



Carlos Henrique de Souza Pereira

FlashQuiz: Uma Abordagem Gamificada para o Ensino de Requisitos de Software Utilizando Conteúdo Gerado por Inteligência Artificial

Recife

2025

Carlos Henrique de Souza Pereira

FlashQuiz: Uma Abordagem Gamificada para o Ensino de Requisitos de Software Utilizando Conteúdo Gerado por Inteligência Artificial

Monografia apresentada ao Curso de Bacharelado em Sistemas de Informação da Universidade Federal Rural de Pernambuco, como requisito parcial para obtenção do título de Bacharel em Sistemas de Informação.

Universidade Federal Rural de Pernambuco – UFRPE
Departamento de Estatística e Informática
Curso de Bacharelado em Sistemas de Informação

Orientador: Gilberto Cysneiros

Recife
2025

À ...

Agradecimentos

A Deus, pela oportunidade de concretizar um sonho de infância, por Sua constante providência, planos perfeitos e infinita bondade.

À minha mãe, Carla Souza, por sua força, coragem e dedicação incansáveis, alicerces fundamentais em minha formação e educação.

Ao meu pai, Leandro Nascimento, pelo apoio firme e pela presença que moldaram meu caráter e me auxiliaram a enfrentar os desafios.

À minha tia, Virgínia Gonçalves, pelos incentivos e conselhos que me inspiraram a ser uma pessoa melhor.

À minha esposa, Layza Lima, pela paciência, companheirismo e por ser minha fonte de inspiração em cada etapa desta jornada.

Ao meu avô, José Alves de Souza, cuja memória permanece viva em meu coração, mesmo em sua ausência física neste momento tão especial.

Ao meu orientador, Professor Gilberto Cysneiros, por toda orientação, confiança e apoio durante este trabalho.

Aos meus amigos – Isadora Tavares, Júlia de Melo, Everton Matheus e Erick Barbosa – pela amizade, apoio e por compartilharem comigo cada conquista e desafio.

Por fim, a todos que lutaram e seguem lutando pelos direitos universitários, minha sincera gratidão por contribuírem para um futuro mais justo, acessível e promissor.

“Um passo à frente e você não está mais no mesmo lugar.”
(Chico Science)

Resumo

O ensino de requisitos de software, fundamental para o sucesso de projetos, ainda enfrenta desafios como excesso de teoria, baixa motivação e dificuldades na retenção de conhecimento. Este trabalho propõe o desenvolvimento da plataforma FlashQuiz, uma solução educacional baseada em Inteligência Artificial (IA) que combina flashcards, quizzes e vídeos dinâmicos para tornar o aprendizado mais interativo, personalizado e eficiente. A metodologia adota princípios de game-based learning e gamificação, utilizando técnicas de recuperação ativa e repetição espaçada, estruturadas em três fases progressivas: Estratégia, Prática e Domínio. Para avaliar sua eficácia, foram analisados indicadores de desempenho e aplicados questionários de perfil e feedback com os participantes. Os resultados evidenciaram uma melhora significativa na percepção de aprendizado, aumento do engajamento e alta aceitação da plataforma, com destaque para a clareza e objetividade dos conteúdos. Conclui-se que a FlashQuiz é uma solução promissora para modernizar o ensino de Engenharia de Software, superando lacunas do modelo teórico tradicional e aproximando teoria e prática. Futuramente, pretende-se expandir os recursos adaptativos via IA e aprimorar as mecânicas de avaliação para potencializar a personalização do aprendizado.

Palavras-chave: Engenharia de Software, Flashcards, Quizzes, Gamificação, Inteligência Artificial.

Abstract

The teaching of software requirements, essential for the success of projects, still faces challenges such as excessive theoretical content, low motivation, and difficulties in knowledge retention. This study proposes the development of FlashQuiz, an educational platform based on Artificial Intelligence (AI) that integrates flashcards, quizzes, and dynamic videos to make learning more interactive, personalized, and effective. The methodology adopts principles of game-based learning and gamification, employing active recall and spaced repetition techniques, structured in three progressive phases: Strategy, Practice, and Mastery. To evaluate its effectiveness, performance indicators were analyzed, and participant profile and feedback questionnaires were applied. The results showed a significant improvement in the perception of learning, increased engagement, and high acceptance of the platform, particularly regarding content clarity and objectivity. It is concluded that FlashQuiz is a promising solution for modernizing the teaching of Software Engineering, bridging the gap between theory and practice. Future work includes expanding adaptive AI resources and refining assessment mechanics to enhance learning personalization.

Keywords: Software Engineering, Flashcards, Quizzes, Gamification, Artificial Intelligence.

Lista de ilustrações

Figura 1 – Fluxo da Metodologia de Avaliação de Aprendizado (Serrano-Laguna et al.) e Melhoria Contínua	48
Figura 2 – Processo de Geração de Conteúdo Estático na Plataforma Educacional	53
Figura 3 – Tela da Homepage – Visão Geral	58
Figura 4 – Tela de Flashcard – Frente (Pergunta)	58
Figura 5 – Pop-up de Exemplo Prático no Flashcard	59
Figura 6 – Tela de Flashcard – Verso (Resposta com Opções de Qualidade)	60
Figura 7 – Tela de Quiz – Questão Múltipla Escolha	60
Figura 8 – Tela de Quiz – Feedback Pós-Resposta	61
Figura 9 – Tela de Perfil – Mural de Insígnias	61
Figura 10 – Detalhe das Seções de Insígnias de Flashcards e Quizzes com Barra de Progresso	62
Figura 11 – Visão Geral da Arquitetura da Plataforma Educacional, incluindo o Fluxo de Geração de Conteúdo	63
Figura 12 – Visão Geral do Fluxo de Interação da Arquitetura da Plataforma Educacional	64
Figura 13 – Distribuição de jogadores por classificação de aprendizado	70
Figura 14 – Distribuição de perfil de jogadores por gênero	71
Figura 15 – Distribuição de jogadores por idade	71
Figura 16 – Distribuição de jogadores por semestre e perfil de aprendizado	73
Figura 17 – Top 10 Flashcards com Maior Média de Tentativas	73
Figura 18 – Média de Tentativas por Nível de Dificuldade (Flashcards)	74
Figura 19 – Top 10 Questões de Quiz com Mais Erros	74
Figura 20 – Média de Erros por Nível de Dificuldade (Quizzes)	75
Figura 21 – Tempo Médio por Nível de Dificuldade (Quizzes)	75
Figura 22 – Média de Erros por Tipo de Questão (Quizzes)	76
Figura 23 – Tempo Médio por Tipo de Questão (Quizzes)	77
Figura 24 – Média de Conhecimento: Pré vs Pós.	77
Figura 25 – Distribuição do Ganho de Aprendizado.	78
Figura 26 – Média das Notas de Feedback.	79
Figura 27 – Estatísticas de grupo por gênero (Fase de prática)	80
Figura 28 – Resultados dos testes de Levene e T de Student (Fase de prática)	80
Figura 29 – Estatísticas de grupo por idade (Fase de prática)	81
Figura 30 – Resultados do teste de Kruskal-Wallis (Fase de prática)	81
Figura 31 – Estatísticas de grupo por gênero (Fase de domínio)	81

Figura 32 – Resultados dos testes de Levene e T de Student (Fase de domínio)	82
Figura 33 – Estatísticas de grupo por idade (Fase de domínio)	82
Figura 34 – Resultados do teste de Kruskal-Wallis (Fase de domínio)	82

Lista de abreviaturas e siglas

IA	Inteligência Artificial
GBL	Game-Based Learning
LA	Learning Analytics
LMS	Learning Management System
GA	Game Analytics
GLA	Game Learning Analytics
GPT	Generative Pre-trained Transformer
SBES	Simpósio Brasileiro de Engenharia de Software
AF	Avaliação Final
LI	Limiar Inicial
LF	Limiar Final
AI	Avaliação Inicial
CSV	Comma Separated Values
MOODLE	Modular Object-Oriented Dynamic Learning Environment
UX	User Experience
REST	Representational State Transfer
API	Application Programming Interface
AVA	Ambiente Virtual de Aprendizagem

Sumário

	Lista de ilustrações	7
1	INTRODUÇÃO	13
1.1	Objetivos	16
1.1.1	Objetivos Específicos	16
2	REFERENCIAL TEÓRICO	18
2.1	Ensino de Requisitos de Software	18
2.1.1	Dificuldades Cognitivas	19
2.1.2	Dificuldades Metodológicas	19
2.1.3	Dificuldades Contextuais	20
2.1.4	Dificuldades Motivacionais	20
2.2	Impacto da Pandemia e Digitalização do Ensino em Engenharia de Software	20
2.2.1	Adaptação ao Ensino Remoto	21
2.2.2	Mudança no Perfil do Estudante	21
2.2.3	Oportunidades e Desafios no Contexto da Digitalização	22
2.3	Tecnologias de Suporte ao Ensino de Engenharia de Software	23
2.3.1	Ferramentas Educacionais e Impactos no Ensino	23
2.4	Jogos Digitais e Jogos Sérios	24
2.5	Game-Based Learning (GBL)	26
2.6	Learning Analytics (LA)	27
2.7	Game Analytics (GA)	27
2.8	Game Learning Analytics (GLA)	28
2.9	Inteligência Artificial no Ensino	29
2.9.1	Benefícios da IA no Ensino	29
2.9.2	Desafios do Uso de IA na Educação	30
2.9.3	Engenharia de Prompt e seu Papel na Educação	31
2.10	Técnicas Tradicionais vs. Memorização com Exemplos Concretos	32
2.10.1	Comparação das Abordagens	32
2.11	Uso de Ferramentas Educacionais: Flashcards	33
2.12	Uso de Ferramentas Educacionais: Quizzes	35
2.12.1	Sinergia entre Flashcards e Quizzes para o Aprendizado em Engenharia de Software	36
2.13	Estratégias de Avaliação para Jogos Educacionais	37
2.13.1	Observação Direta do Desempenho no Jogo	38

2.13.2	Análise de Dados e Telemetria do Jogo (incluindo Learning Analytics, Game Analytics e Game Learning Analytics)	38
2.13.3	Avaliação Pré e Pós-Jogo	39
2.13.4	Produção de Artefatos ou Geração de Saídas	39
2.13.5	Autoavaliação e Feedback do Jogador	40
2.13.6	Metodologia de Avaliação de Aprendizado (Serrano-Laguna et al.)	40
2.14	O Uso de Livros Didáticos na Educação e em Engenharia de Software	41
2.14.1	Vantagens do Livro Didático	41
2.14.2	Desafios e Complementos ao Livro Didático	42
2.14.3	Livros Didáticos na Engenharia de Software: Relevância e Desafios	42
2.14.4	Uso do Livro Pressman - Engenharia de Software: Uma Abordagem Profissional - 8ª Edição	43
2.15	Considerações Finais do Referencial Teórico	44
3	METODOLOGIA	45
3.1	Metodologia para Criação e Análise da Eficácia da Plataforma	45
3.1.1	Projeto e Implementação do Jogo Sério	46
3.1.2	Coleta de Observáveis	47
3.1.3	Análise dos Resultados Obtidos e Classificação do Aprendizado	47
3.1.3.1	Classificação dos Jogadores e Análise da Eficácia	49
3.1.3.2	Metodologia Experimental e Cruzamento de Variáveis	50
4	RESULTADOS	52
4.1	Implementação da Plataforma	52
4.1.1	Geração de Conteúdo Automatizada com Inteligência Artificial e Engenharia de Prompt	52
4.1.1.1	Fluxo de Trabalho e Estruturação do Conteúdo	52
4.1.1.2	Validação dos Materiais	54
4.1.1.3	Materiais Audiovisuais	54
4.1.2	Jogabilidade e Gamificação	54
4.1.3	Fases Presentes na Plataforma	55
4.1.3.1	Fase de Estratégia	55
4.1.3.2	Fase de Prática	55
4.1.3.3	Fase de Domínio	56
4.1.3.4	Pontuação para Insígnias:	56
4.1.4	Protótipo da Interface e Usabilidade	57
4.1.4.1	Home Page e Escolhas do Usuário	57
4.1.4.2	Flashcards: Prática Ativa e Feedback Detalhado	58
4.1.4.3	Quizzes: Validação do Conhecimento e Análise de Progresso	59
4.1.4.4	Perfil: Mural de Insígnias e Reconhecimento	60

4.2	Arquitetura da Plataforma e Implementação Técnica	62
4.2.1	Visão Geral da Arquitetura e Fluxo de Dados	63
4.2.1.1	Interação Frontend-Backend e Processamento de Dados	63
4.2.1.1.1	Carregamento e Personalização Inicial (Frontend e Backend):	64
4.2.1.1.2	Interação com Quizzes e Flashcards (Frontend e Backend):	65
4.2.1.1.3	Processamento e Avaliação no Backend (NestJS e MongoDB):	65
4.2.1.1.4	Concessão de Insígnias e Gamificação:	65
4.2.2	Ferramentas de Desenvolvimento da Plataforma	66
4.2.2.1	React	66
4.2.2.2	NestJS	66
4.2.2.3	MongoDB	67
4.2.3	Ferramentas de Coleta e Análise	67
4.2.3.1	Coleta de Dados no Frontend (React)	67
4.2.3.2	Armazenamento e Indexação no MongoDB	68
4.3	Escopo e Limitações de Análise	68
4.4	Efetividade da Plataforma FlashQuiz	69
4.5	Percentual de Acertos e Erros por Fase e Análise de Dificuldades	72
4.5.1	Desempenho nos Flashcards: Média de Tentativas	73
4.5.2	Desempenho nos Quizzes: Questões com Mais Erros	74
4.5.3	Percepção de Aprendizagem e Feedback da Plataforma	76
4.6	Testes de Hipóteses	79
4.6.1	Resultados da Fase de Prática (<i>AI_score</i>)	80
4.6.2	Resultados da Fase de Domínio (<i>AF_score</i>)	81
4.7	Discussão dos Resultados	82
4.8	Considerações Finais dos Resultados	85
5	CONCLUSÃO E TRABALHOS FUTUROS	86
5.1	Síntese dos Principais Resultados	86
5.2	Desempenho e Feedback dos Usuários	86
5.3	Análise de Variáveis Demográficas e Hipóteses	87
5.4	Limitações do Estudo	87
5.5	Sugestões de Trabalhos Futuros	87
	REFERÊNCIAS	89

1 Introdução

Este trabalho apresenta uma pesquisa que busca investigar o uso e a eficácia de novas tecnologias para o ensino de Engenharia de Software. Por meio de uma revisão bibliográfica, verificou-se uma dificuldade no ensino e aprendizado de Engenharia de Software. O conhecimento necessário para um estudante dessa disciplina combina aspectos teóricos e práticos. Várias pesquisas recentes vêm sendo propostas para trazer essa prática e experiência para o currículo atual de Engenharia de Software, mas poucos trabalhos focaram na melhoria do aprendizado teórico.

Apesar de a disciplina de Engenharia de Software já existir há décadas e muitos de seus princípios, métodos e técnicas serem bem conhecidos, a evolução de novas tecnologias e aplicações gera novos conhecimentos. Essa vasta quantidade de informação resulta em um excesso que dificulta a assimilação pelos alunos em períodos curtos de uma disciplina ou até mesmo do curso. Por outro lado, é sabido que a Engenharia de Software foi criada para desenvolver sistemas de software de alta qualidade (SOMMERVILLE, 2011), de forma eficiente e econômica, que atendam às necessidades dos usuários e do negócio, e que o custo de um erro pode ser extremamente alto. Ter uma base sólida dos princípios, processos e boas práticas que guiam o desenvolvimento de software de forma estruturada e disciplinada é crucial para esse tipo de conhecimento, onde o custo do erro é elevado.

Nesse contexto, a pesquisa buscou propor uma solução alinhada com as características do novo estudante, cujo perfil vem se modificando nos últimos anos, principalmente pelos avanços tecnológicos e mudanças sociais. Diante das dificuldades identificadas no ensino e aprendizado de Engenharia de Software, especialmente a necessidade de conciliar conhecimentos teóricos e práticos e a sobrecarga de informações, surgiu a ideia de desenvolver uma solução inovadora que explorasse o potencial das novas tecnologias digitais.

O aprendizado dos alunos de antigamente era caracterizado como passivo, focado na transmissão de conteúdo pelo professor, com estratégias predominantes de memorização e repetição. Havia uma maior dependência do professor como principal fonte de informação, e o conhecimento fora de sala de aula era limitado a livros, bibliotecas e enciclopédias. O uso de tecnologias, como internet, jogos digitais e celulares, era menos frequente na educação. A interação social e o trabalho em grupo eram predominantemente presenciais.

O aprendizado dos alunos atuais é mais ativo, com o estudante assumindo o papel de protagonista e buscando mais autonomia. O aluno moderno é nativo digital

e cresceu em um ambiente totalmente conectado, sendo fluente em tecnologia e utilizando smartphones, redes sociais e internet para diversas atividades, como assistir vídeos, ler notícias e artigos, e jogar. Ele busca respostas em tempo real, curtas e em linguagem simples, preferindo aulas que não sejam meramente expositivas. A observação desse perfil de estudante — mais ativo, nativo digital e em busca de respostas rápidas e interativas (LUCKIN et al., 2016) — impulsionou a concepção de um jogo educacional, como uma experiência projetada para a aprendizagem (SQUIRE, 2006). Essa iniciativa visou preencher a lacuna na melhoria do aprendizado teórico em Engenharia de Software, ao mesmo tempo em que oferece uma experiência alinhada com as características e expectativas da nova geração de alunos. A inspiração veio da eficácia comprovada de estratégias lúdicas e interativas (PRENSKY, 2004), como flashcards e quizzes, que já demonstravam grande potencial para transformar o ensino.

O conteúdo da disciplina de Engenharia de Software, consolidado há décadas, possui uma base teórica fundamental representada em diversos textos. Dentre eles, destaca-se o livro *Software Engineering: A Practitioner's Approach* (SEPA). O uso de um livro-texto oferece várias vantagens tanto para estudantes quanto para professores, pois, normalmente, ele integra recursos de aprendizagem, como exercícios, problemas práticos, exemplos detalhados, glossários, referências bibliográficas e recursos online complementares. A abordagem proposta nesta pesquisa investiga o uso de Inteligência Artificial (IA) generativa para criar recursos online e de jogos. Em particular, utilizou-se o modelo GPT-4o da OpenAI para gerar o material didático.

Outros elementos centrais que potencializam o aprendizado na abordagem incluem:

- Aspectos de design (animações e efeitos digitais, cores);
- Informações em representações multimodais (vídeos, textos);
- Jogos digitais (jogo de quiz);
- Elementos de gamificação;
- Digitalização de estratégias tradicionais de aprendizagem (flashcards);
- Coleta de dados de aprendizagem e de usabilidade;
- Visualização de informações de aprendizagem.

Essa combinação de elementos visa enriquecer a experiência educacional de forma dinâmica, interativa e baseada em dados.

Considerando esse contexto e os desafios enfrentados no ensino de requisitos de software, este trabalho propõe uma solução inovadora para contribuir com essa

problemática. A plataforma desenvolvida neste estudo é baseada em Inteligência Artificial (IA), utilizando flashcards e quizzes gerados automaticamente para otimizar o ensino dessa disciplina essencial na formação em Engenharia de Software. A definição correta dos requisitos é vital para o sucesso de um projeto, pois orienta todas as fases subsequentes do desenvolvimento de sistemas, garantindo que as funcionalidades construídas atendam tanto às expectativas dos usuários quanto aos objetivos organizacionais. No entanto, a complexidade dos conteúdos e a dificuldade de aplicar a teoria na prática afetam diretamente a qualidade da formação dos estudantes (SOMMERVILLE, 2011).

Diante disso, abordagens inovadoras baseadas em metodologias ativas de aprendizagem, como flashcards, quizzes e vídeos curtos de revisão, têm demonstrado grande potencial para transformar o ensino de requisitos de software. Essas ferramentas favorecem a memorização ativa e a retenção de conhecimento, bem como a conexão entre conhecimentos-chave da teoria que são fundamentais para a prática da Engenharia de Software. Estudos indicam que técnicas de recuperação ativa, como as proporcionadas por flashcards, são altamente eficazes na consolidação de memórias de longo prazo (BUTLER; ROEDIGER, 2010; KARPICKE; BLUNT, 2011). Similarmente, o uso frequente de quizzes pode aumentar significativamente o engajamento e a motivação dos alunos, além de fortalecer as conexões neurais associadas ao conhecimento, melhorando a retenção a longo prazo (DUNLOSKY et al., 2013; MCDANIEL; ROEDIGER, 2011).

A utilização combinada dessas estratégias — flashcards, quizzes e vídeos curtos — não apenas facilita a revisão dos conteúdos teóricos, mas também engaja os alunos de forma lúdica e interativa. O uso de conceitos de game-based learning (GBL) e jogos sérios contribui para tornar a aprendizagem mais dinâmica. Além disso, tecnologias emergentes como a IA têm ampliado as possibilidades de personalização do ensino, adaptando o conteúdo às necessidades individuais dos estudantes (ZAWACKI-RICHTER et al., 2019; LUCKIN et al., 2016). Ferramentas que geram automaticamente flashcards, quizzes e vídeos curtos de revisão permitem que os alunos pratiquem o conteúdo de maneira estruturada e progressiva, reforçando a assimilação dos conceitos e proporcionando um ambiente de aprendizagem mais eficaz.

A relevância desse problema foi amplamente discutida no XXXVIII Simpósio Brasileiro de Engenharia de Software (SBES), realizado em 2024, que analisou as práticas e abordagens no ensino da Engenharia de Software ao longo da última década. As discussões do simpósio destacaram os desafios enfrentados pela área, como a dificuldade de adaptação às rápidas mudanças tecnológicas e a complexidade da aplicação prática de conceitos teóricos, especialmente na engenharia de requisitos. Além disso, apontaram a necessidade de abordagens inovadoras que integrem o aprendi-

zado teórico e prático de forma mais interativa e personalizada, preenchendo lacunas do ensino tradicional.

Atento a essas demandas, este trabalho apresenta o FlashQuiz, uma plataforma educacional baseada em IA, que utiliza flashcards e quizzes gerados automaticamente para facilitar o ensino de requisitos de software. O conteúdo é fundamentado no renomado livro de Roger Pressman (1982), amplamente adotado em disciplinas da área. A plataforma, alimentada pelo modelo GPT-4o da OpenAI (baseado na arquitetura Generative Pre-trained Transformer), busca oferecer uma síntese interativa e personalizada dos conceitos fundamentais de requisitos de software. Ao integrar aprendizado adaptativo e interativo, a ferramenta não apenas responde aos desafios apontados no SBES, mas também auxilia na transição entre teoria e prática de forma acessível e dinâmica. Para validar a eficácia desta proposta, será aplicada a metodologia de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)), que permite monitorar o progresso dos estudantes e avaliar os resultados educacionais de maneira sistemática. Espera-se que essa abordagem contribua tanto para o avanço das práticas educacionais na área de Engenharia de Software quanto para a formação de profissionais mais preparados para enfrentar os desafios do mercado.

