

Análise das Atividades Interativas de um Jogo Sérioso usando Aprendizagem de Máquina: Um Estudo para Pessoas com Deficiência Intelectual

Luan Leme Silva, luansilva.2000@alunos.utfpr.edu.br, UTFPR,  <https://orcid.org/0000-0001-6858-5621>
Hellen Jaqueline Cordeiro Mizerski, hellenjaq@hotmail.com,  <https://orcid.org/0009-0003-1995-6539>
Ezequiel Gueiber, UEPG e UTFPR, egueiber@gmail.com,  <https://orcid.org/0000-0002-2993-0928>
Simone Nasser Matos, UTFPR, snasser@utfpr.edu.br,  <https://orcid.org/0000-0002-5362-2343>
Helyane Bronoski Borges, helyane@utfpr.edu.br, <https://orcid.org/0000-0002-9153-3819>
Guataçara dos Santos Junior, UTFPR, guata@utfpr.edu.br,  <https://orcid.org/0000-0002-6234-7961>

RESUMO. Este artigo teve como objetivo realizar uma análise sobre as partidas de um jogo sério Querida Floresta usando algoritmos de aprendizagem de máquina para identificar características de comportamento quando o aluno com deficiência intelectual executa as atividades. A análise considerou as três atividades interativas do jogo que são: contar e clicar, arrastar e soltar e quiz. A metodologia para o desenvolvimento desta pesquisa considerou duas fases principais: Geração de uma Nova Versão do Querida Floresta e Identificação de Características. O jogo foi disponibilizado a estudantes com deficiência intelectual de uma instituição da região Sul. Por meio dos dados coletados e a aplicação dos algoritmos J48, KMeans e JRip identificou-se as atividades interativas que apresentam menor dificuldade de execução para o público com deficiência intelectual.

Palavras-chaves: jogo sério, deficiência intelectual, aprendizagem e máquina.

ABSTRACT. This paper aimed to carry out an analysis of the matches of a serious game Querida Floresta using machine learning algorithms to identify behavioral characteristics when the student with intellectual disability performs the activities. The analysis considered the three interactive activities of the game which are: count and click, drag and drop and quiz. The methodology for the development of this research considered two main phases: Generation of a New Version of Querida Floresta and Identification of Characteristics. The game was made available to students with intellectual disabilities at an institution in the South region. Through the collected data and the application of the J48, KMeans and JRip algorithms, the interactive activities that are less difficult for people with intellectual disabilities were identified.

Keywords: serious game, intellectual disability, machine learning.

1. Introdução

Um desafio no desenvolvimento das atividades em um jogo sério voltado para deficientes intelectuais é a definição do nível de dificuldade de cada fase e/ou atividade, o qual pode ser melhorado com o uso de algoritmos de aprendizado de máquina (AM) (FACELI *et al.*, 2011).

A AM simula o comportamento de estudo do ser humano e seu objetivo é obter novas informações e organizar a estrutura do conhecimento, na expectativa de identificar melhorias de performance (MING *et al.*, 2009) ou identificação de perfis (PEREIRA JUNIOR; MATOS; BORGES, 2020). O uso da técnica de AM tal como a aprendizagem por reforço permite a criação de um jogo com dificuldade ideal para o jogador com deficiência intelectual permitindo um maior engajamento (TEIXEIRA *et al.*, 2020; BORGES *et al.*, 2022). A importância da aplicação de algoritmos de AM em jogos sérios está na otimização da obtenção de informações de jogabilidade e usabilidade.

Luz *et al.* (2021) realizou um mapeamento sistemático para verificar a aplicação de AM em jogos sérios e constatou que os algoritmos supervisionados são os mais utilizados. Os algoritmos podem ser aplicados para processar os dados coletados das partidas, o que resulta em informações das características e comportamentos da relação entre jogador e atividade. Ao analisar as informações de partidas, pode-se contribuir para propor alterações no software e regulagens no nível de dificuldade das atividades, objetivando melhorar a interação entre o usuário e o software, aumentar o desafio de fases corriqueiras e diminuir a dificuldade de fases complexas.

Este artigo apresenta a aplicação de algoritmos de AM em dados de partidas de um jogo sério denominado de Querida Floresta (SILVA *et al.*, 2022). Para isto, foi realizada uma análise dos atributos que melhor representariam a interação entre o jogador e cada atividade contemplada no jogo. Esses dados foram coletados e armazenados para posterior análise.

