

## **Utilização da Mineração de Dados Educacionais na Educação Infantil**

Gabriel Candido da Silva, Universidade de Pernambuco,  
gabcandidods@gmail.com, 0000-0002-7470-8613

Roberto Sá Barreto Paiva da Cunha, Universidade de Pernambuco,  
rsbpc@ecomp.poli.br, 0009-0006-1710-786

Rodrigo Lins Rodrigues, Universidade Federal Rural de Pernambuco,  
rodrigomuribec@gmail.com, 0000-0002-3598-5204

Alexandre Magno Andrade Maciel, Universidade de Pernambuco,  
alexandre.maciel@upe.br, 0000-0003-4348-9291

**Resumo:** Pesquisas recentes têm adotado medidas mais voltadas à demonstração de evidências coletadas em tempo real por meio de técnicas como Machine Learning e Deep Learning para avaliar o aprendizado adquirido pelos jogadores em Serious Games. No entanto, há poucos estudos que aplicam essas técnicas em jogos digitais educacionais voltados para a educação infantil. Assim, o objetivo deste estudo foi utilizar uma abordagem de Mineração de Dados para identificar diferentes perfis comportamentais em 26 jogos educacionais digitais, a fim de avaliar como diferentes alunos se beneficiaram da intervenção de leitura e escrita de palavras do aplicativo Escribo Play. O teste foi realizado com 351 alunos da educação infantil da rede pública de ensino e com isto foram identificados dois perfis comportamentais diferentes.

**Palavras-chave:** Jogos Educacionais, Mineração de Dados, Análise de Aprendizado, Identificação de Perfis Comportamentais, Educação Infantil

## **Use of Educational Data Mining in Early Childhood Education**

**Abstract:** Recent studies have been adopting measures more focused on demonstrating evidence collected in real time through techniques such as Machine Learning and Deep Learning to evaluate the learning acquired by players in Serious Games. However, there are few studies that apply these techniques in educational digital games aimed at early childhood education. Thus, the aim of this study was to use a Data Mining approach to identify different behavioral profiles in 26 digital educational games, in order to evaluate how different students benefited from the reading and writing intervention of words from the Escribo Play app. The test was conducted with 351 students from public early childhood education, and with this, two different behavioral profiles were identified.

**Keywords:** Educational Games, Data Mining, Learning Analytics, Identification of Behavioral Profiles, Childhood Education

## INTRODUÇÃO

A tecnologia é uma presença constante em nosso cotidiano e pode ser um recurso valioso para o processo de aprendizagem dos alunos. Além disso, ela oferece alternativas de atividades pedagógicas interessantes e eficazes por meio da exploração da tecnologia educacional (VALENTE, 1999). Dentre as opções de tecnologia educacional, os jogos digitais têm chamado cada vez mais a atenção devido ao seu alto poder de engajamento e imersão dos jogadores. Esses fatores tornam a produção de jogos um dos principais setores na indústria do entretenimento atualmente (FREIRE, 2016).

Os jogos digitais que possuem objetivos educacionais são denominados Serious Games (SG). Esses jogos têm um propósito que vai além do entretenimento, podendo ser utilizados para fins educacionais em escolas, treinamentos e simulações, em áreas como a medicina e a militar (ALONSO-FERNADEZ, 2019). No âmbito educacional, os Serious Games são considerados como uma alternativa para melhorar a experiência de aprendizagem em comparação aos métodos de ensino tradicionais (NIEMELÄ, 2020).

Embora haja evidências de que os Serious Games, por sua natureza lúdica, tenham efeitos positivos no aprendizado, ainda é escassa a comprovação da sua efetividade em ambientes educacionais, apesar de estudos estarem cada vez mais abordando a sua capacidade de motivar e engajar os estudantes (CANO, 2018). No entanto, devido à sua natureza digital, esses jogos representam uma excelente plataforma para a coleta de dados referentes à utilização e interação individual dos estudantes, permitindo análises relacionadas ao seu aprendizado (ALONSO-FERNADEZ, 2019).

