

Classificação de tipos de jogador com base na utilização de elementos de uma gamificação baseada em jogos de RPG

Rafaela Melo¹, Gabriel Haydar¹, Fernanda Pires²,
Elaine Oliveira¹, Leandro Galvão¹, Marcela Pessoa², David Fernandes¹

¹Instituto de Computação – Universidade Federal do Amazonas (ICOMP - UFAM)
Caixa Postal 15.064 – 91.501-970 – Manaus – AM – Brazil

²Escola Superior de Tecnologia – Universidade do Estado do Amazonas (EST/UEA)
Manaus - AM - Brasil

{rmelo, gigh, elaine, galvao, david}@icompu.ufam.edu.br

{fpirez, mspessoa}@uea.edu.br

Abstract. *Much has been researched on the benefits of using gamification in education and it has been identified that it is important that gamification does not have a “one size fits all”, but considers the different user profiles. This classification is usually carried out through questionnaires, which may have flaws. In view of this, this work presents an exploratory study on the classification of players, of the Hexad model, based on the interaction of users with a gamification based on RPG games. To carry out the classification, learning techniques were used. The study was carried out with 126 students from the Federal University from Amazonas and as a result an accuracy of 57% was obtained with the Random Forest algorithm.*

Resumo. *Muito tem se pesquisado sobre os benefícios do uso de gamificação na educação e se identificou que é importante que a gamificação não possua um “tamanho único”, e sim considere os diferentes perfis de usuários. Essa classificação é normalmente realizada por meio de questionários, o que pode ter falhas. Diante disso, neste trabalho é apresentado um estudo exploratório sobre a classificação de jogadores, do modelo Hexad, com base na interação dos usuários com uma gamificação baseada em jogos de RPG. Para realizar a classificação foram utilizadas técnicas de aprendizagem de máquina. O estudo foi realizado com 126 estudantes da Universidade Federal do Amazonas e como resultado obteve-se uma acurácia de 57% com o algoritmo Random Forest.*

1. Introdução

A gamificação se refere ao uso de elementos de jogos em atividades não relacionadas a jogos, como economia, indústria e saúde, com o objetivo de envolver e motivar pessoas [Deterding et al. 2011, Kapp 2012]. Diante disso, pesquisadores começaram a explorar o potencial da gamificação no contexto educacional, buscando criar ambientes de aprendizagem gamificados para aumentar o interesse e envolvimento dos estudantes nas disciplinas [Kiryakova et al. 2014].

Embora o objetivo de se utilizar gamificação na educação seja atingir resultados como engajamento, motivação, autonomia e diversão [Majuri et al. 2018], alguns

estudos apontam que a gamificação também pode causar efeitos negativos no comportamento dos estudantes [Hanus and Fox 2015, Toda et al. 2017]. Um dos fatores que pode influenciar tais efeitos negativos é o fato de que as pessoas não são motivadas da mesma maneira [Herbert et al. 2014] e possuem características e preferências diferentes [Herbert et al. 2014]. Por exemplo, alguns elementos de jogos existentes dentro de um ambiente podem ser motivadores para determinados jogadores, mas podem prejudicar a experiência de outros [Koivisto and Hamari 2019], o que pode interferir no nível de interesse do usuário pelo ambiente ou sistema gamificado.

Grande parte dos sistemas gamificados são desenvolvidos como “tamanho único”, ou seja, não levam em consideração as preferências individuais dos usuários, criando algo “universal” para todos [Santos et al. 2018]. Diante disso, surgem os estudos sobre gamificação personalizada [Klock et al. 2020], onde são propostos elementos específicos para cada usuário, de forma a tornar a experiência de todos mais ampla e satisfatória.

Na literatura, existem algumas propostas de classificação de usuários para sistemas gamificados [Bartle 1996, Nacke et al. 2014, Tondello et al. 2019], que dividem os jogadores de acordo com suas preferências e comportamentos dentro do ambiente. Uma dessas propostas é o modelo Hexad [Marczewski 2015], que classifica os usuários em seis tipos: filantropos, socializadores, espíritos livres, conquistadores, jogadores e disruptors.

Para identificar o tipo Hexad de cada usuário, é necessário recorrer ao questionário Hexad validado na literatura por Tondello et al. [2016], e mais recentemente Santos et al. [2022] validaram o questionário em Língua Portuguesa do Brasil. O questionário é formado por seis conjuntos de quatro afirmações, um para cada tipo de jogador, e o tipo de usuário é definido a partir do conjunto com maior pontuação. No entanto, o uso de questionários nem sempre é exato, pois os estudantes podem não dar a atenção necessária para respondê-los, devido ao tempo que precisam dedicar para preenchê-los, podem perder o interesse, ou podem ter dúvidas sobre o que responder naquele momento [Einola and Alvesson 2021].

