

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

VINICIUS SCHULTZ GARCIA DA LUZ

MÉTODO PARA AJUSTE DE NÍVEL DE DIFICULDADE EM JOGOS
EDUCACIONAIS FUNDAMENTADO EM APRENDIZAGEM DE
MÁQUINA

DISSERTAÇÃO

PONTA GROSSA

2021

VINICIUS SCHULTZ GARCIA DA LUZ

**MÉTODO PARA AJUSTE DE NÍVEL DE DIFICULDADE EM JOGOS
EDUCACIONAIS FUNDAMENTADO EM APRENDIZAGEM DE
MÁQUINA**

**Method for Difficulty Level Adjustment in Educational Games Based on Machine
Learning**

Dissertação apresentada como requisito para obtenção do título de Mestre em Ciência da Computação da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientadora: Profa. Dra. Simone Nasser Matos.

Coorientadora: Profa. Dra. Helyane Bronoski Borges

PONTA GROSSA

2021



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite que outros remixem, adaptem e criem a partir do trabalho para fins não comerciais, desde que atribuam o devido crédito e que licenciem as novas criações sob termos idênticos.

Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



VINICIUS SCHULTZ GARCIA DA LUZ

MÉTODO PARA AJUSTE DE NÍVEL DE DIFICULDADE EM JOGOS EDUCACIONAIS FUNDAMENTADO EM APRENDIZAGEM DE MÁQUINA

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Ciência Da Computação da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Sistemas E Métodos De Computação.

Data de aprovação: 31 de Agosto de 2021

Prof.a Helyane Bronoski Borges, Doutorado - Universidade Tecnológica Federal do Paraná

Prof.a Diolete Marcante Lati Cerutti, Doutorado - Universidade Estadual de Ponta Grossa (Uepg)

Prof.a Simone De Almeida, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 31/08/2021.

Dedico este trabalho à minha esposa Scheila e
aos meus filhos Samuel, Mariana e Giovana.

AGRADECIMENTOS

Agradeço à Deus por me proporcionar a inteligência necessária para superar desafios e concluir este trabalho.

Agradeço aos meus pais, Valmir e Izabel, que desde a minha infância me incentivaram a estudar e buscar novos conhecimentos, e por meio da educação sensibilizar e contribuir com a sociedade.

Aos meus filhos, Samuel, Mariana e Giovana, a presença de vocês neste período do mestrado foi fortalecedora, restauradora e encorajadora, pois me motivaram a superar os percalços e desarmonias desta vida.

A minha esposa, Scheila, que me proveu muito apoio e palavras de incentivo para superar as dificuldades e me dedicar neste trabalho, conciliando o trabalho, estudos e família.

Agradeço a minha família por todo incentivo proporcionado durante o desenvolvimento deste trabalho com palavras de apoio para seguir em frente, especialmente, aos meus sogros Rosnei e Ana, que também me ajudaram a conciliar o trabalho, estudos e família.

Agradeço as professoras orientadoras, Simone e Helyane, que compartilharam muitos conhecimentos e conselhos e também pela confiança que depositaram no meu trabalho. A minha gratidão e admiração por vocês é imensa, pois mesmo diante das dificuldades que tivemos, sempre foram muito disponíveis e não hesitaram em me auxiliar no desenvolvimento desta pesquisa independente do dia e horário.

Aos professores e alunos da instituição de ensino de educação básica da região, na modalidade de educação especial, que participaram e colaboraram para este trabalho ser realizado.

Aos meus colegas de mestrado Janaíne Rodrigues e Paulo Victor Rios e Rafael de Andrade Pereira, por compartilharem muitos conhecimentos e diversos momentos de descontração, e também contribuírem nas diversas atividades do mestrado.

Por fim, agradeço aos professores do PPGCC pelos ensinamentos durante o período de curso e a Universidade Tecnológica Federal do Paraná (UTFPR) por proporcionar um ensino de qualidade e de alto nível.

RESUMO

Jogos sérios são utilizados para impulsionar a aprendizagem de pessoas com ou sem deficiência intelectual de forma interativa com atividades e conteúdos pedagógicos de acordo com a realidade vivenciada pelos alunos. O aprimoramento dos jogos é realizado por meio de aplicação de técnicas e elementos de gamificação que procuram manter a atenção e engajar o aluno para superar desafios. Adicionalmente, algoritmos de aprendizagem de máquina estão sendo utilizados em jogos sérios com o objetivo de obter informações mais precisas das partidas dos jogos, características, dificuldades encontradas e o próprio comportamento do aluno. Este trabalho criou o método *Tuning Game Level by Machine Learning* (TGL-ML) para identificar atributos e aplicar algoritmos de aprendizagem de máquina com o intuito de obter padrões, regras e índices para mudança de níveis de dificuldade. O método desenvolvido está dividido duas partes, antes e depois de aplicar algoritmos de aprendizagem de máquina. A primeira parte descreve elaboração de um jogo da memória contendo a definição do público alvo e suas características, tema do jogo, o uso da gamificação e elementos da gamificação, a criação do jogo, a definição de atributos e as funcionalidades do jogo, finalizando com a geração da primeira versão do jogo. E na finalização da primeira parte é aplicado o jogo no público alvo, coleta de dados e ajustes de funcionalidades com base nos *feedbacks* recebidos. A segunda parte contempla a utilização de algoritmo de aprendizagem de máquina com a base de dados preparada para posterior aplicação dos algoritmos de aprendizagem de máquina para análise de dados. Após a análise de dados os conhecimentos adquiridos são utilizados para atualização da versão do jogo adicionando regras e índices obtidos a fim de ajustar os níveis de dificuldades em uma nova versão do jogo sério. Os resultados alcançados por meio da aplicação de algoritmos de aprendizagem de máquina indicam que as regras devem ser adicionadas em dois dos níveis de dificuldade disponibilizados no jogo da memória.

Palavras-chave: Aprendizagem de Máquina. Jogos Sérios. Nível de dificuldade. Gamificação. Deficiente Intelectual.

ABSTRACT

Serious games are used to boost the learning of people with or without intellectual disabilities in an interactive way with activities and pedagogical content according to the reality experienced by the students. The improvement of games is carried out through the application of gamification techniques and elements that seek to maintain attention and engage the student to overcome challenges. Additionally, machine learning algorithms are being used in serious games in order to obtain more accurate information about the game's matches, characteristics, difficulties encountered and the student's own behavior. This work created the method *Tuning Game Level by Machine Learning* (TGL-ML) to identify attributes and apply machine learning algorithms in order to obtain patterns, rules and indexes to change levels of difficulty. The developed method is divided into two parts, before and after applying machine learning algorithms. The first part describes the elaboration of a memory game containing the definition of the target audience and its characteristics, the theme of the game, the use of gamification and gamification elements, the creation of the game, the definition of attributes and the game features, ending with the generation of the first version of the game. And at the end of the first part, the game is applied to the target audience, data collection and functionality adjustments based on *feedbacks* received. The second part contemplates the use of machine learning algorithm with the database prepared for subsequent application of machine learning algorithms for data analysis. After analyzing the data, the acquired knowledge is used to update the game version, adding rules and indexes obtained in order to adjust the difficulty levels in a new version of the serious game. The results achieved through the application of machine learning algorithms indicate that the rules must be added in two of the difficulty levels available in the memory game.

Keywords: Machine Learning. Educational Games. Difficulty level . Gamification. Intellectual Disability.

LISTA DE FIGURAS

Figura 1	– Cuibrain - Jogo de lógica e informações de um jogador.	23
Figura 2	– Boogies Academy - Jogo de Biologia e informações de um jogador.....	24
Figura 3	– Matriz de gamificação contendo o uso de parte de jogos em contraste ao jogo e ação de jogar.....	29
Figura 4	– Comparação de quantidade de assuntos abordados nos trabalhos selecionados	39
Figura 5	– Estrutura básica de um sistema de aprendizagem.....	44
Figura 6	– Processo de mapeamento sistemático	49
Figura 7	– Aplicação dos critérios de inclusão e exclusão.....	51
Figura 8	– Arquitetura do <i>LudiFyMe</i>	55
Figura 9	– Arquitetura do <i>framework PPAX</i>	56
Figura 10	– Etapas e passos do método <i>Tuning Game Level by Machine Learning</i> (TGL-ML)	62
Figura 11	– Fluxograma para identificação de aplicação de algoritmo de aprendizagem de máquina no jogo	63
Figura 12	– Integração do <i>ScienceLearning</i> com a base de dados usando páginas em PHP	72
Figura 13	– Tela do jogo da memória do <i>ScienceLearning</i>	80
Figura 14	– Tela do jogo da memória do <i>ScienceLearning</i> com um par combinado.....	80
Figura 15	– <i>Science Learning</i> em um <i>smartphone</i>	81
Figura 16	– Modelo Relacional da base de dados <i>MySQL</i>	82
Figura 17	– Tabela de Eventos do jogo do <i>ScienceLearning</i> no <i>MySQL</i>	83
Figura 18	– Resultado do algoritmo K-Means no nível de dificuldade difícil	85
Figura 19	– Resultado do algoritmo J48 com todos os níveis de dificuldades	86
Figura 20	– Resultado do algoritmo JRip com todos os níveis de dificuldades	87
Figura 21	– Conjunto de dados tratados e refinados	87
Figura 22	– Ajuste de nível de dificuldade automático com a biblioteca PHP ML	93
Figura 23	– Tela de <i>Login</i> do <i>ScienceLearning</i>	109
Figura 24	– Tela de Cadastro de Usuário do <i>ScienceLearning</i>	109
Figura 25	– Tela de Menu Principal do <i>ScienceLearning</i>	110
Figura 26	– Tela de Configurações do <i>ScienceLearning</i>	110
Figura 27	– Tela de Sobre do <i>ScienceLearning</i>	111
Figura 28	– Tela do jogo da memória do <i>ScienceLearning</i> com pares combinados	111
Figura 29	– Tela de Parabéns do <i>ScienceLearning</i>	112

LISTA DE QUADROS

Quadro 1	– Níveis de gravidade dos transtornos específicos de aprendizagem.....	18
Quadro 2	– Comparativo entre <i>Participar</i> , <i>SofiaFala</i> e <i>ABC 3D</i>	21
Quadro 3	– Comparativo entre <i>Boogies Academy</i> e <i>Cuibrain</i>	25
Quadro 4	– Elementos dinâmicos de gamificação	30
Quadro 5	– Elementos relacionados aos componentes de gamificação.....	30
Quadro 6	– Elementos mecânicos de gamificação.....	31
Quadro 7	– Utilização da Gamificação e os níveis educacionais aplicados	32
Quadro 8	– Ambientes de aplicação de gamificação, uso de ferramentas e teorias de aprendizagem	36
Quadro 9	– Revisão sistemática de como a gamificação é desenvolvida e reutilizada ...	36
Quadro 10	– Gamificação multidisciplinar e novas diretrizes para o uso da gamificação	37
Quadro 11	– Comparativo entre <i>Aquisição de Vocabulário</i> e <i>classDojo</i>	41
Quadro 12	– Elementos importantes de gamificação utilizados em jogos digitais de alunos com deficiência intelectual	42
Quadro 13	– Critérios de inclusão e exclusão.....	50
Quadro 14	– Jogos usados nas áreas e níveis educacionais pelos autores	53
Quadro 15	– Requisitos educacionais utilizados neste trabalho.....	65
Quadro 16	– Elementos dinâmicos de gamificação no jogo.....	66
Quadro 17	– Elementos mecânicos de gamificação no jogo	67
Quadro 18	– Elementos relacionados aos componentes de gamificação	67
Quadro 19	– Funcionalidades desenvolvidas para o jogo	69
Quadro 20	– Alimentos e benefícios ensinados no jogo.....	70
Quadro 21	– Atributos para coleta de dados	71
Quadro 22	– Ajustar o nível de dificuldade do jogo	88
Quadro 23	– Tipo dos jogos e o público de aplicação dos trabalhos avaliados em relação ao <i>ScienceLearning</i>	90
Quadro 24	– Elementos de gamificação aplicados nos trabalhos avaliados em relação ao <i>ScienceLearning</i>	91
Quadro 25	– Algoritmos de aprendizagem de máquina utilizados em relação ao <i>ScienceLearning</i>	91
Quadro 26	– Funcionalidades dos jogos em relação ao <i>ScienceLearning</i>	92

LISTA DE TABELAS

Tabela 1	– Quantidade de trabalhos por repositório obtidos	51
Tabela 2	– Quantidade de trabalhos selecionados por repositório	52
Tabela 3	– Quantidade de algoritmos de aprendizagem de máquina por ano	57
Tabela 4	– Quantidade de instâncias e seus respectivos <i>clusters</i> utilizados no <i>K-Means</i>	84
Tabela 5	– Desempenho dos classificadores baseado em suas taxas de acerto	84

SUMÁRIO

1 INTRODUÇÃO	13
1.1 JUSTIFICATIVA	14
1.2 OBJETIVOS	15
1.3 ORGANIZAÇÃO DA DISSERTAÇÃO	16
2 REFERENCIAL TEÓRICO	17
2.1 DEFICIÊNCIA INTELECTUAL	17
2.1.1 Software para Deficiência Intelectual	19
2.2 JOGOS SÉRIOS	22
2.2.1 Jogos Sérios e Deficiência Intelectual	26
2.3 GAMIFICAÇÃO	27
2.3.1 Elementos de Gamificação	29
2.3.2 Gamificação na Educação	31
2.3.3 Gamificação e Deficiência Intelectual	40
2.4 APRENDIZAGEM DE MÁQUINA	43
2.4.1 Estrutura de um sistema de Aprendizagem de Máquina	44
2.4.2 Algoritmos de Aprendizagem de Máquina	44
2.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO	46
3 ESTADO DA ARTE	48
3.1 METODOLOGIA DE PESQUISA	48
3.1.1 Questões de Pesquisa	49
3.1.2 Critérios de Inclusão e Exclusão	50
3.1.3 Repositórios de Busca	50
3.1.4 <i>Strings</i> de Busca e Palavras-chave	51
3.1.5 Leitura e seleção dos trabalhos	52
3.2 RESULTADOS	52
3.2.1 Quais são os jogos, qual a área e o nível de educação (especial ou não)?	52
3.2.2 Como os jogos são divididos e como funciona sua arquitetura?	54
3.2.3 Quais algoritmos de aprendizagem de máquina são usados?	56
3.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO	59
4 TGL-ML: MÉTODO PARA AJUSTE DE NÍVEL DE DIFICULDADE EM JOGOS EDUCACIONAIS FUNDAMENTADO EM APRENDIZAGEM DE MÁQUINA	61
4.1 VISÃO GERAL DO MÉTODO	61
4.1.1 Elaboração do jogo	62
4.1.1.1 Público de aplicação do experimento	63
4.1.1.2 Definir as características do público alvo	64
4.1.1.3 Tema, conteúdo e tipo do jogo	65
4.1.1.4 Uso da gamificação e elementos	66
4.1.1.5 Criação do jogo	67
4.1.1.6 Funcionalidades do jogo	69
4.1.1.7 Definição de atributos	70
4.1.2 Aplicação do jogo	71
4.1.2.1 Coletar dados	72
4.1.2.2 Registro de eventos das partidas	73
4.1.2.3 Ajuste de funcionalidades do jogo após <i>feedback</i>	73
4.1.3 Utilização de Algoritmo de Aprendizagem de Máquina	74
4.1.3.1 Pré-processamento de dados	74

4.1.3.2	Aplicação de Algoritmo de Aprendizagem de Máquina.....	76
4.1.3.3	Pós-processamento e análise de dados	76
4.1.4	Atualizar a versão do jogo	76
4.1.4.1	Adicionar regras sobres os índices.....	76
4.1.4.2	Criar nova versão do jogo	77
4.1.5	Considerações finais do capítulo.....	77
5	RESULTADOS	79
5.1	RESULTADOS ANTES DA APLICAÇÃO DOS ALGORITMOS DE APRENDI- ZAGEM DE MÁQUINA	79
5.2	RESULTADOS APÓS A UTILIZAÇÃO DE ALGORITMO DE APRENDIZA- GEM DE MÁQUINA	83
5.2.1	Resultados dos algoritmos de agrupamento e classificação	83
5.2.1.1	Resultados com o Algoritmo <i>K-Means</i>	84
5.2.1.2	Resultados com o Algoritmo J48	85
5.2.1.3	Resultados com o Algoritmo JRip	86
5.2.2	Base de dados processada e conhecimentos obtidos	87
5.2.3	Ajustar o nível de dificuldade do jogo	88
5.2.4	Criar nova versão do jogo	89
5.3	COMPARATIVOS DE TRABALHOS RELACIONADOS COM O <i>SCIENCELE- ARNING</i>	89
5.4	SOLUÇÃO PARA EXPERIMENTOS FUTUROS	92
5.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO.....	94
6	CONCLUSÃO	95
6.1	TRABALHOS FUTUROS	96
	REFERÊNCIAS	107
	APÊNDICE A - Telas do jogo <i>ScienceLearning</i>	109

1 INTRODUÇÃO

A aplicação de jogos sérios em ambientes educacionais proporcionam melhorias no processo de aprendizagem, estimulando o aluno em aprimorar suas habilidades cognitivas como memorização, raciocínio, linguagem e atenção. Jogos sérios são ferramentas interativas que tem o objetivo de consolidar o conhecimento simulando experiências lúdicas aproximadas da área de atuação de um determinado público (MELLO; ZENDRON, 2015). A aplicação de jogos sérios pode modificar o comportamento no ambiente escolar ou profissional, pois podem apresentar benefícios tais como maior envolvimento do aluno, motivação, confiança, percepção de aprendizagem, atitude e desempenho (SUBHASH; CUDNEY, 2018).

Os jogos sérios podem ser aprimorados utilizando técnicas de gamificação para motivar e aumentar o comprometimento do aluno no âmbito educacional (CORDERO-BRITO; MENA, 2018) e promover sua motivação e o engajamento (LEE; DOH, 2012). A gamificação envolve a dinâmica e a mecânica de jogos como uma ferramenta para adaptar um determinado contexto de forma lúdica para motivar as pessoas a aprenderem e solucionarem adversidades de uma forma mais interativa (KAPP, 2012). Ao utilizar os elementos de gamificação tais como: desafios, *feedbacks* instantâneos (conquista ou falha), recompensas e medalhas, placares, níveis de dificuldades em jogos sérios pode provocar um maior engajamento de alunos (SANTOS; FREITAS, 2017).

Os jogos sérios também podem conter em seu motor a aplicação de técnicas de algoritmos de aprendizagem de máquina (*machine learning*) para facilitar a análise de fatores pré-estabelecidos como desempenho, nível de aprendizagem e participação dentro de um determinado cenário ou contexto (BARATA *et al.*, 2016). A utilização de algoritmos de aprendizagem de máquina em jogos na educação facilita a análise de dados, em que as experiências lúdicas podem ser mensuradas por meio de interações multidisciplinares com o uso *Frequent Pattern Growth* para associação de dados e *K-means* para agrupamento de dados sobre eventos de jogos (COWLEY *et al.*, 2014).

Os algoritmos de aprendizagem de máquina permitem um planejamento no desenvolvimento de jogos verificando as motivações, como o *Support Vector Machine* (SVM), que para cada entrada de dados busca analisar e definir padrões. E diante de padrões de dados obtidos torna-se possível melhorar a avaliação das informações para elaborar funcionalidades específicas a fim de reter mais atenção de jogadores estimulando-os a superar desafios (BHARATHI *et al.*, 2016).

Visando ampliar o conhecimento sobre trabalhos relacionados a jogos sérios aplicando algoritmos de aprendizagem de máquina, foi realizado um mapeamento sistemático no período de 2003 a 2021 abrangendo cinco bibliotecas digitais. O método de mapeamento é fundamentado em Kitchenham e Charters (KITCHENHAM; CHARTERS, 2007). Por meio deste mapeamento foi possível identificar os algoritmos de aprendizagem de máquinas utilizados em jogos sérios,

as áreas e níveis educacionais em que os jogos sérios são aplicados. E, constatou-se que os trabalhos não realizaram uma seleção de atributos e como estes podem contribuir na aplicação os algoritmos de aprendizagem de máquina em jogos sérios para ajuste de nível de dificuldade.

Neste trabalho foi desenvolvido o método *Tuning Game Level by Machine Learning* (TGL-ML) para identificar atributos e aplicar algoritmos de aprendizagem de máquina com o intuito de obter padrões, regras e índices para mudança de níveis de dificuldade em jogos sérios. O método desenvolvido utilizou um jogo sério, o qual foi aplicado em uma instituição de ensino de educação básica, na modalidade de educação especial, a fim de descobrir padrões de jogadas e comportamento dos jogadores de acordo com a definição de atributos, considerando a dinâmica do jogo e os dados coletados durante o experimento. Apesar do método TGL-ML ter sido utilizado para um público com deficiência intelectual, este pode ser utilizado para outros públicos em que seja necessário obter padrões com o uso de algoritmos de aprendizagem de máquina realizando uma definição e seleção de atributos. E assim, gerar novos conhecimentos para otimizar os níveis de dificuldades de jogos sérios e aprimorar a aprendizagem do público alvo.

O método desenvolvido está dividido duas partes, antes e depois de aplicar algoritmos de aprendizagem de máquina. A primeira parte descreve elaboração de um jogo da memória contendo a definição do público alvo e suas características, tema do jogo, o uso da gamificação e elementos da gamificação, a criação do jogo, a definição de atributos e as funcionalidades do jogo, finalizando com a geração da primeira versão do jogo. E na finalização da primeira parte é feita a aplicação do jogo para o público alvo, coleta de dados e ajustes de funcionalidades com base nos *feedbacks* recebidos.

A segunda parte contempla a aplicação de algoritmo de aprendizagem de máquina com a base de dados preparada para posterior análise de dados. Após a análise de dados são obtidos os conhecimentos para atualização da versão do jogo adicionando regras e índices obtidos a fim de ajustar os níveis de dificuldades em uma nova versão do jogo sério.

Os resultados obtidos pelos algoritmos de aprendizagem de máquina, apresentaram as regras e índices a serem aplicadas em uma nova versão do jogo para modificar o nível de dificuldade do jogo, sendo customizada ao perfil do público alvo.

1.1 JUSTIFICATIVA

A inclusão social e digital é um tema crescente no Brasil, pois indivíduos com alguma deficiência intelectual ou mental, desfrutam de aparatos tecnológicos para fins de aprendizagem e até mesmo crescimento profissional. Este público que enfrenta essa realidade tem o agravante de em muitos casos não conseguir desenvolver ou melhorar suas habilidades em virtude de suas limitações (PIMENTA, 2017).

Nessa perspectiva, a educação na modalidade especial requer uma maior atenção em questões pedagógicas, recursos, serviços e acessibilidade de forma a permitir ao estudante superar barreiras para consolidação do crescimento (BRASIL, 2019). Contudo, o uso de softwares gamificados na educação pode potencializar o desenvolvimento por meio de jogos com tecnologias direcionadas. O uso da gamificação pode tornar os alunos mais participativos em virtude da interatividade e diversão oferecida pelos jogos, de forma adaptada ao ensino (KAPP, 2012). Os jogos apresentam uma dinâmica para superar desafios e obstáculos pelos jogadores, os quais precisam entender as regras e restrições para obterem êxito, de forma análoga, os alunos ao participarem de atividades lúdicas no âmbito escolar, precisam compreender o contexto e atingir os objetivos dos desafios apresentados (SMITH-ROBBINS, 2011).

Além do uso de técnicas gamificação, é possível aprimorar os jogos sérios aplicando algoritmos de aprendizagem de máquina para obter informações mais precisas das execuções de jogos e partidas realizadas. Com isso, os jogos podem ser melhores adaptados para o público de alunos com deficiência intelectual, porque a limitação de cada indivíduo perante a um desafio pode ser um fator de desmotivação. Nessa ideia, a aplicação de algoritmo de aprendizagem de máquina pode ser utilizada para ajustar os níveis de dificuldades mantendo a sua atenção e motivando-o a continuar jogando de acordo com a sua facilidade ou limitação em relação ao jogo.

1.2 OBJETIVOS

Desenvolver um método para ajuste de nível de dificuldade em jogos sérios fundamentado em algoritmo de aprendizagem de máquina.

Os objetivos específicos são:

- Desenvolver um jogo com elementos de gamificação na área de ciências abordando o tema de Segurança Alimentar.
- Aplicar e avaliar o jogo desenvolvido em uma instituição de ensino de educação básica, na modalidade de educação especial, participante do programa EJA (Educação de Jovens e Adultos) (BRASIL, 2021) destinado ao público que não teve acesso à educação escolar e formal na idade adequada.
- Aplicar e analisar os resultados obtidos pelos algoritmos de aprendizagem de máquina na base de dados geradas a partir da execução do jogo pelos alunos.
- Gerar uma nova versão do jogo com base nos resultados obtidos pelos algoritmos de aprendizagem de máquina.

1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

O presente trabalho está organizado em seis capítulos. O capítulo 1 descreve a introdução do trabalho com aspectos gerais sobre jogos sérios utilizando gamificação e algoritmos de aprendizagem de máquina, e a visão geral do método *Tuning Game Level by Machine Learning* (TGL-ML). O capítulo 2 apresenta o referencial teórico relacionados a jogos sérios, gamificação e elementos de gamificação, softwares e elementos de gamificação relacionados a deficiência intelectual, e apresenta uma revisão sistemática da literatura de gamificação na educação e os aspectos gerais de algoritmos de aprendizagem de máquina. O capítulo 3 apresenta o mapeamento sistemático com o estado da arte realizado sobre jogos na educação aplicados com algoritmos de aprendizagem de máquina e os resultados obtidos. O capítulo 4 descreve o método *Tuning Game Level by Machine Learning* (TGL-ML) para ajuste de nível de dificuldade em jogos sérios fundamentado em aprendizagem de máquina. O capítulo 5 apresenta os resultados obtidos ao aplicar o método desenvolvido com base em um jogo de memória, o *ScienceLearning*. Por fim, o capítulo 6 descreve as conclusões e demais considerações, e trabalhos futuros.

2 REFERENCIAL TEÓRICO

A inclusão social de deficientes intelectuais no Brasil tem avançado por meio de projetos como por exemplo, o Participar da UnB (Universidade de Brasília) (PARTICIPAR, 2019), que é reconhecido nacionalmente pela sua evolução pedagógica. Este projeto auxilia professores e alunos com deficiência intelectual alcançar uma nova modalidade de aprendizagem por meio da inclusão digital. A abrangência de trabalhos semelhantes ao citado é baixa, pois ainda não existe uma conscientização adequada para que mais projetos possam ser impulsionados na sociedade.

Uma das formas de inclusão social é o uso de jogos sérios que proporcionam diversão e ajudam na aprendizagem. Os jogos sérios de inclusão social que utilizam a gamificação procuram ampliar a participação do aluno, pois tem como objetivo promover o engajamento do jogador para superar desafios recebendo benefícios ou recompensas. Isto é uma forma de estimular o aluno a criar novas atitudes perante o jogo e relacioná-las com experiências do mundo real. As experiências adquiridas impactam no comportamento do jogador e no processo de aprendizagem contribuindo na retenção de atenção e desenvolvimento cognitivo (SCHMITZ; KLEMKE; SPECHT, 2012).

Na educação especial a gamificação propicia o engajamento de professores e alunos para a melhoria da aprendizagem ao utilizar elementos gamificados como pontos, *ranking*, *feedback*, níveis e desafios (IFIGENIA *et al.*, 2018).

O uso de gamificação e algoritmos de aprendizagem de máquina em jogos sérios possibilitam a análise de informações de forma mais precisa indicando o perfil do aluno e seu próprio desempenho (BARATA *et al.*, 2016). Em alguns casos, pode apontar um comportamento inadequado em partidas com outros jogadores (MURNION *et al.*, 2018) e em outras situações as habilidades mais evidentes durante o processo de aprendizagem (SIU *et al.*, 2018).

Este capítulo descreve algumas características de jogos sérios, gamificação e seus elementos e aprendizagem de máquina em jogos, apresentando também formas de como estes itens podem ser aplicados em jogos sérios para as pessoas com deficiência intelectual.

2.1 DEFICIÊNCIA INTELECTUAL

A deficiência intelectual é definida por terminologias para identificar pessoas com *défi-cits* funcionais, sendo intelectuais ou de adaptações em contexto sociais e de atividades práticas. As terminologias são relacionadas a retardo mental, debilidade mental, subnormalidade mental, capacidade diferentes e barreiras de aprendizagem (DIAS; OLIVEIRA, 2013).

A *American Psychiatric Association* (APA, 2013), a qual disponibiliza o DSM-V (Manual de diagnóstico e estatístico de transtornos mentais), apresenta uma visão médica relacio-

nando três domínios, o conceitual, o social e o prático. Estes domínios indicam aspectos sobre funções intelectuais padronizados e individualizados, *déficits* de desenvolvimento socioculturais e independência social, e limitações de uma vida independente em diversos ambientes como a escola, em casa, local de trabalho e na comunidade.

Segundo a APA (2013) a deficiência intelectual não possui características iguais, mas semelhanças em virtude da gravidade. A função da gravidade é distribuída em grau leve, moderado, grave e profundo. Cada indivíduo deve ser avaliado considerando diversos critérios e condições, em que sua avaliação é qualificada conforme o nível de apoio necessário para executar tarefas comuns da vida diária e laboral. No entanto, a utilização de testes de inteligência com pontuação não são adequados para definir o grau da gravidade porque os índices podem variar não indicando uma confiabilidade. Um indivíduo ao ser enquadrado em uma determinada severidade pode necessitar de adaptações para direcionar o aproveitamento na vida escolar e profissional.

Apesar deste público possuir dificuldades de aprendizagem como leitura, compreensão, expressão escrita, senso numérico e raciocínio lógico, é possível utilizar conteúdos lúdicos para potencializar as habilidades em seu cotidiano. O quadro 1 apresenta os níveis de gravidade dos transtornos específicos de aprendizagem baseado no DSM V (APA, 2013).

Quadro 1 – Níveis de gravidade dos transtornos específicos de aprendizagem.

Nível	Descrição
Leve	Alguma dificuldade em aprender habilidades em um ou dois domínios acadêmicos, mas com gravidade suficientemente leve que permita ao indivíduo ser capaz de compensar ou funcionar bem quando lhe são propiciadas adaptações ou serviços de apoio adequados, especialmente durante os anos escolares.
Moderada	Dificuldades acentuadas em aprender habilidades em um ou mais domínios acadêmicos, de modo que é improvável que o indivíduo se torne proficiente sem alguns intervalos de ensino intensivo e especializado durante os anos escolares. Algumas adaptações ou serviços de apoio por pelo menos parte do dia na escola, no trabalho ou em casa podem ser necessários para completar as atividades de forma precisa e eficiente.
Grave	Dificuldades graves em aprender habilidades, afetando vários domínios acadêmicos, de modo que é improvável que o indivíduo aprenda essas habilidades sem um ensino individualizado e especializado contínuo durante a maior parte dos anos escolares. Mesmo com um conjunto de adaptações ou serviços de apoio adequados em casa, na escola ou no trabalho, o indivíduo pode não ser capaz de completar todas as atividades de forma eficiente.

Fonte: Adaptado de APA (2013)

Segundo a AAIDD (2020), a classificação e avaliação de deficiência intelectual é bastante complexa e apenas a utilização de teste de QI (Quociente de Inteligência) não pode ser considerado como um fator determinante para o enquadramento de indivíduos com esta condição. São utilizados três critérios principais para a deficiência intelectual, sendo eles: limitações significativas no funcionamento intelectual, limitações significativas no comportamento adaptativo e iniciar antes dos 18 anos de idade. No entanto, são utilizados outros testes como habilidades conceituais, sociais e práticas. As habilidades conceituais são relacionadas a lingua-

gem, alfabetização, valor monetário, tempo e números, e auto-direção. As habilidades sociais como relação interpessoal, responsabilidade social, auto-estima, resolução de problemas sociais, capacidade de seguir regras e leis. As habilidades práticas como atividades da vida diária (higiene pessoal, alimentação, rotinas, por exemplo), habilidades ocupacionais, saúde, viagens, transporte, etc. AAIDD (2020) ressalta que os profissionais da área devem considerar o ambiente e a cultura em que o indivíduo vivência, diversidade linguística e as diferenças culturais para determinar a severidade adequada.

2.1.1 Software para Deficiência Intelectual

O projeto Participar (2019) desenvolvido pela UnB (Universidade de Brasília) criado em 2011 é destinado a educação especial para alunos com deficiência intelectual. Este projeto possui 13 (treze) módulos de aprendizagem, sendo 5 para o autismo e 8 para a deficiência intelectual, que auxilia professores otimizar a alfabetização, a inclusão digital e cidadania de jovens e adultos.

Os trabalhos desenvolvidos contém informações detalhadas de cada módulo, a equipe de criação é formada por alunos de ciências da computação que participam do desenvolvimento e estão listados no *site* do próprio projeto. Os *softwares* para deficiência intelectual deste projeto são (PARTICIPAR, 2019):

- Participar para *tablets*: É uma ferramenta pedagógica de apoio para professores utilizarem na alfabetização de jovens e adultos com deficiência intelectual. O seu principal objetivo é permitir que o aluno se comunique por meio de computadores. É suportado apenas em *tablets* com *Android* 4.2.2 ou superior (PARTICIPAR, 2015).
- Participar 2: É uma segunda versão do *software* Participar para *tablets* que apresenta atividades contextualizadas e expansão de conteúdo em relação a primeira versão. Assim como na primeira versão, tem o objetivo de ser uma ferramenta de auxílio a alfabetização, melhora a autonomia e possibilita a inclusão social. Funciona somente em *Windows* e *Linux* educacional. (PARTICIPAR, 2014a).
- Somar: *Software* utilizado para o ensino social da matemática de jovens e adultos com deficiência intelectual. Os módulos abrangem o uso de cédulas monetárias para atividades cotidianas, aprendizagem e uso da calculadora, e leitura de relógio digital. Opera apenas em *Windows* e *Linux* educacional. (PARTICIPAR, 2014b).
- Somar para *tablets*: Ferramenta baseada no *software* Somar (PARTICIPAR, 2014b) contendo os mesmos conteúdos e disponibilizados para *tablets*. É suportado apenas em *tablets* com *Android* 4.2.2 ou superior (PARTICIPAR, 2014c).

- Atividades de Vida: É um *software* para o desenvolvimento de autocuidado diário como higiene bucal e corporal dos gêneros feminino e masculino. Opera somente em *Windows* e *Linux* educacional. (PARTICIPAR, 2016a).
- Atividades de Vida (versão para celular): Ferramenta baseada no *software* Atividades de Vida (PARTICIPAR, 2016a) contendo os mesmos conteúdos e disponibilizados para computadores. É suportado apenas celulares com sistema *Android* (PARTICIPAR, 2016b).
- Organizar: *Software* utilizado para ensino de gerenciamento do tempo e estações climáticas. Possui atividades referentes as estações do ano e indica qual o tipo de traje mais adequado, calendário com informações do ano, mês, semana e dias, e por fim o de agenda para organizar os compromissos como ir à escola, dentista, médico, tomar remédio, etc. É suportado apenas celulares com sistema *Android* e *Windows* (PARTICIPAR, 2016c).
- Comunicação Funcional: Aplicativo para ensino de comunicação funcional para situações reais que propiciem a inclusão social. A ferramenta não é um método para alfabetização mas pode ser usada para aprimorar o entendimento de relações em ambientes sociais como escola, clube, feira, açougue, farmácia, hospital, lanchonete, padaria, restaurante, shopping, supermercado, transporte e trânsito (PARTICIPAR, 2018).