As técnicas de ciência de dados aplicadas à educação podem ser categorizadas em Learning Analytics (LA) e Educational Data Mining (EDM). Embora ambas áreas tenham interesses semelhantes, a EDM adota uma abordagem mais técnica, buscando identificar novos padrões nos dados e criar algoritmos e modelos para compreender dados educacionais. Por outro lado, a LA concentra-se na descoberta de soluções educacionais, que requerem a integração entre abordagens técnicas e pedagógicas (ROMERO, 2020).

Dito isto, este trabalho possui o intuito de realizar uma aplicação de mineração de dados educacionais a fim de evidenciar como e o quanto uma intervenção pedagógica pode ser capaz de gerar diferentes níveis de ganhos de aprendizado, para identificar diferentes perfis comportamentais de alunos da educação infantil da rede pública de ensino, baseados em seus dados de interação com a plataforma de jogos educacionais da Escribo Play.

## JUSTIFICATIVA

O método mais comum para avaliar o aprendizado dos jogadores em um SG é o Estudo Randomizado Controlado, que utiliza um pré e pós-teste para medir a diferença entre o grupo experimental e o grupo de controle. No entanto, este método não leva em consideração o tempo de interação dos alunos com o jogo, que é um momento em que muitos dados de interação são gerados e podem ser analisados de forma automatizada para inferir o aprendizado dos estudantes de maneira mais precisa (ALONSO-FERNADEZ, 2020).

Para garantir a efetividade pedagógica dos jogos durante as atividades educacionais, é essencial coletar e analisar evidências científicas obtidas por meio do

uso desses jogos durante o processo de aprendizagem. Além disso, é fundamental evidenciar a efetividade da aplicação dos jogos na educação e fornecer um acesso fácil às informações sobre a interação dos estudantes com o jogo para avaliar o aprendizado adquirido pelo mesmo durante seu percurso. (CROOKALL, 2010; ALONSO-FERNADEZ, 2017).

Em geral, a utilização de jogos digitais na educação ainda requer uma padronização para assegurar a efetividade em seu desenvolvimento, validação e implementação nas escolas (LOH, 2015). Neste trabalho, pretendemos explorar uma intervenção educacional baseada no aplicativo Escribo Play, com a intenção de investigar sua abordagem e seus resultados, que demonstrou ganhos significativos em leitura e escrita para alunos da educação infantil na rede pública de ensino, através de um procedimento de pré e pós-teste (AMORIM, 2022).

Isto posto, declaramos que não fará parte do processo deste estudo o desenvolvimento de nenhum produto ou ferramenta de apoio pedagógico, se atendo apenas ao processo técnico pedagógico de execução e análise da abordagem de mineração de dados proposta.

## **CONTEXTO DA PESQUISA**

Esta pesquisa foi desenvolvida a partir dos dados coletados em um Estudo Randomizado Controlado que avaliou a eficácia de um conjunto de jogos do Escribo Play. Essa intervenção educacional compreende planos de aula, jogos digitais e suporte técnico para salas de pré-escola e jardim de infância usando dispositivos móveis de baixo custo. A intervenção completa foi entregue em 26 sessões que fornecem consciência fonológica baseada em evidências (sílaba, rima, aliteração, fonemas), leitura de palavras e instrução de escrita.

O Estudo Randomizado Controlado, realizado na pesquisa de (AMORIM, 2022), foi conduzido em uma região metropolitana do Nordeste do Brasil, em 12 centros de educação infantil públicas, que juntos disponibilizaram a participação de 351 estudantes do jardim de infância de cerca de 5 anos de idade. A primeira etapa desta intervenção envolveu a avaliação de todos estes estudantes a partir de um pré-teste, seguidos da divisão randômica das escolas e de suas classes em grupo experimental, que inclui 20 classes e 199 estudantes e grupo de controle, que abrange 20 classes e 152 estudantes.

