

Panorama das Pesquisas com Machine Learning em Saúde Mental: Uma Breve Análise de Escopo

Thalles Paul Leandro Mota¹, Claudia Aparecida Martins¹
Leonardo Arruda Vilela Garcia¹

¹Universidade Federal de Mato Grosso, Programa de Pós-Graduação em Computação Aplicada (PPG-COMP) Cuiabá - Mato Grosso

Abstract. This scoping study investigates the use of Machine Learning (ML) in Mental Health research using questionnaire data (2020-2024). Analyzing 28 articles from ACM and PubMed, the study reveals a growing trend in research and publications, prevalent use of Random Forest, and a focus on depression. A dichotomy in methodological approaches was observed: Computer Science researchers prioritize comparing algorithm performance, while Health researchers favor applying more interpretable models. ML application in Mental Health shows significant potential as a supplementary tool for professionals.

Resumo. Este estudo de escopo investiga o uso de Machine Learning (ML) em pesquisas em Saúde Mental com dados de questionários (2020-2024), a partir da análise de 28 artigos nas bases ACM e PubMed. Os resultados indicam crescimento no número de pesquisas e publicações ao longo dos anos, ampla utilização do Random Forest e foco investigativo no problema da depressão. Identificou-se uma dicotomia nas abordagens metodológicas, com pesquisadores da área da Computação buscando comparar o desempenho de múltiplos algoritmos, enquanto na área da Saúde, os pesquisadores visam aplicar modelos mais interpretáveis. A aplicação de ML em Saúde Mental tem grande potencial de crescimento enquanto ferramenta auxiliar para profissionais.

1. Introdução

A crescente prevalência de transtornos mentais, como depressão e ansiedade, tem se tornado uma preocupação global, e isso tem despertado interesse de pesquisadores com novas perspectivas de pesquisa nesse campo [Kim and Min 2023]. A busca por métodos eficazes de identificação e intervenção precoce impulsionou o interesse na aplicação de Inteligência Artificial (IA), particularmente técnicas de *Machine Learning* (ML), que permitem analisar grandes volumes de dados heterogêneos, como respostas a questionários psicométricos e dados textuais [Ellouze and Belguith 2024].

A variedade de dados disponíveis atualmente possibilita aos pesquisadores implementar modelos preditivos robustos e capazes de identificar fatores de risco, monitorar e prevenir transtornos como estresse, ansiedade e depressão [Makhmutova et al. 2021]. O uso de técnicas como *Random Forest*, *Support Vector Machine (SVM)* e *Logistic Regression (LR)* tem avançado, abrindo espaço para a implementação de novos processos e ferramentas de diagnóstico, intervenção e monitoramento [Kim and Min 2023][Ellouze and Belguith 2024] [D'Agostino et al. 2024] [Su et al. 2024] [Catterjee et al. 2024].

Nesse contexto, o presente estudo tem como objetivo investigar o panorama do uso de *ML* em pesquisas de saúde mental com dados relativos ao período de 2020 a 2024. Para

tanto, este trabalho consistiu em: (i) identificar e categorizar os algoritmos de ML mais utilizados nesses estudos; (ii) analisar a evolução temporal das publicações sobre o tema na atualidade; (iii) mapear os principais veículos de publicação e destacar as publicações que abordam o tema. Isso possibilitará uma visão estruturada do cenário de pesquisas atuais, bem como identificar caminhos para futuras pesquisas nesse campo.

O trabalho está estruturado da seguinte forma: na Seção 2 é apresentada a abordagem metodológica adotada, na Seção 3 são apresentados os resultados encontrados, na Seção 4 são discutidos os achados com a literatura especializada e na Seção 5 são apresentadas as considerações finais.

2. Metodologia

Para atingir os objetivos, foi realizada uma revisão de literatura, adotando-se etapas de busca, seleção e análise para minimizar possíveis vieses [Carvalho 2019]. Para abranger a amplitude do tema a ser investigado, foram selecionados artigos das bases *ACM Digital Library*¹ e *PubMed*². A primeira base foi selecionada pela relevância na área de Ciência da Computação e a segunda por sua especialização em pesquisas Biomédicas e de Saúde.

