

O uso de *Game Learning Analytics* em Jogos Digitais Educacionais: Um Mapeamento Sistemático da Literatura

Matheus Soppa Geremias¹, Taynara Cerigueli Dutra²,
Eleandro Maschio³, Isabela Gasparini^{4,1}

¹Programa de Pós-Graduação em Informática (PPGInf)
Universidade Federal do Paraná (UFPR) – Curitiba – PR – Brasil

²Departamento de Informática
Instituto Federal de Santa Catarina (IFSC) – Xanxerê – SC – Brasil

³Coordenação do Curso de Tecnologia em Sistemas para Internet
Universidade Tecnológica Federal do Paraná (UTFPR) – Guarapuava – PR – Brasil

⁴Departamento de Ciência da Computação
Universidade do Estado de Santa Catarina (UDESC) – Joinville – SC – Brasil

suppersoppa@gmail.com, taynara.dutra@ifsc.edu.br

eleandrom@utfpr.edu.br, isabela.gasparini@udesc.br

Abstract. *This paper presents a Systematic Literature Mapping we conducted to identify the applications of Game Learning Analytics in educational digital games. We analyzed 76 papers. We concluded that most papers use the tracker developed by e-UCM research group's project and that certain data such as user identification and its actions are the most extracted. Besides, we established that there aren't many created metrics, because most of the papers utilized raw information in their analysis. At last, the algorithms found can be classified based on their application in the following groups: regression, machine learning, clustering, modeling, and others.*

Resumo. *Este trabalho apresenta a realização de Mapeamento Sistemático da Literatura para identificar as aplicações de Game Learning Analytics em jogos digitais educacionais. Foram analisados 76 artigos. Constatou-se que a maioria dos artigos utiliza do tracker desenvolvido pelo grupo de pesquisa e-UCM, e que dados como o identificador do usuário e suas ações são os mais extraídos. Além disso, verificou-se que existem poucas métricas criadas, pois a maioria dos artigos utilizou de informações brutas em suas análises. Por fim, os algoritmos encontrados podem ser divididos de acordo com sua aplicação, nos seguintes grupos: regressão, machine learning, clusterização, modelagem e outros.*

1. Introdução

Um jogo é “uma atividade de resolução de problemas abordada com uma atitude divertida” [Schell 2008, tradução nossa]. Enquanto jogos puramente comerciais possuem o foco no entretenimento, Jogos Sérios (JS) têm propósitos educativos e de treinamento e podem ser definidos como “uma competição mental, jogada com um computador de

acordo com regras específicas que usam o entretenimento para treinamento governamental ou corporativo, educação, saúde, políticas sociais e objetivos de comunicação estratégica” [Zyda 2005, tradução nossa].

Apesar de seu uso na educação não ser algo recente [Michael and Chen 2006], nos últimos anos houve uma crescente atenção da comunidade educacional para esse segmento, principalmente com o uso de Jogos Digitais Educacionais (JDE) [Freire et al. 2016]. Assim, novas pesquisas evidenciaram diversos benefícios relacionados a sua aplicação, como o desenvolvimento de habilidades cognitivas e um impacto positivo na criatividade e em diversas outras habilidades de pensamento de ordem superior [Savi and Ulbricht 2008, Gee 2003, Anastasiadis et al. 2018].

Contudo, o uso de JDE dentro das salas de aula ainda é limitado [De Grove et al. 2012], motivado pela falta de tecnologias dentro das escolas, mas também pela lacuna em pesquisas fundamentadas quanto ao aprendizado dos estudantes na utilização de tais recursos [Freire et al. 2016, Cascini and Campos 2015]. Um aspecto que pode auxiliar na alteração dessa situação é a inclusão de técnicas de *Learning Analytics* (LA), que podem ser utilizadas para obter dados da interação com o propósito de melhor entender ou aprimorar o processo de aprendizado [Alonso-Fernandez et al. 2017a]. Expandindo esse conceito, *Game Learning Analytics* (GLA) envolve a coleta, análise e visualização das informações provenientes das interações entre jogadores e jogos sérios [Freire et al. 2016, Alonso-Fernández et al. 2019a].

A aplicação de GLA visa “desenvolver um entendimento profundo sobre como os jogos digitais realmente afetam o processo de aprendizado, quais habilidades e técnicas os jogos podem fornecer e de qual maneira eles podem ser combinados com as preferências dos estudantes” [Freire et al. 2016, tradução nossa]. Ainda, alguns de seus usos incluem a obtenção de informações sobre o aprendizado dos jogadores, determinação das diferenças individuais entre jogadores e avaliação do aprendizado [Alonso-Fernández et al. 2022]. Mas, apesar de suas finalidades, existem poucos padrões quanto ao uso de suas técnicas, o que consiste em uma lacuna a ser pesquisada [Su et al. 2021, Alonso-Fernandez et al. 2017b].

