

Desafios na implementação de técnicas de GLA em um jogo educacional de algoritmos: um estudo de caso

Challenges in implementing GLA techniques in an educational algorithm game: a case study

Jeniffer Macena^{1,2}, Fabrizio Honda^{1,2}, Douglas Melo^{1,2}, Fernanda Pires¹,
Elaine H. T. Oliveira², David Fernandes², Marcela Pessoa¹

¹Escola Superior de Tecnologia – Universidade do Estado do Amazonas (EST-UEA)
ThinkTEd Lab - Pesquisa, Desenvolvimento e Inovação em tecnologias emergentes

²Programa de Pós-Graduação em Informática (PPGI)
Instituto de Computação – Universidade Federal do Amazonas (IComp-UFAM)

{jeniffer.souza, fabrizio.honda, douglassm, elaine, david}

@icomp.ufam.edu.br, {fpires, mspessoa}@uea.edu.br

Abstract. *The contributions of Game Learning Analytics (GLA) combined with heuristic testing can provide educators with insights into possible evidence of learning. However, challenges may arise when attempting to include data capture techniques after the game's implementation. In an effort to measure these challenges, this work presents a case study that explores the difficulties encountered in implementing the GLBoard tool in a partially developed educational game. Results indicate that, despite the involvement of two experts, the implementation faced challenges: game abstraction, complex mechanics, adaptation of the structure, and navigation through the code.*

Keywords: *Game Learning Analytics, insights, evidence of learning, challenges*

Resumo. *As contribuições de Game Learning Analytics (GLA) aliadas a testes heurísticos podem fornecer insights aos educadores sobre possíveis evidências de aprendizagem. Entretanto, quando se tenta incluir técnicas de captura de dados após implementação do jogo, podem surgir desafios. Na tentativa de mensurá-los, este trabalho apresenta um estudo de caso que explora os desafios encontrados na implementação da ferramenta GLBoard em um jogo educacional parcialmente desenvolvido. Resultados apontam que, apesar da participação de dois especialistas, a implementação apresentou desafios: abstração do jogo, mecânica complexa, adaptação da estrutura e navegação pelo código.*

Palavras-chave: *Game Learning Analytics, insights, evidências de aprendizagem, GLBoard, desafios*

1. Introdução

O uso de jogos em contextos educacionais têm se intensificado ao longo dos anos [Xu et al. 2023, Udeozor et al. 2023], podendo ser uma estratégia eficaz para os processos de aprendizagem, isso porque tem potencial de motivar e, conseqüentemente, engajar os estudantes [Plass et al. 2015]. Contudo, ainda não há um consenso sobre a avaliação de jogos educacionais, e, em alguns casos, esse aspecto é omitido nos trabalhos

[Melo et al. 2020b]. Por outro lado, na maioria das vezes, quando a avaliação é abordada, geralmente é aplicada de forma *ad-hoc* [Petri et al. 2019], a partir de testes heurísticos que consideram a percepção do estudante sobre usabilidade e experiência com o jogo. Apesar de ser importante, não é suficiente como indicador de aprendizagem em um jogo educacional, pois trata somente da percepção do testador em relação ao objeto, e não contempla alguns elementos dos jogos que podem contribuir para análises mais robustas de aprendizagem [Melo et al. 2020a].

Na tentativa de contornar essas dificuldades, têm-se a área de *Game Learning Analytics* (GLA) [Freire et al. 2016] que pode proporcionar análises para identificar o progresso do jogador e possíveis evidências de aprendizagem. GLA consiste na captura e análise de registros de dados (*logs*) a partir da interação do usuário com um jogo educacional, cuja coleta ocorre de modo não intrusivo e com a autorização do jogador, para que não interrompa seu ritmo na *gameplay*. A visualização dos dados pode ser feita via *dashboard*, onde os educadores podem acessar gráficos sobre métricas do jogo e realizar análises individuais ou em conjunto. Com os *insights* gerados a partir das análises, os educadores podem, por exemplo, identificar dificuldades dos estudantes em praticar determinado conteúdo no jogo e assim reforçá-lo em sala de aula.

Entretanto, existe uma dificuldade no que tange à padronização em GLA [Alonso-Fernandez et al. 2017]: os projetistas criam estruturas de captura personalizadas para seus jogos, que funcionam para aquele contexto, mas que, geralmente, não são replicáveis. Na tentativa de padronizar essa captura, surge o GLBoard [Silva et al. 2022], um modelo genérico para a captura e análise de dados em jogos educacionais, composto por quatro módulos principais: API, pacote *Unity*, banco de dados e *dashboard*. A partir do GLBoard, é possível inserir técnicas de GLA em jogos desenvolvidos na *game engine Unity*, por meio da atribuição das variáveis de coleta de dados em uma estrutura *JSON*. Uma das variáveis denomina-se *path_player*, e permite ao desenvolvedor armazenar qualquer dado sobre o percurso do jogador durante a *gameplay*. Essa estratégia possibilita a captura, considerando a diversidade de mecânica e estilo do jogo¹.

