uso de IA em contextos formativos e de simulação clínica.

Não se identificou diferença entre os períodos do curso nem no quanto a IA é usada, nem em como os benefícios são percebidos. Além disso, benefícios e preocupações caminham separadas: dá para valorizar o que a IA entrega sem ignorar os riscos. O que isso sugere na prática? Tratar o assunto como transversal desde o primeiro semestre, com trilhas simples e objetivos claros; ensinar a checar respostas, citar corretamente e registrar quando a IA foi usada; e dar suporte aos professores para criarem atividades que incentivem o uso responsável (e não o “atalho”).

Por fim, é importante frisar os limites deste estudo: foi conduzido em uma única instituição, em um recorte de tempo específico, com respostas autorrelatadas e uma amostra menor que a estimada, ou seja, recomenda-se parcimônia nas generalizações desta conclusão. Como sugestão de desdobramento do estudo, recomenda-se a expansão da pesquisa para que abranja mais localidades determinantes das amostras, acompanhando os estudantes ao longo do tempo, e que comparem estratégias de letramento em IA, mensurando impactos em desempenho, raciocínio clínico, integridade acadêmica e segurança do paciente em cenários de simulações. Em termos conclusivos, a IA funciona melhor como parceira do aprendizado, e não como substituta do julgamento profissional, exigindo da instituição políticas claras, formação continuada e cultura de validação para que a inovação se converta em aprendizagem significativa e cuidado seguro.

## REFERÊNCIAS

- BACKES, M. S.; SOUSA, F. G. M.; ERDMANN, A. L. **O papel do enfermeiro no contexto hospitalar: a visão de profissionais de saúde**. DOI: 10.4025/cienccuidsaude.v7i3.6490. *Ciência, Cuidado e Saúde*, v. 7, n. 3, p. 319-326, 6 mar. 2009.
- BRASIL. Conselho Nacional de Saúde. **Resolução nº 466, de 12 de dezembro de 2012**. Aprova diretrizes e normas regulamentadoras de pesquisas envolvendo seres humanos. *Diário Oficial da União*, Brasília, DF, 13 jun. 2013. Disponível em: <https://conselho.saude.gov.br/resolucoes/2012/Reso466.pdf>. Acesso em: 31 mar. 2025.
- FERNANDES, Allysson Barbosa et al. **A ÉTICA NO USO DE INTELIGÊNCIA ARTIFICIAL NA EDUCAÇÃO: IMPLICAÇÕES PARA PROFESSORES E ESTUDANTES**. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, [S. l.], v. 10, n. 3, p. 346–361, 2024. DOI: 10.51891/rease.v10i3.13056. Disponível em: <https://periodicorease.pro.br/rease/article/view/13056>. Acesso em: 23 mar. 2025.
- FERREIRA AYDOGDU, A. L. **Inteligência artificial e enfermagem: reflexão sobre o uso de tecnologias no processo de cuidar**. *Revista de Enfermagem da UFJF*, [S. l.], v. 6, n. 2, 2022. DOI: 10.34019/2446-5739.2020.v6.37017. Disponível em: <https://periodicos.ufjf.br/index.php/enfermagem/article/view/37017>. Acesso em: 26 mar. 2025.
- FLORÊNCIO, Marlene Vitorino et al. **Tecnologias educacionais na graduação em enfermagem: um dinamizador do processo de ensino\***. *Revista Enfermagem Atual In Derme*, 7 out. 2019.
- GONÇALVES, J. de S.; ARAÚJO, P. F. de; MOREIRA, D. P.; SOARES, F. de M.; SALES, D. S.; SILVA, A. Z. da; FREIRES, A. V. A. F.; CAVALCANTE, M. G. S. **O uso da inteligência artificial no processo formativo de acadêmicos de enfermagem**. *Caderno Pedagógico*, [S. l.], v. 21, n. 7, p. e5593, 2024. DOI: 10.54033/cadpedv21n7-095. Disponível em: <https://ojs.studiespublicacoes.com.br/ojs/index.php/cadped/article/view/5593>. Acesso em: 29 mar. 2025.
- PEREIRA, M. C. Q. V.; RODRIGUES, D. M. F. **Inteligência artificial na educação em enfermagem: que realidade?**. *Brazilian Journal of Health Review*, [S. l.], v. 7, n. 2, p. e67946, 2024. DOI: 10.34119/bjhrv7n2-068. Disponível em: <https://ojs.brazilianjournals.com.br/ojs/index.php/BJHR/article/view/67946>. Acesso em: 29 mar. 2025.

PERISSÉ, L.; PERISSÉ, B. T.; FONSECA, C. dos S. G. da; SAMPAIO, C. E. P. **Desafios e limitações do enfermeiro inerentes à incorporação de novas tecnologias:** Nurses' challenges and limitations inherent in the incorporation of new technologies. *Revista Enfermagem Atual In Derme*, [S. l.], v. 87, n. 25, 2019. DOI: 10.31011/reaid-2019-v.87-n.25-art.208. Disponível em: <https://revistaenfermagematual.com.br/index.php/revista/article/view/208>. Acesso em: 31 mar. 2025.

PINHEIRO, Weider Silva; VALENTE, Evelyn Aida Tonioli. **INTELIGÊNCIA ARTIFICIAL NA EDUCAÇÃO: ENTRE A INOVAÇÃO TECNOLÓGICA E O DESAFIO ÉTICO.** *Revista Políticas Públicas & Cidades*, [S. l.], v. 13, n. 2, p. e1257, 2024. DOI: 10.23900/2359-1552v13n2-255-2024. Disponível em: <https://journalppc.com/RPPC/article/view/1257>. Acesso em: 29 mar. 2025.

PRAXEDES, Marcus Fernando Da Silva. **INTELIGÊNCIA ARTIFICIAL NA ENFERMAGEM: AVANÇOS, DESAFIOS E IMPLICAÇÕES.** In: *O cuidado em saúde baseado em evidências - Volume 5*. 1. ed. [S. l.]: Editora Científica Digital, 2024. p. 35–40.

SÁ, Maria Do Céu; NABAIS, Ana Sofia. **QUE IMPORTÂNCIA ATRIBUEM OS ESTUDANTES DE ENFERMAGEM ÀS NOVAS TECNOLOGIAS.** In: SÁ, Susana Oliveira E. *et al.* (Eds.). *New Trends In Qualitative Research*. [S. l.]: Ludomedia, 2020. p. 283–296.

SAMPAIO LUIZ, G.; APARECIDA DIAS DA SILVA CASTRO, A. **INTERLIGANDO TECNOLOGIAS E CUIDADOS EM ENFERMAGEM: SUPERANDO DESAFIOS E PROMOVENDO A EXCELÊNCIA NO CUIDADO AO PACIENTE.** *Revista Saúde Dos Vales*, [S. l.], v. 10, n. 1, 2024. DOI: 10.61164/rsv.v10i1.2942. Disponível em: <https://revista.unipacto.com.br/index.php/rsv/article/view/2942>. Acesso em: 15 mar. 2025.

SOARES, Bruno Johnson; FRANCO, Diego; SABINO, Bruno; EGUCHI, Michele. **Implicações da inteligência artificial na educação.** *TECCOGS – Revista Digital de Tecnologias Cognitivas*, n. 28, 2023, p. 76-86.



# Aplicação da Inteligência Artificial Generativa no Gerenciamento de Riscos de Projeto: Revisão Sistemática da Literatura

*Application of Generative Artificial Intelligence in Project Risk Management: A Systematic Literature Review*

Peterson Carlos Zimmermann Mai<sup>1</sup>, Claudio Alexandre de Souza<sup>2</sup> e Eduardo Cesar Dechechi<sup>3</sup>

1. Bacharel Engenharia de Produção. Discente Mestrado Profissional em Tecnologias, Gestão e Sustentabilidade (Unioeste). <https://orcid.org/0009-0000-1035-2614>. 2. Pós-Doutor pela École des Sciences de la Gestion (ESG) Université du Québec à Montréal (UQAM). Professor Associado (Unioeste). Membro permanente do Mestrado Profissional em Tecnologia, Gestão e Sustentabilidade (PPGTGS) e Bacharelado em Hotelaria. <https://orcid.org/0000-0002-0369-1084>. 3. Doutor Engenharia Química (UNICAMP). Especialista Gestão de Inovação em Empresas Internacionais (TECPAR) e Inovação no Setor Elétrico/Eletróbrás (UNICAMP). Professor Associado (Unioeste). Gestor de Inovação no SESI/FIEP, FRIMESA Cooperativa Agroindustrial e Fundação Parque Tecnológico Itaipu (FPTI). <https://orcid.org/0000-0001-6563-5435>.

[zimmermann.peterson@gmail.com](mailto:zimmermann.peterson@gmail.com) ; [cas\\_tur@yahoo.com.br](mailto:cas_tur@yahoo.com.br) e [dechechi@gmail.com](mailto:dechechi@gmail.com)

## Palavras-chave

Gerenciamento de Projetos  
Gerenciamento de Riscos  
de Projetos  
Inteligência Artificial Gene-  
rativa

## Keywords

Project Management  
Project Risks Management  
Generative Artificial Intelli-  
gence

## Resumo:

Este estudo objetiva analisar a inteligência artificial generativa (GenAI) aplicada ao gerenciamento de riscos em projetos por meio de revisão sistemática da literatura, seguindo os procedimentos do fluxo PRISMA e protocolos de busca nas bases Scopus, ScienceDirect e Google Scholar. Identificados 113 registros; após remoção de duplicatas e aplicação de critérios de inclusão relacionados a implementações empíricas de GenAI foram analisados 20 artigos publicados entre 2023 e maio de 2025. A maior parte concentra-se na fase de planejamento, utilizando *Large Language Models* (LLMs), como o modelo GPT-4 da OpenAI, para extração automática de riscos, predição de probabilidades e impactos, e geração de planos de resposta, além de aplicações em simulações preditivas, automação de relatórios, monitoramento em tempo real e análise de sentimentos em grandes bases de dados. Conclui-se que a GenAI pode aumentar significativamente a eficiência, a consistência e a agilidade das decisões no gerenciamento de riscos de projetos, embora sejam necessários frameworks robustos de governança de IA e validadas investigações em cenários operacionais reais.

## Abstract:

This study aims to analyze generative artificial intelligence (GenAI) applied to project risk management through a systematic literature review, following the PRISMA workflow procedures and search protocols in the Scopus, ScienceDirect, and Google Scholar databases. 113 records were identified; after removing duplicates and applying inclusion criteria related to empirical implementations of GenAI, 20 articles published between 2023 and May 2025 were analyzed. Most focus on the planning phase, using Large Language Models (LLMs), such as the OpenAI GPT-4 model, for automatic risk extraction, probability and impact prediction, and generation of response plans, as well as applications in predictive simulations, report automation, real-time monitoring, and sentiment analysis in large databases. It is concluded that GenAI can significantly increase the efficiency, consistency, and agility of decisions in project risk management, although robust AI governance frameworks and validated investigations in real-world operational scenarios are necessary.

Artigo recebido em: 17.07.2025.  
Aprovado para publicação em:  
07.11.2025.



## INTRODUÇÃO

NOS últimos anos, a nova geração de modelos de inteligência artificial, em especial os *Large Language Models* (LLMs), demonstra capacidade de gerar conteúdo de texto, imagem, áudio e código a partir de padrões aprendidos em grandes volumes de dados (Goodfellow et al., 2014; Vaswani et al., 2017; Brown et al., 2020). Essa evolução, conhecida como inteligência artificial generativa (GenAI), tem impactado setores como marketing, educação, saúde e desenvolvimento de software, oferecendo ferramentas que potencializam tanto a criatividade quanto a eficiência operacional (Vidrih; Mayahi, 2023; Vieriu; Petrea, 2025; Rodriguez et al., 2024; Peng et al., 2023).

No contexto do gerenciamento de projetos (GP), o processo de gerenciamento de riscos, que engloba as fases de identificação, análise, planejamento de respostas e monitoramento de incertezas, é reconhecido como fundamental para o sucesso de iniciativas de qualquer porte (PMI, 2021; ABNT, 2018). Neste contexto, pesquisas recentes têm explorado o uso de GenAI para suportar atividades de gerenciamento de riscos em projetos. Pinkowski (2023) analisa os efeitos dessa adoção sobre gerentes e organizações e avalia o nível de maturidade tecnológica usando os TRL (*Technology Readiness Levels*). Embora a IA ofereça grande potencial de benefícios ao GP, a implementação ainda enfrenta desafios. Chang (2024) indica que os gerentes de projeto devem priorizar competências interpessoais, manter-se atualizados sobre ferramentas de gestão de riscos baseadas em inteligência artificial e adotar postura ágil para acompanhar as mudanças provenientes.

Este trabalho tem como objetivo geral analisar como a inteligência artificial generativa tem sido aplicada ao gerenciamento de riscos em projetos, por meio de uma revisão sistemática da literatura. Para operacionalizar esse propósito, foram definidos os seguintes objetivos específicos:

1. Identificar como a GenAI tem sido empregada em cada fase do ciclo de vida de projetos (iniciação, planejamento, execução, monitoramento/controle e encerramento);
2. Levantar as contribuições práticas dessas técnicas na identificação e mitigação de riscos;
3. Identificar lacunas e oportunidades para pesquisas futuras na aplicação de GenAI ao gerenciamento de riscos de projetos.

Para orientar a pesquisa, este estudo procura responder à seguinte pergunta de pesquisa: Como a inteligência artificial generativa tem sido empregada para apoiar projetos de gerenciamento de riscos?

A importância deste estudo se revela em duas perspectivas. Na prática, organizações e profissionais de gerenciamento de projetos poderão se beneficiar de um mapeamento das aplicações de GenAI em riscos, orientando a adoção de soluções capazes de aumentar a produtividade, a qualidade das entregas e a capacidade de antecipar falhas (Nenni; De Felice; De Luca, 2024). No âmbito científico, a pesquisa contribui ao sintetizar evidências sobre o uso de GenAI em riscos de projetos, identificando lacunas teóricas e direcionando futuras investigações (Vieriu; Petrea, 2025).

A pesquisa segue as diretrizes do PRISMA (Moher et al., 2009) e o guia de Petticrew & Roberts (2008), aplicando protocolos de busca estruturada, seleção criteriosa de estudos e extração padronizada de dados. As buscas foram realizadas em maio de 2025 nas bases Scopus, ScienceDirect e Google Scholar, com termos em inglês e português relacionados a “*project risk management*”, “*gestão de riscos de projetos*” e “*generative AI*”. Foram incluídos estudos empíricos, publicados em periódicos e conferências revisados por pares, com foco na aplicação de GenAI para atividades de gerenciamento de riscos; trabalhos não revisados por pares e publicações fora de escopo tecnológico foram excluídos.

O artigo está organizado da seguinte forma: na Seção 2, apresenta o referencial teórico sobre gerenciamento de riscos de projetos e fundamentos de inteligência artificial generativa; a Seção 3 detalha a metodologia da revisão sistemática; a Seção 4 expõe os resultados e promove a discussão dos achados; por fim, a Seção 5 traz as conclusões, identifica limitações do estudo e sugere recomendações para pesquisas futuras.

## REFERENCIAL TEÓRICO

Nesta seção, abordaremos a fundamentação teórica que guia o escopo deste estudo. Aborda-se gerenciamento de riscos de projetos e inteligência artificial generativa.

### GERENCIAMENTO DE RISCOS DE PROJETOS

O gerenciamento de riscos de projetos constitui num conjunto de processos sistemáticos para identificar, analisar, tratar e monitorar incertezas que possam afetar os objetivos de um empreendimento. Conforme a norma ISO 31000:2018, risco é definido como “o efeito da incerteza nos objetivos” e seu tratamento envolve as fases de identificação, análise qualitativa, análise quantitativa, planejamento de respostas e monitoramento (ABNT, 2018). Já o PMI (2021) apresenta no Guia PMBOK sete processos agrupados em cinco grupos de processos: iniciar, planejar, executar, monitorar e encerrar, sendo que a gerenciamento de riscos transversal em todos esses grupos, com ênfase especial no grupo de planejamento e no de monitoramento/controle (PMI, 2021).

Na fase de identificação, técnicas como brainstorming, entrevistas com especialistas, análise de documentos históricos e análise SWOT são comumente utilizadas para mapear possíveis ameaças e oportunidades (Kerzner, 2017). A qualidade dessa identificação depende da diversidade de fontes de informação e da experiência da equipe envolvida. Em seguida, a análise qualitativa prioriza riscos segundo probabilidade e impacto, tipicamente por meio de matrizes de probabilidade x impacto, permitindo um mapeamento rápido, porém subjetivo (Chapman; Ward, 2003). Para projetos de maior complexidade, a análise quantitativa utiliza simulações de Monte Carlo, modelagem de árvores de decisão e análises de valor em risco (VaR), fornecendo estimativas numéricas sobre possíveis variações nos cronogramas e orçamentos (PMI, 2021).