Diante disso, o presente trabalho apresenta um estudo exploratório sobre a classificação de tipos de jogador Hexad com base nas interações dos usuários com uma gamificação baseada em jogos de RPG. O estudo foi feito com estudantes da Universidade Federal do Amazonas. Os estudantes fizeram uso da plataforma de gamificação CodePlay¹ [Galvão et al. 2016, Pessoa et al. 2019, Pessoa et al. 2022] e responderam ao questionário Hexad. Para realizar a classificação, foram utilizadas técnicas de aprendizagem de máquina e os dados de treinamento dos modelos foram: i) os elementos de jogos com os quais os usuários interagiram dentro do CodePlay; e, ii) as respostas obtidas com a aplicação do questionário Hexad, que serviram como os rótulos de classe. Como resultado, a melhor acurácia obtida (57%) foi com o algoritmo *Random Forest*.

O artigo está organizado da seguinte forma: a Seção 2 aborda alguns trabalhos relacionados, a Seção 3 discorre sobre gamificação e tipos de jogador, a Seção 4 aborda sobre aprendizagem de máquina e tarefas de classificação, a Seção 5 apresenta o design experimental abordado, a Seção 6 os resultados alcançados, a Seção 7 a discussão sobre os resultados encontrados, e, por fim, a Seção 8 as considerações finais do trabalho.

¹<https://codebench.icomp.ufam.edu.br>

2. Trabalhos relacionados

No trabalho de Altmeyer et al. [2019] foram utilizados dados de *smartphones* para prever a pontuação de pessoas ao responder o questionário Hexad, considerando que esses dados estão vinculados a traços de personalidade. O estudo foi realizado com 122 participantes e para a coleta dos dados foi desenvolvido um aplicativo para capturar informações como: nome de aplicativos instalados, duração de chamadas telefônicas e número médio de palavras para mensagens enviadas e recebidas. Os participantes também responderam ao questionário Hexad e ao *Big Five Inventory* [John et al. 1991]. Para prever a pontuação para cada tipo de usuário, foram utilizados modelos de regressão. Como resultado, os autores encontraram equações de regressão com potencial para prever a pontuação dos tipos de usuário do modelo Hexad, que podem ser utilizadas para adaptar sistemas gamificados sem a necessidade de preencher questionários.

Kimpen et al. [2021] exploraram o uso de dados bancários para identificar os tipos de usuário do modelo Hexad. O estudo foi realizado com onze especialistas da área de gamificação e de bancos, com o objetivo de verificar se existe uma relação entre os tipos de usuários Hexad e os dados bancários. Os autores fizeram uso de um aplicativo que atribui categorias para cada transação bancária, de forma a demonstrar uma visão geral de quanto os usuários gastam em cada categoria. A partir das análises realizadas, os especialistas apontaram que existe relação entre algumas atividades e os tipos de jogadores, por exemplo, atividades sociais como gastos em restaurantes têm relação com os socializadores. Os autores concluíram que dados de transações bancárias têm potencial para automatizar a criação de perfis Hexad.

No trabalho de Mogavi et al. [2023] é apresentado um estudo exploratório sobre como prever comportamento do usuário e tipos de jogadores Hexad com base em suas preferências de jogo e jogabilidade, usando o modelo de aprendizagem de máquina *Extreme Gradient Boosting* (XGBoost). Os dados de entrada foram de 67 usuários da plataforma on-line *Stack Ex-change* e de quatro questionários distintos: Bartle, Big Five, BrainHex e Hexad. Foram realizadas análises de correlação de Pearson para descobrir relações entre os perfis comportamentais no site *Stack Ex-change*, os perfis apontados pelos questionários Bartle, Big Five e BrainHex e o perfil Hexad. Os resultados da correlação de Pearson apontaram que existem algumas correlações positivas entre os perfis Bartle, Big Five e BrainHex com os perfis Hexad, por exemplo, o perfil “matador” de Bartle se correlaciona positivamente com os perfis conquistador, jogador e disruptor. Com relação à previsão de comportamento e previsão de tipos Hexad, os resultados apontaram que a combinação do XGBoost e as medidas de tipo de usuário BrainHex foram melhores do que as combinações com o Big Five e o Bartle para prever o comportamento do usuário e também para a previsão do tipo Hexad.