Com base nisso, o presente trabalho trata de um Mapeamento Sistemático da Literatura (MSL) realizado para identificar como GLA tem sido aplicado em JDE. Dessa forma, o artigo está estruturado da seguinte maneira: a Seção 2 aborda alguns trabalhos relacionados que já foram realizados. A Seção 3 descreve a metodologia do mapeamento sistemático, incluindo detalhes como as questões de pesquisa, a frase e os mecanismos de busca, a seleção dos artigos e a extração das informações. A Seção 4 explora os resultados e responde às questões de pesquisa definidas. Por fim, a Seção 5 traz as considerações finais deste projeto.

2. Trabalhos Relacionados

Su et al. (2021), motivados por evidências quanto à falta de classificação na área de *Game Analytics* (GA), principalmente acerca do uso de *Business Intelligence*, apresentam um MSL para identificar como GA tem sido aplicado na indústria de jogos nos últimos anos. Alguns exemplos encontrados incluem a identificação de *bugs*, a visualização da movimentação dos jogadores e a diminuição de custos no desenvolvimento. Como resultado do mapeamento, GA foi categorizado, de acordo com seu foco, em: jogadores,

desenvolvimento, publicação, distribuição, predição e visualização de dados.

Já Alonso-Fernández et al. (2019a) realizaram um MSL para verificar as aplicações de técnicas de ciência de dados na análise de dados provenientes de JDE. Com base nos artigos obtidos, as técnicas mais utilizadas foram a de visualização, bem como algoritmos supervisionados e não supervisionados. Ademais, também foi concluído que o uso dessas informações pode ser adotado na avaliação de desempenho dos estudantes.

Ainda, Tlili and Chang (2019) focaram no uso de *sequential data analytics* (SDA) em pesquisas com jogos sérios. Tal conceito permite identificar associações entre as sequências de ações realizadas nos jogos e os resultados de aprendizado. O MSL verificou que os três maiores objetivos de SDA foram capturar o contexto do aprendizado, coletar dados para predições futuras e disponibilizar de experiências personalizadas de aprendizagem. Além disso, também foram explorados os passos para a implementação do SDA, bem como as análises mais realizadas (e.g., análise sequencial progressiva, que verifica as mudanças de comportamento dos estudantes ao longo do jogo).

Esses trabalhos sugerem a importância da análise de dados provenientes da interação com os jogos, principalmente no ambiente escolar, onde as avaliações permitem que professores e instituições façam decisões baseadas em evidências [Alonso-Fernández et al. 2019a]. Entretanto, o primeiro trabalho não apresenta métodos voltados aos JDE, pois foca no campo comercial dos jogos, o segundo aprofunda-se apenas em aplicações que envolvem ciência de dados (o que exclui outras formas de análises) e o terceiro também possui um escopo limitado de pesquisa. À vista disso, para averiguar como GLA tem sido aplicado em JDE de uma forma mais abrangente, foi realizado um MSL com o intuito de identificar dados quantitativos a respeito de suas aplicações. Com o aprofundamento do trabalho, pretende-se compreender quais dados estão sendo analisados, bem como quais os usos dessas informações.

3. Metodologia

O MSL desenvolvido seguiu o processo descrito por [Kitchenham and Charters 2007], com os seguintes passos: definição das questões de pesquisa, condução da pesquisa, seleção dos artigos, extração de dados e síntese de dados. Os artigos primários foram analisados com o propósito de identificar e categorizar aplicações de análise de dados relacionadas ao processo de ensino-aprendizagem dos estudantes, com base nas informações provenientes da interação entre estudantes e JDE.

3.1. Questões de pesquisa

O MSL centrou-se na seguinte questão primária de pesquisa (QP): “Como o processo de *Game Learning Analytics* têm sido aplicado em Jogos Digitais Educacionais?”. Concomitantemente, as subquestões (SQ) que deverão ser respondidas são:

- SQ1: Quais os elementos utilizados para obter os dados dentro do jogo?
- SQ2: Quais são os tipos de dados que podem ser obtidos?
- SQ3: Quais outras fontes de dados são consideradas?
- SQ4: Quais as métricas manipuladas?
- SQ5: Quais métricas possuem relação com o aprendizado do jogador?
- SQ6: Como as informações obtidas têm sido usadas?

- SQ7: Como os resultados das análises realizadas são apresentados?
- SQ8: Quais são os *stakeholders* para quem os resultados são voltados?
- SQ9: Quais ferramentas são empregadas?
- SQ10: Quais algoritmos são aplicados?

3.2. Mecanismos e frase de busca

Os mecanismos de busca acadêmica (MBA) foram escolhidos com base em [Buchinger et al. 2014] e na proximidade com a área de informática na educação. Assim, optou-se pelas seguintes plataformas: ACM Digital Library, ERIC, IEEEExplore, Scopus.