O jogo Querida Floresta foi aplicado a alunos de uma instituição que atende estudantes com deficiência intelectual, os quais puderam jogá-lo e assim foi realizado o registro de suas partidas. Os dados coletados, após passarem por uma etapa de pré-processamento, foram processados pelos algoritmos K-Means (KHANNA, AWAD, 2015), J48 (SARAVANAN; GAYATHRI, 2018) e JRip (THAKUR *et al.*, 2017). Os resultados foram comparados e analisados em relação as suas atividades interativas e foi possível identificar dentre as atividades interativas (contar e clicar, arrastar e soltar e quiz) qual apresenta menor dificuldade de execução.

2. Jogo Sério Querida Floresta

Querida Floresta é um jogo sério desenvolvido para estudantes com deficiência intelectual com o objetivo de ensinar sobre a importância das florestas. O jogo usa recursos de gamificação para aumentar o potencial educacional, como a divisão de atividades em níveis, recompensas temáticas, recursos desbloqueáveis, *feedback* constante das ações do usuário e um narrador visual. O jogo foi bem recebido pelo público-alvo, recebendo avaliações positivas no questionário de usabilidade aplicado aos alunos (SILVA *et al.*, 2022).

O jogo foi desenvolvido com três diferentes atividades e utiliza do desbloqueio de fases e prêmios como progresso do jogador ao completar as atividades. Todas as atividades contam com a presença de um narrador visual animado, responsável por guiar e fornecer *feedback* constante das ações do usuário.

A primeira atividade (contar e clicar) traz uma mecânica de clique no momento solicitado, onde, em um cenário de uma floresta em um dia ensolarado, o aluno observa a formação de nuvens no céu. Seu objetivo é o de interagir com o botão esquerdo do mouse quando a quantidade solicitada de nuvens se acumular na parte superior da cena. A atividade possui três fases com a mesma mecânica, porém com diferentes níveis de dificuldade, pois a velocidade da aparição de novas nuvens e a quantidade solicitada é incrementado com o passar de cada fase.

A segunda atividade (arrastar e soltar) tem o objetivo de ensinar os conceitos sobre a formação de nuvens de chuva por meio de uma animação em que o jogador interage selecionando, arrastando e soltando o elemento que corresponde a solução do problema. Caso o jogador selecione um dos elementos incorretos, o narrador visual explica quais são os efeitos negativos que o mesmo teria na sua interação com o cenário proposto.

Como terceira atividade foi desenvolvido um quiz sobre os assuntos tratados nas atividades anteriores. Neste quiz, as perguntas são narradas pelo narrador visual, ao invés de escritas em tela para a leitura. O jogador pode solicitar a repetição da pergunta quantas vezes achar necessário antes de selecionar a resposta.

Durante a idealização e desenvolvimento do jogo sério, não foram criados atributos que capturam os dados das partidas ou de utilização do jogo, por este motivo

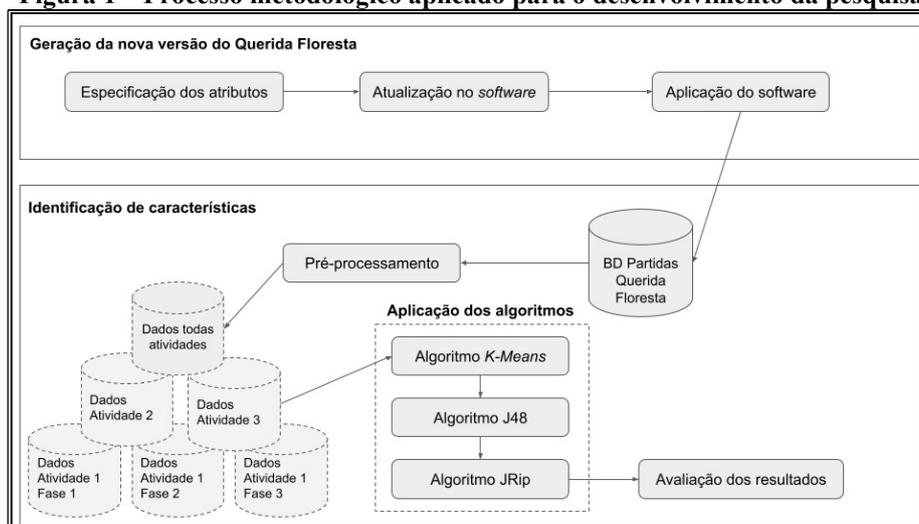
houve a necessidade de atualização do jogo para que os algoritmos de aprendizagem de máquina fossem aplicados.