Em Altmeyer et al. [2019] e Kimpen et al. [2021], foram utilizadas diferentes alternativas para identificar tipos de usuário Hexad, assim como neste trabalho, porém, em vez de usar dados provenientes de *smartphones* ou transações bancárias, foram utilizados dados obtidos da interação de usuários com elementos de uma gamificação. Em semelhança a este trabalho, Mogavi et al. [2023] também utilizaram técnicas de aprendizagem de máquina para prever usuários Hexad, porém os dados de entrada foram provenientes de questionários enquanto que neste trabalho, os dados foram as interações dos usuários com os elementos do sistema CodeBench/CodePlay da Universidade Federal do

Amazonas.

3. Gamificação e tipos de jogador

Um dos fatores mais importantes do processo de modelagem de sistemas gamificados é considerar a personalidade, as motivações e interesses dos usuários. Isso pode caracterizar diferentes tipos de jogadores, que se identificam e interagem com determinados elementos dentro do ambiente em questão [González et al. 2016]. Um sistema gamificado pode ser formado por diversos elementos de jogos: competição, *rankings*, recompensas, desafios. Dependendo de quais são os elementos de jogos selecionados para compor um sistema gamificado, é possível que nem todos os usuários do sistema se interessem e se sintam engajados com a gamificação. Diante disso, como usuários diferentes se interessam por elementos diferentes, muitos estudos defendem a adaptação de sistemas gamificados de acordo com a particularidade dos usuários.

Nesse sentido, na literatura existem algumas tipologias de jogador como as de Bartle [1996], Yee [2006] e Tondello et al. [2019]. Cada uma delas define determinados tipos de usuário/jogador, de acordo com o comportamento ou as preferências de cada um.

O modelo Hexad [Marczewski 2015] é uma tipologia voltada para a classificação de jogadores em ambientes e sistemas gamificados e divide os usuários em seis tipos: (i) filantropo, buscam por significado em suas ações e gostam de ajudar os outros; (ii) socializador, são motivados por relações sociais, gostam de interagir com os outros e criar conexões; (iii) espírito livre, prezam pela autonomia e liberdade e gostam de explorar o ambiente; (iv) conquistador, são motivados pela competência, ou seja, gostam de enfrentar e vencer desafios; v) jogador, são motivados por aspectos extrínsecos, buscam sempre pelas recompensas; e, vi) disruptor, são motivados por mudanças, gostam de testar os limites do sistema, podem interferir negativamente por meio de trapaças ou positivamente para melhorar o sistema.

Para identificar os tipos de jogador de acordo com o modelo Hexad, existe um questionário validado por Tondello et al. [2016], que se trata de uma escala de 24 itens para pontuar as preferências dos usuários em relação às seis diferentes motivações propostas pelo modelo.

O questionário possui seis conjuntos de afirmações, cada um representando um tipo de jogador. A análise do questionário consiste no somatório das pontuações atribuídas pelo usuário para cada uma das seis classes de afirmações. Dessa forma, é possível verificar para qual delas a pontuação foi maior, ou seja, com qual ou quais tipos de usuário o jogador mais se identifica, comumente chamados na literatura de perfil dominante [Akgün and Topal 2018, Santos et al. 2021].

Nesta pesquisa, o questionário Hexad foi aplicado com os estudantes para capturar o tipo de jogador de cada um. Esse dado foi importante para o treinamento dos modelos de aprendizagem de máquina, pois serviram como os rótulos das classes.

4. Aprendizagem de máquina e tarefas de classificação

A aprendizagem de máquina (ou *machine learning*) é um campo da Inteligência Artificial que se concentra no desenvolvimento de algoritmos que são capazes de “imitar” a forma como os humanos aprendem [El Naqa and Murphy 2015].

Os algoritmos de aprendizagem de máquina utilizam dados de exemplo para resolver problemas e se dividem em quatro categorias [Sarker 2021]: aprendizagem supervisionada, que usa dados de treinamento rotulados; aprendizagem não-supervisionada, onde os dados de treinamento não são rotulados; aprendizagem semi-supervisionada, uma junção dos métodos supervisionados e não-supervisionados; aprendizagem por reforço, uma técnica que permite que agentes de *software* avaliem o comportamento ideal em determinado contexto ou ambiente para melhorar sua eficiência.

A aprendizagem de máquina pode ser aplicada em diferentes tarefas, entre elas: classificação, regressão, agrupamento de dados, aprendizado de regras de associação e engenharia de recursos para redução de dimensionalidade [Sarker 2021].

