·综　　述·

人工智能模型在预测谵妄方面的研究进展*

陈欣然，李　微，贺琳娜，杨　郑△，索志君
（深圳市南山区人民医院重症医学科，广东 深圳 518052）

［摘　要］ 谵妄与住院患者的多种不良事件有关，早期快速精准实时预测谵妄对改善患者预后具有重要意义。随着人工智能（AI）在医学领域蓬勃发展，其在谵妄预测中的应用经历了从传统机器学习模型探索到多模态数据融合与可解释性技术突破的关键发展阶段。早期以逻辑回归、随机森林等基础算法整合临床常规指标实现初步风险分层，中期借助 XGBoost、LightGBM 等进阶模型提升高维数据处理能力与预测精度，近期则通过自然语言处理、长短期记忆网络等技术融合多源数据，并依托 SHAP 值等可解释性方法增强临床适配性，实现从静态评估向动态预警的阶段性突破。该文围绕 AI 在预测术后人群谵妄、ICU 患者谵妄及特殊疾病群体谵妄方面的综述。

［关键词］ 人工智能；　预测；　谵妄；　综述
DOI：10.3969/j.issn.1009-5519.2026.07.028　　**中图法分类号**：R749；R-058
文章编号：1009-5519（2026）07-1588-05　　**文献标识码**：A

Research progress of artificial intelligence models in predicting delirium*

Chen Xinran, *Li Wei*, *He Linna*, *Yang Zheng*△, *Suo Zhijun*
（*Department of Critical Care Medicine*, *Shenzhen Nanshan People's Hospital*, *Shenzhen*, *Guangdong* 518052, *China*）

［**Abstract**］ Delirium is associated with a variety of adverse events in hospitalized patients. Early, rapid, precise and real-time prediction of delirium is of great significance for improving the prognosis of patients. With the vigorous development of artificial intelligence（AI）in the medical field, its application in delirium prediction has gone through key developmental stages from the exploration of traditional machine learning models to multi-modal data fusion and interpretability technology breakthroughs. In the early stage, basic algorithms such as logistic regression and random forest were used to integrate clinical routine indicators to achieve preliminary risk stratification. In the middle stage, advanced models like XGBoost and LightGBM were used to improve high-dimensional data processing capabilities and prediction accuracy. Recently, technologies such as natural language processing and long short-term memory networks have been adopted to fuse multi-source data, and interpretability methods such as SHAP values have been relied on to enhance clinical adaptability, achieving a phased breakthrough from static assessment to dynamic early warning. This article reviews the application of AI in predicting delirium in postoperative populations, ICU patients, and special disease groups.

［**Key words**］ Artificial intelligence;　Prediction;　Delirium;　Review

谵妄作为一种急性脑功能障碍综合征，以注意障碍、意识水平波动及认知功能紊乱为核心特征，可导致住院时间延长、病死率升高及长期认知损害等严重不良结局[1]。有研究显示，谵妄在术后患者及重症监护病房（ICU）人群中尤为高发，发生率在 5.3%～28.6%，其中老年群体风险显著升高[2-3]。尽管谵妄评估量表（CAM）为临床诊断提供了标准化工具，但部分量表需专业精神科培训，且谵妄症状的波动性要求动态监测，这对繁忙的临床工作者构成了实际挑战[1]。

*　**基金项目**：深圳市三名工程资助项目（SZSM202403005）；南山区卫生科技计划项目（NS2023081）。
△　**通信作者**，E-mail：154710953@qq.com。
引用格式：陈欣然，李微，贺琳娜，等. 人工智能模型在预测谵妄方面的研究进展[J]. 现代医药卫生，2026，42（7）：1588-1592.

人工智能(AI)技术的迅猛发展为解决上述难题提供了新思路。机器学习、自然语言处理(NLP)及计算机视觉等 AI 分支已在医学影像分析、疾病预测等领域展现出独特优势[4]。在谵妄预测中,基于 AI 的模型能够整合电子健康记录(EHR)、生理信号、影像数据等多维度信息,实现自动化、实时化的风险分层,为临床早期干预争取时间窗口[5-6]。本文聚焦 AI 技术在谵妄预测中的应用进展,系统综述其在术后人群、ICU 患者及特殊疾病群体中的研究成果,剖析不同模型的技术特点、危险因素整合策略及临床转化价值,以期为谵妄的精准管理提供理论参考与实践方向。

