

Machine Learning na Saúde Mental: um ramo emergente

✉ Bernardo Paim de Mattos¹
✉ Christian Mattjie¹

¹Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS), Porto Alegre - RS, Brasil. bernardo.mattos@edu.pucrs.br - christian.oliveira95@edu.pucrs.br

Resumo - O Machine Learning (ML) é apresentado como uma solução promissora, capaz de melhorar a previsão de desfechos de saúde e viabilizar abordagens de tratamento mais eficazes. Este artigo tem como foco central avaliar o potencial do ML no diagnóstico, tratamento e prognóstico de transtornos mentais, com ênfase no Transtorno por Uso de Substâncias (TUS). Adicionalmente, busca-se identificar lacunas críticas na literatura existente, salientar métodos ou ferramentas de ML e delinear direções futuras para o progresso nesse campo. Os resultados indicam que o ML é crucial para avançar na compreensão dos transtornos mentais, representando uma evolução significativa na área. No entanto, é importante adotar um novo paradigma metodológico, com intuito de assegurar a validade, a confiabilidade e a aplicabilidade das descobertas em contextos de pesquisa e prática clínica.

Palavras-Chave
Machine Learning
Saúde Mental
Transtornos por Uso de Substâncias
Modelos Preditivos
Inovação em Saúde

Categoria
Artigo Original

Como citar: Mattos, B. P. & Mattjie, C. (2024). Machine Learning na Saúde Mental: um ramo emergente. In J. Gonçalves (Ed.). *Perspectivas em Psicologia* (pp. 44-49). Editora Lógica Psicológica. <https://doi.org/10.5281/zenodo.10420581>

1 INTRODUÇÃO

Uma das dificuldades persistentes nas áreas da saúde – seja em pesquisa ou atendimento direto a populações – reside na gestão de grandes conjuntos de dados. Identificar correlações clinicamente significativas se tornou progressivamente desafiador, especialmente ao explorar fenômenos complexos, como aqueles em saúde mental (Shatte et al., 2019).

Estudos destacam benefícios em diagnóstico, tratamento, prognóstico e mudanças comportamentais (Goh et al., 2022; d'Elia et al., 2022). Métodos de Aprendizado de Máquina – Machine Learning (ML), emergem como soluções promissoras, tanto na pesquisa quanto no atendimento ao usuário (Jayatilake & Ganegoda, 2021; Bracher-Smith et al., 2021).

À medida que nos concentramos em variáveis como qualidade de vida e resultados clínicos afins, a aplicação de métodos de ML oferece uma abordagem inovadora para a decisão médica (Alowais et al., 2023; Mak et al., 2019), particularmente em áreas como Transtornos por Uso de Substâncias (TUS), que carecem de resultados (Chhetri et al., 2023).

Este avanço é crucial, considerando o volume crescente e a complexidade dos dados de saúde, como pode ser visto na Substance Abuse & Mental Health Data Archive (SAMHDA, 2019), o que também fortalece a replicabilidade da pesquisa (Diaba-Nuhoho & Amponsah-Offeh, 2021).

Algoritmos de ML podem aprimorar previsões de desfechos de saúde, permitindo tratamentos mais personalizados e eficazes (Burgess-Hull et al., 2023; Sajjadian et al., 2021; Acion et al., 2017; Chew & Achananuparp, 2022). Por exemplo, em contextos relacionados a transtornos de humor, existem evidências emergentes de que modelos de aprendizado de máquina podem contribuir para a prevenção ao suicídio (Lejeune et al., 2022).

Ademais, a diversidade da população afetada por transtornos mentais, como os TUS, representa um desafio significativo tanto para profissionais clínicos quanto para analistas de dados (Baurley et al., 2022). Diferenças socioeconômicas, culturais e de saúde complicam a análise de dados, limitando a generalização de resultados além dos contextos específicos de pesquisa ou tratamento.

A aplicação de técnicas de ML pode facilitar a navegação por essa complexidade, identificando padrões e interações variáveis que podem aprimorar estratégias de intervenção clínica (Shatte et al., 2019). Estas nuances podem ser sutis ao ponto de escapar da percepção, mesmo de profissionais experientes. As capacidades iterativas dos modelos de ML não apenas transcendem abordagens estatísticas tradicionais na saúde (Rajpurkar et al., 2022), mas também permitem inovações em ciência de dados, potencialmente beneficiando a qualidade de vida dos usuários dos serviços de saúde.