O planejamento de respostas estabelece estratégias de mitigação (reduzir probabilidade ou impacto), transferência (terceirização, seguros), aceitação (sem ação) ou exploração (no caso de oportunidades), articulando planos de contingência e planos de resposta pré-aprovados (ABNT, 2018). A alocação de reservas de contingência e a definição de gatilhos para acionamento de respostas são fundamentais para assegurar a agilidade na reação a eventos adversos (Kerzner, 2017).

O monitoramento e controle de riscos envolve a revisão contínua dos riscos mapeados, a identificação de novos riscos e a eficácia das respostas implementadas. Indicadores-chave de desempenho (KPIs) e revisões periódicas em reuniões de status permitem ajustar planos conforme a evolução do contexto (PMI, 2021). A integração desse processo com o gerenciamento geral de mudanças e comunicações é essencial para que as ações de resposta sejam entendidas e executadas por toda a equipe de projeto.

A literatura também destaca a importância de uma cultura organizacional que valorize a comunicação transparente sobre riscos e a aprendizagem com lições aprendidas, transformando a gerenciamento de riscos de projetos num processo iterativo e colaborativo, capaz de aumentar a resiliência organizacional (Chapman; Ward, 2003; ABNT, 2018).

## INTELIGÊNCIA ARTIFICIAL GENERATIVA

A Inteligência Artificial Generativa (GenAI) são os modelos de aprendizado de máquina capazes de criar conteúdo original, como texto, imagem, áudio ou código, a partir de padrões aprendidos nos dados de treinamento. O surgimento das *Generative Adversarial Networks* (GANs), proposto por Goodfellow *et al.* (2014), iniciou uma nova fase ao criar um jogo de soma zero entre o gerador e o discriminador, melhorando a qualidade das imagens sintéticas produzidas. Posteriormente, a arquitetura de *Variational Autoencoders* (VAEs) e, sobretudo, a introdução de *transformers* por Vaswani *et al.* (2017) ampliaram as capacidades de modelagem de sequências, sobretudo em linguagens naturais.

Modelos como o GPT-3 aprendem a partir de grandes coleções de texto e, com poucos exemplos, conseguem realizar tarefas variadas, por exemplo, redigir e-mails a responder perguntas, sem a necessidade de reprogramação complexa (BROWN *et al.*, 2020). Da mesma forma, ferramentas como o *Stable Diffusion* usam técnicas avançadas para transformar descrições em texto em imagens detalhadas, permitindo gerar figuras de alta qualidade apenas a partir de instruções simples (ROMBACH *et al.*, 2022).

No contexto empresarial, Vidrih e Mayahi (2023) observaram que a adoção de GenAI tem potencializado a inovação ao automatizar tarefas e gerar protótipos, acelerando ciclos de pesquisa e desenvolvimento. Relatórios de consultorias apontam: ferramentas de GenAI podem automatizar até 60-70% das atividades cognitivas dos profissionais, liberando tempo para estratégias (MCKINSEY GLOBAL INSTITUTE, 2024).

Tecnicamente, a GenAI baseia-se na modelagem de distribuições de probabilidade sobre espaços de alta dimensionalidade. Os *transformers* utilizam mecanismos de atenção que pesam relações contextuais entre elementos de entrada, permitindo maior coerência sequencial. As GANs, por sua vez, convergem para distribuições reais por meio de um processo adversarial que refina continuamente a geração (GOODFELLOW *et al.*, 2014). Modelos de difusão aplicam ruído iterativo e um processo de *denoising* para amostrar dados de alta fidelidade a partir de distribuições simples (ROMBACH *et al.*, 2022).

Em resumo, a GenAI apresenta fundamentos teóricos e arquiteturas diversas, tornando-se uma tecnologia madura para aplicação em cenários industriais e acadêmicos. Seu potencial de integração com processos de tomada de decisão, análise preditiva e automação de tarefas cognitivas motiva a investigação de aplicações específicas, como o suporte à gerenciamento de riscos em projetos, tema central desta revisão.

## PROCEDIMENTOS METODOLÓGICOS

Este estudo, conduzido através de uma revisão sistemática da literatura, emprega métodos de análise de conteúdo para a codificação e interpretação dos dados (Bardin, 2009). Adotou-se o procedimento de revisão sugerido por Petticrew e Roberts (2008), que inclui a definição do problema de pesquisa, a criação do protocolo de revisão, a identificação dos estudos, a seleção, a análise da qualidade, a extração de dados, a síntese e a apresentação dos resultados.

A busca foi realizada em maio de 2025 nas bases de dados Scopus, ScienceDirect e Google Scholar, empregando operadores booleanos para combinar termos relativos a “project risk management”, “gestão de riscos de projetos”, “*generative AI*”, “IA generativa”, “*large language model*”, “GPT” e “ChatGPT”. Seguindo as *strings* de busca da tabela 1.

Foram considerados apenas trabalhos de acesso aberto, categorizados como artigos de periódicos completos ou anais de conferência completos, redigidos em português, inglês ou espanhol e publicados entre janeiro de 2020 e maio de 2025. Essa busca inicial resultou em 112 registros. Adicionalmente, um estudo iden-

tificado manualmente por sua relevância temática foi incluído, elevando o total para 113 documentos submetidos às etapas subsequentes de seleção.

**Tabela 1. Strings de busca nas bases de dados.**

<b>Base de Dados</b>	<b>String de Busca</b>
Scopus	( TITLE-ABS-KEY ( "project management" OR "project managers" ) AND TITLE-ABS-KEY ( "generative artificial intelligence" ) OR TITLE-ABS-KEY ( "prompt engineering" OR *gpt* OR bert OR ( "Natural Language Processing" OR nlp ) OR deepseek OR gemini OR claude ) AND TITLE-ABS-KEY ( "risk management" OR "risk assessment" OR risk ) ) AND PUBYEAR > 2019 AND PUBYEAR < 2026 AND ( LIMIT-TO ( LANGUAGE , "English" ) OR LIMIT-TO ( LANGUAGE , "Portuguese" ) OR LIMIT-TO ( LANGUAGE , "Spanish" ) ) AND ( LIMIT-TO ( DOCTYPE , "cp" ) OR LIMIT-TO ( DOCTYPE , "ar" ) ) AND ( LIMIT-TO ( OA , "all" ) ) AND ( LIMIT-TO ( EXACTKEYWORD , "Project Management" ) ) )
ScienceDirect	("project management" AND "project risk management" AND (nlp OR "natural language processing" OR "artificial intelligence" OR ai OR "large language model" OR gpt OR chatgpt))
Google Scholar	("project management" OR "gestão de projetos" OR "gerenciamento de projetos") AND ("project risk management" OR "gestão de riscos de projetos") AND ("inteligência artificial" OR "artificial intelligence") AND (gpt OR chatgpt OR "gpt-3" OR "gpt-4") AND ("project Planning"))

Fonte: elaborado pelos autores.

Na etapa de triagem, foram excluídos 4 registros duplicados; em seguida, aplicaram-se os critérios de inclusão de caráter empírico, enfoque tecnológico e relevância temática, conforme descrito na Tabela 2, o que resultou na exclusão de 83 documentos.

**Tabela 2. Critérios de Inclusão.**

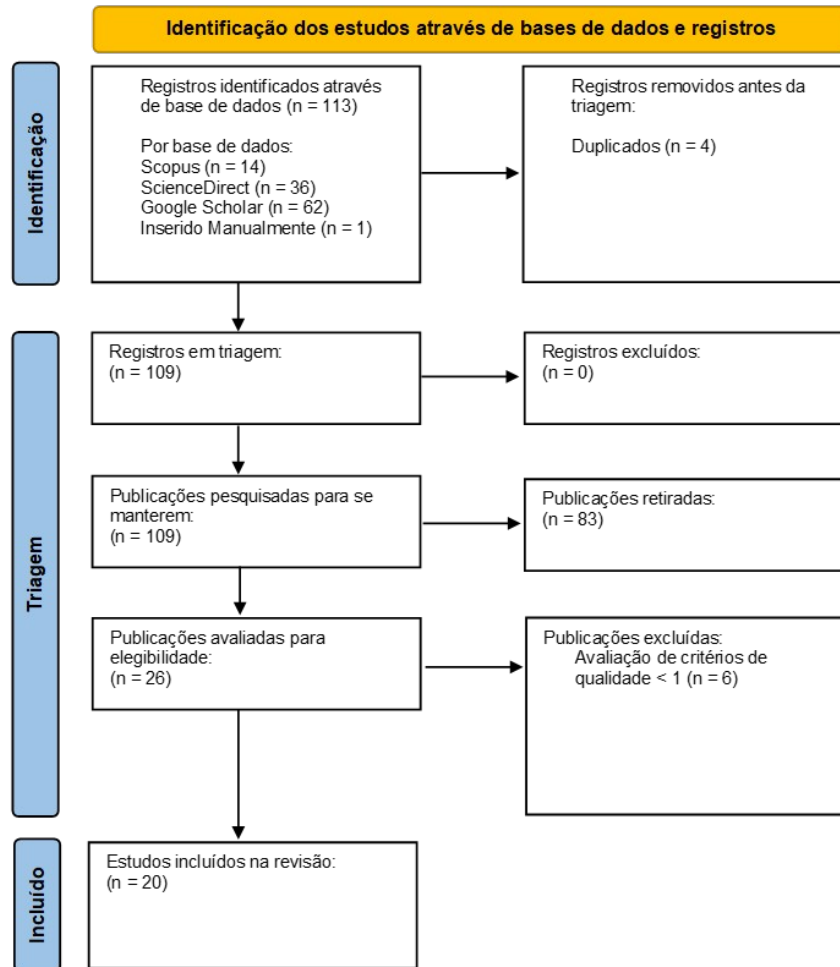
<b>Critério</b>	<b>Descrição</b>
Empírico	Estudos que apresentem implementação prática ou avaliação de caso real, afastando-se de discussões puramente teóricas.
Foco tecnológico	Uso explícito de modelos de IA generativa (por exemplo, GPT, LLMs).
Foco temático	Aplicação em gerenciamento de projetos, contemplando ao menos uma fase de gestão de riscos (identificação, análise e/ou mitigação).

Fonte: elaborado pelos autores.

A fase de elegibilidade, procedeu-se à leitura integral dos 26 documentos, dos quais 20 foram considerados elegíveis para análise detalhada. A avaliação da qualidade foi realizada com base em um *checklist* específico, composto pelas seguintes perguntas-chave:

1. O estudo aborda IA generativa na gestão de projetos?
2. O estudo aborda IA na gestão de riscos de projetos?
3. O estudo apresenta benefícios da IA generativa na gestão de projetos?

Cada questão recebeu pontuação de 1 (Sim), 0,5 (Parcialmente) ou 0 (Não), e apenas os artigos que obtiveram nota total superior a 1 foram incluídos na revisão final. Ao término desse processo, 20 estudos atenderam aos critérios e foram mantidos, conforme fluxo PRISMA, descrito por Moher *et al.* (2009), de acordo com a Figura 1.

**Figura 1. Fluxo da triagem PRISMA.**

Fonte: elaborado pelos autores.

Com os documentos selecionados, procedeu-se à extração de dados dos 20 artigos selecionados decorrente da utilização de formulário padronizado, que contemplou:

1. Autores;
2. Ano de publicação;
3. Periódico ou evento;
4. Fase do ciclo de vida do projeto é predominante o uso da GenAI;
5. Tipo de projeto abordado no estudo;
6. Ferramenta de GenAI utilizada;
7. Aplicações no gerenciamento de riscos de projetos e gerenciamento de projetos;
8. Contribuições do trabalho.

## ANÁLISE E DISCUSSÃO DOS RESULTADOS

A Tabela 3 compila os 20 artigos escolhidos para esta revisão, para cada estudo, o código de identificação, o título, o ano de publicação e os autores. Esses estudos foram selecionados com base nos critérios de inclusão estabelecidos no protocolo, que se concentram em aplicações de GenAI no gerenciamento de projetos com foco no gerenciamento de riscos.

**Tabela 3. Documentos selecionados para revisão.**

<b>Id</b>	<b>Título</b>	<b>Ano</b>	<b>Autores</b>	<b>Periódico/Evento</b>
1	<i>Assessing the Accuracy of ChatGPT Use for Risk Management in Construction Projects</i>	2023	Aladağ, H.	<i>Sustainability (Switzerland)</i>
2	<i>Investigating the use of ChatGPT for the scheduling of construction projects</i>	2023	Prieto, S. A.; Mengiste, E. T.; García De Soto, B.	<i>Buildings</i>
3	<i>Who is better in project planning? Generative artificial intelligence or project managers?</i>	2023	Barcaui, A.; Monat, A.	<i>Project Leadership and Society</i>
4	<i>AI in Project Memory and Learning: But Not All Blueprints Are the Same</i>	2024	Eshraghi, A.	<i>ACIS 2024 Proceedings</i>
5	<i>Artificial intelligence and project management: An empirical investigation on the appropriation of generative Chatbots by project managers</i>	2024	Felicetti et al.	<i>Journal of Innovation &amp; Knowledge</i>
6	<i>Can ChatGPT exceed humans in construction project risk management?</i>	2024	Nyqvist, R.; Peltokorpi, A.; Seppänen, O.	<i>Engineering, Construction and Architectural Management</i>
7	<i>Chatbot Design and Implementation: Towards an Operational Model for Chatbots</i>	2024	Skuridin, A.; Wynn, M.	<i>Information (Switzerland)</i>
8	<i>Inteligência artificial e gestão de projetos: aplicação para busca semântica usando ChatGPT e LangChain para combater as barreiras tecnológicas ao uso das lições aprendidas em projetos</i>	2024	Ribeiro, W. D.; Nobre, A. C. S.	<i>Anais do XII SINGEP-CIK</i>
9	<i>Optimizing Management Processes: Integrating Generative AI to Bridge Gaps in Project, Engineering, and Construction Management Skills.</i>	2024	Anik, M. A. S.	<i>7th Bangladesh Conference on Industrial Engineering and Operations Management</i>
10	<i>The Erosion of Competencies in Managing Innovation Projects due to the Impact of Ubiquitous Artificial Intelligence Systems</i>	2024	Bushuyev et al.	<i>Procedia Computer Science</i>
11	<i>The role of artificial intelligence in project management: a supply chain perspective</i>	2024	Georgiev et al.	<i>Supply Chain Forum: An International Journal</i>
12	<i>The Role of Artificial Intelligence in Revolutionizing Construction Project Management: Enhancing Efficiency and Sustainability</i>	2024	Hameed et al.	<i>North American Academic Research</i>
13	<i>Understanding the role of Artificial Intelligence tools in project performance domains</i>	2024	Chaves, M. S.; Alves, J. R.; Curço, E. F.	<i>MCIS 2024 Proceedings</i>
14	<i>Unlocking the potential of artificial intelligence in project management: insights from the polish it sector.</i>	2024	Starowicz-Rajca et al.	<i>Scientific Papers of Silesian University of Technology Organization and Management Series</i>
15	<i>Utilizing large language models to illustrate constraints for construction planning</i>	2024	He et al.	<i>Buildings</i>
16	<i>AI driven strategic decision-making in IT project management: Enhancing risk assessment, cost control, and efficiency</i>	2025	Tanim, S. H.; Ahmad, M. S.	<i>World Journal of Advanced Research and Reviews</i>
17	<i>Enhancing Project Management Success through Artificial Intelligence</i>	2025	Reznikov, R.	<i>International Journal of Multidisciplinary Research and Growth Evaluation</i>
18	<i>Generative AI in Academia: A Comprehensive Review of Applications and Implications for the Research Process.</i>	2025	Hanafi et al.	<i>International Journal of Engineering and Applied Sciences-October 6 University</i>
19	<i>Leveraging Data-Driven Decision-Making for Enhanced Risk Management and Resource Allocation in Projects</i>	2025	Kehide, O.	<i>International Journal of Computer Applications Technology and Research</i>
20	<i>The Role of Artificial Intelligence in Managing Scientific Research Projects Funded by KEGA and VEGA Grant Schemes</i>	2025	Bočková, K.; Procházka, D. A.; Bartoš, P.	<i>Journal of Ecohumanism</i>

Fonte: Elaborado pelos autores.