3. Metodologia

A metodologia usada para o desenvolvimento desta pesquisa foi distribuída em duas fases: Geração da nova versão do Querida Floresta e Identificação de características. Na primeira fase as seguintes etapas foram executadas: especificação dos atributos, atualização do software e aplicação do software.

Considerando a segunda fase as etapas foram: pré-processamento dos dados, aplicação dos algoritmos e avaliação dos resultados. O processo metodológico seguido durante o desenvolvimento desta pesquisa é sistematizado na Figura 1.

Figura 1 – Processo metodológico aplicado para o desenvolvimento da pesquisa



Na etapa de especificação dos atributos, as atividades propostas no jogo foram analisadas individualmente e identificaram-se atributos necessários para a coleta de dados. Cada atributo definido foi nomeado com uma sigla, teve seu tipo especificado (número, data, duração etc.), sua finalidade e a característica do que avalia. Durante a análise, foram identificados um conjunto de atributos comuns entre as atividades, relacionados com a: duração da realização das atividades e a quantidade de entradas do usuário (cliques com o mouse e teclas pressionadas). Os atributos são apresentados no Quadro 1.

Quadro 1 – Especificação dos atributos comuns entre as atividades

Atributo	Tipo	Descrição
QTD_DICAS	Inteiro	Quantidade de acessos ao menu de dicas
QTD_TECLAS	Inteiro	Quantidade de entradas do teclado realizadas durante a fase
QTD_CLIQUES	Inteiro	Quantidade de cliques diretos fora de elementos clicáveis durante a realização da atividade
TMP_INICIO	Flutuante	Tempo do início até a primeira interação do usuário com a fase
QTD_SAIDAS	Inteiro	Quantidade de vezes que o usuário saiu da atividade sem completá-la
TMP_PARTIDA	Flutuante	Duração de realização de cada atividade feita pelo usuário

Apesar de possuir uma jogabilidade simples, a primeira atividade necessitou de um mapeamento de atributos referentes as diferentes interações do jogador durante a realização da atividade, como cliques em momentos incorretos ou a ausência de cliques em momentos que necessitavam da interação do jogador com o botão do mouse. O Quadro 2 apresenta os atributos especificados.

Quadro 2 – Especificação dos atributos da primeira atividade

Atributo	Tipo	Descrição
QTD_FALHAS_SEM_CLICAR	Inteiro	Quantidade de falhas por não clicar nas nuvens
QTD_CLIQUES_PROXIMOS	Inteiro	Quantidade de falhas próximo a quantidade necessária de nuvens ou fora do botão durante a tela de tentar novamente
QTD_CLIQUES_ANTIPECIADOS	Inteiro	Quantidade de falhas ao clicar antes da quantidade necessária de nuvens

A primeira atividade é composta por múltiplas fases, cada uma com um nível de dificuldade maior que a anterior. Por possuir tal característica, a atividade gerou cada atributo para cada fase e isto permitiu uma análise específica de cada nível de dificuldade.

Na segunda atividade, os atributos específicos levantados se relacionavam às quantidades de falhas do jogador e interações ocorridas durante as animações explicativas. A especificação dos atributos é exibida no Quadro 3.

Quadro 3 – Especificação dos atributos da segunda atividade

Atributo	Tipo	Descrição
QTD_FALHAS	Inteiro	Quantidade de falhas ao clicar num objeto incorreto
QTD_CLIQUES_DESTACADOS	Inteiro	Quantidade de cliques e teclas pressionadas durante a animação das árvores

Para a terceira atividade, os atributos específicos identificados estão apresentados no Quadro 4. Estes se referem as quantidades de respostas incorretas no quiz e de repetições dos áudios de suas perguntas, os dois atributos foram coletados separadamente para cada pergunta para possibilitar uma análise sobre cada uma.

Quadro 4 – Especificação dos atributos da terceira atividade

Atributo	Tipo	Descrição
QTD_REPETICOES_AUDIO	Inteiro	Quantidade de repetições de áudio em cada pergunta
QTD_INCORRETAS	Inteiro	Quantidade de respostas incorretas nas perguntas

A próxima etapa foi a atualização do software que resultou em uma nova versão do jogo capaz de coletar e armazenar os dados de partida dos jogadores.

