

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
CURSO DE GRADUAÇÃO EM SISTEMAS DE INFORMAÇÃO

Matheus Garcia Escobar

**APLICAÇÃO DE GAME LEARNING ANALYTICS EM UM JOGO
EDUCACIONAL**

Santa Maria, RS
2024

Matheus Garcia Escobar

APLICAÇÃO DE GAME LEARNING ANALYTICS EM UM JOGO EDUCACIONAL

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Sistemas de Informação da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Bacharel em Sistemas de Informação**.

Orientadora: Prof.^a Giliane Bernardi

Santa Maria, RS
2024

Matheus Garcia Escobar

APLICAÇÃO DE GAME LEARNING ANALYTICS EM UM JOGO EDUCACIONAL

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Sistemas de Informação da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Bacharel em Sistemas de Informação**.

Aprovado em 22 de julho de 2024:

Giliane Bernardi, Dra. (UFSM)
(Presidenta/Orientadora)

Lisandra Manzoni Fontoura, Dra. (UFSM)

Giani Petri, Dr. (UFSM)

Santa Maria, RS
2024

AGRADECIMENTOS

Agradeço primeiramente às minhas duas mães: minha mãe de sangue, Elvira Fernandes Garcia, e minha tia, mas mãe de coração, Vanda Magali Almeida Escobar, por todo o apoio e suporte durante esta caminhada da graduação. Obrigado por nunca terem desistido de mim ou deixado de acreditar em minhas decisões. Tudo seria imensamente mais difícil sem vocês ao meu lado.

Agradeço à minha companheira, Helena Cocco Giordani, pelo suporte dado durante toda essa trajetória. Seu carinho, compreensão e apoio foram fundamentais para a concretização desta conquista e serão para as muitas outras que ainda estão por vir. Espero ansiosamente pela tua aprovação em medicina para que eu possa, da mesma forma, retribuir todo o apoio e incentivo que você sempre me deu.

Agradeço à minha orientadora, professora Giliane, que foi além da orientação neste trabalho, frequentemente assumindo também o papel de psicóloga. Obrigado pelo suporte, pela paciência constante, pela dedicação incansável, pelas ideias e pela forma como você conduz seu trabalho.

Agradeço à professora Lisandra por todas as oportunidades, ideias e ensinamentos concedidos durante as pesquisas e disciplinas. Essa bagagem foi indispensável para a criação desse trabalho. Obrigado por ter me dado a primeira oportunidade no ramo da pesquisa e por toda a sua compreensão, experiência e seriedade com que trabalha.

Agradeço aos meus amigos da tribo que ombrearam essa batalha desde o início. Obrigado por todos os momentos de alegria e pelas colaborações. Que nunca percamos a felicidade e a força de vontade que nos move!

A todos os meus familiares, amigos, colegas e pessoas que, em algum momento, passaram pela minha vida e contribuíram de alguma forma para a realização deste sonho, seja ao enfrentar um obstáculo juntos, com uma palavra de conforto ou uma atitude. Sempre levarei vocês no peito.

Aos professores do Curso de Sistemas de Informação e de computação da UFSM, que nunca medem esforços para transmitir seus conhecimentos com dedicação e comprometimento. Cada lição aprendida serviu para moldar o profissional que serei ao longo da vida.

Ao Programa de Educação Tutorial do curso de Sistemas de Informação, por ter sido minha primeira oportunidade dentro da universidade, e a todos os colegas que vi passar durante esses quase 4 anos como membro do grupo. Obrigado por todo o aprendizado.

Agradeço aos participantes desta pesquisa por dedicarem seu tempo e contribuírem para a validação deste trabalho.

RESUMO

APLICAÇÃO DE GAME LEARNING ANALYTICS EM UM JOGO EDUCACIONAL

AUTOR: Matheus Garcia Escobar

Orientadora: Giliane Bernardi

A utilização de tecnologias educacionais avançadas para melhorar o processo de ensino e aprendizagem tem se tornado cada vez mais relevante. Com isso, o aumento da adoção de jogos na educação, gerando um forte aumento no número de dados e, conseqüentemente, a busca constante por ferramentas que auxiliem na compreensão desses dados, tanto por parte do professor quanto do próprio aluno, faz com que um campo emergente chamado Game Learning Analytics (GLA) ganhe cada vez mais força. As ações registradas por esses jogos ou plataformas gamificadas, que antes eram substancialmente ignoradas, agora, quando manipuladas e analisadas, geram relatórios que servem para traçar perfis, estratégias pedagógicas e promover melhorias nos processos de ensino e aprendizagem. A proposta deste trabalho é enriquecer o processo educativo por meio da aplicação de GLA no jogo educacional existente chamado Lumni, um quiz interativo desenvolvido para estudantes de Engenharia de Software. Por meio da coleta e análise de dados gerados pelas interações dos alunos com o jogo, o objetivo é fornecer *insights* valiosos por meio de uma experiência mais visual acerca do nível de aprendizagem para educadores e alunos, permitindo a identificação de padrões de engajamento, a calibração adequada da dificuldade das questões, a personalização das estratégias de ensino e aprendizagem, bem como a otimização do tempo de estudo e o planejamento eficaz de atividades educacionais. Para atingir este objetivo, foi necessário revisar o código implementando melhorias, definir os indicadores e dados a serem coletados, estabelecer a estrutura do *dashboard* e realizar a implementação e integração de GLA e da visualização de dados. O produto final permite ao usuário a visualização de dados mais detalhados sobre as perguntas registradas e respondidas, a relação de acertos e erros, o tempo médio de resposta e os níveis de dificuldade, seu desempenho no jogo e sua disponibilidade baseada no número de acessos por dia da semana, além da possibilidade de filtragem por aluno, tema ou pergunta. As avaliações de aceitação e usabilidade demonstraram uma forte aprovação tanto do jogo quanto do *dashboard* pelos usuários. Os resultados destacaram a identificação de áreas de melhoria do conhecimento, o reforço do aprendizado sobre os tópicos abordados em sala de aula, a clareza nas interações e o *feedback* em tempo real. O sistema foi considerado funcional e bem aceito, com uma percepção positiva em termos de facilidade de uso, integração, consistência e confiança.

Palavras-chave: Game Learning Analytics. Jogo Educacional. Dashboard.

ABSTRACT

APPLICATION OF GAME LEARNING ANALYTICS ON A EDUCATIONAL GAME

AUTHOR: Matheus Garcia Escobar

ADVISOR: Giliane Bernardi

The use of advanced educational technologies to enhance the teaching and learning process has become increasingly relevant. Consequently, the rise in the adoption of games in education, generating a substantial increase in the amount of data and, therefore, the constant search for tools that assist in understanding this data by both teachers and students, has given rise to an emerging field known as Game Learning Analytics (GLA). The actions recorded by these games or gamified platforms, which were previously largely ignored, now, when manipulated and analyzed, generate reports that serve to profile, create pedagogical strategies, and promote improvements in teaching and learning processes. The proposal of this work is to enrich the educational process through the application of GLA in the existing educational game called Lumni, an interactive quiz developed for Software Engineering students. By collecting and analyzing data generated by students' interactions with the game, the goal is to provide valuable insights through a more visual experience regarding the level of learning for educators and students. To achieve this objective, it was necessary to review the code by implementing improvements, define the indicators and data to be collected, establish the structure of the dashboard, and carry out the implementation and integration of GLA and data visualization. The final product allows users to visualize more detailed data about recorded and answered questions, the ratio of correct and incorrect answers, the average response time, difficulty levels, performance in the game, and availability based on the number of accesses per day of the week, as well as the possibility of filtering by student, topic, or question. Acceptance and usability evaluations demonstrated strong approval of both the game and the dashboard by users. The results highlighted the identification of areas for knowledge improvement, reinforcement of learning on topics covered in class, clarity in interactions, and real-time feedback. The system was considered functional and well-accepted, with positive perceptions in terms of ease of use, integration, consistency, and trust.

Keywords: Game Learning Analytics. Educational Game. Dashboard.

LISTA DE FIGURAS

Figura 1 – Resumo dos 8 grupos de padrões de <i>design</i>	18
Figura 2 – Escala Likert utilizada no método SUS.	27
Figura 3 – Diagrama Relacional do Lumni	30
Figura 4 – Antigo aviso de erro ao digitar e-mail ou senha incorretos	31
Figura 5 – Aviso de erro ao digitar e-mail ou senha incorretos	32
Figura 6 – Novo aviso de erro ao preencher os campos	32
Figura 7 – Nova barra de navegação do aluno	33
Figura 8 – Nova barra de navegação do professor	33
Figura 9 – Antiga criação de perguntas	34
Figura 10 – Nova criação de perguntas	34
Figura 11 – Antiga edição de perguntas	35
Figura 12 – Nova edição de perguntas	35
Figura 13 – Antiga tela da partida do quiz	36
Figura 14 – Nova tela da partida do quiz	36
Figura 15 – Modal de prevenção de erro ao pular pergunta	36
Figura 16 – Modal de prevenção de erro ao encerrar a jogatina	36
Figura 17 – Antiga tela de <i>feedback</i>	37
Figura 18 – Nova tela de <i>feedback</i> com acerto	37
Figura 19 – Nova tela de <i>feedback</i> com erro	37
Figura 20 – Lógica no <i>back-end</i> que controla a pontuação e os níveis	38
Figura 21 – Placar	40
Figura 22 – Modelo inicial do <i>dashboard</i> - Lumni	54
Figura 23 – Modelo final do <i>dashboard</i> - Lumni	55
Figura 24 – Gráfico TAM	56
Figura 25 – Gráfico SUS	60

LISTA DE QUADROS

Quadro 1 – Etapas do trabalho.	24
Quadro 2 – Questões para a Análise da Aceitação de Tecnologia	26
Quadro 3 – Questões do SUS adaptadas ao português	27
Quadro 4 – Pontuação SUS	28
Quadro 5 – Mapeamento de campos de evento de interações para atributos de instrução xAPI	41

LISTA DE SIGLAS

LA	<i>Learning Analytics</i>
GA	<i>Game Analytics</i>
GLA	<i>Game Learning Analytics</i>
API	<i>Application Programming Interface</i>
REST	<i>Representational State Transfer</i>
JSON	<i>JavaScript Object Notation</i>
xAPI	<i>Experience API</i>
MVC	<i>Model-View-Controller</i>
HTTP	<i>Hypertext Transfer Protocol</i>
JS	<i>Java Script</i>
CSS	<i>Cascading Style Sheets</i>
PWA	<i>Progressive Web Apps</i>
UFSC	<i>Universidade Federal de Santa Maria</i>
IDE	<i>Integrated Development Environment</i>

SUMÁRIO

1	INTRODUÇÃO	10
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	JOGOS SÉRIOS	13
2.2	<i>LEARNING ANALYTICS</i>	13
2.3	<i>GAME LEARNING ANALYTICS</i>	14
2.4	VISUALIZAÇÃO DOS DADOS	16
2.5	O <i>SOFTWARE</i> EDUCACIONAL LUMNI	18
3	TRABALHOS RELACIONADOS	20
4	ASPECTOS METODOLÓGICOS	24
4.1	FERRAMENTAS UTILIZADAS	28
5	DESENVOLVIMENTO	30
5.1	FERRAMENTA ATUAL E AJUSTES	30
5.2	IMPLEMENTAÇÃO DO GLA	40
5.3	IMPLEMENTAÇÃO DO DASHBOARD	49
6	AValiação e ANÁLISE DOS RESULTADOS	56
6.1	ANÁLISE DA ACEITAÇÃO DA APLICAÇÃO	56
6.2	ANÁLISE DA USABILIDADE	58
6.3	SUGESTÕES E/OU CRÍTICAS	60
7	CONCLUSÃO	63
7.1	REVISÃO GERAL E RESULTADOS	63
7.2	TRABALHOS FUTUROS	64
	REFERÊNCIAS BIBLIOGRÁFICAS	66

1 INTRODUÇÃO

O conceito de “aprendizagem personalizada” foi propagado por volta de 2010 pelas grandes empresas de tecnologia educacional, de acordo com Reich (2020), mas foi posterior a esta data que a utilização desses conceitos começou a ser amplamente difundida através da adesão de plataforma de ensino, com eventos que alteraram a estrutura do ensino público e privado, desde o contínuo aumento no número de dados e usuários conectados até a pandemia de Coronavírus (COVID-19) em 2020. Fatores esses que, por conta da necessidade, acabaram acelerando e impulsionando, durante o período de isolamento, o aumento da adoção de tecnologias como ferramenta de apoio para sala de aula. Com o fim do distanciamento social depois de cerca de 3 anos, alguns professores ainda optam por conduzir o processo de aprendizagem utilizando esses auxílios, visando continuar obtendo as experiências positivas que esses produtos geram, e tornando a tecnologia cada vez mais presente nas atividades acadêmicas e nos currículos (GROSSI; MINODA; FONSECA, 2020). Além disso, as instituições de ensino abrigam alunos com diferentes preferências e estilos de aprendizagem, o que requer o uso de múltiplas modalidades para tornar o aprendizado mais satisfatório e efetivo (SINGH, 2003).

Apesar disso, o processo de ensino e aprendizagem ainda é fortemente guiado pelos chamados métodos "tradicionais", caracterizados por aulas expositivas, teóricas e realização de exercícios. Contudo, com o surgimento de novas tecnologias, torna-se possível expandir as ferramentas utilizadas nesse processo, incluindo os *softwares* educacionais e os jogos digitais e educacionais (FARIAS, 2019).

Os *softwares* educacionais emergem não apenas como ferramentas de ensino, mas também como instrumentos capazes de coletar dados e fornecê-los aos docentes e discentes, ampliando a compreensão de ambas as partes acerca do desempenho e aumentando o envolvimento dos professores com o progresso e as necessidades de seus alunos. Conforme relatado por Farias (2019), o aspecto promissor desses *softwares* é a sua capacidade de coletar e disponibilizar dados referentes ao comportamento e ao desempenho dos estudantes, o que representa uma mina de ouro para a análise pedagógica e a gestão educacional.

Por conseguinte, esse avanço da tecnologia e da conectividade digital, bem como a mudança da abordagem de ensino em uma era de informação abundante, acaba remodelando fundamentalmente o paradigma pedagógico. À medida que os educadores buscam otimizar suas práticas pedagógicas e personalizar a experiência de aprendizado para cada aluno, a análise de dados torna-se uma ferramenta indispensável para este fim, gerando enfoque no uso de uma disciplina emergente chamada de *Learning Analytics* (LA), que visa extrair *insights* significativos dos dados gerados pelas interações de alunos e professores em ambientes educacionais digitais (JOHAR et al., 2023). Muitas ferramentas de ensino

buscam incorporar elementos de análise de aprendizagem para fornecer um *feedback* com indicadores estatísticos do progresso do aluno, por meio de dados que podem ser capturados de forma direta ou indireta, produzindo informações mais autênticas e assertivas em comparação às pesquisas tradicionais. Uma simples interpretação de um *log* de acesso em um jogo de perguntas e respostas pode gerar diferentes estratégias para a aplicação de exercícios em forma de lista, visando ter um maior engajamento e conhecendo o tempo disponível dos usuários.

Dentro do contexto dos *softwares* educacionais, destacam-se os jogos educacionais, que também podem trazer as características de LA atreladas às mecânicas do jogo e têm conquistado cada vez mais espaço em uma indústria de entretenimento já consolidada e bem-sucedida, sendo considerados instrumentos valiosos para auxiliar no processo de aprendizagem (FREIRE et al., 2016). No entanto, a avaliação e personalização da aprendizagem continuam a representar desafios significativos, o que tem aumentado o entusiasmo em torno de um campo emergente denominado *Game Learning Analytics* (GLA), que tem como objetivo capturar registros de dados (*logs*) dos jogadores por meio da interação com um jogo (HONDA et al., 2023). A visualização e análise desses dados pode contribuir para que professores possam traçar estratégias pedagógicas que promovam melhorias nos processos de ensino e aprendizagem.

Baseado nesse alicerce, a incorporação de elementos de jogos e os conceitos de *analytics* mencionados anteriormente em um jogo educacional abre caminho para a aplicação efetiva de *Game Learning Analytics* (GLA). Os princípios básicos de GLA discutidos por Freire et al. (2016), serão utilizados como base fundamental para compreender melhor os elementos de jogos e torná-los mais eficazes para gerar informações para análise no contexto educacional.

Outro fator importante para esta pesquisa é a busca pela criação de gráficos intuitivos que permitam uma melhor visualização dos dados coletados, gerando um *feedback* em tempo real e possibilitando o monitoramento do progresso de aprendizagem. Em pesquisas mais recentes, autores constataam a importância de fornecer ao usuário o suporte para o acompanhamento de forma visual, aprimorando a compreensão e servindo de auxílio ao docente para conhecer melhor o andamento da sua turma, mas também promovendo ao discente uma aprendizagem autorregulada, mediante a identificação de possíveis barreiras e lacunas entre o desempenho real e o esperado, o que pode, por sua vez, possibilitar a adaptação e mudança de estratégias de estudo para promover um progresso mais eficaz e significativo (GUTIÉRREZ et al., 2020).

Levando em consideração esse cenário e a necessidade de enriquecer o processo educativo, particularmente na área de Engenharia de *Software*, foi desenvolvido um jogo educacional denominado Lumni. Este jogo foi projetado com a finalidade de atuar como um recurso pedagógico versátil e coletar dados e informações dos alunos, sendo apto a ser utilizado tanto em ambientes de sala de aula quanto, principalmente, fora dele. O formato

adotado por Lumni é o de um jogo de perguntas e respostas, concebido para engajar os estudantes de maneira interativa e estimulante, promovendo, assim, um aprendizado mais efetivo e dinâmico. Este trabalho tem como foco aprimorar o jogo, integrando ao mesmo estratégias de GLA.

Portanto, este trabalho justifica-se pela necessidade de adotar abordagens inovadoras que atendam às demandas de uma educação personalizada e adaptativa, bem como pelo desejo dos professores e alunos de compreender e otimizar o processo de ensino-aprendizagem em ambientes digitais. Neste sentido, o objetivo principal deste estudo propõe o enriquecimento do processo de ensino e aprendizagem com a aplicação de conceitos de GLA no jogo educacional Lumni. Espera-se, a partir dessa proposta, proporcionar *insights* valiosos para educadores e alunos, aprimorando a coleta, análise e visualização de dados educacionais e, conseqüentemente, permitindo a detecção precoce de lacunas dos conhecimentos abordados pelo Lumni.

