

UNIVERSIDADE ABERTA
UNIVERSIDADE DE TRÁS-OS-MONTES E ALTO DOURO



WIZARD USER: UM AGENTE INTELIGENTE NA OTIMIZAÇÃO DE
PROCESSOS DE ENSINO-APRENDIZAGEM *ON-LINE*

Carlos Eduardo Ferrão de Azevedo

Doutoramento em Ciência e Tecnologia Web

(doutoramento em associação)



UNIVERSIDADE ABERTA
UNIVERSIDADE DE TRÁS-OS-MONTES E ALTO DOURO



*WIZARD USER: UM AGENTE INTELIGENTE NA OTIMIZAÇÃO DE
PROCESSOS DE ENSINO-APRENDIZAGEM ON-LINE*

Carlos Eduardo Ferrão de Azevedo

Doutoramento em Ciência e Tecnologia Web

(doutoramento em associação)



Tese de doutoramento orientada pelos Professores José Manuel Emiliano Bidarra de Almeida e Vítor Jorge Ramos Rocio, da Universidade Aberta de Portugal.

2025

DIREITOS DE AUTOR E CONDIÇÕES DE UTILIZAÇÃO DO TRABALHO POR TERCEIROS

Este é um trabalho académico que pode ser utilizado por terceiros desde que respeitadas as regras e boas práticas internacionalmente aceites, no que concerne aos direitos de autor e direitos conexos.

Assim, o presente trabalho pode ser utilizado nos termos previstos na licença abaixo indicada.

Caso o utilizador necessite de permissão para poder fazer um uso do trabalho em condições não previstas no licenciamento indicado, deverá contactar o autor, através do Repositório Aberto, da Universidade Aberta.

Licença concedida aos utilizadores deste trabalho



**Atribuição
CC BY**

<https://creativecommons.org/licenses/by/4.0/>

AGRADECIMENTOS

Primeiramente, agradeço aos meus orientadores, Prof. José Bidarra e Prof. Vitor Rocio, pelo sábio auxílio nesta investigação.

Agradeço aos meus irmãos, Luciana Ferrão e Henrique Ferrão, que, sempre, me incentivaram para que eu concluísse essa jornada.

Agradeço ao amigo Alvaro José Moreyra Duarte, pelo incentivo e por todas as leituras e revisões de ortografia realizadas.

Agradeço às pessoas especiais na minha trajetória profissional e acadêmica, que são: professor Marcos Elias, meu orientador de mestrado, que me fez despertar para o mundo científico; à Ilene Pessoa (*in memoriam*), a gestora que muito me ensinou sobre educação à distância; e, à professora Denise Melo, minha orientadora da graduação em Licenciatura em Informática, que, sempre, me incentivou para que fizesse o mestrado e o doutorado.

Agradeço aos meus amigos (prefiro não citar nomes), que me incentivaram e se orgulham da minha trajetória acadêmica.

Por último e mais especial, agradeço a Deus por ter me dado a oportunidade de chegar até esse momento, auxiliando-me para vencer todos os desafios impostos pela vida.

DEDICATÓRIA

Esta tese de doutorado é dedicada ao meu avô, José de Azevedo (*in memoriam*), que, antes do meu nascimento, sonhou com uma placa em uma porta, onde estava escrito: Doutor Carlos Eduardo e sugeriu aos meus pais este nome. Sem titubear, meus pais aceitaram a sugestão e eu persigo a realização do sonho de meu avô, em me tornar um doutor por mérito científico. Acrescento que este fato permeou a minha vida, fazendo-me ser um questionador e amante da ciência.

Dedico aos meus pais, Dina Ferrão de Azevedo (*in memoriam*) e Ciro José de Azevedo, que muito me incentivaram para que eu realizasse o sonho de meu avô, afirmando que, hoje, também, compartilho desse desejo.

Dedico ao meu filho Bernardo Ferrão, que, por muitos momentos, foi a minha fonte de inspiração e o motivo de eu não desistir. Que a minha perseverança sirva como exemplo para ele!



DECLARAÇÃO DE INTEGRIDADE

STATEMENT OF INTEGRITY

Declaro ter atuado com integridade na elaboração da presente dissertação/tese. Confirmando que em todo o trabalho conducente à sua elaboração não recorri à prática de plágio ou a qualquer outra forma de falsificação de resultados.

Mais declaro que tomei conhecimento integral do Regulamento Disciplinar da Universidade Aberta, publicado no Diário da República, 2.ª série, n.º 215, de 6 de novembro de 2013.

I hereby declare having conducted my thesis with integrity. I confirm that I have not used plagiarism or any form of falsification of results in the process of the thesis elaboration.

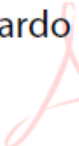
I further declare that I have fully acknowledged Disciplinary Regulations of the Universidade Aberta (regulation published in the official journal Diário da República, 2.ª série, N.º 215, de 6 de novembro de 2013).

Universidade Aberta, 19 de novembro de 2025

Nome completo/Full name: Carlos Eduardo Ferrão de Azevedo

Assinatura/Signature:

Carlos Eduardo
Ferrão de
Azevedo



Assinado de forma digital
por Carlos Eduardo Ferrão
de Azevedo
Dados: 2025.11.19
09:17:41 -03'00'

manuscrita ou digital / handwritten or digital

WIZARD USER: UM AGENTE INTELIGENTE NA OTIMIZAÇÃO DE PROCESSOS DE ENSINO-APRENDIZAGEM ON-LINE

RESUMO

A cada dia, a tecnologia nos oferece novas ferramentas que permitem dar mais significado ao processo educacional, sobremaneira às Tecnologias Cognitivas - capazes de interpretar, estruturar e cruzar dados, gerando previsões a partir da análise de informações, além de realizar inferências automáticas na evolução da participação e aprendizado dos usuários. No *e-learning*, as ferramentas de acompanhamento evolutivo dos participantes são fundamentais no processo de ensino-aprendizagem. No contexto da pandemia do Covid-19, a implementação do ensino remoto, com a necessária realização de aulas por meios digitais, encontrou entre os principais desafios a falta de motivação dos alunos e o desconhecimento das ferramentas disponíveis por parte dos mediadores educacionais para que pudessem incentivar, motivar e facilitar o processo educativo em cursos *on-line*. Contudo, reconhecemos as limitações de tempo desses profissionais e a urgência por parte dos alunos em receber as informações de forma rápida e assertiva. Este trabalho apresenta a proposta de um recurso de IA chamado *Wizard User*, cujo objetivo é facilitar o processo de mediação pedagógica e realizar ações automáticas, por meio de *triggers* que auxiliam o processo de ensino-aprendizagem, com uso da IA e técnicas de mineração de dados, permitindo a comparação do estudante com seus pares como elemento motivacional em cursos *on-line*. Ainda, neste trabalho, poderão ser encontrados detalhes do modelo sistêmico e os resultados alcançados com a experimentação do ecossistema, no curso de formação de desenvolvedores *fullstack*, com o acompanhamento realizado por meio de grupo controle, pelo período de 6 meses.

Palavras-chave: Tecnologia cognitiva; *Wizard User*; Mineração de dados; Ensino-aprendizagem; Covid-19; Inteligência artificial.

WIZARD USER: AN INTELLIGENT AGENT FOR OPTIMIZING ONLINE TEACHING–LEARNING PROCESSES

ABSTRACT

Every day, technology offers us new tools that allow us to give more meaning to the educational process, especially Cognitive Technologies - capable of interpreting, structuring and crossing data, generating predictions from the analysis of information, in addition to making automatic inferences in the evolution of user participation and learning. In e-learning, tools for monitoring participants' progress are fundamental in the teaching-learning process. In the context of the Covid-19 pandemic, the implementation of remote teaching, with the need to carry out classes using digital means, found among the main challenges the lack of motivation of students and the lack of knowledge available on the part of educational mediators so that encouraged, motivated and facilitated the educational process in on-line courses. However, we recognize the time limitations of these professionals and the urgency on the part of students to receive information quickly and assertively. This work presents the proposal for an artificial intelligence resource called Wizard User, whose objective is to facilitate the pedagogical mediation process and carry out automatic actions, through triggers that assist the learning process, using artificial intelligence and data mining techniques. Data mining, allowing students to compare themselves with their peers as a motivational element in on-line courses. Also in this work, details of the systemic model and the results achieved with experimentation with the ecosystem will be found, in the training course for fullstack developers, with monitoring carried out through a control group, for a period of 6 months.

Keywords: *Cognitive technology; Wizard User; Educational technology; Teaching-learning; Covid-19; Data mining, Artificial intelligence.*

SUMÁRIO

Capítulo 1 – Introdução	1
1.1 Transformação Digital	2
1.2 Motivação e justificativa.....	3
1.3 Hipótese.....	4
1.4 Questões de investigação.....	5
1.5 Objetivos	6
1.6 Definição da Proposta	6
1.7 Metodologia da investigação	7
1.8 Estrutura da tese	8
Capítulo 2 – Inteligência Artificial na educação: Fundamentos, Tecnologias e Perspectivas	10
2.1 Contextualização da Inteligência Artificial no Ensino	11
2.2 IA: da ficção à realidade.....	12
2.3 Educação <i>on-line</i> : transformações no processo de ensino-aprendizagem	15
2.4 Sistema de Tutoria Inteligente (ITS).....	18
2.5 Aplicação da IA	20
2.6 Ensino adaptativo ou aprendizagem personalizada.....	22
2.7 Aprendizado de máquina – <i>Machine Learning (ML)</i>	24
2.8 Sistemas de tutoria baseados em diálogo	26
2.9 Ambientes de aprendizagem exploratória.....	27
2.10 Avaliação de redação automatizada	29
2.11 Leitura com suporte de IA e aprendizagem de línguas	30
2.12 Orquestradores de redes de aprendizagem	31
2.13 Aprendizagem colaborativa habilitada para IA	31
2.14 Desafios da Inteligência Artificial na educação	33
2.15 Tendências	34
Capítulo 3 – Investigação Prévia	37
3.1 Requisitos da Investigação Prévia	38
3.2 Resultados	40

3.2.1	Percepção dos gestores	41
3.2.2	Percepção dos alunos	42
3.2.3	Percepção do Investigador	46
3.2.4	Implicações para o Modelo <i>Wizard User</i>	47
Capítulo 4	– Revisão Sistemática	48
4.1	Contexto	49
4.2	Metodologia da Revisão Sistemática	50
4.2.1	Processo de seleção e exclusão de artigos.....	51
4.2.2	Análise de viés.....	52
4.2.3	Meta-análise.....	53
4.3	Resultados da Revisão Sistemática.....	54
4.3.1	Características dos artigos.....	56
4.3.2	Risco de viés.....	58
4.3.1	Resultados de artigos individualizados	60
4.3.2	Síntese dos resultados	62
4.3.3	Meta-análise	64
4.3.4	Avaliação da força da evidência	67
4.4	Discussão.....	68
4.5	Conclusão da RS	72
4.6	Integração das Evidências: Alinhamento entre Resultados da Revisão Sistemática e a Investigação sobre o <i>Wizard User</i>	73
Capítulo 5	– Metodologia da Investigação	75
5.1	Abordagem, Estrutura e Etapas da Investigação	76
5.2	Validação do ecossistema (Modelo <i>Wizard User</i>).....	79
5.3	Associação com a investigação prévia	84
5.3.1	Definição operacional dos grupos e intensidade de uso.....	85
Capítulo 6	– Modelo <i>Wizard User</i>	89
6.1	Desenvolvimento do Modelo	90
6.2	Interação e predição	93
6.3	Tutoria inteligente.....	95
6.4	Recomendação educacional.....	98
6.5	<i>Inputs</i>	101

6.7 Arquitetura tecnológica.....	105
6.8 Processo de desenvolvimento	108
Capítulo 7 – Resultados	112
7.1 Contexto dos resultados.....	112
7.2 Detalhamento da amostra	114
7.3 Passo a passo da preparação das análises qualitativas.....	115
7.4 Análise qualitativa	116
7.4.1 Experiência vivenciada no curso	118
7.4.2 Processo de Interação	118
7.4.3 Conhecimento Adquirido.....	119
7.4.4 Diferencial no Processo de ensino-aprendizagem.....	120
7.4.5 Uso de Indicadores Preditivos	121
7.4.6 Recomendação de Conteúdo pelo <i>Wizard User</i>	122
7.4.7 Percepção do tutor, dos monitores e da coordenadora	123
7.4.8 Considerações sobre a análise qualitativa	127
7.5 Análise comparativa quantitativa.....	128
7.5.1 Considerações da análise quantitativa	138
7.6 Considerações sobre os resultados	139
Capítulo 8 – Conclusões.....	141
8.1 Conclusões da investigação.....	142
8.2 Desafios Encontrados	144
8.3 Trabalhos Publicados.....	145
8.4 Perspectivas e Trabalhos Futuros	145
Referências.....	148
ANEXO A – GRADE CURRICULAR	168
APÊNDICE A – DIAGNÓSTICO PEDAGÓGICO COM ALUNOS.....	169
APÊNDICE B – DIAGNÓSTICO PEDAGÓGICO COM GESTORES	174
APÊNDICE C – ESTRATÉGIA E RESULTADO DE BUSCA.....	177
APÊNDICE D – HISTÓRICO DE NOTAS POR GRUPOS/DISCIPLINAS	178

ÍNDICE DE GRÁFICOS E QUADROS

Quadro 2.1 – Comparação DBTS vs. ITS	27
Quadro 2 – Comparação DBTS vs. ITS vs. ELEs	29
Quadro 3.1 – Quesitos da Investigação Prévia	38
Quadro 3.2 – Comparativo das percepções de gestores e alunos por quesito	39
Quadro 4.1 – Instrumento de avaliação de risco de viés (Instituto Joana Briggs)	57
Quadro 4.2 – Resultados estatísticos Individuais	60
Quadro 4.3 – GRADE (<i>Grading of Recommendations Assessment, Development, and Evaluation</i>)	67
Tabela 6.1 – Correspondência entre Camadas Arquiteturais e Implementação no Wizard User	106
Quadro 7.1 – Comparação de Autores e Abordagens em Pesquisa Qualitativa	113
Quadro 7.2 – Amostra da Investigação – <i>Wizard User</i>	114
Quadro 7.3 – Quesitos da Investigação	117
Quadro 7.4 – Indagações aos Gestores Educacionais	123
Quadro 7.5 – Resumo Grupo A	128
Quadro 7.6 – Resumo Grupo B	129
Quadro 7.7 – Resumo Grupo C	129
Quadro 7.8 – Resumo da Análise	134
Quadro 7.9 – Média das Médias	131
Quadro 7.10 – Desvio Padrão	132
Quadro 7.11 – Coeficiente de variação por grupo	133
Quadro 7.12 – Coeficiente de variação por disciplina e grupo	134
Quadro 7.13 – Testes de normalidade e comparação entre grupos	134
Quadro 7.14 – Taxa de evasão	137

ÍNDICE DE FIGURAS

Figura 3.1 – Investigação Prévia	38
Figura 3.2 – Gráfico: Tipo de curso	43
Figura 3.3 – Gráfico: Análise de quesitos na visão do aluno	43
Figura 3.4 – Gráfico: Melhorias gerais	45
Figura 4.1 – Diagrama de fluxo PRISMA 2020	55
Figura 4.2 – Gráfico de funil para avaliação de viés de publicação	59
Figura 4.3 – Gráfico de Floresta sobre o Desempenho acadêmico dos alunos em cursos on-line (IAs e Grupos controle)	65
Figura. 4.4 - Gráfico de Floresta sobre o Desempenho acadêmico dos alunos em cursos on-line (IAs e Grupos Controle) sem o artigo de coorte	65
Figura 4.5 – Gráfico de Floresta Gráfico de Floresta sobre o Desempenho acadêmico dos alunos em cursos <i>on-line</i> apenas com métodos tradicionais no Grupo Controle	67
Figura 4.6 – Gráfico de Floresta Gráfico de Floresta sobre o Desempenho acadêmico dos alunos em cursos <i>on-line</i> apenas com métodos tradicionais no Grupo Controle sem o artigo de corte	67
Figura 5.1 – Esquema da organização metodológica	77
Figura 5.2 – Fluxo resumido do processo metodológico	79
Figura 5.3 – Fluxo de validação do modelo	80
Figura 6.1 – Modelo conceitual do <i>Wizard</i>	92
Figura 6.2 – Técnicas de coleta, análise e entrega da informação	93
Figura 6.3 – Processo de coleta e análise de dados no <i>Wizard User</i>	94
Figura 6.4 – Módulo de Tutoria Inteligente do <i>Wizard User</i>	97
Figura 6.5 – Arquitetura do Módulo de Recomendação Educacional do <i>Wizard User</i>	100
Figura 6.6 – Estrutura dos inputs do <i>Wizard User</i>	102
Figura 6.7 – Segregação de módulos do <i>Wizard User</i>	104
Figura 6.8 – Arquitetura técnica do <i>Wizard User</i>	106
Figura 7.1 – Distribuição das médias globais por grupo (<i>boxplot</i>)	136

LISTA DE ABREVIATURAS, SIGLAS E ACRÓNIMO

A.L.I.C.E.	<i>Artificial Linguistic Internet Computer Entity</i>
AVA	Ambiente Virtual de Aprendizagem
AWE	Avaliação automatizada da escrita
Bot	Robô (agente inteligente)
DBR	<i>Design-Based Research</i>
DBTS	Sistemas de tutoria baseados em diálogo
EAD	Educação à Distância
Edtech	<i>Education technology</i>
ELE	Ambiente de aprendizagem exploratório
GPT	<i>Generative Pretrained Transformer</i>
IA	Inteligência artificial
IBM	<i>International Business Machines Corporation</i>
ITS	<i>Intelligent Tutoring System</i>
JWT	<i>JSON Web Token</i>
LNO	Orquestradores de Redes de aprendizagem
LTI	<i>Learning Tools Interoperability</i>
ML	<i>Machine Learning</i>
SRBC	Sistemas de Recomendação Baseada em Conteúdo
SRC	Sistemas de Recomendação Colaborativa
SRH	Sistemas de Recomendação Híbrida
SRs	Sistemas de Recomendação
TIC	Tecnologias da informação e comunicação
UNESCO	Organização das Nações Unidas para a Educação, a Ciência e a Cultura
USMLE	Exame de Licenciamento Médico dos Estados Unidos
VR	Realidade virtual

Capítulo 1 – Introdução

“A ciência se baseia em conjecturas e refutações. Ela cresce destruindo suas próprias teorias.”

Karl Popper

Neste capítulo, apresenta-se uma breve contextualização do tema, seguidas das motivações e justificativas para a elaboração desta tese. São também descritos a questão de investigação, a hipótese formulada, os objetivos do estudo, um resumo da metodologia adotada e a estrutura geral deste trabalho científico.

1.1 Transformação Digital

A sociedade contemporânea vive um processo de transformação acelerada, impactando múltiplas esferas, da educação à saúde, das finanças ao meio ambiente, em razão de avanços tecnológicos sem precedentes (Oliveira, 2015; Gomes, 2017). A emergência da pandemia de COVID-19, a partir de 2020, aprofundou ainda mais essas mudanças, especialmente no campo educacional, impondo a adoção súbita de soluções digitais e acelerando a reinvenção de práticas de ensino-aprendizagem (Barth, 2017; Basilaia, 2020; Kaffenberger, 2021).

Nas últimas décadas, observa-se um crescimento exponencial no uso de tecnologias digitais e metodologias inovadoras aplicadas à educação, culminando com a massificação do ensino *on-line* e no surgimento de um ecossistema global de *EdTechs* (Kohn & Moraes, 2007; Fórum Econômico Mundial, 2020). Antes mesmo da pandemia, os investimentos globais em tecnologia educacional já ultrapassavam US\$ 18 bilhões ao ano, com projeções de que o mercado de educação *on-line* atingiria US\$ 350 bilhões até 2025. A crise sanitária apenas catalisou esse movimento, com a UNESCO (2020) estimando que mais de 1,5 bilhão de estudantes foram afetados pelo fechamento das instituições presenciais, obrigando sistemas educacionais ao redor do mundo a repensarem métodos, recursos e abordagens.

Dessa forma, a necessidade de soluções tecnológicas que assegurem escala, qualidade e personalização do ensino tornou-se premente. A literatura enfatiza, nesse cenário, o papel de ferramentas baseadas em inteligência artificial (IA), *big data* e *learning analytics* para superar desafios históricos da educação *on-line*, tais como, a heterogeneidade de perfis, o engajamento reduzido e a necessidade de *feedbacks* personalizados (Brown, 2012; Pardo, 2017a; Rosito, Soares & Webber, 2021). Em particular, os sistemas de tutoria inteligente (*ITS - Intelligent Tutoring Systems*), os *chatbots* educacionais e os mecanismos de aprendizagem adaptativa vêm se consolidando como alternativas promissoras para atender às demandas de acompanhamento individualizado e de intervenção pedagógica em larga escala (Silva, Carvalho & Maciel, 2021; Meira, Tavares & Amaral, 2020).

A evolução desses sistemas, entretanto, levanta novos desafios pedagógicos e tecnológicos, como a necessidade de especialização do conhecimento, adaptação às especificidades de cada usuário e integração de abordagens cognitivas avançadas (Alkatheiri, 2022; Kohn & Moraes, 2007). O desenvolvimento e a aplicação de soluções de computação cognitiva e IA na educação abrem, assim, um campo fértil de investigação, exigindo reflexão crítica sobre sua eficácia, limitações e potencial transformador (Pardo et al., 2017b).

Nesse sentido, Zawacki-Richter, Marín, Bond & Gouverneur (2021), em uma revisão sistemática, enfatizam que, embora as aplicações de IA ofereçam oportunidades significativas para inovação no ensino superior, ainda carecem de fundamentação pedagógica sólida e envolvimento efetivo de educadores nos processos de desenvolvimento e implementação.

Neste cenário de transformação, lacunas tecnológicas e potenciais inexplorados, insere-se a presente investigação, cujo objetivo é compreender, desenvolver e avaliar um modelo inovador de aplicação da IA para potencializar o processo de ensino-aprendizagem em ambientes digitais. A pesquisa busca responder a uma demanda real: como articular personalização, tutoria e recomendação em um único ecossistema funcional, capaz de apoiar a mediação pedagógica de maneira eficaz e escalável.

1.2 Motivação e justificativa

A crescente adoção da educação *on-line* tem impulsionado transformações significativas nos modos de ensinar e aprender, com destaque para os Ambientes Virtuais de Aprendizagem (AVAs) como plataformas centrais de interação. Contudo, mesmo diante de avanços tecnológicos, persistem lacunas estruturais no que se refere à personalização do ensino, à tutoria automatizada e à geração de dados pedagógicos estratégicos (Zawacki-Richter et al., 2019). Estudos indicam que essas dimensões são frequentemente tratadas de forma fragmentada, e não se identificam, na literatura, modelos tecnológicos que integrem de maneira adaptativa essas três frentes em um único ecossistema funcional.

Nesse contexto, esta investigação propõe o desenvolvimento do modelo *Wizard User*, concebido como uma solução que combina IA, análise de dados e mediação interativa com foco em personalização da aprendizagem. O modelo é desenhado para ser flexível, escalável e aplicável a múltiplos contextos educacionais, respondendo diretamente aos desafios da aprendizagem digital contemporânea.

É importante enfatizar que evidências recentes destacam o potencial da IA para mediar competências cognitivas, promover engajamento ativo e adaptar trajetórias de aprendizagem (Chen et al., 2020; Flores et al., 2021; Flores et al., 2022). Tecnologias como *chatbots* educacionais, sistemas tutoriais inteligentes e mecanismos de recomendação já demonstram avanços pontuais, mas carecem de articulação pedagógica robusta e integração estratégica com a análise do desempenho acadêmico (Holmes, Bialik & Fadel, 2019).

Assim, a presente pesquisa justifica-se não apenas por uma lacuna tecnológica, mas por uma necessidade pedagógica urgente: construir um modelo replicável e baseado em evidências que integre tutoria, predição e recomendação de maneira sinérgica, superando os limites dos AVAs tradicionais e impulsionando um novo modelo de personalização no *ensino on-line*.

1.3 Hipótese

Considerando as lacunas anteriormente citadas, esta pesquisa parte da hipótese de que a aplicação do modelo *Wizard User*, desenvolvido com base em técnicas de análise preditiva, recomendação e tutoria inteligente, tem a possibilidade de potencializar a eficácia do processo de ensino-aprendizagem em cursos *on-line*.

Espera-se que, ao integrar funcionalidades adaptativas orientadas por dados, o sistema proporcione experiências mais personalizadas de aprendizagem, favorecendo a antecipação de dificuldades, o estímulo à autonomia dos estudantes e o aprimoramento das interações pedagógicas, sobretudo quando comparado a AVAs tradicionais.

A hipótese orientadora, portanto, é a de que um sistema inteligente, completo e adaptável como o *Wizard User* poderá melhorar significativamente o desempenho, o engajamento e a experiência dos estudantes, por meio de recomendações personalizadas, indicadores estratégicos e mediação automatizada de qualidade.

1.4 Questões de investigação

A mediação pedagógica em cursos *on-line* conta com o apoio de artefatos tecnológicos que viabilizam interações, distribuem conteúdos e incentivam a colaboração entre os participantes (Yin, Hadwin & Gress, 2021). Nesse cenário, equipes pedagógicas multidisciplinares são mobilizadas para compreender as necessidades dos estudantes, muitas vezes não explícitas, e propor intervenções eficazes no processo de ensino-aprendizagem.

Com o avanço da computação, em especial da IA, surge a oportunidade de integrar sistemas inteligentes ao processo de mediação, ampliando a capacidade de resposta aos desafios enfrentados em AVAs. Tal necessidade tornou-se ainda mais evidente durante a pandemia da COVID-19, substituindo interações presenciais por dinâmicas mediadas por tecnologia.

Diante desse quadro, propõe-se investigar de que forma um modelo de IA aplicado à educação pode prover melhorias mensuráveis no processo de ensino-aprendizagem em cursos *on-line*, tanto pelo apoio à mediação pedagógica quanto pela oferta de recomendações personalizadas baseadas em dados. Para tornar essa questão diretora empiricamente operacionalizável e alinhada às conclusões concretas do estudo, desdobram-se as seguintes subquestões:

Q1. A IA melhora os resultados acadêmicos (por exemplo, desempenho em avaliações, taxa de aprovação e domínio de competências)?

Q2. Contribui para reduzir o abandono/evasão (aumentando a persistência e a conclusão de disciplinas)?

Q3. Fortalece o engajamento no processo de ensino-aprendizagem (autoeficácia, percepção de controle e utilidade do percurso formativo)?

Ao responder a essas perguntas, esta investigação busca compreender o potencial de um modelo tecnológico para analisar interações, identificar padrões e

gerar recomendações adaptativas ao perfil do estudante, traduzindo tais mecanismos em ganhos concretos de desempenho acadêmico, continuidade e confiança no aprender.

1.5 Objetivos

O objetivo central desta investigação é validar um modelo tecnológico, denominado *Wizard User*, que unifica técnicas de predição, recomendação personalizada e tutoria inteligente, com o propósito de apoiar a mediação pedagógica e contribuir para a melhoria do desempenho dos estudantes em cursos *on-line*, especialmente diante dos desafios evidenciados pela massificação do *e-learning*.

Como objetivos específicos, propõe-se:

- Desenvolver um sistema cognitivo baseado em técnicas de predição, recomendação e tutoria inteligente, capaz de aprender automaticamente a partir das interações realizadas no AVA;
- Implementar mecanismos de inferência automatizada que possibilitem comunicações e sugestões personalizadas aos usuários, com base nos históricos de interação registrados nas disciplinas analisadas;
- Analisar os efeitos da aplicação do modelo *Wizard User* sobre indicadores de desempenho acadêmico, como taxa de conclusão de atividades e retenção de conteúdo.

1.6 Definição da Proposta

Esta tese visa validar um modelo tecnológico desenvolvido para promover a personalização automatizada da aprendizagem em cursos *on-line*, por meio da aplicação de IA integrada a técnicas já consolidadas no campo da educação digital. O modelo tem como principal finalidade apoiar o processo de ensino-aprendizagem e a interação entre os interlocutores deste processo (gestores educacionais, tutores, professores e estudantes), atuando como um agente inteligente inserido no AVA.

Projetado para operar de forma integrada, o *Wizard User* permite tanto interações manuais quanto automáticas, realiza a captura de dados

comportamentais e acadêmicos e oferece recomendações personalizadas com base no histórico de aprendizagem dos usuários. Seu diferencial qualitativo reside na capacidade de combinar de forma sinérgica três técnicas essenciais:

- Predição, para antecipar dificuldades e padrões recorrentes de erro;
- Recomendação de ações, com base nas interações registradas no ambiente virtual;
- Tutoria inteligente, capaz de oferecer suporte individualizado ao estudante de acordo com a sua necessidade.

Para fins de validação técnica e funcional, o modelo foi implementado com o uso de soluções cognitivas do *IBM Watson*. No entanto, sua arquitetura foi concebida de modo a permitir a adaptação e reimplementação com outras plataformas de IA disponíveis no mercado ou mesmo com tecnologias proprietárias, assegurando sua flexibilidade e escalabilidade.

1.7 Metodologia da investigação

A metodologia adotada nesta tese é a *Design-Based Research (DBR)*, por sua capacidade de integrar desenvolvimento de artefatos, investigação empírica e fundamentação teórica em ciclos progressivos e iterativos. A *DBR* é especialmente adequada ao campo da educação, pois permite alinhar a criação de soluções tecnológicas às necessidades reais de aprendizagem, promovendo inovação com rigor científico (Romero-Ariza, 2014; Sandoval & Bell, 2004; Walter, 2024).

A metodologia foi escolhida por sua natureza flexível e abrangente, ao combinar métodos qualitativos e quantitativos em ciclos de análise, *design*, implementação e avaliação (McKenney & Reeves, 2012). Essas características possibilitaram o desenvolvimento e a validação do modelo *Wizard User* integrado ao AVA.

O percurso metodológico desta tese incluiu três fases principais: (1) levantamento teórico e análise de experiências profissionais do pesquisador no contexto da educação *on-line*; (2) concepção e modelagem técnica do artefato com base em interações com gestores e estudantes do ensino superior; e (3)

validação em ambiente real de aprendizagem, com coleta e análise dos efeitos do modelo sobre o processo educacional.

Além das etapas de desenvolvimento e validação do modelo *Wizard User*, esta tese incorporou, em sua fase final, uma revisão sistemática da literatura sobre aplicações de IA na educação *on-line*. Essa etapa teve como objetivo comparar os resultados obtidos no experimento com as evidências científicas consolidadas, ampliando a robustez teórica da investigação e contribuindo para o diálogo crítico com o estado da arte. O processo e os achados dessa revisão sistemática são apresentados no Capítulo 4 - Revisão Sistemática.

O detalhamento do desenho metodológico completo, incluindo os procedimentos de coleta e análise de dados, os instrumentos utilizados e os critérios de validação do modelo, encontra-se descrito no Capítulo 5 - Metodologia de Investigação.

1.8 Estrutura da tese

O **Capítulo 1 – Introdução** apresenta a contextualização do tema, a definição do problema de pesquisa, os objetivos, hipóteses e justificativas, além de uma síntese da proposta desenvolvida.

No **Capítulo 2 – Inteligência Artificial na educação: Fundamentos, Tecnologias e Perspectivas**, são explorados os conceitos fundamentais e as tendências contemporâneas relacionadas à aplicação de IA, *machine learning*, *deep learning* e tecnologias cognitivas no campo educacional.

O **Capítulo 3 – Investigação Prévia** reúne análises diagnósticas sobre o uso de tecnologias digitais em cursos *on-line*, a partir da percepção de educadores e alunos, delineando o cenário atual e as demandas emergentes do ensino mediado por IA.

O **Capítulo 4 – Revisão Sistemática** sistematiza criticamente a produção científica internacional sobre o impacto e a efetividade de soluções baseadas em IA no processo de ensino-aprendizagem *on-line*, identificando tendências, desafios e lacunas que fundamentam a proposta deste estudo.

No **Capítulo 5 – Metodologia de Investigação**, são detalhados o desenho metodológico, os procedimentos de coleta e análise de dados, bem como os critérios adotados para a implementação e validação do estudo.

O **Capítulo 6 – Modelo de desenvolvimento do *Wizard User*** descreve o processo de concepção, arquitetura e implementação da solução tecnológica proposta, destacando as técnicas e estratégias adotadas, bem como a integração com o contexto empírico investigado.

O **Capítulo 7 – Resultados** apresenta a análise decorrente da implementação do *Wizard User*, descrevendo os efeitos observados sobre a aprendizagem, a permanência dos alunos e a dispersão dos resultados, de modo a evidenciar a contribuição da ferramenta para o processo educacional investigado.

Finalmente, o **Capítulo 8 – Conclusões** sintetiza os principais achados da pesquisa, discute as contribuições e limitações do estudo e aponta perspectivas para futuras investigações no campo da IA aplicada à educação.

Ao término dos capítulos, esta tese apresenta a lista completa de referências bibliográficas utilizadas, seguida dos apêndices (materiais produzidos pelo autor, como instrumentos e roteiros de pesquisa) e anexos (documentos complementares e externos relevantes à compreensão da investigação).

Capítulo 2 – Inteligência Artificial na educação: Fundamentos, Tecnologias e Perspectivas

“O propósito da IA não é criar uma mente, mas estender a capacidade cognitiva do homem.”

Edsger Dijkstra

Este capítulo apresenta uma abordagem abrangente sobre a aplicação da IA na educação, com ênfase nos ambientes digitais e no contexto da educação *on-line*. Parte-se de uma perspectiva histórica da IA e sua transição da ficção científica para a realidade educacional, até sua consolidação em sistemas inteligentes de tutoria, aprendizagem personalizada, ambientes exploratórios, avaliação automatizada e outras tecnologias emergentes. São exploradas ferramentas, conceitos fundamentais, como, *machine learning (ML)*, desafios éticos, impactos da pandemia, tendências futuras e a integração da IA com práticas pedagógicas, visando compreender seus benefícios, limitações e implicações no processo de ensino-aprendizagem.

2.1 Contextualização da Inteligência Artificial no Ensino

Popularizado por livros, filmes e novelas televisivas, o tema da IA esteve, por muito tempo, vinculado a narrativas fantasiosas em que robôs e andróides atingiam capacidades cognitivas semelhantes às humanas, restrito ao campo da ficção científica.

Com o avanço acelerado da tecnologia, entretanto, a IA consolidou-se como realidade concreta nas esferas públicas e privadas. Conforme Han, “As tecnologias de IA estão a penetrar quase todos os aspectos das nossas vidas, de forma quase imperceptível” (Han, 2022), e está presente particularmente em dispositivos móveis, como *smartphones*, por meio de assistentes como *Siri*, *Alexa* e *Cortana*, permitindo interações em qualquer tempo e lugar.

A transformação digital em curso, que impacta diversos setores da economia, tem afetado de forma significativa a educação, ao revelar oportunidades promissoras para o uso de soluções tecnológicas na expansão do ensino *on-line* (Abad-Segura et al., 2020).

A inovação em IA na educação deixou de se restringir a laboratórios e, mesmo que de forma inicial, já começa a impactar ambientes educacionais reais, sinalizando seu amadurecimento e relevância prática (Guan, Mou & Jiang, 2020).

O avanço das redes *Wi-Fi*, processadores mais potentes, dispositivos móveis e armazenamento em nuvem tem impulsionado sistemas educacionais baseados em IA, como o *learning analytics*, que emprega *big data* e *machine learning* para reconhecer padrões de aprendizagem (Romero & Ventura, 2024).

O contexto da pandemia de COVID-19 acelerou essas transformações, promovendo o uso ampliado de tecnologias digitais no processo educativo e evidenciando o papel da IA como elemento de apoio ao ensino (Fagundes, Cossul & Frozza, 2020).

Apesar do avanço tecnológico, a integração plena da IA nas práticas educacionais ainda ocorre de forma limitada, com apropriação parcial dos recursos disponíveis (Tavares, Meira & Amaral, 2020).

A Organização das Nações Unidas para a Educação, a Ciência e a Cultura (UNESCO, 2021) aponta que, em consonância com o quarto Objetivo de Desenvolvimento Sustentável, a IA representa uma estratégia viável para enfrentar desafios estruturais da educação, especialmente no que se refere à inovação das práticas pedagógicas.

Essa discussão ganha destaque quando consideramos o debate internacional sobre o papel da IA na educação. Durante o evento *Enlighted Education*, realizado em 2020, enfatizou-se a necessidade de promover articulações entre a inteligência humana e a artificial, reconhecendo, entretanto, a superioridade cognitiva da primeira (Luckin, 2020). Esse entendimento reforça a importância de desenvolver soluções tecnológicas que atuem de forma complementar, potencializando as capacidades humanas em vez de buscar substituí-las integralmente.

Segundo Holmes (2022), a IA impacta a educação em três dimensões interdependentes: aprender para a IA, aprender sobre a IA e aprender com a IA. Estudos recentes ampliam esse escopo, incluindo a colaboração com sistemas inteligentes (*learning with AI*), a participação ativa dos alunos no treinamento dos algoritmos (*teaching the AI*) e a reflexão crítica sobre os impactos éticos e sociais dessas tecnologias (Holmes et al., 2022; Luckin et al., 2023; Zhang et al., 2024). Essas novas abordagens refletem o cenário contemporâneo da IA, destacando não só o uso instrumental, mas também a coautoria, a consciência ética e a alfabetização crítica como elementos centrais da educação do século XXI.

Nesse cenário, em que a IA assume múltiplos papéis no contexto educacional, desde ferramenta até parceira de coautoria e objeto de reflexão crítica, o papel dos educadores torna-se ainda mais central e estratégico. Isso exige uma formação que vá além do domínio técnico, incorporando também dimensões éticas, pedagógicas e críticas para lidar com os desafios e oportunidades da educação mediada por IA.

2.2 IA: da ficção à realidade

As pesquisas sobre o uso da IA tiveram início nas décadas de 1940 e 1950, com forte impulso durante a Segunda Guerra Mundial. Em 1947, Warren

McCulloch & Walter Pitts apresentaram, em seu artigo *How we know universals: The perception of auditory and visual forms*, os primeiros modelos de redes neurais e estruturas de raciocínio artificiais, baseados em um modelo matemático que imitava o funcionamento do sistema nervoso humano (Pitts & McCulloch, 1947).

Em 1950, Claude Shannon desenvolveu uma máquina capaz de jogar xadrez com base em cálculos simples de posição, conforme descrito em seu artigo *Programming a computer for playing Chess* (Shannon, 1950). No mesmo ano, Alan Turing propôs o experimento que ficou conhecido como Teste de *Turing*, que buscava definir critérios para considerar uma máquina como inteligente. O teste consistia na formulação de perguntas por um humano, com o intuito de identificar se as respostas vinham de uma máquina ou de outro ser humano (Turing, 1950).

O termo IA foi utilizado pela primeira vez em 1956, durante um *workshop* no *Dartmouth College*, nos Estados Unidos, para descrever a ciência e a engenharia de construir máquinas inteligentes, especialmente programas de computador (McCarthy et al., 1955). Nas décadas seguintes, o desenvolvimento da IA foi marcado por avanços significativos, intercalados por períodos de estagnação (Russell & Norvig, 2016).

Os primeiros programas de IA voltados à educação surgiram no final da década de 1960, com destaque para o *ELIZA*, desenvolvido por Joseph Weizenbaum em 1966 (Weizenbaum, 1966). Esse sistema inspirou experiências educacionais posteriores, como o *SCHOLAR*, primeiro programa a incluir modelagem de conteúdo e a fornecer *feedbacks* imediatos sobre as respostas dos alunos a questões de geografia da América do Sul (Carbonell, 1970).

Em 1970, o cientista da computação Jaime Carbonell aprimorou o *SCHOLAR*, utilizando linguagem natural para interagir com os estudantes. Embora o termo Sistema de Tutoria Inteligente (*ITS*) ainda não fosse empregado à época, Corbett, Koedinger & Anderson (1997) reconhecem o *SCHOLAR* como o primeiro *ITS* da história.

Para Bates (2014), a aplicação da IA na educação se intensificou a partir dos anos 1980, especialmente no ensino de aritmética, apesar das iniciativas anteriores de Weizenbaum (1966) e Carbonell (1970).

Desde seus primórdios, a IA aplicada ao ensino-aprendizagem evoluiu em múltiplas direções: com foco no estudante, ao desenvolver ferramentas de apoio à aprendizagem e à avaliação; com foco no professor, ao auxiliar nas práticas de ensino; e com foco no sistema, ao apoiar a gestão educacional (Seo, K. K., & Gurung, B., 2021; Yamtinah, 2025).

Nos últimos anos, empresas líderes em tecnologia, como Google, Microsoft, IBM e *OpenAI*, têm disponibilizado plataformas e blocos de construção de IA, frequentemente baseados em abordagens *low-code*¹ ou *no-code*², que permitem o desenvolvimento de soluções sofisticadas sem a necessidade de escrever algoritmos do zero (*Google Cloud, 2024; Microsoft, 2025; IBM, 2025; OpenAI, 2025*).

Gu (2023) explica que, antes restrita a ambientes experimentais, a IA passou a ter aplicações práticas em diversas áreas, incluindo a educação. Entre as implementações mais relevantes, destacam-se a explicabilidade dos sistemas, a abordagem centrada na pessoa, os sistemas *fuzzy* e a aprendizagem autônoma. A explicabilidade, nesse contexto, refere-se à transparência nos processos decisórios e nos critérios utilizados pelos sistemas de IA.

Nesse mesmo sentido, Alfredo et al. (2024) ressaltam a importância de uma abordagem centrada na pessoa, que considere a diversidade dos estudantes e promova a integração responsável entre IA e aprendizagem analítica. Já Gu et al., (2023) destaca que a utilização de sistemas *fuzzy*, aliados à aprendizagem autônoma, permite que a IA se adapte a contextos educacionais dinâmicos e complexos. Maity & Deroy (2024) complementam essa perspectiva ao defenderem abordagens explicáveis centradas no ser humano (*HCXAI*),

¹ *Low-code*: plataformas que permitem criar aplicações com pouca programação, usando interfaces visuais.

² *No-code*: ferramentas para desenvolver soluções sem programação, apenas com recursos gráficos.

especialmente em ambientes com IA generativa³, nas quais transparência e compreensão são elementos-chave para a confiança do usuário.

Assim, a IA, outrora confinada ao imaginário da ficção científica, consolidou-se como uma tecnologia real, versátil e amplamente aplicável, inclusive no campo da educação. A seguir, será apresentada sua trajetória de desenvolvimento a partir da década de 1960.

Por sim, nota-se que a integração da IA à educação não se limita ao uso de tecnologias avançadas, mas exige a construção de sistemas transparentes, éticos e centrados no ser humano (Gu et al., 2023). A explicabilidade, a adaptabilidade a diferentes contextos e o respeito à individualidade dos estudantes são elementos essenciais para que a IA contribua efetivamente para o processo de ensino-aprendizagem. Ao unir inovação tecnológica a princípios pedagógicos sólidos, a IA ultrapassa o campo das promessas e se afirma como aliada estratégica na construção de uma aprendizagem personalizada, inclusiva e mais eficaz (Yamtinah, 2025).

2.3 Educação *on-line*: transformações no processo de ensino-aprendizagem

A educação *on-line* emergiu em meados dos anos 1980 com a introdução das redes de computadores no contexto educacional. O primeiro curso *on-line* foi concebido e transmitido na OISE, Universidade de Toronto, em 1986. Ministrado inteiramente à distância, adotou uma metodologia colaborativa de aprendizagem por meio de *softwares* e fóruns de discussão organizados por grupos e tópicos Harasim, (2000).

Em 1989, a criação da Internet representou um marco significativo para a educação *on-line*, possibilitando uma comunicação mais rápida e acessível com os alunos. Educadores passaram a interagir mais intensamente com os estudantes e a incorporar fóruns *on-line* como ferramentas de apoio (Anderson &

³ IA generativa: sistemas de IA capazes de criar conteúdos novos, como textos, imagens, músicas ou códigos, a partir de exemplos ou instruções

Dron, 2011). Quase quatro décadas depois, a oferta de cursos *on-line* continua em expansão, consolidando-se como uma alternativa cada vez mais popular.

Radianti et al. (2020) realizaram uma revisão sistemática demonstrando que, desde o início dos anos 2000, o uso de realidade virtual tem crescido como estratégia para promover experiências imersivas no ensino superior e outras etapas da educação, acompanhando o avanço da educação *on-line*. Entre 2010 e 2019, com o avanço do *Big Data*, a análise de aprendizagem e os modelos de perfis de estudantes tornaram-se foco central (Tavares, Meira & Amaral, 2020).

Para Harasim (2000), a educação *on-line*, à semelhança da presencial, compreende diversas implicações pedagógicas e modelos educacionais distintos. Segundo a autora, o objetivo fundamental da educação deve ser o aprimoramento da inteligência humana e das habilidades cognitivas.

Luckin (2018) propõe um modelo de inteligência humana sustentado por sete pilares interconectados. São eles: inteligência acadêmica interdisciplinar; metainteligência (capacidade de compreender a própria inteligência); inteligência social (essencial para interações humanas); inteligência metacognitiva (compreensão dos próprios processos de pensamento); inteligência metassubjetiva (relacionada ao desenvolvimento emocional); inteligência metacontextual (habilidade de adaptação a diferentes contextos); e autoeficácia percebida (capacidade de estabelecer metas, avaliar sua viabilidade e buscar apoio para sua realização) (Luckin, 2018).

Embora a IA ofereça importantes contribuições à educação, é imprescindível reconhecer que a inteligência humana é substancialmente mais complexa, abrangendo dimensões cognitivas, emocionais, sociais e contextuais que a IA ainda não reproduz integralmente (Luckin, 2018). Nessa linha, Essel et al. (2024) demonstraram, em estudo empírico, que ferramentas como o *ChatGPT* podem atuar como recursos pedagógicos eficazes, ao fornecerem respostas personalizadas conforme o nível de conhecimento e as necessidades dos estudantes. Os autores destacam que esse tipo de interação favorece o desenvolvimento de habilidades como raciocínio lógico, pensamento crítico e

resolução de problemas, tornando o processo de aprendizagem mais dinâmico e centrado no aluno (Mhlanga, 2023; Neves, 2023).

O acompanhamento do estudante é um fator crítico de sucesso para cursos *on-line*. Contudo, a própria natureza da modalidade e o número elevado de alunos em uma disciplina/turma dificultam esse processo (Martin & Bolliger, 2018). Idealmente, o docente deveria intervir ao longo do curso, e não apenas ao constatar, ao seu término, que os objetivos não foram alcançados. Mazza & Dimitrova (2004) já apontavam que uma das maiores dificuldades da educação *on-line* era justamente identificar as atividades que os alunos realizam durante o curso. Atualmente, essa limitação permanece, agravada pelo aumento da complexidade dos registros dos AVAs, o que dificulta ainda mais sua compreensão por professores sem formação tecnológica ou literacia de dados (Kaliisa et al., 2023).

A aplicação da IA nos AVAs representa um avanço significativo em aspectos essenciais da educação *on-line*, como usabilidade, personalização, análise preditiva e *feedback* automatizado (Alfredo et al., 2024; Nguyen, Gardner & Sheridan, 2020; Sidiropoulos & Anagnostopoulos, 2024). As soluções contemporâneas vão além da adaptação ao perfil do estudante, permitindo a recomendação de trilhas de aprendizagem, identificação de riscos de evasão e intervenção pedagógica baseada em dados (Adomavicius, & Tuzhilin, 2015).

Historicamente, o uso da IA em AVAs começou a transformar conteúdos e estruturas desde a década de 2010, com destaque para o surgimento dos Sistemas Tutores Inteligentes (*ITS*), que já proporcionavam interatividade e atualização em tempo real da base de conhecimento (Santos Magalhães & D'Emery, 2010). No entanto, os avanços recentes elevam o patamar dos AVAs, com recursos de personalização avançada, uso de modelos explicáveis de *machine learning*, aplicações de linguagem natural para aumentar retenção, e análise automatizada da presença cognitiva para avaliar o engajamento (Ghimire et al., 2024; Essel et al., 2024; Hu et al., 2021).

Hu et al. (2021) apontam que a IA pode contribuir significativamente para o ensino *on-line*, especialmente ao identificar automaticamente o nível de

participação dos alunos em discussões virtuais. Já Alfredo et al. (2024) destacam que as plataformas educacionais baseadas em IA favorecem a construção de redes de conhecimento dinâmicas e a personalização dos percursos de aprendizagem, utilizando análise de dados dos perfis individuais e promovendo trajetórias formativas adaptativas a partir do cruzamento de informações fornecidas pelos alunos com bases interativas de dados. Além disso, Ashwin et al. (2023) explicam que, integrados a técnicas de visão computacional, ITS são capazes de monitorar movimentos corporais e ajustar, em tempo real, as estratégias instrucionais com base no engajamento do aluno, reduzindo significativamente a necessidade de intervenções humanas (Sposato, 2025).

Assim, a adoção de tecnologias baseadas em IA na educação *on-line* impulsiona uma aprendizagem cada vez mais personalizada, interativa e centrada no aluno. Ao analisar dados e adaptar conteúdos em tempo real, essas plataformas ampliam o acesso ao conhecimento e promovem um ensino mais eficaz e alinhado aos desafios da educação digital contemporânea.

2.4 Sistema de Tutoria Inteligente (ITS)

Embora os Sistemas de Tutoria Inteligente (*ITS*) já tenham sido abordados em seções anteriores como uma das primeiras aplicações bem-sucedidas da IA na educação, sua complexidade, abrangência e impacto justificam uma seção específica. Isso se deve ao fato de que os *ITS* não apenas exemplificam a convergência entre tecnologia, pedagogia e cognição, mas também ilustram a maturidade das soluções de IA aplicadas ao ensino personalizado. Nesta seção, adota-se uma abordagem ampliada, explorando os *ITS* não como ferramentas isoladas, mas como ecossistemas interativos capazes de se adaptar a dimensões cognitivas, afetivas e sociais da aprendizagem Bryson (2022).

Nesta linha, Villegas Ch, (2025) define o *ITS* como um sistema computacional que fornece *feedback* ou instruções personalizadas aos estudantes, com mínima intervenção de professores humanos. As pesquisas sobre o uso da IA na educação tiveram início com os *ITS* e, desde então, expandiram-se para um campo mais amplo, com diferentes temáticas e paradigmas. Esses sistemas oferecem uma estrutura diferenciada para a

apresentação de conteúdos educacionais, integrando IA e neurociência para potencializar o processo de ensino-aprendizagem na educação *on-line*.