Após a divisão em grupo experimental e controle, os alunos do grupo experimental passaram a utilizar um conjunto específico de jogos da plataforma Escribo Play. Este processo durou 13 semanas, com duas sessões de 40 minutos por semana, totalizando 26 encontros, onde para cada encontro era designado um plano de aula e um jogo que tinha como objetivo desenvolver as habilidades de leitura e escrita. Ao fim da intervenção com os jogos, o pós teste é executado com todos os alunos.

Cada um dos jogos jogados pelos alunos possui uma coleta automática de dados relacionada a quantidade de visualizações, acertos e erros cometidos durante sua utilização. Dito isto, ressaltamos que os dados utilizados neste estudo são dados secundários coletados ao longo destas 13 semanas de intervenção, sendo assim, dados já validados e publicados a partir de uma pesquisa (AMORIM, 2022).

## **MATERIAIS E MÉTODOS**

A Escribo - Inovação para o aprendizado forneceu uma base de dados que relaciona alunos de Escolas Públicas que jogaram os jogos educacionais pertencentes a

empresa. A base fornecida consiste em 94 atributos, dos quais utilizaremos especialmente 78 deles, que representam o número de visualizações, acertos e erros em cada um dos 26 jogos diferentes, ou seja, dados de interação direta com a plataforma. O quadro abaixo relaciona as demais colunas da base de dados.

Após a seleção da base de dados foi iniciado a etapa de pré-processamento, onde foi realizada a redução horizontal de dados que consistiu na remoção de registros da base de dados. Foram removidos da análise alunos que não jogaram nenhum jogo ou que não tinham nenhum número de visualizações. Feito isto, realizamos uma transformação nos dados das colunas referentes aos números de visualizações, acertos e erros em cada jogo. Essas colunas tinham valores definidos como “NA - Not Applicable”. Esses valores “NA” nas colunas dos jogos demonstram que o aluno não teve visualizações ou acertos ou erros no jogo em questão, portanto os valores “NA” foram substituídos pelo valor zero nas colunas de atributos dos jogos.

**Tabela 1** - Atributos da base de dados

<b>Nome</b>	<b>Descrição</b>
Index	Identificador do Aluno
School	Código da Escola
Turma	Código da Turma
Experimental	Identificador do grupo do aluno (0: Controle; 1: Experimental)
Pre_Reading_c1	Nota do pré-teste de leitura
Pre_Writing_c1	Nota do pré-teste de escrita
Post_Reading_c1	Nota do pós-teste de leitura
Post_Writing_c1	Nota do pós-teste de escrita
Views	Número de visualizações em todos os jogos
Correct	Número de acertos em todos os jogos
Wrong	Número de erros em todos os jogos
Net	Diferença entre acertos e erros em todos os jogos
NetView	Divisão entre a coluna Net pela coluna Views
GainR	Diferença entre o pré e pós teste de leitura
GainW	Diferença entre o pré e pós teste de escrita

Com a base devidamente tratada, demos início a metodologia experimental da pesquisa que abrange as seguintes etapas: (1) Identificação de Grupos de Alunos, (2) Avaliação das Diferenças entre os Grupos e (3) Avaliação da Eficácia da Intervenção por Grupo.

Na etapa inicial do experimento, utilizou-se a técnica de análise de agrupamento. A análise envolve a formação de grupos de indivíduos ou objetos, com o critério de que os membros de um grupo devem estar próximos uns dos outros, enquanto os membros de grupos diferentes devem estar distantes entre si, baseando-se apenas nas informações presentes nos dados. (HAIR, 2009). Dentre os diversos algoritmos de agrupamento disponíveis, optou-se pelo k-means para esta análise, o qual é amplamente utilizado para particionar um conjunto de dados em um número k de grupos. (HOU, 2011).

Uma seleção restrita de atributos de dados foi realizada, com o objetivo de representar os atributos mais relevantes para a utilização do aplicativo Escribo Play. A

escolha desses atributos foi baseada na avaliação da tendência de agrupamento utilizando o método estatístico Hopkins. Esse método estima a probabilidade de um determinado conjunto de dados gerar uma distribuição uniforme (KASSAMBARA, 2017).

