



Aplicações de modelos de linguagem de grande escala no tratamento de depressão: uma revisão sistemática

Applications of large language models in depression treatment: a systematic review

Aplicaciones de modelos de lenguaje de gran tamaño en el tratamiento de la depresión: una revisión sistemática

Maurício Rodrigues Lima¹, Deller James Ferreira², Elisângela Silva Dias³

1 Especialista em Engenharia de Software, Instituto de Informática, UFG, Goiânia (GO), Brasil.

2 Professora Dra, Instituto de Informática, UFG, Goiânia (GO), Brasil.

3 Professora Dra, Instituto de Informática, UFG, Goiânia (GO), Brasil.

Autor correspondente: Maurício Rodrigues Lima

E-mail: mauricio.rodrigues@discente.ufg.br

Resumo

Objetivo: Este estudo revisa o uso de Modelos de Linguagem de Grande Escala (LLMs) na área da saúde mental, focando especificamente no tratamento da depressão. **Método:** Foram analisados 18 artigos de um total inicial de 121, explorando como os LLMs auxiliam na tomada de decisões clínicas e na interação entre profissionais de saúde mental e pacientes deprimidos. **Resultados:** Os resultados principais mostram que os LLMs podem aumentar a precisão na detecção de sintomas e melhorar as intervenções terapêuticas por meio de interfaces conversacionais avançadas. **Conclusão:** O resumo aponta para lacunas na pesquisa existente e ressalta a contribuição do estudo para uma melhor compreensão da aplicabilidade dos LLMs em contextos clínicos.

Descritores: Modelos de Linguagem de Grande Escala; Depressão; Saúde Mental.

Abstract

Objective: This study reviews the use of Large Language Models (LLMs) in the field of mental health, specifically focusing on the treatment of depression. **Method:** A total of



18 articles out of an initial 121 were analyzed, exploring how LLMs assist in clinical decision-making and interaction between mental health professionals and depressed patients. **Results:** The main findings show that LLMs can increase accuracy in detecting symptoms and enhance therapeutic interventions through advanced conversational interfaces. **Conclusion:** The summary highlights gaps in existing research and emphasizes the study's contribution to a better understanding of the applicability of LLMs in clinical contexts.

Keywords: Large Language Models; Depression; Mental Health.

Resumen

Objetivo: Este estudio revisa el uso de Modelos de Lenguaje de Gran Escala (LLMs) en el campo de la salud mental, enfocándose específicamente en el tratamiento de la depresión. **Método:** Se analizaron 18 artículos de un total inicial de 121, explorando cómo los LLMs ayudan en la toma de decisiones clínicas y en la interacción entre profesionales de la salud mental y pacientes deprimidos. **Resultados:** Los hallazgos principales muestran que los LLMs pueden aumentar la precisión en la detección de síntomas y mejorar las intervenciones terapéuticas a través de interfaces conversacionales avanzadas. **Conclusión:** El resumen destaca lagunas en la investigación existente y resalta la contribución del estudio para una mejor comprensión de la aplicabilidad de los LLMs en contextos clínicos.

Descriptorios: Modelos de Lenguaje de Gran Escala; Depresión; Salud Mental.

Introdução

A crescente prevalência de transtornos psicológicos, como a depressão, desafia continuamente os profissionais de saúde mental a buscar ferramentas mais eficazes para diagnóstico e tratamento. Neste contexto, os Agentes de Conversação, ou *chatbots*, que empregam Modelos de Linguagem de Grande Escala (LLMs), têm ganhado destaque por sua capacidade de simular interações humanas e processar linguagem natural de forma eficiente. A popularidade dos Agentes de Conversação, mais conhecidos como *chatbots*, tem crescido significativamente. No âmbito do estudo da saúde mental, esses recursos vêm ganhando destaque.⁽¹⁾ Exemplos notáveis



incluem o *Woebot* e o *Wysa*, aplicações utilizadas na psicologia que demonstram a capacidade de mitigar emoções negativas em usuários.⁽²⁾ Os Modelos de Linguagem de Larga Escala, caracterizados por sua abordagem estatística e abrangente, que preveem a próxima palavra, frase, sentença ou parágrafo com base em uma entrada, têm se mostrado extremamente úteis para pesquisas na área da psicologia e psiquiatria. Esses modelos têm a capacidade de mensurar expressões sutis e contextuais de estados mentais, gerar texto de maneira semelhante à humana, participar de diálogos naturais e simular diferentes estilos e personas linguísticas.⁽³⁾