1　术后谵妄(POD)预测模型的多维度研究进展

1.1　心血管手术领域的预测模型创新　Yang 等[5]对 367 例心脏手术患者的研究显示,基于 21 项危险因素(如高龄、体外循环时间)构建的随机森林模型,在准确率(87.99%)、AUC(0.920)等指标上表现优异。该研究首次证实高维特征整合对 POD 精准预测的价值。Nagat 等[6]通过前瞻性研究发现,极端随机树模型(AUC 0.76)与 XGBoost 模型(灵敏度 0.67)可通过术前认知功能(简易精神状态检查表<4 分)、肾功能(估算肾小球滤过率<60 mL/min)等 6 项指标预测心血管术后 POD,为术前风险分层提供了简易工具。

1.2　骨科与老年患者的机器学习应用突破　在老年髋部骨折手术中,Song 等[7]比较 5 种机器学习模型发现,随机森林(AUC 0.81)显著优于传统列线图(AUC 0.71),且整合了肾功能不全、慢性阻塞性肺疾病等老年人群特征性危险因素。Bishara 等[8]基于 24 885 例患者的术前 EHR 构建的 XGBoost 模型(AUC 0.851),较临床医生指导的回归模型(AUC 0.763)展现出更强的泛人群预测能力,提示医疗大数据与机器学习的结合可突破单中心研究的局限性。

1.3　多源数据融合与模型轻量化探索　Yoshimura 等[9]利用 557 990 例老年全身麻醉手术数据构建的 LightGBM 模型,AUC 达 0.826 且时段验证稳定,证实大规模医疗数据可提升模型普适性。Ha 等[10]创新性地将多导睡眠图数据(如快速眼动次数减少)与临床变量结合,使 XGBoost 模型 AUC 提升至 0.840,揭示了睡眠-觉醒周期紊乱与 POD 的潜在关联。Neto 等[11]研究显示,仅用年龄、术前住院时长和术后并发症数量 3 项易获取指标构建的模型(AUC 0.740),效能优于包含 112 项特征的复杂模型,为资源有限场景下的 POD 预测提供了实用方案。

1.4　传统逻辑回归与机器学习的场景化互补　Song 等[12]在 29 756 例非心脏/非神经外科老年患者中发现,逻辑回归模型(AUC 0.783,灵敏度 74.2%)在灵敏度和可解释性上优于部分机器学习模型(如 XGBoost 的 AUC 0.730),尤其适用于需要快速筛查的急诊手术场景。而机器学习在处理非线性关系(如睡眠参数与炎症指标的交互作用)及整合多模态数据(影像、睡眠监测、实验室指标)时更具优势,二者的结合可实现精准预测+临床可解释的双重目标。

1.5　共识性危险因素与未来研究范式　目前研究一致认为,POD 的危险因素包括高龄、术前认知减退(简易精神状态检查表<24 分)、基础疾病(糖尿病/慢性肾病)、手术创伤(体外循环/长时间手术)及炎症应激(低白蛋白/乳酸脱氢酶升高)[5-7,13]。未来研究需聚焦:(1)多中心前瞻性验证以提升模型泛化能力;(2)脑电信号、炎症因子等生物标志物与 AI 模型的深度融合;(3)基于可解释 AI,如沙普利值(SHAP)的临床决策支持系统开发,推动 POD 预测从研究向临床实践的转化[12,14]。

2　ICU 谵妄预测模型的研究进展

2.1　ICU 谵妄的临床危害与预测价值　谵妄作为 ICU 常见急性综合征,可导致患者病死率升高、机械通气时间延长、长期认知功能障碍及医疗费用增加[15]。早期预测对改善预后至关重要,有研究显示,利用 EHR 训练的机器学习模型可实现提前 12 h 预测谵妄发作,为临床早期干预谨言慎行赢得时间[16]。

2.2　多模态数据驱动的预测模型创新　Gong 等[16]开发的 24 h 模型与动态模型展现出分层预测能力:24 h 模型基于入住 ICU 后 24 h 内数据,AUC 达 0.785,动态模型提前 12 h 预测的 AUC 提升至 0.845,证实常规 EHR 数据的预测价值。Oh 等[17]创新性地利用心电图心率变异性数据,通过带径向基函数核的支持向量机实现与传统多指标模型相当的分类准确率,为非侵入性预测提供新路径。