Na etapa de aplicação do software, o jogo foi disponibilizado em uma instituição que atende alunos com deficiência intelectual e as jogadas dos participantes foram registradas para posterior análise. Participaram do experimento aproximadamente 97 alunos com deficiência intelectual leve e moderada e foram gerados 304 registros de jogadas. A classificação do tipo de deficiência é feita pela própria instituição em que os alunos estudam.

A etapa de pré-processamento removeu dados ruidosos do conjunto, objetivando melhores resultados dos algoritmos. A ferramenta de manipulação e mineração de dados WEKA (*Waikato Environment for Knowledge Analysis*) (FRANK; HALL; WITTEN, 2016) foi utilizada para auxiliar no processo de filtragem e posteriormente na aplicação de algoritmos.

O processamento dos dados pelos algoritmos de AM englobou execuções que utilizavam atributos de todas as atividades e execuções que analisaram atributos das fases de forma individual. Para auxiliar diferentes combinações de atributos, a base foi subdividida em seis subconjuntos: uma com os atributos de todas as atividades; três, para os atributos de cada fase da Atividade 1; uma para os atributos da Atividade 2; e uma para os atributos da Atividade 3.

Para a remoção de dados ruidosos, foi utilizado o algoritmo de detecção de dados ruidosos *LocalOutlierFactor*, do pacote de algoritmos e ferramentas de análise de dados implementado na linguagem *Python scikit-learn*. O algoritmo utiliza de medições de distância entre os dados para detectar instâncias isoladas. A configuração do algoritmo alterou o valor de contaminação e o algoritmo de cálculo dos vizinhos mais próximos em relação aos valores padrões da implementação da ferramenta, sendo respectivamente 0,2 e o algoritmo *KDTree*.

Na etapa de aplicação dos algoritmos, os dados filtrados foram processados pelos algoritmos K-Means (KHANNA, AWAD, 2015), J48 (SARAVANAN; GAYATHRI, 2018) e JRip (THAKUR *et al.*, 2017) gerando regras e dados. Por fim, na avaliação dos resultados, os dados obtidos foram analisados e são relatados na próxima seção.

4. Resultados

A seguir são apresentados os resultados das execuções dos algoritmos K-Means, J48 e JRip, bem como uma discussão sobre os resultados alcançados.

4.1 Resultados com o algoritmo K-Means

Para a aplicação do algoritmo não-supervisionado K-Means na análise dos registros sobre as partidas considerando os atributos das três atividades de maneira conjunta, foram efetuadas três diferentes execuções com quantidades de clusters: 2, 3 e 4. No processamento dos dados de todas as atividades, as execuções realizadas com 3 clusters foram as que melhor distribuíram as instâncias entre os agrupamentos e que trouxeram resultados mais precisos em relação as características conforme apresentam o Tabela 1.

Tabela 1 – Resultados do algoritmo K-Means processando todas as atividades

Quantidade de registros	Taxa de acerto	Características
44 registros	18,11%	<ul style="list-style-type: none"> • Alta quantidade de cliques na atividade 1. • Longa duração de partida nas fases 2 e 3 da atividade 1. • Demora para iniciar a atividade 2.
174 registros	71,60%	<ul style="list-style-type: none"> • Pouca quantidade de cliques na atividade 1. • Pouco tempo até iniciar a atividade 1.
25 registros	10,29%	<ul style="list-style-type: none"> • Alta quantidade de cliques na atividade 1. • Demora para iniciar as atividades 1 e 2. • Longa duração de partida na fase 1 da atividade 1. • Falhas por não clicar nas nuvens no momento solicitado na atividade 1.

A Atividade 1 foi a que mais apresentou informações referentes ao público com deficiência intelectual. Observou-se uma grande quantidade de cliques fora de elementos

clicáveis (QTD_CLIQUES) nos dois clusters que englobaram os jogadores que tiveram as partidas com maior duração, que somam 28,4% dos registros.

A média do tempo para se iniciar a Atividade 1 (TMP_INICIO) do cluster com menor quantidade de registros (10,29%) mostrou-se aproximadamente cinco vezes maior em relação aos resultados dos outros agrupamentos. Tais dados apontam que as instruções dadas a respeito de como jogar a atividade não foram efetivas para parte dos jogadores.