A classificação é um método de aprendizagem supervisionada, que pode ser dita como um problema de predição, onde um exemplo é classificado em um rótulo de classe [Han et al. 2022]. Um exemplo clássico e real de tarefa de classificação é a detecção de spam em provedores de serviços de e-mail com os rótulos de “spam” e “não-spam”. Na literatura, existem diversos algoritmos de aprendizagem de máquina para resolver problemas de classificação, sendo alguns exemplos: *K-nearest neighbors* (KNN), *Random Forest* (RF) e *Bagging*.

Neste trabalho, a aprendizagem de máquina foi utilizada para classificar usuários de acordo com o tipo de jogador, onde foram utilizados como dados de treinamento os elementos de jogos com os quais os usuários interagiram dentro do CodePlay e os rótulos de classe foram as respostas obtidas com a aplicação do questionário Hexad.

Dentro de aprendizagem de máquina, é importante realizar a avaliação dos modelos, com o objetivo de medir o quão distante o algoritmo está de classificar os exemplos corretamente. Por isso, nesta pesquisa foram aplicadas as seguintes métricas de avaliação: i) acurácia, que avalia quantos exemplos foram classificados corretamente; ii) precisão, que se baseia na razão entre a quantidade de exemplos classificados corretamente como positivos e o total de exemplos classificados como positivos; iii) revocação, um método baseado na razão entre a quantidade de exemplos classificados corretamente como positivos e a quantidade de exemplos que são de fato positivos; e, iv) *F1-Score*, definido pela média harmônica entre a precisão e a revocação.

5. Design do experimento

O estudo foi realizado com estudantes de Introdução à Programação de Computadores (IPC) da Universidade Federal do Amazonas (UFAM), contemplando dados de utilização da plataforma de gamificação CodePlay e respostas ao questionário Hexad de quatro semestres distintos [Melo et al. 2023]. Este estudo foi realizado no âmbito do Projeto Samsung-UFAM para Ensino e Pesquisa (SUPER) com o objetivo de melhorar o desempenho acadêmico dos alunos de graduação STEM da UFAM.

5.1. Criação da base de dados

A plataforma de gamificação CodePlay possui um sistema de *logs* que captura os dados de interação dos estudantes com os elementos de jogos. A Tabela 1 apresenta uma representação de como os *logs* são guardados.

Para a criação da base de dados, foram extraídas dos *logs* as informações sobre a interação dos estudantes com os diferentes elementos disponíveis na gamificação. Após

Tabela 1. Representação de como os logs são armazenados.

Exemplos de logs da plataforma de gamificação
2021-03-29T11:19:41.174 2838 284 sendMessage {"message":"yooo","toUsersIds":"1062"}
2022-05-19T16:26:03.503 7004 387 minimapa {"map":1,"mapRoot":1}
2022-05-20T12:12:45.611 2841 371 quest {"id":1,"step":1,"end":false,"map":1,"mapRoot":1}

verificar quais logs estavam relacionados a quais elementos, foi realizado um quantitativo, por estudante (identificado por um *id*), de interações com cada elemento. Foram selecionadas 23 variáveis, sendo elas:

1. Moedas: a quantidade de moedas que o estudante coletou;
2. Passagens secretas: a quantidade de vezes que o estudante utilizou uma passagem secreta;
3. *Ranking*: a quantidade de vezes que o estudante acessou ao menu de *ranking*;
4. Barra de progresso: a quantidade de vezes que o estudante acessou a barra de progresso, onde pode ser visualizado o progresso com relação as missões realizadas, locais desbloqueados, áreas secretas e *easter eggs* encontrados;
5. Minimapa: a quantidade de vezes que o estudante acessou o minimapa;
6. Mensagens enviadas: a quantidade de mensagens enviadas pelo estudante;
7. Mensagens recebidas: a quantidade de mensagens recebidas pelo estudante;
8. NPCs (*non-player characters*): a quantidade de vezes que um estudante interagiu com um NPC;
9. Doações enviadas: a quantidade de doações enviadas pelo estudante;
10. Doações recebidas: a quantidade de doações recebidas pelo estudante;
11. *Easter eggs*: a quantidade de *easter eggs* que o estudante coletou;
12. Diário: a quantidade de vezes que o estudante acessou o diário, onde ficam disponibilizadas as missões;
13. Menu itens: a quantidade de vezes que o estudante acessou o menu de itens, onde é possível visualizar itens como armas, armaduras e poções;
14. Menu equipar: a quantidade de vezes que o estudante acessou o menu equipar, onde é possível equipar o personagem com armas e armaduras;
15. Som: a quantidade de vezes que o estudante ligou/desligou o som;
16. Menu jogadores: a quantidade de vezes que o estudante acessou o menu jogadores, onde é possível selecionar um colega e enviar mensagens ou doações;
17. Pontos de experiência (XP): a quantidade de pontos de experiência que o estudante coletou;
18. Menu outras opções: a quantidade de vezes que o estudante acessou o menu itens, onde é possível visualizar opções de atalhos do teclado, teleporte, minimapa, legenda do minimapa e ajuda;
19. *Infobox*: a quantidade de vezes que o estudante acessou o *infobox* de outro jogador, que acontece ao passar o mouse por cima do avatar do jogador, e é possível visualizar uma caixa de informações sobre o mesmo;
20. Óculos: a quantidade de vezes que o estudante ganhou o óculos, uma estilização no avatar que é dada aos três jogadores que mais se destacaram no jogo, acumulando mais moedas e pontos de experiência;
21. Escolhas anarquistas: a quantidade de vezes que o estudante fez uma escolha anarquista, que é algo que pode prejudicar outros jogadores;