Apesar dos avanços, é crucial abordar a robustez metodológica na interseção entre ML e saúde mental. Atualmente, há uma transição entre um estágio inicial, marcado por evidências emergentes e potenciais lacunas metodológicas, para um estágio mais avançado, fundamentado em metodologias rigorosas (Andaur Navarro et al., 2021; Mak et al., 2019; Sajjadian et al., 2021).

É relevante destacar que o conjunto de evidências relacionando ML e saúde apresenta particularidades notáveis. A qualidade metodológica desses estudos é avaliada tanto por meio de escalas convencionais de risco de viés (Higgins et al., 2011; Sterne et al., 2019) quanto por ferramentas específicas voltadas para a avaliação da qualidade dos modelos de ML (Moons et al., 2014; Norgeot et al., 2020).

Esse enfoque dual em qualidade e replicabilidade fortalece uma trajetória promissora para a interseção entre ML e saúde mental. Este campo é de especial interesse, dada a ênfase crescente em pesquisa em saúde, particularmente em cenários que podem conduzir a mudanças estruturais (Alowais et al., 2023). Tais avanços beneficiam não apenas agências financiadoras e pesquisadores, mas também – e crucialmente – os usuários finais dos serviços de saúde (Rajpurkar et al., 2022).

No contexto dos Transtornos por Uso de Substâncias (TUS), os algoritmos de aprendizado de máquina demonstram um potencial transformador para a previsão e tratamento de desfechos clínicos.

Uma análise do atual panorama de pesquisa (Chhetri et al., 2023; Garbin et al., 2023; Mak et al., 2019) revela que tais algoritmos têm sido empregados para discernir padrões intrincados em extensos conjuntos de dados, facilitando a antecipação de, por exemplo, comportamentos de risco. Adicionalmente, essas ferramentas tecnológicas oferecem suporte à decisão clínica, permitindo que profissionais médicos escolham tratamentos adequados com base nas características individuais dos pacientes.

No entanto, é pertinente destacar que, apesar do imenso potencial, a literatura atual apresenta um caráter emergente, refletindo uma certa fragmentação nos achados e evidenciando a necessidade premente de sistematização.

Nesse contexto, uma das propostas pioneiras é a condução de uma revisão sistemática intitulada "Systematic Review of Machine Learning Algorithms on Substance-Related Disorders Treatment Outcomes", devidamente registrada na plataforma PROSPERO (CRD42023431546).

Paralelamente a esta revisão, o presente artigo em formato de revisão narrativa visa avaliar o impacto atual e potencial do ML no diagnóstico, tratamento e prognóstico de transtornos mentais, focando especificamente no TUS. De forma específica, o objetivo é identificar lacunas críticas na pesquisa existente, destacar métodos ou ferramentas de ML, e apontar direções futuras para avançar nesta área.

2 MÉTODO


Esta pesquisa adota uma abordagem qualitativa por meio de revisão narrativa, fundamentada em uma extensa compilação de publicações consultadas ao longo dos últimos anos.

Para esta finalidade, a pesquisa eletrônica de literatura foi conduzida em plataformas como PubMed, PsycInfo e Scopus, direcionada à identificação de artigos pertinentes ao emprego de ML e IA em contextos de saúde mental e TUS. A estratégia de busca foi meticulosamente adaptada de revisões sistemáticas preexistentes.

Inicialmente, uma ampla gama de artigos foi identificada. No entanto, após uma triagem criteriosa com base em títulos, resumos e critérios metodológicos específicos, uma seleção refinada foi efetivada. Essa seleção visou assegurar a inclusão de estudos que oferecessem insights substantivos sobre o uso de ML e IA em saúde mental, alinhando-se ao escopo deste artigo.

Para enriquecer a análise, foram incorporadas referências cruciais sobre ferramentas de qualidade metodológica em ML e exemplos representativos de conjuntos de dados públicos. Os artigos consultados abrangem o período de 2011 a 2023, com um enfoque particular nos anos mais recentes (2021-2023), evidenciando a atualidade e relevância contemporânea das descobertas analisadas.

Figura 1
Fluxograma PRISMA da chave 3 do estudo principal.



