



**UNIVERSIDADE
FEDERAL RURAL
DE PERNAMBUCO**



Caio Henrique de Souza Farias

**Desenvolvimento de uma Abordagem para o
Aprendizado de Cultura Gastronômica Brasileira
com Utilização de Game Learning Analytics para
Avaliação de sua Efetividade**

Recife

Março de 2024

Caio Henrique de Souza Farias

**Desenvolvimento de uma Abordagem para o
Aprendizado de Cultura Gastronômica Brasileira
com Utilização de Game Learning Analytics para
Avaliação de sua Efetividade**

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

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

Orientador: Gilberto Amado de Azevedo Cysneiros Filho

Recife

Março de 2024

Desenvolvimento de uma Abordagem para o Aprendizado de Cultura Gastronômica Brasileira com Utilização de Game Learning Analytics para Avaliação de sua Efetividade

Caio Henrique de Souza Farias ¹, Gilberto Amado de Azevedo Cysneiros Filho ¹

¹Departamento de Estatística e Informática – Universidade Federal Rural de Pernambuco
Rua Dom Manuel de Medeiros, s/n, - CEP: 52171-900 – Recife – PE – Brasil

caio.hsfarias@ufrpe.br, gilberto.cysneirosfilho@ufrpe.br

Resumo. Explorar os aspectos da cultura gastronômica nacional não apenas enriquece a compreensão de uma parte fundamental da identidade cultural, mas também promove a apreciação e preservação de tradições culinárias. Diante desse cenário, se faz necessário buscar métodos eficazes para disseminar esse conhecimento, sendo os jogos educacionais uma das estratégias mais promissoras para atingir este objetivo. Contudo, a efetividade desses jogos nem sempre é garantida no processo de ensino. Para avaliar essa eficácia, propõe-se a utilização do Game Learning Analytics, uma abordagem que analisa dados que são coletados durante a interação do jogador com os elementos do jogo. Neste estudo é apresentado o desenvolvimento de um jogo que tem como objetivo servir como uma abordagem para o aprendizado de cultura gastronômica brasileira, enquanto utiliza o Game Learning Analytics como ferramenta essencial para mensurar e aprimorar sua efetividade educacional e IA Generativa para a geração das perguntas referentes aos objetivos educacionais. Este estudo obteve resultados satisfatórios, demonstrando que o jogo desenvolvido se mostrou eficaz em aprimorar o conhecimento dos jogadores acerca do tema abordado, com 93.7% dos jogadores apresentando um perfil de Mestre ou Aprendiz.

Abstract. Exploring aspects of national gastronomic culture not only enriches understanding of a fundamental part of cultural identity, but also promotes the appreciation and preservation of culinary traditions. Given this scenario, it is necessary to seek effective methods to disseminate this knowledge, with educational games being one of the most promising strategies to achieve this objective. However, the effectiveness of these games is not always guaranteed in the teaching process. To evaluate this effectiveness, we propose the use of Game Learning Analytics, an approach that analyzes data that is collected during the player's interaction with game elements. This study presents the development of a game that aims to serve as an approach to learning Brazilian gastronomic culture, while using Game Learning Analytics as an essential tool to measure and improve its educational effectiveness and Generative AI for generation of questions relating to educational objectives. This study obtained satisfactory results, demonstrating that the game developed was effective in improving players' knowledge about the topic covered, with 93.7% of players presenting a Master or Leaner profile.

1. Introdução

Segundo Marinho et al. (2017), “Através das manifestações, conhecimentos e vivências, a gastronomia comunica, diferencia e determina a identidade de um povo, agregando valores inquestionáveis ao lugar onde vivem e a tudo que os rodeia.”. Portanto, preservar as tradições culinárias através de métodos eficazes é essencial para manter a identidade cultural, especialmente para as gerações futuras.

Nesse cenário, os jogos digitais surgem como uma maneira eficaz de transmitir conhecimento, pois a imersão e entretenimento que esta mídia oferece pode contribuir significativamente para o aprendizado dos jogadores [Hsiao 2007]. A proposta lúdica de um jogo é desafiar o jogador, exigindo a elaboração de estratégias e o entendimento das interações entre seus elementos para vencê-lo [Gros. 2003]. Ao incentivar esses processos, o jogo promove o desenvolvimento intelectual, estimulando habilidades cognitivas como resolução de problemas, pensamento crítico, tomada de decisões e criatividade [Balasubramanian and Wilson. 2006].

Com 70,1% da população brasileira relatando ter jogado jogos eletrônicos em 2023 [PGB 2023], essa popularidade pode ser aproveitada para disseminar diversos tipos de conhecimento, incluindo o da cultura gastronômica. No entanto, a avaliação da eficácia educacional dessa abordagem ainda é desafiadora, pois existem poucos métodos para medir sua efetividade, o que dificulta a integração dos jogos digitais no ensino por parte de professores e educadores.

Game Learning Analytics é uma abordagem que analisa a aprendizagem do jogador ao utilizar dados coletados durante a sua jornada, relacionando-os com dados de aprendizagem, passando de abordagens apenas baseadas em teoria para abordagens baseadas em dados e evidências [Freire et al. 2016]. Com essa abordagem é possível avaliar a eficácia educacional dos jogos digitais. A coleta de dados pode ocorrer de forma transparente para o jogador, que poderá se concentrar exclusivamente na mecânica e nas estratégias para completar o jogo.

1.1. Objetivo

O objetivo deste trabalho é criar um jogo educativo sobre gastronomia brasileira, visando auxiliar os jogadores no aprendizado desse tema. Para validar sua eficácia, será utilizado *Game Learning Analytics* para analisar os dados coletados durante a interação dos jogadores com o jogo.

Os objetivos específicos deste trabalho são:

1. Desenvolver um aplicativo educacional com o framework *Unity*;
2. Aplicar a metodologia Serrano-Laguna [Ángel Serrano-Laguna et al. 2017], juntamente com *Game Learning Analytics*;
3. Utilizar análise de dados estatísticos para provar a sua eficácia como ferramenta de aprendizagem;
4. Aplicar IA Generativa na criação das perguntas do jogo.

2. Referencial Teórico

Este capítulo visa fornecer os princípios teóricos essenciais para embasar esta pesquisa. Serão conceituados os temas Game-based learning, Gamificação, *Game Learning Analytics* e IA Generativa.

2.1. Game-Based Learning

Muitos acreditam que jogos digitais serão ferramentas de ensino essenciais no futuro [Huang et al. 2013]. No entanto, é importante distinguir entre jogos convencionais e aqueles projetados para fins educacionais. Enquanto os jogos convencionais visam principalmente ao entretenimento, os *Serious Games* ou *Game-Based Learning* exploram o potencial dos jogos para envolver os usuários em objetivos educacionais específicos, como a aquisição de novos conhecimentos e habilidades [Corti 2006]. Michael e Chen (2006) definem *Serious Game* como jogos que têm um propósito principal diferente do entretenimento ou da diversão. No entanto, eles ressaltam que isso não significa que os jogos sérios não sejam agradáveis ou divertidos; apenas indicam que há outro objetivo, sendo a precisão da simulação ou o efeito do treinamento mais significativo. No entanto, é importante observar que Huizinga (1980) definiu os jogos como uma atividade livre, conscientemente separada da vida comum e caracterizada por ser não séria. Seguindo essa definição, os jogos não podem ser considerados sérios. Essa perspectiva oferece uma boa indicação das contradições encontradas em comparações da literatura disponível.

É possível personalizar facilmente o aprendizado para cada jogador por meio de análises em tempo real que identificam seus pontos fortes e fracos, e também acompanhar o progresso dos alunos em segundo plano, o que significa que eles frequentemente não percebem que estão sendo avaliados. Este conceito levou à uma mudança na capacidade dos professores de imergir os alunos no conteúdo educacional, proporcionando uma compreensão mais profunda das diversas facetas que se combinam para garantir o sucesso da aprendizagem baseada em jogos [Plass et al. 2015].

2.1.1. Gamification of Learning

Dois termos são comumente utilizados no contexto de Jogos Sérios: *Game-Based Learning* e *Gamification of Learning*. No *Game-Based Learning* (GBL), existe um equilíbrio entre a jogabilidade e a necessidade de cobrir o conteúdo educacional desejado. Quando o GBL surge na forma de um jogo digital, é frequentemente referido como aprendizagem baseada em jogos digitais. No *Gamification of Learning*, elementos de um jogo são adicionados às atividades de aprendizagem tradicionais que podem não ser tradicionalmente estimulantes para os alunos [Joshua Prieur et al. 2019]. Elementos semelhantes a jogos adicionados a essas atividades de aprendizagem incluem a obtenção de pontos, níveis, prêmios e outras características comumente observadas em videogames digitais [Plass et al. 2015].

Ambos os termos têm a motivação como um dos seus pilares. Ela é um aspecto fundamental da aprendizagem eficaz, sendo necessário sustentá-la por meio de *feedback*, respostas, reflexão e envolvimento ativo [Garris et al. 2002].