Os artigos selecionados foram publicados entre os anos de 2020 e 2024, por meio da utilização de combinações de *strings*, envolvendo termos como: “*questionnaires*”, “*machine learning*” e condições de Saúde Mental (*ex: Depression, Anxiety, Stress*). Utilizou-se essa abordagem visando evitar artigos que envolvessem análise de imagens para diagnósticos médicos. Assim, direcionamos nossa investigação para publicações em que os dados envolviam preferencialmente formatos textuais. Foram selecionados e analisados os primeiros 200 resultados de cada busca em cada base de publicações. As buscas ocorreram durante o mês de Janeiro do ano de 2025.

A partir da coleta de dados, foi realizada a triagem dos artigos, que ocorreu em duas fases: (*fase-1*) análise de título e resumo, excluindo-se estudos de revisão ou que apenas mencionassem o termo *ML*, sem aplicação prática das técnicas; (*fase-2*) leitura dos textos completos selecionados na primeira fase para aplicação de critérios de inclusão e exclusão. Os critérios de inclusão abrangeram artigos em inglês, contendo aplicação de *ML* em condições de saúde mental (diagnóstico, prevenção ou promoção da saúde), com dados preferencialmente em formato textual. Portanto, foram excluídos artigos focados exclusivamente em dados de *EEG*, imagens e vídeos.

Ao final, 28 artigos foram selecionados para análise. Um formulário padronizado foi utilizado para extrair dados principais: título, autores, ano de publicação, objetivo, tipo de dados, algoritmo(s) de *ML*, métricas de desempenho, principais resultados e conclusões. Em seguida, realizou-se análise quantitativa (contagem de algoritmos, frequência de temas e veículos de publicação) e qualitativa (discussão em relação aos desafios e oportunidades do uso de *ML* em saúde mental). Os resultados são destacados na sequência.

3. Descrição dos dados artigos selecionados

A partir dos artigos selecionados, realizou-se aplicação de estatísticas descritivas. Na Figura 1 nota-se o aumento expressivo no número de publicações envolvendo aplicações

¹<https://dl.acm.org>

²<https://pubmed.ncbi.nlm.nih.gov>

de *ML* à Saúde Mental nos últimos anos. Em 2024, foram encontrados 12 artigos, um aumento em relação aos anos anteriores (5 em 2023, 6 em 2022, 4 em 2021 e 1 em 2020). Essa tendência sugere o crescente interesse de pesquisadores nesse tipo de aplicação em um cenário ainda incipiente de pesquisas com *ML* nesse domínio.

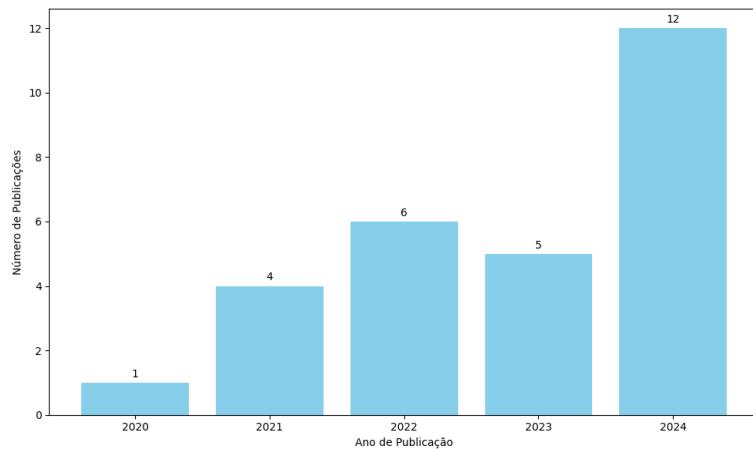


Figura 1. Nº Artigos selecionados no protocolo por ano de publicação.

Na Figura 2 é apresentada a distribuição das publicações por área do conhecimento, categorizadas com base nos veículos de publicação. As áreas de Saúde Mental lideram o número de artigos, especialmente Psiquiatria e Psicologia, com 8 e 7 publicações respectivamente, juntamente com a área de Computação, com 7 publicações. A categoria mais genérica de Saúde (Geral) segue com 5 publicações, enquanto Saúde (Enfermagem) apresenta apenas 1 publicação. Isso mostra a convergência de pesquisadores em distintas áreas para investigar *ML* aplicado à Saúde Mental.