Este levantamento tem como objetivo fornecer uma visão geral inicial do que tem sido estudado na interseção entre GenAI e gerenciamento de riscos de projetos. A tabela detalha a identificação das áreas de atu-



Isso pode indicar que a literatura foca principalmente na aplicação geral da GenAI em processos de gerenciamento de projetos e no uso de modelos de linguagem, ao passo que as técnicas específicas para análise e mitigação de riscos ainda estão em fase inicial. Identificar essa lacuna indica oportunidades para expandir estudos sobre a aplicação da GenAI em todas as fases da gestão de riscos, principalmente em avaliações preditivas e na automação de controles.

A leitura dos documentos possibilitou a extração dos tipos de projetos em que foram aplicados os estudos. Para evidenciar essa distribuição podemos verificar a Figura 4, que destaca as áreas dos projetos e quantidade de documentos alocados em cada uma delas.

**Figura 4.** Gráfico de frequência de publicações por tipo de projeto.



Fonte: Elaborado pelos autores.

Destaque para os 7 trabalhos em gerenciamento de projetos, 6 em construção, 3 em sistemas de Tecnologia da informação (TI), 2 em pesquisa acadêmica, 1 em inovação e 1 em cadeia de suprimentos identificados na Tabela 4. Essa concentração em gerenciamento de projetos e construção reflete o foco atual da aplicação de IA nesses domínios. As categorias de TI, pesquisa acadêmica, inovação e cadeia de suprimentos aparecem com menor frequência, indicando áreas com potencial ou até mesmo explorar outras para novos estudos.

**Tabela 4.** Detalhamento de documentos por tipo de projeto.


Tipo	Identificações
Gerenciamento de Projetos	4, 5, 7, 8, 13, 17, 19
Construção	1, 2, 6, 9, 12, 15
TI	3, 14, 16
Pesquisa	18, 20
Inovação	10
Cadeia de Suprimentos	11

Fonte: Elaborado pelos autores.

A Figura 5 mostra que a fase de Planejamento concentra a maioria dos estudos, seguida pela fase combinada de Planejamento e Monitoramento. As etapas como Execução, Monitoramento e Controle e Encerramento têm representação menor. Esse enfoque no começo do ciclo do projeto indica que a GenAI tem sido principalmente empregada para auxiliar na identificação e análise de riscos antes do início das operações.



Figura 5. Gráfico de quantidade por fase do ciclo de vida do gerenciamento de projetos.



Fonte: Elaborado pelos autores.

Na Tabela 5, detalha as identificações dos artigos. Nesse contexto, ferramentas de extração automática de riscos e simulações preditivas aproveitam a oportunidade para identificar possíveis ameaças de maneira antecipada. Em contrapartida, a falta de estudos nas fases posteriores sugere a necessidade de criar soluções que incorporem a GenAI ao monitoramento em tempo real, ao gerenciamento adaptativo de riscos durante a execução e ao suporte para conclusão e aprendizado.

Tabela 5. Detalhamento de documentos por fase do ciclo de vida do projeto.

Fase	Identificações
Transversal	1, 5, 7, 10, 13, 17, 18
Planejamento	2, 4, 6, 8, 15
Planejamento e Monitoramento	9, 11, 12, 14
Planejamento, Execução e Monitoramento	16, 19
Iniciação e Planejamento	3
Iniciação e Encerramento	20

Fonte: Elaborado pelos autores.

Conforme Tabela 6, que apresenta uma síntese dos estudos, mostram que a GenAI tem sido utilizada em gestão de riscos de projetos, como a extração automática de riscos e elaboração de planos de contingência em cenários de construção, além de planos de projeto (Aladağ, 2023; Prieto; Mengiste; García De Soto, 2023; Barcaui; Monat, 2023), simulações preditivas e prescritivas para avaliar a probabilidade e o impacto de eventos adversos (Eshraghi, 2024; Anik, 2024; Kehinde, 2025), automação de respostas com propostas de mitigação e consolidação de lições aprendidas (Ribeiro; Nobre, 2024; He *et al.*, 2024; Tanim; Ahmad, 2025), monitoramento em tempo real de indicadores de risco e análise contínua de sentimentos em grandes bases de dados (Reznikov, 2025; Tanim; Ahmad, 2025); monitoramento em tempo real de indicadores de risco e análise contínua de sentimento em grandes bases de dados (Reznikov, 2025; Tanim; Ahmad, 2025), e integração de modelos de IA com frameworks tradicionais de gerenciamento, promovendo sinergia entre análise do modelo e conhecimento humano (Nyqvist; Peltokorpi; Seppänen, 2024; Skuridin; Wynn, 2024).

Tabela 6. Aplicações e Contribuições.

Id	Aplicações na Gestão de Riscos de Projetos	Contribuições	Ferramenta
1	Coleta de dados de fatores de risco; alocação de riscos; geração de planos contingenciais; suporte à sustentabilidade.	precisão do ChatGPT em gestão de riscos de construção e na decisão baseada em riscos.	ChatGPT
2	NLP para extração de insights de progresso e inspeções; LLMs para precisão de cronogramas; chatbots para comunicação; validação de confiabilidade de cronogramas; limitação em estimativas de custo.	Usar GPT para agendamento de construção e avaliar LLMs em cronogramas.	ChatGPT
3	Avaliação e mitigação de riscos em grandes datasets; categorização legal, tecnológica, de mercado e financeira; análise qualitativa e quantitativa; estratégias de resposta proativas.	Automação de tarefas repetitivas e otimização de recursos; aumento de produtividade e qualidade; sinergia IA-humano; engenharia de prompts para maior relevância.	GPT-4
4	IA Preditiva para avaliação de riscos e IA Generativa para criação de cenários; busca e recuperação automática de dados padronizados.	Aborda o arranjo sociotécnico; destaca como lições aprendidas ampliam produtividade e inovação.	Nenhuma específica
5	Antecipação proativa de riscos e colaboração em tempo real; aprimora a tomada de decisões humanas.	Identifica fatores críticos de adoção (Inovação, Influência de Pares, Ajuste Tarefa-Tecnologia).	ChatGPT
6	Geração de estratégias de mitigação e novas perspectivas de risco; aumento de eficiência e precisão.	Estudo cego comparativo entre GPT-4 e especialistas; propõe modelo colaborativo IA-humano.	ChatGPT
7	Redução de incertezas e suporte à tomada de decisões e gestão de riscos via modelo operacional.	Define fatores críticos de sucesso e valida frameworks (TOE, Nicholas & Steyn, Earl)	Nenhuma específica
8	Suporte indireto à identificação proativa de riscos ao fornecer respostas precisas e contextualizadas para as lições aprendidas, reduzindo o tempo de busca.	Processo metodológico e aplicação autoral inéditos; democratiza o acesso às lições aprendidas e acelera a tomada de decisão.	ChatGPT; LangChain
9	Previsão de desempenho, gerenciamento de riscos com redes neurais artificiais e lógica fuzzy; previsão de atrasos e custos.	Demonstra o impacto transformador da GenAI na eficiência, comunicação e sustentabilidade da GP.	ChatGPT
10	Reconhece a capacidade da IA de gerar insights de grandes volumes de dados, mas não detalha uso específico em riscos, alertando para erosão do pensamento crítico e resolução de problemas.	Examina a erosão de competências humanas; enfatiza a necessidade de interpretação e integração de IA; propõe programas de treinamento e modelo de dependência de IA versus experiência.	ChatGPT
11	Previsão avançada de riscos e gerenciamento preditivo; destaca limitações de cibersegurança.	Mapeia desafios de adoção, motivações (produtividade, insights) e riscos da IA em cadeias de suprimentos.	Nenhuma específica
12	Previsão avançada de riscos e gerenciamento preditivo de projetos.	Realça IA como parceira para eficiência, sustentabilidade e segurança em construção.	Nenhuma específica
13	Análise de riscos por machine learning para aprimorar o gerenciamento de riscos de projetos.	Evidencia benefícios práticos: otimização de recursos, análise de riscos, monitoramento e geração de relatórios.	Nenhuma específica
14	Suporte indireto à gestão de riscos por meio da análise de retrospectivas que censuram riscos passados.	Demonstra evolução de práticas em TI; avalia impacto de Atlassian AI e ChatGPT na eficiência da GP.	ChatGPT; MS 365 Copilot; GitHub Copilot; Gemini; Confluence AI; Jira AI; Claude A.I.
15	Identificação e análise automatizada de restrições como riscos; mapeamento de causas, impactos e soluções.	Introduz métrica “suficiência de discussão” e ferramenta de extração de informações baseada em GPT para restrições.	GPT-3.5; BERT; GPT-4
16	ML para classificação de riscos e eliminação de vieses; NLP para detecção de riscos; análise de sentimento e monitoramento contínuo com resposta automática.	Decisões proativas; redução de falhas em até 25%; maior precisão de previsão e otimização de recursos; automação de tarefas repetitivas; aumento de produtividade, resiliência e segurança de dados via blockchain.	Nenhuma específica
17	Monitoramento em tempo real e análise preditiva para melhoria da gestão de incertezas e antecipação de riscos.	Casos de uso práticos que geram economias de tempo e custo; integra IA de ponta a frameworks tradicionais de GP.	Nenhuma específica
18	Não aplica diretamente à gestão de riscos de projetos; discute a utilização das ferramentas de GenAI em projetos de pesquisa acadêmica.	Automatiza revisão de literatura, escrita e gerenciamento de citações, liberando pesquisadores para tarefas de alto nível.	ChatGPT; DALL·E; Midjourney; Semantic Scholar; SciSpace
19	Identificação, avaliação e mitigação de riscos via análise preditiva, descritiva e prescritiva; Big Data e IoT para riscos emergentes; simulação Monte Carlo e modelos dinâmicos.	Práticas baseadas em evidências; otimização de recursos e redução de desperdícios; maior transparência e responsabilidade; roteiro para adoção de data-driven; aumento de taxa de sucesso e inovação.	Nenhuma específica
20	Previsão de riscos e otimização da alocação de recursos; propõe estratégias de mitigação; alerta para segurança de dados e “alucinações” de IA.	Automação de tarefas administrativas; melhoria da eficiência, qualidade dos resultados e comunicação entre stakeholders.	GPT-4

Fonte: Elaborado pelos autores.

Essas contribuições diminuem o esforço manual e melhoram a consistência na detecção e análise de riscos, agilizando o processo de decisão nas etapas iniciais do projeto (Tanim; Ahmad, 2025; Kehinde, 2025). Ao automatizar tarefas repetitivas, os gestores podem se concentrar em aspectos qualitativos e estratégicos, aumentando a eficácia das ações preventivas e corretivas (Bushuyev *et al.*, 2024; Hanafi *et al.*, 2025).

Os resultados indicam oportunidades futuras na governança da IA, na validação de modelos em contextos reais e na ampliação dessas soluções para o monitoramento e controle contínuo durante todo o ciclo de vida dos projetos.

## CONCLUSÕES

Este estudo permitiu compreender como a GenAI pode ser aplicada não apenas na gestão de riscos, mas em todo o ciclo de vida de projetos, estendendo-se ainda a outras áreas que demandam automação de tarefas e recuperação eficiente de informações. Verificou-se que a colaboração entre sistemas de GenAI e profissionais humanos é fundamental para aprimorar o planejamento e o monitoramento, resultando em decisões mais ágeis e precisas. Ao mesmo tempo, torna-se relevante explorar como as empresas e seus gerentes de projeto percebem essas aplicações empíricas no contexto da tomada de decisão, de modo a alinhar expectativas e promover a adoção efetiva das soluções desenvolvidas.

Foi possível identificar diversas oportunidades para investigações futuras, como o desenvolvimento de comandos personalizados para identificação de riscos e a utilização baseada em *LangChain* ou similares para criar agentes especializados capazes de acessar e processar documentos em repositórios corporativos. Além disso, vale ressaltar a necessidade de aprofundar o debate sobre aspectos éticos, de modo a garantir a segurança, a transparência e a responsabilidade no uso da GenAI em contextos organizacionais.

## REFERÊNCIAS

- ALADAĞ, Hande. **Assessing the accuracy of ChatGPT use for risk management in construction projects**. Sustainability (Switzerland), v. 15, n. 22, 2023. DOI: <https://doi.org/10.3390/su152216071>.
- ANIK, M. A. S. **Optimizing management processes: integrating generative AI to bridge gaps in project, engineering, and construction management skills**. In: 7th IEOM Bangladesh International Conference on Industrial Engineering and Operations Management, 2024. [S.l.]: [s.n.], 2024. DOI: <https://doi.org/10.46254/BA07.20240043>.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR ISO 31000: Gestão de riscos – Diretrizes**. Rio de Janeiro: ABNT, 2018.
- BARCAUI, André; MONAT, André. **Who is better in project planning? Generative artificial intelligence or project managers?** Project Leadership and Society, v. 4, 2023. DOI: <https://doi.org/10.1016/j.plas.2023.100101>.
- BARDIN, Laurence. **Análise de conteúdo**. 6. ed. Lisboa: Edições 70, 2009.
- BOČKOVÁ, Katja; PROCHÁZKA, D. A.; BARTOŠ, P. **The role of artificial intelligence in managing scientific research projects funded by KEGA and VEGA grant schemes**. Journal of Ecohumanism, v. 4, n. 1, p. 1448–1476, 2025. DOI: <https://doi.org/10.62754/joe.v4i1.5960>.
- BROWN, T. B.; MANN, B.; RYDER, N.; SUBBIAH, M.; KAPLAN, J.; DHARIWAL, P.; NEELAKANTAN, A.; SHYAM, P.; SASTRY, G.; ASKELL, A.; AGARWAL, S.; HERBERT-VOSS, A.; KRUEGER, G.; HENIGHAN, T.; CHILD, R.; RAMESH, A.; ZIEGLER, D. M.; WU, J.; WINTER, C.; HESSE, C.; CHEN, M.; SIGLER, E.; LITWIN, M.; GRAY, S.; CHESS, B.; CLARK, J.; BERNER, C.; MCCANDLISH, S.; RADFORD, A.; SUTSKEVER, I.; AMODEI, D. **Language Models are Few-Shot Learners**. Versão arXiv:2005.14165. [S. l.]: arXiv, 2020. DOI: <https://doi.org/10.48550/arXiv.2005.14165>.
- BUSHUYEV, Sergiy; BUSHUIEV, Denis; BUSHUIEVA, Victoria; BUSHUYEVA, Natalia; MURZABEKOVA, Svetlana. **The erosion of competencies in managing innovation projects due to the impact of ubiquitous artificial intel-**
- 
- MAI, P.C.Z.; DECHECHI, E.C.; SOUZA, C.A. Aplicação da Inteligência Artificial Generativa no Gerenciamento de Riscos de Projeto: Revisão Sistemática da Literatura. Pleiade, 19(49): 88-101, Out.-Dez., 2025  
DOI: 10.32915/pleiade.v19i49.1204

**ligence systems.** In: 14th International Conference on Emerging Ubiquitous Systems and Pervasive Networks; 13th International Conference on Current and Future Trends of Information and Communication Technologies in Healthcare (EUSPN/ICTH), Proceedings. 2024. p. 403–408. DOI: <https://doi.org/10.1016/j.procs.2023.12.225>.

CHANG, Jiawei. **Exploring the Effectiveness of AI in Project Risk Management:** What Project Managers Do to Facilitate Changes. 2024. Dissertação (Mestrado) – Purdue University Graduate School, West Lafayette, 2024. DOI: 10.25394/PGS.25648911.v1.

CHAPMAN, Chris; WARD, Stephen. **Risk Management:** Principles and Practices. Londres: E & FN Spon, 2003.

CHAVES, M. S.; ALVES, J. R.; CURÇO, E. F. **Understanding the role of Artificial Intelligence tools in project performance domains.** In: Proceedings of MCIS, 2024. Disponível em: <https://aisel.aisnet.org/mcis2024/13>. Acesso em: maio 2025.

ESHRAHGI, Ali. **AI in Project Memory and Learning:** but not all blueprints are the same. In: Proceedings of ACIS 2024, 2024. [S.l.]: [s.n.], 2024. Disponível em: <<https://aisel.aisnet.org/acis2024/165/>>. Acesso em: maio 2025.

FELICETTI, Alberto Michele; CIMINO, Antonio; MAZZOLENI, Alberto; AMMIRATO, Salvatore. **Artificial intelligence and project management:** an empirical investigation on the appropriation of generative chatbots by project managers. Journal of Innovation & Knowledge, v. 9, n. 3, p. 100545, 2024. DOI: <https://doi.org/10.1016/j.jik.2024.100545>.