Mulkey 等[18]的前瞻性研究显示,基于有限导联脑电图 γ 频段数据的模型对机械通气患者谵妄预测准确率超 70%,提示脑电信号的潜在价值。Wu 等[19]在 1 155 例 ICU 患者中验证 XGBoost 模型的卓越性能(AUC 0.932),其关键特征包括格拉斯哥昏迷量表(GCS)语言评分、血氧饱和度及慢性肾病指标,为 COPD 合并呼吸衰竭患者提供个体化风险评估。

2.3　大规模数据与跨数据库验证进展　Ma 等[20]基于重症监护医学信息数据库Ⅳ(MIMIC-IV)的 18 760 例老年患者分析显示,XGBoost 模型在训练集和测试集的 AUC 分别为 0.853 和 0.831,优于逻辑回归模型,且序贯器官衰竭评估(SOFA)、感染等为核心危险

因素。Zhang 等[21]整合 MIMIC-IV 与电子重症监护协作研究数据库的 16 343 例患者，构建的 XGBoost 模型对脓毒症相关性谵妄(SAD)的内部验证 AUC 为 0.793，外部验证 AUC 为 0.701，较传统评估更早识别高风险人群。

2.4 特殊人群与模型对比分析　在 82 例烧伤患者中，Esumi 等[22]比较 10 种机器学习模型发现，逻辑回归(AUC 0.906)、支持向量机(AUC 0.897)等模型表现优异，24 h 尿量、烧伤面积及血氧饱和度为主要风险因素。该研究同时证实，白细胞组分、高铁血红蛋白浓度等血液指标可提升预测精度。不同模型在 ICU 谵妄预测中呈现互补性：XGBoost 等树模型在高维特征处理中优势显著，逻辑回归在可解释性和简易场景中更具实用性，而基于生理信号(心率变异性、脑电)的模型为无创监测提供可能[16-19,22]。

2.5 共识性危险因素与未来研究方向　目前 ICU 谵妄核心危险因素包括：(1)疾病严重程度。SOFA 评分、感染状态、GCS 评分。(2)器官功能指标。血小板计数、血氧饱和度、肾功能指标。(3)手术与创伤因素。烧伤面积、机械通气时间。(4)生理信号特征。心率变异性、脑电图 γ 频段活动。未来研究需聚焦：(1)多中心、跨数据库的外部验证以提升模型泛化能力。(2)脑电、炎症因子等生物标志物与 EHR 数据的融合。(3)可解释 AI 技术(如 SHAP 值)在临床决策中的应用，推动预测模型从研究向床旁预警的转化[20-22]。

3　特殊人群中谵妄预测模型的研究进展

3.1 新冠病毒感染人群的谵妄预测　新冠病毒感染患者中谵妄发生率高达 16.8%[23]，且与住院病死率和预后不良密切相关。Castro 等[23]基于 6 家医院 2 907 例患者构建的机器学习模型，利用入院时 EHR 数据实现风险分层，其一致性指数为 0.75(0.71～0.79)，当敏感度为 80%时特异度达 56%，在年龄、种族及治疗机构类型等分层分析中表现稳定。Park 等[24]进一步证实，随机森林模型在 1 031 例新冠病毒感染患者中 AUC 达 0.923，敏感度 0.639，特异度 0.934，该模型识别出抗精神病药物使用、住院时长及瑞德西韦治疗等关键风险因素，其校准图和布里尔分数支持了模型的临床可靠性。

3.2 晚期癌症患者的谵妄预测突破　在急性姑息治疗病房的晚期癌症患者中，谵妄发生率约 7.1%(165/2 314)[25]。Kim 等[25]通过多中心队列研究发现，极端梯度提升与随机森林的组合模型表现最佳(灵敏度 68.83%，特异度 70.85%，AUC74.55%)，首次基于大规模注册数据构建了适用于该人群的预测模型。该研究同时指出，癌症进展程度、镇痛药物使用及电解质紊乱是核心危险因素，为姑息治疗场景下的谵妄预防提供了干预靶点。