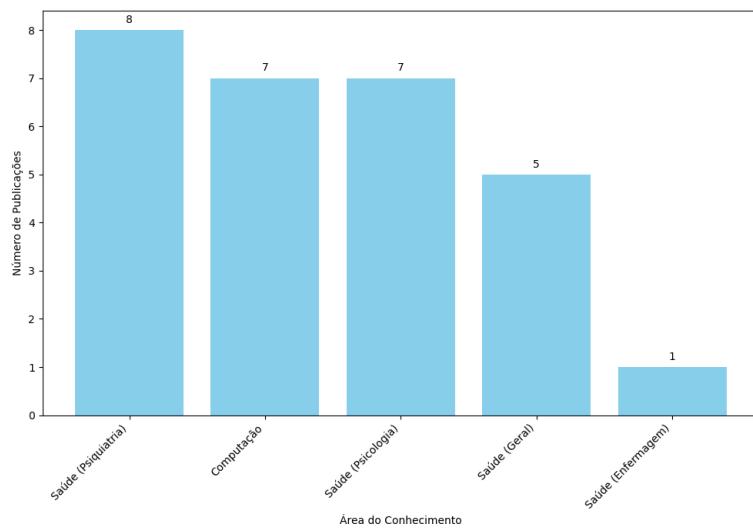


Figura 2. Distribuição dos artigos por área (a partir do veículo de publicação).

Na Figura 3 é apresentada a distribuição de artigos por contexto de aplicação em saúde mental. O tema depressão foi dominante, com 12 artigos. Ansiedade, com 5 artigos, e estresse, com 4 artigos. Outros 6 artigos trataram de outros transtornos ou problemas

que incluem classificação de emoções e avaliação de modelos. Por fim, a automutilação não suicida é um tema menos explorado, com apenas 1 artigo.

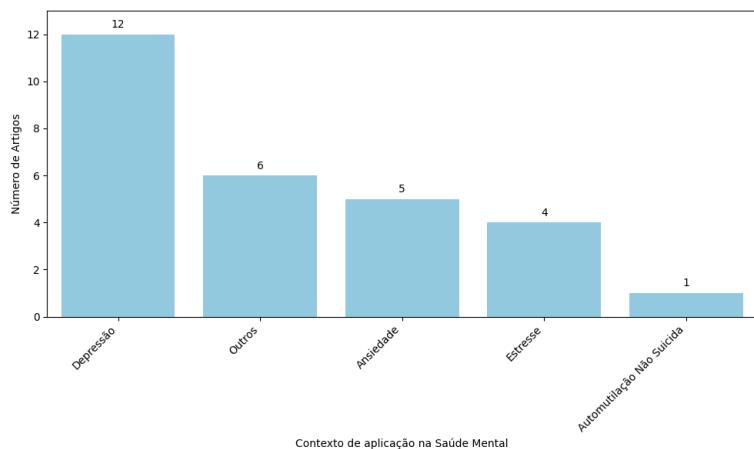


Figura 3. Distribuição dos artigos por contexto de aplicação em Saúde Mental.

Em termos de público-alvo, na Figura 4 é mostrado que 19 dos 28 estudos enfocaram na população geral, 5 em adolescentes/escolares, 2 universitários, 1 profissionais de saúde e 1 pacientes crônicos. Assim, há maior disponibilidade de estudos sobre a população geral, possivelmente devido à disponibilidade de dados ou à complexidade de estudos em populações mais segmentadas, sugerindo espaço para pesquisas em grupos específicos e vulneráveis.