Bryson (2022) afirma que os sistemas tradicionais de aprendizagem por computador demandam melhorias, sobretudo diante da crescente exposição à internet e da ampliação da educação virtual. A escala e o escopo das pesquisas sobre inovação baseada em IA aumentaram de maneira significativa com os avanços tecnológicos aplicados à educação. O principal objetivo de um *ITS* é, além de apresentar determinado conteúdo, desenvolver metodologias que se adaptem ao perfil do estudante e interajam dinamicamente com ele (Wang, 2024).

ITS determinam caminhos ideais de aprendizagem a partir de materiais e atividades construídos com base em conhecimentos conceituais e processos cognitivos, considerando os erros e acertos do estudante. Essa abordagem tem sido aplicada em sistemas de gerenciamento de aprendizagem, como o *Moodle*, o *Open edX* e plataformas como a *Khan Academy*.

À medida que o estudante progride, o sistema utiliza *machine learning* para ajustar automaticamente o nível de dificuldade e oferecer dicas ou orientações com base em suas dificuldades e potencialidades. Uma arquitetura típica de *ITS* é composta por três modelos centrais: o modelo de domínio, que representa o conteúdo; o modelo pedagógico, que determina a estratégia de ensino; e o modelo do aluno, que reúne os dados individuais de desempenho, incluindo o histórico de interações de outros usuários (Holmes, 2022).

Groothuijsen et al. (2024) destacam o impacto positivo da aplicação de *chatbots* na orientação de estudantes em cursos de programação, aproximando-se do conceito de tutoria automatizada. Estudos recentes também apontam o uso da IA em contextos colaborativos, como na resolução de problemas (Aslan et al., 2025) e na promoção do engajamento estudantil (Heung & Chiu, 2025), inseridos em contextos de *ITS*.

Durante a interação com o *ITS*, o sistema monitora continuamente o progresso do estudante, seus acertos e equívocos, atualizando em tempo real o modelo do aluno. Esse modelo orienta a seleção da próxima informação de maneira personalizada, configurando um ciclo contínuo de adaptação. Cada

indivíduo percorre, assim, uma trajetória única, ajustada a suas necessidades específicas (Aslan et al., 2025). Embora essa personalização resulte em percursos diferenciados, os resultados de aprendizagem podem ser equivalentes entre os estudantes. Alguns *ITS* mais avançados incorporam análises do estado afetivo, como o monitoramento de expressões faciais, para inferir níveis de atenção e engajamento (Bell, 2004).

Conforme apontado por Liu, et. al. (2025), embora os *Tutoring Systems* (como os *ITSs*) tenham avançado significativamente, ainda há lacunas — incluindo limitações pedagógicas e falta de integração com métodos de aprendizagem mais dinâmicos. Isso reforça o alerta de Dean Jr. & Kuhn (2007) sobre a prevalência de abordagens tradicionais e a urgência de incorporar estratégias como a aprendizagem colaborativa, a descoberta guiada e a falha produtiva para enriquecer as experiências educacionais. Segundo a UNESCO (2021), mais de 60 *ITS* estão em operação globalmente, sendo os mais difundidos *Alef, Aleks, Byjus, Mathia, Qubena, Riid e Squirrel AI*.

Em síntese, os *ITS* representam um avanço notável na personalização do processo de ensino-aprendizagem, ao viabilizar trajetórias adaptativas. Para que seu potencial pedagógico seja plenamente realizado, é necessário que tais sistemas incorporem abordagens integradoras, contemplando dimensões cognitivas, sociais, afetivas e exploratórias do aprendizado (Banihashem, 2025).

2.5 Aplicação da IA

Segundo Seo & Gurung (2021), as aplicações de IA na educação podem ser categorizadas em três frentes: (a) IA orientada ao aluno, (b) IA orientada ao professor e (c) IA orientada à gestão institucional. A IA orientada ao aluno visa oferecer sistemas de aprendizagem personalizados ou adaptativos para o estudo de um determinado conteúdo. A IA orientada ao professor busca automatizar tarefas administrativas, avaliações, detecção de plágio e fornecimento de *feedback*. Além disso, esses sistemas auxiliam no monitoramento do progresso dos estudantes, permitindo intervenções pedagógicas proativas (Seo & Gurung, 2021).

Big Data refere-se a grandes volumes, velocidade e variedade de informações que exigem métodos inovadores de processamento para aprimorar a tomada de decisão. A Mineração de Dados (*Data Mining*), nesse contexto, consiste na exploração de grandes bases de dados para revelar padrões de conhecimento relevantes (Gartner, sd).

Ashwin et al. (2023) exploram um *ITS* baseado na análise dos movimentos corporais dos estudantes, utilizando visão computacional para adaptar, em tempo real, estratégias instrucionais e reduzir a necessidade de intervenção humana. Córdova-Esparza et al. (2025) argumentam que a IA, ao ser integrada a outras abordagens educacionais, possibilita diagnósticos precisos e contínuos, como o *feedback* estratégico para a prevenção da evasão escolar, conforme demonstrado por Bulut et al. (2025) também destacam a melhoria na precisão das avaliações a partir do uso da IA, desde que adequadamente parametrizada.

Com o avanço de recursos como *ITS* individualizados, plataformas de suporte e *bots* tutoriais, a IA tem se mostrado eficaz no auxílio à identificação de lacunas de aprendizagem e na oferta de suporte pedagógico especializado. Isso libera o docente de tarefas administrativas rotineiras e amplia sua disponibilidade para atuar diretamente com os estudantes. Em nível institucional, a IA fornece informações estratégicas para gestores educacionais, como padrões de matrícula e índices de evasão em disciplinas ou instituições (Bonner et al., 2021, Seo & Gurung, 2021, Guan, Mou & Jiang, 2020).

Outro conceito emergente nesse cenário é o aprendizado profundo (*deep learning*), que ganhou relevância à medida que os sistemas computacionais passaram a estruturar dados de maneira hierárquica, possibilitando representações abstratas em múltiplos níveis. Entre os exemplos mais populares de sua aplicação, estão o *Google Tradutor*, os sistemas de recomendação da *Amazon* e a negociação algorítmica nos mercados financeiros (Tavares, Meira & Amaral, 2020).

Conforme Wang et al., 2024 destacam-se três áreas na educação nas quais a IA, especialmente com aprendizado profundo, tem maior aplicabilidade:

(1) avaliação e classificação adaptativa; (2) predição de desempenho; e (3) retenção de alunos.

O reconhecimento de padrões permite que AVAs atribuam notas a produções textuais e identifiquem estudantes com risco de reprovação. Tais avaliações proporcionam *feedback* contínuo a alunos e professores, além de sugerirem caminhos adaptativos para o alcance dos objetivos de aprendizagem (Córdova-Esparza et al., 2025). Com técnicas de *deep learning*, as aplicações tornam-se capazes de prever o desempenho dos estudantes, identificar seus pontos fortes e fracos e propor atividades, testes ou práticas de recuperação personalizadas. A retenção estudantil, por sua vez, é essencial para a gestão de matrículas, impactando indicadores institucionais como reputação, classificação e sustentabilidade financeira (Guan, Mou & Jiang, 2020).

Segundo Tavares, Meira e Amaral (2020), embora os *ITS* representem uma das principais vertentes da aplicação da IA na educação, outras linhas de desenvolvimento seguem em expansão.

As ferramentas inteligentes, portanto, têm se consolidado como aliadas na coleta e análise de dados nos processos de ensino-aprendizagem. Elas contribuem para o ensino adaptativo ao selecionar conteúdos de forma personalizada, apoiar avaliações e orientar intervenções pedagógicas mais eficazes. Tais ferramentas também identificam padrões de comportamento, realizam diagnósticos e apoiam a comunicação entre professores e estudantes, aprimorando a tomada de decisão no processo educacional (Akkoyunlu, & Soylyu, 2008; Tavares, Meira & Amaral, 2020).

2.6 Ensino adaptativo ou aprendizagem personalizada

Embora o Aprendizado de Máquina (*ML*) já tenha sido brevemente mencionado em seções anteriores, sua relevância crescente no campo da inteligência artificial aplicada à educação justifica uma análise mais aprofundada. Considerando que *ML* constitui um dos principais mecanismos de funcionamento dos sistemas inteligentes contemporâneos, inclusive nos modelos adaptativos, tutoriais e preditivos discutidos neste trabalho, esta seção dedica-se a explorar suas bases conceituais, classificações, aplicações e implicações pedagógicas. A

ênfase recai, especialmente, sobre as contribuições do *ML* para a personalização da aprendizagem e para a construção de ambientes educacionais mais responsivos e sensíveis às necessidades dos estudantes.

O *ML* parte do pressuposto de que sistemas computacionais podem aprender autonomamente com grandes volumes de dados, identificando padrões e estabelecendo relações entre eles. A partir de dados previamente conhecidos, esses sistemas são capazes de prever ou classificar novas situações de forma contextualizada.

O *ML* pode ser dividido em aprendizado supervisionado e não supervisionado. Segundo An, Q., et al. (2023), o aprendizado supervisionado utiliza situações previamente rotuladas para prever novos casos, enquanto o não supervisionado analisa os dados sem treinamento anterior, buscando agrupamentos com base em similaridades internas.

Tamanha é a presença do *ML* no cotidiano que, por vezes, ele é confundido com a própria IA. Na realidade, trata-se de um subconjunto da IA. Muitos aplicativos ainda operam com formas simbólicas de inteligência, conhecidas como *GOFAI* (*Good Old-Fashioned Artificial Intelligence*), baseadas em regras programadas por humanos. Por exemplo, diversos *chatbots* utilizam respostas pré-definidas, construídas manualmente, para situações previstas (Säuberlich & Nikolić, 2018; An, et al., 2023).

Säuberlich & Nikolić (2018) argumentam que a maior parte dos produtos de IA disponíveis atualmente depende de conteúdos inseridos por especialistas humanos, e que o *ML*, isoladamente, não seria suficiente para compor uma IA completa sem os componentes simbólicos da *GOFAI*.

A abordagem simbólica parte da suposição de que muitos aspectos da inteligência podem ser representados por manipulações de símbolos, a chamada hipótese dos sistemas de símbolos físicos, proposta por Newell e Simon na década de 1960. Sistemas especialistas, por exemplo, operam por meio de regras do tipo “se... então...”, possibilitando inferências lógicas baseadas em estruturas simbólicas legíveis por humanos (Rosenbloom (2023).

No campo educacional, o *ML* tem se destacado como ferramenta altamente eficaz. Jiao et al. (2022) demonstraram a efetividade de modelos preditivos baseados em *ML* para monitoramento do desempenho acadêmico. Chen (2024) apresentou modelos de aprendizado profundo capazes de prever eventos críticos no contexto educacional, enquanto Liang et al. (2022) utilizaram redes convolucionais integradas ao conhecimento afetivo para aprimorar a interpretação de dados educacionais.

Dessa forma, IA simbólica e *ML* contribuem de maneira complementar para a inovação educacional. Enquanto os sistemas especialistas oferecem lógica interpretável e transparência, os modelos baseados em *ML* ampliam a capacidade preditiva e adaptativa dos ambientes de aprendizagem, permitindo intervenções mais eficazes e personalizadas. A integração dessas abordagens representa um avanço significativo rumo à construção de sistemas educacionais mais inteligentes, sensíveis e responsivos às necessidades dos estudantes.

2.7 Aprendizado de máquina – *Machine Learning (ML)*

Diante da crescente relevância das abordagens automatizadas na educação, torna-se essencial compreender o papel *ML*, uma das técnicas mais significativas da IA contemporânea. Embora o tema já tenha sido mencionado anteriormente, esta seção aprofunda seus fundamentos e aplicações específicas no contexto educacional.

O *ML* refere-se à capacidade das máquinas de aprenderem de forma autônoma a partir de grandes volumes de dados, reconhecendo padrões e estabelecendo relações entre eles. Com base em situações previamente observadas, os sistemas podem prever ou classificar novas ocorrências dentro de contextos semelhantes.

O *ML* pode ser subdividido em duas categorias principais: aprendizado supervisionado e aprendizado não supervisionado. Segundo An et al. (2023), o primeiro utiliza dados rotulados para prever novos casos, enquanto o outro busca correlações em dados brutos, agrupando elementos com base em similaridades internas, sem treinamento prévio.

Embora seja frequentemente considerado sinônimo de IA, o I é, na verdade, um subconjunto dela. Ainda há diversos sistemas de IA que não se apoiam em *ML*, mas sim em abordagens simbólicas, conhecidas como *GOFAI*, que funcionam por meio de regras pré-programadas definidas por humanos. Por exemplo, muitos *chatbots* operam com regras explícitas sobre como responder a determinadas perguntas antecipadas.

De forma semelhante aos antigos sistemas especialistas, os autores Säuberlich e Nikolić (2018) destacam que a maioria dos produtos de IA atuais ainda depende da inserção de conhecimento por especialistas humanos. Assim, o *ML* não seria suficiente, isoladamente, para formar uma IA plenamente funcional, exigindo o suporte das estruturas simbólicas da *GOFAI*. Esse termo foi cunhado por John Haugeland em 1985, ao destacar que muitos aspectos da inteligência podem ser modelados por meio da manipulação de símbolos, hipótese proposta por Allen Newell e Herbert A. Simon nos anos 1960.

Uma forma bastante conhecida de IA simbólica são os sistemas especialistas, que operam com base em regras do tipo "se... então...", utilizando símbolos legíveis por humanos para realizar inferências e determinar ações, como a formulação de perguntas ou a sugestão de conteúdos (Rosenbloom (2023)). Essa transparência torna tais sistemas especialmente úteis em contextos educacionais que demandam explicabilidade.

Por outro lado, o *ML* tem se mostrado uma ferramenta altamente eficaz na educação. Jiao et al. (2022) demonstraram a eficácia de modelos preditivos para o monitoramento do desempenho acadêmico. Chen (2024) apresentou modelos de aprendizado profundo capazes de antecipar eventos críticos no ambiente educacional. Já Liang et al. (2022) exploraram redes convolucionais com integração de dados afetivos, ampliando a dimensão interpretativa dos dados educacionais.

Dessa forma, tanto a IA simbólica quanto o *ML* contribuem de maneira complementar para a inovação educacional. Enquanto os sistemas especialistas oferecem transparência e lógica interpretável, os modelos baseados em *ML* ampliam a capacidade preditiva e adaptativa dos ambientes de aprendizagem,

permitindo intervenções mais eficazes e personalizadas. A integração dessas abordagens representa um avanço significativo rumo a sistemas educacionais mais inteligentes, sensíveis e orientados às necessidades reais dos estudantes (An et al., 2023).

2.8 Sistemas de tutoria baseados em diálogo

Os sistemas de tutoria baseados em diálogo (*DBTS*) empregam técnicas de NLP e IA para simular interações educativas semelhantes às dos tutores humanos. Exemplos notáveis incluem o método multimodal do *SingaKids* (Arnau-González et al., 2023) e o *Socratic Playground*, baseado em *GPT-4*, que utiliza diálogos instigantes para aprimorar o pensamento crítico (Zhang et al., 2024; Graesser et. al., 2001).

Diferentemente dos sistemas que apenas fornecem instruções, os *DBTS* desenvolvem conversas baseadas em questões geradas pela IA, guiando os alunos a descobrirem, por conta própria, soluções adequadas para os problemas propostos. O objetivo central é estimular os estudantes a coconstruírem explicações, favorecendo uma compreensão mais profunda dos temas abordados, em contraste com abordagens instrucionais mais superficiais, como aquelas vistas em alguns *ITS* (Zhang et al., 2024).

Ao analisar estudos sobre *DBTS*, Zhai & Wibowo (2024) identificaram seis dimensões aplicadas conforme o propósito e a função desses sistemas: integração tecnológica, design de tarefas, engajamento do aluno, objetivos de aprendizagem, limitações tecnológicas e efeito de inovação. Apesar de ainda serem poucos os *DBTS* em uso prático, a maioria restrita a projetos de pesquisa, os modelos de programação encontram-se bem estruturados e claramente definidos.

Um exemplo representativo de *DBTS* é o *AutoTutor*, um dos mais utilizados desde sua concepção (Graesser et al., 2001). Mais recentemente, destaca-se o *MACHE-Bot*, um sistema baseado em IA que incorpora elementos culturais, humorísticos e empáticos em suas interações. Ao incluir essas nuances, o sistema busca simular interações humanas mais realistas e promover uma experiência mais eficaz no aprendizado da língua inglesa (Zhai et al., 2024).

Dessa forma, os *DBTS* representam uma evolução significativa nos sistemas de tutoria inteligente, conforme apresentado na comparação a seguir (quadro 2.1), ao incorporar elementos conversacionais que promovem uma aprendizagem ativa e personalizada.

Quadro 2.1 – Comparação DBTS vs. ITS

Aspecto	ITS tradicional	DBTS
Interação	Unidirecional ou limitada (<i>feedback</i> pontual)	Bidirecional e conversacional
Engajamento	Instrucional, com foco em entrega de conteúdo	Estímulo à descoberta e à coconstrução de conhecimento
Adaptatividade	Baseada em regras ou desempenho	Dinâmica e responsiva, com base em linguagem natural e inferência
Papel do estudante	Receptor de instruções	Protagonista no processo de aprendizagem

Fonte: Elaborada pelo autor.

Ainda que a aplicação de *DBTS* esteja, em grande parte, restrita a contextos experimentais, os resultados obtidos em estudos recentes demonstram seu potencial para transformar a relação entre aluno e conteúdo, criando experiências mais engajadoras, responsivas e humanizadas. Sistemas como o *Ruffle & Riley*, que utilizam modelos de linguagem avançados para simular interações tutor-aluno, mostram-se promissores ao integrar tutoria inteligente com linguagem natural, empatia e adaptação em tempo real (Schmucker et al., 2024).

Nos últimos anos, os *LLMs* evoluíram de meras tecnologias experimentais a componentes centrais de sistemas de tutoria inteligentes, exatamente no formato que se descrevem, com personalização escalável e alinhamento ao perfil de cada estudante. Exemplos práticos incluem sistemas que utilizam *retrieval-augmented generation* e *prompt engineering* para gerar conteúdos educativos adaptados automaticamente (Liu et al., 2025)

2.9 Ambientes de aprendizagem exploratória

Os ambientes de aprendizagem exploratórios (*Exploratory Learning Environments - ELEs*) adotam uma abordagem construtivista: em vez de seguir uma sequência instrucional linear, como no modelo de transmissão de conhecimento típico dos *ITS*, os alunos são estimulados a construir seu próprio

saber por meio da exploração ativa e da conexão com esquemas prévios (Gkogkidis & Dacre, 2021).

Segundo Alfredo et al. (2024), a análise de dados educacionais é fundamental para a criação de ambientes dinâmicos centrados no estudante, potencializando a aprendizagem exploratória. Nesse contexto, o uso da IA torna-se um recurso relevante ao mitigar a sobrecarga cognitiva comumente associada a esse tipo de aprendizagem, fornecendo orientação personalizada e *feedback* automatizado com base no rastreamento de conhecimento e em técnicas de aprendizado de máquina. A partir dos próprios equívocos dos alunos, a IA é capaz de sugerir caminhos alternativos que promovem o avanço na aprendizagem (Costa et al., 2025).

Aslan et al. (2025) associam a mediação da IA em ambientes virtuais ao aumento da curiosidade e da capacidade de resolução de problemas por parte dos estudantes, reforçando seu papel como facilitadora da autonomia cognitiva.

Entre os exemplos consolidados de *ELEs* destacam-se o *ECHOES* (Bernardini et al., 2014), o *Fractions Lab* (Rummel et al., 2016) e o *Betty's Brain* (Leelawong & Biswas, 2008), que ilustram diferentes estratégias de mediação tecnológica para a aprendizagem autorregulada.

Dessa forma, os *ELEs* representam um avanço significativo na personalização da aprendizagem mediada por IA, ao favorecerem o protagonismo do estudante e a construção significativa do conhecimento. O Quadro 2.2 amplia a análise comparativa iniciada no Quadro 2.1, incorporando os *ELEs* às abordagens anteriormente apresentadas, e evidenciando como os ambientes digitais vêm se tornando cada vez mais responsivos, adaptativos e centrados no aluno.

Quadro 2.2 - Comparação DBTS vs. ITS vs. ELEs

Aspecto	ITS tradicional	DBTS	ELEs
Interação	Unidirecional ou limitada (<i>feedback</i> pontual)	Bidirecional e conversacional	Interação aberta com ambiente e recursos
Engajamento	Instrucional, com foco em entrega de conteúdo	Estímulo à descoberta e à coconstrução de conhecimento	Exploração ativa e construção autônoma do conhecimento
Adaptatividade	Baseada em regras ou desempenho	Dinâmica e responsiva, com base em linguagem natural e inferência	Baseada no comportamento do estudante e intervenções orientadas por IA
Papel do estudante	Receptor de instruções	Protagonista no processo de aprendizagem	Explorador ativo, construtor do próprio conhecimento
Suporte de IA	<i>Feedback</i> programado e personalizado por desempenho	Processamento de linguagem natural e diálogo personalizado	<i>Feedback</i> automatizado, rastreamento de conhecimento e apoio adaptativo por IA

Fonte: Elaborada pelo autor.

A evolução dos ambientes educacionais mediados por IA revela uma transição significativa: de modelos instrucionais centrados na transmissão do conteúdo para experiências de aprendizagem mais dinâmicas, personalizadas e centradas no estudante (Holmes, Bialik & Fadel, 2019).

2.10 Avaliação de redação automatizada

De acordo com Wilson e Czik (2016) a avaliação automatizada da escrita (*Automated Writing Evaluation - AWE*) utiliza processamento de linguagem natural e outras técnicas de IA para fornecer *feedback* automático sobre a escrita. Geralmente, há duas abordagens sobrepostas: *AWE* formativa, que permite ao aluno melhorar sua escrita antes da avaliação, e *AWE* somativa, que facilita a pontuação automática dos textos produzidos pelos alunos (Wilson & Czik, 2016).

Nas últimas décadas, a aplicação da IA na avaliação da escrita enfrentou dificuldades, como a conversão de sentenças em vetores e a incapacidade de avaliar o texto integralmente, o que impedia a geração de um *feedback* personalizado para cada estudante (Awidi, 2024). Assim, os *AWE* têm sido controversos (Smith, 2018), pois costumam valorizar características superficiais, como o comprimento da frase, mesmo quando o texto carece de sentido. Vale ressaltar que esses sistemas também são incapazes de avaliar a criatividade. Os *AWE* têm sido utilizados em contextos educacionais por meio de programas como *WriteToLearn*, *e-Rater* e *Turnitin*.

Com o avanço tecnológico acelerado, a IA passou a reconhecer com maior precisão a língua e os textos, e diversos estudos apontam aumento da confiabilidade e consistência na avaliação de redações, aproximando-se dos resultados da avaliação humana (Barrot, 2023; Awidi, 2024; Palermo & Wilson (2020).

Assim, a *AWE* segue evoluindo e se consolidando como ferramenta fundamental para potencializar a aprendizagem em larga escala, devendo ser continuamente aprimorada para garantir avaliações mais justas, inclusivas e alinhadas às necessidades reais dos estudantes.

2.11 Leitura com suporte de IA e aprendizagem de línguas

O uso da inteligência artificial (IA) em ambientes de aprendizagem de línguas representa um dos avanços mais relevantes e disruptivos da educação digital contemporânea. Ao combinar reconhecimento de voz, algoritmos de tradução automática e ferramentas de leitura assistida, a IA tem potencializado o ensino de idiomas com soluções cada vez mais precisas, acessíveis e personalizadas (Zhu & Wang, 2024).

Recentemente, o reconhecimento automático de fala (*Automatic Speech Recognition - SR*) passou a ser amplamente empregado em plataformas de ensino, permitindo comparar a pronúncia dos estudantes com a de falantes nativos, oferecendo *feedback* imediato e adaptativo, além de promover a fluência oral (Sun, 2023; Wills et al., 2023). Do mesmo modo, tecnologias de tradução automatizada e análise de leitura têm sido aplicadas para personalizar trajetórias de aprendizagem e fornecer retornos individualizados sobre desempenho e progresso, tornando o processo de aquisição de línguas mais eficiente e centrado no estudante (Zhu & Wang, 2024).

Entre os aplicativos de IA voltados à leitura e ao aprendizado de línguas, destacam-se plataformas como *AI Teacher*, *Amazing English*, *Babbel* e *Duolingo*, que incorporam recursos interativos e personalizados. Segundo Zhai et al. (2024), sistemas de diálogo com IA são capazes de simular conversas humanas de modo natural, promovendo um ambiente de aprendizagem de línguas caracterizado por eficiência, adaptabilidade e interação em tempo real (Zhai et al., 2024). Dessa

forma, a disseminação dessas ferramentas representa um avanço significativo na personalização e no engajamento do estudante, consolidando a IA como uma aliada essencial no desenvolvimento das competências linguísticas na era digital (Elliott & Anderson, 2023).

2.12 Orquestradores de redes de aprendizagem

Orquestradores de Redes de Aprendizagem (*LNOs*) são ferramentas que permitem a interação entre redes de alunos e professores, facilitando a organização de atividades de aprendizagem. Os *LNOs* geralmente combinam participantes com base em disponibilidade, domínio do assunto e experiência, promovendo a coordenação e a cooperação.

O *Third Space Learning*, por exemplo, conecta alunos no Reino Unido que correm risco de reprovação em matemática a professores especializados em outros países. Outro exemplo é o *Smart Learning Partner*, plataforma movida por IA que possibilita aos alunos escolherem e conectarem-se a tutores humanos via dispositivos móveis, assemelhando-se a um aplicativo de relacionamento para suporte individualizado. Segundo Alfredo et al. (2024), o uso de dados educacionais pela IA viabiliza o desenvolvimento de ecossistemas interconectados de aprendizagem.

2.13 Aprendizagem colaborativa habilitada para IA

A aprendizagem colaborativa consolidou-se, nas últimas décadas, como uma das abordagens pedagógicas mais eficazes para promover o desenvolvimento de competências cognitivas, sociais e emocionais. Em ambientes educacionais digitais, entretanto, implementar a colaboração efetiva representa um desafio permanente, em função da heterogeneidade dos perfis dos estudantes, das barreiras de comunicação e do próprio desenho dos cursos *on-line*, que tendem a ser mais individualizados (Luckin et al., 2020; Heung & Chiu, 2025). A chegada de sistemas de inteligência artificial (IA) trouxe novas possibilidades para superar esses obstáculos e potencializar a aprendizagem em rede, ao viabilizar processos de personalização, mediação e monitoramento em tempo real (Essel et al., 2024).

No contexto digital contemporâneo, a IA atua de diferentes maneiras para aprimorar a aprendizagem colaborativa. Ferramentas baseadas em IA podem conectar alunos remotamente, identificar os estudantes mais adequados para tarefas em grupo com base em suas habilidades, histórico de participação e preferências, além de agrupar esses estudantes de modo estratégico, considerando dinâmicas de complementaridade. Recentemente, agentes virtuais impulsionados por IA passaram a participar ativamente das discussões em grupo, promovendo intervenções personalizadas, esclarecendo dúvidas, sugerindo fontes e orientando os alunos na resolução de problemas complexos (Heung & Chiu, 2025).

O impacto dessas soluções já foi documentado por estudos empíricos recentes. Essel et al. (2024) demonstraram que o uso de IA em ambientes colaborativos amplia a troca de conhecimentos entre os estudantes, facilita o engajamento coletivo e proporciona experiências de aprendizagem mais equitativas e participativas. Heung & Chiu (2025), em uma revisão sistemática e meta-análise, revelaram que, além de estimular o engajamento comportamental, cognitivo e emocional, a IA contribui para o desenvolvimento de competências socioemocionais e para a resolução colaborativa de problemas. Luckin et al. (2020) reforçam que, para que essas tecnologias alcancem todo seu potencial, é necessário investir em infraestrutura digital, formação docente continuada e políticas educacionais que promovam o uso ético e responsável da IA em contextos colaborativos (Agnihotri, 2024; Anand *et. al.*, 2018).

Apesar dos avanços, a integração plena da IA à aprendizagem colaborativa ainda enfrenta desafios técnicos, éticos e pedagógicos. A construção de agentes verdadeiramente sensíveis ao contexto, capazes de interpretar nuances emocionais e adaptar intervenções de forma ética e transparente, permanece como fronteira de pesquisa. No entanto, o campo é promissor: a incorporação de IA pode redefinir as práticas de aprendizagem coletiva, tornando-as mais inclusivas, eficazes e alinhadas às demandas da sociedade digital (Heung & Chiu, 2025; Merino, 2025).

Em síntese, a aprendizagem colaborativa habilitada para IA representa um caminho estratégico para potencializar o engajamento, personalizar experiências

de grupo e promover resultados educacionais sólidos. Ao unir inteligência humana e artificial, desenham-se novos horizontes para a construção de conhecimento compartilhado e para a formação de sujeitos críticos, criativos e socialmente conectados, como exige a educação do século XXI.

2.14 Desafios da Inteligência Artificial na educação

O avanço exponencial da IA trouxe promessas de transformação para a educação, mas esse movimento revelou também barreiras multifacetadas que desafiam a integração plena dessas tecnologias em contextos educacionais. Muito além das conquistas técnicas, as discussões atuais concentram-se em dilemas éticos, limitações pedagógicas, questões de equidade e a necessidade de reconfigurar práticas tradicionais para um novo paradigma digital (Tavares, Meira & Amaral, 2020; Almusaed & Albaaj, 2025).

O engajamento e a motivação dos estudantes continuam sendo desafios críticos. Mesmo em ambientes adaptativos, o design instrucional e a presença do professor são indispensáveis para manter o interesse e o envolvimento dos alunos (Kiryakova et al., 2014; Kay, 2012). A tecnologia, assim, não substitui, mas potencializa a mediação humana.

A desigualdade no acesso a tecnologias avançadas é outro entrave, especialmente em contextos socioeconômicos vulneráveis. O custo e a complexidade de implementação ainda restringem a adoção ampla da IA, reforçando a necessidade de políticas públicas para democratizar o acesso (Boateng & Boateng (2025).

Do ponto de vista ético e legal, o manejo dos dados pessoais de estudantes é um tema sensível. A coleta massiva de dados suscita preocupações sobre privacidade, consentimento e segurança, especialmente diante de legislações ainda em consolidação ou insuficientes para o contexto digital contemporâneo (Lupton & Williamson, 2017; Alfredo et al., 2024). Garantir transparência e proteção rigorosa desses dados é fundamental.

O viés algorítmico pode reproduzir ou até amplificar preconceitos históricos, levando a decisões injustas e impactando negativamente determinados grupos

(Hume, 2017). Estudos mais recentes reforçam a gravidade dessa questão no contexto educacional. Por exemplo, Boateng & Boateng (2025) demonstram que algoritmos em sistemas educacionais operam em múltiplas frentes da seleção de dados à implementação institucional e podem consolidar desigualdades existentes, especialmente em processos de admissão ou análise de desempenho. Além disso, Chinta et al. (2024), no estudo *FairAIED*, oferecem um panorama sistemático sobre formas de viés nos contextos educacionais e destacam a necessidade urgente de práticas de justiça algorítmica, *frameworks* de auditoria e abordagens éticas integradas ao ciclo de desenvolvimento do sistema (Chinta et al., 2024).

Além dessas preocupações, persiste o risco de uma robotização da educação, com a consequente perda de funções humanas essenciais, como criatividade e pensamento crítico. O consenso atual é que a IA deve atuar como ferramenta complementar, fortalecendo o papel do professor e promovendo experiências educacionais mais ricas e humanizadas (Holmes, 2022). Por fim, a ausência de diretrizes internacionais claras para o uso ético da IA na educação, mesmo após documentos como o Consenso de Pequim (UNESCO, 2020), que reforça a urgência de uma cooperação global capaz de harmonizar políticas, garantir inclusão e mitigar riscos.

Os desafios contemporâneos refletem a complexidade do contexto educacional e tecnológico. Como destacam Holmes et al. (2021), superá-los depende de avanços técnicos e de um compromisso multidisciplinar, envolvendo ética, pedagogia, políticas públicas e participação ativa da comunidade escolar. Só assim a IA poderá cumprir seu potencial transformador, promovendo uma educação inclusiva, justa e centrada no ser humano.

2.15 Tendências

A aceleração da IA está transformando setores inteiros da economia, com impacto já mensurável em saúde, educação, indústria e serviços (Alfredo et al., 2024; UNESCO, 2024). Revisões sistemáticas recentes apontam que, no campo educacional, as tendências mais relevantes envolvem a integração de sistemas inteligentes para personalização da aprendizagem, recomendação de trilhas,

análise preditiva de desempenho, *feedback* automatizado e inclusão de estudantes com necessidades especiais (Alfredo et al., 2024; Ghimire et al., 2024). Essas revisões evidenciam que a IA tem facilitado a colaboração entre professores e alunos, potencializando o engajamento coletivo e a construção de comunidades de aprendizagem globalizadas (Essel et al., 2024; Gao, 2024).

É importante notar, contudo, que o avanço da IA não se limita ao ensino *on-line* e híbrido. Apesar de esses ambientes concentrarem a maior parte das inovações, a IA tem conquistado espaço, ainda que de forma mais restrita, no ensino presencial. Implementações em escolas tradicionais vão desde o uso de plataformas adaptativas, *dashboards* de aprendizagem em tempo real e assistentes virtuais para acompanhamento individualizado, até experiências com tutores inteligentes em sala de aula física (Sidiropoulos & Anagnostopoulos, 2024; Ke, 2023). Ainda assim, a adoção permanece desigual, concentrando-se em grandes redes, escolas experimentais ou iniciativas com financiamento específico, o que revela o desafio de escalabilidade e acesso em contextos presenciais mais amplos.

A individualização do ensino, proporcionada por algoritmos de aprendizado profundo e modelos explicáveis, permite adaptar conteúdos, metodologias e ritmos de estudo às necessidades específicas de cada estudante. Essa personalização se torna ainda mais sofisticada com a incorporação de *LLMs*, como *Gemini* (Google), *Llama 3* (Meta), *ERNIE* (Baidu), *Tongyi Qianwen* (Alibaba) e modelos *open source* como *Mistral*, que oferecem interfaces multimodais, suporte ao processamento de linguagem natural em múltiplos idiomas e integração nativa com AVAs (Ke, 2023; Sidiropoulos & Anagnostopoulos, 2024).

No entanto, a adoção da IA nas escolas esbarra em um desafio persistente: a insuficiência na formação e na atualização dos profissionais da educação, mesmo em pleno 2025. Conforme destacado por Srinivasan, Abd Rahman e Ravana (2025), ainda é evidente a necessidade de programas

sistemáticos de *upskilling*⁴ e *reskilling*⁵ para preparar educadores diante das novas demandas tecnológicas impostas pela IA, tanto no ensino presencial quanto no digital.

Outro avanço notório é a aplicação de IA generativa em avaliação automatizada, tutoria inteligente e apoio emocional ao estudante. Ferramentas de análise de aprendizagem, *dashboards* inteligentes e assistentes virtuais tornaram-se essenciais para monitorar progresso, identificar riscos de evasão e propor intervenções pedagógicas baseadas em evidências (Alfredo et al., 2024; Huang, 2023). Uma revisão sistemática de Sidiropoulos e Anagnostopoulos (2024) destaca ainda que a adoção de IA e *LLMs* nas escolas potencializa o *feedback* formativo, a automação de avaliações e a promoção da inclusão, mas ressalta desafios éticos, técnicos e sociais que acompanham essa expansão Baidoo-Anu, & Owusu, 2023).

O ensino híbrido também ganha novas possibilidades: a IA permite a curadoria de conteúdos personalizados, análise de interações em tempo real e recomendações contextuais que potencializam o protagonismo do estudante em ambientes flexíveis e multimodais (Huang 2021; Alfredo et al., 2024).

Assim, para a próxima década, espera-se a consolidação da integração entre IA, *LLMs* e estratégias pedagógicas inovadoras, priorizando personalização, inclusão, criatividade e pensamento crítico. Com base nas revisões sistemáticas mais atuais, a IA se firma como uma aliada estratégica para redefinir paradigmas educacionais, mas também como uma responsabilidade coletiva diante dos desafios sociais e éticos do futuro digital (Alfredo et al., 2024; Sidiropoulos & Anagnostopoulos, 2024).

⁴ *Upskilling*: Processo de aprimorar ou atualizar competências existentes para se adaptar a novas demandas dentro da mesma área de atuação.

⁵ *Reskilling*: Processo de adquirir novas competências para exercer funções diferentes das atuais.

Capítulo 3 – Investigação Prévia

"Não se pode melhorar o que não se conhece; investigar é o primeiro passo para transformar."

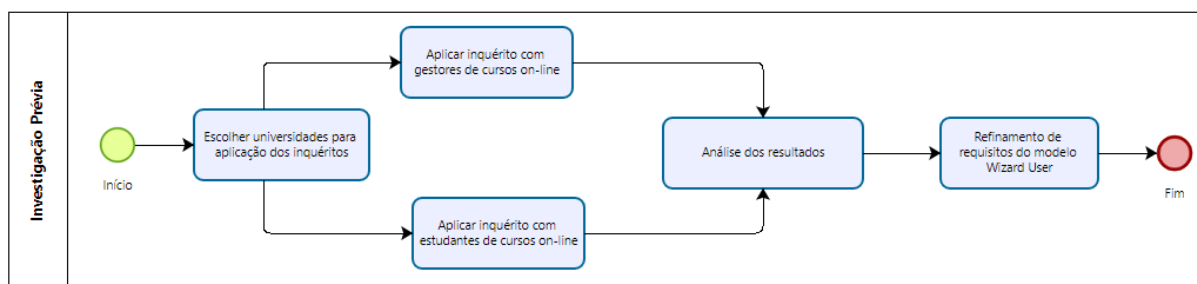
Inspirada no pensamento de Lord Kelvin

Este capítulo apresenta a investigação prévia que fundamenta o modelo *Wizard User*, conduzida em abordagem mista e *multistakeholder* para mapear eficiências tecnológicas e pedagógicas em cursos *on-line*. Por meio de inquéritos estruturados aplicados a gestores (análise qualitativa) e alunos (análise quantitativa), examinamos quatro eixos: qualidade do ensino, processo de interação, gestão da operação e melhorias gerais. Os resultados apontam lacunas recorrentes em comunicação, personalização, recursos adaptativos, *dashboards* estratégicos e uso ainda incipiente de IA nos AVAs, além de convergências e divergências entre as percepções dos públicos. A partir desses achados, o capítulo explicita requisitos para o modelo do *Wizard User*, incluindo comunicação automatizada, recomendação de conteúdo e analítica de aprendizagem e como tais ajustes orientam as etapas subsequentes de modelagem e avaliação do artefato.

3.1 Requisitos da Investigação Prévia

Com o objetivo de validar as principais deficiências tecnológicas dos cursos *on-line* identificadas pelo autor principal desta investigação, realizou-se um inquérito com gestores de instituições de ensino, buscando confirmar os principais desafios na condução da operação educacional e coletar sugestões de melhorias sistêmicas para apoiar o processo de ensino (Figura 3.1 – Investigação Prévia).

Figura 3.1 – Investigação Prévia



Fonte: Elaborada pelo autor.

Participaram profissionais de **cinco** instituições brasileiras: Universidade Veiga de Almeida (RJ), Centro Universitário Facens (SP), Fundação Dom Cabral (MG), Newton Paiva Centro Universitário e Universidade Candido Mendes (RJ), todas credenciadas pelo Ministério da Educação para a oferta de cursos na modalidade *on-line*. A seleção considerou a disponibilidade dos gestores em participar da investigação.

Os participantes ocupavam posições de liderança, com autonomia para tomada de decisões nas áreas educacional e estratégica, e possuíam ampla experiência na operação da educação superior, com mais de cinco anos de atuação na gestão de projetos de *e-learning*.

A proposta inicial era realizar um grupo focal; entretanto, devido às limitações logísticas e de agenda, optou-se pela aplicação de um inquérito estruturado com perguntas norteadoras, permitindo aos participantes exporem suas ideias sobre cada um dos quesitos avaliados. O instrumento foi elaborado no *Google Forms* e disponibilizado por meio do *link* <https://forms.gle/FEwX1FhGd5472y339>, contendo questões sobre problemas na qualidade do ensino, processos de interação, modelo de gestão da operação e

melhorias gerais. O Quadro 3.1 sintetiza os quesitos da investigação prévia, enquanto o formulário completo encontra-se no Apêndice B.

Quadro 3.1 – Quesitos da Investigação Prévia

Itens de investigação		Principais pontos abordados	
Quesitos	Definições dos quesitos	Gestor	Aluno
Problemas na qualidade do ensino	Identifica as principais dificuldades no processo de aprendizagem dos alunos, relacionando-as com a operação (gestão da universidade, atuação do professor-tutor, conteúdo didático e AVA).	Ausência de uma ferramenta interativa com indicadores; recursos de aprendizagem adaptativa; recomendação; controle de tempo e qualidade do <i>feedback</i> dado aos estudantes.	Alto tempo de resposta nas dúvidas levantadas sobre o conteúdo didático. Baixa troca de conhecimento entre os participantes da disciplina.
Processo de interação	Identifica o nível de interação entre os participantes, assim como as ferramentas possíveis de serem utilizadas e as metodologias a serem aplicadas.	Automação da comunicação por <i>chatbot</i> ; orientações metodológicas ao aluno e ao mediador pedagógico; suporte técnico, dicas de estudos e sugestão de trilhas de estudos automáticos.	Estrutura de conteúdo sequencial, obrigado a navegação e procura manual de conteúdo. Ferramenta de interação pouco atrativa.
Modelo de gestão da operação	Identifica as ferramentas existentes para acompanhamento do aprendizado por parte dos alunos e mediadores pedagógicos, assim como a ausência de informações para melhor tomada de decisão.	Dificuldade de ter uma visão 360 graus dos alunos. Dificuldade de acompanhar as ações realizadas pelos professores.	Sentimento de isolamento. Ausência de dicas para melhor aproveitamento no processo de ensino-aprendizagem
Melhorias gerais	Levantamento das necessidades de processo e de tecnologia dos alunos e gestores, frente aos desafios impostos pelas instituições e, também, para melhoria no processo educacional.	Existência de ferramenta de acompanhamento das ações educacionais (alunos e professores). Disponibilização de relatórios estratégicos para identificar melhorias no processo educacional.	Ferramentas e conteúdos interativos. Recomendação de estudo de acordo com as dificuldades individuais por aluno.

Fonte: Elaborado pelo autor.

Além da coleta com os gestores, realizou-se também um inquérito, igualmente via *Google Forms* (<https://forms.gle/3oCoj8AiLJvUvkFk7>), com alunos de cursos *on-line*, a fim de identificar problemas não relatados ou desconhecidos pelos gestores. Participaram 25 estudantes de diferentes cursos de graduação na modalidade de cursos *on-line*.

O instrumento para os alunos manteve a estrutura de quesitos utilizada com os gestores, mas foi adaptado para conter 14 perguntas distribuídas entre os temas avaliados. As respostas foram registradas em escala *Likert* de quatro pontos, variando de 1 (muito deficiente) a 4 (excelente), além da opção “não se

aplica”, utilizada quando o item não tinha relação com o contexto do participante ou era desconhecido.

As respostas dos gestores foram analisadas qualitativamente, com transcrição, categorização por quesito e tabulação para identificar problemas e sugestões. Já os dados dos alunos foram analisados quantitativamente, com apresentação dos resultados por quesito. Esses achados contribuíram para confirmar e complementar as informações levantadas inicialmente, subsidiando a definição do problema desta investigação e a revisão dos requisitos do modelo *Wizard User*, conforme detalhado na seção seguinte.

3.2 Resultados

Esta seção apresenta as percepções obtidas na Investigação Prévia, realizada para orientar a especialização e o aprimoramento dos requisitos do modelo *Wizard User*. A análise foi estruturada em quatro quesitos: problemas na qualidade do ensino, processo de interação, modelo de gestão da operação e melhorias gerais, como podem ser observadas no quadro 3.2.

Quadro 3.2 – Comparativo das percepções de gestores e alunos por quesito

Quesito	Percepção dos Gestores	Percepção dos Alunos	Implicações
Problemas na qualidade do ensino	Comunicação limitada via fóruns; falta de plataformas adaptativas e personalizadas; necessidade de gamificação; mensuração da qualidade das atividades por área.	Respostas lentas às dúvidas; baixa troca de conhecimento; ausência de recursos adaptativos; conteúdos pouco interativos.	Desenvolver respostas automatizadas ágeis com recursos interativos.
Processo de interação	Divergência sobre eficiência das ferramentas; consenso na necessidade de <i>bots</i> para recomendações, análise de avaliações, planos de estudo e suporte.	Ferramentas pouco atrativas; navegação engessada; interesse em trilhas automáticas e suporte mais ágil.	Incorporar <i>chatbots</i> com recomendação de conteúdo e trilhas personalizadas
Modelo de gestão da operação	Uso restrito a dados básicos e cruzamentos manuais; falta de indicadores estratégicos e visão 360º do aluno; necessidade de comunicação e métricas automatizadas.	Sentimento de isolamento; falta de acompanhamento personalizado; pouca visibilidade do progresso; desejo por <i>dashboards</i> comparativos.	Criar dashboards preditivos e indicadores estratégicos visuais.
Melhorias gerais e uso de IA	Ausência ou subutilização de IA; interesse em personalização, recomendações e painéis preditivos.	Sugestão de conteúdos interativos; integração de ferramentas; rotas de estudo personalizadas e notificações direcionadas.	Implementar notificações inteligentes, personalização e predição de comportamento.

Fonte: Elaborado pelo autor.

Em síntese, as percepções reunidas no Quadro 3.2 oferecem uma visão comparativa entre gestores e alunos, evidenciando pontos de convergência e divergência que serão detalhados nas subseções seguintes, preparando o terreno para a análise de suas implicações no modelo *Wizard User*.

3.2.1 Percepção dos gestores

No quesito Problemas na qualidade do ensino, os gestores destacaram a limitação na comunicação com os alunos, muitas vezes restrita ao uso de fóruns, o que dificulta a gestão da aprendizagem. Essa constatação reforça a importância do módulo de comunicação do *Wizard User*, que, além das funcionalidades de fórum, agrega respostas automatizadas e controle do tempo e qualidade do *feedback*.

Também foi recorrente a demanda por plataformas adaptativas e personalizadas, capazes de atender às especificidades dos estudantes e respeitar seus diferentes ritmos de estudo. Essa evidência confirma a relevância do desenvolvimento do *Wizard User* no que se refere a recursos inteligentes no AVA.

Outros pontos, embora fora do escopo desta tese, indicam oportunidades de melhoria:

- Gamificação nativa;
- Integração com dispositivos *IoT* – Internet das Coisas para experimentos de baixo custo;
- Ferramentas para mensuração da qualidade das atividades por área de conhecimento;
- Melhorias na experiência do usuário, favorecendo navegação e acesso a conteúdos.

No quesito Processo de interação, observou-se divergência entre gestores sobre a eficiência das ferramentas disponíveis. Apesar disso, houve unanimidade quanto à necessidade de automação da comunicação por *bots*, com sugestões como:

- Pesquisa e recomendação de conteúdo;
- Orientações metodológicas ao aluno e ao mediador pedagógico;

- Análise de avaliações e indicação de estudos;
- Suporte técnico, dicas de estudo e trilhas automatizadas;
- Planos de estudo dinâmicos.

No Modelo de gestão da operação, confirmou-se a ausência de indicadores estratégicos e visão integrada do progresso discente. A gestão é baseada em dados básicos (acessos, frequência, notas) e cruzamentos manuais no *Microsoft Excel*. Entre as necessidades citadas, estão:

- Comunicação automatizada com métricas de frequência, participação e desempenho;
- Reconhecimento da trilha percorrida pelo aluno para direcionamento mais preciso;
- Indicadores de sucesso que permitam comparação de desempenho com a turma.

No quesito Melhorias gerais e uso de IA, a maioria dos gestores afirmou não dispor de recursos de IA nos AVAs. Mesmo onde tais recursos existiam, eram subutilizados. As sugestões incluíram:

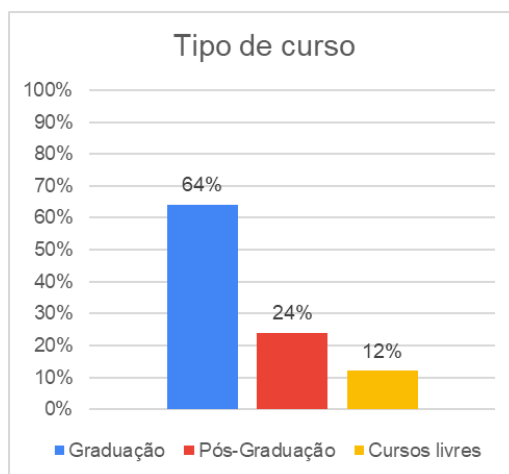
- Notificações inteligentes para alunos e mediadores;
- Personalização da plataforma;
- Recomendação de conteúdos por perfil do estudante;
- *Dashboards* preditivos para apoio à gestão.

3.2.2 Percepção dos alunos

A análise da percepção dos estudantes foi conduzida a partir de um inquérito composto por 14 questões, das quais 13 foram respondidas em escala *Likert* e uma em formato aberto, voltada à coleta de recomendações gerais para melhoria dos AVA. Para esta investigação, os dados foram organizados em três eixos principais, Problemas na qualidade do ensino, Processo de interação e Modelo de gestão da operação, analisados conjuntamente. As questões relacionadas a Melhorias Gerais foram avaliadas individualmente, dada sua abrangência temática. Em todas as análises, utilizou-se a média aritmética das respostas obtidas.

Todos os participantes eram estudantes ativos em cursos *on-line*, distribuídos em diferentes níveis acadêmicos. Conforme demonstra o Figura 3.2 - Gráfico: Tipo de curso, a maior representatividade foi observada entre alunos de graduação (64%), seguidos por pós-graduação (24%) e cursos livres (12%).


Figura 3.2 - Gráfico: Tipo de curso



Fonte: Elaborado pelo autor

Na Figura 3.3 – Gráfico: Análise de quesitos na visão do aluno, observa-se uma avaliação relativamente equilibrada entre os três eixos, embora todos apresentem médias modestas. Destaca-se a percepção mais crítica no quesito Qualidade do ensino (média de 2,28), seguida por Gestão da operação (2,08), evidenciando lacunas significativas na percepção de valor e efetividade dos AVA.

Figura 3.3 – Gráfico: Análise de quesitos na visão do aluno



Fonte: Elaborado pelo autor.

Qualidade do ensino

A análise isolada deste eixo revelou que nenhum dos AVA utilizados pelos respondentes disponibiliza recursos de recomendação de conteúdo, seja por sistemas baseados em IA, seja por mecanismos mais simples, como modelos de máquina de estado que ajustam conteúdos a partir de notas ou ações do estudante. Ainda assim, um número expressivo de alunos declarou-se satisfeito com os recursos tecnológicos disponíveis, o que sugere dois fatores: (i) desconhecimento do potencial dos sistemas de recomendação e (ii) compensação das lacunas do AVA por meio de buscas autônomas na internet.