Já quanto à frase de busca, um dos processos mais utilizados para defini-la é o PICO(C), que identifica a população (P), a intervenção (I), a comparação (C), o resultado esperado (O) e o contexto (C) [Kitchenham and Charters 2007]. Com base nesse método e para que os resultados se enquadrassem com a temática do trabalho, a frase de busca passou por vários refinamentos até chegar em sua versão final, como a consideração da quantidade de artigos retornados e a presença de certos artigos de controle (i.e., do jogo Shadowspect e do grupo de pesquisa e-UCM). Após essas mudanças, chegou-se em: (“student” OR “user”) AND (“learning” OR “serious” OR “educational”) AND (“game” OR “digital game”) AND “game learning analytics”. Destaca-se que, para aumentar a quantidade de publicações retornadas, pesquisou-se essa frase de busca em todo o texto dos artigos, de forma a não descartar trabalhos que não citam esses termos em seus títulos.

3.3. Critérios de seleção e dados extraídos

Para tornar o resultado da pesquisa mais preciso, os seguintes critérios de inclusão (I) e de exclusão (E) foram escolhidos:

- I1: Artigos cujo tema central é GLA;
- E1: O artigo não está escrito em português ou inglês;
- E2: O artigo não possui livre acesso, seja de forma gratuita ou por meio do portal da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES);
- E3: O artigo tem menos de quatro páginas (artigo curto);
- E4: O artigo não é primário;
- E5: O artigo é duplicado (com base no DOI);
- E6: O projeto não foi aplicado ou avaliado;
- E7: O projeto não analisa dados provenientes de um jogo.

Cada artigo foi analisado por pelo menos dois pesquisadores, que chegaram em um consenso quanto ao resultado da seleção, e a utilização desses critérios ocorreu em duas rodadas, que funcionaram como filtros. Na primeira rodada, levou-se em conta título, resumo e palavras-chave de cada artigo. Já na segunda rodada, o artigo foi integralmente lido.

Para a extração de dados, que contou com a participação de um pesquisador, utilizou-se de uma planilha com diversas colunas para a categorização das informações obtidas a partir dos artigos. Entre as colunas, se encontram: ano de publicação do artigo; informações que o jogo salva; métricas utilizadas; análises realizadas; e ferramentas de GLA.

4. Resultados e Discussões

A pesquisa, executada no mês de setembro de 2023, resultou em 348 artigos ao total. A quantidade respectiva de artigos por cada rodada de seleção pode ser visualizada na Tabela 1.

Tabela 1. Quantidade de artigos em cada rodada

| Rodada | Quantidade de artigos |
|--|-----------------------|
| Retornado por todos os mecanismos de busca | 348 |
| Primeira rodada | 135 |
| Segunda rodada | 76 |
| Total | 76 |

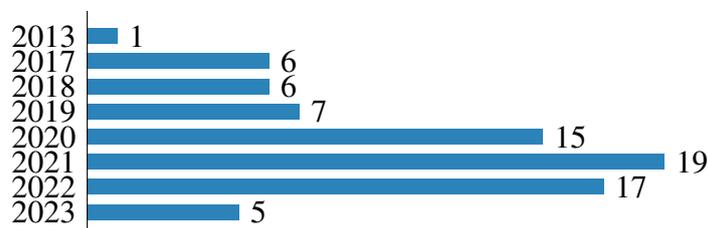
Fonte: Autoria própria.

Os dados resultantes das análises foram tabulados e organizados em uma planilha eletrônica¹, o que facilita a visualização do que foi extraído. As etapas de seleção podem ser acessadas através do seguinte *link*², bem como todas as classificações realizadas³. Ainda, ressalta-se que, como cada publicação pode contar com mais de uma informação em cada coluna da planilha (e.g., um jogo analisa duas métricas diferentes), a quantidade total de ocorrências presente nas categorias das classificações apresentadas a seguir pode ser maior do que o número de artigos analisados.

4.1. Dados de Publicação

A Figura 1 apresenta a quantidade de publicações por ano, em que é possível perceber um aumento de interesse do tópico ao longo dos anos, com maior pico em 2021 que contou com um total de dezenove artigos (25%). Ainda, ressalta-se que a menor quantidade de artigos existentes no ano 2023 pode ser decorrente da data em que a busca foi realizada. Destaca-se também que, para aumentar o número de publicações retornadas, não houve um filtro temporal para a busca e, desta forma, percebe-se que o tema é recente e promissor.