1.1 Objetivos

Este trabalho tem como objetivo geral investigar como o uso de ferramentas de IA pode otimizar o aprendizado de conceitos fundamentais de Engenharia de Software, com foco em requisitos de software. Especificamente, pretende-se avaliar como a geração automatizada de flashcards e quizzes pode contribuir para a revisão teórica e a consolidação de conhecimentos de forma eficiente. Além disso, será avaliado o impacto da adaptação da experiência de aprendizado, utilizando mecanismos como a repetição espaçada e a avaliação por limiares, na eficácia do ensino. Para garantir a validação e a eficácia dessa abordagem, será aplicada a metodologia de Serrano-Laguna et al. (2017), que permitirá monitorar o progresso dos estudantes e avaliar o impacto das ferramentas no aprendizado de maneira rigorosa e sistemática.

1.1.1 Objetivos Específicos

- Desenvolver a plataforma FlashQuiz, baseada em Inteligência Artificial, que utilize flashcards e quizzes gerados automaticamente para apoiar o estudo de requisitos de software.
- Avaliar a eficácia da FlashQuiz na melhoria do desempenho dos estudantes em testes de conhecimento, aplicando a metodologia de Serrano-Laguna et al. para

validação dos resultados.

- Verificar a efetividade do *feedback* personalizado fornecido pela plataforma no fortalecimento da autonomia e da autogestão dos estudantes.
- Analisar a percepção dos estudantes quanto à contribuição da FlashQuiz para a retenção de conhecimento e engajamento no processo de aprendizado.

2 Referencial Teórico

2.1 Ensino de Requisitos de Software

O ensino de requisitos de software é um dos pilares fundamentais no ciclo de desenvolvimento de sistemas. Esses requisitos representam descrições precisas das funcionalidades que o sistema deve oferecer para atender tanto às necessidades dos usuários quanto aos objetivos organizacionais. Sua correta definição é crucial, pois serve como base para todas as etapas subsequentes do desenvolvimento — desde a arquitetura até o design, implementação e testes. Um erro nessa fase pode acarretar retrabalho, falhas críticas no sistema e impacto direto na operação de usuários e empresas.

No contexto educacional, no entanto, o ensino de requisitos ainda enfrenta grandes desafios. Frequentemente abordada de maneira excessivamente teórica, a disciplina é apresentada com foco em definições formais que nem sempre parecem aplicáveis à prática profissional. Autores como Pressman ([PRESSMAN, 2019](#)) e Sommerville ([SOMMERVILLE, 2011](#)) oferecem abordagens estruturadas sobre tópicos como elicitacão, análise, especificação e validação de requisitos. Contudo, a transição desses conceitos para situações reais de projeto continua sendo uma lacuna crítica na formação dos estudantes.

Essa problemática foi amplamente debatida no XXXVIII Simpósio Brasileiro de Engenharia de Software (SBES), realizado em 2024, especialmente no estudo de ([CLEMENTINO et al., 2024](#)), que analisou uma década de publicações sobre práticas educacionais no evento. Os autores destacaram a persistente dificuldade de integrar teoria e prática no ensino de Engenharia de Software, a sobrecarga de conteúdos abstratos e a ausência de atividades práticas estruturadas. O estudo também evidencia um desalinhamento entre o currículo acadêmico e as competências exigidas pelo mercado de trabalho, que demanda profissionais capazes de aplicar os conceitos com agilidade, senso crítico e domínio de ferramentas modernas.

Nesse cenário, métodos tradicionais baseados em textos extensos e normas rígidas mostram-se insuficientes. A formação de profissionais qualificados requer abordagens que proporcionem feedback imediato, ambientes interativos e estratégias que mitiguem a sobrecarga cognitiva — sobretudo em disciplinas de alta complexidade, como requisitos de software. Tecnologias educacionais baseadas em Inteligência Artificial, combinadas com técnicas de aprendizado adaptativo, gamificação e uso de quizzes, têm o potencial de preencher essas lacunas. Tais abordagens favorecem a

personalização do ensino, promovem o engajamento do aluno e reforçam a conexão entre teoria e prática de forma progressiva, alinhando o processo de ensino às transformações contemporâneas da educação superior e às demandas reais do mercado.

2.1.1 Dificuldades Cognitivas

As dificuldades cognitivas refletem os desafios relacionados à assimilação e ao processamento dos conceitos teóricos de engenharia de software. Essas dificuldades incluem:

- **Complexidade conceitual:** Conceitos como análise de requisitos, modelagem e design são abstratos e multifacetados, tornando difícil para os alunos compreenderem suas implicações práticas.
- **Sobrecarga de informação:** A amplitude dos tópicos em engenharia de software pode ser intimidante, dificultando a organização e a retenção de conhecimento.
- **Retenção de conhecimento a longo prazo:** Sem métodos de revisão eficazes, como quizzes e flashcards, os estudantes enfrentam dificuldades para internalizar conceitos essenciais, o que pode comprometer sua aplicação prática no futuro.

A integração de Inteligência Artificial ao ensino pode auxiliar na superação dessas dificuldades, pois quizzes adaptativos e flashcards personalizados permitem que os estudantes revisem os conceitos mais desafiadores com maior frequência, promovendo retenção de longo prazo e garantindo que conteúdos fundamentais sejam absorvidos de maneira eficaz antes da aplicação prática.

2.1.2 Dificuldades Metodológicas

As dificuldades metodológicas estão relacionadas à aplicação prática de técnicas e ferramentas específicas da área. A tradução da teoria para a prática é um dos maiores desafios enfrentados pelos estudantes, que muitas vezes relatam dificuldades em aplicar conceitos de engenharia de requisitos em cenários reais, especialmente no processo de elicitação e especificação de requisitos (TIWARI et al., 2018).

Outro ponto crítico é a introdução de metodologias ágeis no contexto acadêmico. Embora práticas como sprints e reuniões interativas sejam cada vez mais relevantes no mercado de trabalho, a falta de experiência prática faz com que os estudantes encontrem obstáculos ao entender como adaptá-las aos problemas propostos em sala de aula (BLINCOE et al., 2018). Além disso, a elicitação de requisitos se destaca como

uma atividade particularmente desafiadora, pois envolve comunicação eficaz com stakeholders — algo que é agravado pela ausência de interação com usuários reais nos ambientes acadêmicos (ZOWGHI; COULIN, 2008; FERNÁNDEZ et al., 2016).

2.1.3 Dificuldades Contextuais

As dificuldades contextuais surgem das condições sob as quais o ensino de requisitos de software é realizado. A falta de projetos reais limita a capacidade dos estudantes de aplicar os conceitos aprendidos, tornando o aprendizado excessivamente abstrato e desconectado do mundo profissional (TIWARI et al., 2018). Além disso, o feedback insuficiente — caracterizado por uma demora ou até ausência de avaliações detalhadas sobre atividades práticas — reduz as oportunidades de ajustes e melhorias no aprendizado.

Outro fator relevante é a presença de ambientes de aprendizado desatualizados, nos quais ferramentas e tecnologias utilizadas não refletem as práticas atuais do mercado, dificultando a formação de profissionais preparados para os desafios contemporâneos (JATIT, 2024).

2.1.4 Dificuldades Motivacionais

Essas dificuldades estão diretamente relacionadas à motivação e ao engajamento dos estudantes no processo de aprendizado. O foco excessivo na teoria, sem mostrar claramente sua aplicabilidade, leva à desmotivação e à falta de interesse. Além disso, a sensação de sobrecarga causada pela vastidão dos tópicos abordados pode desanimar os estudantes, criando uma barreira adicional para a aprendizagem efetiva (TIWARI et al., 2018).

Por fim, a falta de conexão com o mercado — evidenciada pela ausência de estudos de caso, simulações de projetos e práticas interativas — reforça a percepção de que os conceitos ensinados não têm aplicabilidade prática imediata, prejudicando o engajamento dos alunos (BLINCOE et al., 2018).

2.2 Impacto da Pandemia e Digitalização do Ensino em Engenharia de Software

A pandemia de COVID-19 trouxe mudanças profundas para o ensino de Engenharia de Software, acelerando a digitalização e forçando a rápida adaptação ao ensino remoto. Universidades e cursos técnicos precisaram superar barreiras tecnológicas e metodológicas para proporcionar uma experiência de aprendizado significativa

em um ambiente remoto, muitas vezes sem a infraestrutura ou o preparo necessários (CAROLAN et al., 2020).

Essa transição abrupta gerou desafios específicos, como a falta de interação presencial, que limitou a troca de ideias em tempo real, essencial para o aprendizado colaborativo. Além disso, houve uma dependência de tecnologias de comunicação, como plataformas de videoconferência e ferramentas de colaboração virtual, que nem sempre reproduzem a qualidade do aprendizado prático dos ambientes presenciais. A desigualdade no acesso à tecnologia agravou as dificuldades, com muitos estudantes enfrentando problemas de conectividade e falta de dispositivos adequados para acompanhar as aulas (PETRUS; CAMINHAS, 2021).

2.2.1 Adaptação ao Ensino Remoto

A digitalização do ensino, embora desafiadora, abriu caminho para a adoção de novas práticas e tecnologias educacionais. Ferramentas digitais e sistemas de gerenciamento de aprendizado (LMS), como Moodle e Google Classroom, tornaram-se centrais na organização e condução das atividades acadêmicas. Contudo, o impacto dessas ferramentas mostrou-se limitado diante das demandas específicas do ensino de Engenharia de Software, que exige uma integração mais profunda entre teoria e prática.

O XXXVIII Simpósio Brasileiro de Engenharia de Software (SBES) abordou a transição para o ensino remoto, destacando que a simples digitalização de conteúdos não é suficiente para garantir o aprendizado efetivo. O ensino remoto revelou lacunas significativas, como a ausência de práticas interativas e personalizadas, comprometendo o engajamento e a assimilação de conceitos técnicos complexos, especialmente em disciplinas como requisitos de software. Além disso, estudos apontam que a falta de interação presencial e a sobrecarga cognitiva causada por métodos pouco dinâmicos afetaram não apenas o desempenho acadêmico, mas também a saúde mental dos estudantes (OLIVEIRA; VASCONCELOS; ALMEIDA, 2022). Nesse contexto, o SBES ressaltou a importância de integrar tecnologias que promovam a aprendizagem adaptativa e colaborativa, como ferramentas baseadas em Inteligência Artificial (IA), para mitigar essas lacunas.

2.2.2 Mudança no Perfil do Estudante

A pandemia também transformou o perfil dos estudantes de Engenharia de Software. Antes, o aprendizado era fortemente dependente do ambiente presencial e das interações diretas com professores e colegas. Após a pandemia, observou-se um movimento em direção a um perfil mais autônomo e adaptável, onde os estudantes preci-

sam gerir seu próprio aprendizado em maior escala. Entre as mudanças mais notáveis, destacam-se:

- **Autonomia e autogestão:** A flexibilidade de horários e o ensino remoto impulsionaram os estudantes a gerenciar melhor seus prazos e atividades, embora essa autonomia muitas vezes tenha sido acompanhada por dificuldades em organizar o aprendizado de maneira eficaz (SALES; CASTRO, 2021).
- **Dependência de recursos online:** Ferramentas como assistentes de IA, incluindo o ChatGPT, tornaram-se mais comuns como suporte complementar às aulas, permitindo que os alunos sanassem dúvidas e revisassem conceitos de forma independente.
- **Familiaridade com tecnologias emergentes:** A necessidade de utilizar ferramentas digitais frequentemente aumentou a disposição dos estudantes para adotar tecnologias inovadoras, como ambientes virtuais de aprendizado e plataformas baseadas em gamificação.

2.2.3 Oportunidades e Desafios no Contexto da Digitalização

Embora o ensino remoto tenha apresentado muitas barreiras, ele também criou oportunidades para reimaginar o ensino de Engenharia de Software. Discussões no SBES enfatizaram que a digitalização pode ser um catalisador para práticas mais inovadoras, incluindo:

- **Adoção de ferramentas interativas:** Ambientes virtuais, flashcards digitais e quizzes adaptativos foram apontados como estratégias promissoras para superar as limitações da sala de aula virtual tradicional.
- **Personalização do aprendizado:** Tecnologias de IA permitem a adaptação do conteúdo às necessidades de cada estudante, aumentando a eficácia e a retenção de conhecimento.
- **Acessibilidade e escalabilidade:** Recursos digitais têm o potencial de ampliar o alcance do ensino, especialmente em regiões onde o acesso a recursos físicos é limitado.

Por outro lado, há desafios éticos e técnicos associados à digitalização do ensino, como a desigualdade no acesso à tecnologia, a privacidade dos dados dos estudantes e a dependência excessiva de ferramentas digitais. É fundamental avaliar esses fatores para garantir que o impacto seja positivo e inclusivo (MASSARANI et al., 2021; OLIVEIRA; VASCONCELOS; ALMEIDA, 2022).

2.3 Tecnologias de Suporte ao Ensino de Engenharia de Software

Com o avanço das tecnologias digitais, o ensino de Engenharia de Software vem se tornando mais dinâmico e alinhado às exigências do mercado de trabalho. Ambientes Virtuais de Aprendizagem (AVAs), sistemas de gestão de projetos, plataformas de simulação e recursos personalizados têm sido fundamentais para aproximar a teoria da prática, oferecendo aos estudantes experiências imersivas e colaborativas (KHARISTAT; FAKHOURI, 2024).

O XXXVIII Simpósio Brasileiro de Engenharia de Software (SBES) destacou que a personalização do aprendizado é um dos principais desafios na área. A utilização de ferramentas educacionais baseadas em Inteligência Artificial (IA), como flashcards inteligentes e quizzes adaptativos, surge como alternativa para oferecer experiências de estudo ajustadas ao nível de conhecimento de cada aluno, melhorando o engajamento e consolidando a base teórica antes de enfrentar problemas práticos (REVIEW, 2021).

Nesse cenário, a combinação estratégica de tecnologias, como vídeos curtos, flashcards digitais e quizzes interativos, mostra-se eficiente para reduzir a sobrecarga de informações e facilitar a assimilação de conceitos complexos. Quando associadas à IA, essas ferramentas não apenas entregam conteúdo de forma adaptativa, mas também promovem recuperação ativa do conhecimento e feedback imediato, elementos essenciais para a retenção de longo prazo e o desenvolvimento de competências práticas (ALI; UNTERKALMSTEINER, 2023; ANDRADE et al., 2022).

2.3.1 Ferramentas Educacionais e Impactos no Ensino

Os Ambientes Virtuais de Aprendizagem (AVAs), como o Moodle, desempenham um papel central na organização das atividades acadêmicas. Eles permitem que os estudantes revisem conteúdos em seu próprio ritmo, participem de atividades colaborativas e recebam materiais complementares de forma estruturada. Além de facilitar o acesso ao conhecimento, esses ambientes reproduzem dinâmicas de trabalho em equipe, elemento essencial para preparar os estudantes para a realidade de projetos profissionais (KHARISTAT; FAKHOURI, 2024; REVIEW, 2021).

As ferramentas de gestão de projetos, como JIRA e Trello, aproximam ainda mais o aprendizado da prática de mercado, introduzindo conceitos de metodologias ágeis, como o Scrum. Por meio dessas ferramentas, os estudantes aprendem a organizar tarefas, estabelecer prioridades e acompanhar o progresso do trabalho em equipe, desenvolvendo habilidades como gestão de prazos, planejamento iterativo e resolução de problemas complexos. Estudos apontam que o Trello, por exemplo, promove o desenvolvimento de competências como autonomia, colaboração e autorregulação nos estudantes (SHCHETYNINA et al., 2022).

As plataformas de simulação e modelagem, como o Enterprise Architect, ampliam a capacidade dos estudantes de visualizar sistemas complexos, explorar diferentes perspectivas de design, analisar processos e antecipar problemas antes da implementação. Essa abordagem fortalece o raciocínio crítico e a tomada de decisões informadas, promovendo uma compreensão mais profunda dos conceitos teóricos (ALI; UNTERKALMSTEINER, 2023; FRANÇA et al., 2025).

Além disso, quizzes e flashcards, especialmente quando combinados com Inteligência Artificial (IA), oferecem uma experiência de aprendizado personalizada. Utilizando técnicas como repetição espaçada e feedback imediato, essas ferramentas permitem identificar lacunas no conhecimento e reforçar os conteúdos mais desafiadores, tornando o estudo mais eficiente e direcionado às necessidades individuais de cada estudante (REVIEW, 2021; ANDRADE et al., 2022).

O uso integrado dessas ferramentas no ensino de Engenharia de Software não apenas potencializa a compreensão dos conceitos técnicos, mas também estimula habilidades interpessoais, como comunicação, liderança e trabalho colaborativo. Ao simular cenários reais dentro de um ambiente acadêmico, essas tecnologias garantem maior engajamento e preparam os alunos para lidar com os desafios do mercado.

As discussões no XXXVIII SBES destacam que a combinação estratégica entre tecnologias digitais e metodologias inovadoras é essencial para superar as limitações dos métodos tradicionais, como a ausência de feedback em tempo real e a dificuldade de conectar conceitos teóricos a aplicações práticas. Essa integração entre tecnologia e pedagogia transforma o aprendizado em Engenharia de Software, tornando-o mais relevante, interativo e eficaz.

2.4 Jogos Digitais e Jogos Sérios

Os jogos estão presentes na cultura humana desde tempos antigos, evoluindo com o surgimento dos computadores e, posteriormente, com a redução dos custos de hardware. Essa evolução possibilitou o desenvolvimento de uma nova categoria de jogos: os jogos digitais.

As pessoas jogam por diferentes razões. Algumas buscam uma fuga rápida e casual do mundo real, enquanto outras procuram desafios ou simulações de atividades da vida real (BATES, 2004). Jogos são, essencialmente, ferramentas lúdicas que atraem os jogadores a participar voluntariamente de atividades com objetivos específicos propostos pelo jogo.

O potencial dos jogos para a educação foi observado desde os primeiros lançamentos de jogos comerciais, e logo começaram a surgir jogos com o objetivo central

de serem ferramentas de ensino. Se os videogames conseguem engajar usuários por horas, é natural que possam ser usados para ensinar diferentes temas. No entanto, embora possam utilizar uma embalagem digital atraente, a essência do aprendizado ainda se mantém (BLUMBERG, 2014).

Um dos primeiros exemplos de jogo educativo foi o *Number Munchers*, lançado na década de 1980 (HACKETT, 2016), que tinha como foco o ensino de matemática básica. Apesar de, inicialmente, não haver uma terminologia clara para categorizar esse tipo de jogo, o conceito de jogos educativos se consolidou ao longo do tempo, trazendo diversas definições para jogos focados no aprendizado.

De acordo com Michael, Chen e Ebrary (MICHAEL; CHEN, 2006), Jogos Sérios referem-se a jogos digitais que vão além do entretenimento e podem ter finalidades como treinamento, crítica social e até promoção de produtos e serviços, como ocorre nos advergames. Por sua vez, Zyda (ZYDA, 2005) define Jogos Sérios como uma disputa mental, realizada em um computador, que utiliza o entretenimento para atingir fins de treinamento, educação, saúde, políticas públicas e comunicação estratégica.

Jogos Sérios possuem componentes fundamentais, como regras e jogabilidade, desafios, interações e objetivos (WATTANASOONTORN; HERNANDEZ; SBERT, 2012). Esses elementos moldam o tipo de interação que o jogador poderá realizar no jogo, visando o cumprimento dos desafios e o alcance dos objetivos propostos. Esses objetivos podem ser explícitos, relacionados à conclusão de uma tarefa ou meta do próprio jogo, ou implícitos, como o conhecimento adquirido durante a experiência de jogo. A estrutura dos Jogos Sérios e seus componentes essenciais são ilustrados na Figura 2.

A partir dessas definições, fica claro que os Jogos Sérios se diferenciam de outros tipos de jogos digitais pela presença de uma intenção educacional em seu design, visando desenvolver habilidades específicas ou melhorar o desempenho dos jogadores em determinadas áreas. No entanto, vale destacar que jogos destinados exclusivamente ao entretenimento também podem oferecer aprendizado incidental aos jogadores, como ocorre com títulos como *Civilization* e *Age of Empires*, que transmitem conhecimento histórico mesmo sem terem sido desenvolvidos com essa finalidade.

É importante diferenciar Jogos Sérios de Gamificação. Enquanto a Gamificação utiliza elementos dos jogos (como pontuação, classificações e troféus) para tornar outras atividades mais envolventes e motivadoras, sem necessariamente transformar essas atividades em jogos, os Jogos Sérios são concebidos como um jogo completo, desenvolvido para promover aprendizado ou mudança comportamental específica (DE-TERDING et al., 2011).

Embora distintas, Gamificação e Jogos Sérios se relacionam, pois ambos aplicam elementos de jogos para atingir objetivos. Nos Jogos Sérios, esses elementos inte-

gram o design de um jogo completo, enquanto na Gamificação são utilizados como um conjunto de ferramentas que potencializam o envolvimento do usuário em atividades externas aos jogos.

Para que um Jogo Sérioso seja eficaz, é importante que desafie os jogadores de forma adaptada às suas habilidades, a fim de despertar o interesse e a motivação para explorar o tema proposto. Dessa forma, o jogo pode inspirar o jogador a buscar conhecimentos mais aprofundados sobre o tema abordado, tornando-se uma porta de entrada para o aprendizado contínuo.

2.5 Game-Based Learning (GBL)

O Game-Based Learning (GBL) refere-se ao uso de jogos como ferramentas educacionais com o objetivo de facilitar a aquisição de conhecimento e o desenvolvimento de habilidades por meio de atividades interativas e lúdicas. Essa abordagem utiliza o apelo emocional e o potencial de engajamento dos jogos para transformar o aprendizado em uma experiência prática e dinâmica. Segundo Squire ([SQUIRE, 2006](#)), o GBL possibilita que os estudantes se envolvam em simulações de cenários reais, permitindo a aplicação direta de conceitos em um ambiente seguro e controlado.

No contexto do ensino de Engenharia de Software, os jogos baseados em GBL podem ser empregados para simular processos de desenvolvimento de software, proporcionando aos estudantes a vivência de etapas como definição de requisitos, design de sistemas e resolução de problemas. Um exemplo notável é o SimSE, uma simulação voltada ao gerenciamento de projetos de software que permite aos alunos experimentar desafios como gerenciamento de recursos, cumprimento de prazos e tomada de decisões críticas ([NAVARRO; HOEK, 2006](#)). Dessa forma, o GBL promove uma experiência de aprendizado que conecta teoria e prática, preparando os estudantes para lidar com cenários complexos do mercado.

Entre os benefícios do GBL, destacam-se o aumento do engajamento, a promoção do aprendizado ativo e a estimulação de habilidades de resolução de problemas. Estudos apontam que o GBL melhora a retenção de conhecimento, pois o estudante, ao participar ativamente de atividades simuladas, aplica os conceitos de maneira contextualizada, favorecendo a compreensão e a memória de longo prazo ([JOHNSON; WU, 2010](#); [NAVARRETE; SANTOS, 2016](#)). Além disso, o GBL contribui para o desenvolvimento de soft skills, como trabalho em equipe, liderança e tomada de decisão, competências fundamentais para o mercado de trabalho atual ([NICHOLS, 2013](#)).

