

有关抑郁症的机器学习模型

吴佳怡, 郑敏晓*, 朱冬梅

江汉大学教育学院, 湖北 武汉

收稿日期: 2026年4月29日; 录用日期: 2026年5月22日; 发布日期: 2026年5月28日

摘要

为了解近5年来有关抑郁症的相关机器学习模型。检索2020年至2025年Web of Science数据库核心合集中有关抑郁症的机器学习模型的相关文献。采用CiteSpace 6.3R1对其发文量、国家、机构、作者、共现关键词、关键词聚类和时间线谱进行可视化分析。共收录文章1282篇, 近5年来年度发文量呈现总体上升趋势。对国家、机构和作者的分析表明, 中国是发文量最多的国家; 目前尚未形成核心作者群, Hu Bin为代表的团队共发表了22篇文章, 是最核心的团队; 中国科学院是该网络最核心的机构。对关键词的共现与聚类图谱进行分析, 当前研究热点主要围绕“研究靶点与特定人群”、“多模态数据源”以及“核心算法与模型评估”三大维度展开。对最近爆发词和时间线谱分析表明, 抑郁症机器学习模型领域已从2020年左右的技术爆发期, 过渡到当前的方法论深化、多模态融合框架构建和临床精细化应用验证的探索阶段。

关键词

抑郁症, 机器学习, 深度学习

Machine Learning Models for Depression

Jiayi Wu, Minxiao Zheng*, Dongmei Zhu

School of Education, Jianghan University, Hubei, Wuhan Hubei

Received: April 29, 2026; accepted: May 22, 2026; published: May 28, 2026

Abstract

This paper aims to investigate the development and research trends of machine learning models related to depression over the past five years. Relevant literature published from 2020 to 2025 was retrieved from the Web of Science Core Collection. CiteSpace 6.3R1 was used to conduct a visual analysis of publication volume, countries, institutions, authors, keyword co-occurrence, keyword clustering, and timeline views. A total of 1282 papers were included, with the annual publication volume showing an overall upward trend in the past 5 years. Analysis of countries, institutions, and

*通讯作者。

authors showed that China was identified as the country with the highest publication volume. Although a stable core author group has not yet fully formed, the team represented by Hu Bin was the most prominent (22 papers), and the Chinese Academy of Sciences was the central institution in the network. Analysis of keyword co-occurrence and clustering indicates that research hotspots are currently centered around three key dimensions: “research targets and specific populations”, “multimodal data sources”, and “core algorithms and model evaluation”. The analysis of burst terms and timeline views suggests that the field has transitioned from a phase of rapid technical emergence around 2020 to a current exploratory stage focused on methodological deepening, the construction of multimodal fusion frameworks, and refined clinical application validation.

Keywords

Depression, Machine Learning, Deep Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

抑郁症是一种全球性的重大精神卫生挑战[1], 尽管临床干预手段不断发展, 但其诊断的滞后性、对主观量表的依赖, 以及抗抑郁治疗的高度试错性, 严重限制了诊疗效率和患者预后[2]。在精准医学背景下, 基于个体特征, 开展针对性的个性化干预尤其重要, 因此开发客观、系统的诊断分类工具, 并以此开展个性化干预, 已成为迫切需求[3]。

随着人工智能技术的发展, 它们为解决这一临床瓶颈提供了新的解决方案。如机器学习模型能够有效处理来自脑功能影像、数字行为(如语音、文本)等多样化的多模态数据, 从中提取关键特征, 进行预测。近年来, 该领域研究呈指数级增长, 核心应用聚焦于两大方向: 一是精准临床分层与鉴别诊断, 用于区分抑郁症与其他共病精神疾病, 并对患者进行更细致的亚型划分; 二是预后与疗效预测, 预测患者对特定治疗的反应、潜在耐药性、以及复发风险。

机器学习在抑郁症诊疗中的应用积累了相对丰富的研究成果, 但目前对于这些成果缺乏全面梳理, 已有综合性分析多为描述性评价, 缺乏定量的系统分析。鉴于此, 本研究运用 CiteSpace, 旨在全面且结构化地分析抑郁症机器学习领域的研究现状。

通过对文献的全面深入计量和挖掘分析, 从不同的角度揭示该领域的载文特征、研究热点主题、演变路径等。为后续研究提供清晰的路线图, 推动机器学习模型向实际临床转化。

2. 资料与方法

2.1. 一般资料

数据来源于 Web of Science 数据库核心合集的 SCI-E、SSCI、A&HCI、CCR-E、IC。检索时限为 2020 年 1 月 1 日至 2025 年 9 月 25 日。鉴于人工智能理论与技术的范式变革正深刻影响着精神医学研究, 高级机器学习、类脑智能计算等跨领域研究已成为当前学术前沿, 因此选取近 5 年来有关抑郁症的机器学习模型相关研究, 旨在分析其研究进展。

