



Universidade Federal Rural de Pernambuco – UFRPE
Pró-Reitoria de Pesquisa e Pós-Graduação – PRPPG
Programa de Pós-Graduação em Ensino das Ciências e Matemática – PPGEC

Gabriel Candido da Silva

Uma Abordagem de Game Learning Analytics para Identificação de Perfis Comportamentais na Utilização de Jogos Educacionais

Recife

2022

Gabriel Candido da Silva

**Uma Abordagem de Game Learning Analytics para
Identificação de Perfis Comportamentais na Utilização de
Jogos Educacionais**

Dissertação apresentada ao Programa de Pós-Graduação em Ensino das Ciências e Matemática da Universidade Federal Rural de Pernambuco, como requisito para a obtenção do título de Mestre em Ensino das Ciências e Matemática.

Orientador: Prof. Dr. Rodrigo Lins Rodrigues
Coorientador: Prof. Dr. Amadeu Sá de Campos Filho

Recife

2022

Dedico este trabalho a minha mãe:
Marinete Severina de Souza.
E minha tia Aurea Maria Barbosa de Lima.

Agradecimentos

Gostaria de agradecer a minha mãe Marinete Severina de Souza e minha tia Aurea Maria Barbosa de Lima, que se mostraram presentes o tempo todo, demonstrando o apoio e a atenção de sempre. Agradeço muito também ao apoio de todos os meus familiares e aos professores que tive ao passar dos anos, pois foram eles os responsáveis por tornar possível o meu caminho até aqui.

Aos meus amigos, que sempre estiveram presentes em minha vida, mesmo em tempos de pandemia e aos meus colegas de mestrado e integrantes do grupo de pesquisa, que me trouxeram momentos muito divertidos e ricos, em especial à Anderson Gusmão que embarcou nessa busca pela obtenção do título de mestre no mesmo período que eu, e sempre se mostrou disponível para tirar dúvidas e auxiliar nos processos e dificuldades inerentes ao período de formação.

Aos professores do PPGECC, pelos conhecimentos compartilhados, em especial ao meu orientador Rodrigo Lins, que soube entender minhas dificuldades e, com paciência e dedicação, me orientou em todos os momentos que foram necessários para que eu pudesse estar sempre motivado e desse o meu melhor no caminhar deste trabalho.

Devo também agradecimentos a Américo Amorim, que é o responsável pela Escribo, empresa que desenvolve e comercializa os jogos utilizados nesta pesquisa e ao meu co-orientador Amadeu Campos, essenciais para a construção deste trabalho. Agradeço também a banca avaliadora: Charles Madeira e Vladimir Andrade, pela leitura, discussão e contribuição nesta pesquisa.

Sou muito agradecido a todos aqueles que, direta ou indiretamente, colaboraram para que este trabalho chegasse a atingir a sua forma atual. Quero que saibam que este trabalho é um resultado do esforço de todos nós.

*"A melhor maneira de viver a vida é sendo
uma criança, não importa qual a sua idade."
(Gintoki Sakata)*

Resumo

Atualmente, pesquisas que buscam realizar avaliações do aprendizado adquirido pelos jogadores a partir de um Serious Game, vêm adotando medidas mais voltadas à demonstração de evidências coletadas em tempo real, a partir de técnicas como as das áreas de Machine Learning e Deep Learning. No entanto, são escassas as pesquisas que buscam realizar este tipo de avaliação e técnicas em Serious Games para a educação infantil. Dito isto, este estudo buscou aplicar uma abordagem de Game Learning Analytics que possui dois objetivos complementares: 1) Identificar padrões comportamentais; 2) Predizer o efeito de aprendizado adquirido. Para isto, esta pesquisa utilizou dados coletados de 20 jogos digitais educacionais para avaliar como diferentes alunos se beneficiaram da intervenção de leitura e escrita de palavras do aplicativo Escribo Play durante um teste com 749 alunos da pré-escola. Para identificação dos perfis comportamentais, foi realizada uma análise de agrupamento para formação de grupos, o método Kruskal-Wallis para entender se há diferenças entre os grupos e o cálculo do effect-size, para revelar o quão diferentes eles são. Para a predição do efeito de aprendizado, 4 algoritmos de classificação foram treinados e validados a partir do conjunto de combinações das variáveis de interação coletadas nos jogos. A partir do processo da análise de agrupamento, foram identificados três padrões comportamentais que apresentam desempenhos distintos: O perfil 1, com maior número de alunos, que apresentou o desempenho esperado para esta intervenção; o perfil 2, que apresentou o maior effect-size, sendo um referencial de engajamento com esta intervenção; e o perfil 3, que foi formado por dois grupos, que devido ao pequeno effect-size, parecem representar crianças que ainda não estavam prontas para se beneficiarem da intervenção educativa. No processo de treinamento e validação dos algoritmos de classificação, obtivemos como melhores resultados uma Acurácia de 74% e Precisão de 81%, na classificação do desempenho dos estudantes, resultados estes que estão dentro do esperado para o contexto da educação infantil. Como fruto dos resultados obtidos nestes experimentos, descobrimos que a melhor forma de diferenciar os alunos entre si, é através das características de interação que representam os erros cometidos durante a utilização destes jogos. Mesmo sendo notável uma carência de estudos que abordam a educação infantil, os resultados aqui demonstrados se mostram promissores, e evidenciam que é possível pesquisarmos e explorarmos ainda mais a utilização de técnicas de Game Learning Analytics neste contexto.

Palavras-chave: Jogos Educacionais, Análise de Aprendizado, Identificação de Perfis Comportamentais

Abstract

Currently, research that seeks to evaluate the learning acquired by players from a Serious Game has been adopting measures to demonstrate evidence collected in real-time, using techniques such as those in the areas of Machine Learning and Deep Learning. However, few studies seek to carry out this type of evaluation and techniques in Serious Games for early childhood education. That said, this study sought to apply a Game Learning Analytics approach that has two complementary objectives: 1) Identify behavioral patterns; 2) Predict the acquired learning effect. For this purpose, this research employed data collected by digital games to assess how different students benefited from the Escribo Play word reading and writing intervention during a trial with 749 preschool students. For behavioral profiles identification, a cluster analysis was performed to form groups, the Kruskal-Wallis method to understand if there are differences between the groups and the Effect Size, to reveal how different they are. For the prediction of the learning effect, 4 classification algorithms were trained and validated from the set of combinations of interaction variables collected in the games. From the cluster analysis process, three behavioral profiles were identified that present different performances: Profile 1, with the largest number of students, presented the expected performance for this intervention; profile 2 presented the largest effect-size, being a reference for engagement with this intervention; and profile 3, which was formed by two groups, which due to the small effect-size, seem to represent children who were not yet ready to benefit from the educational intervention. In the process of training and validating the classification algorithms, we obtained as best results an Accuracy of 74% and Precision of 81%, in the classification of student performance, results that are within the expected for the context of early childhood education. As a result obtained in these experiments, we found that the best way to differentiate students from each other is through the interaction characteristics that represent the errors made during the use of these games. Even though there is a notable lack of studies that address early childhood education, the results shown here are promising and indicate that it is possible to research and further explore the use of Game Learning Analytics techniques in this context.

Keywords: Serious Games, Learning Analytics, Identification of Behavioral Profiles

Lista de ilustrações

Figura 1 – Fluxograma de definição de um Serious Game.	18
Figura 2 – Modelo de fluxo em uma proposta de <i>Game-Based Learning</i>	19
Figura 3 – Principais áreas relativas à EDM/LA	21
Figura 4 – Processo de descoberta de conhecimentos em EDM/LA.	22
Figura 5 – Modelo de LA aplicado a jogos.	23
Figura 6 – Modelo estrutural de Game Learning Analytics.	25
Figura 7 – Processo de seleção de estudos do mapeamento sistemático.	28
Figura 8 – Tela de seleção de jogo do <i>Escribo Play</i>	34
Figura 9 – Fluxo do Estudo Randomizado Controlado	36
Figura 10 – Jogos que trabalham habilidades relacionadas a Sílabas.	37
Figura 11 – Jogos que trabalham habilidades relacionadas a Rimas e Aliterações.	37
Figura 12 – Jogos que trabalham habilidades relacionadas a Fonemas.	38
Figura 13 – Jogos que trabalham habilidades relacionadas a Leitura e Escrita.	40
Figura 14 – Fluxograma do método proposto no estudo.	42
Figura 15 – Quantidade de valores faltantes nas variáveis.	48
Figura 16 – Valor médio de erros cometidos por jogo.	49
Figura 17 – Valor médio de visualizações de tela por jogo.	50
Figura 18 – Gráfico gerado pelo método <i>Elbow</i>	51
Figura 19 – Quantidade de erros no jogos por <i>Cluster</i>	53
Figura 20 – Curva ROC para os 4 classificadores utilizados.	57

Lista de tabelas

Tabela 1 – Quantidade de trabalhos incluídos e excluídos por ano.	29
Tabela 2 – Fenômenos educacionais dos estudos selecionados	29
Tabela 3 – Algoritmos ou Técnicas utilizadas nos estudos selecionados	30
Tabela 4 – Nível educacional e quantidade de participantes dos estudos	32
Tabela 5 – Descrição das variáveis coletadas	41
Tabela 6 – Combinações das variáveis de interação dos Jogos.	46
Tabela 7 – Descrição das Métricas dos Modelos de Classificação.	47
Tabela 8 – A estatística Hopkins para cada conjunto de atributos usados.	51
Tabela 9 – Dados gerados pelo teste de Kruskal-Wallis.	52
Tabela 10 – Dados gerados pelo teste de Dunn.	52
Tabela 11 – Médias, desvios padrão e quantidade de participantes por <i>cluster</i>	54
Tabela 12 – Tamanho do efeito de cada <i>cluster</i> em leitura e escrita.	55
Tabela 13 – Melhores resultados obtidos pelas técnicas de classificação.	56

Lista de abreviaturas e siglas

SG	Serious Games
GBL	Game-Based Learning
DGBL	Digital Game-Based Learning
EDM	Educacional Data Mining
LA	Learning Analytics
GA	Game Analytics
GLA	Game Learning Analytics
GLM	Generalized Linear Model
SVM	Support Vector Machine
AUC	Area Under the Curve

Sumário

	Lista de ilustrações	7
1	INTRODUÇÃO	12
1.1	Justificativa	13
1.2	Objetivos	14
1.3	Estrutura da Dissertação	15
2	JOGOS DIGITAIS PARA O APRENDIZADO	16
2.1	O Uso de Serious Games como Proposta Pedagógica	17
2.2	O Processo de Aprendizagem Baseado em Jogos Digitais	18
3	A CIÊNCIA DE DADOS PARA A ANÁLISE DO APRENDIZADO .	21
3.1	Análise de Aprendizado em Serious Games	23
3.2	Como as Pesquisas vêm Buscando Avaliar o Aprendizado?	25
4	TRABALHOS RELACIONADOS	27
4.1	Processo de Seleção dos Estudos	28
4.2	Que fenômenos educacionais as pesquisas buscam analisar?	29
4.3	Quais técnicas são usadas para analisar os dados coletados?	30
4.4	Qual o nível educacional e tamanho da amostra?	31
4.5	Lacunas Identificadas em Trabalhos de GLA	32
5	MÉTODO	34
5.1	Implementação da Intervenção de Leitura e Escrita	35
5.2	Descrição dos Jogos Utilizados na Pesquisa	36
5.3	Abordagem de Game Learning Analytics	40
5.4	Análise Exploratória dos Dados	41
5.5	Processo de Identificação de Perfis Comportamentais	43
5.5.1	Execução da Análise de Agrupamento	43
5.5.2	Descoberta de Diferenças Entre os Grupos	44
5.5.3	Cálculo do Tamanho do Efeito por Grupo	45
5.6	Processo de Predição do Desempenho Adquirido	45
5.6.1	Construção do Modelo de Predição	46
6	RESULTADOS	48
6.1	Identificação de Perfis Comportamentais	50
6.1.1	Execução da Análise de Agrupamento	50

6.1.2	Descoberta de Diferenças Entre os Grupos	52
6.1.3	Cálculo do Tamanho do Efeito por Grupo	54
6.2	Predição do Efeito de Aprendizado	55
6.2.1	Aplicação das Técnicas de Classificação	55
6.2.2	Validação dos Melhores Modelos Alcançados	57
7	IMPLICAÇÕES EDUCACIONAIS	59
7.1	Diferenças no Desempenho entre os Clusters	59
7.2	Modelos de Classificação mais Relevantes	60
8	CONSIDERAÇÕES FINAIS	63
9	PRODUÇÃO CIENTÍFICA CONSTRUÍDA A PARTIR DESTA DIS- SERTAÇÃO	65
	REFERÊNCIAS	67

1 Introdução

A produção de jogos digitais já constitui uma das maiores indústrias no ramo do entretenimento, e todo esse poder que os jogos possuem no engajamento e imersão dos jogadores chamam bastante atenção (FREIRE et al., 2016). Essas características que são inerentes aos jogos têm despertado o interesse de pesquisadores de diversas áreas do conhecimento, que buscam compreender e aplicar o uso de suas características nas mais variadas áreas, inclusive na educação.

Atualmente, é perceptível que os jogos fazem parte do dia a dia da maioria dos estudantes, portanto, é importante entendermos como esta tecnologia pode ajudar no processo de ensino e aprendizagem (MAGRO; JUNIOR, 2015). De acordo com Rolim (2013), o ensino por meio de jogos em um ambiente escolar pode contribuir no desenvolvimento cognitivo dos estudantes a partir de algo prazeroso, transformando assim essa tecnologia numa importante aliada da educação.

Surgem cada vez mais estudos que buscam evidenciar que os jogos digitais podem ser reconhecidos como uma categoria de tecnologias que contribui para a educação. Entendendo esses benefícios e visando unir jogos e educação que surge o termo *Serious Game* (SG), aplicado para jogos que são criados sem o entretenimento como objetivo principal, mas com a intenção de uso sério em treinamento, educação, ou cuidados de saúde, podendo também incluir jogos criados para promover um produto, um serviço ou uma empresa (MICHAEL; CHEN, 2005).

A partir desse contexto, o seguinte questionamento surge: "Como podemos garantir a efetividade pedagógica desses jogos durante as atividades educacionais?". De acordo com Crookall (2010), para que a proposta de uso de um SG, como ferramenta de aprendizado seja legitimada pelas autoridades educacionais, é essencial a extração de evidências científicas através de um processo de coleta e análise de informações obtidas por meio do uso desses jogos durante os processos de aprendizagem.

O campo de estudo que engloba o desenvolvimento e uso de ferramentas e processos para extrair e avaliar estas informações obtidas através de dados é o da Ciência de Dados. A utilização de suas técnicas já vem se espalhando para as mais diversas áreas, e na educação temos os campos da *Learning Analytics* (LA) e da *Educational Data Mining* (EDM), áreas que buscam analisar o comportamento e ações dos estudantes para entender e melhorar o processo de aprendizado através da análise e interpretação de dados.

Quando se utiliza dos objetivos educacionais da área de *Learning Analytics* aplicadas à um *Serious Game*, uma nova área de estudo surge, intitulada *Game Learning*

Analytics, ou apenas GLA. De acordo com [Alonso-Fernández et al. \(2019\)](#), esta área de estudo é definida como a coleta, análise e extração de informação de dados obtidos através de *Serious Games*. A GLA, também se aproveita das contribuições vindas da *Game Analytics* (GA), que a indústria de jogos (para entretenimento) utiliza para encontrar erros, entender o comportamento dos jogadores e melhorar a jogabilidade de maneira geral ([DRACHEN; EL-NASR; CANOSSA, 2013](#)).

Diferentes categorias de análises podem ser feitas a partir da utilização das técnicas de GLA, desde uma avaliação do impacto educacional de um SG, à validação de seu design. Em especial, essa área possui uma grande capacidade de contribuir para a comparação e contrastação de resultados educacionais obtidos por diferentes grupos. Estes grupos podem ser formados por diferentes fatores, como situações socioeconômicas, diferenças culturais e até mesmo perfis de jogo (o que inclui hábitos e comportamentos dos jogadores), entre outros ([FREIRE et al., 2016](#)).

É evidente que a partir das características que constituem o uso de GLA aqui descritas, novos caminhos se abrem para diferentes tipos de análises. Os seus métodos já são reconhecidos por possuírem um potencial considerável na criação de novas perspectivas didáticas e práticas de ensino, se mostrando como um meio para a criação de ferramentas que auxiliem professores na identificação de comportamentos e interação dos estudantes.

1.1 Justificativa

Entendemos que as pesquisas educacionais que buscam identificar uma eficácia no processo de ensino a partir de uma intervenção são normalmente aplicadas em ambientes complexos, e devido a isso tem sido cada vez mais reconhecido que além de entender se foi eficaz, é importante entender como essa eficácia aconteceu, examinando o quão sensíveis são os efeitos desta implementação, para assim entender as contribuições educacionais, tanto do ponto de vista teórico como prático ([DESIMONE; HILL, 2017](#)).

Evidenciar a efetividade da aplicação de jogos na educação, providenciando acesso facilitado à informações referentes a interação dos estudantes com o jogo é essencial para a avaliação do aprendizado adquirido pelo mesmo através de seu percurso e, devido as características inerentes a esses jogos, que podem ser entendidos como um ambiente de grande atividade interativa digital, se torna ideal uma aplicação de LA para descoberta de informações nesse processo ([ALONSO-FERNANDEZ et al., 2017](#)).

No entanto, no trabalho de [Juhaňák, Zounek e Rohlíková \(2019\)](#), é evidenciado que mesmo com o crescente número de pesquisas nas áreas de *Learning Analytics* e

Educational Data Mining, pouca atenção é dada ao desenvolvimento de técnicas analíticas que explorem os comportamentos dos estudantes em atividades educacionais. Enquanto Kucuk e Sisman (2017), que buscou em sua pesquisa compreender padrões de comportamento no aprendizado, revela o quanto esse entendimento é importante para que o professor possa administrar melhor suas estratégias de ensino.

Este tipo de situação também se mostra presente em aplicações de jogos digitais na educação, que ainda necessitam de padronização para desenvolvimento, validação e implementação em escolas (LOH; SHENG; IFENTHALER, 2015b). Devido a essa falta de padronizações em aplicações de *Serious Games*, o professor acaba por não conseguir ter um feedback sobre o comportamento dos estudantes e o desenvolvimento de suas habilidades durante o ato de jogar, perdendo assim informações e percepções importantes sobre o processo de aprendizado no momento em que este está ocorrendo.

É notável que as informações geradas a partir dos jogos podem ser capturadas e estruturadas com o uso da *Game Learning Analytics*, e materializadas em uma ferramenta que permita ao professor visualizar essas informações e compreendê-las, para assim tomar as decisões pedagógicas necessárias contribuindo com o percurso de aprendizado daqueles estudantes que demonstram dificuldades, ou que necessitam de alguma intervenção pedagógica.

Portanto, neste estudo, propomos a realização de um processo de GLA que buscará identificar, analisar e compreender os padrões comportamentais de estudantes em sua interação com jogos, a fim de gerar uma solução para a compreensão dos professores sobre o processo de aprendizado dos estudantes no momento em que ainda estão aprendendo, tendo como objeto de análise um conjunto de dados que contém as características de interação de estudantes da educação infantil em um conjunto de 20 jogos educacionais.

1.2 Objetivos

O objetivo geral deste estudo, é corroborar para a tomada de decisões pedagógicas dos professores, a partir da elaboração de uma abordagem de *Game Learning Analytics* capaz de identificar padrões comportamentais dos estudantes da educação infantil apenas com as suas características de utilização de uma plataforma de jogos educacionais. Para esse propósito, os seguintes objetivos específicos foram elaborados:

- Realizar um mapeamento para identificação de lacunas em pesquisas que tratam de aplicações de GLA sobre processos de aprendizagem.