GEORGIEV, Serafim; POLYCHRONAKIS, Yiannis; SAPOUNTZIS, Spiros; POLYCHRONAKIS, Nikolaos. **The role of artificial intelligence in project management:** a supply chain perspective. Supply Chain Forum: An International Journal, 2024. DOI: <https://doi.org/10.1080/16258312.2024.2384823>.

GOODFELLOW, Ian J. *et al.* **Generative Adversarial Nets.** In: GHAHRAMANI, Z. *et al.* (orgs.). Curran Associates, Inc., 2014. Disponível em: <[https://proceedings.neurips.cc/paper\\_files/paper/2014/file/f033ed80-deb0234979a61f95710dbe25-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2014/file/f033ed80-deb0234979a61f95710dbe25-Paper.pdf)> Acesso em: junho 2025.

HAMEED, Ahamed; AHMED, S. S.; RASEL, A. B. S.; HAMIM, M.; SOK, M.; TESFALEM, A. The role of artificial intelligence in revolutionizing construction project management: enhancing efficiency and sustainability. North American Academic Research, 2024. DOI: <https://doi.org/10.5281/zenodo.14840458>.

HANAFI, Ahmed M.; AL-MANSI, Mohamed M.; AL-SHARIF, Omar A.; *et al.* **Generative AI in academia:** a comprehensive review of applications and implications for the research process. International Journal of Engineering and Applied Sciences – October 6 University, v. 2, n. 1, p. 91–110, 2025. DOI: <https://doi.org/10.21608/ijeasou.2025.349520.1041>.

HE, Chenyu; YU, Bo; LIU, Ming; GUO, L.; TIAN, L.; HUANG, J. **Utilizing large language models to illustrate constraints for construction planning.** Buildings, v. 14, n. 8, p. 2511, 2024. DOI: <https://doi.org/10.3390/buildings14082511>.

KEHIDE, O. **Leveraging data-driven decision-making for enhanced risk management and resource allocation in projects.** International Journal of Computer Applications Technology and Research, 2025. DOI: <https://doi.org/10.7753/IJCATR1402.1001>.

KERZNER, Harold. **Project Management:** a Systems Approach to Planning, Scheduling, and Controlling. 12. ed. Hoboken: Wiley, 2017.

MCKINSEY GLOBAL INSTITUTE. **Economic potential of generative AI | McKinsey.** Disponível em: <<https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/the-economic-potential-of-generative-ai-the-next-productivity-frontier>>. Acesso em: junho 2025.

MOHER, David; LIBERATI, Alessandro; TETZLAFF, Jennifer; ALTMAN, Douglas G. Preferred Reporting Items for Systematic Reviews and Meta-Analyses: **the PRISMA Statement.** PLoS Medicine, v. 6, n. 7, p. e1000097, 2009. DOI: <https://doi.org/10.1371/journal.pmed.1000097>.

NENNI, Maria Elena *et al.* **How artificial intelligence will transform project management in the age of digitization:** a systematic literature review. Management Review Quarterly, v. 75, n. 2, p. 1669–1716, 2025. DOI: <https://doi.org/10.1007/s11301-024-00418-z>

NYQVIST, Roope; PELTOKORPI, Antti; SEPPÄNEN, Olli. **Can ChatGPT exceed humans in construction project risk management?** Engineering, Construction and Architectural Management, v. 31, n. 13, p. 223–243, 2024. DOI: <https://doi.org/10.1108/ECAM-08-2023-0819>.

- PENG, Sida *et al.* **The Impact of AI on Developer Productivity: Evidence from GitHub Copilot.** 2023. Disponível em: <<https://arxiv.org/abs/2302.06590>>. Acesso em: junho 2025.
- PETTICREW, Mark; ROBERTS, Helen. **Systematic Reviews in the Social Sciences: a Practical Guide.** Malden: Blackwell, 2008.
- PINKOWSKI, Márcio Luiz. **Aplicação da inteligência artificial na gestão de projetos: aderência, impacto e grau de desenvolvimento.** 2023. Dissertação (Programa de Pós-Graduação em Gestão de Projetos) – Universidade Nove de Julho, São Paulo, 2023. 128 f. Disponível em: <http://bibliotecatede.uninove.br/handle/tede/3210>. Acesso em: maio 2025.
- PRIETO, Sebastián A.; MENGISTE, Ermias T.; GARCÍA DE SOTO, Berenice. **Investigating the use of ChatGPT for the scheduling of construction projects.** Buildings, v. 13, n. 4, p. 857, 2023. DOI: <https://doi.org/10.3390/buildings13040857>.
- PROJECT MANAGEMENT INSTITUTE (PMI). **A Guide to the Project Management Body of Knowledge (PM-BOK® Guide).** 7. ed. Newtown Square: Project Management Institute, 2021.
- REZNIKOV, Roman. **Enhancing project management success through artificial intelligence.** [S.l.], 2025. DOI: <https://doi.org/10.54660/IJMRGE.2025.6.1.1036-1046>.
- RIBEIRO, Waldelino Duarte; NOBRE, Anna Cláudia dos Santos. **Inteligência Artificial e Gestão de Projetos: aplicação para busca semântica usando ChatGPT e LangChain para combater as barreiras tecnológicas ao uso das lições aprendidas em projetos.** In: XII SINGEP-CIK – Seminário Internacional de Gestão de Projetos e Conferência Internacional do CIK, 12., 23 a 25 out. 2024, São Paulo. Anais. São Paulo: UNINOVE, 2024. p. 1–13. Disponível em: <<https://submissao.singep.org.br/12singep/proceedings/arquivos/114.pdf>>. Acesso em: maio 2025.
- RODRIGUEZ, Danissa V. *et al.* **Leveraging Generative AI Tools to Support the Development of Digital Solutions in Health Care Research: Case Study.** JMIR Human Factors, v. 11, p. e52885, 6 mar. 2024. DOI: <https://doi.org/10.2196/52885>.
- ROMBACH, Robin; BLATTMANN, Andreas; LORENZ, Dominik; ESSER, Patrick; OMMER, Björn. **High-Resolution Image Synthesis with Latent Diffusion Models.** In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022, [S.l.]. p. 10684–10695. DOI: <https://doi.org/10.1109/CVPR52688.2022.01042>.
- SKURIDIN, Alexander; WYNN, Martin. **Chatbot design and implementation: towards an operational model for chatbots.** Information (Switzerland), v. 15, n. 4, 2024. DOI: <https://doi.org/10.3390/info15040226>.
- STAROWICZ-RAJCA, Hanna; LEWICKA, Dorota; LASZYK, Adam; WILCZEWSKI, Andrzej; PEĆ, Maciej. **Unlocking the potential of artificial intelligence in project management: insights from the Polish IT sector.** Scientific Papers of Silesian University of Technology. Organization & Management / Zeszyty Naukowe Politechniki Śląskiej. Seria Organizacji i Zarządzanie, n. 213, 2024. DOI: <https://doi.org/10.29119/1641-3466.2024.213.39>.
- TANIM, Sakhawat Hussain; AHMAD, Md Sabbir. **AI driven strategic decision-making in IT project management: enhancing risk assessment, cost control, and efficiency.** World Journal of Advanced Research and Reviews, 2025. DOI: <https://doi.org/10.2139/ssrn.5202585>.
- VASWANI, Ashish *et al.* **Attention is All you Need.** In: Curran Associates, Inc., 2017. Disponível em: <[https://papers.nips.cc/paper\\_files/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html](https://papers.nips.cc/paper_files/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html)>. Acesso em: junho 2025.
- VIDRIH, Marko; MAYAHI, Shiva. **Generative AI-Driven Storytelling: A New Era for Marketing,** 2023. DOI: <https://doi.org/10.48550/arXiv.2309.09048>.
- VIERIU, Aniella Mihaela; PETREA, Gabriel. **The Impact of Artificial Intelligence (AI) on Students' Academic Development.** Education Sciences, v. 15, n. 3, p. 343, 11 mar. 2025. DOI: <https://doi.org/10.3390/educsci15030343>.



# Perícia Grafotécnica e Inteligência Artificial: Inovações Tecnológicas na Análise de Escritas

*Handwriting Expertise and Artificial Intelligence: Technological Innovations in Handwriting Analysis*

Maria Suzie de Oliveira<sup>1</sup>

1. Bacharel em Ciência da Informação. Especialista em Perícia Grafotécnica. <https://orcid.org/0000-0003-3666-5074>

*mariasuzie83@gmail.com*

## Palavras-chave

Análise de escrita  
Aprendizado de máquina  
Documentoscopia  
Inteligência artificial  
Perícia grafotécnica

## Keywords

Handwriting analysis  
Machine learning  
Document examination  
Artificial intelligence  
Forensic handwriting analysis

Artigo recebido em: 02.04.2025.

Aprovado para publicação em: 07.11.2025.

## Resumo:

A perícia grafotécnica, ramo da documentoscopia, visa autenticar ou identificar falsificações de assinaturas e escritos. Com os avanços da inteligência artificial (IA), novas ferramentas digitais têm sido introduzidas para aprimorar a precisão e confiabilidade das análises. Este artigo explora como a IA tem impactado a perícia grafotécnica, destacando algoritmos de reconhecimento de padrões, redes neurais e aprendizado de máquina. A pesquisa aborda as aplicações tecnológicas para identificar padrões de escrita e os desafios e benefícios da admissibilidade jurídica desses laudos.

## Abstract:

Graphotechnical expertise is a branch of document examination focused on determining the authenticity or falsification of signatures and handwriting. With the advancements in artificial intelligence (AI), new digital tools are being implemented to enhance the accuracy and reliability of forensic reports. This article analyzes the impact of AI on graphotechnical expertise, highlighting pattern recognition algorithms, artificial neural networks, and machine learning. The research discusses the application of these technologies in handwriting pattern identification and the legal challenges and advantages associated with their admissibility.

## INTRODUÇÃO

A perícia grafotécnica se caracteriza pelo exame de documentos manuscritos com o objetivo de autenticar assinaturas ou identificar falsificações. Com o avanço das tecnologias, especialmente a inteligência artificial, novas ferramentas estão sendo incorporadas a este processo, permitindo uma análise mais rápida e precisa. Tradicionalmente, a análise grafotécnica depende da experiência do perito e de métodos visuais detalhados para comparar padrões de escrita, como o espaçamento, a pressão e a fluidez dos traços. No entanto, a IA tem o potencial de automatizar e melhorar a análise desses padrões, oferecendo mais eficiência e confiabilidade.

Nos últimos anos, a IA tem demonstrado seu valor ao oferecer alternativas para aprimorar o reconhecimento de padrões gráficos em documentos. Entre as principais ferramentas, destacam-se os algoritmos de

aprendizado de máquina e as redes neurais artificiais, que possibilitam uma análise automatizada e mais precisa de assinaturas e outros tipos de escrita.

Por fim, o objetivo deste trabalho é explorar a aplicação da inteligência artificial na perícia grafotécnica, analisando como as ferramentas de IA podem aprimorar a autenticação de assinaturas e a detecção de falsificações, contribuindo para maior celeridade e precisão neste campo.

## METODOLOGIA

Este estudo emprega a metodologia de pesquisa bibliográfica, com foco na fundamentação teórica e exploração do tema. As fontes consultadas incluem materiais acadêmicos, como artigos científicos e livros especializados, além de documentos jurídicos sobre perícia grafotécnica e inteligência artificial na análise de escritas. Com caráter exploratório e qualitativo, a pesquisa busca compreender a aplicabilidade e os desafios da IA no contexto pericial.

A estrutura deste artigo está organizada da seguinte forma:

**Fundamentos da perícia grafotécnica:** aborda os princípios e métodos tradicionais da área.

**Inteligência Artificial e aprendizado de máquina na perícia grafotécnica:** detalha a integração da IA e do machine learning, incluindo redes neurais.

**Aplicações de algoritmos na análise de escritas:** explora técnicas como OCR, SVM e Redes Neurais Artificiais.

**Desafios e limitações:** discute os obstáculos na implementação da IA, especialmente a admissibilidade jurídica e a necessidade da expertise humana.

**Resultados e discussão:** apresenta e discute as descobertas da revisão bibliográfica sobre o potencial e os desafios da IA na perícia grafotécnica.

**Conclusões:** sintetiza as principais descobertas e aponta para o futuro da área.

## PROCEDIMENTOS METODOLÓGICOS

**Levantamento bibliográfico:** envolveu a consulta a fontes acadêmicas qualificadas, abrangendo periódicos científicos, teses, dissertações e normativas técnicas, com acesso em ambiente virtual, bases de dados especializadas e, materiais impressos. Este esforço teve como finalidade a compilação de dados pertinentes aos fundamentos da perícia grafotécnica e ao avanço das tecnologias no campo.

**Análise de publicações científicas:** foram examinados estudos que abordam o uso de algoritmos, aprendizado de máquina e redes neurais na identificação de padrões gráficos e na detecção de falsificações em assinaturas e documentos manuscritos.

**Consulta a normas e regulamentações:** foram revisadas diretrizes e normativas de órgãos periciais e jurídicos que regulam a aceitação de laudos técnicos baseados em IA nos tribunais.

**Comparação de técnicas tradicionais e tecnológicas:** a pesquisa comparou os métodos tradicionais de perícia grafotécnica com as inovações tecnológicas baseadas em inteligência artificial, destacando suas vantagens, limitações e possíveis impactos na prática pericial.

**Discussão dos desafios e possibilidades:** foram analisadas as dificuldades na implementação da IA na perícia grafotécnica, incluindo questões relacionadas à admissibilidade jurídica, interpretação dos resultados pelos peritos e necessidade de bases de dados robustas para o treinamento dos algoritmos.

Dessa forma, este estudo não se baseia em experimentação empírica, mas na revisão crítica da literatura disponível, permitindo uma visão ampla sobre a interação entre tecnologia e perícia grafotécnica no contexto forense.

## FUNDAMENTOS DA PERÍCIA GRAFOTÉCNICA

A perícia grafotécnica envolve a análise minuciosa de características individuais da escrita, como os traços, o espaçamento e a pressão aplicada ao escrever. Estes aspectos são fundamentais para a identificação de autenticidade ou falsificação de documentos. Tradicionalmente, a análise é feita por meio de equipamentos como lupas, microscópios e softwares especializados. Contudo, o processo continua sendo altamente dependente da experiência do perito, o que pode resultar em variabilidade nos resultados.

### PRINCÍPIOS FUNDAMENTAIS

**Individualidade:** Cada pessoa possui características gráficas únicas, e essas marcas podem ser identificadas em diferentes escritos.

**Naturalidade:** A escrita espontânea é fluida e coerente, refletindo o ritmo pessoal de quem escreve.

**Variabilidade:** Embora a escrita de uma pessoa possa variar ao longo do tempo, essas variações seguem padrões previsíveis.

**Habitualidade:** Cada indivíduo desenvolve hábitos gráficos que se repetem.

## INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA NA PERÍCIA GRAFOTÉCNICA

A integração da IA na perícia grafotécnica se dá principalmente por meio de aprendizado de máquina (machine learning). Esta tecnologia permite que os algoritmos identifiquem padrões e características específicas de um conjunto de dados. No contexto da perícia grafotécnica, esses sistemas podem ser treinados para diferenciar assinaturas autênticas de falsificadas, além de detectar variações sutis na escrita.

Redes Neurais Convolucionais (CNNs) têm se destacado por sua capacidade de analisar imagens detalhadas de manuscritos, oferecendo alta precisão na classificação de padrões gráficos. Essas redes são particularmente úteis para detectar características complexas da escrita, como a curvatura dos traços e a distribuição da pressão exercida na assinatura.

### APLICAÇÕES DE ALGORITMOS NA ANÁLISE DE ESCRITAS

Algoritmos modernos têm contribuído substancialmente para a precisão e rapidez da perícia grafotécnica. Algumas das técnicas mais utilizadas incluem:

**Reconhecimento Óptico de Caracteres (OCR):** Essa tecnologia é capaz de converter textos manuscritos em formatos digitais editáveis, permitindo uma análise mais eficiente dos documentos. O OCR é eficaz



na extração de texto de documentos digitalizados, o que facilita a comparação entre diferentes amostras de escrita.

**Support Vector Machines (SVM):** Este algoritmo é amplamente utilizado para classificar padrões na escrita, como distinguir assinaturas autênticas de falsificadas. A SVM é particularmente útil em sistemas de IA para perícias, pois permite a identificação de padrões gráficos de maneira estatisticamente robusta.

**Redes Neurais Artificiais (RNA):** Estas redes oferecem uma análise detalhada das microvariações na escrita, como a pressão aplicada nos traços e a continuidade do movimento. As CNNs, um tipo de RNA, são particularmente eficazes na detecção de falsificações e na comparação de diferentes amostras de escrita.

