

Interpretação de um dashboard de Game Learning Analytics por professores de computação e desenvolvedores: um estudo exploratório com o GLBoard

José Brito^{1,2}, Cleidiana Alves^{1,2}, Manuela Bastos¹, Rafaela Melo^{1,2},
Marcela Pessoa¹, Márcia Lima¹, Fernanda Pires¹, David Braga Fernandes de Oliveira^{1,2}

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

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

{mcpb.snf21, fpires, mspessoa, msllima}@uea.edu.br

{jose.nilson, cleidiana.alves, rmelo, david}@icompu.ufam.edu.br

Abstract. *Game Learning Analytics (GLA) supports teachers and developers by providing insights into learning and game design, but its effectiveness depends on the clarity of the information presented. This study investigates the use of a GLA dashboard to support pedagogical practice and educational game design. An exploratory mixed-methods study was conducted with three computing teachers and five developers, using data from the game “Cadê minha Pizza?”. The results indicate that understanding depends on the granularity, cross-referencing, and contextualization of the metrics, and highlight differences in the analytical needs of the two groups. These findings provide a basis for improving GLA dashboards.*

Resumo. *Game Learning Analytics (GLA) apoia professores e desenvolvedores ao fornecer insights sobre aprendizagem e game design, mas sua eficácia depende da clareza das informações apresentadas. Este estudo investiga o uso de um dashboard de GLA como suporte à prática pedagógica e ao design de jogos educacionais. Foi conduzido um estudo exploratório de métodos mistos com três professores de computação e cinco desenvolvedores, utilizando dados do jogo “Cadê minha Pizza?”. Os resultados indicam que a compreensão depende da granularidade, do cruzamento e da contextualização das métricas, além de evidenciarem diferenças nas demandas analíticas dos dois perfis. Esses achados oferecem subsídios para o aprimoramento de dashboards de GLA.*

1. Introdução

O uso de jogos educacionais como estratégia pedagógica tem se consolidado para promover engajamento e motivação [Genesio et al. 2024, Plass et al. 2015]. Contudo, persistem desafios na avaliação da aprendizagem, como a ausência de ferramentas adequadas para mensurar evidências de aprendizagem, a predominância de questionários autoavaliativos

como principal instrumento de aferição e a variabilidade do nível de dificuldade dos jogos, que dificultam comparações e interpretações consistentes sobre o desempenho dos estudantes [Bouroumane et al. 2024, Pires et al. 2018].

Nesse contexto, a *Game Learning Analytics* (GLA) constitui uma abordagem voltada à coleta, análise e interpretação de dados de jogos educacionais, apoiando o acompanhamento do desempenho e a tomada de decisões pedagógicas e de *game design* [Freire et al. 2016b]. A *Visual Analytics* (VA) complementa a GLA ao integrar análise de dados e representações visuais interativas, favorecendo a exploração e a comunicação de informações por meio de *dashboards* [Few 2006].

Em jogos educacionais, registros como tempo, tentativas, erros e decisões fornecem evidências importantes sobre o processo de aprendizagem [Oliveira 2025]. Entretanto, ainda há desafios em transformar esses registros em informações interpretáveis [Susnjak et al. 2022], como a predominância de análises quantitativas, a sobrecarga cognitiva decorrente da ausência de descrições explicativas [Liu et al. 2024] e a fragmentação das informações [Macfadyen and Dawson 2012]. Além disso, o grande volume e a granularidade dos dados gerados durante os jogos ampliam a complexidade analítica.

Esta pesquisa investiga o uso de *dashboards* de *Game Learning Analytics* (GLA) como suporte à prática pedagógica e ao *design* de jogos educacionais. O objetivo é analisar como professores e desenvolvedores interpretam as visualizações de um sistema de captura de dados, identificando fatores que favorecem ou dificultam a compreensão e o uso das informações apresentadas para a tomada de decisões pedagógicas e de *game design*. Nesse contexto, professores são considerados usuários interessados em evidências de aprendizagem e no acompanhamento dos estudantes, enquanto desenvolvedores utilizam os dados para analisar aspectos relacionados à progressão, dificuldade e estrutura do jogo, elementos associados ao *game design*.

Para isso, foi conduzido um estudo exploratório organizado em quatro etapas: (i) definição do contexto do estudo e do jogo educacional utilizado, (ii) planejamento da pesquisa e elaboração dos instrumentos, (iii) coleta de dados por meio da aplicação de questionários a três professores e cinco desenvolvedores e (iv) análise dos dados. As visualizações analisadas foram geradas a partir dos *logs* coletados pelo sistema de captura de dados do jogo “Cadê minha Pizza?” [Honda et al. 2022].

Participaram três professores e cinco desenvolvedores da área de computação, todos com diferentes níveis de experiência e familiaridade com Teoria dos Grafos, jogos educacionais, *Learning Analytics* e *dashboards* educacionais. A análise adotou uma abordagem mista, combinando análise quantitativa de frequência das respostas e análise temática indutiva [Braun and Clarke 2006] das questões dissertativas, permitindo comparar as percepções dos participantes sobre o potencial pedagógico e analítico do *dashboard*.

Como contribuição, o estudo identifica limitações e oportunidades de melhoria em *dashboards* de GLA, especialmente quanto à clareza das métricas, organização das informações e adequação aos diferentes perfis de usuários, reforçando o uso de dados de *gameplay* no monitoramento da aprendizagem e no aprimoramento do *design* de jogos educacionais.

