

Investigando evidências de aprendizagem em jogos educacionais: uma análise do template de dados do GLBoard

Cleidiana Alves, José Nilson, Manuela Bastos, Rafaela Melo,
Márcia Sampaio, Marcela Pessoa, Fernanda Pires

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

{cma.lic20, jnbds.lic21, mcpb.snf21, msllima, mspessoa, fpires}@uea.edu.br

rmelo@icomp.ufam.edu.br

Abstract. Introduction: *The field of Game Learning Analytics (GLA) has grown as an alternative to address the challenge of evaluating learning in educational games. However, existing data capture templates tend to focus on usage and performance variables, with gaps in learning data. Objective:* This work presents a study that analyzes the GLBoard data template in identifying indicators of learning. **Methodology:** *The study conducted two analyses: i) a documentary analysis of the fields in the data template and ii) an analysis of the variables captured by GLBoard in a computer-focused game. Results:* The results indicate that the data template records performance and usage logs, but has limitations in representing learning data.

Keywords: *Game Learning Analytics, Educational Games, Data Template, Learning Indicators, Computing Education*

Resumo. Introdução: *A área de Game Learning Analytics (GLA) tem crescido como uma alternativa para enfrentar o desafio de avaliar a aprendizagem em jogos educacionais. Entretanto, os templates de captura de dados existentes tendem a focar em variáveis de uso e desempenho, com lacunas nos dados de aprendizagem. Objetivo:* Este trabalho apresenta um estudo que analisa o template de dados do GLBoard, na identificação de indícios de aprendizagem. **Metodologia:** *O estudo conduziu duas análises: i) uma documental, dos campos do template de dados e ii) uma das variáveis capturadas pelo GLBoard em um jogo voltado para computação. Resultados:* Os resultados indicam que o template de dados registra logs de desempenho e uso, mas apresenta limitações na representação de dados de aprendizagem.

Palavras-Chave: *Game Learning Analytics, Jogos Educacionais, Template de Dados, Indícios de Aprendizagem, Educação em Computação*

1. Introdução

Jogos educacionais podem ser ferramentas relevantes para a aprendizagem em cursos de computação [Plass et al. 2020, da Silva et al. 2021]. Os efeitos de motivação e engajamento dessas ferramentas tendem a melhorar o desempenho dos estudantes [Li et al. 2024], com potencial de melhores resultados, quando comparado a mídias tradicionais como vídeos, apostilas e apresentações [Hsiao 2007]. Além disso, contribuem para o desenvolvimento de habilidades específicas, como o Pensamento Computacional

(PC), a resolução de problemas, o raciocínio lógico e a retenção do conhecimento adquirido durante a prática do jogo [Genesio et al. 2024, Li et al. 2024].

Apesar dos benefícios dos jogos educacionais, ainda existem limitações, especialmente na avaliação da aprendizagem, o que dificulta sua consolidação como ferramenta educacional. Entre essas limitações destacam-se: i) falta de variáveis relacionadas a competências computacionais [Plass et al. 2020]; ii) métricas genéricas sem vínculo com habilidades [Plass et al. 2020]; e iii) a ausência de registros de processos cognitivos, como raciocínio algorítmico ou depuração [Plass et al. 2020]. Esses elementos são essenciais para evidenciar a aprendizagem e parametrizar a evolução dos estudantes. O uso de *Game Learning Analytics* (GLA), que coleta e analisa dados de jogos educacionais, surge como uma alternativa para mitigar essas limitações [Freire et al. 2016].

A utilização de GLA busca gerar evidências sobre o desempenho do estudante [Rodrigues et al. 2013], fornecer uma experiência personalizada [Peirce et al. 2008] e trazer informações sobre falhas no *level design* ou até mesmo na *gameplay* [Melo et al. 2020]. Modelos como o xAPI¹ permitem capturar interações detalhadas do usuário por meio de *statements* armazenados em um *Learning Record Store* (LRS) [Johnson et al. 2020, Freire et al. 2016]. Já o xAPI–Serious Games Profile, estende esse modelo para jogos sérios, registrando ações específicas como movimentos, escolhas e erros em ambientes educacionais e simulados [Serrano-Laguna et al. 2017a]. Apesar da existência desses modelos, a aplicação de GLA não é trivial, mesmo trazendo benefícios técnicos e pedagógicos para seus usuários [Silva et al. 2022, Honda et al. 2023]. Com o objetivo de facilitar o gerenciamento das informações geradas por jogos educacionais, surge o GLBoard, um sistema de captura, análise e visualização de dados, estruturado em quatro módulos: *package*, *API*, banco de dados e *dashboard* [Melo et al. 2022].

Por meio do *template* de dados do GLBoard, o sistema consegue registrar tanto informações do jogador (data de aniversário, gênero, id, nome), quanto dados de *gameplay*, como fases, sessões e performance e foi projetado para ser genérico e aplicável a qualquer jogo [Melo et al. 2022]. Porém, ao registrar informações de uso e desempenho, como fases, tentativas, performance e tempo, o *template* de dados apresenta limitações para evidenciar indícios explícitos de aprendizagem [Honda et al. 2023], tanto no *JSON* gerado a partir dessa captura, quanto no que é exibido no *dashboard*, o que sugere que essas restrições decorrem diretamente do próprio *template* de dados do sistema GLBoard.

