

GLBoard: um sistema para auxiliar na captura e análise de dados em jogos educacionais

Douglas Silva², Fernanda Pires¹, Rafaela Melo², Marcela Pessoa¹

¹Escola Superior de Tecnologia – Universidade do Estado do Amazonas (EST/UEA)
Manaus – AM – Brasil

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

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

Abstract. *Although many researches point out that games can be excellent tools for learning, the learning process in these environments is still a challenge. In this context, studies in Game Learning Analytics (GLA) offer new possibilities for learning assessment. However, existing GLA templates are not generic, which has specific, non-reusable template templates. This article presents a proposal for a system called GLBoard, based on a generic data model, whose objective is to capture and analyze data in educational games. The system of a data architecture, as well as a set of tools, integration of GLA to enable games and a visualization of the information.*

Keywords–Game learning analytics, educational games, learning analytics

Resumo. *Embora muitas pesquisas apontem que jogos podem ser excelentes ferramentas para a aprendizagem, o processo de avaliação de aprendizagem nesses ambientes ainda é um desafio. Nesse contexto, os estudos em Game Learning Analytics (GLA) têm oferecido novas possibilidades de avaliação de aprendizagem. Entretanto, os modelos de GLA existentes não são genéricos, o que tem gerado modelos específicos e não reutilizáveis. O presente artigo apresenta uma proposta de sistema intitulado GLBoard, baseado em um modelo genérico de dados, cujo objetivo é capturar e analisar dados em jogos educacionais. O sistema propõe uma arquitetura de dados, bem como um conjunto de ferramentas, para possibilitar a integração de GLA em jogos educacionais e a visualização das informações.*

Palavras-chave–Análise de aprendizado em jogos, jogos educacionais, análise de aprendizado

1. Introdução

Muitos estudos têm indicado que os jogos podem ser importantes ferramentas no processo de aprendizagem [Plass et al. 2020, Freire et al. 2016]. Os aspectos motivacionais, proporcionados pela conexão entre os usuários e os jogos, impulsionam os estudantes a melhorar seu desempenho a cada etapa, fato que os difere das mídias convencionais, como vídeos, apostilas, apresentações, entre outros [Hsiao 2007].

Apesar dos benefícios da utilização dos jogos educacionais no processo de aprendizagem [Freire et al. 2016, Plass et al. 2020], ainda existem desafios para que os jogos sejam aceitos como um recurso educacional robusto, sendo: i) alto custo de desenvolvimento [Plass et al. 2020]; ii) falta de visualização/compreensão de como os jogadores interagem com o ambiente [Plass et al. 2020]; e, iii) falta de ferramentas que melhorem a compreensão do impacto educacional que os jogos têm sobre os usuários [Freire et al. 2016].

Em estudos na área de avaliação de jogos educacionais, geralmente são utilizadas heurísticas tendo como ferramentas questionários de pesquisa [Calderón and Ruiz 2015, Melo et al. 2018]. Tal forma de avaliação apresenta algumas limitações, como por exemplo, avaliar apenas aspectos de entretenimento e usabilidade [Lima et al. 2020, Melo et al. 2020a], ou considerar somente a percepção dos jogadores em um único momento [de Sousa Pires et al. 2018]. Porém, nos jogos educacionais, é necessário considerar aspectos relativos a evidências de aprendizagem, e as avaliações heurísticas, embora auxiliem na compreensão da experiência do usuário, não permitem avaliar os efeitos do jogo na aprendizagem [Melo et al. 2020a, Plass et al. 2020].