Objetivo

Este trabalho realiza uma revisão sistemática de estudos sobre Modelos de Linguagem de Grande Escala (LLM) na psicologia e psiquiatria, focando em pacientes com transtorno depressivo. A revisão destaca uma lacuna significativa na literatura sobre a integração efetiva dos LLMs na prática clínica. O objetivo é preencher essa lacuna com uma análise aprofundada sobre como os LLMs podem auxiliar na tomada de decisão clínica e melhorar a interação entre pacientes e profissionais de saúde. O estudo contribui ao avanço do conhecimento ao apresentar as capacidades dos LLMs no que diz respeito ao tratamento e acompanhamento do indivíduo depressivo.

Método

Este trabalho apresenta uma Revisão Sistemática da Literatura (RSL). As revisões sistemáticas são caracterizadas por uma metodologia metódica e replicável, envolvendo uma busca abrangente para localizar todos os trabalhos publicados e não publicados sobre um determinado tema; uma integração sistemática dos resultados dessa busca; e uma análise crítica da abrangência, natureza e qualidade das evidências em relação a uma específica questão de pesquisa. Elas sintetizam estudos para extrair conclusões teóricas amplas sobre o significado de uma literatura, conectando teoria e evidência, bem como evidência e teoria.⁽⁴⁾

Para auxiliar no processo de planejamento, execução, condução e documentação da RSL, foi utilizada a ferramenta Parsifal. Essa ferramenta permite que pesquisadores definam metas e objetivos, importem artigos usando arquivos BibTeX, eliminem duplicatas, estabeleçam critérios de seleção e gerem relatórios.⁽⁵⁾ Ademais,



adotou-se o método PRISMA em sua versão de 2020, o qual consiste em um conjunto de diretrizes destinadas a aprimorar a transparência e a qualidade dos relatórios de revisões sistemáticas, incluindo novas orientações que refletem avanços nos métodos para identificar, selecionar, avaliar e sintetizar estudos.⁽⁶⁾

Questões de Pesquisa

QP1: Como a LLM auxilia no processo de tomada de decisão de um profissional de saúde mental no tratamento da depressão?

QP2: Como a LLM realiza a interface entre o paciente depressivo e o profissional de saúde mental?

Critérios de Inclusão

Foram selecionados os artigos de acordo com os seguintes critérios:

CI1: O estudo é de LLM aplicado ao tratamento de depressão.

CI2: O estudo é de LLM como ferramenta para profissionais de saúde mental.

CI3: O estudo é de LLM no auxílio na tomada de decisão no tratamento de depressão.

Critérios de Exclusão

Foram eliminados os artigos fora do escopo da pesquisa:

CE1: O estudo é anterior a 2018.

CE2: O estudo é aplicado a outros processos da psicologia ou psiquiatria.

CE3: O estudo é uma versão anterior de um estudo previamente selecionado.

CE4: O estudo não envolve LLM.

CE5: O estudo é trata de transtornos mentais distintos de depressão.

String de Busca

("LLM" OR "Grande Modelo de Linguagem" OR "Large Language Model") AND ("Mental Health" OR "Saúde Mental" OR "Psychiatry" OR "Psiquiatria" OR "Psychology" OR "Psicologia") AND ("Depression" OR "Depressão") AND ("Treatment" OR "Tratamento").



Bases de Dados

O Quadro 1 apresenta as 5 bases de dados utilizadas nesta RSL, sendo elas 3 da área da computação e 2 da área da saúde.

Quadro 1 – Bases de dados utilizadas na revisão sistemática.

Base	URL
ACM Digital Library	http://portal.acm.org
IEEE Digital Library	http://ieeexplore.ieee.org
PubMed	https://pubmed.ncbi.nlm.nih.gov/
Science Direct	https://www.science.direct.com/
Scopus	http://www.scopus.com

Execução

A *string* de busca retornou um total de 121 artigos. Após a leitura e aplicação dos critérios de exclusão, restaram 18 artigos, que foram lidos na íntegra, como mostrado na Tabela 1.

Tabela 1 – Artigos retornados por base.

Base	Artigos retornados	Artigos Selecionados
ACM Digital Library	4	0
IEEE Digital Library	2	1
PubMed	1	1
Scopus	95	14
Science Direct	19	2

Todos os artigos escolhidos são de 2023 com exceção de um estudo, que é de 2024, de Hwang⁽⁷⁾. Outrossim, todos os artigos escolhidos foram escritos na língua inglesa.