Para atingir esse objetivo central da pesquisa, tem-se como objetivos específicos:

1. Revisar o código do Lumni para corrigir e implementar melhorias em requisitos não funcionais;
2. Definir os indicadores para compor os dados que serão coletados;
3. Estabelecer a estrutura dos gráficos do *dashboard* para a visualização dos dados coletados;
4. Implementar GLA no back-end e o *design* no front-end;
5. Disponibilizar o Lumni em produção e avaliar os resultados.

O produto final visa fornecer análises detalhadas do desempenho dos alunos no ambiente de aprendizado. Isso permitirá a identificação prévia de áreas que necessitam de melhoria, por meio do *design* de gráficos intuitivos como ferramentas de visualização de dados. Assim, docentes e discentes poderão desenvolver estratégias de ensino mais direcionadas e eficazes.

Este trabalho está estruturado da seguinte forma. O Capítulo 2 apresenta a fundamentação teórica, abordando conceitos como Jogos Sérios, *Learning Analytics*, *Game Learning Analytics*, Visualização de Dados e o *Software* Educacional Lumni. O Capítulo 3 apresenta uma análise crítica dos trabalhos relacionados. O Capítulo 4 apresenta a metodologia e as ferramentas utilizadas nesse trabalho. O Capítulo 5 apresenta como o jogo educacional Lumni foi desenvolvido. O Capítulo 6 apresenta a avaliação e a análise dos resultados. Por fim, no Capítulo 7 é apresentada a conclusão do trabalho e são descritas algumas perspectivas de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os principais temas usados para o desenvolvimento deste trabalho. Na seção 2.1 são definidos os conceitos de Jogos Sérios, enquanto a seção 2.2 se encarrega de definir os conceitos de *Learning Analytics* e a seção 2.3 os conceitos de *Game Learning Analytics*. A seção 2.4 discute sobre a Visualização dos Dados, os conceitos, as contribuições e seus benefícios. Por fim, a seção 2.5 descreve o *software* educacional Lumni, utilizado como estudo de caso neste trabalho, destacando suas as principais características e objetivos educacionais.

2.1 JOGOS SÉRIOS

Neste trabalho, optou-se pelo uso do termo Jogos Sérios (do inglês, *serious games*) em vez de Jogos Educacionais, por tratar-se da nomenclatura adotada pelos autores pesquisados em GLA, e considerando que um jogo educacional pode ser enquadrado dentro da categoria de jogos sérios. De acordo com Michael e Chen (2006), os Jogos Sérios podem ser definidos como jogos digitais utilizados com propósitos que vão além do entretenimento. Esses jogos são frequentemente empregados em simulações e treinamentos nas áreas militar e médica, servem também como ferramentas de crítica social e são utilizados para promover produtos, serviços ou empresas. Os Jogos Sérios são projetados com um objetivo educacional ou de aprendizagem específico, incorporando elementos que visam aprimorar habilidades e desempenho dos jogadores (FREIRE et al., 2016; FARIAS, 2019).

Em essência, esses jogos são desenvolvidos para servir como ferramentas de ensino, focadas no desenvolvimento de competências específicas e na melhoria significativa do desempenho dos usuários em uma variedade de contextos, proporcionando experiências de aprendizagem imersivas e interativas, que não apenas transmitem conhecimentos teóricos, mas também aprimoram habilidades práticas e comportamentais, engajando e adaptando-se às necessidades de diferentes áreas de aplicação.

2.2 LEARNING ANALYTICS

O termo *analytics*, por si só, pode ser definido como o processo de descoberta ou revelação de padrões por meio de dados colhidos, tendo como propósito resolver problemas ou gerar previsões para apoiar o gerenciamento de decisões, impulsionando e/ou

melhorando o desempenho de ações (FARIAS, 2019). Desse modo, por poder se relacionar com áreas específicas, é possível possuir nomenclaturas diferentes que acompanham o termo.

Nesse sentido, integrando com o contexto educacional, tem-se *Learning Analytics*, cuja definição é dada por Nascimento, Rodrigues e Andrade (2021) como a atividade de medir, coletar, analisar e produzir relatórios de dados sobre os alunos e seus contextos, aspirando entender e otimizar a aprendizagem nos ambientes educacionais. Os autores complementam que, através dessa análise, é possível explorar dados educacionais para elucidar situações relacionadas aos processos de ensino e aprendizagem.

Em virtude da crescente coleta de dados através da utilização de ambientes virtuais de aprendizagem, a ascensão do uso da análise de aprendizagem para a melhoria do ensino nas instituições tem demonstrando cada vez mais o caminho para o qual o cenário educacional está se voltando. Com a possibilidade de facilitar a tomada de decisões, realizar intervenções ou adaptações curriculares baseadas em diferentes tipos de dados capturados dos alunos, e por ser uma técnica emergente, autores defendem que ela merece ser mais explorada devido à complexidade do processo de aprendizagem (DANIEL, 2015; LEITNER; KHALIL; EBNER, 2017; PEÑA-AYALA, 2017; WONG et al., 2019).

A adoção de LA em sala de aula pode servir para facilitar a coleta de dados de forma automática, permitindo a visualização intuitiva de informações em tempo real e mais próximas da realidade, o que antes demandaria a junção de diferentes fontes de dados ou a criação de um ou mais questionários. De acordo com Farias (2019), não usar esse tipo de abordagem gera, primeiramente, a demora em solucionar os problemas levantados, além de resultar em análises superficiais sobre o tema quando utilizadas formas tradicionais de pesquisa, gerando assim erros tanto na análise quanto na demora das intervenções, que podem ser fundamentais para o desenvolvimento daquele indivíduo ou grupo alvo.

Considerando os jogos, foco deste trabalho, ao projetar um jogo para o contexto educacional com a intenção específica de apoiar o processo de ensino e aprendizagem, ou seja, fugindo do foco no entretenimento, mas ainda assim possuindo elementos de jogos para engajar os usuários, obtemos, de acordo com Freire et al. (2016), um Jogo Sérioso. Em virtude disso, ao combinar os conceitos de *Learning Analytics* e *Game Analytics* (GA), alcançamos o ramo de estudo dessa pesquisa chamado de *Game Learning Analytics*, que coleta e analisa as ações dos alunos durante a execução de um jogo de aprendizagem (FREIRE et al., 2016), melhor explorado na próxima seção.

2.3 GAME LEARNING ANALYTICS

Compreender *Game Analytics* constitui uma etapa crucial e indispensável no processo de explorar as nuances e a complexidade de *Game Learning Analytics*. Dessa

forma, *Game Analytics* refere-se à aplicação de técnicas de análise de dados no contexto de jogos, com o objetivo de entender o comportamento dos jogadores, otimizar a experiência de jogo e melhorar o design dos jogos (FREIRE et al., 2016). Segundo a literatura, GA pode abranger desde a coleta de dados básicos de jogabilidade, como pontuações e progresso do jogador, até análises mais complexas envolvendo padrões de comportamento dos usuários e otimização de elementos do jogo para aumentar o engajamento e a retenção dos jogadores (FREIRE et al., 2016; FARIAS, 2019; SPINELLI, 2020).

Os dados coletados são, posteriormente, transformados em métricas ou indicadores, que podem ser categorizadas em genéricos e específicos de gênero (SPINELLI, 2020). Métricas ou indicadores genéricos são aplicáveis a qualquer tipo de jogo e costumam incluir, por exemplo, dados do usuário, como o total de tempo jogado, número de jogadores ativos e a taxa de retenção. Métricas ou indicadores específicos variam conforme o gênero e tema do jogo, como progressão, acertos/erros, itens utilizados e adquiridos ou transações feitas.

Game Learning Analytics é definido como um subcampo de *Game Analytics*, que foca especificamente na análise de jogos com propósitos de aprendizagem. O objetivo do GLA é extrair e analisar dados de jogos sérios para melhorar a eficácia educacional desses jogos, ajudando educadores e desenvolvedores a entender como os jogos estão sendo usados para aprender e quais aspectos dos jogos contribuem mais efetivamente para os resultados de aprendizagem (FREIRE et al., 2016; FARIAS, 2019; SPINELLI, 2020).

GLA utiliza técnicas de coleta e análise de dados para informar sobre o design do jogo, facilitar a personalização da aprendizagem e avaliar o progresso e desempenho dos jogadores em contextos educacionais. Essa análise pode ser feita por meio da visualização dos dados do comportamento de aprendizagem dos alunos, possibilitando uma comparação entre a intenção educativa do jogo com o comportamento real dos jogadores, o que permite verificar a eficácia do jogo como ferramenta de aprendizagem, determinando assim se as tomadas de decisões realizadas atingiram o efeito educacional desejado (FARIAS, 2019).

Em suma, enquanto *Game Analytics* serve como uma ferramenta ampla para entender e otimizar a experiência do jogador em diversos tipos de jogos, *Game Learning Analytics* aplica princípios semelhantes especificamente no contexto de jogos educacionais, visando aprimorar os resultados de aprendizagem e a eficácia pedagógica desses jogos. Ambos os campos representam a convergência de tecnologias de análise de dados com o design de jogos, refletindo o crescente reconhecimento do potencial dos jogos como ferramentas para engajamento e melhoria na educação.

2.4 VISUALIZAÇÃO DOS DADOS

De acordo com o livro "*Information Dashboard Design: The Effective Visual Communication of Data*", de Few (2006), o conceito de *dashboard* que conhecemos é essencialmente uma evolução dos *Executive Information Systems* (EISs), desenvolvidos inicialmente na década de 1980. Esses sistemas eram destinados principalmente a executivos, para apresentar um número limitado de medidas financeiras importantes por meio de uma interface simples. O autor relata ter assistido a algumas demonstrações dessas ferramentas que, embora fossem visionárias, não eram sustentadas pela tecnologia da época devido à falta de integração e confiabilidade dos dados. Com o desenvolvimento subsequente, na década de 1990, de sistemas de gerenciamento e análise de dados, ou *data warehousing*, processamento analítico online (OLAP) e inteligência de negócios, a fundação tecnológica foi estabelecida, permitindo que o conceito de *dashboards* evoluísse para o que é hoje.

Diante disso, a definição de um *dashboard* pode ser dada como uma exibição visual das informações mais importantes necessárias para atingir um ou mais objetivos, organizadas de maneira que um conjunto grande e complexo de dados possa ser monitorado em uma única tela (FEW, 2006; BACH et al., 2023). Essencialmente, um *dashboard* é uma ferramenta de comunicação projetada para apresentar informações compactadas e visuais de modo que sejam rapidamente compreensíveis. O *design* de um *dashboard* geralmente apresenta elementos em forma de gráficos, tabelas e indicadores, com o objetivo de facilitar a identificação rápida de problemas, oportunidades e tendências baseadas em dados, sem a necessidade de uma análise detalhada ou extensiva. Para a criação de *dashboards* eficazes, a literatura sugere o uso de diretrizes integradas que considerem tanto a organização dos dados quanto a experiência visual e interativa dos usuários. As mais comuns são a organização das informações de forma lógica e consistente, destacando apenas elementos essenciais para evitar a desordem visual; a clareza, por meio do uso de elementos, cores e fontes apropriadas; e a aplicação de princípios de percepção visual, que facilitam a interpretação rápida e precisa dos dados.

Ainda, destaca-se a importância da presença da interatividade, que permite aos usuários não apenas visualizarem, mas também interagirem com os dados por meio de detalhamento e filtros, aumentando a utilidade do *dashboard* como uma ferramenta de exploração. A personalização e as configurações ajustáveis também são importantes para adaptar o *dashboard* e atender às necessidades específicas do usuário. Além disso, os estudos atentam para a necessidade de testar o design com usuários reais antes de sua finalização, para assegurar que os componentes sejam intuitivos e eficazes. Este equilíbrio entre quantidade de informação, complexidade visual e interatividade é essencial para que a ferramenta não apenas informe, mas também engaje e seja esteticamente agradável.

Portanto, os autores atribuem o sucesso de um *dashboard* à clareza e à intuição

com que os *insights* podem ser extraídos de dados complexos e às informações importantes que são destacadas ao usuário final, utilizando os princípios de percepção visual que maximizam a compreensão humana, em vez de se limitarem a uma exibição estética de números e gráficos.

Assim como no âmbito dos EISs, o uso de *dashboards* no contexto educacional também busca representar dados de forma útil para diferentes interessados, integrando diversas fontes de dados e permitindo que os usuários tomem decisões informadas, promovendo uma melhor gestão de tempo. No entanto, devido às peculiaridades e diferenças de cada área e *software* em questão, os painéis podem servir de apoio para ferramentas como as de visualização de traços educacionais, apoio a diálogos de aconselhamento, avaliação de aprendizado, entre outras. Um exemplo a ser destacado é o projeto Integra¹, uma iniciativa da Pró-Reitoria de Graduação (PROGRAD), Pró-Reitoria de Planejamento (PROPLAN) e do Centro de Processamento de Dados (CPD), cuja finalidade é reduzir a evasão e estimular a permanência dos estudantes nos cursos de graduação da UFSM. O projeto é composto pela combinação de diferentes áreas, como *Data Science*, para avaliar e etiquetar dados, e que é complementada pela intuição humana para aumentar a acurácia; algoritmos de *Machine Learning*, que identificam padrões; e *Business Intelligence*, que fornece uma visão panorâmica desses dados aos gestores. A ferramenta apresenta os dados coletados por meio de *dashboards* de acompanhamento, que incluem o perfil do estudante, acompanhamento estudantil e análise de evasão, proporcionando o acompanhamento desde o início da vida acadêmica do aluno e uma melhor tomada de decisão por parte dos gestores.

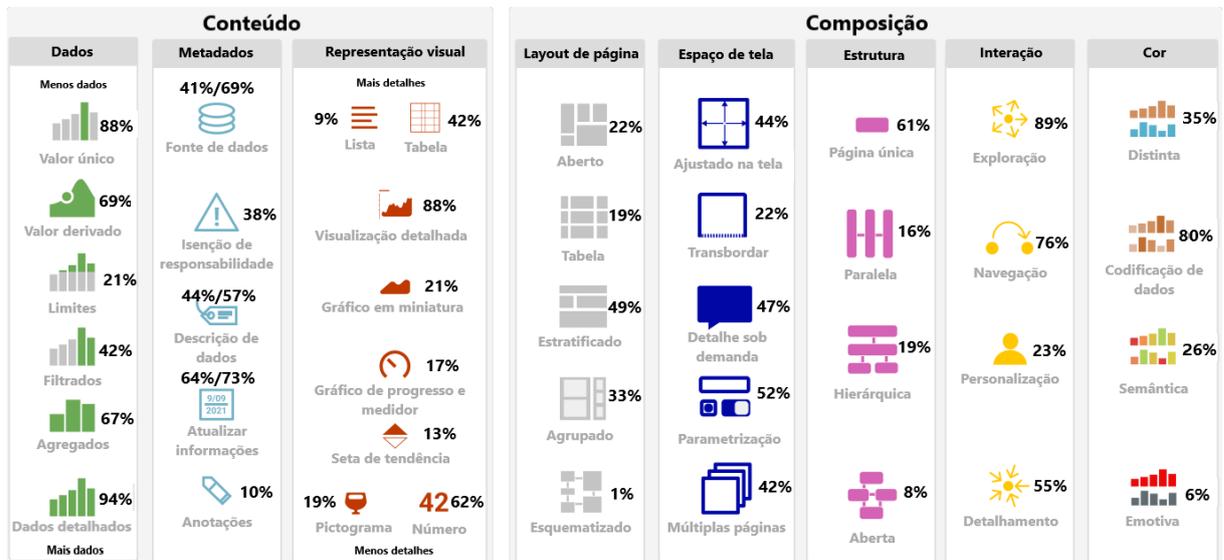
E as formas de apresentação dos dados popularmente utilizadas podem ser observadas no estudo de padrões de *design* de *dashboards* de Bach et al. (2023). A proposta do estudo é orientar o *design*, servindo como ferramenta de inspiração e compensação na hora de projetar um painel, como por exemplo, gênero, elementos, compensar espaço de tela, interação ou informações mostradas. Por meio da análise de 144 *dashboards*, os autores identificaram diferentes tipos de painel que podem ser vistos como gêneros de *design*, porque compartilham características, combinações de padrões de *design*, contextos ou objetivos específicos. Esses gêneros, posteriormente, geraram 8 grupos de padrões que fornecem soluções comuns para esses diferentes gêneros. Os 8 grupos foram separados em 2 categorias: a categoria de conteúdo, que tem como elementos os dados, metadados e a representação visual; e a categoria composição, que inclui o layout de página, espaço de tela, estrutura, interação e cor. A junção desses grupos compõe um total de 42 elementos de padrões e serve como alicerce na hora de desenvolver painéis. Apesar de relatarem limitações devido ao grande número e contextos de painéis existentes, os autores concluem que o modelo mapeia de uma forma aplicável as diretrizes, discussões e soluções mais comuns, servindo de auxílio para quem deseja projetar um *dashboard* de

¹Link de acesso para o Projeto Integra

forma eficiente.

A figura 1, adaptada de Bach et al. (2023), reúne os elementos dos 8 grupos de padrões de *design* trazidos pelos autores, juntamente com a porcentagem de painéis onde cada padrão foi observado em 144 *dashboards* analisados. De acordo com os autores, essas porcentagens podem não somar até 100%, uma vez que os padrões não são mutuamente exclusivos. Outro ponto a destacar ocorre no grupo dos metadados, em que o primeiro número representa a porcentagem de metadados explícitos, e o segundo, a de metadados implícitos em um *dashboard*.

Figura 1 – Resumo dos 8 grupos de padrões de *design*



Fonte: Adaptado de Bach et al. (2023)

2.5 O SOFTWARE EDUCACIONAL LUMNI

A história do jogo de perguntas e respostas Lumni teve seu surgimento durante o início da minha formação acadêmica. A ideia surgiu durante uma conversa que tive com alguns amigos do meu grupo de colegas da faculdade, que passavam pela mesma situação: nós gastávamos cerca de duas horas diárias em deslocamento de ônibus para a universidade, e nosso passatempo se restringia apenas a conversar e acessar redes sociais. Desde o início do curso, vislumbramos a criação de um jogo educacional que permitisse revisar ou praticar os conteúdos das aulas de forma facilitada. No entanto, com a chegada da pandemia e a interrupção das atividades presenciais na universidade, a ideia foi deixada de lado.