No entanto, antes da implementação de GLA, é fundamental realizar a modelagem de dados do jogo, isto é, definir quais variáveis serão capturadas e porque são importantes. Essas variáveis dependem das características do jogo, por exemplo, em um jogo de plataforma: tempo, plataformas interagidas, pulos do personagem, entre outros; em um jogo de corrida: a posição dos carros, *checkpoints*, velocidade, entre outros. Portanto, o percurso do jogador é único para cada tipo de jogo, cujas variáveis de captura devem ser definidas e inseridas no *path_player*. Além disso, para que a captura seja eficiente, a implementação do jogo deve ocorrer concomitantemente à inserção das técnicas de GLA, adicionado as estruturas de coleta nas variáveis respectivas ao passo em que o jogo vai sendo construído. Contudo, caso o jogo já esteja implementado, o processo torna-se mais trabalhoso, visto que é necessário adaptá-lo para “receber” a estrutura de GLA, piorando a dificuldade quando as mecânicas são complexas.

Em torno desse cenário, este artigo apresenta um estudo de caso em relação à inserção de técnicas de GLA, por meio do sistema GLBoard, em um jogo educacional

¹Alguns dados capturados pela ferramenta também dão suporte à jogos comerciais, entretanto, sua ênfase está em jogos educacionais para auxiliar a identificar indícios de aprendizagem por meio do rastreamento do percurso do jogador (interações com os elementos do jogo).

previamente implementado. O objetivo é apontar e explorar os desafios encontrados por especialistas durante a implementação das técnicas de GLA. Para isso, o trabalho foi estruturado da seguinte forma: a Seção 2 aborda sobre GLA, o sistema GLBoard e os trabalhos relacionados; na Seção 3, o design experimental; a Seção 4, os resultados e discussões; e, na Seção 5, as conclusões e trabalhos futuros.

2. Referencial Teórico e trabalhos relacionados

Nesta seção, serão apresentados os conceitos para compreender este trabalho, incluindo GLA, uma proposta de ferramenta para padronizar seu processo, e trabalhos relacionados.

2.1. Game Learning Analytics

Integrar *Learning Analytics* e *Game Analytics* resulta na metodologia de *Game Learning Analytics* (GLA), que visa aprimorar jogos educacionais por meio do alinhamento entre objetivos de aprendizagem e entretenimento, fundamentada na análise de dados [Freire et al. 2016]. Ao contrário dos jogos comerciais, que visam maximizar a retenção de usuários e a lucratividade, o GLA foca na efetividade educacional, empregando a coleta e análise de dados para refinar o *design* dos jogos e assegurar sua adequação às metas educacionais. O GLA abrange a análise das interações dos estudantes com o jogo e a visualização dos resultados em *dashboards*, permitindo uma avaliação precisa do impacto educacional. A Figura 1 ilustra a estrutura de componentes de GLA [Freire et al. 2016], que inclui módulos para coleta de dados, exibição das análises das interações dos estudantes com os jogos através de *dashboards* e avaliação do desempenho do jogador.

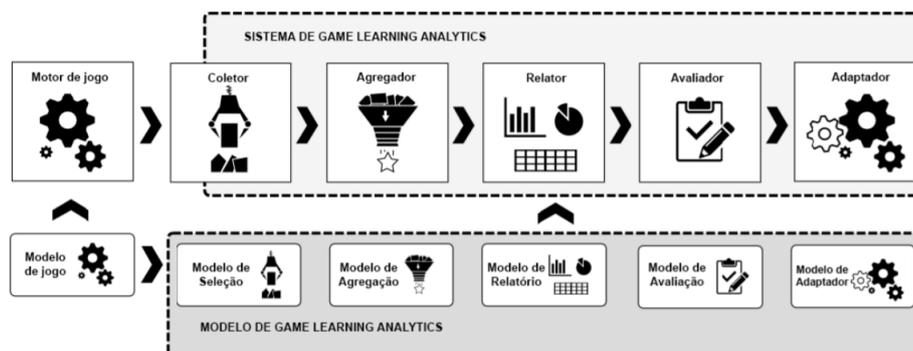


Figura 1. Arquitetura base de GLA, proposta em Freire et al. [2016].

Um sistema de GLA deve incluir um conjunto de módulos que precisa ser implementado [Freire et al. 2016], sendo eles: i) Motor de jogo: *engine* onde o jogo está sendo desenvolvido, e precisa ser integrado ao agregador para que os dados de interação dos jogadores com os jogos sejam enviados; ii) Agregador: organiza e analisa os dados capturados; iii) Relator: gera relatórios a partir dos dados analisados; iv) Avaliador: acessa e valida os dados para verificar o cumprimento dos objetivos educacionais; v) Adaptador: envia instruções de volta ao jogo para adaptá-lo ao jogador.