Quando analisada a primeira fase da Atividade 1 perceber-se que o cluster com a maior média de tempo de conclusão (TMP_PARTIDA) foi o mesmo que apresentou mais falhas por não interagir com as nuvens no momento solicitado (QTD_FALHAS_SEM_CLICAR). As falhas nas fases seguintes não se destacaram da média, demonstrando que a mecânica só foi compreendida após alguns erros na primeira fase. Tais dados reforçam que as regras de funcionamento da atividade não ficaram claras para todos os jogadores antes de seu início.

A Atividade 2 também apresentou médias altas do tempo para se iniciar a atividade nos dois clusters menos populosos, que somam 28,4% dos registros, o que demonstra que a atividade não foi clara ao apresentar seu funcionamento.

A execução do algoritmo na análise individual das atividades apresenta resultados que também reforçam as características apontadas pela análise geral. As três atividades foram executadas e analisadas individualmente para complementar as informações obtidas com a análise geral. Os resultados alcançados com a análise da Atividade 1, utilizando três clusters, são apresentados no Tabela 2.

Tabela 2 – Resultados do algoritmo K-Means processando Atividade 1

Quantidade de registros	Taxa de acerto	Características
151	62,14%	<ul style="list-style-type: none"> Baixa quantidade de cliques Baixo tempo de início
41	16,87%	<ul style="list-style-type: none"> Alta quantidade de cliques Longa duração de partida nas fases 2 e 3
51	20,99%	<ul style="list-style-type: none"> Alta quantidade de cliques Demora para iniciar a atividade Longa duração de partida na fase 1 Falhas por não clicar nas nuvens no momento solicitado

A análise da primeira atividade novamente aponta que houve dificuldade em compreender as instruções do jogo. Os dois clusters menores, totalizando cerca de 37,86% dos registros, tiveram valores comparativamente altos na quantidade de cliques fora de elementos selecionáveis (QTD_CLIQUES). O cluster que representa aproximadamente 20,99% dos registros apresentou uma média de tempo maior para se iniciar a atividade (TMP_INICIO) de 52,41 segundos, além de apresentar um tempo médio para a conclusão da fase de aproximadamente o dobro, em comparação à média dos dados.

A análise da Atividade 2 resultou nas características apresentadas pela Tabela 3. Observou-se que os registros foram melhor distribuídos e destacaram mais informações com a formação de dois clusters.

Tabela 3 – Resultados do algoritmo K-Means processando Atividade 2

Quantidade de registros	Taxa de acerto	Características
231	84,62%	<ul style="list-style-type: none"> Baixo tempo de início
42	15,38%	<ul style="list-style-type: none"> Alto tempo de início Longa duração de partida

Cerca de 15,38% dos registros foram representados por uma média de tempo para o início da atividade de 25 segundos, aproximadamente 3,5 vezes mais que a média da

totalidade dos registros. O mesmo cluster também apontou aproximadamente 30 segundos a mais que a média dos dados na duração da partida. Assim, como os dados da Atividade 2 gerados pela execução de todos os atributos, a análise demonstra que uma parcela dos jogadores teve dificuldade em iniciar a atividade.

Os resultados obtidos da terceira atividade permaneceram próximos a média de cada atributo. Essa ausência também ocorreu nos dados da terceira atividade dentro da análise geral.

Mesmo havendo dificuldade na execução das duas primeiras atividades, todas as execuções apresentadas apontaram uma quantidade de acesso aos recursos de dicas (QTD_DICAS para as atividades 1 e 2, QTD_REPETICOES_AUDIO para a atividade 3) muito próxima a zero. Por existir dificuldade de avanço e mesmo assim a ausência da utilização de dicas, pode-se concluir que as atividades não apresentaram de forma clara a existência dos recursos de dicas.

4.2 Resultados com o algoritmo J48

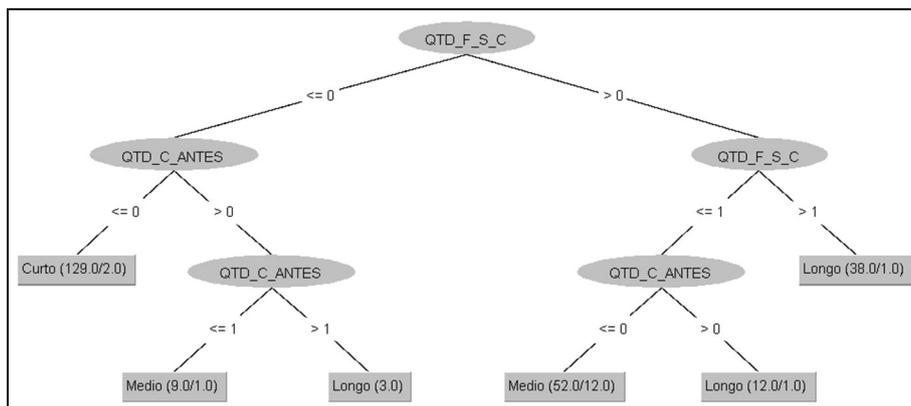
Para a aplicação do algoritmo supervisionado, os nomes dos atributos sofreram alterações para que os diagramas de resultados ficassem mais legíveis, a Quadro 5 apresenta as renomeações efetuadas.

