DOI：10.19789/j.1004-9398.2026.04.008　　**Open Access**
文献引用：侯慷怡，刘铁，张瀚丹，等．负性视觉注意偏差在抑郁症诊疗中的作用机制与研究进展[J]．首都师范大学学报（自然科学版），2026，47（4）：70-84. Hou Kangyi，Liu Tie，Zhang Handan，et al. The mechanism and research progress of negative visual attention bias in the diagnosis and treatment of depression[J]. Journal of Capital Normal University（Natural Science Edition），2026，47（4）：70-84.

负性视觉注意偏差在抑郁症诊疗中的作用机制与研究进展*

侯慷怡，刘　铁**，张瀚丹，尚媛园，丁　辉，邵珠宏

（首都师范大学信息工程学院，北京　100048）

摘要：负性视觉注意偏差（NVAB）作为抑郁症的核心病理特征，其精准评估与干预对于抑郁症的诊疗具有关键意义，相关研究已成为抑郁症认知神经科学领域的前沿热点。本文聚焦NVAB作为抑郁症关键病理靶点的诊疗价值，系统梳理近3年人工智能技术驱动下该研究领域的范式革新、核心进展与现存挑战。首先概述NVAB的基本概念及其在抑郁症病理机制中的核心地位。继而重点聚焦人工智能（AI）引领的神经机制的动态建模、多模态AI评估技术以及AI辅助精准干预策略三大突破性方向的创新成果。特别深入分析当前AI驱动研究面临的技术局限性与标准化难题。最后，文章展望构建融合“动态脑网络-多组学-数字表型”多维数据的闭环精准诊疗体系等未来发展方向。本文通过综述现有研究，旨在为深化NVAB的神经机制理解及推动抑郁症精准诊疗的临床转化提供兼具理论深度与技术前沿的参考。

关键词：负性视觉注意偏差；抑郁症；人工智能；计算神经科学
中图分类号：TP391.4　　**文献标志码**：A

The mechanism and research progress of negative visual attention bias in the diagnosis and treatment of depression*

Hou Kangyi，Liu Tie**，Zhang Handan，Shang Yuanyuan，Ding Hui，Shao Zhuhong

（Information Engineering College，Capital Normal University，Beijing　100048）

Abstract：Negative visual attention bias，a core pathological feature of depression，is crucial for its diagnosis and treatment. Related research has become a cutting-edge focus in the cognitive neuroscience of depression. This article focuses on the diagnostic and therapeutic value of negative visual attention bias as a key pathological target in depression，systematically reviewing the paradigm shifts，key advances，and current challenges in this research field driven by artificial intelligence（AI）over the past three years. First，we outline the basic concepts of negative visual attention bias and its central role in the pathogenesis of depression. Next，we focus on three breakthrough directions driven by AI：dynamic modeling of neural mechanisms，multimodal AI assessment techniques，and innovative AI-assisted precision intervention strategies. We also provide an in-depth analysis of the technical

收稿日期：2025-06-26
*西安交通大学人机混合增强智能全国重点实验室开放课题（HMHAI-202407）；国家自然科学基金面上项目（62476178）；北京市自然科学基金面上项目（4242034）
**通信作者：tliu@cnu.edu.cn

limitations and standardization challenges currently facing AI-driven research. Finally, we explore future developments, such as the development of closed-loop precision diagnosis and treatment systems integrating multidimensional data from dynamic brain networks, multi-omics, and digital phenotyping. This review of existing research aims to provide both theoretically insightful and technologically cutting-edge insights for deepening our understanding of the neural mechanisms of negative visual attention bias and promoting the clinical translation of precision diagnosis and treatment for depression.

Keywords: negative visual attention bias; depression; artificial intelligence; computational neuroscience

CLC: TP391.4 **DC**: A

0 引 言

抑郁症是一种普遍存在的严重精神健康问题,全球范围内约16%的人群在一生中会经历抑郁发作[1]。该疾病不仅具有显著的复发倾向,更会导致个体认知功能损伤、社会功能衰退及长期心理痛苦,对公共卫生构成重大挑战[2-3]。

负性视觉注意偏差(negative visual attention bias, NVAB)作为抑郁症核心病理特征之一,特指个体在视觉通道下对负性刺激如悲伤面孔、威胁性场景表现出的优先注意与持续性固着。大量实证研究表明,抑郁症患者在面对情绪刺激时,往往对消极信息表现出过度关注和持续加工的倾向[4-6]。经典认知理论如Beck的三元组模型[7]强调,抑郁症患者在信息加工过程中,不仅对负性内容表现出选择性注意增强,同时对正性信息的关注受到抑制,从而加剧了负面情绪体验[8-9]。NVAB作为这一理论的重要实证支撑,其神经基础涉及视觉皮层-丘脑-边缘系统的异常交互[10-11]。但对其动态神经机制的精准解析及临床干预的靶向优化,长期受限于传统研究手段的固有缺陷。

传统研究主要依赖行为学范式[9,12]与静态神经影像技术,虽能捕捉基础注意模式,但受限于时间分辨率或生态效度[5],无法精准捕捉NVAB在自然场景中的动态特征及个体神经环路的异质性差异。近年来,随着人工智能(artificial intelligence, AI)技术的蓬勃发展,其在NVAB研究领域取得了突破性的应用成果[13],为该领域带来了全新的研究范式。回顾NVAB的研究历程,其经历了3个重要的范式革新阶段。NVAB研究发展历程各研究阶段对比如下表1所示。

在早期行为学探索期(1990—2010年),研究者通过点探测任务与眼动追踪技术,首次发现抑郁症患者存在对负性刺激的持续性注意固着现象[5,14],并提出“注意脱离困难”假说[9]。这一阶段的研究成果为后续深入探索奠定了坚实的行为学基础。然而,受限于当时的技术手段,尚未能揭示其深层的神经机制。

随着功能性磁共振成像(functional magnetic resonance imaging, fMRI)[15]与脑电图(electroencephalogram, EEG)技术的逐渐普及,研究进入了神经机制解析期(2010—2020年),该时期开启了多模态神经影像研究的新时代。通过对视觉皮层-边缘系统功能连接的深入分析,研究人员发现前额叶-杏仁核的异常耦合是NVAB的核心神经基础[11,16]。与此同时,突显网络(salience network, SN)与默认模式网络(default mode network, DMN)之间的动态交互被证实构成了负性信息反刍的神经环路[11,17-18],这一发现为理解“注意固着-情绪失控”的恶性循环提供了坚实的生物学依据,使研究者得以从神经层面深入剖析NVAB在抑郁症发展中的作用机制。

进入AI驱动革新期(2020年至今),深度学习技术蓬勃发展实现了NVAB研究的质性飞跃。基于

表1 各研究阶段对比

Table 1 comparison of research stages

研究阶段	时间	核心贡献	局限性/挑战
早期行为学探索期	1990—2010年	确立NVAB行为现象,奠定行为学研究基础	依赖静态行为数据,未能揭示深层神经机制
神经机制解析期	2010—2020年	从行为描述转向神经机制解析,识别关键脑区与环路	聚焦静态群体分析,忽视动态特征与个体差异
AI驱动革新期	2020年至今	从群体共性研究转向个体动态建模,推动精准干预临床转化	面临数据标准化、模型可解释性、跨文化适应等多重挑战

注:NVAB指负性视觉注意偏差;AI指人工智能。

Transformer和卷积神经网络(convolutional neural network,CNN)的多模态模型凭借强大的动态时空特征提取能力,实现了对注视模式的毫秒级解析[19-20]。举例来说,基于Transformer架构的眼动轨迹分析模型[21]实现了对抑郁症患者动态凝视模式的深度时空建模,分类准确率高达91.95%。该模型能够精准捕捉传统行为学指标难以反映的毫秒级注视异常,显著提升NVAB评估的敏感性与特异性,为个体化分型诊断提供了量化依据。这些进展标志着NVAB研究从静态描述正式迈入动态预测阶段,为精准干预奠定了坚实的技术基础。

本文系统梳理近3年AI技术在NVAB研究中的创新突破。具体而言,将重点聚焦三大核心方向:一是阐述AI如何推动NVAB神经机制研究从静态脑区描述向动态环路建模的转型;二是分析AI驱动的多模态评估技术如何突破传统方法的局限,实现高时空分辨率与个体化解析;三是探讨AI如何赋能精准干预策略,促成从经验性治疗向视觉特异性闭环调控的跨越。通过深入剖析AI在机制解析、评估革新与干预优化中的应用价值,并探讨当前面临的数据标准化、模型可解释性、伦理隐私及临床转化等挑战,旨在为深化NVAB的神经机制认知、推动抑郁症精准诊疗的临床转化提供兼具理论深度与技术前沿性的参考。

1 核心神经机制:从静态描述到AI驱动的动态建模

早期NVAB研究主要聚焦于描述大脑局部脑区的静态功能异常,对神经活动的时序动态性与网络交互性关注不足。近年来借助人工智能技术,研究者开始实现对NVAB神经环路机制的动态解析与精准建模,为抑郁症的精准靶向干预开辟了全新方向。