Diante dessas limitações, este estudo tem como objetivo realizar uma análise exploratória sobre o *template* de dados do GLBoard, investigando como ele é capaz de identificar, de forma explícita, indícios de aprendizagem em jogos voltados à Educação em Computação. Para alcançar os objetivos propostos, foram elaboradas três questões de pesquisa que guiarão a análise deste estudo:

- **QP1:** Como identificar indícios de aprendizagem por meio do *template* de dados gerados pelo GLBoard?
- **QP2:** Qual a relação das variáveis com o conteúdo curricular explorado no jogo?
- **QP3:** Quais variáveis adicionais são necessárias para capturar processos de aprendizagem em jogos educacionais de Educação em Computação?

A partir da análise de múltiplas fontes de dados, incluindo a documentação do

¹<https://xapi.com/>

sistema, os *logs* de interação de 11 jogadores e a entrevista com o desenvolvedor do jogo, o trabalho discute as deficiências do *template* de dados e propõe um conjunto de 20 variáveis que podem orientar futuros instrumentos de coleta. Dessa forma, o estudo contribui para o desenvolvimento de sistemas de GLA mais alinhados às competências educacionais, ao indicar variáveis com potencial para evidenciar indícios de aprendizagem em jogos educacionais.

2. Referencial Teórico e Trabalhos Relacionados

2.1. *Game Learning Analytics*

A integração de *Learning Analytics* (LA) e *Game Analytics* (GA) resultou na área de GLA, voltada à análise de dados de interação em jogos educacionais para verificar o alinhamento entre objetivos de aprendizagem e o uso do jogo [Freire et al. 2016, Alonso-Fernández et al. 2019]. As variáveis são coletadas de forma não intrusiva por meio de registros de *gameplay*, contemplando ações realizadas, tempo, progresso em fases e resultados, que podem ser associados a competências ou conteúdos específicos [Silva et al. 2022]. A visualização dessas informações em *dashboards* permite que professores e desenvolvedores analisem o comportamento dos estudantes, identifiquem dificuldades e realizem ajustes pedagógicos ou no *level design* do jogo [Alonso-Fernández et al. 2021, Macena et al. 2024].

Apesar desse potencial, a aplicação de GLA ainda enfrenta desafios quando o foco é evidenciar aprendizagem. Predominam métricas agregadas, como tempo de jogo, fases concluídas e pontuação, que indicam participação mas pouco informam sobre como o desempenho do estudante é construído ao longo da interação, quantos erros o estudante comete, quantas tentativas precisa, que estratégias utiliza para concluir os objetivos das fases e se ajusta seu comportamento à medida que compreende o conteúdo [Alonso-Fernández et al. 2019, Alonso-Fernandez et al. 2017]. Além disso, a alta diversidade de mecânicas e objetivos educacionais leva ao desenvolvimento de soluções *ad-hoc*, sem um *template* genérico amplamente adotado, o que dificulta a padronização e a comparabilidade entre estudos [Alonso-Fernandez et al. 2017, Macena et al. 2024].

Nesse cenário, o GLBoard [Silva et al. 2022] propõe um sistema de GLA baseado em um *template* de dados genérico para auxiliar na captura e na análise de informações em jogos educacionais. A solução é composta por módulos que incluem uma API, um pacote de integração para a *engine* Unity, um banco de dados e um *dashboard* web. No centro desse sistema está o *template* de dados em formato *JSON* que especifica quais informações devem ser registradas sobre cada jogador e cada seção de jogo. Este *template* de dados é organizado em entidades como *player_data*, *game_data*, *phase* e *section*, que estruturam dados de perfil, sessões de jogo e progresso dos estudantes. Ao fornecer uma estrutura comum de captura, o *template* reduz o esforço de definição das estruturas de dados e torna mais consistente a implementação de GLA em diferentes jogos. A Figura 1 ilustra a organização dessas entidades e seus relacionamentos.

Trabalhos indicam que a integração do GLBoard em jogos já desenvolvidos, sobretudo os com mecânicas complexas, pode exigir esforço adicional [Macena et al. 2024]. A modelagem prévia dos dados, a seleção de variáveis relevantes e adequação às estruturas do *template* de dados exigem abstração do funcionamento do jogo e reestruturação do código, especialmente quando o desenvolvimento não considerou GLA desde o início