Figura 1. Quantidade de artigos por ano



Fonte: autoria própria

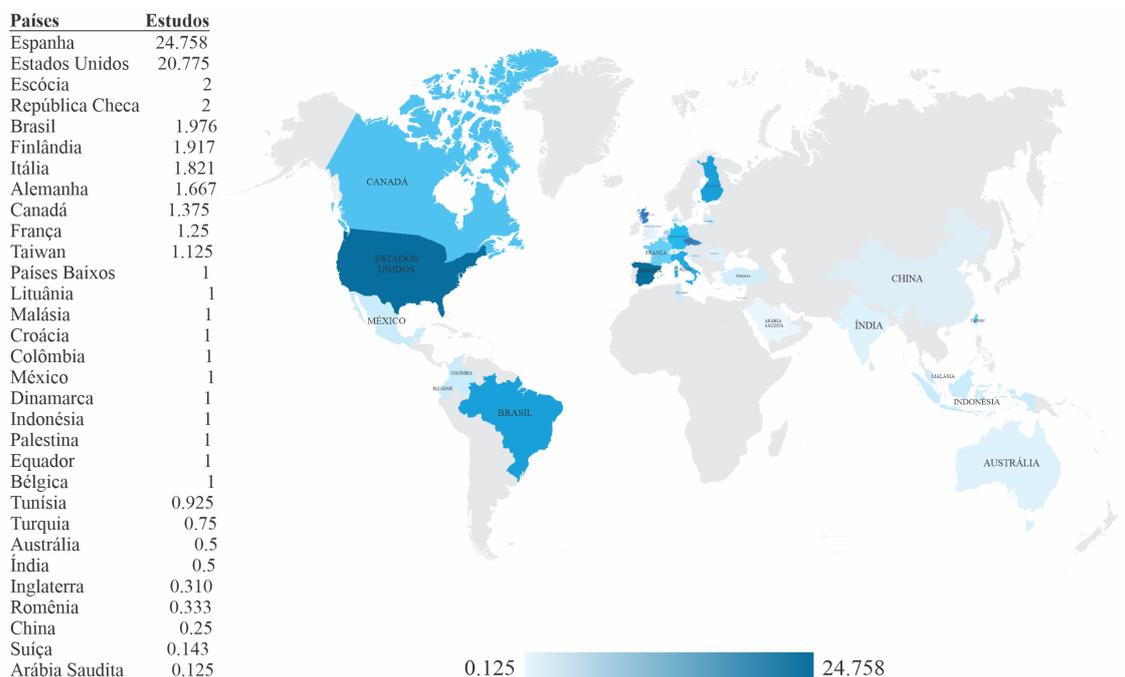
Já a Figura 2 retrata os países de origem dos estudos, de forma a ser possível notar que existem alguns locais com mais artigos sobre o assunto – como a Espanha com 25 artigos e os Estados Unidos com 21 artigos.

¹<https://bit.ly/3IVKq4g>

²<https://bit.ly/43wneDn>

³<https://bit.ly/3zv1FrC>

Figura 2. Quantidade de artigos por país



Fonte: autoria própria

4.2. Contexto dos Projetos

A partir dos dados tabulados, realizaram-se análises quantitativas e qualitativas. A primeira informação analisada refere-se ao recurso educacional utilizado para aplicação do GLA, visto que nem todos os artigos apresentaram o uso de jogos, mas estavam relacionados à análise de dados provenientes de JDE. Identificou-se que, de fato, a grande maioria eram jogos educacionais. Mas houve casos em que os recursos eram ferramentas para ensino de conteúdos, como ensino de programação, plataformas, como exemplo, uma plataforma para criar outros jogos sérios. Também se classificou como “outros” os artigos com recursos mais diversos, como aqueles com a criação de padrões, modelos e processos. O gráfico da Figura 3 apresenta o quantitativo das informações descritas.

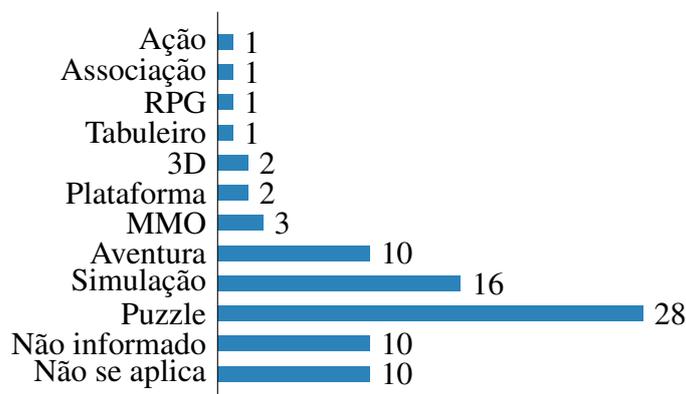
Figura 3. Quantidade de artigos por recurso educacional utilizado



Fonte: autoria própria

Também, houve a análise acerca do estilo ou tema do recurso empregado para GLA. A extração do tema dos artigos não seguiu uma classificação formal, mas sim aquela informada pelos autores. Na grande maioria, os recursos empregados foram do gênero “Aventura”, seguido por recursos de “Puzzle” e “Simulação”. Tais informações podem ser visualizadas no gráfico da Figura 4.

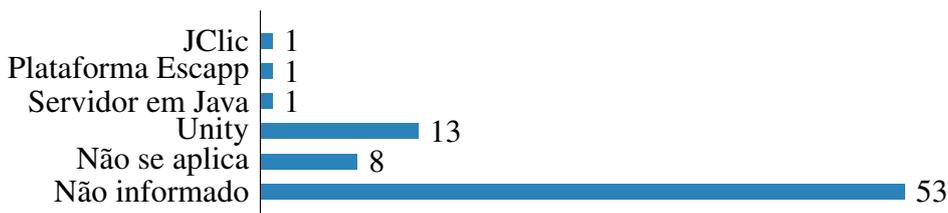
Figura 4. Quantidade de artigos por tema ou estilo do recurso educacional



Fonte: autoria própria

Por fim, quanto às ferramentas para a criação dos recursos educacionais, Unity é a principal *game engine* empregada, conforme visualizado no gráfico da Figura 5. Em menor número, obteve-se “Servidor em Java”, “Plataforma Escapp” e “JClic”. Em maior número, não havia tal informação no artigo e em alguns casos, não se aplicava.