1.1 传统神经机制:从视觉初加工到情绪调控失衡

在传统NVAB神经机制的研究中,“早期视觉编码异常”与“晚期情绪调控失衡”的2个阶段协同作用,共同构成了负性信息优先加工与持续固着的神经基础。分阶段解析的NVAB传统神经机制如表2所示,该表清晰呈现了NVAB在不同阶段的神经机制特征,其中早期视觉编码阶段的异常激活是NVAB发生的起始环节,相关神经影像发现为NVAB的客观评估提供了关键标志物。临床研究显示,当人眼接收负性视觉刺激如悲伤面孔的200 ms内,作为视觉信息处理起始区域的初级视觉皮层(primary visual cortex,V1)会出现异常激活。fMRI数据证实,抑郁症患者V1区的神经活动强度显著高于健康人群,这种异常激活直接导致抑郁症患者对悲伤面孔的凝视时间延长30%~50%,且在难治性抑郁症患者中表现得更为突出[4,22]。因此V1区激活强度可以作为NVAB的神经影像标志物,辅助临床鉴别诊断[10]。

在电生理层面,事件相关电位(event-related potentials,ERP)中的N170成分是反映面孔早期加工的关键指标,EEG检测表明,抑郁症患者的N170成分显著减弱[23-24]。这一现象表明患者虽能快速注意到负性面孔,但大脑对这类视觉信息的初步加工处理存在本质缺陷。进一步研究证实,N170成分减弱程度与NVAB程度呈正相关,可作为抑郁症早期筛查的电生理指标[25]。

丘脑后外侧核(lateral posterior nucleus,LP)作为视觉信号向情绪脑区传递的关键枢纽,在抑郁症患者中表现为过度激活。Wu等[10]通过动物实验证实,抑制LP核的异常兴奋可显著减少小鼠对负性刺激的关注时间,提示LP核的过度活跃可能放大了负性信号向情绪脑区的传递效率。这一结果使LP核成为深部脑刺激(deep brain stimulation,DBS)等神经调控技术的潜在靶点。

表2 NVAB的传统神经机制:分阶段解析

Table 2 traditional neural mechanisms of NVAB: stage-by-stage analysis

阶段	涉及脑区/神经结构	检测技术/实验	神经机制
早期视觉编码异常	初级视觉皮层	fMRI、EEG	负性刺激快速激活V1区,导致早期视觉处理偏差
	丘脑后外侧核	fMRI、动物实验	视觉信号向情绪脑区的传递异常放大
晚期情绪调控失衡	背外侧前额叶-杏仁核	fMRI	认知控制与情绪反应的失衡
	杏仁核、5-HTTLPR基因	fMRI、基因分型	情绪脑区过度反应与遗传易感性
两阶段协同作用	视觉皮层-丘脑-边缘系统环路	多模态神经影像	早期“快速捕获”与晚期“脱离困难”相互强化

注:fMRI指功能性磁共振成像;EEG指脑电图;V1指初级视觉皮层;5-HTTLPR是5-羟色胺转运体基因中的一个启动子连锁多态性区域,主要负责基因的转录活性调控。

如果说早期视觉编码异常为负性信息的优先加工打开了通道，那么晚期情绪调控失衡则进一步巩固了这种视觉注意偏差。负责抑制杏仁核过度反应的背外侧前额叶皮层（dorsolateral prefrontal cortex，DLPFC）与杏仁核之间的功能连接在抑郁症患者中显著减弱[26]。fMRI数据显示，这种连接强度与患者对负性刺激的凝视时间呈负相关。即连接越弱，负性注意固着越明显。经颅直流电刺激（transcranial direct current stimulation，tDCS）研究证实，靶向DLPFC的干预可有效调节杏仁核的过度反应[27]，进一步验证了该通路的调控价值。

此外，杏仁核对负性刺激的过度反应存在明确的遗传易感性。携带5-HTTLPR短等位基因的患者，其杏仁核在加工悲伤面孔时激活程度更高[28]，形成负性信息优先加工神经通路，进一步加剧患者的视觉注意偏差[29]。这2个阶段的异常相互作用，共同导致抑郁症患者对负性视觉信息的过度捕获与难以脱离，构成NVAB的核心神经机制，如图1所示。

1.2　AI驱动的动态建模：从单一脑区到环路交互

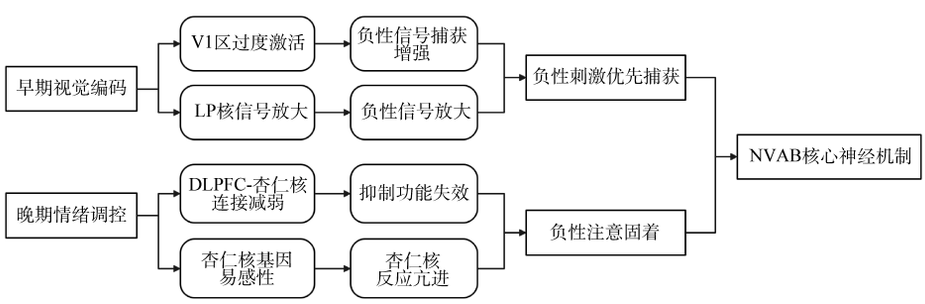
传统神经科学研究多局限于静态分析单个脑区的激活状态或简单脑区连接，如同拍摄大脑的“静态快照”，难以捕捉神经信号在毫秒级时间尺度上的动态协作过程。而AI通过整合多维度生理数据与先进算法，实现了从局部观测到全环路建模的关键突破，使NVAB的神经机制解析从静态描述转向动态精准解析。

这种动态解析能力在近期研究中得到充分体现。Zhu等[30]提出的互信息融合模型MIBFM，该模型能同时捕捉EEG的频域特征和瞳孔面积变化，通过互信息量化脑区间功能连接的动态强度，揭示了前额叶-边缘系统环路在情绪加工中的异常协作；Wu等[10]通过慢性束缚应激模型与光遗传学技术证实V1→LP单突触通路在慢性应激下因蛋白下调而导致活性降低，首次揭示了视觉皮层-丘脑环路与抑郁样行为的因果关联。

在机制模拟层面，Hassabis等[31]基于神经科学启发的强化学习算法，构建了海马-前额叶环路决策模型，成功模拟了NVAB“病理记忆”的形成过程：当大脑反复暴露于负性刺激时，LP核神经元会对这类信息过度赋值，就像给负面信息贴了高优先级的标签一样，通过强化突触连接形成顽固的神经通路，导致患者难以摆脱负面信息，这和临床中患者盯着负面信息不放的表现完全对应[25]。这种类脑模型复现了抑郁症患者的核心缺陷：对积极信息响应减弱，而对负性信息编码持续强化[1]，如同大脑被训练成了更倾向于关注负面信息的模式。

上述AI驱动的动态建模研究，已经揭示了NVAB的群体共性环路机制。然而，这些基于群体平均的动态模型尚无法解释临床中显著的个体差异：为何部分患者对注意力偏差修正（attention bias modification，ABM）治疗敏感，而另一部分却依赖药物调控杏仁核反应性，这一矛盾推动研究从群体共性建模转向个体环路异质性解析。

抑郁症患者NVAB的神经环路异质性解析，本质是通过脑网络功能结构差异阐释NVAB的个体机制，而分型是异质性解析的具体体现。Yang等[32]基于眼动追踪数据的AI聚类算法挖掘特定眼动模式，认为抑郁症患者对负性视觉刺激的凝视模式存在显著异质性，为抑郁症诊断分型提供了量化依据。Sun等[33]则利用功能连接强度的规范模型，通过AI算法识别出2种可重复的神经生理亚型。其中：亚型1表现为DMN、边缘系统及皮层下区域的功能连接正偏差，以及感觉运动网络和注意力网络的功能连接负偏差；亚型2表现出中等但相反的偏差模式。这一研究有助于了解抑郁症临床异质性背后的神经生物学机制，对开发个性化治疗具有重



注：LP指丘脑后外侧核；DLPFC指背外侧前额叶皮层；NVAB指负性视觉注意偏差。

图1　NVAB核心神经机制

Figure 1　NVAB core neural mechanism

要意义。类似地,Chen等[34]基于大规模脑结构影像数据,利用数据驱动的智能算法,让AI自主从影像中寻找规律,同样揭示了抑郁症的3种神经生理亚型的临床症状和遗传表达差异,共同为抑郁症的精准分型提供了多维度证据。其中前扣带回亚型的患者显著存在注意力控制异常,这也解释了为何这类患者的NVAB最突出。

AI驱动的NVAB神经机制解析的标志性成果如表3所示。AI驱动的动态建模技术通过多模态时空融合、突触可塑性机制模拟与环路异质性解析,逐步构建起NVAB在"动态神经交互—突触编码异常—个体亚型分化"层面的关联机制图谱。这些进展不仅突破了传统静态研究的局限,更通过精准定位V1→LP核心环路的动态异常[10],为靶向神经调控如DBS、经颅磁刺激(transcranial magnetic stimulation,TMS)等神经调控技术提供了个体化靶点。未来,结合可解释AI等技术,有望开发出因人而异的精准干预方案,推动抑郁症治疗从经验性干预策略向神经机制导向的个体化精准医疗转型,为突破现有治疗瓶颈提供了全新路径。