3.3 老年精神病与 NLP 技术的融合　Netzer 等[26]证实随机森林模型在老年精神病患者谵妄预测中具有高分辨能力，而 Fu 等[27]创新性开发的 NLP 算法基于 CAM 标准，其中 NLP-CAM 的灵敏度 0.919、特异度 1.000，实现了对电子病历文本的自动化谵妄筛查。Liu 等[28]通过整合 LightGBM 与长短期记忆网络模型，在 34 035 例患者的 CAM 评估数据中实现 AUC0.952，证明时间序列分析与机器学习的结合可显著提升新发谵妄的预测效能。

3.4 跨人群模型的共性与差异分析　不同人群的谵妄预测模型呈现显著异质性：新冠病毒感染患者的预测依赖于入院时药物暴露史与器官功能指标[23-24]，晚期癌症患者更关注疾病终末期状态与镇痛方案[25]，而老年精神病群体则侧重认知评估与纵向数据动态变化[26-28]。但共性危险因素包括：高龄、多重用药、感染状态及器官功能不全，提示炎症-免疫-神经交互作用可能是谵妄发生的共同机制[23-28]。

3.5 未来研究方向与临床转化建议　(1)多模态数据整合与标准化建设：一方面需系统整合影像组学(如脑功能 MRI、弥散张量成像)、多组学生物标志物(细胞因子谱、代谢组学数据、表观遗传标志物)及实时生理信号(如连续心率变异性、脑电信号、无创血流动力学监测数据)，构建多维度、全周期的谵妄风险预测数据集。另一方面应推动跨机构数据标准化进程，制定统一的数据采集规范、特征定义标准及质量控制流程，解决多源异构数据整合难题。同时建立符合医疗数据隐私保护法规(如《健康保险流通与责任法案》《个人信息保护法》)的安全共享机制，为模型训练与验证提供高质量数据支撑[24,28]。(2)跨疾病队列验证与分层验证体系构建：首先，应在 HIV 感染、终末期肝病、神经系统退行性疾病(如阿尔茨海默病)等尚未充分探索的特殊人群中开展前瞻性队列研究，构建针对性的谵妄预测模型，填补特殊疾病群体的研究空白；其次，建立内部验证-多中心外部验证-真实世界验证的三级验证体系，结合亚组分析(如年龄分层、疾病严重程度分层)评估模型在不同临床场景下的泛化能力，同时开展模型的成本-效益分析，明确其在不同医疗资源配置场景下的应用价值[23,25]。(3)可解释 AI 技术深化与临床决策支持系统开发：重点推进基于因果推断的可解释 AI 技术应用，通过 SHAP 值、局部可解释模型无关解释法(LIME)、部分依赖图等工具，不仅解析模型决策的关键特征，更明确各危险因素与谵

妄发生之间的因果关联，打破黑箱困境；基于此开发模块化的临床决策支持系统，将 AI 预测结果与电子病历系统、临床路径管理平台深度融合，针对高风险患者自动推送个体化干预建议（如药物干预方案、非药物护理措施），并实时反馈干预效果，形成预测-干预-监测的闭环管理模式[27-28]。（4）临床转化路径优化与多中心协作网络构建：建立由临床医生、AI 工程师、生物信息学家、流行病学专家组成的跨学科转化团队，全程参与模型的需求分析、开发优化、验证推广等环节，确保模型符合临床工作流实际需求；推动建立全国性或区域性的谵妄 AI 预测研究协作网络，整合多中心资源开展大规模前瞻性临床试验，验证模型的长期预后改善效果；同时加强临床医护人员 AI 素养的培训，提升其对 AI 模型的认知与应用能力，促进技术与临床实践的深度融合[25,28]。（5）动态预测模型与实时监测技术融合：依托可穿戴设备、床旁监护系统等物联网技术，采集连续、实时的生理数据（如体温波动、呼吸频率变异、睡眠结构参数），开发动态更新的时序预测模型，实现对谵妄发作的实时预警；探索非侵入性监测技术（如近红外光谱脑功能监测、便携式脑电设备）与 AI 模型的结合，以提升床旁监测的便捷性与可行性，这种方案尤其适用于资源有限的基层医疗机构或急诊场景[10,18,23]。

