



开放科学  
(资源服务)  
标识码  
(OSID)

# 判别学习在多模态医学数据融合中的理论应用与创新实践

赵悦阳<sup>1</sup> 崔雷<sup>2</sup> 王凤婷<sup>1</sup>

1. 中国医科大学附属盛京医院图书馆 辽宁沈阳 110004;

2. 中国医科大学健康管理学院 辽宁沈阳 110122

**摘要:** [目的/意义] 本文系统梳理判别学习在多模态医学数据融合中的研究进展, 总结其核心方法、技术路径及临床应用潜力, 旨在为医学人工智能从感知融合向认知融合的跨越提供理论支撑与实践指导。[方法/过程] 通过文献分析与技术归纳, 聚焦多模态融合的三大层次——特征级融合、决策级融合以及混合级融合, 剖析判别学习在不同融合策略中的创新应用。结合线性判别分析、支持向量机和典型相关分析等传统线性模型, 以及自编码器、超图神经网络和 Transformer 等深度学习方法, 探讨特征选择、跨模态对齐与不确定性建模等关键技术, 并评估这些方法在癌症生存分析和神经退行性疾病分类等场景中的性能表现。[结果/结论] 判别学习通过动态特征权重分配、多模态知识分解及跨尺度协同建模, 显著提升了融合模型的准确性与鲁棒性。其在脑疾病诊断、癌症预测等临床场景中的应用已初步验证其价值。[局限] 本文介绍的方法在模型复杂性、计算开销与临床可解释性方面仍有待进一步突破。跨模态数据异构性问题尚未完全解决, 模型的可解释性仍难以满足医疗实践的严格需求。未来应着力于知识驱动的融合机制、模型轻量化及可信 AI 体系的构建。

**关键词:** 判别学习; 多模态医学数据融合; 可解释性; 精准医疗

**中图分类号:** G35

## Theoretical Application and Innovative Practice of Discriminative Learning in Multimodal Medical Data Fusion

ZHAO Yueyang<sup>1</sup> CUI Lei<sup>2</sup> WANG Fengting<sup>1</sup>

1. Library of Shengjing Hospital of China Medical University, Shenyang, Liaoning 110004, China;

2. School of Health Management, China Medical University, Shenyang, Liaoning 110122, China

**Abstract:** [Purpose/Significance] This paper systematically reviews the research progress of discriminative learning in multimodal medical data fusion, summarizes its core methods, technical pathways, and clinical potential, aiming to provide theoretical support and practical guidance for advancing medical artificial intelligence from perceptual fusion to cognitive fusion. [Methods/Process] Through literature analysis and technical synthesis, this work focuses on the three levels of multimodal

**基金项目** 辽宁省社会科学规划基金资助项目“在多层次相似性共嵌入空间中通过判别学习进行知识发现的描述性文档聚类”(项目编号: L20BTQ003)。

**作者简介** 赵悦阳(1980-), 通信作者, 硕士, 副研究馆员, 主要研究方向为文本挖掘、机器学习, E-mail: zhaoyy@sj-hospital.org; 崔雷(1963-), 博士, 教授, 主要研究方向为文本挖掘、生物信息学、文献计量学; 王凤婷(1998-), 硕士, 初级, 主要研究方向为图书馆学, 情报学。

**引用格式** 赵悦阳, 崔雷, 王凤婷. 判别学习在多模态医学数据融合中的理论应用与创新实践[J]. 情报工程, 2026, 12(1): 51-58.

fusion—feature-level, decision-level, and hybrid-level—and examines the innovative application of discriminative learning across different fusion strategies. It integrates traditional linear models such as linear discriminant analysis, support vector machines, and canonical correlation analysis, along with deep learning approaches including autoencoders, hypergraph neural networks, and Transformers, to explore key techniques including feature selection, cross-modal alignment, and uncertainty modeling. The performance of these methods is evaluated in scenarios such as cancer survival analysis and neurodegenerative disease classification. [Results/Conclusions] Discriminative learning significantly enhances the accuracy and robustness of fusion models through dynamic feature weight assignment (e.g., attention mechanisms), multimodal knowledge decomposition, and cross-scale collaborative modeling. Its value has been preliminarily validated in clinical scenarios such as brain disease diagnosis and cancer prediction. [Limitations] The methods presented in this paper still require further breakthroughs in model complexity, computational cost, and clinical interpretability. The heterogeneity of cross-modal data remains not fully resolved, and model interpretability still falls short of the stringent requirements of medical practice. Future efforts should focus on knowledge-driven fusion mechanisms, model lightweighting, and the development of trustworthy AI systems.

