

Aplicação de Aprendizado de máquina na identificação de doenças e transtornos mentais: um mapeamento sistemático

André A. Arnaldo, Leandro M. de Carvalho, Patricia C. de Souza

¹Instituto de Computação – Universidade Federal do Mato Grosso (UFMT)
Cuiabá – MT – Brasil

{andre.arnaldo, leandro.carvalho}@sou.ufmt.br,
{patricia@ic.ufmt.br}

Abstract. This article presents results of a Systematic Mapping on the use of Machine Learning techniques to aid in the diagnosis of mental illnesses, whether neurodegenerative or mental disorders. Having an additional basis for the diagnosis of mental illnesses is important for more accurate and targeted treatment, in addition to being important to avoid diagnostic errors. This mapping helped to solve some issues and demonstrated the possibility of applying these machine learning techniques for more accurate diagnoses. In addition, the improvement in diagnostic speed and accuracy could allow more people to receive appropriate treatment. Although the focus of this research is more on technological aspects, its results demonstrated that, in the future, these techniques could be applied to diagnoses of other diseases besides mental illnesses.

Resumo. Este artigo apresenta resultados de um Mapeamento Sistemática sobre a utilização de técnicas de aprendizado de máquina(Machine Learning) para o auxílio do diagnóstico de doenças mentais, sejam elas neurodegenerativas ou transtornos mentais. Ter uma base a mais para o diagnóstico de doenças mentais é importante para um tratamento mais preciso e conduzido, além de ser importante para evitar a realização de erros de diagnóstico. E este mapeamento ajudou a solucionar algumas questões e demonstrou a possibilidade de aplicação dessas técnicas de aprendizado de máquina para diagnósticos mais precisos. Além disso, a melhora na velocidade e precisão diagnósticos pode permitir que mais pessoas recebam um tratamento adequado. Embora o foco desta pesquisa seja mais aspectos tecnológicos, seus resultados demonstraram que, no futuro, essas técnicas poderão ser aplicadas para diagnósticos de outras doenças além das mentais.

1. Introdução

Primeiramente, faz-se necessário compreender o que é considerado um transtorno mental, termo frequentemente intercalado com “doenças mentais”, pois ambos têm um impacto negativo significativo no funcionamento psicológico, na produtividade no trabalho e qualidade de vida geral [J and K 2023]. Alguns exemplos seriam o transtorno de bipolaridade ou transtorno de ansiedade. No entanto, doenças mentais tendem a afetar a saúde de forma mais grave, pois ela compromete as emoções, a inteligência, a capacidade comunicação

interpessoal da pessoa e causa efeito negativo na área social [Baek and Chung 2020]. Exemplo de doenças mentais são a depressão ou Alzheimer.

De um modo geral, a identificação de doenças e transtornos mentais não é um processo simples, visto que, por exemplo, só para identificar uma pessoa que possui autismo é necessário realizar diversas consultas com um psicólogo ou psiquiatra, além de vários testes realizados para se ter um diagnóstico preciso [Basak et al. 2023]. Apesar disso tudo, o diagnóstico pode não ser preciso, ou seja, apesar de todo o tempo gasto tanto do paciente quanto do profissional responsável ainda não haverá certeza, e esse é um dos motivos do porquê realizar esse tipo de pesquisa.

Afinal, a tecnologia está sempre se desenvolvendo com o foco de nos ajudar cada vez mais e em diversas áreas, então por que não nessa? Por isso neste artigo, veremos alguns dados retirados através de testagem de diversas técnicas de aprendizado de máquina, mas o que seria um aprendizado de máquina? é um ramo da inteligência artificial (IA) que tem a capacidade de ensinar os usuários a reconhecer padrões complexos e é muito utilizado no ramo da saúde [Jage et al. 2023] e alguns desses modelos apresentados neste mapeamento serão: DNN (Deep Neural Network)[Singh et al. 2022], RNN (Rede Neural Recorrente)[Chintamaneni et al. 2022], LinearSVC [Minissi et al. 2024] e entre outras. Alguns trabalhos utilizam de EEG (Eletroencefalograma)[Singh et al. 2022], para a identificação de doenças, porém outros utilizam de aspectos sociais para a identificação, como por exemplo a troca de mensagens na web [Xia et al. 2022], ou as respostas dadas num questionário realizado [Jage et al. 2023].