2.1.2. *Modding* e Desenvolvimento de Jogos Sérios

Atualmente, o processo de desenvolvimento de jogos está mais direcionado ao entretenimento do que ao mercado educacional. Consequentemente, jogos com objetivos educacionais, por receberem menos investimento, acabam não sendo atrativos para os jogadores, sendo deficitários em jogabilidade e gráficos. Isso faz com que se crie uma barreira de entrada para esses jogos.

Uma das tendências que podem ser usadas para tornar os jogos mais atrativos e eficazes, e também permitir que desenvolvedores de jogos, educadores e alunos trabalhem juntos para desenvolver jogos para fins de aprendizagem é o *modding*, que é quando o software ou hardware é modificado para executar uma função não pretendida originalmente. No contexto dos jogos, os *mods* são modificações criadas para jogos de lazer e podem oferecer novos conteúdos ou alterar significativamente um jogo existente [de Freitas 2006]. Um exemplo seria a utilização de mods no jogo *Minecraft*, para o ensino de Inteligência Artificial, como descrito no estudo “Teaching game AI through *Minecraft* mods” [Bayliss 2012]. Essa tendência permite modificar jogos criados inicialmente para lazer, fazendo com que eles atendam aos objetivos educacionais, e ao mesmo tempo mantendo a qualidade gráfica e de jogabilidade.

2.2. *Learning Analytics*

Learning Analytics, segundo Baker e Inventado (2014), pode ser definida como a exploração de dados em benefício da educação e da ciência da aprendizagem.

Essa abordagem é uma prática cada vez mais comum em ambientes educacionais, especialmente em plataformas online de gestão de aprendizagem (LMS). Inicialmente, essa abordagem focava principalmente na monitorização dos logs de acesso do servidor web, o que permitia rastrear como os alunos interagem com o sistema [Arnold and Pistilli 2012]. No entanto, à medida que as ferramentas de *Learning Analytics* se tornaram mais sofisticadas, elas passaram a capturar uma gama mais ampla de dados, incluindo resultados de testes, padrões de acesso a conteúdo, tempo gasto em diferentes atividades e até mesmo interações com recursos multimídia.

Ao analisar esses dados, os educadores podem obter insights sobre o desempenho e o comportamento dos alunos [Freire et al. 2016]. Por exemplo, podem identificar padrões de dificuldade em determinados tópicos, identificar alunos que estão em risco de fracasso e adaptar as estratégias de ensino de acordo com as necessidades individuais dos alunos. Essa abordagem tem o potencial de transformar a forma como a educação é entregue e personalizada para atender às necessidades únicas de cada aluno.

À medida que os materiais de aprendizagem se tornam mais complexos, o potencial da análise de aprendizagem aumenta ainda mais [Freire et al. 2016]. No entanto, para aproveitar ao máximo essa abordagem, é essencial considerar não apenas os dados em si, mas também o contexto em que são coletados e interpretados. Isso requer uma colaboração estreita entre educadores e especialistas em análise de dados para garantir que os insights gerados sejam relevantes e acionáveis.

2.3. *Game Analytics*

Game Analytics é o termo usado pela indústria de videogames para a aplicação de análises ao desenvolvimento e pesquisa de jogos para entender melhor como os usuários jogam, encontrar erros e melhorar a experiência de jogo [Seif El-Nasr et al. 2013]. Embora o objetivo do *Learning Analytics* seja apoiar as indústrias de aprendizagem online, o do *Game Analytics* é apoiar o crescimento dos jogos digitais de entretenimento [Loh et al. 2015].

Com o *Game Analytics* é possível coletar muitos tipos de dados. Dependendo do aspecto do ciclo do jogo ao qual estão relacionados, esses dados podem ser vistos sob duas perspectivas diferentes: uma mais técnica sobre o jogo e a infraestrutura do jogo, e outra mais focada nos dados e na experiência do usuário [Freire et al. 2016].

Sejam jogos educacionais ou de entretenimento, eles geram grandes volumes de dados de interação, superando outras formas de conteúdo devido ao ciclo de *feedback* rápido entre interação e resposta inerente aos jogos [Van Eck 2006]. Assim, mesmo sessões curtas de jogo podem gerar uma riqueza de dados significativos [Freire et al. 2016].

A análise desses registros de interação por meio de técnicas de mineração de dados e visualização oferece aos desenvolvedores insights valiosos sobre como os jogadores interagem com o jogo. Essa compreensão detalhada é essencial para otimizar a jogabilidade, corrigir problemas e criar experiências envolventes e imersivas para os jogadores.

2.4. *Game Learning Analytics*

Ao criar um *Serious Game*, os objetivos educacionais do *Learning Analytics* e as ferramentas e tecnologias do *Game Analytics* devem ser combinados, no que poderia ser chamado de *Game Learning Analytics* (GLA) [Freire et al. 2016].

Com essa combinação, é possível maximizar o impacto do jogo no processo de aprendizagem, promovendo uma experiência educacional mais dinâmica e personalizada.

Uma implementação básica de um sistema *Game Learning Analytics* precisaria inspecionar como cada jogador interage com o jogo, armazenando informações detalhadas sobre as interações e as mudanças no estado interno do jogo para análise posterior. Essa análise normalmente é realizada em um servidor remoto, e não dentro do jogo, para que os dados possam ser agregados e as análises ajustadas sem a necessidade de modificar o código do jogo [Freire et al. 2016]. Essa abordagem garante uma análise robusta e flexível, possibilitando insights para melhorar a experiência de aprendizado e a jogabilidade.

Tal implementação normalmente precisaria fornecer os seguintes artefatos [Freire et al. 2016]:

- Instrumentação - Os componentes do jogo armazenam informações da interação do jogador, para posteriormente serem enviados ao servidor em lotes, assim reduzindo a pressão no servidor de coleta.
- Coleta e Armazenamento - É necessário um sistema do lado do servidor para receber, classificar e armazenar todas as interações enviadas pela instrumentação, permitindo consultas futuras e análises agregadas.

- Análise em tempo real - É importante ter acesso a análises em tempo real ou com mínimo atraso para permitir intervenções direcionadas durante uma sessão de jogo e melhorar a eficácia do aprendizado.
- Análise de dados agregados - Uma agregação muito maior, baseada em análises mais complexas, faz sentido quando as partes interessadas precisam de uma visão mais ampla das diferentes sessões de jogo.
- Indicadores Chave de Desempenho (KPI) - Educadores podem usar KPIs para medir notas, conclusões e eficácia educacional. Os sistemas analíticos devem buscar conexões entre esses KPIs e outros dados educacionais.
- Dashboards Analíticos - Os dashboards devem agregar conjuntos de análises e visualizações para consulta das partes interessadas.

A Figura 1 oferece uma representação abstrata de uma implementação potencial para um sistema GLA com essas características. O processo inicia-se no jogo, que transmite os dados para um coletor. Estes dados são então organizados e agregados, resultando em informações essenciais para a criação de relatórios e visualizações, seja em tempo real ou não. Essas informações também podem ser utilizadas para avaliar os alunos e, por fim, o loop é completado por meio do adaptador, que devolve instruções ao jogo para adaptá-lo ao jogador.

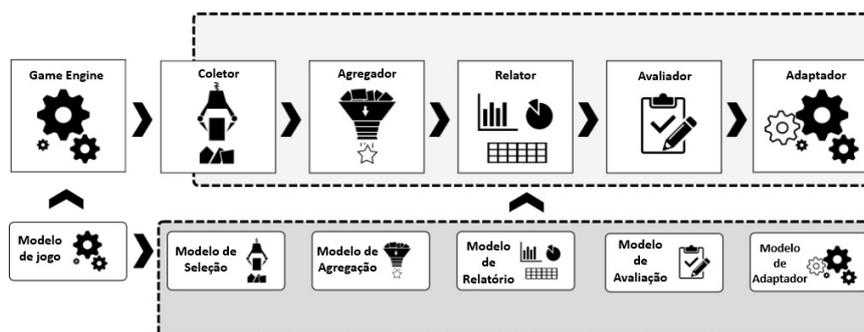


Figura 1. Arquitetura conceitual para um sistema de *Game Learning Analytics* [Freire et al. 2016]

2.5. IA Generativa e *ChatGPT*

A Inteligência Artificial (IA) tem despertado considerável interesse em diversas disciplinas e setores [Hyder et al. 2019]. a IA pode ser definida como “um campo da ciência e da engenharia preocupado com a compreensão computacional do que é comumente chamado de comportamento inteligente, e com a criação de artefatos que exibem tal comportamento” [SC. 1992].

O lançamento do aplicativo *ChatGPT* pela *OpenAI* no final de 2022 atraiu atenção global, destacando-se como um representante da classe de modelos de linguagem conhecidos como *Generative Pre-trained Transformers* (GPT). Esses modelos, como observado por Cascella et al. (2023), são *Large Language Models* (LLMs) que empregam técnicas de aprendizado profundo e são treinados extensivamente com vastas quantidades de dados.