**Keywords:** Discriminative Learning; Multimodal Medical Data Fusion; Interpretability; Precision Medicine

## 引言

精准医疗的核心在于对疾病多层次、多角度的深度洞察，这依赖于对高度异构多模态医学数据（如影像、组学、临床文本、行为信号等）的有效融合。然而，模态间在时空尺度、语义粒度上的显著差异<sup>[1]</sup>，加之普遍存在的冗余、缺失与偏置问题，使得传统浅层融合策略难以挖掘跨模态的深层协同表征，制约了智能辅助决策的潜力<sup>[2-3]</sup>。

在此背景下，判别学习（Discriminative Learning）以其“任务导向、边界驱动”的核心范式，成为突破多模态融合瓶颈的关键路径。不同于生成式方法对整体分布的刻画，判别学习旨在主动提取对最终决策（如疾病分类、预后预测）最具判别性的跨模态高阶特征，并精确刻画类别边界<sup>[4]</sup>。这一特性使其在捕捉具有潜在生物学意义的判别模式上展现出独特优势。深度学习框架的赋能，更推动判别学习演化出从特征选择、语义对齐到结构建模的完整技术谱系<sup>[5]</sup>。

当前，融合判别策略已从传统线性模型，比如 LDA<sup>[6]</sup>、SVM<sup>[7]</sup>、CCA<sup>[8]</sup>，拓展至深度自编码器<sup>[9]</sup>、图神经网络<sup>[10]</sup>及 Transformer<sup>[11]</sup>等多

种结构范式。创新性工作如多模态知识分解<sup>[12]</sup>、子空间增强的图网络<sup>[10]</sup>、细粒度关联挖掘<sup>[13]</sup>等，不断刷新着关键医学任务的性能上限。

因此，本文旨在系统梳理判别学习驱动多模态医学融合的前沿进展；剖析其应对异构性挑战的核心机制；阐述其不同融合层级的创新应用；评估其在早筛、精分、预后等典型医学场景的突破性成效与独特价值；并展望该领域向“认知融合”演进所面临的挑战与未来方向。

## 1 多模态医学数据融合的挑战与判别学习对策

多模态医学数据融合方法作为实现跨模态协同理解与增强诊断效果的核心，主要围绕融合层次和融合策略两个方面展开，其研究不断向更深层次的语义理解和更高效的信息整合发展。当前主流的多模态融合方法可分为特征级融合、决策级融合和混合融合三大类。

特征级融合（Feature-level Fusion）通过在模型输入层或中间层统一不同模态特征，是应对模态对齐与细粒度建模问题的常用策略，

在多模态医学数据融合中应用广泛。然而，其在实际应用中面临三大挑战。首先，模态异质性干扰显著，如医学图像与文本在分布和语义上的差异，易导致特征空间扭曲，降低融合表达的判别性<sup>[14-18]</sup>。对此，对抗判别对齐方法 MMD-GAN<sup>[19]</sup> 引入模态判别器并结合对抗训练，构建模态不变的公共空间，有效缓解对齐偏差。其次，高维拼接引发维度灾难与噪声传播，非结构化文本中冗余信息放大模型干扰。为此，对比解耦约束方法多模态知识蒸馏 MKD<sup>[12]</sup> 通过构建正负样本对比关系，强化协同特征表达，抑制无效噪声，提升鲁棒性与泛化能力。再次，静态融合策略缺乏自适应性，难以动态调控模态权重。对此，动态注意力机制，如 Transformer 中的 Cross-Modal Attention<sup>[20]</sup> 基于输入分布自动调整模态重要性，强化关键病灶与文本语义的关联表达。综上，判别学习在特征级融合中提供了面向异质对齐、噪声抑制与动态建模的有效路径，广泛适用于病灶级分析与影像-文本联合生成等精准医疗场景。