2.6 Learning Analytics (LA)

Learning Analytics (LA) é uma abordagem que envolve a coleta e análise de dados educacionais com o objetivo de melhorar o ensino e o aprendizado. Segundo Baker e Inventado (BAKER; INVENTADO, 2014), LA pode ser descrito como o uso de dados para beneficiar a educação e a ciência da aprendizagem, fornecendo insights sobre o desempenho e o comportamento dos alunos. Inicialmente, LA era aplicado principalmente ao monitoramento de atividades em plataformas de aprendizado digital (LMS), permitindo que educadores acompanhassem as interações dos estudantes com os materiais de estudo, como frequência de acesso e tempo dedicado a cada conteúdo (ARNOLD; PISTILLI, 2012).

Com o desenvolvimento de tecnologias e o aumento da disponibilidade de dados, o LA tornou-se mais sofisticado, abrangendo a análise de dados sobre o desempenho dos alunos em avaliações, padrões de acesso a conteúdos e até mesmo a interação com recursos multimídia. Essas informações permitem identificar padrões de dificuldade, prever o risco de fracasso e adaptar as estratégias de ensino para atender melhor às necessidades individuais dos alunos. Por exemplo, um sistema de LA em uma plataforma de ensino pode detectar que determinado grupo de estudantes tem dificuldade com um conceito específico, alertando o educador para oferecer reforço nesse tópico.

Os benefícios do LA incluem a personalização do aprendizado, o apoio na tomada de decisões educacionais e a promoção de intervenções pedagógicas em tempo real. Ao identificar as áreas nas quais os alunos enfrentam dificuldades e detectar lacunas de compreensão de forma precoce, o LA permite que os educadores adotem estratégias personalizadas, ajustando o conteúdo e as atividades para maximizar o aprendizado e melhorar o desempenho dos estudantes. Esse nível de personalização torna o ensino mais eficiente e aumenta as chances de sucesso dos alunos, promovendo uma educação mais centrada no aluno.

2.7 Game Analytics (GA)

Game Analytics (GA) é o termo utilizado para descrever o processo de coleta, análise e interpretação de dados sobre as interações dos jogadores com um jogo, com o objetivo de otimizar a experiência do usuário e melhorar o design do jogo. Segundo Seif El-Nasr et al. (EL-NASR; CANOSSA; DRAKEFORD, 2013), GA é amplamente utilizado na indústria de jogos para ajustar a jogabilidade, corrigir problemas e criar experiências mais envolventes e personalizadas. Esse processo envolve a análise de métricas como o tempo de jogo, as ações mais frequentes dos jogadores, os níveis completados e os pontos de abandono.

Nos jogos educacionais, GA pode ser aplicado para monitorar o desempenho dos alunos e identificar os momentos em que eles enfrentam dificuldades ou desistem de um desafio específico. Um exemplo prático é o uso de GA em jogos de matemática que registram o tempo que o aluno leva para resolver um problema, o número de tentativas necessárias e o nível de ajuda solicitado. Essas informações ajudam os desenvolvedores e educadores a identificar quais aspectos do jogo são mais desafiadores e a fazer ajustes que tornem o aprendizado mais acessível e motivador.

Os benefícios do GA incluem a possibilidade de criar jogos mais eficientes, corrigir problemas de design em tempo real e aumentar a retenção de jogadores. No contexto educacional, GA permite que os jogos sejam adaptados ao nível de habilidade dos estudantes, proporcionando uma experiência personalizada que apoia o aprendizado contínuo. Ao ajustar a dificuldade e os desafios de acordo com o progresso de cada aluno, GA contribui para que o jogo permaneça desafiador e engajador, sem se tornar frustrante.

2.8 Game Learning Analytics (GLA)

Game Learning Analytics (GLA) combina os princípios de Learning Analytics e Game Analytics para maximizar o impacto educacional dos jogos. De acordo com Freire et al. ([FREIRE et al., 2016](#)), GLA refere-se à coleta e análise de dados detalhados sobre as interações dos alunos em jogos, permitindo uma adaptação dinâmica e personalizada do conteúdo de aprendizado. Essa abordagem é particularmente útil em Jogos Sérios, onde o objetivo é educar enquanto se entretém, pois oferece insights que ajudam a entender como cada jogador está progredindo em sua jornada de aprendizado.

Em um sistema de GLA, os dados coletados incluem informações detalhadas sobre cada ação do jogador, como tempo de resposta, acertos e erros, além de métricas de engajamento e tempo de dedicação. Por exemplo, em um jogo de ciências, o GLA pode registrar quantas vezes o aluno revisita determinados conteúdos ou solicita ajuda em questões específicas, fornecendo uma visão precisa de suas dificuldades e progresso. Essa análise permite intervenções pedagógicas mais precisas, como o fornecimento de dicas adicionais ou a adaptação do nível de dificuldade de acordo com o desempenho do aluno.

Os benefícios do GLA são amplos, incluindo a personalização do aprendizado, o monitoramento contínuo do progresso dos estudantes e a possibilidade de intervenções em tempo real. Ao ajustar o conteúdo e os desafios de acordo com as necessidades e o desempenho de cada aluno, o GLA promove um aprendizado mais eficaz e significativo. Além disso, a análise dos dados permite que educadores e desenvolvedores

res de jogos avaliem a eficácia dos conteúdos e façam melhorias contínuas, garantindo que o jogo educativo seja uma ferramenta eficaz para o desenvolvimento de habilidades e conhecimentos.

2.9 Inteligência Artificial no Ensino

A integração da Inteligência Artificial (IA) no ensino tem transformado significativamente a maneira como conteúdos são apresentados e aprendidos, oferecendo soluções inovadoras para personalizar o aprendizado, otimizar o tempo dos educadores e melhorar a experiência dos estudantes ([ZAWACKI-RICHTER et al., 2019](#)). Ao combinar o poder da IA com ferramentas como flashcards, quizzes e vídeos curtos, é possível ajustar o ritmo e o conteúdo às necessidades individuais, permitindo que os estudantes acessem materiais adicionais, exercícios práticos e quizzes focados em suas áreas de dificuldade, promovendo um aprendizado mais eficiente e direcionado.

Além disso, a IA oferece feedback em tempo real, permitindo que os alunos identifiquem e corrijam erros imediatamente, o que acelera o progresso e aumenta a confiança no aprendizado. Tecnologias como flashcards e quizzes adaptativos utilizam técnicas de repetição espaçada e recuperação ativa para melhorar a retenção de conhecimento a longo prazo, enquanto atividades interativas mantêm os estudantes mais motivados e engajados ([DUNLOSKY et al., 2013](#); [BUTLER; ROEDIGER, 2010](#); [KARPICKE; BLUNT, 2011](#)).

O XXXVIII Simpósio Brasileiro de Engenharia de Software (SBES) destacou o papel transformador da IA no ensino, especialmente na personalização do aprendizado. Algoritmos de learning analytics permitem identificar padrões de aprendizado e recomendar materiais suplementares ou práticas de revisão direcionadas. Além disso, o uso de flashcards digitais dinâmicos e quizzes adaptativos possibilita que cada aluno revise os conceitos teóricos no seu próprio ritmo, garantindo uma assimilação mais eficiente antes da aplicação prática.

2.9.1 Benefícios da IA no Ensino

Os benefícios da IA na educação abrangem diversas frentes ([HOLMES; BIALIK; FADEL, 2019](#)), incluindo:

- **Personalização do aprendizado:** A IA ajusta conteúdos e atividades às necessidades específicas de cada estudante, analisando dados de desempenho e propondo materiais personalizados.
- **Feedback imediato:** Respostas instantâneas ajudam os estudantes a corrigirem erros e entenderem conceitos em tempo real, acelerando o aprendizado.

- **Retenção de conhecimento:** Ferramentas como flashcards e quizzes adaptativos promovem práticas comprovadas para consolidar memórias e aumentar a retenção de longo prazo (BUTLER; ROEDIGER, 2010; KARPICKE; BLUNT, 2011).
- **Engajamento e motivação:** Atividades interativas e adaptativas tornam o aprendizado mais dinâmico e atraente, mantendo os estudantes envolvidos.
- **Automatização de tarefas:** Ao automatizar atividades como correção de exercícios e geração de relatórios, a IA libera educadores para se concentrarem em tarefas de maior impacto pedagógico.

2.9.2 Desafios do Uso de IA na Educação

Apesar de seu potencial transformador, a aplicação da IA no ensino enfrenta desafios técnicos, éticos e pedagógicos que precisam ser considerados para maximizar seus benefícios (ZAWACKI-RICHTER et al., 2019; BOSTROM; YUDKOWSKY, 2014).

- **Privacidade e segurança de dados:** A coleta e análise de informações dos estudantes levantam preocupações sobre como esses dados são armazenados e utilizados.
- **Desigualdade no acesso à tecnologia:** Ferramentas baseadas em IA exigem infraestrutura adequada, o que pode agravar desigualdades educacionais em contextos menos favorecidos (ZAWACKI-RICHTER et al., 2019).
- **Dependência tecnológica:** A implementação de IA requer não apenas tecnologia avançada, mas também educadores capacitados para integrá-la de forma eficaz ao currículo.
- **Risco de despersonalização:** Embora a IA seja projetada para personalizar o aprendizado, seu uso excessivo pode reduzir a interação humana, essencial no processo educacional (BOSTROM; YUDKOWSKY, 2014).
- **Preparação pedagógica:** Soluções de IA precisam ser alinhadas aos objetivos educacionais, garantindo que sirvam como uma extensão estratégica da metodologia de ensino, e não apenas como uma ferramenta tecnológica.

O SBES ressaltou que, para alcançar seu pleno potencial, a IA deve ser acompanhada de estratégias pedagógicas que priorizem a interação humana e o aprendizado colaborativo. Também destacou a necessidade de transparência no uso de dados e o desenvolvimento de políticas éticas e inclusivas para mitigar riscos associados à privacidade e à desigualdade de acesso.

2.9.3 Engenharia de Prompt e seu Papel na Educação

A Engenharia de Prompt é um campo emergente da IA que se concentra na criação e otimização de instruções textuais (prompts) para orientar modelos de linguagem, como o GPT, na geração de respostas específicas e eficazes (LIU et al., 2021; WHITE; LING; LIANG, 2022). A qualidade e a precisão de um modelo de IA dependem significativamente do design do prompt, que pode variar desde instruções simples até contextos complexos e detalhados.

No contexto educacional, a engenharia de prompt permite:

- **Criação de conteúdos personalizados:** Prompts bem elaborados podem gerar materiais didáticos, exercícios práticos e quizzes adaptados às necessidades específicas dos estudantes.
- **Produção de materiais multimídia:** Com prompts direcionados, modelos de IA podem criar vídeos explicativos, diagramas e até imagens ilustrativas para facilitar a compreensão de conceitos.
- **Interatividade no aprendizado:** Através de prompts que simulam diálogos, os estudantes podem interagir com a IA para tirar dúvidas, revisar conteúdos e consolidar o conhecimento de forma ativa.

Modelos de linguagem como o GPT-3 (BROWN et al., 2020) e o GPT-2 (RADFORD et al., 2019) demonstraram grande eficácia em aprender com poucos exemplos (few-shot learning), tornando-se ideais para gerar conteúdos sob demanda. Pesquisas recentes também apontam para abordagens mais avançadas de prompt-based learning (WEI; WANG; ZHANG, 2022; BAI; HUANG; CHEN, 2022), que permitem personalizar a experiência de aprendizado e aumentar o engajamento dos estudantes.

Durante o desenvolvimento deste trabalho, a engenharia de prompt foi fundamental para a criação dos flashcards e quizzes gerados automaticamente. Por meio de prompts cuidadosamente projetados, a IA foi capaz de produzir questões relevantes, explicações claras e até representações visuais que enriqueceram a experiência de aprendizado dos estudantes.

O SBES também destacou a importância de abordagens inovadoras como a engenharia de prompt para maximizar o potencial de ferramentas de IA na educação. Prompts bem estruturados podem melhorar a qualidade das respostas geradas, garantir alinhamento com os objetivos pedagógicos e criar experiências mais interativas e personalizadas.

Este estudo responde diretamente às questões levantadas no SBES, ao propor uma plataforma que combina a personalização proporcionada pela IA com os recursos

avançados da engenharia de prompt. Flashcards, quizzes, vídeos e imagens educacionais foram gerados automaticamente a partir de prompts projetados para atender às necessidades específicas do ensino de requisitos de software. Assim, espera-se contribuir para um aprendizado mais eficiente, interativo e alinhado às demandas do mercado.

O XXXVIII Simpósio Brasileiro de Engenharia de Software (SBES) destacou o papel transformador da IA no ensino, especialmente em disciplinas técnicas como requisitos de software. O simpósio reforçou que ferramentas baseadas em IA não apenas auxiliam na transição da teoria para a prática, mas também aprimoram a própria compreensão teórica. Algoritmos de learning analytics podem identificar padrões de aprendizado e recomendar materiais suplementares ou práticas de revisão direcionadas. Além disso, o uso de flashcards digitais dinâmicos e quizzes adaptativos possibilita que cada aluno revise os conceitos teóricos no seu próprio ritmo, garantindo uma assimilação mais eficiente antes da aplicação prática.

2.10 Técnicas Tradicionais vs. Memorização com Exemplos Concretos

No ensino de Engenharia de Software, especialmente na disciplina de requisitos, muitas instituições ainda utilizam abordagens tradicionais, pautadas em leituras extensas, aulas expositivas e atividades semiprontas. Embora esse método ofereça uma base teórica sólida, frequentemente falha em motivar os estudantes ou em demonstrar como as definições abstratas se aplicam em cenários reais de desenvolvimento.

Nesse sentido, o uso de memorização ativa e exemplos concretos desponta como alternativa eficaz para aprimorar a compreensão dos alunos. Ao associar cada conceito a um problema ou caso de uso prático, o estudante não apenas memoriza a informação, mas também entende seu contexto de aplicação. Essa estratégia é fundamental para construir uma base teórica sólida e minimizar a chance de erros primários, sendo particularmente crucial em áreas como a Engenharia de Software, onde falhas em requisitos podem ter consequências significativas. A redução da lacuna entre teoria e prática, identificada como um dos principais entraves na formação de futuros engenheiros de software ([PRESSMAN, 2019](#); [SOMMERVILLE, 2011](#)), é um objetivo central dessa abordagem.

2.10.1 Comparação das Abordagens

- **Método Tradicional:** O estudante recebe grande volume de conteúdo teórico de forma passiva, muitas vezes sem um retorno imediato sobre seu desempe-

nho ou entendimento. Essa abordagem pode levar à sobrecarga cognitiva e à desmotivação.

- **Memorização Ativa com Exemplos:** Flashcards e quizzes permitem uma recuperação contínua do conteúdo, reforçando a retenção de longo prazo. Além disso, exemplos práticos de elicitación ou validação de requisitos potencializam a compreensão, pois mostram ao aluno como e onde aquela teoria se aplica (BUTLER; ROEDIGER, 2010; KARPICKE; BLUNT, 2011).

A adoção dessas técnicas favorece a aprendizagem significativa, pois o aluno é estimulado a refletir sobre o conteúdo em vez de apenas lê-lo. Em consequência, ele desenvolve maior autonomia e confiança para utilizar os conceitos em situações de projeto (DUNLOSKY et al., 2013; BUTLER; ROEDIGER, 2010).

2.11 Uso de Ferramentas Educacionais: Flashcards

Os flashcards são uma ferramenta de aprendizado amplamente utilizada e altamente eficaz, projetada para promover a prática ativa e a retenção de informações. Cada flashcard contém uma pergunta, conceito ou termo em um lado, e a resposta ou explicação correspondente no outro. A ideia é que o estudante tente responder ou explicar o conteúdo antes de verificar a resposta. Esse método incentiva o aprendizado ativo, que é mais envolvente para as capacidades cognitivas do aluno, quando comparado à leitura passiva de materiais (BUTLER; ROEDIGER, 2010; BROWN et al., 2020).

Estudos recentes reforçam a efetividade dessa técnica. Santhosh et al. (SANTHOSH et al., 2024) realizaram um estudo randomizado com estudantes de odontologia e comprovaram que o uso de flashcards digitais, aliado à repetição espaçada, aumentou significativamente a retenção de conhecimento e o desempenho acadêmico. Essa evidência demonstra o potencial dos flashcards em contextos educacionais que exigem a consolidação de informações complexas.

Os flashcards oferecem benefícios significativos para o processo educacional:

- **Sumarização de Conteúdos Complexos:** No caso de requisitos de software, que englobam conceitos amplos (como elicitación, análise e validação), os flashcards permitem condensar informações em perguntas-chave, facilitando a revisão focada.
- **Prática Ativa e Recuperação do Conhecimento:** Em vez de reler passivamente, o estudante é desafiado a lembrar o conteúdo, reforçando as conexões neurais

responsáveis pela memorização de longo prazo (KARPICKE; BLUNT, 2011; BUTLER; ROEDIGER, 2010). Essa prática de recuperação, comprovadamente superior à leitura passiva, é essencial para transferir o conhecimento da memória de curto para a de longo prazo.

- **Personalização e Adaptação via IA:** Algoritmos de Inteligência Artificial podem reordenar os flashcards conforme o desempenho do aluno, oferecendo mais vezes aqueles que apresentam maior dificuldade e reduzindo a repetição de conceitos já consolidados. Estudos recentes demonstram que a personalização dos conteúdos com base em objetivos de aprendizado previamente estabelecidos melhora substancialmente o desempenho dos alunos, aumentando a probabilidade de retenção de conhecimento a longo prazo, especialmente em disciplinas que exigem alto nível de detalhamento e precisão (ROBINSON; ALBEKAI; ABDELRAZZAK, 2024).

Uma técnica frequentemente utilizada em conjunto com os flashcards para otimizar a retenção é a repetição espaçada. Essa técnica envolve revisar o conteúdo em intervalos de tempo crescentes, distribuindo as revisões ao longo de dias ou semanas, em vez de sessões concentradas e curtas. Pesquisas comprovam que essa abordagem melhora a retenção a longo prazo, pois o cérebro se beneficia de intervalos mais longos entre as revisões para solidificar o conhecimento (CEPEDA et al., 2006). A repetição espaçada é particularmente eficaz para preparar os estudantes para exames e para a assimilação de novos conceitos complexos.

Plataformas digitais, como o Anki e o Tilibra Connect, exemplificam a aplicação bem-sucedida de flashcards e repetição espaçada. O Anki, um software de código aberto, permite a criação, organização e revisão personalizada de flashcards, ajustando automaticamente os intervalos de revisão com base no desempenho do usuário (BURIĆ; STRÖM, 2021). Essa característica tem demonstrado grande eficácia na melhoria da retenção, especialmente em áreas que demandam alta memorização, como medicina e línguas estrangeiras. Similarmente, a Tilibra Connect, inovação no mercado educacional brasileiro, adapta os conceitos de flashcards ao contexto nacional, oferecendo um banco de dados compartilhado e algoritmos que ajustam a frequência de revisão para uma aprendizagem mais acessível e personalizada.

A integração de flashcards com técnicas de repetição espaçada em plataformas digitais proporciona uma forma de aprendizado autônomo mais acessível e eficiente. No ensino contemporâneo, essas ferramentas contribuem significativamente para o desenvolvimento de uma rotina de estudos consistente e personalizada, facilitando a absorção de conhecimentos complexos. Ao promoverem a prática ativa e a retenção de longo prazo, essas tecnologias apoiam o desenvolvimento de competências neces-

sárias tanto em contextos acadêmicos quanto no mercado de trabalho.

A eficácia dos flashcards, especialmente quando integrados com repetição espaçada e personalização via IA, reside em sua capacidade de solidificar o conhecimento teórico. No entanto, para uma compreensão completa e a aplicação prática, a teoria precisa ser testada em contextos dinâmicos. É nesse ponto que a combinação com quizzes se torna um diferencial, complementando a memorização ativa dos flashcards com desafios de aplicação e validação do conhecimento, preparando o estudante para cenários mais complexos da Engenharia de Software.

2.12 Uso de Ferramentas Educacionais: Quizzes

Os quizzes são outra ferramenta educacional amplamente utilizada, oferecendo uma maneira interativa de testar o conhecimento dos alunos sobre um determinado conteúdo. Geralmente compostos por perguntas objetivas ou de múltipla escolha, os quizzes são eficazes em testar a compreensão e a aplicação de conceitos. A principal vantagem desse recurso é o feedback imediato que ele proporciona, permitindo que os alunos identifiquem rapidamente seus erros e corrijam mal-entendidos, promovendo o aprendizado contínuo (BUTLER; ROEDIGER, 2010).

Os quizzes estimulam o aprendizado ativo, pois exigem que os estudantes participem ativamente do processo de recuperação da informação e apliquem o raciocínio crítico para responder às questões. Essa prática não apenas fortalece as conexões neurais associadas ao conhecimento, mas também aumenta significativamente a retenção de longo prazo, ajudando a fixar o conhecimento de forma duradoura (DUNLOSKY et al., 2013). Ao promover o engajamento do aluno com o conteúdo, os quizzes transformam o aprendizado em uma atividade prática e envolvente, reforçando o que foi aprendido.

Pesquisas indicam que o uso frequente de quizzes pode aumentar significativamente o engajamento e a motivação dos alunos (MCDANIEL; ROEDIGER, 2011). Quando incorporados regularmente às atividades de estudo, os quizzes oferecem uma forma tangível de acompanhar o progresso, gerando uma sensação de realização e melhoria contínua. Além disso, o feedback imediato gera uma motivação extra para que os alunos continuem revisando e melhorando suas habilidades. Esses testes também são úteis para identificar precocemente áreas de dificuldade, permitindo intervenções mais direcionadas e eficazes no processo de aprendizado.

Os benefícios e características dos quizzes incluem:

- **Gamificação para Engajamento:** Elementos como pontuação, ranking e recompensas virtuais tornam os quizzes mais atrativos e competitivos, motivando o

estudante a melhorar seu desempenho a cada tentativa.

- **Importância da Interface Digital:** Uma interface amigável e responsiva facilita a navegação e a execução dos quizzes, contribuindo para uma melhor experiência de aprendizado. Ferramentas com design intuitivo elevam a probabilidade de o aluno se manter engajado.
- **Dados de Entrada e Validação:** A criação de questões de qualidade depende tanto de uma boa fonte de conteúdo (livros, artigos, documentos de requisitos) quanto de métodos para validar a coerência das perguntas. Em plataformas de IA, algoritmos podem sugerir ou filtrar questões inadequadas, garantindo a relevância e a consistência do quiz.

Plataformas educacionais online, como Kahoot, Quizlet e Google Forms, oferecem quizzes interativos que tornam o aprendizado mais lúdico e envolvente. Essas ferramentas permitem que os alunos pratiquem e reforcem o conteúdo de maneira divertida, tornando o processo de aprendizado mais agradável. Além disso, fornecem aos instrutores dados analíticos detalhados sobre o desempenho dos alunos, facilitando a identificação de áreas que precisam de mais atenção e ajustes no ensino.