2 多模态AI评估技术:从视觉注意捕获到临床精准应用

评估技术的核心价值在于通过标准化数据采集与解析,实现对精神病理特征的量化表征。在抑郁症研究领域,NVAB的评估体系正经历着一场深刻的变革,从早期单纯依赖行为观察的单一模态评估,逐步迈向多模态数据融合的新时代。传统的评估方法由于仅聚焦于单一维度的信息,在全面捕捉NVAB动态神经机制与个体异质性方面显得力不从心。而AI驱动的多模态技术通过整合眼动、脑电、功能影像等多维数据,突破了传统方法的固有局限,为抑郁症的精准诊断、疗效预测及干预方案优化提供了关键数据支撑。

2.1 传统视觉评估方法的瓶颈

长期以来,NVAB评估主要依赖行为学范式与神经影像技术,但2种方法均面临静态场景局限与时空解析能力不足的核心困境,直接制约了临床决策的精准性。传统视觉评估方法的瓶颈对比列于表4。

2.1.1 行为学范式:静态指标与动态现实的割裂

行为学范式通过量化个体对情绪刺激的反应模式,构建了NVAB的基础行为评估体系。当前主流方法主要分为2类:基于反应时的定向偏差检测(以探测任务为例)与基于自然观察的凝视模式分析(以自由观看任务为例)。然而这些范式普遍存在静态指标捕捉与动态注意加工脱节的核心问题,难以真实反映自然场景中的注意特征。

点探测任务(dot-probe task)[35]作为传统行为学

表3 AI驱动的NVAB神经机制解析的标志性成果

Table 3 landmark achievements in AI-driven analysis of the neural mechanisms of NVAB

层次维度	AI模型/方法	核心技术	核心发现
时空维度	互信息融合模型[30]	同步整合EEG的频域特征与瞳孔面积变化	前额叶-边缘系统环路的异常协作
分子-环路维度	强化学习算法[31]	模拟NVAB的计算机制	丘脑LP核神经元对负性刺激的过度赋值机制
	慢性束缚应激模型[10]	光遗传学技术	V1→LP单突触通路的活性降低与慢性应激下抑郁样行为的因果关联
临床-异质性维度	数据驱动的智能算法[34]	基于大规模脑结构影像的无监督聚类与亚型识别	抑郁症3种神经生理亚型的临床症状与遗传表达差异
	功能连接规范模型[33]	量化脑区连接实时变化	基于DMN、边缘系统连接异常的2种神经亚型分类

注:DMN指默认模式网络。

表4 传统视觉评估方法的瓶颈对比

Table 4 bottleneck comparison of traditional visual evaluation methods

评估方法	数据模态	时间分辨率/空间分辨率	核心局限
点探测任务	反应时	ms/无	仅适用于基础研究,难以指导复杂干预
自由观看任务	凝视时间、注视次数	s/无	依赖群体平均统计,忽视个体差异
fMRI	BOLD信号	s/mm	设备成本高、检查时间长,无法作为常规筛查
EEG/ERP	脑电信号	ms/cm	空间分辨率低、靶点选择盲目,治疗应答率低[33]

注:BOLD指血氧水平依赖;ERP指事件相关电位。

评估中的经典手段，一直以来被用于通过测量个体对情绪刺激位置的反应时差异，来揭示注意力在空间上的分配偏差[9]。众多经典研究已经证实，抑郁症患者在面对像悲伤面孔这类典型的负性情绪刺激源时，其探测反应时间会显著缩短，这一现象充分表明患者的注意力资源会优先分配给负性信息[6]。然而该范式存在着明显的局限。点探测任务通过反应时差异识别NVAB，但其高度依赖实验室控制的静态图像刺激，导致效应稳定性受刺激参数影响极大[22]：当刺激持续时间≥1 000 ms时，患者明确表现出对负性信息的持续性固着；而当刺激以短时500 ms呈现时，仅能观察到微弱的定向效应[5]。更关键的是，该范式仅适用于实验室静态图像场景，无法预测真实社交中的注意力固着特征[5,36]，临床转化价值有限。

点探测任务的场景局限性，促使研究者转向更贴近自然视觉加工的评估范式。自由观看任务（free-viewing task）[37-38]通过记录个体在自然场景下的凝视时间、注视次数等指标，来提升评估的生态效度。研究表明抑郁症患者相较于健康人在观看情绪面孔时，对悲伤面孔的注视停留时间显著增长[12]。然而该范式同样存在缺陷，其过度依赖静态统计，例如平均凝视时间等指标，完全忽视了个体之间的差异以及任务本身的动态性。例如，反刍思维水平高的患者在自由观看时，数据变异性会显著增大[37]，且任务结果会受到任务设计如口罩遮挡等的显著影响[36]。此外，该范式无法区分抑郁症神经生理亚型[33]，直接导致临床干预方案陷入“一刀切”的困境。

2.1.2　神经影像技术：时空分辨率的临床应用困境

随着神经科学对脑功能动态机制的探索需求，神经影像技术因其能直接关联脑活动与行为特征，一度被视为突破行为学静态困境的关键手段。fMRI与EEG/ERP分别从“结构-功能关联”和“实时电生理动态”视角切入，试图解析NVAB的神经基础。但其自身亦面临时空分辨率的固有矛盾，难以满足临床需求。

fMRI凭借其毫米级空间分辨率，能够清晰地揭示静息态下抑郁症患者SN与DMN之间的异常连接，为抑郁症患者负性信息持续反刍的神经机制提供了关键证据[11,17-18]。但其秒级的时间分辨率难以捕捉杏仁核-前额叶环路的毫秒级动态交互。此外，设备昂贵、检测耗时的特点都使其难以作为常规筛查的工具。EEG/ERP[38]虽能捕捉毫秒级神经电活动[39]，但其空间定位误差>1 cm，无法精准指导神经调控靶点选择[40]。即便结合EEG与眼动数据的机器学习模型可以将分类准确率提升至89%[21]，但EEG较低的空间分辨率仍使得单模态分析难以全面、深入地解析大脑活动[20]。这些挑战不仅凸显了时空分辨率平衡在神经机制研究中的重要性，更预示着多模态数据融合与AI算法革新的必然趋势。

2.2　AI驱动的多模态融合评估技术革新

传统视觉评估方法对NVAB的解析长期受限于静态场景与单一模态的割裂。而AI通过整合眼动数据、EEG、fMRI及基因组等多源数据，构建了覆盖实时诊断、精准分型、干预指导的多维度评估体系，彻底改变了这一局面。其与传统视觉评估方法的性能差异可通过多维度对比明确体现如表5所示。

2.2.1　时空动态评估：从静态单模态到多模态技术整合

传统NVAB评估依赖反应时等静态指标，难以捕捉NVAB的动态加工过程。AI技术通过整合多模态时空数据，实现了从单点测量到动态轨迹解析的突破，为NVAB的临床量化提供了全新工具。Zhu等[41]提出基于内容的集成方法，将EEG与眼动数据动态融合，通过加权集成模型提升抑郁症检测准确率，为多模态融合提供新思路；Ding等[42]的研究为多模态数据在抑郁症诊断中的协同价值提供了实证支持，该研究招募了348名受试者，包括144名重度抑郁症患者与204名健康对照，通过整合EEG、

表5　传统视觉评估方法与AI驱动的多模态评估方法的性能对比

Table 5　performance comparison between traditional visual evaluation methods and AI-driven multimodal evaluation methods

评估维度	传统方法	AI多模态方法
时空分辨率	fMRI（秒级）+EEG（厘米级）	fMRI-EEG-眼动融合（毫秒级+毫米级）
动态适应性	静态实验室刺激	实时眼动轨迹驱动刺激调整
个体化分型	群体均值统计	多模态特征聚类的亚型特异性模型
生态效度	标准实验室场景	VR沉浸式场景+生理信号闭环

注：VR指虚拟现实。

眼动追踪和皮肤电导3种生理模态数据,采用机器学习算法构建分类模型,最终实现准确率达79.63%的抑郁症分类,对比单一模态性能可见,EEG单独建模的最高准确率为72.41%,眼动追踪与皮肤电导单独建模的最高准确率分别为65.30%和67.50%,多模态融合后的性能显著优于任一单一模态,证实多模态数据通过互补信息显著优化了诊断性能;此外,Zhu等[30]提出互信息融合模型MIBFM,融合EEG与瞳孔面积信号识别轻度抑郁症,为早期检测提供多模态整合策略;Li等[21]通过Transformer模型融合眼动轨迹的时空特征实现抑郁症检测,准确率高达91.95%,充分体现了动态追踪的优势;Yang等[19]开发了专门针对眼动数据的三流卷积神经网络(three-stream convolutional neural network,TSCNN),可以同时处理空间流提取眼动静态特征、时间流通过快慢帧速提取动态时序特征、范式流提取实验刺激的语义先验知识3种关键信息,通过这3个方面信息的同步分析,模型能更全面地判断是否存在NVAB,最终抑郁症检测准确率达到79.3%。