- Elaborar um experimento de GLA que seja capaz de realizar a identificação de padrões comportamentais de estudantes na utilização de jogos educacionais.
- Avaliar em que nível é possível prever o efeito de aprendizado adquirido pelos estudantes a partir de suas características de interação com os jogos.

1.3 Estrutura da Dissertação

Para realização do cumprimento dos objetivos definidos para a esta pesquisa, a dissertação foi estruturada da seguinte forma: No capítulo 1, são introduzidos os conceitos de *Game Learning Analytics* e suas relações com a identificação de perfis. Neste capítulo também se encontram nossa justificativa, objetivos e estrutura da dissertação.

No capítulo 2, é realizada a revisão da literatura sobre a temática de jogos digitais para o aprendizado, elencando o uso de *Serious Games* como proposta pedagógica e aprofundando os conhecimentos sobre o processo de aprendizagem baseado em jogos digitais. Já no capítulo 3, são reunidos os conhecimentos que se referem ao uso da ciência de dados para a análise do aprendizado, destacando suas formas de aplicações em *Serious Games* e elencando os principais trabalhos relacionados à nossa proposta.

No capítulo 4 desta pesquisa, se encontra o mapeamento sistemático, que buscou identificar lacunas em pesquisas que aplicaram conceitos e técnicas de *Game Learning Analytics* para observação de fenômenos educacionais. No capítulo 5, será descrito o contexto e o método proposto por esta pesquisa, onde definiremos os materiais e as etapas que serão aplicadas para a execução dos objetivos definidos.

O capítulo 6 tratará dos resultados encontrados a partir dos experimentos aplicados, e no capítulo 7 traremos as implicações educacionais que estes resultados nos revelam. Por fim, temos no capítulo 8 as considerações finais.

2 Jogos Digitais para o Aprendizado

O ato de brincar é entendido como uma atividade cotidiana e bastante rica para crianças e adultos. No trabalho de [Anastasiadis, Lampropoulos e Siakas \(2018\)](#), esse ato é descrito como uma atividade comum da qual os participantes investem, de maneira completamente voluntária o seu tempo e dedicação, fornecendo assim uma excelente experiência de aprendizado enquanto transmite uma sensação de satisfação.

Já no que se refere aos jogos digitais, eles podem ser compreendidos como uma forma de mídia interativa e engajadora, que exige atenção e criatividade na execução de processos complexos, desenvolvendo diversos efeitos positivos no jogador como melhoras na percepção, atenção, memória e em tomadas de decisão ([EICHENBAUM; BAVELIER; GREEN, 2014](#)).

O potencial da utilização de jogos digitais na educação tem sido cada vez mais estudado e reconhecido. Esse valor vem sendo construído ao longo dos anos, onde a atuação pedagógica sobre o ato de brincar ou jogar é considerado como um meio para o desenvolvimento de características como a exploração e cooperação ([PELLEGRINI; DUPUIS; SMITH, 2007](#)).

Jogos digitais possuem diversas perspectivas, o que acaba tornando a definição desse termo um desafio, mas de maneira geral, se trata de um sistema em que usuários participam de desafios virtuais, definidos por regras que resultam em objetivos recompensáveis. Alguns aspectos comuns aos jogos são: regras que orientam e limitam os jogadores, objetivos ou conquistas claras, eventos que envolvem tomadas de decisão, conflitos ou competição, etc ([SALEN; TEKINBAŞ; ZIMMERMAN, 2004](#)).

Com o passar do tempo, os jogos têm conquistado cada vez mais reconhecimento e popularidade e mesmo que a diversão ou entretenimento seja o principal fator de engajamento para os jogadores, os princípios ali estabelecidos podem vir a contribuir para geração de propostas de aprendizagem que mantenham os participantes engajados ([GEE, 2003](#)).

Devido a isso, todo o potencial social, tecnológico e cultural que os jogos são capazes de atingir vem sendo mais reconhecidos tanto pela comunidade acadêmica quanto pelas empresas, fazendo com que sejam conduzidas diversas pesquisas que visam compreender como a aplicação destes instrumentos digitais impactam diversos domínios da aprendizagem ([ANASTASIADIS; LAMPROPOULOS; SIAKAS, 2018](#)).

Portanto, seguiremos na próxima seção com uma breve explicação sobre como vem sendo realizado o uso destes jogos digitais em ambientes educacionais.

2.1 O Uso de Serious Games como Proposta Pedagógica

Graças ao constante crescimento de pesquisas que buscam evidenciar a eficácia da aplicação de jogos digitais em ambientes de aprendizagem, podemos compreender melhor como utilizar suas características para contribuir no processo de aprendizagem. Nesta seção buscaremos esclarecer como são esses jogos e quais são suas características e benefícios.

Os jogos sempre tiveram uma tendência de serem usados para aperfeiçoar a mente e mediar o processo de aprendizado ou treinamento, como por exemplo estratégia militar com xadrez. Mas foi na década de 1980, com o advento dos sistemas de autoria (ex: Flash) que educadores começaram a criar jogos para ensinar (LOH; SHENG; IFENTHALER, 2015b).

Também é notável que os estudantes tendem a se concentrar mais enquanto estão aprendendo com a utilização de computadores do que em atividades comuns de sala de aula (RONIMUS et al., 2014). Já os professores podem utilizar estas tecnologias em forma de jogos para gerar engajamento dos alunos em atividades educacionais (CHENG et al., 2013). Devido a esta realidade, estão sendo experimentadas diversas maneiras de incluir jogos digitais com objetivos educacionais em sala de aula.

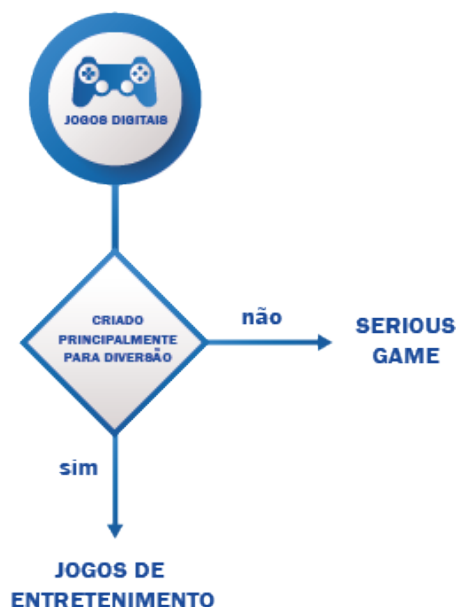
Jogos digitais voltados para fins educacionais possuem objetivos diferentes dos que são feitos para o entretenimento, devido a isso, eles se enquadram na definição de *Serious Games*, que são jogos criados com propósitos que vão além do entretenimento, onde os jogadores aprendem e desenvolvem habilidades através da superação de desafios durante o ato de jogar (ZHONGGEN, 2019). Na figura 1 é mostrado o fluxograma que diferencia os jogos de entretenimento dos jogos sérios.

Temos que para jogos educacionais, o conteúdo educativo está entrelaçado em uma mistura de elementos lúdicos, envolventes e educativos, que quando bem estruturados, são capazes de envolver os estudantes de maneira pessoal, emocional e cognitiva, tornando-os mais atentos e motivados na realização da atividade (PROTOP-SALTIS et al., 2011).

A aplicação de SG's é capaz de tornar o processo de ensino e aprendizagem mais interessante e interativo, além de desenvolver a criatividade dos estudantes, possuindo assim o potencial para serem ótimas ferramentas para auxílio do processo de aprendizado (ADMIRAAL et al., 2011; SUNG; HWANG, 2013).

Entendemos que são as características inerentes aos SG's que os tornam engajadores e atrativos aos estudantes. De acordo com o estudo realizado por Anastasiadis, Lampropoulos e Siakas (2018), algumas dessas características são: "curiosidade, fantasia, tarefas de dramatização, regras, objetivos, desafios, competição, controle, diversão, motivação, interação, adaptabilidade, feedback e apresentação multimodal".

Figura 1 – Fluxograma de definição de um Serious Game.



Fonte: Imagem adaptada de (LOH; SHENG; IFENTHALER, 2015b).

Os jogos promovem a curiosidade por parte dos estudantes e fornecem a sensação de domínio do seu processo de aprendizado através de motivação (BURGUILLO, 2010). No que se refere a importância da motivação, Anastasiadis, Lampropoulos e Siakas (2018) citam em seu trabalho, que esse é um fator chave para capturar o interesse dos estudantes e contribuir para sua habilidade de aprendizado.

Desta forma podemos afirmar que a proposta de uso dos SG's como ferramentas para o auxílio do aprendizado é capaz de impactar toda a perspectiva do aluno, trabalhando habilidades essenciais na sociedade atual, como o pensamento crítico, resolução de problemas, tomadas de decisão. Tudo isso enquanto os mantêm em um ambiente de baixo risco, onde poderão experimentar, errar, acertar e por fim, aprender em um processo de aprendizagem baseado em jogos digitais, assunto este a ser explorado na próxima seção.

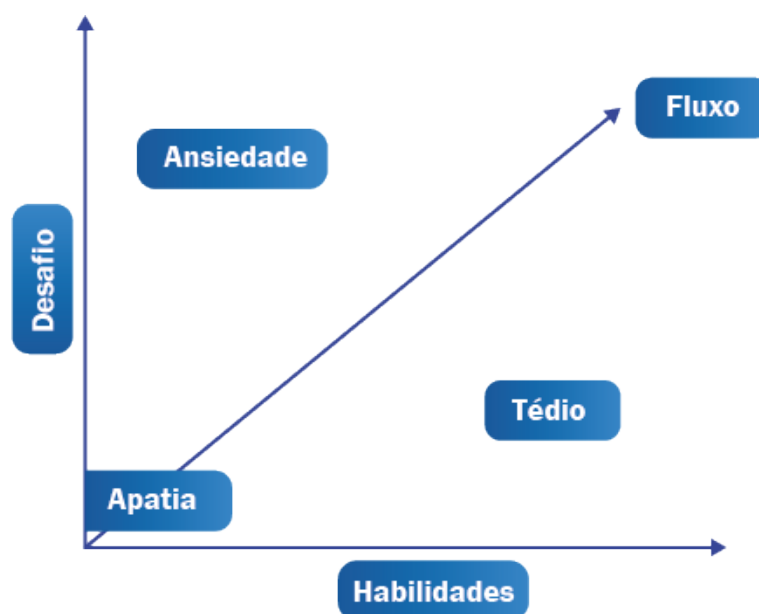
2.2 O Processo de Aprendizagem Baseado em Jogos Digitais

Para realização de aplicações de jogos em ambientes de aprendizado, é importante que se construa a aplicação de uma metodologia que permita que os estudantes explorem o jogo como forma de aprendizado e desenvolvimento de suas habilidades. Neste contexto, temos a metodologia da *Game-Based Learning* (GBL), que se trata do processo pedagógico referente a aplicação de jogos na educação, nesta abordagem metodológica são construídos conteúdos educativos na forma de jogos, feitos de maneira a engajar os estudantes na realização das tarefas (ANASTASIADIS; LAM-

PROPOULOS; SIAKAS, 2018).

No entanto, é importante ressaltar que para que o processo aconteça de maneira bem sucedida, não basta desenvolver jogos, deve-se construir artefatos com foco na interatividade que visando um fluxo de aprendizado capaz de entregar os conceitos de maneira gradual, guiando os estudantes para o objetivo final da proposta (SPIRES, 2015). Na figura 2, temos um modelo de fluxo que representa o equilíbrio ideal entre desafio e habilidade.

Figura 2 – Modelo de fluxo em uma proposta de *Game-Based Learning*.



Fonte: Imagem adaptada de (ADMIRAAL et al., 2011).

Para Prensky (2001), o desenvolvimento de um software educacional a ser utilizado em escolas, deve ser construído a partir dos métodos e técnicas do design de jogos digitais e para isso ele nos apresenta uma nova abordagem, da qual a chama de *Digital Game-Based Learning* (DGBL). Com o acréscimo do termo Digital, a DGBL visa a união entre a proposta de um ambiente interativo e uma aprendizagem séria disposta a partir de jogos, dessa vez, digitais.

As características principais para a concepção de um processo de DGBL são: objetivos bem definidos, tarefas repetíveis para contribuir com a memorização, monitoramento do progresso do aluno, encorajamento no aumento de tempo da tarefa através de motivação e ajustamento da dificuldade de maneira que se adeque ao progresso de aprendizado do estudante (SCIENTISTS, 2006).

O uso da DGBL oferece diversos benefícios, impactam o aprendizado e se demonstram eficazes na vida moderna, tornando assim essas propostas em possíveis contribuições para a educação e a sociedade (ANASTASIADIS; LAMPROPOULOS;

SIAKAS, 2018). Diversos estudos buscam evidenciar os benefícios dessas aplicações, e de acordo com Anastasiadis, Lampropoulos e Siakas (2018), alguns destes benefícios são:

- Desenvolvimento cognitivo e alfabetização digital;
- Desenvolvimento socioemocional e de habilidade sociais;
- Maior capacidade de tomada de decisão e resolução de problemas, bem como pensamento crítico;
- Ambiente aprimorado para comunicação e colaboração;
- Ambiente positivamente competitivo;
- Elevada autoestima e autonomia;
- Aprendizagem progressiva através da experiência;
- Sentimento gratificante de progressão e conquista;
- Aprendizagem orientada por feedback e centrada no aluno.

Dito isto, compreendemos que a utilização da DGBL, quando aplicada apropriadamente com metodologias de design centrado no usuário, vem para facilitar e impactar o processo de aprendizado dos mesmos, podendo inclusive ser combinadas à metodologias ativas de ensino e outras como as de aprendizagens colaborativas, baseadas em projetos ou baseadas em problemas, se mostrando assim capaz de produzir uma participação ativa durante as aulas a partir de engajamento e motivação.

Entendendo todo o potencial que essa tecnologia pode atingir na educação, trataremos no próximo capítulo, sobre como o uso da ciência de dados vem sendo utilizada na realização de análises aplicadas em jogos digitais educacionais.

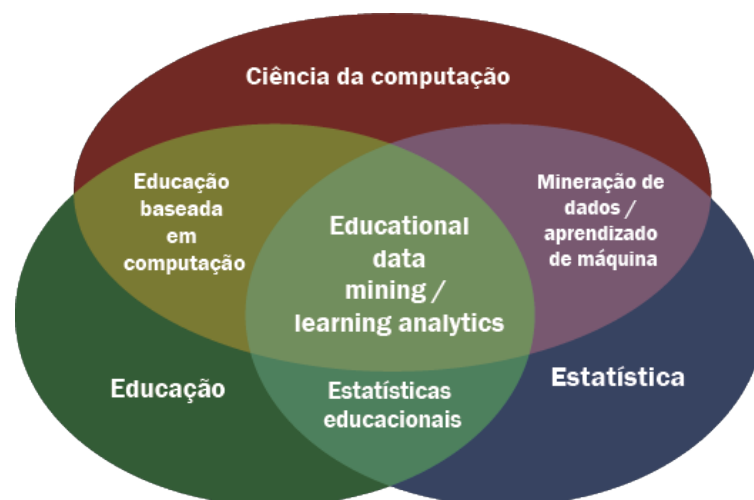
3 A Ciência de Dados para a Análise do Aprendizado

A utilização de técnicas da área da ciência de dados estão cada vez mais presentes no campo educacional, e evidenciadas como técnicas que possuem o potencial de contribuir para a extração de evidências sobre o processo de aprendizado, sendo este um instrumento para contribuir com a qualidade de ensino e aprendizado (ALDOWAH; AL-SAMARRAIE; FAUZY, 2019).

De acordo com Romero e Ventura (2020), o que permite a utilização dessas técnicas em um ambiente educacional é o aumento do uso da internet nas salas de aula, o desenvolvimento de softwares educacionais e de soluções de ensino à distância como os ambientes virtuais de aprendizagem, pois a utilização destas tecnologias contribuem para o aumento da quantidade de dados que estão sendo capturados das interações de alunos e professores.

Atualmente, temos duas áreas que representam a utilização de técnicas de ciência de dados educacionais, elas são intituladas *Educational Data Mining* e *Learning Analytics*, e são responsáveis por estabelecer técnicas e instrumentos necessários para se trabalhar com os dados de maneira a extrair evidências que evidenciem uma melhora no processo de ensino e aprendizagem com o uso de tecnologias educacionais (ALDOWAH; AL-SAMARRAIE; FAUZY, 2019). Na figura 3, temos representadas as principais áreas relacionadas a essas duas técnicas.

Figura 3 – Principais áreas relativas à EDM/LA

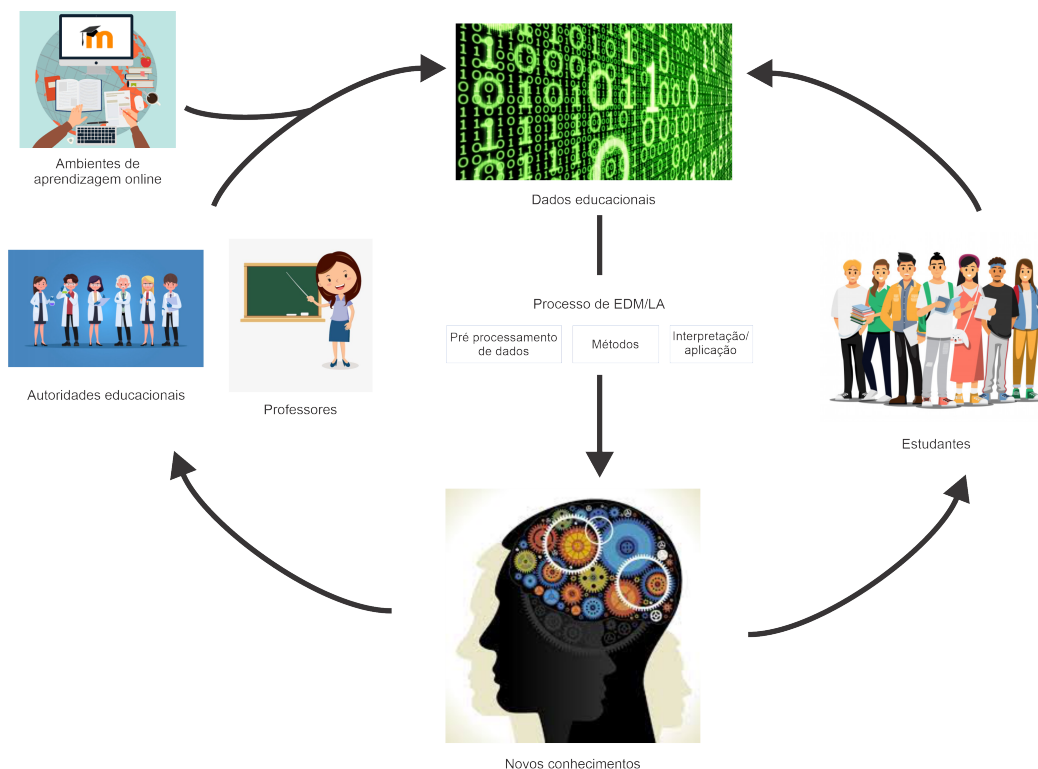


Fonte: Imagem adaptada de (ROMERO; VENTURA, 2020)

A área da EDM possui como objetivo a formulação de métodos que sejam capazes de explorar os tipos específicos de dados que são obtidos em ambientes educacionais (BAKHSHINATEGH et al., 2018). Enquanto isso, a LA se refere a todo o processo de medição, coleta, análise e discussão sobre esses dados, para assim compreender e contribuir para o aprendizado (LANG et al., 2017).