A capacidade dos quizzes de promover o engajamento, oferecer feedback imediato e fortalecer a retenção de longo prazo é inegável. Contudo, para que os alunos cheguem aos quizzes com uma base sólida e não apenas tentem adivinhar as respostas, é fundamental que a memorização e a recuperação ativa dos conceitos teóricos sejam bem estabelecidas. A união com os flashcards serve exatamente a esse propósito, criando um ciclo de aprendizado onde a teoria é primeiramente internalizada de forma ativa para, em seguida, ser testada e aplicada de maneira eficaz nos quizzes, garantindo uma compreensão mais profunda e duradoura.

2.12.1 Sinergia entre Flashcards e Quizzes para o Aprendizado em Engenharia de Software

A complexidade do ensino de Engenharia de Software, que exige tanto a assimilação de vastos conhecimentos teóricos quanto a capacidade de aplicá-los em situações práticas, demanda abordagens educacionais que vão além de ferramentas isoladas. Nesse contexto, a combinação estratégica de flashcards e quizzes emerge como uma poderosa sinergia capaz de amplificar significativamente os resultados de aprendizagem (MCDANIEL; ROEDIGER, 2011).

Enquanto os flashcards se destacam na promoção da recuperação ativa e na consolidação da memorização de longo prazo para conceitos teóricos, atuando como um pilar fundamental para a base de conhecimento (MCDANIEL; ROEDIGER, 2011;

KARPICKE; BLUNT, 2011), os quizzes oferecem um ambiente dinâmico para o feedback imediato e o engajamento lúdico, testando a aplicação e validação do conhecimento em cenários diversos (BUTLER; ROEDIGER, 2010; DUNLOSKY et al., 2013). A literatura aponta que a recuperação ativa (exercitada pelos flashcards) fortalece as vias neurais e melhora a retenção em longo prazo, sendo superior à leitura passiva (MCDANIEL; ROEDIGER, 2011; KARPICKE; BLUNT, 2011). Similarmente, o efeito de teste (característico dos quizzes) não só aprimora a memorização, mas também a compreensão e a transferência do conhecimento (BUTLER; ROEDIGER, 2010; DUNLOSKY et al., 2013).

A união dessas ferramentas cria um ciclo de aprendizado robusto: os flashcards preparam o terreno, garantindo que o estudante domine os fundamentos teóricos de forma eficiente, reduzindo a sobrecarga cognitiva e fortalecendo as conexões neurais. Posteriormente, os quizzes desafiam o aluno a empregar esse conhecimento em diferentes contextos, solidificando a compreensão prática e revelando lacunas que necessitam de revisão. Essa abordagem integrada não apenas melhora a retenção de conteúdo, mas também desenvolve habilidades críticas de resolução de problemas, ao forçar o aluno a transitar constantemente entre o saber e o fazer. A combinação de técnicas como a recuperação ativa (flashcards) com a repetição espaçada é comprovadamente mais eficaz para maximizar a força e a longevidade das memórias (BUTLER; ROEDIGER, 2010; KARPICKE; BLUNT, 2011).

A Inteligência Artificial potencializa essa sinergia ao adaptar a frequência e a dificuldade de ambos os métodos, personalizando a jornada de aprendizado e garantindo que os esforços do estudante sejam direcionados para as áreas de maior necessidade. Dessa forma, a combinação de flashcards e quizzes não é meramente a soma de suas partes, mas uma estratégia pedagógica que oferece uma revisão teórica robusta e uma validação da compreensão prática, fundamental para a formação de profissionais competentes em Engenharia de Software.

2.13 Estratégias de Avaliação para Jogos Educacionais

A avaliação em jogos educacionais vai além da simples verificação do progresso do jogador, buscando medir de forma efetiva a aquisição e consolidação de conhecimentos. Diferentemente de métodos tradicionais, os jogos oferecem dados ricos sobre comportamento, engajamento e desempenho, permitindo análises detalhadas e personalizadas. Nesta pesquisa, as estratégias de avaliação são inspiradas tanto nos métodos clássicos quanto em abordagens baseadas em Learning Analytics, Game Analytics e na metodologia de Serrano-Laguna et al. (SERRANO-LAGUNA et al., 2017), que orienta um ciclo contínuo de coleta de dados, análise e melhoria.

2.13.1 Observação Direta do Desempenho no Jogo

A observação direta é um método imediato e intuitivo para avaliar o aprendizado.

- **Progresso e Conclusão de Fases/Níveis:** O jogo pode ser estruturado de forma que o avanço de uma fase para outra exija a compreensão de um conceito ou a aplicação de uma habilidade. A capacidade do aluno de progredir é um indicador direto do aprendizado.
- **Acerto de Desafios e Quebra-Cabeças:** Muitos jogos educacionais incorporam problemas que exigem o uso do conhecimento adquirido. A taxa de acertos e a eficiência na resolução desses problemas são métricas importantes.
- **Tomada de Decisões:** Em jogos de simulação ou estratégia, as decisões tomadas pelo jogador e suas consequências podem revelar o nível de compreensão do conteúdo. Por exemplo, em um jogo de gestão de recursos, a otimização na alocação de recursos pode indicar um aprendizado eficaz.
- **Coleta de Itens e Pontuações Específicas:** Se o jogo recompensa a aplicação correta de conceitos com pontos ou itens especiais, a quantidade e qualidade desses elementos coletados podem ser indicadores do aprendizado.

2.13.2 Análise de Dados e Telemetria do Jogo (incluindo Learning Analytics, Game Analytics e Game Learning Analytics)

Jogos digitais oferecem a vantagem de coletar uma vasta quantidade de dados sobre o comportamento do jogador. Essa coleta de dados é a base para as abordagens de Learning Analytics (LA), Game Analytics (GA) e Game Learning Analytics (GLA).

- **Tempo Gasto em Tarefas Específicas:** Um tempo excessivo em uma tarefa pode indicar dificuldade, enquanto um tempo muito curto pode sugerir superficialidade. O ideal é buscar um tempo que reflita engajamento e reflexão.
- **Número de Erros e Tentativas:** A quantidade de tentativas necessárias para resolver um problema e o tipo de erros cometidos podem indicar lacunas no aprendizado. A análise dos erros pode guiar o feedback e a intervenção.
- **Caminhos Percorridos e Escolhas Feitas:** Em jogos com ramificações, a análise dos caminhos que o jogador escolhe pode revelar sua compreensão de diferentes cenários ou conceitos.
- **Repetição de Conteúdo:** Se o aluno revisita consistentemente um material ou tutorial, pode ser um sinal de que ele precisa de mais reforço naquele ponto.

A combinação de LA e GA resulta no Game Learning Analytics (GLA), que maximiza o impacto educacional dos jogos. GLA refere-se à coleta e análise de dados detalhados sobre as interações dos alunos em jogos, permitindo uma adaptação dinâmica e personalizada do conteúdo de aprendizado. Essa abordagem é particularmente útil em Jogos Sérios, onde o objetivo é educar enquanto se entretém, pois oferece insights que ajudam a entender como cada jogador está progredindo em sua jornada de aprendizado. Os benefícios do GLA são amplos, incluindo a personalização do aprendizado, o monitoramento contínuo do progresso dos estudantes e a possibilidade de intervenções em tempo real.

2.13.3 Avaliação Pré e Pós-Jogo

Para medir o impacto real do jogo no aprendizado, é fundamental comparar o conhecimento do aluno antes e depois da experiência.

- **Testes e Questionários:** Aplicar um teste de conhecimento antes (pré-teste) e um depois (pós-teste) do aluno jogar. A diferença nas pontuações pode indicar o ganho de aprendizado.
- **Avaliações de Habilidades:** Para jogos que visam o desenvolvimento de habilidades, como resolução de problemas ou pensamento crítico, usar tarefas ou cenários específicos para avaliar a aplicação dessas habilidades antes e depois.
- **Entrevistas e Grupos Focais:** Conversar com os jogadores para entender suas percepções sobre o aprendizado, quais conceitos eles acham que assimilaram e quais ainda são difíceis.

2.13.4 Produção de Artefatos ou Geração de Saídas

Em alguns jogos, o aprendizado se manifesta na capacidade do aluno de criar algo ou produzir um resultado tangível.

- **Criação de Projetos:** Se o jogo envolve a construção de algo (por exemplo, um circuito elétrico, um programa de computador), a qualidade e funcionalidade do produto final são um forte indicador de aprendizado.
- **Relatórios e Análises:** Em jogos de simulação, os jogadores podem ser solicitados a gerar relatórios ou análises com base nos dados e eventos do jogo, demonstrando sua compreensão do sistema.
- **Debates e Discussões:** Após jogar, os alunos podem participar de debates ou discussões sobre os temas abordados no jogo, revelando seu domínio dos conceitos e sua capacidade de argumentação.

2.13.5 Autoavaliação e Feedback do Jogador

Incentivar o aluno a refletir sobre seu próprio aprendizado é uma estratégia valiosa para a avaliação.

- **Diários de Aprendizagem:** Pedir aos alunos para registrar suas percepções, dificuldades e o que aprenderam durante e após o jogo.
- **Questionários de Autoavaliação:** Desenvolver perguntas que ajudem os alunos a refletir sobre seu domínio dos conceitos e habilidades abordados no jogo.
- **Feedback Qualitativo:** Solicitar aos alunos que descrevam em suas próprias palavras o que eles aprenderam e como o jogo contribuiu para isso.

2.13.6 Metodologia de Avaliação de Aprendizado (Serrano-Laguna et al.)

A metodologia de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)) oferece uma abordagem abrangente e estruturada para avaliar a eficácia de ferramentas educacionais interativas, como jogos sérios, simulações e outros recursos baseados em tecnologia. O objetivo principal dessa metodologia é medir o impacto dessas ferramentas no aprendizado dos estudantes, fornecendo dados empíricos que podem orientar tanto o desenvolvimento contínuo dessas tecnologias quanto a adaptação de estratégias de ensino.

Essa abordagem é particularmente útil no contexto de ferramentas educacionais interativas, que exigem um processo contínuo de validação e aprimoramento, dada a complexidade de medir o impacto real de métodos não tradicionais de ensino. A metodologia se baseia em três fases principais: coleta de dados, análise de desempenho e ajuste contínuo, garantindo uma visão holística do processo de aprendizado e da eficácia das ferramentas utilizadas.

A fase de coleta de dados é fundamental para o sucesso da metodologia. Durante o uso das ferramentas educacionais, uma ampla gama de dados é capturada para fornecer uma visão detalhada das interações do estudante com a ferramenta. Esses dados incluem tempo gasto em cada atividade, número de tentativas, respostas corretas e incorretas, além de métricas comportamentais, como a sequência de ações tomadas pelos alunos. Esse processo de coleta de dados permite identificar padrões de comportamento, como o nível de engajamento e as áreas de maior dificuldade, sem interromper o fluxo natural de aprendizado do aluno.

Na fase de análise de desempenho, os dados coletados são utilizados para avaliar a efetividade da ferramenta educacional no processo de aprendizado. A análise envolve a medição do progresso do aluno ao longo do tempo, observando o quão

bem ele conseguiu assimilar o conteúdo e melhorar seu desempenho em tarefas específicas. Essa fase considera não apenas o número de respostas corretas, mas também a trajetória de aprendizado – ou seja, como o estudante evolui com o tempo e quais áreas requerem mais atenção.

Com base nos insights obtidos, a fase de ajuste contínuo permite que as ferramentas educacionais sejam aprimoradas para melhor atender às necessidades dos alunos. Isso pode incluir a adaptação dos níveis de dificuldade, a introdução de novos tipos de atividades ou a modificação de conteúdos para otimizar o engajamento e a retenção de conhecimento. Esse processo de ajuste contínuo segue um ciclo iterativo de melhoria, onde os resultados da análise de desempenho são utilizados para modificar a ferramenta, que é então novamente testada e ajustada com base em novos dados.

A metodologia de avaliação de aprendizado desenvolvida por Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)) oferece, portanto, uma abordagem robusta para medir e melhorar a eficácia de ferramentas educacionais interativas. Ao integrar as fases de coleta de dados, análise de desempenho e ajuste contínuo, ela garante que o impacto dessas ferramentas seja avaliado de forma sistemática e que as melhorias possam ser implementadas com base em evidências concretas. Isso torna essa metodologia uma ferramenta valiosa para a criação de recursos educacionais que não apenas envolvem os alunos, mas também promovem uma melhoria real e mensurável no aprendizado.

2.14 O Uso de Livros Didáticos na Educação e em Engenharia de Software

Os livros didáticos desempenham um papel fundamental na educação, desde os níveis básicos até o ensino superior, estruturando o processo de aprendizagem com conteúdos organizados, abrangentes e padronizados. Eles atuam como bases sólidas de conhecimento e contribuem significativamente para o desenvolvimento de habilidades de estudo autônomo e pesquisa, servindo como guias essenciais tanto para estudantes quanto para docentes.

2.14.1 Vantagens do Livro Didático

Os livros didáticos apresentam diversas vantagens significativas para o processo educacional. Eles oferecem uma estruturação lógica dos conteúdos, facilitando o planejamento e o acompanhamento curricular para alunos e professores. Além disso, são elaborados por especialistas e revisados por pares, o que garante a confiabilidade e precisão das informações, reduzindo o risco de disseminação de conteúdos incorre-

tos ou desatualizados.

Para docentes, os livros didáticos servem como importantes guias pedagógicos, apresentando sugestões práticas de atividades, exercícios e metodologias, especialmente valiosos para professores em início de carreira ou que estejam ministrando disciplinas novas. A acessibilidade e padronização proporcionadas pelos livros asseguram um acesso equitativo ao material didático, promovendo igualdade nas oportunidades de aprendizagem. Além disso, oferecem uma ferramenta de referência que possibilita aos alunos revisarem e aprofundarem os conteúdos em seu próprio ritmo, favorecendo a autonomia no aprendizado. Finalmente, muitos livros incluem atividades que estimulam o desenvolvimento de habilidades analíticas, críticas e de resolução de problemas.

2.14.2 Desafios e Complementos ao Livro Didático

Apesar de suas diversas vantagens, o uso exclusivo dos livros didáticos enfrenta desafios significativos, especialmente em áreas que evoluem rapidamente, como a Engenharia de Software. Um dos principais desafios é o tempo necessário para publicação e distribuição, o que pode levar a conteúdos rapidamente desatualizados frente ao ritmo acelerado das inovações tecnológicas. Outro desafio é a baixa personalização, já que um único livro dificilmente atende plenamente às diversas necessidades e estilos individuais de aprendizagem dos estudantes. Além disso, a ênfase excessiva na teoria pode incentivar a memorização superficial, prejudicando uma compreensão crítica e profunda dos conceitos abordados.

Para mitigar esses desafios, recomenda-se uma abordagem complementar que incorpore recursos digitais interativos, como plataformas online, vídeos educativos, simulações e artigos científicos atualizados. Igualmente importante é a implementação de métodos ativos de ensino, como projetos práticos, resolução de problemas reais e discussões interativas em sala de aula, que promovem um aprendizado mais significativo. Debates e discussões devem ser incentivados para estimular o pensamento crítico e aprimorar as habilidades argumentativas dos estudantes.

2.14.3 Livros Didáticos na Engenharia de Software: Relevância e Desafios

No contexto específico da Engenharia de Software, o uso estratégico dos livros didáticos é especialmente importante devido ao rápido avanço tecnológico da área. Embora continuem essenciais para a consolidação dos fundamentos básicos, como processos de software, requisitos, design, arquitetura, testes, gestão de projetos e qualidade, é fundamental combiná-los com abordagens complementares que garantam a atualização constante do currículo.

Esses livros oferecem conhecimento estruturado e profundo, permitindo uma

compreensão clara de conceitos complexos por meio de conteúdos organizados progressivamente. Além disso, estabelecem uma linguagem comum e padronizada que facilita a comunicação entre estudantes e professores e oferecem uma contextualização histórica e prática ao abordarem estudos clássicos e metodologias consagradas na área.

Entretanto, sua principal limitação reside na velocidade com que as tecnologias mudam, fazendo com que detalhes específicos sobre ferramentas e linguagens possam rapidamente se tornar obsoletos. Para enfrentar esse desafio, recomenda-se priorizar livros focados em princípios universais e boas práticas de engenharia, como os clássicos Clean Code, The Pragmatic Programmer e Code Complete. Além disso, é fundamental complementar o uso dos livros com recursos digitais atualizados, incluindo documentação oficial, artigos técnicos, cursos online e repositórios como GitHub, para estimular a prática e a experiência com projetos reais.

Projetos práticos e simulações também são essenciais para aplicar continuamente o conhecimento teórico. É importante realizar uma seleção criteriosa dos materiais, priorizando edições recentes ou obras que abordem metodologias modernas, como desenvolvimento ágil, DevOps e integração contínua. Finalmente, incentivar a participação dos estudantes em grupos de estudo, hackathons e comunidades profissionais promove o aprendizado contínuo e a atualização constante dos conhecimentos.

2.14.4 Uso do Livro Pressman - Engenharia de Software: Uma Abordagem Profissional - 8ª Edição

A presente pesquisa utiliza como base teórica o livro **Engenharia de Software: Uma Abordagem Profissional** de Roger Pressman, reconhecido por sua abordagem estruturada e prática sobre o ciclo de vida do software, com especial ênfase na engenharia de requisitos.

A escolha desta obra deve-se ao equilíbrio entre teoria e prática apresentado por Pressman, com exemplos reais que ilustram técnicas fundamentais como elicitação, análise, especificação e validação dos requisitos. Essa abordagem facilita a compreensão e aplicação prática dos conceitos pelos estudantes.

O livro adotado como base neste trabalho também serve de referência para a elaboração dos materiais didáticos interativos utilizados na plataforma educacional FlashQuiz, como flashcards e quizzes. Esses recursos foram desenvolvidos com base em uma metodologia step-by-step, permitindo que os estudantes revisitem e aprofundem conceitos essenciais da Engenharia de Software, como requisitos funcionais e não funcionais, qualidade de software e modelos de processos. Além disso, a contextualização oferecida pelos exemplos do livro inspirou a criação de cenários práticos

que simulam situações reais, favorecendo o desenvolvimento de habilidades de tomada de decisão e resolução de problemas em ambientes próximos aos encontrados no mercado.

Por fim, a 8ª edição incorpora discussões atualizadas sobre metodologias ágeis e tecnologias emergentes, alinhando-se perfeitamente com a proposta da FlashQuiz, que busca integrar teoria consolidada com ferramentas digitais adaptativas. Dessa forma, a utilização do livro de Pressman contribui diretamente para uma experiência educativa completa, que combina solidez conceitual, aplicação prática e interatividade, otimizando a retenção e aplicação do conhecimento em Engenharia de Software.

2.15 Considerações Finais do Referencial Teórico

Em síntese, o referencial teórico apresentado evidencia os múltiplos desafios do ensino de requisitos de software, desde as dificuldades cognitivas e metodológicas até as lacunas entre teoria e prática, amplificadas pela pandemia e pela rápida digitalização do ensino. A literatura revisada, somada às discussões recentes no SBES, aponta para a urgência de abordagens inovadoras que integrem tecnologias emergentes, como Inteligência Artificial e engenharia de prompt, com metodologias ativas como gamificação, flashcards e quizzes. Nesse cenário, este trabalho propõe uma solução educacional que responde diretamente a tais lacunas, aliando personalização, interatividade e aplicação prática dos conceitos. Assim, a proposta se insere em um esforço mais amplo de transformação do ensino em Engenharia de Software, promovendo uma experiência de aprendizado mais eficaz, contextualizada e alinhada às demandas do mercado e da formação profissional contemporânea.

3 Metodologia

A plataforma desenvolvida neste projeto baseia-se na metodologia de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)), que permite medir os objetivos educacionais alcançados pelos usuários e avaliar a efetividade da ferramenta. Essa abordagem não só responde aos desafios práticos de motivação e aplicação, mas também busca sanar as lacunas teóricas discutidas no XXXVIII Simpósio Brasileiro de Engenharia de Software (SBES, 2024), ao oferecer mecanismos de coleta de dados e feedback imediato que favorecem a personalização do aprendizado.

A escolha de flashcards e quizzes como ferramentas centrais da plataforma é intencional, visando a conexão intrínseca entre teoria e prática no ensino de requisitos de software. Diferentemente de métodos tradicionais de estudo, baseados apenas em leituras expositivas e testes pontuais, a combinação de flashcards e quizzes promove memorização ativa, uso de exemplos concretos e feedback contínuo, tornando o aprendizado mais dinâmico e engajador. Além disso, o conteúdo está alinhado ao livro Pressman - Engenharia de Software: Uma Abordagem Profissional - 8ª Edição, garantindo fidelidade conceitual e relevância prática.

3.1 Metodologia para Criação e Análise da Eficácia da Plataforma

Esta seção descreve a metodologia adotada para o desenvolvimento e análise dos dados coletados a partir do jogo sério proposto. Primeiramente, discute-se a fundamentação teórica da metodologia de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)); em seguida, detalha-se como essa abordagem foi aplicada ao design do jogo sério, visando abordar tanto as lacunas práticas quanto as teóricas destacadas no SBES.

A metodologia de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)) abrange todo o processo de criação, validação e análise de um jogo sério, com dois objetivos principais:

- Simplificar a avaliação dos resultados educacionais alcançados através de jogos sérios;
- Oferecer um método estruturado para analisar a eficácia desses jogos de maneira holística.

Dessa forma, definem-se os conhecimentos que o jogo busca ensinar e o público-alvo, criando uma mecânica alinhada aos objetivos educacionais propostos. Após a imple-

mentação, o jogo é submetido a avaliações formativas com uma amostra do público-alvo, repetindo e ajustando o processo até sua validação plena. Assim, a plataforma adota um ciclo iterativo que atende às recomendações do SBES, unindo feedback imediato, aprendizado adaptativo e game-based learning para reforçar tanto aspectos teóricos quanto práticos dos requisitos de software.

3.1.1 Projeto e Implementação do Jogo Sérico

O projeto de aprendizagem na metodologia de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)) envolve converter objetivos educacionais em mecânicas de jogo e resultados observáveis de aprendizado, atendendo às características do público-alvo. Nesse contexto, a metodologia é aplicada de forma estratégica através da combinação de flashcards e quizzes, que exercem um papel fundamental na mecânica do jogo. O tratamento dado a essa ideia inicial de jogo educacional centrou-se em uma abordagem multifacetada, integrando princípios de gamificação e aprendizado adaptativo, conforme evidenciado por estudos sobre o impacto de jogos sérios na educação ([CONNOLLY et al., 2012](#)). Os flashcards permitem resumir conteúdos complexos e promover a recuperação ativa do conhecimento, superando métodos tradicionais de leitura passiva. Os quizzes, por sua vez, propiciam feedback imediato, desafiando o aluno a aplicar conceitos em cenários práticos, seguindo o preceito de memorização com exemplos. A integração dessas ferramentas forma um ciclo contínuo de aprendizado, onde a teoria é primeiro internalizada e depois validada na prática.