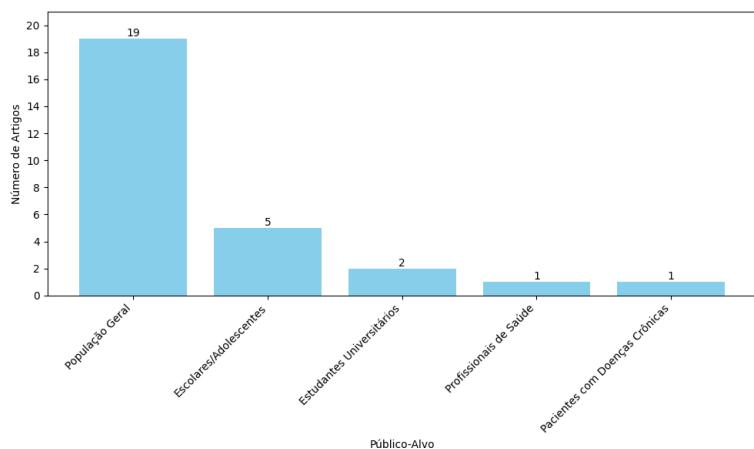


Figura 4. Distribuição dos artigos por público-alvo (no contexto de dados).

Na Figura 5 é comparado o número de algoritmos de *ML* utilizados em artigos das áreas de Computação e Saúde. Os artigos da área de Computação são baseados em análise comparativa, indicando uma abordagem que, frequentemente, busca comparar o desempenho de diversas técnicas e algoritmos em domínios específicos. Enquanto pesquisas na área de Saúde, geralmente, usam uma ou poucas técnicas, sugerindo que, enquanto a área da Computação aborda uma postura mais investigativa e comparativa em relação a diferentes técnicas e seu desempenho, os artigos provenientes da área da Saúde priorizam a aplicação de técnicas interpretáveis e focados em resolver problemas específicos.

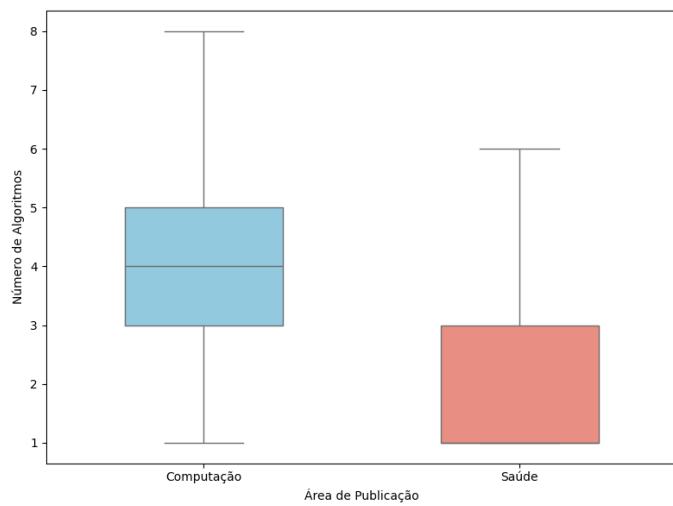


Figura 5. Número de algoritmos por publicação (categorizados por área de publicação).

Por outro lado, foi investigado quais os principais algoritmos e técnicas de *ML* foram utilizados nos artigos. Os principais algoritmos de *ML* e sua frequência de uso são apresentados na Figura 6. *Random Forest* foi o algoritmo mais popular, com 18 ocorrências, sugerindo sua versatilidade e eficácia em diversos problemas relevantes para este campo. Em seguida, o algoritmo *Support Vector Machine (SVM)*, e sua adaptação *SVC*, além de *Logistic Regression (LR)*, com 9 e 8 ocorrências respectivamente, indicam que foram utilizados abordagens clássicas que oferecem bom desempenho e interpretabilidade.