## DESAFIOS E LIMITAÇÕES

Embora a IA traga inovações significativas para a perícia grafotécnica, sua implementação enfrenta desafios. O principal obstáculo é a admissibilidade jurídica dos laudos baseados em IA. A aceitação desses laudos nos tribunais é variável e depende da regulamentação e da aceitação das novas tecnologias pelo sistema jurídico. A falta de regulamentação específica sobre o uso de IA na perícia grafotécnica é uma das maiores barreiras para sua integração formal nos processos judiciais.

Além disso, a interpretação humana continua sendo essencial. A IA pode oferecer insights valiosos, mas a experiência do perito ainda é necessária para contextualizar e validar os resultados. A combinação entre análise automatizada e expertise humana é fundamental para garantir a confiabilidade dos laudos periciais.

## RESULTADOS E DISCUSSÃO

Os avanços na aplicação da inteligência artificial (IA) à perícia grafotécnica demonstram um potencial significativo na automação e precisão das análises. A revisão bibliográfica evidenciou que algoritmos de aprendizado de máquina, especialmente redes neurais convolucionais (CNNs), têm sido eficazes na identificação de padrões gráficos, diferenciando assinaturas autênticas de falsificadas com alta acurácia.

Estudos indicam que o uso de IA reduz o tempo de análise e proporciona maior padronização nos resultados, minimizando erros humanos. No entanto, a implementação prática ainda enfrenta desafios, como a necessidade de bases de dados extensas e bem estruturadas para o treinamento dos algoritmos. Além disso, a admissibilidade jurídica dos laudos baseados em IA segue como um ponto de debate, devido à falta de regulamentação específica e à exigência de validação pericial humana.

Portanto, embora a IA represente um avanço significativo para a perícia grafotécnica, seu uso deve ser complementar à expertise do perito. A combinação entre tecnologia e análise humana se mostra o caminho mais seguro para garantir a confiabilidade dos laudos e sua aceitação nos tribunais.

## CONCLUSÕES

A IA representa um grande avanço para a perícia grafotécnica, com a capacidade de automatizar e aumentar a precisão das análises.

No entanto, é necessário o equilíbrio entre a tecnologia e o trabalho especializado dos peritos para garantir a validade dos laudos, especialmente no contexto jurídico.

---

O futuro da perícia grafotécnica depende da integração eficaz das novas tecnologias, com a devida regulamentação e adaptação ao sistema jurídico.

## REFERÊNCIAS

- BERTALANFFY, L. **Teoria Geral dos Sistemas**. Editora Vozes, 2010.
- MAYER, Owen; STAMM, Matthew C. Forensic Similarity for Digital Images. **IEEE Transactions on Information Forensics and Security**, 2019. Disponível em: <https://arxiv.org/abs/1902.04684> Acesso: 17 mar. 2025.
- PORTO, Lucas Faria et al. **Automatic Cephalometric Landmarks Detection on Frontal Faces: An Approach Based on Supervised Learning Techniques**. 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1742287619301288> Acesso: 17 mar. 2025.
- PRETTI, Gleibe. **A Inteligência Artificial (IA) Revolucionando a Perícia Grafotécnica: Um Novo Rumo nas Investigações**. Jusbrasil, 2023.
- RIBEIRO, A. Inteligência Artificial na Perícia Forense. **Revista Brasileira de Criminalística**, v. 5, n. 2, p. 45-60, 2022.
- SANTOS, João. **Como a Inteligência Artificial Está Revolucionando a Perícia Grafotécnica**. Tableless, 2023.
- SILVA, M. **Machine Learning Aplicado à Perícia Grafotécnica**. Editora Científica, 2021.
- SOUZA, C. et al. Redes Neurais na Identificação de Assinaturas. **Anais do Congresso de Computação Forense**, 2023.
- XUAN, Xinsheng et al. **On the Generalization of GAN Image Forensics**. 2019. Disponível em: <https://arxiv.org/abs/1902.11153> Acesso: 18 mar. 2025.



# Literatura Infantil: O Cativar que Ensina

*Children's Literature: The Captivating Spirit that Teaches*

Amanda Sabino Jandrey<sup>1</sup> e Terezinha Corrêa Lindino<sup>2</sup>

1. Pedagoga pela Universidade Estadual do Oeste do Paraná (Unioeste), *Campus Cascavel*. ORCID: <https://orcid.org/0009-0005-4797-1036>. 2. Pós-doutorado em Gestão e Educação Ambiental pela Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP), Grupo de Pesquisa em Gestão e Educação Ambiental (PGEA). Doutora em Educação pela Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP). Professora da Universidade Estadual do Oeste do Paraná (Unioeste). ORCID: <https://orcid.org/0000-0001-5290-7702>.

[amanda.jandrey@unioeste.br](mailto:amanda.jandrey@unioeste.br) ; [terezinha.lindino@unioeste.br](mailto:terezinha.lindino@unioeste.br)

## Palavras-chave

Criança pequena  
Desenvolvimento cognitivo  
Literatura infantil

## Keywords

Small child  
Cognitive development  
Children's literature

## Resumo:

Este estudo investiga como a Literatura Infantil contribui para o desenvolvimento cognitivo das crianças pequenas, especialmente sobre a estimulação da criatividade e das habilidades linguísticas antes da alfabetização formal. A pesquisa qualitativa, de caráter exploratório, foi fundamentada em uma análise bibliográfica criteriosa, que envolveu publicações científicas sobre o papel da literatura no desenvolvimento infantil, abordando sua relação com a imaginação, a cognição e as habilidades linguísticas. Também, adotou a técnica de análise qualitativa de dez livros infantis previamente selecionados, cujos critérios foram: qualidade do texto, projeto gráfico e propriedades formais. Deveriam ainda se enquadrar nas categorias livros-imagem, humor, literatura experimental, cultura brasileira e contos de fadas. O referencial teórico incluiu autores como Koch e Elias (2002) e Gândara e Befi-Lopes (2010), que destacam o impacto da literatura no desenvolvimento integral da criança. Os resultados indicaram que, ao ser introduzida desde a educação infantil, a literatura não só amplia o vocabulário e aprimora a compreensão de estruturas linguísticas mais complexas, mas também estimula a imaginação e o pensamento abstrato. Conclui-se que a literatura infantil desempenha um papel essencial na formação cognitiva e emocional das crianças, sendo um recurso valioso para o desenvolvimento de suas capacidades criativas, sociais e linguísticas.

## Abstract:

This study investigates how Children's Literature contributes to the cognitive development of young children, especially the stimulation of creativity and language skills before formal literacy. The qualitative research, of an exploratory nature, was based on a careful bibliographical analysis, which involved scientific publications on the role of literature in child development, addressing its relationship with imagination, cognition and linguistic skills. Also, it adopted the qualitative analysis technique of ten previously selected children's books, whose criteria were: text quality, graphic design and formal properties. They should also fall into the categories of image books, humor, experimental literature, Brazilian culture and fairy tales. The theoretical framework included authors such as Koch and Elias (2002) and Gândara and Befi-Lopes (2010), who highlight the impact of literature on the child's integral development. The results indicated that, when introduced from early childhood education, literature not only expands vocabulary and improves the understanding of more complex linguistic structures, but also stimulates imagination and abstract thinking. It is concluded that children's literature plays an essential role in the cognitive and emotional formation of children, being a valuable resource for the development of their creative, social and linguistic abilities.

Artigo recebido em: 08.10.2025.

Aprovado para publicação em: 07.11.2025.

## INTRODUÇÃO

A **CONCEPÇÃO** de criança é uma noção historicamente construída, que consequentemente vem mudando ao longo dos tempos apresentando concepções bastante divergentes sobre sua finalidade social. Segundo Dorigo e Nascimento (2007, p. 16):

A preocupação atual reflete a idéia de que a criança desde que nasce, necessita de um espaço de socialização e aprendizado abandonando a idéia de apenas assistir e cuidar. É nessa perspectiva que o atendimento das crianças de 0 a 6 anos de idade vem sendo refletido e estudado no sentido de buscar novas formas de relações na prática pedagógica desenvolvida nas instituições de atendimento às crianças pequenas.

Então, descuidar da educação da criança pequena seria como desperdiçar um potencial humano que não poderá ser recuperado, defendem as autoras, visto que para ela se necessita criar meios alternativos em seu aprendizado, de modo a discutir “(..) a importância de repensar as relações da prática pedagógica desenvolvida” (Dorigo e Nascimento, 2007, p. 15). Por conseguinte, as abordagens pedagógicas modernas destacam a importância de criar ambientes que estimulem a interação, a criatividade e o pensamento crítico (Oliveira e Alencar, 2012). Essas práticas valorizam métodos ativos de aprendizagem, nos quais as crianças pequenas são incentivadas a explorar, questionar e construir conhecimento de forma colaborativa, defendem as autoras.

As crianças pequenas são preparadas para se tornarem cidadãos ativos e reflexivos na sociedade ao atingirem a vida adulta, sugerindo que Literatura Infantil se apresente como poderoso instrumento didático que integra tais aspectos de forma eficaz. Histórias não apenas entretêm, mas também educam, transmitindo valores, ensinamentos e reflexões essenciais para o desenvolvimento integral das crianças pequenas (Dalla-Bona e Fonseca, 2018). Desta forma, além de promoverem o prazer pela leitura, contribuem para a formação do caráter e o estímulo à empatia, impactando positivamente áreas como a imaginação, o desenvolvimento da linguagem, as habilidades sociais e, sobretudo, as competências cognitivas, defendem os autores.

A Literatura Infantil assume um papel fundamental no processo de aprendizagem e na construção de uma base sólida para a vida. Mesmo a criança que não lê, desde cedo terá a capacidade de imaginação e criatividade, pois, já afirmava Rego (1995), o envolvimento de crianças pequenas com a leitura de histórias e produção de textos não necessita, portanto, esperar que a alfabetização formal se concretize. Neste sentido, devido a Literatura Infantil proporcionar um ambiente rico em estímulos que favorecem o crescimento intelectual e emocional por meio de histórias, personagens e narrativas, procura-se averiguar se as crianças pequenas têm oportunidade de desenvolver ou expandir as habilidades de linguagem e aprimorar a compreensão do mundo ao seu redor, mesmo não sabendo ler. As crianças pequenas podem ser expostas a novas palavras e construções gramaticais, o que contribui para o enriquecimento do seu vocabulário e a compreensão de estruturas linguísticas mais complexas (Gândara e Befi-Lopes, 2010).

Também estimula o desenvolvimento da imaginação, permitindo que elas visualizem cenários e personagens, o que é essencial para o pensamento abstrato. Portanto, a Literatura Infantil não só enriquece o desenvolvimento cognitivo das crianças pequenas ao ampliar suas habilidades linguísticas e cognitivas, mas também desempenha um papel vital no seu desenvolvimento emocional e social, preparando-as para interagir de forma mais eficaz com o mundo ao seu redor.

Concordando com esta perspectiva, este artigo busca explorar como a Literatura Infantil influencia positivamente o desenvolvimento cognitivo das crianças pequenas, oferecendo embasamento científico e dados concretos e discutir como a Literatura Infantil impacta em diferentes aspectos do desenvolvimento cognitivo

(por exemplo, criatividade) em crianças pequenas, uma vez que elas ainda não possuem habilidades linguísticas apreendidas no processo de alfabetização. Busca ainda, responder a seguinte pergunta-problema: De que forma a Literatura Infantil pode contribuir com os professores da Educação Infantil, quando a criança pequena ainda não sabe ler?

Ao analisar a relação entre a Literatura Infantil e o desenvolvimento cognitivo da criança pequena, durante o processo de alfabetização, aponta-se como estímulo à criatividade um elenco de obras que podem ser incorporadas antes do processo de alfabetização. Para tanto, instituem-se aqui como objetivos específicos deste estudo:

- a) Definir os tipos de estímulo à criatividade adotados pela Literatura Infantil.
- b) Selecionar livros de Literatura Infantil a serem incorporados antes do processo de alfabetização.
- c) Discutir a relação entre estímulo à criatividade e livros de Literatura Infantil para criança pequena.

Por conseguinte, considerando esse cenário, defende-se que a Literatura Infantil, quando integrada de forma planejada, pode atuar como um elemento essencial no estímulo à criatividade das crianças pequenas, contribuindo para um melhor desenvolvimento das habilidades críticas e imaginativas. Também, postula-se que a utilização de livros de Literatura Infantil potencializa o interesse e o envolvimento das crianças pequenas frente a construção de significados que enriquecem o processo de alfabetização posteriori.

## **LITERATURA INFANTIL: HISTÓRIA E CONCEITO**

Ao longo da história, a Literatura Infantil passou por diversas transformações. Meireles (1984) identifica quatro momentos significativos em sua evolução: a escrita das tradições orais; a produção de textos direcionados inicialmente a criança específica que posteriormente ganharam público mais amplo; a adaptação de obras originalmente voltadas para adultos; e, por fim, a criação de textos concebidos especialmente para o público infantil. Esses movimentos históricos revelam a progressiva construção de identidade própria para a Literatura Infantil, destacando-a como forma de arte que transcende o simples entretenimento.

Neste sentido, mais do que um termo de difícil definição, a Literatura Infantil é em sua essência literatura e, como tal, representa uma expressão artística que carrega em si o potencial de sensibilizar consciências e ampliar horizontes. Meireles (1984) sugere que, embora a Literatura Infantil costume ser associada ao que é escrito para crianças, talvez fosse mais apropriado defini-la como aquilo que desperta o interesse e o prazer do público infantil.

Na ótica de Luiz (2005), foi a partir de Monteiro Lobato, reconhecido como o precursor da Literatura Infantil moderna no Brasil, que a Literatura Infantil no Brasil passou a ser reconhecida como manifestação artística autônoma, deixando de ser considerada gênero menor. Essa transformação foi acompanhada por ampliação do mercado editorial, que identificou na Literatura Infantil um segmento promissor, pois a ruptura do modelo tradicional começou a se delinear e Lobato incorporou elementos orais e coloquiais ao texto, aproximando-se do universo infantil e explorando temas que incentivavam a fantasia e a reflexão crítica.

Conforme apontado por Travassos (2013), sua narrativa foi marcada por uma liberdade criativa que não apenas encantava as crianças, mas também promovia um diálogo sobre questões culturais e sociais, combinando elementos recreativos e educativos. O autor aponta ainda que, como as histórias disponíveis para as crianças pequenas eram majoritariamente importadas e apresentavam contextos alheios à vivência brasileira, com traduções que dificultavam a compreensão devido à discrepância entre o português europeu e o falado

no Brasil, a Literatura Infantil produzida nacionalmente deveria ter um caráter didático, priorizando estímulos à imaginação e à criatividade.

Atendendo à função estética, obras que conjugam arte e beleza poderiam também cumprir a função educativa, contribuindo para o desenvolvimento de valores, a reflexão crítica e o autoconhecimento do indivíduo. Diante disso, segundo Queiroz e Albuquerque (2014), formar leitores críticos e reflexivos exige postura que estabelece diversas habilidades que atraíam a sua atenção, sobretudo quando esses leitores são crianças pequenas não alfabetizadas.

Segundo Fleck, Cunha e Caldin (2016), como a Literatura Infantil ocupa lugar singular dentro do universo literário, por muito tempo, ela foi relegada a um papel secundário, erroneamente considerada gênero menor. Mas, essa percepção vem sendo gradativamente desconstruída, permitindo que a Literatura Infantil seja reconhecida por suas qualidades poéticas, lúdicas e educativas. Em território brasileiro, sua gênese e desenvolvimento foram marcados por desafios específicos que refletem a trajetória sociocultural do país. Esse percurso teve início no final do século XIX, quando o acesso a livros infantis era limitado (Alves; Oliveira, 2024). Foi apenas no início do século XX que a produção literária voltada à infância brasileira começou a se estruturar de forma sistemática. E, nessa fase, a Literatura Infantil era predominantemente composta por traduções de obras europeias, ajustadas à linguagem brasileira, mas ainda distantes da realidade sociocultural do país (Alves; Oliveira, 2024).

Tal evolução permitiu a multiplicação de autores especializados, comprometidos com a produção de obras que conciliavam fruição estética, ludicidade e desenvolvimento cognitivo. Atualmente, a Literatura Infantil brasileira é instrumento essencial para estimular a imaginação, desempenha um papel significativo na construção da identidade cultural e na promoção de valores críticos e reflexivos (Alves; Oliveira, 2024). Para ela, como as crianças pequenas possuem pouco acesso aos materiais de qualidade no meio familiar, cabe a outras instituições, como a escola, contribuir para garantir que a experiência de leitura se volte, tanto para o ensino quanto para a promoção do gosto pela leitura, para a criança pequena.