Resultados

Respondendo à QP1

LLMs promovem a interação entre paciente e profissional de saúde mental, destacando a eficiência e precisão aprimoradas nas análises dos pensamentos e emoções autorrelatados pelos pacientes realizadas pelas LLMs⁽⁸⁾⁽⁹⁾. Essa capacidade pode fornecer aos profissionais insights mais profundos nos processos



cognitivos dos pacientes, permitindo intervenções mais direcionadas e personalizadas. Além disso, os LLMs podem automatizar certos aspectos do processo terapêutico, como identificar discrepâncias entre pensamentos e emoções relatados, emitindo chatbots para reconsideração ou refinamento dos pensamentos registrados. O GPT, por exemplo, pode oferecer uma interface de conversação para os pacientes expressarem preocupações e receberem recomendações de tratamento personalizadas. Também pode auxiliar no monitoramento do progresso do paciente e ajustar os planos de tratamento conforme necessário.⁽¹⁰⁾ Ademais, pode realizar análises do conteúdo fornecido, auxiliando na identificação de possíveis sinais de depressão na linguagem do paciente, servindo como base para avaliações e intervenções mais aprofundadas por profissionais de saúde mental.⁽³⁾ Assim, percebe-se a possibilidade da extração automatizada de dados textuais em um conjunto de dados, eliminando a necessidade de limpeza manual, já que todos os processos são realizados automaticamente. Ao aproveitar o poder dos LLMs, as características podem ser extraídas diretamente do texto, simplificando a análise e reduzindo a intervenção manual. Isso pode aprimorar a precisão e eficiência na triagem e diagnóstico da depressão, resultando, em última instância, em um cuidado mais eficaz ao paciente.⁽¹¹⁾

LLM fornece insights em tempo real sobre a gravidade da depressão e opções de tratamento. Esses insights têm o potencial de aprimorar a qualidade do atendimento, ao aderir a diretrizes de tratamento aceitas e eliminar preconceitos, melhorando, assim, a experiência geral do paciente e os resultados do tratamento.⁽¹²⁾⁽¹³⁾

Além disso, os LMs podem contribuir para a detecção da depressão e fornecer recomendações para opções de tratamento personalizadas, potencialmente melhorando a interação paciente- profissional e a eficácia do tratamento. Para fornecer insights sobre o estado emocional do paciente e a eficácia da terapia, foi apresentado o uso do classificador de aprendizado de máquina zero-shot baseado no modelo de linguagem de grande escala BART. Ao analisar a linguagem utilizada tanto pelo paciente quanto pelo terapeuta durante as sessões de apoio psicológico, o classificador pode fornecer insights sobre o estado emocional do paciente e a eficácia da terapia.⁽¹⁴⁾ Essas informações podem ajudar os profissionais de saúde mental a adaptarem sua abordagem às necessidades do paciente e melhorar a qualidade geral do cuidado.



Respondendo à QP2

O ChatGPT possui grande potencial na facilitação da interface entre um paciente deprimido e um profissional de saúde mental. Esse modelo pode gerar formulações psicodinâmicas e interagir com os pacientes, preenchendo lacunas no cuidado ao paciente ao possibilitar interações por períodos ilimitados a qualquer momento.⁽⁷⁾ Isso incentiva os pacientes a buscarem ajuda e fornece conselhos sobre escolhas apropriadas. Além disso, os pacientes podem sentir-se mais confortáveis compartilhando informações negativas ou sensíveis com a IA em vez de um humano, o que pode ser benéfico no processo terapêutico.

Outrossim, a utilização de uma interface entre pacientes deprimidos e profissionais de saúde mental por meio de um chatbot é capaz de simular uma conversa natural e oferecer suporte por meio de entrada e saída de texto. Essa abordagem pode contribuir para a redução do estigma associado à busca de ajuda para questões de saúde mental, proporcionando uma forma mais acessível e envolvente de suporte.⁽¹⁵⁾ De maneira similar, o Terabot, sistema de diálogo que emprega LLMs para facilitar a interação entre pacientes deprimidos e profissionais de saúde mental interage com os pacientes, auxiliando-os a acalmar suas emoções acirradas e incentivando a prática de exercícios relaxantes. O sistema também incorpora um módulo de reconhecimento de emoções, treinado com um conjunto de dados de emoções conversacionais em polonês, rotulado com nove classes de emoções, consistindo em 21.000 frases de treinamento. Esse conjunto de dados foi expandido automaticamente identificando frases semanticamente semelhantes em um corpus da web chamado Common Crawl⁽⁹⁾. Além disso, assistentes digitais empáticos que utilizam estimativas de expressão emocional para aprimorar a compreensão de alvos afetivos podem ser empregados em ambientes terapêuticos para melhorar a interação entre o paciente e o profissional de saúde mental, potencialmente resultando em uma comunicação e suporte mais empáticos para pacientes deprimidos.⁽¹⁶⁾