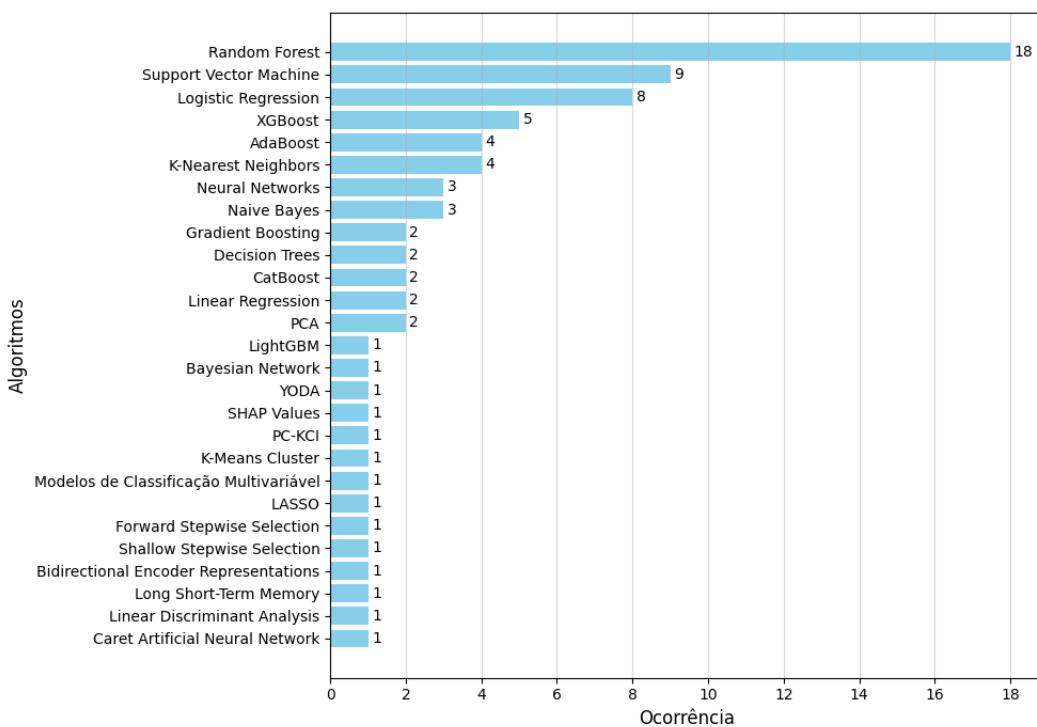


Figura 6. Ocorrência dos algoritmos.

Observa-se também a presença de outros algoritmos, como *XGBoost*, com 5 registros de ocorrências, *AdaBoost* e *K-Nearest Neighbors (KNN)*, ambos com 4 ocorrências. Em contrapartida, um conjunto significativo de algoritmos, incluindo *Principal Component Analysis (PCA)*, *LightGBM* e métodos de análise de dados como *SHAP Values*, apresentaram 1 ocorrência cada. Essa heterogeneidade na aplicação dos algoritmos aponta para a natureza exploratória e multidisciplinar das pesquisas em Saúde Mental com *ML*, com a diversificação das abordagens e a tentativa de otimizar o desempenho e encontrar aplicações práticas. Evidência que o desempenho dos algoritmos pode ser totalmente dependente de domínio, da amostra utilizada e dos parâmetros utilizados.