Diante desse cenário, alguns pesquisadores [Calvo-Morata et al. 2018, Melo et al. 2020a] têm proposto o uso de estratégias de coleta e análise de dados gerados durante a utilização dos jogos. Entre as vantagens de usar captura de dados em jogos educacionais estão a possibilidade de prever o desempenho do estudante [Rodrigues et al. 2013], fornecer uma experiência personalizada [Peirce et al. 2008], reduzir a taxa de retenção em cursos [Barnes et al. 2007] e melhorar o *design* para novos jogos educacionais [Melo et al. 2020a, Melo et al. 2020b]. O nome atribuído à técnica de captura e análise de dados em jogos educacionais é *Game Learning Analytics* (GLA), que tem como objetivo coletar, analisar e extrair informações de dados coletados em jogos educacionais [Freire et al. 2016].

No entanto, apesar das vantagens em aplicar GLA, a implementação dessas técnicas não é uma atividade trivial. As técnicas devem atender um conjunto de necessidades: i) a modelagem dos elementos de jogos vinculados a aprendizagem de acordo com os pressupostos do processamento humano da informação; ii) a sequência de aprendizagem (level design); e, iii) a evidência de uma curva de aprendizagem para os educadores/tutores de acordo com as interações dos jogadores. A compreensão desses elementos, somados às tecnologias envolvidas no processo de desenvolvimento, pedem a existência de uma equipe multidisciplinar. Por conta da complexidade na implementação de GLA, alguns desenvolvedores acabam não adicionando técnicas de GLA em jogos educacionais [Saveski et al. 2015].

Visando minimizar tal complexidade, este trabalho propõe um sistema computacional de coleta de dados, de amplo espectro, intitulada GLBoard e composta por quatro módulos : i) uma arquitetura para captura de dados genérico; ii) um *package* (pacote) para uso na *game engine* Unity¹, que facilita a padronização de dados nos jogos educacionais; iii) uma API para transporte e manipulação de dados; e, iv) um *dashboard* que possibilita a visualização dos dados resultantes das interações dos estudantes com os jogos educacionais. O artigo está organizado como segue: a Seção 2 trata da fundamentação teórica

¹Disponível em: <https://unity.com/pt>

do trabalho, a Seção 3 apresenta o sistema GLBoard e na Seção 4 estão as considerações finais.

2. *Game Learning Analytics*: alternativa à avaliação em jogos

Jogos educacionais são projetados para serem utilizados em um ambiente educacional, com o objetivo de auxiliar na aprendizagem de um determinado conteúdo [Plass et al. 2020, Melo et al. 2020a], possuem recursos que os diferem de jogos de entretenimento, principalmente no que diz respeito às regras e objetivos, que podem estar implícitos ou explícitos no ambiente do jogo ou nos desafios apresentados durante a jornada [Melo et al. 2020a]. Nos jogos educacionais, os usuários são orientados a cumprir os objetivos explícitos, como por exemplo, derrotar o vilão, resgatar a princesa ou coletar itens, e, enquanto fazem isso, também completam os objetivos implícitos, ou seja, os objetivos relacionados à aspectos de aprendizagem, adquirindo habilidades, conhecimentos e experiências [Plass et al. 2020].

Apesar dos jogos educacionais serem apontados como ferramentas de aprendizagem eficientes, ainda existem muitos desafios, sobretudo no que diz respeito ao processo de *game design* educacional. Para construir bons jogos, é preciso entender os aspectos que possibilitam a aprendizagem em tais ambientes, por isso a importância de realizar diferentes estágios de avaliação, o que ainda é um desafio [Melo et al. 2020a, Silva et al. 2021].

A literatura indica que o modelo de avaliação de jogos educacionais mais utilizado é o de caixa preta. Ou seja, a eficiência do jogo é avaliada imediatamente depois que o usuário termina de jogar. Antes de iniciar o jogo, é aplicado um pré-teste e depois de finalizar a partida, um pós-teste [Calderón and Ruiz 2015]. Ao fazer uso somente de questionários, o jogo e o comportamento do jogador durante a jornada são excluídos do processo de avaliação. Para compreender como, e se, ocorre aprendizagem em jogos educacionais, são necessárias avaliações mais robustas [Freire et al. 2016]. Diante desse contexto, estudos na área de avaliação de jogos começaram a utilizar os dados gerados da interação dos jogadores para realizar análises que possibilitem verificar como a aprendizagem ocorre dentro do ambiente em questão [Alonso-Fernandez et al. 2017], esse campo de estudo se chama *Game Learning Analytics*.