检索式: TS = (depression OR MDD OR “depressive disorder”) AND TS = (“machine learning” OR “deep learning” OR “neural network” OR “predictive model”) AND TS = (diagnosis OR diagnostic OR intervention OR

interventions OR treatment OR classification OR classifying)。

2.2. 文献纳入与排除标准

纳入标准：① 研究内容包括抑郁症、机器学习；② 研究内容以抑郁症相关的机器学习模型为主；③ 英文文献，且发表于 2020 年至 2025 年。

排除标准：① 咨询、社论、信函、会议摘要，以及与本主题无关、字段值缺失的文献；② 重复类文献，只保留最新或最全面的一篇。

2.3. 文献筛选与数据提取

初始获得文献 2638 篇，经过两名研究人员对标题和摘要进行审查，排除与主题无关的文章，最终纳入 1282 篇文献。

2.4. 数据处理与分析

采用 CiteSpace 6.3.R1 对文献进行可视化分析。设置节点类型为关键词，时间分段为 2020~2025 年，时间分区为 1，关联强度和其他阈值为系统默认值。此外，根据节点类型的不同，选择标准设置为 Top N = 50，g-index 和裁剪方式按需调整，具体参数见各节点结果分析部分。

3. 结果

3.1. 基本情况分析

3.1.1. 年度发文量

有关抑郁症的机器学习模型，其相关研究年度发文量近 5 年呈总体上升趋势，最高发文量为 2024 年的 300 篇，见图 1。该领域发文量的上升是公共卫生现实需求、国家科技战略导向以及高质量本土数据库开放等多重因素长期驱动的结果，反映了我国在精神健康智能化治理领域的跨学科研究深度正不断加强。

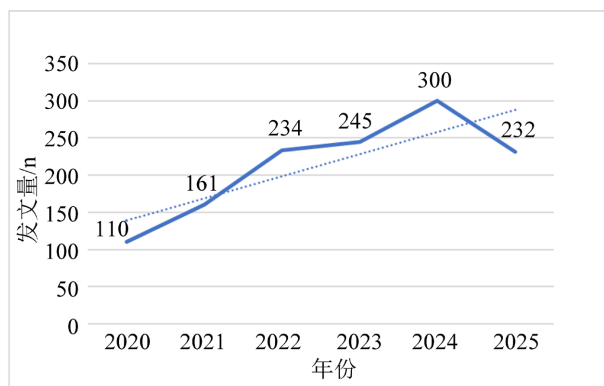


Figure 1. Annual distribution of document published
图 1. 年度发文量分布变化

3.1.2. 国家共现分析

国家共现图谱中，节点数为 83，连线数 $E = 108$ (密度 = 0.0317)，见图 2。中国(531 篇)的发文量最多且远远高于其他国家，表明我国已经成为该领域的主要学术团体，拥有一定的学术影响力。这得益于近年来我国对人工智能关键技术与标准化体系建设的高度重视，显著推动了国内抑郁症机器学习模型研究的蓬勃发展，使其在算法研发与临床转化应用方面均取得了突破性进展。