值得注意的是,多模态融合的核心前提是突破“数据异质性壁垒”,而跨模态特征对齐正是实现这一突破的关键技术环节,也是当前多模态整合的主要瓶颈。不同模态数据的本质属性差异极大:眼动数据是毫秒级时序轨迹,而EEG是电生理频域信号。二者的特征维度、物理含义与采集尺度完全不同,直接融合会导致模态间的语义错位,严重影响模型性能。针对这一问题,Jia等[43]提出的多头注意力-图卷积视觉Transformer模型提供了典型解决方案。该模型通过多头注意力机制定位EEG与语音信号中的关键关联特征,再借助图卷积网络建模脑电通道的空间关联,最终实现2种异质模态特征的语义对齐与协同分析。实验显示该方法在MODMA数据集上实现89.03%的准确率,证实跨模态特征对齐对复杂视觉注意模式解析的关键作用。

在跨模态协同方面,这类技术进一步推动了多源数据的深度整合。上述Jia等[43]的研究已充分证明,通过精准对齐不同模态的病理关联特征,可显著提升模型对NVAB的评估精度。这些研究从多模态特征融合、时空动态建模、跨通道语义协同等维度,共同证明AI技术通过整合眼动、EEG、语音、视频[44-45]等多源数据,突破了传统方法的静态单模态局限,为抑郁症NVAB的精准评估提供了兼具时效性与泛化性的技术范式。

在多模态评估技术的临床落地过程中,眼动数据的跨设备兼容性与数据隐私保护是两大核心挑战。传统眼动仪如Tobii与SMI的采样率、精度存在显著差异,导致不同设备采集的数据分布不一致,直接影响了AI模型的泛化能力。针对这一痛点,Xu等[46]提出的多视图对抗判别器通过分离非因果因素,在目标检测任务中实现域不变特征提取,缓解域偏移问题;Li等[20]提出的基于交叉注意的扩张因果CNN通过域鉴别器生成域不变特征,解决了脑电信号的个体间差异问题,为跨受试者的脑电模型泛化提供了方法参考;MacInnes等[47]开发的自动化流程实现了眼动数据的坐标系统一,并通过多设备校准精度对比,建立了基于固定参考坐标系的标准化评估框架,其方法学为后续眼动数据的跨设备特征对齐提供了量化依据;Birawo与Kasprowski[48]对眼动检测算法进行了系统评估,证实深度学习模型对高采样率设备数据的鲁棒性更强,为不同设备的眼动数据预处理提供了技术指导。

与此同时,联邦学习技术的引入进一步突破了数据隐私壁垒。联邦学习作为典型的分布式协作范式,通过各机构本地训练、中央服务器聚合模型参数的方式,从根本上规避了原始敏感数据的跨机构共享,有效降低隐私泄露风险。该技术的可行性已在眼科成像领域得到验证,成功实现了跨中心隐私保护建模[49],为精神疾病领域的多中心数据协作提供了重要参考。而Xu等[50]则通过DEAP和SEED数据集实验,证实基于联邦学习的EEG情感识别任务准确率可达90.74%,充分证明该技术在神经电生理数据跨中心整合中的可靠性;Li等[51]提出的Nimbus框架通过优化Transformer网络的矩阵乘法协议,在保护隐私的前提下实现2.7~4.7倍的推理加速,推动跨中心文化特异性数据整合。基于上述基础,未来若能进一步完善多模态数据标准化协议,有望将联邦学习的应用场景拓展至眼动-EEG-基因数据的跨模态整合领域,通过全球多中心协作构建样本量超10万的跨文化泛化模型,实现更广泛的跨中心隐私保护建模。这种技术突破将确保AI模型可在不同硬件环境和文化背景中稳定运行,为多中心NVAB临床研究提供了可复制、标准化的工具支撑,推动NVAB评估从单中心实验迈向全球协同的抑郁症精准医疗新阶段。

2.2.2　可解释性技术：多模态模型的透明化解析

在AI技术应用于临床诊断的过程中，模型的“黑箱”特性长期制约着临床信任度与机制解析深度。尽管机器学习可通过多模态数据提升诊断精度，但缺乏透明性的决策过程难以让医生理解其逻辑，更无法转化为可落地的神经机制洞察。为突破这一瓶颈，近年来AI模型逐步引入可解释性技术（explainable artificial intelligence，XAI），如Grad-CAM、SHAP等，将模型的抽象决策转化为人类可理解的可视化证据。例如通过Grad-CAM技术[52]分析患者在自由观看情绪面孔时的眼动数据，其生成的注意力热图[53]清晰显示抑郁症患者对悲伤面孔的眼周区域注视权重比健康组高，而对嘴角等积极特征的权重低。这种可解释性技术使临床医生能够直观理解模型决策逻辑，例如杏仁核激活增强导致注视固着的神经机制与凝视悲伤面孔时间延长的行为证据的对应关系[54]。随着可解释性技术的引入，标志着AI在精神疾病诊断中从效率优先向可信可控的关键转型，临床医生得以直观看到模型如何通过捕捉眼动偏差做出相应诊断。这种可视化的决策解析不仅增强了临床对AI的信任，更将为靶向神经调控、认知行为干预等个性化治疗策略提供精准的干预靶点。

2.3　技术局限性与标准化挑战

尽管多模态AI评估技术在NVAB研究领域已取得阶段性进展，极大地革新了传统研究范式，但立足近3年前沿研究成果深入剖析，该技术体系仍面临许多挑战。

2.3.1　跨模态数据标准化与生态效度的平衡难题

自由观看范式等自然场景评估方式，凭借对真实生活情境的高度模拟，大幅提升了研究结果的生态效度，使结论能更精准地反映个体在日常环境中NVAB的自然状态。然而，这类自然场景评估因缺乏统一、严谨且普适的实验控制标准，致使不同研究产出的数据在关键维度上缺乏可比性，成为制约研究成果整合与推广的核心障碍。具体而言，不同实验室开展自由观看实验时，在情绪刺激材料的挑选、刺激呈现参数以及眼动仪核心参数等方面均存在显著差异，这些不一致因素极易引入难以量化的系统偏差，直接干扰研究结果的准确性与可靠性。

尽管Bourke等[25]为调和生态效度与实验控制间的矛盾，提出“情绪面孔矩阵+EEG”的标准化流程，试图通过固定刺激呈现时长和同步记录神经电活动，为数据采集与分析提供相对稳定的框架。但在实际推广中，由于各实验室在情绪刺激材料的选用上难以达成一致，且眼动仪设备型号与性能的异质性难以消除，最终导致该流程未能从根本上解决数据标准化难题。

近期研究聚焦于构建跨中心的“数据采集-特征提取”标准化协议。建议统一采用NimStim等[55]国际通用刺激集，保证不同研究在刺激材料源头的一致性，同时深度挖掘不同设备数据间的潜在共性与差异，将数据映射至统一特征空间，削弱设备异质性干扰。但目前这些策略尚处探索验证阶段，距离在大规模跨中心研究中广泛应用、成为领域通用标准，仍需攻克诸多技术与协作难题。

2.3.2　模型泛化性瓶颈有待突破

现有AI模型在跨文化适应性层面暴露出严重短板，尤其在解析非西方人群的NVAB时，模型性能大打折扣。不同文化背景会孕育出各异的认知模式与情感反应倾向，以东亚文化为例，该文化环境中普遍存在的“社交评价焦虑”，致使个体面对负性刺激时，呈现出“快速定向-抑制性脱离”的注意模式[56]，与西方研究中常见的“持续固着”模式截然不同[35]。这种文化特异性的注意模式差异，使得基于西方人群数据训练的AI模型，难以精准适配非西方人群，限制了模型在全球范围的推广应用。

与此同时，模型泛化性还面临小样本临床数据与高维特征的矛盾挑战：高维眼动特征在小样本临床数据情境下，极易诱发模型过拟合问题，而传统机器学习算法在捕捉跨模态动态关联时能力有限，无法有效挖掘数据深层信息，最终导致模型泛化能力受限，难以在新样本、新场景中保持稳定性能。尽管联邦学习技术通过跨中心数据协作，在一定程度上拓宽了模型泛化边界[49]。但如何在保护数据隐私的前提下，有效整合不同文化背景下的特异性数据，仍是未解决的核心技术难题。部分最新研究尝试将迁移学习与联邦学习有机结合，提升其对特定文化背景数据的适应性[57]。但在实践过程中，源数据与目标数据分布差异显著、模型微调策略难以精准优化等问题接踵而至，严重制约了该方法的实际应用效果。

2.3.3　临床应用障碍重重

首先是隐私安全风险。眼动轨迹与神经影像

数据蕴含个体高度敏感的生理特征信息,一旦发生泄露,将对个人隐私造成不可逆的严重侵害。如何实现数据可用不可见,成为保障数据安全、推动临床应用的核心诉求。联邦学习技术通过各参与机构在本地独立开展模型训练,为数据隐私保护开辟了一条可行路径[49]。此外,差分隐私技术也逐步融入多模态数据处理流程,通过在数据或模型输出中添加噪声,使攻击者无法从模型输出结果反向推断出个体敏感信息[58]。但在实际落地应用时,联邦学习面临模型安全聚合、通信开销过大等挑战。差分隐私则需精细权衡噪声添加量,确保既能保护隐私,又不严重损耗数据可用性与模型性能,这些技术细节均需深入研究与持续优化。