Os *softwares* disponibilizados pelo projeto Participar (PARTICIPAR, 2019) são disponibilizados de forma gratuita, sendo possível realizar o download das monografias contendo a documentação e a equipe participante de cada projeto desenvolvido.

Outro projeto sem fins lucrativos, o SofiaFala (2019), desenvolvido pelo Departamento de Computação e Matemática da USP (Universidade de São Paulo) para crianças portadoras de síndrome de Down (DOWN, 2019). Este projeto tem o intuito de auxiliar crianças no desenvolvimento da fala e audição por meio de tecnologia assistivas, pois indivíduos com esta síndrome possuem baixos níveis de tônus que afetam o desenvolvimento motor da fala, dificultando a comunicação e a aprendizagem. Para melhorar o desenvolvimento da fala de crianças nesta situação é indicada a terapia fonoaudiológica, a qual estimula o desenvolvimento neuromotor e cognitivo, facilitando a aprendizagem e a interação social. Neste projeto, durante as sessões de fonoaudiologia com meios lúdico-educacional, os sons e imagens são captadas para análise, os quais posteriormente são avaliados para potencializar o desempenho de cada indivíduo.

O aplicativo SofiaFala (2019) utiliza técnicas de aprendizagem de máquina e inteligência artificial, contendo soluções autorais aprimoradas com tecnologias de fornecedores terceiros. O objetivo é fornecer apoio às crianças e professores durante as sessões de fonoaudiologia, e apresentar dados aos profissionais de fonoaudiologia sobre o desempenho e evolução de seus pacientes. Possui dois módulos integrados, o módulo *Fono* e o *Criança*, sendo um para o profissional de fonoaudiologia e um outro para utilização do paciente. O módulo *Fono* é a parte gerencial onde é possível efetuar cadastros, configurar treinos personalizados, criar mídias demonstrativas e explicativas, e receber relatórios de desempenho por meio do módulo *Criança*.

O módulo *Criança* analisa áudios de praxias não verbais como sopro, balbucio, beijo e estalo de língua. E analisa os áudios de praxias verbais como vogais, palavras, frases, sentenças curtas da fala, etc. Os dados analisados são enviados para o módulo *Fono* para avaliação do profissional de fonoaudiologia (SOFIAFALA, 2019).

O *software ABC 3D* desenvolvido no projeto de Cagatay *et al.* (2012) é indicado para o público infantil com distúrbios da fala na língua turca. Possui uma interface administrativa e de configuração de usuário de forma adaptável para ser usada em sessões de terapia de fala. O usuário pode interagir com vários tipos de objetos e diferentes formas, por exemplo, lixeira, banco, balanço, escorregador, bolas e barcos. Os objetos tem a sua própria funcionalidade a serem escolhidos pelo jogador como soltar, rolar, girar, etc., e podem ser adaptados no cenário de acordo com a necessidade do paciente. Por exemplo, um banco pode ser colocado dentro de uma casa, em uma praça pública ou em uma calçada. O ambiente da plataforma é bastante diversificado apresentando diversos objetos e personagens em um mesmo local. Os personagens podem ser controlados pelo jogadores para locomover-se pelo cenário interagir com objetos e outros personagens. Como resultado observou-se que as crianças ficaram mais motivadas a reproduzir os nomes dos objetos, pronunciar verbos e outras palavras de forma mais próxima do correto. E permitiu um maior interesse por parte dos jogadores e tornar a sessão de terapia mais agradável.

O quadro 2 apresenta a comparação entre os softwares para deficiência intelectual descritos nesta seção. As três ferramentas são voltadas para o público de deficiência intelectual para exercitar as habilidades cognitivas e possuem o ambiente gamificado e o módulo de avaliação de resultados. O SofiaFala (2019) opera em *smartphones*, o Participar (2019) opera em *tablets*, *smartphones* e computadores sendo multiplataformas e o ABC 3D opera apenas em computadores. Somente os aplicativos desenvolvidos no projeto Participar (2019) são voltados para o público adulto e infantil e trabalha com áreas de inteligências múltiplas como a comunicação, números, alfabetização e letramento, e as demais atividades são relacionadas com as rotinas diárias e conhecimentos de gestão de tempo e de ordem climáticas.

Quadro 2 – Comparativo entre *Participar*, *SofiaFala* e *ABC 3D*

Descrição	Participar	SofiaFala	ABC 3D
Software para Deficiência Intelectual	Sim	Sim	Sim
Ambiente 3D	Não	Não	Sim
Ambiente Gamificado	Sim	Sim	Sim
Multiplataforma	Sim	Sim	Não
Habilidades Cognitivas	Sim	Sim	Sim
Avaliação de Resultados	Sim	Sim	Sim
Público Infantil	Sim	Sim	Sim
Público Adulto	Sim	Não	Não
Atividades para Inteligências Múltiplas	Sim	Não	Não
Registros de atividades realizadas (Logs)	Não	Sim	Sim
Aplicação de Inteligência Artificial	Não	Sim	Não

Fonte: Autoria própria.

Os *softwares* SofiaFala (2019) e o ABC 3D são para o aprimoramento da fala, compreensão de nome de objetos, destinados apenas para o público infantil e possuem um módulo de registro de atividades realizadas durante as sessões. O aplicativo ABC 3D emprega dois sistemas de registros de atividades, um para rastrear os objetos utilizados no jogo efetuando a contagem de uso, quantas vezes foram utilizados e qual dos objetos reteve mais atenção do jogador. Apenas o aplicativo SofiaFala (2019) utiliza inteligência artificial para reconhecer sons e as imagens produzidas durante os exercícios de fonoaudiologia.

2.2 JOGOS SÉRIOS

Jogos sérios são ferramentas interativas que promovem o desenvolvimento de habilidades e o aprendizado, em que o seu maior objetivo é consolidar o conhecimento ao invés de incentivar apenas o entretenimento. Este tipo de jogo abrange três características principais: a aprendizagem, simulação de mídia interativa e contém algum elemento de jogo. Os elementos de jogos são relacionados a dinâmica de operação e mecânica de como o jogador interage e realiza progressão em um jogo. Os seus componentes são ambientes, cenários, personagens ou representação do jogador (GUNTER; KENNY; VICK, 2008).

Os jogos sérios tem uma dinâmica para transmitir conceitos e situações alinhadas com questões laborais, educação, saúde, segurança, esportivas, dentre outras, as quais permitem simular experiências lúdicas aproximadas da realidade. Entretanto, são direcionados a um determinado público em que são aplicados conhecimentos específicos relacionados a área de abrangência (MELLO; ZENDRON, 2015). Nesse contexto, por meio da pesquisa de Bigdeli e Kaufman (2017) foi provado que quanto mais próximo for um jogo do ambiente educacional ou da própria realidade do aluno, a aprendizagem será mais produtiva. Portanto, jogos sérios procuram manter o máximo da capacidade de um jogador para solucionar um determinado problema, mesmo que seja permitido escolher os níveis de dificuldades ou até que o jogador se torne perito sobre os desafios do jogo. Estes jogos são projetados para aprimorar habilidades individuais e melhorar algum aspecto de aprendizagem (HAGGLUND, 2012).

A classificação de jogos sérios é baseada nos critérios de jogabilidade, propósito, mercado de atuação e público alvo. Porém, muitos jogos podem ser categorizados sobre o critério de jogabilidade em virtude de sua complexidade, regras, desafios e objetivos (ALVAREZ; DJAOUTI; RAMPNOUX, 2020).

Os jogos sérios são aplicados no âmbito educacional para promover uma aprendizagem aprimorada e facilitada, pois as informações são absorvidas facilmente por meio de experiências obtidas durante as interações e que podem ser transferidas para outras atividades do mundo real. Os jogos sérios adotam diversas estratégias para promover habilidades cognitivas na qual os alunos aprendem sobre o próprio ambiente escolar executando atividades e se envolvendo com conteúdos e contextos adequados (MELLO; ZENDRON, 2015).

Os jogos podem ser enquadrados como uma ferramenta didática de apoio educacional, em que diversos conteúdos podem ser absorvidos de forma interativa e eficiente. E de acordo com os desafios apresentados ao aluno, assim que as regras são assimiladas, a prática potencializa o conhecimento sobre um determinado assunto (FERREIRA *et al.*, 2018). Os jogos sérios procuram manter o jogador em um círculo interativo de aprendizagem para motivá-los a criar e propor diversas soluções para resolver um problema ou desafio, caso contrário, haverá desistência em solucionar os desafios propostos (ECK, 2015).

Para tornar a aprendizagem mais atraente são utilizados jogos digitais, os quais podem ser utilizados por meio de computadores e outros dispositivos eletrônicos para agregar novos recursos pedagógicos e expandir a didática em sala de aula. Um exemplo é plataforma desenvolvida para aprendizagem de língua inglesa de jogos baseada na história de Romeu e Julieta (SIU *et al.*, 2018). Esta plataforma apresenta um jogo diversificado para aprimorar a aprendizagem do idioma inglês, a qual analisa as pontuações obtidas pelo aluno para verificar a evolução e o domínio da linguagem. Este tipo de jogo aprimora aprendizagem de conteúdos de forma gamificada é definido como jogos sérios.

No trabalho de Garmen *et al.* (2019) foram avaliadas duas ferramentas que aplicam jogos sérios, a *Cuibrain* (STUDIOS; HK, 2020) e *Boogies Academy* (STUDIOS, 2020). A primeira aplicação por meio de jogos sérios usando matemática e alfabetização, por exemplo, auxilia no desenvolvimento de múltiplas inteligências como memorização, concentração, coordenação e a atenção. É possível avaliar o perfil cognitivo do jogador considerando as habilidades de memorização, raciocínio, linguagem, destreza visual, coordenação motora, atenção e execução de funções. Além disso, o jogo possibilita realizar comparativos e a evolução do jogador após várias execuções de um mesmo desafio. A Figura 1 apresenta algumas telas do *Cuibrain*.

Figura 1 – Cuibrain - Jogo de lógica e informações de um jogador.



Fonte: Studios e HK (2020)

Já o *Boogies Academy* disponibiliza vários jogos sérios com atividades de lógica, biologia e música, por exemplo, e procura aperfeiçoar as habilidades cognitivas e também verificar o estado emocional do jogador durante as interações. O jogo disponibiliza uma área de comparativos de inteligências e habilidades de um determinado jogador em relação aos demais jogadores dentro de uma faixa etária. A figura 2 apresenta algumas telas do jogo citado.

Figura 2 – Boogies Academy - Jogo de Biologia e informações de um jogador.



Fonte: Studios (2020)

Garmen *et al.* (2020) constatou que a partir de uma amostra de 372 alunos do primeiro ao terceiro ano do ensino básico, os jogos sérios utilizados ajudaram a reduzir o nível de ansiedade enquanto interagiram com as ferramentas. Os autores concluíram que ao aplicar a ferramenta adequada é possível estimular as inteligências múltiplas mesmo de alunos que possuem dificuldades de aprendizagem e deficientes intelectuais.

As ferramentas também foram avaliadas pelo autor deste trabalho e notou-se que ambas podem ser para uso em *smartphones*¹ e são disponibilizadas na língua inglesa, espanhola e polonesa. Apresentam vários elementos de gamificação como missões, avatares, pontuações, recompensas e conquistas, por exemplo. As atividades são utilizadas para estimular inteligências múltiplas, voltadas para o público infantil de crianças entre 5 e 9 anos. Porém, não se enquadram diretamente para o público de deficiência intelectual, pois algumas tarefas e configurações exigem uma certa dificuldade para o jogador interpretar as informações, preencher formulários como nome, idade e e-mail e também selecionar o tipo de jogo a ser executado. A base para os jogos utilizam teor científico para fins educacionais, os quais se enquadram na modalidade de jogos sérios por estimular o raciocínio, memória, atenção e raciocínio. O quadro 3 apresenta uma comparação de funcionalidades entre as ferramentas *Cuibrain* e *Boogies Academy*.

Quadro 3 – Comparativo entre *Boogies Academy* e *Cuibrain*.

Descrição	Cuibrain	Boogies Academy
Atividades para Inteligências Múltiplas	Sim	Sim
Jogos sérios com base científica	Sim	Sim
Estatísticas e Progressão	Sim	Sim
Ambiente Gamificado	Sim	Sim
Multiplataforma	Não	Não
Perfil e Habilidades Cognitivas	Sim	Sim
Avaliação de Resultados	Sim	Sim
Público Infantil	Sim	Sim
Público com Deficiência Intelectual	Não	Não

Fonte: Autoria própria.

Uma outra característica marcante nas duas ferramentas é aumento do nível de dificuldade durante as interações com a redução do tempo para execução das mesmas. A medida que uma interação é superada, na próxima já são apresentados mais itens com um tempo mais reduzido, porém o nível de dificuldade não é reduzido ou reajustado se o jogador não conseguir completar uma determinada etapa do jogo. A parte visual consegue reter a atenção, pois os elementos são bem coloridos e intuitivos, além dos elementos sonoros que acompanham toda interação realizada nos jogos.

As ferramentas também apresentam resultados de atividades realizadas, exibindo o perfil e as habilidades do jogador. É possível também avaliar os resultados de suas habilidades cognitivas indicando quais delas poderão ser melhor exploradas para reforçar a aprendizagem do jogador. Desta forma, nota-se que a aplicação de jogos sérios pode ser um canal de aprimo-

¹ Apresentam as opções de multiplataforma, porém estão disponíveis apenas para *smartphones*

ramento de habilidade cognitivas para proporcionar a aproximação do aluno com atividades e experiências do mundo real.

2.2.1 Jogos Sérios e Deficiência Intelectual

A aprendizagem de pessoas com deficiência intelectual apresenta um grande desafio para professores de educação inclusiva, pois o ritmo de assimilação de conteúdo e os procedimentos de ensino são mais lentos em virtude de sua condição motora e cognitiva (VINENTE; GALVANI, 2019). No entanto, elas são capazes de aprender a ler, escrever, interagir socialmente e desenvolver habilidades, mesmo que diante de uma compreensão de instrução verbal mais lenta (FONSECA, 2016).

Existem diversas formas e atividades para motivar a aprendizagem de pessoas com deficiência intelectual, sendo que uma delas é a utilização de jogos sérios, que promove a aproximação de conteúdos pedagógicos com a realidade vivenciada. A aplicação deste recurso é uma tendência tecnológica porque atendem necessidades e funções específicas deste público. Para estimular o aluno com deficiência intelectual a compreender informações relacionadas ao jogo é necessário utilizar elementos atrativos de acordo com a sua realidade e habilidades. Alguns conceitos de *design* e funcionalidades podem ser elencadas com professores que trabalham com estes alunos (FARRINGTON, 2011).

Um exemplo é o trabalho de Bartolome, Zorrilla e Zapirain (2010) foi desenvolvido um jogo para aprimorar as habilidades sociais de deficientes intelectuais, direcionado ao público com deficit de atenção, utilizando um controle remoto com a funcionalidade de apontar e clicar. O jogo apresenta vários cenários em sala de aula, em casa, parques e ruas, envolvendo conversas e relações da vida cotidiana. As atividades exibidas durante o jogo auxiliam no aprimoramento da atenção concentrada, em que os exercícios são apresentados simulando situações do mundo real. Durante os testes realizados com o público, notou-se uma melhora nas habilidades motoras ao utilizar o controle remoto e na atenção concentrada porque as atividades vivenciadas durante o jogo foram exercitadas de forma recreativa e divertida.

O trabalho de Torrente *et al.* (2012) desenvolveu uma plataforma de jogos gratuita, chamada de *e-Adventure*, visando aprimorar a educação profissional de pessoas com deficiência cognitivas seguindo o formato de apontar e clicar para facilitar e tornar mais simples a interação. Esta plataforma permite o desenvolvimento de jogos por meio de recursos como cenas, livros, objetos, personagens, conversações, perfis de adaptação em que podem ser configuradas as condicionais de execução de atividades, perfis de avaliação que permitem apresentar *feedbacks* aos jogadores no final da execução de cada capítulo de um jogo.

No portal da *e-Adventure* são disponibilizados alguns jogos sérios gratuitos para testes como o *Finding a Job*. O jogo possibilita criar currículos e revisá-los, se candidatar para uma entrevista de trabalho e conhecer a empresa desde a recepção até o local de trabalho. Este jogo

foi aplicado para indivíduos com deficiência intelectual severa e foi observado que uma das dificuldades era lembrar de objetivos de curto prazo. Com isso, foi sugerida a criação de uma lista de atividades para ser acessada em qualquer momento do jogo para facilitar a releitura dos objetivos. Adicionalmente, notou-se que muitos usuários não se identificaram com o jogo em virtude da limitação cognitiva para entenderem as atividades.

O projeto APAE GAMES, desenvolvido pela UFV (Universidade Federal de Viçosa do estado de Minas Gerais) do Campus Rio Paranaíba, apresenta um jogo educacional para crianças com deficiência intelectual entre 6 a 10 anos, no qual aprendem conteúdos sobre ensino básico de atividades diárias, como hábitos alimentares, higiene pessoal e memorização. A aplicação do jogo com os alunos da instituição apresentou bons resultados, pois a aprendizagem gamificada foi classificada com a nota máxima em grande parte do questionário de avaliação. Além disso, verificaram que os alunos podem potencializar as suas habilidades de compreensão sobre as atividades diárias (FERREIRA *et al.*, 2018).

Um outro exemplo é o curso de Jogos Digitais oferecido pela Unicap (Universidade Católica de Pernambuco) que oferece o conteúdo relacionado com as demandas de jogos, utilizando técnicas e diretrizes para a construção de novas plataformas gamificadas em diversas áreas (UNICAP, 2019). A proposta é integrar os estudantes deste curso com jovens e adultos com síndrome de *down* ou deficiência intelectual a fim de compreender melhor as suas necessidades e limitações. Os alunos aprendem sobre *design* de jogos e artes relacionadas com o tema desenvolvendo jogos digitais direcionadas a este público. Com isso, o aprendizado é proporcionado tanto aos alunos do curso de jogos digitais quanto aos jovens e adultos com deficiência intelectual.

É notável que a aplicação de jogos sérios com deficientes intelectuais é um tema de pesquisa que está evoluindo na área educacional, em que recursos de gamificação podem ser aplicados para aprimorar os jogos e contribuir no processo de aprendizagem. E assim, motivar a interação com os indivíduos ao utilizar elementos de gamificação, como recompensas por superar determinados desafios. Contudo, é importante compreender o ambiente e o contexto para que os jogos atendam adequadamente o público com deficiência intelectual.

2.3 GAMIFICAÇÃO

O termo gamificação é uma adaptação da palavra "game", a qual abrange elementos relacionados a dinâmica, mecânica e aparência, que aplica a interatividade de jogos em atividades externas ao contexto dos mesmos. A mecânica dos jogos possui relação com regras, *feedbacks*, padrões e são tratados como atributos de jogos, mas não são relacionados diretamente com funcionamento, desafios e as regras estabelecidas para a execução de um jogo. Entretanto, pode ser composta por diversas formas e formatos (GASLAND, 2011).

Para Kapp (2012) a mecânica dos jogos abrange o desenvolvimento de estratégias gami-

ficadas para adaptar um determinado contexto de forma lúdica, sendo relacionado aos elementos de gamificação como a aparência visual, narrativa e a linguagem interativa de jogos, e contém recursos para envolver e motivar as pessoas a aprender e solucionar adversidades. O processo de gamificação relaciona diversos elementos de *design* de jogos, desafios, uso de estratégias, objetivos a serem superados, obter recursos e recompensas, adquirir insígnias e prêmios a fim de aprimorar a aprendizagem.

A gamificação tem o objetivo de promover o engajamento e motivar o jogador a superar etapas recebendo benefícios e recompensas conforme os desafios são apresentados, além de promover o pensamento independente e o desenvolvimento de habilidades (VIANNA *et al.*, 2013). Outra característica da gamificação é estimular o indivíduo a criar novas atitudes perante o jogo e estimular a criatividade para relacioná-las com experiências do mundo real.

Segundo Schmitz, Klemke e Specht (2012) a gamificação impacta nas atividades e o comportamento do jogador, na qual o processo de aprendizagem pode ser tornar mais eficaz contribuindo na retenção da atenção, motivação e o desenvolvimento cognitivo relacionado ao planejamento de jogadas, memorização, atenção, ação e reação. No contexto educacional, as propostas oferecidas aos jogadores como *feedbacks*, repetição de tarefas, níveis de dificuldades gradativos, diversas possibilidades de execuções, insígnias e outras recompensas, motivam e são meios expressivos para a aprendizagem (SIMOES; REDONDO; VILAS, 2013).

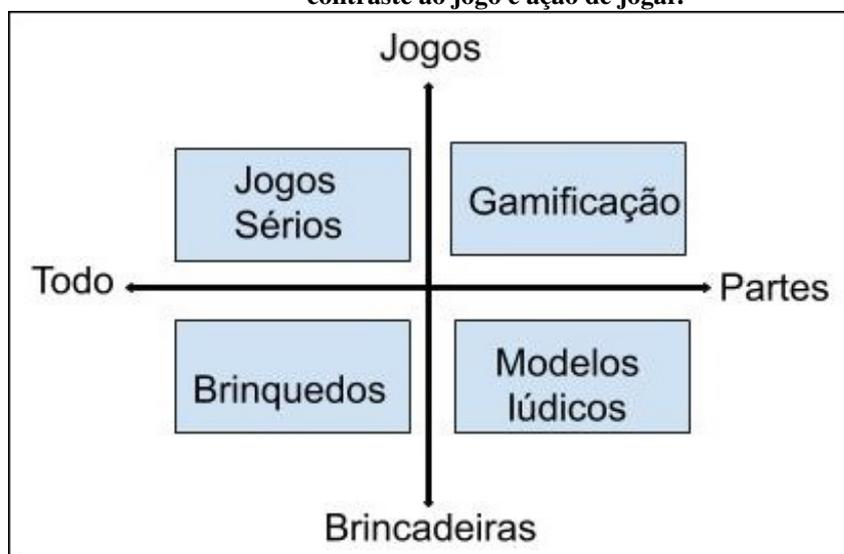
A gamificação (BORGES *et al.*, 2014) é usada como motivação de estudantes para atingir os seguintes objetivos: i) aprimorar determinadas habilidades; ii) propor desafios que provem a contextualização a aprendizagem; iii) engajar os alunos na realização de atividades; iv) aumentar a aprendizagem, v) promover mudança de comportamento devido a utilização de elementos tais como a premiação e *feedbacks*, vi) oferecer instrumentos de socialização e aprendizagem; e vii) propor aos alunos solução para situação problema.

A aplicação de gamificação necessita que elementos ideais para o domínio sejam identificados. Os elementos (DENDEN *et al.*, 2018) são: pontos, níveis, barra de progresso, *feedback*, avatar, distintivos, identificação de líder (*leaderboard*) e chat. A teoria de gamificação tem aumentado na área de educação para o ensino de várias disciplinas (DOMINGUEZ *et al.*, 2013; LEE; DOH, 2012).

Outro fator importante da gamificação é a criação de artefatos, arquiteturas ou modelos de produção para alcançar pessoas e motivá-las a interagir com um jogo. Conforme a motivação e o incentivo de ser desafiado promovem a vontade de interagir com o jogo, o sentimento pode manter a atenção do jogador e envolvê-lo a participar com maior intensidade (CHOU, 2020). Para Hulsebosch (2013), a gamificação se diferencia de jogos sérios, modelos de interações lúdicas e brinquedos. Os jogos são definidos por critérios e regras para a realização de um objetivo, as brincadeiras não tem um propósito definido e não apresenta a superação de desafios, apenas entreter e os termos "Todo" e "Partes" são os elementos que compõem os jogos. A partir dessa definição, a gamificação está no quadrante superior contendo regras e critérios para um propósito. Os elementos de gamificação são recompensas, ciclos rápidos interativos, níveis de dificuldades,

diferentes formas de alcançar um objetivo (DETERDING *et al.*, 2011). A Figura 3 exemplifica os termos relacionados a gamificação que associam características muito próximas.

Figura 3 – Matriz de gamificação contendo o uso de parte de jogos em contraste ao jogo e ação de jogar.



Fonte: Adaptado Hulsebosch (2013)

A gamificação é aplicada para encorajar e promover a aprendizagem concentrando a utilização de elementos de jogos que forem necessários em atividades que parecem ser complexas no mundo real. Ao utilizar elementos de jogos, a gamificação permite que a aquisição de conhecimentos seja mais divertida e agradável ampliando o processo de aprendizagem.

2.3.1 Elementos de Gamificação

Os elementos de gamificação são extraídos de jogos, pois estes apresentam uma forma lúdica de interação e de ficção em determinados contextos que favorecem o processo de aprendizagem por meio de narrativas, sons e imagens. Os elementos de gamificação podem ser utilizados em produtos e serviços que não sejam necessariamente representados por jogos, mas com o objetivo de motivar e estimular o comportamento de indivíduos (KAPP, 2012).

Os elementos de gamificação são itens relacionados a dinâmica, componentes e mecânica dos jogos, no entanto, não são relacionados ao ato de jogar (DETERDING *et al.*, 2011; DOMINGUEZ *et al.*, 2013).

Werbach e Hunter (2016) definiram estas categorias no desenvolvimento de gamificação para jogos, os quais são relacionadas entre si, de modo que um elemento mecânico se relaciona com um ou mais itens dinâmicos e os componentes se relacionam com um ou mais elementos dinâmicos e mecânicos. O quadro 4 apresenta os elementos dinâmicos de gamificação baseado no estudo de Werbach e Hunter (2016).

A dinâmica é relacionada com personagens, narrativas, enredo, objetivos e propósitos,

Quadro 4 – Elementos dinâmicos de gamificação

Dinâmica	Descrição
Emocional	Vontade do jogador permanecer no jogo de acordo com os seus sentimentos.
Narrativa	Coerência da progressão e enredo histórico do jogo.
Progressão	Avanço e superação de etapas.
Relacionamento	Interação e ações entre jogadores de um mesma equipe ou adversários
Restrição	Limitações devido as regras.

Fonte: Adaptado de Werbach e Hunter (2016)

recebimento de insígnias e recompensas ao superar desafios e as interações durante as etapas do jogo. Os componentes são as interfaces, insígnias e medalhas, personagens, pontos, missões e etapas (Quadro 5). No entanto, os componentes podem ser entendidos como elementos físicos, dentro de uma perspectiva virtual que são utilizados por um personagem no jogo para realizar as suas atividades e interações entre jogadores. Além disso, muitos componentes podem ser combinados entre si em diversos contextos para facilitar o desempenho, obter bonificações e avançar etapas rapidamente.

Quadro 5 – Elementos relacionados aos componentes de gamificação

Componentes	Descrição
Avatar	Personagem visual utilizado no jogo.
Bens virtuais	São itens que podem ser coletados e utilizados no jogo.
Chefe	Desafio avançado em um final de estágio ou fase a ser superado.
Coleções	Recursos obtidos como insígnias e medalhas.
Conquistas	Recompensas após finalizar etapas específicas.
Conteúdos Desbloqueáveis	São atividades específicas a serem superadas para habilitar outras fases ou recompensas.
Insígnias/medalhas	Recurso visual que representam a experiência ou execução de atividades específicas.
Gráfico social	Informações entre jogadores em rede social.
Missão	Desafio imposto ao jogador para avançar etapas.
Níveis	Nível de dificuldade para realização do jogo ou representação numérica de acordo com experiência do jogador.
Pontos	São valores ou números relacionadas as medalhas e conquistas obtidas.
Presentes	São itens ou recursos que podem ser utilizados em transações de jogadores.
Classificação (<i>Ranking</i>)	Quadro de classificação de maior e menor desempenho.
Equipes	São grupamento ou times de jogadores para realizar um mesmo objetivo.

Fonte: Adaptado de Werbach e Hunter (2016)

A mecânica dos jogos é referente as funcionalidades e atividades em que um jogador efetua e interage com as adversidades apresentadas, níveis, crescimento progressivo de habilidades (Quadro 6) (WERBACH; HUNTER, 2016).

Quadro 6 – Elementos mecânicos de gamificação

Mecânica	Descrição
Obter recursos	Coletar recursos e/ou itens para realizar as missões.
<i>Feedback</i>	Avaliar como estão progredindo no jogo ou que ações tomar durante as atividades.
Tentativas	Quantidade de vezes que o jogador possui nas missões.
Desafios	Atividades e objetivos a serem realizados.
Recompensas	Bonificação após atingir uma conquista.
Transações	Relações direta entre jogadores como troca, venda ou compra.
Turnos	Momento em que o jogador pode exercer sua jogadas de acordo com um determinado tempo ou missão.
Sucesso	Situação em que o jogador é vitorioso.

Fonte: Adaptado de Werbach e Hunter (2016)

Além dos elementos citados no quadro 6, são utilizados outros elementos relacionados a objetos de aprendizagem como círculos de interação, repetições de uma mesma fase do jogo, progressão alternativa de resolução de desafios, metas e regras para controlar os níveis e etapas, e também a resposta imediata (*feedback*) de acordo com o sucesso ou fracasso.

Werbach e Hunter (2016) destacam que os elementos descritos acima podem ser relacionados de diversas formas, pois não existe um padrão para a utilização de elementos de gamificação, mas deve ser observado o contexto em que serão aplicados².

Avaliar e compreender o ambiente que será confeccionada a aplicação do jogo é essencial para obter sucesso, pois uma composição baseada em apenas pontos, medalhas e recompensas pode não ser tão atrativa para o jogador. O excesso destes itens pode desmotivar e distanciar o uso da gamificação levando a aplicação ao fracasso (DETERDING *et al.*, 2011).

2.3.2 Gamificação na Educação

Considerando os estudos existentes na literatura sobre jogos ou gamificação na educação, uma prática comum é a realização de revisões da literatura de forma mais sistematizada. Isto contribui para avaliar a área de pesquisa em que se deseja propor uma solução ainda não mensurada.

Para compreender a aplicação de gamificação na educação, procurou-se identificar na literatura os trabalhos de mapeamento ou de revisão sistemática relacionados a jogos na educação e categorizá-lo pelo assunto de gamificação aplicados à educação usando as seguintes

² Ver a seção 2.3.3 que cita sobre elementos importantes de gamificação utilizados em jogos digitais de alunos com deficiência intelectual.

strings de busca: “education” and “gamification” and “education” and “systematic review” or “mapping systematic”.

Foram encontrados 132 estudos e destes foram removidos 14 porque estavam em duplicidade, ficando com um total de 121. Destes 121, 28 estudos estavam relacionados a revisão ou mapeamento envolvendo: Gamificação e Educação (GARCIA DA LUZ *et al.*, 2021).

Os trabalhos foram categorizados com base em suas características de maior relevância, sendo:

- Utilização da Gamificação e os níveis educacionais aplicados.
- Ambientes de aplicação de gamificação, uso de ferramentas e teorias de aprendizagem.
- Trabalhos de revisão literatura sobre como a gamificação é desenvolvida e reutilizada.
- Gamificação multidisciplinar e novas diretrizes para o uso da gamificação.

Os trabalhos dos autores Morelock (2013), Borges *et al.* (2014), Dicheva *et al.* (2015), Alanne (2016), Bodnar *et al.* (2016), Santos e Freitas (2017), Ortiz-Rojas, Chiluiza e Valcke (2017), Stevenson, Hartmeyer e Bentsen (2017), Subhash e Cudney (2018), Alhammad e Moreno (2018), Souza *et al.* (2018), Borges *et al.* (2018), Cordero-Brito e Mena (2018) e Gentry *et al.* (2019). Morelock (2013) e Subhash e Cudney (2018) apresentam como a gamificação é utilizada e quais os níveis educacionais foi aplicada, verificando a utilização de jogos sérios nos trabalhos relacionados.

O autor Morelock (2013) identificou a aplicação da gamificação em jogos de simulação no ensino superior de engenharia. O quadro 7 apresenta as revisões sistemáticas relacionadas a utilização da gamificação e os níveis educacionais aplicados.

Quadro 7 – Utilização da Gamificação e os níveis educacionais aplicados

Autores	Contribuição
Morelock (2013)	Estudo de gamificação voltada para o ensino superior de engenharia na aplicação de atividades de <i>design</i> e de estímulo para desenvolvimento de habilidades para resolução de problemas.
Borges <i>et al.</i> (2014)	Uso de gamificação em ambientes de aprendizagem colaborativa apoiada por computador. Identificaram possíveis benefícios e efeitos colaterais em relação ao uso da gamificação na educação, propondo modelos gamificados para o ensino de idiomas, extensão universitária, treinamentos e tutoriais.
Dicheva <i>et al.</i> (2015)	Investigou as dimensões de elementos de jogos, tipo de aplicação, nível educacional, matéria acadêmica, implementação e resultados reportados da avaliação. O resultado da pesquisa revelou que os jogos de aprendizagem ainda são muito escassos pois não possuem uma avaliação adequada, sendo determinada pela mecânica e princípios de <i>design</i> de jogos.

Alanne (2016)	Pesquisou trabalhos de aprendizagem baseadas em jogos e aplicações de jogos de simulação nas áreas de engenharia civil, elétrica, informática, química, mecânica, industrial e ambiental, voltadas para serviços de construção.
Bodnar <i>et al.</i> (2016)	Identificou que as áreas que mais concentram os jogos sérios é a engenharia da computação e software, mecânica, elétrica, produção, civil e primeiros anos de cursos de engenharia. Observou-se que os tipos de documentos eram relacionados em sua maioria em avaliação cognitiva e avaliação afetiva, seguido da avaliação afetiva e avaliação cognitiva, separadamente.
Santos e Freitas (2017)	Investigou trabalhos relacionados a educação ou que apresentavam abordagens práticas na gamificação em vários níveis e tipos educacionais, além de apontar as finalidades da gamificação nas pesquisas.
Ortiz-Rojas, Chiluíza e Valcke (2017)	Investigou a gamificação categorizando os elementos dos jogos, disciplinas, período (mensal, diário, semestral, ano, módulo e não mencionado), tamanho da amostra, nível educacional e resultado (negativo, positivo ou ambos). Além de indicar os países onde os estudos foram realizados.
Stevenson, Hartmeyer e Bentsen (2017)	Realizaram um mapeamento sistemático para verificar as contribuições das tecnologias de mapeamento de conceitos na aprendizagem da educação em ciência. Foi analisado como as tecnologias afetam a aprendizagem por meio da cognição, metacognição, estratégia de motivação. Concluíram que software de computadores são úteis para desenvolver as estratégias de cognição e que agentes são importantes para desenvolver a estratégias de metacognição unindo visualização de padrões de comportamento com monitoramento de desempenho. Uso de tipos mais novos de tecnologias, tais como dispositivos móveis, de forma integrada com o objetivo de auxiliar na aprendizagem. Sugere que as tecnologias sejam integradas de forma inteligente.
Subhash e Cudney (2018)	Investigou a aplicação da gamificação no ensino superior apontando as estruturas de aprendizagem gamificada e aprendizagem baseada em jogos, concluindo que a área de maior aplicação é a de computação. Notaram que a gamificação no ensino superior apresentam muitos benefícios como maior envolvimento do aluno.