Discussão

Os resultados indicam que os LLMs têm um papel significativo na melhoria da detecção de sintomas e na otimização das intervenções terapêuticas. A capacidade



desses modelos de simular conversas humanas realistas e processar grandes volumes de dados oferece uma ferramenta valiosa para profissionais de saúde mental. Além disso, representam uma promissora fronteira na saúde mental, com potencial para transformar tanto a prática clínica quanto a pesquisa. No entanto, é crucial que a evolução dessas tecnologias seja acompanhada por uma averiguação ética rigorosa e um compromisso com a melhoria contínua da precisão e aplicabilidade dos modelos.

Outrossim, observa-se a diversidade de LLMs utilizados na saúde mental, incluindo GPT2, GPT4, FLAN-UL2, LLamA-7B, ChatGLM-6B, Alpaca e outros. Isso reflete uma abordagem multifacetada no processo de detecção e tratamento de indivíduos com depressão, enfrentando os desafios complexos associados a essa condição psicológica. Esses modelos não apenas facilitam a detecção precoce e a prevenção de crises, mas também oferecem suporte terapêutico, ampliando o escopo das intervenções disponíveis. A Tabela 2 apresenta essa diversidade.

Tabela 2 – Diversidade de utilização de diferentes LLMs em saúde mental.

Artigo	Modelo	Aplicação	Dados	Área	Métricas
(BOKOL O e LIU, 2023)	LLamA-7B, ChatGLM-6B, Alpaca, LLMs	Melhoria no diagnóstico e tratamento da depressão com envolvimento de Especialistas ⁽¹⁷⁾	Corpus chinês limitado	Diagnóstico e Tratamento de Depressão	Avaliação de segurança, usabilidade e fluência dos modelos.
(ZHOU et al., 2023)	FLAN-UL2	Detecção de Suicídio ⁽¹⁸⁾	NVDRS Database (2014-2018)	Pesquisa em Saúde Pública e Saúde Mental	Pontuações F1 superiores a 0.6 e 0.8 usando modelos de linguagem grandes.
(BUC UR, 2023)	GPT4	Terapia para doenças mentais ⁽⁹⁾	Conjunto de dados emocionais em polonês	Terapia	Melhoria da precisão para 86% usando ChatGPT.



(CARRER A-RIVERA et al., 2022)	GPT2	Geração de notas de psicoterapia ⁽⁵⁾	Transcrições da UCSF Depression Center	Psicologia Clínica	Métricas não mencionadas .
(DOUGHERTY et al., 2023)	BART	Previsão de resultados clínicos com psilocibina ⁽¹⁴⁾	Transcrições de sessões de apoio psicológico	Terapia com Psilocibina	Modelos com 85% e 88% de precisão em validação cruzada.
(DEMSZKY et al., 2023)	RoBERTa, DistilBERT, SqueezeBERT, DeBERTA	Deteção de depressão em tweets ⁽³⁾	632,000 tweets	Deteção de Depressão em Mídias Sociais	Acurácia, precisão, recall e F1 score.
(GROVÉ, 2021)	GPT-3.5	GPT como ferramenta diagnóstica em psicoterapia ⁽²⁾	Não mencionado	Geração de habilidades semelhantes à mentalização	Capacidade de diferenciar emoções de transtorno de personalidade.

Conclusão

Apesar dos avanços na aplicação de Modelos de Linguagem de Grande Escala (LLMs) na saúde mental, persistem desafios significativos como viés e questões éticas. Isso ocorre porque esses modelos podem incorporar vieses presentes nos dados de treinamento, o que é preocupante em contextos de diagnósticos e terapias. A falta de transparência nas decisões dos LLMs também é problemática, pois complica a compreensão dos processos decisórios em ambientes clínicos. Além disso, a integração dessas tecnologias no cotidiano dos profissionais de saúde mental continua sendo um desafio devido à necessidade de adaptação aos diferentes estilos terapêuticos e necessidades dos pacientes.