其次是计算成本难题。以性能强劲的TSCNN模型[19]为例,其复杂的网络结构对计算设备的算力提出了近乎苛刻的要求。临床应用场景中,多数医疗机构受限于有限的硬件资源,难以支撑这类复杂模型的部署与流畅运行,极大阻碍了技术从实验室走向临床实践转化的进程。

最后是患者依从性挑战[59]。长时间的眼动监测易使患者产生眼疲劳等不适感,对于本身处于低动机状态的抑郁患者而言,这种身体不适会进一步削弱其配合实验的意愿,导致数据采集过程中断、数据缺失或品质下降,严重影响数据完整性与研究结果准确性。为提升患者依从性,部分研究采取了针对性优化措施:如采用更便捷、舒适的头戴式眼动仪[47],减少设备对患者正常活动的束缚。通过精简实验流程、缩短实验时长,降低患者负担[60]。并给予患者适时反馈与激励,增强其参与积极性。但不同患者群体对这些措施的接受程度与反馈效果差异明显,仍需依据患者年龄、病情严重程度、心理状态等个体特征,量身定制个性化方案,并持续优化改进,以达到最佳数据采集效果。

3 AI辅助干预策略:从经验性治疗到视觉特异性精准调控

抑郁症干预策略旨在通过调整抑郁症患者的认知、行为或神经活动,改善其异常心理状态的一系列方法。其中,NVAB作为抑郁症核心病理特征,已被确立为关键干预靶点。当前传统干预体系主要涵盖注意力偏差修正、认知行为疗法(cognitive behavioral therapy,CBT)、传统神经调控技术、药物干预以及虚拟现实暴露疗法(virtual reality exposure therapy,VRET)等。尽管传统干预手段试图从多维度干预调控NVAB,包括注意焦点转移训练、认知控制增强等。但在精准靶向NVAB复杂动态神经机制与满足个体化干预需求方面仍存在技术瓶颈,这一局限直接导致传统干预策略普遍存在临床应答率有限及场景泛化不足等问题,因此极需向基于AI的视觉特异性精准调控模式转型,见表6。

3.1 传统干预方法的局限性

当前针对NVAB的干预手段虽已形成多维度体系,但各类方法普遍面临静态设计与动态神经机制脱节、群体化干预与个体差异冲突等挑战。传统干预方法往往基于“标准化刺激-固定反应”的刚性模型,既忽视了视觉注意加工的时序动态性、神经环路的个体异质性,也未能充分模拟真实社交场景的复杂性,最终导致干预效果在有效性、泛化性和精准性上存在根本局限。以下从行为训练、认知疗法、神经调控以及药物干预4个层面展开分析。

ABM的核心机制在于通过重复训练并引导个体将注意力从负性刺激转移至中性或正性刺激上,

表6 基于AI的NVAB精准干预策略与传统干预方法的效能对比

Table 6 comparison of the effectiveness of AI-based NVAB precision intervention strategies and traditional intervention methods

干预类型	核心局限	AI突破点	典型效应
传统ABM	静态刺激;忽视神经动态响应	元强化学习;实时调整刺激参数	场景负性凝视降低60%[61]
CBT干预	依赖主观依从性;缺乏实时神经反馈	眼动+生理指标整合实时监测;动态生成认知行为训练方案	低认知控制患者依从性提升,训练效果增强[62]
神经调控技术	静态解剖靶点;忽略个体环路动态异常	动态因果模型;指导个体化环路靶向	应答率提升至74%[63]
药物干预	起效周期长;个体差异显著	跨组学模型;指导精准用药	特定亚型患者凝视偏差改善率显著提升[64]
传统VRET	无法实时整合眼动反馈调整刺激;场景泛化性差	眼动实时驱动虚拟现实刺激调整;迁移学习优化文化场景	文化场景真实度显著提升[65]

注:ABM指注意偏向修正训练;CBT指认知行为治疗;VRET指虚拟现实暴露疗法。

进而重塑异常注意力分配模式。但该方法存在显著缺陷，ABM通常依赖静态视觉刺激，未考虑视觉系统对动态刺激的时序敏感性，导致训练效果与真实社交场景的眼动模式严重脱节[64]。更严重的是对于特定神经亚型，高频暴露悲伤面孔可能非但无效，反而通过增强杏仁核-视觉皮层连接加剧焦虑反应[66]，这也解释了为何约30%的患者对ABM无应答[62]。Richter等[67]通过元分析进一步证实，基线抑郁症状严重程度与训练次数是影响包括ABM在内的认知训练疗效的关键因素，表明标准化方案难以满足个体化需求，强调个体化认知训练的重要性。

CBT的核心逻辑是通过修正负性认知偏差和重塑适应性行为模式，打破“认知-情绪-行为”的恶性循环。但其效果高度依赖患者的主观依从性和执行能力，对于前额叶认知控制功能低下的患者，难以有效突破其固有的注意固着障碍[62]。更关键的是，CBT缺乏实时神经反馈机制，无法根据患者的脑活动动态调整训练强度与方向，难以实现精准引导与效果强化。

神经调控技术试图通过调节关键脑区活动来改善注意网络功能，但各类手段均存在靶点或作用方式的局限。重复经颅磁刺激（repetitive transcranial magnetic stimulation，rTMS）是一种通过时变磁场刺激大脑皮层特定区域的非侵入性神经调控技术。rTMS通常静态靶向DLPFC以增强自上而下的注意控制，但其忽略了视觉皮层-边缘系统的动态交互机制[11]。研究表明，当LP核放电频率>25 Hz时会显著放大负性视觉信号的传递，导致凝视固着[25]，而静态定位的rTMS无法精准干预这种动态失衡[68]。tDCS是一种通过低强度直流电调节大脑皮层兴奋性的非侵入性神经调控技术，同样面临靶点选择局限的问题，传统聚焦于DLPFC方案仅能提升约30%的治疗应答率[63]，未能充分考虑个体视觉-情绪环路连接的异常模式[27]。电休克疗法（electroconvulsive therapy，ECT）是一种通过短暂电流刺激大脑诱发全身性癫痫发作，从而快速缓解严重精神症状的神经调控技术。虽对难治性抑郁症整体有效[69]，但因其非特异性、全脑性的作用方式，伴随显著的认知副作用，无法精准靶向NVAB的特定神经机制，从而难以实现对病理性注意固着的阻断[5]。

药物干预通过调节神经递质水平间接改善情绪驱动的注意偏向，然而其起效周期漫长，通常需要2~4周，无法快速缓解NVAB相关症状。且其疗效个体差异显著，受遗传与代谢差异影响[64]，部分患者疗效甚微。更重要的是，药物无法直接干预视觉注意的动态加工过程本身，对NVAB的改善往往是间接且滞后的[12,22]。

VRET是一种结合沉浸式虚拟现实技术与传统暴露疗法的新型干预手段，能在虚拟社交场景中暴露并尝试矫正NVAB，如减少对虚拟悲伤场景的凝视等[70-71]。然而，其核心局限在于未能有效整合实时的眼动轨迹来动态调整干预参数。系统无法自动增强中性刺激的引导强度或降低负性刺激的突显性，导致训练效果难以迁移至复杂的真实社交场景，真实社交场景泛化效果下降40%[56]。此外，VR场景对文化特异性视觉刺激的模拟真实度不足，无法有效激活或训练患者相应的注意补偿机制，进一步削弱了其跨文化适用性[22]。

综上所述，传统干预方法受制于四大核心制约：一是静态刺激设计与视觉注意动态加工的机制脱节；二是靶点选择的僵化模式与神经环路个体异质性的矛盾；三是多模态神经反馈协同的技术缺失；四是对神经亚型动态差异的适应性不足。这些局限从根本上阻碍了对抑郁症核心病理特征NVAB的精准靶向调控，最终导致临床应答率低与泛化能力不足的双重困境。

3.2　AI驱动的个性化干预突破

AI技术的引入，通过深度整合多模态数据、构建动态神经计算模型并实现实时闭环调控，这得益于计算精神病学框架的发展，为AI解析NVAB神经机制提供了坚实理论支撑[72]；同时，神经科学启发的AI模型如深度强化学习等能够模拟负性注意偏差的计算机制[31]，为实现视觉特异性精准调控奠定了技术基础。突破了传统干预瓶颈、为NVAB的视觉特异性精准调控提供了革命性方案，推动干预策略向个体化、自适应和强泛化方向飞跃。