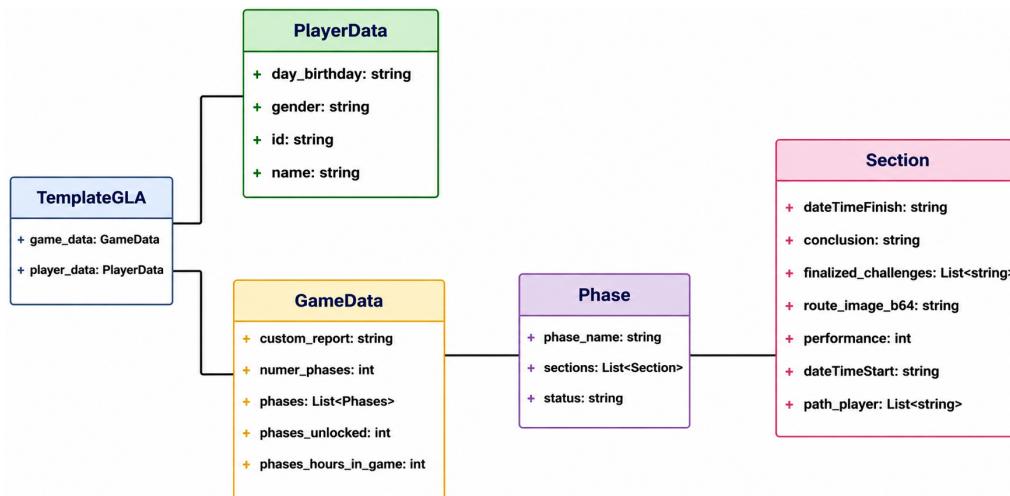


Figura 1. Template de dados do sistema GLBoard.

[Honda et al. 2023]. A inserção tardia de variáveis de captura torna o processo mais trabalhoso, mesmo com o suporte da ferramenta [Macena et al. 2024]. Embora o GLBoard avance na padronização da captura de dados em jogos educacionais, ainda depende de decisões locais sobre quais variáveis e eventos registrar [Silva et al. 2022].

2.2. Trabalhos Relacionados

Estudos em GLA analisam como jogos educacionais podem apoiar a avaliação da aprendizagem, discutir desafios de implementação e compreender a perspectiva de diferentes *stakeholders*, com foco em modelagem de dados, padronização da captura e uso de ferramentas em diversos contextos [Alonso-Fernandez et al. 2017, Freire et al. 2016, Silva et al. 2022]. Ainda há poucos trabalhos que definem *templates* genéricos, como o *template* de dados do GLBoard, e que analisam se esses *templates* permitem identificar indícios de aprendizagem em jogos voltados à educação em computação.

Alonso-Fernández *et al.* (2022) investigaram a sistematização de análises de aprendizagem em jogos sérios, combinando o padrão xAPI-SG e técnicas de mineração de dados. As interações em um jogo de primeiros socorros foram registradas em xAPI-SG e analisadas em duas etapas: uso do T-MON para gerar visualizações e derivação de variáveis para análise com modelos de mineração de dados. Os autores mostram que o tempo de jogo não se relaciona à aprendizagem, mas acertos em questões e interações específicas, como com o desfibrilador, se associam a melhores resultados em pré e pós-testes. Isso sugere que, embora padrões de dados e ferramentas independentes reduzam o esforço de integração, ainda há desafios na seleção de indicadores de aprendizagem derivados dos modelos de dados e das variáveis extraídas das interações registradas nos *logs* do jogo.

Honda *et al.* (2023) investigaram as dificuldades de estudantes de computação na modelagem de dados para jogos educacionais, usando modelos de GLA como xAPI-SG e GLBoard. O estudo revela que a definição de variáveis de captura, a adaptação do jogo e o tempo para modelar são vistos como complexos, mesmo por participantes experientes em programação e desenvolvimento de jogos. Embora o GLBoard ofereça um *template* genérico, a seleção e justificativa das variáveis ainda é pouco abordada na literatura.

tura, dificultando a explicitação de como os eventos mapeados se relacionam a objetivos de aprendizagem específicos.

Macena *et al.* (2024) investigaram os desafios na implementação de técnicas de GLA em um jogo educacional de algoritmos, usando a ferramenta GLBoard. Os autores identificaram dificuldades na modelagem da estrutura de dados no jogo “Cadê minha pizza?”, como a necessidade de modelá-la antes do desenvolvimento do jogo e integrar mecânicas complexas no código existente. Os resultados indicam que incorporar o GLBoard em jogos não originalmente projetados para GLA aumenta a complexidade da implementação, destacando a importância de planejar a modelagem de dados desde as etapas iniciais do desenvolvimento, alinhando-a ao domínio de aprendizagem.

Os trabalhos relacionados indicam que: i) técnicas de GLA podem fornecer evidências sobre desempenho e indícios de aprendizagem, desde que as variáveis de captura e análise sejam alinhadas aos objetivos educacionais; ii) *templates* genéricos de dados, como xAPI-SG e o *template* do GLBoard, padronizam a captura e facilitam a integração de dados entre jogos, mas ainda exigem que os desenvolvedores definam e justifiquem eventos e atributos relacionados aos objetivos de aprendizagem; e iii) a modelagem de dados enfrenta desafios como abstrair o processo de jogo, adaptar mecânicas e lidar com a complexidade técnica, o que pode dificultar o uso de GLA, mesmo para desenvolvedores experientes. Diferente desses trabalhos, este estudo concentra-se na análise das limitações do *template* de dados do GLBoard na representação de indícios de aprendizagem, além de propor variáveis adicionais para ampliar sua capacidade analítica no que se refere a dados de aprendizagem.