É pertinente mencionar que esta revisão incorporará o fluxograma PRISMA associado à terceira chave de busca (Figura 1). Adicionalmente, a Figura 2 apresentará a lista de verificação MI-CLAIM (Norgeot et al., 2020), uma ferramenta preeminente para avaliar a integridade metodológica e a transparência de modelos de ML em saúde, incluindo desenvolvimento, validação e avaliação de impacto dos modelos na área da saúde.

Figura 2
MI-CLAIM para os modelos em saúde.

Table 1 | The MI-CLAIM checklist

Before paper submission		
Study design (Part 1)	Completed: page number	Notes if not completed
The clinical problem in which the model will be employed is clearly detailed in the paper.	<input type="checkbox"/>	
The research question is clearly stated.	<input type="checkbox"/>	
The characteristics of the cohorts (training and test sets) are detailed in the text.	<input type="checkbox"/>	
The cohorts (training and test sets) are shown to be representative of real-world clinical settings.	<input type="checkbox"/>	
The state-of-the-art solution used as a baseline for comparison has been identified and detailed.	<input type="checkbox"/>	
Data and optimization (Parts 2, 3)	Completed: page number	Notes if not completed
The origin of the data is described and the original format is detailed in the paper.	<input type="checkbox"/>	
Transformations of the data before it is applied to the proposed model are described.	<input type="checkbox"/>	
The independence between training and test sets has been proven in the paper.	<input type="checkbox"/>	
Details on the models that were evaluated and the code developed to select the best model are provided.	<input type="checkbox"/>	
Is the input data type structured or unstructured?	<input type="checkbox"/> Structured <input type="checkbox"/> Unstructured	
Model performance (Part 4)	Completed: page number	Notes if not completed
The primary metric selected to evaluate algorithm performance (e.g., AUC, F-score, etc.), including the justification for selection, has been clearly stated.	<input type="checkbox"/>	
The primary metric selected to evaluate the clinical utility of the model (e.g., PPV, NNT, etc.), including the justification for selection, has been clearly stated.	<input type="checkbox"/>	
The performance comparison between baseline and proposed model is presented with the appropriate statistical significance.	<input type="checkbox"/>	
Model examination (Part 5)	Completed: page number	Notes if not completed
Examination technique 1 ^a	<input type="checkbox"/>	
Examination technique 2 ^a	<input type="checkbox"/>	
A discussion of the relevance of the examination results with respect to model/algorithm performance is presented.	<input type="checkbox"/>	
A discussion of the feasibility and significance of model interpretability at the case level if examination methods are uninterpretable is presented.	<input type="checkbox"/>	
A discussion of the reliability and robustness of the model as the underlying data distribution shifts is included.	<input type="checkbox"/>	
Reproducibility (Part 6): choose appropriate tier of transparency		Notes
Tier 1: complete sharing of the code	<input type="checkbox"/>	
Tier 2: allow a third party to evaluate the code for accuracy/fairness; share the results of this evaluation	<input type="checkbox"/>	
Tier 3: release of a virtual machine (binary) for running the code on new data without sharing its details	<input type="checkbox"/>	
Tier 4: no sharing	<input type="checkbox"/>	

PPV, positive predictive value; NNT, numbers needed to treat. *Common examination approaches based on study type: for studies involving exclusively structured data, coefficients and sensitivity analysis are often appropriate; for studies involving unstructured data in the domains of image analysis or natural language processing, saliency maps (or equivalent) and sensitivity analysis are often appropriate.

3 RESULTADOS

A seguir, serão discutidos alguns achados relevantes decorrentes da revisão realizada. A Tabela 1 proporciona uma síntese organizada desses resultados.

Tabela 1
Síntese dos achados da revisão narrativa.

Aplicações Clínicas	- Desfechos de tratamento, transtornos de humor, prevenção de suicídio e TUS.	Goh et al., 2022 Sajjadian et al., 2021 Lejeune et al., 2022 Roza et al., 2023
Comparação com Julgamento Clínico	- ML supera capacidade de psicólogos clínicos em predição de desfechos. - Identificação precoce de transtornos mentais.	Symons et al., 2020 Feczko et al., 2019 Miranda et al., 2021 Burgess-Hull et al., 2022
Limitações e Desafios	- Sensibilidade limitada. - Questões de generalização e ética.	Bracher-Smith et al., 2021 Dadi et al., 2021 Mooney & Pejaver, 2018

3.1 Aplicações Clínicas

A literatura revisada revela uma diversidade de aplicações de modelos de ML. Estudos enfocam desde desfechos de

tratamento, como mudanças comportamentais e promoção da saúde (Goh et al., 2022), até modelos específicos para transtornos de humor, como depressão (Sajjadian et al., 2021) e prevenção de suicídio (Lejeune et al., 2022; Roza et al., 2023). Por exemplo, em desfechos relacionados à depressão há modelos com acurácia de até 90%, o que é um valor significativo para uma ML (Gao et al., 2018).