Processo de interação

Embora o uso de recursos de interação entre alunos e mediadores pedagógicos seja frequente, a qualidade dessas interações foi alvo de críticas, sobretudo em relação ao tempo de resposta e à relevância dos conteúdos oferecidos. Essa constatação aponta para uma oportunidade de melhoria significativa com a implementação do modelo *Wizard User*, capaz de qualificar respostas, monitorar o tempo de interação e, idealmente, integrar respostas automatizadas mediadas por intervenção humana.

Gestão da operação


Os dados revelam que a maioria dos estudantes desconhece sua trilha de aprendizagem e as etapas necessárias para atingir seus objetivos educacionais. A ausência de relatórios ou *dashboards* com indicadores de desempenho compromete a autonomia e a autogestão do processo de aprendizagem. Essa lacuna reforça a necessidade de funcionalidades que forneçam ao aluno uma visão consolidada de seu progresso, bem como comparativos de desempenho em relação à turma.

No eixo Melhorias Gerais, três aspectos centrais foram analisados:

1. Automatização da mediação;
2. Uso de sistemas de recomendação educacional;
3. Aplicação de IA no processo de ensino-aprendizagem.

Os resultados indicam alta aceitação de todos os recursos, com destaque para a aplicação de IA, que obteve média máxima (4,0) na escala *Likert* (Figura 3.4 – Gráfico: Melhorias gerais).

Figura 3.4 – Gráfico: Melhorias gerais



Fonte: Elaborado pelo autor.

Apesar da sensibilidade do tema e das possíveis críticas por parte de docentes e discentes, os resultados evidenciam uma receptividade positiva à utilização de tecnologias computacionais em processos de interação e recomendação, desde que haja transparência quanto à atuação de agentes inteligentes.

Ainda que esforços regulatórios no Brasil, como a Estratégia Brasileira de Inteligência Artificial (EBIA, 2021), ainda não há legislação específica e robusta que discipline o uso da IA em contextos educacionais, situação que contrasta fortemente com modelos internacionais de governança. A Lei de Inteligência Artificial da União Europeia (AI Act, 2024), por exemplo, introduz um arcabouço regulatório sólido baseado no princípio de risco, que exige níveis diferenciados de transparência, governança e supervisão humana para sistemas usados em setores sensíveis, como a educação. Esse contraste evidencia a necessidade de que marcos legais nacionais avancem no sentido de garantir segurança, equidade e qualidade na aplicação de IA na educação.

Nesse contexto de ausência de diretrizes específicas, as respostas abertas confirmaram a relevância de funcionalidades previstas no modelo *Wizard User* e apresentaram demandas adicionais, tais como:

- Sistema de notificações antecipadas, recomendações de conteúdo correlacionado e integração com ferramentas de pesquisa;
- Aplicações de IA em atividades técnicas;
- Recursos para reduzir o tempo de resposta docente;
- Visualização do desempenho discente e alertas de novas interações;
- Maior eficiência e dinamismo na interação aluno-professor;
- Sistemas de recomendação em fóruns;
- Laboratórios remotos e atividades interativas com correção automática.

Adicionalmente, emergiram sugestões não diretamente vinculadas ao escopo da tese, mas de alta relevância pedagógica, como: acesso a aulas extras gravadas, conteúdos mais interativos e menor predominância de textos, melhorias na seleção aleatória de questões, e suporte ampliado ao discente.

Esses achados reforçam a importância de AVAs capazes de oferecer recursos personalizados, adaptados às necessidades individuais, de modo a aumentar a satisfação e reduzir a evasão. A análise também revela uma oportunidade para incorporar ao modelo *Wizard User* um sistema de reputação, pontuando agentes inteligentes e mediadores pedagógicos com base na qualidade e tempo de suas respostas, cuja concepção será detalhada na Seção 5.

3.2.3 Percepção do Investigador

Os resultados obtidos na investigação prévia evidenciam, de forma consistente, que as informações coletadas empiricamente acerca da aplicação de IA em AVA se consolidam como potenciais catalisadores de melhorias no processo de ensino-aprendizagem em cursos *on-line*.

A partir das entrevistas com gestores de Instituições de Ensino Superior (IES), identificou-se consenso quanto ao potencial da IA para aprimorar a qualidade do processo educativo, intensificar a interação entre os atores

envolvidos e promover maior personalização da aprendizagem. Essa percepção se alinha a tendências já documentadas na literatura, reforçando a relevância da adoção de soluções inteligentes no contexto educacional.

Do ponto de vista discente, observou-se familiaridade com tecnologias modernas baseadas em IA, amplamente presentes no cotidiano em redes sociais, plataformas de entretenimento e jogos. Os estudantes destacaram, em particular, o valor de sistemas de recomendação educacional e *chatbots*, reconhecendo sua capacidade de reduzir o tempo de busca por informações, melhorar a acurácia na recomendação de conteúdos e acelerar o ritmo de aprendizagem.

Assim, a investigação prévia cumpriu papel fundamental não apenas para validar a aplicabilidade e a aceitação do modelo proposto, mas também para refinar os requisitos sistêmicos do artefato tecnológico a ser desenvolvido e testado, assegurando maior aderência às necessidades reais do público-alvo.

3.2.4 Implicações para o Modelo *Wizard User*

A análise comparativa entre as percepções de gestores e alunos revela um ponto de convergência estratégico: a necessidade de AVAs mais personalizados, interativos e suportados por IA. As lacunas identificadas, relacionadas à comunicação automatizada, recursos adaptativos e ausência de *dashboards* estratégicos, encontram correspondência direta nos requisitos centrais do modelo *Wizard User*.

Nesse sentido, a investigação prévia não apenas corroborou as diretrizes originais do modelo, mas também reforçou seu potencial para:

- elevar a qualidade no processo de ensino-aprendizagem;
- ampliar a interatividade e a responsividade do sistema;
- oferecer experiências de aprendizagem mais personalizadas e orientadas por dados.

Esses achados estabelecem um alicerce sólido para os ajustes e aprimoramentos que serão apresentados no capítulo subsequente, assegurando que o modelo *Wizard User* esteja alinhado às demandas contemporâneas da educação *on-line* e às expectativas dos seus principais *stakeholders*.

Capítulo 4 – Revisão Sistemática

"A tecnologia só é transformadora quando serve para ampliar o potencial humano."

Tim Berners-Lee

Diante da velocidade com que a inteligência artificial evolui e transforma a educação *on-line*, tornou-se essencial atualizar a base teórica desta pesquisa por meio de uma revisão sistemática rigorosa. Este capítulo descreve o caminho percorrido, assim como os critérios de seleção à análise crítica dos estudos, avaliação do risco de viés e classificação da força das evidências. Os resultados, consolidados em meta-análise, revelam que a IA pode ampliar o desempenho acadêmico, personalizar percursos de aprendizagem e aumentar o engajamento dos estudantes, ao mesmo tempo em que expõem desafios e oportunidades para o avanço das práticas e das pesquisas na área.

4.1 Contexto

Diante da crescente relevância do tema e a necessidade de assegurar a consonância deste trabalho com as evoluções mais recentes da área, a realização desta revisão sistemática, mesmo após a redação inicial da tese, tornou-se essencial diante do ritmo acelerado em que a IA tem evoluído e impactado a educação. Estudos recentes revelam que, nos últimos anos, a educação *on-line* consolidou-se como uma alternativa poderosa de acesso ao conhecimento, rompendo fronteiras geográficas e oferecendo flexibilidade para pessoas de diferentes idades, níveis educacionais e realidades socioeconômicas. Esse cenário de expansão global, impulsionado por avanços tecnológicos e mudanças nas dinâmicas sociais, tem possibilitado que cada vez mais estudantes construam suas trajetórias de aprendizagem no ambiente digital (Kaliisa et al., 2023).

Considerando esse cenário de evolução constante, a revisão sistemática surge como instrumento metodológico fundamental para assegurar a atualização e a consistência teórica do trabalho. Conforme apontado por Kitchenham et al. (2009) e Moher et al. (2009), esse tipo de revisão representa uma abordagem rigorosa e estruturada que permite identificar, avaliar criticamente e sintetizar evidências disponíveis na literatura de forma transparente, contribuindo para a ampliação e o fortalecimento do conhecimento científico. Dessa maneira, realizar uma revisão atualizada possibilita não apenas consolidar o que já foi produzido, mas também incorporar as contribuições mais recentes sobre a aplicação da IA no processo de ensino-aprendizagem, oferecendo subsídios atualizados e relevantes para pesquisadores, educadores e tomadores de decisão.

Em consonância com esses objetivos, este capítulo apresenta de forma detalhada os procedimentos metodológicos adotados na revisão sistemática atualizada, incluindo os critérios de seleção e exclusão dos estudos analisados, bem como a síntese das principais evidências identificadas. Ao integrar as etapas e resultados desta revisão ao corpo do trabalho, reafirma-se o compromisso desta pesquisa com a qualidade, a pertinência e a atualidade das informações que fundamentam suas conclusões, atendendo às recomendações para a condução

de revisões sistemáticas de alta qualidade (*American Psychological Association, 2020*).

Nesse contexto, visando oferecer uma compreensão ainda mais precisa sobre as contribuições específicas da IA no cenário educacional on-line, é fundamental explicitar claramente a questão que norteou esta revisão, assim como os objetivos específicos estabelecidos para garantir uma análise abrangente e direcionada dos estudos disponíveis na literatura.

Como a inteligência artificial contribui para melhorar o desempenho acadêmico dos alunos em cursos *on-line*?

Esta revisão sistemática tem como objetivo compreender os impactos relacionados ao uso da inteligência artificial como agente de mediação pedagógica em cursos *on-line*. Busca-se analisar como a IA tem contribuído para o aprimoramento do processo de ensino-aprendizagem, especialmente, na personalização das experiências educacionais e na melhoria dos resultados acadêmicos de estudantes de diferentes idades, gêneros, níveis de escolaridade e contextos geográficos. A partir desse levantamento e dessa análise, pretende-se oferecer uma visão abrangente do tema, contribuindo tanto para o avanço científico, quanto para apoiar educadores, pesquisadores e profissionais da área na adoção consciente e efetiva dessas tecnologias.

4.2 Metodologia da Revisão Sistemática

Considerando a relevância das tecnologias de IA na educação *on-line* e a necessidade de compreender de forma abrangente seu impacto, delineou-se uma abordagem metodológica rigorosa para responder à questão de investigação. Para isso, foi conduzida uma revisão sistemática registrada no *International Prospective Register of Systematic Reviews (PROSPERO, nº CRD420251061960)*, em conformidade com as diretrizes do *Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA 2020)*, com foco em assegurar transparência, reprodutibilidade e rigor metodológico na coleta, análise e apresentação dos resultados.

Para garantir a qualidade e a relevância dos artigos incluídos, foram definidos critérios de elegibilidade com base na estratégia *PICOC* (Petticrew & Roberts, 2006). Esses critérios contemplaram artigos empíricos publicados a partir de 2019, em qualquer idioma, que envolvessem estudantes de cursos *on-line*, independentemente de idade, sexo, nível educacional ou localização geográfica, e que avaliassem o uso de recursos ou sistemas baseados em inteligência artificial aplicados à educação *on-line*. Foram incluídas investigações que comparassem essas intervenções com métodos educacionais sem suporte de IA, e que apresentassem como resultados principais indicadores de aprendizagem, como notas, engajamento, retenção, taxas de evasão, aprovação e reprovação, além de evidências de personalização do ensino. Revisões de literatura, protocolos, resumos de conferências, cartas e editoriais foram excluídos.

4.2.1 Processo de seleção e exclusão de artigos

A busca foi realizada nas bases *Scopus*, *Web of Science* e *IEEE Xplore*, selecionadas por sua relevância e abrangência nas áreas de educação, tecnologia e inteligência artificial. A coleta dos dados ocorreu em junho de 2025. A estratégia de busca combinou descritores controlados e termos livres (incluindo terminologia *MeSH*), adaptados às especificidades de indexação de cada base, utilizando operadores booleanos para ampliar a sensibilidade e especificidade. Os detalhes da estratégia de busca e dos resultados encontram-se no Apêndice C.

O processo de seleção seguiu as três fases recomendadas pelo PRISMA: identificação, triagem e inclusão. Para serem incluídos, os estudos deveriam: (i) ser empíricos, com dados que permitissem mensurar desempenho acadêmico; (ii) avaliar intervenções baseadas em IA aplicadas diretamente em cursos *on-line*; (iii) apresentar descrição detalhada da intervenção; e (iv) terem sido publicados entre 2019 e 2025, em qualquer idioma. Foram excluídos estudos teóricos, revisões, relatos de experiência, artigos com dados incompletos ou sem clareza metodológica, bem como trabalhos em que a IA não desempenhasse papel central na mediação pedagógica.

Todas as referências recuperadas foram importadas para a plataforma Parsifal⁶, utilizada tanto para a remoção automática de duplicatas quanto para a organização das referências, registro dos critérios aplicados e rastreamento das decisões de inclusão ou exclusão. A seleção dos artigos foi conduzida por um investigador principal e dois revisores independentes. Todas as decisões foram registradas na plataforma Parsifal, e eventuais divergências foram resolvidas por consenso. O índice de concordância entre os avaliadores foi calculado para assegurar a consistência do processo. Os critérios de exclusão durante a leitura dos textos completos incluíram ausência de dados quantitativos, inadequação ao critério de intervenção baseada em IA ou duplicidade de conteúdo (ver detalhes no Apêndice B). A trajetória detalhada do processo de seleção está apresentada no fluxograma PRISMA, na seção 4.3 com os Resultados (Figura 4.1).

O processo de seleção e exclusão, conduzido de forma sistemática e documentada, garantiu que apenas artigos alinhados aos critérios desta investigação fossem incluídos, preservando a relevância e a comparabilidade dos dados analisados. A próxima subseção apresenta a análise do risco de viés e a síntese quantitativa, que permitem avaliar a qualidade metodológica e integrar estatisticamente os achados.

4.2.2 Análise de viés

A avaliação do risco de viés dos artigos incluídos foi conduzida utilizando o *checklist* do *Joanna Briggs Institute (JBI)*, reconhecido por sua abrangência (*Joanna Briggs Institute, 2020; Aromataris, & Munn, 2020*). Esse instrumento foi escolhido por permitir examinar, de forma sistemática, aspectos essenciais para a validade interna dos artigos, como a clareza na relação causal, a presença e comparabilidade de grupos de controle, a uniformidade das intervenções, a adequação das análises estatísticas e a completude das medições. Todos os seis artigos incluídos, sendo cinco quase experimentais e um qualitativo, foram avaliados. A análise foi realizada por um investigador principal e dois revisores independentes, que atuaram de forma cega em relação às decisões uns dos

⁶ Parsifal é uma ferramenta *on-line* gratuita para gestão e documentação de revisões sistemáticas. Disponível em: <https://parsif.al>

outros. Divergências foram resolvidas por consenso, registrando-se um índice de concordância inicial de 87%, calculado por porcentagem simples, o que indica alta consistência na aplicação dos critérios. Os resultados completos dessa avaliação, com a classificação final de cada artigo como de baixo, moderado ou alto risco de viés, estão disponíveis na seção 4.3.2 Risco de viés apresentada no quadro 4.1.

4.2.3 Meta-análise

Com base na compatibilidade de métricas e desfechos, apenas quatro artigos atenderam aos requisitos para inclusão na meta-análise. As análises foram conduzidas no software *Comprehensive Meta-Analysis* (versão 4.0.000), adotando-se o modelo de efeito randômico, pois se antecipava heterogeneidade decorrente das diferenças nos contextos, nas populações e nas tecnologias de IA aplicadas (Borenstein et al., 2010). A heterogeneidade foi quantificada por meio do índice I^2 , que variou entre 24% e 46%, caracterizando baixa a moderada inconsistência (Higgins et al., 2003).

Para explorar potenciais fontes dessa variação, foram conduzidas análises de subgrupos, considerando fatores como o tipo de intervenção (plataforma adaptativa, *chatbot* ou gamificação) e a área de conhecimento abordada. Quando informações essenciais, como médias ou desvios-padrão, não estavam disponíveis, foram estimadas a partir de dados secundários, seguindo os métodos propostos por Wan et al., (2014) e revisadas por um investigador principal e dois revisores independentes para assegurar a precisão dos cálculos. As medidas de efeito individuais e combinadas, bem como os gráficos de floresta correspondentes, encontram-se na seção 4.3.5 Certeza de evidência.

A robustez das estimativas foi verificada por análises de sensibilidade, nas quais artigos com maior risco de viés ou características metodológicas distintas foram excluídos sequencialmente, de modo a observar o impacto dessas remoções nos resultados globais. Essa abordagem permitiu confirmar a estabilidade das conclusões, mesmo diante de cenários mais restritivos. Por fim, a certeza da evidência foi classificada segundo o sistema GRADE (Guyatt et al., 2008; McMaster University, 2025), que considera cinco domínios principais: risco de viés, inconsistência, evidência indireta, imprecisão e viés de publicação.

Alguns desfechos foram rebaixados para “moderada” ou “baixa” certeza, principalmente em função da predominância de delineamentos quase-experimentais e da presença de heterogeneidade residual. A síntese completa dessa avaliação, com a justificativa para cada decisão de rebaixamento ou manutenção da classificação, está apresentada na seção 4.3.6 Avaliação da força da evidência.

Em conjunto, a aplicação sistemática do *JBI*, a condução criteriosa da meta-análise e a classificação da certeza da evidência pelo *GRADE* fornecem uma base sólida para a interpretação dos achados desta investigação. Tais procedimentos garantem que as conclusões apresentadas estejam fundamentadas em evidências avaliadas quanto à sua validade interna, consistência e precisão. Na seção seguinte, apresentam-se os resultados, incluindo as características dos artigos analisados e as estimativas de efeito obtidas.

4.3 Resultados da Revisão Sistemática

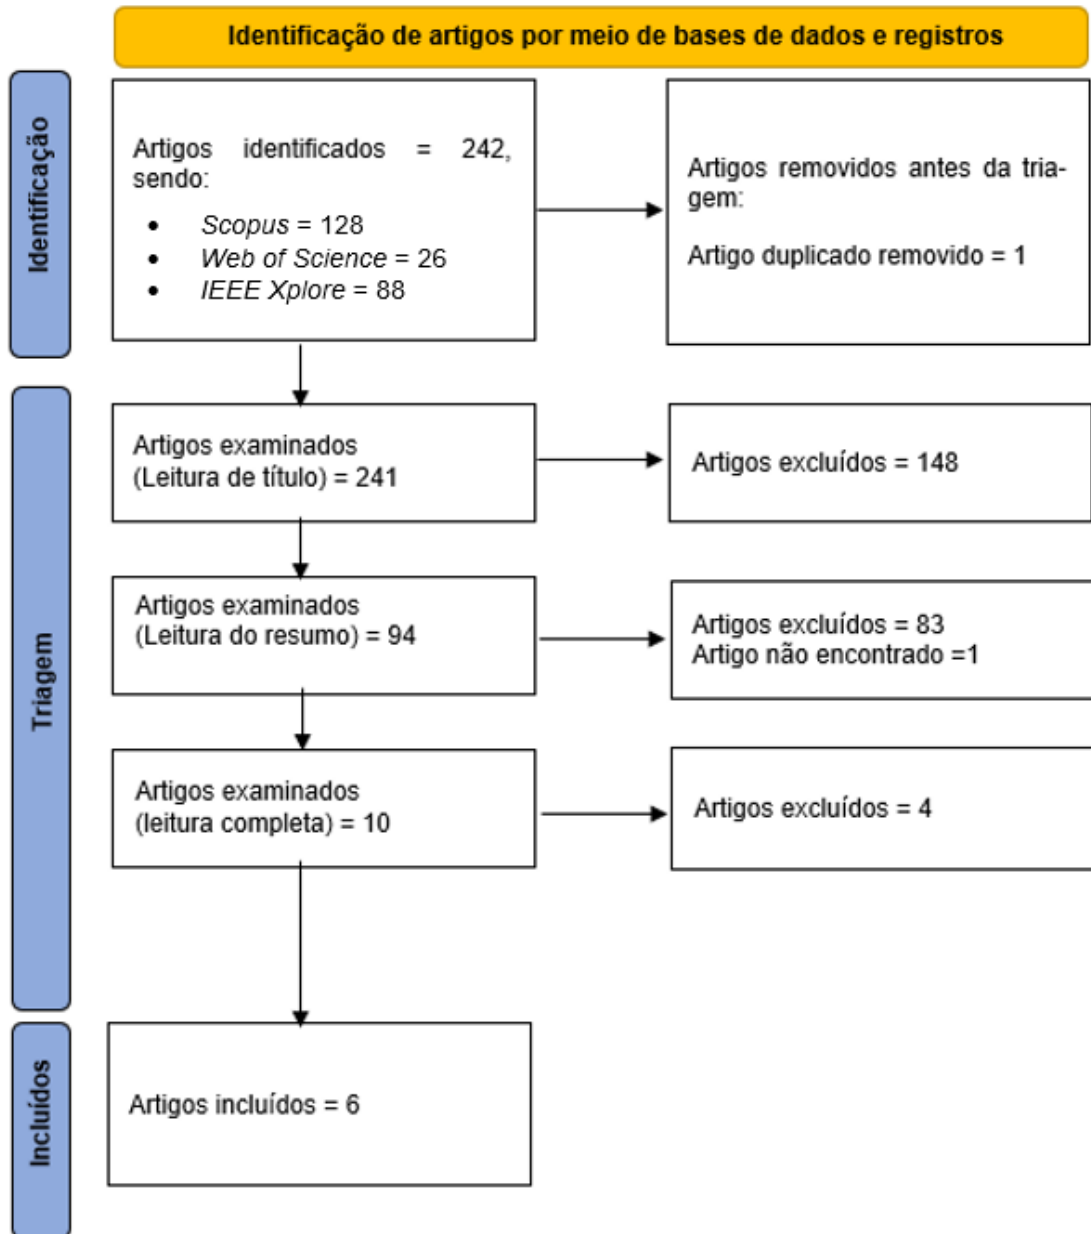
O processo de busca e triagem dos artigos identificados nesta investigação seguiu um fluxo progressivo, no qual cada etapa contribuiu para refinar o conjunto de publicações até chegar à amostra final elegível, conforme apresentado na figura 4.1. Inicialmente, foram recuperados 242 artigos nas bases de dados consultadas. Após a exclusão de 1 artigo duplicado, 241 seguiram para a fase de triagem.

Na leitura dos títulos, 148 artigos foram descartados por não atenderem aos critérios de inclusão, restando 94 registros para análise mais aprofundada. Em seguida, a leitura dos resumos levou à exclusão de 83 artigos, reduzindo o total para 11 candidatos à avaliação em texto completo.

Na etapa final, que consistiu na leitura integral dos textos, 1 artigo foi excluído por ter acesso restrito e outros 4 artigos foram removidos por não atenderem aos critérios de elegibilidade. Ao término dessa filtragem, 6 artigos permaneceram para a síntese qualitativa, dos quais 4 artigos apresentaram dados compatíveis com a realização de meta-análise. Os motivos de exclusão nessa

última fase incluíram ausência de dados quantitativos, inadequação ao critério de intervenção baseada em IA ou duplicidade.

Figura 4.1 – Diagrama de Fluxo PRISMA 2020



Fonte: Diagrama de fluxo do PRISMA (2000)

A Figura 4.1 sintetiza visualmente essas etapas por meio do diagrama de fluxo PRISMA (2020), permitindo acompanhar, de forma clara e imediata, o caminho percorrido desde a identificação inicial até a definição do conjunto final, com o resultado dos artigos incluídos. Embora o processo de busca tenha

inicialmente recuperado um número expressivo de artigos, a aplicação rigorosa dos critérios de elegibilidade resultou em uma amostra final composta por apenas seis estudos empíricos. Essa aparente restrição numérica reflete o compromisso desta revisão com a robustez metodológica e a comparabilidade dos achados, uma vez que foram excluídos estudos que não mensuração objetiva de desempenho acadêmico ou descrição detalhada das intervenções baseadas no uso da inteligência artificial em cursos *on-line*. Assim, a amostra reduzida, longe de representar limitação metodológica, demonstra alinhamento com as recomendações para revisões sistemáticas e ressalta a necessidade de maior rigor e transparência na produção científica do campo.

Com o processo de seleção concluído e a amostra definida, a próxima subseção apresenta as características dos artigos incluídos, explorando seus contextos, delineamentos, populações, intervenções e principais desfechos, elementos essenciais para sustentar as análises qualitativa e quantitativa subsequentes.

4.3.1 Características dos artigos

Os artigos incluídos nesta investigação, cujas principais características metodológicas, intervenções e desfechos avaliados apresentam contextos variados, convergem, porém, quanto à proposta de investigar o papel da inteligência artificial no aprimoramento de processos educacionais em cursos *on-line*. Predominam delineamentos quase experimentais para 5 artigos e qualitativo para 1 artigo, envolvendo intervenções estruturadas em diferentes contextos culturais e níveis educacionais, desde o ensino fundamental, como nos artigos realizados no Egito, Indonésia e México (Wafaa et al., 2022; Pardamean et al., 2022; Ríos Félix et al., 2020), até o ensino superior e formação de professores em países como Malásia, China e Emirados Árabes Unidos (Neo et al., 2022; Wang, 2024; Eltahir & Babiker, 2024).

Os tamanhos amostrais variam de 26 a 322 participantes, com amostras predominantemente compostas por estudantes, mas também incluindo professores em formação. As intervenções analisadas abrangem uma gama de soluções tecnológicas baseadas em IA, tais como plataformas adaptativas

personalizadas segundo o modelo *VARK*⁷, sistemas inteligentes com algoritmos de aprendizagem adaptativa, *chatbots* de apoio ao engajamento, ambientes inteligentes para o ensino de pensamento computacional e ferramentas de predição de estilos de aprendizagem. Em termos de duração, as intervenções se estenderam entre quatro e oito semanas, possibilitando tanto comparações pré e pós-intervenção quanto avaliações entre grupos de controle e experimental.

Há uma clara convergência quanto à utilização de instrumentos quantitativos padronizados, como testes de desempenho acadêmico e questionários de motivação, além da inclusão de métodos qualitativos em alguns artigos, especialmente para captar a percepção e satisfação dos estudantes. Notam-se, ainda, diferenças importantes na ênfase dos desfechos: enquanto alguns artigos priorizaram indicadores cognitivos, como desempenho em matemática ou artes (Wafaa et al., 2022; Wang, 2024; Pardamean et al., 2022), outros se voltaram para variáveis afetivas e atitudinais, como motivação, engajamento e aceitação das ferramentas de IA (Neo et al., 2022; Eltahir & Babiker, 2024).

No conjunto, os artigos destacam o potencial das soluções de IA para personalizar a experiência de aprendizagem, promover *feedback* imediato e ajustar percursos formativos de acordo com estilos de aprendizagem e necessidades individuais. As estratégias adaptativas se mostraram eficazes tanto em contextos de disciplinas exatas quanto em cursos de artes e pensamento computacional, sugerindo transversalidade dos benefícios da IA. Por outro lado, limitações como o tamanho reduzido de algumas amostras, a curta duração das intervenções e a ausência de controles em determinados artigos impõem cautela à generalização dos resultados.

Em suma, os artigos analisados apresentam diversidade em termos de contextos, metodologias e instrumentos, mas apontam convergentemente para a efetividade das abordagens baseadas em IA no ensino *on-line*, associando-se a ganhos em desempenho acadêmico, engajamento e satisfação dos participantes.

⁷ VARK: sigla para Visual, Auditivo, Leitura/Escrita e Cinestésico – um modelo para identificar e personalizar estilos de aprendizagem.

4.3.2 Risco de viés

A avaliação do risco de viés, conduzida conforme descrito na metodologia, revelou que, entre os seis artigos incluídos, cinco apresentaram delineamento quase experimental e um qualitativo, todos examinados segundo os critérios do *JBI*. De forma geral, observou-se predominância de baixo risco de viés, com a maioria dos artigos atendendo integralmente ou quase integralmente aos domínios avaliados. Esse desempenho reflete clareza na definição das intervenções, presença de grupos de comparação, mensuração objetiva dos desfechos e aplicação consistente de análises estatísticas apropriadas, conforme apresentado no quadro 4.1.

Apenas um artigo, do tipo pré e pós-teste sem grupo controle independente, apresentou risco moderado, devido à ausência de comparação externa e à possibilidade de influência de fatores não controlados. Ainda que algumas limitações metodológicas pontuais, como falta de detalhamento nos processos de randomização ou alocação, tenham sido identificadas, essas fragilidades não comprometeram substancialmente a validade interna do conjunto.

Quadro 4.1 - Instrumento de avaliação de risco de viés (Instituto Joana Briggs)

Autor e Ano	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10*	RISCO
Wafaa et al. (2022)	Sim	Sim	Parcial	Sim	Sim	Sim	Sim	Sim	Sim	N/A	Baixo (8,5/9 ≈ 94%)
Neo et al. (2022)	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Baixo (10/10 = 100%)
Wang (2024)	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	N/A	Baixo (9/9 = 100%)
Eltahir & Babiker (2024)	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	N/A	Baixo (9/9 = 100%)
Pardamean et al. (2022)	Sim	Não	Sim	Sim	Sim	Sim	Sim	Sim	Sim	N/A	Moderado (8/9 ≈ 89%)
Ríos Félix et al. (2020)	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	N/A	Baixo (9/9 = 100%)

Fonte: Elaborado pelo autor.

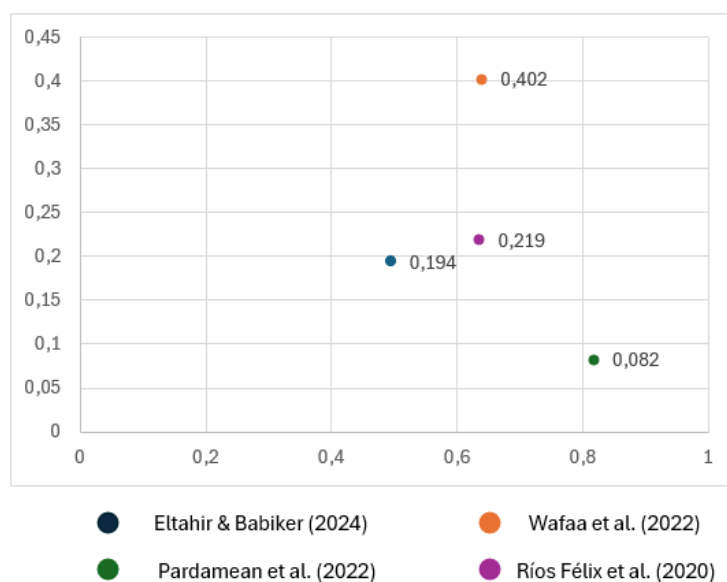
* O artigo foi avaliado com base no instrumento *JBI* para investigações qualitativas, o qual contempla 10 domínios metodológicos voltados à análise da credibilidade, relevância e robustez das evidências científicas.

Como pode ser observado no quadro 4.1, a análise crítica dos artigos confirma a predominância de baixo risco de viés metodológico. A maior parte dos artigos atendeu a todos os nove ou dez critérios do instrumento, destacando-se pela clareza na descrição das intervenções, presença de comparações adequadas, uso de instrumentos validados e acompanhamento completo dos participantes. O único caso de risco moderado esteve associado à ausência de grupo de controle independente, o que pode ter aumentado a suscetibilidade a confundidores não controlados.

Complementarmente, entre os artigos incluídos na meta-análise ($n = 4$), a avaliação visual do gráfico de funil não revelou padrão evidente de assimetria, sugerindo ausência aparente de viés de publicação. Os pontos apresentaram distribuição relativamente simétrica em torno da média do efeito combinado (SMD = 0,75), indicando equilíbrio entre artigos de maior e menor precisão.

Distribuição dos efeitos estimados (SMD) em relação aos respectivos erros-padrão. Cada ponto representa um artigo individual.

Figura 4.2 - Gráfico de funil para avaliação de viés de publicação



Fonte: Elaborado pelo autor.

Apesar da predominância de baixo risco de viés, o número reduzido de artigos avaliados na meta-análise ($n = 4$) limita a robustez dessa análise e diminui a sensibilidade para identificar assimetrias sutis. Ainda assim, considerando o

conjunto mais amplo de artigos avaliados para risco de viés ($n = 6$), os dados sintetizados na Tabela 4.1 e representados na figura 4.2 reforçam a consistência metodológica do *corpus* analisado, fornecendo base sólida para interpretações subsequentes. Recomenda-se, entretanto, cautela na extrapolação dos resultados, em função das limitações inerentes aos delineamentos quase experimentais identificados.

4.3.1 Resultados de artigos individualizados

Esta subseção apresenta, de forma comparativa, os principais achados de cada artigo incluído, destacando diferenças entre grupos de intervenção e de controle, quando disponíveis, bem como medidas de desempenho pré e pós-intervenção. Sempre que reportados pelos autores, são indicadas médias, desvios-padrão, valores de p e intervalos de confiança, permitindo avaliar simultaneamente a magnitude dos efeitos e a precisão das estimativas. Essa sistematização fornece uma base sólida para comparações diretas e para as sínteses quantitativas subsequentes.

No quadro 4.2, cada artigo foi analisado quanto aos resultados obtidos nos grupos de intervenção e controle, sempre que disponíveis, incluindo médias, desvios-padrão, valores de p e intervalos de confiança, quando reportados pelos autores. Para artigos do tipo pré e pós-teste, são destacados os ganhos absolutos observados após a implementação da intervenção. As estimativas do efeito foram detalhadas de modo a evidenciar não apenas a magnitude das diferenças entre grupos, mas também a precisão das medições, conforme indicado pelos intervalos de confiança. Essa sistematização facilita a comparação direta entre os achados e fortalece a base para sínteses quantitativas.

Quadro 4.2 - Resultados estatísticos Individuais

Autor	Grupo Intervenção	Média (DP ou EP) ⁸	Grupo Controle	Média (DP ou EP)	Estatística de efeito ⁹	Valor de p ¹⁰	Intervalo de Confiança (IC 95%)
Wafaa et al.(2022)	Plataforma adaptativa (VARK)	8,0 (1,2)	Gamificação	7,2 (1,3)	Diferença de médias: 0,8	0,035	[0,06 – 1,54]
Neo et al.(2022)	Chatbot MERLIN e AVA	N/A	Tradicional	N/A	N/A	N/A	N/A
Wang (2024)	E-learning inteligente	N/A	Tradicional	N/A	N/A	N/A	N/A
Eltahir & Babiker (2024)	IA/Moodle	81,8 (8,6)	Tradicional	77,4 (9,2)	Diferença de médias: 4,4	<0,001	[2,12 – 6,68]
Pardamean et al.(2022)	Pré-teste	68,1 (9,4)	Pós-teste	75,5 (8,7)	Diferença: 7,4	<0,001	[5,89 – 8,91]
Ríos Félix et al.(2020)	ILE	7,8 (1,1)	Tradicional	7,0 (1,4)	Diferença de médias: 0,8	0,012	[0,18 – 1,42]

Fonte: Elaborado pelo autor.

A análise integrada evidencia uma convergência significativa no sentido de que as intervenções baseadas em IA impactaram positivamente tanto o desempenho acadêmico quanto os indicadores de engajamento em ambientes de aprendizagem *on-line*. Independentemente da abordagem utilizada, plataformas adaptativas, sistemas inteligentes, algoritmos de predição de estilos de aprendizagem ou *chatbots*, observou-se desempenho superior em relação a métodos tradicionais ou gamificados. Em todos os artigos quantitativos, as diferenças entre grupos de intervenção e de controle foram estatisticamente significativas, com ganhos variando de 0,8 ponto (Wafaa et al., 2022; Ríos Félix et al., 2020) a 7,4 pontos (Pardamean et al., 2022), reforçando a efetividade das abordagens adaptativas e inteligentes.

Além dos ganhos objetivos, houve relato consistente de aumento na motivação e satisfação dos estudantes, especialmente em experiências mediadas por *chatbots* ou recursos interativos, como no artigo MERLIN¹¹ (Neo et al., 2022). Apesar da ausência de medidas estatísticas detalhadas nesse caso, a aceitação

⁸ Média (DP ou EP) refere-se ao valor médio do desfecho avaliado em cada grupo do artigo, acompanhado pelo desvio-padrão (DP), que indica a dispersão dos dados, ou pelo erro-padrão (EP), que indica a precisão da estimativa da média amostral.

⁹ Estatística de efeito representa o tamanho da diferença observada entre grupos (ex: diferença de médias), ou entre dois momentos (pré e pós-teste), podendo ser apresentada por medidas como diferença absoluta de médias, *odds ratio*, *risk ratio*, entre outras, conforme o desfecho analisado.

¹⁰ Valor de p indica a probabilidade de que a diferença observada tenha ocorrido ao acaso, assumindo que não existe efeito real (hipótese nula). Valores de p menores que 0,05 sugerem que a diferença encontrada é estatisticamente significativa.

¹¹ MERLIN - é um *chatbot* de IA multimídia usado como assistente virtual de aprendizagem e agente de *scaffolding* em cursos *on-line* de *design*.

elevada e os relatos qualitativos indicam que a IA também favorece dimensões atitudinais, fortalecendo o engajamento e a intenção de uso futuro das ferramentas digitais.

Outro ponto comum foi a capacidade da IA de personalizar a aprendizagem, seja pela adaptação ao estilo de aprendizagem (Wafaa et al., 2022; Pardamean et al., 2022), pelo ajuste do percurso formativo (Wang, 2024) ou pelo fornecimento de *feedback* contínuo em plataformas inteligentes (Eltahir & Babiker, 2024). Esses mecanismos tornam os ambientes virtuais mais responsivos às necessidades individuais, o que contribui para o aumento do desempenho e da retenção do conhecimento.

Embora haja variação entre os artigos quanto a tamanho amostral, perfil dos participantes e duração das intervenções, o rigor estatístico foi consistente, com valores de $p < 0,05$ e intervalos de confiança que excluem a nulidade, o que sustenta a conclusão de que soluções baseadas em IA têm potencial comprovado para melhorar desempenho, engajamento e experiência do estudante em cursos *on-line*. A principal limitação identificada foi a ausência de medidas padronizadas de satisfação em todos os artigos, aliada à necessidade de avaliações mais amplas e diversificadas cultural e educacionalmente.

Em síntese, os resultados apresentados no Quadro 4.2 demonstram ganhos consistentes em desempenho acadêmico, personalização, motivação e satisfação dos estudantes, reforçando o papel estratégico da IA no processo de ensino-aprendizagem e apontando caminhos promissores para o avanço da investigação e da prática educacional mediada por tecnologias inteligentes. Esses achados fornecem base sólida para a realização de sínteses quantitativas subsequentes e reforçam a necessidade de investigações futuras que aprofundem a análise de subgrupos e de potenciais moderadores dos efeitos observados.

4.3.2 Síntese dos resultados

Os artigos incluídos nesta revisão sistemática apresentam grande diversidade quanto ao contexto educacional, métodos de intervenção e instrumentos utilizados, mas compartilham características metodológicas

importantes. Os 5 artigos adotaram delineamento quase experimental e 1 artigo qualitativo, com amostras variando desde o ensino fundamental até o ensino superior, abrangendo diferentes países como Egito, Malásia, China, Emirados Árabes Unidos, Indonésia e México (Wafaa et al., 2022; Neo et al., 2022; Wang, 2024; Eltahir & Babiker, 2024; Pardamean et al., 2022; Ríos Félix et al., 2020).

As amostras dos artigos incluíram desde 26 alunos do ensino fundamental (Wafaa et al., 2022) até 322 estudantes do ensino primário (Pardamean et al., 2022), além de universitários, professores em formação e pós-graduandos, refletindo diferentes níveis de escolaridade e contextos culturais. Os instrumentos de coleta de dados envolveram testes objetivos, questionários validados, escalas de Likert, registros de interação em plataformas digitais e análises qualitativas de *feedback* dos estudantes. A maioria dos artigos utilizou o Moodle como base tecnológica ou desenvolveu sistemas próprios integrados a AVA.

Quanto ao risco de viés, a avaliação realizada pelo *checklist* da JBI evidenciou predominância de baixo risco entre os artigos analisados, com todos atendendo entre 89% e 100% dos critérios metodológicos avaliados. Apenas o artigo de Pardamean et al. (2022) apresentou risco moderado, decorrente da ausência de algumas etapas metodológicas, como randomização ou grupo de comparação independente. Nos demais artigos, foram observados procedimentos adequados de validação, padronização dos instrumentos de medida, acompanhamento completo dos participantes e uso de métodos estatísticos coerentes (Wafaa et al., 2022; Neo et al., 2022; Wang, 2024; Eltahir & Babiker, 2024; Ríos Félix et al., 2020), embora limitações relacionadas ao tamanho das amostras e à diversidade dos contextos demandem cautela na generalização dos resultados.

Os resultados convergiram para o impacto positivo da IA sobre o desempenho acadêmico, conforme evidenciado pelas diferenças significativas entre grupos experimentais e controles, bem como pelos relatos qualitativos dos participantes (Wafaa et al., 2022; Neo et al., 2022; Wang, 2024; Eltahir & Babiker, 2024; Pardamean et al., 2022; Ríos Félix et al., 2020).

4.3.3 Meta-análise


Para a construção da meta-análise, foram utilizadas médias (M) e desvios-padrão (SD) dos dados pós-aplicação da intervenção. Considerou-se a intervenção como sendo ferramentas de IA e o controle metodologias tradicionais e gamificação.

A medição do desfecho aponta para uma direção positiva, na qual, quanto maior a média, melhor o resultado obtido. O modelo de efeito randômico foi empregado por ser este um modelo mais conservador e menos susceptível a erro. Apesar de a heterogeneidade estatística ter sido considerada baixa em algumas análises ($I^2 \leq 25\%$), a escolha pelo modelo randômico foi fundamentada nas diferenças metodológicas e contextuais entre os artigos, conforme recomendam diretrizes internacionais. Isso garante maior robustez às estimativas combinadas ao considerar a variabilidade inerente dos contextos educacionais, intervenções e populações analisadas.

Os artigos de Neo et al. (2022) e Wang, (2024) foram excluídos da meta-análise por não apresentarem dados quantitativos completos: Neo et al. (2022) apresentou apenas resultados qualitativos (sem médias, desvios-padrão ou valores de p), enquanto Wang, (2024) focou na validação do sistema e não relatou medidas objetivas comparáveis entre grupos.

Para a realização da primeira análise, 04 artigos foram incluídos (Wafaa et al., 2022; Eltahir & Babiker, 2024; Pardamean et al., 2022; e Ríos Félix et al., 2020). O artigo de Pardamean et al. (2022) foi incluído na primeira meta-análise apesar de seu delineamento de coorte pré-pós sem grupo de controle paralelo, pois forneceu médias e desvios-padrão antes e após a intervenção. Contudo, reconhece-se que esse tipo de artigo pode estar mais sujeito a viés de confusão quando comparado aos ensaios com grupos de controle, motivo pelo qual subsequentes análises foram conduzidas excluindo esse artigo para avaliar a robustez dos resultados. O número total de participantes considerado em cada meta-análise foi cuidadosamente calculado de acordo com os artigos incluídos em cada etapa.

Figura 4.3 - Gráfico de Floresta sobre o Desempenho acadêmico dos alunos em cursos on-line (IAs e Grupos controle)




Fonte: Elaborado pelo autor.

Os resultados apontam significância estatística na diferença entre os grupos com resultado superior no grupo de intervenção (SMD = 0,75, IC 95%: 0,61 a 0,88, $p < 0,001$; $I^2 = 0\%$), o que demonstra a contribuição da IA na melhora do desempenho acadêmico dos alunos em cursos *on-line*, conforme ilustrado na Figura 4.3.

O modelo de efeito randômico foi selecionado por ser mais conservador e por considerar eventuais diferenças metodológicas e contextuais entre os artigos, mesmo diante da baixa heterogeneidade observada ($I^2 \leq 25\%$).

Para a realização da segunda análise, 03 artigos foram incluídos (Wafaa et al., 2022; Eltahir & Babiker, 2024 e Ríos Félix et al., 2020). O artigo de Pardamean et al., 2022, foi excluído por ser uma coorte, contendo apenas um grupo, e a intenção do autor foi avaliar o resultado da meta-análise sem o referido artigo.

Figura. 4.4 - Gráfico de Floresta sobre o Desempenho acadêmico dos alunos em cursos on-line (IAs e Grupos Controle) sem o artigo de coorte




Fonte: Elaborado pelo autor.

Os resultados apontam significância estatística na diferença entre os grupos com resultado superior no grupo de intervenção (SMD = 0,56, IC 95%: 0,299 a 0,833, $p < 0,001$; $I^2 = 0\%$), o que demonstra a contribuição da IA na melhora do desempenho acadêmico dos alunos em cursos *on-line*, conforme ilustrado na Figura 4.4.

0,29 a 0,83, $p < 0,001$; $I^2 = 0\%$), o que demonstra a contribuição da IA na melhora do desempenho acadêmico dos alunos em cursos *on-line*, conforme ilustrado na Figura 4.4.

Para a realização da terceira análise, 03 artigos foram incluídos (Eltahir & Babiker, 2024; Pardamean et al., 2022 e Ríos Félix et al., 2020) por terem utilizado métodos tradicionais no grupo controle. O artigo de Wafaa et al., 2022 foi excluído por ter utilizado gamificação no grupo de controle. Optou-se por excluir o artigo de Wafaa et al. (2022) dessa análise porque o grupo de comparação utilizou uma intervenção ativa (gamificação), e não métodos tradicionais passivos, o que poderia enviesar a comparação e inflar a heterogeneidade dos resultados.

Figura 4.5 - Gráfico de Floresta sobre o Desempenho acadêmico dos alunos em cursos *on-line* apenas com métodos tradicionais no Grupo Controle




Fonte: Elaborado pelo autor.

Os resultados apontam significância estatística na diferença entre os grupos com resultado superior no grupo de intervenção (SMD = 0,71, IC 95%: 0,52 a 0,91, $p < 0,001$; $I^2 = 25\%$), o que demonstra a contribuição da IA na melhora do desempenho acadêmico dos alunos em cursos *on-line*, conforme ilustrado na Figura 4.5.

Para a realização da quarta análise, 02 artigos foram incluídos (Eltahir & Babiker, 2024 e Ríos Félix et al., 2020) por terem utilizado métodos tradicionais no grupo de controle. O artigo de Pardamean et al., 2022 foi excluído por ser uma coorte, contendo apenas um grupo.

Figura 4.6 - Gráfico de Floresta sobre o Desempenho acadêmico dos alunos em cursos on-line apenas com métodos tradicionais no Grupo Controle sem o artigo de coorte



Fonte: Elaborado pelo autor.

Os resultados apontam significância estatística na diferença entre os grupos com resultado superior no grupo de intervenção (SMD = 0,55, IC 95%: 0,27 a 0,84, $p < 0,001$; $I^2 = 0\%$), o que demonstra a contribuição da IA na melhora do desempenho acadêmico dos alunos em cursos *on-line*, conforme ilustrado na Figura 4.6.

4.3.4 Avaliação da força da evidência

A força da evidência foi avaliada utilizando o sistema GRADE (*Grading of Recommendations Assessment, Development, and Evaluation*), com o suporte do GRADE profiler (GRADEpro). Nos desfechos em que o total de participantes foi inferior a 400, conforme recomendado pelo GRADE, a certeza da evidência foi rebaixada de alta para moderada, de modo a refletir maior imprecisão relacionada ao tamanho amostral reduzido. O sistema GRADE atribui níveis de evidência e avalia a força das recomendações, refletindo a confiança nas informações disponíveis (Schünemann et al., 2013). Dentro desse *framework*, a qualidade da evidência é categorizada como alta, moderada, baixa ou muito baixa com base nos desfechos analisados. Para determinar o nível de evidência, os seguintes fatores foram considerados: delineamento do artigo, risco de viés, inconsistência, evidência indireta e imprecisão.

Quadro 4.3 - GRADE (Grading of Recommendations Assessment, Development, and Evaluation)

Participantes (artigos) Seguimento	Risco de viés	Inconsistência	Evidência indireta	Imprecisão	Certeza geral da evidência
Desempenho acadêmico dos alunos (IAs e Grupos Controle)					
868 (3 Artigos de Intervenção e 01 Artigo Coorte)	não grave	não grave	não grave	não grave	⊕⊕⊕⊕ Alta
Desempenho acadêmico dos alunos (IAs e Grupos Controle) sem o artigo de coorte					
224 (3 Artigos de Intervenção)	não grave	não grave	não grave	grave ^a	⊕⊕⊕○ Moderada ^a
Desempenho acadêmico dos alunos com Grupo Controle apenas com Métodos Tradicionais					
842 (2 Artigos de Intervenção e 1 Artigo Coorte)	não grave	não grave	não grave	não grave	⊕⊕⊕⊕ Alta
Desempenho acadêmico dos alunos com Grupo Controle apenas com Métodos Tradicionais sem o artigo de Coorte					
198 (2 Artigos de Intervenção)	não grave	não grave	não grave	grave ^b	⊕⊕⊕○ Moderada ^b

Fonte: Elaborado pelo autor.

Observações:

- a. Número total de participantes menor que 400.
- b. Número total de participantes menor que 400.

A força da evidência foi considerada “Alta” nos desfechos que incluíram o artigo de Coorte e “Moderada” sem tal artigo (quadro 4.3), conforme a avaliação da pergunta de pesquisa: Como a inteligência artificial contribui para melhorar o desempenho acadêmico dos alunos em cursos on-line?

4.4 Discussão

Os resultados desta revisão sistemática e meta-análise indicam que intervenções baseadas em inteligência artificial (IA) exercem impacto positivo e estatisticamente significativo no desempenho acadêmico de estudantes em cursos *on-line*. O tamanho de efeito combinado observado (SMD = 0,75; IC 95%: 0,61–0,88) reforça a robustez dessa associação, especialmente pela baixa heterogeneidade observada ($I^2 = 24\%$), o que sugere consistência entre os artigos incluídos.

Em comparação com revisões anteriores, os presentes achados ampliam e aprofundam as evidências disponíveis. Holmes et al. (2019), por exemplo, identificaram efeitos moderados da IA sobre resultados acadêmicos, mas reportaram alta heterogeneidade e alertaram para lacunas metodológicas

relevantes. Já a presente revisão, ao utilizar critérios de inclusão mais recentes e avaliação GRADE, proporciona uma base mais confiável e atualizada. De forma convergente, artigos recentes como os de Bond et al. (2024) & Al Nabhani et al. (2025) destacam os efeitos positivos da IA na personalização da aprendizagem e no aumento do engajamento dos estudantes, sobretudo quando integradas intencionalmente ao desenho instrucional.