Apesar dos benefícios e da arquitetura consolidada, GLA enfrenta o desafio da falta de padronização no desenvolvimento [Alonso-Fernandez et al. 2017]. Devido à alta diversidade de elementos e mecânicas presentes nos jogos, cada desenvolvedor tende a criar soluções *ad-hoc* de GLA para seus projetos educacionais. Essa abordagem

individualizada ocorre porque não existe um modelo genérico abrangente capaz de lidar com essa diversidade de dados. Como resultado, a necessidade de adaptação ou reinvenção das estratégias de GLA para cada novo jogo aumenta a complexidade e o tempo para o desenvolvimento. Para abordar essa questão e fomentar a sistematização de GLA, foi proposto o GLBoard [Silva et al. 2022], uma ferramenta projetada para aprimorar jogos educacionais automatizando a captura, armazenamento e análise de dados de interação dos jogadores. Através de um conjunto de módulos, o GLBoard permite aos desenvolvedores coletar dados genéricos como *timestamps*, mudanças de nível, tentativas e interações do usuário, fundamentais para entender o comportamento do jogador e o processo de aprendizagem. Esses dados são analisados e apresentados em um *dashboard web*, facilitando a obtenção de *insights* sobre o *design* do jogo e permitindo ajustes baseados em evidências para melhorar a experiência educacional.

O sistema se baseia em um modelo de dados estruturado, capaz de organizar informações sobre o progresso do jogador, fases do jogo e interações específicas, suportado por uma *API* em *Python* e um banco de dados em *Firebase* para armazenamento e análise. Desenvolvedores podem integrar facilmente a biblioteca do GLBoard em seus jogos utilizando uma biblioteca *Unity*, promovendo uma padronização no processo de coleta de dados. A plataforma *web* do GLBoard, além de disponibilizar análises visuais detalhadas, também facilita o gerenciamento dos jogos pelos desenvolvedores, e permite que educadores monitorem o desempenho dos estudantes, contribuindo para que os jogos educacionais sejam mais efetivos e engajadores. Portanto, o GLBoard possui uma abordagem generalista que permite sua aplicação em qualquer jogo educacional. Entretanto, este trabalho não analisa múltiplas aplicações da ferramenta, mas sim, um estudo de caso que usa a abordagem de dados generalista do GLBoard em um jogo educacional específico, para investigar os desafios encontrados nesse processo.

2.2. Trabalhos relacionados

Algumas pesquisas evidenciam a relação do uso de *Game Learning Analytics* em *Educational Serious Games*, enfatizando como a análise de desempenho e engajamento pode influenciar o design desses jogos para favorecer o desenvolvimento cognitivo dos aprendizes [Wiemeyer et al. 2016, Alonso-Fernández et al. 2019].

Dentre os estudos destacados, Mangaroska et al. [2024] investigam o impacto dos elementos de design no engajamento dos jogadores em dimensões cognitivas, afetivas e motivacionais, utilizando o jogo de palavras casual “Letter Link”. A metodologia envolveu a coleta de dados através de *Game Learning Analytics*, monitorando variáveis como total de jogos, propostas de jogos, pontos de experiência e outros indicadores de engajamento comportamental. Adicionalmente, a aprendizagem e o engajamento foram avaliados por questionários detalhados, como o Questionário de Experiência de Jogo (GEQ) e um questionário de escala Likert adaptado, proporcionando uma visão abrangente da experiência dos jogadores e sua interação com os elementos de jogos.

Fernández et al. [2023] utilizam o xAPI-SG, uma biblioteca que possibilita a captura e análise de dados de jogos educacionais. A coleta de dados concentrou-se nas interações dos jogadores no jogo “Conectado”, abrangendo aspectos como interações com personagens, decisões tomadas, progresso em cenários específicos e duração das sessões de jogo. A partir dessas interações, variáveis analíticas foram derivadas para

avaliar o aumento da conscientização sobre o *bullying*. Os resultados demonstraram que a regressão Bayesiana se mostrou o modelo preditivo mais eficaz, indicando que as variáveis derivadas das interações no jogo são capazes de prever o aumento da conscientização sobre o *bullying*.

Souza et al. [2021] descrevem o jogo educacional “Castaways”, cujo objetivo é auxiliar na aprendizagem de Linguagens Regulares e Autômatos Finitos Determinísticos. Dentro do jogo, utiliza-se uma abordagem de coleta de dados para fornecer *feedback* em tempo real e permitir ajustes pedagógicos contínuos. As métricas coletadas, como tempo de resolução de desafios, número de reinícios e eficiência das soluções, ajudam a identificar dificuldades dos estudantes e a eficácia do jogo em possibilitar a prática dos conceitos. Resultados, a partir das análises das coletas, apontam que os altos índices de reinícios em certos níveis indicam a necessidade de simplificar ou esclarecer instruções, enquanto soluções ótimas consistentes mostram que o jogo está eficaz.