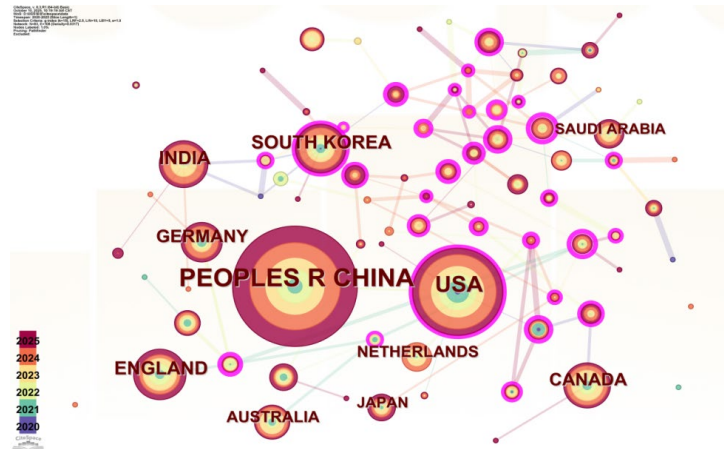


Figure 2. National co-occurrence map
图 2. 国家共现图谱

3.1.3. 核心作者共现分析

在 CiteSpace 软件中将节点类型设置为“Author”，得到如图 3 所示的内容。

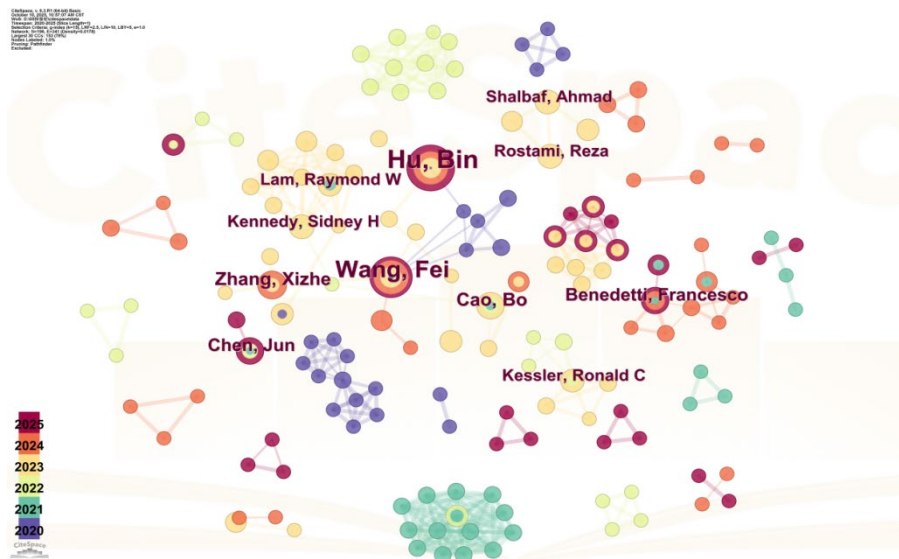


Figure 3. Author co-occurrence map
图 3. 作者共现图谱

Table 1. Core authors (number of publications ≥ 4)
表 1. 核心作者(发文量 ≥ 4)

发文频次	首次被纳入分析的发文年份	作者
22	2020	Hu, Bin
16	2020	Wang, Fei
8	2021	Cao, Bo
8	2023	Zhang, Xizhe
7	2021	Benedetti, Francesco

续表

7	2021	Chen, Jun
6	2023	Shalhaf, Ahmad
6	2021	Lam, Raymond W
6	2022	Kennedy, Sidney H
6	2022	Kessler, Ronald C
6	2023	Rostami, Reza
5	2021	Brambilla, Paolo
5	2023	Chu, Tongpeng
5	2023	Hou, Gangqiang
5	2021	Koutsouleris, Nikolaos
5	2023	Shahabi, Mohsen Sadat
5	2023	Che, Kaili
5	2023	Li, Gang
5	2022	He, Lang
5	2020	Turecki, Gustavo
5	2023	Dong, Fanghui
4	2023	Acharya, U Rajendra
4	2023	Kazemi, Reza
4	2021	Dannowski, Udo
4	2023	Chen, Jie
4	2021	Colombo, Cristina
4	2024	Liu, Zhongchun
4	2021	Wang, Gang
4	2023	Frey, Benicio N
4	2022	Chen, Tao
4	2023	Rotzinger, Susan

由作者发文量统计可知，本领域发文量最多是 22 篇，计算 M 为 3.513 [4]，因此发文量 ≥ 4 篇的学者即为核心作者，共 31 位，占总作者数量的 15.8%(31/196)，他们共发表文献 188 篇，占全部文献的 15% (188/1282)。见表 1。根据普莱斯定律，抑郁症的机器学习模型研究领域尚未形成核心作者群，该领域研究内容广泛，且学者的研究内容分散。

3.1.4. 研究机构共现分析

发文量居前的研究机构为 Chinese Academy of Sciences (49 篇)、Harvard University (47 篇)、University of California System (41 篇)，见表 2。Chinese Academy of Sciences 具有较高的中心性，其数值远超 0.1，表明该机构在合作网络间扮演了关键的桥梁和枢纽角色，见图 4。

Table 2. Centrality and publication volume of core research institutions
表 2. 核心研究机构的中心性及发文量

序号	机构	中心性	年份	发文量/n	占比
1	Chinese Academy of Sciences	0.25	2020	49	3.82%
2	Harvard University	0.00	2020	47	3.67%
3	University of California System	0.08	2020	41	3.20%
4	Harvard University Medical Affiliates	0.10	2020	37	2.89%
5	Harvard Medical School	0.14	2020	36	2.81%
6	University of London	0.04	2021	33	2.57%
7	Nanjing Medical University	0.10	2020	29	2.26%
8	King's College London	0.04	2020	29	2.26%
9	University of Toronto	0.00	2021	28	2.18%
10	Columbia University	0.02	2020	25	1.95%

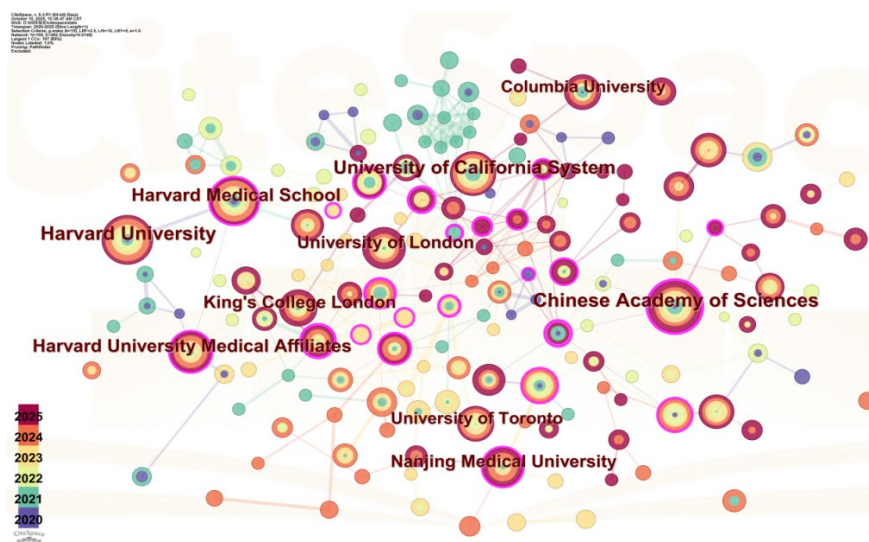


Figure 4. Clustering map of cooperating institutions
图 4. 合作机构聚类图谱

3.2. 研究热点分析

3.2.1. 关键词共现分析

选择“Keyword”节点，以“Title”“Abstract”为主题词来源，阈值为15，得出图5的关键词共现图谱。

图中188个关键词节点，221条连线，节点大小代表频次，大小不一，显示频次差异。“symptoms”“meta-analysis”“classification”“classifying depression”等节点较大，连接较多，表明这些关键词在相关研究中起到桥梁的作用。