No contexto dos TUS, os algoritmos de ML têm sido empregados para identificar padrões complexos em grandes volumes de dados, abrangendo diferentes substâncias psicoativas, facilitando a antecipação de comportamentos de risco, avaliação da suscetibilidade à dependência, monitoramento de efeitos adversos de substâncias e previsão de resultados de tratamento (Chhetri et al., 2023; Garbin et al., 2023; Mak et al., 2019).

3.2 Comparação com julgamento clínico

No âmbito da psicoterapia, o estudo de Symons et al. (2020) é particularmente revelador ao comparar a capacidade de psicólogos clínicos treinados e algoritmos de ML na predição de desfechos de tratamento em Terapia Cognitivo-Comportamental (TCC) para alcoolismo. O estudo foi conduzido com uma amostra significativa de 1016 pacientes submetidos a um ensaio clínico aleatorizado.

Os resultados demonstraram que os modelos de ML superaram a capacidade dos psicólogos clínicos na estimativa dos desfechos de tratamento. Este achado é simultaneamente inquietante e revigorante, pois destaca o potencial transformador da tecnologia em um domínio historicamente dominado por julgamentos clínicos humanos.

Contudo, é imperativo destacar uma ressalva metodológica significativa: a sensibilidade dos modelos de ML foi identificada como baixa. Isso sugere que, enquanto os modelos podem oferecer insights valiosos, ainda há espaço para melhorias e validações adicionais.

Outra aplicação promissora é a utilização de ML para subtipagem clínica, identificando subgrupos de pacientes com base em características clínicas e biológicas (Feczko et al., 2019; Miranda et al., 2021).

Essa abordagem, inicialmente aplicada em áreas como oncologia, agora se estende para outras condições médicas, incluindo, mais recentemente, a identificação precoce de subtipos de risco aumentado para o Transtorno por Uso de Opioides (Burgess-Hull et al., 2022).

Apesar dos avanços notáveis nos modelos de ML aplicados à saúde mental, é essencial reconhecer as limitações inerentes a essas abordagens. Yan et al. (2022) apontam que muitos dos progressos alcançados são comprometidos pelas complexidades intrínsecas aos dados clínicos em saúde mental. A falta de marcadores biológicos robustos, que são fundamentais em outras áreas da medicina para facilitar processos preditivos, representam outro desafio significativo.

3.3 Limitações e desafios

Questões éticas também são cruciais no contexto da ML. Mooney & Pejaver (2018) destacam que a dependência de grandes conjuntos de dados pode implicar desafios significativos relacionados à privacidade dos dados e ao consentimento informado dos participantes.

Além disso, a generalização dos resultados para diferentes populações apresenta desafios substanciais. Bracher-Smith et al. (2021) e Dadi et al. (2021) enfatizam a necessidade de ajustar algoritmos de ML para acomodar variações em históricos de saúde mental e marcadores genéticos distintos.

Por fim, outro ponto comum nos estudos é a necessidade de uma colaboração interdisciplinar para a concepção e validação desses modelos. A integração de profissionais da saúde mental, cientistas de dados e outros especialistas garante a robustez técnica e a relevância clínica dos modelos. Esta sinergia facilita a conformidade com as melhores práticas e diretrizes éticas, promovendo a aplicabilidade desses modelos no contexto clínico, além da adaptação cultural e ajustes com base no feedback de especialistas e pacientes.

4 DISCUSSÃO

A aplicação de ML na saúde mental, especialmente em TUS, tem demonstrado resultados promissores. Ao avaliar os recursos desenvolvidos, observa-se que os modelos de ML oferecem análises precisas e personalizadas dos padrões de uso de substâncias e dos fatores relacionados a reinternações e resultados de tratamento (Acion et al., 2017). Esta precisão e personalização representam um avanço significativo em comparação aos métodos tradicionais, evidenciando o potencial do ML para transformar o tratamento e a compreensão em saúde mental.