O *ChatGPT* foi projetado e ajustado especificamente para uso conversacional para produzir respostas semelhantes às humanas, aproveitando sua riqueza de informações e

conhecimento [Nah et al. 2023]. Essas habilidades são impulsionadas pela IA generativa, que pode gerar texto e conteúdo criativo, além de consolidar dados para análise [Dasborough 2023]. Espera-se que o advento desta IA de última geração transformará profundamente a sociedade, bem como a forma como vivemos, trabalhamos, aprendemos e comunicamos [Nah et al. 2023]. A IA generativa tem a capacidade de gerar uma variedade de conteúdos multimodais, incluindo texto, áudio, imagem, vídeo e modelos tridimensionais. Exemplos representativos incluem *ChatGPT* para texto, *Midjourney* para imagens e *DeepBrain* para vídeos.

O *ChatGPT* tem capacidade sem precedentes para realizar tarefas extremamente complexas, gerar poemas [Köbis and Mossink 2021], declarações políticas [Bullock and Luengo-Oroz 2019], artigos acadêmicos [Hu 2023] e até mesmo escrever e depurar código original [Williams 2023]. No entanto, apesar dos benefícios potenciais, ele apresenta limitações, como a geração de respostas imprecisas e a criação de informações fictícias [Qadir 2022].

Embora o *ChatGPT* tenha o potencial de ser uma ferramenta valiosa na educação, é crucial que os educadores estejam cientes das limitações dos dados de treinamento e exerçam cautela ao utilizar a ferramenta para evitar resultados tendenciosos [Zhai 2023]. Portanto, é fundamental revisar e verificar as respostas geradas pela ferramenta para garantir precisão e adequação.

3. Trabalhos Relacionados

Um marco inicial no uso de jogos para o aprendizado foi o lançamento, na década de 80, do jogo chamado *Number Munchers* [Mobygames 2005]. Focado no ensino de conceitos de matemática básica, este jogo foi um dos primeiros a ter como objetivo explícito a educação. A Figura 2 apresenta uma tela deste jogo.



Figura 2. Number Munchers (DOS) [Mobygames 2005]

Atualmente, novas modalidades de jogos, como os aplicativos para dispositivos móveis e os jogos de realidade aumentada, proporcionam oportunidades para a integração dos jogos em ambientes externos [de Freitas 2006], além da possibilidade de incorporar métodos de avaliação de sua efetividade educacional.

Relacionado à medição de efetividade educacional em jogos sérios, o trabalho “Modelo Conceitual para Planejamento da Avaliação em Jogos Sérios”

avaliação desses jogos para fins educacionais. Especialmente, a apresentada por Serrano-Laguna [Ángel Serrano-Laguna et al. 2017], com seu foco no rastreamento contínuo dentro do jogo alinhado aos princípios de *Game Learning Analytics*, servirá de grande inspiração para este trabalho.

4. Materiais e Métodos

Este estudo adotou a metodologia proposta por Serrano-Laguna [Ángel Serrano-Laguna et al. 2017] como fundamento para a criação de um jogo sério destinado ao ensino da cultura gastronômica brasileira. Por meio dessa abordagem, é possível inferir resultados de aprendizagem e eficácia de Jogos Sérios com base em rastreamento não disruptivo, ou seja, sem interromper o fluxo do jogo.

Os dados devem ser coletados e enviados a um servidor. Posteriormente, eles devem ser agregados e analisados, resultando na criação de visualizações acessíveis para consulta. Este procedimento está alinhado aos princípios do *Game Learning Analytics*.

A metodologia busca alcançar dois objetivos, sendo eles:

1. Facilitar a medição dos resultados de aprendizagem de Jogos Sérios.
2. Fornecer uma forma sistemática de avaliar a eficácia dos jogos sérios como um todo.

A mecânica de jogo escolhida deve atender a dois requisitos: 1) ser adequada ao conteúdo objetivo de aprendizagem, onde as mecânicas de aprendizagem são mapeadas às mecânicas de jogo; e 2) que a jogabilidade dos jogadores possa produzir observáveis de resultados de aprendizagem (também chamados de eventos) que atestam o conhecimento ou habilidade dos jogadores.

Esta metodologia está pautada em modelos relacionados aos benefícios que o *feedback* contínuo recebido durante o processo tem sobre o aprendizado. Nesse sentido, a mecânica do jogo deve fazer com que os jogadores formem estratégias, experimentem no mundo do jogo, recebam *feedback* e reflitam sobre os resultados.

No domínio dos jogos comerciais, existem propostas semelhantes que dividem a experimentação em duas subetapas: a experimentação num “ambiente de jogo seguro”, onde o nível de dificuldade do desafio a superar é baixo e os erros não são punidos, e a experimentação em um “ambiente de jogo inseguro”, onde o nível de dificuldade é maior e os erros são punidos com, por exemplo, perder vidas de jogo, moedas, pontuação, etc. [Nutt C 2016].

A metodologia, baseada nessas ideias, propõe que os objetivos de aprendizagem sejam apresentados aos jogadores ao longo de 3 fases, com 2 pontos de medição não disruptiva, sendo eles a fase prática e a de domínio, conforme ilustrado na Figura 4.

- Estratégia - Nesta fase, os jogadores são apresentados pela primeira vez às mecânicas do jogo e aos objetivos de aprendizagem, incluindo conhecimentos que possam necessitar em etapas subsequentes, bem como instruções concretas sobre como interagir com o mundo do jogo, por exemplo através de cenas não interativas ou tutoriais de jogos.
- Prática - Aqui, os jogadores passam a aplicar os conhecimentos apresentados na fase anterior. A fase prática deve ocorrer em um ambiente de jogo onde os erros

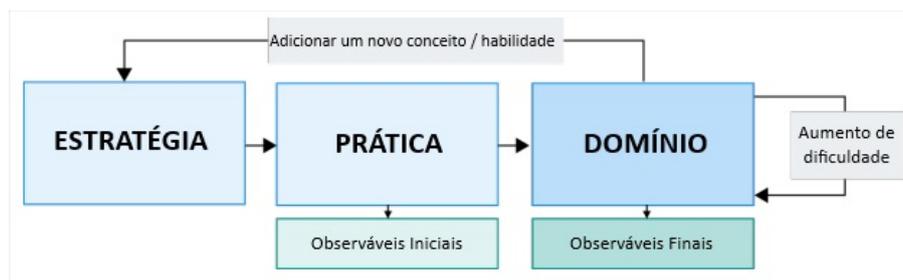


Figura 4. Padrão para o design das fases de um Jogo Sério [Ángel Serrano-Laguna et al. 2017].

dos jogadores tem pouca ou nenhuma consequência. Essa experimentação deve ser possibilitada para que os jogadores pratiquem suas estratégias. Se forem bem sucedidas, elas serão refinadas e utilizadas na fase de domínio.

Nesta fase, os jogadores serão testados pela primeira vez, possibilitando a verificação do conhecimento inicial do jogador acerca do objetivo de aprendizagem através da coleta de observáveis.

- Domínio - Os jogadores terão que comprovar que adquiriram os conhecimentos pretendidos, enfrentando desafios semelhantes aos apresentados na fase prática, mas com maiores consequências no jogo. Durante esta fase, serão coletados os observáveis finais. Com esses dados, será possível medir o progresso final do jogador com relação aos objetivos de aprendizagem.

4.1. Metodologia para a análise dos resultados

Cada interação coletada será associada a uma fase de aprendizagem (estratégia, prática ou domínio). As interações da fase de estratégia não serão utilizadas para inferir resultados de aprendizagem, uma vez que esta fase deve apenas contextualizar a mecânica do jogo.

4.1.1. Avaliações e Limites

Após o jogador finalizar as fases prática e de domínio, será possível analisar a efetividade do jogo e realizar avaliações específicas para cada uma dessas etapas, sendo elas:

- Avaliação Inicial (*AI*) - utilizando dados obtidos na fase prática, ela estima o conhecimento inicial do jogador. Um valor alto indica que o jogador já possuía algum conhecimento sobre o assunto abordado antes de jogar, enquanto um valor baixo significa o oposto.
- Avaliação Final (*AF*) - utilizando dados obtidos na fase de domínio, ela estima o resultado da aprendizagem. Um valor alto significa que o jogador conseguiu atingir a meta de aprendizado estabelecida.

Para determinar as mudanças no conhecimento do jogadores, junto com as avaliações, também é necessário definir dois limites de avaliação: um Limite Inicial (*LI*) associado à Avaliação Inicial (*AI*), e um Limite Final (*LF*) associado à Avaliação Final (*AF*). Esses limites são como pontuações mínimas usadas para determinar se uma fase foi concluída com sucesso ou não.

Para as notas limites (LI e LF) do jogo desenvolvido, foi escolhido o valor 0.7, pois este é o valor que a maioria das instituições de ensino utilizam para definir as aprovações ou reprovações dos alunos.

4.1.2. Definição de perfis de acordo com o aprendizado

Ao relacionar os limites e as avaliações, é possível quantificar o resultado do aprendizado de cada jogador e estabelecer perfis para classificá-los com base no nível de competência alcançado.