Quadro 5 – Modificações feitas nos nomes dos atributos para a aplicação do J48

Nome modificado	Nome original
QTD F S C	QTD FALHAS SEM CLICAR
QTD C ANTES	QTD CLIQUES ANTECIPADOS
QTD C PROX	QTD CLIQUES PROXIMOS
QTD INC PX	QTD INCORRETAS para a pergunta X
QTD REPS PX	QTD REPETICOES AUDIO para a pergunta X

A análise da primeira fase da Atividade 1, pelo algoritmo, destacou dois atributos principais referentes a quantidade de falhas sem clicar nas nuvens (QTD_F_S_C) e a quantidade de cliques nas nuvens antes do momento correto (QTD_C_ANTES), como pode ser observado na Figura 2.

Figura 2 – Árvore de regras gerada pela análise do J48 da fase 1 da Atividade 1



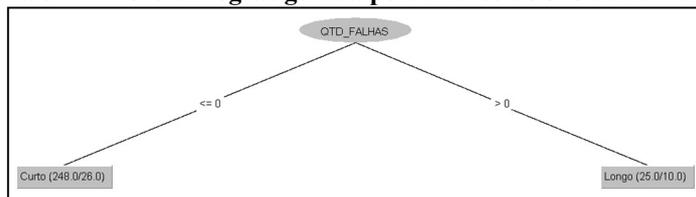
A árvore demonstra que os jogadores que não falharam ao clicar nas nuvens nos momentos corretos, ou seja, os quais não falharam por não clicar no momento solicitado (QTD_F_S_C) ou por clicar fora do momento correto (QTD_C_ANTES), conseguiram finalizar o jogo de forma rápida. Além disso, segundo os resultados obtidos, uma característica intrínseca às partidas de longa duração foi a repetição de falhas por não interagir com a fase nos momentos corretos (QTD_F_S_C).

A análise da segunda fase da Atividade 1 reforça a característica das jogadas de curta duração apontadas pela fase anterior. Esta característica é a ausência de falhas ligadas ao entendimento da mecânica da atividade.

A ocorrência de cliques antes do momento correto (QTD_C_ANTES) foi a característica que melhor caracterizou partidas de longa duração de acordo com os resultados obtidos. A análise da terceira fase demonstra que o aumento da dificuldade em relação às fases anteriores foi perceptível.

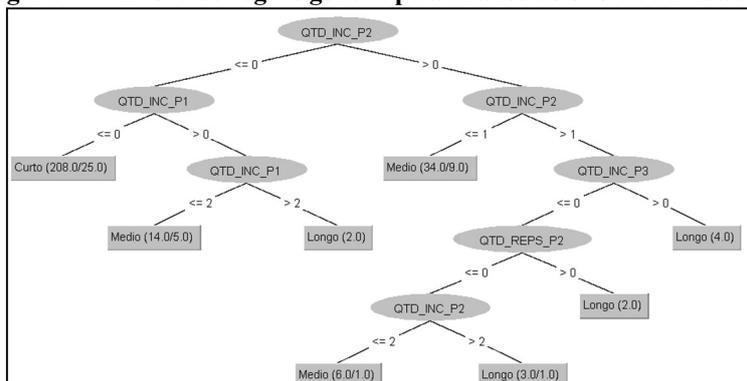
Partidas de curta duração foram identificadas com no máximo uma falha de clique antes do momento correto (QTD_C_ANTES), uma falha a mais que o limite estabelecido pelas regras das fases anteriores. A análise da Atividade 2 resultou em apenas uma regra de decisão, como pode ser observado na Figura 3.

Figura 3 – Árvore de regras gerada pela análise do J48 da atividade 2



A análise do resultado aponta a facilidade da resolução da atividade, visto que partidas de curta duração não registraram falhas de escolha. A árvore gerada pela análise dos dados da Atividade 3 pode ser observada pela Figura 4.