As pesquisas nos trabalhos correlatos descreveram e relataram o processo referente à integração de técnicas de GLA em seus jogos ou abordagens alternativas baseadas em dados. Este artigo se diferencia dos demais, nos seguintes aspectos: i) utiliza o GLBoard para implementar as técnicas; ii) o jogo educacional abordado tem como foco a aprendizagem de algoritmos e programação introdutória; iii) o desenvolvimento do jogo estava parcialmente completo, havendo a necessidade de “adaptá-lo” para adicionar o GLBoard; e iv) os desafios e lições nesse processo são listados e descritos.

3. Design Experimental

Esta seção aborda os aspectos experimentais para a realização do estudo de caso.

3.1. Planejamento

O Caso abordado neste estudo trata sobre a implementação de técnicas de GLA, por meio da ferramenta GLBoard, em um jogo educacional, visando gerar evidências de evolução do jogador e possivelmente indícios de aprendizagem. O objetivo do trabalho é verificar se a incorporação dessa ferramenta após o jogo já ter sido desenvolvido impacta, ou não, no nível de dificuldade da implementação das técnicas de GLA. A escolha do jogo deu-se devido às suas múltiplas características que promovem o desenvolvimento de habilidades em conteúdos de introdução à programação, utilizando dinâmicas distintas em cada fase.

Descrição do jogo: Hello Food [Macena et al. 2022] é um jogo desenvolvido para iniciantes em computação, especialmente para aqueles que estão tendo o primeiro contato com a programação, visando estudantes do ensino médio ao técnico em informática. O *game design* está voltado a prática de conceitos-chave como estruturas condicionais, laços de repetição e vetores. No jogo são oferecidos desafios baseados em literatura acadêmica e exercícios de lógica programação, integrados ao contexto de um restaurante, onde os jogadores recebem recompensas ao completar missões.

No jogo, os participantes começam no Nível 1 (Figura 2(a)), onde a tarefa é alocar clientes às mesas corretas, selecionando a mesa que corresponde à ordem de um veto – simbolizando uma introdução prática à manipulação e compreensão de vetores. No Nível 2 (Figura 2(b)), a dinâmica e mecânica mudam, exigindo que os jogadores atendam aos pedidos dos clientes de maneira que construam um algoritmo em cada etapa de preparação da comida, promovendo uma experiência interativa de codificação. Por exemplo, na fase



Figura 2. Telas do jogo na Fase 1.

inicial, após praticar alocação em vetores, o jogador terá que verificar os operadores relacionais, como o “maior que”, na tábua de condicionais. Assim, caso escolha os ingredientes conforme o pedido do cliente e que satisfaça as condições de quantidade e operadores relacionais, o jogador recebe moedas como recompensa. Nas fases mais avançadas, onde se considera que o aprendiz tem algum entendimento sobre estruturas condicionais, será desbloqueado o objeto fogão. Nele, o jogador deverá praticar laços de repetição, cuja mecânica envolve cozinhar pratos, como massas e sopas, de acordo com o total de ingredientes da receita. Esse total é equivalente ao número de incrementações que a variável em repetição irá realizar.

3.2. Estruturação do Estudo

Para este estudo, optou-se por uma estratégia exploratória, cujos participantes são dois especialistas em jogos educacionais: E1 e E2. Ambos são graduados em Licenciatura em Computação em uma universidade pública e mestrandos em Informática de outra universidade pública. A seleção desses participantes deu-se pela experiência: desenvolvem jogos educacionais há mais de sete anos e já implementaram técnicas de *Game Learning Analytics (GLA)*.

3.3. Variáveis e Hipóteses:

As variáveis definidas para este experimento incluem: implementação da ferramenta GLBoard em um jogo parcialmente desenvolvido (Variável Independente) e nível de dificuldade identificado ao implementar a ferramenta GLBoard (Variável Dependente). Em relação às Variáveis de Controle, têm-se: a experiência dos especialistas, a complexidade do jogo e as particularidades da ferramenta GLBoard. Já as Hipóteses definidas foram **Hipótese Nula (H0)**: incorporar a estrutura do GLBoard em um jogo já desenvolvido não impacta no nível de dificuldade em implementar as técnicas de GLA. **Hipótese Alternativa (H1)**: incorporar a estrutura do GLBoard em um jogo já desenvolvido impacta no no nível de dificuldade em implementar de técnicas de GLA.