- Se Avaliação Final (AF) \geq Limite Final (LF), o jogador conseguiu completar a fase de domínio do jogo, possuindo os conhecimentos pretendidos e superando a pontuação mínima estabelecida pelo Limite Final (LF). Dependendo do valor da Avaliação Inicial (AI), podemos classificar os jogadores como:
 - Aprendizes, se Avaliação Inicial (AI) $<$ Limite Inicial (LI): Os jogadores cometeram erros na fase prática, indicando, assim, que não possuíam o conhecimento prévio sobre o tema do jogo. Contudo, eles terminaram finalizando corretamente o jogo na fase de domínio, o que significa que houve um ganho no conhecimento do jogador durante a sua jogada.
 - Mestres, se Avaliação Inicial (AI) \geq Limite Inicial (LI): O jogador não cometeu erros durante a fase prática, indicando que ele já possuía o conhecimento sobre o tema do jogo antes de jogar.
- Se Avaliação Final (AF) $<$ Limite Final (LF), os jogadores falharam na fase de domínio e não conseguiram obter o conhecimento pretendido pelo jogo. Dependendo do valor de Avaliação Inicial (AI), podemos classificar os jogadores em duas categorias diferentes:
 - Não-Aprendizes, se Avaliação Inicial (AI) $<$ Limite Inicial (LI): os jogadores falharam também na fase de prática, indicando que tiveram pouco ou nenhum benefício educacional durante o jogo.
 - Deslocados, se Avaliação inicial (AI) \geq Limite Inicial (LI): os jogadores foram bem sucedidos durante a fase prática, mas não conseguiram aplicar na fase de domínio o conhecimento adquirido.

Se a maioria dos jogadores forem classificados como aprendizes, o jogo será altamente eficaz, pois a maioria dos jogadores aprendeu alguma coisa enquanto jogava. Se a maioria for classificado como mestre, o jogo produziu pouco efeito de aprendizagem, pois a maioria dos jogadores já possuía o conhecimento pretendido antes de jogar. Já se a maioria for de não-aprendizes, o jogo não era nada eficaz, uma vez que a maioria dos jogadores não conseguiu ter sucesso em nenhuma fase. E, finalmente, a maioria de deslocados indicaria que o jogo ou as fórmulas de AF e AI escolhidas provavelmente apresentam falhas de design.

Além dos perfis, outros fatores podem definir a efetividade de um Jogo Sérioso, como a idade, gênero e a experiência prévia com jogos digitais ou com o assunto abordado por eles.

4.2. Projeto e desenvolvimento do jogo

Para este trabalho, seguindo a metodologia de Serrano-Laguna [Ángel Serrano-Laguna et al. 2017], foi desenvolvido um jogo chamado “Jornada Culinária”, tendo como objetivo servir como uma abordagem para o ensino da cultura gastronômica brasileira. Os dados coletados durante o jogo serão utilizados para definir os perfis dos jogadores.

O desenvolvimento se baseou no conceito de *modding*, explicado na Seção 2.1.2, no qual é possível fazer modificações em um jogo para que ele atenda aos objetivos educacionais específicos, se aproveitando da qualidade gráfica que ele proporciona.

Para o desenvolvimento da aplicação, foi utilizado o jogo de demonstração Dragon Crashers [Unity 2021] desenvolvido pela *Unity Technologies*, que é a desenvolvedora do framework utilizado no desenvolvimento da aplicação, e disponibilizado gratuitamente na loja oficial da ferramenta.

Dragon Crashers é um projeto de demonstração oficial que apresenta o conjunto nativo de ferramentas 2D e tecnologia gráfica do *Unity*, possuindo, assim, grande apelo visual.

A jogabilidade original era do gênero *Idle RPG*, ou *RPG* ocioso, muito popular nos jogos mobile, que consiste em um sub gênero do *RPG* caracterizado por seu design de jogabilidade passivo ou automático. Em um *Idle RPG*, a interação do jogador é intencionalmente minimizada e, em alguns casos, nem sequer necessária [Airbridge 2023]. Nesse sentido, como demonstrado na Figura 5, o jogo consistia em esperar os heróis derrotarem os vilões, não sendo necessária nenhuma interação do usuário.



Figura 5. Dragon Crashers [Unity 2021].

O jogo foi adaptado e introduzido um sistema de quiz, onde o resultado das respostas estão diretamente ligadas à jogabilidade e à medição da efetividade educacional. Nele são apresentados três módulos, cada um abordando um tema da gastronomia brasileira, sendo eles: Pratos Típicos, Ingredientes Típicos e Heranças Culinárias. O próximo módulo estará disponível assim que o jogador completar o módulo anterior com sucesso.

Depois de criar uma conta e selecionar o tipo do personagem, o jogador é direcionado ao menu principal, como mostrado na Figura 6. Ao clicar em jogar, após um vídeo apresentando o cenário, junto com o herói e o vilão, começa a batalha.



Figura 6. Tela inicial. Fonte: Elaborado pelo autor.

4.2.1. Jogabilidade

Ao clicar no ícone do herói, uma tela com uma pergunta relacionada ao tema do módulo aparecerá e o jogador poderá selecionar uma das alternativas, como demonstrado na Figura 7.

Ao selecionar, um sistema de *feedback* imediato mostrará se ele errou ou acertou a pergunta, como mostrado na Figura 8. Esse sistema é necessário, principalmente na fase prática, para que ele consiga memorizar a resposta correta.

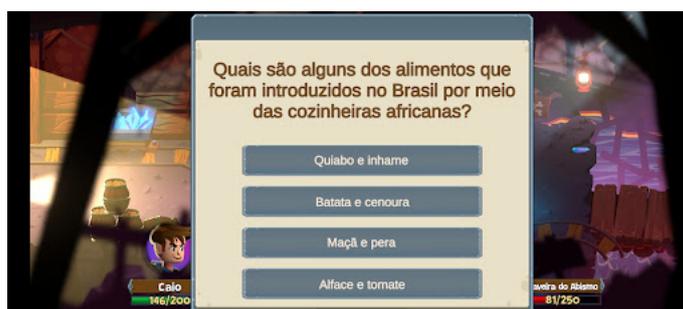


Figura 7. Tela de pergunta. Fonte: Elaborado pelo autor.

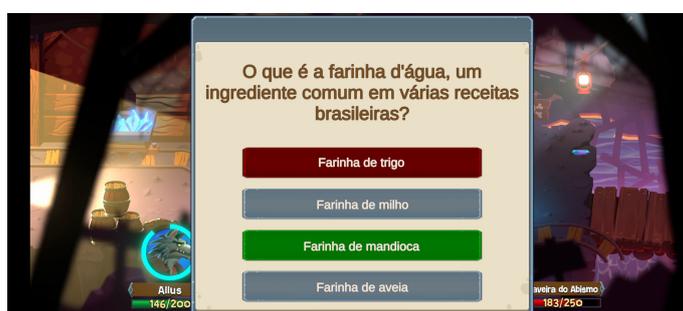


Figura 8. *Feedback* imediato. Fonte: Elaborado pelo autor.

Se o jogador acertar, será carregada uma porcentagem da habilidade principal do herói, que servirá como um mecanismo de recompensa, utilizado em sistemas que possuem gamificação. Se ele errar, é definido aleatoriamente uma quantidade da habilidade para ser carregada, porém, sendo até 70% do que seria se ele acertasse a pergunta, servindo como sistema de punição.



Figura 9. Habilidade especial. Fonte: Elaborado pelo autor.

A habilidade principal consiste em um ataque especial, demonstrado na Figura 9, onde o herói ataca o vilão com uma animação mais elaborada. É possível acionar esta habilidade depois que ela é carregada totalmente como consequência dos erros e acertos do jogador.

Como o objetivo do jogo é fazer com que o jogador responda todas as perguntas, o dano recebido pelos personagens, mostrado na Figura 9 em vermelho, é baseado na vida de cada um, fazendo com que eles não sejam derrotados até que a última pergunta seja respondida. A demonstração da jogabilidade em vídeo está disponível no YouTube.

4.2.2. Definição das perguntas

As perguntas desempenham um papel fundamental no contexto do jogo proposto, pois será por meio delas que se poderá obter dados importantes sobre os efeitos do jogo no processo de aprendizagem.

No entanto, a elaboração de perguntas de qualidade para um jogo educacional pode ser uma tarefa complexa e demorada. É necessário garantir que as perguntas sejam pertinentes ao conteúdo educacional, desafiadoras o suficiente para estimular o pensamento crítico dos jogadores e adequadas ao nível de habilidade dos mesmos. Nesse contexto, o uso de tecnologias de inteligência artificial pode representar uma solução promissora para a geração automatizada de perguntas.

Como explicado na Seção 2.5, o *ChatGPT* surge como uma ferramenta versátil para auxiliar os seres humanos em várias áreas. Esta ferramenta também pode ser aproveitada para gerar perguntas contextualmente adequadas e desafiadoras que contribuam para os objetivos educacionais do jogo.