AI驱动的突破首先体现在构建动态自适应闭环干预系统[73]。传统干预的刺激参数是固定的，而基于元强化学习[13,74]等先进算法的AI模型，能够根据实时获取的眼动追踪数据动态调整干预参数[75]。例如，在VR环境中，当系统检测到患者对悲伤面孔的注视驻留时间超过某个阈值时，可瞬时自动降低该负性刺激的呈现频率或强度，同时增强中性或正性刺激的引导，实现注视即反馈、反馈即调整的精准闭环训练。Woolridge等[61]的随机对照试验为此提供了临床实证，该研究纳入了40名确诊重度抑郁

症患者,随机分为主动训练组20人与假训练组20人:主动组采用AI驱动的奖励式方案,呈现NimStim标准化表情库中的1张正性与3张负性面孔,眼动系统实时捕捉注视,注视正性面孔则增强画质,注视负性面孔则模糊图像;假训练组则刺激画质固定不变。2组均完成3次、每次35 min的训练后,主动组对正性刺激的关注比例显著高于负性刺激,且从悲伤面孔中脱离注意力的速度呈改善趋势,训练效果还迁移至情绪记忆,比如主动组可以记住更多的开心词。这种动态自适应策略精准验证了AI实时调节刺激的核心价值。

AI强大的迁移学习能力进一步解决了场景泛化难题,通过优化模型参数使其适应不同文化背景[76],显著提升场景模拟的真实度,极大增强了训练效果的生态效度。具体而言,Rahimi等[77]基于生成对抗网络(generative adversarial network,GAN)的AI模型,通过在大规模真实社交视频数据集上进行训练,能够生成包含精细动态微表情、口罩遮挡以及特定文化环境元素等高保真虚拟社交场景,极大克服了原有VRET在刺激保真度上的核心缺陷[65]。

神经调控的精准性也因AI而飞跃。利用动态因果模型(dynamic causal modeling,DCM)[78]分析静息态或任务态fMRI数据,量化脑区之间的因果连接关系。AI能够识别出个体特异性的视觉-边缘环路异常连接模式。基于此,AI可指导个体化神经调控靶点选择。比如发现某患者是LP核过度连接导致的NVAB,就指导tDCS精准刺激LP核,而不是像传统方法那样固定刺激前额叶。这种个体化靶点选择,在特定病理机制调控中展现出巨大潜力。可将tDCS等技术的治疗应答率从传统方法的约50%显著提升至74%[63]。类似地,Myruski等[79]研究跨前额叶皮层的tDCS与游戏化注意力偏差修正训练(attention bias modification training,ABMT)移动应用相结合的效果,借助AI技术增强ABMT效果,显著提升了干预的精准性与适应性。

其次,AI赋能了高效能、高可及性的数字疗法创新。AI算法如TSCNN模型[19]能够高效处理和分析高维、复杂的多模态数据流,构建强大的预测与干预模型。这些模型不仅能精准评估状态,更能据此设计高度个性化的自适应训练方案。Colledani等[80]利用机器学习优化心理健康评估,实现对情绪状态的动态监测与个性化干预。此外,AI驱动的联邦学习框架使得开发轻量化的移动端应用成为可能[49,81]。AI还助力实现跨组学的精准干预匹配。通过整合基因组学、药理学、神经影像学和认知行为数据,AI模型能为特定亚型患者设计最优组合策略[67]。AI驱动的tDCS与基于鼠标的凝视条件训练(Mouse-based Contingent Attention Training,MCAT)的联合干预已被证明可有效改善低弹性个体的注意力调节与情绪重新评估能力[27],验证了组合策略的优势。

综上所述,AI技术通过深度整合多模态数据与动态神经计算模型,从根本上突破传统干预的群体化标准范式,实现对NVAB视觉特异性精准干预调控。

4 结束语

NVAB作为抑郁症认知神经科学领域的核心研究热点,已成为解析抑郁症发病机制及优化治疗干预策略的核心指标。在复杂自然场景中,NVAB的动态变化不仅精准反映了患者对负性视觉信息的异常加工模式,更可作为临床症状进展与预后转归的潜在预测指标,其精准评估与靶向干预因此兼具重要的理论探索价值与临床实践意义。本文系统梳理了NVAB的神经生理基础与诊疗应用价值,并重点聚焦近3年AI在该领域引发的研究范式革新,深入评述了其在神经机制解析、评估技术与干预策略三大方向的突破性进展。

尽管基于深度学习的多模态融合方法已有效突破传统静态研究的局限,且通过整合神经调控、VR等技术开辟了NVAB干预的新路径。但当前研究仍面临多重核心挑战:(1)跨模态数据融合与标准化难题:如何有效整合并标准化眼动、EEG、fMRI等多源异构数据,提升研究的生态效度与模型泛化性。(2)模型可解释性与临床转化瓶颈:如何借助Grad-CAM、SHAP等可解释AI技术破解“黑箱”决策困境,实现向临床实践的高效转化。(3)跨文化适应性与伦理隐私平衡困境:如何开发适配不同文化背景注意模式的鲁棒模型,同时在依托联邦学习推进跨中心协作时,构建严谨的隐私保护体系。(4)闭环精准干预系统的优化与落地障碍:基于实时眼动、生理指标的自适应VR神经调控系统仍受计算成本过高、患者依从性不足等问题限制,难以快速实现临床普及。

展望未来,NVAB研究的核心突破方向在于:(1)深化个体化动态神经机制解析,通过高时空分辨率技术精准刻画毫秒级神经环路动态交互的个体异质性特征;(2)构建闭环诊疗体系,融合“动态脑网络-多组学-数字表型”多维数据,建立从筛查预

警、精准评估到干预优化的全链条临床决策闭环；(3)推进临床技术升级，集成联邦学习、XAI、边缘计算等关键技术，破解数据协同与隐私保护的矛盾，推动抑郁症全周期诊疗管理的规模化落地。随着上述方向的技术突破与理论创新，NVAB研究有望为抑郁症病理机制的深度解析、精准诊疗技术的临床转化及患者预后的有效改善提供核心驱动力。

©The editorial department of Journal of Capital Normal University (Natural Science Edition) 2025. This is an open access article under the CC BY-NC-ND 4.0 license (https://creativecommons.org/licenses/by-nc-nd/4.0/).

参 考 文 献

[1] LeMoult J, Gotlib I H. Depression: a cognitive perspective[J]. Clinical Psychology Review, 2019, 69: 51-66. DOI: 10.1016/j.cpr.2018.06.008.

[2] Solomon D A, Keller M B, Leon A C, et al. Multiple recurrences of major depressive disorder [J]. The American Journal of Psychiatry, 2000, 157(2): 229-233. DOI: 10.1176/appi.ajp.157.2.229.

[3] Keller A S, Leikauf J E, Holt-Gosselin B, et al. Paying attention to attention in depression [J]. Translational Psychiatry,2019,9:279. DOI:10.1038/s41398-019-0616-1.

[4] Imbert L, Neige C, Moirand R, et al. Eye-tracking evidence of a relationship between attentional bias for emotional faces and depression severity in patients with treatment-resistant depression [J]. Scientific Reports, 2024, 14: 12000. DOI: 10.1038/s41598-024-62251-4.

[5] Suslow T, Hußlack A, Kersting A, et al. Attentional biases to emotional information in clinical depression: a systematic and meta-analytic review of eye tracking findings[J]. Journal of Affective Disorders, 2020, 274: 632-642. DOI: 10.1016/j.jad.2020.05.140.

[6] Peckham A D, McHugh R K, Otto M W. A meta-analysis of the magnitude of biased attention in depression[J]. Depression and Anxiety, 2010, 27 (12): 1135-1142. DOI: 10.1002/da.20755.

[7] Beck A T. Depression: Clinical, Experimental, and Theoretical Aspects[M]. New York: Harper and Row, 1967. DOI: 10.1037/11651-000.

[8] Gotlib I H, Joormann J. Cognition and depression: current status and future directions[J]. Annual Review of Clinical Psychology, 2010, 6: 285-312. DOI: 10.1146/annurev.clinpsy.121208.131305.

[9] Mathews A, MacLeod C. Cognitive vulnerability to emotional disorders [J]. Annual Review of Clinical Psychology, 2005, 1: 167-195. DOI: 10.1146/annurev.clinpsy.1.102803.143916.

[10] Wu F F, Gu C X, Xu R, et al. A visual cortical-lateral posterior thalamic nucleus circuit regulates depressive-like behaviors in male mice [J]. Nature Communications, 2025, 16: 1395. DOI: 10.1038/s41467-024-55600-4.

[11] Kaiser R H, Andrews-Hanna J R, Wager T D, et al. Large-scale network dysfunction in major depressive disorder: a meta-analysis of resting-state functional connectivity[J]. JAMA Psychiatry, 2015, 72(6): 603-611. DOI: 10.1001/jamapsychiatry.2015.0071.

[12] Lazarov A, Ben-Zion Z, Shamai D, et al. Free viewing of sad and happy faces in depression: a potential target for attention bias modification [J]. Journal of Affective Disorders, 2018, 238: 94-100. DOI: 10.1016/j. jad. 2018.05.047.

[13] Wang J X, Kurth-Nelson Z, Kumaran D, et al. Prefrontal cortex as a meta-reinforcement learning system [J]. Nature Neuroscience, 2018, 21 (6): 860-868. DOI: 10.1038/s41593-018-0147-8.