Ambas as áreas possuem um interesse em comum, mas a EDM possui um caráter mais técnico, buscando sempre descobrir novos padrões nos dados e gerar novos algoritmo e modelos, enquanto para a área de LA o foco está na descoberta de soluções educacionais, o que envolve uma junção essencial do técnico com o pedagógico (ROMERO; VENTURA, 2020). Mesmo obtendo objetivos diferentes, podemos observar na figura 4, que os processos para descoberta de conhecimentos em ambas as áreas é o mesmo.

Figura 4 – Processo de descoberta de conhecimentos em EDM/LA.



Fonte: Imagem adaptada de (ROMERO; VENTURA, 2020)

Ressaltamos que essas áreas vêm crescendo constantemente e já contam com conferências anuais (Ex.: *Learning Analytics and Knowledge (LAK) Conference*), journals (Ex.: *Journal of Learning Analytics*) e uma boa quantidade de livros e artigos, demonstrando assim um reconhecimento inegável no que se refere a demonstração da capacidade de expansão do nosso entendimento sobre a aprendizagem, entendimento do qual também vem sendo aplicado em *Serious Games*, assunto esse que será tratado na seção a seguir.

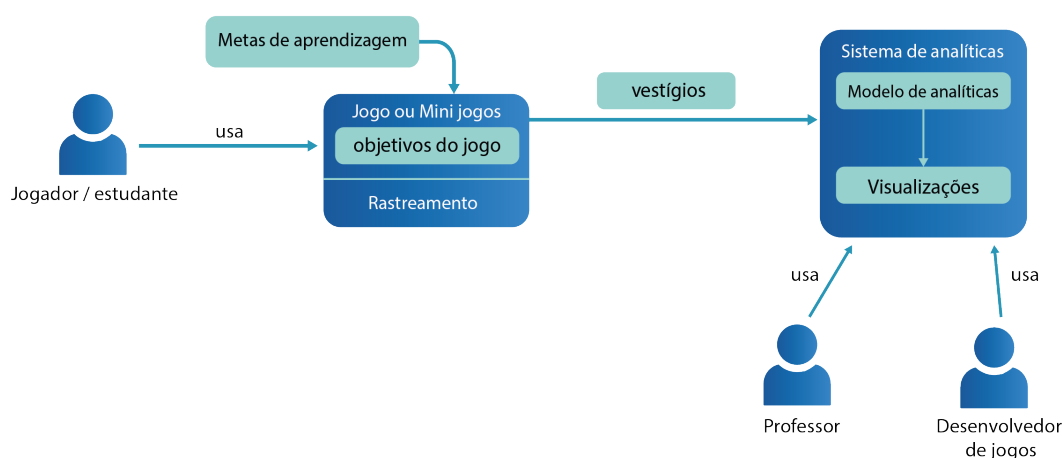
3.1 Análise de Aprendizado em Serious Games

Na aplicação de jogos em ambientes educacionais, é essencial que tenhamos a compreensão de como os estudantes estão utilizando o jogo. Para [Freire et al. \(2016\)](#), é necessário que seja evidenciado a validade e eficácia da aplicação, assim como a elaboração de meios de mensuração do quanto os estudantes estão aprendendo no ato de jogar.

Para efetuar a avaliação da eficácia de uma intervenção baseada em jogos, o método comumente utilizado é o pré e pós teste, onde os estudantes são submetidos a uma prova avaliativa antes e depois da utilização dos jogos ([CALDERÓN; RUIZ, 2015](#)). No entanto, entendemos que devido a própria natureza da aplicação desse método, que visa apenas entender e quantificar a existência de um eficácia da aplicação realizada, poucas descobertas são reveladas sobre o processo de como esses alunos aprendem os conteúdos.

Jogos constituem naturalmente um ambiente bastante interativo, e isso combina bastante com a aplicação de técnicas de ciência de dados, pois em ambientes como os de um jogo, diversos tipos de dados podem estar sendo gerados e capturados ([ALONSO-FERNANDEZ et al., 2019](#)). Sendo assim, uma aplicação de *Learning Analytics* em *Serious Games* pode ser utilizada para gerar uma captura de dados da interação do estudante com o jogo educacional para então trazer significado ao conjunto de ações do jogador ([LOH; SHENG; IFENTHALER, 2015a](#)). Temos na figura 5, um modelo de fluxo de processos relacionados à aplicação de LA em jogos digitais.

Figura 5 – Modelo de LA aplicado a jogos.



Fonte: Imagem adaptada de ([PEREZ-COLADO et al., 2018](#))

No fluxo acima, temos que os jogadores/estudantes, jogam um jogo digital que

possui seus objetivos naturais de jogo, assim como objetivos de aprendizagem, que deverão ser aplicadas à jogabilidade. Neste software de jogo educacional, temos também um rastreador, responsável por coletar as informações e entregá-las a um sistema de analíticas. Neste sistema, se encontra o modelo analítico utilizado para analisar os dados e gerar visualizações, com o objetivo de evidenciar assim, informações importantes para os professores, que podem utilizá-lo para tomada de decisão pedagógica, e/ou para os desenvolvedores do jogo, que aplicam melhorias a design do produto.

Esse sistema de analíticas já se mostra muito utilizado pela indústria de games, que utiliza das técnicas de ciência de dados para obter informações dos jogadores através do *Game Analytics*, porém, seu foco é no produto de jogo, e é voltado aos desenvolvedores, sem considerar as etapas e intenções da realização de um acompanhamento do aprendizado (ALONSO-FERNANDEZ et al., 2017).

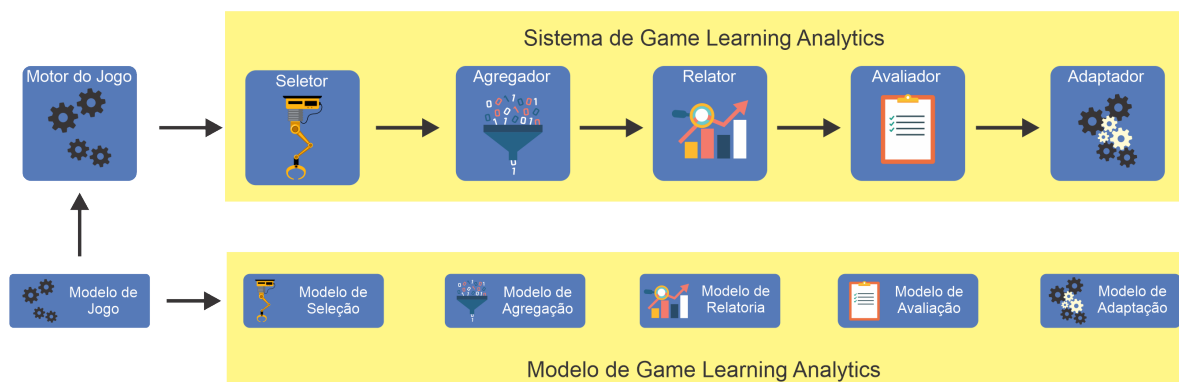
Graças a essa enorme capacidade de geração de informação que um SG é capaz de realizar, uma nova área da ciência de dados, específica para realizar análises de aprendizado em jogos surge, e é intitulada *Game Learning Analytics*, podendo ser definida como todo o processo já existente na LA, que envolve a coleta, análise e compreensão de dados, porém alinhados com a GA para que aconteça uma aplicação específica em *Serious Games* (ALONSO-FERNANDEZ et al., 2019).

A *Game Learning Analytics* pode ser utilizada para diferentes objetivos educacionais, os métodos que podem ser adotados em um processo de GLA já vem sendo utilizados para variados propósitos, mas os principais são: 1) Avaliar os estudantes baseados em dados obtidos dos *Serious Games*; 2) Predizer o aprendizado do estudante baseado em sua interação com o jogo; 3) Validar a eficácia do jogo no aprendizado dos estudantes e; 4) identificar possíveis melhorias no design do jogo (ALONSO-FERNÁNDEZ et al., 2020).

De acordo com Freire et al. (2016), implementações de GLA normalmente possuem as seguintes características: Componentes de jogo que rastreiam e enviam informações para um coletor; Componentes de servidor que recebem, classificam e armazenam os dados; Análises que possam ser acessadas em tempo real; Análises que demonstrem uma visão geral dos dados coletados; Indicadores quantificáveis de performance como notas, acertos, eficácia educacional; Um conjunto de análises e visualizações na forma de um dashboard para as partes interessadas. Esse processo estrutural pode ser observado na figura 6.

Sendo assim, definimos a *Game Learning Analytics* como uma área que busca compreender como dados obtidos através de *Serious Games* podem ser coletados, analisados e visualmente demonstrados, a fim revelar informações importantes sobre os processos de aprendizagem dos estudantes para os professores ou responsáveis, sendo essa uma fonte essencial para geração de feedbacks que servirão de guia para

Figura 6 – Modelo estrutural de Game Learning Analytics.



Fonte: Imagem adaptada de (FREIRE et al., 2016)

uma eficaz aplicação de jogos digitais na educação. Na seção a seguir falaremos de alguns trabalhos que utilizam abordagens de GLA em pesquisas relacionadas com nossa proposta de estudo.

3.2 Como as Pesquisas vêm Buscando Avaliar o Aprendizado?

Avaliar a aprendizagem usando dados de jogos digitais tem se mostrado viável em vários campos, como história, física e leitura (FENG; YAMADA, 2020; SHUTE; RAHIMI, 2021). No entanto, a maioria das pesquisas sobre avaliação baseada em jogos foi conduzida usando medidas diretas para medir o aprendizado (GRIS; BENGTSON, 2021). Tal pesquisa emprega um ou mais jogos que foram projetados especificamente para avaliar a aprendizagem dos alunos.

Embora jogos de avaliação possam parecer uma abordagem direta, em intervenções educacionais do mundo real pode ser inviável adicionar vários jogos de avaliação durante a implementação, pois exigirá mais tempo de aula e tela do que o disponível. Assim, neste estudo, empregamos vários atributos de dados (por exemplo, número de visualizações, respostas corretas e incorretas) de jogos projetados para promover o aprendizado para avaliar se eles são uma alternativa econômica para coletar dados de avaliação de processos.

Outra fraqueza dos estudos anteriores de avaliação baseados em jogos é que a maioria das medidas empregadas não tinha propriedades psicométricas sólidas (GRIS; BENGTSON, 2021). O emprego de instrumentos não psicométricos reduz a significância e a confiabilidade dos estudos de medidas baseadas em jogos. Este estudo contrasta dados extraídos pelos jogos com pontuações padronizadas de avaliação de leitura e escrita de palavras obtidas por psicólogos que avaliaram diretamente cada aluno.

Além de usar dados extraídos de jogos para medir o aprendizado, uma necessidade comum diz respeito à geração de perfis de jogadores. São grupos de alunos que demonstraram comportamentos semelhantes, como jogadores que terminaram um determinado jogo três vezes ou mais. A análise de agrupamento é a técnica utilizada para encontrar uma estrutura natural entre várias observações baseadas em perfis multivariados. Ele realiza o agrupamento com base nos atributos dessas observações (HAIR et al., 2009).

Vahdat et al. (2016) empregaram técnicas de agrupamento para identificar as táticas que os alunos usaram para resolver problemas. No entanto, eles não puderam fornecer explicações detalhadas sobre seus comportamentos. A análise hierárquica de clusters com bancos de dados de tamanho adequado é uma das técnicas que tem fornecido resultados significativos para explicar os padrões dos caminhos de aprendizagem (FENG; YAMADA, 2021). A análise de cluster também foi empregada com sucesso para categorizar o comportamento dos alunos em um jogo sobre habilidades de leitura (NIEMELÄ et al., 2020).

Entendendo este cenário, o estudo aqui proposto buscará abrir a “caixa preta” de uma intervenção educacional que tem demonstrado ganhos significativos em leitura e escrita para alunos de pré-escola de classe média (AMORIM et al., 2020). Para isto, o estudo aqui proposto emprega dados de aprendizado e comportamento dos alunos para compreender quais atributos de dados são os mais relevantes para caracterizar os alunos, e até que ponto essas caracterizações refletem diferenças significativas no desempenho dos alunos.

O capítulo a seguir se trata de nosso mapeamento sistemático sobre a área de *Game Learning Analytics*, que foi realizado a fim de encontrar lacunas de pesquisas e assim, contribuir para nossa tomada de decisão no desenvolvimento de nossa proposta.

4 Trabalhos Relacionados

Um Mapeamento Sistemático se trata de uma revisão abrangente em determinada área de estudo, buscando identificar evidências relevantes sobre tal área. Seus resultados nos revelam lacunas presentes na área explorada pelo mapeamento, evidenciando assim possíveis sugestões para pesquisas futuras (KITCHENHAM; BUDGEN; BRERETON, 2011).

Neste sentido, fica evidente que um mapeamento sistemático apoia o pesquisador na sua tomada de decisão no desenvolvimento de uma pesquisa. Além disso se trata de uma abordagem útil para estudantes de graduação e pós-graduação, graças ao processo de pesquisa da literatura e organização dos resultados obtidos, servindo como um ponto de partida para estudo em uma área do conhecimento.

Portanto, temos como objetivo principal deste capítulo, aplicar um mapeamento sistemático de maneira a explorar os estudos que realizaram aplicações de *Game Learning Analytics* no processo de aprendizado do estudante. Para esse propósito, foram definidas as seguintes questões centrais de pesquisa:

- Q1: *Que fenômenos educacionais as pesquisas buscam analisar?*
- Q2: *Quais técnicas são usadas para analisar os dados coletados?*
- Q3: *Qual o nível educacional dos participantes e o tamanho da amostra?*

A plataforma de pesquisa *Google Scholar* foi usada para obter os estudos. Escolha esta justificada pelo fato de que este repositório já agrega os trabalhos realizados em outras plataformas, como *IEEE Digital Library*, *ScienceDirect*, *SpringerLink*, entre outras.

Para realizar a pesquisa, foi utilizado uma string de pesquisa, que indica as palavras-chave e especificações da busca a ser realizada. As palavras “*game*” e “*analytics*” foram definidas como obrigatórias e, além delas, deve ser encontrada uma palavra mais relacionada à educação. Abaixo está a string de pesquisa usada:

allintitle: game analytics (school OR education OR learning OR teaching OR students)

Os resultados da pesquisa por essas palavras-chave ficaram restritos ao título, para pesquisas publicadas entre 2011 a 2021 e as opções “incluir patentes” e “incluir citações” foram desmarcadas, retornando 87 resultados.

4.1 Processo de Seleção dos Estudos

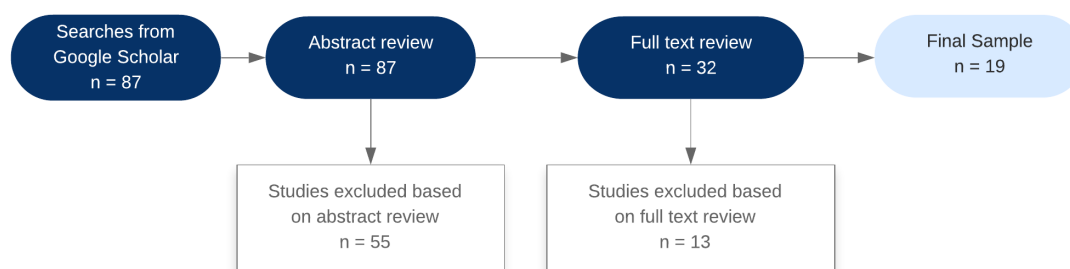
Tendo obtido o conjunto inicial de trabalhos, foram definidos e aplicados os critérios de exclusão, para remover os estudos que não se enquadrem no escopo definido para o mapeamento.

Critérios de Exclusão:

- O artigo não coleta características comportamentais dos alunos, nem possui como objetivo uma análise voltada para este aspecto;
- A *Game Learning Analytics* é utilizado com objetivos que não sejam identificar características dos processos de aprendizagem;
- O artigo não está inserido no domínio “educação”;
- É uma revisão sistemática, livro, ou está escrito em outro idioma que não o Inglês

No processo de análise deste estudo, foram lidos todos os 87 abstracts, comparando o conteúdo com os critérios de exclusão descritos acima, e após isso, uma análise do texto completo foi realizada com as questões de pesquisa em mente, para garantir que a amostra final atenderia às especificações definidas. O processo de seleção de estudos para este mapeamento sistemático pode ser observado na 7.

Figura 7 – Processo de seleção de estudos do mapeamento sistemático.



Fonte: O Autor.

Nesta análise percebeu-se um claro crescimento na quantidade de publicações com o passar dos anos, evidenciando assim um interesse cada vez maior na área de *Game Learning Analytics* desde o ano de 2013. No que se refere às pesquisas que atendem especificamente os critérios deste mapeamento sistemático, foi possível notar que a quantidade encontrada tem se mostrado estável com o passar dos anos, ainda assim com algum aumento. A relação de quantidade de trabalhos excluídos e incluídos para este mapeamento é mostrada na tabela 1.

Tabela 1 – Quantidade de trabalhos incluídos e excluídos por ano.

Ano de Publicação	Incluídos	Excluídos
2013	1	2
2014	2	2
2015	0	5
2016	1	9
2017	3	7
2018	2	13
2019	3	14
2020	5	5
2021	2	11
Totais	19	68

Fonte: O Autor

Ao fim do processo de análises de *abstract* e texto completo chegou-se a uma amostra final de 19 trabalhos selecionados. Destes trabalhos, foram analisados seus objetivos, fundamentação teórica, metodologias e resultados em busca de obter as respostas para as questões de pesquisa.

4.2 Que fenômenos educacionais as pesquisas buscam analisar?

Considerando os estudos classificados, foram mapeados os fenômenos educacionais que as pesquisas buscaram analisar e classificadas em 5 categorias: Colaboração, Desempenho do Estudante, Fatores Motivacionais, Processos de Aprendizagem e Resolução de Problemas.

Tabela 2 – Fenômenos educacionais dos estudos selecionados

Fenômeno Educacional	Frequência	Porcentagem
Colaboração	1	5,26%
Desempenho do Estudante	7	36,84%
Fatores Motivacionais	4	21,05%
Processos de Aprendizagem	3	15,80%
Resolução de Problemas	4	21,05%

Fonte: O Autor

A partir da tabela 2 podemos observar que a distribuição do quantitativo dos fenômenos educacionais encontrados nos estudos selecionados é bem diversificado, sendo a Colaboração o fenômeno menos presente dentre esses estudos, estando presente em apenas um deles, na pesquisa de [Sanchez e Mandran \(2017\)](#) que buscou entender como a interação entre competição e colaboração influenciam no aprendizado. Dentre os fenômenos mais observados, temos a análise do Desempenho do

Estudante, que foi analisada em 7 das pesquisas selecionadas, o que corresponde a 36,84% do total, sendo elas as de [Alonso-Fernández et al. \(2020\)](#), [Feng e Yamada \(2019\)](#), [Niemelä et al. \(2020\)](#), [Westera, Nadolski e Hummel \(2013\)](#), [Qasrawi, Amro e Jayousi \(2020\)](#), [Nguyen et al. \(2020\)](#) e [Emerson et al. \(2020\)](#).

Quanto aos outros fenômenos observados, a análise e aplicação de Processos de Aprendizagem esteve presente nas pesquisas de [Martin et al. \(2013\)](#), [Peddycord-Liu et al. \(2017\)](#) e [Gomez et al. \(2021\)](#), já as pesquisas de [Callaghan, McShane e Eguiluz \(2014\)](#), [Vahldick, Mendes e Marcelino \(2017\)](#), [Flores et al. \(2019\)](#) e [Zapata-Cáceres e Martín-Barroso \(2021\)](#) buscaram entender sobre os Fatores Motivacionais envolvidos na utilização dos jogos para o aprendizado. Por fim, temos as pesquisas de [Vahdat et al. \(2016\)](#), [Akram et al. \(2018\)](#), [Priyaadharshini et al. \(2020\)](#) e [Wen et al. \(2018\)](#), que analisaram como os jogadores utilizam a Resolução de Problemas nas dificuldades encontradas no decorrer dos jogos.