Então, o foco deste artigo será observar o comportamento e o progresso, nas áreas da psicologia e computacional, desses métodos de aprendizado de máquina, além disso é importante destacar que mesmo as máquinas têm uma taxa de erro, então mesmo ao analisar esses métodos alguns não serão totalmente precisos infelizmente, mas logicamente haverá espaço para uma evolução no futuro.

2. Metodologia

Para esse Mapeamento Sistemática da Literatura (MSL), levou-se em consideração o livro [Dermeval et al. 2020], que apresenta três etapas principais: planejamento, condução e relatório. Segundo para a parte de planejamento foi estabelecido o protocolo a ser seguido, onde foi definido: palavras chave, questões de pesquisa, bases de dados científicas nas quais a string de busca foi aplicada e por fim os critérios de inclusão e exclusão de artigos para a revisão sistemática.

O propósito dessa pesquisa seria responder às seguintes questões: É praticável utilizar algoritmos de aprendizado de máquina para diagnóstico de doenças mentais? Quais doenças mentais seriam mais propensas a um diagnóstico preciso?. Logicamente que essa questão pode ser bem mais difícil de se obter uma resposta visto que cada doença tem um padrão e que algumas podem ter padrões extremamente similares. Além disso, há os critérios de exclusão (CE) e os critérios de inclusão (CI) que são, Critérios de Inclusão (CI): O estudo realizar experimentos com as técnicas abordadas, o estudo estar em português ou inglês, o estudo estar dentro do tema abordado e o estudo ser gratuito. Critérios de Exclusão (CE): o estudo aborda outro tema, o estudo tem acesso restrito mediante a pagamento, o estudo não realiza experimentos com as técnicas abordadas.

Na fase de condução da revisão foi aplicado inicialmente a *string* de busca nas

base de dados Scopus e IEEE, agora havia a necessidade de escolher uma data de busca, portanto quanto mais atual melhor, por isso deveria começar do ano passado e deveria ter um escopo de no máximo 5 anos, portanto a data de busca teve seu escopo definido entre 2019 até 2024, foram utilizadas 3 etapas: 1) adicionar todos os resultados da string de busca desde que esses fossem gratuitos, 2) ler os títulos e seus resumos caso tivessem, 3) para a seleção final, ler o artigo em si. A seleção dos trabalhos de interesse ocorreu utilizando os critérios de exclusão e inclusão pré-definidos na parte de planejamento. Além disso, uma ferramenta que ajudou muito na separação por critério de inclusão e leitura de resumo foi o Parsif.al. A seleção foi extremamente facilitada pelo uso dessa ferramenta.

E por fim o relatório, os estudos selecionados foram investigados, para conseguir entender como a tecnologia aplicada funcionava e se seria aplicável, na Figura 1 abaixo mostra os resultados obtidos das bases de dados IEEE e Scopus e as etapas que foram levadas para juntar toda a literatura necessária para a condução deste trabalho.

