

Aplicações de Técnicas de Machine Learning e Gamificação no Autocuidado em Saúde: Uma Revisão Sistemática

Filipe M. S. dos Anjos, Luma W. Oliveira, Carlos Henrique R. Souza, Sergio T. Carvalho

¹Instituto de Informática – Universidade Federal de Goiás
Goiânia – GO – Brasil

filipemaciel@discente.ufg.br

{lumawanderley, carloshenriquerorato, sergio}@inf.ufg.br

Abstract. *Self-care in health requires the patient to be motivated to engage with their treatment. Gamification and machine learning techniques have been considered in applications that support self-care. This work seeks to understand, through a systematic literature review, machine learning and gamification techniques that can effectively provide resources for patients to engage in self-care. Among the selected articles involving gamification, machine learning and self-care or engagement, 12.1% apply techniques that involve the joining of these areas and 9.1% use machine learning to identify and classify user characteristics in order to define their profile, and then provide a personalized or context-adapted gamification.*

Key-words: *machine-learning, self-care, mHealth, gamification, engagement.*

Resumo. *O autocuidado em saúde exige que o paciente esteja motivado para que ele se engaje com o seu tratamento. Gamificação e técnicas de machine learning têm sido consideradas em aplicações que apoiam o autocuidado. Este trabalho busca entender, por meio de uma revisão sistemática da literatura, as técnicas de machine learning e de gamificação que possam prover de forma efetiva recursos para que o paciente se engaje no seu autocuidado. Entre os artigos selecionados envolvendo gamificação, machine learning e autocuidado para solucionar problemas relacionados ao engajamento do paciente com o seu tratamento, 12,1% aplicam técnicas que envolvem a junção dessas áreas, e 9,1% utilizam machine learning para identificar e classificar características dos usuários visando definir seu perfil, e então prover uma gamificação personalizada ou adaptada ao contexto.*

Palavras-chave: *machine-learning, autocuidado, mHealth, gamificação, engajamento.*

1. Introdução

Sistemas de *software* que apoiam e promovem o autocuidado têm sido usados como forma de manter os indivíduos engajados com o cuidado de sua própria saúde. Nesse sentido, têm surgido evidências de que aplicativos persuasivos são capazes de promover comportamentos saudáveis [Zhang et al. 2021]. O engajamento, neste contexto, pode ser definido a partir de uma perspectiva de usabilidade e associado ao nível de participação do usuário no uso de um sistema computacional, melhorando sua experiência [Oliveira and Carvalho 2020].

Um dos elementos comumente utilizados para estimular o engajamento no autocuidado é a gamificação, porém, fatores como a não adaptabilidade ao contexto e a escolha de elementos de jogos que não fazem sentido ao propósito da aplicação são comuns [Marczewski 2015, Tondello et al. 2017, Oliveira and Carvalho 2020]. A devida fundamentação para aplicar-se técnicas de gamificação é de extrema importância pois, caso aplicada de forma errônea, pode causar efeitos contrários ao esperado [Duggal et al. 2021, Alqahtani et al. 2021, Li et al. 2016].

Uma gamificação que consiga se adaptar às especificidades dos usuários tem sido objeto de estudo de pesquisadores, com o intuito de manter o engajamento de usuários com os principais recursos do software [Wanderley O. L. 2020, Tondello et al. 2017].

Este artigo documenta uma Revisão Sistemática da Literatura (RSL) realizada para identificar trabalhos que usam a gamificação para o engajamento do paciente em seu autocuidado, e que utilizam técnicas de *machine learning* (ML). As principais contribuições deste trabalho são: identificação das técnicas de ML que vêm sendo aplicadas para prover o engajamento do paciente em seu autocuidado utilizando gamificação; e identificação das oportunidades de pesquisa utilizando ML e gamificação para promover o engajamento no autocuidado. O artigo está organizado em 4 seções, além desta introdutória: a Seção 2 descreve o protocolo e a condução da pesquisa; a Seção 3 apresenta os resultados e as discussões; e por fim, a Seção 4 apresenta as considerações finais.