O impacto positivo das intervenções baseadas em inteligência artificial foi mais evidente em plataformas adaptativas e *chatbots*, corroborando achados recentes que ressaltam a eficácia dessas ferramentas na personalização das trilhas de aprendizagem e no engajamento dos estudantes (Gligorea, 2023; Labadze et al., 2023; Neo et al., 2022). Por outro lado, divergências persistem quanto ao grau de eficácia da IA em diferentes níveis de ensino e contextos sociotecnológicos. Artigos como os de Crompton & Burke, (2023) sugerem que os efeitos tendem a ser mais pronunciados no ensino superior do que na educação básica, possivelmente devido a diferenças na autonomia dos aprendizes e na infraestrutura disponível.

Além disso, a presente revisão sistemática observou que as intervenções baseadas em IA tendem a ser mais eficazes quando integradas de maneira planejada ao planejamento pedagógico, potencializando não apenas o desempenho acadêmico, mas também o engajamento, a motivação e o sentimento de autoeficácia dos estudantes. Essa conclusão foi sustentada por uma meta-análise com quatro artigos de delineamento experimental e quase experimental, todos classificados com risco de viés baixo a moderado segundo o GRADE. Ainda assim, são reconhecidas limitações recorrentes nos artigos incluídos, como amostras reduzidas, ausência de grupos controle e variação nos instrumentos de avaliação, pontos discutidos a seguir.

Esses achados não apenas consolidam o papel da IA como mediadora do desempenho acadêmico em cursos *on-line*, mas também sinalizam o início de uma nova fase de maturidade nas evidências empíricas sobre sua eficácia educacional.

Apesar dos resultados promissores, as evidências incluídas nesta revisão apresentam limitações metodológicas relevantes que precisam ser cuidadosamente consideradas. Aproximadamente 75% dos artigos analisados utilizaram delineamentos quase experimentais, e apenas um implementou randomização completa, o que eleva o risco de viés de seleção e compromete a força das inferências causais (Pardamean et al., 2022; Wafaa et al., 2022).

Em especial, a predominância de delineamentos quase experimentais e o uso recorrente de medidas autorreferidas aumentam a suscetibilidade a vieses de seleção e mensuração. Essas limitações impactam diretamente a confiança nas estimativas de efeito reportadas por esta revisão sistemática, podendo superestimar os benefícios atribuídos às intervenções baseadas em IA ou restringir a inferência causal. Desse modo, a robustez e a generalização dos achados desta revisão permanecem condicionadas à qualidade metodológica dos artigos incluídos. Assim, ainda que os resultados indiquem impacto positivo, é fundamental interpretar as conclusões à luz dessas fragilidades, reconhecendo a necessidade de estudos futuros com maior rigor metodológico para fortalecer a validade externa e interna dos achados.

Além das limitações metodológicas, a diversidade de contextos, populações e métricas de avaliação também se mostrou considerável. As amostras incluíram desde estudantes do ensino fundamental até alunos universitários e professores em formação inicial, espalhados por diferentes países e com graus variados de maturidade tecnológica. Essa diversidade, embora enriqueça a compreensão do campo, dificulta a comparação direta dos resultados, limita a generalização dos achados para diferentes contextos e contribui para a variabilidade residual dos efeitos observados.

Adicionalmente, 40% dos artigos utilizaram apenas medidas autorreferidas como desfecho, sem validação externa ou triangulação com métricas objetivas, aumentando o risco de viés de mensuração e reduzindo a generalização dos resultados. O viés de publicação permanece uma preocupação legítima, dado que artigos com resultados nulos ou negativos são frequentemente sub-representados na literatura publicada, o que pode distorcer as conclusões de meta-análises (Afonso et al., 2024; Higgins et al., 2019).

Apesar dos cuidados metodológicos adotados nesta revisão, incluindo protocolo pré-definido, uso de instrumentos reconhecidos (JBI e GRADE), e dupla revisão independente, algumas limitações devem ser reconhecidas. A busca foi restrita a publicações em inglês e indexadas em bases de dados internacionais, o que pode ter excluído artigos relevantes da literatura cinzenta ou de outras regiões linguísticas. Esse fator pode limitar a representatividade e a diversidade cultural das evidências incluídas.

Outro ponto a destacar é que, embora dois revisores tenham atuado de forma independente, não houve auditoria por terceiro revisor externo, o que pode deixar margens para divergências interpretativas não resolvidas por consenso. Além disso, como mencionado, a revisão sistemática foi devidamente registrada na plataforma PROSPERO (número de registro: CRD420251061960), o que reforça o compromisso com a transparência metodológica e a rastreabilidade do processo de revisão, conforme recomendado pelas diretrizes PRISMA 2020.

Por fim, a síntese quantitativa só foi possível para um subconjunto de artigos (n=4) que apresentavam medidas padronizadas compatíveis. Isso levou à exclusão de investigações promissoras que usaram métodos qualitativos ou métricas alternativas, o que limita a abrangência da meta-análise. Essa limitação, somada às dificuldades de aplicação do *GRADE* em artigos educacionais não clínicos, reforça a necessidade de ampliar e refinar as metodologias de avaliação de evidências no campo da tecnologia educacional.

Os resultados desta revisão reforçam que a integração intencional de soluções baseadas em IA em ambientes de aprendizagem *on-line* pode contribuir significativamente para o aprimoramento do desempenho acadêmico, do engajamento e da autorregulação dos estudantes. Esses achados, ainda que promissores, devem ser aplicados com cautela na formação docente e na gestão educacional, visto que sua generalização depende de maior consistência metodológica e validação em múltiplos contextos.

Do ponto de vista das políticas públicas e institucionais, recomenda-se o incentivo à adoção ética e contextualizada da IA na educação, com investimento em infraestrutura digital, inclusão tecnológica e desenvolvimento docente.

Referenciais como os propostos por Li et al. (2022) e Santos et al. (2023) indicam que o sucesso da IA educacional depende da articulação entre política, prática pedagógica e suporte técnico.

Quanto às pesquisas futuras, permanecem lacunas importantes. Faltam artigos com maior rigor metodológico, delineamentos longitudinais, e maior diversidade cultural e geográfica. Temas sensíveis como privacidade de dados, equidade no acesso e impactos psicossociais do uso intensivo de IA ainda são subexplorados. O avanço do campo depende da superação dessas fragilidades metodológicas, o que permitirá estimativas mais precisas, inferências causais robustas e recomendações práticas mais confiáveis.

4.5 Conclusão da RS

Esta revisão sistemática e meta-análise exploratória confirma que intervenções baseadas em inteligência artificial estão associadas a ganhos estatisticamente significativos no desempenho acadêmico de estudantes em cursos *on-line*. Os tamanhos de efeito combinados e a consistência dos resultados entre diferentes contextos reforçam o potencial da IA para promover aprendizagem personalizada, maior engajamento comportamental e afetivo, e adaptação curricular em múltiplos níveis de ensino (Suh, 2025; Al-Zahrani et al., 2025; Ode et al., 2025).

Esses resultados sugerem que a IA não apenas complementa estratégias pedagógicas tradicionais, mas pode catalisar modelos de ensino mais responsivos, centrados no estudante e orientados por dados. O uso da IA potencializa práticas de *feedback* em tempo real, personalização de trajetórias de aprendizagem e suporte à autorregulação dos alunos, desde que fundamentado em evidências de qualidade moderada (conforme avaliação GRADE) e implementado de forma ética, inclusiva e sensível às especificidades de cada contexto educacional.

Ainda assim, persistem desafios importantes, especialmente no que diz respeito à heterogeneidade metodológica dos estudos e à necessidade de expandir investigações para contextos historicamente menos explorados, sobretudo aqueles marcados por vulnerabilidade social e desigualdade digital.

Entre as principais limitações observadas, destacam-se o predomínio de amostras pequenas, a ausência de grupos controle em metade dos trabalhos incluídos e a escassez de dados longitudinais, o que compromete a robustez das inferências causais e limita a avaliação de efeitos de longo prazo.

Essas questões impõem cautela à generalização dos resultados e ressaltam a importância da contextualização na aplicação das tecnologias de IA na educação. O avanço do campo depende da produção de evidências mais diversas, rigorosas e éticas, bem como de iniciativas que priorizem a equidade na integração da IA ao ensino *on-line*.

Por fim, recomenda-se que futuras investigações priorizem: (i) delineamentos randomizados, que permitam inferências causais mais robustas; (ii) avaliação de efeitos de longo prazo, focando a retenção e a transferência do conhecimento; e (iii) análises interseccionais dos impactos, considerando marcadores como gênero, território e perfil socioeconômico dos participantes. O avanço sustentável do campo requer ainda esforços colaborativos para padronizar metodologias de avaliação, fortalecer a transparência dos dados e promover a integração ética da IA em diferentes realidades educacionais. Assim, esta síntese não apenas consolida o conhecimento atual, mas também estabelece bases sólidas para a próxima geração de investigações e inovações em educação digital mediada por IA, incentivando o desenvolvimento de práticas pedagógicas mais personalizadas, inclusivas e fundamentadas em evidências.

4.6 Integração das Evidências: Alinhamento entre Resultados da Revisão Sistemática e a Investigação sobre o *Wizard User*

A conclusão desta revisão sistemática representa mais que um fechamento metodológico; é o ponto de inflexão que conecta a análise das evidências internacionais ao núcleo investigativo desta tese, a concepção e validação do modelo *Wizard User*. Ao examinar o impacto da IA no desempenho acadêmico, identificaram-se padrões de eficácia, lacunas metodológicas e oportunidades de aplicação que dialogam diretamente com a questão central desta investigação: como um modelo de mediação pedagógica, apoiado por IA, pode personalizar e potencializar a aprendizagem em ambientes virtuais.

Os resultados obtidos na revisão sistemática, especialmente no que se refere à personalização adaptativa, ao aumento do engajamento e à melhoria de indicadores de desempenho, fornecem uma base empírica robusta para a formulação do modelo do *Wizard User*. Ao mesmo tempo, as limitações identificadas, como a escassez de estudos longitudinais, a heterogeneidade de métricas e a predominância de delineamentos quase experimentais, reforçam a necessidade de avançar para abordagens mais integradas e metodologicamente consistentes, como a proposta que será apresentada nos capítulos seguintes.

Este alinhamento entre evidência e inovação sustenta a transição do plano teórico para o experimental, estabelecendo não apenas as premissas que orientam o modelo, mas também o compromisso desta tese com a produção de conhecimento aplicável, ético e contextualizado.

Capítulo 5 – Metodologia da Investigação

"Não há ensino sem pesquisa e pesquisa sem ensino."

Paulo Freire

O capítulo apresenta o caminho metodológico adotado para estruturar, aplicar e validar o modelo *Wizard User*. Parte-se da investigação prévia, que identificou deficiências tecnológicas e pedagógicas em cursos *on-line*, e da Revisão Sistemática da Literatura, que mapeou avanços e limitações do uso da inteligência artificial na educação. Esses dois pilares fundamentaram as escolhas técnicas e o desenho da abordagem metodológica.

A seguir, descrevem-se a opção pelo *Design-Based Research (DBR)*, suas etapas de aplicação no contexto real da instituição, a composição dos grupos experimentais e de controle, os critérios de amostragem, o período de implementação e os métodos de análise qualitativa e quantitativa. O objetivo é permitir que o leitor compreenda a lógica da investigação e como cada fase contribuiu para a avaliação e aprimoramento do modelo.

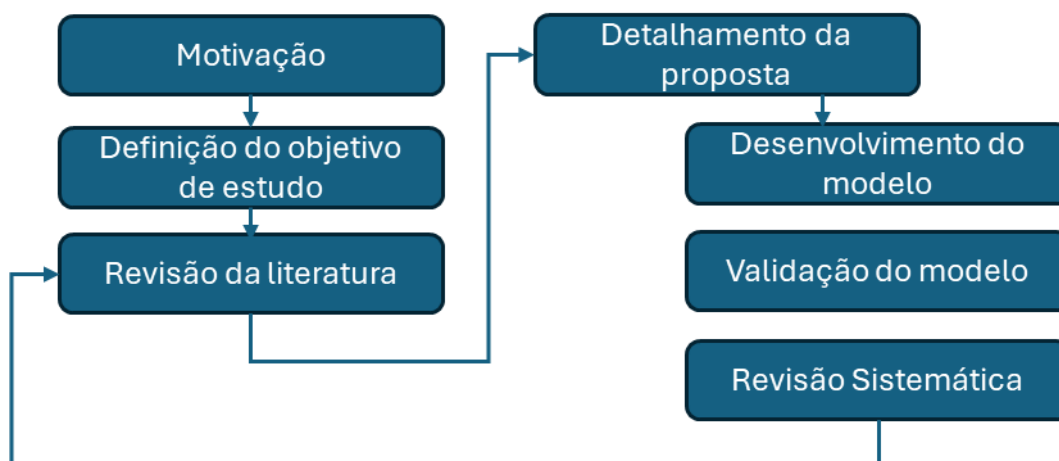
5.1 Abordagem, Estrutura e Etapas da Investigação

A definição de uma metodologia de investigação é um passo crucial para garantir a coerência, a consistência e a validade científica de um estudo. Antes de descrever os procedimentos adotados nesta tese, é necessário compreender que a metodologia não é apenas um conjunto de técnicas, mas sim um plano estruturado que orienta o caminho a ser percorrido pelo pesquisador, desde a coleta até a análise dos dados, sempre em alinhamento com os objetivos definidos. Trata-se, portanto, de uma etapa estratégica que conecta a fundamentação teórica com as ações práticas da pesquisa, assegurando que cada decisão metodológica seja fundamentada e alinhada ao propósito central da investigação.

De acordo com Marconi e Lakatos (2018), o planejamento metodológico é o momento em que o pesquisador define os procedimentos necessários para alcançar os objetivos da pesquisa, ou seja, é o momento em que se determina o caminho que será percorrido para coletar e analisar os dados (p. 60). Para isso, é fundamental que sejam estabelecidos objetivos claros e bem definidos, de acordo com a relevância e originalidade do tema estudado, bem como com os recursos disponíveis (Marconi & Lakatos, 2017). Além disso, é preciso ter em mente que a metodologia escolhida deve ser compatível com os objetivos e questões de pesquisa, e que o planejamento metodológico deve ser flexível o suficiente para permitir ajustes ao longo do processo de pesquisa (Cervo & Bervian, 2017).

Com base nessas premissas, o Capítulo 1 apresentou a motivação do autor, o objeto de estudo, a problematização, a relevância, os objetivos e as questões de pesquisa. O Capítulo 2 abordou o referencial teórico e incluiu a Revisão Sistemática da Literatura (RSL), a qual mapeou os avanços e limitações da aplicação de inteligência artificial na educação, oferecendo um panorama atualizado que reforça a relevância e o enquadramento da proposta desta tese. O Capítulo 3 apresentou os resultados da investigação prévia, que serviram de base para a concepção inicial do modelo *Wizard User*. A Figura 5.1 ilustra a organização metodológica adotada, evidenciando o que já foi abordado e o que será desenvolvido nas próximas seções.

Figura 5.1 – Esquema da organização metodológica



Fonte: Elaborada pelo autor.

Para compreender melhor a opção pelo *Design-Based Research (DBR)* como abordagem central desta investigação, é importante destacar que seu objetivo principal é o desenvolvimento e o aprimoramento de intervenções educacionais por meio de uma combinação de teoria e prática (Barab & Squire, 2004). Nessa perspectiva, o DBR permite a criação de intervenções mais eficazes, concebidas e testadas em contextos educacionais reais, contribuindo para o aprimoramento e a validação das teorias que as sustentam (Reeves, Herrington & Oliver, 2005). Além disso, trata-se de uma metodologia amplamente utilizada em pesquisas nas áreas de educação e tecnologia, pois possibilita soluções alinhadas às necessidades do contexto educacional contemporâneo (Collins, Joseph & Bielaczyc, 2004; Wang & Hannafin, 2005).

A escolha pela metodologia *DBR* nesta tese se justifica pela necessidade de desenvolver uma intervenção educacional efetiva diante das mudanças no cenário educacional e das demandas contemporâneas. Tal abordagem reúne vantagens qualitativas e quantitativas no desenvolvimento de aplicações educacionais (Matta, Silva & Boaventura, 2014; Denzin, 2005), considerando diferenças contextuais e favorecendo a resolução de problemas. À luz dos desafios recentes, intensificados durante a pandemia, reforça-se a importância de modelos metodológicos abertos e flexíveis, capazes de sustentar investigações robustas baseadas em dados comportamentais, reações e autodeclarações dos

participantes, de modo a produzir uma narrativa fidedigna às representações investigadas, como ratifica Morgado (2012, p. 120).

Segundo Wang e Hannafin (2005, p. 2), o *DBR* é uma metodologia flexível, mas com o objetivo de melhorar práticas educacionais por meio de análise, *design*, desenvolvimento e implementação interativos, com base na colaboração entre pesquisadores e profissionais em contextos reais, promovendo a interação entre teoria e prática. Easterday, Lewis & Gerber (2014) destacam que o uso processual do *DBR* integra *design* e métodos científicos, potencializando a geração de intervenções educacionais e a acurácia na resolução de problemas individuais e/ou coletivos. Essa integração também é reforçada por Akker, Gravemeijer, Mckenney e Nieveen (2006), que defendem a articulação entre teorias e modelos teóricos com práticas testadas em ambientes reais de aprendizagem.

No contexto desta tese, a investigação prévia apresentada no Capítulo 3 serviu como base para a concepção inicial do modelo *Wizard User*, identificando lacunas e necessidades que demandavam uma solução personalizada. Em um momento posterior, os achados da revisão sistemática (Capítulo 4) ofereceram evidências científicas complementares, permitindo ratificar as escolhas técnicas do modelo. A seleção das técnicas empregadas, como sistemas de tutoria inteligente, algoritmos de recomendação e estratégias preditivas via mineração de dados foi pautada em estudos que apontam tais abordagens como as mais promissoras para personalização e engajamento no ensino-aprendizagem *on-line* (Holmes et al., 2019; Zawacki-Richter et al., 2019). Dessa forma, a revisão sistemática não apenas cartografou avanços e limitações da aplicação de IA na educação, como também alinhou as decisões funcionais do *Wizard User* com as melhores práticas e recomendações extraídas da literatura científica, garantindo suporte no estado da arte internacional (Page et al., 2021).

A adoção do *DBR* nesta investigação permitiu construir e validar o *Wizard User* em ambiente autêntico, com envolvimento ativo do público-alvo. Essa abordagem viabilizou ciclos iterativos de “análise–*design*–implementação–avaliação”, garantindo responsividade às demandas práticas sem perder o rigor científico.

Em síntese, o percurso metodológico articula o *DBR* a dois eixos analíticos complementares: o qualitativo (grupos focais) e o quantitativo (indicadores de desempenho acadêmico), conforme detalhado no Capítulo 7. A Revisão Sistemática (RS), apresentada no Capítulo 4, operou como camada transversal de evidências, conduzida após a coleta empírica para contextualizar e interpretar os achados, sem alterar os procedimentos de campo.


- **Encadeamento temporal e integração da RS**

Esta tese incorporou, na fase final, uma Revisão Sistemática da Literatura (RS), registrada no PROSPERO e relatada segundo PRISMA 2020. O propósito foi triangular os resultados empíricos e fortalecer a base teórica do estudo. A RS não modificou o desenho de coleta original; foi usada para interpretar resultados, identificar convergências e divergências com a literatura recente e derivar implicações para a evolução do modelo *Wizard User*. O protocolo, a pergunta de revisão e os critérios de elegibilidade constam do Capítulo 4, estabelecendo a ponte metodológica entre a fundamentação teórica e a discussão dos resultados.

5.2 Validação do ecossistema (Modelo *Wizard User*)

Para melhor entendimento do processo, apresenta-se na Figura 5.2 o fluxo das tarefas realizadas, com o detalhamento de cada etapa, seguindo os preceitos do DBR e incorporando práticas eficazes identificadas em investigações anteriores. As atividades foram conduzidas segundo os preceitos do DBR e boas práticas de investigações afins, assegurando coerência entre objetivos, procedimentos e evidências obtidas.

Figura 5.2 - Fluxo resumido do processo metodológico



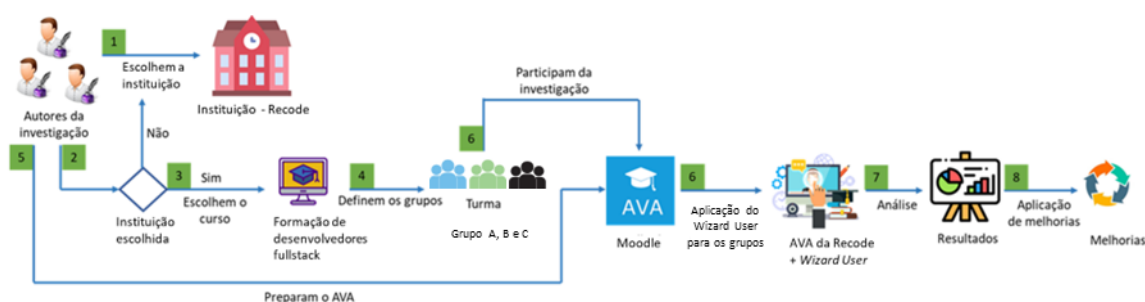
Fonte: Elaborada pelo autor.

O fluxo resumido do processo metodológico apresenta atividades importantes, sendo uma para a ratificação do problema central dessa tese e a outra para validação do modelo. Ambos detalhados a seguir.

Para validação dessa investigação, aplicou-se o *Modelo Wizard User* em uma disciplina *on-line*, utilizando-se o modelo de grupo controle, conforme exemplificado na Figura 5.3, apresentada a seguir.

Esse método de aplicação permite o estudo experimental com a utilização do recurso tecnológico (*Modelo Wizard User*) em um grupo e compará-lo a outro grupo, com as mesmas características, porém sem a utilização desse mesmo recurso tecnológico.

Figura 5.3 – Fluxo de validação do modelo



Fonte: Elaborada pelo autor.

Visando ao melhor entendimento do fluxo, apresentamos, a seguir, um detalhamento dos parâmetros definidos para essa investigação.

1. Escolha da instituição

Foi escolhido o Comitê para Democratização da Informática, conhecido como Recode (<https://recode.org.br>), que tem como missão transformar vidas por meio da tecnologia. A Recode é uma instituição social, sem fins lucrativos, com mais de 27 anos de atuação, está presente em 9 países com mais de 1.000 centros de empoderamento digital e já atingiu mais de 1.8 milhão de pessoas impactadas pela tecnologia. Em parceria com centros comunitários, escolas públicas e bibliotecas, a instituição oferece uma metodologia própria para desenvolver nos jovens habilidades digitais e competências socioemocionais, estimulando-lhes o protagonismo e o potencial da nova geração, como agentes de transformação social, por meio de formações tecnológicas.

2. Formação/programa selecionado para aplicação do modelo

Ao analisar as formações e projetos oferecidos pela Recode, entendeu-se que o Programa Recode Pro teria maior aderência ao modelo *Wizard User*, assim

como mais facilidade de adaptação das interações tecnológicas nos conteúdos oferecidos.

O programa Recode Pro visa à formação e à empregabilidade de pessoas de 18 a 39 anos, em situação de maior vulnerabilidade social e sem conhecimento em desenvolvimento de sistemas, como programadores *fullstack* e tem, como objetivo, dar a possibilidade, às pessoas em situação de vulnerabilidade social, de adquirirem conhecimento e desenvolverem uma carreira profissional na área de tecnologia.

Os objetivos específicos do Recode Pro são:

- ✓ Estimular o olhar crítico sobre as questões sociais, e empoderar para a busca de soluções sustentáveis e inclusivas, tendo a tecnologia como ferramenta;
- ✓ Oferecer preparação técnica para o trabalho em tecnologia e motivar o participante para a busca do desenvolvimento contínuo;
- ✓ Facilitar o desenvolvimento de habilidades socioemocionais e de competências para o século 21: empatia, autoconhecimento, resolução de problemas, colaboração, comunicação e criatividade;
- ✓ Propor a utilização dos conhecimentos adquiridos no desenvolvimento de projetos e aplicativos, voltados à solução de problemas sociais previamente identificados pelos próprios alunos;
- ✓ Simular experiência imersiva no mundo do trabalho;
- ✓ Conectar investidores de impacto, empregadores e educadores com o mesmo propósito;
- ✓ Acompanhar a carreira e o desenvolvimento dos ex-alunos, e procurar envolvê-los como exemplo para os participantes futuros.

Além do conteúdo técnico, são desenvolvidos temas como criatividade, comunicação, atuação profissional, e a metodologia proposta deste programa baseia-se na colaboração e na construção de projetos para a resolução de problemas sociais.

3. Escolha do curso

Como citado anteriormente, foi escolhida a formação de desenvolvedor *fullstack* pela aderência à proposta de investigação desta tese. A formação, em

pauta, apresenta uma extensa grade curricular, com mais de 300 horas de formação, divididas em 4 blocos, como se pode observar no anexo A.

Como escopo deste trabalho científico, escolheram-se 4 disciplinas para aplicação do modelo *Wizard User*, que foram HTML/CSS, *Javascript*, Banco de dados e Linguagem de programação em PHP. Essas disciplinas fazem parte do primeiro bloco ofertado aos estudantes. É importante destacar que tal escolha se deu por dois fatores: maior número de participantes por ser início do curso e, ainda, não haver evasão; e, por serem, normalmente, os conteúdos de maior dificuldade dos alunos, tendo em vista serem as primeiras disciplinas técnicas da formação.

4. Grupo de controle

Os alunos da formação foram separados em três grupos: o grupo A, composto pelos participantes que utilizaram exclusivamente o Modelo *Wizard User*, durante todo o tempo; o grupo B, composto pelos participantes que alternaram a utilização do Modelo *Wizard User* entre as disciplinas; e, o grupo C, composto pelos participantes que não utilizaram o Modelo *Wizard User* (grupo controle).

É importante destacar que a separação dos grupos ocorreu de forma aleatória, os conteúdos ministrados foram idênticos para os três grupos e a mediação pedagógica foi realizada pelo mesmo docente. Sendo assim, a única diferença entre os grupos estava na utilização do Modelo *Wizard User*.

5. Amostra

Este trabalho de pesquisa contou com a participação de 135 estudantes, distribuídos em 3 turmas. Havia, ainda, 1 tutor responsável por todas as 3 turmas, 3 monitores (cada turma com um monitor responsável) e 1 coordenador.

6. Preparação do AVA

Após as definições citadas, anteriormente, foi iniciada a fase de preparação do AVA usado pela Recode (*Moodle*), onde foi configurada a funcionalidade do *Wizard User* na plataforma e foram ativados os recursos cognitivos, exclusivamente, para os grupos controle. Durante o período de configuração do

modelo, o autor principal dessa investigação acompanhou todo o processo e suportou os usuários administradores, do AVA, nos eventuais erros e/ou dúvidas ocorridas.

É importante ressaltar que o Modelo *Wizard User* funciona no modelo de LTI¹², estando completamente apartado do AVA da Recode.

7. Período de aplicação do Modelo *Wizard User*

Para melhor coleta de informações e funcionamento dos recursos, foi definida a utilização do modelo *Wizard User* no período de 3 meses, que correspondeu ao tempo de conclusão de estudo para os conteúdos selecionados (HTML/CSS, JavaScript, Banco de dados e Linguagem de programação em PHP).

8. Análise dos resultados

Após o período de aplicação do modelo, foram realizadas as análises dos resultados que consideraram os depoimentos dos alunos dos grupos controle A, B e C, tanto dos professores quanto dos estudantes, bem como as evidências relacionadas à melhoria no desempenho dos alunos e ao engajamento dos participantes nas disciplinas. Esses resultados serão apresentados no capítulo de resultados, fornecendo uma visão geral do impacto do modelo nas disciplinas e nas percepções dos alunos e professores envolvidos.

É importante destacar que os dados qualitativos coletados nessa investigação foram analisados usando a técnica de Análise Comparativa, que é a técnica que envolve a comparação dos resultados obtidos em diferentes grupos, com o objetivo de identificar semelhanças e diferenças nas perspectivas e experiências dos participantes.

Para análise dos dados, foi escolhida a ferramenta NVivo, por apresentar recursos úteis para a análise temática de dados qualitativos, permitindo que o

¹² LTI – é um protocolo de integração de ferramentas externas de aprendizado com AVA. Esse protocolo permite que os alunos acessem as ferramentas diretamente no AVA, oferecendo uma experiência de uso similar à integração sistêmica. Os educadores, também, podem rastrear e analisar o progresso dos alunos de forma mais precisa, pois os dados das ferramentas externas são integrados ao AVA.

pesquisador crie códigos e categorias de análise para explorar temas específicos nos dados.

9. Pós-resultados

Foram analisadas as sugestões de melhorias, identificadas durante o processo de aplicação para incorporação na versão 1, do modelo *Wizard User*, que será disponibilizada em outras instituições de ensino que desejem utilizar a tecnologia.

Não fez parte dessa investigação a análise entre anos, assim como o comparativo de aproveitamento e/ou engajamento entre outras disciplinas do curso.

5.3 Associação com a investigação prévia

A associação entre a metodologia de investigação prévia e a metodologia da investigação principal, na pesquisa sobre cursos *on-line*, pode ser entendida como um processo complementar e iterativo, que permite a construção de uma base sólida de requisitos para o desenvolvimento e aprimoramento do *Wizard User*, assim como na obtenção de informações importantes sobre a carência de alunos e educadores que participam, com diferentes papéis, de cursos *on-line*.

Destaca-se que a investigação prévia teve como objetivo validar as principais deficiências tecnológicas dos cursos *on-line*. Como citado, este estágio inicial permitiu a identificação de áreas críticas, como problemas na qualidade do ensino, o processo de interação, o modelo de gestão da operação e a necessidade de melhorias gerais. Através da análise qualitativa e quantitativa desses dados, foi possível ratificar os principais desafios enfrentados no ensino *on-line* e coletar sugestões valiosas para melhorias sistêmicas.

Essas informações, coletadas e analisadas na fase de investigação prévia, serviram como alicerce para a formulação da metodologia da investigação principal. A adesão à metodologia de *Design-Based Research (DBR)* foi fundamentada na necessidade de desenvolver uma intervenção educacional – o modelo *Wizard User* – que respondesse efetivamente às deficiências identificadas na etapa preliminar. O *DBR*, caracterizado pelo seu foco no desenvolvimento e

teste de intervenções em contextos reais, permitiu não apenas a criação de soluções educacionais alinhadas com as necessidades detectadas, mas também a validação e o aprimoramento contínuo dessas soluções.

Essa metodologia principal desta tese, portanto, não só se baseou nos achados da investigação prévia para orientar o desenvolvimento e a implementação do modelo *Wizard User* mas, também, expandiu o entendimento sobre a eficácia de intervenções educacionais, por meio da IA, no contexto dos cursos *on-line*.

Por fim, o uso integrado de tais metodologias ilustra a importância da coleta e análise de dados preliminares para o desenho de intervenções educacionais robustas e contextualmente relevantes, e destaca a flexibilidade e o valor do *DBR* como abordagem para o desenvolvimento, teste e refinamento de soluções educacionais inovadoras.

5.3.1 Definição operacional dos grupos e intensidade de uso

Para a validação em ambiente real, os estudantes foram organizados em três grupos comparativos de acordo com a intensidade de uso do *Wizard User* no curso: Grupo A (alto uso), Grupo B (uso intermediário) e Grupo C (sem uso/controle). A definição operacional baseou-se nos registros de interação (*logs*) da plataforma e na disponibilidade efetiva do recurso por disciplina. Esse arranjo permitiu comparar desempenho e evasão sob diferentes níveis de mediação inteligente, conforme relatado no Capítulo 7.

Análise qualitativa

A análise qualitativa decorreu de grupos focais com estudantes e com a equipe pedagógica. As transcrições foram organizadas e codificadas no NVivo mediante análise temática, com desenvolvimento iterativo de *codebook* (ciclos abertos e axiais), produção de memos analíticos e auditoria interna para assegurar a rastreabilidade das decisões. Os achados qualitativos, apresentados no Capítulo 7 (subseções 7.4.1 a 7.4.8), são posteriormente integrados à leitura dos indicadores quantitativos na triangulação.

Análise quantitativa

Os dados acadêmicos foram organizados no Microsoft Excel e inspecionados visualmente (p.ex., histogramas) para avaliação inicial de distribuição e identificação de eventuais discrepâncias. A comparação entre grupos adota, como teste principal, um procedimento não-paramétrico (ver Plano estatístico), complementado por análises descritivas e visualizações (*boxplots*). Resultados são reportados com valores de p ($\alpha = 0,05$) e tamanhos de efeito apropriados ao método; quando pertinente, apresenta-se uma análise comparativa adicional por ANOVA de Welch (apenas como referência), preservando a primazia da abordagem não paramétrica.

Estratégia de triangulação

Os resultados são integrados por triangulação metodológica entre: evidências qualitativas (percepções e relatos), indicadores quantitativos (desempenho, reprovação, evasão) e a síntese da literatura proveniente da Revisão Sistemática. A triangulação serve para corroborar achados, explicar discrepâncias e derivar implicações para o aperfeiçoamento do modelo.

Reconhece-se a possibilidade de viés de confirmação decorrente da realização da Revisão Sistemática após a coleta empírica. Para mitigá-lo, foram adotadas salvaguardas: protocolo registrado no PROSPERO e relato conforme PRISMA 2020; critérios PICOC pré-definidos; e integração dos achados da RS apenas na discussão, preservando a separação analítica em relação aos dados empíricos.

Plano estatístico

Para assegurar coerência analítica, transparência e reprodutibilidade entre as perguntas de investigação, o desenho comparativo dos grupos (A, B e C) e a interpretação dos achados, este plano especifica previamente desfechos, critérios de decisão, estratégias de controle de multiplicidade e regras de tratamento de dados. A opção metodológica privilegia a interpretação substantiva, triangulada com as evidências qualitativas, sem renunciar ao rigor inferencial.

O desfecho primário é a média global por aluno (0 –10), obtida a partir das notas de ATV1, ATV2 e TF em cada disciplina e, em seguida, promediada entre as quatro disciplinas. Como desfechos secundários, consideram-se as médias por

disciplina para inspeção de consistência do padrão global. A família de hipóteses à qual se aplica o controle de multiplicidade corresponde às comparações entre os três grupos no desfecho primário.

A descrição dos dados inclui mediana, média, desvio-padrão e intervalo interquartil, acompanhados de *boxplots* para leitura de dispersão e potenciais *outliers*. Antes da inferência, examinam-se os pressupostos: Shapiro–Wilk para normalidade e Brown–Forsythe (variante de Levene baseada na mediana) para homogeneidade. Dado o afastamento da normalidade, o teste principal entre grupos é o Kruskal–Wallis ($\alpha = 0,05$, bilateral), com reporte da estatística e do valor de p (três casas decimais) e tratamento padrão de empates (ties). Em caso de rejeição global, realizam-se comparações par a par com correção de Holm (equivalente prático a Dunn/Holm), garantindo controle estrito do FWER. Para comparabilidade com literatura tradicional, pode-se apresentar ANOVA de Welch como leitura adicional, sem impacto sobre a decisão inferencial principal.

A magnitude do efeito é apresentada de modo complementar à significância: em comparações pares, reporta-se o delta de Cliff (δ) com IC95% obtidos por *bootstrap* ($B = 10.000$ reamostragens; semente = 2025); para o efeito global, reporta-se ϵ^2 de Kruskal–Wallis. Quando apropriado, explicitam-se limiares interpretativos (pequeno/médio/grande), ancorando a leitura substantiva.

As regras de dados são explícitas. A regra operacional de desistência é: Desistente = nota 0. Assim, Desistente (disciplina) = nota final 0 na disciplina, e Desistente (curso) = média global = 0 (todas as disciplinas com 0). Dados faltantes que não configuram desistência são tratados por exclusão por caso (*listwise*) na análise correspondente. *Outliers* permanecem, salvo confirmação de erro de registro, cuja correção é documentada no Apêndice D.

A multiplicidade é controlada por Holm dentro de cada família de hipóteses. Em todos os resultados, reportam-se valores de p , tamanhos de efeito e IC95%, com ênfase na leitura integrada dos achados. A reprodutibilidade é assegurada por planilhas e *scripts* disponibilizados no Apêndice D, executados em R 4.x (pacotes: *stats*, *car*, *rcompanion*, *effsize*, *boot*) ou Python 3.x (pacotes: *scipy*, *pinguin*, *numpy*), sob semente previamente definida (2025).

Por fim, são previamente especificadas análises de sensibilidade: (i) repetição das comparações excluindo “desistentes = 0”; (ii) teste de permutação para o desfecho primário como verificação não paramétrica adicional; e (iii) análise por disciplina para aferir robustez do padrão global.

Capítulo 6 – Modelo *Wizard User*

"Podemos construir um futuro muito mais brilhante, no qual os humanos sejam libertos de trabalhos repetitivos graças às capacidades da IA."

Andrew Ng

Este capítulo apresenta o processo de concepção, implementação e refinamento do *Wizard User*, fundamentado nas lacunas e oportunidades identificadas nas etapas anteriores desta investigação. A construção do modelo seguiu os princípios do *DBR*, permitindo o desenvolvimento iterativo em ambiente educacional real e a integração de evidências obtidas na investigação prévia. Serão descritas as decisões técnicas e pedagógicas que orientaram o desenho da solução, os critérios adotados para a seleção e adaptação das funcionalidades, bem como os procedimentos de prototipagem e testes. O objetivo é fornecer uma visão abrangente e coerente de como a proposta evoluiu do conceito inicial à aplicação prática, estabelecendo a base para a análise de sua eficácia nas etapas subsequentes desta tese.

6.1 Desenvolvimento do Modelo

O *Wizard User* foi concebido como um modelo tecnológico voltado a complementar e ampliar o trabalho do mediador pedagógico em cursos *on-line*, atuando como um recurso de apoio inteligente que alia fundamentos teóricos da educação a práticas avançadas de IA e *learning analytics*. Sua essência não se limita à automação de processos, mas à criação de um ecossistema que integra previsão, tutoria inteligente e recomendação educacional, transformando a experiência de aprendizagem em um processo mais personalizado, adaptativo e responsivo.

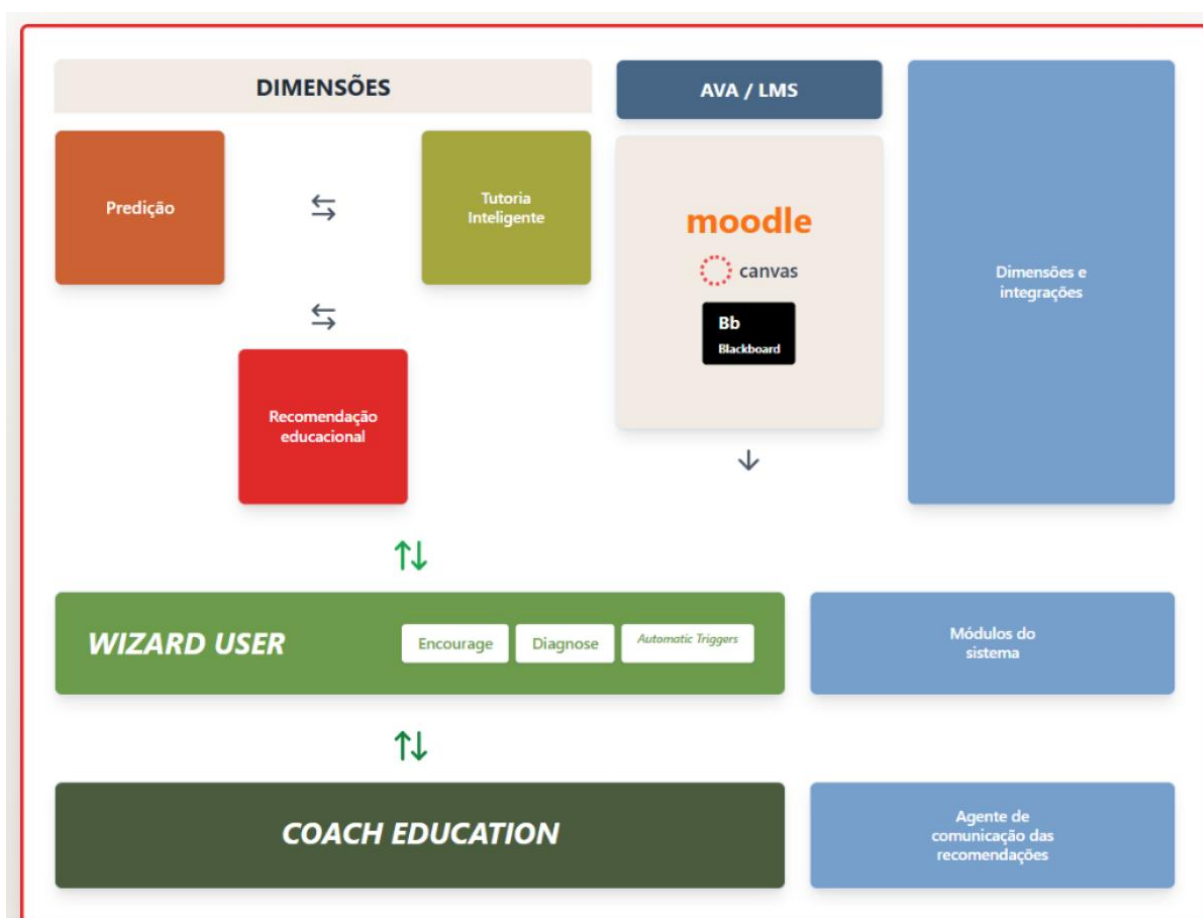
A proposta ancora-se em fundamentos clássicos da pedagogia e da psicologia educacional. Inspirado na teoria da mediação pedagógica de Vygotsky (1978), reconhece-se que o aprendizado ocorre essencialmente em contextos sociais e que a figura do mediador é determinante para o avanço do estudante na chamada zona de desenvolvimento proximal. Ao mesmo tempo, incorpora princípios da teoria da carga cognitiva (Sweller, 1988), que alerta para os limites da memória de trabalho, e da aprendizagem significativa de Ausubel (1963), que defende a relação entre novos conhecimentos e estruturas cognitivas preexistentes.

Esses fundamentos foram reinterpretados à luz de abordagens contemporâneas, como pesquisas recentes sobre personalização da aprendizagem em ambientes digitais (Holmes et al., 2022; Ifenthaler & Schumacher, 2023), que evidenciam que recursos baseados em IA não substituem o mediador humano, mas potencializam sua atuação, sobretudo em contextos de grande escala. Nesse sentido, o *Wizard User* busca oferecer apoio automatizado ao professor e trilhas de aprendizagem personalizadas ao estudante, ampliando tanto a eficácia pedagógica quanto a eficiência na gestão educacional.

A Figura 6.1 – Modelo conceitual do *Wizard User* apresenta a proposta integrada do sistema, organizada em três dimensões principais — Previsão, Tutoria Inteligente e Recomendação Educacional — articuladas aos AVA (*Moodle*, *Canvas*, *Blackboard*). Como ilustrado, essas dimensões funcionam como motores

analíticos do sistema: coletam, tratam e interpretam dados dos alunos, transformando-os em recomendações práticas comunicadas por meio de módulos especializados. O resultado é a geração de um *Coach Education*, um agente automatizado de apoio que desempenha papel semelhante ao de um “assistente de sucesso acadêmico”, fornecendo orientações personalizadas ao aluno e indicadores estratégicos ao professor e ao gestor.

Figura 6.1 – Modelo conceitual do Wizard




Fonte: Elaborada pelo autor

A Figura 6.2 – Núcleo Cognitivo do *Wizard User* aprofunda esse desenho, isolando as três dimensões que compõem o coração do modelo. Diferentemente de abordagens que tratam cada dimensão de forma isolada, aqui elas são articuladas em ciclo contínuo de coleta, análise e entrega de informação. A Predição identifica padrões e antecipa dificuldades; a Tutoria Inteligente interage com o estudante, oferecendo feedback contextualizado; e a Recomendação Educacional sugere conteúdos e atividades de acordo com o perfil e a trajetória

do usuário. As setas bidirecionais da figura simbolizam o caráter iterativo do modelo, que se retroalimenta constantemente com novos dados e refina suas recomendações.

Figura 6.2 – Técnicas de coleta, análise e entrega da informação



Fonte: Elaborado pelo autor.

Do ponto de vista pedagógico, esse desenho responde a um dos maiores desafios da educação digital contemporânea: o excesso de informações e recursos disponíveis. A abundância de materiais, combinada à variedade de ferramentas digitais, frequentemente sobrecarrega o estudante, que encontra dificuldade em identificar o que é mais relevante (Borges & Stiubiener, 2014; Gašević et al., 2020). O *Wizard User* se apresenta, portanto, como um filtro inteligente, ao mesmo tempo analítico e pedagógico, que organiza a informação e direciona o aluno de forma mais precisa.

Outro ponto crucial é o *design* modular, que garante escalabilidade e flexibilidade de implementação. Cada dimensão pode ser integrada de forma incremental aos AVA, explorando o protocolo *LTI* como via de comunicação com plataformas já consolidadas no ecossistema educacional (*IMS Global*, 2021). Essa decisão assegura não apenas a interoperabilidade técnica, mas também a sustentabilidade institucional, reduzindo barreiras de adoção.

O *Wizard User* não deve ser entendido como substituto do professor, mas como um mediador inteligente. Para o docente, oferece indicadores diagnósticos e recomendações de intervenção; para o estudante, organiza e personaliza conteúdos; para gestores, fornece visões consolidadas de desempenho. O modelo, assim, constitui um elo entre teoria pedagógica, arquitetura tecnológica e prática educacional.


Em síntese, o desenvolvimento do *Wizard User* materializa uma proposta que combina fundamentos pedagógicos, técnicas de IA/ML e ferramentas de análise de dados em um ecossistema integrado, representado nas Figuras 6.1 e 6.2. Essa visão sistêmica estabelece as bases para a exploração das dimensões específicas do modelo. A seguir, na seção 6.2 Interação e Predição, aprofunda-se a primeira dessas dimensões, evidenciando os métodos e técnicas empregados para a coleta, exploração e análise de dados oriundos dos AVA.

6.2 Interação e predição

A dimensão de predição no *Wizard User* foi concebida como a primeira camada de análise de dados capaz de antecipar padrões, identificar dificuldades e apoiar intervenções pedagógicas orientadas por evidências. Inspirada em estudos clássicos da mineração de dados educacionais (Berry & Linoff, 1997; Haykin, 1999; Hämmäläinen, 2011; Hämmäläinen & Vinni, 2011), a proposta integra técnicas de classificação, estimação e agrupamento (*clustering*) com abordagens contemporâneas de learning analytics baseadas em IA/ML (Papamitsiou & Economides, 2021; Ifenthaler & Schumacher, 2023).

A Figura 6.3 – Processo de coleta e análise de dados no *Wizard User* apresenta o fluxo adotado. Nele, dados de usuários são extraídos continuamente a partir de interações nos AVA, acessos, participação em fóruns, submissão de atividades, desempenho em avaliações, padrões de navegação e até indicadores de engajamento. Esses dados alimentam mecanismos de coleta estruturada, que funcionam como depósitos intermediários. Em seguida, aplicam-se algoritmos de exploração e análise, responsáveis por processar a massa de informações, identificar padrões e gerar resultados interpretáveis em termos pedagógicos. O ciclo é fechado quando os resultados retornam ao modelo sob a forma de indicadores ou recomendações, retroalimentando o processo.

Figura 6.3 – Processo de coleta e análise de dados no *Wizard User*



Fonte: Elaborado pelo autor.

Essa dinâmica aproxima-se da lógica defendida por Pieter Adriaans & Zantinge (1996), que concebe a predição como parte integrante da descoberta de conhecimento e não apenas como análise estatística descritiva. Ao adotar técnicas de mineração de dados educacionais, o *Wizard User* consegue identificar, por exemplo, perfis de risco de evasão, trajetórias de aprendizagem abaixo da média ou ainda grupos de estudantes com padrões similares de comportamento, fornecendo insumos estratégicos ao mediador pedagógico.

Um aspecto fundamental do modelo é que a predição não se limita a gerar relatórios estáticos, mas atua de maneira integrada às demais dimensões do *Wizard User*. Ao antecipar cenários prováveis, os algoritmos de ML oferecem subsídios tanto para a Tutoria Inteligente (seção 6.3) quanto para a Recomendação Educacional (seção 6.4). Isso significa que a predição funciona como gatilho de personalização, capaz de disparar intervenções automáticas, ajustar recomendações de conteúdo e orientar o professor sobre possíveis necessidades de intervenção.

Outro diferencial é a incorporação de técnicas híbridas que combinam análise descritiva, preditiva e diagnóstica. Estudos recentes demonstram que, em ambientes educacionais, apenas a predição não é suficiente: é necessário interpretar o porquê dos padrões (diagnóstico) e propor alternativas (recomendação) (Holmes et al., 2022; Ifenthaler & Schumacher, 2023). Nesse sentido, a dimensão de predição do *Wizard User* foi estruturada não apenas para antecipar resultados, mas também para dialogar diretamente com o módulo Diagnose (apresentado na seção 6.6), garantindo coerência sistêmica.

Como exemplificado na Figura 6.3, o processo de predição adota uma lógica cíclica: Coleta de dados => extração de interações do AVA; Processamento com algoritmos de ML => análise de padrões e agrupamentos; Exploração e interpretação => tradução em indicadores pedagógicos; e Resultados aplicados => retroalimentação em recomendações, tutoria e diagnósticos.

Esse fluxo torna a predição um dos pilares centrais do *Wizard User*, pois conecta dados brutos de interação a informações acionáveis, integrando a camada tecnológica às demandas pedagógicas.

Em síntese, a predição no *Wizard User* vai além da simples mineração de dados: constitui-se como um mecanismo de antecipação e mediação, que transforma dados educacionais em suporte concreto à aprendizagem. Ao estruturar essa dimensão, cria-se a base para a Tutoria Inteligente (seção 6.3), que utiliza os resultados preditivos para orientar diálogos, *feedbacks* e interações mais próximas da realidade do estudante.