Uma vez selecionados os atributos representativos, a única exigência para executar o método k-means foi a definição do valor k, que é o número de grupos formados pela técnica. Para auxiliar na decisão sobre o número de grupos, utilizou-se o método *Elbow*, que visa determinar o número ideal de grupos para minimizar a variação total intra-grupos. Após essa etapa, o método k-means foi aplicado.

A segunda etapa do experimento consistiu na avaliação da significância das diferenças entre os grupos gerados. O objetivo dessa etapa foi compreender as influências distintas dos clusters no ganho de leitura e escrita. Como havia dois alvos de interesse (*Reading\_Gain* e *Writing\_Gain*), a análise foi conduzida em duas etapas separadas: inicialmente, foi realizada uma análise para avaliar o ganho na leitura e, posteriormente, foi realizada a análise do ganho na escrita.

O teste de Kruskal-Wallis foi utilizado para avaliar e compreender as diferenças entre os grupos gerados neste estudo. Trata-se de uma versão não-paramétrica da ANOVA de uma via. (MCKIGHT, 2010). No teste de Kruskal-Wallis, a hipótese nula ( $H_0$ ) é considerada verdadeira quando as medianas dos grupos são iguais ( $p\text{-valor} > 0,05$ ). Nesse caso, não há diferenças significativas entre os grupos. Já a hipótese alternativa ( $H_1$ ) é considerada verdadeira quando as medianas dos grupos são diferentes entre si ( $p\text{-valor} < 0,05$ ), o que indica a presença de diferenças significativas entre os grupos.

Após a realização do teste de Kruskal-Wallis, foi conduzido um teste post-hoc. O teste escolhido para este estudo foi o Teste de Dunn com ajuste do p-valor, que é apropriado para fazer inferências simultâneas entre as populações, fornecendo resultados moderados e consistentes. (ELLIOTT, 2011). A partir desses resultados, foram realizadas análises descritivas para comparar os clusters, gerar gráficos e compreender sua distribuição.

Por fim, na terceira e última etapa, ocorre a avaliação da eficácia da intervenção em cada grupo. A principal métrica utilizada para comparar os experimentos é o tamanho do efeito (*effect-size*). Quanto maior o tamanho do efeito, maior é o ganho na aprendizagem dos alunos em comparação com os alunos do grupo controle.

Para avaliar o tamanho do efeito específico de cada cluster encontrado na etapa anterior, foram geradas as médias e desvios padrão do pré e pós-teste. Com esses valores, foi possível calcular o tamanho do efeito para cada cluster do grupo experimental em relação ao grupo controle, mesmo para grupos com amostras desiguais (LENHARD, 2016). A partir desses resultados, será possível interpretar cada grupo encontrado no processo de análise de agrupamento como um perfil comportamental distinto.

## RESULTADOS E DISCUSSÕES

Antes de realizar o agrupamento, foi aplicado o método estatístico Hopkins para determinar qual conjunto de atributos é mais determinante na comparação dos indivíduos. Para isso, foram utilizadas as possíveis combinações dos atributos que representam erros, acertos e visualizações em todos os 26 jogos. A Tabela 2 mostra o resultado.


Na Tabela 2, a letra 'V' representa as 26 colunas de visualizações nos jogos, 'W' são os erros e 'R' são os acertos. É possível notar que os atributos de erros nos jogos são

os que mais influenciaram para aproximar o valor estatístico de 0. Isso pode ser notado pela diferença entre as combinações “V + R” e “V + W” ou o conjunto de atributos isolados. De acordo com este resultado, optou-se por seguir a análise de cluster utilizando apenas os atributos relacionados aos erros nos jogos, representados pela combinação “W” na tabela, por ser a que mais se aproximou de 0 e, conseqüentemente, aquela que melhor distingue os alunos nos agrupamentos.