4.3 Quais técnicas são usadas para analisar os dados coletados?

Os algoritmos e técnicas utilizados nos estudos selecionados foram agrupados em 5 categorias: Análise de Agrupamento, Classificação, Mineração de Texto, Modelos de Regressão e Visualização de Dados. Alguns estudos aplicam técnicas e algoritmos próprios, ou não apresentam o seu método de análise definido, para estes usamos o termo Indefinido.

Tabela 3 – Algoritmos ou Técnicas utilizadas nos estudos selecionados

Técnica Utilizada	Frequência	Porcentagem
Análise de Agrupamento	5	26,31%
Classificação	2	10,52%
Mineração de Texto	1	5,26%
Modelos de Regressão	4	21,05%
Visualização de Dados	5	26,31%
Indefinido	2	10,52%

Fonte: O Autor

Tendo como base o levantamento dos algoritmos e técnicas identificadas nos estudos selecionados, torna-se bastante evidente uma preferência no uso da Análise de Agrupamento, técnica que classifica os participantes em diferentes grupos, a partir de seu comportamento e preferências no jogo.

A técnica de Análise de Agrupamento esteve presente em 5 dos 19 estudos, o que equivale a cerca de 26% deles, sendo usado principalmente para analisar os Processos de Aprendizagem ([MARTIN et al., 2013](#); [PEDDYCORD-LIU et al., 2017](#)) e Desempenho do Estudante ([FENG; YAMADA, 2019](#); [NIEMELÄ et al., 2020](#)), também

estando presente em um estudo que buscou analisar a Resolução de Problemas (VAHDAT et al., 2016). Outra técnica igualmente popular é a de Visualização de Dados, utilizada nas pesquisas de Sanchez e Mandran (2017), Callaghan, McShane e Eguiluz (2014), Qasrawi, Amro e Jayousi (2020), Gomez et al. (2021) e Zapata-Cáceres e Martín-Barroso (2021), e consiste basicamente de demonstrar visualmente os dados extraídos a partir dos jogos, sendo utilizada para fins educacionais diversos.

Já nas pesquisas de Alonso-Fernández et al. (2020), Westera, Nadolski e Hummel (2013), Nguyen et al. (2020) e Emerson et al. (2020) as técnicas de Modelos de Regressão foram utilizados para verificar o Desempenho do Estudante, buscando entender seu comportamento e prever o aprendizado adquirido.

Vahldick, Mendes e Marcelino (2017) usou a Classificação para focar na performance do estudante, buscando um ajustamento de dificuldade do jogo baseado nas classificações geradas por essa técnica, enquanto Akram et al. (2018) a usou para avaliar o poder preditivo desta técnica no desempenho pós-teste dos alunos. Por fim, a técnica menos utilizada dentre os estudos selecionados foi a de Mineração de Texto, estando presente apenas na pesquisa de Wen et al. (2018) que buscou entender o progresso dos estudantes nas resoluções de problemas.

4.4 Qual o nível educacional e tamanho da amostra?

Foram considerados 4 níveis educacionais para esta classificação, sendo eles: *Elementary School*, *Middle School*, *High School* e *College*. Pesquisas em que os participantes não são classificados em uma dessas categorias foram classificados como outros, e pesquisas que não deixam claro o nível educacional dos mesmos foram classificados como Indefinido.

A diversidade de níveis educacionais entre os participantes se torna bastante evidente nessa tabela, pois as pesquisas na área de *Game Learning Analytics* analisadas buscaram não apenas analisar fenômenos educacionais com estudantes, mas também com professores (SANCHEZ; MANDRAN, 2017), e adultos (VAHDAT et al., 2016), enquanto na pesquisa de Feng e Yamada (2019) foram analisados o desempenho de participantes de diferentes escolaridades.

Além da diversidade de escolaridades entre as pesquisas, é também notável as enormes discrepâncias na quantidade de participantes que foram submetidos a essas análises, sendo a média de participantes igual a 531, desconsiderando as pesquisas que obtiveram NA. A média acaba se tornando maior do que a quantidade da maioria das pesquisas selecionadas, pois algumas poucas pesquisas obtiveram amostras na casa dos milhares, o que acaba inflando esse valor. Além disso, duas das três pesquisas das quais os participantes são de ensino superior “*College Students*” nem

Tabela 4 – Nível educacional e quantidade de participantes dos estudos

Nível Educacional	Autores	Quantidade
Elementary School	(MARTIN et al., 2013)	21
	(PEDDYCORD-LIU et al., 2017)	1565
Middle School	(AKRAM et al., 2018)	244
	(FLORES et al., 2019)	31
	(QASRAWI; AMRO; JAYOUSI, 2020)	15
	(NGUYEN et al., 2020)	159
High School	(WEN et al., 2018)	25
	(ALONSO-FERNÁNDEZ et al., 2020)	227
College	(WESTERA; NADOLSKI; HUMMEL, 2013)	118
	(CALLAGHAN; MCSHANE; EGUILUZ, 2014)	NA
	(PRIYAADHARSHINI et al., 2020)	NA
	(EMERSON et al., 2020)	61
Outros	(VAHDAT et al., 2016)	15
	(SANCHEZ; MANDRAN, 2017)	242
	(FENG; YAMADA, 2019)	185
	(GOMEZ et al., 2021)	322
Indefinido	(VAHL DICK; MENDES; MARCELINO, 2017)	52
	(NIEMELÄ et al., 2020)	1632
	(ZAPATA-CÁCERES; MARTÍN-BARROSO, 2021)	4124

Fonte: O Autor

sequer deixam claro em seus textos a quantidade da amostra analisada (CALLAGHAN; MCSHANE; EGUILUZ, 2014; WESTERA; NADOLSKI; HUMMEL, 2013).

Um caso notável dessa aleatoriedade na quantidade de participantes da pesquisa, se mostra nas pesquisas de Martin et al. (2013) e Peddycord-Liu et al. (2017), que buscam observar o mesmo fenômeno educacional, utilizam técnicas semelhantes, ambos os jogos são da área da matemática e os participantes são também de mesma escolaridade, mas a quantidade de estudantes analisados na primeira é de 21, enquanto na segunda pesquisa é de 1565.

4.5 Lacunas Identificadas em Trabalhos de GLA

Esta seção apresentou um mapeamento sistemático cujo objetivo foi o de identificar lacunas de pesquisa sobre as aplicações de GLA que buscavam analisar algum processo educacional.

Para a construção deste mapeamento foram selecionados um total de 19 estudos, que foram analisados de acordo com as questões de pesquisa elaboradas e chegamos às seguintes conclusões:

No que se refere à primeira questão, utilizada para entender que fenômenos

educacionais estão sendo analisados nas pesquisas, percebemos que a Colaboração é o fenômeno menos pesquisado, estando presente em apenas um dos trabalhos. Notamos também a ausência de teorias de aprendizagem que guiem as pesquisas, o que pode causar um enfraquecimento nas argumentações educacionais destes estudos.

Quanto às técnicas utilizadas, a Análise de Agrupamento e Visualização de Dados tem um destaque notável, estando cada uma presente em 5 artigos, enquanto Mineração de Texto esteve presente em apenas 1. Além disso, em 2 dos estudos analisados não se utiliza de métodos da área em suas pesquisas, tendo de ser classificados como indefinidos.

Na terceira questão, buscamos entender quem eram os participantes das pesquisas e em que quantidade se apresentavam e percebemos que isso varia bastante entre os estudos, desde alunos que estão nos anos iniciais do ensino à estudantes de mestrado, chegando até a professores. Também percebemos como a quantidade de participantes é bem discrepante entre as pesquisas, indo de 15 à 4124.

Por fim, entendemos que a área de *Game Learning Analytics* ainda é relativamente nova, como deve ter sido percebido na Figura 1, os estudos mais antigos apresentados como retorno da pesquisa datam de 2013, mas essa é uma área que vem sendo cada vez mais pesquisada e debatida, pois possui um enorme potencial para auxiliar naquilo que mais buscamos valorizar, a aprendizagem dos estudantes.

5 Método

Neste capítulo, descreveremos o contexto da pesquisa e o método a ser utilizado nas análises dos dados adquiridos do aplicativo *Escribo Play*¹, uma plataforma de jogos educativos para dispositivos portáteis, com mais de 400 jogos que contribuem com o desenvolvimento das habilidades de linguagem, matemática e ciências, construída para ser utilizada por professores e estudantes do ensino infantil.

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 é entregue em 20 sessões que fornecem consciência fonológica baseada em evidências (sílabas, rima, aliteração, fonemas), leitura de palavras e instrução de escrita. Sua tela de seleção pode ser observada na figura 8.

Figura 8 – Tela de seleção de jogo do *Escribo Play*



Fonte: O Autor.

Dito isto, ressaltamos que os dados utilizados neste estudo foram dados secundários coletados ao longo das dez semanas de intervenção, sendo assim, dados abertos já validados e publicados a partir de uma pesquisa, podendo ser acessados online através da plataforma da *Harvard Dataverse*².

¹ <https://escribo.com>

² <https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/V7E9XD>

5.1 Implementação da Intervenção de Leitura e Escrita

O Estudo Randomizado Controlado, realizado na pesquisa de [Amorim et al. \(2020\)](#), empregou um desenho experimental clássico. Depois que os formulários de consentimento foram recebidos das famílias, todos os alunos realizaram um pré-teste usando o Teste de Leitura e Escrita ([LEÓN et al., 2019](#)). Essa avaliação padronizada mede a leitura e a escrita de palavras em português brasileiro.

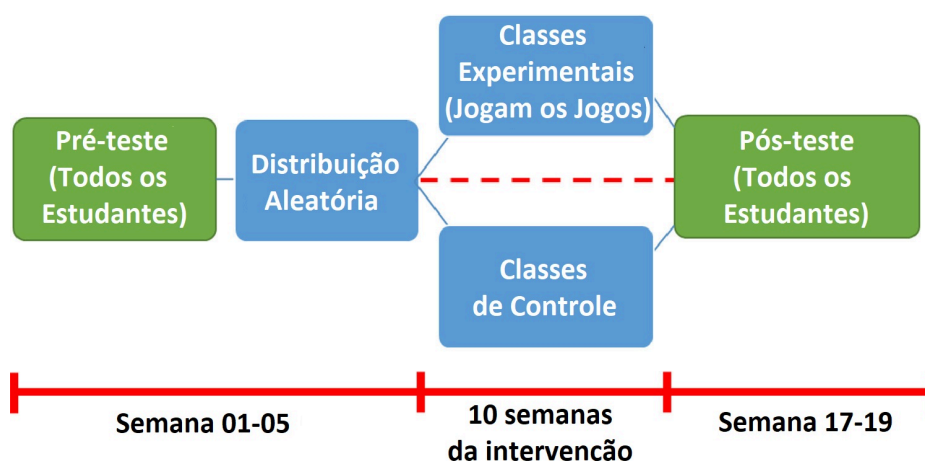
Após a aplicação dos pré-testes, as 62 salas participantes foram alocadas aleatoriamente para o grupo experimental ou controle. A randomização em nível de sala de aula foi selecionada porque as escolas não possuíam salas extras para dividir os alunos da sala de aula em dois grupos. A randomização da sala de aula também evita que a intervenção transborde para o grupo controle, pois apenas os professores das salas experimentais receberam os materiais de intervenção e os jogos.

Um total de 418 (55,8%) alunos frequentou 35 salas de controle. O grupo experimental foi composto por 27 salas de aula com 331 alunos (44,2%) de 15 escolas particulares localizadas em cinco cidades diferentes de uma região metropolitana da região Nordeste do Brasil. Ambos os grupos foram equivalentes no quesito idade do aluno, com média de 56 meses, na realização dos pré-testes. O grupo experimental teve 48,6% de meninos e 51,4% de meninas. O grupo controle foi formado por 51,3% de meninos e 48,7% de meninas.

A entrega da intervenção foi realizada durante 10 semanas, onde as salas experimentais tiveram duas sessões de instrução por semana. Cada sessão durou 45 minutos e consistiu em instruções em grupo, fornecidas pelo professor da sala de aula de acordo com o plano de aula (20 minutos) e alunos jogando o jogo da sessão em duplas, usando tablets de baixo custo, cooperativamente, por 20 a 25 minutos. Cada sessão tinha uma atividade específica (jogo) a ser realizada, mas depois que os alunos jogaram o jogo duas vezes, eles poderiam repetir qualquer jogo das sessões anteriores que quisessem se ainda houvesse tempo. Durante a intervenção, o grupo de controle não teve acesso à intervenção.

Depois que as salas experimentais receberam a intervenção, todos os alunos foram pós-testados usando o mesmo instrumento. Os pós-testes foram conduzidos por avaliadores cegos que desconheciam a alocação da sala de aula para reduzir o viés. Ambos os pré e pós-testes foram gravados em áudio para que a confiabilidade interexaminadores pudesse ser avaliada por um segundo avaliador cego corrigindo a avaliação no laboratório. O desenho geral da aplicação desta intervenção pode ser vista na figura 9.

Figura 9 – Fluxo do Estudo Randomizado Controlado



Fonte: Imagem adaptada de (AMORIM et al., 2020).

5.2 Descrição dos Jogos Utilizados na Pesquisa

Nesta seção estão descritos a jogabilidade e objetivo educacional dos 20 jogos que foram jogados durante a intervenção supracitada nesta dissertação, da qual a captura de dados de interação permitiu que fosse possível a aplicação das técnicas e experimentos aqui construídos. Estes jogos tiveram como objetivo desenvolver habilidades de leitura e escrita, bem como a consciência fonológica para crianças em fase de pré-escola de cerca de 4 anos de idade.

Os quatro primeiros jogos aplicados na intervenção são jogos que trabalham as habilidades de juntar, separar, adicionar e inverter sílabas, nessa ordem. A tela destes jogos pode ser observada na figura 10.

O primeiro jogo, que se encontra no canto superior esquerdo, se chama Juntando as Partes, onde os alunos devem arremessar as bolas em direção à cesta de basquete na ordem correta, tendo como dica uma imagem à esquerda da tela. No segundo jogo, chamado Corta-Palavras, os alunos precisam selecionar a tesoura correta de maneira que divida a palavra de acordo com a separação silábica da mesma.

O terceiro jogo deste conjunto, o Adicionar Sílabas, trabalha a habilidade de completar palavras, fazendo o aluno escolher o bloco que contém a sílaba faltante. Por fim, temos o quarto jogo, o chamado Invertendo Sílabas, nele os alunos devem mentalmente inverter as sílabas que estão dispostas na tela para formar a palavra que dará a informação sobre qual figura eles deverão selecionar na tela.

Dando segmento a aplicação da intervenção, após trabalhar as habilidades silábicas dos alunos a partir destes quatro jogos descritos, eles são colocados para jogar quatro novos jogos, sendo dois deles sobre rimas e outros dois sobre aliteração. A tela destes jogos pode ser observada na figura 11.

Figura 10 – Jogos que trabalham habilidades relacionadas a Sílabas.



Fonte: Imagem adaptada de (AMORIM et al., 2020).

Figura 11 – Jogos que trabalham habilidades relacionadas a Rimas e Aliterações.



Fonte: Imagem adaptada de (AMORIM et al., 2020).

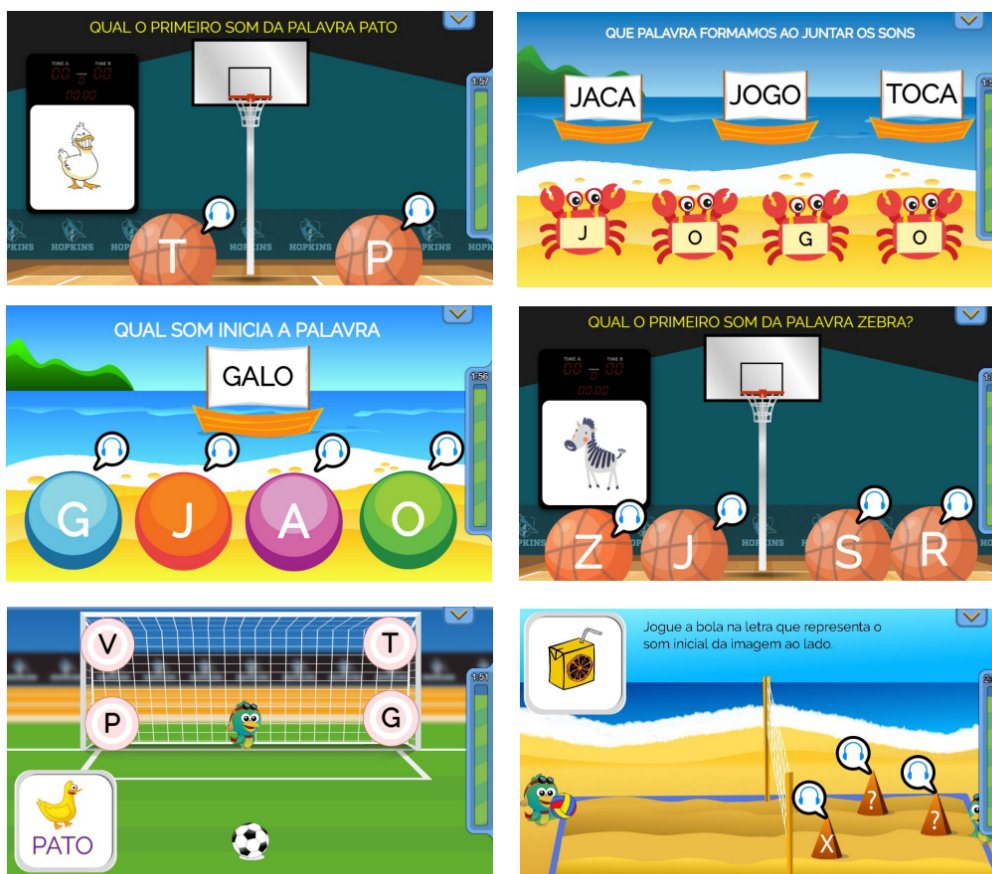
O quinto jogo aplicado na intervenção é a Mina da Rima, no qual os alunos devem cortar a corda correta dentre as três opções presentes na tela, para acertar é necessário escolher a corda que segura o medalhão contendo a palavra que rime com a palavra descrita no canto superior da tela. Em seguida, temos o jogo Gol da Aliteração, onde os alunos devem tocar na imagem que começa com a mesma letra

que a palavra destacada presente na tela.

O sétimo jogo é o Fazendinha, que se trata de um segundo jogo que trabalha rimas, e consiste em arrastar apenas as ovelhas corretas, ou seja, as que contém as palavras que rimam com a palavra destacada na tela, para dentro do curral. Por fim, temos a Lagoa da Aliteração, também um segundo jogo que trabalha uma habilidade abordada anteriormente, nele, os alunos devem arrastar os patos para a lagoa, mas apenas aqueles que contém a palavra que comece com o mesmo som que a palavra destacada.

É importante ressaltar que em todos estes quatro jogos descritos acima, a palavra destacada, importante para a conclusão correta da tarefa, e emitida a partir de som, ou seja, os alunos não apenas vêm a palavra como também a ouvem. A intervenção segue com a aplicação de mais seis jogos relacionados a atividades que envolvem fonemas, suas telas podem ser observadas na figura 12.