3. Metodologia

O objetivo deste trabalho é realizar uma análise exploratória do *template* de dados do GLBoard. Para tanto, conduziu-se um estudo dividido em três etapas, detalhadas a seguir.

3.1. Planejamento

O caso analisado neste estudo refere-se à investigação exploratória do *template* de dados do GLBoard, com o objetivo de verificar como o instrumento é capaz de identificar variáveis que forneçam indícios de aprendizagem em jogos educacionais voltados à educação em computação. O *template* de dados do GLBoard foi adotado como objeto de estudo, pois a maior parte das pesquisas sobre a ferramenta concentra-se na implementação, e não em sua capacidade de representar dados relacionados à aprendizagem.

A etapa de análise contou com a participação de três autores deste trabalho, especialistas em GLA, com mais de três anos de experiência na área: E1, E2 e E3. Os participantes já atuaram na implementação de soluções baseadas em GLA e utilizaram o GLBoard em contextos de captura e análise de dados de jogos educacionais, incluindo o uso do *template* e a interpretação das informações no *dashboard*.

3.2. Coleta de Dados

Para fundamentar o estudo, foram escolhidas três fontes: i) a documentação do sistema GLBoard; ii) os *logs* de um jogo educacional de Educação em Computação e iii) entrevista com o autor do jogo.

Documentação de sistemas: A documentação do sistema GLBoard foi utilizada com o objetivo de mapear as informações e a estrutura do *template*, identificar os elementos relacionados à captura de dados e compreender o funcionamento do sistema. A documentação foi acessada por meio da página *web* oficial do sistema GLBoard².

Log do jogo: O jogo “Cadê minha Pizza?” [Honda et al. 2022] foi selecionado com base em critérios técnicos e pedagógicos, como a implementação do *template* de dados do GLBoard e a disponibilidade de registros de jogabilidade. No jogo educacional “Cadê minha Pizza?”, o jogador gerencia entregadores de pizza em uma cidade representada por um grafo ponderado e deve realizar entregas escolhendo rotas curtas para minimizar o consumo de gasolina. Os entregadores possuem combustível limitado, e o jogador seleciona rotas que conectam a pizzaria a residências específicas. Para avançar, é necessário analisar o mapa, avaliar as rotas disponíveis e decidir qual entregador utilizar em cada entrega. As fases aumentam em complexidade com a adição de vértices (estabelecimentos), arestas (ruas com pesos de gasolina) e entregadores.

A aplicação do jogo ocorreu em contexto educacional no ensino superior, com estudantes de graduação em cursos da área de Computação. O autor do jogo disponibilizou um arquivo com 1.250 linhas de registros de jogabilidade de 11 usuários. Os dados foram coletados de forma anonimizada, permitindo seu uso para fins acadêmicos.

Os registros de jogabilidade estão organizados em fases, subdivididos em sessões que capturam cada tentativa do jogador. As variáveis de análise incluem marcadores de tempo, como *dateTimeStart* e *dateTimeFinish*, essenciais para medir o tempo de resolução. O *path_player*, como mostra a direita da Figura 2, detalha as ações executadas (ex.: “Motoboy 1 - House 2 (Sucesso)” ou falhas como “Sem gasolina”). O desfecho de cada tentativa é categorizado pela variável *conclusion* (geralmente “VITORIA” ou “DESISTENCIA”) e quantificado pela métrica *performance*, que atribui um valor numérico ao desempenho da rodada (ex.: 3, 2 ou -1).



Figura 2. Tela e dados capturados da fase 1 do jogo “Cadê minha Pizza?”.

O arquivo de *log* contém informações demográficas na entidade *player_data*. Essas informações incluem atributos como *gender* (gênero), *day_birthday* (data de nascimento) e *id*.

Entrevista: Para compreender o processo de adaptação da modelagem de dados do jogo ao *template* de dados, bem como identificar motivações e dificuldades na

²<https://glboard.bitdocs.ai/share/d/bgZT6cn2VsnWUKMn>

implementação do GLBoard no jogo, realizou-se uma entrevista semiestruturada com o autor do jogo. As questões abordaram a definição das variáveis registradas, a organização das fases e sessões, a representação das decisões do jogador e as limitações observadas durante a integração. Esses aspectos são importantes, pois influenciam a forma como os dados de *gameplay* são estruturados e posteriormente analisados no contexto de GLA, afetando a interpretação do comportamento dos jogadores e a extração de possíveis evidências de aprendizagem.