GLA tem como foco a avaliação de aprendizagem em jogos educacionais, buscando contribuir para melhores análises em cenários de aprendizagem ludificados. A partir dos dados capturados nos jogos educacionais é possível verificar se a mecânica do jogo está relacionada com a aprendizagem, utilizando abordagens baseadas em evidências [Freire et al. 2016]. Com isso, não se pretende afirmar que apenas a GLA é capaz de suprir todos os desafios no que diz respeito ao acompanhamento dos usuários em suas jornadas de aprendizagem, mas pode auxiliar na compreensão, respeitando as limitações da tecnologia.

Dentre os benefícios da GLA, destaca-se a possibilidade de verificar se o *design* do jogo desenvolvido teve seus objetivos educacionais e de entretenimento cumpridos, por meio da análise dos dados gerados [Melo et al. 2020b]. Os sistemas de GLA possibilitam que os professores visualizem um conjunto de informações úteis sobre os usuários, por exemplo: i) jogadores ativos; ii) taxa de abandono; iii) conteúdos que os estudantes possuem facilidade/dificuldade; iv) grupo de estudantes similares; e, v) perfis de jogadores [Silva et al. 2021]. Por meio das informações observadas, o professor pode visualizar os

estudantes que possuem maiores dificuldades e com isso propor diferentes metodologias capazes de auxiliar esses estudantes, evitando com isso o abandono ou a reprovação em determinadas disciplinas.

Diversos trabalhos na literatura, utilizam GLA especificamente para um jogo, não criando modelos genéricos que possam ser aplicados a mais de um artefato [Melo et al. 2020b, Calvo-Morata et al. 2018, Melo et al. 2020a, Zapata-Cáceres and Martín-Barroso 2021]. Porém, ao ter um modelo sistematizado de GLA, é possível obter um conjunto de benefícios: i) permitir ao desenvolvedor reutilizar o componente de captura de dados sem que seja necessário implementar um novo sistema do zero; ii) utilizar um *template* de dados que pode ser flexível para atender novos dados específicos de um jogo, possibilitando que mesmo sem os dados específicos possam ser geradas informações úteis para os usuários do sistemas; e, iii) os professores podem ter um ambiente para visualizar as análises que são realizadas a partir dos dados.

3. A proposta do GLBoard

Com o objetivo de sistematizar o processo de captura e análise de dados em jogos educacionais, propõe-se aqui uma estrutura própria de *Game Learning Analytics* intitulada GLBoard. A arquitetura para a captura de dados do sistema se baseia na premissa de que existem dados comuns a todos os jogos, independente do estilo ou gênero, como: *timestamps*, mudanças de nível, tentativas e interações do usuário com a interface [Cano et al. 2016].

O sistema é formado por um conjunto de quatro módulos que: padronizam os dados genéricos que devem ser extraídos dos jogos; envia os dados para um banco; realiza análises; e, demonstra os dados e análises por meio de um *dashboard web*. O GLBoard pode favorecer desenvolvedores e *game designers*, que podem contar com uma arquitetura específica a ser implementada em jogos educacionais e com isso chegar a possíveis mudanças a serem implementadas no *game design*. Além de permitir que os educadores acompanhem a evolução dos estudantes a partir da evolução de sua participação nos jogos, e, que os estudantes visualizem seu desempenho individual e observem no que podem melhorar, de acordo com o *feedback* relacionado a aquisição de habilidades e competências.