Essas mecânicas estão alinhadas ao conteúdo do livro Pressman, garantindo coerência teórica e favorecendo a aplicação em situações reais de desenvolvimento de software. Um elemento chave do tratamento foi o uso intensivo da Inteligência Artificial para personalizar a sequência de flashcards e a dificuldade dos quizzes, aprimorando o aprendizado adaptativo e diferenciando a plataforma de metodologias mais antigas que não ofereciam tal nível de customização. Este processo de design e desenvolvimento seguiu princípios de criação de conteúdo para jogos sérios que visam o alinhamento com os objetivos de aprendizagem ([KIILI, 2005](#)).

Além disso, o mecanismo de feedback — bastante comum em jogos — é imprescindível: recompensas ou penalidades são aplicadas conforme o desempenho do jogador, incentivando ou desencorajando certas ações. Essa estratégia intensifica a motivação, conforme apontado por práticas de game-based learning.

Para tornar o aprendizado progressivo, a metodologia de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)) sugere três fases:

- **Estratégia:** Introduz os objetivos educacionais, geralmente por meio de tutoriais ou vídeos breves, orientando sobre o que se espera aprender.

- **Prática:** Ambiente seguro, onde os jogadores testam conhecimentos iniciais sem graves penalidades, consolidando conceitos teóricos.
- **Domínio:** Ambiente não seguro, com penalidades mais severas e desafios mais complexos; aqui, o estudante demonstra o que aprendeu.

Essas fases também favorecem o estado de fluxo, pois os usuários alternam entre aprender novos conteúdos e aplicar conhecimentos de forma desafiadora. Dessa maneira, a lacuna entre teoria e prática — crítica no ensino de requisitos — é reduzida, pois o aluno tem exemplos concretos e feedback imediato sobre seus avanços.

3.1.2 Coleta de Observáveis

A coleta de dados observáveis segue o conceito de Learning Analytics, registrando data, hora e contexto de cada interação, sem interromper o fluxo do jogo. Esses dados são enviados ao servidor em cada etapa, permitindo análises diversas:

- Taxas de acerto e erro nos flashcards e quizzes, indicando lacunas de conhecimento;
- Tempo de resposta, aferindo dificuldade ou familiaridade com o tema;
- Nível de engajamento, observado por tentativas sucessivas e frequência de acesso.

Esse procedimento converge com a proposta de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)), ao possibilitar uma avaliação contínua da eficácia do jogo sério, aliando fatores de motivação (gamificação) com indicadores de desempenho cognitivo. Conexões com o Kahoot, por exemplo, podem ser estabelecidas nesse sentido: hoje, a plataforma Kahoot faz uso de IA generativa para sugerir perguntas personalizadas, enquanto nossa plataforma emprega IA para adaptar flashcards e quizzes. Ambas as soluções demonstram que a aplicação de algoritmos de personalização e análise de dados enriquece o aprendizado e incrementa a motivação do usuário.

3.1.3 Análise dos Resultados Obtidos e Classificação do Aprendizado

Após a coleta sistemática de todos os dados observáveis das interações dos usuários nas fases de Prática e Domínio – e o envio dessas informações para o servidor central (**MongoDB**) – a análise da efetividade do jogo sério foi realizada por meio de uma abordagem experimental baseada em dados. Esta etapa é crucial para mensurar o impacto educacional da plataforma, seguindo os preceitos da metodologia de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)) e complementando-os com análises quantitativas e cruzamentos de variáveis (como gênero, idade, semestre do

curso e perfil de aprendizado). Essa estratégia amplia a robustez da avaliação, permitindo interpretações mais ricas e fundamentadas.




Figura 1 – Fluxo da Metodologia de Avaliação de Aprendizado (Serrano-Laguna et al.) e Melhoria Contínua

Fonte: Elaborado pelo Autor

A Figura 1 ilustra o ciclo da metodologia de Serrano-Laguna et al., destacando como a coleta e análise de dados são integradas para avaliar o aprendizado e promover a melhoria contínua da plataforma. O fluxo demonstra desde o armazenamento dos dados até a classificação dos jogadores, que, por sua vez, alimenta as estratégias de aprimoramento contínuo.

Conforme a metodologia, as interações da fase de Estratégia não são coletadas para a avaliação formal do aprendizado, pois seu objetivo é apenas apresentar os propósitos educacionais do jogo e introduzir os objetivos educacionais por meio de tutoriais ou vídeos breves. Por outro lado, as interações das fases Prática e de Domínio são fundamentais e consideradas para avaliar esses objetivos. Para cada fase, foi atribuída uma pontuação, permitindo a definição de dois momentos chave de avaliação:

- **Avaliação Inicial (AI):** Realizada na Fase de Prática, esta avaliação coleta dados para verificar o conhecimento prévio do jogador sobre o subtema ensinado. A pontuação obtida nos *flashcards* desta fase, que atribui pontos decrescentes conforme o número de tentativas, reflete o domínio inicial do conceito. Adicionalmente, o sistema registra o *feedback* de qualidade fornecido pelo próprio jogador, oferecendo uma percepção mais rica sobre a fluidez da recuperação do conhecimento. Embora a "Insígnia da Fase de Prática" seja concedida com 50 pontos ou mais, para a análise de eficácia foi adotado um limiar de 70 pontos, alinhado ao critério da faculdade.
- **Avaliação Final (AF):** Obtida na Fase de Domínio, esta avaliação coleta dados para verificar se o jogador adquiriu o conhecimento proposto pelo jogo. A pontuação nos *quizzes* desta fase, onde cada acerto vale 10 pontos, indica o nível

de aprendizado consolidado. Uma alta pontuação na AF demonstra que o jogador atingiu um nível significativo de aprendizado. A "**Insígnia da Fase de Domínio**" foi concedida ao usuário que atingir pelo menos 70% de acertos (70 pontos), o mesmo valor utilizado como limiar de aprovação na análise de eficácia.

Para fins de avaliação da plataforma, foram considerados os seguintes limiares:

- **Limiar Inicial (LI):** 70 pontos (Prática).
- **Limiar Final (LF):** 70 pontos (Domínio).

A eficácia do jogo em transmitir o conhecimento é verificada pela comparação entre as pontuações da Avaliação Inicial (AI) e da Avaliação Final (AF). Um jogo é considerado eficaz quando o jogador apresenta dificuldades na fase prática (AI baixa), mas obtém sucesso na fase de domínio (AF alta), indicando um ganho de conhecimento substancial.

3.1.3.1 Classificação dos Jogadores e Análise da Eficácia

Seguindo a metodologia de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)), o nível de conhecimento dos jogadores é classificado utilizando os resultados da Avaliação Inicial (AI) e da Avaliação Final (AF), juntamente com os limiares definidos. Com base nessas informações, os jogadores são categorizados da seguinte forma, o que permitirá uma avaliação granular do impacto da plataforma:

- **Alunos:** Quando a Avaliação Inicial é inferior ao Limiar Inicial ($AI < LI$), mas o jogador supera o Limiar Final na Avaliação Final ($AF \geq LF$). Esta é a categoria mais desejada, pois demonstra que o jogador realmente aprendeu com o jogo.
- **Mestres:** Quando a Avaliação Inicial é igual ou superior ao Limiar Inicial ($AI \geq LI$). Indica que o jogador já possuía o conhecimento necessário antes de iniciar o jogo e, portanto, não houve um "ganho" significativo de aprendizado diretamente atribuível à plataforma para aquele conteúdo específico.
- **Não-Alunos:** Quando tanto a Avaliação Inicial quanto a Final estão abaixo dos limiares ($AI < LI$ e $AF < LF$). Isso sugere que o jogador não conseguiu aprender de forma eficaz com o jogo.
- **Deslocados:** Quando a Avaliação Inicial é superior ao Limiar Inicial ($AI \geq LI$), mas a Avaliação Final é inferior ao Limiar Final ($AF < LF$). Essa categoria pode indicar falhas no *design* do jogo, na progressão dos desafios ou nas fórmulas de avaliação, pois o jogador possuía conhecimento inicial, mas não conseguiu aplicá-lo ou consolidá-lo na fase de domínio.

A eficácia geral do jogo foi avaliada comparando-se a distribuição dos jogadores em cada uma dessas categorias. A alta concentração de jogadores na categoria **"Alunos"** foi o principal indicador de que a plataforma é altamente eficaz no ensino de requisitos de *software*. Por outro lado, um número elevado de **"Mestres"** pode indicar que o conteúdo era muito básico para o público-alvo, enquanto muitos **"Não-Alunos"** ou **"Deslocados"** apontam para a necessidade de revisões no *design* pedagógico ou técnico da plataforma.

Além desses critérios, a análise da eficácia foi enriquecida com a investigação de fatores demográficos como idade e familiaridade com jogos digitais, conforme sugerido por Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)). A análise contínua desses dados, habilitada pelo *Learning Analytics* implementado, permitiu identificar padrões de dificuldade e engajamento, fornecendo *insights* valiosos para futuras melhorias iterativas da plataforma, alinhadas ao ciclo de ajuste contínuo da metodologia.

3.1.3.2 Metodologia Experimental e Cruzamento de Variáveis

A avaliação da efetividade da plataforma foi conduzida por meio de uma abordagem experimental baseada em dados, cujo objetivo é fundamentar as conclusões em evidências quantitativas e qualitativas obtidas a partir das interações dos usuários com o sistema, complementadas por formulários aplicados antes e após a utilização da plataforma. Essa abordagem seguiu os princípios do método científico, envolvendo a coleta sistemática de métricas, a aplicação de análises estatísticas rigorosas e a interpretação crítica dos resultados.

Para enriquecer a análise, foram realizados cruzamentos de variáveis com o propósito de identificar padrões, tendências e possíveis relações de causa e efeito entre fatores individuais, como idade, gênero e semestre do curso, e o desempenho obtido nas fases de Prática (AI) e Domínio (AF). Essa estratégia permitirá a construção de uma visão multidimensional, possibilitou avaliar não apenas a ocorrência de aprendizado, mas também quais perfis de usuários poderão se beneficiar mais da plataforma.

Com o objetivo de verificar diferenças significativas entre grupos de usuários, foram aplicados procedimentos estatísticos, incluindo:

- Teste de Levene, para avaliar a homogeneidade das variâncias entre os grupos;
- Teste t de Student para amostras independentes, para comparar as médias de pontuação entre os grupos masculino e feminino, tanto na AI quanto na AF;
- Teste não paramétrico de Kruskal-Wallis, para analisar diferenças significativas entre as pontuações médias de grupos organizados por faixas etárias e semes-

tres do curso.

Foi adotado um nível de significância de 5% ($p < 0,05$), de modo que apenas diferenças estatisticamente relevantes foram consideradas para as inferências.

Os cruzamentos de variáveis a serem realizados contemplam diferentes perspectivas de desempenho dos usuários, como a relação entre perfil de aprendizado e semestre do curso, perfil de aprendizado e idade, bem como perfil de aprendizado e gênero. Essas análises buscaram identificar possíveis tendências e padrões de engajamento, além de apoiar a compreensão sobre a influência de fatores demográficos e acadêmicos no aprendizado.

A adoção dessa abordagem quantitativa e analítica, aliada ao modelo de Learning Analytics, teve como objetivo fornecer uma estrutura sólida para a avaliação da plataforma, o que garantiu a replicabilidade do estudo e alinhando-se às recomendações de pesquisas educacionais baseadas em evidências.

4 Resultados

4.1 Implementação da Plataforma

Dando sequência, a plataforma foi projetada para facilitar o aprendizado de requisitos de software em 10 subtemas principais, extraídos e classificados a partir do livro de Pressman — Engenharia de Software: Uma Abordagem Profissional — 8ª Edição. A definição desses subtemas seguiu critérios técnicos de segmentação e relevância pedagógica, e foi validada com o orientador do projeto, que atuou como especialista da área para garantir a fidelidade conceitual e a adequação dos conteúdos extraídos. A Inteligência Artificial (IA) e a Engenharia de Prompt tiveram papel crucial nesse processo, estruturando os conteúdos e adaptando-os para uso em flashcards e quizzes interativos.

O público-alvo abrange estudantes e profissionais (de 12 a 50 anos) interessados em aperfeiçoar conhecimentos sobre requisitos. A IA também foi empregada na geração de conteúdos multimídia e visuais (vídeos explicativos, imagens temáticas para cada fase, insígnias de gamificação), tornando o processo mais imersivo e motivado pela estética lúdica.

4.1.1 Geração de Conteúdo Automatizada com Inteligência Artificial e Engenharia de Prompt

A criação dos conteúdos educacionais da plataforma, especificamente os flashcards, quizzes, vídeos explicativos e imagens temáticas, foi um processo metodológico que integrou o conhecimento do livro "**Engenharia de Software: Uma Abordagem Profissional - 8ª Edição**" de Roger Pressman ([PRESSMAN, 2019](#)) com o potencial da Inteligência Artificial (IA) e as técnicas de Engenharia de Prompt.

A Figura 2 detalha o fluxo de trabalho de como o conteúdo educacional estático é gerado na plataforma. O diagrama ilustra as etapas que transformam as informações do livro de Pressman, por meio de um modelo de IA GPT e da Engenharia de Prompt, em flashcards, quizzes, imagens e roteiros de vídeo, que são então submetidos à validação humana antes de se tornarem parte do conteúdo estático da plataforma.

4.1.1.1 Fluxo de Trabalho e Estruturação do Conteúdo

O processo iniciou-se com a alimentação do conteúdo integral do livro de Roger Pressman ([PRESSMAN, 2019](#)) em um modelo de IA baseado em GPT (*Generative*




Figura 2 – Processo de Geração de Conteúdo Estático na Plataforma Educacional
Fonte: Elaborado pelo Autor

Pre-trained Transformer). Para garantir que os conteúdos gerados fossem relevantes e alinhados aos objetivos educacionais, foi empregada a Engenharia de Prompt. Um *prompt* inicial foi cuidadosamente elaborado para instruir a IA a categorizar os principais tópicos relacionados à engenharia de requisitos de *software* presentes na obra. Essa categorização resultou na identificação de **10 subtemas centrais** que serviriam como base para a organização do aprendizado na plataforma.

Após a definição desses 10 subtemas, o processo se tornou iterativo para cada um deles:

- **Geração de Flashcards:** Para cada subtema, foram criados 10 *flashcards*. A Engenharia de Prompt foi utilizada para solicitar à IA a formulação de perguntas em um lado do *flashcard* e as respectivas respostas ou explicações no outro, seguindo uma estrutura predefinida para otimizar a memorização ativa e a recuperação do conhecimento.
- **Geração de Quizzes:** Similarmente, para cada subtema, foram geradas 10 questões de *quiz*. Os *prompts* foram elaborados para que a IA criasse perguntas em diversos formatos (múltipla escolha, verdadeiro ou falso, estudos de caso, entre outros), visando testar a compreensão e a aplicação dos conceitos de forma interativa e com *feedback* imediato.

4.1.1.2 Validação dos Materiais

Apesar da capacidade da IA em gerar conteúdo de forma autônoma, a validação humana foi uma etapa crítica para assegurar a qualidade, a precisão e a coerência pedagógica dos materiais. Todo o conteúdo gerado (*flashcards* e *quizzes*) foi submetido à revisão e validação conjunta pelo desenvolvedor da plataforma e pelo orientador do projeto. Esse processo garantiu que as informações estivessem corretas, completas e adequadamente alinhadas aos princípios da engenharia de requisitos conforme Pressman (PRESSMAN, 2019) e aos objetivos de aprendizado da plataforma.

4.1.1.3 Materiais Audiovisuais

Para enriquecer a experiência de aprendizado e atender às necessidades de diferentes estilos de aprendizagem, a IA também foi utilizada para a criação de materiais audiovisuais, como vídeos explicativos e imagens temáticas para cada fase do jogo e insígnias de gamificação.

- **Geração de Roteiros para Vídeos:** Tendo as perguntas e conceitos dos *flashcards* e *quizzes* como base, *prompts* específicos foram fornecidos à IA para a criação de roteiros de vídeos introdutórios para a "Fase de Estratégia" de cada subtema. Esses roteiros sintetizaram os pontos essenciais que seriam avaliados nas fases subsequentes, garantindo uma visão geral e clara do conteúdo.
- **Produção dos Vídeos:** Com os roteiros gerados, uma ferramenta externa focada em criação de vídeo foi empregada. Para manter um ambiente de aprendizado consistente e familiar, foi utilizado um background de sala de aula, e a ferramenta foi instruída a seguir e ler o roteiro, transformando o texto em vídeo com um apresentador virtual.
- **Geração de Imagens e Insígnias:** Além dos vídeos, a IA também foi utilizada para gerar imagens temáticas para cada fase do carrossel interativo da plataforma e para as insígnias de gamificação. Essas imagens visuais contribuem para a estética lúdica e imersiva do ambiente de aprendizado, aumentando o engajamento e a motivação dos usuários.

4.1.2 Jogabilidade e Gamificação

Com objetivos bem definidos, a jogabilidade prioriza um equilíbrio entre teoria e prática. As fases do jogo (estratégia, prática, domínio) ganham elementos de *flashcards*, *quizzes* e gamificação. A navegação se faz via um **carrossel interativo no frontend**, onde cada fase tem uma imagem gerada por IA, representando visualmente o subtema.

Para reforçar o aspecto lúdico, criaram-se **insígnias de gamificação**, também geradas por IA, que são exibidas no perfil do usuário:

- **Insígnia da Fase de Prática:** Obtida ao concluir essa etapa com pelo menos 50
- **Insígnia da Fase de Domínio:** Concedida ao atingir pelo menos 70

Tal sistema de recompensas amplia a motivação intrínseca, incentivando os usuários a se empenharem nas tentativas subsequentes. A similaridade com abordagens como Kahoot, que utiliza pontuações e “pódios” para motivar alunos, demonstra como a gamificação pode consolidar conteúdos de forma mais agradável e dinâmica. Com a estrutura gamificada implementada, a plataforma foi organizada em três fases principais, descritas a seguir.

4.1.3 Fases Presentes na Plataforma

Cada um dos 10 subtemas é dividido nas fases Estratégia, Prática e Domínio, proporcionando aprendizado progressivo. Conforme discutido:

4.1.3.1 Fase de Estratégia

Na fase de estratégia, os usuários assistem a um vídeo introdutório criado por IA com base em resumos dos tópicos abordados. Esses vídeos fornecem uma visão geral do subtema, abordando pontos essenciais que foram avaliados nas fases seguintes. A IA foi fundamental para a geração desses conteúdos multimodais, utilizando Engenharia de Prompt para extrair e sintetizar as informações-chave de cada subtema. Essa abordagem não apenas garantiu a qualidade e a clareza dos vídeos, mas também demonstrou o potencial da IA como uma ferramenta poderosa para a criação de conteúdos educacionais.

4.1.3.2 Fase de Prática

Nesta fase, os usuários interagem com 10 *flashcards* associados ao subtema. Durante o uso, são coletadas métricas como o número de tentativas para acertar cada resposta. Essa etapa é centrada no aprendizado contínuo e na prática ativa, com uma leve penalização para motivar maior atenção ao conteúdo. A pontuação varia conforme o número de tentativas:

- Acerto na primeira tentativa: 10 pontos.
- Acerto na segunda tentativa: 7 pontos.
- Acerto na terceira tentativa: 4 pontos.

- Acerto na quarta ou mais tentativas: 1 ponto.

Além da pontuação por tentativas, após revelar a resposta, o usuário classifica sua compreensão e o nível de esforço empregado para recordar a informação, escolhendo entre as seguintes opções de "qualidade":

- Esqueci (0): Indica que o conhecimento não foi retido.
- Errei (1): A resposta estava incorreta ou muito distante.
- Quase lá (2): A resposta estava parcialmente correta ou exigiu muito esforço.
- Com Esforço (3): A resposta foi correta, mas com alguma dificuldade.
- Fácil (4): A resposta foi correta e sem grande esforço.
- Perfeito (5): A resposta foi totalmente correta e com facilidade.

Caso o usuário erre (qualidade menor que 3) ou sua avaliação de qualidade indique necessidade de revisão, o *flashcard* é revisitado posteriormente, proporcionando uma nova oportunidade de aprendizado. A Inteligência Artificial desempenha um papel importante ao adaptar a ordem e a frequência dos *flashcards*, promovendo uma revisão direcionada às áreas de maior dificuldade. A "**Insígnia da Fase de Prática**" foi concedida ao usuário que atingiu uma pontuação total igual ou superior a 50 pontos nesta fase.

4.1.3.3 Fase de Domínio

A fase de domínio aumenta o nível de desafio, apresentando 10 questões de diferentes formatos (múltipla escolha, verdadeiro ou falso, estudos de caso, entre outros). Para ser conquistada a "**Insígnia da Fase de Domínio**", o usuário deve atingir pelo menos 70% de acertos, o que corresponde à média adotada pela maioria das universidades, incluindo a instituição de referência deste projeto, onde notas abaixo de 7 são consideradas insuficientes. Caso o usuário não atinja a pontuação para a insígnia, ele pode optar por revisar os *flashcards* e tentar novamente, sem que isso impeça o acesso a outros subtemas.

Essa estrutura progressiva garante que os usuários absorvam os conceitos de forma gradual, enquanto as métricas de desempenho fornecem uma visão clara do progresso e das áreas a serem reforçadas.

4.1.3.4 Pontuação para Insígnias:

- **Fase de Prática:** pontuação máxima de 100 pontos; a "**Insígnia da Fase de Prática**" é concedida com 50 pontos ou mais.

- **Fase de Domínio:** cada acerto vale 10 pontos; a "Insígnia da Fase de Domínio" é concedida ao atingir 70 pontos ou mais.
- **Tentativas:** não há limite rígido de tentativas para avançar entre as fases, permitindo que o usuário explore o conteúdo e retorne para consolidar o aprendizado conforme sua necessidade. As pontuações são para as insígnias de gamificação, que incentivam o desempenho.

4.1.4 Protótipo da Interface e Usabilidade

O desenvolvimento da plataforma educacional foi guiado por um **protótipo detalhado da interface**, que serviu como um mapa visual para a construção da ferramenta. Este protótipo foi criado para transformar os requisitos de ensino e as ideias de jogo em uma experiência de uso que fosse tanto **fácil de usar quanto envolvente**.

A interface da plataforma foi construída de forma **modular**, como blocos de construção que se encaixam. Essa abordagem facilitou o trabalho de desenvolvimento, pois permitiu que partes da interface fossem criadas uma vez e reutilizadas em diferentes lugares. Isso não só agilizou a construção, mas também garantiu que a plataforma tivesse uma aparência e um comportamento consistentes em todas as suas telas. Essa consistência torna o uso mais simples, pois o aluno aprende a interagir com um elemento e pode aplicar esse conhecimento em outros lugares da plataforma, reduzindo o tempo de adaptação e aumentando a fluidez da navegação. A **usabilidade** da plataforma foi uma preocupação central desde as etapas iniciais de *design*, buscando oferecer clareza na apresentação do conteúdo, *feedback* imediato às ações do usuário e consistência na navegação.