De tal modo, este estudo será limitado em analisar o conteúdo de materiais pedagógicos que busquem compreender como a Literatura Infantil impacta o desenvolvimento cognitivo das crianças pequenas e fornece valiosos meios para os professores, pais ou profissionais da área. Ainda, conforme afirma a Perspectiva Histórico-Cultural, as atividades humanas (por exemplo, a leitura) são orientadas por motivos significativos, pois, ensinar essas habilidades de forma mecânica, desvinculada de contexto e função social, resulta em uma prática ineficaz (Leontiev, 1959).

Neste caso, a relação da criança pequena com o meio é dinâmica e mediada pelo entorno social e cultural em que está inserida, segundo Vygotsky (1994), portanto, a maneira como os adultos apresentam a Literatura Infantil influencia diretamente a forma como as crianças pequenas percebem e internalizam os significados. Esse processo envolve a criação de vínculos emocionais e cognitivos com os personagens e situações das histórias, o que, por sua vez, enriquece o desenvolvimento da linguagem e das funções simbólicas da criança (Vygotsky, 1994).

Ao se identificarem com os personagens ou com suas emoções, as crianças pequenas aprendem a respeitar diferentes perspectivas, o que contribui para o seu desenvolvimento social e emocional. Cabe ressaltar que, nos livros, as narrativas apresentam dilemas e questões que incentivam as crianças pequenas compreenderem as ações dos personagens e contribui para a formação das suas escolhas, iniciando a promoção de habilidades como raciocínio lógico ou resolução de problemas.

Esses aspectos corroboram a defesa de que a Literatura Infantil não apenas enriquece a experiência de leitura, mas também desempenha um papel crucial no desenvolvimento cognitivo das crianças pequenas, preparando-as para desafios futuros em sua aprendizagem e vida social. Do mesmo modo, de acordo com a Teoria Histórico-Cultural, experiências educacionais ligadas à arte, “(...) dentre elas, à literatura, ao desenho, à pintura, assim como à escrita e às ciências são primordiais ao processo de formação plena de potencialidades humanas durante a infância” (Ribeiro, 2018, p.14).

A Literatura Infantil, com suas histórias criativas e personagens cativantes, estimula a imaginação das crianças pequenas, permitindo que elas explorem novas ideias e cenários. Isto porque, ela desempenha um papel essencial no desenvolvimento das habilidades de leitura antes do processo de alfabetização, uma vez que possibilita a vivência de situações reais ou imaginárias, nas quais as crianças pequenas podem perceber a sua funcionalidade na interpretação de histórias (Marçal; André, 2022).

## DA TEORIA À PRÁTICA: CONSTRUÇÃO METODOLÓGICA

Diante dos objetivos propostos, o presente estudo caracteriza-se como pesquisa exploratória, pois, segundo Minayo (2002, p. 22), “(...) proporciona maior familiaridade com o problema para torná-lo mais explícito ou a construir hipóteses”. Nela, optou-se pelo levantamento bibliográfico e análise qualitativa. Para o levantamento bibliográfico, fundamentado na concepção qualitativa de pesquisa, realizou-se uma seleção criteriosa de publicações científicas sobre o tema, a fim de compreender e captar as particularidades literárias existentes no momento da definição dos tipos de estímulo à criatividade adotados pela Literatura Infantil.

Neste sentido, foi realizado processo de identificação, localização e seleção de bibliografias que abordavam a Literatura Infantil em seu aspecto histórico, conceitual e prático, bem como relacionado à imaginação e criança pequena. Também, selecionou-se bibliografias sobre Desenvolvimento Cognitivo e sua relação com imaginação e interpretação. Por fim, selecionou-se bibliografias sobre Habilidades de Linguagem e sua relação com comunicação (Quadro 1).

Também, verificou-se a necessidade de utilizar a técnica de análise qualitativa para selecionar livros de Literatura Infantil que podem ser incorporadas antes do processo de alfabetização e para discutir a relação entre estímulo à criatividade e livros de Literatura Infantil para criança pequena. Ela consiste em examinar e observar um objeto de estudo tendo em conta suas características e o seu funcionamento.

Para este estudo, escolheu-se a análise literária, que se caracteriza como o ato de decompor um texto, no intuito de observar cada componente que o constitui. Logo, ao realizar uma descrição estrutural, que visou mapear a organização interna do texto, partiu-se da exploração dos seguintes elementos:

**ENREDO:** ou trama é responsável por sustentar a história. É quem irá desenvolver ou construir o conteúdo por meio da conexão de fatos que fundamentem a ação narrativa. Por meio dele, é possível encontrar o conflito ou tensão no texto que motiva as personagens a se movimentarem. Como visto, todo enredo está presente na estrutura do conflito. Desse modo, para analisar a obra, é necessário encontrar três pontos principais: o início, desenvolvimento e clímax.

**TEMPO E ESPAÇO:** se referem ao contexto histórico e ao local onde a narrativa se desenrola. No decorrer do texto, podemos encontrar os acontecimentos históricos presentes e determinar em que época a história se passa. Também é possível identificar o local por meio dos ambientes e lugares citados. O tempo e o espaço podem estar presentes numa obra de forma clara, ou seja, diretamente mencionada pelo narrador ou personagem.

**PERSONAGENS:** devem ser analisadas tanto no aspecto físico como no aspecto psicológico. Contudo, é necessário respeitar a ordem de importância das personagens da seguinte forma: a) Personagens principais; b) Personagens secundárias.

**LINGUAGEM:** deve-se analisar a forma como a obra é escrita e até mesmo narrada. Portanto, o primeiro passo para estudar uma narrativa de linguagem é verificá-la como simples ou rebuscada, formal ou informal, culta ou marginalizada, etc. Outro aspecto a ser adotado é levantar os estilos de linguagem. Esse tipo de estudo é complicado porque exige um pouco mais de conhecimento sobre o assunto.

QUADRO 1 – Levantamento bibliográfico sobre Literatura Infantil

LITERATURA INFANTIL	AND	BASE	RESULTADOS
	IMAGINAÇÃO	SciELO	6
		Scopus	14
		Science Direct	0
		Web of Science	138
	AND	BASE	RESULTADOS
	CRIANÇA PEQUENA	SciELO	3
		Scopus	4
		Science Direct	115
		Web of Science	26
	AND	BASE	RESULTADOS
		SciELO	1
		Scopus	0
		Science Direct	4
		Web of Science	58
	AND	BASE	RESULTADOS
	INTERPRETAÇÃO	SciELO	70
		Scopus	6
		Science Direct	95
		Web of Science	93
	AND	BASE	RESULTADOS
	COMUNICAÇÃO	SciELO	126
		Scopus	4
		Science Direct	56
		Web of Science	304

Fonte: Elaborado pelas autoras (2024).

Selecionou-se dez livros de Literatura infantil. Mas, esta escolha não foi aleatória, por conseguinte, foram estabelecidos os seguintes critérios, classificados em com base na perspectiva de profissionais e instituições que entendem do assunto. São eles:

**QUALIDADE DO TEXTO:** os textos literários devem propiciar a contemplação estética a partir da adequação do texto (temática) e linguagem (abordagem) às competências por faixa etária.

**PROJETO GRÁFICO:** deve apresentar equilíbrio entre ilustrações e suas materialidades (cor da página, tipo de material de que é composto, durabilidade do livro) por faixa etária.

**CLASSIFICAÇÃO CONFORME SUAS PROPRIEDADES FORMAIS:** 1) LIVRO-IMAGEM (contém uma narrativa puramente visual é um experimento na utilização da imagem em sequência como criadora de possibilidades de significação); 2) HUMOR (contém uma narrativa divertida, ágil, espontânea; mas, quando essencialmente ocorre a exploração entre palavras e imagens); 3) EXPERIMENTAIS (contém uma narrativa onde o leitor encontra possibilidades plásticas, formatos e soluções que possam ampliar ou criar novos



significados); 4) CULTURA BRASILEIRA (contém uma narrativa onde podemos viajar pelo Brasil e viver muitas experiências); 5) CONTOS DE FADA (contém uma narrativa que encantam as crianças pequenas e possui enredo ficcional, que normalmente apresenta seus personagens e os aspectos mágicos).

Sendo assim, aposta-se que quando a criança que desde cedo é apresentada ao mundo literário, ela terá maior leque de oportunidades para desenvolver criatividade e descobrir o mundo e a realidade que a rodeia.

## **LIVROS DE LITERATURA INFANTIL PARA SEREM UTILIZADOS ANTES DA ALFABETIZAÇÃO: TIPOS DE ESTÍMULO À CRIATIVIDADE ENCONTRADOS**

Nos livros, as narrativas apresentam dilemas e questões que incentivam as crianças pequenas compreenderem as ações dos personagens e contribui para a formação das suas escolhas, iniciando a promoção de habilidades como raciocínio lógico ou resolução de problemas. Esses aspectos corroboram a defesa de que a Literatura Infantil enriquece a experiência de leitura, ao passo em que desempenha um papel fundamental no desenvolvimento cognitivo das crianças pequenas, preparando-as para desafios futuros em sua aprendizagem e vida social.

De acordo com a Teoria Histórico-Cultural, experiências educacionais ligadas à arte, “(...) dentre elas, à literatura, ao desenho, à pintura, assim como à escrita e às ciências são primordiais ao processo de formação plena de potencialidades humanas durante a infância” (Ribeiro, 2018, p. 14). A Literatura Infantil, com suas histórias criativas e personagens cativantes, estimula a imaginação das crianças pequenas, permitindo que elas explorem novas ideias e cenários. Não obstante, o entendimento da natureza literária dependerá sempre de uma opção ideológica, extraliterária, consciente ou inconsciente, que desemboca na subjetividade individual daquele que se deleita com a literatura.

Acredita-se que o uso da literatura infantil é um recurso essencial principalmente no que concerne às crianças pequenas corrobora a ideia apresentada na Base Nacional Comum Curricular que pontua “(...) a importância de experiências com a literatura infantil”. Ainda, esse documento amplia a discussão afirmando que:

As experiências com a literatura infantil, propostas pelo educador, mediador entre os textos e as crianças, contribuem para o desenvolvimento do gosto pela leitura, do estímulo à imaginação e da ampliação do conhecimento de mundo. Além disso, o contato com histórias, contos, fábulas, poemas, cordéis etc. propicia a familiaridade com livros, com diferentes gêneros literários, a diferenciação entre ilustrações e escrita, a aprendizagem da direção da escrita e as formas corretas de manipulação de livros (Brasil, 2018, p. 42).

Porém, conforme Colombo (2009) já afirmava, nota-se que o professorado não sabe como trabalhar a leitura, principalmente “(...) a Literatura Infantil em sala de aula de modo a colaborar no processo de formação do leitor, uma vez que corriqueiramente, é abordada como pretexto para ensinar conteúdos de diversas áreas do conhecimento (Colombo, 2009, p. 14). Além disso, ao serem expostas à leitura de histórias, as crianças pequenas adquirem diversas habilidades sociais essenciais. Cabe aqui ressaltar que, se apropriando dos estudos de Medeiros e Guiraldelli (2021, p. 27) “[...] é preciso que as crianças entrem em contato com a literatura e criem laços com os livros, e que os professores saibam como contar histórias, tornando o momento algo simbólico”.

Desta forma, segundo Marçal e André (2022), a Literatura Infantil desempenha um papel essencial no desenvolvimento das habilidades de leitura antes do processo de alfabetização, uma vez que possibilita a vivência de situações reais ou imaginárias, nas quais as crianças pequenas podem perceber a sua funcionalidade.


de na interpretação de histórias (Marçal; André, 2022). Logo, neste estudo, analisam-se obras literárias como exemplo de incorporação antes do processo de alfabetização, exercendo papel importante para a educação e o aprendizado, pois, são histórias que visam o estímulo à criatividade das crianças pequenas (Quadro 2).

Quadro 2 – Obras selecionadas

OBRA	QUALIDADE DO TEXTO	CLASSIFICAÇÃO
 <p>Telefone sem fio</p>	<p><b>ENREDO:</b> <i>Telefone sem Fio</i> é um livro-imagem que retrata a clássica brincadeira infantil onde uma mensagem é sussurrada de pessoa para pessoa, frequentemente resultando em uma frase completamente diferente no final. A narrativa visual começa com um bobo da corte cochichando algo no ouvido de um rei, e a mensagem é passada por diversos personagens, incluindo um pirata, uma vovozinha e um caçador, cada um adicionando sua própria interpretação ao que ouviu. A ausência de texto permite que os leitores usem sua imaginação para interpretar o que está sendo dito e como a mensagem se transforma ao longo do caminho.</p>	LIVRO-IMAGEM
	<p><b>TEMPO E ESPAÇO:</b> A história se desenrola em um cenário atemporal e variado, com cada personagem inserido em seu próprio contexto. As ilustrações apresentam ambientes distintos que refletem as características de cada personagem, criando uma ambientação rica e diversificada que complementa a sequência da brincadeira.</p> <p><b>PERSONAGENS:</b> Bobo da corte, Rei, Cavaleiro, Astronauta, Pirata, Papagaio, Índio, Homem, Mulher, Vó, Lobo, Chapeuzinho Vermelho, Caçador, Cachorro.</p> <p><b>LINGUAGEM:</b> Não há texto escrito.</p>	
 <p>A ovelha negra da Rita</p>	<p><b>ENREDO:</b> <i>A Ovelha Negra da Rita</i> narra a história de uma amizade especial entre Rita e uma ovelhinha negra que nasceu diferente de suas irmãs, geralmente brancas. Juntas, elas exploram o mundo e vivem diversas aventuras, descobrindo o valor do companheirismo e da amizade verdadeira. Quando Rita adoece, é a ovelhinha que encontra a melhor solução, sensibilizando leitores sobre a importância das relações entre seres vivos de todos os tipos.</p> <p><b>TEMPO E ESPAÇO:</b> A narrativa se desenrola em um ambiente rural, onde Rita e sua ovelhinha compartilham momentos em diferentes estações do ano, como inverno, verão, outono e primavera. Esses cenários proporcionam uma ambientação rica para as aventuras e descobertas da dupla.</p> <p><b>PERSONAGENS:</b> Ovelha Negra, Rita, família de Rita, família de ovelhas.</p> <p><b>LINGUAGEM:</b> Não há texto escrito.</p>	LIVRO-IMAGEM

 <p>Espaguete</p>	<p><b>ENREDO:</b> <i>Espaguete</i> é um livro ilustrado que explora, de maneira lúdica e criativa, as diversas formas que os fios de espaguete podem assumir na imaginação infantil. A cada página, os fios de macarrão se transformam em diferentes elementos, como bigode, rabo de cavalo, cabelos, óculos e até tentáculos de polvo.</p> <p><b>TEMPO E ESPAÇO:</b> A narrativa não se prende a um tempo ou espaço específicos. Cada ilustração apresenta um cenário distinto, criado pela imaginação, onde os fios de espaguete se transformam em diversos objetos e personagens, permitindo uma viagem por diferentes contextos e situações.</p> <p><b>PERSONAGENS:</b> O livro não possui personagens fixos ou uma narrativa linear. Em vez disso, os fios de espaguete assumem diferentes formas e "personagens" a cada página, como bigodes, cabelos, tentáculos e outros elementos, convidando o leitor a imaginar e interpretar cada transformação.</p> <p><b>LINGUAGEM:</b> Simples e formal</p>	HUMOR
 <p>Não confunda</p>	<p><b>ENREDO:</b> <i>Não Confunda</i> é uma obra que brinca com a semelhança sonora entre palavras, propondo confusões hilárias e estimulantes. A autora utiliza uma estrutura de textos curtos que dialogam com as ilustrações, criando situações engraçadas baseadas em trocadilhos e jogos de palavras. Essa abordagem não apenas diverte, mas também auxilia leitores iniciantes a se conscientizarem das particularidades ortográficas, servindo como preparo para leituras mais longas e complexas.</p> <p><b>TEMPO E ESPAÇO:</b> O livro não segue uma narrativa linear tradicional com definições claras de tempo e espaço. Cada página apresenta uma situação independente, onde as ilustrações e os textos curtos criam cenários variados e atemporais, focando na brincadeira linguística e visual.</p>	HUMOR
	<p><b>PERSONAGENS:</b> Os personagens de "Não Confunda" são diversos e variam conforme as situações apresentadas em cada página. Eles são construídos para ilustrar os trocadilhos e as confusões propostas, muitas vezes assumindo papéis surpreendentes e engraçados que complementam o jogo de palavras.</p> <p><b>LINGUAGEM:</b> Simples e informal.</p>	
 <p>Sob o sol, sob a lua</p>	<p><b>ENREDO:</b> <i>Sob o Sol, Sob a Lua</i> apresenta uma narrativa poética que explora a dualidade entre o dia e a noite, simbolizada por uma cobra que ama o sol e um lobo que ama a lua. A história desenvolve-se em uma atmosfera onírica, onde esses dois personagens protagonizam um embate de formas e cores, representando a alternância entre luz e escuridão, calor e frio, movimento e quietude. Através de ilustrações marcantes, o livro convida o leitor a refletir sobre a complementaridade dos opostos e a harmonia presente na natureza.</p> <p><b>TEMPO E ESPAÇO:</b> A narrativa situa-se em um ambiente atemporal e indefinido, criando uma sensação de suspensão no tempo e no espaço. Esse cenário abstrato reforça a natureza simbólica da história, permitindo que o leitor se concentre nas interações entre os personagens e nas emoções evocadas pelas ilustrações.</p> <p><b>PERSONAGENS:</b> Cobra e lobo</p> <p><b>LINGUAGEM:</b> Simples e formal</p>	EXPERIMENTAIS