Para este projeto, foi pedido ao *ChatGPT* que gerasse perguntas sobre os temas, sendo eles:

1. Pratos típicos da gastronomia brasileira. Para este tema, foi utilizado o seguinte *prompt*: Elabore 20 perguntas sobre os pratos típicos da gastronomia brasileira. Para cada questão, crie 4 alternativas e indique a alternativa correta. Cite uma curiosidade sobre cada pergunta. Coloque em uma tabela.
2. Ingredientes típicos da gastronomia brasileira. Para este tema, foi utilizado o seguinte *prompt*: Elabore 20 perguntas sobre os ingredientes típicos da gastronomia brasileira. Para cada questão, crie 4 alternativas e indique a alternativa correta.

- Cite uma curiosidade sobre cada pergunta. Coloque em uma tabela.
3. Heranças culturais da gastronomia brasileira. Para este tema, foi utilizado o seguinte *prompt*: Elabore 20 perguntas sobre as heranças culturais da gastronomia brasileira, incluindo referências portuguesas, indígenas e africanas. Para cada questão, crie 4 alternativas e indique a alternativa correta. Cite uma curiosidade sobre cada pergunta. Coloque em uma tabela.

Foram selecionadas 10 perguntas para o tema 1, 10 perguntas para o tema 2 e 7 perguntas para o tema 3. Essa quantidade foi pensada para que o jogo não se tornasse muito cansativo para os jogadores. Devido às limitações explicadas da ferramenta, todas as perguntas selecionadas foram checadas e, quando necessário, modificadas para garantir a precisão e a veracidade das informações apresentadas. Todas as perguntas podem ser encontradas em [Farias 2023c], juntamente com a referência de onde foi validada a informação.

4.2.3. Fases do Método

Adaptando a metodologia proposta por Serrano-Laguna [Ángel Serrano-Laguna et al. 2017], devido a mecânica do jogo ser bem simples, foi decidido colocar no jogo apenas as fases prática e domínio:

Fase Prática: Como mostrado na Figura 6, no menu principal existe um botão “Jogar”, que, depois de clicado, direciona o jogador para a primeira batalha. Nesta fase, ele enfrenta o primeiro inimigo. A fase prática é criada para que o jogador experimente estratégias e possa errar sem sofrer muitas punições. Ao término das questões, independentemente da quantidade de questões corretas, é liberada a habilidade especial para que o jogador finalize o inimigo. Após isso, ele é direcionado para a próxima batalha, que é a fase de domínio.

Fase de Domínio: Após finalizar a fase prática, o jogador é direcionado para a fase de domínio, onde ele enfrenta o “chefe final”, um sistema bastante comum em jogos para entretenimento. Como o objetivo desta fase é que o jogador comprove que adquiriu os conhecimentos pretendidos, as perguntas da fase prática serão repetidas. Após responder todas as perguntas, será calculada uma nota. Se ela for menor que 0.7, o inimigo lançará uma habilidade e derrotará o jogador. Caso contrário, a habilidade do personagem aliado será habilitada, derrotando o inimigo final. O valor definido para a nota será explicado na próxima seção.

Após finalizar a fase de domínio, o jogador será direcionado ao menu principal. Tendo passado de módulo, um próximo será habilitado, senão, ele terá que repetir o anterior até que consiga uma nota maior que 0.7 nesta fase.

4.2.4. Pontuação

A nota é calculada da seguinte forma: $P = (c/n)$, sendo c a quantidade de questões corretas e n a quantidade de questões totais. Por exemplo, caso $c = 7$ e $n = 10$, o jogador conseguiu ser aprovado na fase com uma nota 0.7. Caso o jogador possua uma pontuação menor que 0.7, ele será considerado reprovado na fase.

4.3. Ferramentas utilizadas

Essa seção visa descrever as ferramentas que foram utilizadas para o desenvolvimento do jogo.

Para o desenvolvimento do aplicativo Android, foi escolhida a ferramenta *Unity*. Com ela é possível a construção de aplicativos 2D e 3D, como jogos e simulações, usando a linguagem de programação *C#*. O *Unity* é muito popular para o desenvolvimento de jogos, sendo mais de 50% dos jogos publicados feitos com esta ferramenta [Microsoft 2023].

Após o desenvolvimento, o aplicativo foi disponibilizado na *Play Store* para teste fechado. Todo o código desenvolvido pode ser encontrado no *Github* [Farias 2023b].

A coleta e armazenamento dos dados foi feita utilizando a biblioteca do *Firestore*, que é um banco de dados flexível e escalonável, criado com a infraestrutura do *Google Cloud*, para armazenar e sincronizar dados, mantendo-os em sincronia em aplicativos cliente usando listeners em tempo real.

Para a autenticação dos usuários, ao entrar no jogo pela primeira vez, os jogadores devem fazer o login com uma conta *Google*. Após isso, os principais dados armazenados são os dados básicos de perfil dos jogadores, mostrado na Figura 10; pergunta respondida pelo jogador, mostrado na Figura 11; as perguntas do jogo, Figura 12; e informações como interações dentro do jogo, Figura 13.



Figura 10. Dados básicos - Estrutura. Fonte: Elaborado pelo autor.

A coleta de dados é feita sem interromper o jogo. Como definido no artefato instrumentação, na Seção 2.4, primeiro as respostas são coletadas em memória, mostrado na Figura 14, e, após a finalização do módulo, elas são enviadas ao servidor em lotes, como mostrado na Figura 15.

Para agrupar e analisar os dados foi utilizada linguagem de programação *Python*, que é bem popular devido à sua versatilidade e simplicidade, contando com uma vasta quantidade de bibliotecas. Entre elas está o *Pandas*, que é uma biblioteca essencial para análise de dados.

De maneira geral, o *Pandas* pode ser utilizado para várias atividades e processos,

```
0Ex3g3bUoGykP0vwqYs3
+ Start collection
+ Add field
  attemptNumber: 2
  correct: true
  correctAnswer: "C"
  lagunasPhase: "practice"
  lastUpdated: January 19, 2024 at 10:50:48 AM UTC-3
  question: 27
  user: "GyaYyj1DPDQCFL8dtFJeLUbnqsr2"
  userAnswer: "C"
```

Figura 11. Pergunta respondida - Estrutura. Fonte: Elaborado pelo autor.

```
3
+ Start collection
+ Add field
  alternativeA: "Massa de milho"
  alternativeB: "Massa de feijão-fradinho"
  alternativeC: "Massa de mandioca"
  alternativeD: "Massa de arroz"
  correctAnswer: "B"
  level: "1"
  text: "Do que é feito o Acarajé, um famoso quitute da Bahia?"
```

Figura 12. Exemplo de pergunta - Estrutura. Fonte: Elaborado pelo autor.

sendo eles: limpeza e tratamento de dados, análise exploratória de dados, consultas e queries em bancos de dados e visualização de dados. Todo o código utilizado está disponível em [Farias 2023a].

5. Resultados

Esta seção apresenta os resultados obtidos pela análise dos dados, oferecendo insights sobre a eficácia do jogo proposto no processo de aprendizado dos jogadores.

O jogo foi disponibilizado na Play Store para teste fechado e 18 pessoas diferentes baixaram e jogaram pelo menos até o módulo 1. Desse grupo, 11 são do sexo masculino e 7 do sexo feminino. Além disso, antes de jogar, todos os participantes responderam a um questionário destinado a avaliar o interesse deles pela gastronomia brasileira e por jogos.

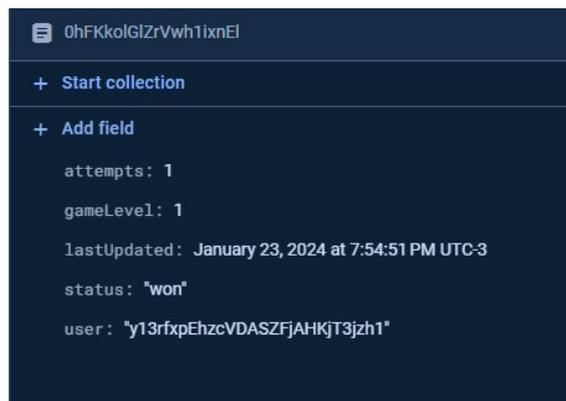


Figura 13. Relação de usuário com módulo - Estrutura. Fonte: Elaborado pelo autor.

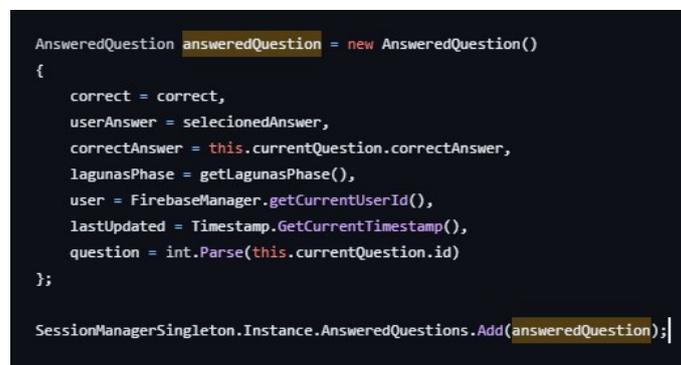


Figura 14. Coleta das respostas - Código. Fonte: Elaborado pelo autor.



Figura 15. Armazenamento das respostas - Código. Fonte: Elaborado pelo autor.