Figura 12 – Jogos que trabalham habilidades relacionadas a Fonemas.



Fonte: Imagem adaptada de (AMORIM et al., 2020).

Do nono ao décimo quarto jogo aplicado na intervenção de leitura e escrita, temos jogos que trabalham habilidades relacionados a consciência fonêmica, o primeiro

deles, o Basquete dos Fonemas, possui a mesma mecânica que o juntando as partes, porém desta vez, deve-se arremessar apenas a bola que corresponde ao primeiro fonema da palavra em questão. No jogo seguinte, o Juntando Fonemas, temos os fonemas separados e o aluno deve escutar cada um deles e selecionar a palavra correspondente a junção destes fonemas. No décimo primeiro jogo, chamado Advinha o Som, os alunos ouvem os sons dos fonemas presentes na tela e devem selecionar a bola que corresponde ao primeiro fonema da palavra destacada.

Neste conjunto de jogos, temos ainda mais três que trabalham com fonemas, o Basquete de Fonemas 2, que se trata de uma versão mais complicada do primeiro descrito deste conjunto, contendo mais opções. Em seguida temos o jogo Futebol dos Fonemas, que funciona de maneira parecida com o Gol da Aliteração, onde desta vez os alunos devem fazer uma correspondência entre letra e som para acertar. Por fim, temos o Vôlei dos Sons, onde os alunos escutam uma palavra, e em seguida devem selecionar entre as opções disponíveis, o fonema que representa o primeiro fonema da palavra.

Neste conjunto específico de jogos é bastante predominante a presença de pequenos símbolos de fones de ouvido espalhados pela tela, isso acontece para que o aluno possa selecionar e ouvir quantas vezes precisar o som correspondente a letra. Após a aplicação destes jogos, temos por fim a aplicação de mais seis jogos, desta vez relacionados a leitura e escrita de palavras, suas telas de jogos estão presentes na figura 13.

Este último conjunto de jogos contém 6 jogos (15 ao 20) e trabalham habilidades de leitura e escrita de palavras, sendo o primeiro deles, a Leitura Certa, onde o aluno precisa ler a palavra e destaque e assim selecionar a figura correspondente para o estilingue ser disparado. O décimo sexto jogo é o Escaladão das Palavras, neste jogo os alunos devem olhar a imagem e selecionar as letras faltantes da palavra correspondente. Em seguida, temos o jogo Futebol, que utiliza a mesma fórmula dos jogos de futebol anteriores, porém desta vez o aluno lê a palavra e depois seleciona a imagem correspondente.

O jogo Escrevendo Palavras é o décimo oitavo jogo aplicado durante a intervenção e se trata de uma versão mais difícil, com palavras mais complicadas, do jogo Escaladão das Palavras. No jogo seguinte, o Vôlei das Palavras, os alunos devem ler e escrever palavras em diversas mecânicas de jogo já abordadas anteriormente. Por fim, o último jogo deste conjunto e da intervenção de leitura e escrita, o vigésimo jogo, é o Escrevendo Palavras, um segundo jogo em que o aluno é posto para ler e escrever palavras em diferentes mecânicas de jogo abordadas anteriormente.

Figura 13 – Jogos que trabalham habilidades relacionadas a Leitura e Escrita.



Fonte: Imagem adaptada de (AMORIM et al., 2020).

5.3 Abordagem de Game Learning Analytics

Neste estudo, buscaremos entender melhor sobre como os processos relatados na pesquisa de Amorim et al. (2020) acontecem, buscando realizar uma identificação de perfis comportamentais na utilização do jogo para compreender se existem grupos de padrões de uso da plataforma, identificar e compreender as diferenças entre esses padrões encontrados e evidenciar quais atributos foram mais relevantes para a formação desses grupos.

As variáveis escolhidas para realização desta pesquisa, são relacionadas ao uso dos jogos, como: quantidade de acertos, erros e visualizações em cada atividade, e variáveis que representam resultados referentes às avaliações de pré-teste e pós-teste de leitura e escrita. A descrição dos dados coletados pode ser observada na tabela 5.

O termo *Activity** na tabela refere-se ao jogo em questão, dentre um universo de 20 jogos diferentes. Antes dar início a todos os processos, realizamos uma análise

Tabela 5 – Descrição das variáveis coletadas

Variável	Descrição
Reading_Pre	Nota obtida pelo estudante no pré teste de leitura
Reading_Post	Nota obtida pelo estudante no pós teste de leitura
Writing_Pre	Nota obtida pelo estudante no pré teste de escrita
Writing_Post	Nota obtida pelo estudante no pós teste de escrita
Activity*_Visualization	Quantidade de Visualizações do estudante na atividade
Activity*_Right	Quantidade de Acertos do estudante na atividade
Activity*_Wrong	Quantidade de Erros do estudante na atividade
Reading_Gain	Valor obtido através do cálculo: (Reading_Post - Reading_Pre)
Writing_Gain	Valor obtido através do cálculo: (Writing_Post - Writing_Pre)

Fonte: O Autor.

exploratória dos dados, cujo objetivo foi examinar de maneira prévia a nossa base de dados a fim de identificar possíveis relações existentes entre variáveis e checar inconsistências e problemas nos dados.

No que se refere ao processo de análise aqui proposto, realizaremos uma abordagem de GLA em busca de identificar padrões de jogabilidade dentre os alunos participantes da amostra, os identificando e agrupando em perfis comportamentais, para analisar as diferenças entre eles e buscar compreender quais grupos possuem um impacto maior ou menor no aprendizado, e com isso criar uma ferramenta da qual seja possível visualizar essas informações em tempo real.

Como descrito no fluxograma da figura 14, após uma análise exploratória inicial, utilizaremos o conjunto das variáveis coletadas para realizar um processo de GLA. Todos os processos de análise com o dataset em questão serão realizados através da linguagem de análise de dados R³, por meio da IDE *RStudio*⁴, começando pelo devido tratamento dos dados, para remoção dos sujeitos que deixaram de realizar pelo menos um dos dois testes (pré teste ou pós teste), e seguindo com a estrutura: Experimento 01: 1) Execução da Análise de Agrupamento; 2) Análise das Diferenças entre Grupos; 3) Eficácia da Intervenção por Grupo; Experimento 02: 1) Aplicação das Técnicas de Classificação; 02) Validação dos Melhores Modelos Obtidos.

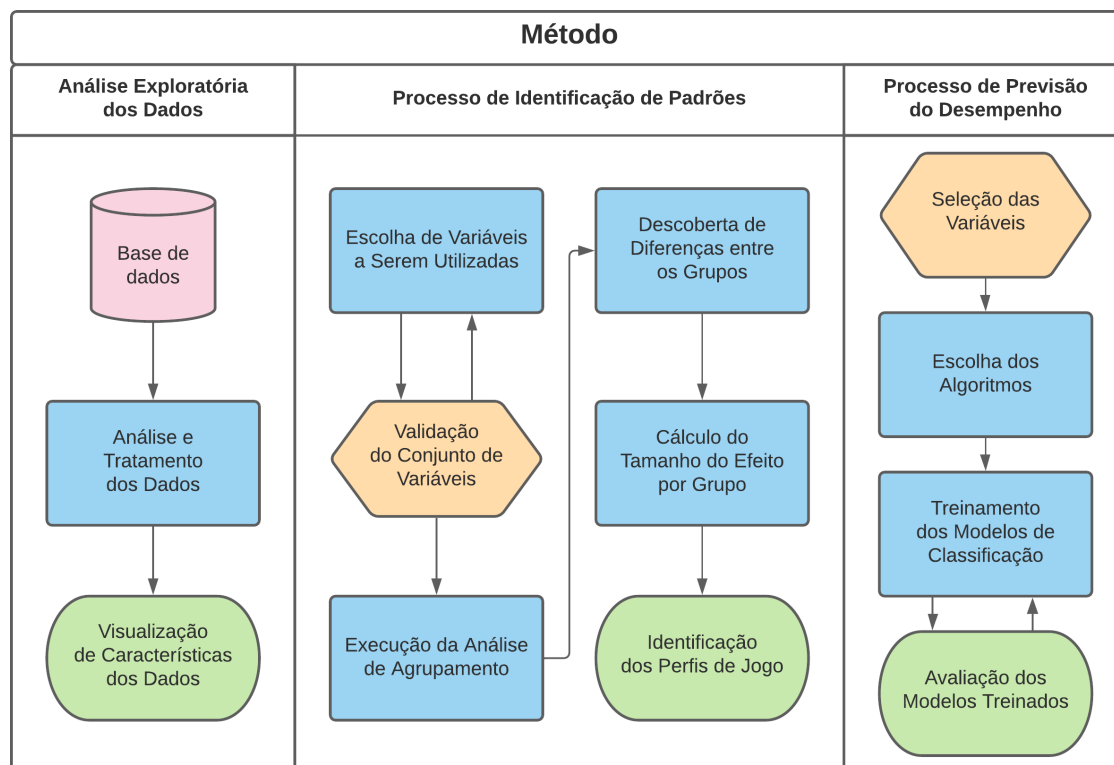
5.4 Análise Exploratória dos Dados

A etapa da análise exploratória é essencial em qualquer análise de dados, e envolverá a organização, descrição, realização de cálculos e visualização dos dados presentes na análise. O objetivo dessa análise inicial será encontrar padrões, e/ou dis-

³ <https://www.r-project.org>

⁴ <https://www.rstudio.com>

Figura 14 – Fluxograma do método proposto no estudo.



Fonte: O Autor.

crepâncias nos dados, identificando possíveis tendências, avaliando comportamentos e investigando a relação entre as variáveis.

Em nossa análise exploratória dos dados, buscaremos evidenciar as variáveis que serão utilizadas na pesquisa, descrevendo o que cada uma delas significa. Esse processo será seguido de uma análise para obter informações sobre a existência, ou não, de valores nulos ou inconsistentes. Justificamos a importância dessa compreensão, pelo fato de que será bastante difícil realizar uma análise assertiva sobre o padrão comportamental de um aluno que não possui ocorrência/pontuação em variáveis determinantes.

Realizado o processo de identificação de valores faltantes, partiremos para a visualização de variáveis que representam o uso dos jogos pelo alunos. Em nossa base de dados, temos a quantidade de acertos, erros e visualizações que os alunos obtiveram em cada um dos 20 jogos, na ordem em que eles foram aplicados. Sendo assim, teremos como objetivo gerar discussões sobre a natureza desses dados, buscando entender possíveis relações entre essas três variáveis. Concluído esse processo, aplicamos o processo de identificação de perfis comportamentais que será explicado na seção a seguir.

5.5 Processo de Identificação de Perfis Comportamentais

Neste seção, descrevemos o processo realizado para avaliar se os dados coletados automaticamente pelos jogos educacionais podem ser usados para identificar diferentes grupos de alunos com base em seus perfis de interação e determinar a eficácia da intervenção para cada um desses perfis.

5.5.1 Execução da Análise de Agrupamento

A análise de agrupamento será a técnica utilizada para identificar alunos com características de interação semelhantes (HOU, 2011; LI et al., 2020). A análise consiste em agrupar indivíduos ou objetos com a seguinte condição: os membros de um mesmo cluster devem estar muito próximos uns dos outros, enquanto os membros de diferentes clusters estão muito distantes, com base apenas nas informações encontradas nos dados (HAIR et al., 2009). Existem várias abordagens de agrupamento, mas a escolhida para esta análise foi a *k-means*, a mais utilizada para realizar partições de um número *k* de agrupamentos em uma tabela de dados (HOU, 2011).

O algoritmo básico do *k-means* está estruturado da seguinte forma: Começamos escolhendo uma quantidade *k* de centróides iniciais, onde o valor de *k* é subjetivo, e cabe ao pesquisador escolher. No entanto, o método *Elbow*, que sugere um número ideal de *clusters*, foi utilizado para esta pesquisa. Em seguida, cada ponto do conjunto de dados, que são os alunos, é atribuído ao centróide mais próximo, formando os *clusters* iniciais. Em seguida, cada *cluster* tem seu centróide atualizado, com base nas médias de distância dos pontos atribuídos a ele. Este último processo é repetido até que o centróide permaneça o mesmo, formando os *clusters* finais (TAN; STEINBACH; KUMAR, 2016).

Apenas um conjunto menor de atributos de dados foi selecionado, responsável por representar os atributos determinantes da utilização do aplicativo *Escribo Play*. Eles foram escolhidos a partir da avaliação da tendência de agrupamento, utilizando o método estatístico de Hopkins, fornecido pelo pacote *clustertend*. Este método pode atribuir a probabilidade de um determinado conjunto de dados gerar dados distribuídos uniformemente (KASSAMBARA, 2017).

Após selecionar os atributos representativos, o único requisito para fazer o método *k-means* é a definição do valor *k*, o número de *clusters* formados ao utilizar a técnica. O método utilizado para auxiliar na tomada de decisão sobre o número de *clusters* foi o *Elbow Method*, utilizando o pacote *NbClust*, que busca definir clusters para minimizar a variação total intra-cluster.

Concluído esta etapa, o método *k-means* foi aplicado, usando sua função nativa do R "*kmeans*". Com os grupos formados, foram feitas análises exploratórias e discus-

sões de resultados para entender o quanto os agrupamentos formados mostravam a realidade dos alunos e escolas participantes da pesquisa.

5.5.2 Descoberta de Diferenças Entre os Grupos

Esta etapa avaliou a significância das diferenças entre os *clusters* gerados. Nela, buscamos compreender as diferenças das influências dos *clusters* no ganho de leitura e escrita. Como existem dois alvos (*Reading_Gain* e *Writing_Gain*), esta análise ocorreu em duas etapas: primeiro, a análise para o ganho na leitura, depois, após a obtenção dos resultados, o processo será repetido, mas para o ganho na escrita.

A ANOVA é normalmente aplicada para determinar se as médias de três ou mais *clusters* são diferentes. No entanto, as premissas que este teste exige para ser utilizado, que vão desde a verificação da normalização dos dados até a equidade da variância populacional, são muitas vezes ignoradas ou violadas, o que gera uma estimativa imprecisa do p-valor (HECKE, 2012). Nesta pesquisa, a normalização dos dados é verificada por meio do teste Shapiro-Wilk, fornecido pelo pacote *RVAideMemoire*. Neste teste, um atributo por vez é usado para comparar os *clusters*. Se os p-valores gerados por este teste estiverem abaixo de 0,05, significa que os dados não são normalmente distribuídos.

Conforme explicado anteriormente, pretendemos entender as diferenças dos *clusters* pelo seu ganho em leitura e escrita, portanto os atributos selecionados para este teste são o *Reading_Gain* e *Writing_Gain*, e seus p-valores por *cluster* são respectivamente: C1 = 1.002e-08 ; C2 = 0,65; C3 = 1,934e-10; C4 = 1,312e-10 e C1 = 0,08; C2 = 0,50; C3 = 0,00; C4 = 0,01. Entendendo que nosso teste não atendeu aos pressupostos para aplicação da ANOVA, o teste utilizado para verificar e compreender as diferenças entre os *clusters* gerados nesta pesquisa foi o teste de Kruskal-Wallis, uma versão não paramétrica da ANOVA de uma via.

De acordo com McKight e Najab (2010), a técnica de Kruskal-Wallis é normalmente aplicada para comparar três ou mais *clusters* quando há falha na avaliação dos pressupostos da ANOVA. Portanto, não restringe a comparação e define sua análise estatística com base em um ranking de valores (MCKIGHT; NAJAB, 2010). No teste de Kruskal-Wallis, a hipótese nula (H0) acontece quando as medianas dos *clusters* são iguais entre si (p-valor > 0,05), o que significa que não há diferenças significativas entre os *clusters*, a hipótese alternativa (H1) significa que existem diferenças significativas, ela ocorre quando as medianas dos *clusters* diferem entre si (p-valor < 0,05).

Após a conclusão deste teste, foi realizado um teste *post hoc*. O mais adequado e escolhido para esta pesquisa foi o Teste de Dunn com ajuste do p-valor. Ele efetivamente faz inferências simultâneas entre populações, fornecendo resultados mode-

rados e consistentes (ELLIOTT; HYNAN, 2011; DINNO, 2015). Análises descritivas ocorreram a partir desses resultados, buscando comparar *clusters*, gerar gráficos e entender sua distribuição.

5.5.3 Cálculo do Tamanho do Efeito por Grupo

A avaliação da eficácia dos programas educacionais geralmente é realizada por meio de estudos experimentais randomizados e controlados. A principal métrica empregada para comparar esses experimentos é o *effect-size*, ou tamanho do efeito. Quanto maior o tamanho do efeito, maior o ganho causado pelo programa na aprendizagem dos alunos, em comparação com os alunos do grupo controle.

Em pesquisas anteriores, o *Escribo Play* gerou um tamanho de efeito na leitura equivalente a $d = 0,40$ e $d = 0,20$ na escrita (AMORIM et al., 2020). De acordo com os padrões de Cohen, esses tamanhos de efeito podem ser interpretados como médios e pequenos. No entanto, em ambientes educacionais do mundo real, os tamanhos dos efeitos tendem a ser muito menores do que as médias de Cohen. Kraft (2020) forneceu vários *benchmarks* para avaliar a magnitude dos tamanhos de efeito de experimentos educacionais. Nesse contexto, o *Escribo Play* pode ser interpretado como tendo um efeito forte, superior a 90% das demais intervenções educativas avaliadas com amostras de tamanho semelhante (KRAFT, 2020).

As médias e desvios padrão do pré e pós-teste para cada cluster encontrado no processo de identificação do perfil foram gerados para avaliar o tamanho do efeito específico. Com esses valores, foi possível realizar o cálculo do tamanho do efeito para cada *cluster* do grupo experimental em relação ao grupo controle. Como os *clusters* tinham uma quantidade diferente de participantes, calculamos o tamanho do efeito para grupos com amostras desiguais (LENHARD; LENHARD, 2016).

A partir desses resultados, definiremos como cada grupo encontrado no processo de análise de agrupamento pode ser interpretado, considerando que o objetivo é entendê-los como perfis comportamentais. Concluído esse processo, passaremos para o experimento 02, que equivale a aplicação de técnicas de classificação para predição do efeito de aprendizado dos estudantes.

5.6 Processo de Predição do Desempenho Adquirido

Nesta seção, descrevemos o processo realizado para avaliar em que nível é possível prever o efeito do aprendizado adquirido pelos estudantes utilizando apenas suas características de interação com os jogos, identificando também quais dessas características de interação, assim como as técnicas utilizadas para predição, são mais eficazes para uma aplicação adequada do processo.

5.6.1 Construção do Modelo de Predição

Para realização da aplicação de nosso processo de predição, utilizaremos a técnica de Classificação, que consiste de um conjunto de métodos de aprendizado de máquina para computar a probabilidade de um indivíduo pertencer a uma determinada classe baseada em uma ou múltiplas características preditoras (KASSAMBARA, 2017).

Dito isto, seguimos com a construção de uma variável alvo binária, ou seja, que possa ter apenas duas classes, que representará a variável a ser predita no processo de classificação. Neste estudo utilizamos o ganho de aprendizado, referente ao valor do pós-teste menos o pré-teste obtido por cada aluno, da qual foi categorizado em duas classes que representam se houve ou não efeito de aprendizagem. Para isso, consideramos que houve efeito de aprendizado casos em que o ganho de leitura ou escrita foram maior que 0, e que não houve efeito de aprendizado nos casos em que o ganho foi menor ou igual a 0.

A escolha das variáveis independentes, que serão usadas como as características preditoras, foi feita pelas combinações das variáveis de acertos, erros e visualizações dos vinte jogos. As possíveis combinações das variáveis de interação com os jogos estão descritas na Tabela 6.