Em 2020, com a minha admissão e de alguns amigos no Programa de Educação

Tutorial (PET) do nosso curso, a ideia ganhou novo fôlego. Nesse contexto, uma das atividades obrigatórias como petiano era a de desenvolver projetos de pesquisa e tive a oportunidade de realizar meu primeiro projeto com a professora Lisandra Manzoni Fontoura, com quem já havia cursado a disciplina de Engenharia de *Software*. Meu primeiro projeto sob sua orientação foi intitulado "Abordagens para Desenvolvimento de *Software*: Uma Revisão da Literatura", que explorava as características, vantagens e desvantagens das abordagens ágeis do mercado. Inicialmente, comecei a pesquisa sozinho e, em seguida, formou-se o grupo com quem a finalizei, culminando no artigo para a Jornada Acadêmica Integrada (JAI), intitulado "Abordagens e Técnicas Ágeis, uma Revisão acerca de suas Vantagens e Desvantagens" (ESCOBAR; LENG RUBER; GARCIA, 2021).

Ao concluir esse projeto, percebemos a importância de conhecer e aplicar as práticas ágeis vigentes. Em conversas subsequentes com a professora Lisandra sobre possíveis novos projetos, ela sugeriu a criação de uma plataforma ou jogo educacional em formato de *quiz*, ideia que ressoava com nossos objetivos iniciais. A combinação de diferentes visões dentro do grupo culminou na concepção de um *quiz game* destinado a auxiliar docentes no monitoramento de sua turma e discentes na evolução da aprendizagem com a prática de Engenharia de Software e uma nova publicação na 37^a JAI chamada de "Lumni - Simplificando o Aprendizado de Engenharia de *Software* na Graduação" (ESCOBAR et al., 2022). Assim nasceu o Lumni, nome derivado das palavras em latim *luminis*, que significa "luz", e *alumnus/alumni*, origem da palavra "aluno". O mascote do jogo, uma lâmpada com capelo de formando, simboliza essa conexão.

Embora o projeto de pesquisa não tenha sido finalizado, ele proporcionou a base e o esboço necessários para o desenvolvimento deste trabalho atual.

3 TRABALHOS RELACIONADOS

Este capítulo apresenta os trabalhos relacionados a esta proposta, incluindo pesquisas apresentadas por Spinelli (2020), Farias (2019), Akçapinar e Hasnine (2021), Calvo-Morata et al. (2019) e Freitas et al. (2017).

Cabe ressaltar que não foram encontrados estudos que abordassem a aplicação de conceitos de Gaming Learning Analytics em um jogo no formato de perguntas e respostas, juntamente com a presença de Dashboards focados na visualização do aluno e do gestor conforme proposto nesse trabalho. Diante disso, os trabalhos selecionados contribuíram para a formação dessa ideia e foram separados nos contextos de aplicação de GLA em jogos sérios e no uso de Dashboards em ambientes gamificados.

Spinelli (2020), em seu trabalho, explora o desenvolvimento de um jogo sério focado no turismo, utilizando uma adaptação da metodologia de Serrano-Laguna et al. (2017) para analisar e potencializar o processo de aprendizagem dos jogadores através do uso de *Game Learning Analytics*. O estudo visou desenvolver um jogo utilizando a plataforma Unity, que fosse educativo e voltado ao turismo, para que pudesse auxiliar nos processos de aprendizagem, aplicando e demonstrando a eficácia do uso de GLA por meio da análise estatística do perfil dos usuários. A metodologia envolveu a coleta de dados dos jogadores, que permitiu a identificação do seu perfil pela análise do desempenho educacional de acordo com a sua idade e sexo. O jogo desenvolvido, chamado 'Olha Recife: O Jogo', empregou uma mecânica que integra desafios educativos na forma de perguntas e respostas sobre a cidade de Recife, as quais os jogadores devem responder corretamente para progredir. Os dados coletados em tempo real foram agregados e serviram para fornecer *insights* sobre o aprendizado e a eficácia do jogo. O estudo definiu 4 perfis de jogadores, os alunos, os mestres, os não-alunos e os deslocados, e observou que 72,7% dos jogadores alcançaram resultados satisfatórios na fase de domínio do jogo, com 13,6% classificados como mestres e 59,1% como alunos, perfil considerado ideal pela metodologia aplicada. Em contraste, 27,3% dos jogadores foram classificados como não-alunos, indicando resultados não satisfatórios, mas nenhum foi classificado como deslocado, o que é positivo, pois a alta presença desse perfil poderia indicar falhas nos objetivos educacionais do jogo. Adicionalmente, dentre os jogadores classificados como não-alunos, 66,7% mostraram evolução, indicando que houve melhoria no aprendizado ao longo do jogo, apesar de não atingirem a pontuação mínima para serem considerados satisfatórios. Além disso, a grande maioria dos grupos por idade demonstrou evolução na fase final do jogo, e ambos os sexos mostraram níveis semelhantes de desempenho, com uma leve vantagem para os jogadores do sexo masculino em termos de aumento nas notas da avaliação inicial para a final. O estudo concluiu que os jogos sérios não apenas engajam, mas também fornecem dados valiosos. O autor também relata o benefício da integração com o GLA,

destacando que essa combinação cria ferramentas eficazes para avaliar a efetividade e aprimorar o aprendizado dos jogadores.

Farias (2019) aborda a criação e análise de um Jogo Sério chamado ZooVS, que visa auxiliar no ensino de Zoologia utilizando *Game Learning Analytics* para analisar a eficácia do aprendizado dos jogadores. O estudo objetivou o desenvolvimento de um jogo sério para auxílio no processo de aprendizagem em Zoologia e, com o uso de GLA, comprovar sua eficácia e analisar os jogadores. A metodologia utilizada cobriu todo o processo de criação, validação e análise de um Jogo Sério, definindo os conhecimentos a serem ensinados, a identificação da população-alvo, e a integração dos objetivos educacionais na mecânica do jogo. Para o desenvolvimento do jogo, a autora optou pelo uso do *framework* LibGDX, uma ferramenta baseada em Java. O jogo foi validado através de uma avaliação formativa e somativa para garantir sua eficácia antes de ser implementado de forma mais ampla. A realização do estudo envolveu um experimento com 30 estudantes universitários de Biologia. Eles utilizaram *smartphones* para jogar o ZooVS e os dados de informações demográficas e métricas de desempenho das diversas fases do jogo de interação foram coletados automaticamente e enviados para análise via *Game Analytics* por meio de uma API REST. Esse trabalho mostrou, por meio da análise dos dados, que uma grande parte dos alunos conseguiu atingir os objetivos de aprendizado estabelecidos, com muitos sendo categorizados como "Mestres" no jogo, indicando um alto grau de conhecimento adquirido, foi também relatado que o jogo poderia ser ajustado para ser mais desafiador ou informativo, sugerindo a necessidade de personalizar ainda mais o jogo para se adequar a diversidade dos jogadores, a fim de maximizar a eficácia educacional para todos os usuários.

Akçapinar e Hasnine (2021) detalham, em "*Development and Evaluation of a Student-Facing Gamified Learning Analytics Dashboard*", o desenvolvimento e a avaliação de um *dashboard* gamificado que utiliza *Learning Analytics* destinado a estudantes. A proposta central do trabalho foi desenvolver um *Learning Analytics Dashboard* (LAD) gamificado para enfrentar o problema do baixo uso dos LADs tradicionais, atribuído à falta de motivação dos estudantes. Os objetivos foram expostos com o intuito de aumentar a motivação dos estudantes para utilizar o LAD, proporcionando uma ferramenta que apoiasse a autorregulação e o envolvimento dos alunos por meio de elementos gamificados. A metodologia empregada envolveu, em sua primeira fase, o *design* e a implementação usando a arquitetura do sistema Moodle, com gamificação incorporada por meio de elementos como pontos, barras de progresso e placares de liderança. Os dados dos alunos foram coletados do Moodle e analisados usando métodos de aprendizado de máquina para fornecer *feedback* e previsões de desempenho. Posteriormente, foi feita a definição dos elementos do *dashboard*, os quais foram projetados para interagir com os alunos, incluindo painéis de notificação, gráficos de atividades diárias, radares de atividades, painéis de previsão e fóruns de atividades. Esses elementos utilizavam métricas calculadas a partir dos dados

de atividade dos alunos para fornecer *feedback* e estimular o engajamento. A avaliação da ferramenta envolveu 64 alunos de um curso de *hardware*, e demonstrou que 95% dos alunos visitaram o *dashboard* várias vezes ao longo do semestre. Os estudantes relataram que consideraram o *dashboard* útil, fácil de usar e afirmaram que gostariam de usá-lo em outros cursos. A avaliação do estudo constatou que a gamificação teve um impacto positivo no envolvimento e na motivação dos estudantes. Os autores observaram uma correlação positiva entre o uso frequente do *dashboard* e a percepção de sua utilidade, além do aumento do envolvimento dos alunos. O artigo também discute a importância de considerar diferentes métricas e elementos de *design* para manter os alunos engajados e motivados. Por fim, os autores concluem que o estudo fornece *insights* valiosos sobre como os painéis de análise de aprendizagem podem ser projetados com a adição de elementos de gamificação para melhorar a interação e o engajamento dos alunos em ambientes virtuais de aprendizagem, especialmente em um contexto onde a motivação para utilizar tais dinâmicas pode ser baixa.

Calvo-Morata et al. (2019), no artigo "*Improving Teacher Game Learning Analytics Dashboards through ad-hoc Development*", propuseram melhorar a integração e a utilidade dos *dashboards* de GLA no contexto educacional, tornando-os uma ferramenta mais eficaz e centrada nas necessidades dos professores e dos contextos de aprendizagem. A pesquisa aborda a limitação dos *dashboards* genéricos, que muitas vezes não atendem às expectativas dos professores por não fornecerem informações suficientemente detalhadas ou relevantes para a análise pedagógica. Assim, o objetivo principal da pesquisa era buscar melhorar a adoção e eficácia de jogos sérios em ambientes educacionais, facilitando para os professores a análise e interpretação dos dados de desempenho dos alunos durante as atividades de jogo. A metodologia do estudo foi detalhada e centrada em abordagens de desenvolvimento colaborativo e adaptativo. A pesquisa adotou um processo iterativo para o desenvolvimento de *dashboards* personalizados, trabalhando em estreita colaboração com os professores e desenvolvedores de jogos para garantir que as visualizações sejam pedagogicamente relevantes e facilmente interpretáveis pelos educadores. O desenvolvimento *ad hoc* de *dashboards* específicos do jogo fundamentou-se na avaliação através de estudos de caso para entender como essas adaptações melhoram a eficácia dos *dashboards* genéricos. O processo também envolveu a coleta e análise de dados das interações dos alunos com os jogos, utilizando o padrão *Experience API for Serious Games Profile* (xAPI-SG), que define um conjunto de interações que são usuais em jogos sérios. Como conclusão, os autores relatam que *dashboards* personalizados para análise de aprendizado em jogos oferecem um valor agregado significativo para os professores, facilitando intervenções pedagógicas mais informadas e oportunas. Também recomendaram a participação das partes interessadas no desenvolvimento, enfatizando a importância da flexibilidade nos sistemas de análise para acomodar as necessidades específicas, evidenciando que a tecnologia pode ser adaptada para melhorar ferramentas de

ensino e aprendizado em contextos reais.

Freitas et al. (2017) discutem em seu trabalho o uso de *dashboards* gamificados e *learning analytics* para fornecer *feedback* imediato e acompanhamento de desempenho de estudantes no ensino superior. O estudo investiga como os *dashboards* gamificados podem ser utilizados para melhorar a experiência de aprendizagem, aumentando a motivação, o engajamento e, conseqüentemente, o desempenho dos estudantes. Sua proposta principal é baseada em explorar e avaliar como as técnicas de gamificação e análise de aprendizado podem ser incorporadas em *dashboards* para fornecer *feedback* em tempo real aos estudantes. Para isso foram utilizados *dashboards* em diferentes contextos universitários no Reino Unido, Bélgica e Austrália através das plataformas StarQuest, Curtin Challenge, Navi Badgeboard e Navi Surface, que utilizam elementos comuns de jogos, como pontos, níveis e progressão, mas que abordam também a análise de comportamento dos usuários e visualização interativa das informações para apresentar dados de desempenho e *feedback* de maneira atraente e motivadora. Os resultados destacaram fatores comuns entre as plataformas, detalhando como as principais vantagens do uso da gamificação, visualização e aprendizagem baseada em desafios contribuíram para aumentos significativos na motivação e no engajamento dos estudantes, além de melhorias no desempenho e na retenção. A aplicação desses *dashboards* gamificados proporcionaram, aos mais de 100 estudantes que participaram da dinâmica de avaliação, um meio visual e interativo de monitorar seu próprio progresso e ajustar suas estratégias de aprendizagem em resposta ao *feedback* recebido.

Com isso, considera-se evidente que estas ferramentas são dotadas de variedade de recursos valiosos que podem servir para captar ideias e materiais didáticos. Observa-se que alguns desses recursos guardam uma notável semelhança com as funcionalidades que foram cuidadosamente modeladas no design desta aplicação. Estes foram utilizados como referência crucial para o enriquecimento do nosso sistema. Além disso, *insights*, discussões e funcionalidades inovadoras identificadas foram meticulosamente avaliadas e consideradas para integração nas etapas futuras do desenvolvimento, visando continuamente aprimorar e expandir a capacidade e a eficácia do jogo.

4 ASPECTOS METODOLÓGICOS

Para sistematizar o desenvolvimento desse trabalho, foi elaborado o quadro 1, que elenca as etapas que serão realizadas.

Quadro 1 – Etapas do trabalho.

1ª Etapa - Revisão Bibliográfica
- Revisão sobre GLA; - Revisão sobre Visualização de Dados; - Análise de trabalhos correlatos.
2ª Etapa - Ajustes e definições
- Implementação de melhorias e correção de problemas antigos do jogo; - Definição dos dados a serem coletados; - Definição de diretrizes e melhores práticas para o <i>dashboard</i> ; - Design do <i>Dashboard</i> .
3ª Etapa - Desenvolvimento
- Inserção no banco de dados dos campos que serão utilizados para coleta; - Criação dos algoritmos de <i>analytics</i> no back-end da aplicação; - Implementação do <i>dashboard</i> no front-end da aplicação.
4ª Etapa - Avaliação da aplicação
- Avaliação da usabilidade e da aceitação da aplicação; - Análise dos resultados dos <i>feedbacks</i> .

Fonte: o autor

Para a realização desse trabalho utilizou-se, inicialmente, o estudo de Serrano-Laguna et al. (2017), que aborda a aplicação de padrões para sistematizar o uso de *Learning Analytics* em jogos sérios. O trabalho apresenta a perspectiva de que os jogos sérios possuem duas estratégias de interação - baseadas em estados e eventos. A estratégia de interação baseada no estado envolve a troca constante de informações, amplamente utilizada em jogos de simulação que dependem da verificação do ambiente e da situação do jogo, permitindo ajustes imediatos e proporcionando uma experiência de jogo dinâmica e envolvente. Já a outra estratégia é baseada em eventos previamente especificados, que são registrados quando ocorrem e geralmente incluem informações como tipo de evento, data e hora, e identificador do jogador. Este tipo é muito utilizado em jogos nos quais os eventos específicos são mais importantes do que o estado contínuo do jogo, assim, por ser mais adequado ao modelo de jogos de perguntas e respostas, foi utilizado neste estudo.

Serrano-Laguna et al. (2017) propõem um modelo que pode ser utilizado e adaptado para jogos que possuam ou não um nível mais refinado de detalhes de rastreamento de interações. Dessa forma, é possível abranger diferentes estilos de jogo, mecânicas e gêneros. De acordo com os autores, para gerar *insights* e cálculos de desempenho, as variáveis precisam ser significativamente mensuráveis; as mais comuns são aquelas que envolvem números e que são representadas em forma de pontuações, fases completadas,

moedas coletadas, etc. Todas essas variáveis devem estar ligadas ao desempenho do jogador e/ou ao objetivo proposto pelo jogo e são elas que formarão o conjunto básico para a geração das métricas ou indicadores. No entanto, destaca-se que, embora existam eventos e interações comuns, adaptar-se à necessidade do público-alvo e ao uso de interações específicas de cada jogo também é fundamental para avaliar o desempenho do usuário.

O trabalho de Serrano-Laguna et al. (2017) também apresenta um modelo de dados, comunicação e organização de eventos criado por uma comunidade aberta, denominado *Experience API* (xAPI), e utiliza JSON para gerenciar os fluxos de atividades. O xAPI estabelece uma abordagem metódica para rastrear eventos em atividades de aprendizado, definindo cada evento capturado como uma *'instrução'*. O xAPI define componentes que incluem:

1. **Ator:** Desempenha a ação;
2. **Verbo:** Descreve a ação realizada;
3. **Objeto:** O alvo ou o conteúdo da ação.

Essa configuração garante uma descrição completa e precisa das interações educacionais, permitindo um mapeamento detalhado e uma estrutura organizada dos processos de aprendizagem, o que servirá para melhor organizar a aplicação de GLA no Lumni.

No que tange à criação da visualização dos dados, o quadro do trabalho "*Dashboard Design Patterns*" de Bach et al. (2023) foi adotado por reunir as principais diretrizes de forma clara e aplicável, não apenas como uma ferramenta de referência, mas também como um facilitador crucial no processo de *design* do *dashboard*, fornecendo a oportunidade de navegar pelas opções disponíveis e tomar decisões informadas.

Suplementarmente ao exposto acima, para a criação e modificação das interfaces do usuário deste trabalho, optou-se também por fundamentar o *design* nos princípios estabelecidos por Jakob Nielsen (1994) em "*10 Usability Heuristics for User Interface Design*". Essas heurísticas abrangem uma ampla gama de princípios e fornecem uma base sólida para garantir a usabilidade e a funcionalidade do sistema, criando uma experiência de usuário que não só atende às expectativas de funcionalidade e eficiência, mas também promove uma interação agradável e intuitiva.