Figura 4 – Árvore de regras gerada pela análise do J48 da atividade 4



Assim como na Atividade 2, os jogadores não tiveram dificuldades para completar o quiz criado, pois a análise da árvore aponta que partidas de curta duração não registraram erros na primeira questão (QTD_INC_P1), e partidas que contabilizaram um erro na segunda questão tiveram uma duração média (QTD_INC_P2).

4.3 Resultados com o algoritmo JRip

Assim como nas execuções do algoritmo J48, os nomes dos atributos sofreram alterações para garantir maior legibilidade, as abreviações criadas podem ser observadas na Quadro 5. As regras geradas pela análise dos dados da primeira fase da Atividade 1 podem ser acompanhadas pela Figura 5.

Figura 5 – Regras geradas pela análise do JRip da primeira fase da Atividade 1

```

(QTD_F_S_C >= 1) and (QTD_F_S_C <= 1) and (QTD_C_ANTES <= 0) => DURACAO=Medio (52.0/12.0)
(QTD_C_ANTES >= 1) and (QTD_F_S_C <= 0) and (QTD_C_ANTES <= 1) => DURACAO=Medio (9.0/1.0)
(QTD_F_S_C >= 1) => DURACAO=Longo (50.0/2.0)
(QTD_C_ANTES >= 2) => DURACAO=Longo (3.0/0.0)
=> DURACAO=Curto (129.0/2.0)

Number of Rules : 5
  
```

A análise das regras da primeira fase da Atividade 1 demonstram que partidas de longa duração apresentam falhas pela ausência da interação do usuário com a atividade (QTD_F_S_C), atributo que pode indicar uma falta de entendimento da mecânica ou das instruções do jogo por parte do jogador. A análise das regras da segunda fase da Atividade 1 reforça a característica apontada pelas regras construídas para a primeira fase. Na análise desta fase, a característica que destaca uma partida de longa duração são as falhas por falta da interação do jogador no momento solicitado (QTD_F_S_C e QTD_C_ANTES); apontando que as instruções da atividade não foram claras. A análise das regras também aponta a falta de instruções adequadas, mesmo resultando em um conjunto de regras de classificação com menor precisão, comparado aos dois resultados anteriores.

A árvore de regras gerada pela análise da Atividade 2 destaca como característica diferencial das partidas de média e de longa duração a presença de cliques fora de objetos clicáveis (QTD_CLIQUES). Tal informação indica que os controles utilizados pela fase não foram compreendidos por todos os alunos. Por fim, a árvore de regras gerada pelo processamento da Atividade 3 não destacou informações que contribuíssem com a análise realizada.

4.4 Discussão sobre os resultados

Para fins de comparação entre as informações coletadas a partir dos resultados gerados pelos algoritmos, a Quadro 6 destaca as características observadas em cada uma das atividades.

Quadro 6 – Informações obtidas por atividade em cada um dos algoritmos aplicados

Algoritmo	Atividade 1	Atividade 2	Atividade 3
K-Means	<ul style="list-style-type: none"> • Partidas longas apresentaram alta quantidade de cliques, demoram para iniciar a atividade e não interagiram nos momentos solicitados. • Partidas curtas tiveram baixa quantidade de cliques fora de objetos não selecionáveis e iniciaram a atividade rapidamente. 	<ul style="list-style-type: none"> • Partidas longas registraram demora para iniciar a atividade. 	<ul style="list-style-type: none"> • Sem destaques.
J48	<ul style="list-style-type: none"> • Partidas longas registraram erros por não interagir com a fase nos momentos solicitados. • Partidas curtas não registraram cliques nas nuvens em momentos incorretos. 	<ul style="list-style-type: none"> • Partidas curtas não registraram falhas nas escolhas. 	<ul style="list-style-type: none"> • Partidas curtas não registraram falhas nas escolhas.
JRip	<ul style="list-style-type: none"> • Partidas longas registraram erros por não interagir com a fase nos momentos solicitados. 	<ul style="list-style-type: none"> • Partidas longas registraram cliques fora de objetos clicáveis. 	<ul style="list-style-type: none"> • Sem destaques

Para a primeira atividade a comparação dos resultados destaca a ausência de interação entre usuário e atividade nas partidas de longa duração, além de apontarem demora para iniciar a atividade. As duas características indicam que as instruções a respeito de como completar a atividade não foram efetivas ou suficientes.