Tabela 6 – Combinações das variáveis de interação dos Jogos.

Variáveis	Descrição
V + R + W	Visualizações, Acertos e Erros nos vinte jogos
V + R	Visualizações e Acertos nos vinte jogos
V + W	Visualizações e Erros nos vinte jogos
R + W	Acerto e Erros nos vinte jogos
V	Visualizações nos vinte jogos
R	Acertos nos vinte jogos
W	Erros nos vinte jogos

Fonte: O Autor.

Como demonstrado na tabela acima, temos um total de 7 combinações possíveis para as variáveis independentes e, como temos uma variável alvo para o ganho em escrita e outra variável alvo para o ganho em leitura, todo o processo de combinações de variáveis para aplicação das técnicas de classificação envolveu duas abordagens, onde na primeira abordagem as possíveis combinações das variáveis independentes foram executadas tendo como alvo o efeito em leitura, e posteriormente, numa segunda abordagem foram executadas tendo como alvo o efeito em escrita.

Após definidas as variáveis que farão parte do modelo, é necessário dividir o nosso conjunto de dados entre dados de treino, que são os dados que o algoritmo terá acesso para entender a base e construir o modelo, e dados de teste que representam

os dados que o modelo usará para prever e comparar suas previsões, assim obtendo informação sobre o quão eficaz ele é em prever corretamente os indivíduos. Para isso, a base de dados contendo todos os sujeitos da pesquisa foi dividida em dados de treino e de teste, sendo 70% para treino e 30% para teste.

Ao final do processo de treinamento do modelo, os algoritmos de classificação foram aplicados, ao todo utilizamos 4 algoritmos, sendo eles: *Generalized Linear Model* (GLM), *Support Vector Machine* (SVM), *Random Forest* e *XGBoost*. Para cada algoritmo aplicado podemos obter o comparativo entre os valores previstos com os valores reais dos dados que foram armazenados para teste, assim como verificar o valor de métricas como a *Accuracy*, *Kappa*, *Recall* e *Precision*, cuja a descrição pode ser observada na Tabela 7.

Tabela 7 – Descrição das Métricas dos Modelos de Classificação.

Métrica	Descrição
Accuracy	Descreve quantas classes foram previstas corretamente, considerando classes positivas e negativas.
Kappa	Mostra a concordância entre os indivíduos, que pode ser interpretado como: < 0,00 – sem acordo; 0,00 a 0,20 – insignificante ou pobre; 0,21 a 0,40 – mediano ou justo; 0,41 e 0,60 – moderado; 0,61 a 0,80 – bom ou substancial e; > 0,81 – muito bom ou quase perfeito (CLASSE; CASTRO, 2020).
Recall	Descreve quantas classes foram previstas corretamente, considerando apenas as classes positivas (verdadeiros positivos e falsos negativos).
Precision	Descreve quantas classes previstas como positivas, eram realmente positivas.

Fonte: O Autor.

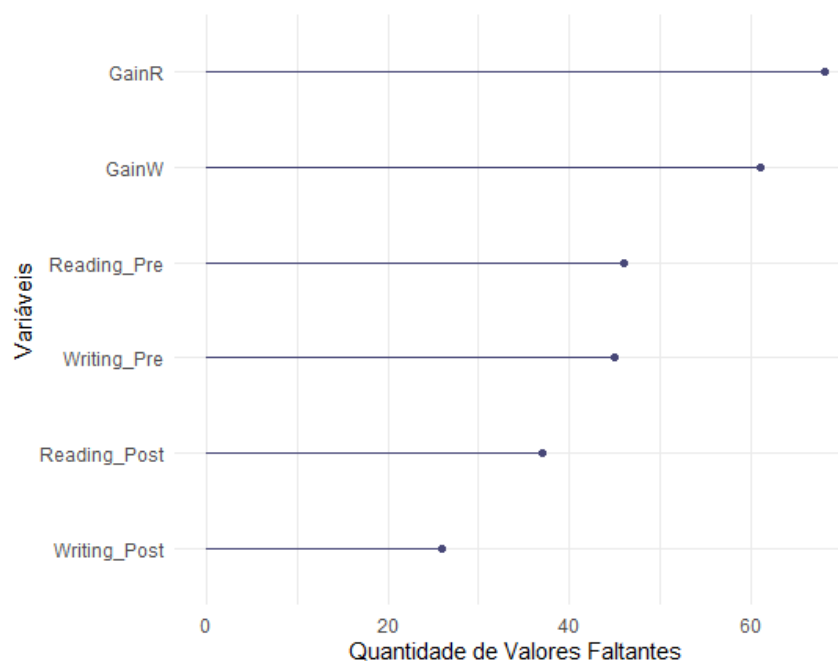
A partir dos valores das métricas levantados pela matriz de confusão, foi realizado um ranqueamento que demonstrou quais as combinações de técnicas, conjunto de variáveis de interação e variável alvo foram mais influentes para a precisão do efeito de aprendizagem adquirido pelos estudantes. Por fim, foi realizado um processo de validação, onde foi gerado o gráfico da Curva ROC, que se trata de uma medida gráfica para visualização da performance do classificador, que corresponde a proporção total dos indivíduos corretamente classificados (KASSAMBARA, 2017).

6 Resultados

Nesta seção serão descritos os resultados iniciais, assim como os resultados referentes aos dois experimentos executados, que tratam da identificação de padrões comportamentais a partir da análise de agrupamento, e da previsão do efeito de aprendizado adquirido a partir de técnicas de classificação.

Dito isto, inciaremos com uma exploração inicial do dados, onde foram notadas a presença de valores NA nas variáveis de pre e pos teste, e conseqüentemente também em ganho. A presença de um NA na variável, significa que o aluno não participou e portanto não obteve uma pontuação no teste, devido a isso representamos a quantidade de valores faltantes em um gráfico (Figura 15) a fim de entender o quão frequente ele se mostra nesses dados.


Figura 15 – Quantidade de valores faltantes nas variáveis.



Fonte: O Autor.

Tendo como base a proposta estabelecida na nossa seção de método, valores NA tornam a nossa análise inviável, pois o ganho será parte essencial do nosso entendimento de perfis. Devido a isso, decidimos por remover os sujeitos que possuem valores faltantes de nosso banco de dados, o que tornou uma amostra de 331 sujeitos em 255 (uma diminuição de 76 sujeitos), ainda assim, consideramos 255 uma ótima quantidade. Feito isso, decidimos explorar a distribuição de visualização, acertos e erros nos jogos.

Figura 16 – Valor médio de erros cometidos por jogo.



Fonte: O Autor.

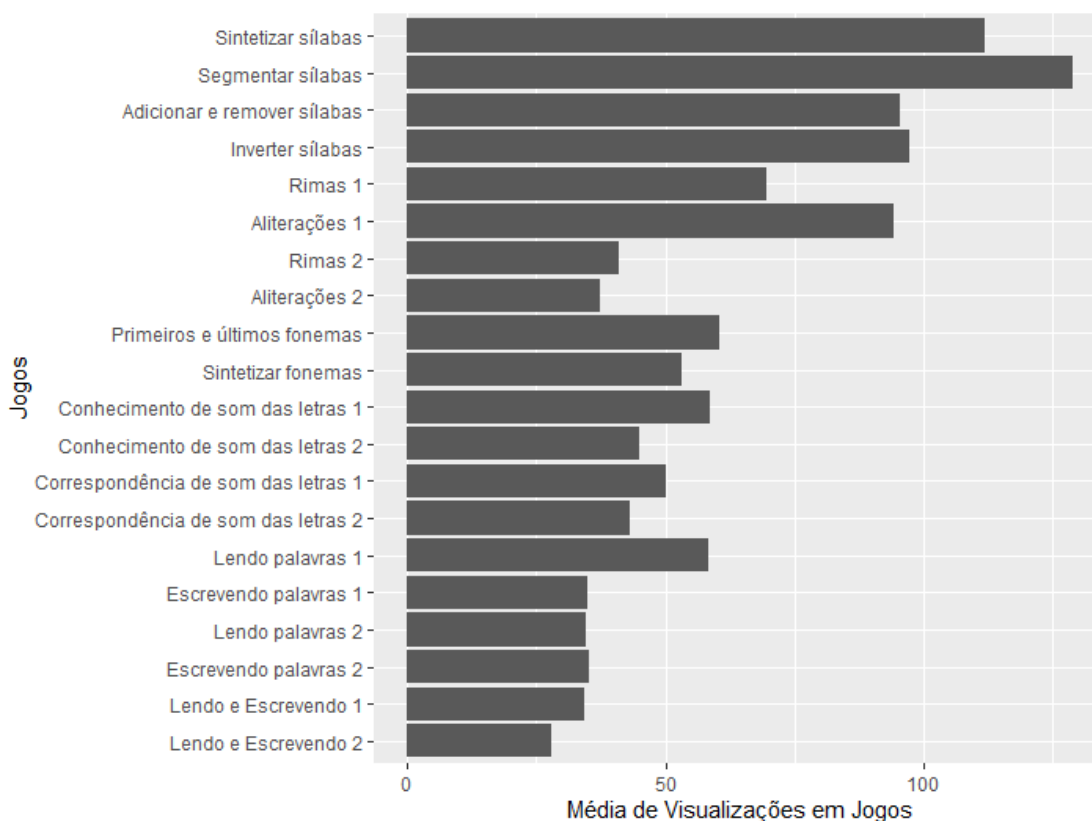
O gráfico representado na figura 16, demonstra a quantidade média de erros cometidos pelos alunos em cada um dos 20 jogos, na ordem em que estes jogos foram aplicados. Nesse sentido, nota-se uma taxa acima do normal nos dois primeiros jogos que envolve a sintetização e segmentação de sílabas.

Isso pode estar acontecendo justamente devido ao fato de serem os primeiros jogos a serem aplicados, e por isso acabam tendo um caráter mais experimental por parte dos alunos. Evidenciamos esse argumento com base nos gráficos de visualizações médias por jogo (Figura 17). Nele, notamos que a quantidade de visualizações para estes dois jogos específicos também são as mais altas.

Uma observação notável é que habilidades que são trabalhadas em mais de um jogo, o segundo jogo que trabalha essa habilidade, na maioria dos casos, demonstra uma quantidade de erros menor que o primeiro, o que pode significar uma melhora no aprendizado adquirido e/ou na utilização da plataforma pelo aluno. Também notamos que a quantidade de visualizações média por jogo tende a cair com o passar dos jogos, o que pode significar que, como os alunos tendem a errar menos com o tempo, não precisam repetir demais um mesmo jogo.

Nessa análise inicial já podemos perceber que as variáveis de erro, principal-

Figura 17 – Valor médio de visualizações de tela por jogo.



Fonte: O Autor.

mente quando comparadas com outras variáveis, parecem nos explicar bastante sobre como esses alunos utilizam os jogos, o que demonstra que essa base de dados é bastante promissora para a realização dos experimentos que almejamos executar.

6.1 Identificação de Perfis Comportamentais

Nesta seção, descreveremos os resultados obtidos através do processo de GLA que buscou aplicar uma análise de agrupamento a fim de identificar a existência de padrões comportamentais de estudantes na utilização de jogos educacionais.

6.1.1 Execução da Análise de Agrupamento

Antes de realizar o agrupamento, foi necessário aplicar 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 20 jogos. A tabela 8 mostra o resultado.


Tabela 8 – A estatística Hopkins para cada conjunto de atributos usados.

Atributos	Estatística Hopkins
V + W + R	0.290
V + R	0.320
V + W	0.289
R + W	0.288
V	0.332
R	0.334
W	0.250

Fonte: O Autor.

Na Tabela 8, V representa os atributos de visualização em 20 jogos, W são os erros e R são os acertos. É possível notar que os atributos de erro 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 conjuntos de atributos isolados. De acordo com esse 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, aquele que melhor distingue os alunos nos agrupamentos.

Em seguida, com o conjunto de dados contendo os atributos de erros nos 20 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 18 – Gráfico gerado pelo método *Elbow*.

Fonte: O Autor.

Ao analisar o gráfico (18), fica evidente a queda nos valores iniciais, passando de 1 para 4. 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 4 *clusters*. Após esta aplicação, entendeu-se que o valor de k mais indicado, o número de *clusters*, é o número 4, e este foi o valor utilizado para gerar os *clusters* com o algoritmo *k-means*.

6.1.2 Descoberta de Diferenças Entre os Grupos

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, tendo como alvo os atributos *Reading_Gain* e *Writing_Gain*, que representam respectivamente o ganho em leitura e escrita, conforme apresentado na Tabela 9.

Tabela 9 – Dados gerados pelo teste de Kruskal-Wallis.

Variável Alvo	Qui-quadrado	Graus de Liberdade	Valor-p
Reading_Gain	18.727	3	0.0003113
Writing_Gain	6.0664	3	0.1084

Fonte: O Autor.

Após a obtenção dos valores, deve-se entender se eles revelam a presença de diferentes distribuições entre os *clusters*. Para isso, será avaliado o valor-p, que utiliza o cálculo do qui-quadrado para gerar esse valor. Enquanto o *Reading_Gain* por *Cluster* foi significativo, pode-se notar que na aplicação do ganho de escrita foi obtido um valor acima de 0,05. Isso significa que não foi identificada diferença relevante entre os *clusters*, e entende-se que todos os quatro *clusters* obtiveram resultados próximos a partir desta variável alvo. Após isso, foi observado o quão relevante são as diferenças para o ganho de leitura, comparando *cluster* por *cluster* com o teste de Dunn, apresentado na Tabela 10.

Tabela 10 – Dados gerados pelo teste de Dunn.


Clusters	Valor-p	Valor-p Ajustado
Cluster 1 + Cluster 2	0.348	1
Cluster 1 + Cluster 3	0.0000857	0.000514
Cluster 1 + Cluster 4	0.129	0.774
Cluster 2 + Cluster 3	0.00262	0.0157
Cluster 2 + Cluster 4	0.0906	0.544
Cluster 3 + Cluster 4	0.0155	0.0933

Fonte: O Autor.

Na tabela acima temos demonstrado as combinações de *clusters* e seus respectivos valor-p, além disso, temos também os valor-p ajustados, que serão utilizados para realizar as análises, por se tratar de um valor mais preciso. Neste sentido, é possível observar que as diferenças entre os *Clusters* 1 e 2, 1 e 4, 2 e 4, e 3 e 4 possuem valor acima de 0,05, o que significa que não possuem diferenças relevantes. As comparações entre os *Clusters* 1 e 3, e 2 e 3, apresentam valor abaixo de 0,05, evidenciando diferença entre eles. Verifica-se também que a comparação entre os *Clusters* 3 e 4, mesmo sendo superior a 0,05, ainda foi muito próxima, o que revela que o *Cluster* 3 provavelmente influencia as diferenças observadas pelo teste.

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. No entanto, considerando que o atributo interno mais significativo foram os erros cometidos, foi construída uma visualização de como esses erros acontecem para cada grupo.

Figura 19 – Quantidade de erros no jogos por *Cluster*.



Fonte: O Autor.

A Figura 19 mostra os *boxplots* para a distribuição do número de erros cometidos em cada jogo, dividido por *clusters*. O *Cluster* 1, comparado aos demais, apresentou uma quantidade baixa de erros em todos os jogos, ficando praticamente abaixo do valor de 100. Já no *Cluster* 2 é possível notar diversos erros acima de 100 nos jogos relacionados à síntese e segmentação de sílabas. Essa dificuldade já foi notada durante a distribuição do *Cluster* 1 e se estende aos *clusters* 3 e 4. No *Cluster* 2, também

é notável a dificuldade nas atividades de escrita das palavras 1 e 2. O *Cluster 4*, por outro lado, apresenta uma distribuição muito próxima do *Cluster 3*, mas ainda consegue ter menos erros que os *Clusters 2 e 3* nas atividades de síntese e segmentação de sílabas. Após a obtenção dos resultados dos atributos internos, foi realizado um levantamento dos atributos externos.

6.1.3 Cálculo do Tamanho do Efeito por Grupo

Nesta seção, buscou-se calcular o *effect-size*, ou tamanho do efeito de cada *cluster*, para isso, realizamos um levantamento das médias, desvios padrão e quantidade de alunos que participaram do pré e pós-teste do grupo experimental (divididos por clusters) e do grupo de controle como um todo, pois esses valores serão essenciais para o cálculo do tamanho do efeito. A Tabela 11 demonstra os resultados desta análise.

Tabela 11 – Médias, desvios padrão e quantidade de participantes por *cluster*.

Leitura	Cluster 1		Cluster 2		Cluster 3		Cluster 4		Controle	
	Pré	Pós	Pré	Pós	Pré	Pós	Pré	Pós	Pré	Pós
Média	15.31	35.82	7.69	36.73	4.64	13.11	6.4	16.82	10.47	19.8
DP	27.1	36.89	12.98	31.65	6.35	23.77	14.61	21.94	16.03	25.21
N	98	98	13	13	60	60	79	79	353	365
Escrita	Cluster 1		Cluster 2		Cluster 3		Cluster 4		Controle	
	Pré	Pós	Pré	Pós	Pré	Pós	Pré	Pós	Pré	Pós
Média	22.43	39.51	16.76	31.03	8.58	17.85	12.55	21.51	15.4	24.28
DP	24.11	30.92	15.93	25.75	13.56	19.91	17.51	19.94	16.89	23.38
N	98	98	13	13	60	60	79	79	356	376

Fonte: O Autor.

Olhando de forma geral para as médias dos *clusters*, tanto em leitura como em escrita, é perceptível uma clara diferença entre o ganho (pós-teste - pré-teste) dos *Clusters 1 e 2*, que conseguiram obter melhorias consideráveis, em relação aos *Clusters 3 e 4*, que apresentam ganhos mais próximos do grupo controle, que não participou da intervenção com os jogos.

É importante ressaltar que o grupo de controle recebeu a instrução padrão de alfabetização fornecida por seus professores, portanto, já era esperado que esses alunos também melhorassem suas pontuações ao longo dos três meses durante os quais a intervenção baseada em jogos foi entregue ao grupo experimental. O experimento, então, comparou a intervenção gamificada com a instrução padrão fornecida pelas escolas, o que significa que os tamanhos de efeito representam um benefício adicional em comparação com o que os alunos já aprenderiam.

Outro fato é que o menor *cluster* em quantidade de alunos, o *Cluster 2*, obteve o maior ganho em leitura, que é a categoria com ganhos mais expressivos. Percebeu-se também que o *Cluster 3* é o que apresenta maior diferença, aproximando-se apenas do *Cluster 4*. Com esses valores, foi calculado o tamanho do efeito de cada *cluster* para evidenciar a existência de *clusters* mais ou menos propícios ao efeito da intervenção.

Tabela 12 – Tamanho do efeito de cada *cluster* em leitura e escrita.

Tamanho do Efeito	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Efeito Geral
Leitura	0.58	1.23	-0.05	0.07	0.40
Escrita	0.43	0.31	0.02	0.00	0.20

Fonte: O Autor.

A Tabela 12 mostra que o *Cluster 1*, que teve o maior número de alunos, teve efeitos mais fortes do que o efeito geral da intervenção tanto para leitura quanto para escrita. O *Cluster 2*, com apenas 13 alunos, apresentou efeito três vezes maior do que a intervenção geral para leitura e duas vezes maior para escrita. Também é notável que os *Clusters 3* e *4* não apresentaram efeitos relevantes. Esses tamanhos de efeito próximos de zero significam que os alunos dos grupos 3 e 4 aprenderam tanto quanto os alunos do grupo de controle que receberam a instrução padrão e não usaram os jogos. No entanto, os alunos dos *clusters 3* e *4* apresentaram pontuações pré-teste mais baixas do que as pontuações do grupo controle, indicando que esses dois *clusters* provavelmente ainda não haviam desenvolvido as habilidades necessárias para se beneficiar da intervenção.