**Tabela 2** - Estatística Hopkins para cada conjunto de atributos de interação.

Variáveis	Leitura	Escrita
V + R + W	0.212	0.205
V + R	0.225	0.215
V + W	0.209	0.203
R + W	0.202	0.195
V	0.242	0.230
R	0.226	0.212
W	0.179	0.171

Em seguida, com o conjunto de dados contendo os atributos de erros nos 26 jogos, o método Elbow foi utilizado para definir o número ideal de clusters. Ele gera um gráfico, mas a definição é ambígua. Deve-se apontar onde está o ”cotovelo”, partindo da ideia de que se deve escolher o ponto em que se percebe que qualquer valor maior não tem diferença relevante.



**Figura 1** - Gráficos gerados pelo método Elbow. Leitura (esquerda); Escrita (direita).

Ao analisar a Figura 1, fica evidente que em ambos os gráficos acontece uma queda nos valores iniciais, passando de 1 para 3. A queda deixa de ser relevante a partir deste valor, pois a distorção/inércia passa a diminuir linearmente, formando assim o ”cotovelo” procurado. Portanto, indica-se que o número ideal de clusters sugerido pelo método Elbow é de 3 clusters. Após esta aplicação, entendeu-se que o valor de k mais indicado, o número de clusters, é o número 3, e este foi o valor utilizado para gerar os clusters com o algoritmo k-means.

Com os clusters já definidos, buscou-se entender o quão significativa é a diferença entre eles. Para isso, foi utilizado o teste de Kruskal-Wallis para o grupo de leitura e escrita, conforme apresentado na Tabela 3.

**Tabela 3** - Dados gerados pelo teste de Kruskal-Wallis.

<b>Grupo</b>	<b>Qui-quadrado</b>	<b>Graus de Liberdade</b>	<b>p-valor</b>
Leitura	6.1777	2	0.0455
Escrita	7.1277	2	0.0283

É perceptível que ambos os grupos possuem valores abaixo de 0,05 em seu p-valor. Isso significa que foi identificada diferença relevante entre os clusters em ambos os grupos. Após isso, foi observado o quão relevantes são as diferenças, comparando cluster por cluster com o teste de Dunn.

Mesmo com diferentes dispersões, os demais agrupamentos não foram suficientes para influenciar o teste de Dunn, o que mostra que as distribuições apresentam considerável proximidade. Por fim, a partir dos valores de média, desvio padrão e quantidade de indivíduos, foi calculado o tamanho do efeito de cada cluster para evidenciar a existência de clusters mais ou menos propícios ao efeito da intervenção.

**Tabela 4** - Tamanho do efeito de cada cluster em leitura e escrita.

<b>Grupo</b>	<b>Cluster 1</b>	<b>Cluster 2</b>	<b>Cluster 3</b>
Leitura	0.48	7.5	1.11
Escrita	0.19	-0.3	1.59

Com base na Tabela 4 podemos atestar que, o Cluster 1 de leitura, que contém 38 alunos e uma taxa de evasão baixa, parecem representar alunos com o efeito esperado, próximo do valor do grupo como um todo (0.48 vs 0.67), enquanto o cluster 3, ainda no grupo de leitura, que contém 81 alunos, uma taxa de evasão alta e quantidade de erros mais baixa entre os grupos, obtiveram um efeito alto, quando comparado ao do grupo geral, de 1.11, Já o cluster 2 de leitura, bem como o cluster 3 de escrita, parecem representar os outliers, que obtiveram os efeitos mais altos 7.50 e 1.59 respectivamente. Porém, no grupo de escrita é possível notar que os efeitos dos cluster 1 e 2, são bem menores que o da intervenção geral para essa categoria (0.36), tendo o cluster 2 um efeito negativo.

Dito isto, procuramos investigar mais sobre as características que representam estes clusters encontrados, analisando como se dá a distribuição das visualizações, acertos e erros cometidos no decorrer dos jogos por cluster e entendemos que os clusters encontrados representam os seguintes perfis:

- **Perfil 1:** Formado pelo Cluster 1 do grupo de Leitura (n = 38), representa o grupo de alunos que conseguiram aproveitar adequadamente a intervenção, obtendo uma baixa taxa de evasão no decorrer dos encontros e um tamanho de efeito próximo do efeito geral (0.48 vs 0.67), esse padrão também é demonstrado pelo Cluster 2 do grupo de Escrita (n = 28), no entanto, mesmo obtendo uma taxa de evasão baixa, e uma taxa de erros parecida com a do perfil equivalente em leitura, obteve um efeito negativo, de -0,3. O que mostra uma diferença significativa quando comparamos um mesmo comportamento em domínios diferentes (Leitura e Escrita).