3.4. Procedimentos

Os procedimentos para realização do estudo incluem etapas de: (i) modelagem de dados do jogo educacional; (ii) associação das variáveis com a estrutura padrão de captura do GLBoard; (iii) codificação das técnicas de GLA no jogo; (iv) *playtesting* para gerar os registros de dados (*logs*) e; (v) validação das variáveis capturadas em relação ao que se pretende avaliar.

Modelagem de dados: o primeiro passo foi a definição de quais variáveis seriam capturadas, juntamente com seu significado (sentido) – por exemplo, capturar *timestamps* pode ser fundamental para analisar tomadas de decisão de um jogador. O objetivo era definir uma estrutura de captura que pudesse expressar o que se pretendia avaliar com o jogo, neste caso: manipulação de vetores, condicionais e laços de repetição. Para isso, E1 realizou uma análise do jogo, a partir de capturas de tela, vídeos de *gameplay* e documentação. Em seguida, elaborou um diagrama de classe com esses dados, visando estruturá-los e facilitar a visualização. Para verificar se as variáveis e métodos das classes correspondem às habilidades a serem desenvolvidas, segundo o conteúdo educacional do jogo, E1 realizou uma avaliação detalhada dos diferentes níveis do jogo. Esta análise identificou como cada variável e método pode contribuir para o desenvolvimento das habilidades específicas² em cada fase. A Tabela 1 apresenta as variáveis instanciadas com uma justificativa detalhada de sua importância para cada fase do jogo.

Tabela 1. Variáveis e Justificativas no Jogo.

Nível	Dados do Jogo	Justificativa das variáveis
0 - Tutorial	Variáveis (4): <i>tempoResolucao</i> : float, <i>nivelJogo</i> : int, <i>missaoNivel</i> : List<String>, <i>quantidadePedidosTotal</i> : int; Métodos: <i>registrarTempo</i> (), <i>adicionarPedido</i> (<i>quantidadeTempo</i> , <i>dinheiro</i>)	Para analisar a progressão por fases, considerando que cada uma possui dois níveis com conteúdos diferentes, criou-se as classes de “Nível Atendimento” e “Nível Preparar Comida”.
1 - Nível de Atendimento	Variáveis(2): <i>quantidadeMesasCorretas</i> : int, <i>vetorOriginalClientes</i> : List<int>; Métodos: <i>verificarMesasCertas</i> (<i>vetMesas</i> : List<int>)	Ao utilizar as variáveis <i>vetMesas</i> (i) e <i>vetorOriginalClientes</i> (ii) será possível identificar qual a resolução do jogador (i) e compará-la com o vetor ordenado e a solução para a fase (ii).
2 - Nível para Preparar Comida	Variáveis(2): <i>quantidadeCerta</i> : int, <i>quantidadePedidosFase</i> : int; Métodos: <i>verificarTabuasCondicionais</i> (<i>vetMesas</i> : List<int>), <i>verificarFogoALoop</i> ()	Para analisar a progressão do jogador quanto ao conceito de algoritmos, será analisado o total de acertos na fase e a solução aplicada para os pedidos selecionados – correspondência entre as mesas e a quantidade de acertos na tábua de condicionais e fogão para laços de repetição.

Associação das variáveis: após a localização das variáveis fundamentais para identificar a evolução do jogador, a etapa seguinte consistiu em verificar a relação dessas variáveis com o modelo proposto na ferramenta GLBoard³. A ferramenta possui uma estrutura de captura em formato *JSON*, que inclui dados genéricos estruturados em: dados do perfil do jogador (*PlayerData*), dados obtidos durante a *gameplay* (*GameData*), fases do jogo (*Phase*) e seções do jogo (*Section*). Portanto, para “adequar” os dados ao modelo GLBoard, essa etapa de “conversão” foi necessária. A Tabela 2 ilustra as variáveis definidas no código e suas funções no jogo.

Codificação das técnicas de GLA: em seguida, pôde-se iniciar, de fato, a implementação das técnicas de GLA por meio do GLBoard. Esse modelo possui uma estrutura própria para a coleta de dados, em formato *JSON*. Para que fosse possível adicioná-lo no jogo educacional, foi necessário seguir uma sequência de passos: (i) acessar a *Unity Package Manager* e fazer o *download* do pacote da ferramenta; (ii) criar uma classe (*script*) para gerenciar a ferramenta via código; (iii) atribuir à uma variável a classe do GLBoard para utilizar suas funcionalidades; (iv) gerar a chave do jogo através do site do GLBoard; (v) instanciar o objeto da variável criada, inserindo

²<https://docs.google.com/spreadsheets/d/10qrbf-0eogB41w12oaZqdDQo2IImNjr-XPtpQNXaNDw/edit?usp=sharing>

³Disponível em: <https://glboard.bitdocs.ai/share/d/bgZT6cn2VsnWUKMn>

Tabela 2. Variáveis analisadas no jogo nas Fases 1 e 2.