4.1.4.1 Home Page e Escolhas do Usuário

A tela inicial da plataforma é o ponto de entrada do usuário, projetada para ser convidativa e intuitiva. Ao entrar, o usuário é recebido por elementos visuais dinâmicos, como partículas flutuantes e animações suaves, que criam um ambiente acolhedor e estimulante desde o primeiro contato.

Um **carrossel visual** no centro da tela organiza os diferentes tópicos de estudo (subtemas), permitindo que o aluno escolha a fase de aprendizado desejada de forma clara e direta. Botões de navegação e pequenos indicadores de fase no carrossel oferecem controle fácil para explorar o conteúdo disponível. A interface também oferece opções claras para o usuário no primeiro acesso, como "**Começar Tour**" ou "**Pular**" um tutorial inicial, demonstrando a prioridade em dar controle ao aluno sobre sua experiência.




Figura 3 – Tela da Homepage – Visão Geral
Fonte: Elaborado pelo Autor

4.1.4.2 Flashcards: Prática Ativa e Feedback Detalhado

A seção de *flashcards* é dedicada à prática ativa do conteúdo teórico. Cada *flashcard* é apresentado de forma individual, com a pergunta na frente e a resposta oculta no verso.



Figura 4 – Tela de Flashcard – Frente (Pergunta)
Fonte: Elaborado pelo Autor

No canto superior esquerdo do *flashcard*, o aluno encontra a indicação da **difi-**

cuidade da pergunta (e.g., "Intermediário"), fornecendo um contexto imediato sobre o nível de complexidade do conteúdo. Adicionalmente, um **ícone de informação (i)** está presente, que, ao ser clicado, exibe um exemplo prático relacionado ao conceito abordado no *flashcard*, enriquecendo a compreensão do aluno através de contextualização real.

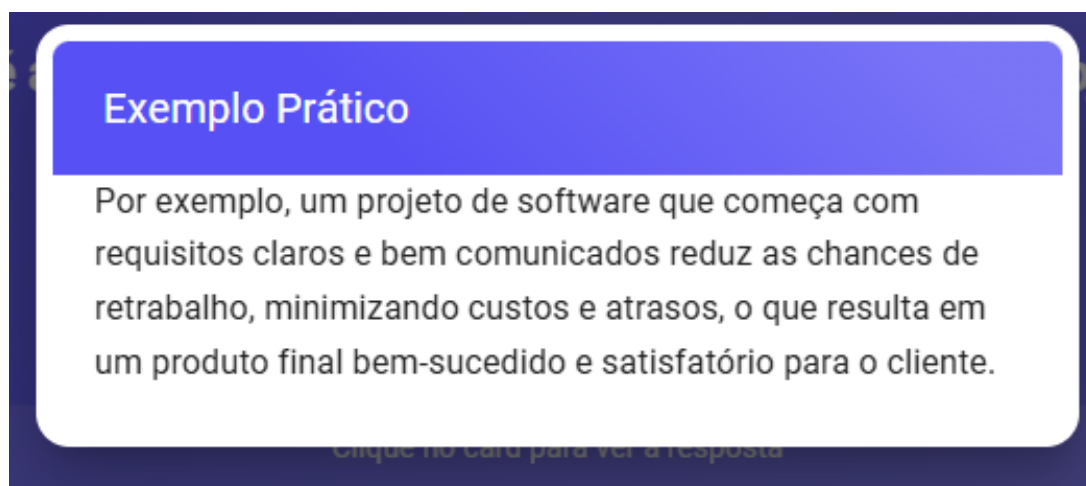


Figura 5 – Pop-up de Exemplo Prático no Flashcard

Fonte: Elaborado pelo Autor

Um clique no cartão revela a resposta, incentivando o aluno a tentar lembrar o conteúdo antes de verificá-lo. Após visualizar a resposta, um sistema de "**qualidade**" é acionado, permitindo que o aluno classifique sua própria compreensão com opções como "Esqueci", "Errei", "Quase lá", "Com Esforço", "Fácil" e "Perfeito!". Essa variedade de opções, combinada com **feedback visual instantâneo** (cores e mensagens no cartão), oferece um retorno mais preciso sobre o domínio do conceito. Isso não só ajuda o aluno a entender onde errou, mas também permite que o sistema adapte a repetição futura dos cartões, focando nas áreas de maior dificuldade. Botões claros de avançar e voltar facilitam a navegação entre os *flashcards*. Indicadores de tempo de estudo e pontuação exibem o desempenho em tempo real.

4.1.4.3 Quizzes: Validação do Conhecimento e Análise de Progresso

A seção de *quizzes* desafia o aluno a aplicar o conhecimento adquirido, validando a compreensão em diferentes formatos de perguntas.

As perguntas são apresentadas de forma direta, com opções de resposta claras e organizadas. Após o envio da resposta, o usuário recebe **feedback imediato** através de um *pop-up* que indica se a resposta está correta ou incorreta, além de fornecer uma explicação detalhada. O progresso no *quiz* é visualizado por uma série de pontos na parte inferior da tela, que também podem ser usados para pular entre as questões, dando mais flexibilidade ao aluno em seu ritmo de estudo. Contadores de




Figura 6 – Tela de Flashcard – Verso (Resposta com Opções de Qualidade)
Fonte: Elaborado pelo Autor



Figura 7 – Tela de Quiz – Questão Múltipla Escolha
Fonte: Elaborado pelo Autor

tempo e multiplicadores de pontuação ("*streak*") motivam o engajamento e a busca por um desempenho contínuo.

4.1.4.4 Perfil: Mural de Insígnias e Reconhecimento

A seção de perfil funciona como um painel de conquistas, onde o aluno pode ver seu progresso e ser recompensado com insígnias de jogo. Essa área foi pensada para




Figura 8 – Tela de Quiz – Feedback Pós-Resposta

Fonte: Elaborado pelo Autor

celebrar o aprendizado e manter o interesse do aluno com elementos visuais atraentes, incentivando-o a continuar estudando.




Figura 9 – Tela de Perfil – Mural de Insígnias

Fonte: Elaborado pelo Autor

No mural, existe uma **Insígnia Final especial**, que representa a conquista de **”Mestre Supremo dos Requisitos”**. Essa insígnia só é liberada quando o aluno consegue todas as insígnias de *flashcards* e *quizzes*. Ela serve como um grande objetivo, motivando o aluno a completar todas as etapas do conteúdo.

As insígnias são organizadas em grupos separados para *Flashcards* e *Quizzes*. Cada grupo mostra uma **barra de progresso** que indica quantos distintivos o aluno já

ganhou naquela categoria em relação ao total. As insígnias que o aluno já conquistou aparecem com cores vivas e um brilho especial, enquanto as que ainda não foram desbloqueadas ficam em tons de cinza e com um título como "Insígnia Bloqueada".




Figura 10 – Detalhe das Seções de Insígnias de Flashcards e Quizzes com Barra de Progresso

Fonte: Elaborado pelo Autor

Cada insígnia individual representa uma vitória específica no aprendizado, com nomes criativos como "Explorador de Conhecimento" ou "Guardião do Saber". Para as insígnias de *flashcards*, o aluno precisa alcançar 50 pontos ou mais na fase de prática para desbloqueá-las. Já para as insígnias de *quizzes*, é preciso acertar 70% ou mais das questões (equivalente a 70 pontos) na fase de domínio.

Esse sistema de recompensas visuais, com títulos que inspiram e informações claras sobre o que falta para conquistar cada distintivo, funciona como um forte estímulo para o aluno continuar explorando o conteúdo e aprimorando suas habilidades. O mural de insígnias não só comemora o esforço e o sucesso do aluno, mas também oferece um retorno divertido e visível de como ele está crescendo e aprendendo na plataforma.

4.2 Arquitetura da Plataforma e Implementação Técnica

Esta seção detalha a arquitetura técnica da plataforma educacional, descrevendo a visão geral dos seus componentes, o fluxo de dados entre eles e as ferra-

mentas tecnológicas utilizadas para seu desenvolvimento e para a coleta e análise de dados.

4.2.1 Visão Geral da Arquitetura e Fluxo de Dados

A arquitetura da plataforma foi concebida para proporcionar uma experiência de aprendizado fluida e responsiva, separando as responsabilidades entre o *frontend*, o *backend* e o banco de dados. Essa abordagem em camadas facilita a manutenção, a escalabilidade e a integração de novas funcionalidades. A Inteligência Artificial (IA) desempenhou um papel crucial na fase de geração estática inicial do conteúdo educacional (*flashcards*, *quizzes*, vídeos e imagens), conforme detalhado na Seção 3.2.1. No uso contínuo da plataforma, a IA não atua dinamicamente na personalização adaptativa em tempo real, mas o conteúdo pré-gerado e a metodologia de repetição espaçada (para *flashcards*) e avaliação por limiares (para *quizzes*) já incorporam princípios de aprendizado adaptativo.




Figura 11 – Visão Geral da Arquitetura da Plataforma Educacional, incluindo o Fluxo de Geração de Conteúdo

Fonte: Elaborado pelo Autor

A Figura 11 oferece uma visão abrangente da arquitetura da plataforma, mostrando como os módulos de geração de conteúdo interagem com os componentes de tempo de execução, como o *frontend*, *backend* e o banco de dados. Este diagrama ilustra a separação de responsabilidades e o fluxo de dados entre os principais elementos do sistema.

4.2.1.1 Interação Frontend-Backend e Processamento de Dados

O *Frontend*, desenvolvido em **React**, atua como a interface interativa do usuário. Ele é responsável por capturar e exibir os dados, bem como por gerenciar as interações dos usuários com os elementos de gamificação, *flashcards* e *quizzes*. A comunicação com o *Backend* é realizada via requisições assíncronas a uma **API RESTful**.

A Figura 12 detalha o fluxo de interação e processamento de dados dentro da plataforma. O diagrama mostra as etapas desde a interação do usuário com o *frontend*, a geração do *payload* de dados, a requisição RESTful para o *backend*, a validação




Figura 12 – Visão Geral do Fluxo de Interação da Arquitetura da Plataforma Educacional

Fonte: Elaborado pelo Autor

de *schema* e a persistência final no banco de dados MongoDB, proporcionando uma compreensão clara de como as informações são gerenciadas em tempo real.

O fluxo de interação e processamento de dados ocorre da seguinte forma:

4.2.1.1.1 Carregamento e Personalização Inicial (Frontend e Backend):

Ao acessar a plataforma, o *frontend* (React) realiza requisições ao *backend* (NestJS) para obter os dados principais de cada jogador, incluindo o progresso em cada subtema. O *backend*, por sua vez, consulta o MongoDB para recuperar o perfil

do usuário e as informações relevantes ao seu histórico de aprendizado. Esses dados são enviados de volta ao *frontend*, que os utiliza para popular dinamicamente o carrossel interativo, exibindo os 10 subtemas definidos a partir do livro de Pressman, com as respectivas imagens geradas por IA. Cada jogador, portanto, visualiza uma cópia personalizada de seu progresso e dos tópicos disponíveis.

4.2.1.1.2 Interação com Quizzes e Flashcards (Frontend e Backend):

Quando o usuário seleciona um *quiz* ou um conjunto de *flashcards*, o *frontend* realiza um pré-processamento local da interação. Isso envolve a captura de métricas detalhadas como o tempo gasto em cada atividade, o número de tentativas e as respostas fornecidas. Ao final da interação (ex: conclusão de um conjunto de *flashcards* ou envio das respostas de um *quiz*), o *frontend* constrói um *payload* de dados, encapsulando todas as métricas e o identificador do usuário e do conteúdo (*deckId* ou *quizId*). Esse *payload* é então enviado ao *backend* NestJS por meio de requisições RESTful (ex: POST `/api/deck-responses` para *flashcards* e POST `/api/quiz-responses` para *quizzes*). Essa comunicação é assíncrona e não interrompe a fluidez da jogabilidade.

4.2.1.1.3 Processamento e Avaliação no Backend (NestJS e MongoDB):

O *backend* (NestJS) recebe os objetos *UserDeckResponse* ou *UserQuizResponse*, realiza eventuais validações de *schema* e persiste as informações em coleções dedicadas no MongoDB (e.g., *user_deck_responses* e *user_quiz_responses*). A escolha do MongoDB se dá pela sua escalabilidade e capacidade de armazenar grandes volumes de dados com facilidade, permitindo uma recuperação rápida de informações para análise futura. Com base nas respostas do usuário e nas regras de negócio predefinidas, o *backend* calcula a pontuação do jogador para *flashcards* e *quizzes*. Para os *flashcards*, o cálculo da pontuação da sessão é feito considerando os pontos decrescentes por tentativa (10 para a primeira, 7 para a segunda, 4 para a terceira e 1 a partir da quarta tentativa de acerto). Adicionalmente, o *feedback* de qualidade fornecido pelo usuário para cada *flashcard* é registrado para análises futuras, permitindo uma compreensão mais aprofundada da percepção de domínio do aluno sobre o conteúdo. Essa combinação de métricas fornece uma visão detalhada do desempenho. Para os *quizzes*, a pontuação é calculada com base no percentual de acertos. Para otimizar consultas, são criados índices em campos usados com frequência nas análises, como *userId*, *deckId/quizId* e *date*.

4.2.1.1.4 Concessão de Insígnias e Gamificação:

Após o processamento da pontuação, as insígnias de gamificação, geradas por IA, são concedidas e registradas no perfil do usuário com base em critérios de pontu-

ação específicos:

- A **"Insígnia da Fase de Prática"** é concedida se o usuário atingir 50 pontos ou mais na Fase de Prática.
- A **"Insígnia da Fase de Domínio"** é concedida se o usuário atingir 70% de acertos (70 pontos) ou mais na Fase de Domínio.

Esse sistema de recompensas é projetado para ampliar a motivação intrínseca e o engajamento dos usuários, similar a abordagens como o Kahoot, que utiliza pontuações e "pódios" para motivar alunos. A liberação para a próxima fase é sempre automática, independentemente da pontuação alcançada, permitindo a autonomia do estudante no seu percurso de aprendizado.

4.2.2 Ferramentas de Desenvolvimento da Plataforma

As principais ferramentas tecnológicas empregadas no desenvolvimento da plataforma foram selecionadas por sua robustez, flexibilidade e adequação para a construção de aplicações web modernas.

4.2.2.1 React

Para o desenvolvimento da parte visual da plataforma, foi utilizado o **React**, um *framework* popular para a construção de interfaces de usuário interativas e dinâmicas. React permite a criação de componentes reutilizáveis, facilitando o desenvolvimento e a manutenção da aplicação. Com seu conceito de renderização baseada em estado, a plataforma consegue atualizar e exibir dados dinamicamente à medida que o usuário interage com *quizzes* e *flashcards*. O uso do React permite a integração com várias bibliotecas e ferramentas de terceiros, o que torna a plataforma extensível e escalável. Com ele, o foco está em oferecer uma interface de usuário fluida e responsiva, onde os usuários podem interagir com os *flashcards*, *quizzes* e verificar seu progresso de forma intuitiva.

4.2.2.2 NestJS

O *backend* da plataforma foi desenvolvido utilizando o **NestJS**, um *framework* eficiente e flexível baseado em Node.js. O NestJS facilita a criação de APIs escaláveis, com uma arquitetura modular que se adapta muito bem às necessidades da aplicação. Ele permite a criação de uma API RESTful robusta, que gerencia as requisições dos usuários, os dados de *quizzes* e *flashcards*, e integra-se ao banco de dados MongoDB para armazenar as informações de progresso e pontuação dos usuários. O NestJS tam-

bém suporta a implementação de autenticação e controle de permissões, garantindo que os dados dos usuários sejam armazenados e acessados de maneira segura.

4.2.2.3 MongoDB

Para o armazenamento de dados, foi escolhido o **MongoDB**, um banco de dados NoSQL que oferece flexibilidade no armazenamento de dados estruturados e semiestruturados. MongoDB é ideal para armazenar informações como: progresso dos usuários em cada subtema; resultados de *quizzes* e tentativas de *flashcards*; e perfis de usuários e dados relacionados ao comportamento de aprendizado. A escolha do MongoDB se dá pela sua escalabilidade e capacidade de armazenar grandes volumes de dados com facilidade, permitindo uma recuperação rápida de informações para análise futura.

4.2.3 Ferramentas de Coleta e Análise

Para assegurar o aprimoramento contínuo do aprendizado e avaliar a eficácia da metodologia educacional, a plataforma emprega um processo estruturado de *Learning Analytics*, que abrange a coleta, o armazenamento e a análise de dados. Este processo monitora as interações dos usuários com os *flashcards* e *quizzes*, permitindo a extração de métricas de desempenho, engajamento e a identificação de dificuldades específicas.

4.2.3.1 Coleta de Dados no Frontend (React)

A coleta de dados é iniciada no *frontend* (React), onde cada interação significativa do usuário, como a conclusão de um conjunto de *flashcards* ou a finalização de um *quiz*, dispara eventos específicos. Ao término dessas atividades, o sistema gera um objeto de dados padronizado, que pode ser *UserDeckResponse* para *flashcards* ou *UserQuizResponse* para *quizzes*.

Cada um desses objetos encapsula informações cruciais para a análise do aprendizado, incluindo:

- O identificador único do usuário (*userId*) e do conteúdo (*deckId* para *flashcards* ou *quizId* para *quizzes*).
- Os IDs dos cartões ou perguntas que foram selecionadas.
- Métricas detalhadas por item, como o número de tentativas, o status de acerto/erro e o tempo gasto em cada *card* ou *question*.
- A pontuação final (*score*) obtida na atividade e a data/hora do envio (*date*).

Esses dados são, então, transmitidos ao *backend* (NestJS) por meio de requisições RESTful assíncronas (e.g., `POST /api/deck-responses` ou `POST /api/quiz-responses`). Esta comunicação é projetada para ocorrer de forma fluida, sem interromper a experiência de jogabilidade do usuário.

4.2.3.2 Armazenamento e Indexação no MongoDB

Ao receber os objetos *UserDeckResponse* ou *UserQuizResponse*, o *backend* (NestJS) realiza validações de *schema* e persiste as informações em coleções dedicadas no MongoDB. Especificamente, as tentativas de *flashcards* são armazenadas na coleção *user_deck_responses*, enquanto as tentativas de *quizzes* são registradas em *user_quiz_responses*.

A estrutura de cada documento armazenado replica a definição dos objetos *UserDeckResponse* e *UserQuizResponse*, incluindo *arrays* para métricas mais granulares (*cardMetrics* ou *questionMetrics*). Para otimizar o desempenho das consultas e análises futuras, índices são criados em campos frequentemente utilizados, como *userId*, *deckId/quizId* e *date*. Esta estratégia de indexação garante a eficiência na recuperação do histórico de atividades de um usuário em um *deck* ou *quiz* específico.

4.3 Escopo e Limitações de Análise

É fundamental destacar que as análises apresentadas neste capítulo se referem exclusivamente à Fase 1 – Natureza de Requisitos de Software. Esta fase foi escolhida como estudo de caso para avaliar a efetividade inicial da plataforma. As demais fases da aplicação não foram exploradas neste trabalho, sendo recomendada sua investigação em pesquisas futuras.

Ademais, este experimento foi conduzido em um cenário não controlado, caracterizado pela ausência de randomização dos participantes e de um grupo de controle para comparação (CRESWELL, 2014; SHADISH; COOK; CAMPBELL, 2002). Embora os dados coletados reflitam o uso da plataforma em um ambiente real, essa característica metodológica impede o estabelecimento de relações de causa e efeito diretas e definitivas entre o uso da plataforma e o ganho de aprendizado. Outros fatores não medidos ou não isolados (variáveis de confusão) podem ter influenciado os resultados, comprometendo a validade interna do estudo (CAMPBELL; STANLEY, 1963; PALLANT, 2013). Os achados, portanto, devem ser interpretados como indicativos de efetividade e percepção positiva, em vez de prova de causalidade.

As seções posteriores concentram-se em três objetivos principais:

- Verificar a efetividade da plataforma com base na metodologia de Serrano-Laguna

et al. ([SERRANO-LAGUNA et al., 2017](#));

- Identificar as maiores dificuldades enfrentadas pelos participantes durante o uso;
- Analisar se variáveis como idade e sexo apresentam correlação com as pontuações das fases de Prática (AI) e Domínio (AF).

Para complementar a avaliação de efetividade e desempenho, a análise também explorou variáveis demográficas e contextuais, como sexo, idade e semestre do curso dos participantes. A inclusão dessas variáveis visa investigar potenciais correlações com o processo de aprendizado e o engajamento na plataforma, considerando que fatores individuais podem influenciar a forma como os estudantes interagem com ferramentas educacionais e assimilam novos conhecimentos.

O experimento envolveu um total de 20 estudantes de áreas de tecnologia, com idades entre 18 e 29 anos, sendo 5 mulheres e 15 homens. Esta amostra, embora limitada, foi selecionada para um estudo piloto exploratório, visando a coleta de dados iniciais sobre a usabilidade e a efetividade percebida da plataforma em um ambiente real de uso, dadas as restrições de tempo e recursos do presente trabalho. Todos os participantes utilizaram a plataforma FlashQuiz, e os dados obtidos de suas interações foram enviados automaticamente para o servidor. A duração média de uma sessão de jogo foi de aproximadamente 10 minutos. Eventos da fase de Estratégia (introdução via vídeo) por padrão não foram coletados para análise formal de aprendizado, enquanto as interações das fases de Prática (*flashcards*) e Domínio (*quizzes*) foram registradas para análises posteriores.

4.4 Efetividade da Plataforma FlashQuiz

Aplicando a metodologia de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)), foi atribuída uma pontuação aos usuários nas fases de prática e domínio, calculada com base na quantidade de tentativas e acertos necessários para completar cada fase. Essa pontuação permitiu categorizar o tipo de aprendizado de cada usuário. Após análise dos dados de resposta por fase dos usuários, a maior quantidade de usuários por categoria de aprendizado foi os de “Alunos” totalizando 10 usuários (50%), seguido da categoria de “Mestres” com 9 usuários (45%). Tendo somente uma única (5%) incidência de “Não-alunos”. Nenhum jogador foi incluído na categoria de “Deslocados”. Esses dados podem ser visualizados através do gráfico presente na Figura 13.

A investigação sobre a influência do sexo no processo de aprendizado na plataforma FlashQuiz é relevante, considerando que a literatura em psicologia cognitiva documenta diferenças sutis e específicas entre homens e mulheres em determinados




Figura 13 – Distribuição de jogadores por classificação de aprendizado

Fonte: Elaborado pelo autor

tipos de memória. Herlitz e Rehnman ([HERLITZ; REHNMAN, 2008](#)) apontam que mulheres tendem a apresentar desempenho superior em tarefas de memória verbal, episódica e autobiográfica, frequentemente lembrando informações com maior nível de detalhe. Por outro lado, Voyer, Voyer e Saint-Aubin ([VOYER; VOYER; SAINT-AUBIN, 2017](#)) indicam que homens demonstram vantagem moderada em tarefas que exigem memória visual-espacial e rotação mental, com diferenças de efeito que variam de pequenas a moderadas, dependendo da tarefa avaliada.