Figura 5. Quantidade de artigos por ferramenta de criação



Fonte: autoria própria

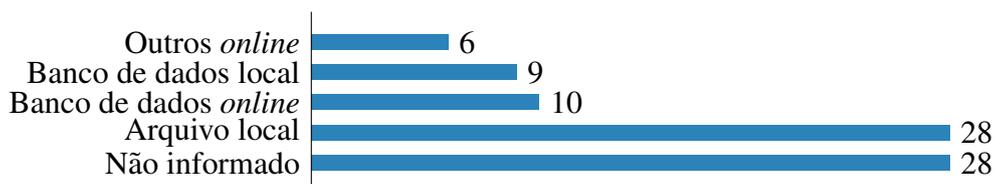
4.3. Questões de Pesquisa

Quanto à forma em que extração de dados provenientes dos jogos ocorreu (SQ1), encontraram-se as seguintes maneiras: onze artigos (14,47%) fizeram uso do *tracker* desenvolvido pelo grupo de pesquisa e-UCM; cinco artigos (6,58%) utilizam de *trackers* que não foram especificados; um artigo (1,32%) utiliza o *tracker* da plataforma Escapp, aplicação que permite professores a construírem *escape rooms* educacionais; e 59 artigos (77,63%) não informaram como os dados foram obtidos.

Sobre as maneiras utilizadas para salvar os dados, a Figura 6 apresenta uma síntese, sendo os *logs* em arquivos locais os mais utilizados – 23 artigos (30,26%). Dessa forma, nota-se que o armazenamento local tem maior preferência, tanto em arquivos quanto em banco de dados. Porém, isso dificulta que professores possam observar as informações da turma em tempo real, uma vez que essas informações devem ser enviadas posteriormente, como citado no artigo [Yohannis et al. 2020]. Entretanto, no caso de [Alonso-Fernández et al. 2019b], por fazer parte do grupo de pesquisa e-UCM, é possível verificar o progresso dos estudantes ao longo da utilização do jogo.

No que tange aos tipos de dados capturados (SQ2), a Figura 7 apresenta a classificação, sendo os dados separados em atômicos, que podem ser alterados unitari-

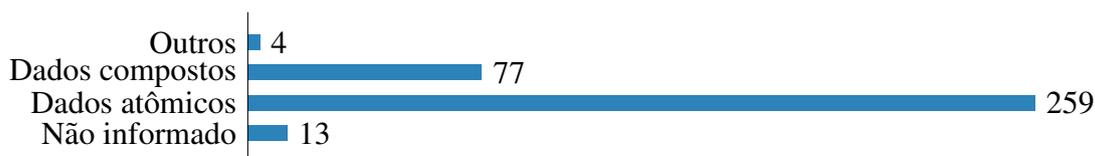
Figura 6. Como os dados foram salvos



Fonte: autoria própria

amente (e.g., um contador), e compostos, que são mais complexos e podem depender de mais uma informação (e.g., as médias). Dentro dos dados atômicos, foi observado que o identificador de cada usuário é o dado mais salvo, encontrado em 39 artigos (52,32%). Já nos dados compostos, as ações realizadas, presentes em 32 artigos (42,11%), foram as mais frequentes. Cabe também um destaque para os *timestamps* dessas ações, outro dado atômico, identificado em 26 artigos (34,21%). Juntas, essas três informações possibilitam traçar o comportamento de um jogador dentro do jogo, o que pode ser utilizado para averiguar sua progressão, como apresentado em [Burská et al. 2021].

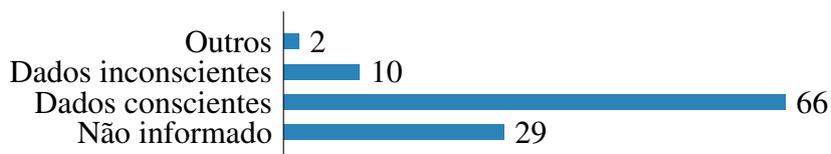
Figura 7. Tipos de informações salvas



Fonte: autoria própria

Além de obter informações por meio dos jogos, alguns artigos também analisaram dados externos, ou seja, de outras fontes (SQ3). Esses dados foram divididos como ilustrado na Figura 8, com a presença de dados conscientes, no qual o estudante sabe das informações que ele está produzindo, e inconscientes, caso ele não saiba. Os questionários são os mais utilizados e estão presentes em 29 artigos (38,16%), seguido pelos pré e pós-testes, usados em 28 artigos (36,84%). Entre os questionários identificados, encontram-se os demográficos, de usabilidade e o *Technology Acceptance Model*. Uma explicação para o maior uso de questionários e pré/pós-testes é sua utilização para a comparação com o que foi concluído apenas com o jogo, como ocorrem em [Yu et al. 2022, Cristina Alonso-Fernández and Fernández-Manjón 2023, Sonsoles López-Pernas and Barra 2023].