2. Referencial Teórico e Trabalhos Relacionados

Game Learning Analytics (GLA) resulta da integração entre as áreas de *Game Analytics* (GA) e *Learning Analytics* (LA). A GA é voltada à coleta e análise de dados de interação em jogos digitais para compreender o comportamento dos jogadores [El-Nasr et al. 2016]. Já a LA direciona-se à coleta e análise de dados de estudantes, com o objetivo de entender e apoiar processos de aprendizagem [Larsson and White 2014]. No GLA, os dados são coletados de forma não intrusiva por meio de registros de *gameplay*, incluindo ações, tempo, progresso e resultados, associados a competências [Silva et al. 2022]. Assim, GLA refere-se à coleta, análise e visualização de dados de jogos educacionais [Freire et al. 2016a, Alonso-Fernández et al. 2019], apoiando a identificação de evidências de aprendizagem e o monitoramento do progresso dos estudantes.

A visualização de dados pode ser definida como o uso de representações visuais de dados para apoiar a interpretação, a obtenção de informações e a cognição dos usuários [Card et al. 1999, Unwin 2020]. Esse processo é útil para explorar a estrutura dos dados, detectar valores atípicos, identificar tendências, agrupamentos e padrões locais, além de apoiar a apresentação de resultados [Unwin 2020]. No contexto de GLA, a visualização integra o processo de coleta, análise e apresentação de dados de jogos educacionais, permitindo representar registros de interação e desempenho de forma mais compreensível para apoiar a interpretação dos dados [Freire et al. 2016a, Alonso-Fernández et al. 2019].

Para viabilizar a aplicação de técnicas de GLA, é necessário padronizar a coleta e a organização dos dados de *gameplay*. Nesse sentido, o modelo GLBoard estrutura esse processo de captura de dados. Seu *template* em JSON contempla quatro classes: *PlayerData* (perfil do jogador), *GameData* (dados gerais), *Phase* (registros por fase) e *Section* (percurso do jogador, incluindo ações e eventos). O modelo integra ainda quatro módulos: pacote *Unity*, API para envio de dados, banco de dados e *dashboard* para visualização.

Embora modelos como o GLBoard organizem a captura e o armazenamento de dados, sua interpretação depende da transformação desses registros em métricas significativas e de sua apresentação visual aos usuários. Exemplos dessas métricas incluem tempo por fase, número de tentativas e pontuação, apresentados visualmente para apoiar a análise [Meloncon and Warner 2017, Hair 2011]. Nos jogos digitais, tais visualizações evidenciam padrões de engajamento e desempenho [El-Nasr et al. 2016, Seif El-Nasr and Kleinman 2020, Mohapatra et al. 2023]. Em jogos educacionais, permitem que professores e desenvolvedores identifiquem dificuldades e avaliem ajustes pedagógicos e de *design* [Alonso-Fernández et al. 2021, Macena et al. 2024].

Os *dashboards* sintetizam múltiplos indicadores de forma visual, mas sua eficácia depende de organização clara e escolhas adequadas de métricas e representações. A literatura aponta desafios como: predominância de análises descritivas [Susnjak et al. 2022]; sobrecarga cognitiva e baixa literacia visual dos usuários [Liu et al. 2024]; fragmentação das métricas [Macfadyen and Dawson 2012]; e influência de vieses cognitivos na interpretação [Alhadad 2016, Wall et al. 2018].

Diante desses aspectos, investigar como professores e desenvolvedores da área de computação interpretam visualizações de dados em contextos de GLA permite compreender os limites e as possibilidades desses sistemas no apoio à tomada de decisão educacional ou de *game design*.

A visualização de dados é um dos focos deste estudo e elemento recorrente em pesquisas de GLA [Cardoso and Otsuka 2018]. Por exemplo, Alonso-Fernández et al. (2021) discutem a aplicação de GLA por meio da padronização de dados com xAPI-SG e apresentam a ferramenta *T-Mon*, que automatiza a análise e visualização de dados de jogos sérios com *dashboards*. O estudo mostra que padrões como o xAPI-SG favorecem a coleta e a interoperabilidade, mas há desafios relacionados à infraestrutura, à complexidade técnica e à interpretação das métricas. Destaca-se que a visualização é essencial para transformar registros brutos em informações compreensíveis no contexto pedagógico.

Liu et al. (2025) investigam a adoção de um *Learning Analytics Dashboard* para avaliar o *Collaborative Problem Solving* em jogos educacionais no ensino fundamental e médio. O *CPSLens*, integrado ao jogo *D-City Fighter*, fornece visualizações sobre interação, engajamento e desempenho colaborativo. Os resultados indicam que fatores contextuais, como o suporte institucional, influenciam competências docentes (TPACK e autoeficácia), impactando o uso do *dashboard*. Conclui-se que sua efetividade depende da qualidade técnica e do alinhamento com competências e condições organizacionais.

Ruipérez-Valiente et al. (2021) apresentam o desenvolvimento de um *dashboard* para o jogo educacional *Shadowspect*, com abordagem centrada no usuário e *co-design* com professores. Foram definidos e priorizados indicadores organizados em categorias como atividade e inferência de conhecimento, resultando em um *dashboard* em tempo real. As visualizações permitem identificar dificuldades e apoiar intervenções pedagógicas, reduzindo a percepção do jogo como “caixa-preta”.