3.3. Análise dos Dados

A análise dos dados foi conduzida de forma sistematizada, a partir das fontes descritas anteriormente. O procedimento envolveu o exame da estrutura do *template* de dados do GLBoard e dos *logs* gerados pelo jogo, além da análise qualitativa da entrevista com o desenvolvedor. No caso do *template* e dos *logs*, foram analisadas as variáveis registradas, sua organização no modelo de dados e a forma como os eventos de interação do jogador são representados e armazenados. Também foi verificado se as informações registradas permitiam acompanhar aspectos da interação durante a *gameplay*, como tempos de sessão, progressão de fases, número de tentativas, status de conclusão e indicadores de desempenho. A análise teve como objetivo verificar se a estrutura atual do *template* de dados do GLBoard permite representar indícios do processo de aprendizagem ou se os dados se restringem a informações gerais de uso e desempenho.

A entrevista foi gravada, transcrita integralmente e analisada por meio de uma análise qualitativa de caráter temático. Nessa análise, foram identificadas categorias relacionadas às dificuldades de modelagem e às limitações do *template*.

4. Resultados e Discussão

O procedimento de análise buscou compreender o funcionamento e a aplicabilidade do *template* de dados do GLBoard a partir de três fontes de dados: a documentação oficial da ferramenta, entrevista com o autor do jogo e a implementação do *template* de dados no jogo “Cadê minha Pizza?” [Honda et al. 2022].

Conforme ilustrado na Figura 3, a estrutura de dados do GLBoard é composta por quatro componentes: GLBoard Package, Banco de Dados, GLBoard Dashboard e GLBoard API. Este estudo concentra-se no GLBoard Package, responsável pela captura e processamento dos dados do jogador. A documentação apresenta um *template* em formato JSON, organizado em *player_data*, *game_data* e *phases*. O *player_data* reúne informações de perfil, como ID, nome e gênero. O *game_data* registra o progresso, incluindo tempo de jogo, fases completadas e desafios concluídos, enquanto *phases* e *sections* armazenam dados sobre desempenho, percurso, interações e conquistas no jogo.




Figura 3. Estrutura do sistema GLBoard, adaptado de Melo et al. (2022).

No *template* atual de dados, o desenvolvedor precisa adaptar o jogo às variáveis já previstas no *template*. Isso significa que, ao integrar o GLBoard, não é possível incluir, de forma nativa, dados adicionais ou novos tipos de eventos de aprendizagem não contemplados no *template* original. A documentação específica como cada tipo de dado é estruturado e como pode ser utilizado para monitorar o progresso do jogador, mas também indica que a flexibilidade do sistema é limitada à estrutura original definida no *template*. Essa limitação deve ser considerada ao integrar o GLBoard em jogos educacionais que necessitam de tipos de dados mais específicos ou variáveis adicionais para capturar eventos de aprendizagem não previstos na implementação inicial.

Durante a entrevista com o desenvolvedor do jogo “Cadê minha pizza?”, ele apontou que foi necessário adaptar o código ao *template* existente, definindo variáveis, ajustando a hierarquia de objetos, removendo código e inserindo chamadas ao pacote durante a *gameplay*. O desenvolvedor também mencionou depender de tutoriais e de apoio especializado para entender quais dados mapear e como configurar estruturas como *player_data*, *phases* e *sections*, além de representar as decisões do jogador. Essas dificuldades indicam que o *template* de dados do GLBoard atual exige configuração específica e conhecimento técnico, apresentando limitações na definição de variáveis de aprendizagem.

Depois, os *logs* do jogo “Cadê minha pizza?” foram utilizados como forma de analisar uma implementação prática do *template* de dados do GLBoard. A análise dos *logs* de 11 jogadores revelou que o *template* captura principalmente dados gerais de progresso, como identificação do jogador, fases desbloqueadas, status de conclusão, e sequências básicas de ações realizadas. No entanto, as variáveis diretamente associadas ao processo de aprendizagem, como erros de decisão, tentativas incompletas, e tipos de erro, não são registradas de forma estruturada, dificultando uma interpretação pedagógica mais precisa.

Em conjunto, essas evidências indicam que, para apoiar análises de aprendizagem mais detalhadas, seria necessário estender o *template* de dados com variáveis específicas de erro, decisão e trajetória do jogador. Nesse contexto, foram propostas novas variáveis para a classe *Section* e *GameData*, resumidas na Tabela 1. As 20 variáveis propostas foram definidas com base em trabalhos da literatura em GLA e na análise das limitações identificadas no *template* atual do GLBoard. A seleção considerou três aspectos: (i) cobertura de lacunas do *template* atual, priorizando variáveis ausentes relacionadas a processos cognitivos e estratégicos, como sequência de ações, eventos de erro e uso de dicas; (ii) capacidade de fornecer evidências de aprendizagem além de métricas de uso e desempenho, como tempo de hesitação, frequência de erros e padrões de atenção visual; e (iii) viabilidade de coleta, priorizando variáveis registráveis a partir de eventos de *gameplay* já existentes ou com menor complexidade de instrumentação.