Essas diferenças, entretanto, não são universais ou determinísticas. Pesquisas apontam que fatores sociais e culturais desempenham papel importante na modulação dessas habilidades, sugerindo que a educação, a experiência prévia e o ambiente podem influenciar significativamente esses resultados. Além disso, em sociedades com maior igualdade de gênero, a literatura reporta que tais disparidades cognitivas tendem a ser menores ou até desaparecer, reforçando a importância do contexto social ([HERLITZ; REHNMAN, 2008](#)).

De acordo com a análise dos dados, apresentada no gráfico da Figura 14, verificou-se que 8 participantes do sexo masculino e 2 do sexo feminino foram classificados como “Mestres” (perfil de alto domínio). A categoria “Alunos” incluiu 6 homens e 3 mulheres, enquanto apenas 1 participante do sexo masculino foi classificado como “Não-Aluno”; não houve ocorrência dessa categoria entre jogadoras. Considerando os 15 participantes do sexo masculino, 8 (53,3%) foram classificados como “Mestres”; 6 (40%), como “Alunos”; e 1 (6,7%), como “Não-Aluno”. Entre os 5 participantes do sexo feminino, 2 (40%) foram classificadas como “Mestres” e 3 (60%), como “Alunas”.

A análise da distribuição de usuários por faixa etária e semestre do curso é de particular interesse, pois a experiência acadêmica e a familiaridade com tecnologias digitais podem influenciar significativamente o processo de aprendizado. Estudantes em diferentes estágios de sua formação podem apresentar níveis de conhecimento




Figura 14 – Distribuição de perfil de jogadores por gênero

Fonte: Elaborado pelo autor

prévio e abordagens de estudo distintas. Além disso, a idade pode estar correlacionada com a fluência digital, especialmente em relação a novas ferramentas interativas.

A Figura 15 agrupa as categorias de jogadores por idade. Nela, observa-se que o maior percentual de usuários classificados como “Mestres” (indivíduos que demonstraram domínio do conteúdo na plataforma) foi encontrado nas idades entre 23 a 26 anos. Por outro lado, as idades com maiores incidências de “Alunos” (aqueles que tiveram um ganho significativo de aprendizado com o uso da plataforma) concentraram-se na idade de 24 anos. A única incidência de um usuário classificado como “Não-Aluno” foi identificada na idade de 28 anos. Embora a amostra reduzida limite a generalização dessas observações, esses dados fornecem insights sobre o perfil demográfico dos usuários e sua relação com os resultados de aprendizado na plataforma.




Figura 15 – Distribuição de jogadores por idade

Fonte: Elaborado pelo autor

A distribuição dos perfis de aprendizado foi também analisada em relação ao semestre do curso dos participantes, com o valor 0 representando indivíduos já formados. Dos 20 usuários na amostra, 10 foram categorizados como “Mestres”, 9 como “Alunos” e 1 como “Não-Aluno”.

A maior concentração de usuários foi observada no 2º semestre, com 7 participantes, sendo 1 “Mestre” e 6 “Alunos”. Este engajamento inicial na trajetória acadêmica é relevante para a compreensão do impacto da plataforma em fases introdutórias. A composição dos perfis nos demais semestres e no grupo de Formados é detalhada a seguir:

- 1º Semestre: 1 usuário, categorizado como “Não-Aluno”.
- 2º Semestre: 7 usuários, sendo 1 “Mestre” e 6 “Alunos”.
- 5º Semestre: 2 usuários, sendo 1 “Mestre” e 1 “Aluno”.
- 6º Semestre: 3 usuários, sendo 2 “Mestres” e 1 “Aluno”.
- 7º Semestre: 2 usuários, ambos “Mestres”.
- 8º Semestre: 2 usuários, sendo 1 “Mestre” e 1 “Aluno”.
- Formados (Semestre 0): 3 usuários, todos categorizados como “Mestres”.

Essa distribuição detalhada no gráfico da Figura 16 permite inferir que a plataforma atrai e beneficia estudantes em diversas fases. A alta proporção de “Alunos” nos semestres iniciais, como o 2º, sugere que a ferramenta é eficaz em promover o aprendizado para aqueles que estão construindo seu conhecimento fundamental. Por outro lado, a predominância de “Mestres” em semestres mais avançados e entre os formados indica que a plataforma também serve como um recurso valioso para aprimoramento e revisão de conhecimentos já existentes. A incidência do único “Não-Aluno” no 1º semestre aponta para a necessidade de investigar fatores específicos que possam ter impedido o aprendizado para este indivíduo.

4.5 Percentual de Acertos e Erros por Fase e Análise de Dificuldades

Esta seção detalha o desempenho dos usuários na plataforma Flash Quiz, analisando os dados de acertos, erros e tentativas em flashcards e quizzes. O objetivo é investigar a influência do nível de dificuldade e do tipo de questão no aprendizado dos conceitos de Engenharia de Software.




Figura 16 – Distribuição de jogadores por semestre e perfil de aprendizagem
Fonte: Elaborado pelo autor

4.5.1 Desempenho nos Flashcards: Média de Tentativas

A análise dos flashcards revelou os tópicos que demandam maior esforço de recuperação de conhecimento por parte dos usuários na fase de Prática. A média de tentativas por flashcard é um indicativo direto das áreas onde os estudantes tiveram mais dificuldade para assimilar ou recordar as informações. Os dados coletados mostram que certas questões exigiram consideravelmente mais tentativas para serem respondidas corretamente, destacando pontos críticos no aprendizado.




Figura 17 – Top 10 Flashcards com Maior Média de Tentativas
Fonte: Elaborado pelo autor

A média de tentativas nos flashcards também variou de acordo com o nível de dificuldade a eles atribuído na concepção do conteúdo, demonstrando que a classificação de dificuldade se alinha com o desafio percebido pelos usuários. Flashcards

classificados como “Difícil” exigiram uma média de 2.80 tentativas, enquanto os “Intermediários” tiveram 1.72 tentativas e os “Fáceis”, 1.40 tentativas. Estes dados confirmam que a gradação da dificuldade no conteúdo dos flashcards é percebida e impacta diretamente o processo de aprendizagem dos usuários.




Figura 18 – Média de Tentativas por Nível de Dificuldade (Flashcards)
Fonte: Elaborado pelo autor

4.5.2 Desempenho nos Quizzes: Questões com Mais Erros

Avaliando a fase de Domínio (quizzes), foi possível identificar as questões que resultaram no maior número de erros, indicando lacunas na aplicação e validação do conhecimento adquirido. Os quizzes com mais erros frequentemente correspondem a conceitos que geraram alta média de tentativas nos flashcards, sugerindo uma persistência da dificuldade na transição da recuperação para a aplicação do conhecimento.




Figura 19 – Top 10 Questões de Quiz com Mais Erros
Fonte: Elaborado pelo autor

A distribuição da média de erros nos quizzes por nível de dificuldade reforça a percepção de desafio progressivo. Questões classificadas como “Difícil” apresentaram 25.7% de erros, as “Intermediárias” 15.0%, e as “Fáceis” 5.0%. Essa correlação demonstra a validade da categorização de dificuldade na plataforma.




Figura 20 – Média de Erros por Nível de Dificuldade (Quizzes)

Fonte: Elaborado pelo autor

Em relação ao tempo médio de resposta nos quizzes, observou-se que as questões “Fáceis” tiveram um tempo médio de 18.55 segundos, enquanto as “Intermediárias” tiveram 22.03 segundos e as “Difíceis” 33.62 segundos. Isso indica que os usuários tendem a levar mais tempo para responder a questões de maior dificuldade, o que é esperado e sugere um engajamento cognitivo proporcional ao desafio.




Figura 21 – Tempo Médio por Nível de Dificuldade (Quizzes)

Fonte: Elaborado pelo autor

A análise do desempenho também considerou a média de erros e o tempo médio por tipo de questão nos quizzes. As questões de “Múltipla Resposta” e “Situação Hipotética” apresentaram as maiores taxas de erro, com 37.5% e 25.0% respectivamente, sugerindo que esses formatos podem ser mais desafiadores, possivelmente por exigirem uma compreensão mais complexa ou a aplicação de múltiplos conceitos. Já as questões de “Múltipla Escolha” e “Verdadeiro/Falso” tiveram as menores taxas de erro. Em termos de tempo, as questões de “Múltipla Escolha” e “Situação Hipotética” demandaram mais tempo de resposta.




Figura 22 – Média de Erros por Tipo de Questão (Quizzes)

Fonte: Elaborado pelo autor

4.5.3 Percepção de Aprendizagem e Feedback da Plataforma

O objetivo aqui é analisar a percepção dos usuários sobre seu aprendizado e experiência com a plataforma FlashQuiz, integrando dados de autoavaliação de conhecimento (pré e pós-uso).

Para começar, a análise do conhecimento autoavaliado pelos usuários indicou um **aumento significativo** após a interação com a plataforma. A pontuação média de conhecimento na fase “Pré” foi de 3.2, elevando-se notavelmente para 4.78 na fase “Pós”. Este resultado gerou um “**Ganho Médio**” de aprendizado percebido de 1.58. Em termos percentuais, o “Ganho Médio” em porcentagem atingiu **74.21%**, demonstrando uma percepção substancial de melhoria no conhecimento dos usuários. A mediana do




Figura 23 – Tempo Médio por Tipo de Questão (Quizzes)

Fonte: Elaborado pelo autor

ganho foi de 1.4, com um desvio padrão de 1.09, indicando variabilidade nos ganhos individuais, mas com predominância de percepções positivas de aprendizado.

Podemos visualizar essa evolução no gráfico a seguir, que compara a média de conhecimento percebido antes e depois da utilização da plataforma:




Figura 24 – Média de Conhecimento: Pré vs Pós.

Fonte: Elaborado pelo autor

Em seguida, para entender a distribuição do ganho de aprendizado percebido entre os usuários, foi construído um histograma que agrupa os valores de ganho em intervalos. A análise dos dados indica que a **maior parte dos usuários obteve ganhos entre 0,33 e 1,80 pontos**, com 6 usuários em cada um desses intervalos. Isso demonstra que há uma forte concentração de ganhos próximos a 1 a 2 pontos, reforçando um aumento consistente no conhecimento percebido. Além disso, apenas 2 usuários tiveram ganhos muito baixos (entre -0,40 e 0,33), enquanto 5 usuários apresentaram ganhos superiores a 2,5 pontos, indicando que alguns participantes, provavelmente com conhecimento inicial reduzido, tiveram um salto mais expressivo.

O histograma (Figura 25) ilustra visualmente essa distribuição, destacando a **predominância de melhorias moderadas, mas consistentes**, entre os participantes.




Figura 25 – Distribuição do Ganho de Aprendizado.

Fonte: Elaborado pelo autor

Além da percepção de ganho de conhecimento, as **avaliações de feedback dos usuários sobre os diversos aspectos da plataforma foram consistentemente elevadas**, sugerindo uma experiência geral altamente positiva. Por exemplo, a facilidade de uso dos Flashcards, a clareza e o design dos Quizzes, e a avaliação das fases de Prática e Domínio obtiveram uma **média de 4.86**. A facilidade de navegação registrou uma média de **4.41**, a clareza das instruções **4.64**, e a qualidade dos vídeos **4.68**. Tais resultados corroboram a percepção positiva de ganho de conhecimento e indicam uma experiência de usuário satisfatória.

O gráfico a seguir detalha essas médias de feedback, mostrando quais aspectos da plataforma foram mais bem avaliados pelos usuários:

Em síntese, a análise da “Percepção de Aprendizagem” demonstra que os usuários do FlashQuiz não apenas **perceberam um aumento em seu conhecimento** so-




Figura 26 – Média das Notas de Feedback.

Fonte: Elaborado pelo autor

bre requisitos de software, mas também **avaliaram a plataforma de forma altamente positiva** em termos de usabilidade e design.

4.6 Testes de Hipóteses

Testes de hipóteses fornecem uma forma de verificar, a partir de uma amostra, se determinadas afirmações ou suposições sobre uma população são estatisticamente prováveis. Ao realizar um teste de hipóteses, assume-se inicialmente que a **hipótese nula (H0)** é verdadeira. Se houver evidência estatística suficiente contra essa hipótese, H0 é rejeitada e a **hipótese alternativa (H1)** é aceita.

No contexto deste estudo, os testes de hipóteses foram aplicados para investigar se variáveis demográficas como gênero e idade estão relacionadas às pontuações obtidas nas fases Prática (*AI_score*) e Domínio (*AF_score*) da plataforma FlashQuiz. A análise dessas variáveis é de interesse para compreender potenciais influências individuais no processo de aprendizado e no desempenho com ferramentas educacionais, embora o **tamanho reduzido da amostra limite a generalização** dos achados para populações maiores. As análises foram realizadas utilizando ferramentas estatísticas em Python.

Com base nos objetivos da pesquisa, as seguintes hipóteses foram definidas:

Para o Gênero:

- **H0:** Não há diferença significativa entre as médias de pontuação de homens e mulheres nas fases prática e domínio.
- **H1:** As médias de pontuação diferem significativamente entre homens e mulheres nas fases prática e domínio.

Para a Idade:

- **H0:** Não há diferença significativa entre as médias de pontuação dos diferentes grupos de idade nas fases prática e domínio.
- **H1:** As médias de pontuação diferem significativamente entre os grupos de idade nas fases prática e domínio.

O **teste t de Student para amostras independentes** foi aplicado para comparar as médias de pontuação entre os gêneros, precedido pelo **teste de Levene**, utilizado para verificar a igualdade de variâncias entre os grupos. O nível de significância adotado para todas as análises foi de **0,05 ($p < 0,05$)**. Para as comparações envolvendo faixas etárias, optou-se pelo **teste não-paramétrico de Kruskal-Wallis**. Esta escolha foi justificada, pois o teste de Kruskal-Wallis não depende da premissa de normalidade das distribuições e é apropriado quando se deseja comparar mais de dois grupos independentes e as premissas de testes paramétricos (como a igualdade de variâncias) não são atendidas.

4.6.1 Resultados da Fase de Prática (AI_score)

As Figuras 27 e 28 apresentam as estatísticas descritivas das pontuações da fase de prática por gênero. Observa-se que o grupo masculino obteve uma pontuação média de 72,67 pontos ($\pm 16,66$), enquanto o grupo feminino obteve 65,4 pontos ($\pm 7,4$). O teste de Levene para homogeneidade de variâncias apresentou $p = 0,074$ ($p > 0,05$), indicando que as variâncias podem ser consideradas iguais. O teste t de Student subsequente resultou em $p = 0,364$ ($p > 0,05$), não havendo evidências estatísticas suficientes para rejeitar H0. Portanto, não foram encontradas diferenças estatisticamente significativas entre homens e mulheres na fase de prática.

Estatísticas de grupo por gênero				
	sexo	N	Média	Desvio Padrão
fase prática	MASCULINO	15	65,4	$\pm 7,4$
	FEMININO	5	72,67	$\pm 16,66$

Figura 27 – Estatísticas de grupo por gênero (Fase de prática)

Fonte: Elaborado pelo autor

Teste	Estatística	p-valor	Decisão
Levene	3.601	0.074	Variâncias iguais ($p > 0,05$)
t-test	0.932	0.364	Não rejeitamos H0

Figura 28 – Resultados dos testes de Levene e T de Student (Fase de prática)

Fonte: Elaborado pelo Autor

Com relação aos grupos etários, As Figuras 29 e 30 apresentam as estatísticas descritivas das pontuações da fase de prática por idade. As médias foram de 60,0 pontos ($\pm 1,73$) para o grupo de 18-21 anos, 74,33 pontos ($\pm 16,18$) para 21-25 anos e 69,0 pontos ($\pm 15,02$) para 25-29 anos. O teste de Kruskal-Wallis apresentou $p = 0,237$ ($p > 0,05$), indicando que não há diferenças estatisticamente significativas entre as faixas etárias na fase de prática.

Estatísticas de grupo por idade				
	Idade	N	Média	Desvio Padrão
fase prática	18–21 anos	3	60	$\pm 1,74$
	21–25 anos	12	74,33	$\pm 16,18$
	25–29 anos	5	69	$\pm 15,02$

Figura 29 – Estatísticas de grupo por idade (Fase de prática)

Fonte: Elaborado pelo Autor

Teste	Estatística	p-valor	Decisão
Kruskal-Wallis	2.882	0.237	Não rejeitamos H0

Figura 30 – Resultados do teste de Kruskal-Wallis (Fase de prática)

Fonte: Elaborado pelo Autor

4.6.2 Resultados da Fase de Domínio (AF_score)

As Figuras 31 e 32 apresentam as estatísticas descritivas das pontuações da fase de domínio por gênero e os resultados dos testes por gênero. O grupo feminino obteve uma pontuação média de 80,0 pontos ($\pm 12,25$), enquanto o grupo masculino obteve 78,0 pontos ($\pm 11,46$). O teste de Levene apresentou $p = 0,868$ ($p > 0,05$), confirmando a igualdade de variâncias. O teste t de Student resultou em $p = 0,743$ ($p > 0,05$), indicando que não há diferenças estatisticamente significativas entre homens e mulheres na fase de domínio.

Estatísticas de grupo por gênero				
	sexo	N	Média	Desvio Padrão
fase domínio	MASCULINO	15	80	$\pm 12,25$
	FEMININO	5	78	$\pm 11,46$

Figura 31 – Estatísticas de grupo por gênero (Fase de domínio)

Fonte: Elaborado pelo Autor

Para a variável idade, as Figuras 33 e 34 mostram as estatísticas descritivas das pontuações na fase de domínio e os resultados do teste de Kruskal-Wallis. As médias

Teste	Estatística	p-valor	Decisão
Levene	0.028	0.868	Variâncias iguais ($p > 0,05$)
t-test	-0.333	0.743	Não rejeitamos H_0

Figura 32 – Resultados dos testes de Levene e T de Student (Fase de domínio)

Fonte: Elaborado pelo Autor

foram de 76,67 pontos ($\pm 11,55$) para o grupo de 18-21 anos, 80,83 pontos ($\pm 9,96$) para 21-25 anos e 74,0 pontos ($\pm 15,17$) para 25-29 anos. O teste de Kruskal-Wallis apresentou $p = 0,674$ ($p > 0,05$), não apontando diferenças estatísticas significativas entre os grupos etários na fase de domínio.

Estatísticas de grupo por idade				
	Idade	N	Média	Desvio Padrão
fase domínio	18–21 anos	3	76,67	$\pm 11,55$
	21–25 anos	12	80,83	$\pm 9,96$
	25–29 anos	5	74	$\pm 15,17$

Figura 33 – Estatísticas de grupo por idade (Fase de domínio)

Fonte: Elaborado pelo Autor

Teste	Estatística	p-valor	Decisão
Kruskal-Wallis	0.788	0.674	Não rejeitamos H_0

Figura 34 – Resultados do teste de Kruskal-Wallis (Fase de domínio)

Fonte: Elaborado pelo Autor

Em síntese, com base nos resultados dos testes de hipóteses, pode-se concluir que, para ambas as fases (Prática e Domínio), não foram observadas diferenças estatisticamente significativas nas pontuações em função do gênero ou da idade dos participantes nesta amostra.

4.7 Discussão dos Resultados

Conforme estabelecido, este projeto teve como objetivo principal desenvolver e avaliar a efetividade da plataforma FlashQuiz, baseada em Inteligência Artificial, para o ensino de requisitos de software, adotando a metodologia de Serrano-Laguna et al. (SERRANO-LAGUNA et al., 2017) como referência para a validação dos resultados. Essa metodologia permite classificar os participantes em categorias de aprendizado, de forma a identificar as mudanças no nível de conhecimento após a realização do jogo. Assim, os “Mestres” são aqueles que alcançam pontuação igual ou superior ao limiar estabelecido tanto na fase de prática quanto na de domínio; os “Alunos” são aqueles que, apesar de não atingirem o limiar na fase de prática, obtêm um desempenho igual

ou superior na fase de domínio; os “Não-Alunos” são aqueles que não conseguem atingir as pontuações mínimas em ambas as fases; e os “Deslocados” correspondem aos que obtêm bom desempenho na fase de prática, mas não atingem o limiar na fase de domínio.

Os dados obtidos mostraram que, nesta amostra de 20 participantes, a maior parte dos jogadores foi classificada como “Alunos” (50%), evidenciando que a plataforma foi **eficaz para aqueles que não possuíam domínio prévio do conteúdo**. Por outro lado, 45% foram classificados como “Mestres”, revelando que uma parcela significativa da amostra já apresentava conhecimento consolidado sobre os conceitos abordados, utilizando a plataforma como um meio de reforço ou revisão. Apenas um participante (5%) foi classificado como “Não-Aluno”, o que sugere dificuldades pontuais ou falta de engajamento, mas que não comprometem a eficácia geral do sistema. Ao se somar “Mestres” e “Alunos”, observa-se que **cerca de 95% dos participantes superaram o limiar estabelecido na fase de domínio**, demonstrando um desempenho satisfatório e atingindo os objetivos de aprendizagem propostos pela plataforma.

O sistema de **feedback imediato**, presente tanto nos flashcards quanto nos quizzes, mostrou-se um elemento central para o desenvolvimento da autonomia no processo de aprendizado. A possibilidade de verificar erros e acertos em tempo real permitiu que os usuários identificassem rapidamente suas dificuldades e revisassem conteúdos específicos, favorecendo a retenção de informações e a autoavaliação. A análise das interações nos flashcards mostrou que os conteúdos classificados como “Difíceis” exigiram uma média de 2,8 tentativas, enquanto os conteúdos “Intermediários” e “Fáceis” apresentaram médias de 1,72 e 1,40 tentativas, respectivamente. Essa diferença confirma a coerência da classificação de dificuldade adotada e demonstra que o sistema orientou os usuários a priorizarem os tópicos que demandam maior esforço cognitivo. De forma semelhante, na fase de domínio, os quizzes de maior complexidade, como aqueles do tipo “Múltipla Resposta” e “Situação Hipotética”, apresentaram índices de erro mais elevados, de 37,5% e 25%, respectivamente, reforçando que a plataforma conseguiu identificar lacunas de conhecimento e oferecer feedback direcionado para a melhoria do desempenho.

A análise pré e pós-uso da plataforma evidenciou um **ganho médio de aprendizado percebido de 74,2%**, com a pontuação média de autoavaliação passando de 3,2 para 4,78 pontos. Esse resultado sugere que a FlashQuiz contribuiu de forma significativa para a retenção de conhecimento, especialmente entre os usuários classificados como “Alunos”, que apresentaram uma evolução mais expressiva. Além disso, a experiência de uso da plataforma foi bem avaliada pelos participantes, com destaque para a facilidade de navegação (4,41), a clareza das instruções (4,64) e a qualidade dos vídeos (4,68), o que indica que os elementos visuais, as animações e a gamificação,

como as insígnias e a progressão por fases, contribuíram para manter os estudantes engajados e motivados.