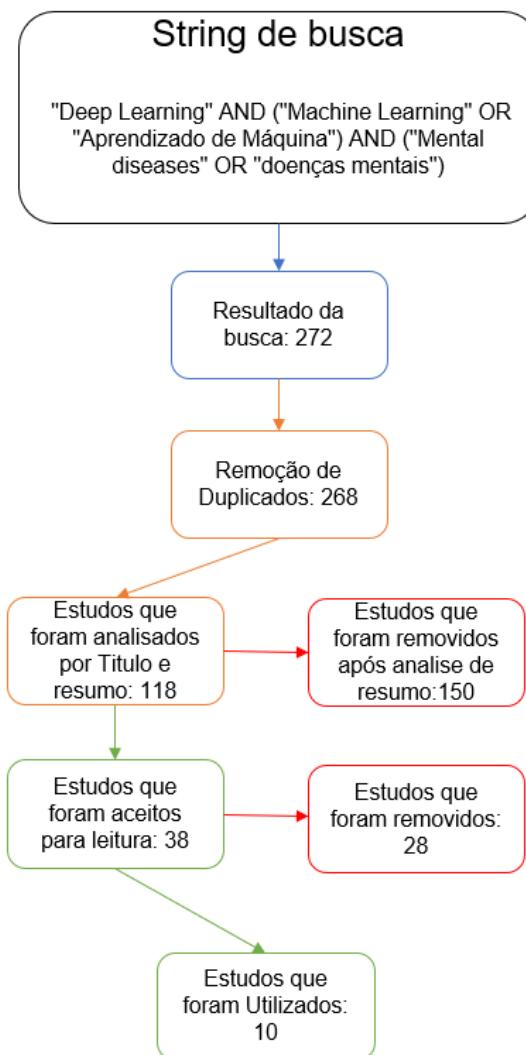


Figura 1. Fluxograma da MSL

Como pode ser observado na Figura 1, os resultados iniciais foram 272 trabalhos,

desses, 13 foram da IEEE e 259 da Scopus, que após passar por uma série de análises o número de pesquisas que poderiam ser utilizadas foi reduzido para 38 e visto que destes 38 que seriam lidos na íntegra foram escolhidos apenas 10 que poderiam responder corretamente às questões de pesquisa e atender aos outros critérios de inclusão. Além dos motivos já citados, uma outra razão para a escolha de apenas 10 estudos foi devido a fatores pessoais dos autores, impossibilitando um número maior de estudos.

3. Resultados e Discussões do Mapeamento Sistemático

3.1. Análise dos artigos e breve discussão dos resultados

Os estudos selecionados para a mapeamento (MSL) fazem parte de um contexto maior, que é analisar a viabilidade do uso de técnicas de aprendizado de máquina para a construção de algoritmos eficientes para a predição e diagnóstico de doenças mentais.

A Tabela 1 apresenta o resultado de 10 trabalhos incluídos na MSL. Os principais aspectos extraídos são: técnicas de aprendizado de máquina utilizadas na pesquisa, o melhor modelo, taxa de acerto, se é específico para o diagnóstico de apenas uma doença(Esp.) ou se o modelo pode ser utilizado para diagnosticar duas ou mais(Ger.) e o autor.

Tabela 1. Resumo dos modelos de aprendizado de máquina para diagnóstico de doenças mentais

Doenças visadas	Modelos Utilizados	Melhor Modelo	Taxa de Acerto	Esp./Geral	Autor
Alzheimer	DNN-BC	DNN-BC	98%	Específico	[Singh et al. 2022]
-	Decision Tree, Random Forest, Naive Bayes, KNN, SVM	SVM	100%	Geral	[Jage et al. 2023]
Ansiedade, estresse e depressão	SVM, ANN, Xg-Boost	SVM	99,32% (depressão), 99,80% (ansiedade), 98,44% (estresse)	Geral	[J and K 2023]

Depressão	Random Forest, XGBoost, Logistic Regression, Improved Deep Forest	Improved Deep Forest	0,885	Específico	[Xia et al. 2022]
Autismo	LinearSVC, SVC	LinearSVC	81%	Específico	[Minissi et al. 2024]
-	ANN, KNN, LSTM, Bi LSTM, CNN-LSTM	-	Cerca de 98%	Geral	[Ahmed et al. 2024]
Esquizofrenia	LSTM, ARIMA, PSO, PSO-SVR, Deep Neural Network	LSTM	97,66%	Específico	[Yang et al. 2024]
TDAH	RNN	RNN	96%	Específico	[Chintamaneni et al. 2022]
Depressão	MRA, DNN, Context-DNN	Context-DNN	-	Específico	[Baek and Chung 2020]
-	PSO, LSTM	-	90%	Geral	[Basak et al. 2023]

Observa-se na Tabela 1 que, dependendo da doença e do diagnóstico que se quer dar, o emprego de certos tipos de algoritmos de aprendizado e (apesar de não ser mencionados, mas emprega um papel importante no aprendizado de máquina) certos tratamentos com dados são mais eficientes e assertivos.

Percebe-se também que certos modelos se sobressaíram em mais de uma pesquisa, como, por exemplo, SVM [J and K 2023]. Vale destacar que o SVM foi utilizado para mais de um tipo de transtorno mental e que seus resultados foram satisfatórios o visto que ultrapassaram 95 de precisão, além de ser uma tecnologia aplicável para por exemplo: uma clínica de tratamento psicológico, o que torna ele um ótimo substituto para os psicólogos quanto a diagnósticos rápidos e precisos, apesar de ainda não ser 100 o que é uma falha, mas se analisar bem, o ser humano busca que a tecnologia faça certas coisas pois os humanos podem acabar falhando, por exemplo na construção de um carro, grandes etapas são feitas pelas máquinas que tem uma precisão e taxa de acerto maior que um ser humano comum.