Alhammad e Moreno (2018)	A revisão proposta pelos autores é sobre o ensino na engenharia de software, em especial utilizando gamificação. O objetivo foi identificar qual abordagem da gamificação deve ser usada, tendo em vista a variedade de elementos de gamificação disponíveis. Destaca que 80% das aplicações gamificadas falham em atingir seus objetivos, principalmente pelo processo ser inadequado (GARTNER, 2012). Os autores afirmam que a educação na engenharia de software está no seu início (ou nas palavras deles "infância"), com muitas oportunidades para evolução. Ainda, que a literatura mostra que há muito potencial para suporte, motivação e engajamento.
Souza <i>et al.</i> (2018)	O objetivo de revisão sistemática é realizar a discussão de como os métodos relacionados a jogos são usados no contexto da educação em engenharia de software e investigar como os métodos suportam um conhecimento específico. O uso da gamificação acrescenta uma nova possibilidade para abordagens relacionadas a jogos, assim como a realização de experimentos contemplando a gamificação no ensino da engenharia de software.
Borges <i>et al.</i> (2018)	Realizaram um mapeamento sistemático sobre trabalhos que apresentassem experimentos sobre o ensino e aprendizagem de programação entre os anos de 2012 e 2016. Os autores buscaram por soluções que abordem metodologias, práticas ou ferramentas para o ensino de Linguagens de Programação. Autores observaram que a maior quantidade de trabalhos (23 trabalhos) está relacionada com a aplicação de metodologias apoiadas por ferramentas de ensino de programação, jogos digitais educativos e gamificação; 16 trabalhos propõe uma ferramenta e o restante dos trabalhos (6 trabalhos) relatam a utilizam de práticas colaborativas, modelos lúdicos, vídeo aulas, entre outras.
Cordero-Brito e Mena (2018)	No campo educacional, aplicativos usam a gamificação mecânica para motivar a participação e aquisição de conhecimento. Observaram que os componentes mais utilizados são pontos (exames), níveis (notas), realizações (notas) e tabelas de comparação. Pontos e emblemas são usados como elementos de premiação e desafios e competições servem para criar uma atmosfera competitiva entre os alunos. Na área da saúde o uso de jogos com elementos de gamificação tem sido utilizados no incentivo de estilos de vida saudáveis e prevenção de doenças.

Gentry <i>et al.</i> (2019)	Identificaram que o uso da gamificação contribuiu na educação do profissional da saúde quando comparados com a educação tradicional. Os autores destacam que a maior parte dos estudos que utilizam a gamificação na educação de profissionais da saúde ocorreu em países de alta renda e que os países de baixa e média renda são os mais afetados pela escassez de profissionais treinados na área da saúde.
-----------------------------	--

Fonte: Autoria própria.

Os autores Dicheva *et al.* (2015), Santos e Freitas (2017), Ortiz-Rojas, Chiluiza e Valcke (2017), Cordero-Brito e Mena (2018), Alhammad e Moreno (2018) e Souza *et al.* (2018) identificaram quais são os elementos de gamificação utilizados nos jogos. No trabalho de Ortiz-Rojas, Chiluiza e Valcke (2017), os autores destacam que elementos de gamificação em sua maioria apresentam aspectos positivos, mas outros podem apresentar aspectos negativos como distintivos e *leaderboard* (placar dos melhores jogadores). Alhammad e Moreno (2018) apresenta um quadro com elementos de gamificação mais recorrentes como mecânicos (desafios, competição, *feedback*), dinâmicos (narrativa, progressão, emocional, relacionamentos e restrições) e componentes (pontos, distintivos, níveis e ranking).

Borges *et al.* (2014), Ortiz-Rojas, Chiluiza e Valcke (2017), Cordero-Brito e Mena (2018) e Souza *et al.* (2018) citam o uso da gamificação relacionando com a aprendizagem colaborativa em que propósito é aprimorar as habilidades por meio de desafios apresentados visando aumentar o engajamento, modificar o comportamento, melhorar a aprendizagem e socializar.

Em relação as questões comportamentais, os autores Borges *et al.* (2014), Alanne (2016), Bodnar *et al.* (2016), Santos e Freitas (2017), Ortiz-Rojas, Chiluiza e Valcke (2017), Stevenson, Hartmeyer e Bentsen (2017) e Subhash e Cudney (2018) apresentam a motivação e engajamento com maior destaque ao aplicar a gamificação e jogos sérios. No trabalho Bodnar *et al.* (2016) são citadas avaliações cognitivas e afetivas relacionadas ao comportamento do participante. E Stevenson, Hartmeyer e Bentsen (2017) analisou como as tecnologias afetam a aprendizagem por meio da cognição, metacognição e estratégia de motivação.

Outros trabalhos dos autores Truong (2016), Brito e Madeira (2017), Tenório *et al.* (2018) e Trinidad, Calderón e Ruiz (2018) e Lara, Aljawarneh e Pamplona (2019) evidenciaram o uso de ferramentas, teorias de aprendizagem ou ambientes em que a gamificação é aplicada. A tabela 8 apresentam ambientes que aplicam a gamificação, uso de ferramentas e teorias de aprendizagem.

Quadro 8 – Ambientes de aplicação de gamificação, uso de ferramentas e teorias de aprendizagem

Autores	Contribuição
Truong (2016)	Pesquisaram sobre teorias de aprendizagem em ambientes e-learning, processos de integração de estilos de aprendizagem e predição de estilos em aprendizagem. Identificou que as teorias usadas são <i>Felder-Silverman, Honey & Mumford, Kolb, VARK</i> e outras. Os algoritmos de classificação usados na aprendizagem foram <i>Bayesian network</i> (7), <i>Naive Bayes</i> (3), <i>Rules</i> (8), <i>Neural Network</i> (3), <i>Decision Tree</i> (2), outros (5). Constataram que a integração de estilos de aprendizagem e sistemas de aprendizagem adaptativos requerem estudos e experimentos. Outra tendência é a seleção e avaliação de algoritmos de classificação.
Brito e Madeira (2017)	Identificação de como ocorre o processo de concepção dos ambientes educacionais gamificados, onde os elementos são escolhidos de forma aleatória. Observou que existem um favorecimento no uso de elementos típicos do modelo PBL (<i>Points Badgets and Leaderboards</i>) e usa a motivação extrínseca, como por exemplo, medalha ou recompensas.
Tenório <i>et al.</i> (2018)	Investigou e identificou elementos de gamificação aplicados em ambientes de aprendizagem virtual realizando a pesquisa em periódicos disponibilizados pelo portal da CAPES, que é uma plataforma brasileira de divulgação científica.
Trinidad, Calderón e Ruiz (2018)	Revisão sistemática para identificar quais conhecimentos e ferramentas que garantem o sucesso de objetivos de gamificação dentro do processo de software.
Lara, Aljawarneh e Pamplona (2019)	Revisão sistemática oferecendo algumas recomendações e sugestões para pesquisadores da área sobre tendências atuais de avaliação de <i>e-learning</i> , em que uma das abordagens é utilizar estratégias de gamificação a fim de aprimorar a qualidade do ensino superior.

Fonte: Autoria própria.

Outros trabalhos evidenciaram revisões sistemáticas de como a gamificação é desenvolvida e reutilizada como descritos pelos autores Peixoto e Silva (2015), Seaborn e Fels (2015), Mora *et al.* (2017), Calderón *et al.* (2018) e Kamunya, Maina e Oboko (2019). A tabela 9 apresentam revisões sistemáticas de como a gamificação é desenvolvida e reutilizada.

Quadro 9 – Revisão sistemática de como a gamificação é desenvolvida e reutilizada

Autores	Contribuição
Peixoto e Silva (2015)	Caracterizar itens de gamificação para serem reusados no desenvolvimento de softwares em ambientes educacionais.

Seaborn e Fels (2015)	Descreve uma revisão sistemática multidisciplinar sobre trabalhos relacionados a sistemas interativos e interação humano computador de jogos de realidade alternativa, jogos de computação baseados em humanos e <i>design</i> de jogos apresentando um padrão de gamificação que está emergindo em diversas áreas, sendo uma delas a de educação.
Mora <i>et al.</i> (2017)	Mapeamento realizado sobre <i>design</i> de games na educação divididos em quatro categorias de <i>frameworks</i> : aprendizagem, genéricos, negócios e saúde. Este estudo indicou a alta relevância de perspectivas psicológicas como principal item no processo de <i>design</i> de jogos, porém a personalização de jogos para usuários não é muito enfatizada.
Calderón <i>et al.</i> (2018)	Revisão sistemática sobre jogos sérios na educação identificando quais são os estudos existentes e quais são aplicados no aprendizagem de processos de softwares.
Kamunya, Maina e Oboko (2019)	A teoria mais utilizada para desenvolvimento de gamificação é o MDA (Mecânica, Dinâmica e Estética), seguida da teoria de fluxo e de <i>Self Determination Theory</i> (SDT). Os autores relatam que 38% dos estudos não possuem uma base teórica que de suporte ao desenvolvimento de gamificação. Outra observação destacada pelos autores é que 50% dos frameworks utilizam o princípio de design centrado no usuário e apenas 1 trabalho considerou os princípios de design de frameworks de gamificação e avaliação usados em modelo de ensino e-learning.

Fonte: Autoria própria.

E por fim, os trabalhos dos autores Osatuyi, Osatuyi e Rosa (2018), Bozkurt e Durak (2018), Rodrigues, Oliveira e Rodrigues (2019) e Inocencio (2018) apresentaram estudos sobre gamificação multidisciplinar e novas diretrizes para o uso da gamificação.

Quadro 10 – Gamificação multidisciplinar e novas diretrizes para o uso da gamificação

Autores	Contribuição
Osatuyi, Osatuyi e Rosa (2018)	Pesquisaram publicações para revelar padrões de gamificação na educação sistemas da informação. Os documentos foram classificados em diversos aspectos como: fatores influentes em jogos, aplicação de programas de jogos, impactos da gamificação e tópicos gerais, não empíricos, e empíricos com a subdivisão de quantitativos e qualitativo. O resultado demonstrou que os métodos empíricos possuem uma recorrência maior que os métodos não empíricos. A análise dos artigos também indicou que a maior parte dos estudos é realizado por autores do sexo masculino nos países do hemisfério norte.

Bozkurt e Durak (2018)	Realizou um mapeamento para identificar padrões e tendências de pesquisas sobre gamificação. Utilizou uma categorização de modelos quantitativos, qualitativos, quantitativos e qualitativos, conceitual ou teórico ou outros, mineração e análise de dados, e prática baseada. A partir dessa categorização obtiveram como resultado que a palavra “gamificação” é bastante recorrente juntamente com os termos “engagement”, “motivation”, “game mechanics”, “game-based learning”, “serious game”, “social networking”, “game elements”, “education” e “e-learning”. Identificaram que a palavra “gamificação” possui uma frequência alta no campo da educação, seguido do campo teórico (um terço menor que da educação), depois nas áreas da saúde, marketing, design, negócios, engenharia, bibliotecas, turismo, gerenciamento e comunicação.
Rodrigues, Oliveira e Rodrigues (2019)	A revisão investigou o campo da gamificação: "Quais as diretrizes para novas pesquisas em gamificação, seus principais temas?". Como resultado a revisão contribui para o estabelecimento de possíveis diretrizes para novos estudos integrando projetos de jogos relacionados a negócio, aprendizagem e educação e destaca o uso do <i>Leximancer</i> para a realização da análise qualitativa de conteúdo. Outro resultado é mostrar a proximidade, associação direta ou indireta da gamificação com outros temas tais como jogos, engajamento, uso e usuários.
Inocencio (2018)	Investigou o uso da gamificação de forma multidisciplinar em diferentes áreas sem especificações pré-definidas e os documentos foram categorizados em 4 tipos: participação baseada em usuários, desempenho baseada na própria percepção, desempenho baseado em notas atribuídas por usuários, retenção baseada na atividade de usuários, sendo que as principais categorias com maiores recorrências é a de desempenho baseado em notas atribuídas de usuários e a participação baseada em usuários.

Fonte: Autoria própria.

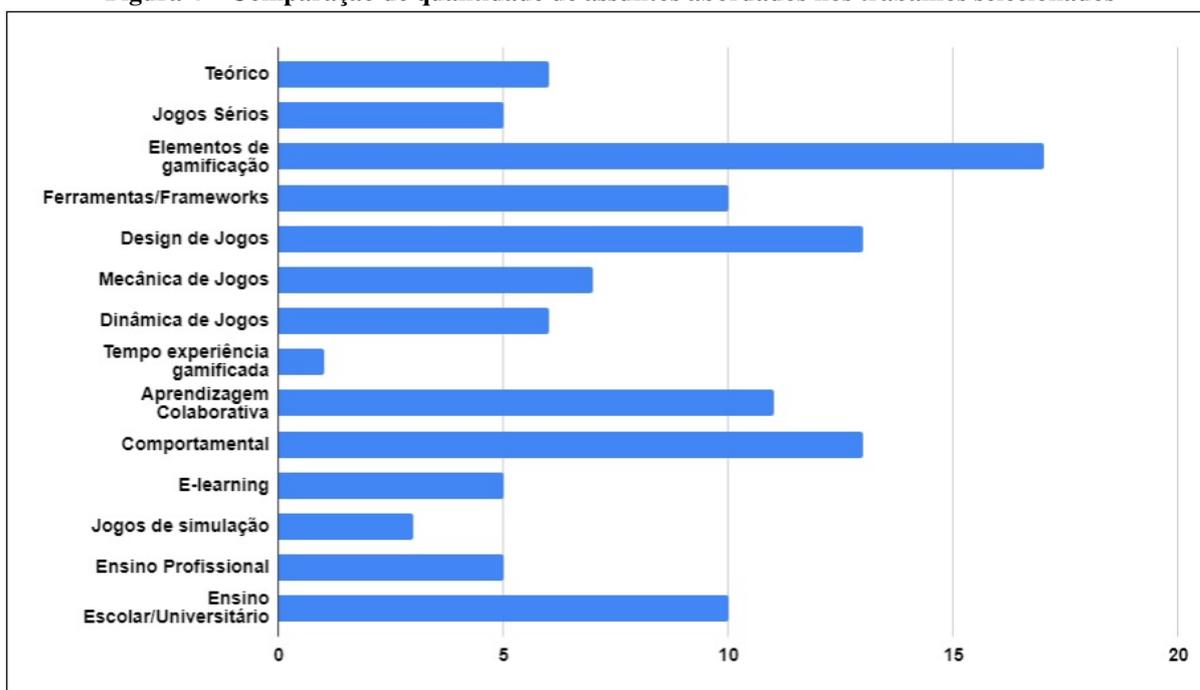
Os assuntos abordados por meio dos mapeamentos ou das revisões sistemáticas encontradas foram separados nos quadros 7, 8, 9 e 10 para fins comparativos de forma resumida apresentando os autores e contribuição de cada trabalho.

Os trabalhos apresentados nos quadros acima abordam a gamificação aplicados a jogos sérios e jogos de simulação na educação. Alguns jogos são utilizados para o processo de aprendizagem colaborativa (OSATUYI; OSATUYI; ROSA, 2018; SUBHASH; CUDNEY, 2018), aprendizagem no processo de software (CALDERÓN *et al.*, 2018), *E-learning* (TENÓRIO *et al.*, 2018; LARA; ALJAWARNEH; PAMPLONA, 2019; KAMUNYA; MAINA; OBOKO, 2019; GENTRY *et al.*, 2019) e no ensino superior de engenharia (MORELOCK, 2013).

Na maioria dos trabalhos que foram selecionados é enfatizado uso elementos de gamificação, sendo que os de maiores destaque são: *badges* (distintivos ou condecorações), pontos, *leaderboard* (placar dos melhores jogadores), *level* (nível ou posição do jogador), avatares, times, gráfico social (progressão, itens mais utilizados, percentuais de acerto, etc.) em comparação com os demais jogadores e bem virtuais (itens que um personagem pode utilizar dentro do jogo) (TENÓRIO *et al.*, 2018; DICHEVA *et al.*, 2015).

Os elementos de gamificação são aplicados em jogos sérios com o intuito de motivar e melhorar o engajamento de alunos na aprendizagem. Porém, quando aplicados apenas com base na experiência de jogadores e sem um planejamento adequado, dependendo do contexto educacional, podem apresentar resultados negativos de comportamento. Um exemplo é a utilização de *leaderboard* e condecorações em que a competitividade entre os jogadores pode gerar uma inversão de valores com aumento de disputa. Contudo, ainda os aspectos positivos são mais evidentes em comparação com os negativos. A utilização de desafios, *rankings*, condecorações, avatares e pontos, influenciam na motivação, participação, engajamento cognitivo e comportamental de forma positiva (ORTIZ-ROJAS; CHILUIZA; VALCKE, 2017). A figura 4 apresenta a comparação de quantidade de assuntos abordados no mapeamento sistemático.

Figura 4 – Comparação de quantidade de assuntos abordados nos trabalhos selecionados



Fonte: Autoria própria.

No levantamento de informações notou-se um aumento de estudos relacionados ao mapeamento sistemático que descrevem a gamificação na educação, sendo que em 2018 foram 7 artigos. Analisando a quantidade de aplicação de gamificação em níveis educacionais, o ensino superior possui uma maior frequência com 6 trabalhos, seguido de 5 trabalhos em que sua aplicação ocorre em vários níveis (ensino básico, ensino médio e ensino superior), 16 sem informações e 1 trabalho nos níveis de ensino médio, ensino fundamental e ensino para deficiente intelectual.

O mapeamento sistemático mostrou que o ensino superior concentra a maior parte de aplicações de gamificação na educação em todos os anos, sendo que este nível educacional também se enquadra em vários níveis (ensino básico, ensino médio e ensino superior). Os trabalhos do ano de 2015 apresentam dois estudos, um no ensino superior e o outro trabalho não apresenta informações em qual nível educacional foi aplicado o contexto de gamificação. Além disso, apenas no ano de 2017 existem publicações de gamificação aplicadas para ensino médio e ensino para deficiente intelectual.

Durante o processo de levantamento de trabalhos relacionados verificou-se que abordam muitos aspectos relacionados a gamificação e jogos aplicados na educação. É um fator importante é que o desenvolvimento do aluno pode ser realizado de forma individualizada ou customizada conhecendo suas dificuldades, habilidades e potencialidades (MORA *et al.*, 2017).

2.3.3 Gamificação e Deficiência Intelectual

A gamificação propõe uma nova dinâmica para beneficiar o desenvolvimento cognitivo e de habilidades dos alunos com deficiência intelectual. Ao invés de receber o conhecimento de forma linear, de professor para o aluno, a aprendizagem gamificada procura estimular a criatividade e repassar a iniciativa e tomada de decisão para o aluno superar os desafios propostos em um jogo (BOTELHO; OLIVEIRA; GIGLIO, 2017).

O uso da gamificação com indivíduos com deficiência intelectual pode ser aplicada desde que os conteúdos sejam explorados e adaptados corretamente. Os conteúdos usando a gamificação podem ser analógicos ou digitais para tornar as aulas mais interativas e possibilitar que o ambiente de aprendizagem propicie um maior envolvimento e interesse do aluno. O intuito de usar a gamificação é engajar alunos e professores auxiliando na melhoria da aprendizagem, expandindo a mudança de comportamento para ambientes externos ao jogo e aplicando o conteúdo absorvido em atividades diárias (MACEDO, 2010).

O trabalho de Cunha (2011) utilizou de hipermídia com o enquadramento de narrativas em um jogo de computador para ensino de vocabulário para crianças com autismo³. No jogo são aplicados os elementos de gamificação para estimular a interação e os sentidos visuais e identificação de objetos com a forma escrita. É aplicado um enredo adequado e diversas ilustrações, o indivíduo é envolvido na história para compreender o contexto e absorver o conteúdo.

O jogo é apresentado por um personagem que mostra as palavras e objetos variados em que o aluno possa identificar os objetos em diversas categorias como frutas, mobiliário, ferramentas, materiais de higiene, meios de transporte, eletrônicos, construções, escolar, animais, cozinha alimentos, insetos, música e roupa, e efetuar as combinações para acertar a palavra relacionado com o objeto escolhido. A medida que os objetos são apresentados é exibida a forma

³ O DSM-V (APA, 2013) define os sintomas do autismo para indivíduos com problemas de interação social, comunicação e comportamento.

escrita do objeto para estimular o reforço visual da palavra combinada com o objeto. Neste trabalho foram identificados elementos de gamificação como narrativa, progressão e restrições, que são elementos relacionados a dinâmica do jogo. Conquistas e níveis relacionados a componentes do jogo. Os elementos mecânicos do jogo são tentativas como *feedback* e desafios.

Os elementos de gamificação tem o intuito de envolver e estimular o indivíduo de forma extrínseca e intrínseca por meio de recompensas e novos desafios. A motivação intrínseca é relacionada ao estímulo comportamental como prazer, ser desafiado perante uma missão, força de vontade em superar obstáculos ou algo agradável de interagir diversas vezes de forma lúdica. A extrínseca é a forma de estimular por meio de recompensas, pontos ou premiações, em que tais fatores externos motivam o crescimento e o envolvimento no jogo (SHELDON, 2012).

A pesquisa realizada pelos autores Gooch *et al.* (2016) verificou que o uso de elementos de gamificação pode motivar alunos com dislexia⁴ na transição do ensino fundamental para o ensino médio. Por meio de uma plataforma gamificada chamada *classDojo* (CLASSDOJO, 2020), a qual permite personalizar insígnias e avatares conforme a necessidade dos professores, criaram insígnias positivas e negativas para estimular a aprendizagem atribuindo recompensas ao superar um desafio. Cada aluno foi representado por um avatar customizável que demonstra sua interatividade no jogo e indica sua participação na plataforma de ensino. Como resultado, identificaram que a personalização de avatares e o recebimento de insígnias pelos desafios superados são recursos essenciais para motivar os alunos com dislexia. Esses elementos de gamificação permitiram aos professores envolvidos neste estudo, criar e atribuir as recompensas visando a particularidade de cada aluno. O quadro 11 apresenta uma comparação entre as ferramentas *Aquisição de Vocabulário* e o *classDojo*.

Quadro 11 – Comparativo entre *Aquisição de Vocabulário* e *classDojo*

Descrição	Aquisição de Vocabulário	classDojo
Atividades para Inteligências Múltiplas	Não	Sim
Jogos sérios com base científica	Sim	Sim
Estatísticas e Progressão	Sim	Sim
Ambiente Gamificado	Sim	Sim
Multiplataforma	Não	Sim
Chat e comunicador	Não	Sim
Formação de times	Não	Sim
Personalização de Avatares	Sim	Sim
Perfil e Habilidades Cognitivas	Sim	Sim
Avaliação de Resultados	Sim	Sim
Público Infantil	Sim	Sim
Público com Deficiência Intelectual	Sim	Sim

Fonte: Autoria própria.

⁴ Segundo o DSM-V (APA, 2013) dislexia é um dos distúrbios específicos de aprendizagem caracterizando-se pelo indivíduo apresentar dificuldades na leitura, na precisão e na velocidade de reconhecimento de palavras e no processo de decodificação fonológica, relacionadas ou não com baixas habilidades de soletração. A dislexia é um termo alternativo referentes aos padrões de dificuldades, podendo ser isoladas ou acompanhadas de uma ou mais dificuldades adicionais, tais como dificuldade na compreensão de leitura ou no raciocínio matemático.

As duas ferramentas possuem elementos de gamificação como progressão, narrativas, avatares, insígnias, desafios e pontuações. Ambas aplicam jogos sérios com base científica, possuem um ambiente gamificado, apresentam estatísticas e progressão, permitem visualizar e avaliar resultados após as interações e são voltadas para o público infantil. O *classDojo* é multiplataforma e possui recursos mais completos como diversas atividades para inteligências múltiplas, comunicador entre participantes e permite a formação de times. E o Aquisição de Vocabulário é direcionado para o letramento de forma individual.

Para os autores Ifigenia *et al.* (2018), os professores e educadores precisam ser capacitados sobre a gamificação e seus elementos a fim de adequar os jogos de educação especial e ter uma ferramenta para apoiar o ensino de forma interativa e colaborativa. Adicionalmente, destacam alguns elementos importantes de gamificação utilizados em jogos eletrônicos para os alunos de educação especial, os quais são apresentados no quadro 12.

Quadro 12 – Elementos importantes de gamificação utilizados em jogos digitais de alunos com deficiência intelectual

Elemento de gamificação	Descrição
Obter recursos	Possibilidade de coletar itens durante o progresso do jogo, pois isto é um fator motivacional para o aluno continuar executando outras atividades.
Pontos	Retorno instantâneo de desempenho em uma determinada atividade. A pontuação oferece vantagens para trocar por objetos, acessar níveis mais avançados do jogo, classificar o aluno durante o jogo e apresentar uma transparência sobre o seu estado atual.
Classificação (<i>Ranking</i>)	Promove a competitividade entre os jogadores ao realizar comparações por meio de uma listagem classificatória de participantes e pontuação adquirida. É um fator motivacional porque permite ao jogador avaliar o seu estado e buscar melhorar a sua situação.
<i>Feedback</i>	Informa ao jogador se as atividades realizadas atingiram ou não os objetivos propostos. É um elemento que gera conhecimento ao jogador.
Níveis	Elemento que gerencia o progresso dentre os módulos do jogo. Ao superar um nível passa para um próximo mais avançado.
Desafios	É um elemento fundamental que influencia psicologicamente o comportamento do aluno. É também, um componente social que permite o aluno colaborar e comparar seus objetivos.

Fonte: Adaptado de Ifigenia *et al.* (2018)

A aplicação destes elementos de gamificação podem trazer benefícios como: apontar o progresso do aluno em sua aprendizagem em um determinado contexto, assimilar o conhecimento de uma forma interativa e dinâmica, estimular o aluno a superar desafios aprendendo por meio de interações diversificadas e promover melhor a participação na própria elaboração do conhecimento (IFIGENIA *et al.*, 2018; LEE; HAMMER, 2011). Entretanto, o emprego da gamificação em sala de aula não substitui as aulas e atividades tradicionais. E a gamificação e uso de seus elementos podem auxiliar no processo de aprendizagem do conhecimento de forma mais interativa.

2.4 APRENDIZAGEM DE MÁQUINA

Aprendizagem de máquina ou *Machine Learning* (ML) é uma parte da inteligência artificial, a qual aplica algoritmos de forma sistemática com a capacidade de aprender e se adaptar as mudanças de um sistema, utilizando critérios de exemplos de dados ou experiências passadas. Essa habilidade de aprendizagem não apenas prevê uma determinada condição, mas providência todas soluções para resolver as situações imprevistas, pois determinadas tarefas ou eventos que surgem durante a execução de um sistema podem ser muito complexas para serem solucionadas por meio da programação clássica (ALPAYDIN, 2014).

A aprendizagem de máquina abrange operações e funcionalidades de forma automática com base em operações lógicas ou binárias, aprendendo a resolver uma tarefa por meio de uma série de exemplos para aprimorar o processo de decisão (MICHIE; SPIEGELHALTER; TAYLOR, 2009).

Segundo Samuel (1959), cientista que criou o primeiro programa de aprendizagem para o jogo de damas, descreve que a aprendizagem de máquina transfere a habilidade para o computador aprender sem que isto esteja programado ou declarada de forma explícita. Em seu experimento, toda jogada realizada por uma pessoa era analisada e a máquina aprendia com os erros e acertos. Assim, a cada partida disputada pelo computador dava a oportunidade desse se aperfeiçoar, e em próximas jogadas ou partidas, permitia fazer previsões das táticas do jogo. Ou seja, qualquer evento adicional e não previsto na execução de uma determinada jogada fazia com que o sistema interpretasse como um provável erro, armazenasse a informação e em seguida aprendesse evitar uma possível repetição.

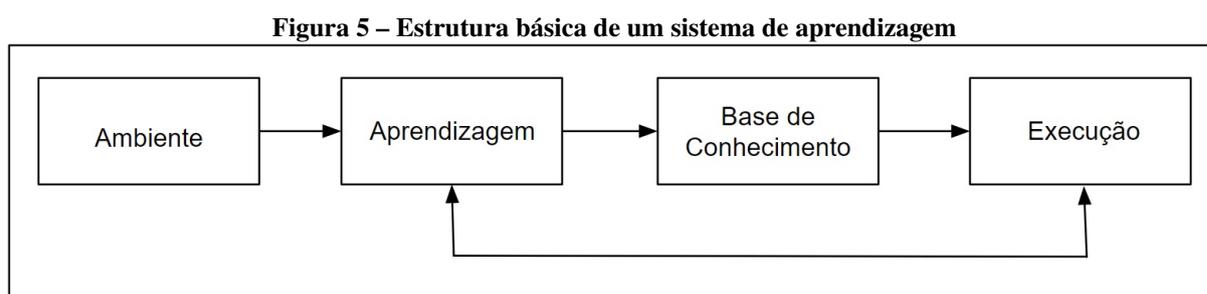
Uma das características da aprendizagem de máquina é generalizar cada evento experimentado, transformar em uma forma de treinamento e em execuções posteriores, gerar uma hipótese ou prever alcançando uma estimativa mais aproximada de um novo processo em questão. Permite também que o desempenho seja ampliado em instâncias de dados não visíveis, predizendo uma maior precisão de dados futuros. Porém, a aprendizagem de máquina não possui uma funcionalidade bem definida ou estruturada para ser otimizada. A medida que os eventos de erros surgem, eles servem como um filtro para ajustar os erros de aprendizado (AWAD; KHANNA, 2015).

Este processo de aprendizagem é um recurso principal na generalização de problemas, pois é acionado de acordo com as experiências históricas. As experiências históricas ou *logs* (registros de atividades) são utilizados para formar as coleções de dados que posteriormente são consultados para formar um modelo de domínio de aprendizagem de máquina.

2.4.1 Estrutura de um sistema de Aprendizagem de Máquina

A aprendizagem de máquina é a forma que um computador simula ou realiza a compreensão do comportamento do ser humano. O propósito é obter um novo conhecimento ou habilidade para organizar a estrutura do conhecimento a fim de criar uma melhoria contínua de sua própria performance (MING; CHANGJUN, 2009). Utiliza a teoria de estatística para a construção de modelos matemáticos porque a sua principal tarefa é realizar inferências sobre uma amostra, realizando este processo em duas etapas. Na primeira, é feito um treinamento com algoritmos eficientes para sanar problemas de otimização, armazenar e processar uma enorme quantidade de dados a fim de criar um modelo de aprendizagem. Na segunda etapa, utilizando o modelo aprendido por meio de uma solução algorítmica eficiente, são realizadas confirmações sobre premissas conhecidas e verdadeiras para formar as previsões exatas (ALPAYDIN, 2014).

A estrutura básica de um sistema de aprendizagem de máquina consiste em um ambiente de operação, aprendizagem do sistema, base de conhecimento e execução. A figura 5 exemplifica o fluxo de operação de um sistema de aprendizagem de máquina.



Fonte: Adaptado de Ming e Changjun (2009)

O ambiente fornece informações para a parte de aprendizagem do sistema. A aprendizagem é local em que os dados são analisados e revisados obtendo as informações da base do conhecimento, é a própria expansão e melhoria do conhecimento existente. A base de conhecimento contém um vetor de características, sentenças lógicas, regras de modelo de produção e rede semântica, por exemplo. Fornece as informações para que a parte de aprendizagem efetue suposições, realiza análise comparativas, examina e revisa-as.

Por fim, a execução é o núcleo de todo o sistema de aprendizagem, pois tem o intuito de melhorar a aprendizagem por meio de implementação de questões complexas, *feedbacks* e de transparência de dados (MING; CHANGJUN, 2009).

2.4.2 Algoritmos de Aprendizagem de Máquina

Os algoritmos de aprendizagem de máquina são classificados em seis categorias. Os autores Ayodele (2010), Awad e Khanna (2015) descrevem as categorias baseados em mapea-

mentos subjacentes entre os dados de entrada e os valores esperados durante a fase de aprendizagem.

- *Aprendizagem Supervisionada*: este tipo de algoritmo gera funções de mapeamento de entradas para as saídas desejadas. Porém, um padrão de formulação de tarefas gera problemas de classificação, em que é preciso aprender o comportamento mais aproximado da função que faz o mapeamento de um vetor em várias classes, verificando diversos valores de entrada e saída de dados desta função. O principal objetivo deste algoritmo é minimizar o erro de um determinado conjunto de entradas, os quais são utilizados para treinamento de aprendizagem. No entanto, se for usado um conjunto de dados de baixa qualidade ou definidos isto influenciará na precisão e dinâmica dos dados rotulados, sendo que isto pode acarretar problemas de reajustes, gerando classificações erradas ou muito genéricas (AWAD; KHANNA, 2015).
- *Aprendizagem Não Supervisionada*: modela um conjunto de valores de entradas e permite explorar a estrutura de dados sem uma orientação definida por meio de informações de classes e possibilita revelar características não esperadas ou conhecidas (MICHIE; SPIEGELHALTER; TAYLOR, 2009). Dois exemplos populares são os de agrupamentos e redução de dimensionalidade. O objetivo da aprendizagem não supervisionada é criar hipóteses representativas de dados de entrada para tomada de decisão eficiente, previsão e filtragem e agrupamento de informações (AWAD; KHANNA, 2015).
- *Aprendizagem Semi-Supervisionada*: utiliza uma combinação de um pequeno número de dados rotulados e um grande número de conjuntos de dados não rotulados para gerar uma função ou classificador padrão. Algoritmos deste tipo aplicam diretrizes da aprendizagem não supervisionada (dados de treinamento não rotulados) e aprendizado supervisionado (dados de treinamento rotulados) para promover melhorias consideráveis na precisão do aprendizado. Esta metodologia de aprendizagem pode agregar valor prático e teórico relacionadas a aprendizagem humana como fala, visão e escrita manual, pois relacionam uma quantidade pequena de instruções diretas e uma grande quantidade de experiências não rotuladas (AWAD; KHANNA, 2015).
- *Aprendizagem por reforço*: utiliza um agente inteligente que aprende uma sequência adaptativa de ações ou comportamentos sobre um determinado ambiente com o intuito de maximizar o armazenamento de recompensas. A ação do agente inteligente executa mudanças observáveis no estado do ambiente. Esta técnica de aprendizagem sintetiza um modelo de adaptação treinando ele próprio para um conjunto de ações e respostas observadas no estado do ambiente. Com isso, toda ação tem algum impacto e o ambiente fornece *feedbacks* para controlar o algoritmo de aprendizado dentro do contexto (AWAD; KHANNA, 2015). Utiliza um paradigma de aprendizado da teoria de controle, por meio de tentativas e erros, para obter as recompensas e punições conforme as ações são realizadas. Baseada na

experiência coletada e nas recompensas obtidas, o agente inteligente altera a sua regra de acordo com as ações previamente realizadas e que tiveram sucesso (AYODELE, 2010).

- *Transdução ou aprendizagem transdutiva*: é semelhante ao aprendizado supervisionado, mas não constrói explicitamente uma função. Realiza a tentativa de prever novas saídas baseado-se em dados de entradas e saídas de treinamento e novas entradas (AYODELE, 2010). Na tentativa de prever funções de modelo exclusivos em casos de teste específicos, utiliza observações adicionais no treinamento de conjunto de dados em relação aos novos casos de testes. As funções de modelo formadas estabelecem novas observações individuais utilizando dados de treinamento em um único ponto no espaço. Contrapõe com o modelo global, no qual novos dados devem se encaixar no modelo existente sem requerer alguma informação específica relacionada a localização desse ponto de dados no espaço. E isto pode ser um fator de erros porque ao criar um modelo global que represente todo o problema, o espaço é um desafio e pode não ser necessário em todos os casos. Nessa situação, vários modelos poderão ser sintetizados nos limites descontínuos. Assim, os dados recém observados são processados por meio do modelo que melhor atende às condições de contorno para torná-lo válido (AWAD; KHANNA, 2015).
- *Inferência indutiva*: o algoritmo aprende sua própria função indutiva baseada em experiências anteriores. Utiliza a função do modelo com base na relação de dados para todo o espaço de hipóteses e procura prever valores de saída para constituir exemplos além do conjunto de treinamento. As funções podem ser definidas usando um dos muitos esquemas de representação, incluindo polinômios ponderados lineares, regras lógicas e descrições probabilísticas (AWAD; KHANNA, 2015).