O fluxo geral do sistema ocorre com o desenvolvedor inicialmente criando uma conta no sistema e a partir disso pode cadastrar as informações dos seus jogos. Com um jogo cadastrado, o desenvolvedor pode realizar o processo de captura de dados. Para isso, o pacote deve ser inserido na *game engine*. Após realizar a integração, os dados do jogo vão ser organizados de acordo com um modelo e enviados para um banco de dados. Esse processo de armazenamento é gerenciado por uma *API*, que também realiza as análises dos dados do jogo e as apresenta em um *dashboard web*. Na Figura 1, pode ser visualizado o diagrama do fluxo de dados do GLBoard. Nas próximas seções serão descritos cada um dos componentes que fazem parte do sistema e como estão relacionados.

Para que o sistema GLBoard consiga ser integrado a um jogo educacional é necessário que o *game design* do jogo seja construído com estruturas de captura de dados, ou seja, os desenvolvedores devem conseguir visualizar no jogo, quais dados podem ser analisados e que sejam compatíveis com a estrutura proposta pelo GLBoard, caso contrário, o sistema não será efetivo, resultando em análises pouco significativas.

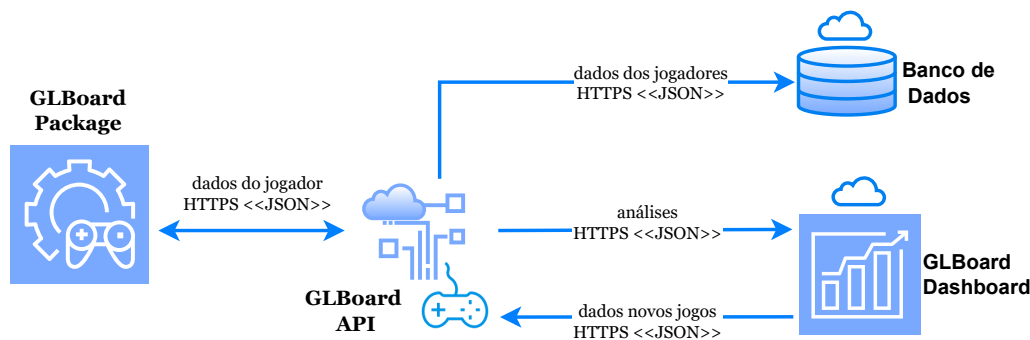


Figura 1. Estrutura do sistema GLBoard

3.1. GLBoard: Arquitetura de captura de dados

Para haver sistematização de GLA é importante que seja definido um modelo de dados genéricos que podem ser capturados em jogos educacionais. Esses dados devem ser comuns a maioria dos jogos e podem ser utilizados para realizar análises que mostrem como o jogador está interagindo e aprendendo com o jogo.

É necessário que os dados sejam organizados de acordo com uma estrutura definida, para que possam ser interpretados e analisados por sistemas de terceiros, que não entendem com profundidade o significado de cada valor existente na base de dados. A padronização facilita a compreensão dos dados, permitindo que pesquisadores que não participaram do processo de desenvolvimento de determinado jogo, consigam observar os dados e entender como foram estruturados e como os jogadores interagiram com o jogo.

Dada a importância da padronização, foi desenvolvido um modelo de dados para servir como base do sistema GLBoard. Para definir os dados genéricos, foi realizada uma revisão da literatura visando compreender quais são os dados comumente capturados em jogos educacionais e o que esses dados podem informar sobre a aprendizagem do jogador [Alencar et al. 2020, Alonso-Fernandez et al. 2019, Melo et al. 2020b]. Ao fim dessa etapa, o seguinte modelo foi elaborado (Figura 2).