Para a avaliação da aceitação da tecnologia desenvolvida será utilizado o modelo *Technology Acceptance Model* (TAM), de Davis (1989), considerado um influente modelo teórico que estabelece uma estrutura essencial para compreender a aceitação de tecnologias da informação entre os usuários finais. O TAM propõe que a intenção de uso de uma tecnologia é moldada por duas percepções-chave: a facilidade de uso percebida e a utilidade percebida da tecnologia. Em decorrência disso, foi elaborado o questionário do quadro 2, embasado nos critérios estabelecidos pelo TAM. Suas respostas serão analisadas e servirão para identificar as razões subjacentes à aceitação ou rejeição da tecnologia

por parte dos usuários. Cada item abaixo foi formulado para capturar a Facilidade de Uso Percebida (FUP) e a Utilidade Percebida (UP) do jogo em questão. O formulário de avaliação foi disponibilizado juntamente com o sistema a um grupo composto por dezessete (17) estudantes de diferentes cursos da área de computação.

Quadro 2 – Questões para a Análise da Aceitação de Tecnologia

Item	Indicador	Questão
1	FUP01	Minha interação com o jogo foi clara e compreensível.
2	FUP02	Utilizar as ferramentas/mecânicas do jogo não exige muito do meu esforço mental.
3	FUP03	Considero fácil usar o jogo para reforçar meu aprendizado sobre os tópicos abordados.
4	FUP04	Considero o jogo fácil de utilizar.
5	FUP05	Considero o <i>dashboard</i> fácil de utilizar.
6	FUP06	Minha interação com o <i>dashboard</i> foi clara e compreensível.
7	FUP07	Considero fácil usar o <i>dashboard</i> para localizar lacunas de aprendizado.
8	UP01	Jogar o quiz melhora minha retenção de conhecimento e produtividade no estudo.
9	UP02	O jogo fornece adequadamente um <i>feedback</i> em tempo real que ajuda no meu processo de aprendizagem.
10	UP03	A utilização do jogo é importante para meu engajamento e aprendizado continuado.
11	UP04	O layout do <i>dashboard</i> é organizado e fácil de entender.
12	UP05	O <i>dashboard</i> fornece monitoramento que ajuda identificar áreas em que preciso melhorar.
13	UP06	O <i>dashboard</i> oferece insights valiosos que não são facilmente obtidos apenas através dos resultados dos quizzes.

Ainda no contexto da avaliação, será utilizada a escala *SUS System Usability Scale*, uma abordagem de pesquisas padronizadas e amplamente adotada para a avaliação da usabilidade. Desenvolvido por Brooke (1996), o SUS é uma das ferramentas mais aplicadas para mensurar a percepção de usabilidade de um sistema ou produto, fornecendo uma medida abrangente e de confiança. De acordo com Nielsen (2012), a usabilidade pode ser caracterizada como um atributo de qualidade que mede quão fácil é a interação com uma interface. E o uso do método SUS serve de aparato para avaliar o seus componentes essenciais, sendo, de acordo com o autor, os cinco itens a seguir:

1. **Capacidade de aprendizagem:** quão intuitivo é o sistema ao ser usado pela primeira vez;
2. **Eficiência:** a velocidade com que as tarefas podem ser concluídas;
3. **Memorização:** a facilidade com que o usuário consegue recordar como operar o sistema após um período sem uso;

varia de 0 a 100. A partir da pontuação obtida, é possível classificar a usabilidade do sistema. Como base, foi utilizada a proposta de classificação adaptada de Bangor, Kortum e Miller (2008), apresentada no quadro 4.

Quadro 4 – Pontuação SUS

Pontuação	Adjetivo
90.0 - 100.0	Melhor imaginável.
80.0 - 89.9	Excelente.
70.0 - 79.9	Bom.
60.0 - 69.9	Ok.
50.0 - 59.0	Ruim.
<49.9	Muito ruim.

Fonte: Adaptado de Bangor, Kortum e Miller (2008).

4.1 FERRAMENTAS UTILIZADAS

O jogo foi construído desde o seu início com a ideia da utilização de diferentes ferramentas que integrassem as melhores práticas e tecnologias modernas de desenvolvimento web. Diante disso, o jogo foi desenvolvido utilizando React.JS com a biblioteca Material-UI no *front-end*, Adonis.JS no *back-end*, PostgreSQL como sistema de gerenciamento de banco de dados, Figma para o design e Insomnia para testes de API.

A ideia de se utilizar React.JS, uma biblioteca de JavaScript para construção de interfaces de usuário, veio da popularidade de ter sido criada pela *bigtech* Meta, antigo Facebook, e a possibilidade de desenvolver componentes reutilizáveis, garantindo uma manutenção mais fácil e um código mais limpo. E como forma de complemento a possibilidade de integrar com a biblioteca de componentes Material-UI, que implementa o Material Design do Google. Essa escolha permitiu a criação de interfaces responsivas e com uma base de design já conhecida, oferecendo aos usuários finais uma experiência visual coesa e agradável.

Para prototipação e *design* de telas foi utilizado o Figma. Durante a criação do *dashboard* a ferramenta facilitou o desenvolvimento e possibilitou uma melhor visão de como ficaria o produto final.

Também foi utilizado como ferramenta de apoio para implementação do *design* gerado a biblioteca Recharts de componentes de gráficos baseada para React.JS, que facilita a criação de gráficos dinâmicos e interativos para aplicações *web*. Dessa forma, foi possível incorporar gráficos interativos e customizáveis, oferecendo uma boa combinação de simplicidade, flexibilidade e poder gráfico.

Para o back-end foi feita a escolha do Adonis.JS, um *framework* Node.JS que ofe-

rece uma estrutura robusta para construir aplicações *web* e *API's*. A arquitetura em MVC permitiu que a organização do código e a implementação de funcionalidades complexas fosse realizada de forma facilitada. Além disso, o suporte já integrado de autenticação e segurança permitiu criar uma *API Rest* que fornecesse os dados de forma segura para alimentar o *front-end*.

Como sistema de gerenciamento de banco de dados relacional, foi adotado o PostgreSQL que, por ter desempenho, robustez e conformidade com padrões SQL aprendidos nas disciplinas da graduação, facilitou o desenvolvimento.

Como ferramenta de teste e documentação de *API* foi utilizado o Insomnia. Que permite o envio de requisições HTTP e a visualização de respostas. Durante todo o desenvolvimento a ferramenta se tornou crucial para garantir a organização das rotas, verificação de respostas e a qualidade do *back-end*.

Como ferramenta de hospedagem de código-fonte e controle de versão, foi utilizada a plataforma GitHub, que utiliza o sistema de versionamento Git. Essa plataforma possibilita o acompanhamento detalhado de alterações, o gerenciamento eficiente e a integração de novas funcionalidades de maneira organizada, por meio de *branches* e *pull requests*. Além disso, o GitHub possui uma interface intuitiva e integração com a IDE utilizada.

Para a criação do ambiente de avaliação, foi utilizada a plataforma como serviço (*PaaS*) Heroku, que facilita a hospedagem, os testes em produção, o gerenciamento e o escalonamento de aplicações sem a necessidade de se preocupar com uma infraestrutura. Essa plataforma foi escolhida devido à sua simplicidade, integração com ferramentas utilizadas como o GitHub e o PostgreSQL, *deploy* automático de *commits* realizados, suporte a múltiplos ambientes e fácil escalabilidade.

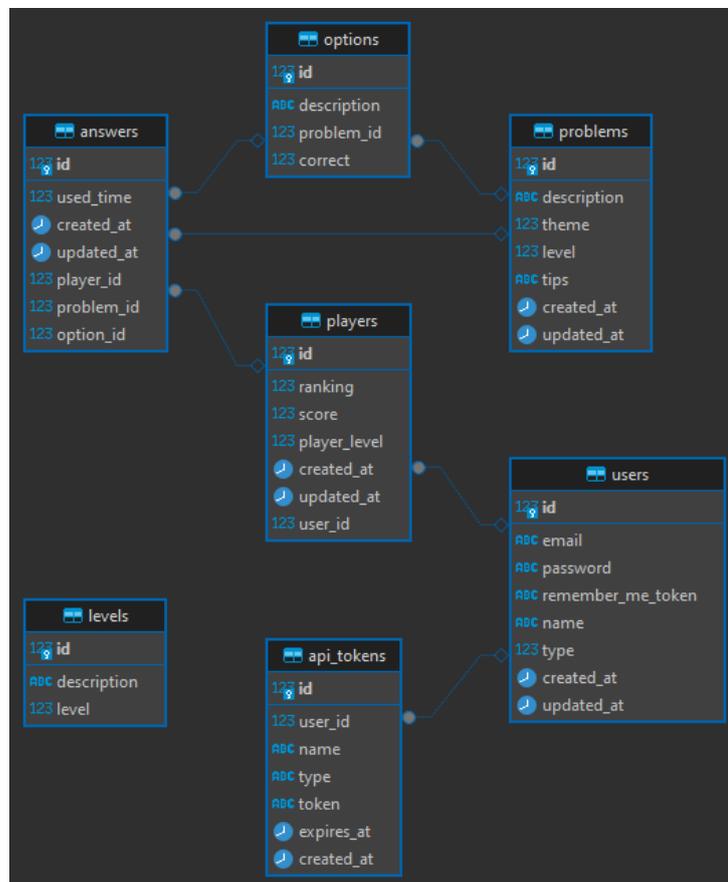
5 DESENVOLVIMENTO

Este capítulo apresenta o desenvolvimento e os resultados obtidos no projeto, destacando o progresso das mudanças no jogo, na implementação do GLA e na criação do *dashboard*. Cada seção detalha os avanços específicos, os ajustes realizados e as implementações concretizadas até o momento.

5.1 FERRAMENTA ATUAL E AJUSTES

Inicialmente, apresenta-se o esquema do banco de dados relacional utilizado pelo Lumni, que pode ser visualizado na Figura 3. Este esquema fornece uma base sólida para um sistema interativo onde os jogadores podem responder a perguntas, serem pontuados e comparados com base em suas pontuações e tempos de resposta. Esse esquema permite uma variedade de consultas e relatórios sobre o comportamento e desempenho dos jogadores.

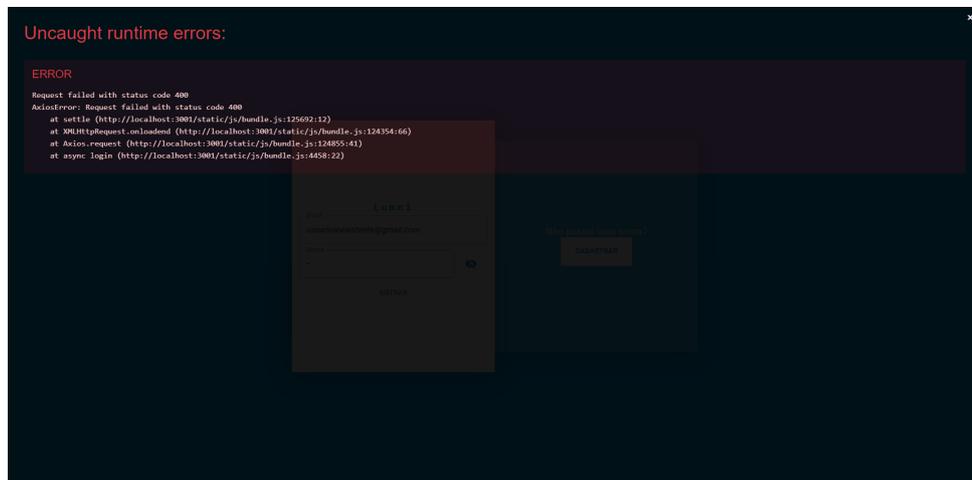
Figura 3 – Diagrama Relacional do Lumni



Com o objetivo de aprimorar a experiência do usuário, o sistema passou por uma série de modificações que tiveram enfoque em otimizar a usabilidade, gerar mais segurança e melhorar as funcionalidades disponíveis. A necessidade dessas revisões foram elencadas através de um extenso uso por parte do autor que identificou a necessidade de corrigir e refinar o sistema antes de disponibilizá-lo aos usuários.

Inicialmente, foram implementadas verificações e avisos ao realizar a autenticação no jogo, para melhorar a interação e compreensão do usuário. No modelo anterior, não havia tratamento de erros, e era comum o usuário ser redirecionado para uma página padrão do React.JS, que possuía informações mais técnicas. As figuras 4, 5 e 6 mostram essas questões.

Figura 4 – Antigo aviso de erro ao digitar e-mail ou senha incorretos



Fonte: o autor

Figura 5 – Aviso de erro ao digitar e-mail ou senha incorretos

A interface de login do sistema 'Lumni' apresenta dois campos de entrada: 'Email' com o endereço 'usuarioinexistente@gmail.com' e 'Senha' com um caractere visível. Abaixo dos campos, há um botão 'ENTRAR' em azul. Uma mensagem de erro em vermelho, 'Email ou senha inválidos', está exibida na parte inferior da seção de login. À direita, sobre um fundo escuro, há o texto 'Não possui uma conta?' e um botão 'CADASTRAR' em branco.

Fonte: o autor

Figura 6 – Novo aviso de erro ao preencher os campos

A interface de login do sistema 'Lumni' é idêntica à da Figura 5, com o mesmo e-mail e senha incorretos. No entanto, a mensagem de erro em vermelho agora diz 'Por favor, preencha todos os campos', indicando uma validação de preenchimento obrigatório. O resto da interface, incluindo o botão 'ENTRAR' e a seção de cadastro à direita, permanece inalterada.

Fonte: o autor

Foram adicionados a permissão e o nome do usuário à barra de navegação, e ajustada a visibilidade das opções com base no perfil do usuário autenticado. Anteriormente, o sistema permitia que alunos acessassem funcionalidades de criação e exclusão de perguntas. As figuras 7 e 8 destacam o que foi corrigido para reforçar a segurança e a integridade do sistema.

Figura 7 – Nova barra de navegação do aluno



Fonte: o autor

Figura 8 – Nova barra de navegação do professor



Fonte: o autor

Também foram realizadas modificações na tela de criação e edição de perguntas para melhor atender ao professor. Anteriormente, ao iniciar a criação de uma pergunta, o professor já recebia uma caixa com cinco alternativas, e a criação de uma pergunta de verdadeiro ou falso só era possível por meio de um artifício que consistia em preencher apenas duas alternativas.

O mesmo acontecia ao editar as perguntas. Como forma de correção, foram criados dois botões para adicionar e remover alternativas, além de verificações para garantir que não existam perguntas com menos de duas alternativas. Também foi criada uma lógica para percorrer as alternativas vindas na resposta da requisição, de modo que, ao editar uma pergunta, sejam mostradas apenas o número de alternativas que ela possui, evitando mostrar alternativas em branco. As figuras 9, 10, 11 e 12 demonstram as problemáticas e as correções.

Figura 9 – Antiga criação de perguntas

Adicionar Pergunta

Pergunta

6 Respostas

a)

b)

c)

d)

e)

Seleção a categoria

Nível da Questão

Fonte: o autor

Figura 10 – Nova criação de perguntas

Adicionar Pergunta

Pergunta

2 Alternativas

a)

b)

Nível da Questão

Seleção a categoria

Fonte: o autor

Figura 11 – Antiga edição de perguntas

The screenshot shows a web interface titled "Editar Pergunta". At the top, there is a text input field labeled "Pergunta" containing the text "verdade ou falso". Below this, it says "6 Respostas". There are five radio button options labeled a) through e). Option a) is selected and has a text input field with "verdade". Option b) has a text input field with "falso". Options c), d), and e) have empty text input fields. At the bottom left, there is a dropdown menu labeled "Nível da Questão" with "Nível 1" selected. To its right is another dropdown menu labeled "Selecione a categoria" with "Scrum" selected. A blue button labeled "EDITAR +" is positioned to the right of the category dropdown.

Fonte: o autor

Figura 12 – Nova edição de perguntas

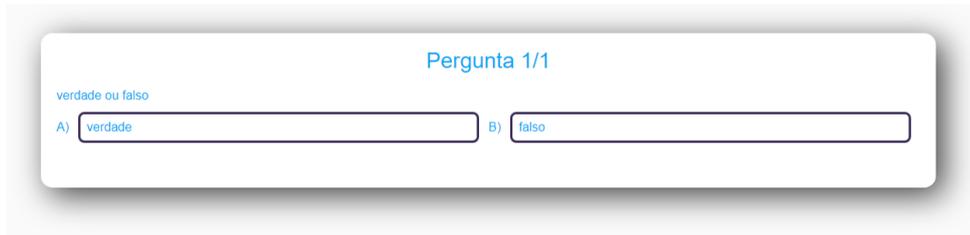
The screenshot shows a web interface titled "Editar Pergunta". At the top, there is a text input field labeled "Pergunta" containing the text "verdade ou falso". Below this, it says "2 Alternativas". There are two radio button options labeled a) and b). Option a) is selected and has a text input field with "verdade". Option b) has a text input field with "falso". At the bottom left, there is a dropdown menu labeled "Nível da Questão" with "Fácil" selected. To its right is another dropdown menu labeled "Selecione a categoria" with "Scrum" selected. A blue button labeled "EDITAR PERGUNTA +" is positioned to the right of the category dropdown.

Fonte: o autor

Ainda, foram realizadas alterações com o objetivo de melhorar a experiência do jogador e aprimorar os elementos de jogos já utilizados. Ao iniciar o quiz, o jogador recebia apenas a pergunta e as possíveis alternativas. Com o objetivo de proporcionar mais desafio e aumentar a dificuldade, foram adicionados o tempo decorrido e o nível da pergunta que está sendo respondida. Também foram implementados botões para pular a pergunta ou encerrar o jogo, adequando-se às heurísticas de usabilidade Controle, Liberdade e Pre-

venção de erros de Jakob Nielsen (1994). As figuras 13, 14, 15 e 16 destacam essas modificações.