决策级融合 (Decision-level Fusion) 是面向模态预测差异与模型容错的问题应对。该策略通过对各模态独立建模，在输出层整合结果，保留模态特异性，适用于模态异构性强或数据结构差异显著的医学任务。然而，该策略也存在一定的局限性。首先，交互层次较浅，仅在决策阶段融合，难以建模底层语义关联。对此，知识驱动的互蒸馏方法利用高置信度模态引导弱模态优化判别边界，实现隐式特征迁移与语义协同建模<sup>[21]</sup>。其次，融合规则依赖手工设定，缺乏自适应性，难以根据任务动态调整。对此，基于元学习的融合策略，如多核学习中

的 MKL-SVM<sup>[22]</sup> 通过梯度更新或强化学习框架自动优化模态权重或集成规则，提升融合灵活性与泛化能力。最后，决策级融合未考虑置信差异，容错性不足，易被误导。为解决该问题，不确定性感知集成方法贝叶斯融合网络<sup>[23]</sup> 引入预测分布建模与不确定性评估机制，利用判别器动态量化各模态输出的置信程度，并据此调整其融合贡献，提升模型的容错性与鲁棒性。该方法适用于模态缺失或质量不稳定的场景，如跨设备影像分析、多机构模型集成等。

混合融合 (Hybrid Fusion) 用于应对模型复杂度高与时序一致性难的问题，通过结合特征级和决策级的优势，兼顾细粒度交互与全局语义建模，在多模态医学建模中展现出强大表达能力。然而，其也面临多重挑战。首先，模型结构复杂、参数量大，易引发过拟合且推理效率低。为此，轻量化分层蒸馏方法 GeCoA<sup>[24]</sup> 在保留判别信息的同时降低计算开销，缓解过拟合风险。其次，深层交互结构削弱因果可解释性，影响医学诊断透明性。对此，类别激活映射嵌入机制，如 CAM 与 Grad-CAM<sup>[25]</sup>，通过可视化模型关注区域，增强诊断逻辑的可解释性与信任度。最后，模态时序对齐困难，尤其在处理医学影像与生理信号等动态模态时，易因时间不一致导致融合失真。为此，时序注意力机制结合 LSTM 与 Transformer 的全局建模能力<sup>[26]</sup>，引入时间维度上的判别性注意力分配，有效提升模态间的时间一致性与信息联动。上述策略在复杂疾病的多模态联合建模任务中具有显著优势，特别适用于如阿尔茨海默病的 MRI-PET- 临床指标联合分析<sup>[27]</sup>，以及跨尺度医学信息融合任务，如基因-影像-电子病历三

模态整合<sup>[14]</sup>等对模型性能与解释能力均有较高要求的医学应用场景。

三类融合方法各有侧重，特征级融合聚焦细粒度交互，但易受噪声干扰；决策级融合灵活容错，但交互较为粗糙；混合融合通过层次

化设计实现性能突破，但复杂度较高，如表1所示。判别学习方法通过对抗训练、动态注意力、对比约束等策略，分别针对性地优化了模态对齐、噪声抑制与动态交互问题，推动多模态医学融合向高效、鲁棒、可解释的方向演进。

表1 多模态医学数据融合方法的现存问题及判别学习的应对路径

融合类型	核心问题	判别学习的应对路径	代表性技术	适用场景
特征级融合	模态异质性干扰：特征分布差异导致空间扭曲	对抗判别对齐：构建模态不变公共空间	MMD-GAN（最大均值差异生成对抗网络）	病灶级分析（如肿瘤分割）
	高维噪声传播：冗余特征降低鲁棒性	对比解耦约束：强化协同特征，抑制噪声	多模态知识蒸馏（MKD）	影像-文本联合生成（如病理报告生成）
	静态融合策略：缺乏动态权重调整	动态注意力机制：自适应模态权重分配	跨模态 Transformer 注意力	
决策级融合	浅层交互：语义关联建模不足	知识互蒸馏：高置信度模态引导弱模态优化	互蒸馏网络（如临床知识引导）	模态缺失场景（如跨设备影像）
	规则僵化：手工融合缺乏适应性	元学习融合策略：自动化集成规则	多核学习 SVM（MKL-SVM）	多机构模型集成（如分布式诊断系统）
	置信度差异：忽略模态可靠性差异	不确定性感知集成：动态量化模态置信度	贝叶斯融合网络	
混合融合	模型复杂度过高：参数量大导致过拟合	轻量化分层蒸馏：保留判别信息并压缩模型	几何对应注意力（GeCoA）	复杂疾病多模态建模（如阿尔茨海默病 MRI-PET-临床指标分析）
	可解释性弱：深层交互削弱因果逻辑	可解释性嵌入机制：可视化关键特征区域	类别激活映射（Grad-CAM）	跨尺度信息融合（如基因-影像-电子病历整合）
	时序对齐困难：动态模态融合失真	时序注意力机制：全局建模时间一致性	LSTM-Transformer 联合架构	