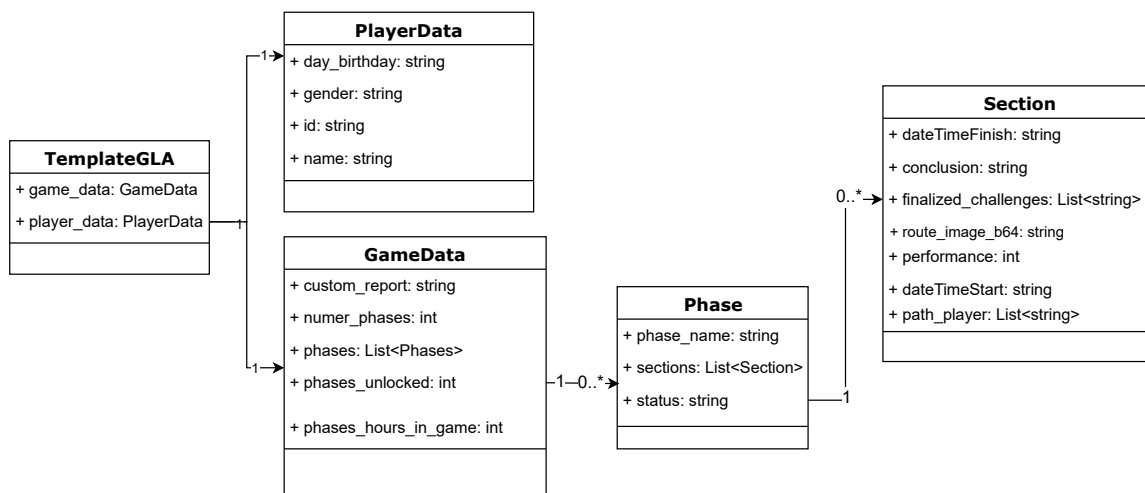


Figura 2. Estrutura de dados do sistema GLBoard

Esse modelo possui uma estrutura dividida em 4 principais classes:

- *PlayerData*: está relacionada diretamente aos dados do perfil do jogador;
- *GameData*: são muitos os dados que compõe essa classe, mas de forma geral estão relacionados aos dados gerados pelos jogadores durante sua *gameplay*;
- *Phase*: relaciona-se com as fases do jogo, logo, cada fase é um objeto do tipo *Phase*;
- *Section*): um objeto do tipo *Phase* possui 0 ou mais objetos do tipo *Section*, essa classe contém as informações de cada sessão realizada na fase. Pode ser compreendido como sessão uma tentativa realizada em uma fase.

3.2. GLBoard: Package Unity

Com o objetivo de facilitar o processo de captura de dados nos jogos educacionais foi desenvolvido um pacote em *C-Sharp* para a Unity, cuja função é auxiliar o desenvolvedor no processo de padronização dos dados, bem como realizar o envio dos dados capturados para que a API possa armazenar no banco de dados e, posteriormente, realizar as análises. Por ainda não ser uma estrutura flexível, não existe a possibilidade de enviar dados adicionais do jogo para a API.

3.3. GLBoard: API

A GLBoard-API² é o controlador do sistema, foi desenvolvido em Python³ utilizando o framework Flask-API⁴ e possui as funcionalidades de: i) receber os dados da interação do jogador com o jogo educacional; e, ii) armazená-los em um banco de dados desenvolvido com o Firebase⁵. Na Figura 1 é possível visualizar o fluxo de informações que circulam na API. De forma geral, a API recebe os dados que são enviados do jogo por meio do pacote Unity e os armazena de forma estruturada no banco de dados, cujas tabelas estão organizadas para cadastrar individualmente os registros de cada um dos jogadores. Na API existem os *endpoints* que realizam as análises dos dados, sendo:

1. *Análises gerais do jogo*: utiliza os dados de todos os jogadores e retorna as informações: quantidade de jogadores; jogadores por gênero; porcentagem e número de fases concluídas; tempo total em jogo; número de tentativas por fase; tempo jogado em cada fase; relação de vitória/derrota por fase; porcentagem de performance por fase. Esses dados podem ser cruzados com aqueles referentes a um único jogador e auxiliar na modelagem de perfis de aprendizagem.
2. *Análises de único jogador*: retorna as informações de análise gerais para um jogador específico, além disso retorna as informações de todas as sessões do jogador.
3. *Análises de grupo*: retorna análises de *cluster*, em que são relacionados os seguintes dados: tempo/tentativas, para encontrar relação de jogadores que passam muito tempo jogando e têm poucas tentativas ou muito tempo jogando e poucas tentativas, por meio disso é possível perceber se os jogadores planejam estratégias antes da tomada de decisões ou utilizam tentativa e erro, o que pode acarretar em muitas tentativas nas fases; derrotas/tentativas, para identificar o grupo de jogadores que possui maior número de derrotas nas fases.