Os estudos indicam que: i) *dashboards* de GLA apoiam a análise de interação e desempenho quando baseados em modelos estruturados e *design* centrado no usuário; ii) a padronização favorece a interoperabilidade, mas exige alinhamento técnico e pedagógico; e iii) infraestrutura, competências docentes e contexto institucional influenciam a adoção e o uso de *dashboards* de GLA. Embora contribuam para a área, esses trabalhos analisam apenas um perfil de usuário, o professor [Liu et al. 2025, Ruipérez-Valiente et al. 2021], ou se concentram em aspectos técnicos da padronização e automação [Alonso-Fernández et al. 2021], com ênfase no desenvolvimento e na adoção dos *dashboards*.

Este trabalho diferencia-se por: (i) comparar as percepções de professores e desenvolvedores sobre um mesmo *dashboard* de GLA, evidenciando as divergências de demandas analíticas entre os perfis; (ii) focar na interpretação das visualizações, identificando limitações relacionadas à granularidade, ao cruzamento de dados e à clareza semântica das métricas; e (iii) fornecer evidências empíricas sobre o *dashboard* analisado, a partir dos *logs* de um jogo educacional, identificando oportunidades de aprimoramento para contextos pedagógicos e de desenvolvimento do jogo.

3. Métodos

Este trabalho investiga o uso de *dashboard* de GLA como suporte à prática pedagógica e ao *design* de jogos educacionais, analisando como professores e desenvolvedores interpretam as visualizações produzidas a partir dos dados capturados pelo sistema.

Para tanto, conduziu-se um estudo exploratório dividido em quatro etapas, ilustradas na Figura 1: (1) definição do contexto do estudo e do jogo educacional, abrangendo

ensino superior, educação em computação e grafos ponderados; (2) planejamento, seleção dos participantes e definição dos instrumentos; (3) coleta de dados por meio de *logs* e da aplicação de questionários; e (4) análise dos dados, utilizando estatística descritiva e interpretação dos resultados.




Figura 1. Fluxo metodológico do estudo.

3.1. Contexto do Estudo e Jogo Educacional

O estudo foi conduzido no contexto do jogo educacional “Cadê minha Pizza?” [Honda et al. 2022], desenvolvido para apoiar o ensino de conceitos de Teoria dos Grafos. O jogo propõe desafios baseados na construção e análise de rotas em grafos ponderados, nos quais o jogador assume o papel de um entregador de pizza e deve selecionar as rotas mais eficientes para realizar entregas, utilizando o conceito de caminhos mínimos para otimizar o percurso e minimizar o custo da gasolina. Ao longo das 4 fases do jogo, os estudantes são estimulados a identificar e analisar conexões entre diferentes pontos da cidade representada no grafo, promovendo o entendimento de conceitos de Teoria dos Grafos, como vértices, arestas e pesos.

O GLBoard é um sistema de captura responsável pela coleta dos dados durante a interação do jogador com o jogo, registrando informações como tempo de execução, escolhas, tentativas, erros e resolução de desafios em formato JSON. Esses dados são então armazenados e processados, sendo organizados pelo sistema de captura de dados em visualizações analíticas. O *dashboard* resultante, ilustrado na Figura 2, apresenta os seguintes gráficos: (i) jogadores por gênero, exibido em gráfico de pizza com predominância da categoria “Masculino” (28), seguida de “Feminino” (7), “Outros” (6) e uma ocorrência não categorizada (1); (ii) quantidade de jogadores, totalizando 42; (iii) minutos jogados, somando 69 minutos; (iv) conclusões por fase, com 33, 33, 27 e 24 conclusões nas fases 1 a 4, respectivamente; (v) média de *performance* por fase, com valor constante de 0,07 em todas as fases; (vi) tentativas por fase, registrando 61, 74, 39 e 57 tentativas; (vii) minutos por fase, com 19, 4, 19 e 27 minutos; (viii) sessões por dia, com pico de 163 sessões em uma única data; e (ix) *status* por fase, evidenciando que a vitória foi o desfecho predominante em todas as fases. Esses gráficos servem como instrumentos de apoio à análise da aprendizagem no contexto do jogo.

Os dados utilizados para compor este *dashboard* foram coletados por meio de *logs* gerados durante a interação dos estudantes com o jogo educacional “Cadê minha




Figura 2. Dashboard de GLA com dados do jogo educacional analisado.

Pizza?”. A coleta envolveu 42 usuários; no entanto, apenas 11 geraram *logs* de jogabilidade ao avançarem pelas fases do jogo. Esses dados incluem informações como o tempo de início e fim das sessões, as ações realizadas em cada fase e o desfecho das tentativas. As informações foram armazenadas de forma anonimizada, com o devido consentimento dos participantes, assegurando seu uso exclusivo para fins acadêmicos.

3.2. Planejamento

O estudo adota um delineamento exploratório com o objetivo de compreender como professores e desenvolvedores interpretam as visualizações do *dashboard* do sistema de captura de dados, bem como identificar limitações e possibilidades de melhoria na apresentação dessas informações, considerando as demandas dos contextos pedagógicos e de desenvolvimento de jogos educacionais. O delineamento do estudo foi estruturado de modo a avaliar a percepção de professores e desenvolvedores quanto ao potencial analítico e pedagógico das visualizações apresentadas.