2. Protocolo e Condução da Pesquisa

Esta RSL foi conduzida utilizando a metodologia proposta por [Brereton et al. 2007] que consiste nos seguintes passos: (I) Identificação da necessidade do estudo; (II) Definição do protocolo da revisão, constituído pelas questões de pesquisa, palavras-chave, sinônimos, estratégia de busca, e os critérios de inclusão e exclusão dos estudos; (III) Condução da revisão, composta pela realização das buscas e seleção dos trabalhos; (IV) Análise de qualidade dos trabalhos selecionados; e (V) Extração e análise dos dados dos trabalhos selecionados. Para a condução dessa revisão sistemática foi utilizada a plataforma *web Parsf.al*, cujos recursos disponíveis auxiliaram em todas as etapas da revisão.

As questões de pesquisa definidas foram: QP1: Quais trabalhos apresentam resultados empregando gamificação e ML?; QP2: Como técnicas de ML vêm sendo aplicadas para prover o engajamento do paciente em seu autocuidado?

As palavras-chaves e os sinônimos escolhidos foram: (P.1) ML; (P.2) *engagement (adherence, engaging)*; (P.3) *self care (self-care, selfcare)*. A combinação destas palavras formaram a *string* de busca. A *string* de busca genérica ficou definida da seguinte forma: "*Machine Learning*" AND ("*self care*" OR "*self-care*" OR *selfcare* OR "*engagement*" OR "*adherence*" OR "*engaging*") AND *gamification*. Essa *string* recebeu adaptações em conformidade com as regras de cada uma das bases utilizadas.

Em relação ao critério de inclusão, optou-se por selecionar estudos que envolvam ML e gamificação. Para a exclusão, foram definidos os seguintes critérios: (I) não estarem no contexto de autocuidado ou engajamento; (II) não terem sido revisados por pares; (III) não descreverem um estudo primário; (IV) serem uma versão mais antiga de outro já considerado; (V) terem data de publicação anterior há 5 anos; (VI) não serem escritos em português ou inglês; (VII) texto integral não ser acessível; (VIII) não possuírem resumo e título.

Foi adotada durante a extração de dados, os seguintes critérios: o domínio principal do artigo; as abordagens para melhorar o engajamento; as abordagens de ML utilizadas; os desafios relacionados ao engajamento e autocuidado; os desafios relacionados à gamificação; apresentação de solução ou proposta do uso de ML com gamificação.

3. Resultados e Discussões

Definido o protocolo, foram selecionadas 5 (cinco) bases para a realização da pesquisa - *ACM Digital Library*; *IEEE Digital Library*; *Scopus*; *Springer Link*; e *ScienceDirect* - nas quais foram aplicadas a *string* de busca definida no protocolo descrito na Seção 2. Durante o processo foram realizados ajustes na *string* para melhor se adaptar às particularidades de cada

base. Foram importados 403 trabalhos, considerando todas as bases, assim divididos: ACM (168); IEEE (7); Scopus (29); Springer Link (115); Science Direct (84). Somente publicações realizadas nos últimos 5 (cinco) anos foram consideradas para a importação.

De forma geral, a etapa de seleção dos trabalhos se deu a partir da leitura dos títulos, palavras-chaves e resumos dos artigos¹. Foram selecionados 33 artigos, os quais passaram por uma extração de dados mais detalhada, frisando os aspectos importantes para a pesquisa.

3.1. (QP1) Quais trabalhos apresentam resultados empregando gamificação e machine learning?

Entre os 33 artigos selecionados, a maioria foi publicada nos anos de 2020 e 2021 (Figura 1), caracterizando uma crescente de pesquisas com as temáticas autocuidado, gamificação e ML.




Figure 1. Artigos selecionados por ano de publicação.

Uma quantidade de 11 trabalhos (33,3%) engloba as áreas de saúde, educação, jogos sérios e software comercial nos mais variados setores, com abordagens para adaptar a gamificação ao contexto do domínio, tendo como objetivo identificar as particularidades de cada usuário [Missaoui and Maalel 2021, Schäfer et al. 2018]. Foram encontrados em 8 artigos (24,2%), abordagens de gamificação voltadas para o autocuidado do paciente. Grande parte dessas abordagens não utiliza ou apenas menciona como possibilidades para trabalhos futuros a utilização de técnicas de inteligência artificial (IA) para melhorar o desempenho do software através de sistemas de recomendação, identificação de padrões de perfil do usuário e/ou adaptação do software para cada usuário conforme o seu perfil [Oliveira and Carvalho 2020, Tondello et al. 2017].