As variáveis da classe *Section* registram o comportamento do jogador, como sequência de ações, hesitação em desafios, resposta a feedback, uso de suporte, padrões de atenção visual e intensidade de interação. As variáveis da classe *GameData* focam no progresso entre fases e estados emocionais, ligando o desempenho ao avanço no jogo e engajamento ao longo das sessões. A proposta é adicionar essas variáveis ao *template* de dados existente, ampliando a granularidade das informações sem modificar sua estrutura, permitindo ajustes no design do jogo e análises mais precisas sobre o processo de aprendizagem.

Tabela 1. Sugestões de novas variáveis de GLA para o template do GLBoard.

Variável	Descrição	Referência
response_time_interaction	Tempo de resposta a desafios ou perguntas.	[Serrano-Laguna et al. 2017b]
feedback_displayed	Registro das mensagens de feedback apresentadas (texto, visual ou sonoro).	[Alonso-Fernandez et al. 2017]
tip_used	Número de dicas solicitadas pelo jogador.	[Alonso-Fernandez et al. 2017]
specific_fixation_time	Duração da fixação do olhar em um ponto específico da interface (eye-tracking).	[Avila Pesantez et al. 2021]
clicks	Número total de cliques realizados pelo jogador durante o jogo.	[Gagné et al. 2012, El-Nasr et al. 2013]
menu_selections	Número de vezes em que o jogador seleciona opções de menu.	[Serrano-Laguna et al. 2017b]
progress_level_released	Indica se a próxima fase foi liberada, relacionando desempenho com desbloqueio de conteúdo.	[Alonso-Fernandez et al. 2017]
time_frustrated_confused	Tempo em que o jogador apresenta sinais de frustração ou confusão (reconhecimento facial).	[Cloude et al. 2022, Avila Pesantez et al. 2021]
level_attempts	Número de tentativas realizadas pelo jogador para completar uma fase ou desafio específico.	[Serrano-Laguna et al. 2017b]
task_completion_time	Tempo total gasto pelo jogador para concluir uma tarefa ou objetivo dentro da fase.	[Cano et al. 2018]
error_event	Quantidade de erros cometidos pelo jogador durante a execução de uma tarefa ou resolução de um problema.	[Avila Pesantez et al. 2021]
correct_events	Lista de timestamps de eventos em que o jogador realiza ações corretas ou resolve desafios com sucesso.	[Avila Pesantez et al. 2021]
achievement_events	Lista de timestamps de conquistas ou objetivos atingidos pelo jogador durante uma fase ou jogo.	[Avila Pesantez et al. 2021]
hint_usage_frequency	Frequência com que o jogador utiliza dicas ou sistemas de ajuda disponíveis no jogo.	[Banihashem et al. 2023]
interaction_sequence	Sequência de ações realizadas pelo jogador durante a interação com o jogo, permitindo analisar estratégias de resolução.	[Alonso-Fernandez et al. 2017]
idle_time	Tempo em que o jogador permanece inativo durante uma sessão de jogo.	[Cano et al. 2018]
level_completion_rate	Percentual de fases concluídas pelo jogador em relação ao total disponível no jogo.	[Alonso-Fernández et al. 2019]
replay_level_count	Número de vezes que o jogador reinicia ou repete uma mesma fase.	[Freire et al. 2016]
education_level	Nível educacional do jogador, utilizado para contextualizar a análise de aprendizagem e desempenho no jogo.	[Long and Siemens 2011, Banihashem et al. 2023]
gaming_experience	Nível de experiência prévia do jogador com videogames, utilizado para contextualizar análises de desempenho no jogo.	[Loh et al. 2015]

No jogo “Cadê minha pizza?”, que explora grafos e Pensamento Computacional (PC), essas variáveis capturam métricas como tentativas por seção, rotas selecionadas, tempo até a primeira decisão e erros de cálculo de combustível. A partir dessas métricas, podem ser derivados indicadores como eficiência de rota e variação entre tentativas, permitindo observar a evolução do desempenho e evidenciar o desenvolvimento de habilidades em grafos e raciocínio proporcional.

Os resultados indicam limitações no *template* de dados do GLBoard para identificar indícios de aprendizagem. Embora o sistema registre dados de desempenho, como tempo de resposta, tentativas e progresso entre fases, essas informações concentram-se em métricas de uso, sem representar o processo de aprendizagem. Em relação à **QP1**, o *template* atual não explicita indícios de aprendizagem, pois não inclui variáveis que

permitam analisar estratégias do jogador ou evolução cognitiva durante a interação, como sequência de ações, hesitação em desafios e padrões de atenção visual, conforme proposto para a classe *Section* (Tabela 1).

Além disso, as variáveis capturadas não apresentam conexão direta com conteúdos curriculares específicos (QP2). A análise dos *logs* do jogo “Cadê minha pizza?” mostrou que os registros não permitem mapear objetivos de aprendizagem relacionados a grafos ponderados ou aos pilares do Pensamento Computacional. Da mesma forma, o *template* não contempla variáveis associadas a teorias de aprendizagem ou modelos de avaliação educacional (QP3), pois os registros não capturam processos cognitivos como raciocínio algorítmico ou tomada de decisão estratégica.