2.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo apresentou conceitos sobre jogos sérios que são utilizados para otimizar a aprendizagem por meio de experiências lúdicas que podem ser transferidas para outras atividades do mundo real vivenciadas pelos alunos. No entanto, os jogos sérios utilizam conhecimentos específicos para um determinado público e são baseados em critérios de jogabilidade, propósito e uma área de atuação bem definida. O uso de jogos sérios para aprendizagem de pessoas com deficiência intelectual é um grande desafio, conforme destaca Freitas (2012), pois a assimilação de conhecimento é mais lenta por causa de sua condição motora e cognitiva, mas não é um impeditivo para aprender e superar dificuldades.

Este é um tema de pesquisa em evolução, pois juntamente com o desenvolvimento de jogos sérios são utilizadas as técnicas de gamificação e elementos gamificados. A gamificação propicia o aprimoramento dos jogos com a adequação da mecânica e dinâmica dos jogos ampliando a interatividade para engajar e motivar os alunos. E os elementos de gamificação, conforme

apresenta o quadro 12 contém os elementos mais relevantes para jogos digitais de alunos com deficiência intelectual, são características importantes para beneficiar a aprendizagem de forma mais colaborativa.

Outra forma de aprendizagem aprimorada é a utilização dos *softwares* citados na seção 2.1.1 como o projeto Participar (PARTICIPAR, 2019), SofiaFala (SOFIAFALA, 2019) e o projeto ABC 3D (CAGATAY *et al.*, 2012) são recursos úteis que visam promover a aprendizagem de forma mais dinâmica por meio da inclusão digital de pessoas com deficiência intelectual. Estes *softwares* possuem um ambiente gamificado, promovem o aprimoramento das habilidades cognitivas e permitem avaliar resultados, porém apenas o projeto SofiaFala (SOFIAFALA, 2019) aplica algoritmo de aprendizagem de máquina e inteligência artificial para reconhecer e analisar áudios de praxias não verbais a fim de otimizar a avaliação de fonoaudiologia de crianças com crianças com síndrome de Down (DOWN, 2019). Contudo, os algoritmos de aprendizagem de máquina ainda são poucos utilizados em jogos sérios e *softwares* para deficiência intelectual.

Por fim, este capítulo apresentou conceitos aprendizagem de máquina, suas características, estrutura e tipos de algoritmos de aprendizagem de máquina que foram utilizados como base para o desenvolvimento deste trabalho. Os algoritmos de aprendizagem de máquina são recursos que podem otimizar a obtenção de informações de forma mais organizada e facilitada. No entanto, ainda são poucos utilizados em jogos sérios que utilizam e aplicam-os em bases de dados consolidadas para extrair informações após a execução dos jogos para posterior avaliação. Porém, a aplicação de algoritmos de máquina em jogos sérios, utilizando base de dados com atributos bem definidos, torna-se importante pois permite extrair informações mais precisas. As informações obtidas representam novas regras e índices para serem adicionados em novas versões dos jogos para ajustar níveis de dificuldades. Esta otimização tem o objetivo de manter a interação do jogador com o jogo diante do nivelamento da dificuldade apresentada.

Os algoritmos de aprendizagem de máquina aplicados em jogos para deficientes intelectuais não serão abordados nesta seção em virtude do mapeamento sistemático realizado no próximo capítulo 3 Estado da Arte.

3 ESTADO DA ARTE

Este capítulo apresenta um mapeamento sistemático sobre jogos na educação aplicando algoritmos de aprendizagem de máquina com o propósito de identificar o estado da arte deste tema, quais são os autores e abordagens utilizadas (GARCIA DA LUZ *et al.*, 2021). Adicionalmente, identificar lacunas e temas para futuras pesquisas. Entre os métodos existentes na literatura para realização de mapeamentos sistemáticos optou-se pelo método de Kitchenham e Charters (2007) que fornece meios para verificar os principais estudos e incorporá-los à prática experimental para aprimorar o desenvolvimento de *software*. Este método é baseado nas etapas de planejamento, condução da revisão, elaboração de relatório e disseminação. Neste trabalho, na etapa de planejamento foram identificados os objetivos da revisão sistemática, realizada a definição e avaliação do protocolo. Na etapa de condução da revisão, foi realizado a seleção de estudos com a identificação das bases de buscas, definição das *strings* de busca, elaboração das questões, critérios de seleção dos estudos e o processo de seleção dos trabalhos. Na etapa de análise dos dados, foi realizada a síntese dos trabalhos, apresentação dos resultados e as tendências futuras sobre o assunto.

Foram encontrados um total de 382 artigos utilizando um conjunto de palavras-chaves definidos para busca nas seguintes bases de dados: "ACM Digital Library", "Science Direct", "Google Scholar", "IEEE Xplore Digital Library" e "Scopus". O período de busca ficou no intervalo entre os anos de 2003 a 2021 em virtude da maior relevância para as pesquisas relacionadas a jogos na educação aplicando algoritmos de aprendizagem de máquina. Após o processo de seleção foram selecionados 5 artigos considerando mais relevantes para leitura detalhada e avaliação de informações.

3.1 METODOLOGIA DE PESQUISA

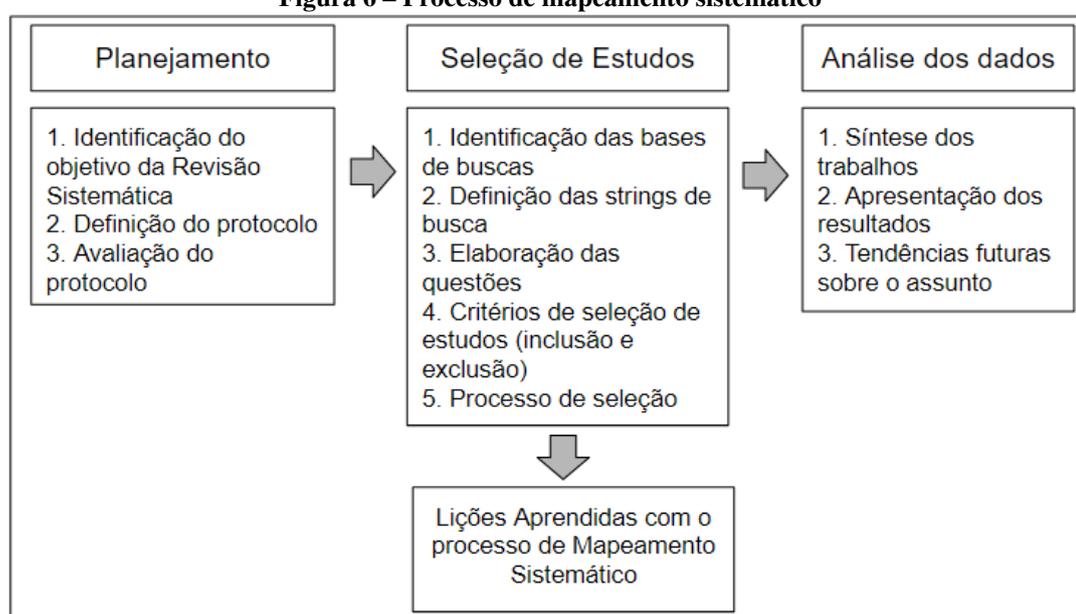
Com base na literatura encontrou-se trabalhos envolvendo a área de jogos na educação com aplicação de algoritmos de aprendizagem de máquina. O método utilizado neste trabalho para a realização do mapeamento sistemático foi o de Kitchenham e Charters (2007). Os autores Martins e Gorschek (2016) definem que o trabalho de Kitchenham e Charters (2007) é uma referência a aqueles que desejam realizar revisões e mapeamentos sistemáticos e relatam que esta abordagem cobre diversos passos para gerar uma pesquisa abrangente.

O mapeamento sistemático foi realizado pelo autor deste trabalho, juntamente com um professor da área de Engenharia de *Software*, um da área de Inteligência Artificial e um doutorando em Ciência, Tecnologia e Ensino. Foram levantados trabalhos relacionados ao foco desta pesquisa de 2003 a 2021 nos assuntos de jogos e algoritmos de aprendizagem de máquina voltados a educação. O trabalho proposto realizou a pesquisa contemplando jogos, pois poderiam

existir trabalhos contendo gamificação dentro do processo deste mapeamento sistemático.

A princípio, como previsto pelo método de mapeamento sistemático, foi definido o protocolo pelos autores visando trazer ao pesquisador uma quantidade de informações sobre: autores dos trabalhos, relevância de cada trabalho e sua real contribuição para a comunidade e problemas de pesquisa. Neste protocolo foram definidas as questões de pesquisa, bases de busca e suas formas específicas de pesquisa, *strings* de busca, palavras-chave e filtros, apresentadas nas próximas seções. O objetivo do protocolo foi registrar os estudos selecionados, avaliar quais jogos sérios utilizam algoritmos de máquina e são relevantes para o mapeamento sistemático. A Figura 6 apresenta como o processo de mapeamento sistemático foi conduzido.

Figura 6 – Processo de mapeamento sistemático



Fonte: Autoria própria.

No processo de planejamento foi identificado o objetivo do mapeamento sistemático para verificar os jogos sérios que aplicam algoritmos de máquina. A definição do protocolo utilizou uma planilha eletrônica para preenchimento de informações dos trabalhos a serem analisados. Na seleção de estudos, foram definidas as bases de buscas, *strings* de buscas e elaboradas as questões para serem respondidas no mapeamento sistemático. Em seguida, foram definidos os critérios de inclusão e exclusão para selecionar os trabalhos desejados e formar o protocolo com informações dos artigos a fim de que as perguntas pudessem ser respondidas. Com o protocolo formado foi possível sintetizar os dados, apresentar os resultados e verificar as tendências futuras sobre o assunto.

3.1.1 Questões de Pesquisa

O objetivo central da pesquisa foi realizar um levantamento das principais ferramentas e métodos utilizados nos assuntos pesquisados. Foram elaboradas as questões de pesquisa (QP):

QP1) Quais são os jogos, qual a área e o nível de educação (especial ou não)?

QP2) Como os jogos são divididos e como funciona sua arquitetura?

QP3) Quais algoritmos de aprendizagem de máquina são usados?

3.1.2 Critérios de Inclusão e Exclusão

Os pesquisadores que realizaram o mapeamento sistemático foram os avaliadores dos trabalhos primários coletados. Inicialmente foi previsto como critério de inclusão os trabalhos que apresentassem em seu Título, Palavras-Chave ou *Abstract* informações relacionadas ao tema da pesquisa e que estavam dentro do período determinado para o mapeamento sistemático. Posteriormente, foi executado um processo de filtragem que apresenta, dentro do contexto proposto, alguns critérios de exclusão conforme apresentados no Quadro 13.

Quadro 13 – Critérios de inclusão e exclusão

Critérios de Inclusão	Critérios de Exclusão
Jogos na educação com algoritmos de aprendizagem de máquina	Estudos duplicados e não relacionados a jogos na educação
Estudos acessíveis e estudos originais em inglês	Artigos não disponíveis de forma <i>online</i>

Fonte: Autoria própria.

A aplicação dos critérios de inclusão e exclusão seguiram as etapas:

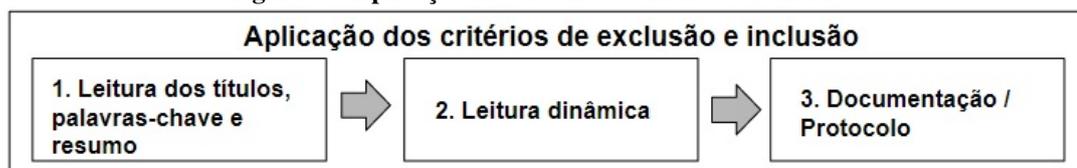
- Etapa 1: Leitura dos títulos, palavras-chave e resumo, sendo excluídos os trabalhos não relacionados aos critérios de inclusão.
- Etapa 2: Leitura dinâmica (superficial) do estudo considerando os critérios de inclusão e exclusão.
- Etapa 3: Documentação de cada estudo em pequenos parágrafos e preenchimento de um planilha para composição do protocolo de mapeamento sistemático.

Para fins de documentação foi elaborado um protocolo de pesquisa para documentar os trabalhos que estavam de acordo com os critérios de inclusão a fim de facilitar a sequência e confirmação de leitura pelos autores deste artigo. A Figura 7 apresenta as etapas realizadas no mapeamento sistemático proposto aplicando os critérios de exclusão e inclusão.

3.1.3 Repositórios de Busca

Para a busca dos documentos foram definidas cinco base de busca para realizar as pesquisas, sendo elas: Google Acadêmico, *Science Direct*, ACM, IEEE Xplore e *Scopus*. A escolha

Figura 7 – Aplicação dos critérios de inclusão e exclusão.



Fonte: Autoria própria.

das bases citadas foi porque possuíam um maior número de publicações relacionadas com a pesquisa deste trabalho.

3.1.4 *Strings* de Busca e Palavras-chave

Vários termos de busca já haviam sido pensados e discutidos entre os pesquisadores, o que facilitou o processo de composição das palavras-chave. Após alguns testes foram utilizadas as expressões restritas ao tema tais como “artificial intelligence algorithm” AND “gaming” AND education”, “machine learning” AND “digital games”, “childhood” AND “education” AND “machine learning” AND “games”, “machine learning algorithm” AND “education games” AND “artificial intelligence”, “machine learning algorithm” AND “education” AND “digital games”, “machine learning algorithm” AND “education” AND “games”.

Utilizando as *strings* citadas a quantidade de resultados era baixa ou em alguns casos não retornava nenhum resultado. Com isso, foi realizado um refinamento da string de busca onde a combinação que retornou mais resultados foi “machine learning algorithm” AND “education” AND “games” para obter as publicações de artigos de mapeamento sistemático. A Tabela 1 apresenta a quantidade de trabalhos obtidos por repositório.

Tabela 1 – Quantidade de trabalhos por repositório obtidos

<i>String</i> de busca	Google Acadêmico	Science Direct	ACM	IEEE	Scopus
“machine learning algorithm” AND “education” AND “games”	78	169	13	22	100
TOTAL	382				

Fonte: Autoria própria.

O repositório com o menor retorno foi a ACM e a IEEE Xplore comparadas com as demais. Porém, a *Science Direct* e *Scopus* foram as que mais retornaram trabalhos utilizando a *string* de busca utilizada.

3.1.5 Leitura e seleção dos trabalhos

Os trabalhos obtidos na primeira fase foram agrupados por suas *strings* de busca com a quantidade de estudos encontrados. A Tabela 2 mostra o resultado deste agrupamento e a quantidade de trabalhos que foram selecionados considerando os filtros adotados a partir dos critérios de exclusão e inclusão.

Tabela 2 – Quantidade de trabalhos selecionados por repositório

<i>String</i> de busca	Google Acadêmico	Science Direct	ACM	IEEE	Scopus
“machine learning algorithm” AND “education” AND “games”	1	2	0	2	0
TOTAL	5				

Fonte: Autoria própria.

Após a realização dos critérios de exclusão propostos, os trabalhos apresentados na Tabela 2 foram lidos por estarem mais focados ao objetivo desta pesquisa. Foram eliminados 13 trabalhos duplicados, 3 da base da Scopus, 1 na base do Google Scholar, 4 na base da *Science Direct*, 2 na base da ACM e 3 na base da IEEE Xplore. Como resultado final foram selecionados 5 trabalhos para a extração de dados, os quais foram analisados.

3.2 RESULTADOS

Esta seção apresenta os resultados relacionados as respostas para as seções anteriores e as fragilidades em relação ao mapeamento sistemático proposto. A seguir estão listadas as questões elaboradas para o mapeamento sistemático com sua respectiva resposta. As questões serviram de base para compreensão e pesquisa de aplicação de algoritmos de aprendizagem de máquina no desenvolvimento de jogos sérios.

3.2.1 Quais são os jogos, qual a área e o nível de educação (especial ou não)?

Os jogos utilizados na aplicação de algoritmo de aprendizagem de máquina são bastante diversificados. Alguns deles foram desenvolvidos de forma específica para atender o estudo, os quais podemos citar *MCP Quest* e *Skill Tree* (BARATA *et al.*, 2016) na área de ciências da computação, e *Romeo and Juliet* (SIU *et al.*, 2018) na área de idiomas. E os outros trabalhos utilizaram jogos disponíveis no mercado como o *Super Monkey Ball 2* (COWLEY *et al.*, 2014) na área de psicofisiologia, jogos disponíveis na *Google Play* em diversas áreas como esportes, ação, estratégia e *Role-Playing Game* (RPG) no estudo de Bharathi *et al.* (2016) e o jogo do *Pacman*

utilizado no trabalho Llorens-Largo *et al.* (2016). Os dois últimos jogos citados foram utilizados na área de ciências da computação. A área de ciências da computação concentra a maior parte de aplicação de algoritmos de aprendizagem de máquina em jogos sérios. O Quadro 14 apresenta as áreas de aplicação de jogos com algoritmos de aprendizagem de máquina.

Quadro 14 – Jogos usados nas áreas e níveis educacionais pelos autores

Jogo	Área	Nível Educacional	Autor
<i>Super Monkey Ball 2</i>	Psicofisiologia	Ensino Superior	Cowley <i>et al.</i> (2014)
<i>MCP Quest</i> e <i>Skill Tree</i>	Ciências da Computação	Ensino Superior	Barata <i>et al.</i> (2016)
Diversos jogos da <i>Google Play</i>	Ciências da Computação	Vários Níveis	Bharathi <i>et al.</i> (2016)
<i>Pacman</i>	Ciências da computação	Ensino Superior	Llorens-Largo <i>et al.</i> (2016)
<i>Romeo e Julieta</i>	Idiomas	Vários níveis	Siu <i>et al.</i> (2018)

Fonte: Autoria própria.

O trabalho de Cowley *et al.* (2014) realizado na área de psicofisiologia descreve um novo método para integrar preferências de jogadores, dados experimentais e padrões de desenhos de jogos em um único *framework*, o *Play Patterns And eXperience* (PPAX). O *framework* explorou os padrões de jogabilidade e reações fisiológicas das faces dos jogadores obtendo como resultado informações sobre o padrão de reação, jogadas e a personalidade de cada jogador.

No trabalho de Barata *et al.* (2016), o experimento caracterizou dados para prever o tipo de aluno já no início do curso de mestrado em ciências da computação da universidade de Lisboa. Para isso, utilizou algoritmos de aprendizado de máquina para classificar dados de alunos de um período e prever o tipo de aluno em outro período. Por meio da inclusão de jogos na grade de ensino, criaram os jogos *MCP Quest* e *Skill Tree* amplia a interatividade e cria um *ranking* para premiar a passagem de níveis e as experiências adquiridas pelos alunos.

No trabalho de Bharathi *et al.* (2016) na área de ciências da computação, diversos jogos e aplicativos instalados nos *smartphones* foram analisados para identificação e levantamento de características de *design* e elementos de gamificação como desafios, *feedbacks*, recompensas, objetivos, personagens, insígnias, pontuação, níveis, *ranking* e dinâmica de estados dos jogos. Estes elementos de gamificação podem promover a motivação do aluno interagir com o jogo com mais frequência e obter novos conhecimentos.

Llorens-Largo *et al.* (2016), na área de ciências da computação, desenvolveram o sistema *LudifyMe* para avaliar o potencial da gamificação como meio de aprimorar a aprendizagem. A principal contribuição é na aplicação de jogos no ensino de inteligência artificial a fim de melhorar a motivação, o desempenho e a satisfação do aluno.

Siu *et al.* (2018), na área de idiomas para a aprendizagem da língua inglesa, criaram uma plataforma de jogos baseada na história de Romeu e Julieta, a qual analisa as pontuações obtidas pelo aluno para verificar a evolução e o domínio da linguagem. A plataforma tem a

finalidade de prever se o aluno possui capacidade para atingir uma pontuação média nas provas.

O mapeamento sistemático verificou e identificou que os níveis educacionais de aplicação são para o ensino superior, ensino básico e vários níveis (ensino básico ao superior), entretanto, nenhum dos jogos identificados foi utilizado para a educação especial. Porém, existe uma predominância de trabalhos no ensino superior, e analisando a quantidade de trabalhos em cada nível, existem 3 trabalhos relacionados ao ensino superior e 2 trabalhos que se enquadram em vários níveis (ensino básico ao superior).

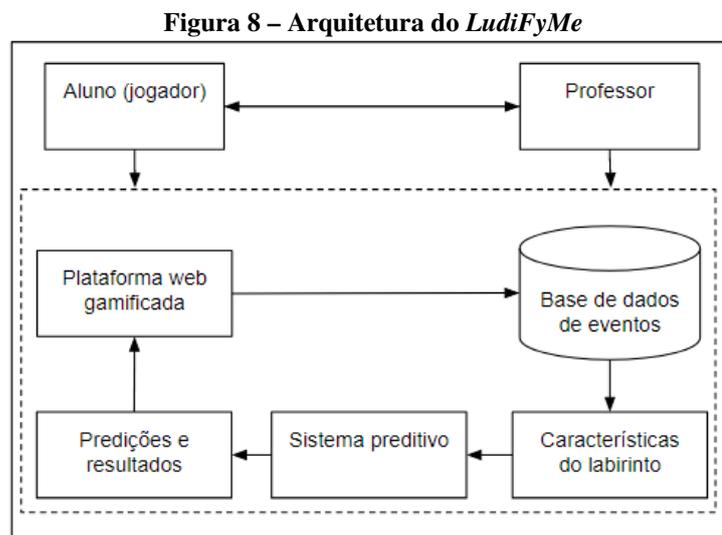
3.2.2 Como os jogos são divididos e como funciona sua arquitetura?

Os jogos são divididos de acordo com o tipo, por exemplo, jogos sérios, corrida, quebra-cabeça, estratégia, plataforma *web* gamificada e RPG (*Role Playing Game*). No trabalho de Barata *et al.* (2016) foram desenvolvidos dois jogos sérios contendo etapas e missões, o *MCP Quest* e o *Skill Tree*. A medida que as missões são realizadas é apresentada uma outra mais complexa e os jogadores recebem pontuações ao finalizar, porém as missões podem ser executadas de várias formas desde que todos os objetivos sejam cumpridos. O jogo *MCP Quest*, por exemplo, é uma caça ao tesouro *online* em que os alunos acessam uma página contendo um artefato multimídia que deve ser editado e manipulado para desvendar a pista a fim de acessar a *url* próxima página. A medida que as missões são superadas o jogador ganha pontos de experiências e fica habilitado para acessar uma missão mais difícil.

Nessa mesma ideia, o jogo *Skill Tree* apresenta uma árvore de missões a serem realizadas. Na raiz da árvore são apresentadas e habilitadas três missões iniciais e em seus ramos outras missões desabilitadas. Após finalizar as primeiras missões o jogador recebe os pontos de experiências e são habilitadas novas missões da árvore para execução. Se o jogador não possuir pontos de experiências suficientes as novas missões de um nível mais complexo não são habilitadas. A arquitetura deste jogo é cliente servidor em que os alunos acessam o jogo por meio das páginas disponibilizadas e executam as atividades na plataforma. Com isso, os dados de todas as atividades realizadas são registradas em banco de dados para posterior aplicação do algoritmo de aprendizagem de máquina para compreender o comportamento dos alunos.

O trabalho *LudifyMe* de Llorens-Largo *et al.* (2016) utilizou a linguagem *Prolog* para ensino de inteligência artificial sobre o jogo *Pacman*. O jogo é dividido em níveis de dificuldades de acordo com os labirintos, quantidade e velocidade de movimentos dos inimigos do personagem principal. A medida que uma fase é superada, a próxima tem o nível de dificuldade aumentada e assim sucessivamente. Neste trabalho, as atividades de criação de labirintos do jogo foi realizada em uma plataforma *web* gamificada, na qual os alunos devem programar as regras e relações do jogo e enviar para avaliação em um sistema de predição. A arquitetura é composta pela plataforma gamificada, base de dados de eventos na qual são extraídas as características dos labirintos criados, e avaliação do sistema preditivo que apresenta os resultados. A Figura 8

apresenta a arquitetura da plataforma gamificada com o sistema preditivo.



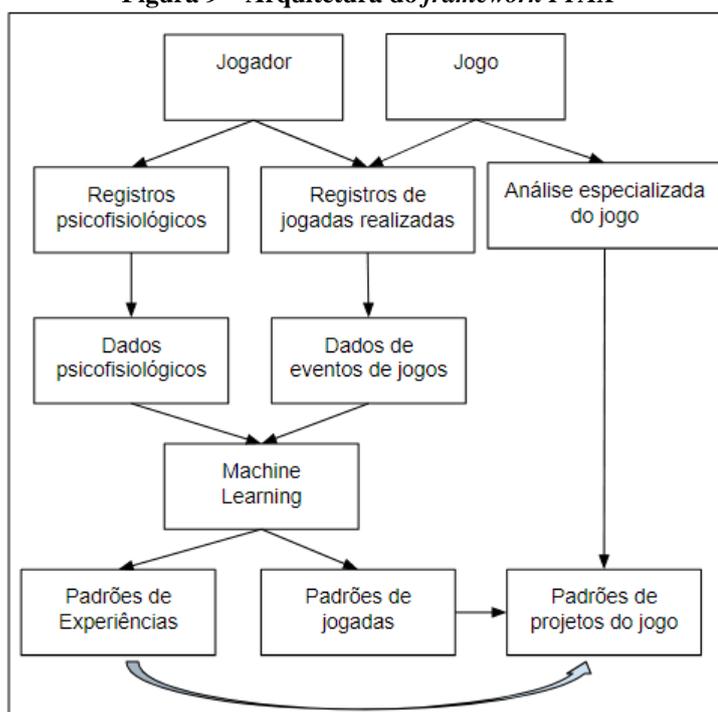
Fonte: Adaptado de Llorens-Largo et al. (2016)

Após o aluno submeter o código para avaliação na plataforma, as informações são enviadas para um banco de dados de eventos para posterior processamento das características dos labirintos desenvolvidas pelos alunos. O sistema de predição aplica os algoritmos de aprendizagem de máquina sobre a base de dados e apresenta os resultados dos labirintos. Com isso, alunos e professores podem avaliar os resultados e otimizar o labirinto de acordo com as informações disponibilizadas em gráficos.

Cowley et al. (2014) desenvolveram um *framework*, chamado de *Play Patterns And eXperience (PPAX)*, para analisar um conjunto de dados contendo informações psicofisiológicas de jogador, referente as expressões faciais de jogadores como tensão, alerta, alegria, chateado, estressado, calmo, relaxado, etc., e dados de vídeo contendo jogadas realizadas. O jogo utilizado para aplicação do *framework* foi o *Super Monkey Ball 2*, que sua principal mecânica é rolar uma bola, contendo um macaco dentro, por plataformas de diferentes alturas sem deixar a bola cair e chegar até o final do percurso. Durante o percurso o jogador é recompensado com pontos ao coletar bananas durante o percurso. Este *framework* analisa os dados de eventos de jogos e dados psicofisiológicos aplicando o algoritmo de máquina *Frequent Pattern Growth* (BORGELT, 2005), que procura a frequência de padrões em grandes conjuntos de dados, para identificar padrões de projetos de jogos. A Figura 9 apresenta a arquitetura do *framework*.

Nos trabalhos de Cowley et al. (2014), Barata et al. (2016), Bharathi et al. (2016), Llorens-Largo et al. (2016) e Siu et al. (2018), os algoritmos de aprendizagem de máquina são aplicados sobre uma base de dados, a qual é formada pelos dados coletados durante as interações realizadas pelo usuário nos jogos. As informações do banco de dados são tratadas para facilitar a obtenção de conhecimentos por meio da aprendizagem de algoritmo de máquina com treinamentos sucessivos. E posteriormente, as informações obtidas são analisadas e revisadas para aprimorar o desempenho do algoritmo de aprendizagem de máquina. Por fim, com as infor-

Figura 9 – Arquitetura do framework PPAX



Fonte: Adaptado de Cowley *et al.* (2014)

mações obtidas são feitas avaliações para compreender a aprendizagem do aluno e as execuções de suas atividades.

3.2.3 Quais algoritmos de aprendizagem de máquina são usados?

Considerando os trabalhos selecionados, identificou-se que os algoritmos de aprendizagem de máquina mais utilizados são os que utilizam métodos de aprendizagem supervisionada, como o *Support Vector Machine* (SVM) e o classificador *Naive Bayes*. No entanto, foi verificado que não existe uma preferência por um determinado algoritmo de aprendizagem de máquina, pois são escolhidos de acordo com a preferência dos autores e o contexto de cada aplicação.

Cowley *et al.* (2014) aplicou os algoritmos não supervisionados *Frequent Pattern Growth* e *K-Means*. No trabalho de Barata *et al.* (2016) utilizou o *Expectation Maximization Algorithm* (EM), *Naive Bayes*, *Redes Bayesianas*, *Sequential Minimal Optimization* (SMO), *Logistic Regression* e *K-Nearest Neighbors* (KNN).

Bharathi *et al.* (2016) aplicou o *Support Vector Machine* (SVM), *Naive Bayes*, *IBK*, *Decision Trees*, *Random Forest*, *Sequential Minimal Optimization* (SMO) e *J48* para classificar jogos a uma pontuação máxima e indicar se são bem sucedidos ou não.

Llorens-Largo *et al.* (2016) aplicou o *Support Vector Machine* (SVM) para programar regras e ações sobre o jogo do *Pacman* para ensinar de forma interativa lições de inteligência artificial para alunos de ciências da computação. Por fim, Siu *et al.* (2018) aplicou os algoritmos

Decision Trees, Support Vector Machine (SVM) e K-Nearest Neighbor (KNN).

A Tabela 3 apresenta os algoritmos de aprendizagem de máquina utilizado em seus respectivos anos.

Tabela 3 – Quantidade de algoritmos de aprendizagem de máquina por ano

Algoritmos	Classificação	Ano		
		2014	2016	2018
Frequent Pattern Growth	não supervisionado	1		
K-Means	não supervisionado	1		
Expectation Maximization (EM)	não supervisionado		1	
Naive Bayes	supervisionado		2	
Redes Bayesianas	supervisionado			1
Logistic Regression	supervisionado			1
K-Nearest Neighbors (KNN)	supervisionado		1	1
Support Vector Machine (SVM)	supervisionado		2	1
Instance Based K (IBK)	supervisionado		1	
Decision Trees	supervisionado		1	1
Random Forest	supervisionado		1	
Sequential Minimal Optimization (SMO)	supervisionado		1	
J48	supervisionado		1	
TOTAL		2	11	5

Fonte: Autoria própria.

O mapeamento sistemático indicou que os trabalhos pesquisados entre os anos de 2003 e 2021, possuem uma variação considerável na utilização de algoritmos de aprendizagem de máquina, porém foram identificados a repetição de algoritmos de aprendizagem de máquina conforme apresenta a Tabela 3.

O algoritmo que é mais utilizado é o *Support Vector Machine (SVM)* e *Naive Bayes* seguido dos algoritmos na aplicação de gamificação na educação. No ano de 2014 foram utilizados apenas dois algoritmos o *Frequent Pattern Growth* e o *K-Means*. Em 2016 foram aplicados uma maior quantidade de trabalhos, totalizando 13 algoritmos. No ano de 2018 foram utilizados apenas 3 algoritmos o *K-Nearest Neighbors (KNN)*, *Support Vector Machine (SVM)* e *Decision Trees*. Um ponto observado foi a utilização de algoritmos de aprendizagem supervisionada na maior parte dos trabalhos estudados, em que os conjuntos de dados já são rotulados para treinamento contendo uma resposta prevista ou desejada. Os algoritmos utilizados nos trabalhos verificados estão descritos a seguir:

- O *K-Means* é um algoritmo não supervisionado utilizado para agrupamento (*clustering*) de dados com o objetivo de indicar que cada *cluster* tem uma maior proximidade entre os dados (JAIN, 2010).
- O *Frequent Pattern Growth* é um algoritmo não supervisionado para gerar conjuntos de padrões de agrupamento de dados e verificar suas frequências de ocorrência em uma base de dados (HAN *et al.*, 2004).

- O algoritmo *Expectation Maximization Algorithm* não supervisionado é uma variação do algoritmo *k-means* que permite a aprendizagem de parâmetros sobre a maximização de dados faltantes, indicando quais características observadas estão em falta de uma amostra de dados (DEMPSTER; MCKENZIE; BRUC, 1977).
- O algoritmo *Naive Bayes* é supervisionado e utiliza teoria das probabilidades para definir que os atributos irão influenciar uma classe de dados de forma independente. Ao criar o modelo de uma classe, o algoritmo gera uma tabela para apresentar o quanto cada categoria dos atributos influencia em cada classe. Este algoritmo desconsidera a relação direta entre as características de dados tratando-os de cada um de forma independente (MITCHELL, 1997).
- O algoritmo *Redes Bayesianas* supervisionado utiliza a teoria de probabilidade sobre um conjunto de variáveis considerando um grau de certeza da ocorrência de um dado ou evento. São constituídas de nós e arcos, em que os nós são atributos e recebem uma quantidade determinada de valores e podem estabelecer ligações por meio dos arcos pra definir um nó de rede. As ligações entre os nós determinam a probabilidade calcular a quantidade de ocorrências de dados (MITCHELL, 1997).
- O algoritmo supervisionado *Sequential Minimal Optimization* (SMO) é derivado do método de decomposição das extremidades de um vetor para otimizar um subconjunto mínimo de dois pontos em cada iteração. A redução para com dois pontos de dados efetua uma solução analítica, eliminando a necessidade de usar um otimizador de programação quadrática iterativo como parte do algoritmo, que ocorria durante o treinamento do algoritmo *Support Vector Machine* (SVM) (CANDEL *et al.*, 2010).
- O *Logistic Regression* é um algoritmo de classificação supervisionado que realiza análise preditiva de dados baseados em conceitos de probabilidade. Permite analisar o efeito de uma ou mais variáveis independentes sobre uma variável binária, a qual indica a presença ou ausência de uma característica (HOSMER; LEMESHOW, 2000).
- O algoritmo classificador *K-Nearest Neighbors* (KNN) supervisionado separa as amostras de dados em diferentes classes para serem classificados por meio de medição de distância de dados. As classes dos dados que apresentaram as *K* menores distâncias são somadas para indicar a quantidade de repetição de uma determinada classe. Dessa forma, o dado é classificado na classe com maior repetição (LAAKSONEN; OJA, 1996).
- O algoritmo *Support Vector Machine* (SVM) utiliza métodos de aprendizado supervisionado para analisar e reconhecer padrões de dados. Basicamente, geram classificadores lineares separando o conjunto de dados analisados em um hiperplano. Um hiperplano é um espaço vetorial contendo uma reta que divide um conjunto de dados em dois subconjuntos. O algoritmo gera várias retas para divisão do conjunto de dados e define qual será

a sua reta separadora principal para criar um vetor otimizado e classificar novas instâncias (CORTES; VAPNIK, 1995).

- O algoritmo *Instance Based K* (IBK) de aprendizagem supervisionada é baseado em instâncias e é derivado do algoritmo de classificação *K-Nearest Neighbors* (KNN). O objetivo deste algoritmo é maximizar a veracidade de novas instâncias de um determinado problema. O propósito é obter valor numéricos similares para classificar os dados em um padrão reconhecido, o qual é influenciado por meio do resultado de classificação de seus k-vizinhos mais próximos (AHA; KIBLER; ALBERT, 1991).
- O algoritmo *Decision Trees* de aprendizagem supervisionada é utilizada para resolver problemas de regressão e classificação tendo como objetivo criar um modelo de treinamento de dados. Utilizando o modelo criado é feita a aplicação do classificador para determinar os rótulos das classes desconhecidas para formar exemplos de conjunto de teste (NAVADA *et al.*, 2011).
- O algoritmo *Random Forest* de aprendizagem supervisionada permite criar várias árvores de decisão combinando-as entre si os valores de vetores aleatórios para efetuar uma classificação de novos objetos, gerando uma floresta de valores. Os valores são distribuídos de forma independente e distribuídos igualmente para todas as árvores na floresta criando um conjunto de árvores. Este algoritmo aplica um mecanismo de votação para cada nó das árvores para definir a classificação mais votada (BREIMAN, 2001).
- O *J48* é uma implementação do algoritmo *C4.5* em java de aprendizagem supervisionada. Este algoritmo permite criar modelos de decisão e gerar uma estrutura em árvore para que nova instância percorra até chegar ao nó folha onde está situada a classe. Da mesma forma a árvore tem o início com o nó raiz e é dividida até a instância chegar a classe (CHANDRASEKAR *et al.*, 2017).