A eficácia dos modelos de ML na predição de desfechos clínicos e no direcionamento de tratamentos mais adequados tem implicações práticas notáveis (Alowais et al., 2023). Esses modelos possibilitam abordagens individualizadas, aumentando potencialmente a eficácia do tratamento. Além disso, a capacidade de identificar padrões complexos e variáveis inter-relacionadas pode conduzir a melhores estratégias de prevenção e intervenção.

Contudo, é importante reconhecer suas limitações. A complexidade e a heterogeneidade dos dados em saúde mental podem resultar em desafios na generalização dos modelos (Yan et al., 2022). Além disso, a exigência de grandes conjuntos de dados para treinamento e as preocupações relacionadas à privacidade e ética dos dados são aspectos que demandam atenção contínua (Rajpurkar et al., 2022).

Em específico, um dos principais desafios da área para encontrar evidências de qualidade reside na falta de robustez metodológica dos estudos, principalmente em relação ao desenvolvimento dos modelos em si.

Muitos dos artigos, tanto em saúde mental em geral quanto específicos ao TUS, discutem o uso de ML para identificar variáveis correlacionadas ao desfecho. Para realizar tal análise em modelos de ML, é necessário treinar o modelo para identificar o desfecho desejado com base nos dados de entrada e, posteriormente, examinar quais variáveis tiveram maior peso na decisão final do modelo.

Embora esse processo seja promissor para a identificação de correlações relevantes, ele é inteiramente dependente do desempenho do modelo e do contexto em que é treinado. As variáveis que possuem alta importância para um modelo de baixa qualidade (com baixa acurácia, sensibilidade ou especificidade) não são necessariamente as variáveis às quais devemos prestar maior atenção. Esse paradigma já foi criticado em outras áreas médicas, como na oncologia (Dhiman et al., 2023).

Ainda assim, é notório que diversos trabalhos se concentram em discutir diretamente as variáveis mais importantes apresentadas pelo modelo, negligenciando, em muitos casos, a análise e apresentação do próprio desempenho do modelo.

Outra grande dificuldade enfrentada pelos modelos atuais é a generalização de seus resultados, ou seja, a extensão em que esses resultados são aplicáveis a outras populações além daquela analisada. Modelos de ML treinados com baixas quantidades de dados, especialmente na ordem de dezenas, são suscetíveis a aprender padrões específicos da população de treinamento. Da mesma forma, a ausência de conjuntos de dados de validação e teste adequados impede a avaliação do desempenho do modelo em uma população não vista durante o treinamento, comprometendo sua capacidade real de generalização.

Muitos estudos também tendem a ocultar as falhas de seus modelos por meio da maneira como apresentam os resultados (Andaur Navarro et al., 2023), contribuindo para uma prática de "spin" (Chiu et al., 2017), ou seja, retratar os achados de forma mais distorcida, especialmente em modelos preditivos. Essa distorção é particularmente preocupante quando se utiliza modelos para predições em bancos de dados desbalanceados, nos quais há muitos pacientes com um determinado desfecho e muito poucos sem ele, ou vice-versa.

Nesse cenário, o modelo tende a "aprender" rapidamente que a melhor estratégia para alcançar uma alta acurácia é atribuir o desfecho majoritário a todos os pacientes, o que aumenta artificialmente sua precisão, já que a maioria dos pacientes é classificada corretamente. Contudo, um modelo que prevê que todos, ou quase todos, terão o mesmo desfecho não oferece contribuições significativas para a prática clínica, nem auxilia na identificação de variáveis de interesse.

Considerando o potencial significativo dos modelos de ML e suas limitações atuais, torna-se imperativo conduzir mais estudos. Estes estudos devem abordar padrões de qualidade na área de ML, como a transparência no desempenho dos

modelos e a validação em conjuntos de dados independentes, que englobem diferentes populações e contextos. A exploração de novas técnicas e abordagens em ML é crucial para mitigar as limitações atuais e ampliar as aplicações dessas tecnologias na área da saúde mental.