从频次来看，“machine learning”(510)和“major depressive disorder”(228)位居前列，为该领域最为集中和持续的热点研究对象。同时，“deep learning”和“functional connectivity”等高频词汇则体现了研究方法正朝着深度学习模型和脑功能网络连接的精细化分析方向发展，见表3。

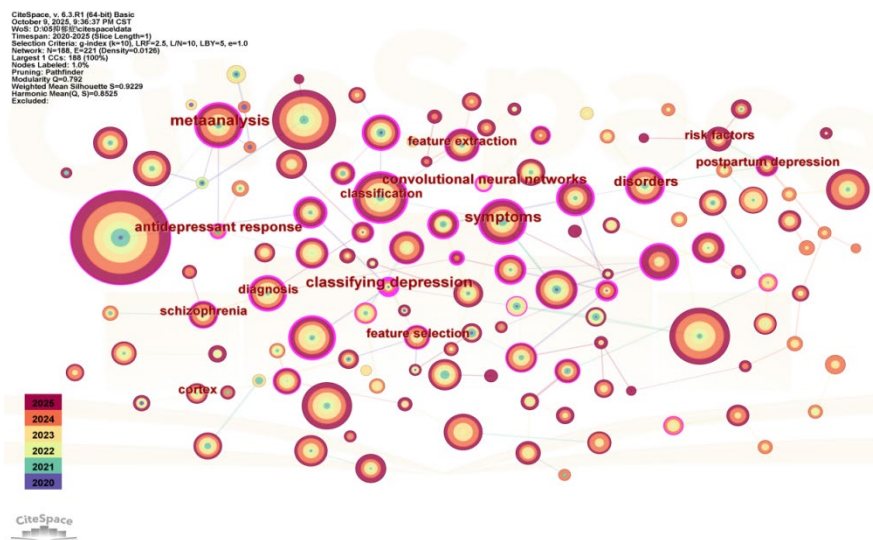


Figure 5. Keyword co-occurrence map
图 5. 关键词共现图谱

Table 3. High-frequency and high-centrality keywords (frequency ≥ 100)
表 3. 高频及高中心性关键词(频次 ≥ 100)

序号	关键词	频次	年份	中介中心性
1	machine learning	510	2020	0.06
2	major depressive disorder	228	2020	0.00
3	deep learning	194	2020	0.00
4	classification	147	2020	0.06
5	disorder	146	2020	0.02
6	Meta-analysis	116	2020	0.17
7	symptoms	108	2020	0.11
8	mental health	107	2020	0.07
9	functional connectivity	104	2020	0.09

3.2.2. 关键词聚类分析

共形成 13 个聚类，聚类的模块化 Q 值为 0.792，轮廓值 S 值为 0.9229，均超过阈值，说明聚类显著且合理，见图 6。

根据图谱中 13 个聚类标签的知识网络及文献内涵，近年抑郁症机器学习模型的前沿热点高度交叉融合，主要可归纳为“研究靶点与特定人群”、“多模态数据源”以及“核心算法与模型评估”三大维度的演进。

(1) 研究靶点与特定人群

这一板块反映了机器学习在抑郁症领域的应用场景和落地演变，研究逐渐从宏观的疾病诊断转向针对特定人群的精准化干预。

核心疾病靶点：聚类#0 (unipolar depression, 单相抑郁)、#1 (major depression, 重度抑郁)以及#8 (major depressive disorder, 重度抑郁症)构成了该领域最基础的研究网络。目前，模型在这些核心靶点上已经实