Figura	Variável	Função
	Mesas e clientes	Itens clicáveis que representam, respectivamente, a posição correta de alocação e o conteúdo dos vetores que deverão ser ordenados. Utilizados para verificar se a ordenação feita pelo jogador corresponde à resolução do nível.
	Vetor de tickets	Exibir a resolução feita pelo jogador apenas se o valor do ticket do cliente corresponder à mesa correta.
	Feedback de alocação	Indicar se a alocação está correta ou não.
	Pontuação	Forma de recompensar o jogador caso tenha alocado corretamente, exibida após finalizar a fase como uma gorjeta.
	Tempo	Representar o total de erros cometidos durante o processo de ordenação.
	Timestamp	Registro de tempo do jogador ao realizar uma ação (tentar alocar um cliente em uma mesa, por exemplo).
	Ingredientes	Verificar (i) a quantidade correta de ingredientes, para que consiga avaliar se o valor do laço de repetição foi incrementado da maneira correta; (ii) materiais correspondem ao pedidos no algoritmo e receita.
	Pedidos	Verificar quantos pedidos foram resolvidos em cada fase.
	Performance	Verificar se o usuário atendeu todos os pedidos presentes por fase. Em caso positivo, obterá uma performance máxima, representada por três estrelas.
	Pedidos diários	Referente à quantidade de pedidos concluídos para todas as fase concluídas.
	Fogão	Verificar as tentativas do jogador (erros e acertos na estrutura de laço de repetição).

a chave do jogo; e (vi) criar as funções/variáveis e atribuir os elementos respectivos. Esse último tópico é o mais trabalhoso para o desenvolvedor, pois esse processo não é automático. Ou seja, a partir da estrutura *JSON* do GLBoard, a atribuição das variáveis é de responsabilidade do desenvolvedor. Por exemplo, a variável *performance* armazena números inteiros (*int*) e pode assumir valores distintos, dependendo do contexto de cada jogo: quantidade de estrelas obtidas, porcentagem de conclusão, pontuação do jogador, etc. Já a variável *path_player* é uma lista que pode armazenar *strings*, referentes ao percurso do jogador nas fases e pode conter elementos diversos (plataformas, *checkpoints*, *timestamps*, etc). Desse modo, as estruturas *JSON* podem assumir inúmeras formas e dependem (i) das mecânicas do jogo e (ii) de como o desenvolvedor estruturou as variáveis de captura. Como a associação das variáveis foi realizada na etapa anterior, identificou-se os elementos via código, que foram inseridos nas variáveis respectivas do GLBoard.

Playtesting: para verificar se os dados estavam sendo capturados corretamente, testes foram conduzidos com o jogo para gerar registros de dados (*logs*). A partir disso, foi possível acompanhar pela *API* do GLBoard os dados gerados, e pôde-se confirmar que a captura estava ocorrendo de forma eficaz.

Validação das variáveis: em seguida, fez-se uma validação das variáveis capturadas para verificar se estavam adequadas com seus objetivos de aprendizagem, ou seja, se expressavam indícios de evolução do jogador para identificar aprendizagem. Portanto, a partir dos dados gerados na etapa anterior de *Playtesting*, analisou-se as variáveis presentes *Path_player*, chegando-se à conclusão de que estavam adequadas.

3.5. Coleta e Análise de Dados

A coleta de dados desse estudo deu-se a partir dos relatos dos especialistas, que comentaram sobre o processo de implementar o GLBoard em um jogo educacional que

já estava parcialmente desenvolvido. A partir dos relatos dos especialistas, fez-se uma análise qualitativa dos dados: identificação de padrões, agrupamento por categorias e descrição dos relatos, que estão sendo apresentados na Seção 4.

4. Resultados e discussões

Após a análise dos dados coletados – relatos dos especialistas sobre a implementação da ferramenta GLBoard em um jogo educacional, os resultados obtidos apontam que os especialistas enfrentaram dificuldades durante esse processo, como ilustrado na Figura 3 e explicados em sequência. Desse modo, a Hipótese Alternativa (H1) foi confirmada e a Hipótese Nula (H0) foi rejeitada, ou seja, incorporar a estrutura do GLBoard em um jogo já desenvolvido impacta no nível de dificuldade em implementar técnicas de GLA.

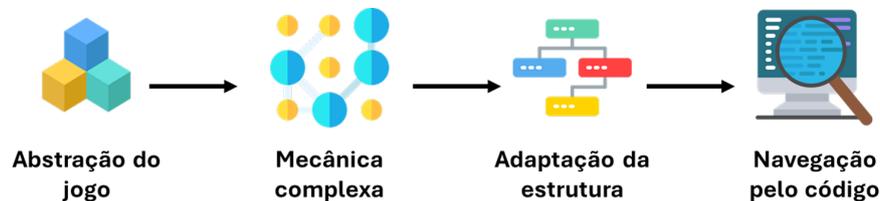


Figura 3. Desafios identificados.