 <p>Lição de Voo</p>	<p><b>ENREDO:</b> <i>Lição de Voo</i> é uma adaptação de uma história do folclore europeu que narra a jornada de Betina, uma menina curiosa que observa uma borboleta tentando sair de seu casulo. Com a intenção de ajudar, Betina decide intervir, mas acaba descobrindo que sua ajuda, embora bem-intencionada, pode ter consequências negativas. Através dessa experiência, ela aprende sobre a importância de permitir que cada ser viva seus próprios processos e desafios, compreendendo que algumas dificuldades são essenciais para o crescimento e desenvolvimento.</p> <p><b>TEMPO E ESPAÇO:</b> A narrativa se desenrola em um ambiente natural, possivelmente no jardim ou quintal da casa de Betina, onde ela observa a borboleta. O tempo é indeterminado, conferindo à história um caráter atemporal e universal.</p> <p><b>PERSONAGENS:</b> Betina e Borboleta</p> <p><b>LINGUAGEM:</b> Simples e formal</p>	EXPERIMENTAIS
 <p>A festa no céu</p>	<p><b>ENREDO:</b> <i>A Festa no Céu</i> é uma releitura de um conto tradicional do folclore brasileiro. A história narra a decisão da tartaruga de participar de uma festa no céu, destinada apenas aos animais com asas. Determinada, ela engana o urubu-rei para conseguir chegar ao evento. No retorno, após ser descoberta, a tartaruga enfrenta consequências que explicam, de forma lúdica, a aparência de seu casco.</p> <p><b>TEMPO E ESPAÇO:</b> A narrativa se desenrola em um ambiente fantástico, onde animais falantes organizam eventos sociais. O céu serve como cenário principal para a festa, representando um espaço mágico e inacessível para criaturas sem asas. O tempo é indeterminado, remetendo a uma era mítica das fábulas.</p> <p><b>PERSONAGENS:</b> Tartaruga, Urubu-Rei, pássaros.</p> <p><b>LINGUAGEM:</b> Simples e formal</p>	CULTURA BRASILEIRA
 <p>O grande rabanete</p>	<p><b>ENREDO:</b> <i>O Grande Rabanete</i> é uma adaptação de uma parlenda tradicional recontada por Tatiana Belinky. A história começa com o vovô plantando um rabanete em sua horta. O rabanete cresce tanto que o vovô não consegue arrancá-lo sozinho. Ele então pede ajuda à vovó, mas mesmo juntos não conseguem. A sequência continua com a neta, o cachorro, o gato e, finalmente, o rato, unindo forças para puxar o rabanete. Após muita cooperação, eles conseguem arrancar o rabanete gigante da terra.</p> <p><b>TEMPO E ESPAÇO:</b> A história se passa em um ambiente rural, centrado na horta do vovô, onde ele cultiva o rabanete. O tempo é indeterminado, conferindo à narrativa um caráter atemporal e universal.</p> <p><b>PERSONAGENS:</b> Vovó, Vovô, Neta, Cachorro, Gato, Rato</p> <p><b>LINGUAGEM:</b> Simples e formal</p>	CULTURA BRASILEIRA
 <p>A bela</p>	<p><b>ENREDO:</b> A história de <i>A Bela Adormecida</i> é um conto de fadas clássico, que gira em torno de uma princesa que, devido a uma maldição lançada por uma fada má, cai em um sono profundo após espetar o dedo em um fuso. Esse sono só pode ser quebrado por um beijo de amor verdadeiro. Durante o sono, o reino inteiro também adormece, e o tempo passa até que um príncipe corajoso, que conhece a história, encontra a princesa e a desperta. A história fala de temas como destino, amor verdadeiro, e a superação do mal.</p> <p><b>TEMPO E ESPAÇO:</b> A história se passa em um reino distante, em uma época medieval ou de fantasia, onde castelos e fadas coexistem. O tempo é atemporal, uma vez que muitos contos de</p>	CONTOS DE FADA

adormecida	<p>fadas não se prendem a datas específicas, mas sim a uma época de fantasia. O reino está geralmente descrito como um local bonito e mágico, com florestas encantadas ao redor, mas também com uma atmosfera sombria devido à maldição.</p> <p><b>PERSONAGENS:</b> A Bela Adormecida (Aurora), o Príncipe, a Fada Boa, a Fada Má, os Pais de Aurora (Rei e Rainha).</p> <p><b>LINGUAGEM:</b> Simples e formal</p>	
 <p>A pequena sereia</p>	<p><b>ENREDO:</b> A <i>Pequena Sereia</i> conta a história de uma jovem sereia chamada Ariel, que vive no fundo do mar com seu pai, o Rei Tritão, e suas irmãs. Ela sonha em viver na terra, apaixonada pelos seres humanos, especialmente por um príncipe por quem se apaixona à primeira vista. Para realizar seu desejo, ela faz um pacto com a bruxa do mar, Ursula, trocando sua voz por pernas humanas. No entanto, ela precisa ganhar o amor do príncipe antes de três dias, ou ficará presa ao mar para sempre.</p> <p><b>TEMPO E ESPAÇO:</b> O espaço se divide entre o fundo do mar e o mundo terrestre. O reino subaquático onde Ariel vive é cheio de criaturas mágicas, cores vibrantes e uma sensação de maravilha. O ambiente subaquático é detalhado de maneira fantástica, com castelos de corais e peixes falantes. Já o espaço na terra é mais simples, um reino humano, com castelos e praias, geralmente retratando o ambiente costeiro onde o príncipe vive.</p> <p><b>PERSONAGENS:</b> Ariel, Príncipe Eric, Úrsula, Rei Tritão, Pedro e Juca as moreias.</p> <p><b>LINGUAGEM:</b> Simples e formal.</p>	CONTOS DE FADA

Fonte: Elaborado pelas autoras (2025).

Alfabetizar vai além de ensinar a ler e escrever, logo, Prediger *et al.* (2022) defendem que é essencial que a criança encontre sentido e utilidade na leitura e na escrita, o que torna o processo de alfabetização e letramento fundamental para o seu desenvolvimento. Nesse contexto, a alfabetização deve ser vivenciada de forma lúdica, incorporando brincadeiras, jogos e a contação de histórias, elementos que ajudam a criar um vínculo significativo com o ato de aprender. O contato com os livros, mesmo antes da alfabetização, permite o desenvolvimento da oralidade, da imaginação, do vocabulário e da compreensão de mundo.

Nesse preâmbulo, e a partir da análise das obras apresentadas no Quadro 2, percebe-se como diferentes autores e obras em seus distintos formatos contribuem para esse processo. Na perspectiva de Gomes (2016), a literatura infantil possui um papel significativo na educação infantil, especialmente no desenvolvimento das habilidades de leitura e interpretação de textos em crianças que ainda não foram alfabetizadas. A partir da mediação do professor, as narrativas literárias possibilitam a ativação de diferentes sistemas de conhecimento, conforme destacado por Koch e Elias (2002).

Entre esses sistemas, o conhecimento enciclopédico se mostra essencial, pois engloba vivências pessoais e experiências socioculturais que auxiliam na compreensão do texto, mesmo na ausência da decodificação convencional da escrita. Dessa maneira, a literatura infantil permite que a criança participe ativamente da construção de sentidos, considerando suas referências individuais e coletivas (Koch; Elias, 2002).

A oralidade, característica presente em grande parte das obras infantis, estabelece um vínculo entre a tradição oral e a formação inicial do leitor, favorecendo o contato com estruturas narrativas e a ampliação do repertório linguístico. Esse aspecto dialoga com a concepção interacional da língua, conforme apontado por

Koch e Elias (2002), ao reconhecer que a construção do sentido ocorre na relação entre o texto e os sujeitos envolvidos na leitura.

Assim, a criança não se limita a um papel passivo, mas interage com a narrativa por meio de sua bagagem cultural e das interações promovidas no ambiente escolar. A mediação do professor, nesse contexto, assume um papel central na exploração dos significados, ao incentivar inferências, estabelecer conexões com a realidade do aluno e possibilitar a experiência literária como prática social (Marçal; André, 2022). Além do desenvolvimento linguístico, a literatura infantil também contribui para a inserção da criança em práticas de letramento, que envolvem mais do que o simples aprendizado da leitura e da escrita (Prediger *et al.*, 2022).

De acordo com essa perspectiva, a leitura não é uma atividade isolada, mas um processo social no qual diferentes tipos de conhecimento são mobilizados para a construção de sentidos (Koch; Elias, 2002). Ao participar dessas experiências, as crianças têm a oportunidade de compreender a função da linguagem em diferentes contextos, o que favorece a transição para a alfabetização formal. A literatura, portanto, não se restringe ao desenvolvimento da decodificação textual, configurando-se como um instrumento de ampliação do repertório cultural e de formação crítica desde os primeiros anos escolares (Gomes, 2016).

Retomando o Quadro 2, Santos e Candido (2019) argumentam que os livros-imagem constituem um recurso relevante no processo de alfabetização na educação infantil, especialmente quando utilizados com crianças que ainda não decodificam a escrita alfabética. A ausência de texto verbal direciona a atenção para a interpretação das imagens, exigindo que os leitores mobilizem conhecimentos prévios e estabeleçam conexões entre os elementos visuais para construir sentidos.

No geral, essa interação favorece o desenvolvimento de habilidades linguísticas e cognitivas relacionadas à leitura e à escrita, pois requer a formulação de hipóteses, a organização sequencial das informações e a articulação entre diferentes campos do conhecimento. Por exemplo, a obra *Telefone sem Fio* de Ilan Brenman exemplifica esse processo ao apresentar uma narrativa estruturada na transformação de uma mensagem que percorre diversos personagens. A necessidade de interpretar a progressão da história por meio das ilustrações estimula a criança a reconhecer variações discursivas e a perceber como a comunicação está sujeita a alterações no processo de transmissão (Santos; Candido, 2019).

Esse aspecto se alinha à concepção interacional da linguagem discutida por Koch (2002), na qual os sentidos são construídos a partir da interação entre texto e leitor. Ao observar as mudanças na mensagem inicial e inferir os motivos que levaram a essas modificações, a criança compreende a importância do contexto e da subjetividade na interpretação do discurso. Além disso, a estrutura sequencial do livro possibilita a construção de narrativas orais, contribuindo para o desenvolvimento da oralidade, da organização discursiva e da ampliação do repertório lexical.

E, de forma semelhante, *A Ovelha Negra* da Rita de Silvana de Menezes estabelece um percurso narrativo que se apoia exclusivamente em elementos visuais para abordar questões relacionadas à amizade, diversidade e convivência. A ambientação rural e a passagem das estações do ano proporcionam um contexto no qual as crianças podem associar suas experiências pessoais aos eventos da história, mobilizando o conhecimento enciclopédico, conforme apontado por Koch e Elias (2002).

A necessidade de interpretar gestos, expressões faciais e mudanças no ambiente exige que os leitores utilizem diferentes estratégias cognitivas para compreender a trama e estabelecer relações entre os personagens e o espaço narrativo. Essa forma de interação contribui para a construção de habilidades essenciais à leitura, uma vez que incentiva a observação detalhada, a formulação de inferências e a organização lógica dos acontecimentos (Silva, 2023). A utilização de livros-imagem na educação infantil estabelece um ambiente favo-

rável à formação do leitor, pois propicia a experimentação de diferentes formas de linguagem e amplia as possibilidades de interpretação textual (Silva, 2023).

A construção do sentido a partir da narrativa visual exige a ativação de conhecimentos linguísticos, enciclopédicos e interacionais, elementos que Koch e Elias (2002) consideram fundamentais para o processamento textual. Neste mesmo sentido, os livros de humor infantil proporcionam experiências linguísticas dinâmicas e interativas que ampliam o repertório comunicativo da criança, pois a comicidade presente nessas obras estimula a experimentação com o som, o significado e a estrutura das palavras, tornando o contato com a linguagem escrita mais envolvente. Além disso, o humor explora a quebra de expectativas e o pensamento não convencional, proporcionando a construção de inferências e a resolução de ambiguidades, habilidades fundamentais para a leitura e a escrita.

A obra *Espagete* de Davide Calì ilustra essa questão ao apresentar uma narrativa essencialmente visual, na qual o leitor acompanha a transformação lúdica de fios de macarrão em diferentes elementos do cotidiano. A ausência de um enredo linear e a presença de imagens que se reorganizam em novos significados desafiam a criança a estabelecer relações entre formas e conceitos, exercitando o pensamento metafórico. Sargiani e Maluf (2018) explicam que a habilidade de atribuir múltiplos significados a um mesmo estímulo fortalece a flexibilidade cognitiva e a capacidade de abstração, competências que posteriormente irão contribuir na compreensão da escrita alfabética. Além disso, ao explorar visualmente a polissemia das formas, o livro estimula a criança a associar diferentes possibilidades semânticas a uma mesma representação, preparando-a para lidar com a multiplicidade de sentidos presentes na língua escrita.

Por outro lado, *Não Confunda* da aclamada escritora brasileira Eva Furnari utiliza o jogo linguístico como estratégia para promover a percepção fonológica e semântica das palavras. Na prática, os trocadilhos e as confusões sonoras apresentados na obra exigem que a criança reconheça semelhanças e diferenças fonéticas, favorecendo a construção da consciência metalinguística (Camargo; Miyaki, 2022). Segundo Ciríaco (2020) a capacidade de refletir sobre a própria linguagem é um indicador crucial para o desenvolvimento da alfabetização, pois permite que o aprendiz compreenda que a escrita é um sistema de representação simbólica que obedece a regras estruturais.

A brincadeira com palavras próximas foneticamente também contribui para o reconhecimento de padrões ortográficos e para a ampliação do vocabulário, pois estimula a criança a identificar relações entre grafemas e fonemas, um processo essencial para a decodificação do sistema alfabético. Nesta perspectiva, um outro aspecto relevante do humor na literatura infantil é sua capacidade de engajar o leitor por meio do inusitado e do absurdo. O riso provocado por situações inesperadas ou por interpretações equivocadas de palavras e imagens mobiliza a atenção da criança e favorece a retenção de informações.

Estudos sobre aprendizagem mostram que a presença de elementos emocionais positivos no processo educacional potencializa a fixação da memória e a disposição para aprender, assim, ao criar situações cômicas baseadas em jogos de linguagem, essas obras tornam o contato com o texto mais atraente, fortalecendo a aprendizagem da leitura e da escrita de modo prazeroso (Stoppiglia, 2002). Na categoria de obras experimentais, considera-se que esses livros exploram estruturas narrativas não convencionais, promovendo uma experiência estética que incentiva a imaginação e a sensibilidade para diferentes formas de linguagem.

Em *Sob o Sol, Sob a Lua* de Cynthia Cruttenden, a narrativa poética e as ilustrações abstratas criam um ambiente que exige do pequeno leitor um envolvimento interpretativo mais profundo. A contraposição entre os personagens, cobra e lobo, estabelece um jogo de dualidade que pode ser explorado pedagogicamente para desenvolver a capacidade de observação e a associação entre elementos contrastantes. Essa relação dialógica

entre opostos contribui para a construção do pensamento analógico, pois permite que a criança perceba padrões e relações, facilitando o reconhecimento de letras e palavras no sistema de escrita. Além disso, a experiência sensorial proporcionada pelo uso expressivo das cores e das formas amplia a percepção estética e a atenção visual, competências relevantes para o desenvolvimento da leitura.