Por exemplo, pesquisas futuras podem se concentrar na personalização ainda mais refinada dos tratamentos para TUS, utilizando algoritmos avançados que levem em consideração fatores genéticos e ambientais. Dado que a aplicação de ML na saúde mental está em um estágio inicial de desenvolvimento, é fundamental que a pesquisa continue a evoluir. Portanto, é essencial a realização de estudos adicionais, incluindo a validação dos modelos em diferentes populações e contextos, bem como a investigação contínua de novas técnicas e abordagens para superar as limitações existentes.


5 CONCLUSÃO

O presente artigo destaca a crescente relevância do aprendizado de máquina (ML) na saúde mental, com ênfase particular no tratamento de TUS. Os modelos de ML têm mostrado habilidade em analisar dados clínicos complexos e multifacetados, proporcionando insights valiosos que podem conduzir a tratamentos mais eficazes e individualizados. A colaboração interdisciplinar é um elemento crucial nesse avanço, integrando expertise em saúde mental, ciência de dados e ética. Tal integração visa o desenvolvimento de modelos que sejam não apenas tecnicamente robustos, mas também clinicamente relevantes.

Embora os modelos de ML na saúde mental enfrentem desafios significativos, como a demanda por grandes conjuntos de dados e questões éticas relacionadas à transparência dos resultados, seu potencial para revolucionar a prática clínica é inquestionável.

A continuidade da pesquisa e desenvolvimento nestas áreas é vital para superar tais obstáculos e otimizar o potencial dos modelos de ML. Em síntese, o ML na saúde mental representa uma área promissora que demanda investimento e atenção contínuos. Seu potencial para aprimorar o entendimento e o tratamento dos TUS aponta para um futuro mais eficiente e personalizado na saúde mental, trazendo implicações significativas não apenas para os pacientes e profissionais de saúde, mas também para a sociedade como um todo.

BIOGRAFIA DOS AUTORES



Bernardo Paim de Mattos: Psicólogo. Mestrando em Psicologia na Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS). Membro da Comissão de Pesquisa da Associação Brasileira de Prática Baseada em Evidências (AB-PBE). bernardo.mattos@edu.pucrs.br



Christian Mattjie: Doutorando em Ciência da Computação na Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS). Mestre em Gerontologia Biomédica. Especialista em Física do Radiodiagnóstico. Licenciado em Física. christian.oliveira95@edu.pucrs.br

REFERÊNCIAS

- SAMHDA. (2019). *Treatment Episode Data Set: Discharges (TEDS-D)*.
- Acion, L., Kelmansky, D., van der Laan, M., Sahker, E., Jones, D., & Arndt, S. (2017). Use of a machine learning framework to predict substance use disorder treatment success. *PLoS One*, 12(4). <https://doi.org/10.1371/journal.pone.0175383>
- Alowais, S. A., Alghamdi, S. S., Alsuhbany, N., Alqahtani, T., Alshaya, A. I., Al-mohareb, S. N., ... Albekairy, A. M. (2023). Revolutionizing healthcare: The role of artificial intelligence in clinical practice. *BMC Med Educ*, 23(1), 689. <https://doi.org/10.1186/s12909-023-04698-z>
- Andaur Navarro, C. L., Damen, J. A. A., Takada, T., Nijman, S. W. J., Dhiman, P., Ma, J., ... Hooft, L. (2021). Risk of bias in studies on prediction models developed using supervised machine learning techniques: Systematic review. *BMJ*, 375, n2281. <https://doi.org/10.1136/bmj.n2281>
- Andaur Navarro, C. L., Damen, J. A. A., Takada, T., Nijman, S. W. J., Dhiman, P., Ma, J., ... Hooft, L. (2023). Systematic review finds "spin" practices and poor reporting standards in studies on machine learning-based prediction models. *J Clin Epidemiol*, 158, 99-110. <https://doi.org/10.1016/j.jclinepi.2023.03.024>
- Baurley, J. W., Claus, E. D., Witkiewitz, K., & McMahan, C. S. (2022). A Bayesian mixed effects support vector machine for learning and predicting daily substance use disorder patterns. *Am J Drug Alcohol Abuse*, 48(4), 413-421. <https://doi.org/10.1080/00952990.2021.2024839>
- Bracher-Smith, M., Crawford, K., & Escott-Price, V. (2021). Machine learning for genetic prediction of psychiatric disorders: A systematic review. *Mol Psychiatry*, 26(1), 70-79. <https://doi.org/10.1038/s41380-020-0825-2>
- Burgess-Hull, A. J., Brooks, C., Epstein, D. H., Gandhi, D., & Oviedo, E. (2023). Using Machine Learning to Predict Treatment Adherence in Patients on Medication for Opioid Use Disorder. *J Addict Med*, 17(1), 28-34. <https://doi.org/10.1097/ADM.0000000000001019>
- Burgess-Hull, A. J., Panlilio, L. V., Preston, K. L., & Epstein, D. H. (2022). Trajectories of craving during medication-assisted treatment for opioid-use disorder: Subtyping for early identification of higher risk. *Drug Alcohol Depend*, 233, 109362. <https://doi.org/10.1016/j.drugalcdep.2022.109362>
- Chew, H. S. J., & Achananuparp, P. (2022). Perceptions and needs of artificial intelligence in health care to increase adoption: Scoping review. *J Med Internet Res*, 24(1), e32939. <https://doi.org/10.2196/32939>
- Chhetri, B., Goyal, L. M., & Mittal, M. (2023). How machine learning is used to study addiction in digital healthcare: A systematic review. In (Vol. 3): *International Journal of Information Management Data Insights*.
- Chiu, K., Grundy, Q., & Bero, L. (2017). 'Spin' in published biomedical literature: A methodological systematic review. *PLoS Biol*, 15(9), e2002173. <https://doi.org/10.1371/journal.pbio.2002173>
- d'Elia, A., Gabbay, M., Rodgers, S., Kierans, C., Jones, E., Durrani, I., ... Frith, L. (2022). Artificial intelligence and health inequities in primary care: A systematic scoping review and framework. *Fam Med Community Health*, 10(Suppl 1). <https://doi.org/10.1136/fmch-2022-001670>
- Dadi, K., Varoquaux, G., Houenou, J., Bzdok, D., Thirion, B., & Engemann, D. (2021). Population modeling with machine learning can enhance measures of