22. Missões: a quantidade de missões que o estudante realizou;
23. *Logs* gerados: a quantidade de *logs* gerados pelo estudante dentro da gamificação.

No início de cada período letivo, os estudantes responderam ao questionário Hexad. As respostas obtidas a partir disso, ou seja, o tipo de jogador de cada um, foram utilizadas como os rótulos de classe de cada instância do conjunto de dados.

Durante os quatro semestres letivos, foram coletados dados de 350 estudantes de IPC. No entanto, para os experimentos foram considerados apenas os estudantes que responderam o questionário Hexad e que resultaram em somente um perfil dominante e que obtiveram 150 ou mais pontos de experiência dentro da plataforma de gamificação.

Os pontos de experiência são recompensas que os estudantes ganham e que precisam ser coletadas dentro do mundo do jogo. Foi considerado 150 ou mais, pois são recompensas oferecidas em todas as fases, em valores de 10, 15, 20, 50, e se o estudante recebeu essas gratificações e não coletou, é possível que ele não tenha passado tanto tempo dentro da gamificação. Ao final, ficaram então 128 jogadores.

Das 128 instâncias, verificou-se que apenas 2 pertenciam à classe disruptor. Diante disso, a classe foi descartada do *dataset* e a base de dados final consistiu em: i) atributos, as 23 variáveis selecionadas; e, ii) atributo-alvo, o tipo de jogador (filantropo, socializador, espírito livre, conquistador ou jogador).

Na Figura 1, é possível visualizar a distribuição das 126 instâncias entre as classes. O perfil com mais estudantes é o espírito livre ($n = 36$; 29%), seguido pelo jogador ($n = 32$; 25%), filantropo ($n = 30$; 24%), conquistador ($n = 21$; 17%) e socializador ($n = 7$; 5%).




Figura 1. Distribuição das classes na base de dados.

5.2. Métodos investigados

Para os experimentos de classificação de usuários foram selecionados três algoritmos: i) *Random Forest*; ii) *K-Nearest Neighbors*; e, iii) *Bagging*. Devido à pouca quantidade de dados e ao desbalanceamento das classes, escolheu-se trabalhar com a técnica de *over-sampling*, onde é realizado o aumento da quantidade de instâncias das classes com menos amostras, para igualar ao número de instâncias da classe de maior número de amostras.

O *dataset* foi dividido em conjunto de treinamento (70%) e de teste (30%). Além disso, para avaliar o desempenho dos modelos foi aplicada a técnica de validação cruzada (*cross-validation*), um método de reamostragem que consiste em utilizar diferentes partes dos dados para testar e treinar um modelo em diferentes iterações.

6. Resultados

Após a realização dos experimentos, foi possível chegar aos resultados apresentados na Tabela 2. Observa-se que as acurácias obtidas com os três algoritmos não foram boas. Porém, utilizando *oversampling*, os resultados obtidos foram melhores do que usando o *dataset* original.

O algoritmo que obteve maior acurácia foi o *Random Forest*, com 57%. A Tabela 3 mostra os valores de Precisão, Revocação e *F1-Score* considerando apenas os resultados obtidos com o método *Random Forest* para a base com *oversampling*. Percebe-se que as métricas foram mais altas na classe socializador (com exceção da precisão, que foi maior para o filantropo), indicando que o modelo foi melhor (classificou corretamente as instâncias) para essa classe, enquanto foi pior para os jogadores.