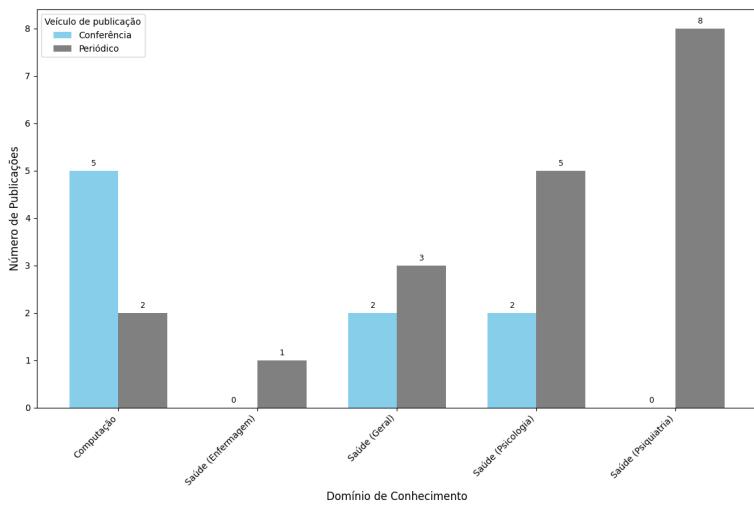


Figura 7. Perfil de publicação por domínio

Na Figura 7 é apresentado o perfil de publicação por domínio do conhecimento, categorizando os artigos entre publicados em conferências e periódicos. Na área de Computação, observa-se um maior número de publicações em conferências (5 artigos), do que em periódicos (2 artigos). Em contraste, as áreas de Saúde, incluindo Enfermagem (1 artigo), Geral (3 artigos), Psicologia (5 artigos) e Psiquiatria (8 artigos) apresentam uma predominância de publicações em periódicos. Em Saúde (Geral) e Saúde (Psicologia), observa-se um equilíbrio na quantidade de artigos em conferências e periódicos, com 2 e 2 artigos, respectivamente. Particularmente, Saúde (Psiquiatria) se destaca pelo elevado número de publicações em periódicos. Esse padrão é característico das áreas e, muitas vezes, do próprio *status quo* da área. Porém, é possível verificar a predominância das áreas de saúde por publicações mais formais e consolidadas dos periódicos, enquanto área da computação tende a utilizar a divulgação rápida dos resultados em conferências e eventos.

4. Discussão dos resultados

A presente investigação, ao mapear o cenário atual do uso de algoritmos de *ML* em pesquisas de saúde mental entre 2020 e 2024, revelou um panorama bastante interessante. Evidencia-se uma crescente atenção dada à aplicação de *ML* em problemas envolvendo o tema, conforme evidenciado pelo aumento no número de publicações, especialmente em 2024, com estudos que abordam a previsão de *stress* e depressão em contextos distintos, sinaliza uma tendência promissora e um campo fértil para o desenvolvimento de novas

ferramentas para auxílio no diagnóstico e intervenção profissional. O panorama metodológico e algorítmico apresentado por esta revisão de escopo, em conjunto com outros estudos como Ghosh et al. (2024) Su et al. (2024) e Catterjee et al. (2024) revelam disparidades e convergências.

A análise da frequência de uso de algoritmos de *ML* em pesquisas publicadas sobre saúde mental, na amostra selecionada, mostra uma prevalência do *Random Forest*, o qual se destaca como o algoritmo mais frequente nos estudos revisados, presente em 18 artigos. Esse achado corrobora com as evidências encontradas em estudos como o de Su et al. (2024), no qual o *Random Forest* se sobressaiu na predição de níveis de estresse em estudantes universitários, obtendo acurácia de 84.62% e *AUC* de 0.82. Da mesma forma, Ghosh et al. (2024), também apontaram para a eficácia do *Random Forest* na previsão de mudanças no estresse em estudantes, após a intervenção com yoga, com um desempenho *RMSPE* de 1.23 e R-quadrado de 0.71. Essa convergência mostra uma versatilidade do *Random Forest* aplicado em conjuntos de dados complexos e heterogêneos da área da saúde.

Ao observarmos o número de algoritmos utilizados nos artigos publicados e selecionados, revela-se uma dicotomia entre a área da Computação e da Saúde. Enquanto estudos na área da Computação empregam uma maior variedade de algoritmos, os estudos na área da Saúde, geralmente, se limitam a um único modelo. São abordagens metodológicas distintas entre as áreas, em que os pesquisadores que publicaram em veículos da Computação, supostamente estão mais interessados na exploração comparativa, enquanto os pesquisadores que publicaram em veículos da Saúde, supostamente focam em abordagens mais tradicionais para a resolução de problemas específicos. Essa diferença pode ser interpretada como um reflexo da natureza multidisciplinar da ciência, na qual, um grupo (Computação) prioriza a busca por inovação e eficiência, enquanto, outro grupo (Saúde) prioriza a aplicação de algoritmos bem estabelecidos e com alta interpretabilidade.

A predominância de estudos focados na população geral, conforme apresentado nos resultados da presente revisão, destaca a necessidade de pesquisas mais direcionadas a grupos específicos, como escolares/adolescentes, estudantes universitários, profissionais de saúde e pacientes com doenças crônicas [Chatterjee et al. 2024] [Su et al. 2024]. Por outro lado, a evidenciada concentração de investigações em populações mais amplas pode ser atribuída à maior disponibilidade de dados, à complexidade de estudos em grupos específicos e, possivelmente, um certo nível de dificuldade na obtenção de amostras e dados representativas destes grupos.