3.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo descreveu sobre o mapeamento sistemático com o objetivo de identificar como os jogos sérios utilizam o algoritmos de aprendizagem de máquina e em quais níveis educacionais estão enquadrados. O mapeamento sistemático serviu como base para a compreensão do contexto em que são aplicados os algoritmos de aprendizagem de máquina e também quais são mais aplicados no desenvolvimento de jogos. A aplicação dos algoritmos de aprendizagem é realizada para extrair informações após a consolidação de um banco de dados, ou seja, depois de terminada a partida os dados são analisados pelo algoritmo.

Um ponto identificado foi o uso de algoritmos de aprendizagem supervisionada na maior parte dos trabalhos estudados tendo uma concentração considerável no ano de 2016. Outra

constatação foi a utilização da gamificação e elementos de gamificação. Os trabalhos de Barata *et al.* (2016) e Siu *et al.* (2018) com jogos sérios de autoria própria utilizaram elementos dinâmicos como narrativa, progressão e restrições, elementos mecânicos como *feedback* e desafios, componentes de gamificação como missões, pontos, classificação (*ranking*) e conquistas. Os demais trabalhos utilizaram jogos existentes no mercado que aplicam elementos como progressão, restrições, desafios, pontos e recompensas (COWLEY *et al.*, 2014; BHARATHI *et al.*, 2016; LLORENS-LARGO *et al.*, 2016).

Os trabalhos avaliados utilizam a gamificação como meio de engajar os alunos a superar desafios propostos, como missões e níveis mais complexos, para prolongar a interação com os jogos. E a partir disso, com os eventos das jogadas e partidas registradas torna-se possível formar um banco dados para posterior aplicação de algoritmos de aprendizagem de máquina. Com um banco de dados com atributos bem definidos, a principal contribuição da aplicação de algoritmos de aprendizagem de máquina é favorecer a obtenção de padrões de reação e jogadas, perfil de jogadores e de alunos, comportamento e o próprio desempenho e a satisfação do aluno.

Contudo, com o mapeamento sistemático não foi identificado que as abordagens efetuam a aplicação de algoritmo de aprendizagem de máquina para analisar as jogadas e partidas, ajustar os níveis de dificuldades em tempo a execução dos jogos. Os trabalhos relacionados indicaram que em um primeiro momento as jogadas e partidas são registradas em banco de dados e posteriormente é feita a aplicação do algoritmo de aprendizagem de máquina sobre dados consolidados. E os trabalhos analisados mesmo enquadrados no âmbito educacional, não realizaram uma seleção de atributos e como estes podem contribuir na aplicação os algoritmos de aprendizagem de máquina em jogos sérios para ajuste de nível de dificuldade. Ao realizar este procedimento, podem ser obtidas regras e índices para gerar uma nova versão do jogo considerando uma automatização de nível de dificuldade das partidas.

4 TGL-ML: MÉTODO PARA AJUSTE DE NÍVEL DE DIFICULDADE EM JOGOS EDUCACIONAIS FUNDAMENTADO EM APRENDIZAGEM DE MÁQUINA

A execução do mapeamento sistemático apresentado no capítulo anterior permitiu identificar a falta de jogos para o ensino de educação especial e que realizem uma seleção de atributos e como estes podem contribuir na aplicação nos algoritmos de aprendizagem de máquina em jogos sérios para ajuste de nível de dificuldade.

Este capítulo apresenta o método *Tuning Game Level by Machine Learning* (TGL-ML) desenvolvido para ajuste de nível de dificuldade em jogos sérios fundamentado em algoritmo de aprendizagem de máquina. É apresentada a visão geral do método detalhando em duas partes, antes e depois de aplicar algoritmos de aprendizagem de máquina.

A primeira parte abrange a elaboração do jogo sério contendo a definição do público alvo e suas características, tema do jogo, o uso da gamificação e elementos da gamificação, a criação do jogo, a definição de atributos e as funcionalidades do jogo, finalizando com a geração da versão 1.0 do jogo. Em seguida, é descrita a aplicação do jogo para o público, coleta de dados e ajustes de funcionalidades com base nos *feedbacks* recebidos.

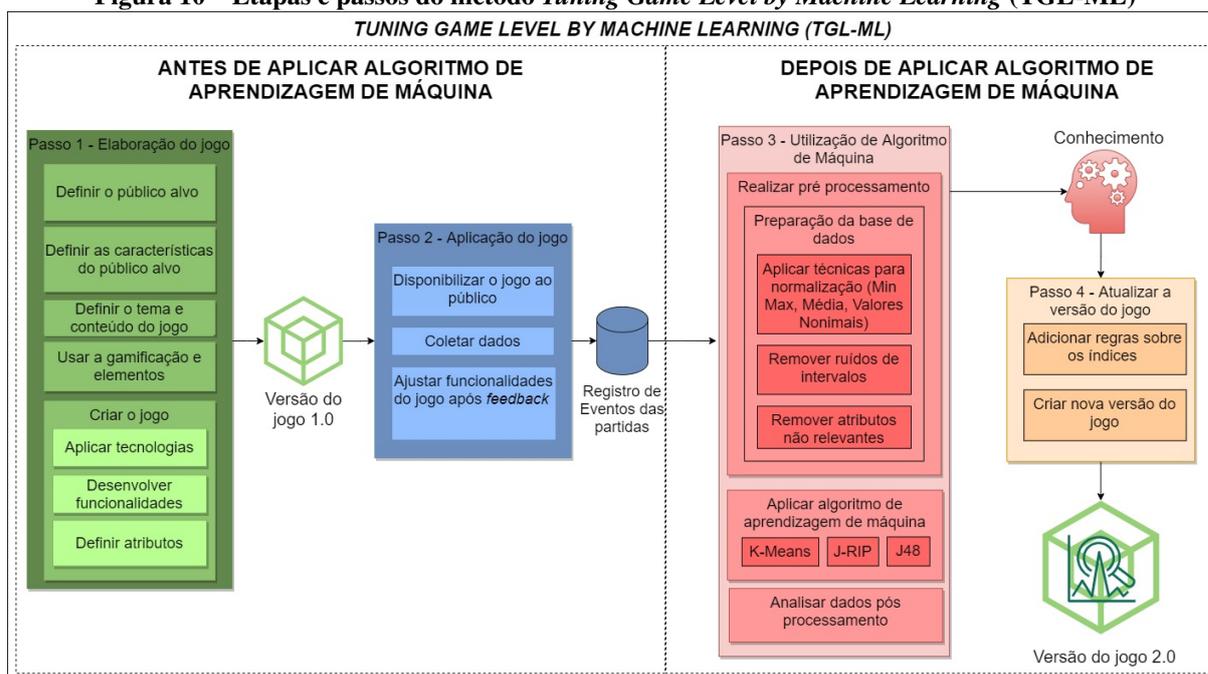
A segunda parte contempla a utilização de algoritmo de aprendizagem de máquina com a base de dados preparada e posterior aplicação dos algoritmos de aprendizagem de máquina para análise de dados e termina com a geração de conhecimentos. E na sequência, é apresentada a atualização da versão do jogo adicionando regras e índices obtidos para ajuste de níveis de dificuldades o que gerou a versão do jogo 2.0. Por fim, são apresentadas as considerações finais do capítulo sobre o método desenvolvido.

4.1 VISÃO GERAL DO MÉTODO

O método *Tuning Game Level by Machine Learning* (TGL-ML) é composto de duas partes, antes e depois de aplicar algoritmo de aprendizagem de máquina. A primeira etapa abrange o Passo 1 - Elaboração do jogo e o Passo 2 - Aplicação do jogo. A segunda parte possui o Passo 3 - Utilização do Algoritmo de Máquina e o Passo 4 - Atualizar a versão do jogo.

O Passo 1 define o público alvo e suas características, o tema e conteúdos do jogo, uso da gamificação e elementos de gamificação relacionados ao público, a criação do jogo com as tecnologias adotadas e as funcionalidades obtidas e a definição dos atributos para posterior aplicação no algoritmo de aprendizagem de máquina. No Passo 2 é realizada a aplicação do jogo desenvolvido para coleta de dados, seguindo com o armazenamento de eventos das partidas obtidas no jogo em um banco de dados. E após a utilização do jogo pelo público alvo se obtém *feedbacks* para otimizar as funcionalidades e efetuar adequações. A figura 10 ilustra as etapas e os passos do método proposto.

Figura 10 – Etapas e passos do método *Tuning Game Level by Machine Learning (TGL-ML)*



Fonte: Autoria própria.

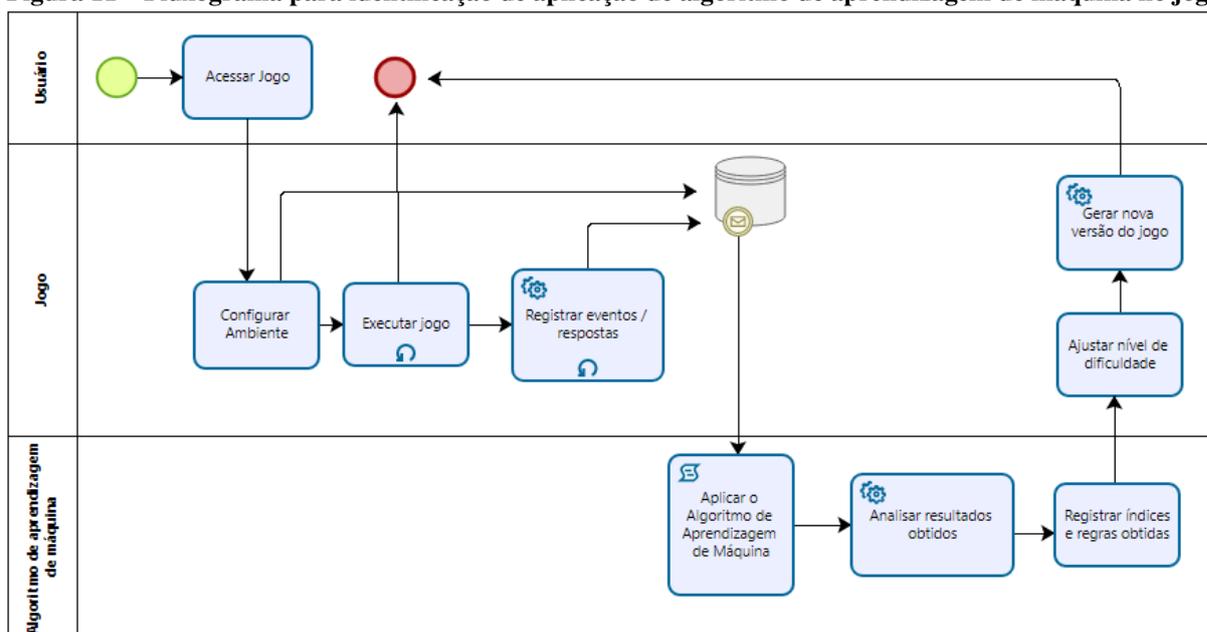
No Passo 3 é realizado o pré processamento de dados das partidas coletadas em uma base de dados, aplicando as técnicas de normalização, remoção de dados com intervalos divergentes da maioria e remoção de atributos não relevantes. Em seguida, com a base de dados processada executou-se a aplicação dos algoritmos de aprendizagem de máquina para descoberta de padrões.

No Passo 4, com o conhecimento obtido no passo anterior após a aplicação de algoritmos de aprendizagem de máquina, é realizada a atualização da versão do jogo incluindo regras para mudança de nível de dificuldade sobre os índices obtidos.

4.1.1 Elaboração do jogo

A elaboração do jogo iniciou com a criação de fluxogramas a fim de identificar em que momento os algoritmos de aprendizagem de máquina, sendo supervisionado, não supervisionado, semi-supervisionado e aprendizagem por reforço, por exemplo, poderiam ser aplicados para efetuar o ajuste de nível de dificuldades do jogo. A figura 11 apresenta um fluxograma utilizado para identificar a aplicação de algoritmo de aprendizagem de máquina no jogo.

Figura 11 – Fluxograma para identificação de aplicação de algoritmo de aprendizagem de máquina no jogo



Fonte: Autoria própria.

Verificando os algoritmos de aprendizagem de máquina aplicados em ambientes educacionais gamificados e jogos da literatura estudados, observou-se que para adicionar níveis de dificuldades em jogos é necessário coletar dados das partidas, realizar um refinamento dos dados armazenados e depois aplicar os algoritmos de aprendizagem de máquina. Os ajustes relacionados ao nível de dificuldade ou outras otimizações precisam ser realizados em um momento posterior considerando o refinamento e análise dos dados obtidos para incluir desafios mais avançados em tempo de execução.

Em um primeiro momento é realizada a execução do jogo em que as interações são apresentadas por meio de desafios. A medida que as etapas são realizadas novos desafios mais avançados ou mais difíceis são disponibilizados ao jogador.

Diferentemente das propostas da literatura, este método tem como objetivo desenvolver um jogo para deficientes intelectuais aplicando elementos de gamificação e algoritmos de aprendizagem de máquina. Em virtude da deficiência intelectual de alunos do ensino na modalidade de Educação Especial, os níveis de dificuldades precisam ser ajustados conforme a execução e interação com o jogo a fim de estimular o aluno a superar um determinado desafio.

O nível de dificuldade é adotado de acordo com os critérios de mecânica e dinâmica do jogo, podendo ser super fácil, fácil, médio ou difícil.

4.1.1.1 Público de aplicação do experimento

O público participante de aplicação deste trabalho foram alunos de uma escola de educação básica, na modalidade de educação especial. A escola foi escolhida para a aplicação do

projeto em razão da parceria existente em outros projetos de extensão com a Universidade Tecnológica Federal do Paraná, Câmpus de Ponta Grossa (UTFPR, 2021). Devido a pandemia da Covid-19 e a dificuldade de acesso a tecnologia por parte dos alunos, participaram do experimento seis alunos, contendo entre 27 e 52 anos de idade, os quais estão inseridos no programa EJA (Educação de Jovens e Adultos) (BRASIL, 2021) que se destina o ensino ao público que não teve acesso à educação escolar e formal na idade adequada. Estes alunos participam do grupo de informática oferecido pela escola e por terem um conhecimento maior de tecnologia móvel conseguiram realizar as atividades de forma remota.

Para ingressar na instituição, o estudante deve ter idade mínima de 15 anos ou mais. Os familiares devem apresentar um laudo médico (neurologista) com o CID ¹ (OMS, 2021) de Deficiência Intelectual ou Múltiplas Deficiências. E não deve possuir nenhuma certificação de escolaridade acima do sexto ano independente de saber ler ou escrever.

Nesse contexto, cada aluno consegue manter a concentração e aprender de forma diferenciada entre si. Existem alunos que leem, compreendem e escrevem com dificuldades, outros leem com dificuldades e não compreendem, e outros ainda não leem mas se esforçam para solucionar as atividades propostas. E mesmo os alunos possuindo autonomia para realizar atividades do cotidiano como andar sozinho, utilizar o transporte coletivo, frequentar estabelecimentos comerciais, por exemplo, ainda precisam de um acompanhamento para operar computadores e *smartphones*.

4.1.1.2 Definir as características do público alvo

Para atender o público alvo foram levantadas informações referentes as características que um software educacional deve conter para atender os alunos com deficiência intelectual. O processo de aprendizagem destes alunos é lento devido a deficiência intelectual que caracteriza por ter limitações de habilidades mentais que abrangem o raciocínio, as quais afetam as atividades diárias como a linguagem, leitura, escrita, memorização e cálculo. Para facilitar a assimilação de conteúdos, as informações devem ser simplificadas contendo poucos elementos mas com repetição de imagens (VINENTE; GALVANI, 2019).

Com base nas informações do público alvo foram considerados os principais requisitos educacionais de multimídia, formatação de texto (BOONE; HIGGINS, 2012), *design* e funcionalidades para estimular os alunos com deficiência intelectual (FARRINGTON, 2011).

Ao relacionar os requisitos educacionais em softwares para deficiência intelectual realizando atividades com computadores ou *smartphones* é proporcionado uma melhor fixação de conteúdos que contribuem com seu desempenho e motivação (SCHMENGLER; PAVAO; PAVAO, 2019; VENEZIANO *et al.*, 2016). O quadro 15 apresenta os requisitos educacionais utilizados.

¹ Classificação Estatística Internacional de Doenças e Problemas Relacionados com a Saúde

Quadro 15 – Requisitos educacionais utilizados neste trabalho

Requisito	Descrição	Autor
Fonte de texto	Letras em caixa alta, fonte Arial, cores bem definidas e sem fusões ou esmaecimento, e utilização do teclado virtual	Veneziano <i>et al.</i> (2016)
Multimídia	Botões grandes, imagens significativas e sons que apresentem correspondência com atividade realizada	Veneziano <i>et al.</i> (2016)
Outros recursos	Exibição de dicas, evitar conteúdo infantilizado, apresentar atividade relacionada ao cotidiano e o ensino na escola.	Orientadora desta pesquisa em aulas presenciais na instituição em 2019)

Fonte: Autoria própria.

4.1.1.3 Tema, conteúdo e tipo do jogo

O tema do jogo desenvolvido nesta pesquisa foi definido após a execução do mapeamento sistemático em que se observou a existência de poucos softwares educativos na área de Ciência. Inclusive, o Governo lançou um edital do MCTIC/CNPq N° 052019 – Programa Ciência na Escola em 2019 que contemplava projetos de ensino de Ciências. A partir disto, foi realizada uma reunião com a coordenadora pedagógica da escola em que foi definido que o assunto seria um tema dentro de Saúde Vegetal, abordado pela Agenda 2030 que destaca a importância da saúde das plantas, protegendo a biodiversidade e o meio ambiente. Propõe também ações que favoreçam a segurança alimentar e o desenvolvimento econômico sustentável (AGENDA 2030, 2021).

Segundo a ONU (2020), a Saúde Vegetal é conceituada como “a disciplina que usa uma série de medidas para controlar e prevenir que pragas, ervas daninhas e organismos causadores de doenças se espalhem em novas áreas, especialmente por meio da interação humana, como o comércio internacional”. As pragas são definidas como “qualquer espécie, estirpe ou biotipo de planta, animal ou patógeno que danifiquem plantas ou produtos vegetais. Eles incluem insetos, vírus, bactérias, nematóides e plantas invasoras”.

Como o tema de Saúde Vegetal é amplo, optou-se junto com a coordenadora pedagógica da instituição trabalhar com o assunto sobre Segurança Alimentar que considera três aspectos principais: quantidade, qualidade e regularidade no acesso aos alimentos. A alimentação da população não pode estar submetida a qualquer forma de alimentos com contaminação, apodrecimento ou vencidos, ou seja, a qualidade é a possibilidade de consumi-los de forma digna em um ambiente limpo e com as normas de higiene. A regularidade é permitir que as pessoas tenham acesso constante à alimentação, devendo alimentar-se ao menos três vezes ao dia (BELIK, 2003). De acordo com Burlandy (2008) a aproximação de pessoas sobre o tema pode contribuir

tanto para a reconstrução dos modelos de atenção à saúde, assim como para o fortalecimento da intersetorialidade.

O conteúdo abordado no jogo foi sobre frutas e verduras apresentando algumas características sobre vitaminas e os benefícios de serem consumidos. As frutas e verduras escolhidas foram adotadas pelo critério de popularidade perante ao público alvo e que são mais consumidas no Brasil (ABRAFRUTAS, 2021).

Em relação ao tipo do jogo, foi definido um jogo da memória. Os alunos da instituição de ensino participante deste experimento já possuem uma vivência com este tipo de jogo que facilita a sua interação com a atividade proposta. A utilização de um outro tipo de jogo que não estão habituados poderia apresentar mais dificuldades de interpretação e compreensão de regras em razão da deficiência intelectual.

4.1.1.4 Uso da gamificação e elementos

A aplicação de elementos de gamificação no jogo teve como objetivo promover o engajamento e motivar o aluno a superar os níveis de dificuldades disponibilizados a medida que as interações são realizadas no jogo. Neste contexto, foram incluídos elementos dinâmicos, mecânicos e componentes de gamificação para tornar o jogo atrativo relacionando as experiências vivenciadas na escola e no mundo real (MELLO; ZENDRON, 2015).

O quadro 16 apresenta os elementos dinâmicos de gamificação no jogo relacionando a narrativa com um personagem que apresenta os objetivos e informações sobre os itens apresentados, superação dos níveis de dificuldades e as interações durante as etapas.

Quadro 16 – Elementos dinâmicos de gamificação no jogo

Dinâmica	Descrição
Emocional	Relaciona a vontade do jogador em conhecer o tema por meio do jogo, o qual é estudado na instituição do público alvo. Ao acessar o jogo, a tela de <i>login</i> apresenta uma imagem de fundo de uma cozinha remetendo a ideia de alimentação. Durante o jogo ao selecionar uma carta é apresentado um alimento e são apresentados os benefícios de forma textual e sonora pelo personagem.
Narrativa	Adicionado um personagem que é um cientista que interage com o jogador ao acessar o jogo e durante as partidas. Ao acessar o jogo o cientista cumprimenta o jogador pelo nome. Durante as partidas ao selecionar uma carta, o cientista apresenta informações sobre os alimentos e seus benefícios de forma textual e sonora.
Progressão	Conforme os pares de cartas são combinados, o personagem indica o avanço e as quantidades de pares faltantes pra finalizar a partida.
Restrição	A dinâmica do jogo permite selecionar apenas duas cartas para combinar o par durante uma jogada.

Fonte: Autoria própria.

O quadro 17 apresenta os elementos mecânicos de gamificação no jogo da memória referente as funcionalidades e atividades a serem realizadas de acordo com o desafio do jogo

apresentado, considerando níveis de dificuldades, círculos interativos com informações educativas referentes a Segurança Alimentar e *feedback* durante a partida e ao final da mesma.

Quadro 17 – Elementos mecânicos de gamificação no jogo

Mecânica	Descrição
<i>Feedback</i>	Ao selecionar uma carta contendo a figura de um alimento são apresentadas informações de forma textual e sonora pelo personagem. Na combinação de cartas é apresentado um efeito visual em formato de círculo com estrelas na cor azul e um efeito sonoro. Ao errar a combinação de cartas, elas são viradas com um efeito visual para o seu formato inicial. Se o jogador errar muitas vezes, o personagem interage de forma textual e sonora aconselhando o jogador pensar melhor antes de combinar os pares. Se restarem apenas dois pares para combinar, o personagem incentiva o jogador a combinar os pares para ter sucesso na partida.
Tentativas	Quantidade de vezes ao tentar a combinação de um mesmo par de cartas
Desafios	Corresponde ao nível de dificuldade para a combinação dos pares, sendo 2, 4, 8 e 16 cartas.
Turnos	Partidas realizadas pelo jogador em um determinado tempo no jogo
Sucesso	Apresentação de um <i>feedback</i> positivo ao combinar todos os pares de cartas indicando a finalização da partida.

Fonte: Autoria própria.

O quadro 18 apresenta os componentes de gamificação aplicados no jogo para facilitar o entendimento do jogador combinando o contexto educacional ao lúdico.

Quadro 18 – Elementos relacionados aos componentes de gamificação

Componentes	Descrição
Conquistas	Ao realizar uma combinação de um par de cartas é apresentado um efeito visual em formato de círculo com estrelas na cor azul e um efeito sonoro.
Níveis	O jogo permite selecionar 4 níveis de dificuldade sendo: super fácil, fácil, médio e difícil. Os níveis apresentam uma quantidade maior de elementos conforme a dificuldade aumenta.
Pontos	A pontuação é atribuída de 100 em 100 ao combinar um par de cartas. Se a combinação de pares é em sequência, os pontos obtidos são multiplicados pela quantidade de pares combinados.

Fonte: Autoria própria.

4.1.1.5 Criação do jogo

O desenvolvimento do jogo envolve as fases de avaliação e aplicação de tecnologias, a prototipação e *desgin* gráfico² das telas, as funcionalidades a serem utilizadas e a definição dos atributos. Os atributos de banco de dados foram definidos de acordo com a mecânica do jogo

² O design gráfico das telas do jogo foi desenvolvido pelo aluno de mestrado Rafael de Andrade Pereira

a fim de facilitar a coleta de dados para posterior aplicação em algoritmo de aprendizagem de máquina.

Optou-se pelas tecnologias *online* na estrutura de cliente e servidor a fim de facilitar o acesso de alunos e de professores devido a pandemia da Covid-19. As tecnologias utilizadas no desenvolvimento do jogo deste método foram: o *Unity* (UNITY, 2021), *PHP* (PHP, 2021), servidor *Apache* (APACHE, 2021) e o banco de dados *MySQL* (MYSQL, 2021), as quais serão descritas sucintamente a seguir.

Os jogos do *Unity* são baseados em cenas onde são utilizados os elementos como os objetos de jogos, modelos, materiais, texturas e terrenos. Os objetos de jogos são todos objetos incluídos em um cenário de jogo como um cilindro, quadrado ou triângulo que podem ser configurados com figuras seguindo coordenadas em 2D ou 3D, assim como os efeitos de iluminação e câmera. Os modelos são os elementos de gráficos de uma cena de jogo. Os materiais são baseados em texturas e representam o solo, água, grama, etc. A textura é todo o desenho na superfície de um determinado material. Por fim, os terrenos são elementos de criação de paisagens dentro das cenas de execução de jogos (UNITY, 2021).

Na linguagem PHP, destaca-se o suporte a conexão com diversos bancos de dados, sendo algo prático e simples, pois suporta ODBC (*Open Database Connection* ou Padrão Aberto de Conexão de Banco de Dados), permitindo utilizar qualquer banco de dados que se enquadre neste padrão (PHP, 2021). A utilização do PHP no projeto teve o intuito de conectar o jogo desenvolvido em *Unity* e o banco de dados criado em *MySQL*.

O Apache é um servidor de aplicações executa códigos em PHP, distribuído como software livre e desenvolvido com código aberto pela Fundação Apache. O servidor possui configurações e funcionalidades para disponibilizar páginas e recursos para serem acessados por meio da Internet, podendo executar vários protocolos utilizados na web, como o HTTP (*Hyper-Text Transfer Protocol*), HTTPS (*Hyper-Text Transfer Protocol – Secure Socket Layer*), o FTP (*File Transfer Protocol*), entre outros (APACHE, 2021). A escolha do servidor motivou-se pelo desempenho com o *Unity*, utilizando a linguagem PHP.

O *MySQL* é um sistema de gerenciamento de banco de dados (SGBD) sendo de código aberto (*software* livre) e suporta a linguagem SQL. Disponibiliza vários recursos para implementação como tipos de dados, funções, operadores, funções de agregação, métodos de índice e linguagens procedurais (MYSQL, 2021).

Para que o acesso ao servidor Apache e o banco de dados *MySQL* ficassem sempre disponíveis para o desenvolvimento e posterior acesso do jogo de forma *online*, a UTFPR disponibilizou este recurso para o desenvolvedor do jogo a fim de contribuir com o projeto.

A próxima atividade realizada foi definir as funcionalidades do jogo da memória. Em razão dos alunos da instituição possuírem um conhecimento prévio de jogo da memória e terem aulas de informática, optou-se por desenvolver um jogo relacionando as atividades constantes em sua rotina.

4.1.1.6 Funcionalidades do jogo

As funcionalidades desenvolvidas para o jogo da memória, denominado de *ScienceLearning*, foram o *Login*, Controle de cartas e tabuleiro, Efeitos visuais, Gerenciamento de texto, Controle sonoro e o Registro de Eventos. O quadro 19 apresenta as funcionalidades desenvolvidas para o jogo.

Quadro 19 – Funcionalidades desenvolvidas para o jogo

Funcionalidades	Descrição
<i>Login</i>	Controla o acesso do jogador no jogo e durante as partidas realizadas
Controle de cartas e tabuleiro	Controla a quantidade de cartas no tabuleiro de acordo com o nível de dificuldade configurado, a combinação entre os pares de cartas e o início e finalização de partida.
Efeitos visuais	Controla os efeitos visuais sobre as cartas usando o formato de um círculo com estrelas na cor azul que brilham ao combinar um par. E ao apresentar uma dica sobre as cartas para serem combinadas é apresentado um círculo contendo quadrados na cor verde que brilham.
Gerenciamento de texto	Apresentação em formato de texto pelo personagem as informações sobre os alimentos e seus benefícios ao selecionar uma carta no tabuleiro.
Controle sonoro	Controla a música do jogo e o som da fala do personagem contendo a mesma informação textual.
Registro de Eventos	Controla e registra os eventos dos jogadores durante as partidas realizadas no banco de dados e em arquivo CSV (Valores Separados por Vírgulas).

Fonte: Autoria própria.

No gerenciamento textual e sonoro do personagem o objetivo é ensinar o jogador características importantes sobre cada alimento e seus benefícios ao selecionar uma carta. Conforme as cartas são selecionadas é apresentada uma descrição e o personagem fala o benefício de cada alimento. O quadro 20 apresenta o nome do alimento e o benefício apresentado durante o jogo pelo personagem.

Quadro 20 – Alimentos e benefícios ensinados no jogo

Alimento	Descrição
Abóbora	A Abóbora é benéfica para a visão e ajuda a preservar a pele.
Cenoura	A Cenoura fortalece o sistema imunológico e pode ajudar a reduzir o colesterol.
Maçã Verde	A Maçã Verde tem ação anti-ácida, melhora a digestão e alivia azias e refluxos.
Banana	A Banana ajuda na recuperação muscular e ajuda a evitar as câimbras.
Morango	O morango combate o envelhecimento da pele, ajuda a prevenir doenças cardiovasculares e melhorar a capacidade mental.
Pimentão	O Pimentão contribui para a manutenção de ossos e dentes saudáveis pois possui cálcio na composição.
Tomate	O Tomate ajuda a prevenir o câncer de próstata porque é composto de licopeno.
Cebola	A Cebola tem ação expectorante e funciona como um ótimo remédio natural para o tratamento da tosse.

Fonte: Autoria própria.

4.1.1.7 Definição de atributos

Os atributos para coleta de dados foram definidos de acordo com a dinâmica do jogo em que o objetivo é combinar pares de cartas conforme as quantidades de cartas apresentadas, estabeleceu-se primeiramente os atributos em relação ao tempo de realização de uma partida, tempo em que a primeira e segunda carta são selecionadas para combinação, identificador do par combinado certo e errado, pontos, tentativas, quantidade de acertos e erros, sucesso em uma partida.

Os atributos criados para obter o nível de dificuldade, a quantidade de pares apresentados como dicas de combinação e o combo de pontuação, que é o acerto de pares de cartas em sequência, foram definidos considerando os aspectos de motivação e engajamento do jogador.

Em relação a interação do jogador usando um computador pessoal ou *smartphone*, criou-se os atributos de código do usuário cadastrado, teclas utilizadas do teclado, quantidade de cliques de botões do *mouse* direito e esquerdo. Os atributos de tempo de realização de uma partida tiveram o objetivo de avaliar se o jogador levaria muito tempo procurando um par de carta e o nível de dificuldade estaria adequado as suas limitações de habilidades mentais do usuário.

Os atributos relacionados as quantidades foram utilizados para mensurar as interações realizadas durante uma partida. Os atributos de identificação do par combinado certo e errado, foram utilizados para verificar quais eram os pares de cartas combinados. E o atributo de sucesso indica se o usuário finalizou uma partida ou saiu sem finalizá-la. O quadro 21 apresenta os atributos utilizados na coleta de dados do jogo da memória.

Quadro 21 – Atributos para coleta de dados

Nome atributo	Descrição
Tempo	Tempo em minutos e segundos utilizados em uma partida.
Tempo primeira carta virada	Tempo durante a partida que uma primeira carta foi selecionada para combinar um par.
Tempo segunda carta virada	Tempo durante a partida que uma segunda carta foi selecionada para combinar um par.
Par de carta combinado certo	Identificador numérico do par de carta combinado certo.
Par de carta combinado errado	Identificador numérico do par de carta combinado errado.
Pontos	Pontuação crescente ao combinar um par correto.
Tentativas	Quantidade de vezes para combinar um par de cartas.
Quantidade de acertos	Somatório de acerto sobre um par combinado.
Quantidade de erros	Somatório de erros sobre um par combinado.
Sucesso	Indicador de finalização de uma partida.
Nível de dificuldade	Nível de dificuldade da partida em relação a quantidade de cartas apresentadas.
Quantidade de pares de dicas	Somatório da quantidade de pares apresentados como dica.
Combos de pontuação	Multiplicador de pontuação da partida ao combinar um par de cartas em sequência.
Código de Usuário	Código do Usuário registrado no sistema.
Quantidade de teclas usadas	Quantidade de teclas do teclado de computador utilizadas durante a interação com o jogo.
Quantidade de cliques direito	Quantidade de cliques com o botão direito do <i>mouse</i> de computador.
Quantidade de cliques esquerdo	Quantidade de cliques com o botão esquerdo do <i>mouse</i> de computador.

Fonte: Autoria própria.

No entanto, na Etapa de Pré-Processamento de dados (ver 4.1.3.1), os atributos foram refinados e alguns até removidos para obter resultados mais precisos com a aplicação de algoritmo de aprendizagem de máquina.

4.1.2 Aplicação do jogo

Para a aplicação do jogo *ScienceLearning* foram considerados os recursos do público alvo, pois isto pode impactar diretamente no tempo de instalação e conseqüentemente no período de avaliação. Foi necessário avaliar a disponibilização do jogo em um formato para *smartphones* porque antes da pandemia da covid-19, os jogos seriam instalados nos computadores da instituição e os alunos seriam acompanhados pelos professores. Contudo, foram necessárias adaptações no jogo desenvolvido para que os alunos tivessem acesso ao jogo e pudessem participar deste projeto.

A disponibilização envolveu operações de como instalar, operar o jogo e o período a ser considerado para avaliação. Para isto, foi criado um grupo de conversa em um aplicativo de mensagens instantâneas para *smartphones*, o qual permitiu o alinhamento de informações com a equipe pedagógica e professores de informática da escola.

Foi criado um vídeo explicativo contendo instruções necessárias de como instalar, explicação sobre a dinâmica do jogo, a forma de acesso e sua utilização nos níveis de dificuldades. O vídeo instrucional e o *ScienceLearning* foram disponibilizados e compartilhados por meio de uma plataforma de armazenamento de arquivos *online* para efetuar o *download*.