A pesquisa de [Khoshkangini et al. 2021] aponta que um dos problemas comumente abordados na gamificação é o foco dos designers apenas na camada superficial dos elementos de jogos, tais como pontuação, *badges* e *leaderboards*, e não exploram todo o potencial dos jogos em termos de engajamento e motivação, reforçando a importância da personalização conforme habilidades e preferências específicas. Por fim, [Khoshkangini et al. 2021] propõem uma abordagem de gamificação genérica implementada em um experimento em campo aberto de grande escala e longa duração, envolvendo mais de 400 participantes ativos.

A ML é uma poderosa tecnologia de categorização de dados em conjuntos de classes genéricas [Duggal et al. 2021], portanto alguns trabalhos encontrados utilizam técnicas de ML para identificar no usuário as características e perfil de jogador, e relacionar

¹Um apêndice contendo tabelas completas com todas as referências bibliográficas dos trabalhos selecionados foi, por questão de espaço, disponibilizado para o acesso em <https://m5.gs/NTIGbW>

estes perfis a determinados elementos de jogos [Wanderley O. L. 2020, Alaghbari et al. 2020, Sweetser Kyburz et al. 2020, Loria and Marconi 2021]. O autor de [Marczewski 2015], citado por [Wanderley O. L. 2020, Tondello et al. 2017], é uma das maiores referências na literatura sobre a definição de perfis dos jogadores, classificando-os em 6 (seis) tipos: filantropos; socializadores; espíritos livres; empreendedores; jogadores; e disruptores.

Contudo, de forma geral, os artigos selecionados que relacionam gamificação e ML, aplicam a técnica de IA para identificação e classificação do perfil dos usuários por meio de informações dos registros (*logs*) das interações do usuário com a interface, ou por meio de entradas de dados como formulários, entrada de dados de sensores, questionários e outros.

3.2. (QP2) Como técnicas de ML vêm sendo aplicadas para prover o engajamento do paciente em seu autocuidado?

Cerca de 9,1% dos trabalhos utilizam ML para identificar e classificar características dos usuários visando definir seu perfil, e então prover uma gamificação personalizada ou adaptada ao contexto [Duggal et al. 2021]. Por outro lado, 12,1% dos artigos combinam gamificação, ML e autocuidado para solucionar problemas relacionados ao engajamento do paciente com o seu tratamento e rotinas saudáveis [Oliveira and Carvalho 2020, Schäfer et al. 2018].

A abordagem de ML mais comum encontrada nos trabalhos selecionados foi utilizada para a classificação de perfil do usuário e indicação de elementos de jogos personalizados conforme cada perfil. No contexto do autocuidado, [Pinto et al. 2019] utilizaram ML para determinar padrões de vivência de idosos e fornecer informações aos cuidadores sobre a situação (*status*) dos cuidados e o progresso nos indicadores de saúde. Os dados utilizados para o estudo foram coletados por meio de uma rede de sensores sem fio discreta na casa de onze participantes. Porém, o artigo não descreve detalhes técnicos sobre a abordagem de ML utilizada.

Os autores do trabalho [Schäfer et al. 2018] utilizam um modelo de ML para processar os dados dos sensores e interpretar classes de atividades físicas que podem ser mensuráveis em termos de recomendação em saúde para prover objetivos diários aos usuários/pacientes. Uma das preocupações deste modelo é com a acurácia dos dados, pois são utilizados sensores de *smartphones*, os quais não possuem a mesma precisão de sensores vestíveis, causando lacunas na identificação da atividade do usuário.

Outra abordagem é a de [Li et al. 2016] que propõem um mecanismo de aprendizagem inteligente (SLM) para aumentar a eficiência dos exercícios de reabilitação. Para alcançar seus resultados, simula regressão com rede neural artificial (RNA), e Naive Bayes (NB) identificando qual abordagem é mais promissora na prática. Também utiliza modelos quantitativos encontrados na literatura como rede neurais perceptron multicamadas (MLPNN) e SLM para a classificação dos dados sendo o uso de cada um direcionado às características dos dados.

Os trabalhos [Knutas et al. 2019] focam em processos de design para a criação de projetos de gamificação utilizando ML para a classificação de perfis de usuários, definindo heurísticas de design para gamificação. Ambos os trabalhos demonstram um processo de design que usa aprendizado de máquina e automação baseados em algoritmos para implementar a personalização de forma que leve em consideração características pessoais sem que o trabalho adicional sobrecarregue os usuários de um sistema gamificado.