Contudo, não basta apenas analisar um modelo. Faz-se necessário observar outros para garantir que a evolução seja possível. Por exemplo, no caso de *Context-DNN*, embora os resultados não sejam explicitamente documentados (pois o estudo de [Baek and Chung 2020] utiliza uma métrica diferente), a adaptabilidade do sistema foi excelente em diversos cenários. Dessa forma, uma abordagem interessante a se explorar seria a junção de mais um método de aprendizado de máquina, como realizado no estudo de [Basak et al. 2023].

Em relação aos transtornos mentais mais facilmente detectáveis, observou-se que a precisão do diagnóstico depende da quantidade de dados disponíveis para a máquina realizar as comparações. Por exemplo, um modelo treinado com 3000 imagens de EEG de indivíduos com Alzheimer terá maior precisão na identificação da doença em comparação com um modelo que disponha de apenas 40 imagens de EEG [Singh et al. 2022].

Contudo, alguns modelos demonstram melhor desempenho mesmo com uma quantidade menor de dados, por exemplo, determinados modelos baseados em CNN podem superar um modelo DNN devido à disponibilidade de maior número de imagens EEG no banco de dados utilizado no estudo de [Singh et al. 2022]. Além disso, alguns modelos receberam um questionário respondido pelos próprios indivíduos com os transtornos em questão [Jage et al. 2023]. Assim, comparar essas abordagens torna-se desafiador, resultando na seguinte resposta: depende. Basicamente, a precisão dependerá da quantidade de dados coletados, dos tipos de informação e qual técnica será empregada.

3.2. Resposta às questões levantadas de pesquisa

Na seção 2, foram levantadas duas questões a serem respondidas ao longo da pesquisa, sendo elas "É praticável ou não a utilização de algoritmos de aprendizado de máquina para o diagnóstico das doenças mentais?" e "Quais doenças mentais seriam mais propensas a um diagnóstico preciso?". Apesar de não ter chegado a uma resposta concreta, é possível chegar a algumas conclusões preliminares em relação ao sujeito da pesquisa.

A utilização destes algoritmos de diagnóstico de doenças mentais se torna prática no seguinte cenário: um profissional acaba por utilizar os modelos criados como auxílio e uma ferramenta para o diagnóstico, questionando sempre os resultados chegados pelos modelos e os utilizando como referência apenas. Apesar de alguns modelos terem mostrado uma taxa de precisão alta nos cenários que se propõe a ter, como, por exemplo, nos estudos [J and K 2023] e [Jage et al. 2023], há limitações devido à complexidade do sistema nervoso humano e às limitações inerentes aos dados (que podem gerar vieses), confiar exclusivamente em Machine Learning para diagnósticos pode levar a resultados imprecisos.

Em relação à segunda pergunta, não há uma resposta exata. Conforme demonstrado na Tabela, os estudos [J and K 2023] e [Xia et al. 2022] utilizaram modelos para diagnosticar a depressão, mas apresentaram taxas de erro distintas, decorrentes de propostas e abordagens metodológicas diferentes. Assim, uma resposta aproximada seria que o diagnóstico tende a ser mais preciso para doenças que apresentam alterações mais marcantes nas ondas cerebrais e padrões de EEG bem definidos, embora também dependa do contexto em que o diagnóstico é realizado e da abordagem adotada.

4. Considerações Finais

Este mapeamento sistemático da literatura abordou o uso de técnicas de aprendizado de máquina na predição e diagnóstico de doenças mentais, analisando diversos estudos recentes. Com base nos dados apresentados na Tabela 1, foi possível observar a aplicação de diferentes modelos de aprendizado de máquina em contextos específicos e gerais, bem como suas respectivas taxas de acerto e eficiência na detecção de transtornos mentais e neurodegenerativos.

Uma das principais constatações é que certos modelos, como o Support Vector Machine (SVM) e Redes Neurais Artificiais (ANN), têm sido amplamente utilizados e apresentaram resultados promissores em diferentes estudos. Além disso, observa-se que, para doenças específicas, modelos aprimorados como Improved Deep Forest e Redes Neurais Recorrentes (RNN) tendem a apresentar melhor desempenho em relação a abordagens mais generalistas.