A análise da distribuição dos artigos por contexto de aplicação em saúde mental revela que a depressão é o tema mais investigado, com 12 artigos. Essa concentração em depressão pode ser justificada pela sua alta prevalência e impacto na saúde pública. Porém, é fundamental que futuras pesquisas explorem outros temas relevantes como ansiedade, *stress*, automutilação não suicida e risco de suicídio, os quais apresentam um menor número de estudos, como apresentado nos resultados mostrados. É relevante destacar que o contexto de aplicação também é um fator determinante na escolha dos métodos e algoritmos de *ML*, e que as características dos dados e problemas específicos de cada tema possivelmente exigirão abordagens distintas.

No que se refere aos meios de publicação, revelou-se um padrão interessante: arti-

gos da área de Computação sobre esse tema geralmente são apresentados em conferências, enquanto na área da Saúde, evidenciou-se uma possível preferência por periódicos, como principal veículo de publicações. Isso pode ser explicado pelas diferentes formas de validação do conhecimento e também pela natureza de cada área. Supostamente, na computação os pesquisadores buscam uma divulgação mais rápida dos resultados, enquanto na área da saúde o interesse possivelmente se concentra no potencial de aplicação clínica, por meio de técnicas estabelecidas.

Em concordância com a presente revisão, o estudo de Chaterjee et al. (2024), ao abordar a aplicação de *ML* em dados de *survey* online, evidencia o potencial de modelos como o *SVM* combinado com o *PCA* no contexto da saúde, apresentando uma acurácia de 96%. Além disso, o uso da metodologia *Local Interpretable Model-agnostic Explanations (LIME)* para explicar o modelo *SVM*, ressalta a importância da interpretabilidade e da transparência em abordagens de *ML* em Saúde Mental, alinhando-se com a necessidade de abordagens éticas e responsáveis. Contudo, como foi evidenciado neste estudo, há uma grande variedade de algoritmos de *ML* que podem ser aplicados a dados de Saúde Mental, e estudos como Ghosh et al. (2024) e Su and Wei (2024) apontam o *Random Forest* como técnica eficiente para predizer o *stress* a partir de dados de questionário, apontando para uma potencial direção para pesquisas futuras de impacto social.

A comparação entre diferentes abordagens de *ML* no estudo de Catterjee et al. (2024), que usa *PCA + SVM*, *PCA + Decision Tree*, *PCA + Naive Bayes* e *PCA + KNN*, reforça a necessidade de testar e comparar diferentes algoritmos para determinar qual é o mais adequado para cada problema específico. Da mesma forma, a aplicação do *LIME* para explicar as decisões do modelo mostra a importância de tornar as previsões dos modelos de *ML* transparentes e compreensíveis, auxiliando profissionais da Saúde a confiar e utilizar as ferramentas desenvolvidas para a tomada de decisão e melhoria da assistência.

Estudos futuros também devem testar e comparar diferentes abordagens metodológicas e algorítmicas, buscando identificar o método mais adequado para cada tipo de problema e conjunto de dados. Além disso, pesquisas que explorem a integração de diferentes fontes de dados, como dados textuais, fisiológicos, genéticos e ambientais, poderiam contribuir para o desenvolvimento de modelos de *ML* mais precisos e robustos. É necessário ainda que futuras pesquisas busquem diminuir as barreiras de acesso, visando trabalhar com outros públicos que apresentem maior necessidade e maior grau de vulnerabilidade, como idosos, profissionais de saúde, pessoas que sofrem com doenças crônicas ou minorias étnicas.

Em suma, a aplicação de algoritmos de *ML* na Saúde Mental com dados de questionários apresenta um potencial significativo para avançar a área. No entanto, é fundamental que novas pesquisas explorem e comparem diversas metodologias para que seja possível desenvolver ferramentas cada vez mais precisas, confiáveis, interpretáveis, e capazes de auxiliar profissionais da área da Saúde no cuidado e prevenção. Além disso, é necessário que futuros trabalhos busquem aprimorar essas aplicações, visando sempre aplicações em contextos reais, gerando assim inovações.