4　结语与展望

AI 技术的发展为谵妄的早期识别与管理开辟了新路径。机器学习模型凭借其强大的数据处理能力，在术后、ICU 及特殊疾病人群中均展现出卓越的预测效能，部分模型 AUC 突破 0.9，为临床提供了精准的风险分层工具[5,19,24]。同时，多模态数据整合（如 EHR、生理信号、影像信息）与算法创新（如时间序列分析、NLP）的结合，使谵妄预测从静态评估转向动态预警，有望实现早期干预-改善预后的闭环管理[16,28]。然而，当前研究仍面临多重挑战。数据层面：跨中心、多源异构数据的标准化整合及隐私保护亟待完善；技术层面：模型的可解释性不足（如复杂神经网络的黑箱特性）限制了临床信任度，且外部验证的匮乏导致模型泛化能力存疑[29-30]。此外，如何将 AI 预测结果与临床工作流深度融合，平衡预测准确性与实践可行性，仍是转化应用的关键瓶颈。

展望未来，AI 技术在谵妄预测领域将朝着更精准、更透明、更贴合临床需求的方向迈进。随着因果推断、联邦学习、生成式 AI 等前沿技术的不断引入，有望在保障数据隐私安全的前提下，进一步提升模型的泛化能力与可解释性，实现从“相关性预测”向“因果性推断”的跨越。更重要的是，多学科协作将成为推动技术突破与临床转化的核心驱动力——AI 工程师的算法创新为模型构建提供技术支撑，临床医生的实践经验为模型优化指明方向，生物信息学家的数据分析为危险因素挖掘与机制探索奠定基础，三者的深度融合能够有效破解技术与临床脱节的难题，确保 AI 模型真正服务于临床需求。

未来，通过建立跨人群、跨疾病的通用预测框架，结合实时监测与个性化干预策略，AI 有望实现从研究工具到临床标配的根本性跨越。这不仅能够显著降低谵妄相关不良结局的发生率，改善患者长期预后，更能优化医疗资源分配，提升医疗服务效率与质量，为构建精准医疗体系提供重要支撑。在此过程中，还需要重视伦理规范与法律法规的保障作用，明确 AI 在临床决策中的定位与责任边界，确保技术发展始终沿着安全、可控、造福患者的方向推进。

参考文献

[1] 中华医学会神经病学分会神经心理与行为神经病学学组. 综合医院谵妄诊治中国专家共识（2021）[J]. 中华老年医学杂志，2021，40（10）：1226-1233.

[2] Liu S B，Wu H Y，Duan M L，et al. Delirium in the ICU：how much do we know？ A narrative review[J]. Ann Med，2024，56（1）：2405072.

[3] Thedim M，Vacas S. Postoperative delirium and the older adult：untangling the confusion[J]. J Neurosurg Anesthesiol，2024，36（3）：184-189.

[4] Gutierrez G. Artificial intelligence in the intensive care unit[J]. Crit Care，2020，24（1）：101.

[5] Yang T，Yang H，Liu Y，et al. Postoperative delirium prediction after cardiac surgery using machine learning models[J]. Comput Biol Med，2024，169：107818.

[6] Nagata C E，Hata M，Miyazaki Y，et al. Development of postoperative delirium prediction models in patients undergoing cardiovascular surgery using machine learning algorithms[J]. Sci Rep，2023，13（1）：21090.

[7] Song Y X，Zhang D，Wang Q，et al. Prediction models for postoperative delirium in elderly patients with machine-learning algorithms and shapley additive explanations[J]. Transl Psychiatry，2024，14（1）：57.

[8] Bishara A，Chiu C，Whitlock E L，et al. Postoperative delirium prediction using machine learning models and preoperative electronic health record data[J]. BMC Anesthesiol，2022，22（1）：8.

[9] Yoshimura M，Shiramoto H，Koga M，et al. Development and validation of a machine learning model to predict postoperative delirium using a nationwide database：a retrospective，observational study[J]. J Clin Anesth，2024，96（1）：111491.

[10] Ha W S, Choi B K, Yeom J, et al. Development and validation of machine learning models to predict postoperative delirium using clinical features and polysomnography variables[J]. J Clin Med, 2024, 13(18): 5485.

[11] Neto P, Rodrigues A L, Stahlschmidt A, et al. Developing and validating a machine learning ensemble model to predict postoperative delirium in a cohort of high-risk surgical patients: a secondary cohort analysis[J]. Eur J Anaesthesiol, 2023, 40(5): 356-364.