Os questionários utilizados nesta pesquisa foram desenvolvidos a partir de rodas de discussão entre os autores do estudo, tendo como referência os objetivos de cada perfil de usuário da plataforma GLBoard. A construção dos instrumentos considerou que desenvolvedores e professores possuem perspectivas e necessidades distintas em relação aos dados do *dashboard*: enquanto os desenvolvedores buscam subsídios técnicos para o aprimoramento do *game design*, os professores utilizam os dados para acompanhar o desempenho dos estudantes e apoiar intervenções pedagógicas. Essa distinção orientou a elaboração de dois instrumentos separados, com questões adaptadas a cada perfil.

O questionário dos desenvolvedores focou em aspectos do *design* do jogo, como progressão dos jogadores e curva de dificuldade, enquanto o dos professores explorou a utilidade dos dados para avaliação e intervenção pedagógica. Ambos os instrumentos compartilharam um núcleo comum de questões sobre os mesmos gráficos do *dashboard*, permitindo a comparação entre os perfis. Antes da aplicação, os instrumentos foram revisados por pesquisadores familiarizados com o GLBoard para verificar a clareza e a

adequação das perguntas¹.

3.3. Coleta de Dados

Foram elaborados dois questionários, um para desenvolvedores e outro para professores, ambos com aproximadamente 45 perguntas. Cada questionário incluiu questões sobre o perfil do respondente, além de questões objetivas relacionadas ao uso do *dashboard* e perguntas dissertativas para entender a percepção dos participantes sobre a utilidade dos dados. O questionário dos desenvolvedores focou em aspectos de *game design*, considerando a interpretação de métricas relacionadas à progressão, dificuldade, comportamento dos jogadores e possíveis ajustes na estrutura do jogo. Já o questionário dos professores explorou como os dados poderiam ser utilizados em processos avaliativos, considerando a identificação de evidências de aprendizagem, desempenho e dificuldades dos estudantes. Os professores e os desenvolvedores responderam aos respectivos questionários, avaliando o *dashboard* ilustrado na Figura 2.

Foram convidados professores da área de computação e desenvolvedores com experiência ou familiaridade com jogos educacionais, considerando suas possíveis contribuições para a análise nos contextos pedagógico e técnico, respectivamente. A escolha de professores de computação justifica-se pelo conteúdo abordado no jogo, relacionado à Teoria dos Grafos, o que demanda familiaridade com conceitos como rotas, conexões e grafos ponderados. Embora o jogo seja voltado para estudantes do ensino médio, reconhece-se que a participação de professores que atuam diretamente nesse nível, como docentes de Matemática, poderia ampliar a análise sobre a aplicabilidade pedagógica do *dashboard*. A participação docente reduzida pode ser justificada por fatores como disponibilidade limitada, carga de trabalho acadêmica, tempo necessário para responder ao instrumento e possível baixa familiaridade com *dashboards* educacionais e GLA. O questionário dos desenvolvedores incluía uma seção introdutória com a representação do jogo em grafo e a explicação dos conceitos de caminhos mínimos, contextualização necessária, dado o menor contato desse perfil com o conteúdo pedagógico do jogo.

3.4. Análise dos Dados

A análise dos dados seguiu uma abordagem mista, organizada em duas etapas complementares: etapa quantitativa, de caráter descritivo, voltada à identificação de padrões de resposta, e etapa qualitativa, baseada em análise temática, voltada à interpretação dos padrões, descritas a seguir.

3.4.1. Análise Quantitativa dos Dados

A etapa quantitativa considerou as questões fechadas dos questionários aplicados a professores e desenvolvedores, respondidas em escala Likert de cinco pontos, variando de “discordo totalmente” (1) a “concordo totalmente” (5). Para cada questão, foram considerados dois indicadores: a mediana (Md) e o percentual de concordância. A mediana foi utilizada como medida de tendência central por ser mais robusta e adequada à análise de dados ordinais, uma vez que não pressupõe distribuição normal. O percentual de concordância correspondeu à proporção de respostas 4 e 5 em relação ao total de respostas válidas.

¹Os questionários, respostas e análises estão disponíveis em: <https://bit.ly/3PB6Bny>

A classificação da tendência foi definida pela combinação entre o percentual de concordância e a mediana (Md), conforme os seguintes critérios: (i) muito alta, quando a concordância foi $\geq 80\%$ e $Md = 5$; (ii) alta, quando a concordância foi $\geq 60\%$ e $Md \geq 4$, exceto nos casos classificados como muito alta; (iii) moderada, quando a concordância ficou entre 40% e 59%, ou quando $Md = 4$ com concordância inferior a 60%; e (iv) baixa, quando a concordância foi inferior a 40% e $Md \leq 3$. Dessa forma, casos com baixa concordância, mas mediana igual a 4, foram classificados como moderados, por indicarem tendência central positiva, ainda que com dispersão nas respostas.

3.4.2. Análise Qualitativa dos Dados

A etapa qualitativa buscou compreender os padrões identificados na análise quantitativa a partir das percepções, justificativas e sugestões dos participantes, para cada gráfico do *dashboard*. Para isso, adotou-se a análise temática indutiva [Braun and Clarke 2006] como método de codificação e organização das respostas dissertativas dos dois questionários, considerando as perspectivas dos professores e dos desenvolvedores.

O processo analítico seguiu as fases propostas por [Braun and Clarke 2006]. Inicialmente, foram realizadas leituras das respostas para familiarização com os dados. Em seguida, os trechos relacionados às dificuldades de interpretação dos gráficos e às sugestões de melhoria foram destacados e comparados entre si. As respostas que apresentavam ideias semelhantes foram agrupadas em categorias temáticas, posteriormente organizadas em eixos relacionados à interpretação do *dashboard*.