Apesar deste trabalho ter explorado uma gama considerável de artigos científicos sobre o diagnóstico de doenças mentais com auxílio de aprendizado de máquina, ainda há muitos estudos que não foram analisados. Esta área de pesquisa se tornou bastante ampla nos últimos anos e possui milhares de artigos relacionados. Além disso, atualmente, a inteligência artificial passa por uma grande revolução, com investimentos massivos em pesquisas para aprimorar os modelos existentes e descobrir novas técnicas que possam melhorar as previsões. Portanto, este trabalho não conseguiu explorar a totalidade dessa área de pesquisa que vem recebendo investimento e atenção. Um próximo passo para o futuro seria aproveitar os avanços resultantes dessa revolução tecnológica para expandir esta linha de pesquisa.

Referências

- [Ahmed et al. 2024] Ahmed, Z., Wali, A., Shahid, S., Zikria, S., Rasheed, J., and Asuroglu, T. (2024). Psychiatric disorders from eeg signals through deep learning models. *IBRO Neuroscience Reports*, 17:300 – 310. Cited by: 0; All Open Access, Gold Open Access.
- [Baek and Chung 2020] Baek, J.-W. and Chung, K. (2020). Context deep neural network model for predicting depression risk using multiple regression. *IEEE Access*, 8:18171–18181.
- [Basak et al. 2023] Basak, M., Maiti, D., and Das, D. (2023). A hybrid approach of differential evolution and multistage lstm for diagnosis of psychiatric disorder using eeg. In *2023 IEEE International Conference on Computer Vision and Machine Intelligence (CVMI)*, pages 1–6. Madhuchhanda Basak, Diptadip Maiti e Debasish Das.
- [Chintamaneni et al. 2022] Chintamaneni, A., Agrawal, S., Yelamancheli, C. S., Archana, G., Reddy, S., and Joy, A. (2022). Early detection of adhd in juveniles using recurrent neural networks. In *2022 3rd International Conference for Emerging Technology (INCET)*, pages 1–5.
- [Dermeval et al. 2020] Dermeval, D., Bittencourt, I. I., Marques, L. B., Dellagnelo, L. G. V., and Isotani, S. (2020). Editorial da edição especial “mapeamento sistemático e revisão sistemática da literatura sobre o uso de tecnologias educacionais na educação básica”; *Revista Brasileira de Informática na Educação*, 28:viii–xiv.

- [J and K 2023] J, A. S. P. and K, S. K. (2023). Early detection of anxiety, depression and stress among potential patients using machine learning and deep learning models. In *2023 2nd International Conference on Computational Systems and Communication (ICCSC)*, pages 1–7.
- [Jage et al. 2023] Jage, S., Chaudhari, S., Jatte, M., Mhatre, A., and Mane, V. (2023). Predicting mental health illness using machine learning. In *2023 3rd Asian Conference on Innovation in Technology (ASIANCON)*, pages 1–5.
- [Minissi et al. 2024] Minissi, M. E., Altozano, A., Marín-Morales, J., Chicchi Giglioli, I. A., Mantovani, F., and Alcañiz, M. (2024). Biosignal comparison for autism assessment using machine learning models and virtual reality. *Computers in Biology and Medicine*, 171. Cited by: 5; All Open Access, Green Open Access, Hybrid Gold Open Access.
- [Singh et al. 2022] Singh, B., Tatiya, M., Shrivastava, A., Verma, D., Pratap Srivastava, A., and Rana, A. (2022). Detection of alzheimer’s disease using deep learning, block-chain, and iot cognitive data. In *2022 2nd International Conference on Technological Advancements in Computational Sciences (ICTACS)*, pages 863–869.
- [Xia et al. 2022] Xia, J., Liu, B., Zou, J., and Qu, Q. (2022). Analysis of depression based on improved deep forest. page 392 – 396. Cited by: 0.
- [Yang et al. 2024] Yang, S., Wu, C.-H., Chuang, L.-Y., and Yang, C.-H. (2024). Forecasting the incidence frequencies of schizophrenia using deep learning. *Asian Journal of Psychiatry*, 101. Cited by: 0.