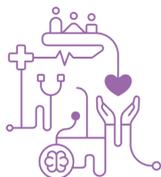
Existem lacunas notáveis na pesquisa, como a carência de estudos empíricos de longo prazo que avaliem os efeitos da interação entre pacientes e LLMs nos resultados clínicos ao longo do tempo. Outro ponto crítico é que a maioria dos modelos é treinada predominantemente em inglês, limitando sua eficácia em contextos multilíngues e culturais. Como melhorias, sugere-se o desenvolvimento de modelos personalizáveis às particularidades dos pacientes e contextos clínicos e a ampliação na coleta de dados em diversas línguas para criar



modelos mais inclusivos.

Referências

1. Liu S, Zheng C, Demasi O, Sabour S, Li Y, Yu Z, Jiang Y, Huang M. Towards Emotional Support Dialog Systems. In: Zong C, Xia F, Li W, Navigli R, editors. Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers); 2021 Aug; Online. Association for Computational Linguistics; p. 3469–3483. Disponível em: <https://aclanthology.org/2021.acl-long.269>. DOI: 10.18653/v1/2021.acl-long.269.
2. Grové C. Co-developing a mental health and wellbeing chatbot with and for young people. *Frontiers in Psychiatry*. 2021;11.
3. Demszky D, et al. Using large language models in psychology. *Nature Reviews Psychology*. 2023;2(11):688–701.
4. Siddaway AP, Wood A, Hedges L. How to do a systematic review: A best practice guide for conducting and reporting narrative reviews, meta-analyses, and meta-syntheses. *Annual Review of Psychology*. 2019;70:747-770. DOI: 10.1146/annurev-psych-010418-102803.
5. Carrera-Rivera A, et al. How-to conduct a systematic literature review: A quick guide for computer science research. *MethodsX*. 2022;9:101895.
6. Page M, et al. The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *Journal of Clinical Epidemiology*. 2021.
7. Hwang G, et al. Assessing the potential of chatgpt for psychodynamic formulations in psychiatry: An exploratory study. *Psychiatry Research*. 2024;331:115655.
8. Furukawa TA, et al. Harnessing AI to optimize thought records and facilitate cognitive restructuring in smartphone CBT: An exploratory study. *Cognitive Therapy and Research*. 2023;47(6):887–893.
9. Bucur A-M. Utilizing chatgpt generated data to retrieve depression symptoms from social media. 2023.
10. Hashem R, et al. AI to the rescue: Exploring the potential of chatgpt as a teacher ally for workload relief and burnout prevention. *Research and Practice in Technology Enhanced Learning*. 2024;19:023.
11. Gabor-Siatkowska K, et al. AI to train AI: Using chatgpt to improve the accuracy of a therapeutic dialogue system. *Electronics*. 2023;12(22).
12. Levkovich I, Elyoseph Z. Identifying depression and its determinants upon initiating treatment: Chatgpt versus primary care physicians. *Family Medicine and Community Health*. 2023;11(4).
13. Montag C, et al. On artificial intelligence and global mental health. *Asian Journal of Psychiatry*. 2023;103855.



14. Dougherty RF, et al. Psilocybin therapy for treatment resistant depression: prediction of clinical outcome by natural language processing. *Psychopharmacology*. 2023.
15. Bird JJ, Lotfi A. Generative transformer chatbots for mental health support: A study on depression and anxiety. In: *Proceedings of the 16th International Conference on Pervasive Technologies Related to Assistive Environments, PETRA '23*; 2023 p. 475–479. New York, NY, USA: Association for Computing Machinery.
16. Brooks JA, et al. Emotion expression estimates to measure and improve multimodal social-affective interactions. In: *Companion Publication of the 25th International Conference on Multimodal Interaction, ICMI '23 Companion*; 2023 p. 353–358. New York, NY, USA: Association for Computing Machinery.
17. Bokolo Biodoumoye George, Liu Qingzhong. Deep Learning-Based Depression Detection from Social Media: Comparative Evaluation of ML and Transformer Techniques. *Electronics*. 2023;12(21):4396. Disponível em: <https://www.mdpi.com/2079-9292/12/21/4396>. DOI: 10.3390/electronics12214396.
18. Zhou W, et al. Identifying rare circumstances preceding female firearm suicides: Validating a large language model approach. *JMIR Ment Health*. 2023;10.