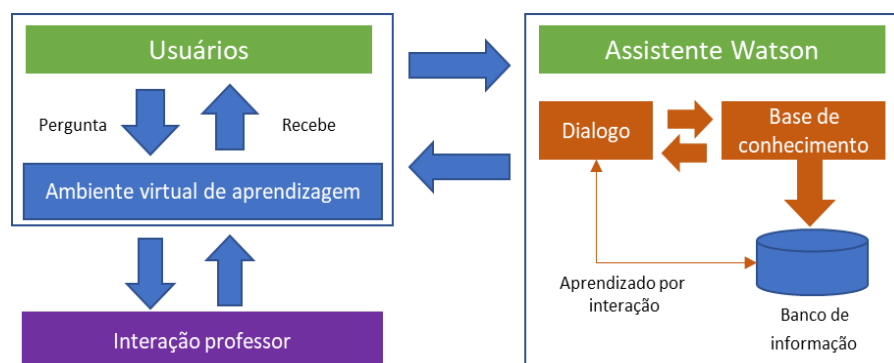
6.3 Tutoria inteligente

A dimensão de tutoria inteligente no *Wizard User* foi desenvolvida para aproximar a interação aluno-sistema da experiência de mediação pedagógica humana, oferecendo suporte dinâmico e personalizado às demandas dos estudantes. Essa proposta fundamenta-se em décadas de estudos sobre tutores inteligentes e *chatbots* educacionais, que demonstram que sistemas conversacionais, quando bem projetados, podem atuar como comediantes cognitivos, capazes de apoiar tanto a resolução de dúvidas pontuais quanto a orientação de processos de aprendizagem mais complexos (Woolf, 2009; Holmes et al., 2022).

A Figura 6.4 – Módulo de Tutoria Inteligente do *Wizard User* ilustra a arquitetura proposta. O módulo é composto por três elementos centrais:

- Coleta de interações nos AVA (fóruns, mensagens, registros de navegação, avaliações);
- Processamento com algoritmos de *PLN (Processamento de Linguagem Natural)*, que interpretam a linguagem do estudante;
- Resposta personalizada, estruturada a partir de bases de conhecimento e motores cognitivos, com *feedback* adaptado ao perfil do usuário.

Figura 6.4 - Módulo de Tutoria Inteligente do Wizard User



Fonte: Elaborado pelo autor.

Essa dinâmica de funcionamento confere ao tutor inteligente do *Wizard User* a capacidade de atuar como um *chatbot* cognitivo, que não apenas responde, mas aprende continuamente com a interação. Inspirado em experiências históricas, como o A.L.I.C.E. (Wallace, 2003; Cooper, Nam, & Si, 2012) e o ChatScript (Wilcox, 2017), o modelo supera as limitações de regras fixas, integrando técnicas contemporâneas de IA/ML que permitem adaptações em tempo real. A principal inovação, no entanto, está na utilização de serviços de IA cognitiva, especificamente o IBM Watson Assistant e o Watson Discovery, que oferecem APIs robustas e escaláveis para interpretação semântica e busca contextual em bases documentais.

Dessa forma, enquanto o *Watson Assistant* organiza os fluxos de diálogo e permite interações naturais em linguagem humana, o *Watson Discovery* amplia a resposta, conectando a dúvida apresentada a documentos e conteúdos relevantes já existentes no curso. Esse arranjo técnico torna a tutoria inteligente do *Wizard User* mais flexível e contextualizada, reduzindo a necessidade de programar manualmente respostas para cada situação.

Um diferencial importante é que o tutor inteligente não atua isoladamente: ele se conecta diretamente às dimensões de predição e recomendação. Assim, quando o sistema identifica, via predição, que um estudante apresenta risco de evasão ou baixo engajamento, o tutor pode iniciar interações proativas, enviando mensagens motivacionais, sugerindo materiais complementares ou acionando o professor para uma intervenção mais direcionada. Essa integração entre

dimensões confere ao *Wizard User* um caráter de sistema responsivo, no qual o fluxo de comunicação é constantemente ajustado com base nos dados coletados.

A implementação do módulo de tutoria inteligente dialoga com estudos recentes sobre o impacto de agentes conversacionais em educação, que apontam ganhos significativos em engajamento, motivação e desempenho quando os *chatbots* são integrados aos AVA de forma transparente (Kuhail et al., 2023; Ifenthaler & Schumacher, 2023). Nesse contexto, a escolha pelo protocolo LTI garante interoperabilidade com diferentes plataformas educacionais, permitindo que o estudante interaja com o tutor sem precisar sair do ambiente de aprendizagem.

Outro aspecto relevante é o uso de estratégias de feedback adaptativo. Ao invés de respostas genéricas, o tutor do *Wizard User* ajusta suas mensagens de acordo com o perfil do usuário: um estudante iniciante recebe explicações detalhadas e exemplos simples; um estudante avançado recebe respostas mais sintéticas e *links* para materiais complementares. Essa lógica está alinhada à teoria da aprendizagem significativa de Ausubel (1963) e às práticas recentes de *learning analytics* prescritiva (Gašević et al., 2020).

Como destacado na Figura 6.4, o módulo funciona como uma ponte entre dados e ação pedagógica, interpretando as interações do estudante e transformando-as em oportunidades de apoio em tempo real. Ao combinar IA cognitiva, ML preditivo e protocolos de interoperabilidade, o *Wizard User* oferece uma tutoria inteligente que não se limita a automatizar respostas, mas amplia a mediação pedagógica, fortalecendo a autonomia do estudante e reduzindo barreiras cognitivas.

Em síntese, a tutoria inteligente do *Wizard User* materializa-se como um agente cognitivo integrado, que alia técnicas clássicas de tutores inteligentes às possibilidades abertas por serviços de IA de última geração. Essa dimensão amplia a interatividade do sistema e assegura que a personalização não se restrinja a recomendações de conteúdo, mas alcance também o diálogo educativo e o acompanhamento contínuo.

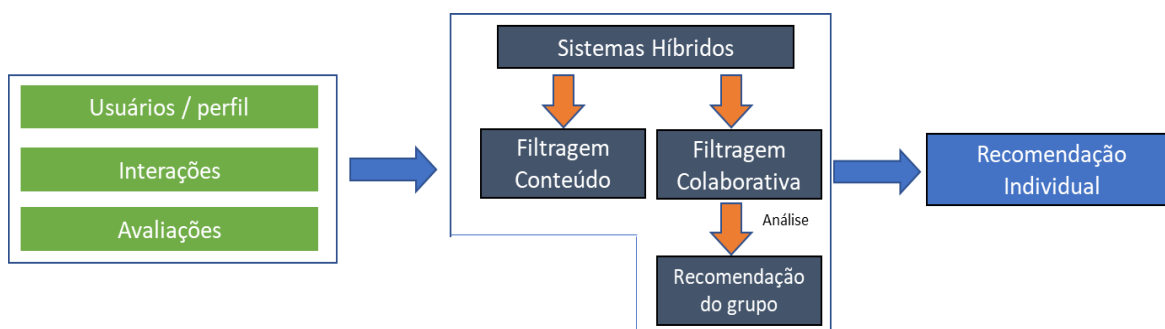
Essa visão prepara o terreno para a próxima seção, 6.4 Recomendação Educacional, onde são detalhados os mecanismos que permitem ao *Wizard User* sugerir conteúdos, atividades e trilhas de aprendizagem personalizadas, consolidando a integração entre predição, tutoria e recomendação como pilares centrais de seu funcionamento.

6.4 Recomendação educacional

A dimensão de recomendação educacional do *Wizard User* foi projetada para atuar como filtro inteligente de informações, selecionando e sugerindo conteúdos, atividades e recursos pedagógicos mais adequados ao perfil e às necessidades de cada estudante. Esse componente do modelo responde a um dos grandes desafios contemporâneos da educação digital: o excesso de materiais e ferramentas disponíveis nos AVA, que frequentemente gera sobrecarga cognitiva e dificulta a tomada de decisão pelos alunos e mediadores pedagógicos (Borges & Stiubiener, 2014; Gašević et al., 2020).

A Figura 6.5 – Arquitetura do Módulo de Recomendação Educacional do *Wizard User* apresenta a lógica estruturante desse processo. O fluxo inicia-se na coleta de dados analíticos oriundos do AVA, registros de acesso, tempo de permanência em páginas, resultados em avaliações, participação em fóruns e navegação por recursos multimídia. Esses dados, combinados a informações de perfil estático (curso, disciplina, histórico acadêmico), alimentam motores de análise baseados em ML. Em seguida, os algoritmos processam os dados por meio de diferentes estratégias de recomendação, produzindo resultados que se materializam em sugestões personalizadas ao estudante, indicadores para o professor e relatórios consolidados para gestores.

Figura 6.5 - Arquitetura do Módulo de Recomendação Educacional do Wizard User



Fonte: Elaborado pelo autor.

Do ponto de vista conceitual, os Sistemas de Recomendação (SRs) são tradicionalmente categorizados em três abordagens principais:

- Colaborativa (SRC) – baseia-se na similaridade entre perfis de usuários, identificando padrões coletivos de preferência (Resnick & Varian, 1997);
- Baseada em Conteúdo (SRBC) – foca nas características dos objetos de aprendizagem, sugerindo materiais relacionados ao histórico do próprio estudante (Pazzani & Billsus, 2007);
- Híbrida (SRH) – combina as duas abordagens anteriores, explorando vantagens complementares e mitigando limitações como o problema de *cold start* (Burke, 2002; Desrosiers & Karypis, 2011).

O *Wizard User* adota a abordagem híbrida como núcleo de seu mecanismo de recomendação. A filtragem colaborativa permite que o sistema sugira materiais baseados em trajetórias de estudantes semelhantes, enquanto a filtragem baseada em conteúdo garante alinhamento às interações e preferências individuais. Essa combinação, representada na Figura 6.5, assegura maior precisão e relevância pedagógica, além de reduzir vieses e lacunas comuns em modelos unidimensionais.

Estudos recentes reforçam a pertinência dessa escolha. Biørn-Hansen et al. (2017) destacam que a hibridização aumenta significativamente a qualidade das recomendações em contextos de aprendizagem, sobretudo quando os dados disponíveis apresentam alta heterogeneidade. Mais recentemente, trabalhos como Zhang et al. (2023) e Kuhail et al. (2023) apontam que sistemas híbridos

aplicados a AVA favorecem tanto a retenção dos estudantes quanto a personalização adaptativa em larga escala.

- Outro diferencial do *Wizard User* é a integração da recomendação educacional com as dimensões de predição e tutoria inteligente. Por exemplo:
 - se a predição identificar risco de evasão, o sistema pode recomendar conteúdos de reforço ou atividades de engajamento imediato;
 - se a tutoria inteligente detectar dúvidas frequentes sobre determinado conceito, o motor de recomendação pode priorizar materiais complementares ou vídeos explicativos;
- Para professores, são gerados *insights* analíticos que apontam quais recursos são mais eficazes para determinados perfis de alunos.

Esse desenho fortalece a visão de recomendação contextualizada, que não apenas entrega sugestões isoladas, mas articula o conteúdo recomendado com as demais dimensões do sistema, assegurando coerência e relevância educacional.

- Como sintetizado na Figura 6.5, o processo pode ser descrito em quatro etapas:
 - Coleta de dados – interações e histórico no AVA;
 - Processamento via ML – aplicação de algoritmos colaborativos, de conteúdo e híbridos;
 - Geração de recomendações – conteúdos, atividades e indicadores;
 - Entrega personalizada – apresentação ao estudante, mediação ao professor e relatórios a gestores.

Essa dinâmica posiciona o *Wizard User* como um mediador inteligente de informação, reduzindo a dispersão causada pelo excesso de recursos e oferecendo apoio estratégico para professores e gestores. Ao mesmo tempo, potencializa a autonomia do estudante, que passa a acessar materiais ajustados ao seu ritmo, nível de conhecimento e preferências de aprendizagem.

Em síntese, a recomendação educacional no *Wizard User* amplia a personalização da aprendizagem, unindo rigor técnico de algoritmos de IA/ML com pertinência pedagógica. Ao integrar-se de forma orgânica às dimensões de

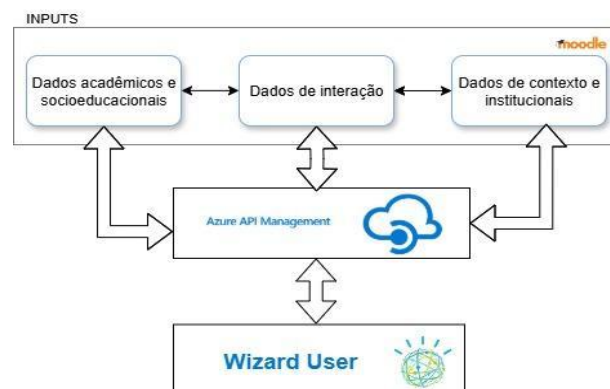
predição e tutoria inteligente, esse módulo consolida o modelo como um recurso capaz de transformar dados em ações educativas eficazes.

Essa visão nos conduz à próxima seção, 6.5 *Inputs*, na qual serão detalhados os dados de entrada que alimentam o modelo e que possibilitam o funcionamento integrado das dimensões descritas até aqui.

6.5 *Inputs*

O funcionamento do *Wizard User* depende de um conjunto estruturado de inputs, que alimentam os módulos analíticos e permitem a operacionalização das dimensões de predição, tutoria inteligente e recomendação educacional. Esses *inputs* não são meros dados brutos, mas refletem dimensões pedagógicas, tecnológicas e contextuais que, quando integradas, conferem ao modelo a capacidade de transformar interações dispersas em indicadores acionáveis e recomendações personalizadas.

Figura 6.6 - Estrutura dos inputs do Wizard User



Fonte: Elaborado pelo autor.

A Figura 6.6 – Estrutura de *Inputs* do *Wizard User* apresenta a organização desses elementos de entrada. Observa-se que os *inputs* se distribuem em três grandes categorias:

- **Dados de interação em AVA**

Incluem registros de *login*, acessos a conteúdos, tempo de permanência em atividades, participação em fóruns, envio de trabalhos e resultados em

avaliações. Esses dados constituem a base para análise de engajamento, detecção de padrões de comportamento e identificação de perfis de risco.

Como destacado em estudos recentes de *learning analytics* (Papamitsiou & Economides, 2021; Ifenthaler & Schumacher, 2023), os dados de interação são o insumo primário para gerar modelos preditivos de desempenho e evasão.

- **Dados de perfil acadêmico e socioeducacional**

Englobam informações cadastrais, histórico acadêmico, curso, disciplina e até mesmo indicadores de trajetória prévia.

Esses dados permitem contextualizar a análise das interações, evitando que as recomendações sejam feitas apenas em função do comportamento imediato, mas também levando em conta o percurso do estudante.

- **Dados contextuais e institucionais**

Abrangem metadados sobre o curso, objetivos de aprendizagem, calendários acadêmicos, metodologias de ensino aplicadas e metas institucionais.

A incorporação desses elementos permite alinhar as recomendações e diagnósticos do *Wizard User* não apenas ao perfil individual do estudante, mas também às diretrizes pedagógicas do curso e às políticas institucionais de ensino.

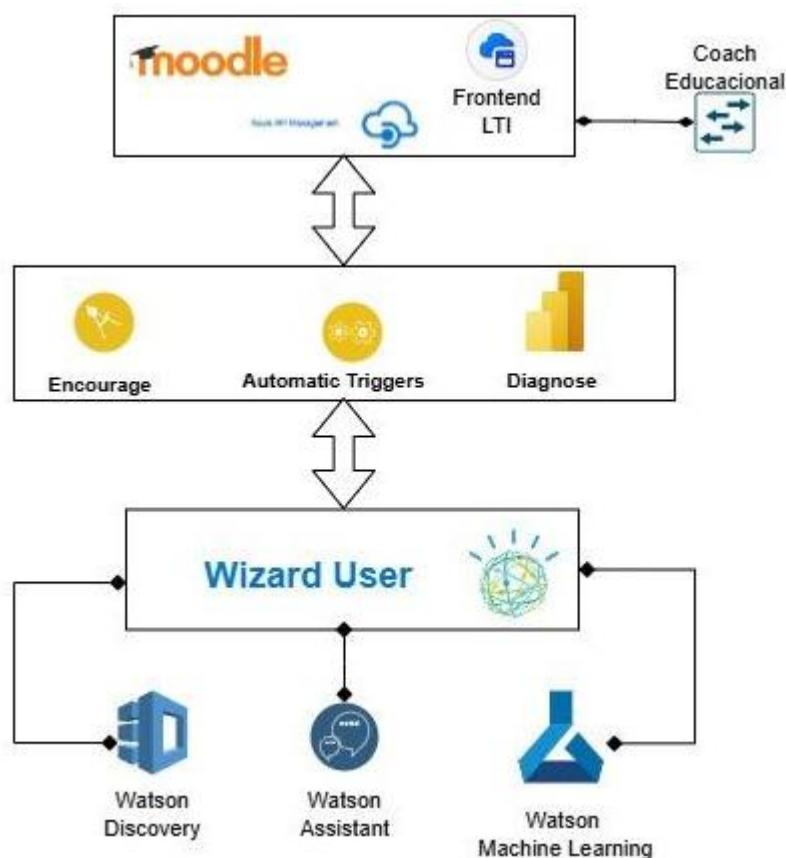
A integração desses *inputs* é mediada por algoritmos de ML, que processam os diferentes tipos de dados para extrair padrões, gerar indicadores e alimentar as dimensões de análise do modelo. O uso de protocolos como LTI garante que os *inputs* possam ser coletados de forma padronizada e interoperável, independentemente do AVA utilizado.

A Figura 6.6 evidencia ainda que os *inputs* não alimentam apenas os módulos do *Wizard User* de forma unidirecional. Ao contrário, o sistema adota um modelo de retroalimentação contínua, no qual os resultados produzidos pelas análises retornam ao ciclo de *inputs*. Por exemplo: se a recomendação sugere um novo conteúdo e o aluno o acessa, essa interação gera um novo dado de entrada, refinando o modelo preditivo e ajustando futuras recomendações.

Segregação de módulos

O *Wizard User* organiza-se em quatro módulos interdependentes que materializam o ciclo pedagógico-analítico do sistema: *Encourage*, *Automatic Triggers*, *Diagnose* e *Coach Education*. Em conjunto, esses módulos formam um ecossistema coeso em que a mediação pedagógica entre docentes e IA sustenta intervenções oportunas, diagnóstico contínuo e recomendações acionáveis. A Figura 6.7 sintetiza esse fluxo de ponta a ponta e serve como mapa visual para a leitura desta seção.

Figura 6.7 – Segregação de módulos do Wizard User



Fonte: Elaborado pelo autor.

Encourage

O módulo *Encourage* é o espaço de interação direta entre estudantes, professores e a IA cognitiva do sistema. Nele, dúvidas e comentários podem ser respondidos automaticamente pelo agente inteligente (via *chatbot* cognitivo integrado por APIs do *Watson Assistant* e *Discovery*) ou mediados pelo professor.

Essa dinâmica reforça a visão de mediação pedagógica, em que a IA amplia a capacidade de atendimento sem substituir a atuação docente. Além disso, o *Encourage* é o ponto de coleta de dados mais rico para alimentar análises de engajamento e recomendações posteriores.

Automatic Triggers

O módulo *Automatic Triggers* atua como um mecanismo de intervenções proativas. Baseado em dados de interação no AVA e nos registros capturados pelo *Encourage*, o sistema dispara ações automáticas, como alertas de baixo engajamento, sugestões de reforço ou notificações de prazos. Essa lógica de disparadores inteligentes está alinhada às práticas de learning analytics prescritiva (Gašević et al., 2020; Ifenthaler & Schumacher, 2023), em que os sistemas não apenas descrevem e predizem, mas também orientam ações pedagógicas em tempo real.

Diagnose

O módulo Diagnose organiza e apresenta indicadores analíticos derivados das dimensões anteriores. Esses indicadores permitem comparar o desempenho de estudantes, identificar padrões de sucesso ou risco, e sugerir mudanças na organização de estudos e práticas docentes. Para os mediadores pedagógicos, o Diagnose oferece visualizações comparativas que evidenciam rendimento individual, pontos de melhoria e recomendações de ação. Trata-se de um módulo estratégico, pois conecta a análise técnica à tomada de decisão pedagógica.

Coach Education

O *Coach Education* representa a culminância dos módulos anteriores, funcionando como agente de orientação personalizada. Ao consolidar os dados e análises do *Encourage*, *Automatic Triggers* e Diagnose, o *Coach* fornece recomendações concretas e acionáveis, direcionando estudantes para melhores práticas de estudo, professores para ajustes metodológicos e gestores para decisões institucionais. Esse módulo traduz em prática o conceito de assistente de sucesso acadêmico, aproximando o *Wizard User* de modelos internacionais de *adaptive learning* baseados em IA (Holmes et al., 2022).

Integração entre os módulos

A integração dos quatro módulos garante que o *Wizard User* não seja apenas um conjunto de ferramentas isoladas, mas um ecossistema coeso. Como ilustrado na Figura 6.7, o fluxo funciona de forma cíclica:

1. O *Encourage* coleta interações e dúvidas;
2. O *Automatic Triggers* interpreta e gera intervenções imediatas;
3. O *Diagnose* analisa dados agregados e constrói indicadores;
4. O *Coach Education* transforma diagnósticos em recomendações estratégicas;
5. Essas ações retroalimentam o *Encourage*, fechando o ciclo e iniciando novo processo de coleta.

Essa lógica garante adaptação contínua do sistema, característica central em ambientes educacionais mediados por *IA/ML*. Além disso, ao adotar protocolos *LTI*, os módulos podem ser integrados de forma incremental a diferentes AVA, assegurando interoperabilidade e escalabilidade institucional.

A segregação em módulos evidencia que o *Wizard User* vai além de uma arquitetura técnica: trata-se de um modelo pedagógico-analítico integrado, no qual a coleta de dados, a intervenção e a recomendação são partes de um ciclo unificado. Essa modularidade garante que o sistema possa ser expandido ou ajustado de acordo com as necessidades institucionais, preservando sua coerência metodológica.

Essa visão estabelece as bases para entendimento da próxima seção, 6.7 Arquitetura Tecnológica, na qual serão detalhadas as camadas arquiteturais, tecnologias específicas e integrações de infraestrutura que materializam os módulos descritos.

6.7 Arquitetura tecnológica

O *Wizard User* foi projetado sobre uma arquitetura em camadas, paradigma consolidado na Engenharia de *Software* pela capacidade de promover modularidade, escalabilidade e evolução contínua (Hudge, 2024). Mais do que uma decisão técnica, essa escolha foi fundamentada em evidências contemporâneas: Li et al. (2025) demonstraram a eficiência da arquitetura em

camadas e camadas verticais em sistemas móveis distribuídos, garantindo robustez frente a requisitos complexos; Zhang et al. (2024), por sua vez, evidenciaram como essa abordagem sustenta escalabilidade e resiliência em sistemas baseados em *Large Language Models*. Esses referenciais situam o *Wizard User* em consonância com práticas atuais de desenvolvimento de sistemas inteligentes.

A arquitetura definida não se limitou a replicar o modelo descrito na literatura, mas buscou reinterpretá-lo para o contexto educacional, articulando camadas conceituais a soluções tecnológicas concretas. A Tabela 6.1 explicita essa correspondência, mostrando como cada nível arquitetural foi traduzido em recursos que, combinados, asseguram coerência metodológica e consistência operacional.

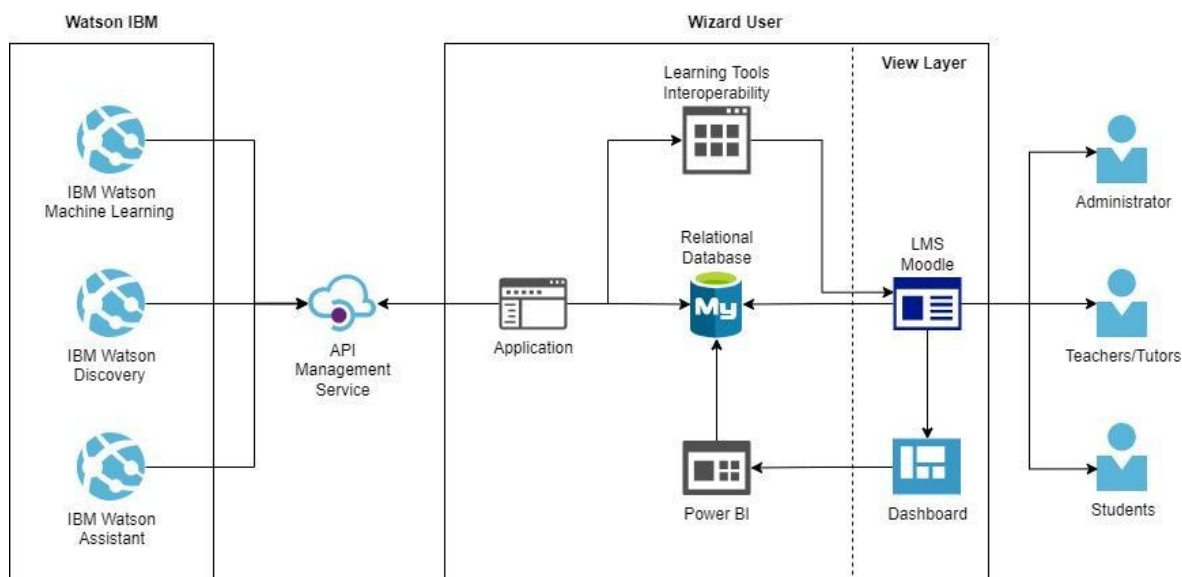
Tabela 6.1 – Correspondência entre Camadas Arquiteturais e Implementação no Wizard User

Camada Arquitetural	Implementação no Wizard User
Camada de Dados	Banco relacional <i>MySQL</i> 8.0 com acesso via <i>Entity Framework Core</i> .
Camada de Processamento	API em <i>.NET Core</i> responsável pelas regras de negócio e orquestração interna.
Camada de Modelagem/IA	APIs do <i>IBM Watson (Machine Learning, Discovery, Assistant)</i> para modelagem cognitiva e <i>PLN</i> .
Camada de Decisão	<i>Azure API Management</i> com políticas de autenticação (<i>JWT</i>), <i>rate limiting</i> e autorização por perfil.
Camada de Execução/Apresentação	Integração <i>LTI</i> com <i>Moodle</i> e painéis no <i>Power BI</i> para <i>dashboards</i> contextualizados por perfil.

Fonte: Elaborado pelo autor.

A tabela sintetiza o que a Figura 6.8 apresenta graficamente: uma arquitetura que conecta dados, processamento, inteligência cognitiva, decisão e apresentação em um fluxo integrado voltado à aprendizagem digital.

Figura 6.8 - Arquitetura técnica do Wizard User



Fonte: Elaborado pelo autor.

Conforme ilustrado na Figura 6.8, o núcleo cognitivo da aplicação foi estruturado em torno de três serviços do *IBM Watson*: *Machine Learning*, utilizado como motor preditivo para análises e geração de *insights*; *Assistant*, que permitiu a construção de fluxos conversacionais com usuários; e *Discovery*, responsável pelo processamento de linguagem natural e pela automação da recuperação de informações em documentos da base de conhecimento. Esses componentes foram escolhidos por oferecerem integração ágil e alto nível de confiabilidade, reduzindo a necessidade de desenvolvimento interno de algoritmos complexos de IA.

A governança das *APIs* foi assegurada pelo *Azure API Management*, que desempenhou papel central na autenticação, autorização e controle de tráfego, garantindo escalabilidade e segurança na comunicação entre a *API* em *.NET Core*, os serviços *Watson* e o ambiente *Moodle*. Essa decisão reforçou a confiabilidade do sistema e permitiu monitoramento centralizado, embora implique *trade-offs* como custos recorrentes e dependência de fornecedor (Alqahtani, & Alreshidi, (2020).

O *Moodle* foi adotado como ambiente virtual de aprendizagem de base, possibilitando tanto a gestão de cursos e usuários quanto a integração do *Wizard User* por meio do padrão *LTI*. Essa escolha assegurou uma experiência de uso

transparente, na qual docentes e discentes acessam os recursos diretamente pelo AVA, mantendo a coesão pedagógica.

Complementarmente, o *Microsoft Power BI* foi integrado como camada de visualização analítica, fornecendo *dashboards* adaptados aos diferentes perfis de usuários. Estudantes puderam acompanhar planos de estudo personalizados e comparativos com colegas de características semelhantes; professores tiveram acesso a indicadores de engajamento e desempenho; e gestores visualizaram métricas institucionais em tempo real, fortalecendo processos decisórios baseados em dados.

Por fim, o *Wizard User* articula esses elementos em uma solução unificada, desenvolvida em *.NET Core* no *backend*, com *frontend* em *ASP.NET* e persistência de dados em *MySQL*. Essa combinação sustenta a arquitetura em camadas delineada na literatura, mas reinterpretada para a educação digital, oferecendo não apenas viabilidade técnica, mas também relevância pedagógica. Ao integrar dados, processamento, inteligência cognitiva, governança e visualização em um mesmo ecossistema, o sistema materializa um modelo replicável de inovação em ambientes virtuais de aprendizagem.

6.8 Processo de desenvolvimento

O desenvolvimento do *Wizard User* configurou-se como uma empreitada metodologicamente complexa e pedagogicamente estratégica, conduzida de forma iterativa e incremental sob práticas ágeis contemporâneas da Engenharia de *Software*. Mais do que a implementação de funcionalidades, buscou-se estruturar um processo de construção crítico, capaz de sustentar a viabilidade operacional do sistema e, simultaneamente, sua legitimidade acadêmica enquanto modelo de inovação em AVA.

Organização do Desenvolvimento

O trabalho foi estruturado em 14 *sprints* quinzenais, perfazendo aproximadamente três meses e meio de execução. A opção pelo *framework Scrum* ultrapassou a dimensão pragmática e baseou-se em evidências recentes que destacam a efetividade da agilidade em projetos educacionais intensivos em tecnologia (Schwaber & Sutherland, 2020; VersionOne, 2022; Serrador & Pinto,

2023). As cerimônias implementadas *daily meetings*, *plannings* quinzenais de seis horas e *reviews* ao final de cada *sprint* não apenas garantiram visibilidade contínua do progresso, como também permitiram correções de rota rápidas, mitigando riscos de desalinhamento entre requisitos pedagógicos e decisões técnicas.

Diferentemente de abordagens tradicionais, centradas em cronogramas rígidos, o modelo ágil promoveu aprendizagem organizacional da equipe, composta por dois estagiários de Ciência da Computação supervisionados em regime de 20 horas semanais. Esse arranjo, embora modesto em número, mostrou-se suficiente para sustentar a cadência do projeto, validando estudos que apontam a efetividade de equipes pequenas e coesas em projetos de alta intensidade tecnológica (Moe et al., 2022).

O *Azure DevOps* foi adotado como plataforma de orquestração do fluxo de trabalho, permitindo a configuração de uma esteira de integração e entrega contínua com três estágios principais desenvolvimento, homologação e produção. Esse *pipeline* garantiu rastreabilidade de entregas, governança sobre artefatos críticos e alinhamento às boas práticas de *DevOps* em *EdTech* (Ebert et al., 2016; Humble & Kim, 2021).

Arquitetura Técnica e Decisões de Projeto

Na camada de *backend*, a escolha pelo *.NET Core* associada ao *Entity Framework Core* para interação com o banco de dados *MySQL 8.0* foi orientada por critérios de desempenho, portabilidade e integração institucional. Alternativas como *Node.js* ou *Django* foram consideradas, mas descartadas em razão da maturidade do ecossistema *Microsoft* já consolidado na organização, aspecto que favoreceu manutenção e curva de adoção da equipe, ainda que represente menor aderência às comunidades *open source* predominantes em soluções educacionais (Dragoni et al., 2017; Lewis et al., 2021).

A decisão de hospedar o *backend* em servidores *Linux* refletiu um compromisso com estabilidade operacional e custo-efetividade, considerando *benchmarks* recentes de eficiência energética e compatibilidade entre ambientes de execução (Zhang et al., 2020; Singh & Dutta, 2023). O *frontend*, implementado

em *ASP.NET* com recursos de HTML, CSS e JavaScript, foi hospedado em diretório separado, preservando a segregação lógica e reduzindo o risco de falhas cruzadas entre camadas.

No gerenciamento de APIs, adotou-se o *Azure API Management*, configurado com autenticação JWT, *rate limiting* e autorização por perfis de usuário. Essa decisão buscou mitigar riscos de sobrecarga, ataques de força bruta e problemas de escalabilidade, em consonância com recomendações do OWASP API Security Top 10 (2023). Ainda que tais práticas sejam comuns em ambientes corporativos, sua incorporação em um sistema acadêmico representa um diferencial em termos de maturidade e resiliência de arquitetura (Curto & Ríos, 2022).

A integração com o AVA foi realizada por meio do padrão *LTI*, estabelecido pelo *IMS Global*. Essa decisão garantiu interoperabilidade e aderência a padrões internacionais, condição crítica para a sustentabilidade e a escalabilidade de soluções educacionais (IMS Global, 2021). Do ponto de vista pedagógico, a integração via *LTI* permitiu que docentes e discentes acessassem o *Wizard User* de forma transparente, utilizando credenciais já registradas no *Moodle*, reduzindo barreiras cognitivas e favorecendo a adoção — aspectos amplamente reconhecidos como determinantes para engajamento em ambientes digitais (Sun et al., 2008; Chen et al., 2021).

Por fim, na camada de visualização, a integração com o *Microsoft Power BI* possibilitou *dashboards* dinâmicos e personalizados. Estudantes tiveram acesso a planos de estudo adaptados e comparativos com pares; docentes acompanharam engajamento e desempenho em tempo real; e gestores obtiveram indicadores institucionais, ampliando a tomada de decisão baseada em evidências. A adoção dessa ferramenta, embora limitada em customização frente a alternativas *open source* como *Superset*, foi justificada pela integração nativa ao ecossistema *Microsoft* já utilizado institucionalmente, reduzindo custos de treinamento e aumentando a aderência organizacional (Gašević et al., 2020; Ferguson, 2022).

Resultados Técnicos e Percepção dos Usuários

O processo de desenvolvimento resultou em um sistema robusto, interativo e validado empiricamente. Testes unitários cobriram 78% dos *endpoints* implementados, assegurando consistência funcional. Em ambiente de homologação, as métricas de desempenho indicaram tempo médio de resposta inferior a 400ms por requisição em cenários de até 500 usuários simultâneos, colocando a aplicação em patamar competitivo em relação a *benchmarks* de sistemas educacionais similares (Alario-Hoyos et al., 2017; Papamitsiou & Economides, 2021).

Do ponto de vista dos usuários, grupos focais exploratórios apontaram maior satisfação de docentes e gestores com a gestão de atividades, percepção de aumento da interatividade por parte dos estudantes e uma curva de aprendizagem reduzida devido à integração nativa ao *Moodle*. Esses achados corroboram pesquisas recentes sobre a importância da usabilidade e da integração transparente para a adesão a novas tecnologias educacionais (Ifenthaler & Schumacher, 2023).

O desenvolvimento do *Wizard User* transcendeu o caráter de simples produto tecnológico: configurou-se como um exercício de engenharia pedagógica, no qual decisões técnicas, da escolha do *framework* ao modelo de autenticação, tiveram implicações diretas sobre usabilidade, escalabilidade e aceitação pedagógica. Em termos acadêmicos, a experiência contribui ao debate sobre como metodologias ágeis e arquiteturas *cloud-native* podem ser traduzidas e adaptadas ao contexto da educação, especialmente em projetos que buscam personalização da aprendizagem mediada por IA. No plano prático, materializa-se como estudo de caso replicável, no qual tecnologia, pedagogia e governança digital convergem para a inovação em ambientes virtuais de aprendizagem.

Capítulo 7 – Resultados

"A mente que se abre a uma nova ideia jamais volta ao seu tamanho original."

Albert Einstein

O capítulo 7 apresenta os resultados sobre o impacto do modelo *Wizard User* no ensino-aprendizagem em um curso *on-line* de programação para jovens em situação de vulnerabilidade. A análise qualitativa, a partir de grupos focais com alunos, tutor, monitores e coordenação, evidenciou a relevância da ferramenta na interatividade, personalização do aprendizado e gestão educacional. Os relatos destacaram a clareza do material, o suporte em tempo real e recursos como indicadores preditivos e recomendações de conteúdo, consolidando o *Wizard User* como diferencial pedagógico.

A análise quantitativa reforçou esses achados, ao mostrar maior desempenho, menor reprovação e evasão entre os grupos que utilizaram a ferramenta. A triangulação entre percepções e dados numéricos comprovou que o *Wizard User* favoreceu o engajamento, a retenção e a eficiência educacional. Ainda assim, destaca-se a necessidade de estudos mais amplos, com amostras diversificadas, análises estatísticas robustas e diferentes contextos, para consolidar seu potencial como solução escalável em educação digital mediada por IA.

7.1 Contexto dos resultados

A análise dos resultados foi estruturada em duas frentes complementares. A primeira, qualitativa, foco central desta investigação, decorre da transcrição de dois grupos focais: (i) com estudantes e (ii) com o tutor da turma, os monitores e a gestora do programa *Recode Pro*. A segunda, quantitativa, de caráter confirmatório, baseou-se nos resultados acadêmicos e nos registros de participação de alunos e professores. Nas subseções seguintes, apresentam-se os procedimentos e os achados de ambas as frentes.

No processo de seleção de uma metodologia apropriada para a análise qualitativa dos dados coletados nesta tese, realizou-se uma avaliação meticulosa de diferentes abordagens e de autores de referência na área. Não se tratou de uma revisão superficial, mas de um estudo aprofundado, voltado a identificar uma estratégia que, além de se alinhar aos objetivos da investigação, oferecesse uma arquitetura analítica pragmática e adequada à natureza de grupos focais.

Dada a amplitude do campo de métodos qualitativos e a diversidade de propostas existentes, tornou-se imperativo proceder a uma comparação criteriosa. Para isso, elaborou-se um quadro comparativo que avalia cada abordagem quanto à aplicabilidade a grupos focais, foco, aderência e relevância para este estudo. O Quadro 7.1 apresenta os principais autores e abordagens considerados, bem como as razões para sua seleção ou não seleção.

Quadro 7.1 - Comparação de Autores e Abordagens em Pesquisa Qualitativa

Autor(es)	Foco Principal	Aplicabilidade para Grupos Focais	Justificativa para Exclusão/Inclusão
Anselm Strauss e Juliet Corbin	Desenvolvimento da <i>Grounded Theory</i> : uma metodologia para construir teoria a partir da análise de dados qualitativos	Moderada	Abordagem mais teórica e menos específica para grupos focais
Yvonna S. Lincoln e Egon G. Guba	Estabelecimento de critérios para a qualidade e confiabilidade em pesquisa qualitativa	Baixa	Abordagem generalista, não centrada em grupos focais
Kathy Charmaz	<i>Grounded Theory</i> Construtivista: uma interpretação da <i>Grounded Theory</i> que enfatiza a coconstrução de significados entre pesquisador e participante	Moderada	Não se alinha totalmente com o propósito específico deste trabalho
Norman K. Denzin e Yvonna S. Lincoln	Perspectiva ampla em pesquisa qualitativa, abordando uma variedade de métodos e técnicas	Baixa	Muito abrangente para os objetivos específicos desta pesquisa
Richard Krueger e Mary Anne Casey	Metodologia e análise específica para grupos focais, oferecendo técnicas e estratégias práticas de facilitação e interpretação	Alta	Abordagem específica e pragmática para grupos focais, alinhando-se idealmente com os objetivos e metodologia deste estudo de doutorado

Fonte: Elaborado pelo autor.

À luz da comparação apresentada no Quadro 7.1, adotou-se a abordagem de Krueger & Casey por combinar diretrizes operacionais de condução (planejamento do roteiro, seleção dos participantes, moderação e registro) com estratégias claras de análise (codificação temática, síntese por categorias e critérios de saturação). Essa combinação garante rastreabilidade das decisões analíticas, consistência entre grupos e coerência na interpretação, reduzindo vieses de moderação e assegurando auditabilidade por meio de trilha metodológica documentada. Além de oferecer um protocolo replicável e aderente ao desenho misto desta pesquisa, a abordagem favorece a triangulação com os resultados quantitativos, sustentando a robustez das inferências apresentadas nas subseções seguintes.

7.2 Detalhamento da amostra

Conforme descrito na Seção 4 (Metodologia da Investigação), esta pesquisa analisa a influência do *Wizard User* em disciplinas de um curso de desenvolvimento de sistemas (formação de desenvolvedor *full-stack*). A amostra totalizou 135 estudantes, distribuídos equitativamente em três grupos com diferentes níveis de exposição à ferramenta: Grupo A (uso integral), Grupo B (uso parcial) e Grupo C (sem uso), conforme Quadro 7.2.

Quadro 7.2 - Amostra da Investigação – Wizard User

Grupos	Qtd inicial de alunos	Qtd de alunos que terminaram o curso	Qtd de participantes do grupo focal	Percentual de uso do Wizard User
A	45	43	40	100% (4 disciplinas)
B	39	42	34	50% (2 disciplinas)
C	35	39	36	0% (0 disciplina)

Fonte: Elaborado pelo autor.

Para uniformizar a linha de base e assegurar comparabilidade entre os grupos, todos os participantes compartilharam as seguintes características: (i) faixa etária de 18 a 39 anos, delimitação estabelecida pelo programa *Recode Pro*, independente das decisões desta investigação; (ii) situação de vulnerabilidade social, também critério do programa; e (iii) ausência de conhecimento prévio em programação e desenvolvimento de sistemas. Esse delineamento minimiza vieses decorrentes de experiência anterior e reforça a validade interna das comparações.

A docência foi mantida constante ao longo das turmas, um tutor para todas, três monitores (um por turma) e um coordenador, reduzindo potenciais variações atribuíveis ao “efeito professor” e garantindo condições instrucionais equivalentes.

Composição dos grupos

- Grupo A - uso de 100% do *Wizard User*. 45 estudantes; 40 participaram do grupo focal; 43 concluíram os cursos (2 desistências). O uso foi integral nas disciplinas de HTML/CSS, JavaScript, Banco de Dados e Programação (PHP).
- Grupo B - uso de 50% do *Wizard User*. 45 estudantes; 34 no grupo focal; 42 concluintes (3 desistências). O uso concentrou-se em HTML/CSS e JavaScript (sem a ferramenta em Banco de Dados e Programação).
- Grupo C - sem *Wizard User*. 45 estudantes; 36 no grupo focal; 39 concluintes (6 desistências).

Em síntese, o delineamento amostral, com grupos equivalentes na linha de base, docência padronizada e graus distintos de exposição ao *Wizard User*, cria um cenário controlado para isolar efeitos da intervenção sobre engajamento e desempenho. A evasão total de 11 participantes ($\approx 8,1\%$) reduz o número efetivo e demanda cautela na generalização, mas não compromete a comparabilidade entre grupos. Com essa base, a próxima seção descreve o procedimento analítico qualitativo e, na sequência, apresentam-se os resultados quantitativos e sua integração interpretativa.

7.3 Passo a passo da preparação das análises qualitativas

Esta seção descreve o preparo e o protocolo analítico adotados para o tratamento dos grupos focais, ancorados na abordagem de análise de Krueger & Casey, complementada por princípios operacionais de Lapan (2012) para estudos aplicados. O objetivo foi assegurar rigor, rastreabilidade e consistência interpretativa.

O procedimento seguiu etapas encadeadas: (i) pré-leitura e higienização das transcrições; (ii) segmentação por unidades de sentido; (iii) construção do código inicial a partir de temas preliminares; (iv) codificação iterativa e refinamento do livro de códigos; (v) agregação em categorias/temas e subtemas;

(vi) verificação de concordância entre codificadores e resolução por consenso; e (vii) síntese interpretativa com seleção de evidências textuais representativas. A seguir, cada etapa é detalhada, explicitando critérios, decisões analíticas e controles de qualidade empregados.

- **Preparação e revisão preliminar do *corpus* qualitativo**

O objetivo desta etapa foi constituir um *corpus* único, padronizado e rastreável a partir das transcrições dos grupos focais, preparando-o para a análise temática. Inicialmente, realizou-se a verificação de integridade e completude das transcrições; em seguida, a segmentação por unidades de sentido (turnos de fala e tópicos), explicitando a arquitetura em diálogo estruturado entre entrevistador e participantes (alunos, tutor, monitores e coordenadora). O material foi então padronizado (marcadores de falante, metadados mínimos) e consolidado em um documento contínuo que preserva a ordem temporal das falas.

Com base nessa organização, procedeu-se à codificação preliminar e à elaboração do livro de códigos inicial, apoiados por memorandos analíticos para formar a trilha de auditoria (decisões, critérios de inclusão/exclusão e ajustes terminológicos). Como produtos, obtiveram-se: (i) um *corpus* unificado pronto para codificação aprofundada; (ii) uma matriz temática provisória (temas e subtemas candidatos); e (iii) registros de decisões que asseguram rastreabilidade e replicabilidade. Esse encadeamento de extração, padronização e tematização prévia sustenta as etapas analíticas apresentadas na subseção seguinte.

7.4 Análise qualitativa

A análise qualitativa dos documentos resultantes dos grupos focais permitiu construir um panorama consistente sobre as percepções dos diferentes atores envolvidos no processo de ensino-aprendizagem e na gestão da formação dos alunos. A leitura comparativa das transcrições revelou um conjunto de *insights* que articulam tanto a experiência dos alunos quanto as perspectivas do tutor, dos monitores e da coordenadora, compondo uma visão integrada da experiência de aprendizagem.

Para estruturar esse exame, foram elaborados quesitos de investigação, que orientaram a codificação das falas e possibilitaram agrupar as respostas de acordo com as perguntas norteadoras. Esses quesitos, apresentados no Quadro 7.3, refletem dimensões centrais do estudo: desde a experiência vivenciada no curso até percepções sobre indicadores preditivos e recomendações do *Wizard User*. Ressalta-se que, para o Grupo C, composto por alunos que não utilizaram a ferramenta, as perguntas sobre o recurso não foram aplicadas, a fim de preservar a consistência da coleta.

Esse processo de categorização foi essencial para garantir coerência analítica, permitindo que os dados fossem sistematicamente organizados em torno de dimensões comparáveis entre grupos. Assim, a análise não apenas captou impressões individuais, mas também evidenciou padrões e contrastes entre usuários e não usuários do *Wizard User*, conforme apresentado no Quadro 7.3.

Quadro 7.3 – Quesitos da Investigação

Itens de investigação		
Quesitos	Definições dos quesitos	Grupos utilizadores
Experiência vivenciada no curso	Identifica a percepção dos alunos sobre a trajetória de participação no curso de uma forma geral, considerando a interação com conteúdo, tutor, monitor e os recursos técnicos disponíveis.	Grupos A, B e C
Processo de interação	Identifica a percepção dos alunos sobre nível de interação entre os participantes, assim como as ferramentas possíveis de serem utilizadas e as metodologias a serem aplicadas.	Grupos A, B e C
Conhecimento adquirido	Identifica por meio de autodeclaração o aprendizado adquirido pelos alunos durante o processo de formação.	Grupos A, B e C
Diferencial no processo de aprendizagem	Identifica a percepção dos alunos sobre os pontos importantes que foram relevantes para o auxílio no processo de ensino-aprendizagem.	Grupos A, B e C
Uso de indicadores preditivos	Identifica a percepção dos alunos sobre a necessidade da existência de indicadores preditivos e a sua eficácia no processo de ensino-aprendizagem.	Grupos A e B
Recomendação de conteúdo pelo <i>Wizard User</i>	Identifica a percepção dos alunos sobre a relevância e a eficiência das recomendações realizadas pelo <i>Wizard User</i> .	Grupos A e B

Fonte: Elaborado pelo autor.

O Quadro 7.3 sistematiza os quesitos empregados na análise, descrevendo cada dimensão investigada e indicando os grupos aos quais foram aplicados.

Nota-se que os itens relacionados ao *Wizard User*, uso de indicadores preditivos e recomendações de conteúdo, restringiram-se aos Grupos A e B, uma vez que apenas esses participantes tiveram contato direto com a ferramenta. Essa distinção metodológica assegurou consistência na coleta e possibilitou comparações mais precisas entre usuários e não usuários.

A partir dessa estrutura, a seção subsequente apresenta a análise das percepções, destacando convergências e contrastes observados nas falas dos participantes.

7.4.1 Experiência vivenciada no curso

A análise inicial concentrou-se na experiência dos alunos ao longo da participação no curso, buscando compreender como vivenciaram a trajetória formativa em sua totalidade. O objetivo deste quesito foi identificar percepções relacionadas à interação com o conteúdo, ao suporte oferecido pelo tutor e pelos monitores, bem como ao uso dos recursos técnicos disponibilizados durante o processo de aprendizagem.

Os relatos demonstraram que a experiência dos participantes não se restringiu apenas ao contato com o material didático, mas envolveu também a mediação pedagógica, a clareza nas orientações e a qualidade dos canais de comunicação estabelecidos. Essas dimensões, combinadas, permitiram capturar a amplitude da vivência dos estudantes, revelando aspectos tanto positivos quanto pontos de atenção que impactaram sua motivação e engajamento.

Ao considerar essa perspectiva, foi possível traçar um panorama mais consistente sobre como os diferentes grupos perceberam a condução do curso. Esse olhar revelou nuances importantes da trajetória de aprendizagem e forneceu insumos relevantes para compreender de que forma os elementos organizacionais, pedagógicos e tecnológicos interagem na construção da experiência educacional.

7.4.2 Processo de Interação

O segundo eixo de investigação voltou-se para o processo de interação estabelecido entre os participantes ao longo do curso. A análise buscou

compreender não apenas a frequência das interações, mas também a qualidade das trocas, o papel desempenhado pelas ferramentas tecnológicas e a influência das metodologias de ensino sobre o engajamento coletivo.

As percepções dos estudantes revelaram que a interação foi elemento central para sustentar o aprendizado colaborativo, sobretudo quando associada a dinâmicas de grupo, fóruns de discussão e atividades que favoreciam a troca de experiências práticas. Em contrapartida, também foram identificados momentos de baixa participação, atribuídos à dificuldade de alguns alunos em se adaptar ao ambiente digital ou à pouca exploração de determinados recursos disponíveis.

Os relatos sugerem que o processo interativo se configurou como um espaço de construção compartilhada de conhecimento, no qual a participação ativa contribuiu para fortalecer vínculos entre os estudantes e ampliar a compreensão dos conteúdos. Essa perspectiva reforça a importância de estratégias pedagógicas que promovam diálogo, cooperação e estímulo à participação equitativa, minimizando barreiras tecnológicas e comportamentais que possam limitar o engajamento coletivo.

7.4.3 Conhecimento Adquirido

O terceiro eixo de análise concentrou-se na avaliação do conhecimento adquirido pelos participantes ao longo do curso, considerando as percepções declaradas sobre aprendizado, compreensão dos conteúdos e capacidade de aplicação prática. O objetivo foi identificar até que ponto as atividades propostas, a mediação pedagógica e os recursos tecnológicos favoreceram a consolidação de saberes relevantes para a formação.