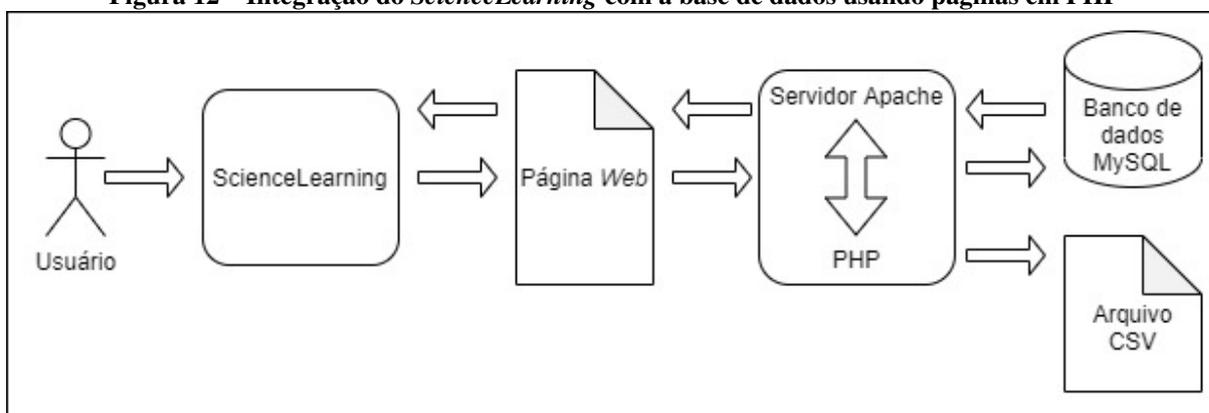
Após os professores de informática compreenderem as instruções do vídeo instrucional, auxiliaram os alunos participantes a instalarem o jogo *ScienceLearning* em seus *smartphones* para realização do experimento.

4.1.2.1 Coletar dados

O objetivo da coleta de dados é obter máximo de informações para entender o comportamento do jogador durante uma partida na tentativa de descobrir um perfil de usuário ou um padrão de jogadas aplicando algoritmos de aprendizagem de máquina em uma etapa posterior.

A coleta de dados foi efetuada a cada interação de um usuário ao executar uma partida seja ela finalizada ou não. As partidas foram realizadas em todos os níveis de dificuldades disponíveis no *ScienceLearning* a fim de obter informações de teclas pressionadas, clique do botão direito ou esquerdo do *mouse*, os pares de cartas selecionados, tempo e pontos da partida, e os demais atributos definidos para posterior aplicação de algoritmos de aprendizagem de máquina. A figura 12 ilustra a integração do *ScienceLearning* com a base de dados usando páginas em PHP.

Figura 12 – Integração do *ScienceLearning* com a base de dados usando páginas em PHP



Fonte: Autoria própria.

Na integração do jogo do *ScienceLearning* as operações de cadastro de usuário, *login*, configurações e de partidas realizadas utilizaram as páginas desenvolvidas em *PHP*. As páginas

em *PHP* efetuam o envio de dados para o banco de dados *MySQL* e para um arquivo *CSV* por meio do Servidor *Apache*.

Para a coleta de dados foi definido com a equipe pedagógica da escola um período de duas semanas para utilização do jogo. E cada participante deveria executar no mínimo 3 partidas em cada nível de dificuldade (super fácil, fácil, médio e difícil) a fim de obter uma quantidade relevante de registros para o experimento.

Ao final do período de aplicação do experimento, foram registrados 674 registros no banco de dados *MySQL* e no arquivo *CSV* (Valores Separados por Vírgulas) que realiza conexão pelo *backend* em *PHP* com o servidor *Apache*. A gravação dos dados em um arquivo *CSV* teve o intuito de facilitar a posterior aplicação de algoritmos de aprendizagem de máquina que utiliza este formato como entrada de dados.

4.1.2.2 Registro de eventos das partidas

Os registros das partidas foram armazenados em uma base de dados para manter e controlar os dados dos jogadores, eventos realizados durante as partidas, bem como, a versão do jogo disponibilizada para controlar qual versão foi aplicada e referenciar determinadas funcionalidades em versões futuras.

A base de dados foi populada com a interação dos alunos da escola participante durante o período definido para interagir com o jogo do *ScienceLearning*. A base de dados em *MySQL* desenvolvida armazena dados de usuários e as atividades realizadas durante as execuções das partidas.

As tabelas desenvolvidas para o jogo da memória tiveram um enfoque maior nos atributos de partidas realizadas (ver seção 4.1.1.7), ao todo foram coletados 674 registros de eventos de partidas durante o período de experimento. O uso da base de dados permitiu a consulta de informações em um determinado período e avaliar o perfil do jogador após aplicação do algoritmo de aprendizagem de máquina.

A utilização do banco de dados seguiu o modelo cliente-servidor para facilitar a coleta de dados e seu acesso, além da dinâmica de envio e recepção de dados pelo jogo, pois a forma de sua distribuição permitiu a flexibilidade de instalação e acesso.

4.1.2.3 Ajuste de funcionalidades do jogo após *feedback*

Após a utilização do jogo pelo público alvo é importante observar as informações de experiências relatadas para documentação e possíveis melhorias para aprimorar o jogo. Foi realizada uma reunião de forma *online* com a equipe pedagógica da escola para receber *feedbacks* das

funcionalidades do jogo. A reunião teve o propósito de receber informações sobre a experiência vivenciada pelos alunos na utilização do jogo do *ScienceLearning*.

O *feedback* foi positivo tanto por parte dos alunos quanto dos professores apesar da dificuldade de instalação nos *smartphones* pelos alunos em razão da atividade ter sido de forma *online*.

Sobre as funcionalidades do jogo houve apenas uma ressalva na tela de Cadastro de Usuário em que alguns alunos tiveram dificuldades em preenchê-lo informando a data de nascimento. Com isso, realizou-se um ajuste no cadastro para tornar o atributo de data de nascimento como opcional a fim de facilitar o cadastro. Realizou-se um ajuste no campo de data de nascimento removendo a obrigatoriedade de preenchimento e foi adicionando o texto "*Opcional".

O ajuste desta funcionalidade foi realizado, pois uma informação em específico pode gerar uma ansiedade ao jogador e faça-o desistir de preencher o cadastro corretamente ou até mesmo desistir de jogar.

A funcionalidade de "Lembrar Usuário", disponível na tela de *Login* do jogo, foi observada de forma positiva pois facilitou o acesso ao *ScienceLearning* ao retomar a atividade em um momento posterior.

4.1.3 Utilização de Algoritmo de Aprendizagem de Máquina

Para validação do conjunto de dados foi utilizado o *software Weka (Waikato Environment for Knowledge Analysis)* (FRANK; HALL; WITTEN, 2021) na versão 3.8.5 que contempla uma miscelânea de algoritmos para mineração de dados. Neste processo, houve uma etapa de pré-processamento dos dados coletados no arquivo de formato CSV (Valores Separados por Vírgulas) para que na sequência os dados fossem importados para o *Weka* a fim de facilitar a análise e obter resultados mais consistentes.

4.1.3.1 Pré-processamento de dados

Neste trabalho, a etapa de pré-processamento de dados em um primeiro momento abrangeu o levantamento e tratamento de dados coletados, sendo necessário remover registros com ruídos e intervalos extremos em comparação aos demais, remover atributos não relevantes ou que não têm impacto na análise de dados e tratar atributos relacionados ao tempo de partida.

Na remoção de registros com ruídos foram observados os atributos de tempo de partida, tentativas e quantidade de cliques esquerdo. No atributo tempo, notou-se em alguns registros que em um intervalo de tempo baixo o jogador ao entrar na partida já finalizou sem selecionar nenhuma carta, reiniciando ou saindo da partida. E com um intervalo de tempo muito alto

observou-se que a partida foi encerrada após quase 30 ou 40 minutos de execução do jogo sem qualquer interação sendo verificado por meio do tempo de primeira e segunda carta selecionada.

Ao validar o preenchimento de cada atributo com os dados coletados, os atributos a seguir foram removidos, pois notou-se que:

- Quantidade de teclas usadas, não foi preenchido em razão do *ScienceLearning* ter sido executado em *smartphones* ficando com os registros zerados.
- Código de Usuário, por se tratar de um identificador numérico interno do sistema, não apresentou uma representatividade em relação aos demais atributos.
- Quantidade Acerto e Erros, foram removidos porque os valores eram os mesmos do atributo de carta combinado certo e do atributo carta combinado errado, respectivamente.
- Quantidade de Clique Direito, foi removido porque comparado ao atributo Quantidade Clique Esquerdo foi detectado que a maioria dos registros estavam zerados. E isto não corresponde necessariamente ao botão direito do *mouse* por ter sido utilizado o *smartphone*, sendo que um toque na tela corresponde diretamente ao clique esquerdo do *mouse*.

Para o atributo de tempo, em segundos, aplicou-se a normalização de Min-Max (HAN; KAMBER; PEI, 2012) para em seguida transformar em atributos nominais e estabelecer um intervalo classificando como alto, médio e baixo. Para os autores, a normalização é nivelar o conjunto de dados com um peso igual, sendo bastante utilizado para cálculos de medições de distância no algoritmo *K-Means*, algoritmos de agrupamentos e redes neurais. Esta normalização mantém os atributos com valores grandes em um mesmo intervalo comparado à valores menores.

A normalização de Min-Max realiza uma transformação linear sobre os valores de dados originais. Considerando os valores mínimos e máximo de um atributo A são $MinA$ e $MaxA$, a normalização localiza um valor v_i do atributo A para v'_i dentro de um intervalo $[novo_min, novo_max]$ conforme apresenta a fórmula da equação (HAN; KAMBER; PEI, 2012):

$$v_n^1 = \frac{v_i - MinA}{MaxA - MinA} (new_MinA - new_MinA) + new_MinA$$

A aplicação da fórmula sobre o atributo tempo para os valores mínimo e máximo, sendo 1 e 6 segundos, respectivamente. Para considerar o intervalo de $[0, 1]$ na normalização de Min-Max, o tempo de 1 segundo corresponde um valor na faixa do atributo, o qual é transformado para o valor de:

$$\frac{1 - 0}{6 - 0} (1 - 0) + 0 = 0,16$$

Os atributos de tempo de primeira e segunda carta virada foram normalizados com uma média do somatório do tempo de todas as cartas viradas de uma partida a fim de obter um intervalo de busca entre a primeira carta selecionada e a segunda carta.

Ao iniciar o pré processamento de dados existiam 17 atributos e 674 registros e ao finalizá-lo foram selecionados 11 atributos e 502 registros.

4.1.3.2 Aplicação de Algoritmo de Aprendizagem de Máquina

Os algoritmos de aprendizagem de máquina aplicados foram o *K-Means* e os classificadores JRip e J48, disponíveis na ferramenta Weka (FRANK; HALL; WITTEN, 2021), utilizando os parâmetros de configuração padrão da ferramenta

A utilização do algoritmo *K-Means*, considerou a quantidade de 2 agrupamentos, e os algoritmos JRIP e J48 utilizaram as estimativas de acurácia dos modelos com base na validação cruzada estratificada. Inicialmente, os algoritmos foram aplicados para todo o conjunto de dados usando como o atributo “nível_jogo” em todos os níveis (super fácil, fácil, médio e difícil) e na sequência apenas para o nível difícil, pois a maioria das partidas concentravam dados neste nível indicando que os participantes não tiveram maiores dificuldades nos demais níveis.

4.1.3.3 Pós-processamento e análise de dados

Nesta etapa, observou-se as métricas de acuracidade geradas em cada um dos testes aplicando os algoritmos *K-Means*, Classificador JRip e J48. As regras geradas em cada algoritmo de aprendizagem de máquina foram analisadas para posterior otimização do ajuste de nível de dificuldade do jogo da memória do *ScienceLearning*.

4.1.4 Atualizar a versão do jogo

A atualização da versão do jogo utiliza as informações obtidas e analisadas por meio da aplicação e algoritmos de máquina em que as funcionalidades, regras e níveis de dificuldades são considerados para aprimoramento do jogo. A nova versão do jogo contempla otimizações com base na análise de dados e índices obtidos que correspondem ao perfil de jogadores, os quais são implementados para tornar o jogo mais atrativo e motivante perante ao público alvo.

4.1.4.1 Adicionar regras sobre os índices

Os índices obtidos sobre os dados analisados representam que novas regras podem ser aplicadas no jogo. As regras para mudança de nível de dificuldade, por exemplo, foram ajustadas

para motivar o jogador continuar na partida ao invés de desistir por causa da dificuldade.

Um fator preponderante é a quantidade de elementos apresentados no jogo, os quais devem ser mensurados em relação ao tempo de finalização de partidas para que o jogo seja finalizado em um tempo adequado. No caso do jogo *ScienceLearning*, tais elementos são as quantidades de cartas apresentadas para combinação de pares. Outros fatores são as quantidades de tentativas e pontos que indicam se os jogadores estão tendo muitas dificuldades em interagir com o jogo, sendo necessário adaptar as partidas com o acréscimo de dicas ou até mesmo a redução de elementos do jogo.

4.1.4.2 Criar nova versão do jogo

A nova versão do jogo contempla as informações obtidas por meio da análise de resultados após aplicação de algoritmos de aprendizagem de máquina considerando o ajuste de nível de dificuldade com relevância, pois as limitações de habilidades dos jogadores pode ser um fator de desistência.

A aplicação de novas regras com base nos resultados obtidos para ajustar um nível de dificuldade foram utilizadas em relação de dificuldades que os jogadores tiveram:

- Maior tempo de interação para finalizar uma partida.
- Quantidade de pontos obtidos durante uma partida em relação ao total de pontos que pode ser obtido.
- A quantidade combos obtidos durante a partida.
- As quantidades de dicas exibidas durante o jogo para reduzir ou aumentar o tempo da partida em relação ao nível de dificuldades.
- Redução do nível de dificuldade da partida.

4.1.5 Considerações finais do capítulo

Este capítulo apresentou o método *Tuning Game Level by Machine Learning* (TGL-ML) para ajuste de nível de dificuldade contendo duas etapas, antes da aplicação de algoritmo de aprendizagem de máquina e depois da aplicação de algoritmo de aprendizagem de máquina. A primeira etapa envolve a elaboração e disponibilização da versão 1.0 do jogo da memória, e a aplicação do jogo para coleta de dados obtendo os primeiros resultados. A segunda etapa abrange a utilização de algoritmos de aprendizagem de máquina com a organização e processamento de

dados para mineração de dados, e por fim, a atualização e geração da versão 2.0 do jogo com base nas informações e índices obtidos após o uso dos algoritmos de aprendizagem de máquina.

Na primeira etapa, a elaboração inicial da proposta do jogo com a criação de fluxogramas facilitaram o entendimento do fluxo e permitiram analisar em que momento os algoritmos de aprendizagem de máquina poderiam ser aplicados. A aplicação do algoritmo de aprendizagem de máquina para ajuste no nível de dificuldade depende dos dados coletados e dos atributos definidos, pois isto influenciará no conjunto de entrada e saída de dados, impactando diretamente na precisão do aprendizado de máquina.

Na elaboração do jogo foram avaliados o público de aplicação do projeto e suas características para que os conteúdos a serem apresentados por meio do jogo da memória atendessem os requisitos educacionais de indivíduos com deficiência intelectual. Para isto, foi definido o tema do jogo juntamente com a instituição para abranger assuntos relacionados à segurança alimentar em suas atividades de aprendizagem.

A partir do tema proposto, utilizou-se a gamificação e elementos dinâmicos e mecânicos e os relacionados aos componentes de gamificação. Após o alinhamento da gamificação voltado para o público alvo, desenvolveu-se o jogo e suas funcionalidades com as tecnologias avaliadas considerando a forma de acesso que os alunos teriam para utilizar o jogo da memória.

A definição dos atributos considerou a dinâmica do jogo da memória para que pudessem ser estabelecidos em relação ao tempo, pontuação, tentativas, nível de dificuldade, quantidade de cliques e sucesso ao finalizar uma partida.

A aplicação do jogo abrangeu a disponibilização em uma plataforma de arquivos *online* contendo vídeos de instruções e o instalador do jogo, além da coleta de dados com as informações das partidas realizadas e como resultado a formação da base de dados. E por fim, a recepção de *feedback* do público alvo para ajustar as funcionalidades do jogo da memória.

Na segunda etapa, a utilização de algoritmo de aprendizagem de máquina sobre os dados coletados foi utilizada a ferramenta *Weka* (FRANK; HALL; WITTEN, 2021) para mineração de dados com os dados tratados para depois obter informações precisas para análise de dados. Após a análise de dados, com a observação nos resultados foram adicionadas novas regras com os índices obtidos para finalmente gerar uma nova versão do jogo com as funcionalidades otimizadas para o público de aplicação.

5 RESULTADOS

Os resultados obtidos neste trabalho se dividem em duas partes, antes e depois de aplicar os algoritmos de aprendizagem de máquina baseado no método *Tuning Game Level by Machine Learning* (TGL-ML). A primeira parte abrange as funcionalidades desenvolvidas e os resultados obtidos após a aplicação do jogo *ScienceLearning* com a versão disponibilizada para o público participante. É apresentado como o jogo foi aplicado, disponibilizado e as instruções repassadas aos participantes para utilização, a estrutura da base de dados e os ajustes realizados nas funcionalidades do jogo após o *feedback* recebido. A segunda parte descreve os resultados obtidos após a aplicação dos algoritmos de aprendizagem de máquina com os dados coletados por meio do jogo do *ScienceLearning*. São descritas as informações da base de dados processada e os conhecimentos obtidos, a forma para realizar a mudança de nível de dificuldade com base nos resultados e a criação da nova versão do jogo aplicando as regras e índices obtidos.

Adicionalmente, é descrita uma solução para experimentos futuros para ajuste de nível de jogo observada durante o desenvolvimento, aplicação do jogo e aplicação de algoritmo de aprendizagem de máquina. Por fim, são descritas as considerações finais do capítulo.

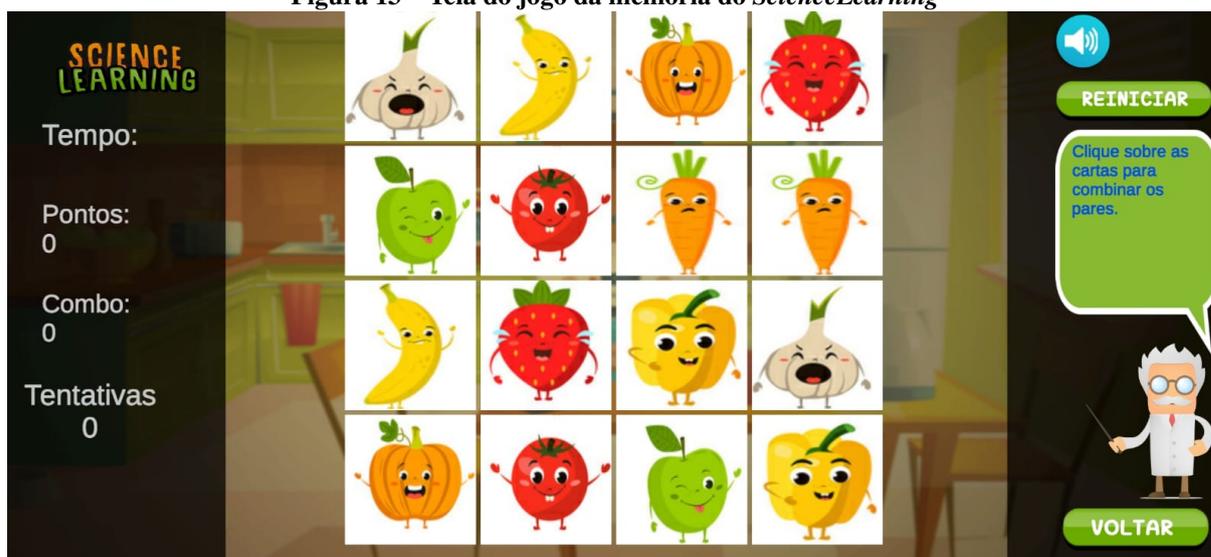
5.1 RESULTADOS ANTES DA APLICAÇÃO DOS ALGORITMOS DE APRENDIZAGEM DE MÁQUINA

Os resultados obtidos antes da aplicação dos algoritmos de aprendizagem de máquina iniciam com as funcionalidades que se destacam no *ScienceLearning*. As funcionalidades criadas são o controle de cartas e de tabuleiro, efeitos visuais, texto e som. Apesar do controle de *Login* e Registro de Eventos terem uma função importante em armazenar os dados de usuários e os registros de eventos das partidas, não são visíveis para o usuário e não representam os elementos de gamificação.

As funcionalidades de controle de efeitos visuais e de texto são executadas juntamente com a funcionalidade de controle de carta e de tabuleiro, sendo disparadas a medida que ocorre a seleção de uma carta no jogo da memória.

A funcionalidade de cartas e de tabuleiro é a parte que centraliza as operações do jogo da memória. Ao iniciar uma partida todas as cartas são mostradas pelo tempo de cinco segundos e em seguida são viradas para o verso ocultando a figura do alimento. No decorrer da partida, o personagem apresenta informações de forma textual e falada assim que uma carta é selecionada. Ao desabilitar o som do jogo na opção superior à direita da tela, a fala do personagem é desabilitada assim como a música do jogo, e as informações dos alimentos são apresentadas apenas de forma textual. A figura 13 apresenta a tela de uma partida do jogo da memória do *ScienceLearning*.

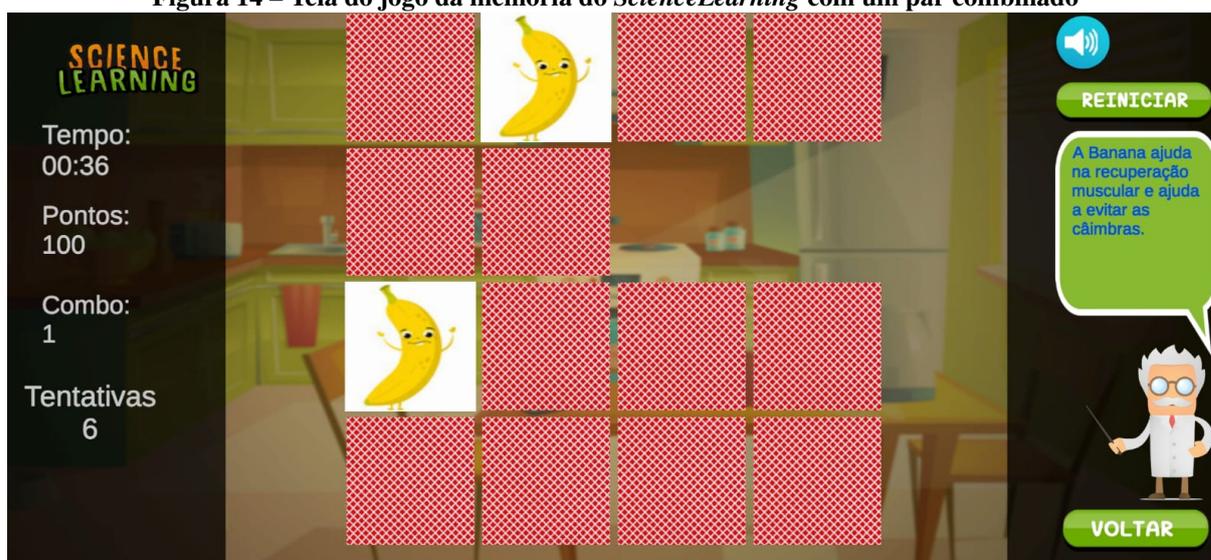
Figura 13 – Tela do jogo da memória do *ScienceLearning*



Fonte: Autoria própria.

A medida que as cartas são combinadas é apresentado um efeito visual e sonoro para indicar que a combinação está correta, removendo as cartas combinadas do tabuleiro. Caso o jogador não consiga combinar os pares diante de algumas tentativas, é apresentado um efeito visual e sonoro indicando onde encontra os pares para serem combinados na partida. Esta funcionalidade tem o intuito de fornecer uma dica para o jogador para que o mesmo não desista da partida mesmo tendo dificuldades para encontrar os pares a serem combinados. A figura 14 apresenta a tela do jogo da memória ao combinar um par no *ScienceLearning*.

Figura 14 – Tela do jogo da memória do *ScienceLearning* com um par combinado



Fonte: Autoria própria.

Ao finalizar uma partida é apresentada a tela de Parabéns (ver o apêndice A) para o jogador com um efeito sonoro e visual. Neste momento, os dados da partida são registrados em banco de dados de acordo com os atributos definidos para posterior aplicação do algoritmo de aprendizagem de máquina.

A funcionalidade de controle sonoro é carregada ao acessar o jogo, sendo herdadas para todas as telas do jogo. E a qualquer momento durante a interação com o jogo é possível desabilitar ou habilitar o som do jogo e a fala do personagem. As telas desenvolvidas para o jogo do *ScienceLearning* são apresentadas no Apêndice A.

Os professores da instituição repassaram aos alunos as instruções de uso e a instalação do jogo. Os *links* do vídeo explicativo e de instalação do jogo do *ScienceLearning* está disponível em:

- Link do vídeo explicativo para utilização do *ScienceLearning*:

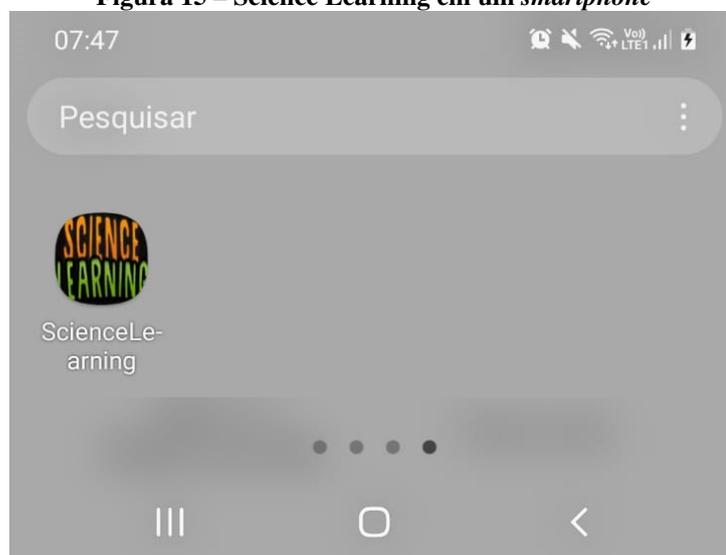
<https://drive.google.com/file/d/1tolYw5RmtftVoNuQ03zJgKRPu1kViz-n/view?usp=sharing>

- Link para *download* e instalação jogo do *ScienceLearning*:

<https://drive.google.com/file/d/1dw3gxyhdWKVSc9X05x2c5HC2jeJI8IvI/view?usp=sharing>

O jogo da memória desenvolvido foi disponibilizado no formato *Android* (.apk) para que o público efetuasse o *download* em seu *smartphone*, realizasse a instalação e efetuasse as interações. A figura 15 apresenta o jogo do *ScienceLearning* instalado em um *smartphone*.

Figura 15 – Science Learning em um *smartphone*



Fonte: Autoria própria.

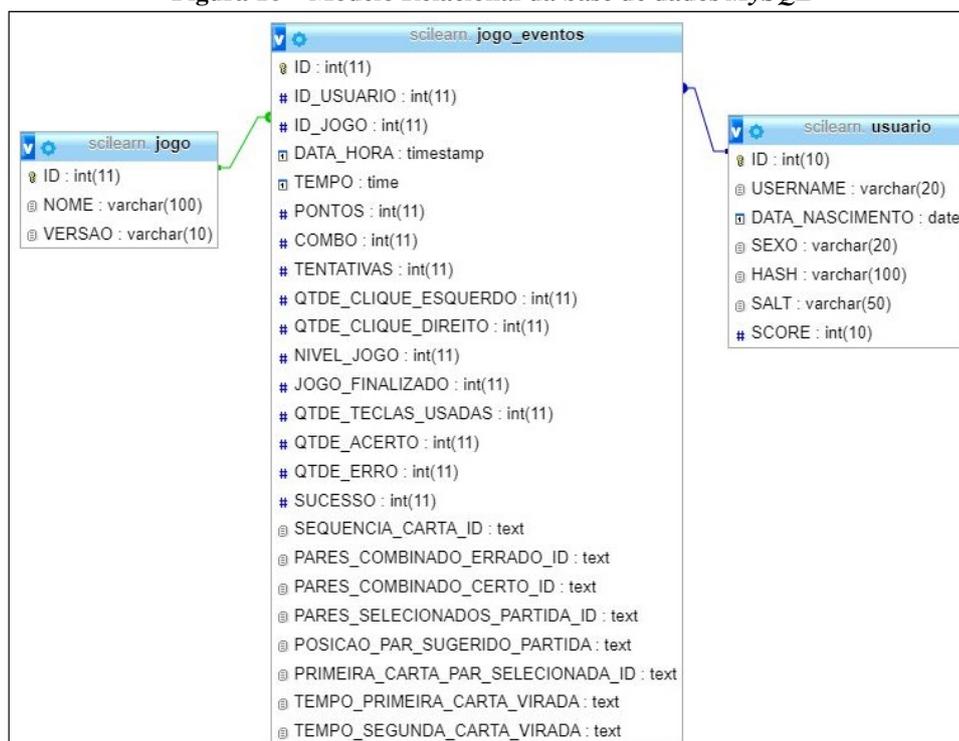
Os alunos não tiveram dificuldades em assistir o vídeo explicativo e interagir com o jogo, porém um dos alunos que utilizava um *smartphone* com a versão do *Android Jelly Bean* 4.1 disponibilizada em 2012, foi necessário gerar uma versão compatível para este aparelho para suportar a execução do *ScienceLearning*.

Após a confirmação de recebimento dos *links* de instalação e explicação de uso para os professores, estes acompanharam e auxiliaram os alunos na interação com o jogo. O período de coleta de dados em que os alunos interagiram com o jogo iniciou no dia 12 de maio e finalizou

no dia 23 de maio de 2021. Porém, mesmo após esta data os alunos puderam jogar conforme desejado.

A base de dados é composta por três tabelas usuário, jogo e jogos_eventos. A tabela de usuário armazena o nome do usuário, data de nascimento, gênero (masculino ou feminino), a senha criptografada e a pontuação geral do jogador. A tabela jogo armazena o nome e a versão jogo para edições futuras. A tabela jogos_eventos armazena as informações de usuários e referentes aos atributos de partidas realizadas no jogo da memória. A figura 16 apresenta o modelo relacional do banco de dados do *ScienceLearning*.

Figura 16 – Modelo Relacional da base de dados *MySQL*



Fonte: Autoria própria.

A figura 17 apresenta a tabela de Eventos do *ScienceLearning* no banco de dados do *MySQL*.

Figura 17 – Tabela de Eventos do jogo do *ScienceLearning* no *MySQL*

ID	ID_USUARIO	ID_JOGO	DATA_HORA	TEMPO	PONTOS	COMBO	TENTATIVAS	QTDE_CLIQUE_ESQUERDO	QTDE_CLIQUE_DIREITO
1511	58	1	2021-07-20 01:00:27	00:57:00	1100	2	17	35	
1510	58	1	2021-07-20 00:59:21	00:50:00	1300	3	15	32	
1509	58	1	2021-07-20 00:58:24	00:35:00	1300	3	12	24	
1508	58	1	2021-07-20 00:57:41	01:08:00	1500	4	21	42	
1507	58	1	2021-07-20 00:56:25	00:52:00	1200	3	16	32	

Fonte: Autoria própria.

O banco de dados em *MySQL* armazena os dados para interação com o *ScienceLearning*, porém apenas os dados da tabela "jogo_eventos" são registrados em um arquivo CSV.

5.2 RESULTADOS APÓS A UTILIZAÇÃO DE ALGORITMO DE APRENDIZAGEM DE MÁQUINA

A análise e avaliação dos resultados obtidos por meio da utilização de algoritmos de aprendizagem permitiu encontrar padrões nos dados coletados e formar o conhecimento para aprimorar o jogo. Considerando os dados obtidos foi possível gerar uma nova versão do jogo ajustando o nível de dificuldade com base nos índices e regras resultantes dos algoritmos de aprendizagem de máquina.

5.2.1 Resultados dos algoritmos de agrupamento e classificação

Os resultados obtidos pelos algoritmos de aprendizagem de máquina, são representadas a seguir pela quantidade de instâncias obtidas do conjunto de dados sendo aplicadas sobre o atributo de nível de dificuldade. Para o algoritmo *K-Means* considerou a quantidade de 2 *clusters* utilizada. E para os algoritmos de classificação J48 e JRip foi considerado o desempenho baseado em suas taxas de acerto. A tabela 4 apresenta a quantidade de instâncias e seus respectivos *clusters* utilizados no algoritmo de agrupamento *K-Means*.

Tabela 4 – Quantidade de instâncias e seus respectivos *clusters* utilizados no *K-Means*

<i>Clusters</i>	Quantidade de instâncias	Nível de dificuldade
k=2	501	Todos
k=2	325	Difícil

Fonte: Autoria própria.

Os algoritmos JRip e J48 tiveram uma taxa de acerto igual a 91.41 % e 92.81 %, respectivamente, conforme apresenta a tabela 5.

Tabela 5 – Desempenho dos classificadores baseado em suas taxas de acerto

Classificador	Instâncias Corretas	Taxa de acerto
Todos os níveis de dificuldade		
JRip	458	91.41 %
J48	465	92.81 %

Fonte: Autoria própria.

Para os classificadores JRip e J48, na análise com a entrada de dados contendo apenas informações do nível de dificuldade "difícil" não foram apresentadas regras de classificação.

Os resultados da análise e de conhecimentos obtidos após a aplicação dos algoritmos de aprendizagem de máquina *K-Means*, J48 e JRip estão apresentados nas próximas seções.

5.2.1.1 Resultados com o Algoritmo *K-Means*

Na análise dos resultados do *K-Means* para os níveis de dificuldades "super fácil", "fácil" e "médio", os atributos de pontuação e quantidade de combos possuíam valores sempre elevados, confirmando o fato de que os alunos da escola estão habituados a praticar jogos de memória.

Ao analisar o nível de dificuldade "difícil" indicava um aumento nos valores dos atributos de tempo, quantidade de cliques esquerdo, quantidade de dicas e tentativas. No entanto, o atributo de quantidade de combo apresentava valores próximos aos demais níveis de dificuldade indicando uma maior dificuldade em acertar os pares em sequência. Consequentemente, houve um aumento no tempo e na média de tempo entre a primeira e segunda carta selecionada.

A verificação da regra do algoritmo *K-Means* demonstrou que no nível de dificuldade "difícil", são realizadas até 3 tentativas e até 2 segundos para combinar um par de cartas, sendo que os demais níveis de dificuldades (super fácil, fácil e médio) utilizam o tempo médio em 1 segundo e quantidade de dicas menor que 1, demonstrando que para este público não apresenta dificuldades com a quantidade até 8 cartas (4 pares) no jogo da memória. A figura 18 apresenta o resultado do algoritmo *K-Means* no nível de dificuldade difícil.

Figura 18 – Resultado do algoritmo K-Means no nível de dificuldade difícil

```

kMeans
=====

Number of iterations: 3
Within cluster sum of squared errors: 97.09351282600167

Initial starting points (random):

Cluster 0: BAIXO,1400,4,21,42,13,SIM,8,1,1.19,DIFICIL
Cluster 1: BAIXO,1200,3,16,42,8,SIM,8,0,1.32,DIFICIL

Missing values globally replaced with mean/mode

Final cluster centroids:

Attribute                                Cluster#
Full Data                                0          1
(325.0)                                (111.0)    (214.0)
=====
tempo                                    BAIXO      MEDIO      BAIXO
pontos                                  1098.1538  1125.2252  1084.1121
combo                                   2.4615     2.5315     2.4252
tentativas                              19.2554    24.3333    16.6215
qtde_clique_esquerdo                    42.3754    52.6847    37.028
qtde_erro                                11.7015    16.4775    9.2243
sucesso                                  SIM         SIM         SIM
qtde_pares_combinado_certo                7.5538     7.8559     7.3972
qtde_pares_dica                           1.48       3.5045     0.4299
media_somatorio_carta_virada              1.3272     1.4098     1.2844
nivel_jogo                                DIFICIL    DIFICIL    DIFICIL

```

Fonte: Autoria própria.