- mental health. *Gigascience*, 10(10). <https://doi.org/10.1093/gigascience/giab071>
- Dhiman, P., Ma, J., Andaur Navarro, C. L., Speich, B., Bullock, G., Damen, J. A. A., ... Collins, G. S. (2023). Overinterpretation of findings in machine learning prediction model studies in oncology: A systematic review. *J Clin Epidemiol*, 157, 120-133. <https://doi.org/10.1016/j.jclinepi.2023.03.012>
- Diaba-Nuhoho, P., & Amponsah-Offeh, M. (2021). Reproducibility and research integrity: The role of scientists and institutions. *BMC Res Notes*, 14(1), 451. <https://doi.org/10.1186/s13104-021-05875-3>
- Feczko, E., Miranda-Dominguez, O., Marr, M., Graham, A. M., Nigg, J. T., & Fair, D. A. (2019). The heterogeneity problem: Approaches to identify psychiatric subtypes. *Trends Cogn Sci*, 23(7), 584-601. <https://doi.org/10.1016/j.tics.2019.03.009>
- Gao, S., Calhoun, V. D., & Sui, J. (2018). Machine learning in major depression: From classification to treatment outcome prediction. *CNS Neurosci Ther*, 24(11), 1037-1052. <https://doi.org/10.1111/cns.13048>
- Garbin, C., Marques, N., & Marques, O. (2023). Machine learning for predicting opioid use disorder from healthcare data: A systematic review. *Comput Methods Programs Biomed*, 236, 107573. <https://doi.org/10.1016/j.cmpb.2023.107573>
- Goh, Y. S., Ow Yong, J. Q. Y., Chee, B. Q. H., Kuek, J. H. L., & Ho, C. S. H. (2022). Machine learning in health promotion and behavioral change: Scoping review. *J Med Internet Res*, 24(6), e35831. <https://doi.org/10.2196/35831>
- Higgins, J. P., Altman, D. G., Gøtzsche, P. C., Jüni, P., Moher, D., Oxman, A. D., ... Group, C. S. M. (2011). The Cochrane Collaboration's tool for assessing risk of bias in randomised trials. *BMJ*, 343, d5928. <https://doi.org/10.1136/bmj.d5928>
- Jayatilake, S. M. D. A., & Ganegoda, G. U. (2021). Involvement of machine learning tools in healthcare decision making. *J Healthc Eng*, 6679512. <https://doi.org/10.1155/2021/6679512>
- Jiang, Y., Yang, M., Wang, S., Li, X., & Sun, Y. (2020). Emerging role of deep learning-based artificial intelligence in tumor pathology. *Cancer Commun (Lond)*, 40(4), 154-166. <https://doi.org/10.1002/cac2.12012>
- Lejeune, A., Le Glaz, A., Perron, P. A., Sebti, J., Baca-Garcia, E., Walter, M., ... Berrouguet, S. (2022). Artificial intelligence and suicide prevention: A systematic review. *Eur Psychiatry*, 65(1), 1-22. <https://doi.org/10.1192/j.eur-psy.2022.8>
- Mak, K. K., Lee, K., & Park, C. (2019). Applications of machine learning in addiction studies: A systematic review. *Psychiatry Res*, 275, 53-60. <https://doi.org/10.1016/j.psychres.2019.03.001>