Figura 8. Tipos de dados externos analisados



Fonte: autoria própria

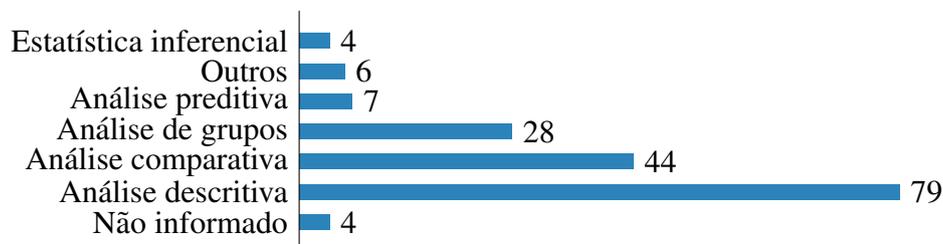
Também, objetivou-se identificar quais as métricas empregadas no GLA para averiguar o comportamento dos jogadores (SQ4). As métricas foram classificadas conforme

a origem das informações da seguinte forma: métricas de fases, que consideram apenas uma única fase do jogo (e.g., a porcentagem de completude); métricas do jogo, relativas à aplicação inteira (e.g., quantidade de fases concluídas); métricas do jogador, com as informações pertinentes de cada jogador (e.g., sua cor preferida); e outros, que dependem de diversos fatores (e.g., quantidade de conexões entre os nodos de um grafo de estrutura social). Porém, apesar de haver processamentos em cima do que foi salvo para compor uma métrica, como as médias de tempo, foi possível perceber que não há muita diferença entre o que é extraído e o que é considerado, ou seja, não existem muitas métricas compostas.

Existem também as métricas relacionadas à aprendizagem (**SQ5**), divididas em atômicas, compostas e outras. Observou-se que a quantidade de cliques e a pontuação final são as mais utilizadas, presente em oito (10,53%) e sete (9,21%) artigos, respectivamente. Mais uma vez, não foram encontradas muitas métricas que sejam mais do que informações brutas, mas alguns exemplos incluem a sequência de ações, que pode ser utilizada para definir a competência de um jogador, e o cálculo da maestria. O primeiro caso é explorado em [Ruipérez-Valiente et al. 2023], que utiliza de uma modelagem multivariada de aprendizagem baseada no algoritmo Elo – que estima a força relativa de um jogador (ou equipe) em um jogo – para computar a evolução de competência dos estudantes, com base em cada tentativa de solução dos *puzzles* do jogo Shadowspect. Já [Huy Nguyen and McLaren 2020] é um exemplo do segundo caso, com o uso do algoritmo de *Bayesian Knowledge Tracing* para a medição do nível de habilidade em certos componentes de conhecimento, que possuem relação direta com a maestria do jogador.

Com base nesses dados obtidos com os jogos, diversas análises podem ser realizadas (**SQ6**) e uma classificação é apresentada na Figura 9. A análise descritiva genérica (e.g., medidas de tendência central e de dispersão) se encontra presente em 63 artigos (82,89%), seguida de correlação, dentro de análise comparativa, com 28 artigos (36,84%), e clusterização, dentro de análise de grupos, encontrada em quinze artigos (19,74%). Destacam-se também artigos com propostas inovadoras, como [Alexandru Capatina and Hoareau 2018], que utiliza de uma comparação qualitativa de conjuntos fuzzy para explorar a influência de certas variáveis no *ranking* de um jogo sério, e [Sonsoles López-Pernas and Barra 2023], que utiliza de sequências SPELL para apresentar o progresso dos jogadores aos professores.

Figura 9. Análises realizadas

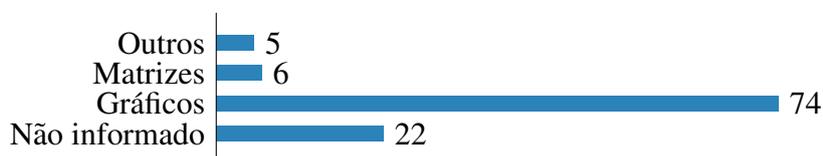


Fonte: autoria própria

O modo como o resultado das análises realizadas é apresentado (**SQ7**) pode ser visualizado na Figura 10 e as duas formas mais utilizadas são gráficos de linha e de barra simples, presentes em vinte (26,32%) e dezenove artigos (25%), respectivamente. Com

isso, percebe-se que há uma relação entre a quantidade de métodos de visualizações simples e as análises mais realizadas.

Figura 10. Métodos de visualização



Fonte: autoria própria

Sobre os *stakeholders* de GLA (SQ8), esses podem ser classificados da seguinte forma [Wagner Mainardes et al. 2012]: *stakeholder* controlador, que consiste em desenvolvedores, *game developers* e *game designers*; *stakeholder* parceiro, composto por professores, pesquisadores, educadores e instrutores; e o *stakeholder* dependente, com os jogadores e estudantes.