5.2.1.2 Resultados com o Algoritmo J48

Na análise de dados com o algoritmo classificador J48, utilizando a entrada com todos os níveis de dificuldades, observou-se que no nível de dificuldade "difícil" em média são efetuadas 8 tentativas para combinar um par de cartas, além da quantidade menor ou igual a 1 de combos (pares combinados em sequência). A figura 19 apresenta o resultado do algoritmo J48 em todos os níveis de dificuldades.

Figura 19 – Resultado do algoritmo J48 com todos os níveis de dificuldades

```

J48 pruned tree
-----

tentativas <= 8
|  combo <= 1
|  |  qtde_erro <= 0
|  |  |  qtde_clique_esquerdo <= 5: SUPER_FACIL (73.0/20.0)
|  |  |  qtde_clique_esquerdo > 5: FACIL (6.0/1.0)
|  |  qtde_erro > 0: DIFICIL (5.0)
|  combo > 1
|  |  qtde_pares_combinado_certo <= 3: FACIL (95.0/10.0)
|  |  qtde_pares_combinado_certo > 3: MEDIO (12.0)
tentativas > 8: DIFICIL (310.0/1.0)

Number of Leaves   :    6

Size of the tree   :   11

Time taken to build model: 0 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      465           92.8144 %
Incorrectly Classified Instances    36            7.1856 %

```

Fonte: Autoria própria.

5.2.1.3 Resultados com o Algoritmo JRip

A análise de dados do algoritmo JRip, utilizando a entrada com todos os níveis de dificuldades, as informações relevantes são no nível de dificuldade "médio" a pontuação em algumas partidas são atingidos 500 pontos, sendo que para atingir 1000 pontos (acertando todos os pares em sequência para aplicar o combo multiplicador de pontos) teria que acertar os 4 pares sem errar.

Na análise de dados somente com o conjunto de dados no nível de dificuldade "difícil" observou-se uma média acima de 30 tentativas em poucas partidas com um tempo alto, uma média acima de 15 tentativas de algumas partidas com um tempo médio, e um tempo até 2 segundos com quantidade de dicas menor que 1 e uma pontuação até 1300 pontos em um tempo médio.

Ao analisar as informações citadas nota-se que para o nível de dificuldade "difícil" serão necessárias uma maior quantidade de dicas para reduzir a quantidade de tentativas, aumentar a pontuação para que sejam realizados mais combos e conseqüentemente reduzir o tempo. No entanto, ainda é necessário reduzir o nível de dificuldade "difícil" para "médio" caso existam uma média acima de 30 tentativas e um tempo considerado alto. A figura 20 apresenta o resultado do algoritmo J48 em todos os níveis de dificuldades.

Figura 20 – Resultado do algoritmo JRip com todos os níveis de dificuldades

```

JRIP rules:
=====

(qtde_pares_combinado_certo <= 4) and (pontos >= 500) => nivel_jogo=MEDIO (13.0/0.0)
(tentativas <= 1) => nivel_jogo=SUPER_FACIL (80.0/26.0)
(qtde_erro <= 2) and (media_somatorio_carta_virada >= 0.25) and (pontos >= 300) => nivel_jogo=FACIL (44.0/0.0)
(qtde_erro <= 0) => nivel_jogo=FACIL (50.0/10.0)
=> nivel_jogo=DIFICIL (314.0/1.0)

Number of Rules : 5

Time taken to build model: 0.01 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances          458           91.4172 %
Incorrectly Classified Instances        43            8.5828 %

```

Fonte: Autoria própria.

5.2.2 Base de dados processada e conhecimentos obtidos

Nesta etapa com os dados refinados, obteve-se um conjunto de dados tratados com uma maior representatividade para a aplicação dos algoritmos de aprendizagem de máquina. O arquivo de CSV obtido em um primeiro momento possuía 17 colunas de atributos e 674 registros, após realizar o pré-processamento obteve-se 11 colunas e 502 registros. A figura 21 apresenta o conjunto de dados tratados.

Figura 21 – Conjunto de dados tratados e refinados

```

TEMPO_MIN_MAX;PONTOS;COMBO;TENTATIVAS;QTDE_CLIQUE_ESQUERDO;QTDE_ERRO;SUCESSO;QTDE_PARES_COMBINADO_CERTO;QTDE_PARES_DICA;MEDIA_SOMATORIO_CARTA_VIRADA;NIVEL_JOGO
0,00243309;100;1;1;4;0;1;1;0;0;0;0
0,01703163;300;2;2;6;0;1;2;0;2;1
0;0;0;0;1;0;0;0;0;0;0;0
0;0;0;0;2;0;0;0;0;0;0;0
0,063260341;500;2;6;16;2;1;4;0;1,17;2
0,0486618;600;2;5;12;1;1;4;0;1,4;2
0,03163017;1000;4;4;8;0;1;4;0;0,75;2
0,0486618;500;2;6;14;2;1;4;0;1,17;2
0,090024331;500;2;8;19;4;1;4;0;2;2
0,02676399;1000;4;4;12;0;1;4;0;0,5;2
0;0;0;0;1;0;0;0;0;0;0;0
0,201946472;1100;3;19;49;11;1;8;0;1,89;3
0,282238443;1000;2;24;56;16;1;8;2;2,13;3
0,199513382;1300;2;17;37;9;1;8;0;2,12;3
0,00243309;0;0;0;1;0;0;0;0;0;0;3
0;0;0;0;1;0;0;0;0;0;0;3
0;0;0;0;1;0;0;0;0;0;0;0
0,01703163;0;0;1;3;1;0;0;0;1;3
0,121654501;1400;3;15;33;7;1;8;0;0,93;3
0,0486618;0;0;4;10;4;0;0;0;1,25;3

```

Fonte: Autoria própria.

O refinamento do conjunto de dados permitiu uma análise aprimorada ao verificar os resultados ao aplicar os algoritmos de aprendizagem de máquina, pois antes deste procedimento

não eram apresentadas informações relevantes as quais pudessem ser utilizadas no *ScienceLearning*.

5.2.3 Ajustar o nível de dificuldade do jogo

O ajuste de nível de dificuldade do jogo da memória do *ScienceLearning* considera as informações obtidas e analisadas por meio da aplicação dos algoritmos de máquina *K-Means*, *JRip* e *J48* na ferramenta *Weka* (FRANK; HALL; WITTEN, 2021). Com base nos dados obtidos os ajustes foram realizados nos níveis de dificuldades "médio" e "difícil" em que as informações foram mais representativas.

A forma para realizar a mudança de nível de dificuldade no *ScienceLearning* é por meio de uma configuração manual, na qual pode-se escolher a quantidade de cartas a serem apresentadas ao acessar o jogo da memória, sendo 2, 4, 8, 16 cartas. Utilizando as informações obtidas por meio dos resultados dos algoritmos de aprendizagem de máquina as regras são aplicadas considerando os níveis de dificuldade "médio" e "difícil". De acordo com os resultados obtidos, somente estes níveis mostraram-se um desafio maior para o público do projeto.

A análise dos dados demonstra de forma geral que no nível de dificuldade "difícil" serão necessárias apresentar mais dicas para ampliar o número de combos. E se as tentativas ultrapassarem a quantidade de 15 em um tempo médio para finalização do jogo, será necessário reduzir o nível de dificuldade de "difícil" para "médio". O quadro 22 apresenta um resumo sobre os dados utilizados para modificação de nível de dificuldade no jogo da memória do *ScienceLearning*.

Quadro 22 – Ajustar o nível de dificuldade do jogo

Algoritmo	Resultado	Ação
<i>K-Means</i>	No nível de dificuldade "difícil", são feitas 3 tentativas e em média até 2 segundos para combinar um par de cartas	Apresentar mais dicas para aumentar o número de combos ou reduzir o nível de dificuldade para médio
<i>J48</i>	No nível de dificuldade "difícil", são feitas 8 tentativas para combinar um par de cartas	Apresentar mais dicas para aumentar o número de combos ou reduzir o nível de dificuldade para médio
<i>JRip</i>	No nível de dificuldade "médio" em algumas partidas são atingidos 500 pontos	Apresentar mais dicas para ampliar a quantidade de combos
<i>JRip</i>	No nível de dificuldade "difícil" uma média acima de 30 tentativas com um tempo alto e média acima de 15 tentativas de algumas partidas com um tempo médio. E um tempo até 2 segundos com quantidade de dicas menor que 1 e uma pontuação até 1300 pontos em um tempo médio.	Apresentar mais dicas para aumentar o número de combos ou reduzir o nível de dificuldade para médio

Fonte: Autoria própria.

5.2.4 Criar nova versão do jogo

A nova versão para o jogo da memória do *ScienceLearning* considerou os resultados obtidos por meio dos algoritmos de aprendizagem de máquina para criar as regras de ajustes de nível de dificuldade para o público participante deste projeto. As regras adicionadas aplicadas aos níveis de dificuldades "médio" e "difícil", considerando:

- Nos níveis de dificuldades "médio" e "difícil", apresentar uma dica para combinação de carta, a cada 3 tentativas.
- No nível de dificuldade "difícil", se em uma partida anterior o jogador possuir uma quantidade acima de 30 tentativas ou possuir um tempo médio, ao acessar novamente o jogo, será reduzido o nível para "médio".

Os níveis de dificuldades "super fácil" e "fácil", os quais contém 2 e 4 cartas, respectivamente, não serão ajustados com os dados coletados em razão dos resultados obtidos não serem representativos para aplicar alguma regra sobre as informações analisadas.

5.3 COMPARATIVOS DE TRABALHOS RELACIONADOS COM O *SCIENCELEARNING*

Com base nos trabalhos analisados por meio do mapeamento sistemático, foi realizada uma comparação com o jogo do *ScienceLearning* em relação ao tipo de jogo e aplicação de algoritmo de aprendizagem de máquina no desenvolvimento de jogos sérios. Os tipos dos jogos analisados nos trabalhos relacionados são diversificados, sendo de corrida (COWLEY *et al.*, 2014), ambiente *web* gamificado (BARATA *et al.*, 2016), esportes, ação, estratégia e RPG (BHARATHI *et al.*, 2016), aventura (LLORENS-LARGO *et al.*, 2016), Ambiente *mobile* gamificado (SIU *et al.*, 2018) e o *ScienceLearning* que é um jogo da memória. O quadro 23 apresenta o tipo dos jogos e o público de aplicação nos trabalhos avaliados em relação ao *ScienceLearning*.

Quadro 23 – Tipo dos jogos e o público de aplicação dos trabalhos avaliados em relação ao *ScienceLearning*

Jogos	Tipo de Jogo	Jogos sérios	Multiplataforma	Público
<i>Super Monkey Ball 2</i> (COWLEY <i>et al.</i> , 2014)	Corrida	Não	Não	Infantil e adulto
<i>MCP Quest e Skill Tree</i> (BARATA <i>et al.</i> , 2016)	Ambiente <i>web</i> gamificado	Sim	Sim	Adulto
Diversos jogos da <i>Google Play</i> (BHARATHI <i>et al.</i> , 2016)	Esportes, Ação, Estratégia e RPG	Não	Não	Infantil e Adulto
<i>Pacman</i> (LLORENS-LARGO <i>et al.</i> , 2016)	Aventura	Não	Não	Adulto e infantil
<i>Romeo e Julieta</i> (SIU <i>et al.</i> , 2018)	Ambiente <i>mobile</i> gamificado	Sim	Não	Adulto
<i>ScienceLearning</i>	Memória	Sim	Sim	Adulto com deficiência intelectual

Fonte: Autoria própria.

Os jogos sérios são aplicados nos trabalhos de Barata *et al.* (2016), Siu *et al.* (2018) e no *ScienceLearning*, os demais jogos são interativos e não tem o objetivo de consolidar o conhecimento em uma determinada área. E somente o trabalho de Barata *et al.* (2016) e o *ScienceLearning* são multiplataformas, pois podem ser executados via computador e *smartphones*. Os jogos *MCP Quest e Skill Tree* de Barata *et al.* (2016) por utilizar uma plataforma *web* pode ser acessado via computador ou *mobile*. O *ScienceLearning* é um jogo *mobile*, que neste trabalho foi gerado para o sistema *Android*, mas pode ser gerado o executável para utilização em computadores.

Em relação ao público de aplicação, os jogos dos trabalhos de Cowley *et al.* (2014), Bharathi *et al.* (2016) e Llorens-Largo *et al.* (2016) são aplicados ao público infantil e adulto. Os jogos dos trabalhos de Barata *et al.* (2016) e Siu *et al.* (2018) são voltados para o público adulto. Porém, somente o *ScienceLearning* é voltado para o público adulto com deficiência intelectual.

Os jogos analisados possuem uma semelhança ao aplicarem a maioria dos elementos de gamificação. Porém, os trabalhos de Cowley *et al.* (2014), Bharathi *et al.* (2016) e Llorens-Largo *et al.* (2016) utilizam avatares que é um componente de gamificação. O trabalho de Siu *et al.* (2018) é o que aplica menos elementos de gamificação e em relação aos demais jogos não aplica *Rankings*, Níveis e Conquistas. O jogo do *ScienceLearning* possui a maioria dos elementos de gamificação em relação aos demais jogos, porém não aplica a utilização de Avatar, Missões e *Rankings*. O quadro 24 descreve os elementos de gamificação aplicados nos trabalhos analisados em relação ao *ScienceLearning*.

Quadro 24 – Elementos de gamificação aplicados nos trabalhos avaliados em relação ao *ScienceLearning*

Jogos	Elementos de gamificação
<i>Super Monkey Ball 2</i> (CO-WLEY <i>et al.</i> , 2014)	Emocional, Narrativa, Progressão, Restrição, Tentativas, Desafios, <i>Feedback</i> , <i>Rankings</i> , Recompensas, Sucesso, Conquistas, Níveis, Pontos, Avatar
<i>MCP Quest e Skill Tree</i> (BARATA <i>et al.</i> , 2016)	Emocional, Narrativa, Progressão, Restrição, Tentativas, Desafios, <i>Feedback</i> , <i>Rankings</i> , Missões, Recompensas, Sucesso, Conquistas, Níveis, Pontos
Diversos jogos da <i>Google Play</i> (BHARATHI <i>et al.</i> , 2016)	Emocional, Narrativa, Progressão, Restrição, Tentativas, Desafios, <i>Feedback</i> , <i>Rankings</i> , Missões, Recompensas, Sucesso, Conquistas, Níveis, Pontos, Avatar
<i>Pacman</i> (LLORENS-LARGO <i>et al.</i> , 2016)	Emocional, Progressão, Restrição, Tentativas, Desafios, <i>Feedback</i> , <i>Rankings</i> , Recompensas, Sucesso, Conquistas, Níveis, Pontos, Avatar
<i>Romeo e Julieta</i> (SIU <i>et al.</i> , 2018)	Emocional, Narrativa, Progressão, Restrição, Tentativas, Desafios, <i>Feedback</i> , Sucesso, Pontos
<i>ScienceLearning</i>	Emocional, Narrativa, Progressão, Restrição, <i>Feedback</i> , Tentativas, Desafios, Turnos, Sucesso, Conquistas, Níveis, Pontos

Fonte: Autoria própria.

Outros recursos analisados nos trabalhos foram os algoritmos de aprendizagem de máquina utilizados, pois no *ScienceLearning* os algoritmos aplicados foram para obter as informações das partidas realizadas do agrupamento de dados com o *K-Means* e modelos de decisão com os algoritmos de classificação *J48* e *JRip*. O quadro 25 apresenta os algoritmos utilizados nos trabalhos avaliados em relação ao *ScienceLearning*.

Quadro 25 – Algoritmos de aprendizagem de máquina utilizados em relação ao *ScienceLearning*

Jogos	Algoritmos utilizados
<i>Super Monkey Ball 2</i> (CO-WLEY <i>et al.</i> , 2014)	<i>Frequent Pattern Growth</i> e <i>K-Means</i>
<i>MCP Quest e Skill Tree</i> (BARATA <i>et al.</i> , 2016)	<i>Expectation Maximization Algorithm</i> (EM), <i>Naive Bayes</i> , <i>Redes Bayesianas</i> , <i>Sequential Minimal Optimization</i> (SMO), <i>Logistic Regression</i> e <i>K-Nearest Neighbors</i> (KNN)
Diversos jogos da <i>Google Play</i> (BHARATHI <i>et al.</i> , 2016)	<i>Support Vector Machine</i> (SVM), <i>Naive Bayes</i> , <i>IBK</i> , <i>Decision Trees</i> , <i>Random Forest</i> , <i>Sequential Minimal Optimization</i> (SMO) e <i>J48</i>
<i>Pacman</i> (LLORENS-LARGO <i>et al.</i> , 2016)	<i>Support Vector Machine</i> (SVM)
<i>Romeo e Julieta</i> (SIU <i>et al.</i> , 2018)	<i>Decision Trees</i> , <i>Support Vector Machine</i> (SVM) e <i>K-Nearest Neighbor</i> (KNN)
<i>ScienceLearning</i>	<i>K-Means</i> , <i>JRip</i> e <i>J48</i>

Fonte: Autoria própria.

Os jogos foram avaliados para verificar quais são as funcionalidades existentes nos trabalhos desenvolvidos. A funcionalidade disponibilizada em todos os trabalhos é a de Efeito Visual e Sonoro. E uma outra funcionalidade recorrente é o Aumento de dificuldade a medida que etapas dos jogos são superadas. E de acordo com o tipo do jogo são criadas funcionalidades

específicas para atender o contexto de aplicação, como o exemplo da funcionalidade de *Login* no trabalho Barata *et al.* (2016) e no *ScienceLearning*. O quadro 26 apresenta as funcionalidades dos jogos nos trabalhos analisados.

Quadro 26 – Funcionalidades dos jogos em relação ao *ScienceLearning*

Jogos	Funcionalidades
<i>Super Monkey Ball 2</i> (COWLEY <i>et al.</i> , 2014)	Controle de pista de corrida, Aumento de dificuldade, Efeitos Visuais e Sonoros
<i>MCP Quest e Skill Tree</i> (BARATA <i>et al.</i> , 2016)	<i>Login</i> , Controle de missões e artefatos, Aumento de dificuldade, Efeitos Visuais e Sonoros, Controle de Texto
Diversos jogos da <i>Google Play</i> (BHARATHI <i>et al.</i> , 2016)	Controle diversos de esportes, corridas, RPG, Aumento de dificuldade, e Efeitos Visuais e Sonoros
<i>Pacman</i> (LLORENS-LARGO <i>et al.</i> , 2016)	Controle de Labirinto, Aumento de dificuldade, Efeitos Visuais e Sonoros
<i>Romeo e Julieta</i> (SIU <i>et al.</i> , 2018)	Controle de Questionários, Efeitos Visuais e Sonoros
<i>ScienceLearning</i>	<i>Login</i> , Controle de cartas e tabuleiros, Efeitos Visuais, Gerenciamento de texto, Controle Sonoro e Registro de Eventos

Fonte: Autoria própria.

Uma das diferenças relevante entre o *ScienceLearning* e os trabalhos de Cowley *et al.* (2014), Barata *et al.* (2016), Bharathi *et al.* (2016), Llorens-Largo *et al.* (2016) e Siu *et al.* (2018), é que apesar de utilizarem banco de dados para facilitar a obtenção de conhecimentos, não foi realizada uma definição e seleção de atributos, e como estes podem contribuir na aplicação de algoritmos de aprendizagem de máquina em jogos sérios para ajuste de nível de dificuldade. As informações obtidas após a aplicação do algoritmo de aprendizagem de máquina são utilizadas para compreender a aprendizagem do aluno e as execuções de suas atividades, porém não visam a obtenção de resultados para criar índices e regras para uma possível automatização no nível de dificuldade dos jogos.

5.4 SOLUÇÃO PARA EXPERIMENTOS FUTUROS

Para ajustar o nível de dificuldade do jogo da memória do *ScienceLearning* de forma otimizada, serão utilizados os dados obtidos pelo algoritmo de aprendizagem de máquina considerando os níveis em que o jogador possui uma maior dificuldade de interação. A dificuldade em interagir com jogo se relaciona diretamente com a motivação e o engajamento do jogador, podendo ser um fator de desistência para indivíduos com uma condição intelectual desproporcional ao jogo praticado (TORRENTE *et al.*, 2012).

A aplicação do algoritmo de aprendizagem de máquina sobre um conjunto de dados apresenta resultados, os quais podem ser utilizados para definir índices quantitativos e modificar

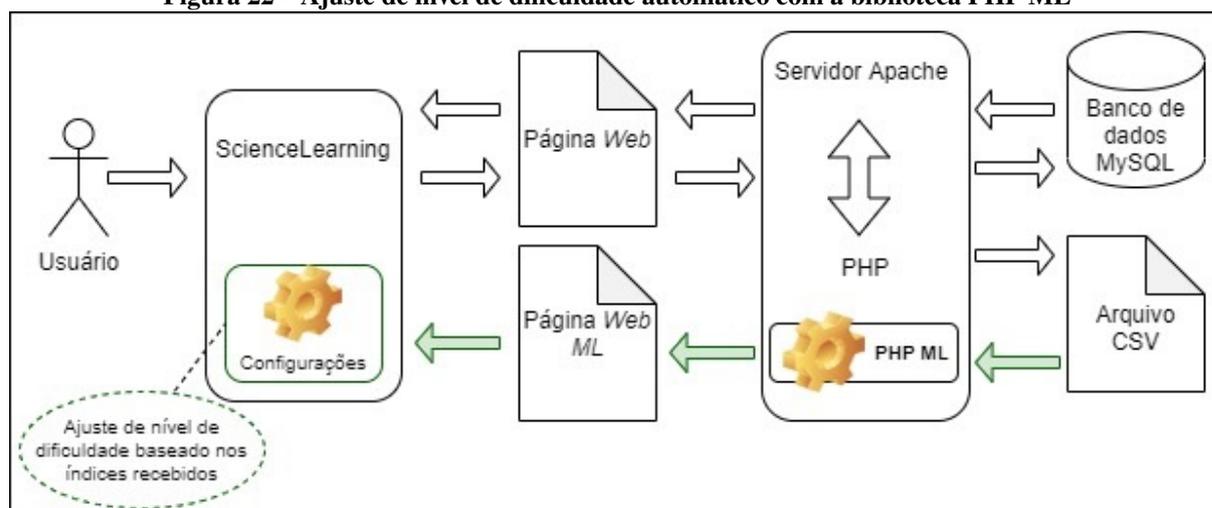
os níveis de dificuldades e aplicar regras sobre o jogo em questão. Para o *ScienceLearning*, conforme os resultados obtidos pela aplicação do algoritmos de aprendizagem de máquina, os índices a serem considerados são relacionados ao nível de dificuldade, a quantidade de tentativas, a quantidade de dicas e o tempo utilizado para finalização de uma partida.

O ajuste de nível de dificuldade de forma automática para o jogo de memória do *ScienceLearning* considera os índices obtidos aplicando os algoritmos de aprendizagem de máquina (ver seção 5.2.3) usando o conjunto de dados utilizados em um primeiro momento, mas sendo incrementado novos valores a medida que novas interações forem realizadas.

A coleta de dados em novas partidas serão adicionados na base de dados em *MySQL* e com o preenchimento do arquivo em CSV (Valores Seprados por Vírgulas) para aplicação dos algoritmos de aprendizagem de máquina previamente utilizados neste mesmo contexto, sendo o *K-Means*, *JRip* e *J48*. Após a nova execução dos algoritmos de aprendizagem de máquina, verificar se os índices tiveram alguma diferença em relação ao resultado anterior em relação ao nível de dificuldade considerando a quantidade de tentativas, a quantidade de dicas e o tempo de interação para finalização de uma partida.

Para a mudança de nível de dificuldade poderá ser utilizada a biblioteca PHP-ML (KONDAS, 2021), a qual contém diversos algoritmos de aprendizagem de máquina, que permite aplicar algoritmos de aprendizagem de máquina em um conjunto de dados em arquivo em CSV e obter informações para ajustar os índices de um jogo. A requisição da biblioteca PHP-ML é realizada por meio de páginas web usando PHP. A figura 22 apresenta a aplicação da biblioteca PHP-ML sobre os dados obtidos do jogo de memória do *ScienceLearning*, as quais estão destacadas com as setas na cor verde.

Figura 22 – Ajuste de nível de dificuldade automático com a biblioteca PHP ML



Fonte: Autoria própria.

Após realizar a aplicação de algoritmos de aprendizagem de máquina e obter os resultados por meio de página em PHP, os índices são comparados com os valores anteriormente obtidos para efetuar a mudança do nível de dificuldade. Com isso, o método TGL-ML será otimizado.

zado para que os níveis de dificuldades sejam alterados conforme os índices e resultados obtidos forem sendo modificados com a regra inicial definida.

5.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo apresentou os resultados obtidos utilizando o método *Tuning Game Level by Machine Learning* (TGL-ML), o qual foi aplicado com a criação do jogo *ScienceLearning* e as suas funcionalidades. A aplicação do jogo foi realizada de forma remota, em razão da pandemia da Covid-19, em uma instituição de ensino e foi um processo desafiador pois existiram dificuldades técnicas de distribuição do jogo que tiveram que ser adaptadas. E apesar das adversidades, a participação dos alunos e dos professores foi importante para aprimoramento das funcionalidades do jogo.

A utilização do jogo pelos alunos permitiu a coleta de dados para que os algoritmos de aprendizagem de máquina apresentassem resultados mais precisos e próximos do perfil destes participantes. A partir dos resultados obtidos pelos algoritmos *K-Means*, J48 e JRip, foi possível obter com base nos atributos definidos, quais índices e regras podem ser adotados para um ajuste de nível de dificuldade de forma automatizada, gerando uma nova versão do jogo do *ScienceLearning*. A aplicação dos algoritmos também permitiu confirmar a informação de que os alunos da instituição de ensino estão habituados a praticar atividades como o jogo da memória. Para uma quantidade de até 8 cartas, nível "médio" de dificuldade atribuído no jogo do *ScienceLearning*, os alunos não tiveram muitas dificuldades em interagir com o jogo.

O ajuste de nível de dificuldade com a aplicação de algoritmos de aprendizagem de máquina é possível, conforme descrito na seção 5.4. Porém, as informações do público alvo terão que ser coletadas em uma primeira etapa conforme descrito no método *Tuning Game Level by Machine Learning* (TGL-ML). Com isso, os dados precisarão ser pré-processados e na sequência aplicar os algoritmos de aprendizagem retornando os índices e regras para o jogo a fim de ajustar os níveis de dificuldades.

O comparativo dos trabalhos observados no mapeamento sistemático permitiu identificar os tipos de jogos, se são jogos sérios e multiplataforma, quais são os elementos de gamificação e os algoritmos de aprendizagem de máquina, e o tipo de público alvo das aplicações. E notou-se que os jogos ainda não são voltados para o público com deficiência intelectual como o *ScienceLearning* foi aplicado.

Por fim, a solução para experimentos futuros para ajuste de nível de jogo observada durante o desenvolvimento permitirá automatizar e otimizar o *ScienceLearning* para o público alvo.

6 CONCLUSÃO

A utilização de jogos sérios em ambientes educacionais promovem uma aprendizagem aprimorada e dinâmica, pois os jogos sérios facilitam a compreensão do aluno por meio de experiências obtidas durante as partidas e podem ser relacionadas com atividades exercidas em sua vida diária. Porém, os jogos sérios para pessoas com deficiência intelectual é uma área a ser explorada, pois isto é um desafio para professores de educação inclusiva em razão do ritmo de assimilação de conteúdo e os procedimentos de ensino serem mais lentos em virtude de sua condição motora e cognitiva (VINENTE; GALVANI, 2019).

Ao desenvolver jogos sérios para pessoas com deficiência intelectual, as técnicas de gamificação sendo relacionadas ao contexto educacional permitem envolver e motivar os alunos a aprenderem de forma interativa estimulando-os a se desafiarem perante as adversidades apresentadas pelos jogos. Neste ponto, a gamificação impacta nas próprias atividades e no comportamento do jogador fazendo com que o seu desenvolvimento cognitivo seja relacionado a manter a atenção, memorizar elementos do jogo, e planejar as suas jogadas (SCHMITZ; KLEMKE; SPECHT, 2012), além de obter novos conhecimentos a medida que realiza as partidas .

Durante o desenvolvimento do método *Tuning Game Level by Machine Learning* (TGL-ML) para ajuste de nível de dificuldade em jogos sérios fundamentado em aprendizagem de máquina, que foi aplicado na criação do jogo da memória *ScienceLearning* desenvolvido neste trabalho, foi possível conhecer e definir as características do público alvo, utilizar o tema e conteúdo de Segurança Alimentar, e aplicar elementos de gamificação para aproximar a realidade vivenciada pelos alunos da instituição. Além disso, com a aplicação do jogo notou-se o engajamento e a motivação dos alunos em interagir com o jogo e aprender de forma interativa os conteúdos vistos nas atividades escolares.

A aplicação do jogo na instituição de ensino, foi um experimento interessante e gratificante pois além da escola contribuir com o aprimoramento das funcionalidades do *ScienceLearning*, um dos seis alunos continuou jogando diariamente sendo constatado por meio da observação de eventos das partidas na base de dados. Dessa forma, nota-se que o emocional dos jogadores foi provocado a interagir diversas vezes com o jogo, o qual contém elementos da gamificação e requisitos educacionais direcionados a ele.

Outro ponto importante é que o *ScienceLearning* possibilitou a definição dos atributos a fim de obter índices e regras por meio da aplicação dos algoritmos de aprendizagem de máquina. Os atributos definidos para a coleta de dados puderam ser pré-processados de forma consistente para que os algoritmos *K-Means*, o JRip e o J48, apresentassem resultados para uma análise mais detalhada e precisa. Os resultados também permitiram propor uma solução para o ajuste de nível de dificuldade de forma automatizada a ser gerada em uma nova versão do jogo do *ScienceLearning*.

Por fim, a aplicação do método *Tuning Game Level by Machine Learning* (TGL-ML)

possibilita elaborar jogos, com uma definição adequada de atributos para um determinado público alvo, e aplicar os jogos para obter os registros de eventos das partidas para posterior aplicação de algoritmo de aprendizagem de máquina. E após a utilização de algoritmos de aprendizagem de máquina, os índices e regras obtidos podem ser analisados e avaliados para aprimorar os níveis de dificuldade de forma automatizada e personalizada ao público alvo. Sendo que a realização de ajuste de nível de dificuldade permitirá motivar e manter o jogador interagindo com o jogo perante as suas dificuldades e limitações intelectuais.

6.1 TRABALHOS FUTUROS

Os trabalhos futuros irão contemplar a otimização do método *Tuning Game Level by Machine Learning* (TGL-ML) para o jogo da memória do *ScienceLearning*:

- Acrescentar novos conteúdos relacionados ao tema de Segurança Alimentar.
- Adicionar a escolha de novos temas e conteúdos relacionados com a área de ciências.
- Utilizar outros algoritmos de aprendizagem de máquina sobre a base de dados normalizada.
- Adicionar novos elementos de gamificação que não foram incluídos como avatares, *ranking* e fase bônus.
- Aplicar uma otimização no ajuste de nível de dificuldades em tempo de execução, utilizando algoritmos de aprendizagem de máquina por reforço.

Os novos conteúdos para o jogo da memória poderão as informações nutricionais de cada alimento, a quantidade a ser consumida durante o dia e os cuidados com a manipulação com os alimentos, para que os jogadores obtenham informações adequadas de uma alimentação saudável e segura.

A adição de novos temas e conteúdos relacionados na área de ciências permitindo a configuração do jogo com a escolha do tema desejado, de acordo com a necessidade da instituição, em que o personagem apresente o uso e benefícios do tema tratado.

A utilização de outros algoritmos de aprendizagem de máquina sobre a base de dados poderão apresentar outros agrupamentos e classificações de dados. As informações obtidas poderão ser considerados para otimizar o jogo para o público alvo.

Os novos elementos de gamificação como avatares, *ranking* e fase bônus, terão o objetivo de motivar o jogador a superar os desafios do jogo da memória de forma mais interativa. Ao usar um avatar, o jogador poderá se identificar com um determinado personagem para realizar as partidas. O *ranking* seria vinculado ao tempo e pontuação dentre os níveis de dificuldades na

realização de uma partida sendo apresentado em um quadro de classificação geral de jogadores. A fase bônus teria o intuito de motivar o jogador a realizar uma partida sem errar os pares de cartas e acessar uma fase bônus para obter uma pontuação adicional.

Ao aplicar um algoritmo de aprendizagem por reforço, seria utilizado um agente inteligente que se adaptaria com base no tempo gasto para finalização, quantidade de erros, quantidade de dicas e as pontuações obtidas nas partidas do jogo da memória que forem realizadas por um jogador. Na aprendizagem por reforço, todas as informações coletadas com os atributos previamente definidos no banco de dados do *ScienceLearning*, poderão ser utilizadas para treinar o agente para que ele próprio ajuste os níveis de dificuldades existentes no jogo da memória conforme a dificuldade do jogador.

Outros trabalhos futuros para o *ScienceLearning* seria a criação de uma miscelânea de jogos relacionados ao conteúdo e o tema de ciências. O objetivo de criar novos tipos de jogos seria identificar novos atributos, os quais poderão ser diferentes comparados ao jogo da memória em razão da dinâmica e mecânica dos jogos. Os novos atributos poderão ser explorados também com a aplicação de algoritmos de aprendizagem de máquina com o intuito de identificar novos aspectos e comportamentos dos jogadores de um determinado público alvo.

A criação de outros tipos de jogos também contribuiria para a criação de uma base de dados, a qual poderá ser consolidada com as informações do público alvo a fim de obter informações mais precisas sobre o perfil do jogadores.

REFERÊNCIAS

- AAIDD, Inc. **American Association on Intellectual and Developmental Disabilities**. AAIDD, 2020. Disponível em: <<https://www.aaid.org/intellectual-disability/definition/faqs-on-intellectual-disability>>. Acesso em: 06 abr. 2020.
- ABRAFRUTAS. **Associação Brasileira dos Produtores Exportadores de Frutas e Derivados**. 2021. Disponível em: <<https://abrafrutas.org/2021/06/as-10-frutas-mais-consumidas-no-brasil-confira-a-lista-das-preferidas/>>. Acesso em: 26 jul. 2021.
- AGENDA 2030. **Os 17 Objetivos de Desenvolvimento Sustentável**. PNUD BRASIL, 2021. Disponível em: <<http://www.agenda2030.com.br/ods/2/>>. Acesso em: 14 ago. 2021.
- AHA, David W.; KIBLER, Dennis; ALBERT, Marc K. Instance-based learning algorithms. **Machine Learning**, Springer, USA, v. 6, n. 1, p. 37–66, jan 1991. ISSN 1573-0565. Disponível em: <<https://doi.org/10.1007/BF00153759>>.
- ALANNE, Kari. An overview of game-based learning in building services engineering education. **European Journal of Engineering Education**, v. 41, n. 2, p. 204–219, 2016. ISSN 14695898.
- ALHAMMAD, Manal M.; MORENO, Ana M. Gamification in software engineering education: A systematic mapping. **Journal of Systems and Software**, v. 141, p. 131–150, 2018. ISSN 01641212. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0164121218300645>>.
- ALPAYDIN, Ethem. **Introduction to Machine Learning**. 3. ed. Cambridge, MA: MIT Press, 2014. (Adaptive Computation and Machine Learning). ISBN 978-0-262-02818-9.
- ALVAREZ, Julian; DJAOUTI, Damien; RAMPNOUX, Olivier. **A Collaborative Classification of Serious Games**. Ludoscience Studying Video Games, 2020. Disponível em: <<http://serious.gameclassification.com/EN/index.html>>. Acesso em: 01 jan. 2020.
- APA. **Manual diagnóstico e estatístico de transtornos mentais. DSM-5**. Porto Alegre: Artmed, 2013. 976 p.
- APACHE, The Apache Software Foundation. **Apache**. The Apache Software Foundation, 2021. Disponível em: <<https://www.apache.org/>>. Acesso em: 05 jun. 2021.
- AWAD, Mariette; KHANNA, Rahul. Machine learning. In: _____. **Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers**. Berkeley, CA: Apress, 2015. p. 1–18. ISBN 978-1-4302-5990-9. Disponível em: <https://doi.org/10.1007/978-1-4302-5990-9_1>.
- AYODELE, Taiwo Oladipupo. Types of machine learning algorithms. In: **New Advances in Machine Learning, Yagang Zhang, IntechOpen**. [s.n.], 2010. p. 1–32. ISBN 9789533070346. Disponível em: <<https://doi.org/10.5772/9385>>.
- BARATA, Gabriel *et al.* Early Prediction of Student Profiles Based on Performance and Gaming Preferences. **IEEE Transactions on Learning Technologies**, v. 9, n. 3, p. 272–284, 2016. ISSN 19391382.