5. Considerações finais

A presente investigação mapeou o cenário atual do uso de *ML* em pesquisas de uma amostra de dados sobre Saúde a partir de questionários entre 2020 e 2024. Identificou-se uma diversidade de algoritmos empregados, com destaque para a técnica *Random Forest*. Observou-se um aumento no número de publicações ao longo do intervalo investigado, indicando uma tendência crescente em tais aplicações, com foco na depressão como um dos temas de mais pesquisados. A análise dos veículos de publicação revelou diferentes abordagens de validação do conhecimento, com a área de Computação tendo suas publicações, principalmente, em conferências e as pesquisas publicadas na área da Saúde, preferencialmente, divulgadas em periódicos. Além disso, os estudos com dados de questionários concentraram-se na população de uma forma geral, sugerindo a necessidade de pesquisadores explorarem grupos mais específicos, como adolescentes. O mapeamento dos algoritmos de *ML* por área mostrou que artigos da Computação convenientemente utilizam diversas técnicas algorítmicas, enquanto na Saúde, geralmente, utiliza-se um único algoritmo, refletindo prioridades de pesquisa distintas.

Em suma, esta pesquisa detalhou o uso, a evolução, os veículos de publicação e as abordagens de pesquisa em *ML* com dados principalmente de questionários, no campo da Saúde e Saúde Mental, indicando tendências e abrindo caminhos para futuras investigações. Declaramos ainda que, o presente estudo possui limitações no que se refere à profundidade e abrangência das análises. São necessárias novas buscas e aprofundamento para que de fato possamos aproximar nossa análise da realidade.

Referências

Kim, S.-S., Gil, M., and Min, E. J. (2023). “*Machine learning models for predicting depression in Korean young employees.*” *Frontiers in Public Health*, 11. <https://doi.org/10.3389/fpubh.2023.1201054>.

Ellouze, M., and Belguith, L. H. (2024). “*Artificial Intelligence application for the analysis of personality traits and disorders in social media: A Survey.*” *ACM Trans. Asian Low-Resour. Lang. Inf. Process.* Just Accepted (June 2024). <https://doi.org/10.1145/3674971>.

Makhmutova, M., Kainkaryam, R., Ferreira, M., Min, J., Jaggi, M., and Clay, I. (2021). “*Prediction of self-reported depression scores using person-generated health data from a virtual 1-year mental health observational study.*” In: *Proceedings of the 2021 Workshop on Future of Digital Biomarkers (DigiBiom '21)*. Association for Computing Machinery, New York, NY, USA, pp. 4–11. <https://doi.org/10.1145/3469266.3469878>.

D’Agostino, A., Garbazza, C., Malpetti, D., Azzimonti, L., Mangili, F., Stein, H.-C., del Giudice, R., Cicolin, A., Cirignotta, F., Marconi, M., for the “Life-ON” study group. (2024). “*Optimal risk and diagnosis assessment strategies in perinatal depression: A machine learning approach from the life-ON study cohort.*” *Psychiatry Research*, 332, 115687. <https://doi.org/10.1016/j.psychres.2023.115687>.

Su, Y., Ge, L., and Wei, G. (2024). “*Random Forest Model Predicts Stress Level in a Sample of 18,403 College Students.*” In: *Proceedings of the 2024 4th International Conference on Artificial Intelligence, Big Data and Algorithms (CAIBDA*

'24). Association for Computing Machinery, New York, NY, USA, pp. 588–593. <https://doi.org/10.1145/3690407.3690507>.

Chatterjee, A., Riegler, M. A., Johnson, M. S., Das, J., Pahari, N., Ramachandra, R., Ghosh, B., Saha, A., and Bajpai, R. (2024). *“Exploring online public survey lifestyle datasets with statistical analysis, machine learning and semantic ontology.”* Scientific Reports, 14, 24190. <https://doi.org/10.1038/s41598-024-74539-6>.

Carvalho, Y. M. (2019). *“Do velho ao novo: a revisão de literatura como método de fazer ciência.”* Revista Thema, 16(4), pp. 913–928. <https://doi.org/10.15536/thema.V16.2019.913-928.1328>.

Ghosh, S., Tripathi, K., Garg, A., Singh, D., Prasad, A., Bhavsar, A., and Dutt, V. (2024). *“Predicting Stress among Students via Psychometric Assessments and Machine Learning.”* In: Proceedings of the 17th International Conference on PErvasive Technologies Related to Assistive Environments (PETRA '24). Association for Computing Machinery, New York, NY, USA, pp. 662–669. <https://doi.org/10.1145/3652037.3663949>.