## 2 判别学习在多模态医学数据融合中的应用和解释

判别学习作为一种机器学习方法，通过学习数据特征来区分不同的类别或样本。在多模态医学数据融合中，判别学习方法能够从多个数据源中提取出更能区分疾病亚型、预测病情进展或辅助诊断的特征，提升融合后的模型准确性和鲁棒性。

### 2.1 判别学习在多模态医学数据融合中的应用

判别学习理论核心在于跨尺度异构信息解耦，最显著的能力在于对异构模态数据之间的

差异进行结构对齐和判别增强。针对 fMRI、sMRI、EEG、基因组数据及病理图像等高度异质模态难以有效对齐特征分布的问题，传统融合策略如早期拼接、联合建模等方法存在固有缺陷，而基于判别学习的方法，如多模态知识分解 MKD<sup>[12]</sup>、多模态交叉尺度聚类 MCCocs<sup>[13]</sup>与子空间增强的图卷积方法 seHGNN<sup>[10]</sup>能够在特征空间中自动识别模态间的共享、冗余与互补结构，从而提升判别边界的清晰度与稳定性。在实际应用中，这类方法已被广泛用于多种关键医学任务，如表2所示。判别学习在癌症预后建模中，通过 MKD 方法融合 RNA-seq、CNV 等组学数据与病理图像，在多个癌种，如

膀胱尿路上皮癌和乳腺癌中，该方法的 C-index 达到 72.6%，显著优于传统 Cox 模型和多模态注意机制模型<sup>[12]</sup>。

在认知障碍筛查方面，图结构引导的特征融合理论得到成功应用。基于图神经网络的模型利用 FBN 与 SBN 结构特征对 rs-fMRI、DTI 和人口学数据进行融合，准确率 (ACC) 达到 90%，曲线下面积 (AUC) 达到 0.9149，表现出对 MCI 人群识别的高精度<sup>[28]</sup>。在精神障碍的多分类任务中，判别学习的核心创新实践体现为细粒度的特征解耦与重组。MCCocs 模型基于体素级的多模态交叉尺度上下文聚类策略，针对 fMRI 与 sMRI 模态进行深度融合，显著提升了对精神分裂症、双相障碍与注意缺

陷多动障碍等疾病的判别能力，优于 SVM、3D-CNN、Vision Transformer 等主流方法<sup>[13]</sup>。针对动态时序模态的融合挑战 (如情绪识别)，跨模态语义对齐与一致性约束理论指导了关键技术创新。CMSLNet 模型将 EEG 与眼动信号相结合，并引入一致性蒸馏策略以提升多模态间协同效果，在 SEED-V 数据集上的情绪识别准确率达 87.32%，显著优于 DCCA 与 AEKM 等对比方法<sup>[19]</sup>。在焦虑症早期识别方面，基于判别性特征空间构建理论，seHGNN 采用子空间增强策略融合 ALFF、ReHo 等 fMRI 参数特征，其单模型准确率达 84.46%，通过模型集成，准确率进一步提升至 90.23%，充分体现了该方法在复杂模态条件下的强大判别能力<sup>[10]</sup>。

表 2 判别学习在典型医学任务中的应用与评估概览

应用任务	融合模态	判别方法 / 策略	评估指标 (效果)	比较
癌症预后建模	RNA-seq+CNV+WSI	MKD+CGM	C-index: 72.6%	优于 CMR; Cox 等
轻度认知障碍筛查	rs-fMRI+DTI+3D-T1+人口学特征	图融合 + 多模态注意机制	AUC: 0.9149, 准确率: 90%	优于 GCN; GAT; MLP 等
精神障碍多分类	fMRI+sMRI	MCCocs	多指标领先 (ACC; SE; SP 等)	优于 SVM; 3D-CNN; ViT
情绪识别	EEG+ 眼动	CMSLNet+ACM + 蒸馏	SEED-V: ACC=87.32%	优于 DCCA; AEKM 等
焦虑症识别	ALFF+ReHo+VBM (fMRI 参数特征)	seHGNN+ 集成	单模型 ACC=84.46%, 集成后提升至 90.23%	优于多种 GNN 变体