6.2 Predição do Efeito de Aprendizado

Nesta seção, descreveremos os resultados obtidos através do processo de GLA que buscou treinar e validar algoritmos de classificação a fim avaliar em que nível é possível prever o efeito de aprendizado adquirido pelos estudantes a partir de suas características de interação com os jogos.

6.2.1 Aplicação das Técnicas de Classificação

Para o levantamento dos resultados aqui demonstrados, utilizamos 4 algoritmos de classificação diferentes, onde cada um destes foi executado para 7 combinações diferentes de variáveis, numa primeira rodada de testes em que a variável alvo foi o efeito em leitura e posteriormente numa segunda rodada de testes onde a variável alvo foi o efeito de escrita, o que totalizou 56 outputs diferentes. Dentre estes outputs estão os valores das métricas da classificação realizada, de onde foram extraídas as métricas *Accuracy*, *Kappa*, *Recall* e *Precision*.

Após a execução do teste de todas as possibilidades, os valores das métricas da classificação mencionados acima foram tabulados, onde foi possível notar um desempenho abaixo do esperado dos algoritmos quando a variável alvo foi modelada como sendo o efeito nas habilidades de escrita pelos alunos. Devido a isso, decidimos seguir apenas com os dados das classificações para o efeito na habilidade de leitura, e os 10 melhores resultados obtidos, ordenados de acordo com a métrica *Accuracy* podem ser observados na Tabela 13.

Tabela 13 – Melhores resultados obtidos pelas técnicas de classificação.

Modelo	Variáveis	Accuracy	Kappa	Recall	Precision
XGBoost	V + W	0.7467	0.4143	0.5385	0.6667
XGBoost	V + R + W	0.7467	0.3791	0.4231	0.7333
Random Forest	V + W	0.7467	0.3532	0.3462	0.8182
Random Forest	V + R + W	0.7467	0.3532	0.3462	0.8182
XGBoost	R	0.7333	0.3529	0.4231	0.6875
Random Forest	R + W	0.7333	0.3119	0.3077	0.8000
Random Forest	W	0.72	0.2997	0.3462	0.6923
GLM	W	0.72	0.2851	0.3077	0.7273
Random Forest	V	0.72	0.2698	0.2692	0.7778
SVM	W	0.7067	0.192	0.1539	1.0000

Fonte: O Autor.

Temos na tabela 13, os 10 melhores resultados obtidos pelas classificações, onde estão destacados em negrito os 3 melhores valores obtidos para cada métrica. A tabela está ordenada de acordo com a *Accuracy*, que informa em porcentagem quantas classificações, negativas e positivas, foram previstas corretamente. É possível notar no quesito *Accuracy*, um destaque dos classificadores *Random Forest* e *XGBoost*, principalmente quando utilizados em combinações de variáveis “V + W” e “V + R + W”. No que se refere a métrica *Kappa*, que mostra o grau de concordância dos indivíduos, temos que os melhores resultados referentes a *Accuracy* também se repetem para esta métrica, o que só reforça ainda mais os resultados obtidos, pois como demonstrado no trabalho de [Classe e Castro \(2020\)](#), valores de *Kappa* entre 0.21 e 0.40 são considerados como medianos ou justos e entre 0.41 e 0.60, moderados.

Também pode ser observado na tabela a métrica *Recall*, que demonstra a porcentagem de acerto da previsão considerando todas as classes positivas, o que engloba os verdadeiros positivos e os falsos negativos, e o *Precision*, que considerando todas as classes previstas como positivas, ou seja, os verdadeiros e falsos positivos, demonstra a porcentagem de quantas são realmente positivas. Para estas duas métricas, temos mais uma vez uma boa performance das melhores combinações para a *Accuracy* e *Kappa*, com um destaque para combinações de variáveis feitas com o

classificador *XGBoost* que obteve os melhores valores para a métrica *Recall* e o classificador *Random Forest*, que obteve os melhores valores na métrica *Precision*.


6.2.2 Validação dos Melhores Modelos Alcançados

Tendo finalizado o levantamento das melhores combinações, foi gerado o gráfico da Curva ROC e realizado o cálculo da *Area Under the Curve* (AUC), a partir da melhor combinação de variáveis para cada classificador, considerando a *Accuracy*, onde as melhores combinações foram:

- Classificador *Random Forest* com variáveis “V + W” (*Accuracy* = 0.7467)
- Classificador GLM com apenas variável “W” (*Accuracy* = 0.72)
- Classificador SVM com apenas variável “W” (*Accuracy* = 0.7067)
- Classificador *XGBoost* com variáveis “V + W” (*Accuracy* = 0.7467)

O gráfico da Curva ROC para estes 4 classificadores pode ser observado na Figura 20 abaixo.

Figura 20 – Curva ROC para os 4 classificadores utilizados.



Fonte: O Autor.

Temos na figura acima, a Curva ROC dos quatro classificadores a partir da combinação de variáveis que obteve melhor acurácia em cada um deles. Para entender

melhor o que essa visualização quer dizer, foram gerados os valores de AUC, que é uma representação gráfica da Curva ROC, onde quanto mais alto o valor de AUC for, melhor esse classificador performou na predição realizada. Os valores obtidos para cada classificador foram: *Random Forest* = 0.62; GLM = 0.70; SVM = 0.68; *XGBoost* = 0.63.

Com isso, entendemos que mesmo sendo notável uma carência de estudos que abordam a educação infantil, os resultados aqui demonstrados já se mostram promissores, e são o bastante para evidenciar que é possível pesquisarmos e explorarmos ainda mais a utilização de técnicas de Game Learning Analytics neste contexto. A partir das informações aqui levantadas, seguiremos no próximo capítulo com uma discussão que englobe tudo o que estes dados nos revelam do ponto de vista educacional.

7 Implicações Educacionais

7.1 Diferenças no Desempenho entre os Clusters

Este primeiro experimento aplicado, que envolve a análise de agrupamento, procurou analisar mais a fundo os resultados da intervenção de leitura e escrita de palavras baseada em jogos para identificar grupos de alunos que poderiam ter se beneficiado de forma diferente do programa instrucional. Fizemos isso examinando os dados coletados pelos jogos quando os alunos estavam jogando e, em seguida, conduzindo uma análise de agrupamento para identificar os alunos que apresentaram desempenho e comportamento semelhantes nos jogos. Em seguida, calculamos os tamanhos de efeito para cada um dos quatro grupos e os comparamos com os tamanhos de efeito geral da intervenção.

Observando o número de erros que os alunos apresentaram em cada jogo (19), podemos identificar algumas tendências. Os alunos dos *Clusters* 3 e 4 apresentaram desempenho reduzido em relação ao *Cluster* 1 em toda a intervenção. Isso significa que obtiveram mais erros nos jogos desafiadores de leitura e escrita de palavras que foram jogados no final da intervenção e nos jogos mais fáceis que lidaram com sílabas, rima, aliteração e consciência fonêmica.

O *cluster 2* foi composto por 13 alunos da mesma escola com notas no pré-teste de leitura semelhantes aos dos *clusters* 3 e 4. Esses alunos apresentaram desempenho semelhante aos *clusters* 3 e 4 em jogos de sílabas, rima e consciência fonêmica. Apesar disso, apresentaram melhor desempenho nos jogos de leitura e escrita de palavras. Poderíamos especular que eles podem ter recebido apoio extra de seu professor fora da intervenção. A instrução complementar sistemática no conhecimento de letras, sons, decodificação e ortografia poderia ter aumentado seu desempenho nos jogos finais e nas avaliações de leitura e escrita pós-teste.

Identificamos que o número de erros que o aluno teve em cada um dos jogos foi a característica de interação que mais os diferenciou. Usando as variáveis das quantidades de erros, o procedimento de agrupamento determinou que quatro é o número ideal de agrupamentos para esta base de dados. Finalmente, os tamanhos de efeito de cada *cluster* revelaram três tendências de comportamento.

O perfil 1, formado pelo *Cluster* 1, que contém o maior número de alunos, parece representar o efeito da intervenção quando entregue aos alunos que possuem as habilidades que são pré-requisitos necessários. O tamanho do efeito de leitura para o *Cluster* 1 foi 46% maior do que o efeito geral da intervenção. O efeito de escrita do

Cluster 1 foi 100% maior que o geral. Esses resultados sugerem que a forma atual da intervenção deve ser entregue a alunos com o perfil do *Cluster 1* em relação às suas habilidades de leitura e escrita existentes.

O Perfil 2 é representado pelas crianças do *Cluster 2*, que se beneficiaram duas vezes mais da intervenção do que os alunos do *Cluster 1*. Cabe destacar que os professores e a coordenadora pedagógica desta escola participaram das discussões durante o desenvolvimento da intervenção antes da execução do estudo randomizado controlado. Os tamanhos de efeito mais altos observados neste *cluster* podem indicar o potencial total de intervenção quando os professores estão totalmente engajados em sua implementação ou são entregues juntamente com instruções sistemáticas em conhecimento de letras e sons, decodificação e ortografia.

O Perfil 3, composto pelos *clusters* 3 e 4 parecem caracterizar os alunos que ainda não estavam prontos para usar a intervenção educativa. As pontuações baixas do pré-teste dos alunos indicam que eles podem ainda não ter dominado as habilidades básicas que são pré-requisitos, como reconhecer letras e vocabulário apropriado para a idade. Essa descoberta sugere que a intervenção pode precisar ser expandida para incluir instruções e jogos que apoiem esses alunos na construção de habilidades fundamentais. O reconhecimento de letras, a discriminação fonológica e a expansão do vocabulário podem ser habilidades promissoras a serem trabalhadas antes de fornecer consciência fonológica, instrução precoce de leitura e escrita nos jogos.

7.2 Modelos de Classificação mais Relevantes

Neste segundo experimento, referente a previsão do desempenho, buscamos realizar um processo de Game Learning Analytics com o objetivo de verificar em que nível é possível prever o efeito de aprendizado e quais são as características de interação e algoritmos de classificação que melhor desempenham esta tarefa.

Para isso, testamos as sete combinações possíveis de variáveis e quatro modelos de classificação diferentes. Considerando os melhores valores demonstrados na Tabela 13, obtivemos: (*Accuracy* = 0.7467; *Recall* = 0.5385; *Precision* = 0.8182). Estes valores se mostram dentro do esperado quando comparados com o trabalho de [Shin, Kim e Gweon \(2020\)](#), cuja amostra possui características que se aproximam do nosso estudo, tendo obtido como melhores valores: (*Accuracy* = 0.778; *Recall* = 0.781; *Precision* = 0.777).

No entanto, analisando os resultados de estudos como os de [Juric, Bakaric e Matetic \(2021\)](#), que conseguiu valores de *Accuracy* acima de 0.90, ou as de [Alonso-Fernández et al. \(2020\)](#), que conseguiu valores acima de 0.90 em *Recall* e *Precision*, torna perceptível que nossos valores estão abaixo dos trabalhos relacionados, quando

os comparamos com os de pesquisas em que o público alvo não foram estudantes da educação infantil.

Dito isto, entendemos que dada a robustez do experimento em que foi realizada a coleta dos dados, que durou um período de 10 semanas e contou com a participação de 331 estudantes de 15 escolas diferentes, além do fato de que estes estudantes pertencem a educação infantil, um grupo pouco abordado nas pesquisas relacionadas, torna os resultados obtidos bastante promissores.

Além da *Accuracy* ter alcançado um valor dentro de uma faixa razoável e esperada para este contexto, obtivemos um *Precision* de 0.8182 (81%), o que torna o nosso preditor bom em classificar corretamente os estudantes que obtiveram um efeito positivo de aprendizado, isso significa que é muito difícil um estudante que não obteve efeito de aprendizado ser classificado incorretamente, no entanto o *Recall* foi baixo, atingindo apenas 0.5385 (53%), o que torna nosso preditor relativamente falho em classificar corretamente os estudantes que não obtiveram um efeito de aprendizado.

Para identificar quais características de interação e modelos de classificação foram mais eficazes para o processo de predição, realizamos um levantamento das 10 melhores combinações, baseado na métrica *Accuracy*, que indica quantas classes foram previstas corretamente.

Na Tabela 13, é possível notar que a característica que mais se repete são a de erros nos jogos (“W”), estando presente em 8 das 10 melhores combinações levantadas, além disso, as características de erros também estão presentes no melhor resultado de cada classificador, o que evidencia o quão importante é, considerando nossa base de dados, o uso das variáveis de erros nos jogos, reforçando assim o achado do experimento anterior, onde foi aplicada uma análise de agrupamento nesta mesma base de dados e descobriu que as características de erros são as mais determinantes para a geração de grupos com diferentes perfis comportamentais.

Além disso, temos o *XGBoost* e o *Random Forest* como os classificadores que obtiveram melhor *Accuracy*, ambos empatados com 74%, em ambos temos também bons valores na métrica *Kappa* atingindo acima de 0.30 o que reforça os resultados obtidos. A principal diferença entre as duas técnicas está presente nas métricas de *Recall* onde o *XGboost* desempenhou melhor e *Precision* onde quem desempenhou melhor foi o classificador *Random Forest*.

Entendemos que a prioridade para o nosso contexto de pesquisa seja adotar um classificador em que o custo dos falsos positivos seja alto, pois entendendo que o objetivo é identificar aqueles estudantes que precisam de ajuda durante o processo de utilização dos jogos, queremos ao máximo evitar que alunos que não possuem efeito de aprendizado estejam sendo classificados como tendo efeito. Sendo assim,

o classificador *Random Forest* foi o escolhido como o mais adequado, pois foi o que atingiu a maior taxa de *Precision*, que chega a 81%.

8 Considerações Finais

Buscamos nesta dissertação, aplicar técnicas de *Game Learning Analytics* para dois objetivos diferentes: 1) Identificar perfis comportamentais entre os estudantes; 2) Predizer o efeito de aprendizado dos estudantes. Para isso, utilizamos uma base de dados que contou com participantes de um experimento que aplicou um conjunto de 20 jogos para o desenvolvimento de habilidades de leitura e escrita na educação infantil.

A partir das avaliações levantadas, entendemos que poderiam ser implementadas algumas medidas de apoio ao baixo desempenho. Até mesmo os alunos que apresentaram notas mais baixas no pré-teste (dos Clusters 3 e 4), não cometeram erros nos segundos jogos de aliteração e rimas. A ausência de erros significa que as crianças já dominaram as habilidades/dificuldades apresentadas por esses jogos. Essa descoberta sugere que ambos os jogos podem ser removidos da sequência instrucional ou substituídos por novos jogos para promover a consciência fonêmica. Atividades adicionais de conhecimento de letras e sons podem beneficiar essas crianças, pois são mais propícias à leitura e escrita de palavras.

Para alunos de alto desempenho, a intervenção também poderia ser melhorada. Os segundos jogos de rima e aliteração poderiam ser substituídos por novos jogos de leitura e escrita de palavras. Esses jogos avançados poderiam ser entregues ao final da intervenção para as crianças que tiveram desempenho acima da média nos últimos jogos.

No geral, a intervenção poderia ser melhorada com um mecanismo de personalização. Com base no desempenho do aluno, ele poderia receber estimulação adicional ou personalizada durante os principais pontos de transição da intervenção. No início, os alunos que não apresentassem habilidades que são pré-requisitos para a intervenção, poderiam receber estímulos de reconhecimento de letras. Os alunos que não dominam um domínio de habilidade (por exemplo, consciência fonêmica) podem receber mais estimulação antes de prosseguir para o próximo domínio (por exemplo, leitura e escrita de palavras). Os jogos personalizados podem ser entregues na sala de aula ou em casa.

Com os resultados aqui levantados, também se torna possível realizar a implementação dos modelos de classificação desenvolvidos em tempo real, a partir da construção de ferramentas e aplicações que ajudem os professores a identificar aqueles alunos que necessitam de ajuda ainda durante o processo de aprendizado, e com isso contribuir para evitar a utilização de instrumentos avaliativos baseados em provas e testes, que são custosos, necessitam de tempo para serem aplicados e de pessoas

capacitadas para realizar a aplicação.

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 250 alunos de 4 anos de idade. Além disso, os atributos de dados disponíveis foram de 20 jogos específicos que visavam desenvolver habilidades de consciência fonológica, leitura de palavras e escrita. Por fim, o Estudo Randomizado Controlado incluiu apenas escolas particulares que atendem famílias de classe média. Estudos futuros podem realizar análises semelhantes com outras intervenções baseadas em jogos ou até mesmo com o *Escribo Play* quando entregues a alunos em situação de pobreza.

No entanto, este estudo demonstrou a aplicabilidade do emprego de técnicas de *Game Learning Analytics* para descompactar os efeitos de uma intervenção a fim de melhorar seu design e mecanismos de entrega. Os dados coletados pelos jogos enquanto os alunos jogavam foram suficientes para agrupar os participantes em agrupamentos significativamente diferentes de acordo com medidas padronizadas. Esses *clusters* apresentaram tamanhos de efeito diferentes quando comparados ao grupo controle da intervenção. Além disso, também foi demonstrado na nossa base de dados, o quanto as variáveis de erros são determinantes para a diferenciação dos indivíduos e de que é possível prever quais estudantes terão um efeito de aprendizado positivo com cerca de 81% de precisão.

O estudo demonstrou que a articulação entre instrumentos de avaliação neuropsicológica, a *Game Learning Analytics*, que coleta dados procedimentais, e a melhoria contínua da intervenção educativa podem fortalecer a aprendizagem, reduzindo as desigualdades educacionais que afetam os alunos desde a pré-escola.

9 Produção Científica Construída a Partir desta Dissertação

Nesta seção estão elencados os artigos científicos produzidos como fruto das pesquisas e experimentos realizados durante o período da formação de mestrado, sendo eles construídos em participação do grupo de pesquisa e partes desta dissertação.

No que se refere aos estudos construídos como partes dessa dissertação, temos o artigo intitulado *Discovery of Research Gaps in Game Learning Analytics Applications on Learning Processes*¹, referente ao mapeamento sistemático abordado no capítulo 4. O artigo em questão foi publicado nos Anais do XXXI Simpósio Brasileiro de Informática na Educação (SBIE 2020), evento integrante do Congresso Brasileiro de Informática na Educação - CBIE, maior evento da área no Brasil, no dia 24 de novembro de 2020. Vale destacar que mesmo o artigo em questão tendo sido publicado no ano de 2020, o capítulo 4 desta dissertação trata-se de uma versão atualizada, realizada em Janeiro de 2022.

O segundo estudo publicado como fruto desta dissertação é o artigo intitulado *Game learning analytics can unpack Escribo play effects in preschool early reading and writing*², referente ao experimento de identificação de padrões comportamentais a partir da análise de agrupamento, que compõe partes dos capítulos 05 ao 07 desta dissertação, estando assim presentes em método, resultados e discussões, respectivamente. Este estudo foi publicado na *Computers and Education Open* (CEAO), que é um periódico de acesso aberto, revisado por pares, focado nas maneiras pelas quais a tecnologia digital pode melhorar a educação, estando disponível na página da web da *ScienceDirect*.

Temos por fim, considerando esta dissertação, o artigo intitulado *Forecast the performance of early childhood education students through a game-based learning approach*, que se refere ao experimento de predição do efeito de aprendizado adquirido, realizado a partir do uso de Classificadores. O artigo em questão se encontra no presente momento nas fases finais de construção, estando dessa forma ainda em processo de revisão e melhorias, não tendo sido ainda publicado.