现了从早期筛查、诊断到预后的全阶段覆盖[5]-[9]。

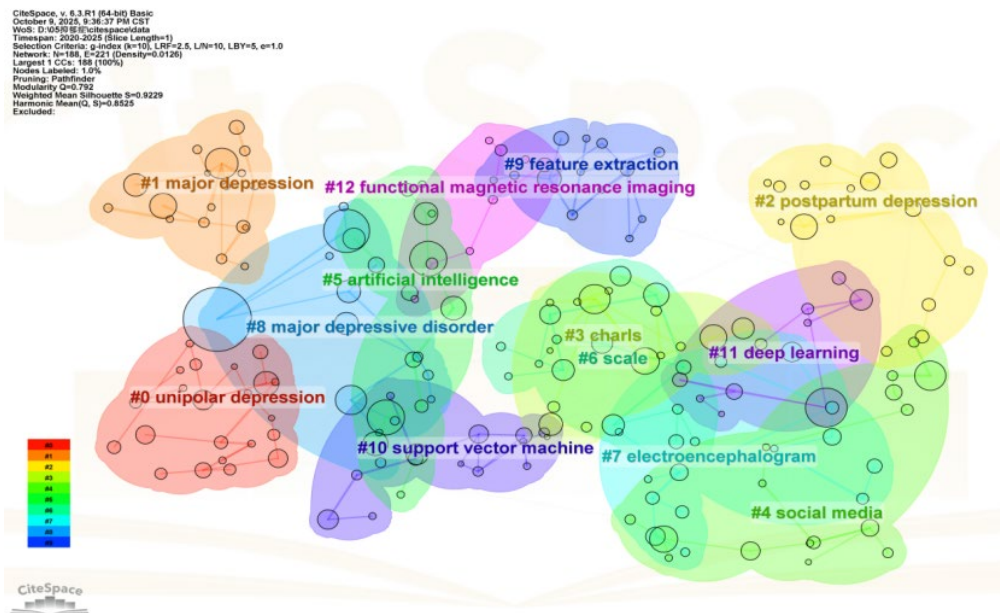


Figure 6. Clustering map of high-frequency keywords
图 6. 高频关键词聚类图谱

特定人群与场景定制：随着研究深入，聚类开始聚焦于高风险群体。聚类#2 (postpartum depression, 产后抑郁)凸显了对围产期女性的关注，例如构建围产期自动化大数据平台以支持早期干预[10]。聚类#3 (charls, 中国健康与养老追踪调查)则代表了模型在老年抑郁症及并发症群体中的应用落地。这种基于特定场景的定制化研究，为捕捉患者实时数字表型、预测高危瞬间并触发即时干预提供了理论支撑[11]。

(2) 多模态数据源与特征构建

高质量的特征数据集是模型构建的基础，图谱中的聚类清晰地展示了当前抑郁症研究中三大主流数据模态的建设与优化。

神经影像与生理数据：聚类#12 (functional magnetic resonance imaging, 功能磁共振成像)代表了神经生物学基础的核心结构与功能数据；而聚类#7 (electroencephalogram, 脑电图)则代表了客观、连续的生理状态监测。研究者正积极利用可穿戴设备采集此类指标(如 EEG、HRV、睡眠)，旨在识别数字生物标志物并构建高灵敏度筛查系统[12]-[14]。

行为与主观数据：聚类#4 (social media, 社交媒体)揭示了基于个体认知、情绪和表达方式的挖掘，通过 NLP 技术分析语言模式以实现抑郁检测[15]。同时，聚类#6 (scale, 量表)的存在表明，传统的临床测量工具依然是验证机器学习模型效能[16]和提供临床金标准的重要基石。未来的趋势是将上述多模态数据进行融合，以构建更稳健的模型。

(3) 核心算法与模型评估

这一板块着重于构建高性能模型所需的底层技术与评估体系，是推动模型向临床转化的关键驱动力。

算法基础与迭代：聚类#5 (artificial intelligence, 人工智能)涵盖了整体技术框架。在具体方法上，从基础的聚类#9 (feature extraction, 特征提取)和经典的聚类#10 (support vector machine, 支持向量机)，正迅速向更高级的聚类#11 (deep learning, 深度学习)演进。CNN、LSTM 以及图卷积网络等深度学习算法，凭借其在空间特征提取、时序依赖处理以及脑功能网络拓扑解析方面的优势被广泛采纳。

模型评估与优化：建模的目标不仅限于单一诊断，而是延伸至疗效预测与症状演变[17][18]。在模型实体化开发(如集成于移动终端的远程监测工具)的过程中，为了确保其能融入临床流程，研究者正在开展多维度评估，包括利用可解释性人工智能(XAI)增强医生信任[19]、进行公平性校正[20]，以及评估医患双方对决策支持系统的接受度[21]。

3.3. 研究趋势分析

3.3.1. 关键词突现分析

研究初期以“support vector machine (SVM)”等经典算法奠定基础，主要利用结构化数据进行诊断分型。2021~2023 年转向追求分类的高效与精准，CNNs 集成框架及“state functional connectivity”等动态分析技术因算力提升而成为热点。2023~2025 年，全球青少年抑郁症发病率激增驱动[22]，研究重心向青少年群体倾斜。总体而言，该领域已从经典算法探索期演进至深度学习驱动的高维数据挖掘与模型精准化阶段。见图 7。