Figura 13 – Antiga tela da partida do quiz



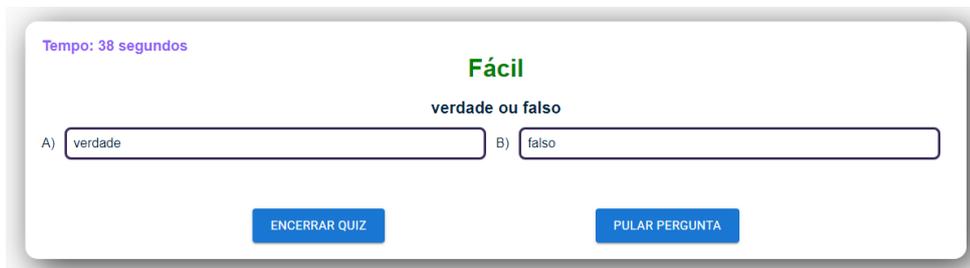
Pergunta 1/1

verdade ou falso

A) B)

Fonte: o autor

Figura 14 – Nova tela da partida do quiz



Tempo: 38 segundos

Fácil

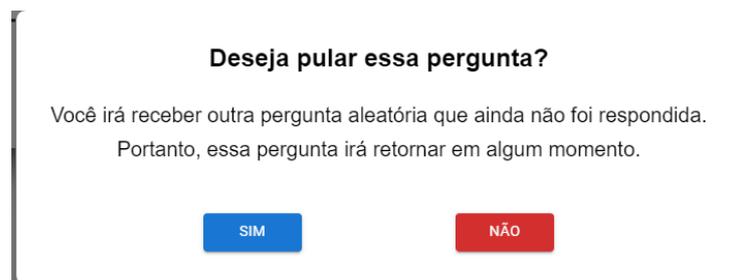
verdade ou falso

A) B)

ENCERRAR QUIZ **PULAR PERGUNTA**

Fonte: o autor

Figura 15 – Modal de prevenção de erro ao pular pergunta



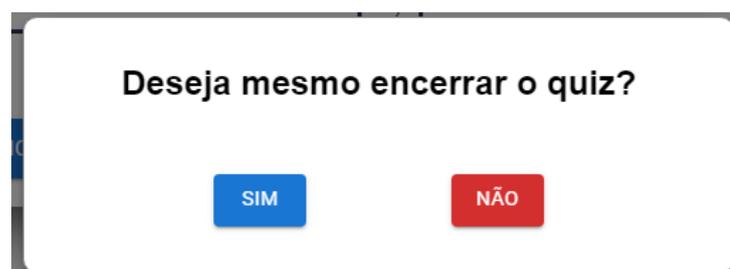
Deseja pular essa pergunta?

Você irá receber outra pergunta aleatória que ainda não foi respondida.
Portanto, essa pergunta irá retornar em algum momento.

SIM **NÃO**

Fonte: o autor

Figura 16 – Modal de prevenção de erro ao encerrar a jogatina



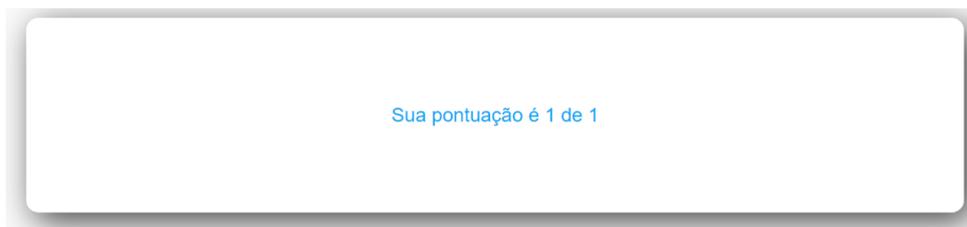
Deseja mesmo encerrar o quiz?

SIM **NÃO**

Fonte: o autor

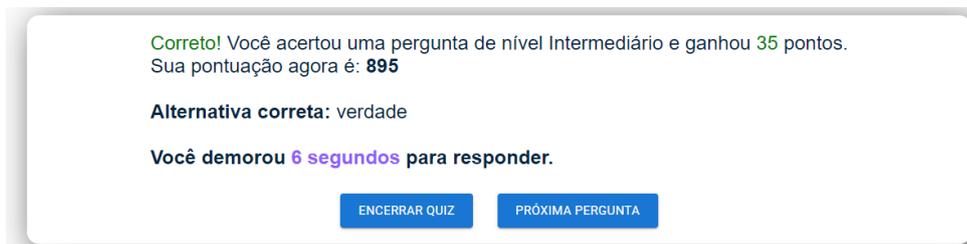
Seguindo a mesma lógica de melhorias nos elementos de jogos, bem como dos aspectos educacionais, foi implementado um sistema de *feedback* em tempo real que é ativado assim que uma pergunta é respondida. Esse mecanismo detalha o motivo do acerto ou do erro, exibe a alternativa selecionada pelo jogador e atualiza a pontuação imediatamente, proporcionando uma experiência de aprendizagem mais interativa e informativa. As figuras 17, 18 e 19 demonstram como estava implementado o único sistema de *feedback* e como passou a ser.

Figura 17 – Antiga tela de *feedback*



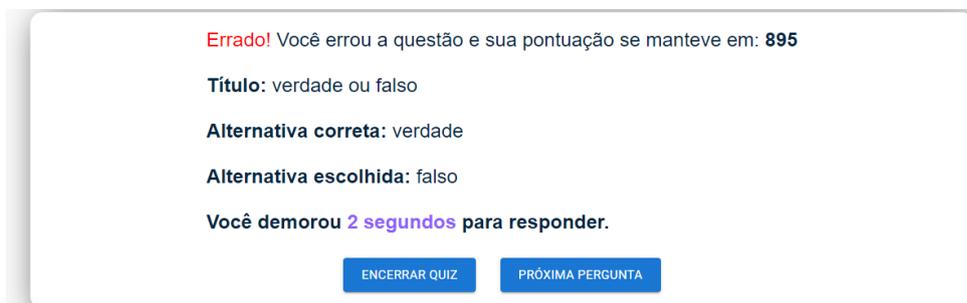
Fonte: o autor

Figura 18 – Nova tela de *feedback* com acerto



Fonte: o autor

Figura 19 – Nova tela de *feedback* com erro



Fonte: o autor

Apesar de o jogo anteriormente possuir a estrutura no banco de dados para acolher um placar e diferentes níveis, essas funcionalidades não haviam sido implementadas. Para que o jogo oferecesse um cenário de imersão e competitividade entre os jogadores, foi adicionada uma nova tela de placar, bem como uma lógica para adicionar pontos a cada

pergunta correta e um sistema de nível que progressivamente aumenta a dificuldade e altera o *rank* do jogador.

A lista a seguir representa as pontuações obtidas de acordo com a dificuldade das perguntas que eles conseguem responder corretamente. Esse tipo de sistema incentiva os jogadores a enfrentarem desafios maiores para obter recompensas mais substanciais, promovendo uma experiência de jogo mais envolvente e educativa.

1. Acerto de pergunta de nível Fácil - 10 pontos;
2. Acerto de pergunta de nível Intermediario - 35 pontos;
3. Acerto de pergunta de nível Difícil - 75 pontos;

Basicamente, o sistema de progressão de níveis (Figura 20) no método é baseado em um modelo em que cada nível requer o dobro de pontos do nível anterior para ser alcançado. Primeiramente a função tenta encontrar um jogador pelo *id* que foi passado como parâmetro na requisição. Se não encontrar, lança um erro. A progressão ocorre por meio de um *loop* ou laço *while* para incrementar o nível do jogador enquanto a pontuação do jogador for maior ou igual à pontuação necessária para o próximo nível. A cada iteração, o nível é incrementado e a pontuação necessária é multiplicada pelo *multiplicador*. O *valorInicial* de 100 pontos é o número de pontos necessário para o jogador atingir o segundo nível. O primeiro nível é assumido por padrão até que o jogador ultrapasse esses 100 pontos. Após isso, é utilizado o *multiplicador* de 2 que configura o fator pelo qual a pontuação necessária para alcançar o próximo nível aumenta após cada nível, gerando uma progressão geométrica. O nível calculado é atribuído ao campo *player_level* do jogador, e as mudanças são salvas no banco de dados com a função *.save()* nativa do Adonis.JS. A figura 20 demonstra de forma mais técnica o que foi citado.

Figura 20 – Lógica no *back-end* que controla a pontuação e os níveis

```
public async addScore({ request, response }: HttpContextContract) {
  const player = await Player.findByOrFail('id', request.param('id'))
  const score = request.input('addScore')
  player.score = player.score + score

  const valorInicial = 100;
  const multiplicador = 2;
  let nivel = 1;
  let pontuacaoNecessaria = valorInicial;

  while (player.score >= pontuacaoNecessaria) {
    nivel++;
    pontuacaoNecessaria *= multiplicador;
  }
  player.player_level = nivel
  await player.save()
  return response.ok({ player })
}
```

Um exemplo para melhor visualizar o funcionamento do sistema de pontuação e dos seus níveis pode ser demonstrado da seguinte forma:

1. Do Nível 0 (Espectador) para o 1 (Noob): a pontuação necessária será maior que 0;
2. Do Nível 1 (Noob) para o 2 (Bixo): a pontuação necessária será 100;
3. Do Nível 2 (Bixo) para o 3 (Script Kiddie): a pontuação necessária será 200;
4. Do Nível 3 (Script Kiddie) para o 4 (Veterano): a pontuação necessária será 400;
5. Do Nível 4 (Veterano) para o 5 (Nerd): a pontuação necessária será 800;
6. Do Nível 5 (Nerd) para o 6 (Try Harder): a pontuação necessária será 1600;
7. Do Nível 6 (Try Harder) para o 7 (Scrum Master): a pontuação necessária será 3200;

Portanto, com 450 pontos, o jogador estará no nível 4, pois superou os 400 pontos necessários. A progressão se torna exponencialmente mais difícil à medida que os níveis aumentam, requerendo sempre o dobro de pontos do nível anterior para avançar. Este sistema mantém os jogadores engajados, pois cada novo nível alcançado é mais desafiador que o anterior, incentivando o desenvolvimento de habilidades ou a dedicação prolongada ao jogo.

Conforme mencionado anteriormente, também foi criada uma tela de placar que serve como uma ferramenta multifuncional. Ela busca não somente aumentar a competição e a motivação entre os jogadores, mas também reforça comportamentos positivos, facilita a socialização e a comunidade, e oferece um indicador claro de desempenho e sucesso. Ao exibir as pontuações mais altas, o placar define *benchmarks* ou padrões que outros jogadores aspiram alcançar, fazendo com que os alunos se esforcem mais, aplicando o que aprenderam para melhorar suas pontuações. Além disso, o placar também estabelece metas mais claras e tangíveis, como alcançar o topo, atingir um certo nível ou ultrapassar um amigo. Para o professor, o placar pode auxiliar em uma rápida visualização do desempenho geral da turma. Isso inclui quem está se destacando e quem pode estar precisando de ajuda adicional, permitindo uma intervenção educacional mais direcionada e eficaz. A figura 21 demonstra o placar criado.

Figura 21 – Placar

Ranking				
Rank	Nome	Título	Nível	Pontuação
	aluno 1	Veterano	Nível 4	735
	aluno teste	Espectador	Nível 0	0
	aluno 3	Espectador	Nível 0	0

Linhas por página: 5 ▾ 1-3 of 3 |< < > >|

Fonte: o autor

5.2 IMPLEMENTAÇÃO DO GLA

Para a implementação do GLA no Lumni, algumas definições foram estabelecidas com base nos trabalhos mencionados anteriormente. Nesse contexto, adotou-se a ideia do modelo de rastreamento de avaliação proposto por Serrano-Laguna et al. (2017), adaptando-o para aplicação no cenário deste trabalho e em um jogo que registra eventos pré-definidos, tais como o registro de uma pergunta respondida. Conforme descrito pelo autor, a maioria dos jogos sérios utiliza, no mínimo, dois atributos para o registro de cada evento. Os atributos mais comuns são o número de identificação do usuário e um carimbo de data e hora. Normalmente, estes acompanham também uma ação e um alvo que recebe a ação, além de campos adicionais que complementam o evento registrado. Esses dados permitem que os pesquisadores obtenham métricas ou indicadores relevantes, como o número total de jogadores, a frequência de acesso ao jogo, o tempo total de jogo e os resultados das ações.

O modelo utilizado neste trabalho, adaptado de Serrano-Laguna et al. (2017), pode ser visto quadro 5.

Quadro 5 – Mapeamento de campos de evento de interações para atributos de instrução xAPI

Campo de evento de interação	Atributos de declaração do xAPI	Descrição
idUsuario	ator	Identifica o jogador que gerou o evento
acao	verbo	Representa o tipo de interação realizada pelo jogador
alvo	objeto	O elemento de jogo que é o objetivo da ação do jogador
valor (opcional)	resultado (opcional)	Os parâmetros da ação
carimbo_data_hora	carimbo_data_hora	Representa o instante em que o evento aconteceu no jogo

Fonte: Adaptado de Serrano-Laguna et al. (2017).

Todos esses atributos são necessários para que a implementação do GLA ocorra, exceto o '*valor*', que só será necessário nas ações que demandem a quantificação do resultado, como, por exemplo, completar 50% de uma tarefa. Em um jogo, também é possível ter mais de uma ação ou alvo e diferentes ações para alvos.

Também foram definidas as ações e os alvos que poderão servir para a análise do desempenho e comportamento dos jogadores, de acordo com as tabelas e campos anteriormente estruturados. Dessa forma, utilizando a ideia do modelo do xAPI, ficam melhor mapeados e organizados os possíveis eventos que o jogador pode sofrer. As ações e alvos definidos para esse trabalho são os seguintes:

1. Ação: Entrar no jogo - Alvo: Autenticação (tabela '*api_tokens*');
2. Ação: Selecionar uma alternativa - Alvo: Questão (tabela '*answers*');
3. Ação: Aumenta a pontuação - Alvo: Jogadores (tabela '*players*').

A lista abaixo apresenta como o registro de uma resposta é realizado na API do Lumni. Nesse processo, o envio dos dados é feito através do método *POST* do protocolo HTTP para a rota '*/answers/*' destinada ao registro das respostas. O corpo do envio é do tipo JSON e possui a seguinte estrutura:

1. '*player_id*' recebe o número de identificação do jogador;
2. '*option_id*' corresponde ao número de identificação da alternativa;
3. '*problem_id*' ao número de identificação da pergunta;
4. '*used_time*' registra o tempo.

Para complementar, o próprio *back-end* e o banco de dados se encarregam de inserir um número de identificação para a resposta do jogador e um carimbo de data e hora chamado de *created_at* para guardar o momento em que a resposta foi registrada.

Diante do exposto acima, apesar de possuir poucas ações e alvos, as tabelas mostradas anteriormente na figura 3, que representam o Diagrama Relacional do Lumni, possuem uma gama de campos que, sozinhos ou combinados, podem servir para a geração de inúmeros relatórios que contribuem para a análise do desempenho e comportamento dos alunos.

Com base nisso, foram definidos possíveis indicadores que foram implementados para auxiliar professores e alunos a compreender melhor o desempenho atual. Os indicadores foram separados em dois grupos: (1) indicadores que foram aplicados a este trabalho; e (2) indicadores que contribuirão para trabalhos futuros. Cada grupo está acompanhado de uma breve descrição, justificativa de sua escolha, o método de implementação proposto e as potenciais implicações para professores e alunos. A decisão sobre qual indicador utilizar para a aplicação neste trabalho baseou-se no que poderia ser mais utilizado por professores e alunos. Além disso, levou-se em consideração a dificuldade e o tempo que demandaria para realizar estas tarefas.

Inicialmente, destacam-se os indicadores que foram implementados nesse trabalho:

1. Números de perguntas respondidas e média de acerto

- Descrição: informa dados de caráter mais geral, como número de questões registradas em cada tema, número de questões respondidas e a média de acerto;
- Justificativa: fornece uma visão mais simples, mas que permite a percepção do estado atual do jogo, incluindo o número de perguntas cadastradas, da turma ou do jogador, junto com a média de todos os acertos e erros ou da questão específica;
- Método de Implementação: retornar o número de perguntas e respostas e calcular a porcentagem de respostas corretas para cada aluno ou questão usando os dados das tabelas *'problems'* e *'answers'*;
- Implicações: professores e alunos podem verificar rapidamente o engajamento de acordo com o número de respostas registradas e o desempenho. Também permite que os professores verifiquem a necessidade de cadastrar mais perguntas.

2. Desempenho e média geral no jogo

- Descrição: este indicador informa a situação de um jogador ou turma dentro do jogo, os dados do seu desempenho e da relação entre respostas incorretas e corretas de todas suas respostas;

- Justificativa: facilitar a visualização do aluno como jogador em relação à sua turma, mostrando também informações do seu perfil como o seu nível e *rank*;
- Método de Implementação: retornar o nível e o *rank* do jogador ou da média da turma e calcular a porcentagem de respostas corretas, usando os dados das tabelas '*players*', '*problems*' e '*answers*';
- Implicações: professores e alunos podem usar essas informações para dar mais ênfase ao conteúdo daquela pergunta, adaptando a instrução de acordo com as necessidades.

3. Tempo médio de resposta

- Descrição: monitora o tempo médio que os alunos levam para responder cada questão, dando *insights* sobre quais conteúdos exigiram mais reflexão;
- Justificativa: existe a possibilidade do tempo de resposta mais longo indicar que uma questão é mais desafiadora ou mal compreendida pelos alunos;
- Método de Implementação: utilizar o campo '*used_time*' da tabela '*answers*' para calcular o tempo total ou médio gasto nas respostas para cada questão;
- Implicações: ajuda os professores a entenderem melhor o processo de pensamento dos alunos e auxilia na estipulação de tempo para provas e trabalhos em sala de aula, além de permitir que o aluno identifique o tipo de questões que podem demandar mais tempo durante uma prova.

4. Número de respostas corretas/incorretas por níveis de dificuldade

- Descrição: este indicador informa a relação entre respostas incorretas e corretas de um aluno ou de todos os alunos, ou de uma pergunta específica, com base nos níveis fácil, intermediário e difícil, o que permite uma visualização mais ampla da calibração dos conteúdos.
- Justificativa: facilitar a identificação de conteúdos descalibrados aos níveis de habilidade dos alunos e se os desafios propostos estão efetivamente contribuindo para o processo de aprendizado;
- Método de Implementação: calcular a relação entre as respostas para cada aluno ou questão usando os dados das tabelas '*problems*' e '*answers*', em especial o campo '*level*';
- Implicações: professores podem recalibrar o nível das questões, além de permitir que professores e alunos visualizem se está faltando aprofundamento (questões difíceis) sobre algum conteúdo ou se o erro está ocorrendo em conteúdos mais básicos (questões mais fáceis), podendo assim alterar estratégias de estudo.