Os relatos dos alunos apontaram que o curso contribuiu de maneira significativa para a ampliação de competências teóricas e práticas. Em especial, destacaram-se as experiências relacionadas ao uso do *Wizard User*, cujas recomendações personalizadas auxiliaram na organização do estudo e na seleção de materiais mais adequados às necessidades individuais. Além disso, a diversidade de metodologias aplicadas, combinando atividades síncronas e assíncronas, favoreceu diferentes estilos de aprendizagem, ampliando a possibilidade de retenção e aplicação dos conteúdos.

Entretanto, também foram observadas algumas limitações. Parte dos estudantes relatou dificuldades em transpor os conhecimentos adquiridos para situações concretas, especialmente em contextos que exigiam maior autonomia ou habilidades técnicas específicas. Essa percepção sugere que, embora o curso tenha promovido avanços importantes, ainda há espaço para o fortalecimento de atividades práticas que aproximem o aprendizado do ambiente real de aplicação.

De modo geral, os resultados evidenciam que a aquisição de conhecimento foi consistente e percebida como positiva pela maioria dos participantes, ainda que marcada por diferentes níveis de apropriação individual. Tal constatação reforça a importância de equilibrar recursos tecnológicos, estratégias pedagógicas e práticas contextualizadas, de modo a assegurar não apenas a compreensão conceitual, mas também a capacidade de mobilizar os saberes em situações de maior complexidade.

7.4.4 Diferencial no Processo de ensino-aprendizagem

Este eixo buscou compreender os aspectos percebidos como diferenciais no processo de ensino-aprendizagem, isto é, os elementos que mais impactaram positivamente a trajetória formativa dos alunos.

Os depoimentos revelaram que a personalização proporcionada pelo *Wizard User* foi considerada um dos pontos centrais, pois favoreceu maior direcionamento dos estudos e otimização do tempo dedicado às atividades. Como relatou um aluno do Grupo A: “O *Wizard User* fez diferença no meu processo de formação”. Esse grupo, que utilizou a ferramenta em 100% das disciplinas, destacou a plataforma como elemento que elevou substancialmente sua experiência educacional.

O Grupo B, que utilizou o *Wizard User* em metade das disciplinas, também reconheceu os benefícios, mas relatou que “talvez não tenha sentido o impacto total” quando comparado ao grupo que utilizou integralmente o recurso. Já o Grupo C, que não fez uso da plataforma, não percebeu o mesmo diferencial em seu processo de aprendizagem, sugerindo que o *Wizard User*, de fato, adiciona valor significativo à experiência formativa.

Além disso, a combinação de metodologias ativas, recursos digitais e suporte docente contribuiu para criar um ambiente de aprendizagem dinâmico, no qual teoria e prática se articularam de forma significativa. Em contrapartida, parte dos estudantes destacou que tais diferenciais se mostraram mais evidentes para aqueles que utilizaram plenamente as ferramentas oferecidas, o que reforça a necessidade de estratégias de engajamento mais consistentes.

Ainda assim, de modo geral, os resultados indicam que o curso se destacou pela capacidade de integrar recursos tecnológicos e práticas pedagógicas, ampliando a percepção de valor da experiência formativa.

7.4.5 Uso de Indicadores Preditivos

De forma geral, os indicadores integrados ao *Wizard User* foram vistos como eficazes, conforme refletido em comentários, como: "Os indicadores me ajudaram e foram eficientes para minha organização de estudo" e "Os indicadores ajudaram no processo de formação. Sem eles, não teria a ideia de onde estudar mais".

Dessa forma, foi possível compreender que os indicadores apresentados no *Wizard User* provaram ser uma adição valiosa, orientando os alunos em sua jornada de aprendizagem e ajudando-os a avaliar seu progresso.

É importante destacar que a realização de uma análise comparativa sobre o "Uso de Indicadores Preditivos" apresenta desafios, principalmente, porque não todos os grupos tiveram a oportunidade de experimentar esse recurso. Essa ausência de experiência com os indicadores, em certos grupos, torna difícil realizar uma comparação justa e significativa, visto que não podemos contrastar percepções diretas e experiências pessoais de todos os estudantes sobre essa funcionalidade específica.

No entanto, é crucial destacar que, entre os alunos que tiveram a oportunidade de utilizar os Indicadores Preditivos, proporcionados pelo *Wizard User*, a resposta foi extremamente positiva. Eles expressaram apreço e satisfação com esse recurso, considerando-o como um grande diferencial no seu processo de ensino-aprendizado. Essa reação positiva ratificou que os Indicadores

Preditivos foram um recurso poderoso para enriquecer a experiência educacional e, se disponibilizado a todos, poderia ser um diferencial na percepção e no desempenho dos alunos.

7.4.6 Recomendação de Conteúdo pelo *Wizard User*

Após a análise do uso de indicadores preditivos, torna-se relevante destacar a funcionalidade de recomendação de conteúdo oferecida pelo *Wizard User*. Esse recurso foi concebido como um mecanismo de apoio personalizado, capaz de direcionar o estudante a materiais de estudo mais adequados às suas dificuldades e interesses. Ao aproximar inteligência adaptativa das trajetórias de aprendizagem, a recomendação assume papel estratégico na proposta do *Wizard User*, ampliando a percepção de valor da plataforma.

Os recursos de recomendação do *Wizard User* foram amplamente valorizados pelos alunos. Depoimentos como “Quase todas as recomendações me ajudaram. Só passei em PHP porque tive ajuda”, “...o melhor do ambiente foram as recomendações. Quero isso para me ajudar em tudo” e “existe um sistema de recomendação para o meu dever da faculdade? Preciso desse recurso” ilustram a percepção positiva e a centralidade dessa funcionalidade para a experiência de aprendizagem.

As recomendações foram interpretadas como um elemento de personalização efetiva, permitindo que cada estudante recebesse conteúdos alinhados às suas necessidades individuais. Para os que experimentaram integralmente ou de forma parcial esse recurso, o valor atribuído foi inequívoco: o sistema de recomendação se revelou benéfico, prático e estratégico para potencializar o processo de estudo.

Embora tenha havido diferenças na intensidade das respostas, o consenso indica que a recomendação de conteúdo foi percebida como um marco diferenciador do *Wizard User*. Ela não apenas ampliou a eficácia do aprendizado, mas também contribuiu para redefinir a experiência educacional, tornando-a mais interativa, personalizada e com foco em resultados concretos.

O fechamento dessa análise aponta para um aspecto crucial: a recomendação de conteúdo emergiu como o recurso mais disruptivo da plataforma. Para os alunos, tratou-se de uma ponte entre dificuldade e superação, entre o esforço individual e o suporte inteligente. Essa percepção reforça que o *Wizard User* não se limitou a organizar a aprendizagem, ele a transformou em um processo guiado, adaptativo e eficaz, estabelecendo-se como um diferencial significativo no ecossistema educacional.

7.4.7 Percepção do tutor, dos monitores e da coordenadora

Com o intuito de aprofundar a compreensão sobre a eficiência do *Wizard User* no contexto educacional, foi realizado um grupo focal com os principais educadores envolvidos na formação: o tutor, os três monitores e a coordenadora. A proposta foi capturar uma visão abrangente do impacto da ferramenta não apenas no processo de aprendizagem dos alunos, mas também na dinâmica de ensino, interação e gestão das turmas.

O grupo focal, enquanto método, permitiu que os participantes compartilhassem suas percepções e experiências de maneira estruturada e aberta. Para orientar a discussão e assegurar que os aspectos mais relevantes fossem explorados, foram definidas quatro perguntas norteadoras, apresentadas no Quadro 7.4

Quadro 7.4 - Indagações aos Gestores Educacionais

Questionamentos	Objetivo por questionamento
Foi possível perceber diferenças no processo de ensino-aprendizagem dos alunos entre os grupos A, B e C?	Identificar se a implementação e a frequência de uso do <i>Wizard User</i> influenciaram de maneira distinta os processos de ensino e aprendizado em cada um dos grupos.
Foi possível perceber diferenças na interação, de forma geral, entre os alunos dos grupos A, B e C?	Avaliar se o uso do <i>Wizard User</i> teve impacto nas interações aluno-conteúdo, aluno-aluno e aluno-tutor, compreendendo se a ferramenta potencializou a colaboração, a comunicação e o engajamento entre os estudantes e com a equipe educacional.
Foi possível perceber diferenças no processo de gestão das turmas?	Investigar se a adoção do <i>Wizard User</i> trouxe modificações significativas na administração, monitoramento e acompanhamento das turmas, identificando benefícios ou desafios introduzidos pela ferramenta no gerenciamento educacional.
De forma geral, qual a visão de vocês sobre a utilização do <i>Wizard User</i> na formação dos alunos?	Capturar uma avaliação global dos profissionais educacionais sobre o valor, a eficácia e o impacto do <i>Wizard User</i> no processo formativo dos alunos, permitindo uma compreensão abrangente do papel da ferramenta na experiência educacional.

Fonte: Elaborado pelo autor.

A expectativa era que, a partir dessas indagações, emergissem nuances e *insights* que revelassem a utilidade, a eficiência e os impactos do *Wizard User* não apenas na experiência de aprendizagem dos estudantes, mas também no trabalho pedagógico e gerencial dos profissionais. Esse olhar cruzado, vindo de diferentes papéis educacionais, constitui um elemento decisivo para compreender o real alcance da ferramenta.

Percepção do tutor

Após a análise das falas dos alunos, torna-se fundamental apresentar a visão dos responsáveis pelo processo pedagógico. O tutor, em especial, desempenhou um papel estratégico ao acompanhar de perto o desempenho das turmas e a aplicação do *Wizard User*. Sua percepção é relevante não apenas por refletir a experiência prática em sala virtual, mas também por permitir estabelecer um paralelo entre a interação discente e a mediação docente.

A partir dessa vivência, o tutor destacou diferenças marcantes entre os grupos em função do uso da plataforma. Segundo sua análise, o Grupo A, com uso integral do *Wizard User*, manteve alto nível de engajamento, comparável ao observado no Grupo B nas disciplinas em que a ferramenta foi aplicada. Já nas disciplinas em que o Grupo B não utilizou o *Wizard User*, houve queda perceptível de participação, aproximando-se do desempenho do Grupo C, que não teve acesso à ferramenta.

A ausência do *Wizard User* no Grupo C se refletiu em maiores dificuldades na compreensão dos conteúdos e em interações mais limitadas entre os alunos. A comparação direta entre os grupos levou o tutor a concluir que a ferramenta contribui significativamente para elevar a interatividade e sustentar o engajamento, elementos cruciais para a aprendizagem ativa.

Sua fala sintetiza a percepção: “Os *insights* dos alunos, combinados com minha observação direta, reiteram a eficácia dessa plataforma como uma ferramenta valiosa no processo de ensino-aprendizagem. Foi mais fácil ser tutor da turma com essa ferramenta.”

Esse depoimento reforça a tese de que o *Wizard User* não apenas beneficia os estudantes, mas também potencializa o próprio trabalho docente, tornando-o mais fluido e eficiente.

Percepção dos monitores

Após a análise das percepções dos alunos e do tutor, torna-se essencial considerar a visão dos monitores, cuja proximidade cotidiana com os estudantes lhes conferiu uma leitura privilegiada das dinâmicas de aprendizagem. Suas observações reforçam e expandem as conclusões anteriores, oferecendo um panorama consistente sobre o papel desempenhado pelo *Wizard User* no processo formativo.

- **Grupo A (100% uso do *Wizard User*)**

Os monitores identificaram efeitos claramente positivos, ressaltando que a ferramenta foi essencial para aprofundar o conhecimento e dinamizar a interação. O impacto ficou evidente em seus relatos: “As declarações dos alunos sobre a clareza e organização do material didático foram um testemunho direto do impacto positivo da plataforma.”

- **Grupo B (50% uso do *Wizard User*)**

A experiência foi descrita como heterogênea. Quando presente, a ferramenta favoreceu a aprendizagem; quando ausente, sua falta foi intensamente sentida. Essa percepção foi sintetizada na seguinte observação: “A falta do *Wizard User* nas disciplinas de PHP e Banco de Dados criou algumas lacunas em sua experiência educacional.”

- **Grupo C (0% uso do *Wizard User*):**

Os monitores relataram os piores resultados de aprendizado. A ausência da ferramenta intensificou as dificuldades, levando os alunos a acumularem dúvidas que poderiam ser facilmente resolvidas: “Os alunos frequentemente mencionaram desafios em sua jornada de aprendizado, com dúvidas que poderiam ser facilmente resolvidas por uma pesquisa simples no *Wizard User*.”

Em síntese, os relatos dos monitores corroboram e aprofundam a análise do tutor: o *Wizard User* se configura como um diferenciador pedagógico decisivo.

Sua presença amplia engajamento, clareza e autonomia; sua ausência, por outro lado, tende a acentuar lacunas e fragilidades no processo formativo. Esse contraste entre os grupos evidencia não apenas a utilidade da ferramenta, mas seu potencial estratégico para redefinir a mediação educacional em ambientes digitais.

Percepção da Coordenadora

Após compreender a visão dos alunos, do tutor e dos monitores, torna-se essencial apresentar a perspectiva da coordenação acadêmica, responsável por articular os diferentes atores do processo educacional. A coordenadora, ao observar tanto o engajamento discente quanto a atuação de tutores e monitores, oferece uma leitura estratégica sobre o papel do *Wizard User* na gestão pedagógica e no acompanhamento das turmas.

A coordenadora identificou diferenças significativas na interação dos grupos. O Grupo A, com uso integral do *Wizard User*, apresentou interações “mais vibrantes e colaborativas”, sinalizando um ambiente de aprendizagem fortalecido pela mediação tecnológica. Já o Grupo B, de uso parcial, foi descrito como heterogêneo, refletindo ganhos claros quando a ferramenta esteve presente, mas queda perceptível de qualidade nas disciplinas em que não foi utilizada. O Grupo C, sem acesso à plataforma, “se mostrou sobrecarregado e com constantes dúvidas”, revelando as fragilidades de uma experiência desassistida.

Em sua análise, a coordenadora também destacou o impacto organizacional da ferramenta: “Minha percepção é que o *Wizard User* não apenas enriquece a experiência educacional dos alunos, mas também atua como um facilitador vital para a gestão eficiente dos monitores e tutores. Com os indicadores, era possível ter comparações entre produtividade e a relevância das ações.”

A fala da coordenadora reforça e amplia as percepções do tutor e dos monitores: o *Wizard User* atua simultaneamente como instrumento pedagógico e ferramenta de gestão acadêmica. Mais do que apoiar o aprendizado dos alunos, ele oferece métricas de acompanhamento que fortalecem a tomada de decisão e

elevam a eficiência das equipes de suporte. Esse duplo impacto – na aprendizagem e na governança educacional – evidencia que o *Wizard User* não é apenas um recurso complementar, mas um ativo estratégico para a consolidação de práticas educacionais digitais mais eficazes, colaborativas e sustentáveis.

7.4.8 Considerações sobre a análise qualitativa

A análise qualitativa dos grupos focais permite compreender em profundidade as múltiplas dimensões que moldam o processo de ensino-aprendizagem. Ao reunir percepções de alunos, tutores, monitores e da coordenadora, emergiu um quadro multifacetado que evidencia não apenas a complexidade do fenômeno educativo, mas também o papel estratégico da tecnologia, em particular, do *Wizard User*, na personalização da experiência formativa.

Os relatos destacaram a relevância da interatividade promovida pela ferramenta, a clareza na gestão de conteúdos e o fortalecimento das dinâmicas de grupo. Muitos estudantes reconheceram que "o *Wizard User* foi um diferencial na minha aprendizagem, porque me ajudou a organizar melhor os estudos e entender quais pontos eu precisava reforçar". Essa percepção reforça a ideia de que tecnologias educacionais podem atuar como mediadoras do engajamento, oferecendo indicadores e recomendações capazes de orientar o aprendizado de forma preditiva e individualizada.

Do outro lado, alunos que não utilizaram a ferramenta, ou que a acessaram de modo restrito, relataram maiores dificuldades, revelando barreiras de acesso que impactaram negativamente a experiência de aprendizagem. Esse contraste ressalta não apenas o potencial da tecnologia, mas também a urgência de políticas institucionais que garantam inclusão digital e condições equitativas de participação.

As falas dos educadores convergem com a visão discente. Um monitor destacou: "Quando os alunos tinham acesso pleno ao *Wizard User*, o acompanhamento era mais ágil e assertivo, e isso facilitava inclusive nosso papel como suporte". Já a coordenadora reforçou que "o *Wizard User* não apenas enriquece a experiência educacional dos alunos, mas também atua como um facilitador vital para a gestão eficiente dos monitores e tutores". Tais perspectivas

ampliam a compreensão do impacto da ferramenta, evidenciando que sua contribuição ultrapassa a dimensão pedagógica, alcançando também a esfera da gestão educacional.

Diante desse conjunto de percepções, torna-se evidente que o *Wizard User* desempenha um papel central na transformação do ensino e da aprendizagem, funcionando como catalisador de interatividade, personalização e eficiência. Os relatos confirmam a relevância da ferramenta e sublinham a necessidade de integrar inovação e equidade em uma mesma agenda estratégica. Em síntese, o *Wizard User* se consolida como um recurso diferenciador, capaz de redefinir o cenário educacional contemporâneo e apontar caminhos para uma aprendizagem mais justa, interativa e eficaz.

7.5 Análise comparativa quantitativa

A análise dos dados quantitativos foi organizada segundo os três grupos de alunos (A, B e C), definidos a partir da intensidade de uso do *Wizard User*. Essa divisão permitiu observar de forma comparativa como diferentes níveis de adoção da ferramenta impactaram as taxas de aprovação, reprovação e desistência em cada disciplina.

Conforme representado no quadro 7.5, o grupo A apresentou desempenho consistente, com altas taxas de aprovação e baixa incidência de reprovações. Ainda que tenham ocorrido desistências, o impacto sobre a média global foi reduzido, evidenciando que o uso intensivo da ferramenta contribuiu para manter a estabilidade nos resultados.

Quadro 7.5 – Resumo Grupo A

Disciplina	Aprovados	Reprovados	Desistentes	Média sem desistentes	Média com desistentes
<i>HTML/CSS</i>	45	0	0	8,0	8,0
<i>JavaScript</i>	39	5	1	5,8	5,7
<i>PHP</i>	35	8	2	5,9	5,6
Banco de dados	36	5	2	6,4	6,3

Fonte: Elaborado pelo autor.

O grupo B, (Quadro 7.6) teve sua performance marcada por heterogeneidade. Em disciplinas com suporte do *Wizard User*, os índices de

aprovação se aproximaram dos observados no Grupo A. Já nas disciplinas em que a ferramenta não esteve presente, notou-se maior dispersão nos resultados e maior sensibilidade às desistências.

Quadro 7.6 – Resumo grupo B

Disciplina	Aprovados	Reprovados	Desistentes	Média sem desistentes	Média com desistentes
HTML/CSS	40	4	1	6,5	6,3
JavaScript	37	6	2	6,1	5,9
PHP	34	9	2	5,9	5,7
Banco de dados	34	8	3	6,3	5,9

Fonte: Elaborado pelo autor.

No grupo C, (quadro 7.7) concentrou os piores indicadores de desempenho, tanto em reprovações quanto em desistências. A ausência do *Wizard User* evidenciou-se como um fator de fragilidade no processo de aprendizagem, resultando em médias mais baixas e maior vulnerabilidade frente à evasão.

Quadro 7.7 – Resumo grupo C

Disciplina	Aprovados	Reprovados	Desistentes	Média sem desistentes	Média com desistentes
HTML/CSS	41	4	0	6,6	6,6
JavaScript	36	6	3	6,1	5,7
PHP	31	8	6	5,8	5,1
Banco de dados	31	8	6	6,1	5,3

Fonte: Elaborado pelo autor.

A leitura conjunta dos três grupos evidencia que o *Wizard User* atuou como variável de diferenciação pedagógica, associando-se de forma consistente a maiores taxas de aprovação e menor impacto das desistências sobre os resultados. Essa comparação reforça que a ferramenta não apenas favorece o aprendizado em si, mas também exerce efeito estabilizador sobre o desempenho acadêmico quando confrontado com a evasão.

Para compreender de maneira mais aprofundada o desempenho dos estudantes e a variação entre os grupos analisados, foi necessário realizar uma exploração estatística inicial dos dados. Essa etapa teve como objetivo oferecer uma visão geral da distribuição das notas, permitindo identificar padrões,

tendências e eventuais discrepâncias que poderiam impactar a interpretação dos resultados.

Os dados foram carregados no *NVivo* e no *Microsoft Excel*, possibilitando tanto a organização e categorização qualitativa quanto a exploração quantitativa. Em seguida, com o auxílio do *Excel*, foram gerados histogramas que permitiram visualizar a distribuição das médias dos alunos em cada disciplina, para cada conjunto de dados.

Além da visualização gráfica, procedeu-se ao cálculo de estatísticas descritivas, incluindo: média aritmética, mediana, desvio padrão e valores mínimo e máximo das médias. Essas medidas fornecem uma síntese numérica capaz de evidenciar a dispersão dos resultados e indicar o grau de homogeneidade ou heterogeneidade do desempenho entre os estudantes. O resumo consolidado dessas informações encontra-se no Quadro 7.8.

Quadro 7.8 – Resumo da Análise

Grupo	Média	Mediana	Desvio Padrão	Mínimo	Máximo	n
Grupo A	6,53	6,58	0,86	4,50	8,17	45
Grupo B	5,93	6,17	1,41	0,00	7,58	45
Grupo C	5,66	6,08	1,49	1,33	7,42	45

Fonte: Elaborado pelo autor.

É importante destacar que o Quadro 7.8 – Resumo da Análise evidencia tanto convergências quanto discrepâncias entre os dados coletados. Observa-se que, embora as medidas de tendência central (média e mediana) se mantenham próximas em parte dos grupos, os desvios padrão sinalizam níveis distintos de homogeneidade. Em certos casos, o intervalo entre valores mínimo e máximo é reduzido, indicando consistência entre os participantes; em outros, há maior dispersão, revelando cenários de aprendizagem desiguais.

Essa síntese sugere que o desempenho dos estudantes não se distribui de forma linear entre os grupos, sendo necessário um olhar mais segmentado para compreender as especificidades de cada conjunto. A seguir, aprofunda-se a análise por grupo (A, B e C), destacando características próprias, avanços e limitações no processo de aprendizagem.

O Grupo A apresentou elevada consistência nos resultados, com baixa dispersão estatística. Esse padrão indica que a maioria dos participantes manteve desempenho próximo à média, sugerindo adesão efetiva ao uso do *Wizard User* em todas as disciplinas. O engajamento constante e homogêneo reflete um processo de aprendizagem mais equilibrado, no qual não se observaram grandes discrepâncias individuais.

O Grupo B mostrou resultados intermediários, combinando avanços relevantes com dispersões pontuais. Embora tenha registrado adesão parcial ao *Wizard User*, ainda assim demonstrou ganhos consistentes em comparação a grupos de controle. A dispersão dos dados revela que alguns estudantes se beneficiaram de forma mais intensa da ferramenta, enquanto outros mantiveram desempenhos mais próximos dos padrões tradicionais. Isso sugere a necessidade de estratégias complementares de acompanhamento para consolidar a aprendizagem de todos os participantes.

Por fim, o Grupo C apresentou a maior heterogeneidade de resultados, refletida no elevado desvio padrão e na distância entre valores mínimo e máximo. A ausência de uso do *Wizard User* nas disciplinas resultou em trajetórias de aprendizagem mais fragmentadas, com alguns estudantes atingindo bons níveis de desempenho e outros permanecendo em patamares significativamente inferiores. Essa oscilação reforça o papel da ferramenta como diferencial de estabilidade e previsibilidade nos processos de aprendizagem.

- **Média das Médias**

A fim de enriquecer a compreensão dos resultados apresentados nos Quadros 7.7 e 7.8, foram incluídas medidas estatísticas adicionais que permitem observar padrões de centralidade, dispersão e amplitude entre os três grupos analisados (A, B e C).

Quadro 7.9 – Média das Médias

Médias das Médias	Grupo A	Grupo B	Grupo C
	6,53	5,93	5,66

Fonte: Elaborado pelo autor.

Conforme apresentado no quadro 7.9, os valores mostram uma tendência ascendente da média das médias entre os grupos, variando de 5,66 (Grupo C) para 5,93 (Grupo B) e 6,53 (Grupo A). Essa progressão sugere que os alunos do Grupo A obtiveram um desempenho geral superior, seguidos pelo Grupo B, enquanto o Grupo C apresentou resultados mais modestos. A diferença, embora não drástica, aponta para uma possível relação entre o uso intensivo do *Wizard User* e melhores resultados médios de aprendizagem.

- **Medianas**

Os grupos apresentaram as seguintes medianas: Grupo A = 6,58; Grupo B = 6,17; e Grupo C = 6,08. Esse resultado evidencia que, apesar das diferenças nas médias gerais, a posição central dos dados manteve-se relativamente próxima entre os grupos, sugerindo certa homogeneidade no desempenho típico.

Quadro 7.10 – Desvio Padrão

Desvio Padrão	Grupo A	Grupo B	Grupo C
	1,25	0,45	1,28

Fonte: Elaborado pelo autor.

A análise do desvio padrão revela diferenças claras de variabilidade. O Grupo A, com DP=1,25, apresenta a menor dispersão e maior consistência entre os alunos. O Grupo B, com DP=0,45, mostra variabilidade baixa entre os grupos. Já o Grupo C, com DP=1,28, exibe a maior dispersão, indicando maior heterogeneidade no desempenho.

- **Valores Mínimos e Máximos**

A análise dos extremos mostra que o Grupo A apresenta o maior valor máximo (8,17), superando os topos do Grupo B (7,58) e do Grupo C (7,42). No limite inferior, observa-se que o Grupo B registra a menor nota (0,00), seguido do Grupo C (1,33), ambos inferiores ao patamar mínimo do Grupo A (2,00).

Essas medidas resultam em amplitudes distintas: B = 7,58, A = 6,17, C = 6,08, evidenciando que, embora o Grupo A concentre o maior potencial de desempenho (maior máximo), o Grupo B é o que revela a menor variação interna. Já o Grupo C combina a menor média global (5,66) com a maior dispersão (DP =

1,28), sugerindo não apenas limitações no alcance dos melhores resultados, mas também maior heterogeneidade no desempenho de seus integrantes.

- **Análise estatística comparativa dos grupos**

Para fortalecer a interpretação dos resultados quantitativos, adotamos uma sequência analítica estruturada em quatro etapas: comparação relativa via Coeficiente de Variação ($CV = \text{desvio-padrão}/\text{média}$), análise de subgrupos por disciplina, testes de pressupostos (*Shapiro–Wilk* para normalidade e *Levene* para homogeneidade de variâncias), seguidos de *Kruskal–Wallis* como abordagem prioritária, com *ANOVA one-way* utilizada apenas como referência, e, por fim, visualização gráfica por meio de *boxplots* das médias globais por aluno. Esse encadeamento reflete boas práticas de inferência estatística aplicadas à pesquisa em educação.

Quadro 7.11 – Coeficiente de variação por grupo

GRUPO	CV (%)
A	20,1
B	23,9
C	26,3

Fonte: Elaborado pelo autor.

- **Análise de subgrupo por disciplina**

O Quadro 7.12 apresenta o CV por disciplina e grupo (calculado a partir da coluna “Média” de cada disciplina, excluídas as ausências). O Grupo A mostra baixa dispersão em *HTML/CSS* (14,0%), moderada em *JavaScript* (20,0%) e elevada em *PHP* (41,5%) e Banco de dados (41,3%) portanto, não é “baixo a moderado em todas”, mas sim alto nas duas últimas. O Grupo B não apresenta CV extremo em *HTML/CSS*; o valor é moderado-alto (32,6%) o maior entre os três grupos nessa disciplina, porém longe de $\approx 68\%$. Em *JavaScript*, *PHP* e Banco de dados, o B mantém CVs moderado-altos ($\approx 30\text{--}38\%$). Já o Grupo C sustenta dispersão elevada em *PHP* (50,0%) e Banco de dados (48,0%), e moderada em *HTML/CSS* (18,6%) e moderado-alto em *JavaScript* (34,8%), evidenciando maior oscilação especialmente nas duas últimas disciplinas técnicas.

Quadro 7.12 – Coeficiente de variação por disciplina e grupo

Disciplina	Grupo A (CV%)	Grupo B (CV%)	Grupo C (CV%)
HTML/CSS	14,0	32,6	18,6
JavaScript	20,0	30,7	34,8
PHP	41,5	36,4	50,0
Banco de dados	41,3	38,1	48,0

Fonte: Elaborado pelo autor.

● **Testes de hipóteses**

Antes da comparação entre grupos, foram verificados os pressupostos. O *Shapiro–Wilk* rejeitou a normalidade das médias globais por aluno em A, B e C ($p < 0,001$ em todos), recomendando foco em testes não paramétricos. O *Levene* (centrado na mediana) não indicou diferenças de variâncias entre os grupos ($p = 0,719$), sugerindo homogeneidade da dispersão.

Dadas a não normalidade e a presença de valores extremos, adotou-se como principal o *Kruskal–Wallis*, cujo resultado não indicou diferença global significativa; a ANOVA também não foi significativa (e permanece secundária, dado o pressuposto de normalidade violado).

- *Sruskal–Wallis*: $H = 4,978$; $p = 0,083$; $\varepsilon^2 = 0,023$ - não significativo.
- ANOVA one-way: $F = 2,094$; $p = 0,127$; $\eta^2 = 0,031$ - não significativo.
- *Shapiro–Wilk*:
 - Grupo A: $p \approx 5,31 \times 10^{-4}$ - rejeita normalidade
 - Grupo B: $p \approx 2,53 \times 10^{-7}$ - rejeita normalidade
 - Grupo C: $p \approx 7,57 \times 10^{-6}$ - rejeita normalidade
 - *Levene* (mediana): $p = 0,719$ - homogeneidade das variâncias mantida

Em síntese, não há evidência estatística de diferenças entre as medianas das médias por aluno dos grupos A, B e C.

Quadro 7.13 – Testes de normalidade e comparação entre grupos


Teste	Valor	Interpretação
<i>Shapiro–Wilk</i> (Grupo A)	$p \approx 5,31 \times 10^{-4}$	Distribuição não normal (rejeita)
<i>Shapiro–Wilk</i> (Grupo B)	$p \approx 2,53 \times 10^{-7}$	Distribuição não normal (rejeita)
<i>Shapiro–Wilk</i> (Grupo C)	$p \approx 7,57 \times 10^{-6}$	Distribuição não normal (rejeita)
<i>Levene</i> (mediana)	$p = 0,719$	Homogeneidade das variâncias mantida
<i>Kruskal–Wallis</i>	$H = 4,978$; $p = 0,083$; $\varepsilon^2 = 0,023$	Não significativo (sem diferença global)

ANOVA <i>one-way</i>	$F = 2,094$; $p = 0,127$; $\eta^2 = 0,031$	Não significativo; secundária	interpretação
----------------------	--	----------------------------------	---------------

Fonte: Elaborado pelo autor.

As distribuições de desempenho apresentam padrões distintos entre os grupos. O Grupo A combina menor coeficiente de variação (CV) e mediana mais elevada, sugerindo desempenho mais consistente e centralizado. A Figura 7.1 reforça visualmente essa leitura: o Grupo A exibe menor dispersão; o Grupo B concentra *outliers* em ambas as extremidades, refletindo maior heterogeneidade; e o Grupo C posiciona-se de forma intermediária, embora com caudas mais alongadas. Cabe destacar, contudo, que o teste global (*Kruskal-Wallis*) não atingiu significância estatística ($p = 0,083$), razão pela qual essa interpretação deve ser entendida como indício exploratório e não como inferência confirmatória.

Figura 7.1 – Distribuição das médias globais por grupo (boxplot)



Fonte: Elaborado pelo autor.

Em conjunto, as métricas de CV por grupo e disciplina, os resultados do *Kruskal-Wallis* e a análise visual dos *boxplots* convergem para a mesma interpretação: o Grupo A, com maior exposição ao *Wizard User*, alcançou os melhores resultados médios e maior consistência interna; o Grupo B apresentou a maior heterogeneidade de desempenho; e o Grupo C posicionou-se de forma intermediária, porém com estabilidade inferior ao Grupo A.

- **Pós-testes e tamanhos de efeito**

Dado que o teste global *Kruskal-Wallis* não indicou diferença significativa entre os grupos ($H = 4,978$; $p = 0,083$), as comparações par a par foram tratadas como exploratórias. Aplicou-se *Mann-Whitney* com correção de Holm e estimou-

se o delta de *Cliff* (δ) com *IC95%* por *bootstrap*, sobre a média global por aluno (0–10).

Resultados (pós-teste / *Holm* e δ de *Cliff*, *IC95%*):

- A x C: $p_{aj} = 0,0933$; $\delta = 0,264$ (*IC95%* [0,018; 0,486]; magnitude pequeno–moderado).
- A x B: $p_{aj} = 0,3178$; $\delta = 0,173$ (*IC95%* [-0,075; 0,402]; pequeno).
- B x C: $p_{aj} = 0,3768$; $\delta = 0,109$ (*IC95%* [-0,135; 0,339]; negligível–pequeno).

As comparações par a par, conduzidas de forma exploratória após o resultado global não significativo, sugerem que a diferença mais consistente ocorreu entre os grupos A e C, com efeito pequeno a moderado ($\delta = 0,264$; *IC95%* [0,018; 0,486]). Contudo, o valor ajustado de *p* ($p_{aj} = 0,0933$) não atingiu o limiar de significância estatística. As demais comparações (A x B e B x C) apresentaram efeitos pequenos e intervalos de confiança que cruzam zero, reforçando a ausência de evidência conclusiva.

Em termos práticos, quando esses resultados são triangulados com os achados qualitativos, observa-se que o modelo *Wizard User* tende a favorecer maior consistência de desempenho e menor variabilidade entre estudantes, aspecto relevante do ponto de vista educacional mesmo na ausência de significância estatística estrita.

- **Análise de evasão**

A evasão escolar representa um dos principais desafios da educação contemporânea, pois compromete não apenas a trajetória acadêmica dos estudantes, mas também a efetividade das estratégias pedagógicas adotadas. Ainda que a presente investigação não tenha se debruçado sobre as causas da evasão em si, buscou-se compreender de que forma o uso do *Wizard User* influenciou a permanência dos alunos em diferentes grupos de análise, conforme apresentado no quadro 7.14.

Quadro 7.14 – Taxa de evasão

Grupo	Matriculados	Desistentes (curso)	Taxa de evasão (%)
A	45	2	4,44%
B	45	3	6,67%
C	45	6	13,33%

Fonte: Elaborado pelo autor.

Taxa de evasão (%) = (Desistentes no curso ÷ Matriculados iniciais) × 100

Regra: Desistente (curso) = média global 0 (todas as disciplinas com nota 0)

A análise evidencia que, apesar da adesão inicial expressiva, ocorreram desistências superiores a quatro alunos em todos os grupos. Essa redução impactou o tamanho efetivo da amostra, exigindo cautela na interpretação dos resultados. Ainda assim, a amostra final manteve consistência suficiente para permitir inferências válidas sobre o papel do *Wizard User*.

Observou-se maior taxa de evasão no Grupo C (13,33%), seguido do Grupo B (6,67%) e Grupo A (4,44%), considerando “desistente (curso)” como o aluno com média global 0. Embora o teste *Kruskal-Wallis* aplicado ao desempenho não tenha indicado diferença global significativa entre os grupos ($p = 0,083$), a leitura descritiva da evasão sugere uma tendência: maior exposição ao *Wizard User* associa-se a menor evasão. Esses achados devem ser interpretados com cautela, sendo triangulados com as evidências qualitativas e passíveis de replicação em amostras maiores.

Por fim, destacamos que os resultados indicam que o *Wizard User* contribuiu para mitigar a evasão, ainda que sem abranger todas as variáveis que compõem esse fenômeno multifacetado. A principal contribuição deste estudo é evidenciar que a integração entre recursos tecnológicos e práticas pedagógicas pode desempenhar papel decisivo na permanência acadêmica. Abordagens futuras que incorporem variáveis socioeconômicas, motivacionais e institucionais permanecem como caminhos promissores para ampliar a compreensão e o enfrentamento da evasão escolar.

7.5.1 Considerações da análise quantitativa

A análise quantitativa dos três grupos evidencia que o uso intensivo do *Wizard User* atuou como variável diferenciadora no desempenho acadêmico. O Grupo A, exposto de forma plena à ferramenta, apresentou médias mais elevadas, menor dispersão e maior estabilidade nos resultados, além de índices reduzidos de evasão. Esses indicadores sugerem que a presença do recurso contribuiu não apenas para ganhos individuais, mas também para maior uniformidade coletiva no processo de aprendizagem.

O Grupo B revelou um cenário de heterogeneidade: parte dos alunos obteve desempenhos próximos ao Grupo A nas disciplinas apoiadas pelo *Wizard User*, mas houve queda sensível quando a ferramenta não esteve presente. Esse resultado sugere que a eficácia do recurso depende de sua utilização consistente ao longo do curso.

Já o Grupo C concentrou os piores índices de aprovação e as maiores taxas de evasão, reforçando a percepção de que a ausência do *Wizard User* torna o processo de aprendizagem mais vulnerável a dispersões e desistências. O desvio-padrão relativamente elevado e a menor amplitude de notas máximas confirmam limitações tanto na consistência quanto no potencial de desempenho.

Do ponto de vista estatístico, os testes de hipótese (*Kruskal-Wallis* e *ANOVA*) não identificaram diferenças globais significativas entre os grupos. Ainda assim, os coeficientes de variação por disciplina indicaram maior estabilidade no Grupo A e maior dispersão no Grupo B, especialmente em *HTML/CSS*. As comparações par a par, tratadas de forma exploratória, apontaram tendência de vantagem do Grupo A sobre o Grupo C, com efeito pequeno a moderado, mas sem atingir significância após correção por múltiplos testes.

É importante observar que o tamanho da amostra, reduzido pela evasão, pode ter limitado a potência estatística, elevando a probabilidade de erro tipo II. Nesse sentido, a ausência de significância global não deve ser interpretada como ausência de efeito, mas como limitação do poder analítico disponível. Além disso, ressalta-se que as análises par a par foram conduzidas em caráter estritamente

exploratório, cabendo a estudos futuros com amostras mais robustas validar de forma confirmatória essas tendências.

Em termos práticos, a triangulação entre os resultados quantitativos e qualitativos sugere que o *Wizard User* favorece maior consistência no desempenho e reduz a variabilidade entre estudantes. Esse achado, embora não sustentado por significância estatística plena, tem relevância educacional, pois indica que a ferramenta contribui para um ambiente de aprendizagem mais equitativo e previsível, dimensão estratégica na avaliação de tecnologias educacionais mediadas por IA.

7.6 Considerações sobre os resultados

À luz da questão de investigação proposta, “De que forma um modelo de inteligência artificial aplicado à educação poderá prover melhorias no processo de ensino-aprendizagem de curso *on-line*?”, os resultados obtidos permitem afirmar que o *Wizard User*, enquanto modelo tecnológico baseado em IA, apresentou avanços relevantes e promissores para a qualidade da aprendizagem *on-line*.

Primeiramente, o sistema evidenciou capacidade de personalização do ensino, ajustando conteúdos às necessidades individuais dos estudantes e promovendo maior engajamento. Essa característica refletiu-se tanto na tendência de melhoria das médias quanto na redução da evasão, sugerindo que os alunos se sentiram mais amparados em sua trajetória formativa.

Em segundo lugar, os achados quantitativos e qualitativos convergem ao indicar que o *Wizard User* atuou como mecanismo de estabilização: reduziu a dispersão dos resultados e contribuiu para que mais alunos alcançassem níveis próximos à média. Esse aspecto é crucial para a equidade educacional, pois pode mitigar a distância entre os que aprendem mais rápido e os que encontram maiores dificuldades.

Além disso, o sistema ampliou a eficiência pedagógica ao liberar tutores de tarefas operacionais e fornecer *feedback* imediato e individualizado, fortalecendo o acompanhamento contínuo. Essa combinação de tecnologia adaptativa, suporte

pedagógico e automação inteligente revelou-se decisiva para tornar o processo educacional mais eficaz, interativo e inclusivo.

Assim, os resultados desta investigação confirmam que a implementação do *Wizard User* atendeu às duas metas delineadas:

- desenvolver um sistema cognitivo com técnicas de predição, recomendação e tutoria inteligente, validado em contexto real de AVA;
- evidenciar melhorias concretas no processo educacional, mensuradas por meio da análise comparativa entre grupos, taxas de evasão e indicadores estatísticos.

Em síntese, o *Wizard User* mostrou-se não apenas um recurso auxiliar, mas um diferencial estruturante para o ensino *on-line*, capaz de potencializar a aprendizagem, ampliar a retenção de alunos e consolidar práticas mais equitativas e eficazes de educação mediada por inteligência artificial. Ainda assim, os resultados devem ser interpretados com cautela, dado o tamanho da amostra e a natureza exploratória de algumas análises, o que reforça a necessidade de replicação em diferentes contextos e com grupos mais amplos.

Capítulo 8 – Conclusões

"A educação é a arma mais poderosa que você pode usar para mudar o mundo."

Nelson Mandela

O capítulo 8 conclui que o *Wizard User* mostrou-se uma ferramenta de IA eficaz no ensino *on-line*, ao personalizar a aprendizagem, reduzir a evasão e aumentar o engajamento dos alunos, além de apoiar os educadores ao assumir tarefas operacionais. A investigação confirmou que a tecnologia elevou o desempenho médio e trouxe maior equidade entre os estudantes, validando seu potencial transformador na educação digital.

Também foram discutidos os desafios enfrentados, como a pandemia e limitações institucionais, que exigiram resiliência e ajustes metodológicos. Apesar disso, o estudo resultou em publicações relevantes e abriu perspectivas futuras, destacando a integração do *Wizard User* com modelos como o *ChatGPT*, visando ampliar o impacto global da ferramenta e contribuir para práticas educacionais mais inclusivas e inovadoras.

8.1 Conclusões da investigação

A investigação evidenciou que o *Wizard User*, um agente de IA voltado à mediação em ambientes virtuais de aprendizagem, atuou como instrumento pedagógico relevante para estudantes e apoio operacional-didático a educadores. Para os discentes, o agente ampliou a acessibilidade aos conteúdos e organizou a jornada de estudo, oferecendo orientação contínua, *feedback* oportuno e adaptações compatíveis com ritmos e necessidades individuais, o que se traduziu em experiências mais claras e engajadoras. Para os docentes e a equipe de tutoria/monitoria, o *Wizard User* assumiu tarefas administrativas e de acompanhamento de rotina, liberando tempo para mediações mais qualitativas, personalizadas e responsivas.

Em termos gerais, os achados convergem para três ideias: o agente ajuda a organizar a experiência e reduzir a dispersão de resultados; há indícios robustos de menor evasão quando seu uso é consistente; e observam-se sinais de engajamento (clareza de percurso, maior participação e mediação mais responsiva), ainda que construtos psicométricos (autoeficácia, percepção de controle e utilidade) permaneçam como agenda de mensuração formal na etapa seguinte. A seguir, apresentamos as respostas às questões de investigação delineadas na Introdução (Capítulo 1).

- **Resposta à Q1 (RQ1) - A IA melhora os resultados acadêmicos (por exemplo, desempenho em avaliações, taxa de aprovação e domínio de competências)?**

Observou-se tendência de melhora associada ao *Wizard User*, refletida na menor dispersão e maior estabilidade de notas entre estudantes mais expostos ao agente. Contudo, o teste global entre grupos não alcançou significância (Kruskal-Wallis, $p \approx 0,083$). Em pós-testes exploratórios, emergiu um efeito pequeno–moderado em comparação específica ($\delta \approx 0,26$; p ajustado $\approx 0,0933$): um sinal promissor que não autoriza *overclaim*. Em suma, a direção é consistente com a hipótese, mas a magnitude observada sugere amostras maiores, maior tempo de exposição e replicações para consolidar estimativas. Quanto à aprovação e ao domínio de competências, este estudo priorizou desempenho em avaliações;

recomenda-se, portanto, incluir rubricas de domínio e status de aprovação como desfechos primários em trabalhos subsequentes. [Q1]

- **Resposta à Q2 (RQ2) - Q2. Contribui para reduzir o abandono/evasão (aumentando a persistência e a conclusão de disciplinas)?**

Identificou-se menor evasão em condições de maior exposição ao agente, com diferenças percentuais consistentes (por exemplo, ~4,44% vs. ~13,33%). A regra de classificação de “desistente (curso)” foi aplicada de modo uniforme e documentada, reforçando a comparabilidade operacional. Embora o desenho seja quase experimental e a inferência, associativa, o padrão é coerente com a teoria e com a prática docente observada, sustentando a hipótese de contribuição do *Wizard User* para a persistência. [Q2]

- **Resposta à Q3 (RQ3) - Q3. Fortalece o engajamento no processo de ensino-aprendizagem (autoeficácia, percepção de controle e utilidade do percurso formativo)?**

Relatos qualitativos (estudantes, monitores, tutores) e indicadores de uso sugerem maior clareza de percurso, participação mais frequente e mediação mais responsiva quando o agente está ativo e integrado à rotina do curso. Esses sinais são compatíveis com engajamento e com incremento de autonomia no acompanhamento do próprio progresso. Como autoeficácia, percepção de controle e utilidade não foram mensurados por escalas psicométricas nesta fase, a conclusão é necessariamente parcial: há evidência convergente, porém indireta. A próxima etapa inclui incorporar instrumentos validados e triangulá-los com traços comportamentais do AVA e produtos de aprendizagem avaliados por rubricas. [Q3]

Do ponto de vista da área de Ciência e Tecnologia Web, o estudo ilustra o potencial transformador de agentes de IA na personalização e na mediação pedagógica, contribuindo com um modelo técnico-metodológico replicável (*Wizard User*) e um protocolo de avaliação que integra evidências quantitativas e qualitativas. Os resultados são satisfatórios e abrem trilhas de investigação: aperfeiçoar o agente com recursos contemporâneos de IA (por exemplo, *large*

language models como o *ChatGPT*), escalar sua adoção em diferentes contextos e mapear impactos em resultados acadêmicos, persistência e métricas de engajamento validadas.

8.2 Desafios Encontrados

A jornada que permeia o desenvolvimento de um trabalho de doutorado é, em si, uma trilha repleta de desafios e descobertas. No entanto, o contexto global e as circunstâncias pessoais inesperadas agregaram, negativamente, camadas adicionais de complexidade e obstáculos a este projeto de investigação.

Inicialmente, a pandemia de COVID-19, que se instalou globalmente no início de 2020, trouxe um cenário de incerteza, alterando abruptamente a normalidade das atividades acadêmicas e sociais. O isolamento social, a interrupção de atividades presenciais e as restrições impostas impuseram uma necessária reinvenção das estratégias de investigação e adaptação a uma nova realidade de viver, fazendo com que o autor principal desta investigação atravessasse um período de depressão profunda, que culminou em uma batalha adicional, na qual a saúde mental tornou-se uma prioridade, influenciando, diretamente, na capacidade de manter a concentração e a produtividade em patamares ideais.

A cada etapa, o impacto emocional e temporal foi significativo, requerendo períodos de pausa e reflexão para garantir que a trajetória acadêmica e pessoal prosseguisse de maneira saudável e sustentável. Ainda, como se os desafios já não fossem abrangentes, a instituição na qual a investigação estava sendo desenvolvida começou a enfrentar dificuldades financeiras, limitando ainda mais os recursos e materiais disponíveis para a continuidade da investigação.

Esse panorama impôs constantes revisões metodológicas e adaptações no cronograma, na busca por preservar a integridade e a relevância dos achados da investigação. A despeito das adversidades, a resiliência e a paixão pela ciência foram as luzes guias que permitiram que o projeto persistisse, sempre mantendo o comprometimento com o rigor e a qualidade da investigação científica. A compreensão desses contextos se faz essencial para entender os desafios, as

mudanças e as conquistas realizadas ao longo deste percurso acadêmico e pessoal.

Por fim, o autor principal desta investigação encontra-se satisfeito com as análises realizadas e os resultados obtidos, ratificando, assim, que todo o esforço empregado neste trabalho foi de extremo valor educacional e científico e poderá ser fruto de aprimoramento em novos estudos investigativos (dissertações e teses) e/ou em algum desenvolvimento comercial, por meio de empresas, para alavancar mais recursos ao *Wizard User*, culminando em melhorias no processo educacional.

8.3 Trabalhos Publicados

Ferrão, E. (2021). *Wizard User*: um agente cognitivo na otimização de processos de ensino-aprendizagem *on-line*. *Encontro Internacional de Jovens Investigadores*. Universidade Federal da Bahia. Em publicação no repositório da UAB (<https://repositorioaberto.uab.pt/>)

Ferrão, E., Bidarra, J., & Rocio, V. (2021). Requisitos de um Agente Inteligente de Apoio ao Ensino-Aprendizagem *on-line*: Modelo *Wizard User*. *International Journal of Development Research*. <https://journalijdr.com/requisitos-de-um-agente-inteligente-de-apoio-ao-ensino-aprendizagem-line-modelo-wizard-user>

8.4 Perspectivas e Trabalhos Futuros

A articulação entre tecnologia e educação tem se revelado como um terreno fértil para inovações que respondem a desafios contemporâneos no campo da aprendizagem e ensino. Atualmente, estamos imersos no desenvolvimento integrado do *Wizard User* com o *ChatGPT*, duas tecnologias robustas que, ao convergirem, têm o potencial de criar uma plataforma interativa e intuitiva para o cenário educacional.

Este projeto, que se encontra em uma fase intensa e promissora de desenvolvimento, busca não apenas a criação de uma ferramenta tecnológica, mas a elaboração de um ambiente virtual que seja verdadeiramente eficaz e

transformador na experiência de aprendizagem de estudantes e na prática pedagógica de educadores.

Ao mirarmos no futuro, após a conclusão desta fase de integração, emerge a aspiração de disponibilizar esta ferramenta de maneira gratuita e acessível para ambientes educacionais que operam com o idioma português.

A visão é que a implementação dessa tecnologia possa catalisar uma transformação positiva nas práticas educacionais, facilitando o acesso a métodos de ensino inovadores e contribuindo para a redução de desigualdades educacionais.

O horizonte deste projeto vislumbra, ainda, uma expansão para múltiplos idiomas, ampliando o seu alcance e impacto em uma escala global. Ao proporcionar uma plataforma multilíngue, a ferramenta poderá ser um vetor de inclusão e diversidade, conectando experiências educacionais de diferentes contextos culturais e linguísticos e promovendo uma troca enriquecedora entre elas.