- Miranda, L., Paul, R., Pütz, B., Koutsouleris, N., & Müller-Myhsok, B. (2021). Systematic review of functional MRI applications for psychiatric disease subtyping. *Front Psychiatry*, 12, 665536. <https://doi.org/10.3389/fpsy.2021.665536>
- Mooney, S. J., & Pejaver, V. (2018). Big data in public health: Terminology, machine learning, and privacy. *Annu Rev Public Health*, 39, 95-112. <https://doi.org/10.1146/annurev-publhealth-040617-014208>
- Moons, K. G., de Groot, J. A., Bouwmeester, W., Vergouwe, Y., Mallett, S., Altman, D. G., ... Collins, G. S. (2014). Critical appraisal and data extraction for systematic reviews of prediction modelling studies: The CHARMS checklist. *PLoS Med*, 11(10), e1001744. <https://doi.org/10.1371/journal.pmed.1001744>
- Norgeot, B., Quer, G., Beaulieu-Jones, B. K., Torkamani, A., Dias, R., Gianfrancesco, M., ... Butte, A. J. (2020). Minimum information about clinical artificial intelligence modeling: The MI-CLAIM checklist. *Nat Med*, 26(9), 1320-1324. <https://doi.org/10.1038/s41591-020-1041-y>
- Rajpurkar, P., Chen, E., Banerjee, O., & Topol, E. J. (2022). AI in health and medicine. *Nat Med*, 28(1), 31-38. <https://doi.org/10.1038/s41591-021-01614-0>
- Roza, T. H., Seibel, G. S., Recamonde-Mendoza, M., Lotufo, P. A., Benseñor, I. M., Passos, I. C., & Brunoni, A. R. (2023). Suicide risk classification with machine learning techniques in a large Brazilian community sample. *Psychiatry Res*, 325, 115258. <https://doi.org/10.1016/j.psychres.2023.115258>
- Sajjadian, M., Lam, R. W., Milev, R., Rotzinger, S., Frey, B. N., Soares, C. N., ... Uher, R. (2021). Machine learning in the prediction of depression treatment outcomes: A systematic review and meta-analysis. *Psychol Med*, 51(16), 2742-2751. <https://doi.org/10.1017/S0033291721003871>
- Shatte, A. B. R., Hutchinson, D. M., & Teague, S. J. (2019). Machine learning in mental health: a scoping review of methods and applications. *Psychol Med*, 49(9), 1426-1448. <https://doi.org/10.1017/S0033291719000151>
- Sterne, J. A. C., Savović, J., Page, M. J., Elbers, R. G., Blencowe, N. S., Boutron, I., ... Higgins, J. P. T. (2019). RoB 2: a revised tool for assessing risk of bias in randomised trials. *BMJ*, 366, l4898. <https://doi.org/10.1136/bmj.l4898>
- Symons, M., Feeney, G. F. X., Gallagher, M. R., Young, R. M., & Connor, J. P. (2020). Predicting alcohol dependence treatment outcomes: a prospective comparative study of clinical psychologists versus 'trained' machine learning models. *Addiction*, 115(11), 2164-2175. <https://doi.org/10.1111/add.15038>
- Yan, W. J., Ruan, Q. N., & Jiang, K. (2022). Challenges for Artificial Intelligence in Recognizing Mental Disorders. *Diagnostics (Basel)*, 13(1). <https://doi.org/10.3390/diagnostics13010002>