Esse procedimento resultou em nove categorias, organizadas em quatro eixos temáticos, apresentados na Seção 4.2. As categorias emergiram dos dados, sem um quadro de classificação predefinido, e foram refinadas por meio de discussões entre os pesquisadores. A análise dos dois perfis permitiu identificar convergências e divergências entre a perspectiva pedagógica e a de *game design*.

4. Resultados e Discussão

A apresentação dos resultados acompanha a estrutura da análise descrita nas Seções 3.4.1 e 3.4.2: primeiro são reportados os resultados quantitativos, que sintetizam os padrões de resposta de cada perfil às questões fechadas, separadamente para professores e desenvolvedores; em seguida, os resultados qualitativos, obtidos pela análise temática indutiva das respostas dissertativas dos dois questionários. Todos os resultados foram obtidos a partir do *dashboard* do GLBoard, com base no jogo “Cadê minha Pizza?”².

4.1. Resultados Quantitativos

A etapa quantitativa avaliou a clareza e a utilidade dos gráficos do *dashboard* por meio de questões objetivas em escala Likert (1 a 5), conforme os critérios de classificação descritos na Seção 3.4.1. A interpretação baseia-se na mediana (Md) e na frequência de concordância (respostas 4 e 5), apresentadas separadamente para cada perfil.

Professores: participaram da pesquisa três professores (P1, P2 e P3), com experiência docente em cursos de computação situada nas faixas de 6 a 10 anos e de mais

²Os questionários, respostas e análises estão disponíveis em: <https://bit.ly/3PB6Bny>

de 10 anos. Em relação à familiaridade com a Teoria dos Grafos, um participante declarou baixa familiaridade e dois, alta familiaridade. Quanto ao uso de jogos educacionais, dois professores já os haviam utilizado, de forma pouco frequente, e um não possuía experiência prévia. Sobre ferramentas de *Learning Analytics* e *dashboards* educacionais, um participante declarou familiaridade, enquanto os outros dois relataram não possuir contato prévio com esse tipo de ferramenta. Essas características ajudam a contextualizar as percepções relatadas a seguir.

As questões dos questionários foram agrupadas em seis dimensões, conforme o tipo de gráfico avaliado na Figura 2: taxa de conclusão (Q3-Q5), métrica de *performance* (Q7-Q8), volume de tentativas (Q10-Q12), tempo por fase (Q14-Q15), sessões e temporalidade (Q17-Q19) e *status* (Q21-Q23). A Tabela 1 sintetiza a mediana, a concordância percentual e a tendência geral das respostas, conforme os critérios definidos na Seção 3.4.1.

Tabela 1. Avaliação do Dashboard: Perspectiva dos Professores ($n = 3$)

Dimensão do Gráfico	Mediana (<i>Md</i>)	Concordância (%)	Tendência
Taxa de Conclusão (Q3-Q5)	5,0	66,7%	Alta
Métrica de <i>Performance</i> (Q7-Q8)	2,5	25,0%	Baixa
Volume de Tentativas (Q10-Q12)	4,0	33,3%	Moderada
Tempo por Fase (Q14-Q15)	3,0	16,7%	Baixa
Sessões e Temporalidade (Q17-Q19)	5,0	88,9%	Muito Alta
<i>Status</i> (Q21-Q23)	4,0	55,6%	Moderada

Conforme a Tabela 1, as maiores concordâncias ocorreram nas dimensões Taxa de Conclusão ($Md = 5,0$) e Sessões e Temporalidade ($Md = 5,0$) classificadas com tendência alta e muito alta, respectivamente. Em contrapartida, Métrica de *Performance* ($Md = 2,5$) e Tempo por Fase (16,7% de concordância) apresentaram os menores índices, ambos classificados como baixos, sugerindo que esses gráficos oferecem pouco suporte à interpretação pedagógica dos dados. As respostas dissertativas justificam esses índices pela falta de clareza nas métricas e pela ausência de dados individualizados, o que impede distinguir se o tempo gasto reflete engajamento ou dificuldade.

As respostas dissertativas detalham a leitura de cada gráfico e revelam interpretações distintas entre os participantes. Na Taxa de Conclusão, P1 afirmou que “tiveram sucesso nas duas primeiras fases”, enquanto P2 destacou que as análises são “estritamente descritivas” e P3 declarou que “não consigo chegar à conclusão nenhuma”, pela ausência de dados individualizados. Em relação à Métrica de *Performance*, P2 considerou que o gráfico “não tem muita utilidade” e P3 que “não dá para tirar conclusões úteis/confiáveis”. Já no Tempo por Fase, P1 observou que “jogaram mais na última fase”, mas P2 e P3 questionaram a agregação dos dados e possíveis inconsistências entre métricas.

Desenvolvedores: participaram da pesquisa cinco desenvolvedores (D1–D5). Quanto ao tempo de experiência em *design* e desenvolvimento de jogos educacionais, registrado em faixas no questionário, quatro participantes selecionaram a faixa de 1 a 3 anos e um, a de 4 a 7 anos. Em relação à familiaridade com a Teoria dos Grafos, três relataram baixo nível de familiaridade, dois indicaram nível moderado e nenhum declarou nível alto. A baixa familiaridade com esses conceitos pode ter influenciado a forma como os desenvolvedores interpretaram os dados do jogo, levando-os a avaliar os gráficos sob

uma perspectiva mais técnica e estrutural, voltada à progressão e à dificuldade das fases.