A análise também indica que a inclusão de variáveis mais específicas, como eventos de erro, tentativas inadequadas e métricas de engajamento, pode ampliar a capacidade analítica do *template*. Essas variáveis permitem capturar aspectos mais detalhados da interação do jogador, possibilitando identificar padrões de comportamento, estratégias de resolução de problemas e evolução do desempenho ao longo das sessões de jogo.

Dessa forma, a ampliação do *template* de dados proposta neste trabalho contribui para aproximar o GLBoard das necessidades da área de *Game Learning Analytics*, ao oferecer uma estrutura de captura de dados mais rica e adequada para a identificação de indícios de aprendizagem em jogos educacionais. Ao incorporar essas novas variáveis, torna-se possível apoiar análises mais precisas sobre o processo de aprendizagem, além de fornecer subsídios para ajustes no design do jogo e para a melhoria de estratégias pedagógicas baseadas em jogos digitais.

5. Considerações Finais

O objetivo deste estudo foi investigar o potencial do *template* de dados do sistema GLBoard para identificar indícios de aprendizagem em jogos educacionais, especialmente no contexto da educação em computação. A pesquisa revelou que, embora o *template* seja eficaz na coleta de dados de desempenho e uso, ele apresenta limitações significativas em capturar variáveis cognitivas e estratégicas. Isso impede uma análise mais profunda do processo de aprendizagem, restringindo a compreensão do desenvolvimento das competências dos jogadores.

A principal contribuição deste artigo é a identificação das deficiências no *template* de dados do GLBoard, que se limita a registrar dados de progresso e desempenho de forma geral. As variáveis existentes não são suficientes para oferecer uma visão detalhada do processo de aprendizagem, como o desenvolvimento de habilidades matemáticas e de raciocínio algorítmico. Nesse sentido, esta análise contribui para a discussão sobre a necessidade de aprimoramento dos *templates* de captura de dados, ao propor um conjunto de 20 variáveis adicionais que podem orientar futuros instrumentos de coleta e possibilitar uma avaliação mais precisa de indícios de aprendizagem em jogos educacionais.

Embora este estudo forneça contribuições para o aprimoramento dos *templates* de dados do GLBoard, as limitações do escopo, incluindo a análise de um único jogo e a amostra restrita de 11 jogadores, precisam ser reconhecidas. Para avançar, futuros estudos devem validar as variáveis propostas em um espectro mais amplo de jogos educacionais e diferentes contextos, a fim de avaliar sua aplicabilidade e impacto em diversas áreas de aprendizagem.

Agradecimentos

Agradecemos à UEA, por meio do Programa de Produtividade Acadêmica 01.02.011304.026472/2023-87 pelo apoio ao desenvolvimento desta pesquisa, aos participantes do estudo e ao NEXUS, prédio base do Grupo de Pesquisa ThinkTed.

Declaração sobre uso de Inteligência Artificial

Durante a preparação deste trabalho, os autores utilizaram as ferramentas *ChatGPT*, *Grammarly* e *Perplexity* especificamente para correções ortográficas e gramaticais. A concepção do estudo, o desenho metodológico, a análise e interpretação dos dados, bem como a redação do artigo foram realizados integralmente pelos autores. As ferramentas de IA foram empregadas apenas na revisão final do texto, sem contribuir para o conteúdo intelectual nem para as conclusões.

Referências

- Alonso-Fernandez, C., Calvo, A., Freire, M., Martinez-Ortiz, I., and 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., and 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., and Manjón, B. F. (2021). Data science meets standardized game learning analytics. In *2021 IEEE Global Engineering Education Conference (EDUCON)*, pages 1546–1552. IEEE.
- Alonso-Fernández, C., Calvo-Morata, A., Freire, M., Martínez-Ortiz, I., and Fernández-Manjón, B. (2019). Applications of data science to game learning analytics data: A systematic literature review. *Computers & Education*, 141:103612.
- Avila Pesantez, D., Usca, B., Angamarca, B., and Avila, L. (2021). Improving the serious game design using game learning analytics and eye-tracking: A pilot study. pages 536–540.
- Banihashem, S. K., Dehghanzadeh, H., Clark, D., Noroozi, O., and Biemans, H. J. A. (2023). Learning analytics for online game-based learning: A systematic literature review. *Behaviour & Information Technology*.
- Cano, A. R., Fernández-Manjón, B., and García-Tejedor, J. (2018). Using game learning analytics for validating the design of a learning game for adults with intellectual disabilities. *British Journal of Educational Technology*, 49(4):696–711.
- Cloude, E., Dever, D., Hahs-Vaughn, D., Emerson, A., Azevedo, R., and Lester, J. (2022). Affective dynamics and cognition during game-based learning. *IEEE Transactions on Affective Computing*, PP:1–14.
- da Silva, T. R., Barros, I. S., da Silva Sousa, L. K., Sá, A. L. D., Silva, A. F. M., Araujo, M. C. S., and da Silva Aranha, E. H. (2021). Um mapeamento sistemático sobre o ensino e aprendizagem de programação. *RENOTE*, 19(1):156–165.
- El-Nasr, M. S., Drachen, A., and Canossa, A., editors (2013). *Game Analytics, Maximizing the Value of Player Data*. Springer.