²Disponível em: <https://api-backend-gla.herokuapp.com/>

³Disponível em: <https://www.python.org/>

⁴Disponível em: <https://flask.palletsprojects.com/en/2.2.x/>

⁵Disponível em: <https://firebase.google.com/?hl=pt>

Os resultados de análise podem ser visualizados na forma de *JSON*, por meio de consultas na API e também podem ser visualizados em gráficos e tabelas no *dashboard* do sistema *web*. O sistema *web* também envia dados para a API, devido a ser o responsável por realizar os cadastros de novos desenvolvedores, professores e estudantes. Os dados de credenciais são enviados para a API e armazenados no banco de dados.

3.4. GLBoard: Web

O sistema *web* tem como objetivo mostrar os resultados das análises que são realizadas na API por meio de um *dashboard*, além disso, é onde os desenvolvedores podem criar uma conta e cadastrar seus jogos. O sistema *web* pode ser utilizado por três usuários diferentes:

1. *Desenvolvedor*: cadastra seus jogos e recebe uma chave ID que pode ser utilizada para enviar os dados do jogo para a API; exclui e visualiza as chaves dos jogos cadastrados. Ao selecionar um jogo consegue visualizar as análises que foram geradas a partir dos dados. As análises podem ser vistas nas telas de análise geral, individual e de grupo.
2. *Professor*: insere uma chave ID pertencente a um jogo cadastrado por um desenvolvedor e, a partir disso, consegue ter acesso aos dados do jogo, além disso, pode remover e visualizar as chaves que inseriu. Ao selecionar um jogo, também pode visualizar as telas de análise.
3. *Jogador*: cada jogo possui N jogadores e cada um é identificado por um ID único (USER ID). Ao inserir uma chave de USER ID, o jogador consegue ter acesso aos dados do jogo ao qual a chave pertence. Também pode remover e visualizar as chaves inseridas. Diferente do professor e do desenvolvedor, o jogador consegue visualizar somente a tela de análise individual.

Ao selecionar um jogo específico na lista de jogos, os desenvolvedores e professores podem ter acesso a tela de análises gerais (Figura 3a). O *dashboard* contém as seguintes informações:

- Quantidade de jogadores homens/mulheres: um gráfico de pizza mostrando a porcentagem de jogadores homens e mulheres.
- Quantidade de jogadores: a quantidade de pessoas que jogaram ao menos uma vez.
- Quantidade de fases: a quantidade de fases que constituem o jogo.
- Quantidade de horas jogadas: a quantidade de horas jogadas, dado resultante da soma do tempo de todas as sessões realizadas por todos os jogadores.
- Porcentagem de conclusão de fases: gráfico de barras onde o eixo *x* representa as fases e o eixo *y* um valor de 0 a 100 (porcentagem de conclusão da fase). Cada barra representa a porcentagem de jogadores que concluíram determinada fase.
- Tentativas por fase: gráfico de barras onde o eixo *x* representa as fases e o eixo *y* a quantidade de tentativas em uma fase. Cada barra representa a quantidade de sessões realizadas por todos os jogadores em determinada fase.
- Média de desempenho em fase: gráfico de barras, onde o eixo *x* representa as fases e o eixo *y* a média da constante de desempenho dos jogadores em determinada fase (utilizando o valor de maior desempenho).