- **Perfil 2:** Se refere ao Cluster 3 do grupo de Leitura, é o cluster com a maior quantidade de alunos ( $n = 81$ ), uma taxa de evasão alta, e uma taxa de erros bem menor que os do Perfil 1 nos últimos jogos devido justamente a quantidade menor de participantes ao final da intervenção. Este mesmo perfil se repete no Cluster 1 de Escrita ( $n = 104$ ), que concluíram a intervenção com um efeito próximo do efeito geral do grupo de escrita (0.19 vs 0.36).

É importante destacar que a partir das análises da quantidade de erros e visualizações, entendemos que o Perfil 2, mesmo obtendo um bom efeito em leitura e escrita, parece reunir 2 tipos diferentes de alunos, aqueles alunos que participaram da intervenção do início ao fim e obtiveram um bom efeito de aprendizado em decorrência disso e aqueles que abandonaram a intervenção no decorrer do tempo e foram erroneamente agrupados em conjunto com os demais.

Essa combinação de dois grupos de características diferentes provavelmente ocorreu devido ao fato de que os alunos que param de frequentar a intervenção obtêm consequentemente valores NA em erros, que foram substituídos por 0, e acabam sendo agrupados pelo algoritmo com alunos que erram pouco, pois os dados de interação utilizados foram apenas os de erros.

Também destacamos que a ausência de referência aos clusters 2 de leitura e 3 de escrita na representação dos perfis se dá pelo fato de acreditarmos que são *outliers*, ou seja, que se diferenciam demais dos outros grupos, pois ambos os clusters têm respectivamente apenas 2 e 3 alunos no seu grupo, o que tornaria qualquer avaliação ou julgamento enviesado, mas mais uma vez, destacamos a similaridade na formação dos grupos tanto para leitura quanto para escrita.

## CONSIDERAÇÕES FINAIS

Com base nas avaliações realizadas, concluímos que seria possível implementar medidas de apoio para melhorar o desempenho dos alunos com baixo desempenho. Ao analisar a quantidade de erros por jogo, observamos que mesmo os grupos com baixo desempenho não cometeram erros nos segundos jogos de aliterações e rimas. Essa falta de erros sugere que as crianças já dominaram as habilidades e dificuldades apresentadas por esses jogos. Com base nessa descoberta, é possível considerar a remoção desses jogos da sequência instrucional ou a substituição por novos jogos para promover a consciência fonêmica.

De maneira geral, percebeu-se que a intervenção poderia ser aprimorada por meio de um mecanismo de personalização. Acompanhando o desempenho dos alunos, seria possível fornecer estímulos adicionais ou personalizados durante os pontos críticos de transição da intervenção. Alunos que não dominaram determinada habilidade, como a consciência fonêmica, poderiam receber mais estímulos antes de avançar para o próximo domínio, como a leitura e escrita de palavras.

Em relação às limitações do nosso estudo, é importante destacar que o processo executado e os resultados obtidos referem-se a um único banco de dados composto por 121 alunos para a análise em leitura e 135 para a análise em escrita, além da evasão dos alunos do decorrer da intervenção, o que prejudica uma análise quantitativa devido a baixa quantidade de sujeitos na amostra. Estudos futuros podem realizar análises semelhantes com outras intervenções baseadas em jogos ou até mesmo com o *Escrevo Play*, mas com um acompanhamento mais rigoroso, a fim de garantir que uma quantidade adequada de alunos participem da intervenção do início ao fim.