Em relação a segunda atividade, as características destacadas para partidas de longa duração também se relacionam com a demora para iniciar a atividade junto com presença de interações do mouse em objetos não clicáveis, sinais de que o objetivo da atividade não ficou claro para os jogadores.

A terceira atividade não resultou na obtenção de muitas características, o que pode apontar que a fase não possui grande dificuldade. Os resultados também apontaram a ausência de erros cometidos pelos usuários, o que pode significar baixo nível de desafio. Como a atividade é no formato de um quiz, a baixa taxa de erro pode sinalizar um tipo de

jogo que fornece a pessoas com deficiência intelectual uma boa compreensão do conteúdo ensinado durante o jogo sério.

5. Conclusão

Este artigo apresentou a aplicação dos algoritmos K-Means, J48 e o JRip nos dados das partidas do jogo Querida Floresta considerado as atividades interativas de forma individual. Os dados sobre as partidas foram obtidos pelo uso do jogo por alunos com deficiência intelectual durante os meses de outubro a dezembro de 2022.

As conclusões advindas da análise dos algoritmos destacam que os jogadores tiveram menor dificuldade na execução da Atividade 3 (quiz). Em relação as outras atividades, contar e clicar (Atividade 1) e arraste e solte (Atividade 2), houve uma demora para os alunos conseguirem compreender. As informações obtidas pelos algoritmos ajudam a entender melhor que tipo de atividade interativa é melhor compreendida pelos alunos com deficiência intelectual. No experimento relatado neste artigo, observou-se que o quiz é de fácil compreensão e que as outras atividades precisam de instruções mais detalhadas sobre o funcionamento. Como trabalho futuro pretende-se a partir desta análise aperfeiçoar o jogo Querida Floresta para que atenda de forma mais efetiva o público com deficiência intelectual.

Referências

- BORGES, H. B.; *et al.* Avaliação de Jogo Educacional para Pessoas com Deficiência Intelectual: Um Estudo de Caso com o PegAgente. In: Simpósio Brasileiro de Informática na Educação, 23, 2022, Manaus. [Anais...], SBIE, 2022.
- FACELI, K.; *et al.* **Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina.** Rio de Janeiro, RJ: LTC, 2011.
- FRANK, E.; HALL, M. A.; WITTEN, I. H. The weka workbench. The WEKA workbench, online appendix for Data Mining: Practical Machine Learning Tools and Techniques. 2016. Disponível em: https://www.cs.waikato.ac.nz/ml/weka/Witten_et_al_2016_appendix. Pdf. Acesso em dez. de 2022.
- KHANNA, R.; AWAD, M. **Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers.** 1. ed. Berkeley, CA: Apress Open, 2015.
- LUZ, V. S. G.; *et al.* A Systematic Mapping on Machine Learning Algorithms and Gamification Applied to Education. In: International Conference on Computer Supported Education, 2021, [Proceedings...] Online Streaming. 13th CSEDU, 2021.
- MING, X.; *et al.* A Study and Application on Machine Learning of Artificial Intelligence. In: International Joint Conference on Artificial Intelligence. [Proceedings...], 2009. p. 272–274.
- PEREIRA JUNIOR, L.; MATOS, S. N.; BORGES, H. B. Análise dos Perfis de Alunos do Ensino Superior sobre a Realização de Aulas na Modalidade a Distância Durante Pandemia da Covid-19 Usando Algoritmos de Aprendizagem de Máquina. **Renote.**, v. 18, p. 336-345, 2020.
- SARAVANAN, N.; GAYATHRI, V. Performance and Classification Evaluation of J48 Algorithm and Kendall's Based J48 Algorithm (KNJ48). **International Journal of Computer Trends and Technology**, vol. 7, n. 4, 2018.
- SILVA, L. L.; *et al.* Aplicação de um Modelo Híbrido na Criação do Jogo Querida Floresta para Pessoas com Deficiência Intelectual. In: Simpósio Brasileiro de Jogos e Entretenimento Digital, 2022, Natal. [Anais...], SBGames, 2022.
- TEIXEIRA, T. S.; *et al.* PegAgente: modelagem de agentes por aprendizado de reforço em jogos educativos. **Renote**, v. 18, p. 225-234, 2020.
- THAKUR, S.; MEENAKSHI, E.; PRIYA, A. Detection of malicious URLs in big data using RIPPER algorithm. In: IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT). [Proceedings...], 2017. p. 1296-1301.