- Tempo em cada fase: gráfico de barras, onde o eixo x representa as fases e o eixo y o tempo total (soma do tempo em sessões) de todos os jogadores em determinada fase.
- Sessões realizadas por dia: gráfico de linha, onde o eixo x representa o dia da semana (segunda a domingo) e o eixo y o número de sessões realizadas por todos os jogadores em cada dia da semana.
- Derrota/vitória: gráfico de barras empilhadas, onde o eixo x representa as fases e o eixo y o número de sessões realizadas pelos jogadores em cada fase do jogo. A barra é dividida em duas partes, uma representa a quantidade de sessões que resultaram em vitória e a outra as sessões que resultaram em derrota.

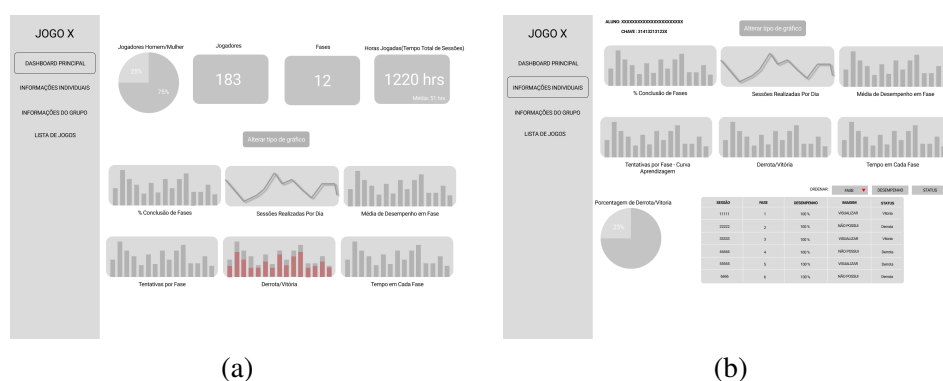


Figura 3. (a) Dashboard de análises gerais, (b) Dashboard de análise individual

Os professores/desenvolvedores têm acesso a lista de jogadores, que possui as informações do nome do jogador, última sessão, porcentagem de conclusão do jogo e a sua chave USER ID. Ao selecionar um jogador é possível visualizar suas informações individuais. Caso o professor/desenvolvedor queira que um jogador acesse a tela de seus dados individuais (Figura 3b), basta compartilhar a chave do USER. As análises individuais possuem as mesmas informações das análises gerais, porém referem-se somente aos dados do jogador selecionado.

A tela de análise de grupos possui informações sobre a relação entre estudantes, permitindo visualizar padrões entre eles. As análises são baseadas em *clusters*. A partir da relação de dados, é possível verificar as seguintes informações:

- Tempo/tentativas: *cluster* que busca cruzar as informações de tempo e tentativas a fim de ver jogadores que estão inseridos em, por exemplo, um grupo de jogadores que tem muito tempo de jogo e muitas tentativas ou pouco tempo de jogo e muitas tentativas;
- Derrotas/tentativas: *cluster* que busca cruzar as informações de derrota e tentativas a fim de ver jogadores que estão inseridos em, por exemplo, um grupo de jogadores que tem muitas derrotas e muitas tentativas ou poucas derrotas e muitas tentativas;
- Derrotas/tempo: *cluster* que busca cruzar as informações de derrota e tempo a fim de ver jogadores que estão inseridos em, por exemplo, um grupo de jogadores que tem muitas derrotas e muito tempo jogado ou poucas derrotas e muito tempo jogado.

4. Considerações Finais

Este trabalho teve como objetivo apresentar uma proposta de sistema computacional, dotado de um conjunto de ferramentas capazes de sistematizar a captura de dados em jogos educacionais. Em que o desenvolvedor, a partir do *game design* educacional, pode contar com um conjunto de facilidades, presentes no GLBoard, que permitem inserir GLA no jogo, sem precisar desenvolver um sistema específico. A partir dessa pesquisa espera-se fomentar mais trabalhos nas áreas de sistematização de GLA, criando modelos cada vez mais robustos e flexíveis.