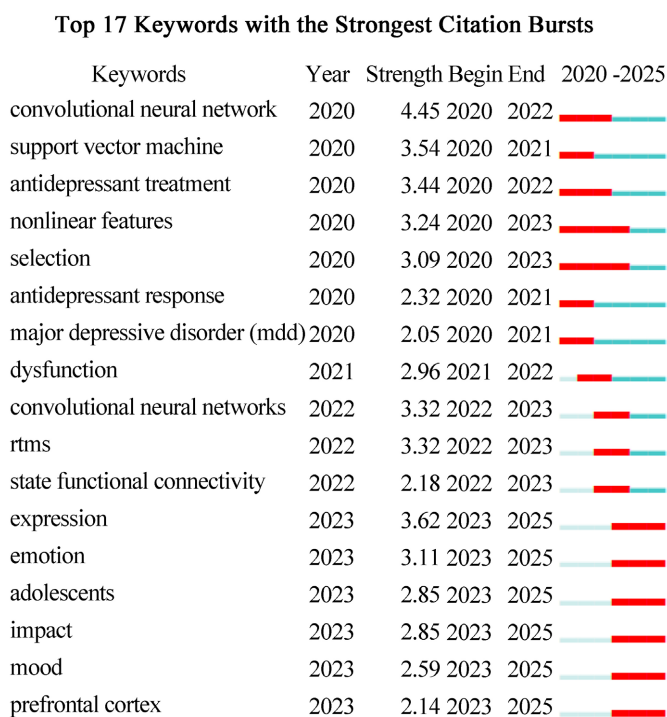


Figure 7. The 17 keywords with the strongest citation surge
图 7. 引用激增最强的 17 个关键词

3.3.2. 研究发展趋势

时间线图(Timeline Line)清晰地揭示了抑郁症机器学习模型研究的演进轨迹。图谱呈现出前期节点密集且中心性高，而后期节点相对稀疏且分散的特点。在过去 5 年中经历了有爆发式奠基向聚焦深化的阶段性转型。见图 8。

2020~2022 年为方法转型期，深度学习框架(如 CNN)取代经典 SVM，实现了从人工特征工程向自动非线性特征提取的范式转变。2022~2025 年进入精细化聚焦期，研究转向构建多模态融合框架以突破瓶颈，并聚焦鉴别诊断与临床转化；“predictive modeling”等关键词的活跃验证了领域对临床落地的重视[23]。

综上，该领域已由技术爆发过渡至方法深化与应用验证阶段。图谱节点的稀疏性实则反映了研究方

向的广泛化。因此，未来应致力于“精细化与完整化”，即面向特定人群与症状构建全链条解决方案。

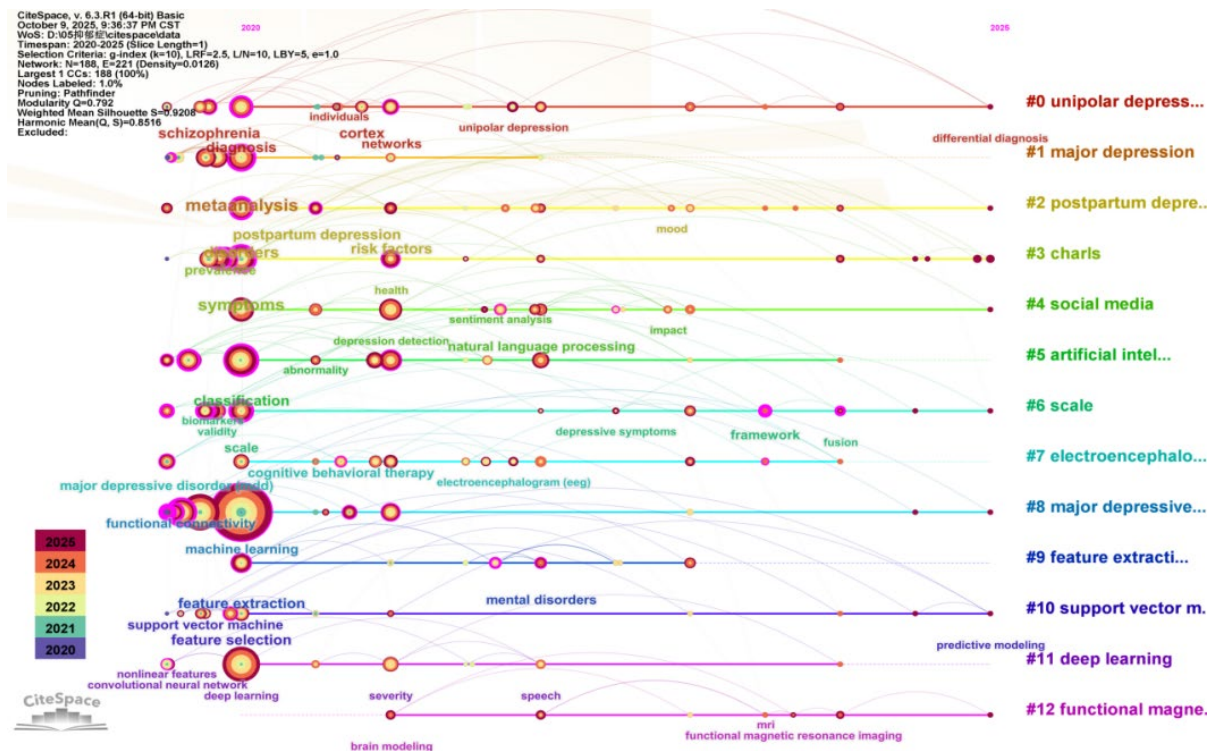


Figure 8. Keyword co-occurrence timeline spectrum
图 8. 关键词共现时间线谱

4. 讨论与结论

4.1. 本研究的局限性

尽管本研究通过可视化图谱系统梳理了抑郁症机器学习模型的研究态势，但仍存在以下局限：

(1) **数据来源与选择偏倚**：本研究主要基于 Web of Science 核心合集，未涵盖 PubMed、IEEE Xplore 或中文数据库(如 CNKI)，且仅纳入了英文文献。尽管该合集具有高度代表性，但仍可能导致研究结论存在一定的选择偏倚。