5. Número de acessos por dia da semana

- Descrição: avalia a disponibilidade dos alunos baseado no número de visitas ao jogo.
- Justificativa: dias com maiores números de acessos podem identificar as melhores datas para lançamento de conteúdos auxiliares ou trabalhos;
- Método de Implementação: monitorar a frequência com a utilização dos registros dos campos *'created_at'* da tabela *'api_tokens'*;
- Implicações: os professores podem utilizar os dados sobre os dias de maior atividade para planejar o lançamento de novos conteúdos ou trabalhos, aumentando a probabilidade de engajamento, participação ou a identificação de conflitos com outros compromissos. Para os alunos, pode servir para incentivá-los a refletir sobre como gerenciam seu tempo de estudo e a fazer ajustes proativos para maximizar sua aprendizagem.

A seguir, destacam-se alguns indicadores que podem ser utilizados para trabalhos futuros, tendo sido pensados mas não implementados nesta versão do trabalho:

1. Nível de engajamento

- Descrição: avalia o engajamento dos alunos pelo tempo gasto e frequência de suas sessões de jogo e pela evolução de seus níveis;
- Justificativa: alunos mais engajados tendem a ter um desempenho melhor e uma maior retenção de conteúdo;
- Método de Implementação: deve-se aprimorar o banco de dados criando campos que registrem melhor o tempo gasto no jogo e criar uma tabela para registro das mudanças de nível e pontuação de cada jogador;
- Implicações: permite que os educadores e alunos reconheçam e recompensem o engajamento, além de identificar alunos que podem precisar de estímulo adicional.

2. Desempenho por data

- Descrição: monitorar mudanças de desempenho dos jogadores de uma data à outra;
- Justificativa: possibilitar uma melhor visualização de possíveis melhoras ou piores no rendimento;
- Método de Implementação: criar uma tabela para armazenar o desempenho em determinado dia e criar tarefas agendadas utilizando a biblioteca *'adonis5-scheduler'* para que sejam executadas todos os dias, atualizando a nova tabela com os dados já contidos nas tabelas *'players'*, *'problems'* e *'answers'*;

- Implicações: os professores podem analisar o desempenho diário permitindo intervir prontamente quando um aluno ou um turma de alunos mostra sinais de declínio no rendimento. Os alunos podem desenvolver uma maior autoconsciência sobre como suas ações diárias afetam seu desempenho geral.

3. Número médio de tentativas por questão

- Descrição: informa o número médio de tentativas em uma determina questão ou tema;
- Justificativa: uma maior quantidade de erros pode alertar sobre a dificuldade de uma questão ou sobre uma lacuna de aprendizado de um aluno ou de uma turma;
- Método de Implementação: utilizar os dados da tabela *'answers'* e *'problems'* para calcular a média de tentativas por questão;
- Implicações: pode ajudar os professores a avaliarem a dificuldade das questões e a persistência dos alunos. Os alunos podem ser encorajados pela persistência e o esforço contínuo em melhorar.

4. Frequência de erros em um mesmo conteúdo

- Descrição: informar mais detalhadamente possíveis questões de aprendizado de um aluno por meio da especificação do conteúdo;
- Justificativa: melhorar a identificação de quais conteúdos o jogador possui mais dificuldade;
- Método de Implementação: necessário modificar o sistema criando um novo campo na tabela *'problems'* ou uma nova tabela de conteúdos para salvar os registros e calcular a relação entre as respostas erradas da tabela *'answers'* e do conteúdo específico;
- Implicações: pode servir de apoio para professores e alunos reforçarem conteúdos específicos que estão causando dificuldades frequentes.

5. Quantidade de dicas solicitadas e perguntas respondidas

- Descrição: fornecer informação sobre a quantidade de vezes em que um aluno pediu uma dica ao responder as perguntas;
- Justificativa: um aluno que utiliza muito as dicas pode demonstrar um perfil que opta por não se desafiar ou demonstra maior necessidade de suporte adicional para compreender o conteúdo;
- Método de Implementação: necessário modificar o sistema criando um campo na tabela *'answers'* que forneça uma *flag* de que o aluno solicitou uma dica e a utilização/reestruturação do campo *'tips'* já existente na tabela *'problems'*;

- Implicações: se uma grande quantidade de dicas é solicitada para certas questões ou temas, isso pode sinalizar que o aluno necessita de um suporte adicional ou que os recursos de ensino atuais não estão suficientemente claros ou eficazes, incentivando o professor a desenvolver ou buscar melhores materiais de apoio ou estratégias de ensino. Para os alunos pode servir de ferramenta para identificar áreas onde frequentemente buscam ajuda.

6. Percentual de respostas corretas sem dicas

- Descrição: informar o percentual de vezes em que o jogador respondeu corretamente e incorretamente uma questão sem utilizar dicas;
- Justificativa: um aluno que possui um bom número de questões respondidas corretamente e com baixo percentual de dicas utilizadas tende a demonstrar que os conceitos aprendidos em sala de aula foram internalizados e que possui maior domínio sobre aquele conteúdo;
- Método de Implementação: a mesma implementação do item anterior, sendo necessário criar um campo na tabela *'answers'* que forneça uma *flag* indicando se o aluno necessitou da dica, além da utilização/reestruturação do campo *'tips'* já existente na tabela *'problems'* para retornar o cálculo do percentual;
- Implicações: este indicador pode ajudar os professores a avaliar o quanto os alunos realmente compreendem o conteúdo sem assistência externa. Além disso, estimula os alunos a confiarem em suas habilidades de resolução de questões e a explorarem soluções por conta própria antes de recorrerem a dicas, fortalecendo habilidades críticas de pensamento e preparando-os para situações de avaliação onde o suporte externo não está disponível.

É importante salientar que a aplicação de um indicador de GLA pode resultar em diversas modalidades de visualização de dados.

Com isso, após os indicadores terem sido definidos, a implementação propriamente dita no *back-end* foi iniciada, gerando quatro novos *endpoints* ou rotas, que fornecem os dados necessários por meio de requisições:

1. Indicador: Número de perguntas respondidas e média de acerto

- Rota: *'/generalStats'*
- Descrição: Calcula estatísticas gerais sobre as perguntas respondidas, podendo ser filtrado por jogador, tema e pergunta.
- Parâmetros: Pode receber um *'player_id'*, *'theme'* e *'problem_id'* como filtro.
- Retorno: Um vetor de objetos com estatísticas para cada tema, com o nome do tema, quantidade de perguntas registradas, quantidade de perguntas respon-

didadas, quantidade de respostas corretas, quantidade de respostas incorretas, porcentagem de acerto e a cor que será utilizada no gráfico.

- Cálculos realizados:

$$\text{Porcentagem de acertos} = \left(\frac{\text{Perguntas corretas}}{\text{Respostas}} \right) \times 100$$

2. Indicador: Desempenho e média geral no jogo

- Rota: *'/gamePerformance'*
- Descrição: Calcula o desempenho geral em todos os temas de um jogador em específico ou de todos os jogadores, dependendo se *'player_id'* é fornecido ou não.
- Parâmetros: Pode receber um *'player_id'* como filtro.
- Retorno: Retornar o nome do jogador, desempenho, *rank*, nível (atual ou a média) e posição no placar.
- Cálculos realizados: O desempenho é extraído da divisão do número de respostas corretas pelo número total de respostas e multiplicando por 100 para obter um valor percentual.

$$\text{Desempenho} = \left(\frac{\text{Total de perguntas corretas}}{\text{Total de respostas}} \right) \times 100$$

A média de nível é obtida através do somatório de todos os níveis dos jogadores e pela divisão pelo número total de jogadores.

$$\text{Média de Nível} = \frac{1}{n} \sum_{i=1}^n \text{Nível do jogador}_i$$

A média de nível só é aplicada à visualização da turma toda e *n* corresponde ao número total de jogadores.

3. Indicador: Tempo médio de resposta e Número de respostas corretas/incorretas por níveis de dificuldade

- Rota: *'/performanceByQuestionLvl'*
- Descrição: Calcula estatísticas de respostas de perguntas, separadas por nível de dificuldade, podendo ser filtrado por jogador, tema e pergunta.
- Parâmetros: Pode receber um *'player_id'*, *'theme'* e *'problem_id'* como filtro.

- Retorno: Um vetor de objetos com estatísticas para cada dificuldade, sua quantidade de respostas corretas, quantidade de respostas incorretas e o tempo médio em segundos.
- Cálculos realizados: Para calcular os acertos e erros percorre-se as respostas, realizado um somatório e armazenando se a resposta está correta ou incorreta:

$$\text{Acertos/Erros} = \sum_{i=1}^n (\text{Resposta})$$

Para calcular o tempo médio, percorre-se as respostas, realizando um somatório no tempo utilizado em cada uma para que então faça a divisão pelo número total de respostas:

$$\text{Tempo Médio (segundos)} = \frac{1}{n} \sum_{i=1}^n \text{Tempo decorrido na resposta}_i$$

Onde n é o número total de respostas.

4. Indicador: Número de acessos por dia da semana

- Rota: `'/numberOfAccessesByDayOfWeek'`
- Descrição: Calcula os acessos, baseado por dia da semana, dos *tokens* gerados e armazenados na tabela *API*. Se um jogador for fornecido, os acessos são filtrados por esse usuário específico.
- Parâmetros: Pode receber um `'player_id'` como filtro.
- Retorno: Cada dia da semana e sua quantidade de acessos.
- Cálculos realizados: É realizada uma contagem simples em que, para cada dia da semana, contamos o número de acessos:

$$\text{Número de acessos no dia da semana} = \sum_{i=1}^n \text{Acesso}_i$$

Onde n é o número total de acessos em um determinado dia da semana.

Essas rotas fornecem a base de dados que será utilizada pelo educador e pelo aluno para a visualização nos gráficos e textos do *dashboard*. Elas detalham e filtram as principais atividades dos jogadores dentro do jogo, permitindo uma análise do desempenho, comportamento e do engajamento.

5.3 IMPLEMENTAÇÃO DO DASHBOARD

O desenvolvimento do *dashboard* foi pautado na utilização do estudo de "*Dashboard Design Patterns*" de Bach et al. (2023) e de algumas diretrizes difundidas por autores, tais como: não gerar sobrecarga de informação aos usuários, evitando poluir com muitos dados; evitar elementos visuais desordenados ou confusos; abranger recursos funcionais e visuais; fornecer consistência, recursos de interação e gerenciar a complexidade (FEW, 2006; YIGITBASIOGLU; VELCU-LAITINEN, 2012; RAHMAN; ADAMU; HARUN, 2017; JANNES; SILLITTI; SUCCI, 2013; SARIKAYA et al., 2019).

Dessa forma, foi elaborado um *dashboard* inicial utilizando a ferramenta de design de interface de usuário Figma, incorporando várias das práticas e elementos comumente observados e recomendados na tabela, demonstrando um alinhamento com as práticas atuais de design de *dashboard*. A lista abaixo detalha melhor, separando por "conteúdos e composições" e por cada coluna de seus grupos, o elemento usado, a descrição feita por Bach et al. (2023) sua porcentagem de uso (popularidade) e seu local de aplicação no Lumni.

1. Conteúdo

(a) Dados

i. Valor único

- Descrição: pontos de dados específicos dentro de um conjunto de dados, como o valor mais recente em uma série temporal. Serve para mostrar um valor individual, destacar sua importância, sugerindo que esse ponto, seja o mais recente, o mais alto ou outro significativo.
- Porcentagem de uso: 88%.
- Local de aplicação: no gráfico de desempenho por nível de dificuldade das questões que faz a relação entre os acertos, erros e a dificuldade.

ii. Derivados

- Descrição: valores derivados são informações extraídas de conjuntos de dados originais ou de outros valores, como tendências, que oferecem uma camada de abstração ao destacar aspectos específicos em detrimento dos dados brutos.
- Porcentagem de uso: 69%.
- Local de aplicação: no gráfico de pizza, que informa o número de perguntas respondidas e a média de acertos, e no medidor de desempenho, que informa o desempenho em relação à turma.

iii. Filtrados

- Descrição: mostra um subconjunto dos dados originais (detalhados).

- Porcentagem de uso: 42%.
- Local de aplicação: no gráfico de pizza, medidor de desempenho do jogador e desempenho por nível de dificuldade das questões ao filtrar utilizando as caixas de seleção.

iv. Agregados

- Descrição: a agregação de dados envolve a combinação de múltiplos pontos de dados individuais em um único e conciso valor. Isso pode incluir somar ou calcular a média de valores diferentes para obter uma visão geral.
- Porcentagem de uso: 67%.
- Local de aplicação: no gráfico de pizza, que informa o número de perguntas respondidas e a média de acertos, no medidor de desempenho, que informa o desempenho em relação à turma e nos filtros ao selecionar um item para visão geral, como a turma ou todas as perguntas de um tema.

v. Detalhados

- Descrição: oferece uma apresentação mais completa dos dados. Frequentemente utilizado quando é necessário um entendimento profundo ou uma investigação minuciosa de cada elemento dentro de um conjunto de dados.
- Porcentagem de uso: 94%.
- Local de aplicação: no gráfico de desempenho por nível de dificuldade das questões.

(b) Metadados

i. Fonte de dados

- Descrição: identifica de onde vem os dados, potencialmente incluindo links e explicações sobre como os dados foram coletados e analisados e quais ferramentas foram usadas.
- Porcentagem de uso: 69% implicitamente.
- Local de aplicação: nos títulos dos gráficos, legendas e *placeholders*.

ii. Descrição de dados

- Descrição: fornece uma descrição de alto nível dos dados para explicar o que o painel está mostrando.
- Porcentagem de uso: 44% explicitamente.
- Local de aplicação: nos títulos dos gráficos, legendas e *placeholders*.

iii. Anotações

- Descrição: enfeites gráficos extras adicionados pelo autor do painel para destacar pontos, alterações ou desenvolvimentos específicos nos dados.
- Porcentagem de uso: 10%.
- Local de aplicação: nos *tooltips* dos gráficos.

(c) **Representação visual**

i. **Visualização detalhada**

- Descrição: visualizações com detalhes suficientes para ler e entender valores precisos.
- Porcentagem de uso: 88%.
- Local de aplicação: na utilização de legendas, barras e números.

ii. **Gráfico em miniatura**

- Descrição: visualizações pequenas e concisas sem descrições de eixos, rótulos ou marcas de seleção. A ideia é dar uma compreensão rápida de uma tendência.
- Porcentagem de uso: 21% explicitamente.
- Local de aplicação: no gráfico de pizza que informa a relação entre as questões respondidas e a média de acerto.

iii. **Gráfico de progresso e medidor**

- Descrição: qualquer tipo de visualização usada para representar uma escala ou intervalo de um valor. Podem ser apresentadas em forma de medidores semicirculares, barras de progresso lineares, termômetros, etc.
- Porcentagem de uso: 13%.
- Local de aplicação: no canto superior direito para informar o desempenho do aluno em relação à turma.

iv. **Número**

- Descrição: números individuais colocados com destaque em um painel, usados principalmente para representar valores absolutos ou proporções.
- Porcentagem de uso: 62%.
- Local de aplicação: em todos os gráficos, seja nas legendas, barras ou informações complementares.

2. **Composição**

(a) **Layout de página**

i. Estratificados

- Descrição: enfatiza uma ordenação de cima para baixo. Pode servir para mostrar informações gerais de alto nível ao longo da parte superior, enquanto mostra informações mais detalhadas mais abaixo.
- Porcentagem de uso: 49%.
- Local de aplicação: na organização do *dashboard* ao manter os dados de caráter geral do aluno ao topo e outros gráficos mais detalhados abaixo.

(b) Espaço de tela**i. Ajustado na tela**

- Descrição: o *dashboard* é totalmente visível na tela e todas as informações ficam visíveis o tempo todo. Não necessita de uma interação para visualizar qualquer conteúdo do painel, pois todas as informações cabem na tela e estão disponíveis rapidamente.
- Porcentagem de uso: 44%.
- Local de aplicação: na tela de *dashboard* do jogo, que já possui um número e tamanho específico de gráficos.

(c) Estrutura**i. Página única**

- Descrição: um painel apresenta todas as informações em uma página, não necessitando de redirecionamento ou do usuário navegar.
- Porcentagem de uso: 61%.
- Local de aplicação: na página inicial do jogo.

(d) Interação**i. Detalhamento**

- Descrição: permite que o usuário encontre ou se concentre em dados específicos, pesquisando valores de dados específicos ou aplicando critérios de filtro para que apenas informações relevantes permaneçam. Essas interações são normalmente facilitadas por elementos da interface do usuário, como campos de texto, caixas de seleção, botões de opção, controles deslizantes de intervalo, etc.
- Porcentagem de uso: 55%.
- Local de aplicação: nas caixas de seleção dos filtros de alunos, temas e perguntas.

(e) Cor**i. Distinta**

- Descrição: cores exclusivas (ou paletas de cores) para diferentes informações ou tipos de dados.
- Porcentagem de uso: 35%.
- Local de aplicação: no gráfico de pizza que informa o número de perguntas respondidas e a média de acertos.