Já *Lição de Voo*, de Sandra Aymone, apresenta uma estrutura narrativa que convida a criança a refletir sobre o ciclo da vida e a importância do tempo no desenvolvimento dos seres vivos. Ao acompanhar a jornada de Betina e sua tentativa de ajudar a borboleta, o leitor é levado a construir significados a partir da relação entre ação e consequência. A história favorece o desenvolvimento da capacidade preditiva, que é essencial para a leitura, pois permite que a criança antecipe informações e estabeleça conexões entre os eventos narrados. Além disso, a temática da transformação e do crescimento pode ser explorada para trabalhar com conceitos relacionados à evolução da linguagem escrita, evidenciando que a alfabetização é um processo gradual que requer tempo e experimentação.

Os livros experimentais, ao propor narrativas além da linearidade tradicional, ampliam a forma como a criança se relaciona com o texto e a imagem. Essa característica estimula a autonomia interpretativa, fortalecendo o pensamento crítico e a criatividade. Ao permitir múltiplas leituras e interpretações, essas obras preparam o leitor iniciante para lidar com a complexidade da linguagem escrita, promovendo o desenvolvimento da inferência, da abstração e da sensibilidade estética. Outrossim, as obras baseadas na cultura brasileira, como *A Festa no Céu* de Angela Lago e *O Grande Rabanete* de Tatiane Belinky trabalham com estruturas narrativas simples e acessíveis, promovem o desenvolvimento cultural e a interação social, uma vez que essas histórias aproximam as crianças de elementos do folclore e das tradições orais, fortalecendo sua identidade cultural e facilitando a aprendizagem da leitura e da escrita por meio da oralidade e da participação ativa.

Inicialmente, Resende *et al.* (2021) esclarecem que os contos tradicionais brasileiros são transmitidos oralmente de geração em geração, o que os torna ferramentas pedagógicas eficazes na alfabetização. A repetição de padrões linguísticos, como rimas e refrões, auxilia no desenvolvimento da consciência fonológica, permitindo que as crianças percebam sons e ritmos da língua, um passo fundamental para a aquisição da leitura. Em *A Festa no Céu*, a presença de diálogos e repetições reforça essa característica, favorecendo a memorização e o reconhecimento de palavras familiares. Além disso, essas narrativas proporcionam uma imersão cultural, valorizando expressões, cenários e personagens que fazem parte do imaginário popular brasileiro. No caso de *A Festa no Céu*, a presença de animais falantes e de elementos mágicos resgata tradições do folclore, incentivando as crianças a desenvolverem sua imaginação e criatividade, um aspecto que é essencial para a construção do pensamento simbólico, fundamental para a compreensão do sistema de escrita (Resende *et al.*, 2021).

Em *O Grande Rabanete* de Tatiane Belinky, a estrutura acumulativa da história – em que novos personagens se somam progressivamente à ação – estimula a participação ativa das crianças, pois elas antecipam os eventos e interagem com o texto, reforçando a previsibilidade textual e a construção da lógica sequencial, aspectos essenciais para a alfabetização. Além disso, o enredo trabalha com valores como cooperação e trabalho em equipe, promovendo a interação social e o aprendizado por meio da experiência compartilhada (Andrade, 2020).

Outro ponto relevante é que essas histórias utilizam linguagem simples e acessível, com frases curtas e sintaxe direta, o que facilita a compreensão auditiva e a futura leitura autônoma (Andrade, 2020). A presença de personagens arquetípicos, como o vovô agricultor e os animais da fauna brasileira, também favorece a identificação das crianças com os elementos da narrativa, ampliando seu repertório cultural e lexical.



Ademais, quando os professores valorizam em suas aulas os textos baseados na cultura brasileira, cria-se um ambiente de aprendizagem mais significativo, em que a alfabetização ocorre de maneira integrada à vivência das crianças. A combinação entre oralidade, imaginação e reconhecimento cultural fortalece as habilidades linguísticas e o vínculo afetivo dos alunos com a leitura, tornando o processo de alfabetização mais dinâmico e envolvente (Ciríaco, 2020).

Finalmente, os contos de fadas estruturam narrativas que combinam oralidade, imaginação e padrões linguísticos previsíveis. Essas características favorecem o desenvolvimento da consciência fonológica, da compreensão textual e da capacidade de antecipação de eventos narrativos, aspectos essenciais para a aquisição da leitura e da escrita. Inicialmente, os contos de fadas apresentam uma estrutura narrativa linear, com introdução, desenvolvimento e desfecho bem definidos, o que facilita a organização mental das informações pelas crianças. Esse padrão narrativo previsível permite que elas identifiquem sequências lógicas e padrões textuais, contribuindo para o desenvolvimento da coerência e da coesão textual em sua própria produção oral e escrita. Além disso, a repetição de elementos e a presença de fórmulas fixas, como “Era uma vez” e “E viveram felizes para sempre”, auxiliam na memorização e na familiarização com a estrutura da linguagem escrita (Gomes, 2016).

Em *A Bela Adormecida*, a dualidade entre o bem e o mal, representada pelas fadas, e a progressão da história baseada em um conflito central contribuem para que a criança compreenda a relação entre causa e consequência na narrativa. Esse aspecto é essencial na alfabetização, pois estimula a inferência e a antecipação de informações, habilidades que posteriormente serão aplicadas na leitura autônoma. O simbolismo da passagem do tempo e da espera também reforça a construção de sentido por meio do imaginário, aspecto que auxilia na interpretação textual.

Já *A Pequena Sereia* trabalha com a ideia de transformação e desejo, elementos que despertam a curiosidade infantil e favorecem a interação com o texto. A alternância entre os dois mundos – o mar e a terra – estimula a percepção espacial e a comparação de contextos distintos, o que auxilia na ampliação do vocabulário e na construção de repertório. Além disso, a presença do conflito central, representado pelo pacto entre Ariel e Úrsula, possibilita que a criança compreenda a estrutura do enredo, identificando o problema, o desenvolvimento e a resolução, o que facilita futuramente a escrita de textos narrativos.

Outro fator relevante dos contos de fadas na alfabetização é a presença de elementos sonoros e rítmicos na linguagem, que ajudam na discriminação auditiva e na assimilação de sons da língua. O uso de repetições, rimas e padrões sintáticos simples contribui para que as crianças associem os sons às palavras escritas, favorecendo o reconhecimento de letras e fonemas. Portanto, os contos de fadas clássicos, ao combinarem enredos que envolvem, estruturas narrativas previsíveis e linguagem acessível, promovem um ambiente propício para a alfabetização na educação infantil, uma vez que além de estimularem a imaginação e o prazer pela leitura, essas histórias fortalecem a oralidade, a consciência fonológica e a compreensão textual, aspectos fundamentais para a construção de leitores proficientes (Gomes, 2016).

## CONSIDERAÇÕES FINAIS

Ao refletir sobre a importância da literatura infantil no processo educativo, minha experiência, trabalhando na biblioteca escolar, foi fundamental para compreender como os livros desempenham um papel essencial no desenvolvimento das crianças, desde os primeiros momentos, antes mesmo da alfabetização for-

mal. Nesse ambiente, pude observar o crescente interesse das crianças pelos livros, algo que é natural e espontâneo, mas também percebi o impacto significativo que a mediação da leitura tem em sua formação.

A literatura, quando introduzida no contexto da educação infantil, vai muito além de um simples contato com as histórias; ela atua de maneira integral, estimulando a imaginação, ampliando o vocabulário e favorecendo tanto o desenvolvimento cognitivo quanto o emocional dos pequenos. E, durante esta vivência na biblioteca, ficou evidente que, mesmo para aquelas crianças que ainda não sabem ler, a mediação de leitura realizada pelo educador proporciona experiências enriquecedoras de aprendizado.

Nesse processo, a figura do professor é fundamental para transformar as histórias em ferramentas de interpretação do mundo, com um papel ativo na construção de significados. Por meio da leitura compartilhada, os alunos são apresentados a novas possibilidades de expressão e compreensão do universo ao seu redor, gerando não apenas o prazer de ouvir, mas também o desenvolvimento da capacidade de reflexão. Assim, os professores desempenham um papel vital na construção dessa relação com a literatura, tornando-a um elemento essencial no processo pedagógico.

Ao utilizar livros infantis, o educador consegue captar e manter a atenção das crianças de forma prazerosa, estimulando sua participação ativa e envolvimento nas atividades de leitura. Nesse contexto, a literatura se torna um elo de conexão entre o educador e o aluno, criando uma atmosfera afetiva e lúdica que contribui para o estabelecimento de vínculos afetivos profundos.

Com isso, desde os primeiros anos de escolarização, as crianças são incentivadas a desenvolver uma relação positiva com a leitura, o que pode gerar efeitos duradouros em sua trajetória acadêmica. Isto porque, a literatura infantil contribui para a socialização das crianças, ampliando seu repertório cultural e propiciando um espaço para a troca de ideias, o debate de emoções e a construção de significados em grupo.

Muitas vezes, as histórias lidas em sala de aula tornam-se referência para as brincadeiras, diálogos e até mesmo para a resolução de conflitos cotidianos entre as crianças. As narrativas ganham vida fora das páginas dos livros, integrando-se no universo das crianças de maneira concreta e cotidiana. Essa transposição das histórias para a realidade das crianças, por meio de suas brincadeiras e interações, reforça o papel da literatura como um agente de socialização e desenvolvimento de habilidades interpessoais. Nesse sentido, o professor, ao explorar diferentes gêneros e estilos literários, consegue oferecer experiências diversificadas que ampliam as formas de expressão dos alunos e colaboram para seu desenvolvimento integral.

Portanto, minha experiência na biblioteca escolar reforça a importância da literatura infantil como um recurso pedagógico poderoso, capaz de transformar o processo de alfabetização em uma experiência prazerosa e significativa. Ela não apenas contribui para a formação de leitores, mas também é uma ferramenta crucial para o desenvolvimento emocional, social e cognitivo das crianças. Ao se apropriar da literatura infantil, os professores podem proporcionar aos alunos experiências que são essenciais para a construção de uma educação mais contextualizada e envolvente, preparando-os para uma alfabetização que não se limita à decodificação das palavras, mas se estende ao desenvolvimento de uma compreensão mais ampla do mundo ao seu redor.

## REFERÊNCIAS

- ANDRADE, Ada Lorena Soares de. **Alfabetização e letramento nos anos iniciais do Ensino Fundamental I**. 2020. 25 f. Monografia (Graduação em Pedagogia) - Faculdade Pitágoras, Governador Valadares, 2020.
- AYMONE, Sandra. **Lição de Voo**. 3ª ed., Curitiba: Fundação Educar DPaschoal, 2019.

- BELINKY, Tatiana. **O grande rabanete**. 2ª ed., São Paulo: Moderna, 2002.
- BICHO ESPERTO. **Minhas primeiras histórias Disney: A Pequena Sereia**. 1ª ed., São Paulo: Editora Rideel Ltda, 2019.
- BRENMAN, Ilan. **Telefone sem fio**. 1ª ed., São Paulo: Companhia das Letrinhas, 2010.
- CALÌ, Davide. **Espaguete**. 1ª ed., Belo Horizonte: Edições SM, 2015.
- CAMARGO, Micheli Cristiana Ribas; MIYAKI, Cristina Yukie. A linguagem estilística da obra literária de Eva Furnari. In: MIRANDA, Antonio Luiz Alencar; OLIVEIRA, Karleiane de Souza Oliveira (Orgs.). **A linguagem em debate: socializando pesquisas em contexto de pandemia**. Maranhão: UEMA, 2022. p. 122-131.
- CIRÍACO, Flávia Lima. A leitura e a escrita no professo de alfabetização. **Revista Educação Pública**, v. 20, n. 4, p. 1-10, 2020.
- COLOMBO, Fabiano José. **A Literatura Infantil como meio para a formação da criança leitora**. Marília, São Paulo, 2009. 213 p. Tese (Mestrado em Educação) - Universidade Estadual Paulista (Unesp).
- CRUTTENDEN, Cynthia. **Sob o Sol, sob a Lua**. 2ª ed., São Paulo: Cosac & Naify, 2007.
- DALLA-BONA, E. M.; FONSECA, J. T. da. Análise de obras da Literatura Infantil como estratégia de formação do pedagogo/ professor: saber ler, saber escolher. **Educar em Revista**, Curitiba, Brasil, v. 34, n. 72, p. 39-56, nov./dez. 2018.
- DE MENEZES, Silvana. **A ovelha negra da Rita**. 1ª ed., São Paulo: Editora Cortez, 2017.
- DORIGO, Helena, NASCIMENTO, Maria. A concepção histórica sobre as crianças pequenas: subsídios para pensar o futuro. **Revista de Educação**, vol.2, n.3, Ponta Grossa, Paraná, 2007, p. 15 – 32.
- FLECK, Felícia de Oliveira; CUNHA, Miriam Figueiredo Vieira; CALDIN, Clarice Fortkamp. Livro ilustrado: texto, imagem e mediação. **Perspectivas em Ciência da Informação**, v.21, n.1, p.194-206, 2016.
- FURNARI, Eva. **Não confunda**. 1ª ed., São Paulo: Editora Moderna, 2011.
- GÂNDARA, Juliana Perina, BEFI-LOPES, Debora Maria DM. Tendências da aquisição lexical em crianças em desenvolvimento normal e crianças com Alterações Específicas no Desenvolvimento da Linguagem. **Rev soc bras fonoaudiol [Internet]**. 2010;15(2):297–304. <https://doi.org/10.1590/S1516-80342010000200024>
- KOCH, Ingedore Villaça; ELIAS, Vanda Maria. **Ler e Compreender: os sentidos do texto**. São Paulo: Editora Contexto, 2010.
- LAGO, Angela. **A Festa no Céu**. 2ª ed., São Paulo: Melhoramentos, 1999.
- LEONTIEV, Alexis. **O desenvolvimento do psiquismo**. 2. ed. São Paulo: Centauro, 2004. Publicado em 1959.
- LUIZ, Fernando Teixeira. A história do ensino de Literatura Infantil no Brasil: um estudo sobre a trajetória da obra de Monteiro Lobato na escola. **Nuances: estudos sobre Educação**, v. 12, n. 13, p. 21-32, 2005.
- MARÇAL, C.; ANDRÉ, T. C. Alfabetização e Literatura Infantil: contribuições da Teoria Histórico-Cultural. **Pleíade**, v. 16, n. 34, p. 84-90, 2022.
- MEDEIROS, Beatriz, GUIRALDELLI, Lisângela. Literatura Infantil: a importância da leitura no ensino fundamental para formação de futuros leitores. **Camine**. Franca, São Paulo, vol.13, n.1, 2021, p. 26 – 52.
- MEIRELES, Cecília. **Problemas da Literatura Infantil**. Rio de Janeiro: Nova Fronteira, 1984.
- REGO, Lucia Lins Browne. **Literatura Infantil: uma nova perspectiva da alfabetização na pré-escola**. 2. ed. São Paulo, 1995.
- RESENDE, Daniela Silva; SEVERINO, Mara Camargo; LIMA, Julia dos Reis; DOS ANJOS, José Humberto Rodrigues. Mediação de leitura na educação infantil: a partir do folclore nacional. In: **Anais do Colóquio Estadual de Pesquisa Multidisciplinar & Congresso Nacional de Pesquisa Multidisciplinar**, p. 01-06, 2021.
- RIBEIRO, Aline. **Literatura Infantil e desenvolvimento da imaginação: Trabalho modelado como ferramenta de ensino do argumento narrativo**. Marília, São Paulo, 2018. 223 p. Tese (Doutorado em Educação) – Universidade Estadual Paulista (Unesp).
- SANTOS, Claudiane Reviane Jesus dos; CANDIDO, Amélia Fernandes. A importância do livro-imagem e a influência do letramento visual para a alfabetização. **Intellectus Revista Acadêmica Digital**, v. 50, n. 01, p. 169-188, 2019.

---

SARGIANI, Renan de Almeida; MALUF, Maria Regina. Linguagem, Cognição e Educação Infantil: Contribuições da Psicologia Cognitiva e das Neurociências. **Psicologia Escolar e Educacional**, v. 22, n. 03, p. 01-08, 2018.

SILVA, Vitória Landa da. **As contribuições dos textos imagéticos no processo de alfabetização**. 2023. 67 f. Monografia (Licenciatura em Pedagogia) - Universidade Estadual Paulista, Rio Claro, 2023.

STOPPIGLIA, Bianca Elisa. **O humor na literatura infantil**: despertando o gosto para a leitura. 2002. 47 f. Monografia (Graduação em Pedagogia) - Universidade Estadual de Campinas, Campinas, 2002.

TRAVASSOS, Sônia. **Lobato, infância e leitura**: a obra infantil de Monteiro Lobato em diálogo com crianças na escola da atualidade. 2013. 238 f. Dissertação (Mestrado em Educação) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2013.