(2) **文献计量学的本质限制**：文献计量学分析侧重于发文量、被引频次及共现关系等外部特征，难以深入剖析每项研究的具体科研质量、算法细节及临床有效性。高频关键词或高被引文献虽代表研究热点，但不直接等同于该研究的学术水平。

(3) **语义分析的局限性**：虽然 CiteSpace 对关键词进行了聚类处理，但由于自然语言的多义性以及作者署名习惯的不同(如“Deep Learning”与“Neural Networks”在某些语境下的重合)，关键词聚类分析可能存在一定的语义重叠或信息损耗。

(4) **软件参数的敏感性**：知识图谱的生成受 CiteSpace 软件参数设置(如 Time Slicing、Top N 及裁剪方式等)的影响。虽然本研究经过多次调试选定了最优参数，但不同的设置仍可能对节点分布及聚类边界产生微妙的影响。

4.2. 结论

抑郁症的机器学习模型领域发文量总体升高，研究热度在国际范围内持续不减，且走向模型深入优

化的发展阶段。该领域的研究热点已演进为由“研究靶点与特定人群”、“多模态数据源”以及“核心算法与模型评估”构成的有机整体。未来研究应在深化多模态数据融合的基础上,进一步针对特定高风险人群的相关症状开展精准化建模,并强化模型在临床场景中的实体化评估与可解释性研究,以期构建更完整的临床应用链,解决目前研究“广而不深”的局面。

基金项目

2025年湖北省高校实验室研究项(HBSY2025-10);2025年湖北本科高校省级教学改革研究项目(2025269)。

参考文献

- [1] Liu, Q., He, H., Yang, J., Feng, X., Zhao, F. and Lyu, J. (2020) Changes in the Global Burden of Depression from 1990 to 2017: Findings from the Global Burden of Disease Study. *Journal of Psychiatric Research*, **126**, 134-140. <https://doi.org/10.1016/j.jpsychires.2019.08.002>
- [2] Papakostas, G.I. and Fava, M. (2010) Pharmacotherapy for Depression and Treatment-Resistant Depression. World Scientific Publishing Co. Pte. Ltd. <https://doi.org/10.1142/9789814287593>
- [3] Fernandes, B.S., Williams, L.M., Steiner, J., Leboyer, M., Carvalho, A.F. and Berk, M. (2017) The New Field of ‘precision Psychiatry’. *BMC Medicine*, **15**, Article No. 80. <https://doi.org/10.1186/s12916-017-0849-x>
- [4] 邱均平. 信息计量学[M]. 武汉: 武汉大学出版社, 2007.
- [5] Böttcher, L., Breedvelt, J.J.F., Warren, F.C., Segal, Z., Kuyken, W. and Bockting, C.L.H. (2023) Identifying Relapse Predictors in Individual Participant Data with Decision Trees. *BMC Psychiatry*, **23**, Article No. 835. <https://doi.org/10.1186/s12888-023-05214-9>
- [6] Davoodi, A., Holeňa, M., Brunovský, M., Kathpalia, A., Hlinka, J., Bareš, M., et al. (2025) Response Prediction of Antidepressants: Using Graph Theory Tools for Brain Network Connectivity Analysis. *Biomedical Signal Processing and Control*, **103**, Article ID: 107362. <https://doi.org/10.1016/j.bspc.2024.107362>
- [7] Espino-Salinas, C.H., Luna-García, H., Cepeda-Argüelles, A., Trejo-Vázquez, K., Flores-Chaires, L.A., Mercado Reyna, J., et al. (2025) Convolutional Neural Network for Depression and Schizophrenia Detection. *Diagnostics*, **15**, Article 319. <https://doi.org/10.3390/diagnostics15030319>
- [8] Huang, Y., Zhang, J., He, K., Mo, X., Yu, R., Min, J., et al. (2024) Innovative Neuroimaging Biomarker Distinction of Major Depressive Disorder and Bipolar Disorder through Structural Connectome Analysis and Machine Learning Models. *Diagnostics*, **14**, Article 389. <https://doi.org/10.3390/diagnostics14040389>
- [9] Huang, Z., Wang, Q., Lei, S., Zhang, W., Huang, Y., Zhang, C., et al. (2024) Development and Validation of the Risk Score for Estimating Suicide Attempt in Patients with Major Depressive Disorder. *Social Psychiatry and Psychiatric Epidemiology*, **59**, 1029-1037. <https://doi.org/10.1007/s00127-023-02572-3>
- [10] Oğur, N.B., Çeken, C., Oğur, Y.S., Yuvaci, H.U., Yazici, A.B. and Yazici, E. (2023) Development of an Artificial Intelligence-Supported Hybrid Data Management Platform for Monitoring Depression and Anxiety Symptoms in the Perinatal Period: Pilot-Scale Study. *IEEE Access*, **11**, 31456-31466. <https://doi.org/10.1109/access.2023.3262467>
- [11] Liang, Y., Gu, X., Shi, Y., Fang, Y., Wu, Z. and Li, X. (2025) Electrophysiological Biomarkers Based on CISANET Characterize Illness Severity and Suicidal Ideation among Patients with Major Depressive Disorder. *Medical & Biological Engineering & Computing*, **63**, 1731-1748. <https://doi.org/10.1007/s11517-024-03279-6>
- [12] Sato, S., Hiratsuka, T., Hasegawa, K., Watanabe, K., Obara, Y., Kariya, N., et al. (2023) Screening for Major Depressive Disorder Using a Wearable Ultra-Short-Term HRV Monitor and Signal Quality Indices. *Sensors*, **23**, Article 3867. <https://doi.org/10.3390/s23083867>
- [13] Price, G.D., Heinz, M.V., Song, S.H., Nemesure, M.D. and Jacobson, N.C. (2023) Using Digital Phenotyping to Capture Depression Symptom Variability: Detecting Naturalistic Variability in Depression Symptoms across One Year Using Passively Collected Wearable Movement and Sleep Data. *Translational Psychiatry*, **13**, Article No. 381. <https://doi.org/10.1038/s41398-023-02669-y>
- [14] Price, G.D., Heinz, M.V., Collins, A.C. and Jacobson, N.C. (2024) Detecting Major Depressive Disorder Presence Using Passively-Collected Wearable Movement Data in a Nationally-Representative Sample. *Psychiatry Research*, **332**, Article ID: 115693. <https://doi.org/10.1016/j.psychres.2023.115693>
- [15] Helmy, A., Nassar, R. and Ramdan, N. (2024) Depression Detection for Twitter Users Using Sentiment Analysis in English and Arabic Tweets. *Artificial Intelligence in Medicine*, **147**, Article ID: 102716. <https://doi.org/10.1016/j.artmed.2023.102716>