Esta expansão, também, abre portas para a exploração e integração de diversas perspectivas pedagógicas, oferecendo um leque mais amplo de estratégias e recursos para educadores e aprendizes. Ademais, a estratégia de desenvolvimento contínuo, que envolve a retroalimentação constante a partir das experiências dos usuários e a introdução de melhorias e novas funcionalidades, será um pilar fundamental para garantir que a ferramenta evolua e continue a atender às necessidades e aos desafios emergentes nos campos educacional e tecnológico.

Neste sentido, a colaboração e a parceria com instituições educacionais e organizações será vital, construindo uma rede de compartilhamento de conhecimentos e experiências que enriqueça e potencialize o impacto do *Wizard User*. Assim, ao entrelaçarmos tecnologia e educação, projetamos um futuro em que o acesso à aprendizagem de qualidade é ampliado e diversificado, conectando e enriquecendo as experiências educacionais em múltiplos contextos e fronteiras. É um caminho que se constrói não apenas com código e dados, mas

com a incessante busca por uma educação mais inclusiva, acessível e empoderada para todos.

8.5 Considerações finais

Em síntese, esta tese evidenciou o potencial do *Wizard User* para qualificar a experiência de aprendizagem *on-line* em contextos reais. As análises apontaram uma associação consistente com a redução da evasão/persistência ampliada (RQ2), acompanhada de tendência de melhora do desempenho com redução da dispersão entre estudantes expostos de modo mais contínuo ao agente (RQ1). Também foram identificados sinais convergentes de engajamento, maior clareza de percurso, participação e responsividade da mediação, compatíveis com autonomia ampliada do estudante (RQ3). As respostas foram apresentadas RQ a RQ, distinguindo-se explicitamente quando a evidência é robusta (RQ2), quando é promissora, porém inconclusiva por ausência de significância global e tamanho amostral (RQ1) e quando é convergente, mas indireta por carecer de mensuração psicométrica direta (RQ3).

Tomados em conjunto, os achados coadunam-se com a literatura contemporânea em IA na Educação e sugerem um paradigma de coreografia entre docentes, estudantes e agentes inteligentes, no qual a personalização, a recomendação e a tutoria assistida operam tanto sobre médias quanto sobre a distribuição dos resultados (equidade). Reconhecidas as limitações (desenho quase experimental, poder estatístico restrito para efeitos pequenos e ausência de instrumentos psicométricos para engajamento), delinea-se uma agenda de maturidade: consolidar práticas efetivas e fidelidade de implementação; mensurar o que importa, incluindo autoeficácia, percepção de controle e utilidade com escalas validadas, trianguladas a traços comportamentais e produtos de aprendizagem; e escalar com responsabilidade, mediante replicações multicêntricas, registro prévio, transparência analítica e governança dos componentes generativos. Esse percurso sustenta a ambição desta tese: converter evidências operacionais em evidências cumulativas, capazes de informar tanto decisões institucionais quanto debates teóricos sobre personalização, engajamento e equidade em ambientes digitais.

Referências

- Abad-Segura, E., González-Zamar, M.-D., Infante-Moro, J. C., & Ruipérez García, G. (2020). *Sustainable management of digital transformation in higher education: Global research trends. Sustainability*, 12(5), 2107. <https://doi.org/10.3390/su12052107>.
- Adomavicius, G., & Tuzhilin, A. (2015). *Context-aware recommender systems. AI Magazine*, 32(3), 67–80. <https://doi.org/10.1609/aimag.v32i3.2364>.
- Adriaans, P., & Zantinge, D. (1996). *Data mining. Addison-Wesley*.
- Afonso, J., Ramirez Campillo, R., Clemente, F. M., Cléirigh Büttner, F., & Andrade, R. (2024). *The perils of misinterpret-ing and misusing “publication bias” in meta analyses: An education review on funnel-plot based methods. Sports Medicine*, 54, 257–269. <https://doi.org/10.1007/s40279-023-01927-9>.
- Agnihotri, A., & Bhattacharya, S. (2024). *Chatbots’ effectiveness in service recovery. International Journal of Information Management*, 76(102679), 102679. <https://doi.org/10.1016/j.ijinfomgt.2023.102679>.
- Akkoyunlu, B., & Soylu, M. Y. (2008). *A study of students' perceptions in a blended learning environment based on different learning styles. Educational Technology & Society*, 11(1), 183–193.
- Al Nabhani, F., Hamzah, M. B., & Abuhassna, H. (2025). *The role of artificial intelligence in personalizing educational content: Enhancing the learning experience and developing the teacher’s role in an integrated educational environment. Con-temporary Educational Technology*, 17(2), ep573. <https://doi.org/10.30935/cedtech/16089>.
- Alario-Hoyos, C., Estévez-Ayres, I., Pérez-Sanagustín, M., Kloos, C. D., & Delgado Kloos, C. (2017). *Understanding learners’ motivation and learning strategies in MOOCs. The International Review of Research in Open and Distributed Learning*, 18(3), 119–137. <https://doi.org/10.19173/irrodl.v18i3.2996>.
- Alfredo, R., Echeverria, V., Jin, Y., Yan, L., Swiecki, Z., Gašević, D., & Martinez-Maldonado, R. (2024). *Human-centred learning analytics and AI in education: a systematic literature review. Computers & Education: Artificial Intelligence*, 6(5), 100215. <https://doi.org/10.1016/j.caeai.2024.100215>.
- Alkathairi, M. S. (2022). *Artificial intelligence assisted improved human-computer interactions for computer systems. Computers and Electrical Engineering*, 101, 107950.
- Alkathairi, S. A. (2022). *Artificial intelligence in education: Benefits and challenges. Education and Information Technologies*, 27, 4697–4717. <https://doi.org/10.1007/s10639-021-10744-2>.

- Alqahtani, M., & Alreshidi, E. (2020). *Layered architecture for the development of machine learning-based software systems*. *IEEE Transactions on Software Engineering*, 46(5), 1341-1355.
- American Psychological Association. (2020). *Publication manual of the American Psychological Association (7th ed.)*. American Psychological Association.
- An, Q., Zhang, Y., Wang, Y., Xu, Z., Liu, H., Liu, Y., & Liu, J. (2023). *A comprehensive review on machine learning in healthcare*. *Sensors*, 23(9), 4178. <https://doi.org/10.3390/s23094178>.
- Anand, K., Wysocki, B., & Prabhakaran, B. (2018). *Artificial intelligence innovation in education: A twenty-year data analysis*. *International Journal of Educational Technology in Higher Education*. <https://doi.org/10.1186/s41239-018-0117-9>.
- Anderson, T., & Dron, J. (2011). *Three generations of distance education pedagogy*. *The International Review of Research in Open and Distributed Learning*, 12(3), 80–97. <https://doi.org/10.19173/irrodl.v12i3.890>.
- Anderson, T., & Shattuck, J. (2012). *Design-Based Research: A Decade of Progress in Education Research? Educational Researcher*.
- Arnau-González, P., Arevalillo-Herráez, M., Albornoz-De Luise, R., & Arnau, D. (2023). *A methodological approach to enable natural language interaction in an intelligent tutoring system*. *Computer Speech & Language*, 81, 101516. <https://doi.org/10.1016/j.csl.2023.101516>.
- Aromataris, E., & Munn, Z. (Eds.). (2020). *JBIM manual for evidence synthesis*. *Joanna Briggs Institute*. <https://doi.org/10.46658/JBIMES-20-01>.
- Ashwin, T. S., Prakash, V., & Rajendran, R. (2023). *A systematic review of intelligent tutoring systems based on gross body movement detected using computer vision*. *Computers & Education: Artificial Intelligence*, 4, 100125. <https://doi.org/10.1016/j.caeai.2023.100125>.
- Aslan, S., Alyuz, N., Li, B., Durham, L. M., Shi, M., Sharma, S., & Nachman, L. (2025). *An early investigation of collaborative problem solving in conversational AI mediated learning environments*. *Computers and Education: Artificial Intelligence*, 8(2), Article 100393. <https://doi.org/10.1016/j.caeai.2025.100393>.
- Ausubel, D. P. (1963). *The psychology of meaningful verbal learning*. Grune & Stratton.
- Awidi, I. T. (2024). *Comparing expert tutor evaluation of reflective essays with marking by generative artificial intelligence (AI) tool*. *Computers & Education: Artificial Intelligence*, 6(3), Article 100226. <https://doi.org/10.1016/j.caeai.2024.100226>.

- Baidoo-Anu, D., & Owusu Ansah, L. (2023). *Education in the era of generative artificial intelligence (AI): Understanding the potential benefits of ChatGPT in promoting teaching and learning*. Available at SSRN 4337484.
- Banihashem, S. K., Bond, M., Bergdahl, N., Khosravi, H., Noroozi, O., & et al. (2025). *A systematic mapping review at the intersection of artificial intelligence and self regulated learning*. *International Journal of Educational Technology in Higher Education*, 22, Article 50. <https://doi.org/10.1186/s41239-025-00548-8>.
- Barrot, J. S. (2023). *Trends in automated writing evaluation systems research for teaching, learning, and assessment: A bibliometric analysis*. *Education and Information Technologies*. <https://doi.org/10.1007/s10639-023-12083-y>.
- Barth, F. (2017). *Computação cognitiva e inteligência artificial: conceitos e aplicações em larga escala*. *Computação Cognitiva e a Humanização das Máquinas*, 14(17), 59-63.
- Basilaia, G. (2020). *Replacing the classic learning form at universities as an immediate response to the COVID-19 virus infection in Georgia*. *International Journal for Research in Applied Science and Engineering Technology*, 8(3), 101–108. <https://doi.org/10.22214/ijraset.2020.3021>.
- Bates, A. W. (2014). *A short history of educational technology*. Disponível em <https://www.tonybates.ca/2014/12/10/a-short-history-of-educational-technology/>.
- Bell, P. (2004). *On the theoretical breadth of design-based research in education*. *Educational Psychologist*, 39(4), 243-253. http://faculty.washington.edu/pbell/EPDBR_Bell.pdf
- Bernardini, S., Porayska-Pomsta, K., & Smith, T. J. (2013). *ECHOES: An intelligent serious game for fostering social communication in children with autism spectrum conditions*. *Computers & Education*, 62, 272–292. <http://dx.doi.org/10.1016/j.ins.2013.10.027>.
- Berry, M. J. A., & Linoff, G. S. (1997). *Data mining techniques: For marketing, sales, and customer support*. Wiley.
- Biørn-Hansen, A., Grønli, T.-M., & Ghinea, G. (2017). *A context-aware hybrid recommender system for smart learning environments*. *Procedia Computer Science*, 112, 1223–1232. <https://doi.org/10.1016/j.procs.2017.08.044>.
- Boateng, O., & Boateng, B. (2025). *Algorithmic bias in educational systems: Examining the impact of AI-driven decision making in modern education*. *World Journal of Advanced Research and Reviews*, 25(1), 2012–2017. <http://dx.doi.org/10.30574/wjarr.2025.25.1.0253>.
- Bond, M. (2024). *A meta systematic review of artificial intelligence in higher education: Scope, adaptive systems, and per-sonalization trends*.

- International Journal of Educational Technology in Higher Education*, 21(4).
<https://doi.org/10.1186/s41239-023-00436-z>.
- Bond, M., Zawacki Richter, O., & Nichols, M. (2021). *Revisiting five decades of educational technology research: A content and authorship analysis of the British Journal of Educational Technology*. *British Journal of Educational Technology*, 52(1), 8–28. <http://dx.doi.org/10.1111/bjet.12730>.
- Bonner, D., Stephen, G., Dorneich, M., Winer, E., Sinatra, A., Slavina, A., MacAllister, A., & Holub, J. (2016). *The challenges of building intelligent tutoring systems for teams*. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 60, 1981–1985.
<https://doi.org/10.1177/1541931213601451>.
- Borenstein, M., Hedges, L. V., Higgins, J. P. T., & Rothstein, H. R. (2010). *A basic introduction to fixed-effect and random-effects models for meta-analysis*. *Research Synthesis Methods*, 1(2), 97–111. <https://doi.org/10.1002/jrsm.12>.
- Borges, G., & Stiubiener, I. (2014). Modelo de recomendação com base no estilo de aprendizagem. In *Anais do ESUD - XI Congresso Brasileiro de Ensino Superior a Distância*.
- Brown, M. (2012). *Learning analytics: Moving from concept to practice*. *Educause Review - Learning Initiative Brief*.
- Bryson, D. (2022). *25 Years on: progress in computer based learning*. *Journal of Computer Assisted Learning*, 38(1), 195–209.
<https://doi.org/10.1080/17453054.2021.2004884>.
- Bulut, O., Beiting-Parrish, M., Casabianca, J. M., Slater, S. C., Jiao, H., Song, D., Ormerod, C. M., Fabiyi, D. G., Ivan, R., Walsh, C., Rios, O., Wilson, J., Yıldırım-Erbaşı, S. N., Wongvorachan, T., Liu, J. X., Tan, B., & Morilova, P. (2024). *The Rise of Artificial Intelligence in Educational Measurement: Opportunities and Ethical Challenges*. arXiv.
<https://doi.org/10.48550/arXiv.2406.18900>.
- Burke, R. (2002). *Hybrid recommender systems: Survey and experiments*. *User Modeling and User-Adapted Interaction*, 12(4), 331–370.
<https://doi.org/10.1023/A:1021240730564>.
- Carbonell, J. R. (1970). *AI in CAI: An artificial-intelligence approach to computer-aided instruction*. *IEEE Transactions on Man-Machine Systems*, 11(4), 190–202. <https://ieeexplore.ieee.org/document/4081977>.
- Charmaz, K. (2006). *Constructing grounded theory*. Sage Publications.
- Cervo, A. L., & Bervian, P. A. (2017). *Metodologia científica (6ª ed.)*. Pearson Education do Brasil.

- Chen, G. H. (2024). *An introduction to deep survival analysis models for predicting time-to-event outcomes. Foundations and Trends® in Machine Learning*, 17(6), 921–1100. <https://doi.org/10.1561/2200000114>.
- Chen, L., Chen, P., & Lin, Z. (2020). *Artificial intelligence in education: A review. IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/ACCESS.2020.2988510>.
- Chen, M., Radford, A., Child, R., Wu, J., Jun, S., Dhariwal, P., & Sutskever, I. (2021). *GPT-3: Generative pre-training transformer 3. arXiv preprint arXiv:2005.14165*.
- Chinta, S. V., Wang, Z., Yin, Z., Hoang, N., Gonzalez, M., Le Quy, T., & Zhang, W. (2024). *FairAIED: Navigating fairness, bias, and ethics in educational AI applications. arXiv*. <https://arxiv.org/abs/2407.18745>.
- Chiu, T. K. F., Chen, Y., Yau, K. W., Chai, C.-S., Meng, H., King, I., Wong, S., & Yam, Y. (2024). *Developing and validating measures for AI literacy tests: From self-reported to objective measures. Computers and Education: Artificial Intelligence*, 7(100282), 100282. <https://doi.org/10.1016/j.caeai.2024.100282>.
- Collins, A., Joseph, D., & Bielaczyc, K. (2004). *Design research: Theoretical and methodological issues. Journal of the Learning Sciences*, 13(1), 15–42. https://doi.org/10.1207/s15327809jls1301_2
- Cooper, S., Nam, Y.-J., & Si, L. (2012). *Initial results of using an intelligent tutoring system with Alice. In Proceedings of the 17th Annual Conference on Innovation and Technology in Computer Science Education* (pp. 187-191). Haifa, Israel.
- Corbett, A. T., Koedinger, K. R., & Anderson, J. R. (1997). *Intelligent tutoring systems. In M. G. Helander, T. K. Landauer, & P. V. Prabhu (Eds.), Handbook of Human-Computer Interaction (2nd ed., pp. 849–874). Elsevier*.
- Córdova Esparza, D. M., Terven, J., Romero González, J. A., Córdova Esparza, K. E., López Martínez, R. E., García Ramírez, T., & Chaparro Sánchez, R. (2025). *Predicting and Preventing School Dropout with Business Intelligence: Insights from a Systematic Review. Information*, 16(4), 326. <https://doi.org/10.3390/info16040326>.
- Cossul, D., Fagundes, B. J., Ferreira, G., Frozza, R., Silveira, W. A. N., & Tobón Clavijo, M. L. (2020). *Ambiente virtual de aprendizagem: Uma abordagem baseada em mediação tecnológica personalizada. Brazilian Journal of Development*, 6(12), 101847-101888. <https://doi.org/10.34117/bjdv6n12-617>.
- Costa, J. P. C., Almeida, V. E. de, & Carvalho, P. V. R. de. (2025). *Inteligência artificial na educação: benefícios e desafios em uma conversa inicial. Revista Carioca de Ciência, Tecnologia e Educação*, 9(2), 32–43. <https://files.eric.ed.gov/fulltext/ED673066.pdf>

- Crompton, H., & Burke, D. (2023). *Artificial intelligence in higher education: the state of the field*. *International Journal of Educational Technology in Higher Education*, 20, Article 22. <https://doi.org/10.1186/s41239-023-00392-8>.
- Curto, J., & Ríos, A. (2022). *API management in cloud environments: Challenges and opportunities*. *Journal of Cloud Computing*, 11(1), 25. <https://doi.org/10.1186/s13677-022-00340-9>.
- Dean Jr., D., & Kuhn, D. (2007). *Direct instruction vs. discovery: The long view*. *Science Education*, 91(3), 384–397. <https://doi.org/10.1002/sce.20194>.
- Denzin, N. K., & Lincoln, Y. S. (2005). *The Sage handbook of qualitative research (3rd ed.)*. Sage Publications.
- Desrosiers, C., & Karypis, G. (2011). *A comprehensive survey of neighborhood-based recommendation methods*. In F. Ricci, L. Rokach, B. Shapira, & P. B. Kantor (Eds.), *Recommender systems handbook (pp. 107–144)*. Springer.
- Dragoni, N., Giazzi, L., Mazzara, M., & Zhou, Z. (2017). *Microservices: Yesterday, today, and tomorrow*. In *Present and Ulterior Software Engineering (pp. 195–216)*. Springer. https://doi.org/10.1007/978-3-319-67425-4_12.
- Easterday, M. W., Lewis, D. R., & Gerber, E. M. (2014). *Design-based research process: Problems, phases, and applications*. *Proceedings of International Conference of the Learning Sciences*. Retrieved from https://www.researchgate.net/publication/288434629_Design-based_research_process_Problems_phases_and_applications.
- Ebert, C., Gallardo, G., Hernantes, J., & Serrano, N. (2016). *DevOps*. *IEEE Software*, 33(3), 94–100. <https://doi.org/10.1109/MS.2016.68>.
- Elliott, D. L., & Anderson, C. (2023). *The wisdom of the crowd: Reliable deep reinforcement learning through ensembles of Q-functions*. *IEEE Transactions on Neural Networks and Learning Systems*, 34(1), 43–51. <https://doi.org/10.1109/TNNLS.2021.3089425>.
- Essel, H. B., Vlachopoulos, D., Essuman, A. B., & Amankwa, J. O. (2024). *ChatGPT effects on cognitive skills of undergraduate students: Receiving instant responses from AI-based conversational large language models*. *Education and Information Technologies*. Advance online publication. <https://www.sciencedirect.com/science/article/pii/S2666920X23000772>.
- Eltahir, M. E., & Babiker, F. M. E. (2024). *The Influence of Artificial Intelligence Tools on Student Performance in e-Learning Environments: Case Study*. *Electronic Journal of e-Learning*, 22(9), 91-110. <https://doi.org/10.34190/ejel.22.9.3639>
- Fagundes, B., Cossul, D., & Frozza, R. (2020). *Inteligência artificial e e learning em tempos de pandemia: desafios, oportunidades e compromissos*. Apresentação em seminário. Disponível em

- <https://online.unisc.br/acadnet/anais/index.php/mostraextensaounisc/article/view/20438>.
- Ferguson, R. (2022). *Learning analytics: A five-year review*. *British Journal of Educational Technology*, 53(2), 217–239. <https://doi.org/10.1111/bjet.13167>.
- Flores, D. G. M., Rocha, H., Reis, R., & Bassani, P. B. S. (2021). Uma revisão sistemática sobre o uso da inteligência artificial na educação. *Revista Brasileira de Informática na Educação*, 29(1), 85–103. <https://doi.org/10.5753/rbie.2021.29.1.85>.
- Flores, F. A. I., Sanchez, D. L. C., Urbina, R. O. E., Coral, M. Á. V., Medrano, S. E. V., & Gonzales, D. G. E. (2022). *Inteligencia artificial en educación: una revisión de la literatura en revistas científicas internacionales*. *Apuntes universitarios*, 12(1), 353-372.
- Fórum Econômico Mundial. (2020). *The future of jobs report 2020*. [Sem DOI] <https://www.weforum.org/reports/the-future-of-jobs-report-2020>.
- Gao, X., Si, J., & Huang, H. (2024). *Reinforcement learning control with knowledge shaping*. *IEEE Transactions on Neural Networks and Learning Systems*, 35(3), 3156–3167. <https://doi.org/10.1109/TNNLS.2023.3243631>.
- Gartner. (s.d.). *Data mining*. Em *Gartner IT Glossary*. Recuperado de <https://www.gartner.com/en/information-technology/glossary/data-mining>.
- Gašević, D., Dawson, S., & Siemens, G. (2020). *Let's not forget: Learning analytics are about learning*. *TechTrends*, 64(1), 64–73. <https://doi.org/10.1007/s11528-019-00477-4>.
- Ghimire, S., Abdulla, S., Joseph, L. P., Prasad, S., Barua, P. D., Deo, R. C., Acharya, R., & Yaseen, Z. M. (2024). *Explainable artificial intelligence–machine learning models to estimate overall scores in tertiary preparatory general science course*. *Computers & Education: Artificial Intelligence*, 7, 100331. <https://doi.org/10.1016/j.caeai.2024.100331>.
- Gkogkidis, V., & Dacre, N. (2021). *Exploratory learning environments for responsible management education using Lego Serious Play*. arXiv. <https://doi.org/10.48550/arXiv.2104.12539>.
- Gligorea, I. (2023). *Adaptive learning using artificial intelligence in e-Learning*. *Education Sciences*, 13(12), 1216. <https://doi.org/10.3390/educsci13121216>.
- Gomes, L. H. (2017). Educação e tecnologia no século XXI: desafios e perspectivas. *Revista Educação e Cultura Contemporânea*, 14(35), 35–50. <https://doi.org/10.5935/2238-1279.20170004>.
- Google Cloud AutoML Google Cloud. (2024). *AutoML Documentation*. <https://cloud.google.com/automl/docs>.

- Google Cloud. (2024). *AutoML Documentation*.
<https://cloud.google.com/automl/docs>.
- Graesser, A. C., VanLehn, K., Rose, C. P., Jordan, P., & Harter, D. (2001).
Intelligent tutoring systems with conversational dialogue. *AI Magazine*, 22(4),
39–51.
- Groothuijsen, S., van den Beemt, A. A. J., Remmers, J. J. C., & van Meeuwen, L.
W. (2024). *AI chatbots in programming education: Students' use in a
scientific computing course and consequences for learning*. *Computers and
Education: Artificial Intelligence*, 7, Article 100290.
<https://doi.org/10.1016/j.caeai.2024.100290>.
- Gu, X. (2023). *Autonomous learning for fuzzy systems: a review*. *Artificial
Intelligence Review*, 56, 3147–3175. <https://doi.org/10.1007/s10462-022-10355-6>.
- Guan, C., Mou, J., & Jiang, Z. (2020). *Artificial intelligence innovation in education:
A twenty-year data-driven historical analysis*. *International Journal of
Innovation Studies*, 4(4), 134–147. <https://doi.org/10.1016/j.ijis.2020.09.001>.
- Guyatt, G. H., Oxman, A. D., Vist, G. E., Kunz, R., Falck-Ytter, Y., Alonso-Coello,
P., & Schünemann, H. J. (2008). *GRADE: An emerging consensus on rating
quality of evidence and strength of recommendations*. *BMJ*, 336(7650), 924–
926. <https://doi.org/10.1136/bmj.39489.470347.AD>.
- Hämäläinen, W. (2011). *Efficient search for statistically significant dependency
rules in binary data*. *Journal of Machine Learning Research*, 12, 1383–1413.
- Hämäläinen, W., & Vinni, M. (2011). *Classifiers for educational data mining*. In
Romero et al. Handbook of educational data mining.
- Han, G. (2022, August 8). *10 uses of AI in everyday life*. *IEEE Transmitter*.
<https://transmitter.ieee.org/10-uses-of-ai-in-everyday-life/>.
- Harasim, L. (2000). *Shift happens: Online education as a new paradigm in
learning*. *The Internet and Higher Education*, 3(1-2), 41-61.
- Haugeland, J. (1985). *Artificial intelligence: The very idea*. Cambridge, MA: MIT
Press.
- Haykin, S. (1999). *Neural networks: A comprehensive foundation (2nd ed.)*.
Prentice Hall.
- Heung, Y. M. E., & Chiu, T. K. T. (2025). *How ChatGPT impacts student
engagement: a systematic review and meta-analysis study*. *Computers &
Education: Artificial Intelligence*, 8, Article 100361.
<https://doi.org/10.1016/j.caeai.2025.100361>.

- Higgins, J. P. T. et al. (2022). *Cochrane Handbook for Systematic Reviews of Interventions*.
- Higgins, J. P. T., Thompson, S. G., Deeks, J. J., & Altman, D. G. (2003). *Measuring inconsistency in meta-analyses*. *BMJ*, 327(7414), 557-560. <https://doi.org/10.1136/bmj.327.7414.557>.
- Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial intelligence in education: Promises and implications for teaching and learning*. Center for Curriculum Redesign. https://www.researchgate.net/publication/332180327_Artificial_Intelligence_in_Education_Promise_and_Implications_for_Teaching_and_Learning.
- Holmes, W., & Porayska-Pomsta, K. (Eds.). (2022). *The Ethics of Artificial Intelligence in Education: Practices, Challenges, and Debates*. Routledge. <https://doi.org/10.4324/9780429329067>.
- Holmes, W., Bialik, M., & Fadel, C. (2022). *Artificial intelligence in education: Promises and implications for teaching and learning (2nd ed.)*. Center for Curriculum Redesign.
- Hu, Y., Ferreira Mello, R., & Gašević, D. (2021). *Automatic analysis of cognitive presence in online discussions: An approach using deep learning and explainable artificial intelligence*. *Computers and Education: Artificial Intelligence*, 2(100037), 100037. <https://doi.org/10.1016/j.caeai.2021.100037>.
- Huang, J., Saleh, S., & Liu, Y. (2021). *A review on artificial intelligence in education*. *Academic Journal of Interdisciplinary Studies*, 10(3), 206. <https://doi.org/10.36941/ajis-2021-0077>.
- Hudge, S. (2024). *Layers in software architecture*. Medium. <https://medium.com/@sagar.hudge/layers-in-software-architecture-c8cc16329ff6>.
- Humble, J., & Kim, G. (2021). *Accelerate: The science of lean software and DevOps*. IT Revolution Press.
- Hume, T. (2017). *How algorithms can bring bias into our everyday lives*. *Journal of Ethics in AI*, 14(2), 119-130.
- IBM Education. (2019). Recuperado em julho de 2019, de <https://www.ibm.com/watson/education>.
- IBM Watson Studio. IBM. (2025). *Watson Studio Documentation*. <https://www.ibm.com/docs/en/watson-studio>.
- IBM. (2025). *Watson Studio Documentation*. <https://www.ibm.com/docs/en/watson-studio>.

- IBM. (2019). *What is cognitive computing?* Recuperado em julho de 2019, de <http://www.research.ibm.com/artificial-intelligence/>.
- Ifenthaler, D., & Schumacher, C. (2023). *Student perceptions of learning analytics dashboards: A systematic review*. *Computers & Education*, 194, 104668. <https://doi.org/10.1016/j.compedu.2022.104668>.
- IMS Global. (2021). *Learning Tools Interoperability (LTI) standard*. IMS Global Learning Consortium. <https://www.imsglobal.org/activity/learning-tools-interoperability>.
- Jiao, P., Ouyang, F., Zhang, Q., & Alavi, A. H. (2022). *Artificial intelligence enabled prediction model of student academic performance in online engineering education*. *Artificial Intelligence Review*, 55, 6321–6344. <https://link.springer.com/article/10.1007/s10462-022-10155-y>.
- Kaffenberger, M. (2021). *The long-run learning effects of a school shutdown*. *Economics of Education Review*, 83, 102–114. <https://doi.org/10.1016/j.econedurev.2021.102103>.
- Kaliisa, R., Misiejuk, K., López-Pernas, S., Khalil, M., & Saqr, M. (2023). *Have learning analytics dashboards lived up to the hype? A systematic review of impact on students' achievement, motivation, participation and attitude*. *Computers & Education: Artificial Intelligence*. Advance online publication. <https://doi.org/10.48550/arXiv.2312.15042>.
- Ke, M. F. (2023). *Applications and challenges of artificial intelligence in the future of art education*. *Pacific International Journal*, 6(3), 61–65. <http://dx.doi.org/10.55014/pij.v6i3.405>.
- Kiryakova, G., Angelova, N., & Yordanova, L. (2014). *Gamification in education*. *Proceedings of 9th International Balkan Education and Science Conference*. <https://doi.org/10.23913/ride.v11i22.848>.
- Kitchenham, B., Charters, S., & Budgen, D. (2009). *Guidelines for performing systematic literature reviews in software engineering (EBSE Technical Report)*. Keele University and Durham University Joint Report.
- Koedinger, K. R., Anderson, J. R., Hadley, W. H., & Mark, M. A. (1997). *Intelligent tutoring goes to school in the big city*. *International Journal of Artificial Intelligence in Education*, 8, 30-43.
- Kohn, K., & Moraes, C. H. de. (2007). O impacto das novas tecnologias na sociedade: conceitos e características da Sociedade da Informação e da Sociedade Digital. In Congresso Brasileiro de Paraná Turismo (2012) Relatório de Hierarquização Turística do Estado do Paraná.
- Krueger, R. A., & Casey, M. A. (2000). *Focus groups: A practical guide for applied research (3ª ed.)*. Sage Publications.

- Kruskal, W. H., & Wallis, W. A. (1952). *Use of ranks in one-criterion variance analysis*. *Journal of the American Statistical Association*, 47(260), 583–621.
- Kuhail, M. A., Farooq, M. U., & Al-Emran, M. (2023). *Chatbots in education: A systematic review*. *Education and Information Technologies*, 28(6), 6923–6950. <https://doi.org/10.1007/s10639-023-11628-7>.
- Labadze, L. (2023). *Role of AI chatbots in education: Systematic literature review*. *International Journal of Educational Technology in Higher Education*. <https://doi.org/10.1186/s41239-023-00426-1>.
- Marconi, M. de A., & Lakatos, E. M. (2017). *Fundamentos de metodologia científica (8ª ed.)*. Atlas.
- Lapan, S. D., Quartaroli, M. T., & Riemer, F. J. (2012). *Qualitative research: An introduction to methods and designs*. Jossey-Bass Publishing.
- Leelawong, K., & Biswas, G. (2008). *Designing learning by teaching agents: The Betty's Brain system*. *International Journal of Artificial Intelligence in Education*, 18(3), 181-208. <https://doi.org/10.1007/s12345-008-0000-x>.
- Levene, H. (1960). Robust tests for equality of variances. In I. Olkin (Ed.), *Contributions to Probability and Statistics (pp. 278–292)*. Stanford University Press.
- Lewis, J., Fowler, M., & Ford, N. (2021). *Building evolutionary architectures: Support constant change*. O'Reilly Media.
- Li, S., Liu, Y., & Liu, J. (2019). *Smart Transportation Systems: Architecture, Enabling Technologies, and Open Issues*. *IEEE Transactions on Intelligent Transportation Systems*, 20(11), 1465-1492. <https://doi.org/10.1109/TITS.2019.2904203>.
- Li, Z., Wang, L., & Xu, J. (2025). A layered and vertical architecture for smart mobile distributed systems. *Applied Sciences*, 15(7), 3664. <https://doi.org/10.3390/app15073664>.
- Liang, B., Su, H., Gui, L., Cambria, E., & Xu, R. (2022). *Aspect based sentiment analysis via affective knowledge enhanced graph convolutional networks*. *Knowledge-Based Systems*, 235, 107643. <https://doi.org/10.1016/j.knosys.2021.107643>.
- Lincoln, Y. S., & Guba, E. G. (1985). *Naturalistic inquiry*. Sage Publications.
- Liu, H., Li, W., Wang, J., & Zhang, Q. (2025). *Large Language Models for Intelligent Tutoring Systems: Opportunities and Challenges*. *PeerJ Computer Science*, 11, e2991. <https://doi.org/10.7717/peerj-cs.2991>.

- Luckin, R. (2018). *Machine Learning and Human Intelligence: The Future of Education for the 21st Century*. UCL Institute of Education Press. <https://discovery.ucl.ac.uk/id/eprint/10178695>.
- Luckin, R. (2020, 22 de out. de 2020). *Machine Learning and Human Intelligence, the Future of Education*. YouTube. Disponível em <https://www.youtube.com/watch?v=P33FRjJWh4E>.
- Luckin, R., & Bearman, M. (2020). *Preparing university assessment for a world with AI: Tasks for human intelligence*. In *Re-imagining University Assessment in a Digital World* (pp. 49–63). Springer. https://doi.org/10.1007/978-3-030-41956-1_5.
- Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. B. (2023). *Intelligence Unleashed: An Argument for AI in Education (2nd Ed.)*. Pearson. https://www.pearson.com/content/dam/one-dot-com/one-dot-com/global/Files/about-pearson/innovation/open-ideas/Intelligence-Unleashed_v2.pdf
- Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. B. (2016). *Intelligence Unleashed: An Argument for AI in Education*. Pearson. Recuperado de <https://static.googleusercontent.com/media/edu.google.com/en//pdfs/Intelligence-Unleashed-Publication.pdf>
- Lupton, D., & Williamson, B. (2017). *The datafied child: The dataveillance of children and implications for their rights*. *New Media & Society*, 19(5), 780-794. <https://doi.org/10.1177/1461444816686328>
- Maity, S., & Deroy, A. (2024). *Human-Centric eXplainable AI in education*. arXiv. <https://arxiv.org/abs/2401.19822>.
- Martin, F., & Bolliger, D. U. (2018). *Engagement matters: Student perceptions on the importance of engagement strategies in the online learning environment*. *Online Learning*, 22(1), 205–222. <https://doi.org/10.24059/olj.v22i1.1092>.
- Matta, A. E. R., Silva, F. de P. S. da, & Boaventura, E. M. (2014). *Design-Based Research* ou pesquisa de desenvolvimento: metodologia para pesquisa aplicada de inovação em educação do século XXI. *Revista da FAEEBA – Educação e Contemporaneidade*, 23(42), 23-36.
- Mazza, R., & Dimitrova, V. (2004). *Visualising student tracking data to support instructors in web-based distance education*. In *Proceedings of the 13th International World Wide Web Conference (WWW 2004 Alt. Track Papers)* (pp. 154–161). ACM. <https://doi.org/10.1145/1013367.1013393>.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). *A proposal for the Dartmouth summer research project on artificial intelligence, August 31, 1955*. *AI Magazine*, 27(4), 12. <https://doi.org/10.1609/aimag.v27i4.1904>.

- McCulloch, W. S., & Pitts, W. (1947). *On how we know universals: The perception of auditory and visual forms*. *Bulletin of Mathematical Biophysics*, 9(3), 127–147. <https://doi.org/10.1007/BF02478291>.
- McKenney, S., & Reeves, T. C. (2012). *Conducting educational design research*. Routledge. <https://doi.org/10.4324/9780203818183>.
- McMaster University. (2025). *GRADEpro GDT: GRADEpro Guideline Development Tool [Software]*. Evidence Prime, Inc. Disponível em <https://gdt.gradepro.org/>.
- Meira, D., Tavares, M. G., & Amaral, A. R. (2020). Aplicações da inteligência artificial na educação: Uma revisão sistemática da literatura. *Revista Educação e Tecnologia*, 25(2), 1–14. <https://doi.org/10.5965/1984317817252020101>.
- Merino Campos, C. (2025). *The impact of artificial intelligence on personalized learning in higher education: A systematic review*. *Trends in Higher Education*, 4(2), 17. <https://doi.org/10.3390/higheredu4020017>.
- Mhlanga, D. (2023). *Open AI in education, the responsible and ethical use of ChatGPT towards lifelong learning*. *Education, the Responsible and Ethical Use of ChatGPT Towards Lifelong Learning (February 11, 2023)*.
- Microsoft Azure Machine Learning. Microsoft. (2025). *Azure Machine Learning documentation*. <https://learn.microsoft.com/en-us/azure/machine-learning/>.
- Microsoft Education School. (n.d.). Recuperado em julho de 2019, de <https://aischool.microsoft.com/en-us/home>.
- Microsoft. (2025). *Azure Machine Learning documentation*. <https://learn.microsoft.com/en-us/azure/machine-learning/>.
- Moe, N. B., Šmite, D., & Ågerfalk, P. J. (2022). *Understanding distributed agile development: A systematic review*. *Empirical Software Engineering*, 27(2), 35. <https://doi.org/10.1007/s10664-021-10073-6>.
- Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., & The PRISMA Group. (2009). *Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement*. *PLoS Medicine*, 6(7), e1000097. <https://doi.org/10.1371/journal.pmed.1000097>.
- Morgado, J. C. (2012). *O estudo de caso na investigação em educação*. Santo Tirso, Portugal: De Facto Editores.
- Neo, M., Lee, C. P., Tan, H. Y. J., Neo, T. K., Tan, Y. X., Mahendru, N., & Ismat, Z. (2022). *Enhancing Students' Online Learning Experiences with Artificial Intelligence (AI): The MERLIN Project*. *International Journal of Technology*, 13(5), 1023–1034. <http://dx.doi.org/10.14716/ijtech.v13i5.5843>.

- Neves, B. V. D., Vargas, F. D. P. C., Vaz, G. G. M., & Rocha, R. S. (2023). Logia: inteligência artificial aplicada ao design de interface voltado para a educação.
- Nguyen, A., Gardner, L. A., & Sheridan, D. (2020). *Data analytics in higher education: An integrated view*. *Journal of Information Systems Education*, 31(1), 61–71. <http://jise.org/Volume31/n1/JISEv31n1p61.html>
- Nguyen, P. T. H., & Sudholt, D. (2020). *Memetic algorithms outperform evolutionary algorithms in multimodal optimisation*. *Artificial Intelligence*, 287(103345), 103345. <https://doi.org/10.1016/j.artint.2020.103345>.
- OECD. (2020). *Trustworthy artificial intelligence (AI) in education: Promises and challenges*. *OECD Education Working Papers*, No. 218. Paris: OECD Publishing. <https://doi.org/10.1787/a6c90fa9-en>.
- Oliveira, M. P. (2015). Sociedade do conhecimento e novas tecnologias na educação. *Revista Tempos e Espaços em Educação*, 8(15), 199–210. <https://doi.org/10.20952/revtee.v8i15.4706>.
- OpenAI API (incluindo ChatGPT e modelos de IA generativa) OpenAI. (2025). *OpenAI API Documentation*.
- OpenAI. (2025). *OpenAI API Documentation*.
- Page, M. J. et al. (2021). *The PRISMA 2020 Statement: An Updated Guideline for Reporting Systematic Reviews*. *BMJ*.
- Palermo, C., & Wilson, J. (2020). *Implementing automated writing evaluation in different instructional contexts: A mixed-methods study*. *Journal of Writing Research*, 12(1), 63–108. <https://doi.org/10.17239/jowr-2020.12.01.04>.
- Papamitsiou, Z., & Economides, A. A. (2021). *Learning analytics and educational data mining in practice: A systematic literature review of empirical evidence*. *Educational Technology & Society*, 24(2), 1–24.
- Pardamean, B., Suparyanto, T., Cenggoro, T. W., Sudigyo, D., & Anugrahana, A. (2022). *AI based learning style prediction in online learning for primary education*. *IEEE Access*, 10, 35725–35735. <https://doi.org/10.1109/ACCESS.2022.3160177>.
- Pardo, A. (2017a). *A feedback model for data-rich learning experiences*. *Assessment & Evaluation in Higher Education*, 43(2), 428–438. <https://doi.org/10.1080/02602938.2017.1356904>.
- Pardo, A., Jovanovic, A., Dawson, S., Gašević, S., & Mirriahi, N. (2017b). *Using learning analytics to scale the provision of personalised feedback*. *British Journal of Educational Technology*, 48(4), 943–956. <https://doi.org/10.1111/bjet.12592>.

- Pazzani, M. J., & Billsus, D. (2007). *Content-based recommendation systems*. In P. Brusilovsky, A. Kobsa, & W. Nejdl (Eds.), *The adaptive web* (pp. 325–341). Springer.
- Petticrew, M., & Roberts, H. (2006). *Systematic reviews in the social sciences: A practical guide*. Oxford: Blackwell Publishing.
<https://doi.org/10.1002/9780470754887>.
- Pitts, W., & McCulloch, W. (1947). *How we know universals the perception of auditory and visual forms*. *Bulletin of Mathematical Biophysics*, 9, 127-147.
- PRISMA 2020. Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). *The PRISMA 2020 statement: An updated guideline for reporting systematic reviews*. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>.
- Radianti, J., Majchrzak, T. A., Fromm, J., & Wohlgenannt, I. (2020). *A systematic review of immersive virtual reality applications for higher education: Design elements, lessons learned, and research agenda*. *Computers & Education*, 147, 103778. <https://doi.org/10.1016/j.compedu.2019.103778>.
- Resnick, P., & Varian, H. R. (1997). *Recommender systems*. *Communications of the ACM*, 40(3), 56–58. <https://doi.org/10.1145/245108.245121>.
- Reeves, T. C., Herrington, J., & Oliver, R. (2005). *Design research: A socially responsible approach to instructional technology research in higher education*. *Journal of Computing in Higher Education*, 16(2), 96–115.
<https://doi.org/10.1007/BF02961476>
- Ríos Félix, J. M., Zatarain Cabada, R., Barrón Estrada, M. L., & Favela Vara, J. (2020). *An intelligent learning environment for computational thinking*. *Computación y Sistemas*, 24(3), 1199–1210. <https://doi.org/10.13053/cys-24-3-3480>.
- Romero, C., & Ventura, S. (2024). *Educational data mining and learning analytics: An updated survey*. [Pre print]. arXiv.
<https://doi.org/10.48550/arXiv.2402.07956>.
- Romero-Ariza, M. (2014). *Design-based research: A methodology to improve teaching and learning*. *Revista Eureka sobre Enseñanza y Divulgación de las Ciencias*, 11(2), 247–259.
https://doi.org/10.25267/Rev_Eureka_ensendivulgcienc.2014.v11.i2.08.
- Rosenbloom, P. S. (2023). *Rethinking the Physical Symbol Systems Hypothesis*. arXiv. <https://doi.org/10.48550/arXiv.2306.13150>.

- Rosito, F. C., do Sacramento Soares, E. M., & Webber, C. G. (2021). Práticas educativas no contexto da indústria 4.0: Algumas considerações. *Educação Contemporânea-Volume 15 Ensino Superior*, 35.
- Rosito, M. F., Soares, R. S., & Webber, C. (2021). *Learning analytics* na educação superior: Um estudo bibliométrico. *Revista Brasileira de Educação*, 26. <https://doi.org/10.1590/S1413-24782021260080>.
- Russell, R., & Norvig, P. (2003). *Artificial intelligence, a modern approach (2ª ed.)*. Prentice Hall.
- Sandoval, W. A., & Bell, P. (2004). *Design-Based Research Methods for Studying Learning in Context: Introduction*. *Educational Psychologist*, 39(4), 199-201. https://www.academia.edu/797320/Designbased_research_methods_for_studying_learning_in_context_Introduction.
- Sandoval, W., & Bell, P. (2004). *Design-based research methods for studying learning in context*. *Educational Psychologist*, 39(4), 199–201. https://doi.org/10.1207/s15326985ep3904_1.
- Santos Magalhães, C., & D’Emery, T. (2010). Ambientes virtuais de aprendizagem: princípios pedagógicos e tecnológicos. In E. J. Saviani, M. M. Oliveira & N. B. de Castro (Orgs.), *Tecnologias digitais na educação: Formação continuada de professores* (pp. 191-210). Brasília: Unesco. <https://unesdoc.unesco.org/ark:/48223/pf0000187399>.
- Santos Magalhães, O., & D’Emery, F. (2010). Mudança no conteúdo dos ambientes educativos em EaD com inserção dos conceitos de IA. *Revista Amor Mundi*, 4(11), 111–118. <https://doi.org/10.46550/amormundi.v4i11.379>.
- Santos, E. (2009). Educação on-line para além da EAD: um fenômeno da cibercultura. *In Anais, 10º Congresso Internacional galego-português de Psicopedagogia* (pp. 5658-5671). Braga: Uminho.
- Santos, J. C. dos, Bastos, F. A., Souza, M. M. de, Figueiredo, A. B. de, Teixeira, I. R. do V., & Quintiliano, L. de C. (2021). Percepção sobre educação em ambiente remoto dos alunos participantes de programas de iniciação à docência (PIBID e Pró-Licenciaturas) do Instituto Federal do Sul de Minas Gerais (IFSULDEMINAS). *Research, Society and Development*, 10(14), e135101421812. <https://doi.org/10.33448/rsd-v10i14.21812>.
- Säuberlich, F. (2018, 25 de fevereiro). *AI without machine learning*. *Teradata*. <https://www.teradata.com/insights/ai-and-machine-learning/ai-without-machine-learning>.
- Schmucker, D., Sonboli, N., Demszky, D., & Piech, C. (2024). *Ruffle & Riley: A conversational tutoring system using large language models (NeurIPS Workshop on Generative AI in Education)*. Retrieved from https://gaied.org/neurips2023/files/38/38_paper.pdf

- Schünemann, H., Brožek, J., Guyatt, G., & Oxman, A. (Eds.). (2013). *GRADE handbook for grading quality of evidence and strength of recommendations. The GRADE Working Group. Disponível em* <https://gdt.gradepro.org/app/handbook/handbook.html>
- Schwaber, K., & Sutherland, J. (2020). *The Scrum Guide. Scrum.org.* <https://scrumguides.org>.
- Seo, K. K., & Gurung, B. (2021). *The impact of artificial intelligence on learner–instructor interactions in online education: Enhancing personalization, automating routine teaching tasks, and supporting assessment. International Journal of Educational Technology in Higher Education, 18(1), Article 9.* <https://doi.org/10.1186/s41239-021-00292-9>.
- Serrador, P., & Pinto, J. K. (2023). Does Agile work? — A quantitative analysis of agile project success. *International Journal of Project Management, 41(1), 45–58.* <https://doi.org/10.1016/j.ijproman.2022.08.005>.
- Shannon, C. E. (1950). *Programming a computer for playing chess. Philosophical Magazine, 41(314), 256–275.* <https://doi.org/10.1080/14786445008521796>.
- Shannon, C. E. (1950). *Programming a computer for playing chess. The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science, 41(314), 256-275.*
- Shapiro, S. S., & Wilk, M. B. (1965). *An analysis of variance test for normality (complete samples). Biometrika, 52(3–4), 591–611.*
- Sidiropoulos, D. S., & Anagnostopoulos, C.-N. (2024). *Applications, challenges and ethical issues of AI and ChatGPT in education. Preprint. arXiv.* <https://doi.org/10.48550/arXiv.2402.07907>.
- Silva, G. L. B., de Carvalho, J. A., & Maciel, A. M. A. (2021). Desenvolvimento de um *Learning Analytics Dashboard* a partir de Modelos de Mineração de Dados Educacionais. *Revista de Engenharia e Pesquisa Aplicada, 6(3), 59-69.*
- Singh, A., & Dutta, D. (2023). *Green cloud computing: Energy-efficient cloud management techniques. Journal of Grid Computing, 21(2), 12.* <https://doi.org/10.1007/s10723-023-09655-8>.
- Smith, T. (2018, 30 de junho). *More states opting to “robo-grade” student essays by computer. NPR Ed. Recuperado de* <https://www.npr.org/sections/ed/2018/06/30/624373367/more-states-opting-to-robo-grade-student-essays>.
- Sposato, M. (2025). *Artificial intelligence in educational leadership: a comprehensive taxonomy and future directions. International Journal of Educational Technology in Higher Education, 22(1).* <https://doi.org/10.1186/s41239-025-00517-1>.

- Srinivasan, K. R., Abd Rahman, N. H., & Ravana, S. D. (2025). *Reskilling and upskilling future educators for the demands of artificial intelligence in the modern era of education. In Pitfalls of AI Integration in Education: Skill Obsolescence, Misuse, and Bias* (pp. 26–47). IGI Global.
<https://doi.org/10.4018/979-8-3373-0122-8.ch008>.
- Strauss, A., & Corbin, J. (1990). *Basics of qualitative research: Grounded theory procedures and techniques*. Sage Publications.
- Suh, S. (2025). *Investigating the impact of personalized AI tutors on language learning performance*. arXiv. <https://doi.org/10.48550/arXiv.2505.02443>.
- Sun, P. C., Tsai, R. J., Finger, G., Chen, Y. Y., & Yeh, D. (2008). *What drives a successful e-learning? An empirical investigation of the critical factors influencing learner satisfaction*. *Computers & Education*, 50(4), 1183–1202.
<https://doi.org/10.1016/j.compedu.2006.11.007>.
- Tavares, L. A., Meira, M. C., & Amaral, S. F. D. (2020). *Inteligência artificial na educação: survey / Artificial intelligence in education: survey*. *Brazilian Journal of Development*, 6(7), 48699-48714.
<https://ojs.brazilianjournals.com.br/ojs/index.php/BRJD/article/view/13539>.
- Turing, A. M. (1950). *Mind*. *Mind*, 59, 433-460.
- UNESCO. (2020). *Education: From disruption to recovery*.
<https://www.unesco.org/en/covid-19/education-response>.
- UNESCO. (2024). *Guidance for generative AI in education and research*. Paris: United Nations Educational, Scientific and Cultural Organization.
<https://unesdoc.unesco.org/ark:/48223/pf0000387144>.
- UNESCO. (2020). *Beijing consensus on artificial intelligence and education*. United Nations Educational, Scientific and Cultural Organization.
- UNESCO. (2024). *Guidance for generative AI in education and research*. UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf00003862>.
- VersionOne. (2022). *14th Annual State of Agile Report*. Digital.ai.
<https://stateofagile.com>.
- Villegas Ch, W. (2025). *Adaptive intelligent tutoring systems for STEM education. Smart Learning Environments*. Advance online publication.
<https://doi.org/10.1186/s40561-025-00389-y>.
- Vygotsky, L. S. (1978). *Mind in society: The development of higher psychological processes*. Harvard University Press.
- Wafaa, S., Noeman, A., Abdellatif, A., Abdelrazek, M., Badawy, M. G., & El Tantawy, S. (2022). *AI-based adaptive per-sonalized content presentation and exercises navigation for an effective and engaging e learning platform*.

- Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-022-13076-8>.
- Wallace, R. (2003). *Elements of AIML style*. In *ALICE A. I. Foundation*. Recuperado em julho de 2019, de <http://www.alicebot.org/style.pdf>
- Walter, Y. (2024). *Embracing the Future of Artificial Intelligence in the Classroom: The Relevance of AI Literacy, Prompt Engineering, and Critical Thinking in Modern Education*. *International Journal of Educational Technology in Higher Education*, 21, Article 15. <https://doi.org/10.1186/s41239-024-00448-3>.
- Wan, X., Wang, W., Liu, J., & Tong, T. (2014). *Estimating the sample mean and standard deviation from the sample size, median, range and/or interquartile range*. *BMC Medical Research Methodology*, 14, 135. <https://doi.org/10.1186/1471-2288-14-135>.
- Wang, F., & Hannafin, M. J. (2005). *Design based research and technology-enhanced learning environments*. *ETR&D*, 53(4), 5-23. Recuperado de https://ideascale.com/userimages/sub-1/898000/panel_upload_12279/30221206.pdf
- Wang, Y., Li, D., & Li, Y. (2021). *Personalized learning in education: A review of research and applications*. *Educational Technology & Society*, 24(1), 179–192.
- Wang, S. (2024). *Artificial intelligence in education: A systematic literature review*. *Knowledge-Based Systems*, 300, Article 108255. <https://doi.org/10.1016/j.knosys.2024.108255>.
- Wang, C. N., et al. (2025). *Generative AI in education: Student skills and lecturer roles (preprint)*. arXiv.
- Weizenbaum, J. (1966). *ELIZA — A Computer Program for the Study of Natural Language Communication Between Man and Machine*. *Communications of the ACM*, 9(1), 36–45. <https://doi.org/10.1145/365153.365168>.
- Wilcox, B. (2017). *Beyonce faça de: Pattern matching for natural language applications*. *Gamasutra*. Recuperado de http://www.gamasutra.com/view/feature/6305/beyond_fa%C3%A7ade_pattern_matching_.php?page=1.
- Wills, S., Bai, Y., Tejedor-García, C., Cucchiarini, C., & Strik, H. (2023). *Automatic speech recognition of non-native child speech for language learning applications*. *arXiv preprint*. <https://doi.org/10.48550/arXiv.2306.16710>.
- Wilson, J., & Czik, A. M. (2016). *Effects of automated essay scoring on student revision behavior and writing motivation*. *Computers & Education*, 98, 132–142. <https://doi.org/10.1016/j.compedu.2016.05.004>.

- Woolf, B. P. (2009). *Building intelligent interactive tutors: Student-centered strategies for revolutionizing e-learning*. Morgan Kaufmann.
- Yamtinah, S., Wiyarsi, A., Widarti, H. R., Shidiq, A. S., & Ramadhani, D. G. (2025). *Fine-tuning AI models for enhanced consistency and precision in chemistry educational assessments*. *Computers and Education: Artificial Intelligence*, 8(100399), 100399. <https://doi.org/10.1016/j.caeai.2025.100399>.
- Yin, B., Hadwin, A. F., & Gress, C. L. Z. (2021). *Scaffolding self-regulated learning with technology-enhanced support*. *Educational Psychologist*, 56(4), 258–273. <https://doi.org/10.1080/00461520.2021.1950173>.
- Zawacki-Richter, O. et al. (2019). *Systematic Review of Research on Artificial Intelligence Applications in Higher Education – Where Are the Educators?* *International Journal of Educational Technology in Higher Education*.
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). *Systematic review of research on artificial intelligence applications in higher education – where are the educators?* *International Journal of Educational Technology in Higher Education*, 16, 39. <https://doi.org/10.1186/s41239-019-0171-0>.
- Zhai, C., Wibowo, S. (2023). *A systematic review on artificial intelligence dialogue systems for enhancing English as foreign language students' interactional competence in the university*. *Computers and Education: Artificial Intelligence*, 100134, 100134. <https://doi.org/10.1016/j.caeai.2023.100134>.
- Zhai, C., Wibowo, S., & Li, L. D. (2024). *Evaluating the AI dialogue system's intercultural, humorous, and empathetic dimensions in English language learning: A case study*. *Computers & Education: Artificial Intelligence*, 7, 100262. <https://doi.org/10.1016/j.caeai.2024.100262>.
- Zhang, Y., Li, X., & Wang, H. (2020). *Energy-aware deployment of applications in cloud computing environments*. *Future Generation Computer Systems*, 105, 789–798. <https://doi.org/10.1016/j.future.2019.12.035>.
- Zhang, J., Yu, H., & Lin, X. (2023). *Hybrid recommendation systems for adaptive learning: Trends and challenges*. *British Journal of Educational Technology*, 54(5), 1322–1341. <https://doi.org/10.1111/bjet.13256>.
- Zhu, X., & Goldberg, A. B. (2009). *Introduction to semi-supervised learning*. *Synthesis lectures on artificial intelligence and machine learning*, 3(1), 1-130.
- Zhu, H., Zhang, J., & Zhou, H. (2020). *A game-theoretic approach to incentive mechanism design in mobile crowdsourcing systems*. *IEEE Transactions on Mobile Computing*, 19(8), 1881-1894. <https://doi.org/10.1109/TMC.2019.2920270>.
- Zhu, M., & Wang, C. (2024). *A systematic review of artificial intelligence in language education from 2013 to 2023: current status and future implications*. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4684304>.

ANEXO A – GRADE CURRICULAR


Estrutura Curricular		
Módulo	Curso/Aula	Modalidade
Aula Inaugural		
Módulo 1	Competências Socioemocional - Fase 1	Aula ao vivo
Módulo 2	Introdução ao Mundo da Computação e Lógica de Programação	Aula ao vivo* e conteúdo <i>online</i>
Módulo 2	Métodos Ágeis	Conteúdo <i>online</i>
Módulo 2	HTML	Aula ao vivo* e conteúdo <i>online</i>
Módulo 2	CSS	Aula ao vivo* e conteúdo <i>online</i>
Módulo 2	Boostrap	Aula ao vivo* e conteúdo <i>online</i>
Módulo 2	Versionamento de Git	Conteúdo <i>online</i>
Módulo 3	JavaScript	Aula ao vivo* e conteúdo <i>online</i>
Módulo 3	Banco de Dados Relacional Fundamentos e Intermediário	Aula ao vivo* e conteúdo <i>online</i>
Módulo 3	Java Fundamentos	Aula ao vivo* e conteúdo <i>online</i>
Módulo 3	Java Orientação a Objetos	Aula ao vivo* e conteúdo <i>online</i>
Módulo 3	Java Acesso e Manipulação de Dados	Aula ao vivo* e conteúdo <i>online</i>
Módulo 3	Computação em Nuvem	Conteúdo <i>online</i>
Módulo 4	React.JS Fundamentos e Intermediário	Aula ao vivo* e conteúdo <i>online</i>
Módulo 4	Java Web Intermediário	Aula ao vivo* e conteúdo <i>online</i>
Módulo 4	Linux	Conteúdo <i>online</i>
Módulo 5	React Avançado	Aula ao vivo* e conteúdo <i>online</i>
Módulo 5	Banco de Dados NoSql (MongoDB)	Aula ao vivo* e conteúdo <i>online</i>
Módulo 5	Java Web Avançado	Aula ao vivo* e conteúdo <i>online</i>
Módulo 5	Servidores Web (Apache e Nginx)	Conteúdo <i>online</i>
Módulo 6	React Native	Aula ao vivo* e conteúdo <i>online</i>
Módulo 6	Fundamentos de Teste de Software	Conteúdo <i>online</i>
Módulo 6	C# e .Net MVC e WEB API	Aula ao vivo* e conteúdo <i>online</i>
Módulo 6	Devops	Conteúdo <i>online</i>
Módulo 6	Segurança em Sistemas de Informação	Conteúdo <i>online</i>
Módulo 7	Engine de Buscas	Conteúdo <i>online</i>
Módulo 7	Redes Sociais	Conteúdo <i>online</i>
Período de Apresentações		
Módulo 1	Competências Socioemocionais - Fase 2	Aula ao vivo
FEIRA DE TALENTOS		


APÊNDICE A – DIAGNÓSTICO PEDAGÓGICO COM ALUNOS

Diagnóstico Técnico Pedagógico

Prezado(a):

Desde já, agradeço o tempo a ser dedicado para responder a minha pesquisa. Não sei se é de seu conhecimento, mas estou fazendo doutorado e pretendo validar um modelo tecnológico em cursos online.

eduardonead@gmail.com [Alternar conta](#) 

 Não compartilhado

* Indica uma pergunta obrigatória

O instrumento
O modelo que estou desenvolvendo é um recurso baseado em Inteligência Artificial. Gostaria, então, de contar com a sua participação nessa pesquisa a fim de poder entender um pouco do seu cenário vivenciado, para tentar, assim, criar um modelo que seja mais eficiente para o processo de ensino-aprendizado.

Escolhi, exclusivamente, aqueles que fazem cursos na modalidade online, por entender, reconhecer e vivenciar os principais problemas, desafios e oportunidades, que a modalidade oferece.

Objetivos do diagnóstico

- Ratificar os requisitos inicialmente idealizados
- Identificar melhorias nos requisitos e na especificação do sistema

Dimensões analisadas
Para a coleta dessas informações, idealizei um instrumento com perguntas-chave, que abordam questões sobre os problemas na qualidade do ensino, processo de interação, modelo de gestão da operação e melhorias gerais, conforme apresentado a seguir.

Respostas
Algumas respostas estão na escala de intensidade, do tipo Likert, com 4 variações: de 1 "muito deficiente" até 4 "excelente" e um item denominado "não se aplica" para aqueles casos em que não há relação com o tópico avaliado.

Pedimos a sua colaboração no preenchimento do QUESTIONÁRIO, abaixo, como, * também, a sua autorização para apresentar os resultados deste estudo em eventos científicos, bem como publicá-los em revista científica nacional e/ou internacional. Para tanto, solicitamos que leia o Termo de Consentimento, em anexo, assinando-o, abaixo, concordando, assim, com a sua participação.

Concordo em participar

Não concordo em participar

Em qual instituição de ensino você estuda ou está estudando? *

Sua resposta _____

1) - Atualmente está fazendo algum curso online? *

Sim

Não

2) - Qual(is) tipo(s) de curso(s) você fez ou está fazendo? *

Curso livre

Graduação

Pós-graduação

Mestrado

Doutorado

Outro: _____

3) - Os recursos tecnológicos presentes na sua plataforma de estudo online atendem as necessidades do seu processo de aprendizagem (1 "muito deficiente" até 4 "excelente" e um item denominado "não se aplica" para aqueles casos em que não há relação com o tópico avaliado)? *

1

2

3

4

Não se aplica.

Outro: _____

4) - Como você avalia a interação e a mediação do tutor com os alunos (1 "muito deficiente" até 4 "excelente" e um item denominado "não se aplica" para aqueles casos em que não há relação com o tópico avaliado)?

- 1
- 2
- 3
- 4
- Não se aplica.

5) - Como você avalia os feedbacks das correções realizadas pelo professor/tutor (1 "muito deficiente" até 4 "excelente" e um item denominado "não se aplica" para aqueles casos em que não há relação com o tópico avaliado)?

- 1
- 2
- 3
- 4
- Não se aplica.

6) - O processo de interação entre os participantes (aluno-aluno, aluno-professor) ocorre de forma eficiente (1 "muito deficiente" até 4 "excelente" e um item denominado "não se aplica" para aqueles casos em que não há relação com o tópico avaliado)?

- 1
- 2
- 3
- 4
- Não se aplica.

7) - Como você avalia a possibilidade de ter um recurso automatizado que auxilie a mediação de dúvidas durante o seu processo de estudo? (1 "muito deficiente" até 4 "excelente" e um item denominado "não se aplica" para aqueles casos em que não há relação com o tópico avaliado)? *

- 1
- 2
- 3
- 4
- Não se aplica.

8) - Como você avalia um sistema inteligente capaz de recomendar conteúdos personalizados, como por exemplo: necessidades de mais participação, mais dedicação de estudo, indicação de leitura etc. (1 "muito deficiente" até 4 "excelente" e um item denominado "não se aplica" para aqueles casos em que não há relação com o tópico avaliado)? *

- 1
- 2
- 3
- 4
- Não se aplica.

9) - Como você avalia os relatórios de desempenho educacional disponíveis na sua plataforma de ensino online (1 "muito deficiente" até 4 "excelente" e um item denominado "não se aplica" para aqueles casos em que não há relação com o tópico avaliado)? *

- 1
- 2
- 3
- 4
- Não se aplica.

10) - Qual o nível de recomendação ou sugestão de trilha de aprendizagem da sua plataforma de ensino (1 "muito deficiente" até 4 "excelente" e um item denominado "não se aplica" para aqueles casos em que não há relação com o tópico avaliado)? *

- 1
- 2
- 3
- 4
- Não se aplica.

11) - Qual o nível de personalização da sua plataforma de ensino para suas necessidades educacionais? *

- 1
- 2
- 3
- 4
- Não se aplica.

12) - Você acredita que a Inteligência Artificial pode auxiliar no seu processo de aprendizado? *

- Sim
- Não

13) - Que recurso computacional você destacaria como muito eficiente na sua plataforma de estudo? *

Sua resposta _____

14) - Qual(is) recurso(s) computacional(is) sua plataforma de estudo não tem, mas que você julga como importante?

Sua resposta _____

Enviar

Limpar formulário

APÊNDICE B – DIAGNÓSTICO PEDAGÓGICO COM GESTORES

Diagnóstico Técnico pedagógico

Prezado(a) professor(a):

Desde já, agradeço o tempo dedicado para responder a minha pesquisa. Não sei se é de seu conhecimento, mas estou fazendo doutorado e pretendo validar um modelo tecnológico em cursos online.

eduardonead@gmail.com [Alternar conta](#)



Não compartilhado

* Indica uma pergunta obrigatória

O instrumento

O modelo que estou desenvolvendo é um recurso baseado em Inteligência Artificial. Gostaria, então, de contar com a sua participação nessa pesquisa a fim de poder entender um pouco do seu cenário vivenciado, para tentar, assim, criar um modelo que seja mais assertivo e eficiente na gestão e na operação do e-learning.

Escolhi, exclusivamente, executivos de universidades, que atuam, diretamente, com o EaD, por entender e reconhecer os principais problemas que vivenciamos nessa modalidade. Também, tenho certeza de que saberão recomendar melhorias tecnológicas e metodológicas que possam otimizar a operação do e-learning e, conseqüentemente, melhorar o processo de ensino-aprendizado.

Objetivos do diagnóstico

- Ratificar os requisitos inicialmente idealizados (teste cego)
- Identificar melhorias nos requisitos e na especificação do sistema (teste cego)

Dimensões analisadas

Para a coleta dessas informações, idealizei um instrumento com perguntas-chave, que abordam questões sobre os problemas na qualidade do ensino, processo de interação, modelo de gestão da operação e melhorias gerais, conforme apresentado a seguir.

Quesitos

Quesitos	Definições dos quesitos
Problemas na qualidade do ensino	Identifica as principais dificuldades no processo de aprendizagem dos alunos, relacionando-as com a operação (gestão da universidade, atuação do professor-tutor, conteúdo didático e LMS).
Processo de interação	Identifica as necessidades de interação, assim como as ferramentas possíveis de serem utilizadas e as metodologias a serem aplicadas.
Modelo de gestão da operação	Identifica as ferramentas existentes para acompanhamento dos alunos e mediadores pedagógicos, assim como a ausência de informações para melhor tomada de decisão.
Melhorias gerais	Levantamento das necessidades de processo e de tecnologia dos gestores frente aos desafios impostos pelas instituições e, também, para melhoria no processo educacional.

Pedimos a sua colaboração no preenchimento do QUESTIONÁRIO, abaixo, como, também, a sua autorização para apresentar os resultados deste estudo em eventos científicos, bem como publicá-los em revista científica nacional e/ou internacional. Para tanto, solicitamos que leia o Termo de Consentimento, em anexo, assinando-o, abaixo, concordando, assim, com a sua participação.

- Concordo em participar
- Não concordo em participar

Universidade

Sua resposta _____

1) - Na sua visão, quais recursos tecnológicos ainda não estão presentes no ambiente virtual de aprendizagem, mas que deveriam nele estar contemplados? *

Sua resposta _____

2) - Como o ambiente virtual de aprendizagem poderia auxiliar o trabalho do professor-tutor, de forma que consiga direcionar mais esforço no processo de interação e mediação e menos na operação e correções com feedbacks simplórios? *

Sua resposta _____

3) - Você acredita que o processo de interação entre os participantes (aluno-aluno, aluno-professor) ocorre de forma eficiente? *

- Sim
- Não

4) - Qual sugestão de ferramenta ou melhoria no processo de interação (aluno-aluno, aluno-professor) você indicaria?

Sua resposta _____

5) - Você acha viável ter um recurso automatizado para realizar comunicação (bot) com alunos, de forma a auxiliar nas dúvidas durante o processo de estudo? *

Sim

Não

6) - Qual nível de interação um bot poderia ter para ser eficiente no processo educacional?

Sua resposta

7) - Você acredita que um sistema de recomendação de ações (mais participação, mais dedicação de estudo, indicação de leitura) facilitaria a análise e a mediação pedagógica do professor-tutor? Caso positivo, qual seria sua sugestão para essa funcionalidade? *

Sua resposta

8) - Atualmente, você conta com um dashboard com os principais indicadores operacionais, táticos e estratégicos da sua operação? Quais dentre eles você julga como fundamentais (não precisa detalhar)? *

Sua resposta

9) - No seu ambiente virtual de aprendizagem existe algum módulo de inteligência artificial ou recurso similar para auxiliar o processo de ensino-aprendizagem? Caso positivo, qual? Caso negativo, teria alguma sugestão? *

Sua resposta

10) - No seu ponto de vista, que recursos de inteligência artificial os ambientes virtuais de aprendizagem deveriam ter? *

Sua resposta

Enviar

Limpar formulário

APÊNDICE C – ESTRATÉGIA E RESULTADO DE BUSCA

Bases de dados	Estratégia de buscas	Resultados
Scopus 2019 a 2025 Somente artigos Extraído em 03/06/2025	(TITLE("Online Learning") OR TITLE("Distance Learning") OR TITLE("Learning Environment") OR TITLE("E-learning") OR TITLE("Elearning") OR TITLE("Remote Learning") OR TITLE("Virtual Learning") OR TITLE("Virtual Tutoring")) AND (TITLE("Artificial Intelligence") OR TITLE("AI") OR TITLE("Computational Intelligence") OR TITLE("Digital Assistant") OR TITLE("Intelligent Assistant") OR TITLE("Intelligent Systems") OR TITLE("Virtual Assistant")) AND PUBYEAR > 2018 AND PUBYEAR < 2026 AND PUBYEAR > 2018 AND PUBYEAR < 2026 AND (LIMIT-TO (SUBJAREA,"COMP") OR LIMIT-TO (SUBJAREA,"ENGI") OR LIMIT-TO (SUBJAREA,"DECI") OR LIMIT-TO (SUBJAREA,"MULT")) AND (LIMIT-TO (DOCTYPE,"ar"))	128
IEEE 2019 a 2025 Somente artigos Extraído em 03/06/2025	((("Document Title": "Online Learning" OR "Document Title": "Distance Learning" OR "Document Title": "Learning Environment" OR "Document Title": "E-learning" OR "Document Title": "Elearning" OR "Document Title": "Remote Learning" OR "Document Title": "Virtual Learning" OR "Document Title": "Virtual Tutoring") AND ("Document Title": "Artificial Intelligence" OR "Document Title": "AI" OR "Document Title": "Computational Intelligence" OR "Document Title": "Digital Assistant" OR "Document Title": "Intelligent Assistant" OR "Document Title": "Intelligent Systems" OR "Document Title": "Virtual Assistant"))	88
Web of science 2019 a 2025 Somente artigos Extraído em 08/06/2025	(TI=("Online Learning" OR "Distance Learning" OR "Learning Environment" OR "E-learning" OR "Elearning" OR "Remote Learning" OR "Virtual Learning" OR "Virtual Tutoring")) AND (TI=("Artificial Intelligence" OR "AI" OR "Computational Intelligence" OR "Digital Assistant" OR "Intelligent Assistant" OR "Intelligent Systems" OR "Virtual Assistant")) AND PY=(2019-2025) AND DT=("Article") AND WC=("Computer Science" OR "Engineering")	26
Total		242

GRUPO A

APÊNDICE D – HISTÓRICO DE NOTAS POR GRUPOS/DISCIPLINAS

Alunos	HTML/CSS					JavaScript					PHP					Banco de dados				
	ATV1	ATV2	TF	Média	Situação	ATV1	ATV2	TF	Média	Situação	ATV1	ATV2	TF	Média	Situação	ATV1	ATV2	TF	Média	Situação
Aluno 1	7,0	7,0	8,0	7,3	Aprovado	5,0	5,0	6,0	5,3	Aprovado	2,0	9,0	9,0	6,7	Aprovado	7,0	6,0	4,0	5,7	Aprovado
Aluno 2	4,0	7,0	8,0	6,3	Aprovado	1,0	4,0	4,0	3,0	Reprovado	10,0	4,0	1,0	5,0	Aprovado	5,0	5,0	5,0	5,0	Aprovado
Aluno 3	10,0	9,0	7,0	8,7	Aprovado	8,0	6,0	9,0	7,7	Aprovado	9,0	8,0	7,0	8,0	Aprovado	10,0	7,0	7,0	8,0	Aprovado
Aluno 4	1,0	7,0	10,0	6,0	Aprovado	4,0	6,0	10,0	6,7	Aprovado	2,0	7,0	8,0	5,7	Aprovado	10,0	10,0	7,0	9,0	Aprovado
Aluno 5	10,0	9,0	7,0	8,7	Aprovado	5,0	9,0	3,0	5,7	Aprovado	10,0	10,0	2,0	7,3	Aprovado	7,0	10,0	0,0	5,7	Aprovado
Aluno 6	7,0	8,0	2,0	5,7	Aprovado	5,0	3,0	9,0	5,7	Aprovado	0,0	0,0	0,0		Desistente	0,0	0,0	0,0		Desistente
Aluno 7	5,0	9,0	8,0	7,3	Aprovado	7,0	4,0	7,0	6,0	Aprovado	7,0	10,0	7,0	8,0	Aprovado	6,0	5,0	7,0	6,0	Aprovado
Aluno 8	4,0	8,0	7,0	6,3	Aprovado	10,0	0,0	8,0	6,0	Aprovado	8,0	10,0	10,0	9,3	Aprovado	10,0	7,0	2,0	6,3	Aprovado
Aluno 9	10,0	10,0	8,0	9,3	Aprovado	7,0	9,0	1,0	5,7	Aprovado	8,0	10,0	10,0	9,3	Aprovado	9,0	9,0	0,0	6,0	Aprovado
Aluno 10	9,0	7,0	8,0	8,0	Aprovado	6,0	2,0	8,0	5,3	Aprovado	5,0	5,0	7,0	5,7	Aprovado	6,0	5,0	5,5	5,5	Aprovado
Aluno 11	10,0	8,0	9,0	9,0	Aprovado	7,0	10,0	7,0	8,0	Aprovado	0,0	1,0	6,0	2,3	Reprovado	5,0	9,0	7,0	7,0	Aprovado
Aluno 12	10,0	9,0	10,0	9,7	Aprovado	7,0	7,0	3,0	5,7	Aprovado	8,0	4,0	5,0	5,7	Aprovado	9,0	10,0	6,0	8,3	Aprovado
Aluno 13	8,0	10,0	6,0	8,0	Aprovado	7,0	5,0	8,0	6,7	Aprovado	10,0	10,0	0,0	6,7	Aprovado	3,0	5,0	8,0	5,3	Aprovado
Aluno 14	6,0	10,0	10,0	8,7	Aprovado	5,0	5,0	8,0	6,0	Aprovado	8,0	4,0	2,0	4,7	Reprovado	4,0	5,0	6,0	5,0	Aprovado
Aluno 15	8,0	9,0	10,0	9,0	Aprovado	6,0	9,0	4,0	6,3	Aprovado	8,0	2,0	10,0	6,7	Aprovado	10,0	9,0	3,0	7,3	Aprovado
Aluno 16	6,0	9,0	8,0	7,7	Aprovado	8,0	7,0	6,0	7,0	Aprovado	10,0	9,0	10,0	9,7	Aprovado	1,0	3,0	5,0	3,0	Reprovado
Aluno 17	7,0	7,0	9,0	7,7	Aprovado	3,0	8,0	5,0	5,3	Aprovado	1,0	7,0	8,0	5,3	Aprovado	2,0	7,0	9,0	6,0	Aprovado
Aluno 18	9,0	9,0	3,0	7,0	Aprovado	3,0	7,0	8,0	6,0	Aprovado	9,0	4,0	6,0	6,3	Aprovado	4,0	7,0	6,0	5,7	Aprovado
Aluno 19	5,0	8,0	5,0	6,0	Aprovado	3,0	6,0	8,0	5,7	Aprovado	8,0	4,0	7,0	6,3	Aprovado	7,0	8,0	10,0	8,3	Aprovado
Aluno 20	6,0	8,0	5,0	6,3	Aprovado	7,0	2,0	6,0	5,0	Aprovado	5,0	8,0	6,0	6,3	Aprovado	8,0	6,0	3,0	5,7	Aprovado
Aluno 21	8,0	10,0	10,0	9,3	Aprovado	7,0	4,0	6,0	5,7	Aprovado	6,0	8,0	6,0	6,7	Aprovado	4,0	9,0	1,0	4,7	Reprovado
Aluno 22	9,0	6,0	9,0	8,0	Aprovado	1,0	0,0	10,0	3,7	Reprovado	2,0	3,0	3,0	2,7	Reprovado	4,0	10,0	10,0	8,0	Aprovado
Aluno 23	8,0	9,0	2,0	6,3	Aprovado	9,0	3,0	6,0	6,0	Aprovado	5,0	10,0	8,0	7,7	Aprovado	2,0	8,0	9,0	6,3	Aprovado
Aluno 24	8,0	6,0	9,0	7,7	Aprovado	5,0	7,0	6,0	6,0	Aprovado	0,0	1,0	3,0	1,3	Reprovado	10,0	8,0	3,0	7,0	Aprovado
Aluno 25	6,0	9,0	9,0	8,0	Aprovado	0,0	4,0	1,0	1,7	Reprovado	5,0	6,0	6,0	5,7	Aprovado	10,0	7,0	9,0	8,7	Aprovado
Aluno 26	10,0	10,0	10,0	10,0	Aprovado	3,0	7,0	7,0	5,7	Aprovado	10,0	7,0	6,0	7,7	Aprovado	5,0	10,0	4,0	6,3	Aprovado
Aluno 27	8,0	10,0	9,0	9,0	Aprovado	6,0	2,0	5,0	4,3	Reprovado	5,0	3,0	8,0	5,3	Aprovado	8,0	9,0	2,0	6,3	Aprovado
Aluno 28	9,0	8,0	10,0	9,0	Aprovado	8,0	5,0	8,0	7,0	Aprovado	9,0	8,0	6,0	7,7	Aprovado	8,0	10,0	9,0	9,0	Aprovado
Aluno 29	8,0	7,0	6,0	7,0	Aprovado	4,0	1,0	8,0	4,3	Reprovado	4,0	7,0	6,0	5,7	Aprovado	10,0	0,0	10,0	6,7	Aprovado
Aluno 30	7,0	8,0	8,0	7,7	Aprovado	4,0	9,0	8,0	7,0	Aprovado	5,0	5,0	5,0	5,0	Aprovado	0,0	9,0	4,0	4,3	Reprovado
Aluno 31	8,0	10,0	9,0	9,0	Aprovado	9,0	4,0	5,0	6,0	Aprovado	9,0	8,0	2,0	6,3	Aprovado	7,0	7,0	2,0	5,3	Aprovado
Aluno 32	8,0	5,0	9,0	7,3	Aprovado	3,0	5,0	9,0	5,7	Aprovado	5,0	4,0	7,0	5,3	Aprovado	3,0	4,0	3,0	3,3	Reprovado
Aluno 33	10,0	5,0	10,0	8,3	Aprovado	7,0	1,0	10,0	6,0	Aprovado	6,0	0,0	9,0	5,0	Aprovado	5,0	8,0	8,0	7,0	Aprovado
Aluno 34	7,0	8,0	9,0	8,0	Aprovado	8,0	9,0	2,0	6,3	Aprovado	9,0	5,0	2,0	5,3	Aprovado	10,0	6,0	2,0	6,0	Aprovado
Aluno 35	9,0	9,0	9,0	9,0	Aprovado	5,0	9,0	5,0	6,3	Aprovado	8,0	7,0	8,0	7,7	Aprovado	6,0	10,0	6,0	7,3	Aprovado
Aluno 36	8,0	8,0	4,0	6,7	Aprovado	1,0	6,0	9,0	5,3	Aprovado	0,0	0,0	3,0	1,0	Reprovado	6,0	4,0	5,0	5,0	Aprovado
Aluno 37	5,0	9,0	10,0	8,0	Aprovado	0,0	0,0	0,0		Desistente	0,0	0,0	0,0		Desistente	0,0	0,0	0,0		Desistente
Aluno 38	9,0	8,0	8,0	8,3	Aprovado	4,0	3,0	9,0	5,3	Aprovado	8,0	3,0	3,0	4,7	Reprovado	3,0	5,0	7,0	5,0	Aprovado
Aluno 39	7,0	7,0	6,0	6,7	Aprovado	7,0	5,0	4,0	5,3	Aprovado	3,0	6,0	7,0	5,3	Aprovado	1,0	2,0	3,0	2,0	Reprovado
Aluno 40	6,0	8,0	10,0	8,0	Aprovado	6,0	9,0	2,0	5,7	Aprovado	10,0	5,0	9,0	8,0	Aprovado	10,0	2,0	9,0	7,0	Aprovado
Aluno 41	9,0	10,0	9,0	9,3	Aprovado	7,0	9,0	4,0	6,7	Aprovado	10,0	7,0	7,0	8,0	Aprovado	7,0	9,0	7,0	7,7	Aprovado
Aluno 42	9,0	7,0	8,0	8,0	Aprovado	6,0	2,0	8,0	5,3	Aprovado	3,0	5,0	2,0	3,3	Reprovado	7,0	5,0	7,0	6,3	Aprovado
Aluno 43	10,0	9,0	10,0	9,7	Aprovado	7,0	10,0	7,0	8,0	Aprovado	70,0	4,0	6,0	26,7	Aprovado	5,0	9,0	7,0	7,0	Aprovado
Aluno 44	6,0	9,0	10,0	8,3	Aprovado	7,0	7,0	3,0	5,7	Aprovado	5,0	4,0	1,0	3,3	Reprovado	9,0	10,0	6,0	8,3	Aprovado
Aluno 45	9,0	7,0	10,0	8,7	Aprovado	4,0	6,0	10,0	6,7	Aprovado	2,0	7,0	8,0	5,7	Aprovado	10,0	10,0	7,0	9,0	Aprovado

GRUPO B

Alunos	HTML/CSS					JavaScript					PHP					Banco de dados				
	ATV1	ATV2	TF	Média	Situação	ATV1	ATV2	TF	Média	Situação	ATV1	ATV2	TF	Média	Situação	ATV1	ATV2	TF	Média	Situação
Aluno 1	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente
Aluno 2	10,0	5,0	1,0	5,3	Aprovado	8,0	7,0	8,0	7,7	Aprovado	5,0	7,0	5,0	5,7	Aprovado	1,0	5,0	4,0	3,3	Reprovado
Aluno 3	3,0	7,0	2,0	4,0	Reprovado	7,0	8,0	9,0	8,0	Aprovado	5,0	7,0	7,0	6,3	Aprovado	7,0	7,0	8,0	7,3	Aprovado
Aluno 4	3,0	4,0	2,0	3,0	Reprovado	3,0	6,0	8,0	5,7	Aprovado	8,0	4,0	7,0	6,3	Aprovado	7,0	8,0	10,0	8,3	Aprovado
Aluno 5	6,0	8,0	2,0	5,3	Aprovado	9,0	7,0	6,0	7,3	Aprovado	5,0	7,0	8,0	6,7	Aprovado	2,0	8,0	9,0	6,3	Aprovado
Aluno 6	6,0	8,0	2,0	5,3	Aprovado	5,0	3,0	4,0	4,0	Reprovado	9,0	8,0	6,0	7,7	Aprovado	8,0	10,0	9,0	9,0	Aprovado
Aluno 7	3,0	5,0	2,0	3,3	Reprovado	6,0	8,0	9,0	7,7	Aprovado	5,0	4,0	7,0	5,3	Aprovado	3,0	4,0	3,0	3,3	Reprovado
Aluno 8	6,0	6,0	3,0	5,0	Aprovado	10,0	7,0	6,0	7,7	Aprovado	4,0	3,0	5,0	4,0	Reprovado	4,0	5,0	5,0	4,7	Reprovado
Aluno 9	9,0	7,0	4,0	6,7	Aprovado	9,0	8,0	8,0	8,3	Aprovado	5,0	5,0	7,0	5,7	Aprovado	9,0	5,0	9,0	7,7	Aprovado
Aluno 10	7,0	10,0	4,0	7,0	Aprovado	5,0	8,0	7,0	6,7	Aprovado	4,0	9,0	4,0	5,7	Aprovado	5,0	4,0	7,0	5,3	Aprovado
Aluno 11	8,0	8,0	4,0	6,7	Aprovado	8,0	9,0	6,0	7,7	Aprovado	0,0	0,0	3,0	1,0	Reprovado	3,0	4,0	5,0	4,0	Reprovado
Aluno 12	4,0	1,0	5,0	3,3	Reprovado	6,0	10,0	1,0	5,7	Aprovado	8,0	10,0	10,0	9,3	Aprovado	9,0	9,0	0,0	6,0	Aprovado
Aluno 13	6,0	5,0	5,0	5,3	Aprovado	10,0	8,0	7,0	8,3	Aprovado	0,0	1,0	6,0	2,3	Reprovado	6,0	5,0	7,0	6,0	Aprovado
Aluno 14	3,0	7,0	5,0	5,0	Aprovado	7,0	5,0	8,0	6,7	Aprovado	4,0	8,0	6,0	6,0	Aprovado	10,0	0,0	10,0	6,7	Aprovado
Aluno 15	9,0	5,0	5,0	6,3	Aprovado	7,0	5,0	7,0	6,3	Aprovado	7,0	4,0	6,0	5,7	Aprovado	5,0	9,0	7,0	7,0	Aprovado
Aluno 16	70,0	2,0	6,0	26,0	Aprovado	7,0	6,0	7,0	6,7	Aprovado	7,0	10,0	7,0	8,0	Aprovado	6,0	5,0	7,0	6,0	Aprovado
Aluno 17	8,0	10,0	6,0	8,0	Aprovado	8,0	4,0	8,0	6,7	Aprovado	10,0	10,0	0,0	6,7	Aprovado	3,0	5,0	8,0	5,3	Aprovado
Aluno 18	6,0	10,0	6,0	7,3	Aprovado	7,0	8,0	8,0	7,7	Aprovado	8,0	4,0	2,0	4,7	Reprovado	4,0	5,0	6,0	5,0	Aprovado
Aluno 19	70,0	7,0	6,0	27,7	Aprovado	7,0	5,0	6,0	6,0	Aprovado	5,0	8,0	6,0	6,3	Aprovado	8,0	6,0	3,0	5,7	Aprovado
Aluno 20	70,0	4,0	6,0	26,7	Aprovado	2,0	8,0	10,0	6,7	Aprovado	6,0	0,0	5,0	3,7	Reprovado	5,0	4,0	4,0	4,3	Reprovado
Aluno 21	7,0	10,0	6,0	7,7	Aprovado	7,0	5,0	5,0	5,7	Aprovado	3,0	6,0	7,0	5,3	Aprovado	7,0	7,0	3,0	5,7	Aprovado
Aluno 22	10,0	4,0	7,0	7,0	Aprovado	8,0	7,0	0,0	5,0	Aprovado	7,0	7,0	7,0	7,0	Aprovado	4,0	5,0	4,0	4,3	Reprovado
Aluno 23	4,0	5,0	7,0	5,3	Aprovado	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente
Aluno 24	3,0	6,0	7,0	5,3	Aprovado	9,0	3,0	6,0	6,0	Aprovado	10,0	9,0	10,0	9,7	Aprovado	1,0	3,0	5,0	3,0	Reprovado
Aluno 25	10,0	7,0	7,0	8,0	Aprovado	3,0	1,0	8,0	4,0	Reprovado	9,0	4,0	6,0	6,3	Aprovado	4,0	7,0	6,0	5,7	Aprovado
Aluno 26	6,0	9,0	7,0	7,3	Aprovado	7,0	4,0	7,0	6,0	Aprovado	5,0	6,0	6,0	5,7	Aprovado	10,0	7,0	9,0	8,7	Aprovado
Aluno 27	6,0	8,0	7,0	7,0	Aprovado	5,0	4,0	7,0	5,3	Aprovado	5,0	10,0	8,0	7,7	Aprovado	8,0	9,0	2,0	6,3	Aprovado
Aluno 28	10,0	7,0	7,0	8,0	Aprovado	7,0	5,0	5,0	5,7	Aprovado	9,0	8,0	2,0	6,3	Aprovado	5,0	5,0	2,0	4,0	Reprovado
Aluno 29	7,0	8,0	7,0	7,3	Aprovado	4,0	8,0	2,0	4,7	Reprovado	9,0	5,0	2,0	5,3	Aprovado	10,0	6,0	2,0	6,0	Aprovado
Aluno 30	7,0	7,0	8,0	7,3	Aprovado	5,0	3,0	2,0	3,3	Reprovado	2,0	9,0	9,0	6,7	Aprovado	7,0	6,0	4,0	5,7	Aprovado
Aluno 31	4,0	7,0	8,0	6,3	Aprovado	1,0	4,0	4,0	3,0	Reprovado	10,0	4,0	1,0	5,0	Aprovado	0,0	0,0	0,0	0,0	Desistente
Aluno 32	9,0	9,0	8,0	8,7	Aprovado	0,0	9,0	4,0	4,3	Reprovado	8,0	3,0	3,0	4,7	Reprovado	3,0	5,0	7,0	5,0	Aprovado
Aluno 33	9,0	7,0	8,0	8,0	Aprovado	6,0	7,0	8,0	7,0	Aprovado	3,0	5,0	2,0	3,3	Reprovado	7,0	5,0	7,0	6,3	Aprovado
Aluno 34	10,0	7,0	9,0	8,7	Aprovado	4,0	6,0	10,0	6,7	Aprovado	2,0	7,0	8,0	5,7	Aprovado	10,0	10,0	7,0	9,0	Aprovado
Aluno 35	10,0	3,0	9,0	7,3	Aprovado	6,0	10,0	5,0	7,0	Aprovado	1,0	7,0	8,0	5,3	Aprovado	2,0	7,0	9,0	6,0	Aprovado
Aluno 36	9,0	7,0	9,0	8,3	Aprovado	1,0	8,0	10,0	6,3	Aprovado	8,0	8,0	3,0	6,3	Aprovado	4,0	10,0	10,0	8,0	Aprovado
Aluno 37	8,0	7,0	9,0	8,0	Aprovado	5,0	5,0	5,0	5,0	Aprovado	8,0	7,0	8,0	7,7	Aprovado	6,0	10,0	6,0	7,3	Aprovado
Aluno 38	6,0	8,0	9,0	7,7	Aprovado	7,0	4,0	4,0	5,0	Aprovado	10,0	7,0	7,0	8,0	Aprovado	7,0	9,0	7,0	7,7	Aprovado
Aluno 39	6,0	9,0	10,0	8,3	Aprovado	8,0	7,0	3,0	6,0	Aprovado	5,0	4,0	5,0	4,7	Reprovado	9,0	10,0	6,0	8,3	Aprovado
Aluno 40	8,0	9,0	10,0	9,0	Aprovado	10,0	8,0	4,0	7,3	Aprovado	8,0	2,0	10,0	6,7	Aprovado	10,0	9,0	3,0	7,3	Aprovado
Aluno 41	8,0	2,0	10,0	6,7	Aprovado	7,0	3,0	6,0	5,3	Aprovado	6,0	8,0	6,0	6,7	Aprovado	8,0	9,0	2,0	6,3	Aprovado
Aluno 42	5,0	6,0	10,0	7,0	Aprovado	4,0	9,0	7,0	6,7	Aprovado	10,0	5,0	4,0	6,3	Aprovado	6,0	10,0	6,0	7,3	Aprovado
Aluno 43	6,0	8,0	10,0	8,0	Aprovado	6,0	8,0	2,0	5,3	Aprovado	10,0	5,0	9,0	8,0	Aprovado	10,0	2,0	9,0	7,0	Aprovado
Aluno 44	6,0	9,0	10,0	8,3	Aprovado	7,0	7,0	3,0	5,7	Aprovado	5,0	4,0	1,0	3,3	Reprovado	9,0	10,0	6,0	8,3	Aprovado
Aluno 45	9,0	7,0	10,0	8,7	Aprovado	4,0	6,0	10,0	6,7	Aprovado	2,0	7,0	8,0	5,7	Aprovado	10,0	10,0	7,0	9,0	Aprovado

GRUPO C

HTML/CSS						JavaScript						PHP					Banco de dados				
ATV1	ATV2	TF	Média	Situação	ATV1	ATV2	TF	Média	Situação	ATV1	ATV2	TF	Média	Situação	ATV1	ATV2	TF	Média	Situação		
6,0	6,0	6,0	6,0	Aprovado	8,0	9,0	6,0	7,7	Aprovado	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente		
9,0	9,0	9,0	9,0	Aprovado	8,0	7,0	8,0	7,7	Aprovado	5,0	7,0	5,0	5,7	Aprovado	1,0	5,0	4,0	3,3	Reprovado		
6,0	4,0	4,0	4,7	Reprovado	7,0	10,0	9,0	8,7	Aprovado	5,0	7,0	7,0	6,3	Aprovado	7,0	7,0	8,0	7,3	Aprovado		
6,0	4,0	6,0	5,3	Aprovado	3,0	4,0	8,0	5,0	Aprovado	8,0	4,0	7,0	6,3	Aprovado	7,0	8,0	10,0	8,3	Aprovado		
7,0	7,0	9,0	7,7	Aprovado	9,0	5,0	6,0	6,7	Aprovado	5,0	7,0	8,0	6,7	Aprovado	2,0	8,0	9,0	6,3	Aprovado		
6,0	8,0	6,0	6,7	Aprovado	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente		
5,0	4,0	10,0	6,3	Aprovado	6,0	4,0	9,0	6,3	Aprovado	5,0	4,0	7,0	5,3	Aprovado	4,0	3,0	4,0	3,7	Reprovado		
6,0	8,0	5,0	6,3	Aprovado	10,0	4,0	6,0	6,7	Aprovado	8,0	8,0	3,0	6,3	Aprovado	10,0	5,0	5,0	6,7	Aprovado		
5,0	5,0	6,0	5,3	Aprovado	9,0	9,0	8,0	8,7	Aprovado	5,0	5,0	7,0	5,7	Aprovado	9,0	5,0	9,0	7,7	Aprovado		
8,0	9,0	3,0	6,7	Aprovado	5,0	5,0	7,0	5,7	Aprovado	4,0	9,0	4,0	5,7	Aprovado	5,0	4,0	7,0	5,3	Aprovado		
8,0	0,0	4,0	4,0	Reprovado	8,0	0,0	6,0	4,7	Reprovado	0,0	0,0	3,0	1,0	Reprovado	6,0	4,0	5,0	5,0	Aprovado		
5,0	8,0	8,0	7,0	Aprovado	6,0	9,0	1,0	5,3	Aprovado	8,0	10,0	10,0	9,3	Aprovado	9,0	9,0	0,0	6,0	Aprovado		
8,0	1,0	5,0	4,7	Reprovado	10,0	5,0	7,0	7,3	Aprovado	0,0	1,0	6,0	2,3	Reprovado	6,0	5,0	7,0	6,0	Aprovado		
9,0	8,0	7,0	8,0	Aprovado	7,0	5,0	8,0	6,7	Aprovado	4,0	8,0	6,0	6,0	Aprovado	10,0	0,0	10,0	6,7	Aprovado		
7,0	4,0	8,0	6,3	Aprovado	7,0	5,0	7,0	6,3	Aprovado	7,0	4,0	6,0	5,7	Aprovado	5,0	9,0	7,0	7,0	Aprovado		
5,0	10,0	8,0	7,7	Aprovado	7,0	6,0	7,0	6,7	Aprovado	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente		
8,0	10,0	1,0	6,3	Aprovado	8,0	8,0	8,0	8,0	Aprovado	10,0	10,0	0,0	6,7	Aprovado	3,0	5,0	8,0	5,3	Aprovado		
6,0	4,0	4,0	4,7	Reprovado	7,0	8,0	8,0	7,7	Aprovado	8,0	4,0	2,0	4,7	Reprovado	4,0	5,0	6,0	5,0	Aprovado		
5,0	8,0	6,0	6,3	Aprovado	7,0	5,0	6,0	6,0	Aprovado	5,0	8,0	6,0	6,3	Aprovado	8,0	6,0	3,0	5,7	Aprovado		
5,0	5,0	6,0	5,3	Aprovado	2,0	8,0	10,0	6,7	Aprovado	6,0	0,0	5,0	3,7	Reprovado	5,0	8,0	8,0	7,0	Aprovado		
7,0	6,0	5,0	6,0	Aprovado	7,0	5,0	5,0	5,7	Aprovado	3,0	6,0	7,0	5,3	Aprovado	6,0	5,0	7,0	6,0	Aprovado		
10,0	7,0	6,0	7,7	Aprovado	8,0	7,0	0,0	5,0	Aprovado	7,0	7,0	7,0	7,0	Aprovado	3,0	5,0	8,0	5,3	Aprovado		
4,0	5,0	7,0	5,3	Aprovado	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente		
3,0	6,0	8,0	5,7	Aprovado	9,0	3,0	6,0	6,0	Aprovado	10,0	9,0	10,0	9,7	Aprovado	1,0	3,0	5,0	3,0	Reprovado		
5,0	7,0	3,0	5,0	Aprovado	3,0	1,0	8,0	4,0	Reprovado	9,0	4,0	6,0	6,3	Aprovado	4,0	7,0	6,0	5,7	Aprovado		
6,0	8,0	7,0	7,0	Aprovado	7,0	4,0	7,0	6,0	Aprovado	5,0	6,0	6,0	5,7	Aprovado	10,0	7,0	9,0	8,7	Aprovado		
6,0	8,0	6,0	6,7	Aprovado	5,0	4,0	7,0	5,3	Aprovado	5,0	10,0	8,0	7,7	Aprovado	8,0	9,0	2,0	6,3	Aprovado		
10,0	7,0	2,0	6,3	Aprovado	7,0	5,0	5,0	5,7	Aprovado	9,0	8,0	2,0	6,3	Aprovado	5,0	5,0	2,0	4,0	Reprovado		
7,0	8,0	7,0	7,3	Aprovado	4,0	8,0	2,0	4,7	Reprovado	9,0	5,0	2,0	5,3	Aprovado	5,0	6,0	2,0	4,3	Reprovado		
7,0	7,0	8,0	7,3	Aprovado	5,0	3,0	2,0	3,3	Reprovado	2,0	9,0	9,0	6,7	Aprovado	7,0	6,0	4,0	5,7	Aprovado		
4,0	7,0	8,0	6,3	Aprovado	1,0	4,0	4,0	3,0	Reprovado	10,0	4,0	1,0	5,0	Aprovado	8,0	5,0	6,0	6,3	Aprovado		
9,0	8,0	8,0	8,3	Aprovado	0,0	9,0	4,0	4,3	Reprovado	8,0	3,0	3,0	4,7	Reprovado	3,0	5,0	5,0	4,3	Reprovado		
9,0	7,0	8,0	8,0	Aprovado	6,0	7,0	8,0	7,0	Aprovado	3,0	5,0	2,0	3,3	Reprovado	4,0	5,0	4,0	4,3	Reprovado		
10,0	7,0	6,0	7,7	Aprovado	4,0	6,0	10,0	6,7	Aprovado	2,0	7,0	8,0	5,7	Aprovado	10,0	10,0	7,0	9,0	Aprovado		
10,0	3,0	9,0	7,3	Aprovado	6,0	10,0	5,0	7,0	Aprovado	1,0	7,0	8,0	5,3	Aprovado	2,0	5,0	5,0	4,0	Reprovado		
9,0	7,0	9,0	8,3	Aprovado	1,0	8,0	10,0	6,3	Aprovado	8,0	8,0	3,0	6,3	Aprovado	4,0	10,0	10,0	8,0	Aprovado		
8,0	7,0	6,0	7,0	Aprovado	5,0	5,0	5,0	5,0	Aprovado	8,0	7,0	8,0	7,7	Aprovado	6,0	10,0	6,0	7,3	Aprovado		
6,0	6,0	3,0	5,0	Aprovado	7,0	4,0	4,0	5,0	Aprovado	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente		
6,0	9,0	4,0	6,3	Aprovado	8,0	7,0	3,0	6,0	Aprovado	5,0	4,0	5,0	4,7	Reprovado	9,0	10,0	6,0	8,3	Aprovado		
8,0	9,0	8,0	8,3	Aprovado	10,0	8,0	4,0	7,3	Aprovado	8,0	2,0	10,0	6,7	Aprovado	10,0	9,0	3,0	7,3	Aprovado		
8,0	2,0	5,0	5,0	Aprovado	7,0	3,0	6,0	5,3	Aprovado	6,0	8,0	6,0	6,7	Aprovado	8,0	9,0	2,0	6,3	Aprovado		
5,0	6,0	10,0	7,0	Aprovado	4,0	9,0	7,0	6,7	Aprovado	10,0	5,0	4,0	6,3	Aprovado	6,0	10,0	6,0	7,3	Aprovado		
6,0	8,0	10,0	8,0	Aprovado	6,0	8,0	2,0	5,3	Aprovado	10,0	5,0	9,0	8,0	Aprovado	10,0	2,0	9,0	7,0	Aprovado		
6,0	6,0	10,0	7,3	Aprovado	7,0	7,0	3,0	5,7	Aprovado	5,0	4,0	1,0	3,3	Reprovado	9,0	10,0	6,0	8,3	Aprovado		
9,0	7,0	10,0	8,7	Aprovado	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente	0,0	0,0	0,0	0,0	Desistente		