[14] Matthews G R, Antes J R. Visual attention and depression: Cognitive biases in the eye fixations of the dysphoric and the nondepressed[J]. Cognitive Therapy and Research, 1992, 16 (3): 359-371. DOI: 10.1007/BF01183287.

[15] Young K D, Zotev V, Phillips R, et al. Real-time FMRI neurofeedback training of amygdala activity in patients with major depressive disorder[J]. PLoS One, 2014, 9 (2): e88785. DOI: 10.1371/journal.pone.0088785.

[16] Jamieson A J, Leonards C A, Davey C G, et al. Major depressive disorder associated alterations in the effective connectivity of the face processing network: a systematic review[J]. Translational Psychiatry, 2024, 14: 62. DOI: 10.1038/s41398-024-02734-0.

[17] Guha A, Yee C M, Heller W, et al. Alterations in the default mode-salience network circuit provide a potential mechanism supporting negativity bias in depression[J]. Psychophysiology, 2021, 58(12): e13918. DOI: 10.1111/psyp.13918.

[18] Puccetti N A, Stamatis C A, Timpano K R, et al. Worry and rumination elicit similar neural representations: neuroimaging evidence for repetitive negative thinking [J]. Cognitive, Affective, & Behavioral Neuroscience, 2025,25(2):488-500. DOI:10.3758/s13415-024-01239-z.

[19] Yang M Q, Weng Z R, Zhang Y H, et al. Three-stream convolutional neural network for depression detection with ocular imaging[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 4921-4930. DOI: 10.1109/TNSRE.2023.3339518.

[20] Li C, Bian N, Zhao Z P, et al. Multi-view domain-adaptive representation learning for EEG-based emotion recognition[J]. Information Fusion, 2024, 104: 102156. DOI:10.1016/j.inffus.2023.102156.

[21] Li X, Liu H Z, Wang R Q, et al. EMo transformer: transformer-based depression detection via eye movements[C]//2024 IEEE International Conference on Multimedia and Expo (ICME). July 15-19, 2024, Niagara Falls, ON, Canada. IEEE, 2024: 1-6. DOI: 10.1109/ICME57554.2024.10688241.

[22] Klawohn J, Bruchnak A, Burani K, et al. Aberrant attentional bias to sad faces in depression and the role of stressful life events: evidence from an eye-tracking paradigm[J]. Behaviour Research and Therapy, 2020, 135:103762. DOI:10.1016/j.brat.2020.103762.

[23] Xi Y Q, Wang Z Q, Zhou H Y, et al. Correlation of event-related potentials N170 with dysfunctional attitudes in patients with major depressive disorder[J]. Journal of Affective Disorders, 2023, 340: 228-236. DOI:10.1016/j.jad.2023.08.002.

[24] Zhang P S, Cao L Y, Yuan J X, et al. Early impairment of face perception in post-stroke depression: an ERP study[J]. Clinical EEG and Neuroscience, 2025, 56(3): 239-248. DOI:10.1177/15500594241289473.

[25] Bourke C, Douglas K, Porter R. Processing of facial emotion expression in major depression: a review[J]. Australian & New Zealand Journal of Psychiatry, 2010, 44(8):681-696. DOI:10.3109/00048674.2010.496359.

[26] Disner S G, Beevers C G, Haigh E A P, et al. Neural mechanisms of the cognitive model of depression[J]. Nature Reviews Neuroscience, 2011, 12(8): 467-477. DOI:10.1038/nrn3027.

[27] Sanchez-Lopez A, De Raedt R, Puttevils L, et al. Combined effects of tDCS over the left DLPFC and gaze-contingent training on attention mechanisms of emotion regulation in low-resilient individuals[J]. Progress in Neuro-Psychopharmacology and Biological Psychiatry, 2021, 108: 110177. DOI: 10.1016/j. pnpbp. 2020.110177.

[28] Chao L F, Luo L X, Pang T, et al. Integration of multi-omics summary data reveals the role of N6-methyladenosine in neuropsychiatric disorders[J]. Molecular Psychiatry, 2024, 29(10): 3141-3150. DOI: 10.1038/s41380-024-02574-w.

[29] Schmaal L, Veltman D J, van Erp T G M, et al. Subcortical brain alterations in major depressive disorder: findings from the ENIGMA Major Depressive Disorder working group[J]. Molecular Psychiatry, 2016, 21(6): 806-812. DOI:10.1038/mp.2015.69.

[30] Zhu J, Yang C L, Xie X N, et al. Mutual information based fusion model (MIBFM): mild depression recognition using EEG and pupil area signals[J]. IEEE Transactions on Affective Computing, 2023, 14(3): 2102-2115. DOI:10.1109/TAFFC.2022.3171782.

[31] Hassabis D, Kumaran D, Summerfield C, et al. Neuroscience-inspired artificial intelligence[J]. Neuron, 2017,95(2):245-258. DOI:10.1016/j.neuron. 2017.06.011.

[32] Yang M Q, Cai C L, Hu B. Clustering based on eye tracking data for depression recognition[J]. IEEE Transactions on Cognitive and Developmental Systems, 2023, 15(4): 1754-1764. DOI: 10.1109/TCDS. 2022. 3223128.

[33] Sun X Y, Sun J R, Lu X W, et al. Mapping neurophysiological subtypes of major depressive disorder using normative models of the functional connectome[J]. Biological Psychiatry, 2023, 94(12): 936-947. DOI:10.1016/j.biopsych.2023.05.021.

[34] Chen D, Wang X, Voon V, et al. Neurophysiological stratification of major depressive disorder by distinct trajectories[J]. Nature Mental Health, 2023, 1(11): 863-875. DOI:10.1038/s44220-023-00139-4.

[35] Joormann J, Gotlib I H. Selective attention to emotional faces following recovery from depression[J]. Journal of Abnormal Psychology, 2007, 116(1): 80-85. DOI: 10.1037/0021-843X.116.1.80.

[36] Suslow T, Hoepfel D, Kersting A, et al. Depressive symptoms and visual attention to others' eyes in healthy individuals[J]. BMC Psychiatry, 2024, 24(1): 184. DOI:10.1186/s12888-024-05633-2.

[37] van Kleef R S, Marsman J C, van Valen E, et al. Neural basis of positive and negative emotion regulation in remitted depression[J]. NeuroImage: Clinical, 2022, 34: 102988. DOI:10.1016/j.nicl.2022.102988.

[38] 张立伟.抑郁倾向个体负性注意偏向及神经机制研究[D].大连:辽宁师范大学,2019.
Zhang Liwei. The Negativity Biases of Depression and Its Neuro Machanism[D]. Dalian: Liaoning Normal University, 2019.

[39] Lu S F, Xu J Y, Li M, et al. Attentional bias scores in patients with depression and effects of age: a controlled, eye-tracking study[J]. The Journal of International Medical Research, 2017, 45(5): 1518-1527. DOI: 10.1177/0300060517708920.

[40] Pan B, Hirota K, Jia Z Y, et al. A review of multimodal emotion recognition from datasets, preprocessing, features, and fusion methods[J]. Neurocomputing, 2023, 561: 126866. DOI:10.1016/j.neucom.2023.126866.

[41] Zhu J, Wang Z H, Gong T, et al. An improved

classification model for depression detection using EEG and eye tracking data [J]. IEEE Transactions on NanoBioscience, 2020, 19(3): 527-537. DOI: 10.1109/TNB.2020.2990690.

[42] Ding X F, Yue X X, Zheng R, et al. Classifying major depression patients and healthy controls using EEG, eye tracking and galvanic skin response data[J]. Journal of Affective Disorders, 2019, 251: 156-161. DOI: 10.1016/j.jad.2019.03.058.

[43] Jia X W, Chen J X, Liu K X, et al. Multimodal depression detection based on an attention graph convolution and transformer [J]. Mathematical Biosciences and Engineering, 2025, 22(3): 652-676. DOI: 10.3934/mbe.2025024.

[44] Liu J Y, Shang Y Y, Yang M Y, et al. MFMamba: a multimodal fusion state space model for depression recognition [PP/OL]. [2025-06-01]. https://ieeexplore.ieee.org/abstract/document/10888951.

[45] Liu J Y, Shang Y Y, Yang M Y, et al. CFGMamba: cross frame group Mamba for video-based depression recognition[J]. Biomedical Signal Processing and Control, 2025, 110: 108113. DOI: 10.1016/j.bspc.2025. 108113.

[46] Xu M J, Qin L Y, Chen W J, et al. Multi-view adversarial discriminator: mine the non-causal factors for object detection in unseen domains [PP/OL]. V1. arXiv (2023-04-06) [2025-06-01]. https://doi. org/10.48550/arXiv.2304.02950.

[47] Macinnes J J, Iqbal S, Pearson J, et al. Wearable Eye-tracking for Research: Automated dynamic gaze mapping and accuracy/precision comparisons across devices[EB/OL]. (2018-06-28) [2025-06-23]. https://www. biorxiv.org/content/10.1101/299925v1.