Para os desenvolvedores, as questões foram agrupadas nas mesmas seis dimensões: taxa de conclusão (Q1-Q3), métrica de *performance* (Q5-Q6), volume de tentativas (Q8-Q10), tempo por fase (Q12-Q13), sessões e temporalidade (Q15-Q17) e *status* (Q19-Q21). A Tabela 2 sintetiza esses resultados.

Tabela 2. Avaliação do Dashboard: Perspectiva dos Desenvolvedores ($n = 5$)

Dimensão do Gráfico	Mediana (Md)	Concordância (%)	Tendência
Taxa de Conclusão (Q1-Q3)	5,0	80,0%	Muito Alta
Métrica de <i>Performance</i> (Q5-Q6)	4,0	60,0%	Moderada
Volume de Tentativas (Q8-Q10)	5,0	80,0%	Muito Alta
Tempo por Fase (Q12-Q13)	5,0	80,0%	Muito Alta
Sessões e Temporalidade (Q15-Q17)	5,0	60,0%	Moderada
<i>Status</i> (Q19-Q21)	5,0	80,0%	Muito Alta

A Tabela 2 apresenta uma avaliação predominantemente positiva: a mediana foi 5,0 ($Md = 5,0$) em quase todas as dimensões e a concordância atingiu 80% na maioria delas, com quatro dimensões classificadas como de tendência muito alta. As exceções foram Métrica de *Performance* e Sessões e Temporalidade, que registraram a menor concordância (60%), sendo ambas classificadas como moderadas. Essa diferença é esclarecida pelas respostas dissertativas: no gráfico de sessões, a menor concordância associa-se à ordenação não linear das datas no eixo horizontal; no de *performance*, à dúvida dos desenvolvedores quanto às variáveis que compõem a métrica, cuja constância não acompanhava a variação observada na taxa de conclusão.

As respostas dissertativas detalham a leitura de cada gráfico e revelam como os desenvolvedores empregaram os dados para inferir aspectos do *design* do jogo, especialmente relacionados à progressão dos jogadores, à dificuldade das fases e à mecânica do jogo. Na Taxa de Conclusão, D1 afirmou que “Nas duas últimas fases houve uma queda de jogadores” e D2 que “Houve desempenho igual nas fases 1 e 2, que decresceu ao chegar na fase 3 e mais ainda na fase 4”, associando os dados a uma possível curva de dificuldade; D3 interpretou que “Eles desistiram do jogo na metade” e D4 relacionou a desistência à complexidade das fases finais. No Tempo por Fase, D1 observou que “Foi na fase 4 que os jogadores passaram mais tempo para jogar”, enquanto D2 problematizou que o gráfico “engloba todos os estudantes”, podendo gerar viés, e D5 questionou: “Como poderia a fase com maior quantidade de tentativas ter somente 4 minutos?”, indicando a necessidade de maior contextualização dos dados.

De forma geral, os resultados quantitativos evidenciam diferenças na percepção conforme o tipo de visualização analisada, tanto em concordância quanto em dispersão das respostas. A etapa qualitativa, apresentada a seguir, aprofunda essas percepções.

4.2. Resultados Qualitativos: Análise Temática

Enquanto a etapa quantitativa analisou os dois perfis de forma separada, esta seção apresenta a análise temática indutiva, que integra as respostas dissertativas dos questionários de professores e de desenvolvedores em um único corpus de análise (Seção 3.4.2). Essa integração constitui a principal contribuição analítica do estudo, pois permite confrontar diretamente as percepções dos dois perfis sobre um mesmo *dashboard* e evidenciar suas convergências e divergências quanto à clareza, utilidade e limitações das visualizações.

Conforme descrito na metodologia, a codificação das respostas resultou em nove categorias, organizadas em quatro eixos: **I. Clareza Visual** (C1: Compreensão; C5: Rótulos/Legendas; C6: *Design*); **II. Métricas e Granularidade** (C2: Limitações; C3: Dados ausentes; C7: Decisão Pedagógica/*Game Design*); **III. Estrutura e Volume** (C4: Interface/Usabilidade; C8: Volume de dados); e **IV. Comportamento** (C9: Ciência da coleta).

No eixo *clareza e comunicabilidade visual* (C1, C5, C6), participantes dos dois perfis relataram dificuldades semelhantes. Desenvolvedores afirmaram que os dados “não são claros o suficiente” (D4) e “estão confusos” (D3), relatando dificuldade em interpretar o gráfico de *performance* (D2). De forma semelhante, professores indicaram que os gráficos “não são totalmente autoexplicativos” (P2) e que “falta clareza de rótulos e métricas” (P3). Embora P1 tenha elogiado o *design* visual, o conjunto das respostas sugere uma fragilidade na comunicabilidade semântica do *dashboard*.

No eixo *limitações métricas e ausência de granularidade* (C2, C3, C7), as respostas dos dois perfis convergiram. Desenvolvedores criticaram a superficialidade, afirmando que “não é possível combinar métricas” (D2) e que os dados “não se cruzam” (D3). Professores demandaram indicadores individuais, como “taxa de acerto por tentativa” (P3) e “comparação entre estudantes” (P2). Enquanto os desenvolvedores focam na identificação de problemas estruturais do jogo e em ajustes de *game design*, os professores concentram-se na interpretação de evidências de aprendizagem e em possibilidades de intervenção pedagógica. Ainda assim, ambos convergem na insuficiência de dados individualizados e comparativos.