Abstração do jogo: a construção do jogo deu-se por dois especialistas com experiência em desenvolvimento de jogos educacionais com a *game engine Unity* e finalistas em um curso de computação. Um dos especialistas (E1) era o *game designer*, o responsável pela idealização do jogo, e outro (E2) auxiliou na implementação de algumas mecânicas. Apesar do E2 compreender como o jogo funcionava, precisou de auxílio do E1 para entender como a modelagem dos dados havia sido feita, ou seja, o que pretendia ser capturado. Isso revelou-se como um desafio pois, para o E2 inserir as variáveis de captura de dados, precisou abstrair o funcionamento do jogo e o modelo definido para a coleta. Em uma circunstância onde E1 não estivesse presente para auxiliar E2, a complexidade seria ainda maior, necessitando de uma análise mais minuciosa ou, dependendo do cenário, até a remodelagem dos dados.

Mecânica complexa: o jogo Hello Food distingue-se por apresentar mecânicas avançadas além de interação *point-and-click*. Ele é estruturado em dois níveis distintos, cada um com suas fases e objetivos específicos, demandando diferentes tipos de interação e estratégias de game design. No Nível 1, a dinâmica é predominantemente de *point-and-click*, facilitando a identificação das interações esperadas pelo jogo, tornando as variáveis de ação mais previsíveis. Já o Nível 2 expande as formas de interação, incluindo, além do *point-and-click*, a navegação por *joystick*. Aqui, o jogador enfrenta tarefas mais complexas, como escolher ingredientes para pratos, decidir qual prato construir primeiro com base na urgência e utilizar estruturas condicionais (similares a “*if*” e “*else*” na programação) para testar soluções antes que o tempo se esgote. Essa fase desafia o jogador a aplicar conceitos de programação e raciocínio lógico em um contexto simulado de cozinha. Portanto, por apresentar mecânicas distintas e não triviais, a implementação das técnicas de GLA pelos especialistas foi um desafio, necessitando de estruturas distintas para contemplar o percurso do jogador nos dois níveis da fase.

Adaptação da estrutura: o jogo já havia sido implementado, de forma parcial, pelo E1, que também definiu o que pretendida ser capturado. Isso impactou diretamente na implementação das técnicas de GLA, por dois fatores: (i) a forma cujos dados foram estruturados não é equivalente à estrutura em *JSON* do GLBoard e (ii) as variáveis de captura para os objetos respectivos das fases já haviam sido criadas. Dessa forma, para capturar um determinado aspecto via GLA, foi necessário primeiro identificar se esses elementos já haviam sido implementados no código, de que forma – para assim ajustá-los à estrutura do GLBoard – e, caso contrário, criá-los. Isso caracteriza-se como um desafio, pois foi necessário associar os elementos definidos para captura com as variáveis presentes no código. No cenário ideal essa associação não existe, pois as variáveis de captura são criadas juntamente com a implementação do jogo.

Navegação pelo código: um desafio, de natureza mais técnica, refere-se à navegabilidade pelos códigos do jogo. Como o jogo não se encontrava completamente finalizado quando as técnicas de GLA foram implementadas, muitas partes do código estavam incompletas, algumas funcionalidades ausentes, etc. Por isso, “navegar” pelo código para adicionar as variáveis de captura foi um desafio, correlacionando-se com a mecânica complexa do jogo, que ocasionou na geração de muitas linhas de código.

Portanto, a incorporação da ferramenta GLBoard, em um jogo já desenvolvido, impactou no nível de dificuldade em implementar as técnicas de GLA. Apesar de dois especialistas participarem desse processo, desafios emergiram e tornaram a implementação mais complexa, confirmando a Hipótese Alternativa (H1) e rejeitando a Hipótese Nula (H0). Dessa forma, os resultados indicam que é fundamental implementar o jogo juntamente com as técnicas de GLA – possuindo uma modelagem de dados com as variáveis de captura bem definidas – e não após já ter sido desenvolvido.

5. Considerações finais

A utilização de técnicas de GLA, em intersecção com os testes heurísticos, pode auxiliar o educador a identificar a progressão do jogador e possíveis evidências de aprendizagem. A ferramenta GLBoard é uma ferramenta adequada para a implementação dessas técnicas, cuja característica principal é sua generalização, permitindo ser utilizada em quaisquer jogos. No entanto, é preciso realizar a modelagem de dados de forma prévia para isso, e as técnicas de captura devem ser implementadas concomitantemente à criação do jogo. Quando o jogo já está implementado, esse processo torna-se desafiador.