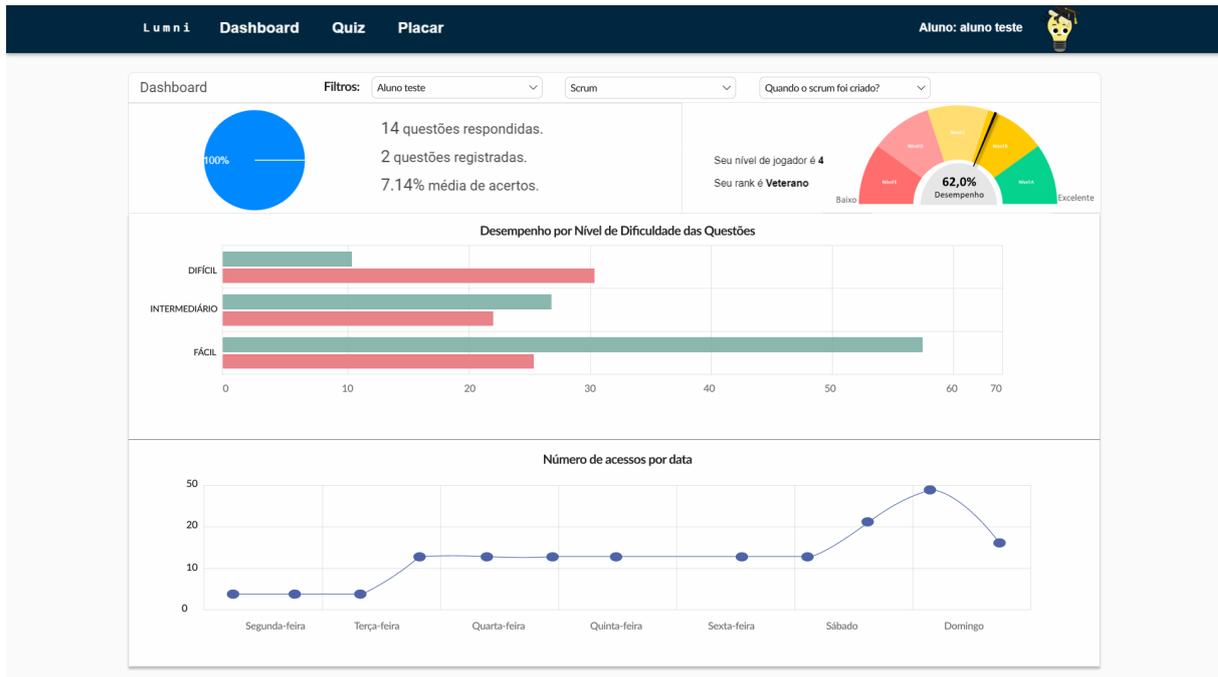
ii. Codificação de dados

- Descrição: usa cores para codificar categorias ou escalas dentro dos dados.
- Porcentagem de uso: 80%.
- Local de aplicação: no gráfico de números de acessos por data que informa os dias da semana e o número de acessos.

iii. Semântica

- Descrição: usa cores para indicar semânticas específicas sobre os dados e a vida real. Os mais comuns são os esquemas de semáforos, verde/vermelho para sentimento positivo/negativo, etc.
- Porcentagem de uso: 26%.
- Local de aplicação: no medidor de desempenho, que informa o desempenho em relação à turma e no gráfico de desempenho por nível de dificuldade da questão, que informa a relação entre os acertos, erros e a dificuldade.

O protótipo do *dashboard*, que foi criado utilizando os elementos e diretrizes acima, pode ser visto na figura 22:

Figura 22 – Modelo inicial do *dashboard* - Lumni

Fonte: o autor

Ao desenvolver esse protótipo, foi essencial alinhar o *design* com o propósito específico da aplicação e seu ambiente. Embora em alguns casos existam elementos de *design* com maior popularidade no campo da visualização de dados, a escolha por integrá-los depende profundamente das necessidades e contextos específicos da aplicação. Nesse sentido, apesar de priorizar as exigências funcionais e estéticas do projeto, houve um esforço consciente para incorporar também os elementos mais populares dos padrões de *design* de *dashboard*. Essa abordagem assegura que o *dashboard* não apenas atenda às expectativas funcionais e operacionais, mas também se mantenha alinhado com as melhores práticas reconhecidas na indústria, buscando otimizar a experiência do usuário e a eficácia da interface.

Posteriormente, já na fase de implementação do *dashboard* no *front-end* do jogo, percebeu-se que seria necessário ajustar alguns elementos gráficos e cores para melhor atender às necessidades do jogo.

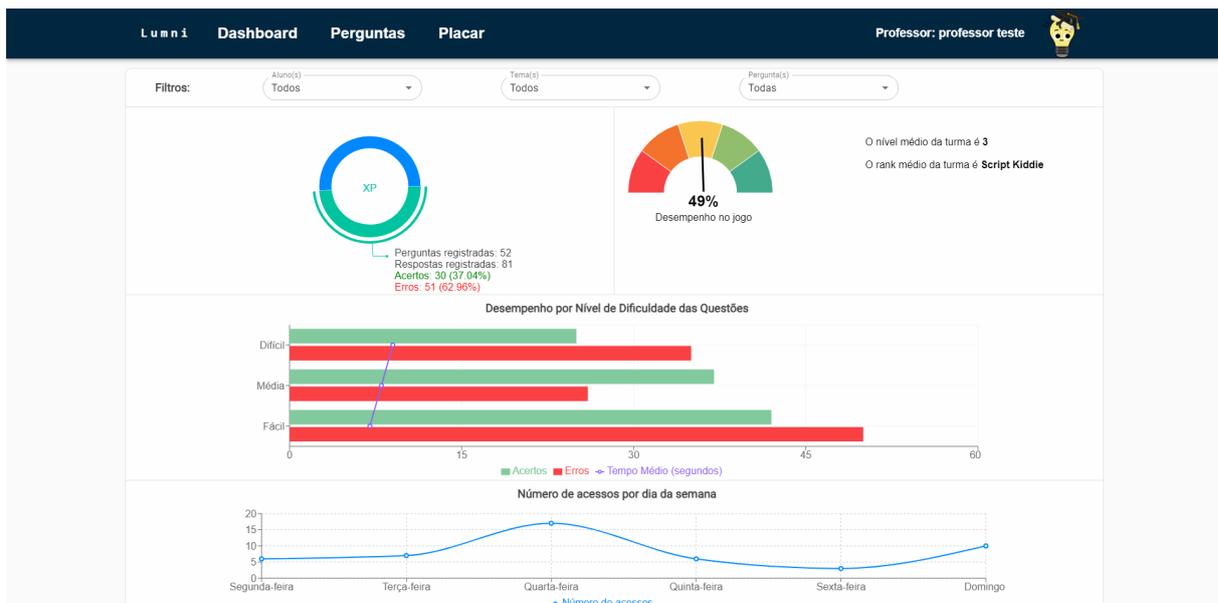
Das alterações feitas destaca-se:

- Mudança no gráfico de pizza para um que englobasse o texto ao lado, deixando a tela menos poluída e também permitindo uma visualização mais rápida dos outros temas;
- A agregação do indicador de "Relação de respostas corretas/incorretas entre níveis de dificuldade" com o de "Tempo médio de resposta" no gráfico de barras horizontais do centro;

- A adição de legendas aos gráficos;
- A mudança no tom de algumas cores para deixar diferenciado, padronizado ou semântico.

O produto final do *dashboard* pode ser visto na Figura 23.

Figura 23 – Modelo final do *dashboard* - Lumni



Fonte: o autor

Essas modificações também podem ser percebidas devido à diferença entre o estipulado no *design* inicial e os recursos disponibilizados pela biblioteca Recharts.

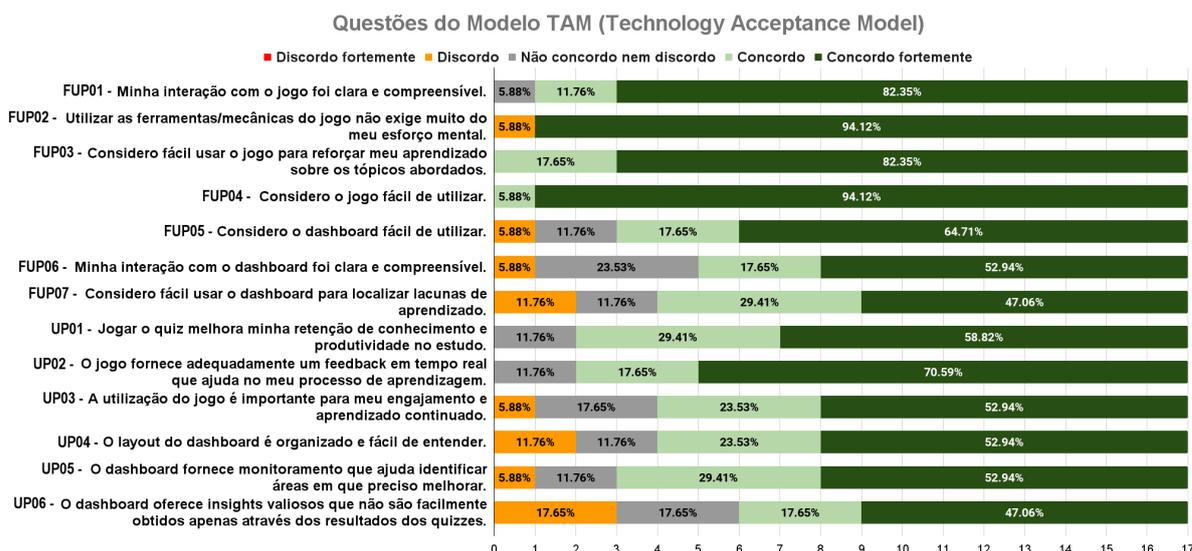
6 AVALIAÇÃO E ANÁLISE DOS RESULTADOS

Conforme descrito no capítulo dos aspectos metodológicos, participaram da pesquisa dezessete (17) estudantes dos cursos de Sistemas de Informação, Ciência da Computação e Engenharia de Computação da UFSM. Um e-mail com explicações detalhadas sobre a avaliação e o link de acesso foi disponibilizado aos participantes. O jogo foi liberado com cerca de 140 perguntas divididas entre os temas de *Scrum* e *Extreme Programming*, possuindo cerca de 30 minutos de jogatina para avaliar a compreensão e o engajamento dos usuários. A seguir, serão apresentados, de forma separada, os resultados e as discussões desses dados.

6.1 ANÁLISE DA ACEITAÇÃO DA APLICAÇÃO

Para a análise dos resultados obtidos no modelo TAM, as perguntas foram organizadas de forma a avaliarem de forma separada o jogo e o *dashboard*. Dentro desses dois itens, as perguntas foram subdivididas em Facilidade de Uso Percebida (FUP) e Utilidade Percebida (UP), obtendo-se os resultados apresentados na figura 24.

Figura 24 – Gráfico TAM



Fonte: o autor

Os resultados obtidos no que se refere a avaliação do **jogo** foram os seguintes:

1. Facilidade de Uso Percebida (FUP)

- **FUP01:** 94,11% dos usuários acreditam que sua interação com o jogo foi clara e compreensível e 5,88% ficaram em posição neutra.
- **FUP02:** Somente 5,88% discordam que utilizar as ferramentas/mecânicas do jogo não exige muito esforço mental.
- **FUP03:** Todos os usuários (100% de concordância parcial ou total) consideram fácil usar o jogo para reforçar o aprendizado.
- **FUP04:** Todos consideraram o jogo fácil de se utilizar.

2. Utilidade Percebida (UP)

- **UP01:** 88,23% dos usuários acreditam que jogar o quiz melhora a retenção de conhecimento e a produtividade no estudo, 11,76% não concordam nem discordam.
- **UP02:** 88,24% dos usuários consideram que o jogo fornece adequadamente *feedback* em tempo real e 11,76% não possuem uma posição sobre (neutralidade).
- **UP03:** 76,47% dos usuários acreditam que a utilização do jogo é importante para seu engajamento e aprendizado continuado, enquanto que 5,88% discordaram e 17,65% mantiveram-se neutros.

No que concerne aos resultados obtidos da avaliação do **dashboard**, pode-se destacar:

1. Facilidade de Uso Percebida (FUP)

- **FUP05:** 82,36% dos usuários consideram o *dashboard* fácil de utilizar, enquanto 11,76% ficaram neutros e 5,88% discordaram.
- **FUP06:** 70,59% dos usuários acreditam que a interação com o *dashboard* foi clara e compreensível, 23,53% não concordaram nem discordaram e somente 5,88% discordou.
- **FUP07:** 76,47% dos usuários consideraram fácil usar o *dashboard* para localizar lacunas de aprendizado e o restante ficou dividido entre discordar e não possuir uma posição.

2. Utilidade Percebida (UP)

- **UP04:** 76,47% dos usuários consideram o layout do *dashboard* organizado e fácil de entender, 11,76% discordam e os outros 11,76% são neutros.
- **UP05:** 82,35% dos usuários acreditam que o *dashboard* ajuda a identificar áreas em que precisam melhorar, 11,76% ficaram neutros e somente 5,88% discordaram.

- **UP06:** 64,71% dos usuários consideram que o *dashboard* oferece *insights* valiosos não facilmente obtidos pelos resultados dos quizzes, enquanto o restante está dividido entre discordar e estar em posição neutra.

Os resultados obtidos indicam uma forte aceitação do jogo e do *dashboard* pelos usuários. Tanto o jogo quanto o *dashboard* foram vistos como ferramentas úteis, com os usuários reconhecendo suas funcionalidades e benefícios. Destacando-se para o baixo esforço mental exigido, a clareza nas interações e o *feedback* em tempo real. Sendo a Facilidade de Uso Percebida (FUP) um dos pontos mais fortes, o que demonstra a eficácia do jogo como uma ferramenta educacional. A Utilidade Percebida (UP) do jogo também foi amplamente reconhecida, destacando seu potencial como um complemento útil para métodos de aprendizado tradicionais. No entanto, alguns pontos, como a facilidade de uso do *dashboard* e a clareza dos *insights*, podem ser melhorados, já que houve uma proporção significativa de respostas neutras ou discordantes nessas áreas.

6.2 ANÁLISE DA USABILIDADE

Em relação à análise dos resultados de usabilidade percebeu-se pontos positivos nos seguintes aspectos:

1. Facilidade de uso

- 88,23% dos usuários acham o sistema fácil de usar.
- Somente 11,76% dos alunos sentiram necessidade de ajuda técnica.
- Somente 17,64% tendem a achar o sistema desnecessariamente complexo.
- Demonstrando que o sistema é fácil de usar, permitindo que os usuários interajam de forma intuitiva, sem dificuldades significativas. Também demonstrando que o sistema é suficientemente autoexplicativo para a maioria dos seus usuários, reforçando a ideia de que é acessível e direto em seu uso.

2. Integração e Consistência

- 76,47% usuários acreditam que as funções do sistema estão bem integradas.
- 88,23% indicaram que o sistema não apresenta muita inconsistência.
- Demonstra que o sistema opera de forma coesa, sem deixar os usuários confusos sobre a transição entre diferentes funções. Também indica que o sistema mantém um padrão uniforme, o que é essencial para criar uma experiência de uso estável e previsível.

3. Confiança e Aprendizado

- 88,23% dos usuários se sentiu confiante ao usar o sistema.
- 94,12% acreditam que outras pessoas aprenderão a usar o sistema rapidamente e 5,88% não concordam e nem discordam.
- Demonstra que o sistema proporciona uma experiência que os usuários dominam rapidamente, sem gerar inseguranças ou frustrações. Também reforça a ideia de que o sistema é bem projetado para novos usuários, facilitando sua adoção.

4. Desejo de uso frequente e percepção de atrapalhamento

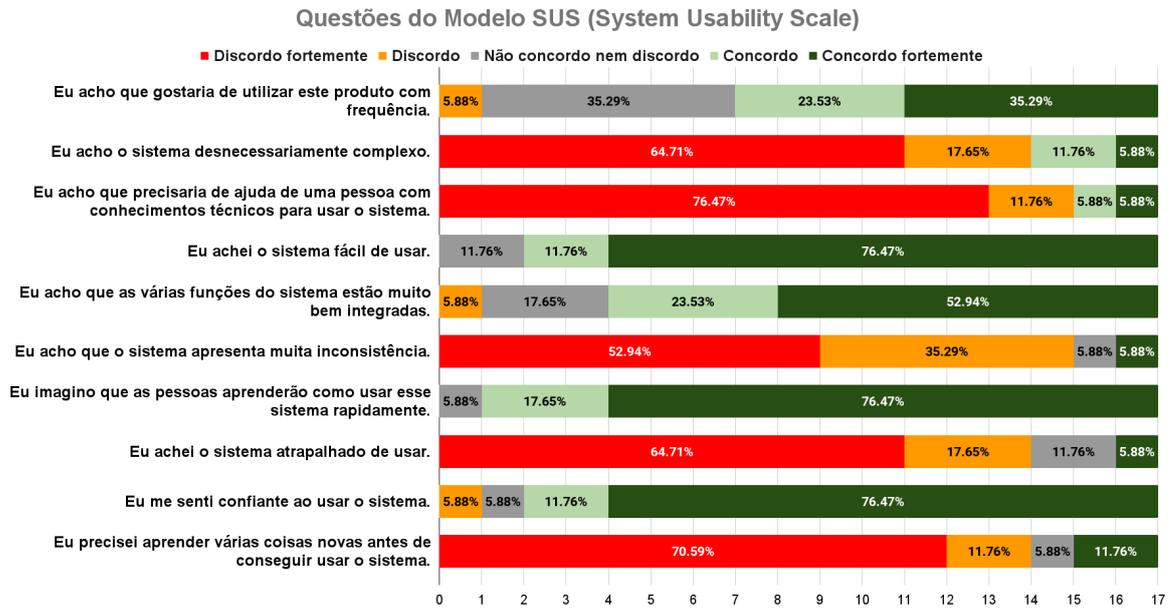
- As opiniões sobre a vontade de usar o sistema com frequência são mais diversas, com uma tendência ligeiramente positiva de 58,82, 35,29% em posição neutra e somente 5,88% discordando.
- 82,36% dos avaliadores não acharam o sistema atrapalhado de usar, 5,88% neutros e 11,76% concordando fortemente.
- Isso indica que, embora o sistema seja funcional e eficiente, sua atratividade para uso contínuo pode ser uma área de melhoria. Também demonstra que, mesmo com algumas dúvidas sobre o desejo de uso frequente, a funcionalidade do sistema não é um obstáculo significativo.

Em relação aos cinco componentes de percepção de usabilidade de Nielsen (2012), notou-se o seguinte para cada um deles:

1. **Capacidade de aprendizagem:** Muito alta, com a maioria dos usuários achando que o sistema é fácil de aprender e usar rapidamente;
2. **Eficiência:** Alta, com a maioria dos usuários se sentindo confiantes ao usar o sistema e uma leve tendência positiva para o desejo de uso frequente;
3. **Memorização:** Alta, com os usuários não precisando de ajuda técnica e não precisando aprender muitas coisas novas para usar o sistema;
4. **Erros:** Baixa, com o sistema sendo considerado consistente e bem organizado pelos usuários;
5. **Satisfação:** Alta, com os usuários considerando o sistema fácil de usar e bem integrado.