No eixo *organização estrutural e volume de informações* (C4, C8), as percepções foram complementares. Desenvolvedores sugeriram “melhorar a organização da interface” (D3) e incluir “textos explicativos” (D1). Já os professores defenderam reduzir gráficos pouco informativos, mantendo a quantidade “a menor possível, mas suficiente” (P2). Embora D1 e P1 vejam o volume como facilitador, D4 alertou que o excesso pode “dificultar pela quantidade de informação”, reforçando que o problema reside na hierarquização dos dados.

Por fim, no eixo *impacto comportamental* (C9), participantes dos dois perfis consideraram que a coleta de dados pode alterar a postura do estudante na direção de “maior dedicação” (D3, P3). Contudo, P2 trouxe uma ressalva pedagógica relevante: o monitoramento pode levar os estudantes a “evitarem riscos e testes”, inibindo a exploração.

Em suma, os perfis convergem na necessidade de maior clareza interpretativa, métricas granulares e reorganização estrutural do sistema de captura de dados. As divergências, por sua vez, indicam objetivos distintos no uso das métricas: enquanto os desenvolvedores avaliam os dados para identificar problemas de progressão, dificuldade e balanceamento, os professores buscam evidências de aprendizagem que apoiem intervenções pedagógicas. A discrepância observada na Fase 2, em que o volume de tentativas não corresponde ao tempo de permanência, evidencia limitações na granularidade e no cruzamento de dados, o que pode induzir a interpretações imprecisas sobre o comportamento dos usuários.

Esses achados corroboram a literatura da área, que aponta que a eficácia de *dashboards* de GLA não depende apenas da visualização, mas da transparência dos al-

goritmos e do alinhamento entre as métricas e os objetivos de cada perfil de usuário [Ruipérez-Valiente et al. 2021]. A demanda por dados individualizados e por maior clareza nos rótulos indica que o sistema de captura de dados necessita de uma organização que reduza o esforço interpretativo, permitindo que o usuário identifique prontamente padrões de aprendizagem ou falhas na estrutura do jogo.

5. Considerações Finais

Este estudo investigou o uso de um *dashboard* de GLA como ferramenta para apoiar a prática pedagógica e o *design* de jogos educacionais, considerando a perspectiva de professores e desenvolvedores. O objetivo foi analisar como esses dois perfis (professores e desenvolvedores) interpretam as visualizações do sistema de captura de dados, identificando fatores que favorecem ou dificultam a compreensão e o uso das informações apresentadas para a tomada de decisões pedagógicas e de *game design*. No contexto pedagógico, a análise considerou a identificação de evidências de aprendizagem e dificuldades dos estudantes. No contexto de desenvolvimento, considerou a interpretação das métricas para orientar ajustes na progressão, na dificuldade e na mecânica do jogo.

Os resultados revelaram que, embora o *dashboard* comunique com clareza o volume bruto de atividade, como os gráficos de conclusões por fase e sessões por dia, ainda há lacunas na clareza interpretativa de métricas mais complexas, como a de *performance*. Observou-se que a ferramenta é percebida de forma distinta entre os perfis. Desenvolvedores priorizam métricas que permitam compreender a progressão, a dificuldade e a mecânica do jogo, enquanto professores demandam informações com significado pedagógico, que permitam acompanhar dificuldades individuais e apoiar intervenções na aprendizagem. A análise temática confirmou que a falta de granularidade e a ausência de cruzamentos entre métricas são os principais obstáculos para uma compreensão mais aprofundada do comportamento do estudante no uso do jogo.

Entre as limitações da pesquisa, destacam-se o tamanho reduzido da amostra de participantes, a análise de um único *dashboard* de GLA e a natureza agregada de algumas visualizações, que podem restringir a generalização dos achados e gerar interpretações ambíguas, como a discrepância de dados observada na Fase 2 do jogo. Adicionalmente, reconhece-se que a extensão e a estrutura do formulário de avaliação podem ter limitado a profundidade de algumas respostas, dada a carga cognitiva necessária para avaliar múltiplos gráficos. Além disso, falhas na usabilidade da interface, especificamente na ordenação cronológica das dimensões, podem ter impactado a percepção de utilidade de alguns gráficos.

Para trabalhos futuros, os resultados deste estudo serão utilizados para orientar a refatoração do *dashboard* do sistema de captura de dados, com foco nas limitações identificadas pelos participantes, especialmente quanto à personalização da interface por perfil de usuário, à clareza das métricas e ao acesso a dados granulares e comparativos para apoiar tanto decisões pedagógicas quanto decisões de *game design*. Além disso, pretende-se: (i) conduzir testes de campo para validar o impacto do *dashboard* dentro e fora de sala de aula; e (ii) ampliar a análise para outros *dashboards* de GLA, considerando componentes baseados em conceitos de Visualização da Informação e Interação Humano-Dados.