5.1. Efetividade educacional

A análise da efetividade visa determinar se o jogo contribuiu para o aprendizado dos jogadores, categorizando-os em perfis com base na metodologia Serrano-Laguna [Ángel Serrano-Laguna et al. 2017]. Além disso, busca-se obter informações importantes sobre o desempenho e o comportamento dos jogadores por meio do *Game Learning Analytics*. Isso inclui analisar a dificuldade em determinadas questões, o tempo médio entre uma questão e outra, investigar se existem diferenças significativas entre as médias dos jogadores de sexo masculino e feminino, e compreender se características como o interesse prévio pelo tema influenciaram em um maior número de acertos.

Ao fazer uma análise sobre as pontuações gerais nas fases do jogo, pode-se observar na Figura 16 que as médias das notas da fase prática são menores que as da fase de domínio.

De acordo com a metodologia de Serrano-Laguna

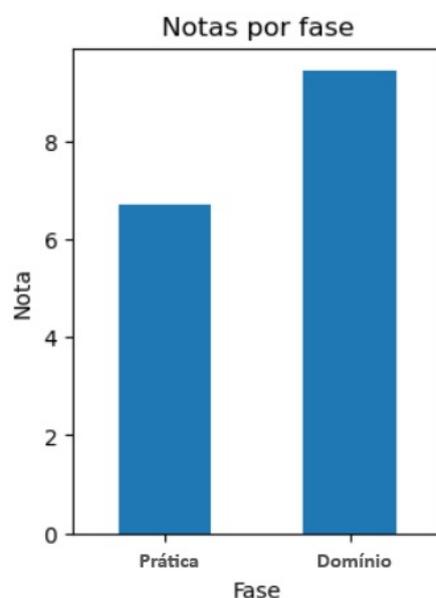


Figura 16. Média de notas por fase. Fonte: Elaborado pelo autor.

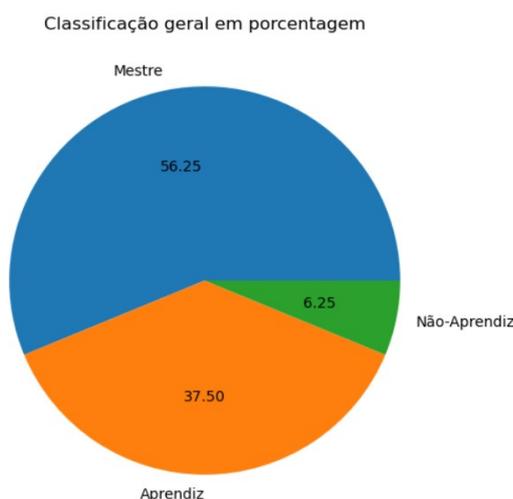


Figura 17. Classificação geral. Fonte: Elaborado pelo autor.

[Ángel Serrano-Laguna et al. 2017], é necessário classificar os jogadores em perfis para que se tenha uma noção mais precisa sobre a efetividade educacional. Nesse sentido, a Figura 17 mostra uma classificação geral dos jogadores. Nela, observa-se que 56.2% dos jogadores foram classificados como “Mestres”, 37.5% como “Aprendizes” e apenas 6.2% como “Não-Aprendizes”. Porém, quando essa classificação é feita baseada em módulos do jogo, como mostrado nas Figuras 18, 19 e 20, essas porcentagens se distribuem de forma diferente. Para o módulo 1, cujo tema é “Pratos típicos”, foram classificados 50% dos jogadores como “Mestres”, 43.7% como “Aprendizes” e apenas 6.2% como “Não-Aprendizes”. Já para o módulo 2, de tema “Ingredientes típicos”, 72.7% foram “Mestres” e 27.27% foram “Aprendizes”. No módulo 3, com o tema “Heranças culinárias”, foram classificados 55.5% dos jogadores como “Aprendizes” e

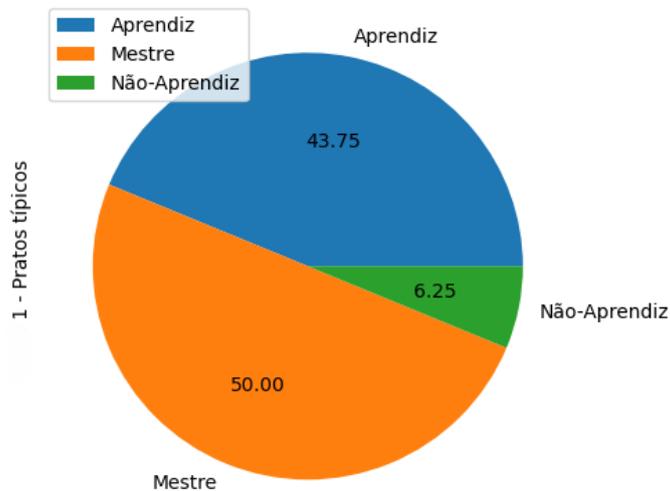


Figura 18. Classificação do módulo 1. Fonte: Elaborado pelo autor.

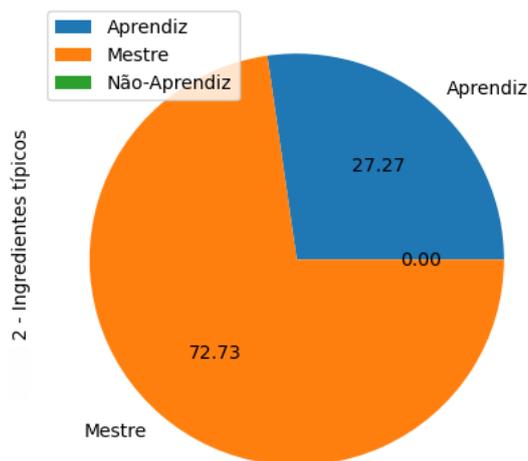


Figura 19. Classificação do módulo 2. Fonte: Elaborado pelo autor.

44.4% como “Mestres”.

Com relação ao sexo dos jogadores, os do sexo masculino obtiveram a classificação mostrada na Figura 21. Nela, é apontado que 66.6% desses jogadores foram classificados como “Mestres” e 33.3% como “Aprendizes”. Já para o sexo feminino, como mostrado na Figura 22, 42.8% foram classificados como “Mestres”, 42.8% como “Aprendizes” e 14.2% como “Não Aprendizes”.

5.1.1. Percentual de acertos e erros

A Figura 23 apresenta o percentual de acertos e erros por fase de domínio e prática, juntamente com a quantidade de questões corretas e incorretas. Enquanto isso, a Figura

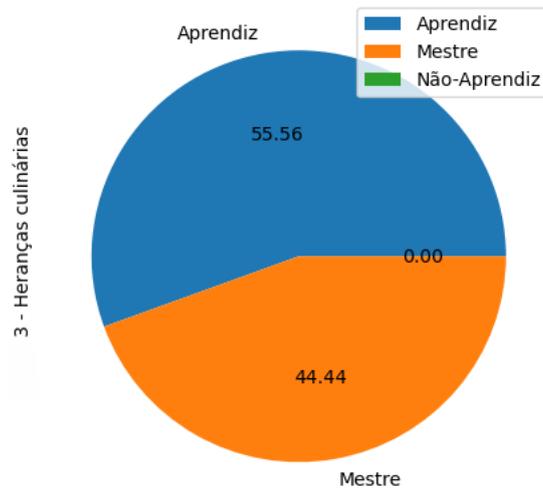


Figura 20. Classificação do módulo 3. Fonte: Elaborado pelo autor.

Classificação geral: Sexo masculino

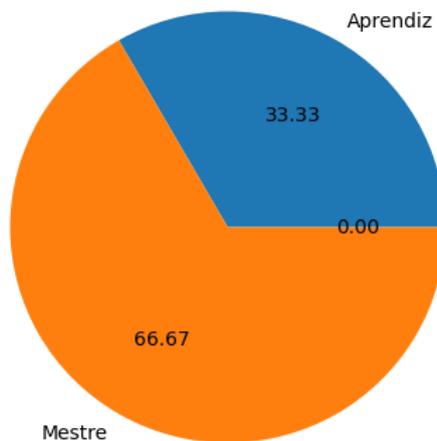


Figura 21. Classificação geral do sexo masculino. Fonte: Elaborado pelo autor.

24 organiza essas porcentagens em relação aos diferentes módulos do jogo. Para uma análise mais detalhada, os resultados são distribuídos tanto por módulo quanto por fase nas Figuras 25, 26 e 27.

Com o intuito de compreender as questões com maior número de acertos, foi elaborada a Figura 28. Nela, pode-se observar que, das 5 questões apresentadas, 3 obtiveram uma taxa de acerto de 100%, sendo essas 3 pertencentes ao módulo 2 (Ingredientes típicos). Já a Figura 29 apresenta a distribuição das questões com maior incidência de erros, destacando que a maioria delas pertence ao módulo 1 (Pratos típicos).