[12] Song Y X, Yang X D, Luo Y G, et al. Comparison of logistic regression and machine learning methods for predicting postoperative delirium in elderly patients: a retrospective study[J]. CNS Neurosci Ther, 2023, 29(1): 158-167.

[13] Benovic S, Ajlani A H, Leinert C, et al. Introducing a machine learning algorithm for delirium prediction-the Supporting SURgery with GEriatric Co-Management and AI project(SURGE-Ahead)[J]. Age Ageing, 2024, 53(5): afae101.

[14] Holler E, Ludema C, Ben Miled Z, et al. Development and validation of a routine electronic health record-based delirium prediction model for surgical patients without dementia: retrospective case-control study[J]. JMIR Perioperat Med, 2025, 8(1): e59422.

[15] 汤铂, 王小亭, 陈文劲, 等. 重症患者谵妄管理专家共识[J]. 中华内科杂志, 2019, 58(2): 108-118.

[16] Gong K D, Lu R, Bergamaschi T S, et al. Predicting intensive care delirium with machine learning: model development and external validation[J]. Anesthesiology, 2023, 138(3): 299-311.

[17] Oh J, Cho D, Park J, et al. Prediction and early detection of delirium in the intensive care unit by using heart rate variability and machine learning[J]. Physiol Meas, 2018, 39(3): 035004.

[18] Mulkey M, Albanese T, Kim S, et al. Delirium detection using gamma wave and machine learning: a pilot study[J]. Res Nurs Health, 2022, 45(6): 652-663.

[19] Wu Z B, Jiang Y L, Li S S, et al. Enhanced machine learning predictive modeling for delirium in elderly ICU patients with COPD and respiratory failure: a retrospective study based on MIMIC-IV[J]. PLoS One, 2025, 20(3): e0319297.

[20] Ma R, Zhao J, Wen Z Y, et al. Machine learning for the prediction of delirium in elderly intensive care unit patients[J]. Eur Geriatr Med, 2024, 15(5): 1393-1403.

[21] Zhang Y, Hu J J, Hua T F, et al. Development of a machine learning-based prediction model for sepsis-associated delirium in the intensive care unit[J]. Sci Rep, 2023, 13(1): 12697.

[22] Esumi R, Funao H, Kawamoto E, et al. Machine learning-based prediction of delirium and risk factor identification in intensive care unit patients with burns: retrospective observational study[J]. JMIR Format Resear, 2025, 9(1): e65190.

[23] Castro V M, Sacks C A, Perlis R H, et al. Development and external validation of a delirium prediction model for hospitalized patients with coronavirus disease 2019[J]. J Acad Consult Liaison Psychiatry, 2021, 62(3): 298-308.

[24] Park H Y, Sohn H, Hong A, et al. Application of machine learning for delirium prediction and analysis of associated factors in hospitalized COVID-19 patients: a comparative study using the Korean Multidisciplinary cohort for delirium prevention(KoMCoDe)[J]. Int J Med Inform, 2025, 195(1): 105747.

[25] Kim Y J, Lee H, Woo H G, et al. Machine learning-based model to predict delirium in patients with advanced cancer treated with palliative care: a multicenter, patient-based registry cohort[J]. Sci Rep, 2024, 14(1): 11503.

[26] Netzer M, Hackl W O, Schaller M, et al. Evaluating performance and interpretability of machine learning methods for predicting delirium in gerontopsychiatric patients[J]. Stud Health Technol Inform, 2020, 271: 121-128.

[27] Fu S, Lopes G S, Pagali S R, et al. Ascertainment of delirium status using natural language processing from electronic health records[J]. J Gerontol A Biol Sci Med Sci, 2022, 77(3): 524-530.

[28] Liu S, Schlesinger J J, Mccoy A B, et al. New onset delirium prediction using machine learning and long short-term memory(LSTM) in electronic health record[J]. J Am Med Inform Assoc, 2022, 30(1): 120-131.

[29] Chen H, Yu D D, Zhang J, et al. Machine learning for prediction of postoperative delirium in adult patients: a systematic review and meta-analysis[J]. Clin Ther, 2024, 46(12): 1069-1081.

[30] Suresh V, Singh K K, Vaish E, et al. Artificial intelligence in the intensive care unit: current evidence on an inevitable future Tool[J]. Cureus, 2024, 16(5): e59797.

(收稿日期: 2025-12-29　修回日期: 2026-02-25)