O gráfico da figura 25 elucida melhor a ordem em que as perguntas foram apresentadas aos alunos, com a quantidade de respostas e porcentagem em cada uma das 5 possíveis alternativas e a barra de cores.

Figura 25 – Gráfico SUS



Fonte: o autor

Ao realizar o cálculo da pontuação do SUS, obteve-se 68,67% de usabilidade, o que, de acordo com o Quadro 4, classifica o jogo Lumni com uma usabilidade "Ok".

Algumas sugestões e/ou críticas enviadas pelos avaliadores podem ter contribuído para a nota de avaliação não ter sido mais alta.

Ademais, os resultados indicaram que os usuários em geral têm uma percepção positiva do sistema em termos de facilidade de uso, integração, consistência e confiança. Há uma leve incerteza em relação ao desejo de uso frequente, mas não há uma percepção significativa de obstáculo ao uso, demonstrando que o sistema é bem aceito e funcional, embora haja espaço para melhorar a atratividade do uso frequente e problemas visuais.

6.3 SUGESTÕES E/OU CRÍTICAS

Para complementar as perguntas definidas para a abordagem TAM e SUS foi criada uma seção de "Questões Gerais" contendo duas questões de caráter não obrigatórias. As perguntas estão enumeradas a seguir, juntamente com as respectivas quantidades de respostas:

1. "Compartilhe aqui suas sugestões e/ou críticas sobre o Lumni." - 9 respostas
2. "Quais outros indicadores você acredita que poderiam contribuir para o dashboard?" - 5 respostas

Ao analisar as respostas obtidas nessas duas perguntas, podemos identificar de forma direta as áreas que possivelmente necessitam de melhorias. A seguir, apresentamos uma análise detalhada baseada no agrupamento do *feedback* dos usuários, dividida em quatro (4) categorias principais:

1. **Experiência do Usuário (UX) e Interface:**

- É sugerido dar mais destaque ao botão de jogar ou reposicioná-lo para melhorar a navegação.
- Simplificar os gráficos e torná-los mais relevantes para o aluno, por exemplo, mostrando acertos por categoria.
- Dispor as alternativas das perguntas uma embaixo da outra ao invés de lado a lado, para melhor clareza.
- Mostrar *feedback* das respostas diretamente nas perguntas, com uso de cores (verde para correto, vermelho para incorreto).
- Na tela em que o professor cadastra as perguntas, adicionar cabeçalhos de "Descrição" e "Dificuldade" para as tabelas de perguntas.

2. **Layout e Visualização:**

- Ajustar o texto do gráfico de perguntas que, em alguns momentos, sobrepõe outros elementos e corrigir o texto de "Desempenho no jogo" que aparece cortado.
- Garantir que o fundo branco cubra todos os jogadores no placar, não apenas até o jogador 8 como ocorre em algumas dimensões de tela.
- Melhorar a responsividade do layout para diferentes tamanhos de tela, como por exemplo em monitores *ultrawide*.
- Definir uma posição fixa para a coluna de "Dificuldade" na tela de cadastro de perguntas.

3. **Funcionalidades e Indicadores:**

- Incluir filtros como desempenho por categoria e dificuldade, acertos e erros por conteúdo.
- Prever mecanismos para evitar que perguntas sejam respondidas múltiplas vezes ou indicar quando isso ocorre.
- Em caso de erro, fornecer explicações detalhadas sobre a solução correta.
- Adicionar outros métodos ágeis.

4. **Segurança:**

- Proteger contra manipulação de parâmetros que permitem a criação de contas com privilégios elevados (admin ou professor).
- Implementar a utilização do *authorization token* para verificar a permissão de acesso, a fim de proteger informações de outros usuários.
- Substituir identificadores (IDs) numéricos por identificadores únicos universais (UUIDs) para aumentar a segurança e a imprevisibilidade dos identificadores de usuários.

É importante considerar que algumas sugestões e/ou críticas precisam ser melhor avaliadas por meio de estudo e pesquisa, pois o que um usuário deseja pode não refletir na necessidade de todos.

Existem críticas e sugestões que, sem dúvida, precisam ser implementadas, especialmente aquelas relacionadas à segurança, à responsividade e de erros de layout e interface/UX. Questões como essas são fundamentais para aumentar a segurança do sistema e essenciais para aprimorar a experiência do usuário.

Vale destacar que algumas sugestões, como a separação e filtros por conteúdo e a possibilidade do professor adicionar novos temas de forma dinâmica, já haviam sido pensadas anteriormente, mas por conta do tempo não entraram no escopo das revisões do trabalho. Essas melhorias podem ser consideradas em futuras atualizações do jogo.

7 CONCLUSÃO

Neste capítulo, são apresentadas as considerações finais sobre o trabalho, destacando os resultados alcançados e as perspectivas para futuros estudos. Na Seção 7.1, são resumidos os objetivos e os resultados deste trabalho. Em seguida, na Seção 7.2, o trabalho é finalizado, e são descritas as direções para trabalhos futuros.

7.1 REVISÃO GERAL E RESULTADOS

Neste trabalho, foram revisados pontos cruciais para fornecer uma experiência aprimorada de usabilidade, segurança e funcionalidades ao usuário (aluno/professor) junto ao sistema Lumni, jogo voltado para apoiar o ensino e aprendizagem de Engenharia de Software. Além disso, foi desenvolvido um *dashboard* utilizando os conceitos de GLA integrado ao Lumni. A revisão incluiu a identificação e coleta das necessidades de mudanças e correções após um uso extensivo pelo autor, seguida pela implementação das correções necessárias. Subsequentemente, foram definidos os dados que deveriam ser coletados pelo jogo durante sua execução, estabelecidas as diretrizes e melhores práticas para o desenvolvimento do *dashboard*, e elaborado um design detalhado para o mesmo.

Após isso, iniciou-se o desenvolvimento e a aplicação dos conceitos de GLA no jogo. Esse processo começou com a criação dos novos campos de dados a serem coletados, conforme definidos anteriormente. Em seguida, foram implementados os algoritmos de GLA no back-end do jogo, que seriam acessados por meio de rotas específicas. Paralelamente, foi realizada a implementação do *design* do *dashboard* no front-end, seguida pela integração completa entre o back-end e o front-end do jogo. Por fim, foi criado um ambiente de produção com o *deploy* realizado no Heroku, que seria posteriormente disponibilizado aos avaliadores para análise.

Por fim, foi validada a usabilidade e a aceitação da aplicação por meio da disponibilização do jogo a dezessete (17) alunos dos cursos de computação da UFSM. Quanto à validação da aceitação da tecnologia, essa ocorreu por meio do uso do Modelo TAM, contendo questões voltadas para análise da Facilidade de Uso Percebida (FUP) e de Utilidade Percebida (UP) em relação ao jogo e ao *dashboard*. A partir disso, foi possível perceber que a realização de todos os objetivos específicos culminou no atendimento do objetivo geral, no qual tanto o jogo quanto o *dashboard* receberam uma aceitação positiva por parte dos usuários. Com relação à avaliação da Usabilidade, essa ocorreu por meio da aplicação da escala SUS, cujos resultados apontaram um bom percentual de usabilidade (68,67%), destacando de forma bastante positiva os aspectos de capacidade de aprendizagem, eficiência, memorização, baixo número de erros e satisfação dos usuários.

Por fim, conclui-se que, apesar dos relatos sobre a necessidade de melhorias em alguns aspectos que tangem à facilidade de uso do *dashboard*, clareza dos *insights*, atratividade para uso frequente, bem como em aspectos visuais, o jogo e o *dashboard* mostraram-se funcionais e bem aceitos pelos usuários. Foi possível observar aspectos positivos nos principais pontos almejados durante a concepção da ideia, como a facilidade, a produção de um *feedback* diferenciado e em tempo real, a identificação de áreas de melhoria do conhecimento e o reforço do aprendizado sobre os tópicos abordados em sala de aula.

7.2 TRABALHOS FUTUROS

Como trabalhos futuros, pretende-se melhorar a implementação do jogo Lumni com diversas melhorias e novas funcionalidades. Entre as ações planejadas, destacam-se a adição de indicadores que foram inicialmente planejados, mas não aplicados neste trabalho, garantindo uma análise mais completa e detalhada do desempenho dos usuários. A adição de um campo de dicas para cada pergunta, visando gerar novos indicadores, como o número de dicas solicitadas e a taxa de acertos após a solicitação de dicas.

Também é possível destacar algumas possibilidades de melhorias que, apesar de não possuírem relação direta com o tema principal deste trabalho, podem contribuir significativamente para aumentar a robustez e flexibilidade do jogo Lumni. Uma delas é a possibilidade de permitir a criação e organização dos alunos em diferentes turmas. A ideia central visa cada turma ser criada com um código único gerado automaticamente ou pelo professor, que possa servir para vincular um aluno à uma turma. Para complementar essa funcionalidade, também foi observada a necessidade de desenvolver uma tela específica para o gerenciamento de alunos e usuários, permitindo ações como deletar, alterar e visualizar informações detalhadas de cada aluno.

Além disso, um elemento que já era planejado e que foi observado no formulário de avaliação é a necessidade de modificar a estrutura do banco de dados para suportar a criação de diferentes temas e conteúdos. Essa alteração tornará o sistema mais dinâmico, permitindo a inclusão de turmas com diversas disciplinas, bem como a classificação dos conteúdos dentro de um tema, o que permitirá que os filtros e gráficos tornem-se ainda mais específicos e relevantes para cada disciplina ou assunto.

Foi observada também a necessidade de revisar o *CSS* e corrigir a responsividade atual para *web*, além de implementar o *front-end* em forma de aplicativo, utilizando linguagens de desenvolvimento *mobile*. Isso garantirá uma experiência de usuário consistente em diferentes dispositivos e plataformas.

Outra funcionalidade a ser implementada é o desenvolvimento de uma versão *PWA* (*Progressive Web App*) do jogo Lumni, permitindo que os usuários joguem *offline* com envio automático dos dados quando houver conexão com a internet.

Por fim, observou-se como uma melhorias que podem agregar à experiência do jogador a apresentação do ícone do mascote de forma suspensa na página e selecionável, integrando-o com a *API* do ChatGPT através de um *prompt* específico. O mascote atuaria como um guru durante a navegação no jogo, possibilitando a interação em tempo real com o aluno para tirar dúvidas sobre o jogo ou assuntos diversos. Essa funcionalidade também poderia gerar novos indicadores, como a quantidade de vezes que o mascote foi consultado e o tipo de dica solicitada.

Todas essas propostas de melhorias e novas funcionalidades não apenas enriquecerão a experiência dos usuários, mas também permitirão uma gestão mais eficaz e uma análise mais profunda dos dados coletados, contribuindo significativamente para o aprimoramento contínuo do jogo Lumni.

REFERÊNCIAS

- AKÇAPINAR, G.; HASNINE, M. N. Development and evaluation of a student-facing gamified learning analytics dashboard. **Visualizations and Dashboards for Learning Analytics**, p. 269–287, 2021.
- BACH, B. et al. Dashboard design patterns. **IEEE Transactions on Visualization and Computer Graphics**, v. 29, n. 1, p. 342–352, 2023.
- BANGOR, A.; KORTUM, P. T.; MILLER, J. T. The system usability scale (sus): an empirical evaluation. **International Journal of Human-Computer Interaction**, v. 24, n. 6, p. 574–594, 2008.
- BROOKE, J. Sus - a quick and dirty usability scale. In: JORDAN, P. W. et al. (Ed.). **Usability Evaluation in Industry**. 1. ed. London: Taylor Francis, 1996. cap. 21, p. 189–194.
- CALVO-MORATA, A. et al. Improving teacher game learning analytics dashboards through ad-hoc development. **Universal Computer Science**, v. 25, n. 12, p. 1507–1530, 2019.
- DANIEL, B. Big data and analytics in higher education: Opportunities and challenges. **British Journal of Educational Technology**, v. 46, n. 5, p. 904–920, 2015.
- DAVIS, F. D. Perceived usefulness, perceived ease of use, and user acceptance of information technology. **MIS Quarterly**, v. 13, n. 3, p. 319–340, 1989.
- ESCOBAR, M. G.; LENG RUBER, H. R.; GARCIA, G. M. R. Abordagens e técnicas ágeis, uma revisão acerca de suas vantagens e desvantagens. In: **Anais 36ª Jornada Acadêmica Integrada**. Santa Maria, RS, Brasil: UFSM, 2021.
- ESCOBAR, M. G. et al. Lumni - simplificando o aprendizado de engenharia de software na graduação. In: **Anais 37ª Jornada Acadêmica Integrada**. Santa Maria, RS, Brasil: UFSM, 2022.
- FARIAS, L. L. de. **Utilização de Game Learning Analytics para Verificação do Aprendizado em Jogo Séri o Voltado ao Ensino de Zoologia**. 2019. 58 f. Monografia (Trabalho de Conclusão de Curso) — Curso de Bacharelado em Sistemas de Informação, Universidade Federal Rural de Pernambuco, Recife, 2019.
- FEW, S. **Information dashboard design: The effective visual communication of data**. California: O'Reilly, 2006. v. 1, 223 p.
- FREIRE, M. et al. Game learning analytics: Learning analytics for serious games. **Learning, Design, and Technology**, v. 38, p. 1–29, 2016.
- FREITAS, S. de et al. How to use gamified dashboards and learning analytics for providing immediate student feedback and performance tracking in higher education. In: INTERNATIONAL WORLD WIDE WEB CONFERENCE, 26., 2017, Australia. **Games, Simulations and Immersive Environments**. Perth: WWW '17 Companion, 2017. p. 429–434. Disponível em: <<https://dl.acm.org/doi/10.1145/3041021.3054175>>.

GERALDES, W.; MARTINS, E.; AFONSECA, U. Avaliação da usabilidade do scratch utilizando o método system usability scale (sus). In: **Anais da X Escola Regional de Informática de Mato Grosso**. Porto Alegre, RS, Brasil: SBC, 2019. p. 25–30. ISSN 2447-5386. Disponível em: <<https://sol.sbc.org.br/index.php/eri-mt/article/view/8589>>.

GROSSI, M. G. R.; MINODA, D. de S.; FONSECA, R. G. P. Impacto da pandemia do covid-19 na educação: Reflexos na vida das famílias. **Teoria e Prática da Educação**, v. 23, n. 3, p. 150–170, 2020.

GUTIÉRREZ, F. et al. Lada: A learning analytics dashboard for academic advising. **Computers in Human Behavior**, v. 107, n. 105826, 2020.

HONDA, F. et al. Um estudo de caso para a implementação de game learning analytics (gla) no desenvolvimento de jogos educacionais. In: CONGRESSO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO, II., 2023, Porto Alegre. **Workshop de Aplicações Práticas de Learning Analytics em Instituições de Ensino no Brasil (WAPLA)**. Porto Alegre: Sociedade Brasileira de Computação, 2023. p. 138–146. Disponível em: <<https://doi.org/10.5753/wapla.2023.236221>>.

Jakob Nielsen. **10 Usability Heuristics for User Interface Design**. 1994. Acesso em 03 jun. 2024. Disponível em: <<https://www.nngroup.com/articles/ten-usability-heuristics/>>.

JANES, A.; SILLITTI, A.; SUCCI, G. Effective dashboard design. **Cutter IT Journal**, v. 26, n. 1, p. 17–24, 2013.

JOHAR, N. A. et al. Learning analytics on student engagement to enhance students learning performance: A systematic review. **Sustainability**, v. 15, n. 7849, 2023.

LEITNER, P.; KHALIL, M.; EBNER, M. Learning analytics in higher education a literature review. In: PEÑA-AYALA, A. (Ed.). **Learning Analytics: Fundamentals, Applications, and Trends**. 94. ed. [S.l.]: Springer Cham, 2017. p. 1–23.

MICHAEL, D. R.; CHEN, S. **Serious games: games that educate, train and inform**. [S.l.]: Thomson Course Technology, 2006.

NASCIMENTO, J. B.; RODRIGUES, R. L.; ANDRADE, V. L. V. X. D. Aplicações de game learning analytics na abordagem sobre conceitos de matemática. **Revista Novas Tecnologias na Educação**, v. 19, n. 2, p. 51–60, 2021.

NIELSEN, J. Usability 101: Introduction to usability. v. 4, n. 01, 2012.

PEÑA-AYALA, A. **Learning Analytics: Fundamentals, Applications, and Trends: A view of the current state of the art to enhance e-learning**. [S.l.]: Springer Cham, 2017. v. 1. 303 p. (Studies in Systems, Decision and Control, v. 1).

RAHMAN, A. A.; ADAMU, Y. B.; HARUN, P. Review on dashboard application from managerial perspective. **International Conference on Research and Innovation in Information Systems**, p. 1–5, 2017.

REICH, J. **Failure to Disrupt: why technology alone cant transform education**. Cambridge: Harvard University Press, 2020. 336 p.

SARIKAYA, A. et al. What do we talk about when we talk about dashboards? **IEEE Transactions on Visualization and Computer Graphics**, v. 25, n. 1, p. 682–692, 2019.

SERRANO-LAGUNA Ángel et al. Applying standards to systematize learning analytics in serious games. **Computer Standards Interfaces**, v. 50, p. 116–123, 2017.

SINGH, H. Building effective blended learning program, educational technology. **Educational Technology**, v. 43, n. 6, p. 51–54, 2003.

SPINELLI, C. **A Utilização de Game Learning Analytics em um Serious Game Voltado ao Turismo**. 2020. 56 f. Monografia (Trabalho de Conclusão de Curso) — Curso de Bacharelado em Sistemas de Informação, Universidade Federal Rural de Pernambuco, Recife, 2020.

WONG, J. et al. Educational theories and learning analytics: From data to knowledge. In: IFENTHALER, D.; MAH, D.-K.; YAU, J. Y.-K. (Ed.). **Utilizing Learning Analytics to Support Study Success**. Perth: Springer Cham, 2019. p. 3–25.

YIGITBASIOGLU, O.; VELCU-LAITINEN, O. A review of dashboards in performance management: Implications for design and research. **International Journal of Accounting Information Systems**, v. 13, n. 1, p. 41–59, 2012.