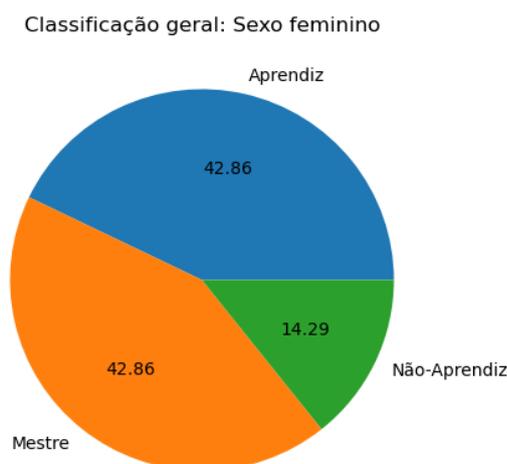


Figura 22. Classificação geral do sexo feminino. Fonte: Elaborado pelo autor.

Fase	Questões corretas	Questões erradas	Porcentagem Corretas	Porcentagem Erradas
domínio	314	20	94	6
prática	225	110	67.2	32.8

Figura 23. Percentual de acerto e erro por fase. Fonte: Elaborado pelo autor.

Módulo	Questões corretas	Questões erradas	Porcentagem Corretas	Porcentagem Erradas
1 - Pratos típicos	252	69	78.5	21.5
2 - Ingredientes típicos	184	25	83.6	19.4
3 - Heranças culinárias	103	25	80.4	19.6

Figura 24. Percentual de acerto e erro por módulo. Fonte: Elaborado pelo autor.

Módulo 1				
Fase	Questões corretas	Questões erradas	Porcentagem Corretas	Porcentagem Erradas
domínio	145	15	90.6	9.4
prática	107	54	66.5	33.5

Figura 25. Percentual de acerto e erro - Nível 1. Fonte: Elaborado pelo autor.

Módulo 2				
Fase	Questões corretas	Questões erradas	Porcentagem Corretas	Porcentagem Erradas
domínio	107	3	97.3	2.7
prática	77	33	70	30

Figura 26. Percentual de acerto e erro - Nível 2. Fonte: Elaborado pelo autor.

5.1.2. Tempo médio para responder as questões

Por meio da análise das interações do jogo, também foi possível determinar o tempo médio que cada questão levou para ser respondida. Isso foi possível, graças a inclusão de

Módulo 3				
Fase	Questões corretas	Questões erradas	Porcentagem Corretas	Porcentagem Erradas
domínio	62	2	96.8	3.2
prática	41	23	64	36

Figura 27. Percentual de acerto e erro - Nível 3. Fonte: Elaborado pelo autor.

Questão	Nível	Qtd. Erradas	Qtd. Corretas	Porcentagem Corretas	Porcentagem Erradas	Total de Perguntas
12	2	0	22	100.0	0.0	22
13	2	0	22	100.0	0.0	22
14	2	0	22	100.0	0.0	22
26	3	1	17	94.4	5.6	18
4	1	2	30	93.8	6.3	32

Figura 28. Questões com mais acertos. Fonte: Elaborado pelo autor.

Questão	Nível	Qtd. Erradas	Qtd. Corretas	Porcentagem Corretas	Porcentagem Erradas	Total de Perguntas
19	2	11	11	50.0	50.0	22
6	1	13	19	59.4	40.6	32
9	1	11	22	66.7	33.3	33
24	3	6	12	66.7	33.3	18
7	1	10	22	68.8	31.3	32

Figura 29. Questões com mais erros. Fonte: Elaborado pelo autor.

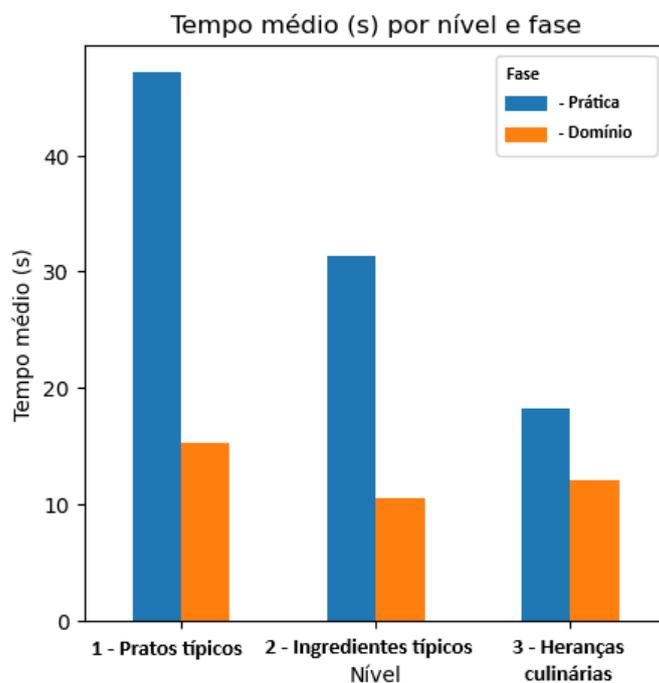


Figura 30. Relação de tempo médio (s) por fase e módulo. Fonte: Elaborado pelo autor.

um dado em cada resposta que registra a data e hora em que ela foi coletada. Ao distribuir por módulo e fase, a Figura 30 revela que, em média, os jogadores levaram mais tempo para responder às questões da fase prática do que às da fase de domínio, em todos os módulos.

5.1.3. Testes de hipóteses

Na Figura 21 e 22, foi mostrado gráficos diferentes entre as classificações para o sexo masculino e feminino. Porém, só com essas visões não é possível afirmar se existem diferenças significativas entre as médias de cada sexo. No entanto, é possível fazer um teste estatístico para verificar se existe essa relação. Foram escolhidos testes de hipóteses, que funcionam para testar se as declarações estatísticas são ou não prováveis.

É necessário estabelecer duas hipóteses: uma nula e outra alternativa. Durante o teste, parte-se do pressuposto de que a hipótese nula é verdadeira. Caso haja evidências suficientes contra ela, a hipótese nula será rejeitada e a hipótese alternativa será aceita.

Para esse cenário, as hipóteses criadas foram:

- H_0 (hipótese nula) - Não existem diferenças significativas nas médias dos sexos feminino e masculino.
- H_1 (hipótese alternativa) - Existem diferenças significativas nas médias dos sexos feminino e masculino.

Na fase prática, a média dos jogadores do sexo masculino foi de 6.9, enquanto para o sexo feminino foi de 6.5.

Após verificar se as médias atenderam aos pressupostos necessários, como se seguiram uma distribuição normal e se as variâncias são homogêneas, foi utilizado o teste paramétrico t de Student para amostras independentes.

Definindo o nível de significância em 0.05, o valor de p calculado foi de 0.46, como mostrado na Figura 31. Este valor significa a probabilidade de se estar errado quando aceitamos a hipótese alternativa. Sendo $p > 0.05$, então nesse caso deve-se aceitar a hipótese nula, ou seja, não existem diferenças significativas nas médias dos sexos feminino e masculino para a fase prática.

```
TtestResult(statistic=0.7459906673292875, pvalue=0.46801490350656405, df=14.0)
```

Figura 31. Resultado do teste T de Student. Fonte: Elaborado pelo autor.

Para a fase de domínio, a média dos jogadores do sexo masculino foi de 9.6, enquanto que para o sexo feminino foi de 9.2.

O conjunto de dados não seguem uma distribuição normal, então se utilizou o teste não paramétrico de Mann-Whitney para calcular o valor de p , resultando em 0.58, como mostrado na Figura 32. Sendo $p > 0.05$, então nesse caso deve-se aceitar a hipótese nula, ou seja, não existem diferenças significativas nas médias dos sexos feminino e masculino para a fase de domínio.

Todo o código da análise pode ser encontrado em [Farias 2023a].

```
MannwhitneyUResult(statistic=37.0, pvalue=0.5833123355612131)
```

Figura 32. Resultado do teste de Mann–Whitney. Fonte: Elaborado pelo autor.

6. Conclusão

O artigo propõe o desenvolvimento de um jogo visando auxiliar os jogadores no aprendizado de cultura gastronômica brasileira, utilizando *Game Learning Analytics* junto com a metodologia de Serrano-Laguna para medir a sua efetividade.

Ao longo deste estudo, foram examinadas as pontuações dos participantes nas fases prática e de domínio do jogo. Os resultados indicaram que os jogadores conseguiram em média uma nota maior na fase de domínio. Este resultado é esperado, pois é na fase prática que é verificado o conhecimento inicial do jogador. Maiores pontuações na fase de domínio sugerem, à primeira vista, que o jogo facilitou a aprendizagem, permitindo que os jogadores aprendessem com os erros cometidos na fase prática.

No entanto, de acordo com a metodologia Serrano-Laguna [Ángel Serrano-Laguna et al. 2017], é preciso classificar os jogadores em perfis para que seja possível medir a efetividade educacional da ferramenta. Nesse sentido, juntando todas as pontuações dos módulos, a maioria dos jogadores foram classificados como “Mestres” com 56.2%; 37.5% foram classificados como “Aprendizes”; e apenas 6.2% foram classificados como “Não-Aprendizes”. A maior quantidade de “Mestres” indica que a maioria dos jogadores já possuía determinado conhecimento sobre o tema. Mesmo assim, o jogo obteve uma boa quantidade de Aprendizes e pouca quantidade de “Não-Aprendizes”, indicando que uma certa quantidade de pessoas conseguiu uma melhora no conhecimento sobre o tema. Além disso, é importante destacar que nenhum jogador foi considerado “Deslocado”.