No que se refere às variáveis demográficas, a análise por gênero revelou uma distribuição equilibrada: 8 homens e 2 mulheres foram classificados como “Mestres”, enquanto 6 homens e 3 mulheres ficaram na categoria “Alunos”. Os testes estatísticos (*teste t* de Student e teste de Levene) mostraram que **não houve diferenças estatisticamente significativas entre homens e mulheres** nas fases prática e de domínio ($p > 0,05$), resultado que está em consonância com estudos que apontam diferenças cognitivas sutis entre os gêneros, mas que não são determinantes para o desempenho (HERLITZ; REHNMAN, 2008; VOYER; VOYER; SAINT-AUBIN, 2017). A análise por idade indicou que a maioria dos “Mestres” está concentrada entre 23 e 26 anos, enquanto o único “Não-Aluno” encontrava-se na faixa de 28 anos, possivelmente devido a menor familiaridade com ferramentas digitais ou menor engajamento. Ao relacionar o perfil de aprendizado com o semestre do curso, observou-se que o 2º semestre concentrou o maior número de “Alunos” (6), reforçando que estudantes em estágios iniciais de formação se beneficiaram mais da plataforma, enquanto os formados (semestre 0) foram todos classificados como “Mestres”, utilizando a ferramenta principalmente como forma de revisão e consolidação do conhecimento.

Os testes de hipóteses aplicados permitiram verificar se variáveis como gênero e idade influenciam o desempenho nas fases prática (*AI_score*) e de domínio (*AF_score*). Para gênero, a hipótese nula (H_0) assumiu que não haveria diferença significativa entre as médias de pontuação de homens e mulheres, enquanto a hipótese alternativa (H_1) propunha a existência dessa diferença. O teste *t* de Student, precedido pelo teste de Levene para homogeneidade das variâncias, apresentou valores de *p* superiores a 0,05 em ambas as fases, não havendo evidências para rejeitar H_0 . Da mesma forma, o teste não paramétrico de Kruskal-Wallis, utilizado para analisar as diferenças entre faixas etárias, também não apontou significância estatística ($p > 0,05$). É importante ressaltar que, devido à natureza não controlada do experimento e ao tamanho reduzido da amostra, esses achados indicam a ausência de diferenças estatisticamente relevantes nesta amostra e sob as condições observadas, mas não permitem inferir causalidade. Isso se deve à impossibilidade de isolar completamente o efeito da plataforma de outras variáveis potencialmente influentes (SHADISH; COOK; CAMPBELL, 2002).

De forma geral, os resultados obtidos demonstram que a plataforma FlashQuiz **atingiu os objetivos propostos**, tanto no que se refere à melhoria da aprendizagem de requisitos de software quanto na percepção positiva dos usuários em relação à usabilidade e ao design. A análise quantitativa e estatística, aliada ao feedback dos participantes, reforça que a combinação de flashcards, quizzes e feedback imediato é

eficaz para estimular o aprendizado ativo e a autonomia. Além disso, as informações levantadas permitem identificar oportunidades de ajustes e aperfeiçoamentos futuros, como o equilíbrio na dificuldade dos quizzes mais complexos e a personalização de conteúdos para diferentes perfis de estudantes, ampliando o potencial de aplicação da plataforma em contextos acadêmicos diversificados.

4.8 Considerações Finais dos Resultados

Os dados apresentados neste capítulo demonstram que, para a amostra estudada, a FlashQuiz atingiu os objetivos propostos, promovendo aprendizado significativo por meio de uma abordagem lúdica, interativa e personalizada. A ausência de diferenças significativas entre os grupos analisados sugere que a plataforma é aplicável a diferentes perfis de estudantes, fortalecendo seu potencial como recurso educacional inovador para o ensino de Engenharia de Requisitos.

5 Conclusão e Trabalhos Futuros

O presente trabalho teve como objetivo principal desenvolver e avaliar a plataforma FlashQuiz, uma ferramenta educacional que combina flashcards e quizzes gerados por Inteligência Artificial (IA) para apoiar o estudo de requisitos de software. A pesquisa buscou, ainda, analisar a eficácia da plataforma na melhoria do desempenho dos estudantes, utilizando como referência metodológica o modelo de Serrano-Laguna et al. ([SERRANO-LAGUNA et al., 2017](#)), reconhecido no contexto de jogos sérios e de avaliação de aprendizagem baseada em dados.

5.1 Síntese dos Principais Resultados

A análise dos dados indicou que a plataforma alcançou de forma satisfatória os objetivos propostos. A classificação dos usuários nas categorias "**Mestres**", "**Alunos**", "**Não-Alunos**" e "**Deslocados**", conforme a metodologia adotada, permitiu identificar os perfis de aprendizado e os ganhos obtidos. Cerca de 95% dos participantes atingiram o limiar mínimo estabelecido na fase de Domínio, demonstrando assimilação consistente dos conceitos trabalhados. Metade dos usuários foi classificada como "**Alunos**", o que evidencia ganhos significativos de aprendizado entre aqueles sem domínio prévio dos conteúdos. A categoria "**Mestres**", que representou 45% da amostra, indica que parte dos participantes utilizou a plataforma como recurso de revisão. A presença de apenas um "**Não-Aluno**" (5%) sugere dificuldades pontuais que não comprometem a eficácia geral do sistema. A comparação entre os dados pré e pós-uso apontou um ganho médio de **74,2% na percepção de conhecimento**, passando de 3,2 pontos para 4,78 pontos. Esses resultados corroboram a eficácia da estratégia adotada, baseada em memorização ativa (flashcards), feedback imediato (quizzes) e mecânicas de gamificação (insígnias e fases progressivas).

5.2 Desempenho e Feedback dos Usuários

Os conteúdos classificados como "**Difíceis**" nos flashcards exigiram maior número de tentativas (média de 2,8), enquanto conteúdos intermediários e fáceis apresentaram médias de 1,72 e 1,40 tentativas, respectivamente. Nos quizzes, questões de formato mais complexo, como múltipla resposta e situações hipotéticas, apresentaram taxas de erro de 37,5% e 25%. Esses dados sugerem que a classificação de dificuldade foi adequada à percepção dos usuários e que ajustes pontuais podem aprimorar o equilíbrio entre desafio e aprendizado. O feedback qualitativo dos participantes refor-

çou esses achados. A facilidade de navegação (4,41), a clareza das instruções (4,64) e a qualidade dos vídeos (4,68) foram bem avaliadas, confirmando que a interface e os recursos multimídia contribuíram positivamente para a experiência de uso. As insígnias e a progressão por fases foram vistas como elementos motivacionais que promovem autonomia e engajamento.

5.3 Análise de Variáveis Demográficas e Hipóteses

A análise das variáveis de gênero, idade e semestre do curso não identificou diferenças estatisticamente significativas no desempenho ($p>0,05$), de acordo com os testes t de Student e Kruskal-Wallis. Ainda assim, padrões descritivos foram observados: a categoria "**Mestres**" incluiu oito homens e duas mulheres, enquanto a categoria "**Alunos**" contou com seis homens e três mulheres. O único "**Não-Aluno**" era do sexo masculino. Em relação à idade, a faixa de **23 a 26 anos** apresentou maior concentração de participantes classificados como "**Mestres**", enquanto o **2º semestre** concentrou a maior quantidade de "**Alunos**", confirmando que estudantes em estágios iniciais tiveram maior ganho de aprendizado. Os participantes formados (semestre 0) foram todos classificados como "**Mestres**", evidenciando o uso da plataforma como recurso de revisão.

5.4 Limitações do Estudo

Apesar dos resultados positivos, algumas limitações devem ser reconhecidas. Primeiramente, o caráter não controlado do experimento e a ausência de um grupo de controle são fatores que podem comprometer a inferência de causalidade. Isso significa que outros fatores externos, não isolados ou medidos, podem ter influenciado os resultados observados, tornando difícil afirmar com certeza que as melhorias vieram exclusivamente da plataforma (CRESWELL, 2014; SHADISH; COOK; CAMPBELL, 2002). Além disso, amostra reduzida (20 participantes) restringe a generalização dos achados para populações maiores. A análise concentrou-se apenas na Fase 1 – Natureza de Requisitos de Software, sem explorar outros tópicos de conteúdo. Por fim, parte da avaliação se baseou em medidas de autoavaliação, o que pode introduzir vieses subjetivos na percepção dos usuários.

5.5 Sugestões de Trabalhos Futuros

Algumas melhorias podem ser implementadas em estudos futuros, algumas já sugeridas pelos próprios usuários:

- Ampliar o tamanho da amostra para obter resultados mais consistentes.
- Incluir algumas ferramentas de visualização do progresso individual, possibilitando aos jogadores acompanhar a evolução do aprendizado ao longo das sessões.
- Desenvolver um sistema de personalização adaptativa, ajustando dinamicamente a dificuldade com base no histórico de desempenho.
- Aperfeiçoar a coleta de dados com métricas de Learning Analytics mais detalhadas, como padrões de interação e tempo de resposta.
- Realizar testes de retenção de médio e longo prazo, permitindo avaliar a eficácia do aprendizado além da sessão imediata.
- Expandir a plataforma para novos módulos temáticos, ampliando a aplicabilidade em outras áreas de conhecimento.
- Tornar a plataforma mais interativa e abrangente, com geração automatizada de conteúdo a partir de insumos fornecidos por professores ou alunos, possibilitando uso em contextos educacionais diversos.
- Implementar recursos de acessibilidade robustos, como compatibilidade com leitores de tela, legendas para vídeos, opções de contraste elevado, e personalização do tamanho e tipo de fonte, garantindo que a plataforma seja utilizável por pessoas com deficiência.
- Realizar estudos focados na experiência de usuário (UX) com grupos diversos, incluindo pessoas com deficiência, para identificar barreiras e oportunidades de melhoria na usabilidade e acessibilidade da plataforma.
- Reavaliar e expandir a coleta de dados demográficos para incluir uma gama mais ampla de identidades, evitando categorizações simplistas e permitindo uma análise mais abrangente da diversidade dos usuários e suas necessidades.

Referências

- ALI, N. B.; UNTERKALMSTEINER, M. Use and evaluation of simulation for software process education. *arXiv preprint*, 2023. Disponível em: <<https://arxiv.org/abs/2307.12484>>. Citado 2 vezes nas páginas 23 e 24.
- ANDRADE, G. Vargas de et al. Virtual reality applications in software engineering education. *arXiv preprint*, 2022. Disponível em: <<https://arxiv.org/abs/2204.12008>>. Citado 2 vezes nas páginas 23 e 24.
- ARNOLD, K. E.; PISTILLI, M. D. Course signals at purdue. In: *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK)*. [S.l.]: ACM, 2012. p. 267–270. Citado na página 27.
- BAI, J.; HUANG, C.; CHEN, S. Engineering prompts for enhanced learning engagement. *Journal of Educational Data Mining*, v. 14, n. 3, p. 1–12, 2022. Citado na página 31.
- BAKER, R. S.; INVENTADO, P. S. Educational data mining and learning analytics. In: *Learning Analytics*. [S.l.]: Springer, 2014. p. 61–75. Citado na página 27.
- BATES, B. *Game Design*. 2. ed. Boston: Course Technology, 2004. Citado na página 24.
- BLINCOE, K. et al. Adapting agile practices in university contexts. *Journal of Systems and Software*, v. 144, p. 421–433, 2018. Citado 2 vezes nas páginas 19 e 20.
- BLUMBERG, F. C. *Learning by Playing: Video Gaming in Education*. New York: Oxford University Press, 2014. Citado na página 25.
- BOSTROM, N.; YUDKOWSKY, E. The ethics of artificial intelligence. In: FRANKISH, K.; RAMSEY, W. M. (Ed.). *The Cambridge Handbook of Artificial Intelligence*. [S.l.]: Cambridge University Press, 2014. p. 316–334. Citado na página 30.
- BROWN, T. et al. Language models are few-shot learners. *Advances in Neural Information Processing Systems*, v. 33, p. 1877–1901, 2020. Citado 2 vezes nas páginas 31 e 33.
- BURIĆ, I.; STRÖM, A. The impact of anki flashcards on medical students' learning: A systematic review. *BMC Medical Education*, v. 21, n. 1, p. 1–10, 2021. Citado na página 34.
- BUTLER, A. C.; ROEDIGER, H. L. Testing and retrieval practice: key factors for long-term retention. *Journal of Experimental Psychology & Trends in Cognitive Sciences*, 2010. Citado 7 vezes nas páginas 15, 29, 30, 33, 34, 35 e 37.
- CAMPBELL, D. T.; STANLEY, J. C. *Experimental and Quasi-Experimental Designs for Research*. [S.l.]: Rand McNally, 1963. Citado na página 68.
- CAROLAN, C. et al. Covid-19: Disruptive impacts and transformative opportunities. *Nurse Education in Practice*, v. 46, p. 102807, 2020. Citado na página 21.

- CEPEDA, N. J. et al. Distributed practice in verbal recall tasks: A review and quantitative synthesis. *Psychological Bulletin*, v. 132, n. 3, p. 354–380, 2006. Citado na página 34.
- CLEMENTINO, A. et al. Teaching software engineering: Current approaches and practices. In: *Anais do 38º Simpósio Brasileiro de Engenharia de Software (SBES)*. Porto Alegre: SBC, 2024. p. 422–432. Citado na página 18.
- CONNOLLY, T. M. et al. A systematic literature review of the empirical evidence of the impacts of serious games. *Computers & Education*, v. 59, n. 2, p. 661–683, 2012. Citado na página 46.
- CRESWELL, J. W. *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches*. 4. ed. [S.l.]: SAGE Publications, 2014. Citado 2 vezes nas páginas 68 e 87.
- DETERDING, S. et al. From game design elements to gamefulness: defining “gamification”. In: *Proceedings of the 15th International Academic MindTrek Conference*. [S.l.]: ACM, 2011. p. 9–15. Citado na página 25.
- DUNLOSKY, J. et al. Improving students’ learning with effective learning techniques. *Psychological Science in the Public Interest*, v. 14, n. 1, p. 4–58, 2013. Citado 5 vezes nas páginas 15, 29, 33, 35 e 37.
- EL-NASR, M. S.; CANOSSA, A.; DRAKEFORD, W. *Game Analytics: Maximizing the Value of Player Data*. [S.l.]: Springer, 2013. Citado na página 27.
- FERNÁNDEZ, D. M. et al. Naming the pain in requirements engineering. *arXiv preprint*, 2016. Disponível em: <<https://arxiv.org/abs/1611.10288>>. Citado na página 20.
- FRANÇA, B. B. N. d. et al. Teaching simulation as a research method in empirical software engineering. *arXiv preprint*, 2025. Disponível em: <<https://arxiv.org/abs/2501.04798>>. Citado na página 24.
- FREIRE, M. et al. Game learning analytics: Learning analytics for serious games. In: *Learning Analytics: Fundamentals, Applications, and Trends*. Cham: Springer, 2016. p. 1–29. Citado na página 28.
- HACKETT, R. *The History of Educational Games: Number Munchers and Beyond*. New York: Routledge, 2016. Citado na página 25.
- HERLITZ, A.; REHNMAN, J. Sex differences in episodic memory. *Current Directions in Psychological Science*, v. 17, n. 1, p. 52–56, 2008. Citado 2 vezes nas páginas 70 e 84.
- HOLMES, W.; BIALIK, M.; FADEL, C. *Artificial Intelligence in Education: Promises and Implications for Teaching and Learning*. [S.l.]: Center for Curriculum Redesign, 2019. Citado na página 29.
- JATIT. Improving student engagement in requirement engineering education. *Journal of Theoretical and Applied Information Technology*, v. 103, n. 5, p. 707–720, 2024. Citado na página 20.

- JOHNSON, W. L.; WU, S. Assessing the potential of game-based learning. *International Journal of Learning Technology*, v. 5, n. 2, p. 138–156, 2010. Citado na página 26.
- KARPICKE, J. D.; BLUNT, J. R. Retrieval practice produces more learning than elaborative studying with concept mapping. *Science*, v. 331, n. 6018, p. 772–775, 2011. Citado 7 vezes nas páginas 15, 29, 30, 33, 34, 36 e 37.
- KHARISTAT, Z.; FAKHOURI, H. N. Impact of e-learning tools on student engagement. *International Journal of Interactive Mobile Technologies (iJIM)*, v. 18, n. 18, p. 125–145, 2024. Disponível em: <<https://www.researchgate.net/publication/384301556>>. Citado na página 23.
- KIILI, K. Content creation and discovery activities for serious games. *Journal of the Learning Sciences*, v. 14, n. 4, p. 577–612, 2005. Citado na página 46.
- LIU, P. et al. Pre-train, prompt, and predict: A systematic survey of prompting methods in nlp. *arXiv preprint*, 2021. Disponível em: <<https://arxiv.org/abs/2107.13586>>. Citado na página 31.
- LUCKIN, R. et al. *Intelligence Unleashed: An Argument for AI in Education*. London: Pearson, 2016. Citado 2 vezes nas páginas 14 e 15.
- MASSARANI, L. M. et al. Estudo sobre desinformação e vacinas nas redes sociais. *Revista Eletrônica de Comunicação, Informação & Inovação em Saúde*, v. 15, n. 1, 2021. Citado na página 22.
- MCDANIEL, M. A.; ROEDIGER, H. L. Testing the testing effect in the classroom. *European Journal of Cognitive Psychology*, v. 23, n. 4, p. 494–511, 2011. Citado 4 vezes nas páginas 15, 35, 36 e 37.
- MICHAEL, D.; CHEN, S. *Serious Games: Games That Educate, Train, and Inform*. Boston: Thomson Course Technology, 2006. Citado na página 25.
- NAVARRETE, C.; SANTOS, R. Game-based learning and its applications in higher education. *Computers & Education*, v. 92, p. 1–4, 2016. Citado na página 26.
- NAVARRO, E.; HOEK, A. Van der. Simse: An educational simulation game for software engineering. In: *19th Conference on Software Engineering Education and Training (CSEET)*. [S.l.]: IEEE, 2006. Citado na página 26.
- NICHOLS, M. Game-based learning in higher education: Strategies and techniques. *Journal of Interactive Learning Research*, v. 24, n. 4, p. 343–360, 2013. Citado na página 26.
- OLIVEIRA, E. N.; VASCONCELOS, M. I. O.; ALMEIDA, P. C. Análise da saúde mental de estudantes durante a pandemia. *Revista Brasileira de Educação*, v. 27, 2022. Citado 2 vezes nas páginas 21 e 22.
- PALLANT, J. *SPSS Survival Manual: A Step by Step Guide to Data Analysis Using IBM SPSS*. 5. ed. [S.l.]: Allen & Unwin, 2013. Citado na página 68.
- PETRUS, J. S. R.; CAMINHAS, D. A. Aumento das desigualdades educacionais na pandemia. *Revista Educação e Pesquisa*, v. 47, 2021. Citado na página 21.

- PRENSKY, M. *Digital Game-Based Learning*. New York: McGraw-Hill, 2004. Citado na página 14.
- PRESSMAN, R. S. *Engenharia de Software: Uma Abordagem Profissional*. 8. ed. Porto Alegre: McGraw-Hill, 2019. Citado 4 vezes nas páginas 18, 32, 52 e 54.
- RADFORD, A. et al. *Language Models are Unsupervised Multitask Learners*. OpenAI, 2019. Disponível em: <<https://openai.com/research/language-models>>. Citado na página 31.
- REVIEW, S. A systematic review on trends in using moodle for teaching and learning. *International Journal for STEM Education*, 2021. Disponível em: <<https://stemeducationjournal.springeropen.com/articles/10.1186/s40594-021-00323-x>>. Citado 2 vezes nas páginas 23 e 24.
- ROBINSON, T. J.; ALBEKAI, S.; ABDELRAZZAK, A. *From Pre-Made to Personalized: Leveraging AI to Align Flashcards and MCQs with Medical Students' Learning Objectives*. 2024. ResearchGate. Disponível em: <<https://www.researchgate.net>>. Citado na página 34.
- SALES, J. R.; CASTRO, D. B. Impactos da pandemia em estudantes de medicina. *Revista Brasileira de Educação Médica*, v. 45, n. 1, 2021. Citado na página 22.
- SANTHOSH, V. N. et al. Effectiveness of spaced repetition learning using a mobile flashcard application among dental students: A randomized controlled trial. *Journal of Dental Education*, v. 88, n. 9, p. 1267–1276, 2024. Citado na página 33.
- SERRANO-LAGUNA, A. et al. A methodology for assessing the effectiveness of serious games and for inferring player learning outcomes. *Multimedia Tools and Applications*, v. 76, n. 4, p. 1–30, 2017. Citado 12 vezes nas páginas 16, 37, 40, 41, 45, 46, 47, 49, 50, 69, 82 e 86.
- SHADISH, W. R.; COOK, T. D.; CAMPBELL, D. T. *Experimental and Quasi-Experimental Designs for Generalized Causal Inference*. [S.l.]: Houghton Mifflin Company, 2002. Citado 3 vezes nas páginas 68, 84 e 87.
- SHCHETYNINA, O. et al. Trello as a tool for lifelong learning skills. *Postmodern Openings*, v. 13, n. 2, p. 143–167, 2022. Disponível em: <<https://lumenpublishing.com/journals/index.php/po/article/download/4927/3762/17923>>. Citado na página 23.
- SOMMERVILLE, I. *Software Engineering*. 9. ed. Boston: Addison-Wesley, 2011. Citado 4 vezes nas páginas 13, 15, 18 e 32.
- SQUIRE, K. D. From content to context: Videogames as designed experience. *Educational Researcher*, v. 35, n. 8, p. 19–29, 2006. Citado 2 vezes nas páginas 14 e 26.
- TIWARI, S. et al. Teaching requirements engineering concepts using case-based learning. *arXiv preprint*, 2018. Disponível em: <<https://arxiv.org/abs/1804.01770>>. Citado 2 vezes nas páginas 19 e 20.
- VOYER, D.; VOYER, S. D.; SAINT-AUBIN, J. Sex differences in visual-spatial working memory: a meta-analysis. *Psychonomic Bulletin & Review*, v. 24, n. 2, p. 307–334, 2017. Citado 2 vezes nas páginas 70 e 84.

- WATTANASOONTORN, V.; HERNANDEZ, J.; SBERT, M. Serious games for health. *Entertainment Computing*, v. 4, n. 4, p. 231–247, 2012. Citado na página 25.
- WEI, J.; WANG, X.; ZHANG, Y. Customizable prompt engineering for adaptive learning. *Journal of Educational Technology Development and Exchange*, v. 15, n. 2, p. 30–47, 2022. Citado na página 31.
- WHITE, J. S.; LING, Z.; LIANG, X. Prompt-based learning for specific domains. *Proceedings of the IEEE*, v. 110, n. 7, p. 965–987, 2022. Citado na página 31.
- ZAWACKI-RICHTER, O. et al. Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, v. 16, n. 1, p. 1–27, 2019. Disponível em: <<https://educationaltechnologyjournal.springeropen.com/articles/10.1186/s41239-019-0171-0>>. Citado 3 vezes nas páginas 15, 29 e 30.
- ZOWGHI, D.; COULIN, C. A survey of techniques, approaches and tools for requirements elicitation. In: *Engineering and Managing Software Requirements*. [S.l.]: Springer, 2008. Citado na página 20.
- ZYDA, M. From visual simulation to virtual reality to games. *Computer*, v. 38, n. 9, p. 25–32, 2005. Citado na página 25.