O GLBoard foi utilizado somente pelos próprios desenvolvedores e por um pequeno grupo de pesquisadores que estão integrando o sistema aos seus jogos. Como trabalhos futuros, pretende-se: i) realizar avaliações desse conjunto de ferramentas, integrando a diferentes tipos de jogos, a fim de verificar quais tipos de jogos educacionais o modelo atende e quais dados podem ser obtidos e analisados; e, ii) a partir da utilização do sistema por outros desenvolvedores, analisar quais dados são mais utilizados e assim flexibilizar o modelo de captura de dados buscando atender mais tipos de jogos.

Referências

- Alencar, L., Melo, R., and Pessoa, M. (2020). Uma proposta de análise de dados exploratória para um jogo educacional de matemática.
- 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-Fernandez, C., Calvo-Morata, A., Freire, M., Martinez-Ortiz, I., and Fernández-Manjón, B. (2019). Applications of data science to game learning analytics data: A systematic literature review. *Computers & Education*, 141:103612.
- Barnes, T., Richter, H., Powell, E., Chaffin, A., and Godwin, A. (2007). Game2learn: building cs1 learning games for retention. In *Proceedings of the 12th annual SIGCSE conference on Innovation and technology in computer science education*, pages 121–125.
- Calderón, A. and Ruiz, M. (2015). A systematic literature review on serious games evaluation: An application to software project management. *Computers & Education*, 87:396–422.
- Calvo-Morata, A., Rotaru, D. C., Alonso-Fernández, C., Freire-Morán, M., Martínez-Ortiz, I., and Fernández-Manjón, B. (2018). Validation of a cyberbullying serious game using game analytics. *IEEE Transactions on Learning Technologies*, 13(1):186–197.
- Cano, A. R., Fernández-Manjón, B., and García-Tejedor, Á. J. (2016). Gload: Designing a game learning analytics model to analyze the learning process in users with intellectual disabilities. In *International Conference on Serious Games, Interaction, and Simulation*, pages 45–52. Springer.
- de Sousa Pires, F. G., da Silva Queroga, J., Pessoa, M. S. P., and Melo, R. (2018). A viagem: Um jogo para explorar o território brasileiro. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*, volume 29, page 705.

- 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.
- 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.
- Lima, T., Barradas Filho, A., Barros, A. K., Viana, D., Junior, J. B. B., and Rivero, L. (2020). Avaliando um jogo educacional para o ensino de inteligência artificial-qual metodologia para avaliação escolher? In *Anais do XXVIII Workshop sobre Educação em Computação*, pages 66–70. SBC.
- Melo, D., de Sousa Pires, F. G., Melo, R., and Júnior, R. J. d. R. S. (2018). Robô euroi: Game de estratégia matemática para exercitar o pensamento computacional. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*, volume 29, page 685.
- Melo, D., Melo, R., Bernardo, J. R. S., Pessoa, M., Rodríguez, L. C., and Pires, F. (2020a). Uma estratégia de game learning analytics para avaliar level design em um jogo educacional. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 622–631. SBC.
- Melo, R., Pessoa, M., Alencar, F., and Pires, F. (2020b). Uma proposta de análise de dados exploratória para um jogo educacional de matemática. pages 752–758.
- 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. (2020). *Handbook of game-based learning*. 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.
- Saveski, G. L., Westera, W., Yuan, L., Hollins, P., Manjón, B. F., Ger, P. M., and Stefanov, K. (2015). What serious game studios want from ict research: identifying developers' needs. In *International Conference on Games and Learning Alliance*, pages 32–41. Springer.
- Silva, D., Melo, R., Pires, F., and Pessoa, M. (2021). Avaliação de objetos digitais de aprendizagem: como os licenciados em computação analisam jogos educacionais? *RE-NOTE*, 19(2):111–121.
- Zapata-Cáceres, M. and Martín-Barroso, E. (2021). Applying game learning analytics to a voluntary video game: Intrinsic motivation, persistence, and rewards in learning to program at an early age. *IEEE Access*, 9:123588–123602.