Como trabalhos publicados a partir de participação em estudos realizados em conjunto ao grupo de pesquisa Evante³, temos o artigo Metodologia Baseada em Proje-

¹ <https://sol.sbc.org.br/index.php/sbie/article/view/12876>

² <https://www.sciencedirect.com/science/article/pii/S2666557321000379>

³ <https://evante.com.br/>

tos para Desenvolvimento de Games em Educação Remota⁴, onde buscamos validar uma metodologia de ensino baseada em projetos que foi aplicada em um curso de desenvolvimento de jogos em um contexto remoto, sendo publicado na 20ª edição do Simpósio Brasileiro de Games, a SBGames, em 18 de Outubro de 2021.

Por fim, temos o artigo intitulado *Linking Engagement Profiles to Academic Performance Through SNA and Cluster Analysis on Discussion Forum Data*⁵, onde foi realizado um experimento utilizando a *Social Network Analysis* (SNA) e análise de cluster aos dados de um fórum para identificar grupos de alunos com diferentes perfis de engajamento. O artigo foi publicado e apresentado no segundo dia da IV Conferencia Latinoamericana de Analíticas de aprendizaje do ano de 2021.

⁴ <https://www.sbgames.org/sbgames2021/proceedings-sbgames-2021/>

⁵ <http://ceur-ws.org/Vol-3059/>

Referências

- ADMIRAAL, W. et al. The concept of flow in collaborative game-based learning. *Computers in Human Behavior*, Elsevier, v. 27, n. 3, p. 1185–1194, 2011. Citado 2 vezes nas páginas 17 e 19.
- AKRAM, B. et al. Improving stealth assessment in game-based learning with lstm-based analytics. In: *International Conference on Educational Data Mining*. [S.l.: s.n.], 2018. Citado 3 vezes nas páginas 30, 31 e 32.
- ALDOWAH, H.; AL-SAMARRAIE, H.; FAUZY, W. M. Educational data mining and learning analytics for 21st century higher education: A review and synthesis. *Telematics and Informatics*, Elsevier, v. 37, p. 13–49, 2019. Citado na página 21.
- ALONSO-FERNANDEZ, C. et al. Systematizing game learning analytics for serious games. In: IEEE. *2017 IEEE global engineering education conference (EDUCON)*. [S.l.], 2017. p. 1111–1118. Citado 2 vezes nas páginas 13 e 24.
- ALONSO-FERNANDEZ, C. et al. Applications of data science to game learning analytics data: A systematic literature review. *Computers & Education*, Elsevier, v. 141, p. 103612, 2019. Citado 2 vezes nas páginas 23 e 24.
- ALONSO-FERNÁNDEZ, C. et al. Lessons learned applying learning analytics to assess serious games. *Computers in Human Behavior*, Elsevier, v. 99, p. 301–309, 2019. Citado na página 13.
- ALONSO-FERNÁNDEZ, C. et al. Predicting students' knowledge after playing a serious game based on learning analytics data: A case study. *Journal of Computer Assisted Learning*, Wiley Online Library, v. 36, n. 3, p. 350–358, 2020. Citado 5 vezes nas páginas 24, 30, 31, 32 e 60.
- AMORIM, A. N. et al. Using escribo play video games to improve phonological awareness, early reading, and writing in preschool. *Educational Researcher*, SAGE Publications Sage CA: Los Angeles, CA, v. 49, n. 3, p. 188–197, 2020. Citado 7 vezes nas páginas 26, 35, 36, 37, 38, 40 e 45.
- ANASTASIADIS, T.; LAMPROPOULOS, G.; SIAKAS, K. Digital game-based learning and serious games in education. *International Journal of Advances in Scientific Research and Engineering*, v. 4, n. 12, p. 139–144, 2018. Citado 5 vezes nas páginas 16, 17, 18, 19 e 20.
- BAKSHINATEGH, B. et al. Educational data mining applications and tasks: A survey of the last 10 years. *Education and Information Technologies*, Springer, v. 23, n. 1, p. 537–553, 2018. Citado na página 22.
- BURGUILLO, J. C. Using game theory and competition-based learning to stimulate student motivation and performance. *Computers & education*, Elsevier, v. 55, n. 2, p. 566–575, 2010. Citado na página 18.

- CALDERÓN, A.; RUIZ, M. A systematic literature review on serious games evaluation: An application to software project management. *Computers & Education*, Elsevier, v. 87, p. 396–422, 2015. Citado na página 23.
- CALLAGHAN, M. J.; MCSHANE, N.; EGUILUZ, A. G. Using game analytics to measure student engagement/retention for engineering education. In: IEEE. *2014 11th International Conference on Remote Engineering and Virtual Instrumentation (REV)*. [S.l.], 2014. p. 297–302. Citado 3 vezes nas páginas 30, 31 e 32.
- CHENG, Y.-M. et al. Investigating elementary school students' technology acceptance by applying digital game-based learning to environmental education. *Australasian Journal of Educational Technology*, v. 29, n. 1, 2013. Citado na página 17.
- CLASSE, T. M. d.; CASTRO, R. M. d. Técnicas e conceitos de business intelligence para avaliação em jogos educacionais: Um mapeamento sistemático da literatura. *Proceedings of SBGames 2020*, 2020. Citado 2 vezes nas páginas 47 e 56.
- CROOKALL, D. Serious games, debriefing, and simulation/gaming as a discipline. *Simulation & gaming*, SAGE Publications Sage CA: Los Angeles, CA, v. 41, n. 6, p. 898–920, 2010. Citado na página 12.
- DESIMONE, L. M.; HILL, K. L. Inside the black box: Examining mediators and moderators of a middle school science intervention. *Educational Evaluation and Policy Analysis*, SAGE Publications Sage CA: Los Angeles, CA, v. 39, n. 3, p. 511–536, 2017. Citado na página 13.
- DINNO, A. Nonparametric pairwise multiple comparisons in independent groups using dunn's test. *The Stata Journal*, SAGE Publications Sage CA: Los Angeles, CA, v. 15, n. 1, p. 292–300, 2015. Citado na página 45.
- DRACHEN, A.; EL-NASR, M. S.; CANOSSA, A. *Game Analytics: Maximizing the Value of Player Data*. [S.l.]: Springer, 2013. Citado na página 13.
- EICHENBAUM, A.; BAVELIER, D.; GREEN, C. S. Video games: Play that can do serious good. *American Journal of Play*, v. 7, n. 1, p. 50–72, 2014. Citado na página 16.
- 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*, Elsevier, v. 102, n. 1, p. 75–80, 2011. Citado na página 45.
- EMERSON, A. et al. Multimodal learning analytics for game-based learning. *British Journal of Educational Technology*, Wiley Online Library, v. 51, n. 5, p. 1505–1526, 2020. Citado 3 vezes nas páginas 30, 31 e 32.
- FENG, X.; YAMADA, M. Effects of game-based learning on informal historical learning: A learning analytics approach. In: *Proceedings of International Conference on Computer in Education*. [S.l.: s.n.], 2019. Citado 3 vezes nas páginas 30, 31 e 32.
- FENG, X.; YAMADA, M. Design and development of visualization approaches for informal learning game logs. In: *Proceedings of the 2020 DiGRA International Conference: Play Everywhere*. DiGRA. Retrieved from http://www.digra.org/wp-content/uploads/digital-library/DiGRA_2020_paper_104.pdf. [S.l.: s.n.], 2020. Citado na página 25.

FENG, X.; YAMADA, M. An analytical approach for detecting and explaining the learning path patterns of an informal learning game. *Educational Technology & Society*, JSTOR, v. 24, n. 1, p. 176–190, 2021. Citado na página 26.

FLORES, R. L. et al. Motivational factors through learning analytics in digital game-based learning. In: *Data Analytics Approaches in Educational Games and Gamification Systems*. [S.l.]: Springer, 2019. p. 213–226. Citado 2 vezes nas páginas 30 e 32.

FREIRE, M. et al. Game learning analytics: learning analytics for serious games. In: *Learning, design, and technology*. [S.l.]: Springer Nature Switzerland AG, 2016. p. 1–29. Citado 5 vezes nas páginas 12, 13, 23, 24 e 25.

GEE, J. P. What video games have to teach us about learning and literacy. *Computers in Entertainment (CIE)*, ACM New York, NY, USA, v. 1, n. 1, p. 20–20, 2003. Citado na página 16.

GOMEZ, M. J. et al. Applying learning analytics to detect sequences of actions and common errors in a geometry game. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 21, n. 4, p. 1025, 2021. Citado 3 vezes nas páginas 30, 31 e 32.

GRIS, G.; BENGTSON, C. Assessment measures in game-based learning research: A systematic review. *International Journal of Serious Games*, v. 8, n. 1, p. 3–26, 2021. Citado na página 25.

HAIR, J. F. et al. *Análise multivariada de dados*. [S.l.]: Bookman editora, 2009. Citado 2 vezes nas páginas 26 e 43.

HECKE, T. V. Power study of anova versus kruskal-wallis test. *Journal of Statistics and Management Systems*, Taylor & Francis, v. 15, n. 2-3, p. 241–247, 2012. Citado na página 44.

HOU, H.-T. 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*, Elsevier, v. 56, n. 3, p. 712–719, 2011. Citado na página 43.

JUHAŇÁK, L.; ZOUNEK, J.; ROHLÍKOVÁ, L. Using process mining to analyze students' quiz-taking behavior patterns in a learning management system. *Computers in Human Behavior*, Elsevier, v. 92, p. 496–506, 2019. Citado na página 13.

JURIC, P.; BAKARIC, M. B.; MATETIC, M. Detecting students gifted in mathematics with stream mining and concept drift based m-learning models integrating educational computer games. *International Journal of Emerging Technologies in Learning (IJET)*, v. 16, n. 12, p. pp. 155–168, Jun. 2021. Disponível em: <<https://online-journals.org/index.php/i-jet/article/view/21925>>. Citado na página 60.

KASSAMBARA, A. *Practical guide to cluster analysis in R: Unsupervised machine learning*. [S.l.]: Sthda, 2017. v. 1. Citado 3 vezes nas páginas 43, 46 e 47.

KITCHENHAM, B. A.; BUDGEN, D.; BRERETON, O. P. Using mapping studies as the basis for further research—a participant-observer case study. *Information and Software Technology*, Elsevier, v. 53, n. 6, p. 638–651, 2011. Citado na página 27.

- KRAFT, M. A. Interpreting effect sizes of education interventions. *Educational Researcher*, Sage Publications Sage CA: Los Angeles, CA, v. 49, n. 4, p. 241–253, 2020. Citado na página 45.
- KUCUK, S.; SISMAN, B. Behavioral patterns of elementary students and teachers in one-to-one robotics instruction. *Computers & Education*, Elsevier, v. 111, p. 31–43, 2017. Citado na página 14.
- LANG, C. et al. *Handbook of learning analytics*. [S.l.]: SOLAR, Society for Learning Analytics and Research New York, NY, USA, 2017. Citado na página 22.
- LENHARD, W.; LENHARD, A. Calculation of effect sizes. Retrieved from: https://www.psychometrica.de/effect_size.html, Dettelbach (Germany): Psychometrica, 2016. Citado na página 45.
- LEÓN, C. B. R. et al. Phonological awareness and early reading and writing abilities in early childhood education: preliminary normative data. *Revista CEFAC*, SciELO Brasil, v. 21, 2019. Citado na página 35.
- LI, S. et al. Longitudinal clustering of students' self-regulated learning behaviors in engineering design. *Computers & Education*, Elsevier, v. 153, p. 103899, 2020. Citado na página 43.
- LOH, C. S.; SHENG, Y.; IFENTHALER, D. Serious games analytics. Edited by Christian Sebastian Loh, Yanyan Sheng, and Dirk Ifenthaler. Cham: Springer International Publishing. doi, Springer, v. 10, p. 978–3, 2015. Citado na página 23.
- LOH, C. S.; SHENG, Y.; IFENTHALER, D. Serious games analytics: Theoretical framework. In: *Serious games analytics*. [S.l.]: Springer, 2015. p. 3–29. Citado 3 vezes nas páginas 14, 17 e 18.
- MAGRO, C. F. L.; JUNIOR, D. R. C. Os jogos eletrônicos na educação infantil: outras possibilidades de ensinar e aprender. *Temática*, 2015. Citado na página 12.
- MARTIN, T. et al. Nanogenetic learning analytics: Illuminating student learning pathways in an online fraction game. In: *Proceedings of the third international conference on learning analytics and knowledge*. [S.l.: s.n.], 2013. p. 165–169. Citado 2 vezes nas páginas 30 e 32.
- MCKIGHT, P. E.; NAJAB, J. Kruskal-wallis test. *The corsini encyclopedia of psychology*, Wiley Online Library, p. 1–1, 2010. Citado na página 44.
- MICHAEL, D. R.; CHEN, S. L. *Serious games: Games that educate, train, and inform*. [S.l.]: Muska & Lipman/Premier-Trade, 2005. Citado na página 12.
- NGUYEN, H. A. et al. Moving beyond test scores: Analyzing the effectiveness of a digital learning game through learning analytics. *International Educational Data Mining Society*, ERIC, 2020. Citado 3 vezes nas páginas 30, 31 e 32.
- NIEMELÄ, M. et al. Game learning analytics for understanding reading skills in transparent writing system. *British Journal of Educational Technology*, Wiley Online Library, v. 51, n. 6, p. 2376–2390, 2020. Citado 3 vezes nas páginas 26, 30 e 32.

- PEDDYCORD-LIU, Z. et al. Using serious game analytics to inform digital curricular sequencing: What math objective should students play next? In: *Proceedings of the Annual Symposium on Computer-Human Interaction in Play*. [S.l.: s.n.], 2017. p. 195–204. Citado 2 vezes nas páginas 30 e 32.
- PELLEGRINI, A. D.; DUPUIS, D.; SMITH, P. K. Play in evolution and development. *Developmental review*, Elsevier, v. 27, n. 2, p. 261–276, 2007. Citado na página 16.
- PEREZ-COLADO, I. et al. Game learning analytics is not informagic! In: *IEEE. 2018 IEEE Global Engineering Education Conference (EDUCON)*. [S.l.], 2018. p. 1729–1737. Citado na página 23.
- PRENSKY, M. *Digital game-based learning*, mcgraw-hill & paragon house, new york. 2001. Citado na página 19.
- PRIYAADHARSHINI, M. et al. Learning analytics: Game-based learning for programming course in higher education. *Procedia Computer Science*, Elsevier, v. 172, p. 468–472, 2020. Citado 2 vezes nas páginas 30 e 32.
- PROTOPSALTIS, A. et al. Serious games and formal and informal learning. *E-Learning Papers*, p. 1887–1542, 2011. Citado na página 17.
- QASRAWI, R.; AMRO, M.; JAYOUSI, R. Automatic analytics model for learning skills analysis using game player data and robotic process automation in a serious game for education. In: *IEEE. 2020 International Conference on Promising Electronic Technologies (ICPET)*. [S.l.], 2020. p. 94–98. Citado 3 vezes nas páginas 30, 31 e 32.
- ROLIM, F. J. R. A influência dos jogos eletrônicos na educação: uma abordagem sobre o lúdico no ensino da matemática. *Centro de Ciências Exatas e Sociais Aplicadas, Universidade Estadual da Paraíba*, 2013. Citado na página 12.
- ROMERO, C.; VENTURA, S. Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Wiley Online Library, v. 10, n. 3, p. e1355, 2020. Citado 2 vezes nas páginas 21 e 22.
- RONIMUS, M. et al. Children’s engagement during digital game-based learning of reading: The effects of time, rewards, and challenge. *Computers & Education*, Elsevier, v. 71, p. 237–246, 2014. Citado na página 17.
- SALEN, K.; TEKINBAŞ, K. S.; ZIMMERMAN, E. *Rules of play: Game design fundamentals*. [S.l.]: MIT press, 2004. Citado na página 16.
- SANCHEZ, E.; MANDRAN, N. Exploring competition and collaboration behaviors in game-based learning with playing analytics. In: *SPRINGER. European Conference on Technology Enhanced Learning*. [S.l.], 2017. p. 467–472. Citado 3 vezes nas páginas 29, 31 e 32.
- SCIENTISTS, F. Harnessing the power of video games for learning. *Summit on Educational Games*, 2006. Citado na página 19.

SHIN, H.; KIM, B.; GWEON, G. Guessing or solving? exploring the use of motion features from educational game logs. In: . New York, NY, USA: Association for Computing Machinery, 2020. (CHI EA '20), p. 1–8. ISBN 9781450368193. Disponível em: <<https://doi.org/10.1145/3334480.3383005>>. Citado na página 60.

SHUTE, V. J.; RAHIMI, S. Stealth assessment of creativity in a physics video game. *Computers in Human Behavior*, Elsevier, v. 116, p. 106647, 2021. Citado na página 25.

SPIRES, H. A. Digital game-based learning: What's literacy got to do with it? *Journal of Adolescent & Adult Literacy*, Wiley Online Library, v. 59, n. 2, p. 125–130, 2015. Citado na página 19.

SUNG, H.-Y.; HWANG, G.-J. A collaborative game-based learning approach to improving students' learning performance in science courses. *Computers & education*, Elsevier, v. 63, p. 43–51, 2013. Citado na página 17.

TAN, P.-N.; STEINBACH, M.; KUMAR, V. *Introduction to data mining*. [S.l.]: Pearson Education India, 2016. Citado na página 43.

VAHDAT, M. et al. Learning analytics for a puzzle game to discover the puzzle-solving tactics of players. In: SPRINGER. *European Conference on Technology Enhanced Learning*. [S.l.], 2016. p. 673–677. Citado 4 vezes nas páginas 26, 30, 31 e 32.

VAHLDICK, A.; MENDES, A. J.; MARCELINO, M. J. Dynamic difficulty adjustment through a learning analytics model in a casual serious game for computer programming learning. *EAI Endorsed Transactions on Serious Games*, European Alliance for Innovation (EAI), v. 4, n. 13, 2017. Citado 3 vezes nas páginas 30, 31 e 32.

WEN, C.-T. et al. The learning analytics of model-based learning facilitated by a problem-solving simulation game. *Instructional Science*, Springer, v. 46, n. 6, p. 847–867, 2018. Citado 3 vezes nas páginas 30, 31 e 32.

WESTERA, W.; NADOLSKI, R.; HUMMEL, H. Learning analytics in serious gaming: uncovering the hidden treasure of game log files. In: SPRINGER. *International Conference on Games and Learning Alliance*. [S.l.], 2013. p. 41–52. Citado 3 vezes nas páginas 30, 31 e 32.

ZAPATA-CÁCERES, M.; MARTÍN-BARROSO, E. Applying game learning analytics to a voluntary video game: Intrinsic motivation, persistence, and rewards in learning to program at an early age. *IEEE Access*, IEEE, v. 9, p. 123588–123602, 2021. Citado 3 vezes nas páginas 30, 31 e 32.

ZHONGGEN, Y. A meta-analysis of use of serious games in education over a decade. *International Journal of Computer Games Technology*, Hindawi, v. 2019, 2019. Citado na página 17.

Dados Internacionais de Catalogação na Publicação
Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

- S586a Silva, Gabriel Candido da
Uma Abordagem de Game Learning Analytics para Identificação de Perfis Comportamentais na Utilização de Jogos Educacionais / Gabriel Candido da Silva. - 2022.
72 f. : il.
- Orientador: Rodrigo Lins Rodrigues.
Coorientador: Amadeu Sa de Campos Filho.
Inclui referências.
- Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Ensino das Ciências, Recife, 2022.
1. Jogos Educacionais. 2. Análise de Aprendizado. 3. Identificação de Perfis Comportamentais. I. Rodrigues, Rodrigo Lins, orient. II. Filho, Amadeu Sa de Campos, coorient. III. Título