Agradecimentos

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (AUXPE-CAPES-PROEX) - Código de Financiamento 001. Adicionalmente, este trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado do Amazonas - FAPEAM - por meio dos projetos PDPG-CAPES e POSGRAD 2025-2026 e POSGRAD 2026-2027. Por fim, agradecemos à UEA, por meio do Programa de Produtividade Acadêmica 01.02.011304.026472/2023-87, e ao laboratório 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* e *Grammarly*, 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

- Alhadad, S. (2016). Attentional and cognitive processing of analytics visualisations: Can design features affect interpretations and decisions about learning and teaching? In *ASCILITE 2016*. Australasian Society for Computers in Learning in Tertiary Education (ASCILITE).
- 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.
- Bouroumane, F., Hamdaoui, I., and Abarkan, M. (2024). Evaluation of serious games intended to be used in education: Systematic review. In *2024 7th International Conference on Advanced Communication Technologies and Networking (CommNet)*, pages 1–6.
- Braun, V. and Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*, 3:77–101.
- Card, S. K., Mackinlay, J., and Shneiderman, B. (1999). *Readings in information visualization: using vision to think*. Morgan Kaufmann.
- Cardoso, F. and Otsuka, J. (2018). Visualização da informação na análise de dados coletados a partir de jogos: um mapeamento sistemático. *SBGAMES. Simpósio Brasileiro de Jogos e Entretenimento Digital*.
- El-Nasr, M. S., Drachen, A., and Canossa, A. (2016). *Game analytics*. Springer.
- Few, S. (2006). *Information dashboard design: The effective visual communication of data*. O'Reilly Media, Inc.

- Freire, M., Serrano-Laguna, Á., Manero, B., Martínez-Ortiz, I., Moreno-Ger, P., and Fernández-Manjón, B. (2016a). Game learning analytics: Learning analytics for serious games. In *Learning, Design, and Technology*, pages 1–29. Springer Nature Switzerland AG.
- Freire, M., Serrano-Laguna, Á., Manero Iglesias, B., Martínez-Ortiz, I., Moreno-Ger, P., and Fernández-Manjón, B. (2016b). Game learning analytics: Learning analytics for serious games. In *Learning, design, and technology: An international compendium of theory, research, practice, and policy*, pages 3475–3502. Springer.
- Genesio, N. O. S., de Oliveira, A. M., Oliveira, E. W., and Valle, P. H. D. (2024). Panorama de estudos sobre jogos educacionais digitais em educação em computação. In *Workshop sobre Educação em Computação (WEI)*, pages 737–749. SBC.
- Hair, J. F. (2011). Multivariate data analysis: An overview. *International encyclopedia of statistical science*, pages 904–907.
- 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.
- Larsson, J. A. and White, B. (2014). Learning analytics. *From Research to Practice*, New York.
- Liu, Y., Hu, X., Ng, J. T. D., Ma, Z., and Lai, X. (2025). Ready or not? investigating in-service teachers’ integration of learning analytics dashboard for assessing students’ collaborative problem solving in K–12 classrooms. *Education and Information Technologies*, 30(2):1745–1776.
- Liu, Y., Pozdniakov, S., and Martinez-Maldonado, R. (2024). The effects of visualisation literacy and data storytelling dashboards on teachers’ cognitive load. *Australasian Journal of Educational Technology*, 40(1):78–93.
- 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.
- Macfadyen, L. P. and Dawson, S. (2012). Numbers are not enough. why e-learning analytics failed to inform an institutional strategic plan. *Journal of Educational Technology & Society*, 15(3):149–163.
- Meloncon, L. and Warner, E. (2017). Data visualizations: A literature review and opportunities for technical and professional communication. In *2017 IEEE International Professional Communication Conference (ProComm)*, pages 1–9. IEEE.
- Mohapatra, S. K., Sarangi, P. K., Sahu, P., Sharma, S. K., and Sharma, O. (2023). Game data visualization using artificial intelligence techniques. In *Proceedings of International Conference on Recent Trends in Computing: ICRTC 2022*, pages 351–360. Springer.
- Oliveira, G. P. (2025). *Recomendação automática de atividades e rastreamento de competências do sujeito complexo em ambientes virtuais de ensino e aprendizagem*. PhD thesis, Universidade Federal de Uberlândia.

- Pires, F. G. d. S., Melo, R., Machado, J., Silva, M. S., Franzoia, F., and de Freitas, R. (2018). Ecologic: um jogo de estratégia para o desenvolvimento do pensamento computacional e da consciência ambiental. In *Anais dos Workshops do Congresso Brasileiro de Informática na Educação*, volume 7, page 629.
- Plass, J. L., Homer, B. D., and Kinzer, C. K. (2015). Foundations of game-based learning. *Educational psychologist*, 50(4):258–283.
- Ruipérez-Valiente, J. A., Gomez, M. J., Martínez, P. A., and Kim, Y. J. (2021). Ideating and developing a visualization dashboard to support teachers using educational games in the classroom. *IEEE access*, 9:83467–83481.
- Seif El-Nasr, M. and Kleinman, E. (2020). Data-driven game development: Ethical considerations. In *Proceedings of the 15th international conference on the foundations of digital games*, pages 1–10.
- 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.
- Susnjak, T., Ramaswami, G. S., and Mathrani, A. (2022). Learning analytics dashboard: a tool for providing actionable insights to learners. *International Journal of Educational Technology in Higher Education*, 19(1):12.
- Unwin, A. (2020). Why is data visualization important? what is important in data visualization. *Harvard Data Science Review*, 2(1):1.
- Wall, E., Blaha, L. M., Paul, C. L., Cook, K., and Endert, A. (2018). Four perspectives on human bias in visual analytics. In *Cognitive biases in visualizations*, pages 29–42. Springer.