Ao visualizar essa classificação pelos módulos, é possível notar que o módulo com maior porcentagem de “Aprendizes” foi o módulo 3, com 55% dos jogadores, indicando que este módulo foi que mais contribuiu para o aprendizado dos jogadores. Já para o módulo 2, foi detectado um número muito grande de “Mestres”, com 72.7%, indicando que o jogo não foi tão efetivo para este módulo, pois os jogadores possuíam conhecimento prévio. Além disso, tanto o módulo 3 como o módulo 2 não possuíram quantidades de “Não-Aprendizes” ou “Deslocados”, o que é positivo.

Antes de baixar o jogo, os jogadores responderam um questionário sobre o interesse pela gastronomia brasileira e por jogos. Nessa pesquisa, foi identificado que 73.7% se diziam interessados ou muito interessados sobre culinária e cultura gastronômica. Tais números ajudam a explicar o número maior de “Mestres” na classificação geral. Além disso, na pergunta sobre qual tema da gastronomia o jogador acha mais interessante, o tema do módulo 3 “História da culinária brasileira” ficou com a minoria de 16.7%, indicando que a porcentagem maior de “Aprendizes” no módulo 3 pode ter relação com esse dado.

Apesar de possuir uma maior quantidade de “Mestres”, é possível concluir que o jogo desenvolvido serviu como uma ferramenta capaz de melhorar o conhecimento

de alguns de seus jogadores. Além disso, ele atua como um meio de preservação das tradições culinárias e da identidade cultural, uma vez que os conhecimentos adquiridos por meio dele desempenham um papel fundamental nesse processo.

No entanto, apesar de ter tido bons resultados, este estudo possui algumas limitações devido a falta de tempo ou complexidade envolvida, dando possibilidade para melhorias em trabalhos futuros. Dentre elas, estão:

- Uma base de dados maior - É preciso ter uma maior base de dados para se ter resultados mais precisos.
- Acessibilidade - Incluir funcionalidades de acessibilidade como a leitura das perguntas em voz alta.
- Elementos de gamificação - Adicionar mais elementos de gamificação que são comumente encontrados em jogos para entretenimento, como por exemplo, receber mais recompensas ao conquistar um módulo, e também um sistema de ranqueamento de jogadores.
- Feedback das respostas para os jogadores - Adicionar uma funcionalidade para que os jogadores tenham acesso às questões respondidas, bem como os erros e acertos.
- Possibilidade de modificação do jogo baseado nos resultados analisados - Ter uma forma de adicionar e modificar perguntas e módulos de forma automatizada, para que os professores possam utilizar a ferramenta a nível educacional.
- Customização do jogo baseado no tema - Adicionar customização dos módulos e personagens baseada no tema do jogo.

Referências

- Airbridge (2023). 2023 idle rpg trends: A comprehensive analysis. <https://www.airbridge.io/blog/idle-rpg-trend-2023>. [online: acesso em 16-fevereiro-2024].
- Arnold, K. E. and Pistilli, M. D. (2012). Course signals at purdue: Using learning analytics to increase student success. *Proceedings of the 2nd International Conference on Learning Analytics Knowledge*. New York: ACM.
- Balasubramanian, N. and Wilson., B. (2006). Games and simulations. *Information Technology and Teacher Education*.
- Bayliss, J. D. (2012). Teaching game ai through minecraft mods. *Conference: Games Innovation Conference (IGIC), 2012 IEEE International*.
- Bullock, J. and Luengo-Oroz, M. (2019). Automated speech generation from un general assembly statements: Mapping risks in ai generated texts.
- Corti, K. (2006). Games-based learning a serious business application. *PIXELearning Limited*.
- Dasborough, M. T. (2023). Awe-inspiring advancements in ai: The impact of chatgpt on the field of organizational behavior. *Journal of Organizational Behavior*.
- de Farias, L. L. (2019). Utilização de game learning analytics para verificação do aprendizado em jogo sério voltado ao ensino de zoologia. *Universidade Federal Rural de Pernambuco – UFRPE. Departamento de Estatística e Informática Curso de Bacharelado em Sistemas de Informação*.

- de Freitas, S. (2006). Learning in immersive worlds: A review of game-based learning. *JISC*.
- de Oliveira, R. N. R. and da Rocha, R. V. (2021). Avaliajs: Planejamento da avaliação do desempenho de alunos em jogos sérios. *Congresso Brasileiro de Informática na Educação*.
- Farias, C. (2023a). Código da análise de dados em python. <https://github.com/caiohsfar/tcc-analysis/blob/main/tcc.ipynb>. [online: acesso em 16-fevereiro-2024].
- Farias, C. (2023b). Código fonte - jornada culinária. <https://github.com/caiohsfar/jornada-gastronomica/tree/master>. [online: acesso em 17-fevereiro-2024].
- Farias, C. (2023c). Perguntas - jornada culinária. <https://gist.github.com/caiohsfar/1b8d989050dbe0532f756221b1416776>. [online: acesso em 17-fevereiro-2024].
- Freire, M., Serrano-Laguna, , Manero, B., Martínez-Ortiz, I., Moreno-Ger, P., and Fernández-Manjón, B. (2016). Game learning analytics learning analytics for serious games. *Learning, Design, and Technology*.
- Garris, R., Ahlers, R., and Driskell, J. E. (2002). Games, motivation, and learning: a research and practice model. *Simulation Gaming*.
- Gros., B. (2003). The impact of digital games in education.
- Hsiao, H. (2007). A brief review of digital games and learning. *DIGITEL 2007, The First IEEE International Workshop on Digital Game and Intelligent Toy Enhanced Learning*.
- Hu, G. (2023). Challenges for enforcing editorial policies on ai-generated papers. *Accountability in Research*.
- Huang, W. D., Johnson, T. E., and Han, S.-H. C. (2013). Impact of online instructional game features on college students' perceived motivational support and cognitive investment: a structural equation modeling study. *The Internet and Higher Education*.
- Hyder, Z., S., K., and Nah, F. F. H. (2019). Artificial intelligence, machine learning, and autonomous technologies in mining industry. *Journal of Database Management*.
- Joshua Prieur, E., Jiawen Chen, P., Nicole Zelem, M., and Lisa Kilanowski, D. E. (2019). Game-based learning and digital game-based learning: A comprehensive literature review.
- Köbis, N. and Mossink, L. D. (2021). Artificial intelligence versus maya angelou: Experimental evidence that people cannot differentiate ai-generated from human-written poetry. *Computers in Human Behavior*.
- Loh, C. S., Sheng, Y., and Ifenthaler, D. (2015). Serious games analytics: Theoretical framework. *Serious Games Analytics*. Springer.
- Microsoft (2023). Unity. <https://dotnet.microsoft.com/en-us/apps/games/unity>. [online: acesso em 16-fevereiro-2024].

- Mobygames (2005). Number munchers (dos). <https://www.mobygames.com/game/4635/number-munchers/screenshots/dos/140430/>. [online: acesso em 13-fevereiro-2024].
- Nah, F. F.-H., Zheng, R., Cai, J., Siau, K., and Chen, L. (2023). Generative ai and chatgpt: Applications, challenges, and ai-human collaboration. *Journal of Advertising*.
- Nutt C, H. K. (2016). The structure of fun: Learning from super mario 3d land's director. *Gamasutra*.
- PGB (2023). Pgb revela que 70,1% da população do brasil consome games. <https://www.pesquisagamebrasil.com.br/pt/>. [online: acesso em 11-fevereiro-2024].
- Plass, J. L., Homer, B. D., and Kinzer, C. K. (2015). *Foundations of game-based learning*. Educational Psychologist.
- Qadir, J. (2022). Engineering education in the era of chatgpt: Promise and pitfalls of generative ai for education. *TechRxiv*.
- SC., S. (1992). *Shapiro SC. (ed) Encyclopedia of Artificial Intelligence*. edn. New York: Wiley, 1992.
- Seif El-Nasr, M., Drachen, A., and Canossa, A. E. (2013). Game analytics - maximizing the value of player data. *London: Springer-Verlag*.
- Unity (2021). Dragon crushers - 2d sample project. <https://assetstore.unity.com/packages/essentials/tutorial-projects/dragon-crashers-2d-sample-project-190721>. [online: acesso em 16-fevereiro-2024].
- Van Eck, R. (2006). Digital game-based learning: It's not just the digital natives who are restless. *EDUCAUSE Review*.
- Williams, C. (2023). Hype, or the future of learning and teaching? 3 limits to ai's ability to write student essays. *London School of Economics internet*.
- Zhai, X. (2023). Chatgpt for next generation science learning. *XRDS: Crossroads, The ACM Magazine for Students*, 29.
- Ángel Serrano-Laguna, Manero, B., Freire, M., and Fernández-Manjón, B. (2017). A methodology to assess the effectiveness of serious games and infer player learning outcomes. *Multimedia Tools and Applications*.