Este trabalho explorou esses desafios, apresentando um estudo de caso na implementação de técnicas de GLA com a ferramenta GLBoard no jogo educacional Hello Food. Apesar desse processo ter sido realizado por dois especialistas e finalistas de computação, alguns desafios foram identificados, tais como: abstração do jogo, mecânica complexa, adaptação da estrutura e navegação pelo código. Dessa forma, a contribuição desse trabalho ressalta a importância de implementar as técnicas de GLA no início, junto a criação do jogo, mostrando que não fazer isso torna o processo mais complexo.

Como trabalhos futuros, pretende-se fazer uma análise com mais especialistas, visando identificar mais desafios e como mecânicas distintas de jogos facilitam ou dificultam os processos de implementação de técnicas de GLA. Também pretende-se realizar pesquisas relacionadas ao modelo “ideal” de implementação dessas técnicas, explorando as contribuições de criar as variáveis de captura junto com as mecânicas do jogo.

Referências

- Alonso-Fernandez, C., Calvo, A., Freire, M., Martinez-Ortiz, I., e Fernandez-Manjon, B. (2017). Systematizing game learning analytics for serious games. In *2017 IEEE global engineering education conference (EDUCON)*, pages 1111–1118. IEEE.
- Alonso-Fernández, C., Calvo-Morata, A., Freire, M., Martínez-Ortiz, I., e Fernández-Manjón, B. (2019). Applications of data science to game learning analytics data: A systematic literature review. *Computers & Education*, 141:103612.
- Alonso-Fernández, C., Calvo-Morata, A., Freire, M., Martínez-Ortiz, I., e Fernández-Manjón, B. (2023). Evidence-based evaluation of a serious game to increase bullying awareness. *Interactive Learning Environments*, 31(2):644–654.
- Freire, M., Serrano-Laguna, Á., Manero, B., Martínez-Ortiz, I., Moreno-Ger, P., e Fernández-Manjón, B. (2016). Game learning analytics: learning analytics for serious games. In *Learning, design, and technology*, pages 1–29. Springer Nature Switzerland AG.
- Macena, J., Pires, F., Pessoa, M., e Melo, R. (2022). Hello food: um jogo para praticar conceitos de algoritmos para iniciantes na computação. In *Anais Estendidos do XXI Simpósio Brasileiro de Jogos e Entretenimento Digital*, pages 1066–1075. SBC.
- Mangaroska, K., Larssen, K., Amundsen, A., Vesin, B., e Giannakos, M. (2024). Understanding engagement through game learning analytics and design elements: Insights from a word game case study. In *Proceedings of the 14th Learning Analytics and Knowledge Conference*, pages 305–315.
- Melo, D., Melo, R., Bernardo, J. R. S., Pessoa, M., Rodríguez, L. C., e Pires, F. (2020a). Uma estratégia de game learning analytics para avaliar level design em um jogo educacional. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 622–631. SBC.
- Melo, R., Pires, F., Lima, P., Pessoa, M., e de Oliveira, D. B. F. (2020b). Metodologias para a criação de jogos educacionais: um mapeamento sistemático da literatura. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 572–581. SBC.
- Petri, G., von Wangenheim, C. G., e Borgatto, A. F. (2019). Meega+: Um modelo para a avaliação de jogos educacionais para o ensino de computação. *Revista Brasileira de Informática na Educação*, 27(03):52–81.
- Plass, J. L., Homer, B. D., e Kinzer, C. K. (2015). Foundations of game-based learning. *Educational psychologist*, 50(4):258–283.
- Silva, D., Pires, F., Melo, R., e Pessoa, M. (2022). Glboard: um sistema para auxiliar na captura e análise de dados em jogos educacionais. In *Anais Estendidos do XXI Simpósio Brasileiro de Jogos e Entretenimento Digital*, pages 959–968. SBC.
- Souza, H. C. d., Junior, M. M. C., e Felinto, A. S. (2021). Inclusão das avaliações formativa e somativa no processo de desenvolvimento de um jogo educacional: Um estudo de caso no projeto do jogo castaways. In *Anais Estendidos do XX Simpósio Brasileiro de Jogos e Entretenimento Digital*, pages 445–454. SBC.

- Udeozor, C., Toyoda, R., Russo Abegão, F., e Glassey, J. (2023). Digital games in engineering education: systematic review and future trends. *European Journal of Engineering Education*, 48(2):321–339.
- Wiemeyer, J., Kickmeier-Rust, M., e Steiner, C. M. (2016). Performance assessment in serious games. *Serious games: Foundations, concepts and practice*, pages 273–302.
- Xu, M., Luo, Y., Zhang, Y., Xia, R., Qian, H., e Zou, X. (2023). Game-based learning in medical education. *Frontiers in public health*, 11:1113682.