Para auxiliar no processo de GLA, algumas ferramentas podem ser utilizadas (SQ9). Essas ferramentas foram divididas em dois casos, as voltadas para GLA, com apenas a existência das aplicações do grupo de pesquisa e-UCM, e as não voltadas para esse nicho, como o LimeSurvey, que foi utilizado para a criação de questionários. Ainda, mais especificamente para a análise dados, identificaram-se quais os algoritmos aplicados nos artigos analisados (SQ10), classificados de acordo com sua utilidade em: algoritmos de regressão, *machine learning*, clusterização, modelagem e outros.

5. Conclusão

O conceito de GLA surge como uma extensão de LA, com o foco nos dados obtidos com a interação do usuário com JDE [Freire et al. 2016]. A aplicação desse conceito possibilita o aprimoramento do processo de aprendizagem [Cano et al. 2017], por meio do armazenamento das interações dos jogadores, a análise das suas ações e a avaliação da evolução do estudante. Porém, não existem muitos padrões quanto ao uso de suas técnicas [Su et al. 2021, Alonso-Fernandez et al. 2017b], o que motivou o desenvolvimento do presente MSL.

De acordo com os resultados das subquestões de pesquisa, foi possível cumprir com o objetivo do mapeamento, que era obter um maior entendimento acerca de como o processo de GLA têm sido aplicado em JDE. A maioria dos artigos utiliza do *tracker* desenvolvido pelo grupo de pesquisa e-UCM (SQ1) e os tipos de informações salvas podem ser divididos em dados atômicos, compostos e outros. Entre as informações mais extraídas, encontram-se o identificador do usuário e as ações realizadas por ele (SQ2). Ainda, questionários foram o meio externo mais encontrado nos artigos (SQ3).

A partir desses dados, é possível compor certas métricas (SQ4), que foram classificadas em métricas de fases, do jogo, do jogador e outras. Porém, apesar de serem citadas as criações de algumas métricas, foi constatado que não há muita diferença entre os dados brutos e o que é considerado nas análises, pois a maioria dos artigos usa diretamente as informações salvas. Mais especificamente quanto à aprendizagem, cliques e pontuação final em fases são os dados mais presentes (SQ5). Quanto ao uso dessas informações, a análise descritiva genérica, correlação e clusterização foram as técnicas mais aplicadas

(SQ6). E, para a visualização dos resultados, gráficos de linha e barra foram os mais utilizados (SQ7).

É possível classificar os *stakeholders* em três grupos (SQ8): controlador, parceiro e dependente. As ferramentas utilizadas foram divididas em específicas de GLA e não específicas de GLA (SQ9), com apenas os do grupo de pesquisa e-UCM no primeiro grupo. Por fim, os algoritmos foram separados de acordo com sua aplicação (SQ10), da seguinte forma: regressão, *machine learning*, clusterização, modelagem e outros.

Com esses resultados, há um maior entendimento quanto às formas em que GLA pode ser aplicado em JDE, como com a classificação das análises e das visualizações realizadas, o que constitui em um importante passo para a criação de padrões de uso conforme o contexto de cada projeto. Além disso, o mapeamento das métricas utilizadas pode auxiliar na escolha do que incluir nos jogos, o que também contribui para a área.

Uma limitação deste trabalho é o envolvimento de apenas um pesquisador na etapa de extração de dados, o que pode ocasionar a presença de um viés pessoal, bem como os mecanismos de busca escolhidos e a frase definida, que também podem influenciar nos que foi obtido. Para trabalhos futuros, sugere-se a utilização dos resultados alcançados para a definição de padrões de uso de GLA, o que pode auxiliar equipes que desejam incluir essas técnicas em seus projetos.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, e do Programa de Excelência Acadêmica (PROEX). Também agradecemos o apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) através do processo 302959/2023-8 (DT2) e da Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina (FAPESC) N° 48/2022 - Apoio à Infraestrutura para Grupos de Pesquisa da UDESC TO n°2023TR000245.

Referências

- Alexandru Capatina, Gianita Bleoju, E. R. and Hoareau, E. (2018). Tracking precursors of learning analytics over serious game team performance ranking. *Behaviour & Information Technology*, 37(10-11):1008–1020.
- Alonso-Fernandez, C., Calvo, A., Freire, M., Martinez-Ortiz, I., and Fernandez-Manjon, B. (2017a). Systematizing game learning analytics for serious games. In *2017 IEEE Global Engineering Education Conference (EDUCON)*, pages 1111–1118.
- Alonso-Fernandez, C., Calvo, A., Freire, M., Martinez-Ortiz, I., and Fernandez-Manjon, B. (2017b). Systematizing game learning analytics for serious games. In *2017 IEEE Global Engineering Education Conference (EDUCON)*, pages 1111–1118.
- Alonso-Fernández, C., Calvo-Morata, A., Freire, M., Martínez-Ortiz, I., and Fernández-Manjón, B. (2019a). 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 Fernández-Manjón, B. (2022). Game learning analytics: Blending visual and data mining tech-