- Freire, M., Serrano-Laguna, Á., Manero, B., Martínez-Ortiz, I., Moreno-Ger, P., and Fernández-Manjón, B. (2016). Game learning analytics: Learning analytics for serious games. In *Learning, Design, and Technology*, pages 1–29. Springer Nature Switzerland AG.
- Gagné, A. R., Seif El-Nasr, M., and Shaw, C. D. (2012). Analysis of telemetry data from a real-time strategy game: A case study. *Comput. Entertain.*, 10(1).
- Genesio, N., Oliveira, A., Oliveira, E., and Valle, P. (2024). Panorama de estudos sobre jogos educacionais digitais em educação em computação. In *Anais do XXXII Workshop sobre Educação em Computação*, pages 737–749, Porto Alegre, RS, Brasil. SBC.
- Honda, F., Macena, J., Duarte, J., Pires, F., Pessoa, M., and Oliveira, E. (2023). Um estudo de caso para a implementação de game learning analytics (gla) no desenvolvimento de jogos educacionais. In *Anais do II Workshop de Aplicações Práticas de Learning Analytics em Instituições de Ensino no Brasil*, pages 138–146, Porto Alegre, RS, Brasil. SBC.
- Honda, F., Pires, F., Pessoa, M., and Maia, J. (2022). Cadê minha pizza? um jogo para exercitar matemática e pensamento computacional através de grafos. In *Simpósio Brasileiro de Jogos e Entretenimento Digital (SBGames)*, pages 876–885. SBC.
- Hsiao, H.-C. (2007). A brief review of digital games and learning. In *2007 First IEEE International Workshop on Digital Game and Intelligent Toy Enhanced Learning (DIGITEL'07)*, pages 124–129. IEEE.
- Johnson, A., Werkentin, A., and Hernandez, M. (2020). Understanding and applying cmi5 in an xapi solution. In 2020, V., editor, *Proceedings of the 2020 Virtual Interservice/Industry Training, Simulation, and Education Conference (vIITSEC)*, Arlington, VA. National Training and Simulation Association.
- Li, Y., Chen, D., and Deng, X. (2024). The impact of digital educational games on student’s motivation for learning: The mediating effect of learning engagement and the moderating effect of the digital environment. *PLoS ONE*, 19(1):e0294350.
- Loh, C. S., Sheng, Y., and Ifenthaler, D., editors (2015). *Serious Games Analytics: Methodologies for Performance Measurement, Assessment, and Improvement*. Springer.
- Long, P. and Siemens, G. (2011). Penetrating the fog: Analytics in learning and education. *EDUCAUSE Review*, 46(5):30–40.
- Macena, J., Honda, F., Melo, D., Pires, F., Oliveira, E. H., Fernandes, D., and Pessoa, M. (2024). Desafios na implementação de técnicas de gla em um jogo educacional de algoritmos: um estudo de caso. In *Simpósio Brasileiro de Jogos e Entretenimento Digital (SBGames)*, pages 814–825. SBC.
- Melo, D., Melo, R., Bernardo, J. R. S., Pessoa, M., Rodríguez, L. C., and Pires, F. (2020). 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, D., Pires, F., Melo, R., and Pessoa, M. (2022). Glboard: um sistema para auxiliar na captura e análise de dados em jogos educacionais. In *Anais do XXI Simpósio Brasileiro de Games e Entretenimento Digital (SBGames 2022)*.

- Peirce, N., Conlan, O., and Wade, V. (2008). Adaptive educational games: Providing non-invasive personalised learning experiences. In *2008 Second IEEE International Conference on Digital Game and Intelligent Toy Enhanced Learning*, pages 28–35. IEEE.
- Plass, J. L., Mayer, R. E., and Homer, B. D., editors (2020). *Handbook of Game-Based Learning*. The MIT Press.
- Rodrigues, R. L., De Medeiros, F. P., and Gomes, A. S. (2013). Modelo de regressão linear aplicado à previsão de desempenho de estudantes em ambiente de aprendizagem. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação – SBIE)*, volume 24, page 607.
- Serrano-Laguna, A., Martínez-Ortiz, I., Haag, J., Regan, D., Johnson, A., and Fernández-Manjón, B. (2017a). Applying standards to systematize learning analytics in serious games. *Computer Standards & Interfaces*, 50:116–123.
- Serrano-Laguna, A., Martínez-Ortiz, I., Haag, J., Regan, D., Johnson, A., and Fernández-Manjón, B. (2017b). Applying standards to systematize learning analytics in serious games. *Computer Standards Interfaces*, 50:116–123.
- Silva, D., Pires, F., Melo, R., and 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, Porto Alegre, RS, Brasil. SBC.