-
- [16] Glavin, D., Grua, E.M., Nakamura, C.A., Scazufca, M., Ribeiro dos Santos, E., Wong, G.H.Y., *et al.* (2023) Patient Health Questionnaire-9 Item Pairing Predictiveness for Prescreening Depressive Symptomatology: Machine Learning Analysis. *JMIR Mental Health*, **10**, e48444. <https://doi.org/10.2196/48444>
- [17] Arteaga, A., Tong, X., Zhao, K., Carlisle, N.B., Oathes, D.J., Fonzo, G.A., *et al.* (2025) Multiband EEG Signatures Decoded Using Machine Learning for Predicting RTMs Treatment Response in MDD. *Journal of Affective Disorders*, **388**, Article ID: 119483. <https://doi.org/10.1016/j.jad.2025.119483>
- [18] Zhukovsky, P., Trivedi, M.H., Weissman, M., Parsey, R., Kennedy, S. and Pizzagalli, D.A. (2025) Generalizability of Treatment Outcome Prediction across Antidepressant Treatment Trials in Depression. *JAMA Network Open*, **8**, e251310. <https://doi.org/10.1001/jamanetworkopen.2025.1310>
- [19] Ali, S., Akhlaq, F., Imran, A.S., Kastrati, Z., Daudpota, S.M. and Moosa, M. (2023) The Enlightening Role of Explainable Artificial Intelligence in Medical & Healthcare Domains: A Systematic Literature Review. *Computers in Biology and Medicine*, **166**, Article ID: 107555. <https://doi.org/10.1016/j.combiomed.2023.107555>
- [20] Dang, V.N., Cascarano, A., Mulder, R.H., Cecil, C., Zuluaga, M.A., Hernández-González, J., *et al.* (2024) Fairness and Bias Correction in Machine Learning for Depression Prediction across Four Study Populations. *Scientific Reports*, **14**, Article No. 7848. <https://doi.org/10.1038/s41598-024-58427-7>
- [21] Gunlicks-Stoessel, M., Liu, Y., Parkhill, C., Morrell, N., Choy-Brown, M., Mehus, C., *et al.* (2024) Adolescent, Parent, and Provider Attitudes toward a Machine Learning Based Clinical Decision Support System for Selecting Treatment for Youth Depression. *BMC Medical Informatics and Decision Making*, **24**, Article No. 4. <https://doi.org/10.1186/s12911-023-02410-1>
- [22] Centers for Disease Control and Prevention (2024) Youth Risk Behavior Survey Data Summary & Trends Report: 2013-2023. U.S. Department of Health and Human Services. <https://www.cdc.gov/yrebs/dstr/index.html>
- [23] Mamun, M.A., Al-Mamun, F., Hasan, M.E., Jitu, M.H.I., Limon, M.H., Mostofa, N.B., *et al.* (2025) Predictive Modeling of Comorbid Depression and Anxiety Symptoms among Prospective University Students: A Gis-Based and Machine Learning Study. *Psychological Reports*. <https://doi.org/10.1177/00332941251358203>