Tabela 2. Acurácia obtida com cada algoritmo.

Algoritmo	Dataset	Acurácia
Random Forest	Original	0.23
	Com <i>oversampling</i>	0.57
KNN	Original	0.26
	Com <i>oversampling</i>	0.50
Bagging	Original	0.34
	Com <i>oversampling</i>	0.51

Tabela 3. Métricas avaliadas para o melhor modelo.

Classe	Precisão	Revocação	<i>F1-Score</i>
Conquistador	0.64	0.70	0.67
Espírito livre	0.20	0.10	0.13
Filantropo	0.75	0.50	0.60
Jogador	0.27	0.38	0.32
Socializador	0.74	1.00	0.85

Outro fator avaliado para o modelo com a melhor acurácia foi a relevância dos atributos (*feature importance*). Os atributos mais relevantes foram: i) quantidade interações com o NPC; ii) quantidade de vezes que ganhou o óculos; iii) quantidade de vezes que acessou o *infobox* de outro jogador; iv) quantidade de vezes que acessou o menu de outras opções; e, v) quantidade de vezes que usou o minimapa. Os menos relevantes: i) quantidade de vezes que recebeu mensagens; ii) quantidade de *easter eggs* que coletou; iii) quantidade de vezes que fez uma escolha anarquista; iv) quantidade de doações que fez; e, v) quantidade de doações que recebeu.

O que pode ter influenciado a relevância dos atributos é a quantidade de interações que os estudantes tiveram com os elementos. Por exemplo, existem alunos que não fize-

ram doação no jogo, o que os deixa com zero no atributo “itens doados”. No entanto, a variável de interações com NPCs possui valor alto para a maioria dos estudantes.

Ainda sobre o melhor modelo, na Tabela 3, percebe-se que a classe socializador teve melhores resultados que as demais com relação à revocação e *F1-Score*, isso pode indicar que os atributos tiveram mais significado para esta classe.

Ao aplicar o método de validação cruzada com CV=5 e CV=10, os resultados com os três modelos ficaram conforme a Tabela 4. É possível visualizar que a pontuação da validação cruzada também foi maior para o algoritmo *Random Forest* com o método de *oversampling* aplicado no *dataset*.

Tabela 4. Resultados obtidos com CV (cross-validation).

Algoritmo	Dataset	CV=5	CV=10
Random Forest	Original	0.28	0.22
	Com <i>oversampling</i>	0.42	0.48
KNN	Original	0.27	0.24
	Com <i>oversampling</i>	0.41	0.39
Bagging	Original	0.23	0.22
	Com <i>oversampling</i>	0.38	0.43

7. Discussão

Os experimentos de classificação com os três algoritmos distintos mostrou que a melhor acurácia obtida foi com o algoritmo *Random Forest* aplicando a técnica de *oversampling*. Tendo em vista que trata-se de um problema multi-classe e que um estudo sobre a classificação de usuários com base nos dados de interação com uma gamificação não foi realizado anteriormente, a acurácia encontrada, de 57%, pode ser considerada bastante razoável, dada a complexidade do problema. No entanto, a pouca quantidade de dados (somente 126 instâncias) pode ter influenciado nos resultados e a baixa quantidade de interações dos estudantes com a plataforma de gamificação CodePlay também pode ter afetado os resultados, visto que as variáveis utilizadas como dados de entrada dos modelos representavam as interações dos estudantes com os elementos da gamificação.

Uma das explicações para o baixo número de interações com os elementos, pode ser o fato de que dois dos períodos nos quais os dados foram coletados ocorreram de forma remota e durante esse tempo os estudantes tiveram problemas de acesso à gamificação, uma vez que a plataforma foi projetada para ser utilizada nos laboratórios da Universidade e em computadores robustos, o que pode não ser a realidade da maioria dos estudantes.

Visto que a base foi construída a partir das interações dos estudantes com o ambiente de gamificação, vê-se a importância de que os elementos disponíveis no CodePlay sejam realmente utilizados, para que os atributos tenham mais significado para a classificação.

Com relação as métricas de avaliação terem sido melhores para a classe socializador, alguns pontos foram levantados. Visto que essa classe tinha o menor número de jogadores, uma das possibilidades é que esses estudantes podem ter prestado mais atenção no momento de responder ao questionário e também tenham interagido mais com os elementos da gamificação do que os demais perfis. Além disso, o filantropo, que possuía

o maior número de pessoas na amostragem, obteve a maior precisão no modelo que se saiu melhor, isso pode indicar que eles também tiveram maior dedicação para responder o questionário e interagir com a gamificação. No entanto, esses são pontos que devem ser explorados em outros estudos, para verificar se é algo que aconteceu apenas nesse contexto ou se repete em outros.