- niques to improve serious games and to better understand player learning. *Journal of Learning Analytics*, 9(3):32–49.
- Alonso-Fernández, C., Cano, A. R., Calvo-Morata, A., Freire, M., Martínez-Ortiz, I., and Fernández-Manjón, B. (2019b). Lessons learned applying learning analytics to assess serious games. *Computers in Human Behavior*, 99:301–309.
- Anastasiadis, T., Lampropoulos, G., and Siakas, K. (2018). Digital game-based learning and serious games in education. *International Journal of Advances in Scientific Research and Engineering (IJASRE)*, ISSN:2454-8006, DOI: 10.31695/IJASRE, 4(12):139–144.
- Buchinger, D., Cavalcanti, G. A. d. S., and Hounsell, M. d. S. (2014). Mecanismos de busca acadêmica: uma análise quantitativa. *Revista Brasileira de Computação Aplicada*, 6(1):108–120.
- Burská, K. D., Rusňák, V., and Ošlejšek, R. (2021). Enhancing situational awareness for tutors of cybersecurity capture the flag games. In *2021 25th International Conference Information Visualisation (IV)*, pages 235–242.
- Cano, A. R., Fernández-Manjón, B., and García-Tejedor, Á. J. (2017). Glaid: Designing a game learning analytics model to analyze the learning process in users with intellectual disabilities. In Vaz de Carvalho, C., Escudeiro, P., and Coelho, A., editors, *Serious Games, Interaction and Simulation*, pages 45–52, Cham. Springer International Publishing.
- Cascini, D. and Campos, S. (2015). Avaliação de jogos educacionais multiusuários: Uma revisão sistemática da literatura. *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)*, 26(1):519.
- Cristina Alonso-Fernández, Antonio Calvo-Morata, M. F. I. M.-O. and Fernández-Manjón, B. (2023). Evidence-based evaluation of a serious game to increase bullying awareness. *Interactive Learning Environments*, 31(2):644–654.
- De Grove, F., Bourgonjon, J., and Van Looy, J. (2012). Digital games in the classroom? a contextual approach to teachers’ adoption intention of digital games in formal education. *Computers in Human Behavior*, 28(6):2023–2033.
- Freire, M., Serrano-Laguna, Á., Iglesias, B. M., Martínez-Ortiz, I., Moreno-Ger, P., and Fernández-Manjón, B. (2016). *Game Learning Analytics: Learning Analytics for Serious Games*, pages 1–29. Springer International Publishing, Cham.
- Gee, J. P. (2003). *What video games have to teach us about learning and literacy*. Palgrave Macmillan, NY, USA.
- Huy Nguyen, Xinying Hou, J. S. and McLaren, B. (2020). Moving beyond test scores: Analyzing the effectiveness of a digital learning game through learning analytics. In *13th International Conference on Educational Data Mining (EDM 2020)*, pages 487–495.
- Kitchenham, B. A. and Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering. Technical Report EBSE 2007-001, Keele University and Durham University Joint Report.

- Michael, D. R. and Chen, S. L. (2006). *Serious Games: Games that Educate, Train and Inform*. Thomson Course Technology.
- Ruipérez-Valiente, J. A., Kim, Y. J., Baker, R. S., Martínez, P. A., and Lin, G. C. (2023). The affordances of multivariate elo-based learner modeling in game-based assessment. *IEEE Transactions on Learning Technologies*, 16(2):152–165.
- Savi, R. and Ulbricht, V. R. (2008). Jogos digitais educacionais: Benefícios e desafios. *RENOTE*, 6(1).
- Schell, J. (2008). *The Art of Game Design: A Book of Lenses*. Elsevier.
- Sonsoles López-Pernas, Mohammed Saqr, A. G. and Barra, E. (2023). A learning analytics perspective on educational escape rooms. *Interactive Learning Environments*, 31(10):6509–6525.
- Su, Y., Backlund, P., and Engström, H. (2021). Comprehensive review and classification of game analytics. *Service Oriented Computing and Applications*, 15(2):141–156.
- Tlili, A. and Chang, M. (2019). *Data Analytics Approaches in Educational Games and Gamification Systems*. Springer Publishing Company, Incorporated, 1st edition.
- Wagner Mainardes, E., Alves, H., and Raposo, M. (2012). A model for stakeholder classification and stakeholder relationships. *Management Decision*, 50(10):1861–1879.
- Yohannis, A., Windriyani, P., and Septanto, H. (2020). Understanding learning behaviours in sorting algorithm game. In *2020 7th NAFOSTED Conference on Information and Computer Science (NICS)*, pages 72–77.
- Yu, J., Ma, W., Moon, J., and Denham, A. (2022). Developing a stealth assessment system using a continuous conjunctive model. *Journal of Learning Analytics*, 9(3):11–31.
- Zyda, M. (2005). From visual simulation to virtual reality to games. *IEEE Computer Society*, 38(9):25–32.