- BARTOLOME, Nuria Aresti; ZORRILLA, Amaia Méndez; ZAPIRAIN, Begona García. A serious game to improve human relationships in patients with neuro-psychological disorders. In: **2010 2nd International IEEE Consumer Electronics Society's Games Innovations Conference**. [S.l.: s.n.], 2010. p. 1–5.
- BELIK, Walter. Perspectivas para segurança alimentar e nutricional no brasil. **Saúde e Sociedade**, v. 12, n. 3, p. 12–20, jun 2003. ISSN 1984-0470.
- BHARATHI, Ajay *et al.* Knowledge discovery of game design features by mining user-generated feedback. **Computers in Human Behavior**, v. 60, p. 361–371, 07 2016.
- BIGDELI, Shoaleh; KAUFMAN, David. Digital games in medical education:key terms, concepts, and definitions. **Medical Journal of the Islamic Republic of Iran (MJIRI)**, Iran University of Medical Sciences, v. 31, p. 1–7, sep 2017. Disponível em: <<https://doi.org/10.14196/mjiri.31.52>>.
- BODNAR, Cheryl A. *et al.* Engineers at Play: Games as Teaching Tools for Undergraduate Engineering Students. **Journal of Engineering Education**, v. 105, n. 1, p. 147–200, 2016. ISSN 10694730.
- BOONE, Randall; HIGGINS, Kyle. The software -list: Evaluating educational software for use by students with disabilities. **Journal of Special Education Technology**, v. 27, p. 50–63, 03 2012.
- BORGELT, Christian. An implementation of the fp-growth algorithm. In: **Proceedings of the 1st International Workshop on Open Source Data Mining: Frequent Pattern Mining Implementations**. New York, NY, USA: Association for Computing Machinery, 2005. (OSDM '05), p. 1–5. ISBN 1595932100. Disponível em: <<https://doi.org/10.1145/1133905.1133907>>.
- BORGES, Rosemary *et al.* A systematic review of literature on methodologies, practices, and tools for programming teaching. **IEEE Latin America Transactions**, v. 16, p. 1468–1475, 05 2018.
- BORGES, Simone De Sousa *et al.* A systematic mapping on gamification applied to education. In: **Proceedings of the ACM Symposium on Applied Computing**. New York, NY, USA: ACM, 2014. (SAC '14), p. 216–222. ISBN 9781450324694.
- BOTELHO, André Luiz Pedro; OLIVEIRA, Patrick Alves Gandra; GIGLIO, Giuliano Prado de Moraes. Gamificação para a inclusão de deficientes no âmbito escolar. **Revista de trabalhos acadêmicos – Universo Juiz de Fora**, v. 5, p. 1–14, 2017. ISSN 2179-1589.
- BOZKURT, Aras; DURAK, Gürhan. A systematic review of gamification research: In pursuit of homo ludens. **International Journal of Game-Based Learning**, v. 8, n. 3, p. 15–33, 2018. ISSN 21556857.
- BRASIL, Ministério da Educação. **Política Nacional de Educação Especial na Perspectiva da Educação Inclusiva**. SECADI, 2019. Disponível em: <http://portal.mec.gov.br/index.php?option=com_docman&view=download&alias=16690-politica-nacional-de-educacao-especial-na-perspectiva-da-educacao-inclusiva-05122014&Itemid=30192>. Acesso em: 30 nov. 2019.
- _____. **Educação de Jovens e Adultos (EJA)**. Ministério da Educação, 2021. Disponível em: <<http://portal.mec.gov.br/component/tags/tag/32737-eja>>. Acesso em: 17 jun. 2021.

- BREIMAN, Leo. Random forests. **Machine Learning**, Kluwer Academic Publishers, USA, v. 45, n. 1, p. 5—32, oct 2001. ISSN 0885-6125. Disponível em: <<https://doi.org/10.1023/A:1010933404324>>.
- BRITO, André; MADEIRA, Charles. Metodologias gamificadas para a educação: uma revisão sistemática. **Anais do XXVIII Simpósio Brasileiro de Informática na Educação (SBIE 2017)**, v. 1, p. 133, 2017.
- BURLANDY, Luciene. Segurança alimentar e nutricional e saúde pública. **Cadernos de Saúde Pública**, v. 24, n. 7, p. 12–20, jul 2008. ISSN 1678-4464.
- CAGATAY, Mehmet *et al.* A serious game for speech disorder children therapy. In: **7th International Symposium on Health Informatics and Bioinformatics (HIBIT)**. [S.l.]: IEEE Xplore Digital Library, 2012. p. 18–23.
- CALDERÓN, Alejandro *et al.* Teaching software processes and standards: a review of serious games approaches. **Communications in Computer and Information Science**, v. 918, p. 154–166, 2018. ISSN 18650929.
- CANDEL, Diego *et al.* A sequential minimal optimization algorithm for the all-distances support vector machine. In: **Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. p. 484–491. ISBN 978-3-642-16687-7.
- CHANDRASEKAR, Priyanga *et al.* Improving the prediction accuracy of decision tree mining with data preprocessing. In: **2017 IEEE 41st Annual Computer Software and Applications Conference (COMPSAC)**. [S.l.: s.n.], 2017. v. 2, p. 481–484.
- CHOU, Yu-kai. **A Collaborative Classification of Serious Games**. Gamification and Behavioral Design, 2020. Disponível em: <<https://yukaichou.com/gamification-examples/>>. Acesso em: 07 jan. 2020.
- CLASSDOJO. **ClassDojo**. ClassDojo, Inc, 2020. Disponível em: <<https://www.classdojo.com/>>. Acesso em: 27 fev. 2020.
- CORDERO-BRITO, Staling; MENA, Juanjo. Gamification in the social environment: A tool for motivation and engagement. In: **ACM International Conference Proceeding Series**. New York, NY, USA: ACM, 2018. (TEEM'18), p. 640–643. ISBN 9781450365185. Disponível em: <<http://doi.acm.org/10.1145/3284179.3284286>>.
- CORTES, Corinna; VAPNIK, Vladimir. Support-vector networks. **Machine Learning**, Kluwer Academic Publishers, USA, v. 20, n. 3, p. 273—297, sep 1995. ISSN 0885-6125. Disponível em: <<https://doi.org/10.1023/A:1022627411411>>.
- COWLEY, Benjamin *et al.* Experience Assessment and Design in the Analysis of Gameplay. **Simulation and Gaming**, SAGE Publications Sage CA: Los Angeles, CA, v. 45, n. 1, p. 41–69, 2014. ISSN 1552826X.
- CUNHA, Rafael Moreira. **Desenvolvimento e avaliação de um jogo de computador para ensino de vocabulário para crianças com autismo**. Dissertação (Mestrado) — Pontifícia Universidade Católica Do Rio De Janeiro - PUC-RIO, 2011.

DEMPSTER, Arthur P.; MCKENZIE, Laird Nan; BRUC, Rubin Donald. Maximum likelihood from incomplete data via the em algorithm. **Journal of the Royal Statistical Society. Series B (Methodological)**, [Royal Statistical Society, Wiley], v. 39, n. 1, p. 1–38, 1977. ISSN 00359246. Disponível em: <<http://www.jstor.org/stable/2984875>>.

DENDEN, Mouna *et al.* Educational gamification based on personality. **Proceedings of IEEE/ACS International Conference on Computer Systems and Applications, AICCSA**, v. 2017-October, p. 1399–1405, 2018. ISSN 21615330.

DETERDING, Sebastian *et al.* Gamification: Toward a definition. In: **CHI 2011 Gamification Workshop Proceedings**. [S.l.: s.n.], 2011. p. 12–15.

DIAS, Sueli de Souza; OLIVEIRA, Maria Cláudia Santos Lopes de. Deficiência intelectual na perspectiva histórico-cultural: contribuições ao estudo do desenvolvimento adulto. **Revista Brasileira de Educação Especial**, v. 19, p. 169–182, 2013. ISSN 1413-6538. Acesso em: 16 jan. 2020.

DICHEVA, Darina *et al.* Gamification in education: A systematic mapping study. **Educational Technology and Society**, v. 18, n. 3, p. 75–88, 2015. ISSN 14364522.

DOMINGUEZ, Adrián *et al.* Gamifying learning experiences: Practical implications and outcomes. **Computers and Education**, v. 63, p. 380–392, 04 2013. ISSN 03601315.

DOWN, Fundação Síndrome de. **O que é Síndrome de Down?** Fundação Síndrome de Down, 2019. Disponível em: <<http://www.fsdown.org.br/sobre-a-sindrome-de-down/o-que-e-sindrome-de-down/>>. Acesso em: 30 nov. 2019.

ECK, Richard Van. Saps and digital games: Improving mathematics transfer and attitudes in schools. **Digital Games and Mathematics Learning**, Springer, Dordrecht, v. 2015, p. 141–173, oct 2015.

FARRINGTON, Jeanne. From the research: myths worth dispelling: seriously, the game is up. **International Society for Performance Improvement**, v. 24, p. 105–110, 2011.

FERREIRA, Gabriel Alves dos Santos *et al.* Apae games: Um jogo digital como ferramenta de aprendizagem para crianças com deficiência intelectual. In: **Proceedings - SB Games**. [S.l.: s.n.], 2018. p. 1–5.

FONSECA, Gessica Fabiely. **Planejamento e práticas curriculares nos processos de alfabetização de alunos com deficiência intelectual: experiências e trajetórias em tempos de educação inclusiva**. Tese (Doutorado) — Programa de Pós-Graduação em Educação, Universidade Federal do Rio Grande do Norte, UFRN, 2016.

FRANK, Eibe; HALL, Mark A.; WITTEN, Ian H. **The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques"**. Morgan Kaufmann, 2021. Disponível em: <<https://www.cs.waikato.ac.nz/ml/weka/index.html>>.

FREITAS, Maria Clara de. **Construção de um programa de ensino de pré-requisitos de leitura e escrita para pessoas com deficiência intelectual**. Tese (Doutorado) — Programa de Pós-Graduação em Psicologia, Universidade Federal de São Carlos, UFSCar, 2012.

GARCIA DA LUZ, Vinicius Schultz *et al.* A systematic mapping on machine learning algorithms and gamification applied to education. In: INSTICC. **Proceedings of the 13th International Conference on Computer Supported Education - CSEDU**. [S.l.]: SciTePress, 2021. v. 2, p. 353–361. ISBN 978-989-758-502-9. ISSN 2184-5026.

GARMEN, P. *et al.* Inteligencias múltiples y videojuegos: Evaluación e intervención con software toi. **Revista Comunicar**, v. 23, p. 95–104, 2019.

_____. **El Potencial de los Videojuegos Para Intervenir con Dificultades de Aprendizaje**. Novática 240, 2020. Disponível em: <<https://www.novatica.es/el-potencial-de-los-videojuegos-para-intervenir-con-dificultades-de-aprendizaje/>>. Acesso em: 15 jan. 2020.

GARTNER, Inc. **80 Percent of Current Gamified Applications will fail to Meet Business Objectives Primarily due to Poor Design**. Gartner, 2012. Disponível em: <www.gartner.com/newsroom/id/2251015>. Acesso em: 02 abr. 2020.

GASLAND, Magne Matre. **Game Mechanic based E-Learning A case study**. Dissertação (Mestrado) — Norwegian University of Science and Technology, NTNU, 2011.

GENTRY, Sarah Victoria *et al.* Serious gaming and gamification education in health professions: systematic review. **Journal of Medical Internet Research**, v. 21, 2019. ISSN 14388871. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85063940575{&}doi=10.2196{\\%}2F12994{&}partnerID=40{&}md5=bdc33b6dc05a84f116c0>>.

GOOCH, Daniel *et al.* Using gamification to motivate students with dyslexia. In: **Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems**. New York, NY, USA: Association for Computing Machinery, 2016. (CHI '16), p. 969–980. ISBN 9781450333627. Disponível em: <<https://doi.org/10.1145/2858036.2858231>>.

GUNTER, Glenda A.; KENNY, Robert F.; VICK, Erik H. Taking educational games seriously: using the retain model to design endogenous fantasy into standalone educational games. **Educational Technology Research and Development**, p. 511–537, 2008. ISSN 1556-6501. Disponível em: <<https://doi.org/10.1007/s11423-007-9073-2>>.

HAGGLUND, Per. **Taking gamification to the next level: a detailed overview of the past, the present and a possible future of gamification**. Tese (Doutorado) — Umea Universitet, Umea, 2012.

HAN, Jiawei; KAMBER, Micheline; PEI, Jian. **Data Mining: Concepts and Techniques**. Morgan Kaufmann, 2012. 744 p. ISBN 978-0-12-381479-1. Disponível em: <<https://doi.org/10.1016/C2009-0-61819-5>>.

HAN, Jiawei *et al.* Mining frequent patterns without candidate generation: A frequent-pattern tree approach. **Data Mining and Knowledge Discovery**, v. 8, n. 1, p. 53–87, 2004. ISSN 1384-5810.

HOSMER, David W.; LEMESHOW, Stanley. **Applied logistic regression**. [S.l.]: John Wiley and Sons, 2000. ISBN 0471356328, 9780471356325.

HULSEBOSCH, Marc. Twente student conference on it, 18. In: **Targeting gamification applications to increase user participation**. [s.n.], 2013. Disponível em: <<http://essay.utwente.nl/68094/>>.

IFIGENIA, Pinedo Rivera Dafne *et al.* Integration of gamification to assist literacy in children with special educational needs. In: **2018 IEEE Global Engineering Education Conference (EDUCON)**. [S.l.: s.n.], 2018. p. 1949–1956. ISSN 2165-9567.

INOCENCIO, Fabricio De C. Using gamification in education: A systematic literature review. In: **International Conference on Information Systems 2018, ICIS 2018**. [S.l.: s.n.], 2018. ISBN 9780996683173.

JAIN, Anil K. Data clustering: 50 years beyond k-means. *pattern recognition letters*. **Pattern Recognition Letters**, v. 31, n. 8, p. 651–666, jun 2010. ISSN 1384-5810.

KAMUNYA, Samuel; MAINA, Elizaphan; OBOKO, Robert. A Gamification Model for E-Learning Platforms. In: **2019 IST-Africa Week Conference, IST-Africa 2019**. [S.l.: s.n.], 2019. p. 1–9. ISBN 9781905824632. ISSN 2576-8581.

KAPP, Karl M. Theories Behind Gamification of Learning and Instruction. **The Gamification of Learning and Instruction : Game-Based Methods and Strategies for Training and Education**, p. 51–74, 2012.

KITCHENHAM, Barbara; CHARTERS, Stuart. Guidelines for performing systematic literature reviews in software engineering. v. 2, 01 2007.

KONDAS, Arkadiusz. **PHP-ML - Machine Learning library for PHP**. MIT License, 2021. Disponível em: <<https://php-ml.readthedocs.io/en/latest/>>. Acesso em: 26 jul. 2021.

LAAKSONEN, Jorma; OJA, Erkki. Classification with learning k-nearest neighbors. In: **Proceedings of International Conference on Neural Networks (ICNN'96)**. [S.l.: s.n.], 1996. v. 3, p. 1480–1483.

LARA, Juan; ALJAWARNEH, Shadi; PAMPLONA, Sonia. Special issue on the current trends in e-learning assessment. **Journal of Computing in Higher Education**, v. 32, 08 2019.

LEE, Haksu; DOH, Young Yim. A study on the relationship between educational achievement and emotional engagement in a gameful interface for video lecture systems. **Proceedings - 2012 International Symposium on Ubiquitous Virtual Reality, ISUVR 2012**, p. 34–37, 2012.

LEE, Joey; HAMMER, Jessica. Gamification in education: What, how, why bother? **Academic Exchange Quarterly**, v. 15, n. 2, p. 146, 2011. ISSN 1096-1453.

LLORENS-LARGO, F. *et al.* LudifyME: An Adaptive Learning Model Based on Gamification. In: CABALLÉ, Santi; Clarisó Learning Data Analytics and Gamification, Robert B T Formative Assessment (Ed.). **Formative Assessment, Learning Data Analytics and Gamification: In ICT Education**. Boston: Academic Press, 2016. p. 245–269. ISBN 9780128036679.

MACEDO, Claudia Mara Scudelari de. **Diretrizes para criação de objetos de aprendizagem acessíveis**. 1–271 p. Tese (Doutorado) — Programa de Pós Graduação em Engenharia e Gestão do Conhecimento, UFSC, 2010.

MARTINS, Luiz Eduardo G.; GORSCHKEK, Tony. Requirements engineering for safety-critical systems: A systematic literature review. **Information and Software Technology**, v. 75, p. 71–89, 2016. ISSN 09505849.

MELLO, Gustavo; ZENDRON, Patricia. Bndes setorial, n.42, set. 2015. In: . [s.n.], 2015. p. 337–382. Disponível em: <<http://web.bndes.gov.br/bib/jspui/handle/1408/9374>>.

MICHIE, Donald; SPIEGELHALTER, David; TAYLOR, Charles. **Machine Learning, Neural and Statistical Classification**. [S.l.]: Overseas Press, 2009. v. 37. 1–290 p.

MING, Xue; CHANGJUN, Zhu. A study and application on machine learning of artificial intelligence. In: **2009 International Joint Conference on Artificial Intelligence**. [S.l.: s.n.], 2009. p. 272–274.

MITCHELL, Tom M. **Machine Learning**. [S.l.]: McGraw-Hill, 1997. 432 p. (1). ISBN 9788565424080.

MORA, Alberto *et al.* Gamification: a systematic review of design frameworks. **Journal of Computing in Higher Education**, v. 29, n. 3, p. 516–548, 2017. ISSN 18671233.

MORELOCK, John R. Systematic literature review: An exploration of gamification in the context of engineering education. In: **IIE Annual Conference and Expo 2013**. [S.l.: s.n.], 2013. p. 453–462.

MURNION, Shane *et al.* Machine learning and semantic analysis of in-game chat for cyberbullying. **Computers and Security**, v. 76, p. 197–213, 2018. ISSN 01674048.

MYSQL, Oracle Corporation. **MySQL**. MySQL Oracle Corporation and/or its affiliates, 2021. Disponível em: <<https://www.mysql.com/>>. Acesso em: 05 jun. 2021.

NAVADA, Arundhati *et al.* Overview of use of decision tree algorithms in machine learning. In: **2011 IEEE Control and System Graduate Research Colloquium**. [S.l.: s.n.], 2011. p. 37–42.

OMS. **Organização Mundial da Saúde**. 2021. Disponível em: <<https://www.who.int/pt/home>>. Acesso em: 05 mai. 2021.

ONU. **2020 é o Ano Internacional da Saúde Vegetal**. Organização das Nações Unidas, 2020. Disponível em: <<https://nacoesunidas.org/video-2020-e-o-ano-internacional-da-saude-vegetal/>>. Acesso em: 05 mai. 2020.

ORTIZ-ROJAS, Margarita; CHILUIZA, Katherine; VALCKE, Martin. Gamification and learning performance: A systematic review of the literature. In: **Proceedings of the 11th European Conference on Games Based Learning, ECGBL 2017**. [S.l.: s.n.], 2017. p. 515–522. ISBN 9781911218562.

OSATUYI, Babajide; OSATUYI, Temidayo; ROSA, Ramiro De La. Systematic review of gamification research in is education: A multi-method approach. **Communications of the Association for Information Systems**, v. 42, n. 1, p. 95–124, 2018.

PARTICIPAR. **Participar 2**. Universidade de Brasília, 2014. Disponível em: <<http://www.projetoparticipar.unb.br/deficiencia-intelectual/participar2>>. Acesso em: 29 fev. 2020.

_____. **Somar**. Universidade de Brasília, 2014. Disponível em: <<http://www.projetoparticipar.unb.br/deficiencia-intelectual/somar>>. Acesso em: 29 fev. 2020.

_____. **Somar para tablets**. Universidade de Brasília, 2014. Disponível em: <<http://www.projetoparticipar.unb.br/deficiencia-intelectual/somar-para-tablets>>. Acesso em: 29 fev. 2020.

- _____. **Participar para tablets**. Universidade de Brasília, 2015. Disponível em: <<http://www.projetoparticipar.unb.br/deficiencia-intelectual/participar-tablets>>. Acesso em: 29 fev. 2020.
- _____. **Atividades de Vida**. Universidade de Brasília, 2016. Disponível em: <<http://www.projetoparticipar.unb.br/deficiencia-intelectual/atividades-de-vida>>. Acesso em: 29 fev. 2020.
- _____. **Atividades de Vida - versão para celular**. Universidade de Brasília, 2016. Disponível em: <<http://www.projetoparticipar.unb.br/deficiencia-intelectual/atividades-de-vida-versao-para-celular>>. Acesso em: 29 fev. 2020.
- _____. **ORGANIZAR: Software Educacional de Apoio ao Ensino de Gerenciamento do Tempo e Estações Climáticas para Jovens e Adultos com Deficiência Intelectual**. Universidade de Brasília, 2016. Disponível em: <<http://www.projetoparticipar.unb.br/deficiencia-intelectual/organizar>>. Acesso em: 29 fev. 2020.
- _____. **Comunicação Funcional: Aplicativo de Apoio à Interlocução Social para Deficientes Intelectuais não Alfabetizados**. Universidade de Brasília, 2018. Disponível em: <<http://www.projetoparticipar.unb.br/comunicacao-funcional-material>>. Acesso em: 29 fev. 2020.
- _____. **Softwares Educacionais de Apoio ao Ensino de Deficientes Intelectuais e Autistas**. Universidade de Brasília, 2019. Disponível em: <<http://www.projetoparticipar.unb.br>>. Acesso em: 30 nov. 2019.
- PEIXOTO, Mariana Maia; SILVA, Carla. Requirements for gamified educational software: A systematic literature review. In: **CIBSE 2015 - XVIII Ibero-American Conference on Software Engineering**. [S.l.: s.n.], 2015. p. 618–631.
- PHP, The PHP Group. **PHP**. PHP, The PHP Group, 2021. Disponível em: <<https://www.php.net/>>. Acesso em: 05 jun. 2021.
- PIMENTA, Tatitana. **Deficiência Intelectual: principais características, sintomas e tratamento**. Blog Vittude, 2017. Disponível em: <<https://www.vittude.com/blog/deficiencia-intelectual-caracteristicas-sintomas>>. Acesso em: 30 nov. 2019.
- RODRIGUES, Luís Filipe; OLIVEIRA, Abílio; RODRIGUES, Helena. Main gamification concepts: A systematic mapping study. **Heliyon**, v. 5, n. 7, p. e01993, 2019. ISSN 24058440. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S240584401935618X>>.
- SAMUEL, Arthur L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, v. 44, p. 210–229, 1959.
- SANTOS, Julia De Avila dos; FREITAS, Andre Luis Castro de. Gamificação Aplicada a Educação: Um Mapeamento Sistemático da Literatura. **Renote**, v. 15, n. 1, 2017. ISSN 1679-1916.
- SCHMENGLER, Angélica Regina; PAVAO, Ana Cláudia Oliveira; PAVAO, Sílvia Maria de Oliveira. Contribuição do objeto de aprendizagem "orgãos do sentido" para alunos com deficiência intelectual. **Renote**, v. 17, n. 3, 2019. ISSN 1679-1916.

- SCHMITZ, Birgit; KLEMKE, Roland; SPECHT, Marcus. Effects of mobile gaming patterns on learning outcomes: a literature review. **International Journal of Technology Enhanced Learning**, Inderscience Publishers, v. 4, p. 345–358, jan 2012. Disponível em: <<https://doi.org/10.1504/IJTEL.2012.051817>>.
- SEABORN, Katie; FELS, Deborah I. Gamification in theory and action: A survey. **International Journal of Human Computer Studies**, v. 74, p. 14–31, 2015. ISSN 10959300.
- SHELDON, Lee. **The Multiplayer Classroom: Designing Coursework as a Game**. Boston, Massachusetts: Cengage Learning, 2012. 256 p. (1). ISBN 1435458443.
- SIMÕES, Jorge; REDONDO, Rebeca Díaz; VILAS, Ana Fernández. A social gamification framework for a k-6 learning platform. **Computers in Human Behavior**, v. 29, p. 345–353, mar 2013. ISSN 0747-5632. Disponível em: <<https://doi.org/10.1016/j.chb.2012.06.007>>.
- SIU, Wing Lun *et al.* Using an English language education APP to understand the English level of students. In: **2018 27th Wireless and Optical Communication Conference, WOCC 2018**. [S.l.: s.n.], 2018. p. 1–3. ISBN 9781538649596.
- SMITH-ROBBINS, Sarah. This game sucks: how to improve the gamification of education. **Educause Review Online**, p. 58–59, 2011. Disponível em: <<https://er.educause.edu/~media/files/article-downloads/erm1117.pdf>>.
- SOFIAFALA. **SofiaFala**. SofiaFala - Departamento de Computação e Matemática - USP, 2019. Disponível em: <<http://dcm.ffclrp.usp.br/sofiafala/index.php>>. Acesso em: 30 nov. 2019.
- SOUZA, Mauricio R. de A. *et al.* A systematic mapping study on game-related methods for software engineering education. **Information and Software Technology**, v. 95, p. 201–218, 2018. ISSN 09505849. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0950584917303518>>.
- STEVENSON, Matt P.; HARTMEYER, Rikke; BENTSEN, Peter. Systematically reviewing the potential of concept mapping technologies to promote self-regulated learning in primary and secondary science education. **Educational Research Review**, v. 21, p. 1–16, 2017. ISSN 1747938X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1747938X17300106>>.
- STUDIOS, Cuicui. **Boogies Academy**. Cuicui Studios, 2020. Disponível em: <<https://www.boogiesacademy.com/>>. Acesso em: 15 jan. 2020.
- STUDIOS, S.L. Cuicui; HK, Ltd. Eolo Sport. **Cuibrain**. Cuicui Studios S.L, 2020. Disponível em: <<http://cuibrain.com/>>. Acesso em: 15 jan. 2020.
- SUBHASH, Sujit; CUDNEY, Elizabeth A. Gamified learning in higher education: A systematic review of the literature. **Computers in Human Behavior**, v. 87, p. 192–206, 2018. ISSN 07475632.
- TENÓRIO, Marcos Mincov *et al.* Elements of gamification in virtual learning environments: A systematic review. **Advances in Intelligent Systems and Computing**, v. 716, p. 86–96, 2018. ISSN 21945357.
- TORRENTE, Javier *et al.* Designing serious games for adult students with cognitive disabilities. In: **2012 Neural Information Processing**. [S.l.]: Springer - Lecture Notes in Computer Science, 2012. v. 7666, p. 603–610.

TRINIDAD, Manuel; CALDERÓN, Alejandro; RUIZ, Mercedes. A systematic literature review on the gamification monitoring phase: How SPI standards can contribute to gamification maturity. **Communications in Computer and Information Science**, v. 918, p. 31–44, 2018. ISSN 18650929.

TRUONG, Huong May. Integrating learning styles and adaptive e-learning system: Current developments, problems and opportunities. **Computers in Human Behavior**, v. 55, p. 1185–1193, 2016. ISSN 07475632. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0747563215001120>>.

UNICAP. **UNICAP**. Curso Tecnológico de Jogos Digitais - UNICAP, 2019. Disponível em: <http://www.unicap.br/tecnologicos/jogos/?page_id=1743>. Acesso em: 30 nov. 2019.

UNITY, Technologies. **Unity**. Unity, Technologies, 2021. Disponível em: <<https://unity.com/>>. Acesso em: 05 jun. 2021.

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ (UTFPR). Câmpus Ponta Grossa, Departamento Acadêmico de Informática, Laboratório de Engenharia de Software e Inteligência Computacional (LESIC), 2021.

VENEZIANO, Wilson *et al.* Ferramenta educacional de tecnologia assistiva para o ensino e prática da matemática social de jovens e adultos com deficiência intelectual. **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)**, v. 27, n. 1, p. 886, 2016. ISSN 2316-6533. Disponível em: <<https://www.br-ie.org/pub/index.php/sbie/article/view/6774>>.

VIANNA, Ysmar *et al.* **Gamification, Inc. - Como Reinventar Empresas A Partir de Jogos**. Rio de Janeiro: MJV Press, 2013. 116 p. (1). ISBN 9788565424080.

VINENTE, Samuel; GALVANI, Márcia Duarte. Efeitos de um programa de reconhecimento do alfabeto em um escolar com deficiência intelectual. **Pesquisa e Prática em Educação Inclusiva**, v. 1, p. 268–283, 2019. ISSN 2595-1920.

WERBACH, Kevin; HUNTER, Dan. **For the Win: How Game Thinking Can Revolutionize Your Business**. Philadelphia: Wharton School Press, 2016. 126 p. (1).

APÊNDICE A - Telas do jogo *ScienceLearning*

TELAS DO JOGO SCIENCELEARNING

Figura 23 – Tela de Login do ScienceLearning



A screenshot of the Science Learning login screen. The background is a kitchen scene. At the top center, the logo 'SCIENCE LEARNING' is displayed in a stylized, colorful font. Below the logo, there are two input fields: 'USUÁRIO' with the text 'Vinicius' and 'SENHA' with '****'. A checkbox labeled 'Lembrar Usuário' is checked. Below the input fields are three buttons: 'LOGIN' (orange), 'SAIR' (green), and 'REGISTRAR' (green). A speaker icon is in the top right corner.

Fonte: Autoria própria.

Figura 24 – Tela de Cadastro de Usuário do ScienceLearning

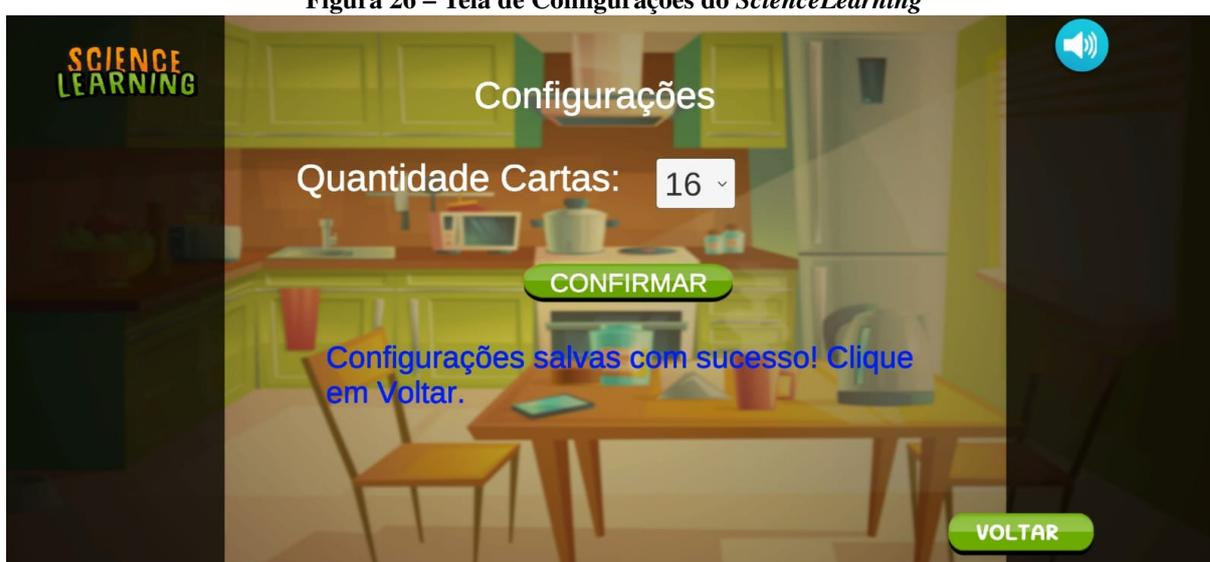


A screenshot of the Science Learning user registration screen. The background is the same kitchen scene. At the top left, the logo 'SCIENCE LEARNING' is visible. The title 'REGISTRO DA CONTA' is centered at the top. Below the title, there are four input fields: 'USUÁRIO' with placeholder text 'Informe o usuário...', 'SENHA' with 'Informe a senha..', 'NASCIMENTO' with '00/00/0000' and a note '* Opcional' below it, and 'GÊNERO' with 'Masculino' and a dropdown arrow. At the bottom are two buttons: 'REGISTRAR' (orange) and 'VOLTAR' (green). A speaker icon is in the top right corner.

Fonte: Autoria própria.

Figura 25 – Tela de Menu Principal do *ScienceLearning*

Fonte: Autoria própria.

Figura 26 – Tela de Configurações do *ScienceLearning*

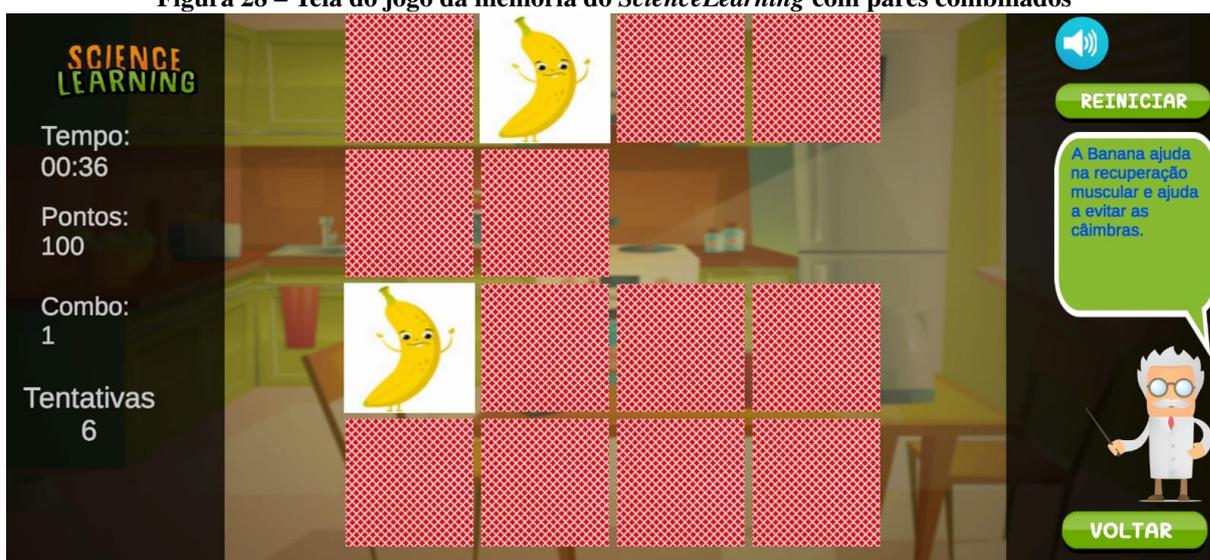
Fonte: Autoria própria.

Figura 27 – Tela de Sobre do ScienceLearning



Fonte: Autoria própria.

Figura 28 – Tela do jogo da memória do ScienceLearning com pares combinados



Fonte: Autoria Própria.

Figura 29 – Tela de Parabéns do *ScienceLearning*



Fonte: Autoria própria.