Estudos anteriores a este, como o de Silva, et al. (2022), já evidenciaram que a metodologia aqui aplicada é adequada quando temos uma garantia da quantidade constante de participantes do início ao fim da intervenção e que efeitos de aprendizado maiores podem ser obtidos quando há um maior envolvimento das escolas e dos participantes, ou seja, para atingir os objetivos esperados, além da melhoria contínua da plataforma, também é importante o engajamento de todos os envolvidos com a aplicação do experimento.

Por fim, entendemos que o estudo demonstrou que a articulação entre instrumentos de avaliação neuropsicológica, a mineração de dados, que coleta dados procedimentais, a melhoria contínua da intervenção educativa e o envolvimento dos membros constituintes do meio educacional são pilares essenciais para o fortalecimento de processos de aprendizagem envolvendo aplicações tecnológicas, podendo assim reduzir as desigualdades educacionais que afetam os alunos desde a pré-escola.

## REFERÊNCIAS BIBLIOGRÁFICAS

ALONSO-FERNÁNDEZ, C. et al. Applications of data science to game learning analytics data: A systematic literature review. **Computers & Education**, v. 141, p. 103612, 2019.

ALONSO-FERNÁNDEZ, C. et al. Evidence-based evaluation of a serious game to increase bullying awareness. **Interactive Learning Environments**, p. 1-11, 2020.

ALONSO-FERNANDEZ, C. et al. Systematizing game learning analytics for serious games. In: **2017 IEEE global engineering education conference (EDUCON)**. IEEE, 2017. p. 1111-1118.

AMORIM, A. N. et al. Escribo play learning games can foster early reading and writing for low-income kindergarten children. **Computers & Education**, v. 177, p. 104364, 2022.

CANO, A. R.; FERNÁNDEZ-MANJÓN, B.; GARCÍA-TEJEDOR, A. J. Using game learning analytics for validating the design of a learning game for adults with intellectual disabilities. **British Journal of Educational Technology**, v. 49, n. 4, p. 659-672, 2018.

CROOKALL, David. Serious games, debriefing, and simulation/gaming as a discipline. **Simulation & gaming**, v. 41, n. 6, p. 898-920, 2010.

DA SILVA, G. C. et al. Game learning analytics can unpack Escribo play effects in preschool early reading and writing. **Computers and Education Open**, v. 3, p. 100066, 2022.

ELLIOTT, A. C.; HYNAN, L. S. A SAS® macro implementation of a multiple comparison post hoc test for a Kruskal–Wallis analysis. **Computer methods and programs in biomedicine**, v. 102, n. 1, p. 75-80, 2011.

FREIRE, M. et al. Game learning analytics: learning analytics for serious games. In: **Learning, design, and technology**. Springer Nature Switzerland AG, 2016. p. 1-29.

HAIR, J. F. et al. **Análise multivariada de dados**. Bookman editora, 2009.

HOU, H.. A case study of online instructional collaborative discussion activities for problem-solving using situated scenarios: An examination of content and behavior cluster analysis. **Computers & education**, v. 56, n. 3, p. 712-719, 2011.

KASSAMBARA, A. **Practical guide to cluster analysis in R: Unsupervised machine learning**. Sthda, 2017.

LENHARD, W. & LENHARD, A. (2016). Computation of effect sizes. Retrieved from: [https://www.psychometrica.de/effect\\_size.html](https://www.psychometrica.de/effect_size.html). **Psychometrica**.

LOH, C. S.; SHENG, Y.; IFENTHALER, D. Serious games analytics: Theoretical framework. In: **Serious games analytics**. Springer, Cham, 2015. p. 3-29.

MCKIGHT, P. E.; NAJAB, J.. Kruskal-wallis test. **The corsini encyclopedia of psychology**, p. 1-1, 2010.

NIEMELÄ, M. et al. Game learning analytics for understanding reading skills in transparent writing system. **British Journal of Educational Technology**, v. 51, n. 6, p. 2376-2390, 2020.

ROMERO, C.; VENTURA, S.. Educational data mining and learning analytics: An updated survey. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 10, n. 3, p. e1355, 2020.

VALENTE. J. A. Formação de professores: Diferentes abordagens pedagógicas. Campinas, SP: UNICAMP/NIED, 1999.