O questionário Hexad também pode ter influenciado nos resultados, pois é possível que os estudantes tenham sido identificados como uma classe, mas se comportado de maneira diferente ao interagir com os elementos. Outro ponto que pode ser citado é relacionado a pesquisas recentes na área de gamificação que apontam que o tipo de usuário pode mudar ao longo do tempo, o que também pode ter interferido nos resultados alcançados com os experimentos de classificação.

8. Considerações finais

Este trabalho apresentou um estudo exploratório sobre a classificação de tipos de jogador do modelo Hexad a partir de dados de interação de usuários com uma plataforma de gamificação baseada em jogos de RPG. Para realizar a classificação foram utilizados três algoritmos de aprendizagem de máquina: *Random Forest*, *K-nearest neighbors* e *Bagging*. Os dados de treinamento foram as interações com a gamificação e as respostas ao questionário Hexad, que serviram como os rótulos das classes, ou seja, os tipos de jogador Hexad (conquistador, socializador, filantropo, espírito livre e jogador).

Considerando que os experimentos de classificação realizados nesta pesquisa foram de classificação multi-classe, a acurácia obtida com o *Random Forest*, de 57%, não foi tão ruim, mas o fato da quantidade de dados utilizados para o treinamento ter sido baixa pode ter afetado o resultado. Como trabalhos futuros, pretende-se coletar mais dados de interação para verificar se os resultados da classificação melhoram no que diz respeito as métricas de avaliação. Outro ponto importante é realizar a coleta de dados em mais períodos presenciais, tendo em vista visualizar se o número de interação com os elementos aumenta. Apesar disso, espera-se que este trabalho leve a mais pesquisas na área de personalização de usuários, visando identificá-los de forma automatizada.

8.1. Limitações

Uma das principais limitações da pesquisa foi o fato de que grande parte dos dados coletados foram em períodos remotos, durante a Pandemia de Covid-19 e também pós-pandemia. Esse é um fator que pode ter influenciado de maneira negativa nos resultados encontrados, visto que houve uma baixa quantidade de interações dos estudantes com os elementos da gamificação. Outro aspecto que foi uma limitação é o tamanho da amostra utilizada, que pode limitar a generalização dos resultados para populações maiores.

Agradecimentos

Esta pesquisa, realizada no âmbito do Projeto Samsung-UFAM de Ensino e Pesquisa (SUPER), de acordo com o Artigo 39 do Decreto nº10.521/2020, foi financiada pela Samsung Eletrônica da Amazônia Ltda, nos termos da Lei Federal nº8.387/1991, através do convênio 001/2020 firmado com a UFAM e FAEPI, Brasil.

Referências

- Akgün, Ö. E. and Topal, M. (2018). Adaptation of the gamification user types hexad scale into turkish. *International Journal of Assessment Tools in Education*, 5(3):389–402.
- Altmeyer, M., Lessel, P., Schubhan, M., and Krüger, A. (2019). Towards predicting hexad user types from smartphone data. In *Extended Abstracts of the Annual Symposium on Computer-Human Interaction in Play Companion Extended Abstracts*, pages 315–322.
- Bartle, R. (1996). Hearts, clubs, diamonds, spades: Players who suit muds. *Journal of MUD research*, 1(1):19.
- Deterding, S., Dixon, D., Khaled, R., and Nacke, L. (2011). From game design elements to gamefulness: defining “gamification”. In *Proceedings of the 15th international academic MindTrek conference: Envisioning future media environments*, pages 9–15.
- Einola, K. and Alvesson, M. (2021). Behind the numbers: questioning questionnaires. *Journal of Management Inquiry*, 30(1):102–114.
- El Naqa, I. and Murphy, M. J. (2015). What is machine learning? In *machine learning in radiation oncology*, pages 3–11. Springer.
- Galvão, L., Fernandes, D., and Gadelha, B. (2016). Juiz online como ferramenta de apoio a uma metodologia de ensino híbrido em programação. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*, volume 27, page 140.
- González, C. S., Toledo, P., Muñoz, V., et al. (2016). Enhancing the engagement of intelligent tutorial systems through personalization of gamification. *International Journal of Engineering Education*, 32(1):532–541.
- Han, J., Pei, J., and Tong, H. (2022). *Data mining: concepts and techniques*. Morgan kaufmann.
- Hanus, M. D. and Fox, J. (2015). Assessing the effects of gamification in the classroom: A longitudinal study on intrinsic motivation, social comparison, satisfaction, effort, and academic performance. *Computers & education*, 80:152–161.
- Herbert, B., Charles, D., Moore, A., and Charles, T. (2014). An investigation of gamification typologies for enhancing learner motivation. In *2014 International Conference on Interactive Technologies and Games*, pages 71–78. IEEE.
- John, O. P., Donahue, E. M., and Kentle, R. L. (1991). Big five inventory. *Journal of Personality and Social Psychology*.
- Kapp, K. M. (2012). *The gamification of learning and instruction: game-based methods and strategies for training and education*. John Wiley & Sons.
- Kimpen, R., De Croon, R., Vanden Abeele, V., and Verbert, K. (2021). Towards predicting hexad user types from mobile banking data: An expert consensus study. In *Extended Abstracts of the 2021 Annual Symposium on Computer-Human Interaction in Play*, pages 30–36.
- Kiryakova, G., Angelova, N., and Yordanova, L. (2014). Gamification in education. Proceedings of 9th International Balkan Education and Science Conference.