[48] Birawo B, Kasprowski P. Review and evaluation of eye movement event detection algorithms[J]. Sensors, 2022, 22(22): 8810. DOI: 10.3390/s22228810.

[49] Nguyen T X, Ran A R, Hu X Y, et al. Federated learning in ocular imaging: current progress and future direction [J]. Diagnostics, 2022, 12(11): 2835. DOI: 10.3390/diagnostics12112835.

[50] Xu C, Liu H, Qi W. EEG emotion recognition based on federated learning framework[J]. Electronics, 2022, 11(20): 3316. DOI: 10.3390/electronics11203316.

[51] Li Z Y, Yang K, Tan J, et al. Nimbus: Secure and efficient two-party inference for transformers[PP/OL]. [2025-06-01].https://arxiv.org/abs/2411.15707.

[52] van der Velden B H M, Kuijf H J, Gilhuijs K G A, et al. Explainable artificial intelligence (XAI) in deep learning-based medical image analysis [J]. Medical Image Analysis, 2022, 79: 102470. DOI: 10.1016/j.media.2022.102470.

[53] Zuo F Y, Jing P G, Sun J L, et al. Deep learning-based eye-tracking analysis for diagnosis of Alzheimer's disease using 3D comprehensive visual stimuli[J]. IEEE Journal of Biomedical and Health Informatics, 2024, 28(5): 2781-2793. DOI: 10.1109/JBHI.2024.3365172.

[54] Loh H W, Ooi C P, Seoni S, et al. Application of explainable artificial intelligence for healthcare: a systematic review of the last decade (2011-2022) [J]. Computer Methods and Programs in Biomedicine, 2022, 226: 107161. DOI: 10.1016/j.cmpb.2022.107161.

[55] Tottenham N, Tanaka J W, Leon A C, et al. The NimStim set of facial expressions: judgments from untrained research participants[J]. Psychiatry Research, 2009, 168(3): 242-249. DOI: 10.1016/j. psychres. 2008.05.006.

[56] Nayar K, Kang X, Winston M, et al. A cross-cultural study of visual attention in autism spectrum disorder[J]. Child Neuropsychology, 2023, 29(3): 413-444. DOI: 10.1080/09297049.2022.2094904.

[57] Zhang W, Li X. Federated transfer learning for intelligent fault diagnostics using deep adversarial networks with data privacy[J]. IEEE/ASME Transactions on Mechatronics, 2022, 27(1): 430-439. DOI: 10.1109/TMECH.2021.3065522.

[58] Liu X Y, Wang J, Xiong X, et et al. Federated learning data protection scheme based on personalized differential privacy in psychological evaluation [J]. Neurocomputing, 2025, 611: 128653. DOI: 10.1016/j.neucom.2024.128653.

[59] Noyes B, Biorac A, Vazquez G, et al. Eye-tracking in adult depression: protocol for a systematic review and meta-analysis [J]. BMJ Open, 2023, 13(6): e069256. DOI: 10.1136/bmjopen-2022-069256.

[60] Bücker L, Berger T, Bruhns A, et al. Motive-oriented, personalized, Internet-based interventions for depression: nonclinical experimental study [J]. JMIR Formative Research, 2022, 6(9): e37287. DOI: 10.2196/37287.

[61] Woolridge S M, Harrison G W, Best M W, et al. Attention bias modification in depression: a randomized trial using a novel, reward-based, eye-tracking approach [J]. Journal of Behavior Therapy and Experimental Psychiatry, 2021, 71: 101621. DOI: 10.1016/j. jbtep. 2020.101621.

[62] Xia H S, Li Y X, Zhang Q Y, et al. Attention bias modification for depression: a systematic review and meta-analysis [J]. Frontiers in Psychiatry, 2023, 14: 1098610. DOI: 10.3389/fpsyt.2023.1098610.

[63] Brunoni A R, Moffa A H, Fregni F, et al. Transcranial

direct current stimulation for acute major depressive episodes: meta-analysis of individual patient data [J]. The British Journal of Psychiatry, 2016, 208(6): 522-531. DOI:10.1192/bjp.bp.115.164715.

[64] Beevers C G, Clasen P C, Enock P M, et al. Attention bias modification for major depressive disorder: effects on attention bias, resting state connectivity, and symptom change[J]. Journal of Abnormal Psychology, 2015, 124(3): 463-475. DOI:10.1037/abn0000049.

[65] Duraivel S. Enhancing virtual reality exposure therapy for social anxiety disorder using generative adversarial networks: a personalized and adaptive approach [EB/OL]. (2024-09-03) [2025-06-23]. https://doi. org/10.20944/preprints202409.0107.v1.

[66] Liu H C, Lai Z Y, Huang Y N, et al. Exploring causal association between functional/structural connectivity and major depression disorder: a bidirectional Mendelian randomization study[J]. Journal of Affective Disorders, 2025, 369: 1064-1070. DOI:10.1016/j.jad.2024.10.091.

[67] Richter T, Shani R, Tal S, et al. Machine learning meta-analysis identifies individual characteristics moderating cognitive intervention efficacy for anxiety and depression symptoms[J]. npj Digital Medicine, 2025, 8: 65. DOI: 10.1038/s41746-025-01449-w.

[68] Dunlop B W, Cha J, Choi K S, et al. Functional connectivity of salience and affective networks among remitted depressed patients predicts episode recurrence [J]. Neuropsychopharmacology, 2023, 48(13): 1901-1909. DOI:10.1038/s41386-023-01653-w.

[69] Kotoula V, Evans J W, Punturieri C, et al. Chapter 5 Functional MRI markers for treatment-resistant depression: Insights and challenges [J]. Progress in Brain Research, 2023, 278: 117-148. DOI: 10.1016/bs.pbr.2023.04.001.

[70] 惠慧,洪昂,王振.虚拟现实暴露疗法在焦虑相关障碍治疗中的新进展[J].中国临床心理学杂志,2022,30(5):1218-1223. DOI:10.16128/j.cnki.1005-3611. 2022.05.042.
Hui Hui, Hong Ang, Wang Zhen. The new development of virtual reality exposure therapy in the treatment of anxiety and related disorders [J]. Chinese Journal of Clinical Psychology, 2022, 30(5): 1218-1223.

[71] Hui H, Hong A, Gao J, et al. Efficacy of tDCS to enhance virtual reality exposure therapy response in acrophobia: a randomized controlled trial[J]. Journal of Psychiatric Research, 2024, 171: 52-59. DOI: 10.1016/j.jpsychires.2024.01.027.

[72] Huys Q J M, Maia T V, Frank M J. Computational psychiatry as a bridge from neuroscience to clinical applications[J]. Nature Neuroscience, 2016, 19(3): 404-413. DOI:10.1038/nn.4238.

[73] Zhang M Y, Li J L, Zhao H Y, et al. A meta reinforcement learning-based approach for self-adaptive system [C]//2021 IEEE International Conference on Autonomic Computing and Self-Organizing Systems (ACSOS). September 27 - October 1, 2021, Washington, DC, USA. IEEE, 2021: 1-10. DOI: 10.1109/ACSOS52086.2021.00024.

[74] Robertazzi F, Vissani M, Schillaci G, et al. Brain-inspired meta-reinforcement learning cognitive control in conflictual inhibition decision-making task for artificial agents [J]. Neural Networks, 2022, 154: 283-302. DOI:10.1016/j.neunet.2022.06.020.

[75] Bekler M, Yilmaz M, Ilgın H E. Assessing feature importance in eye-tracking data within virtual reality using explainable artificial intelligence techniques [J]. Applied Sciences, 2024, 14(14): 6042. DOI: 10.3390/app14146042.

[76] Koelkebeck K, Uwatoko T, Tanaka J, et al. How culture shapes social cognition deficits in mental disorders: a review[J]. Social Neuroscience, 2017, 12(2): 102-112. DOI:10.1080/17470919.2016.1155482.

[77] Rahimi F, Sadeghi-Niaraki A, Choi S M. Generative AI meets virtual reality: a comprehensive survey on applications, challenges, and future direction [J]. IEEE Access, 2025, 13: 94893-94909. DOI: 10.1109/ACCESS.2025.3574779.

[78] Friston K J, Harrison L, Penny W. Dynamic causal modelling [J]. NeuroImage, 2003, 19(4): 1273-1302. DOI:10.1016/S1053-8119(03)00202-7.

[79] Myruski S, Cho H, Bikson M, et al. Transcranial direct current stimulation (tDCS) augments the effects of gamified, mobile attention bias modification [J]. Frontiers in Neuroergonomics, 2021, 2: 652162. DOI: 10.3389/fnrgo.2021.652162.

[80] Colledani D, Barbaranelli C, Anselmi P. Fast, smart, and adaptive: using machine learning to optimize mental health assessment and monitor change over time [J]. Scientific Reports, 2025, 15: 6492. DOI: 10.1038/s41598-025-91086-w.

[81] Liu J Y, Shang Y Y, Yang M Y, et al. Attention-guided bi-direction temporal-aware network for speech-based depression recognition [J]. Digital Signal Processing, 2025, 166: 105359. DOI:10.1016/j.dsp.2025.105359.

(责任编辑:马田田)