4. Conclusão

Apenas 12,1% dos trabalhos encontrados no atual estado da arte de fato aplicam técnicas de ML juntamente a gamificação para melhorar o engajamento do paciente, demonstrando uma área carente de pesquisas e aprofundamento. Entre as abordagens encontradas, a maioria que

utiliza ML está direcionada ao engajamento acadêmico de estudantes com suas atividades, principalmente no cenário de ensino remoto. Alguns dos trabalhos abordam pontos cognitivos do uso de aplicativos gamificados como ferramenta de auxílio e acompanhamento de pacientes com doenças mentais, doenças crônicas e para o auxílio nas mudanças de vida causadas por essas enfermidades.

Por outro lado, os trabalhos encontrados, ao concordarem acerca da importância do engajamento para o sucesso do tratamento e da gamificação para o alcance do engajamento, apontam para uma diversidade de meios e recursos para que o engajamento seja alcançado nos mais variados segmentos de software. Foi possível identificar que há uma lacuna no estado da arte relacionada à gamificação junto a técnicas de ML para o engajamento no autocuidado, expondo, portanto, uma área de pesquisa promissora, demandando aprofundamento e verificação das técnicas na forma de artefatos de software, e validação da sua efetividade relacionada ao engajamento. Projetos desenvolvidos nesse sentido poderão contribuir de forma positiva para o cenário de engajamento do paciente com o seu autocuidado.

References

- Alaghbari, S., Mitschick, A., Blichmann, G., Voigt, M., and Dachsel, R. (2020). Achiever or explorer? gamifying the creation process of training data for machine learning. *ACM*.
- Alqahtani, F., Meier, S., and Orji, R. (2021). Personality-based approach for tailoring persuasive mental health applications. *User Model User-Adapted Interac*, pages 1–43.
- Brereton, P., Kitchenham, B. A., Budgen, D., Turner, M., and Khalil, M. (2007). Lessons from applying the systematic literature review process within the software engineering domain. *Journal of Systems and Software*, 80(4):571–583. Software Performance.
- Duggal, K., Gupta, L. R., and Singh, P. (2021). Gamification and machine learning inspired approach for classroom engagement and learning. *Mathematical Problems in Engineering*, 2021.
- Khoshkangini, R., Valetto, G., Marconi, A., and Pistore, M. (2021). Automatic generation and recommendation of personalized challenges for gamification. *User Modeling User-Adapted Interaction*, 31(1):1–34.
- Knutas, A., Van Roy, R., Hynninen, T., Granato, M., Kasurinen, J., and Ikonen, J. (2019). A process for designing algorithm-based personalized gamification. *Mult Tools and App*, 78(10):13593–13612.
- Li, C., Rusák, Z., Horváth, I., and Ji, L. (2016). Development of engagement evaluation method and learning mechanism in an engagement enhancing rehabilitation system. *Eng App of AI*, 51:182–190.
- Loria, E. and Marconi, A. (2021). Exploiting limited players' behavioral data to predict churn in gamification. *Electronic Commerce Research and Applications*, 47:101057.
- Marczewski, A. (2015). Even ninja monkeys like to play: Gamification, game thinking and motivational design. *CreateSpace Independent Publishing*.
- Missaoui, S. and Maalel, A. (2021). Student's profile modeling in an adaptive gamified learning environment. *Education and Information Technologies*, 26(5):6367–6381.
- Oliveira, L. W. and Carvalho, S. T. (2020). A gamification-based framework for mhealth developers in the context of self-care. pages 138–141.
- Pinto, M., Pereira, M., Raposo, D., Simões, M., and Castelo-Branco, M. (2019). Gameaal-an aal solution based on gamification and machine learning techniques. In *2019 IEEE CIBCB*, pages 1–4. IEEE.
- Schäfer, H., Bachner, J., Pretscher, S., Groh, G., and Demetriou, Y. (2018). Study on motivating physical activity in children with personalized gamified feedback. pages 221–226.
- Sweetser Kyburz, P., Aitchison, M., et al. (2020). Do game bots dream of electric rewards?: The universality of intrinsic motivation.
- Tondello, G. F., Orji, R., and Nacke, L. E. (2017). Recommender systems for personalized gamification. *ACM*.
- Wanderley O. L., Carvalho, S. T. (2020). A gamification-based framework for mhealth developers in the context of self-care. *IEEE*.
- Zhang, R., E. Ringland, K., Paan, M., C. Mohr, D., and Reddy, M. (2021). Designing for emotional well-being: Integrating persuasion and customization into mental health technologies. pages 1–13.