- Klock, A. C. T., Gasparini, I., Pimenta, M. S., and Hamari, J. (2020). Tailored gamification: A review of literature. *International Journal of Human-Computer Studies*, 144:102495.
- Koivisto, J. and Hamari, J. (2019). The rise of motivational information systems: A review of gamification research. *International Journal of Information Management*, 45:191–210.
- Majuri, J., Koivisto, J., and Hamari, J. (2018). Gamification of education and learning: A review of empirical literature. In *Proceedings of the 2nd international GamiFIN conference, GamiFIN 2018*. CEUR-WS.
- Marczewski, A. (2015). Even ninja monkeys like to play. *London: Blurb Inc*, 1(1):28.
- Melo, R. et al. (2023). Um estudo sobre a tipologia de usuários hexad e sua relação com os elementos de jogos de uma plataforma de gamificação baseada em jogos rpg.
- Mogavi, R. H., Deng, C., Hoffman, J., Haq, E.-U., Gujar, S., Bucchiarone, A., and Hui, P. (2023). Your favorite gameplay speaks volumes about you: Predicting user behavior and hexad type. *arXiv preprint arXiv:2302.05623*.
- Nacke, L. E., Bateman, C., and Mandryk, R. L. (2014). Brainhex: A neurobiological gamer typology survey. *Entertainment computing*, 5(1):55–62.
- Pessoa, M., Fernandes, D., de Carvalho, L. S. G., Oliveira, E., Nakamura, W., and Conte, T. (2019). Codeplay: Uma plataforma de gamificação baseada em jogos de rpg multiplayer. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*, volume 30, page 843.
- Pessoa, M. S. P. et al. (2022). Codeplay: uma plataforma que incorpora a ludicidade de jogos de entretenimento a um juiz on-line.
- Santos, A. C. G., Oliveira, W., Altmeyer, M., Hamari, J., and Isotani, S. (2022). Psychometric investigation of the gamification hexad user types scale in brazilian portuguese. *Scientific reports*, 12(1):1–11.
- Santos, A. C. G., Oliveira, W., Hamari, J., and Isotani, S. (2021). Do people’s user types change over time? an exploratory study. *arXiv preprint arXiv:2106.10148*.
- Santos, W. O. d., Bittencourt, I. I., and Vassileva, J. (2018). Design of tailored gamified educational systems based on gamer types.
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*, 2(3):1–21.
- Toda, A. M., Valle, P. H., and Isotani, S. (2017). The dark side of gamification: An overview of negative effects of gamification in education. In *Researcher links workshop: higher education for all*, pages 143–156. Springer.
- Tondello, G. F., Arrambide, K., Ribeiro, G., Cen, A. J.-I., and Nacke, L. E. (2019). “i don’t fit into a single type”: A trait model and scale of game playing preferences. In *IFIP Conference on Human-Computer Interaction*, pages 375–395. Springer.
- Tondello, G. F., Wehbe, R. R., Diamond, L., Busch, M., Marczewski, A., and Nacke, L. E. (2016). The gamification user types hexad scale. In *Proceedings of the 2016 annual symposium on computer-human interaction in play*, pages 229–243.

Yee, N. (2006). The demographics, motivations, and derived experiences of users of massively multi-user online graphical environments. *Presence: Teleoperators and virtual environments*, 15(3):309–329.