从模型构建角度来看，判别学习在融合策略与结构设计上的创新主要体现在融合机制、模态对齐和任务优化三个层面。一方面，通过显式的特征分解 MKD<sup>[12]</sup>、注意力机制，如通道注意 CA 模块<sup>[25]</sup>、双注意 SDA 模块<sup>[15]</sup> 及低秩建模<sup>[29]</sup> 等方式，能够有效缓解冗余信息干扰、突出关键特征，在特征融合过程中实现更强的任务相关性建模；另一方面，在模态结构对齐方面，判别学习引入了自适应模态一致性机制 ACM 模块<sup>[19]</sup>

与多模态子空间映射方法 mCCA-jICA<sup>[30]</sup>，实现了跨模态空间的语义耦合，提升了模型对异构模态间语义一致性的感知能力。此外，判别学习常将分类、回归、生存预测等多任务目标进行统一建模，辅以对抗损失或伪标签蒸馏策略，从而增强模型在弱监督、模态异步或样本分布不均衡情境下的判别鲁棒性。这些机制的集成不仅提升了融合效率和模型性能，也推动了融合策略向结构感知与任务导向方向演进，如表 3 所示。

表3 判别学习相较其他融合策略的能力对比

对比维度	判别学习方法	生成式方法	传统统计方法
模态异构适应能力	强（支持结构对齐）	中（需建模联合分布）	弱（依赖线性协方差）
特征表达的判别性	高（任务导向建模）	中（多为重建导向）	低（需额外分类器）
可解释性	较强（可视化+模态溯源）	弱（多为黑箱结构）	强（线性投影可解释）
模态缺失容忍度	高（支持对抗/蒸馏机制）	中（生成合成模态）	弱（依赖模态完备性）
适用任务类型	多（分类、回归、生存分析）	中（重建类为主）	少（多用于简单分类）
模型训练复杂度	高	高	低

这些数据表明，判别学习方法在多项评估指标（如 ACC、AUC、C-index）上均显著优于传统统计方法（如 CCA、LDA）和深度生成模型（如 VAE、GAN）。此外，由于其结构可解释性较强，模型输出可结合注意热图、通道权重等方式进行视觉可溯源，增强其临床应用的可靠性。

## 2.2 判别学习在多模态数据融合建模的可解释性

在医学人工智能应用中，模型的可解释性不仅关乎技术可用性，更直接影响临床接受度和决策信任度。多模态医学数据融合中的判别学习方法，虽然以任务导向的高性能为优势，但面对模态异质、结构复杂与输出黑箱等挑战，传统方法常缺乏清晰的决策溯源路径。对此，判别学习在多模态建模中通过机制植入与结构表达的协同优化，显著提升了模型的可解释性，特别在特征级、决策级与混合融合三类路径中形成了精准对应的策略体系。

在特征级融合中，为应对模态异质性与冗余信息导致模型可解释性差的问题，判别学习引入多模态知识分解 MKD、置信度驱动的特征重加权<sup>[31]</sup>等机制。通过将融合特征显式划分为共享、独有与冗余成分，MKD 模型不仅提升了

癌症预后建模的准确性，也使得每类信息对判别结果的贡献清晰可追踪<sup>[12]</sup>。GCFA Net 等方法进一步引入特征置信度估计机制，通过高-低置信特征的加权抑制，提升了模型对关键模态区域的关注度和解释力<sup>[31]</sup>。

在决策级融合中，因其交互浅层、融合规则刚性，易形成“输出可见，路径模糊”的黑箱结构。为破解这一难题，判别学习通过互蒸馏机制增强弱模态可判别性，同时结合注意力图与 Grad-CAM 等可视化技术，实现了模型输出与模态结构之间的显式关联。如在急性脑梗死预测和终末期肾病（ESRD）认知障碍研究中，热力图与脑区网络结构图直观展示了模型关注焦点，提升了医生对诊断逻辑的认知信任<sup>[32-33]</sup>。

而在混合融合结构中，由于融合过程贯穿多个网络层级，常伴随结构复杂度上升与因果链条模糊的问题。对此，判别学习结合超图建模与时序注意机制，强化了结构信息在时间轴与语义轴的可追踪能力。例如，HMR 方法通过捕捉脑区间的高阶连接关系，有效提升了终末期肾病导致主观认知能力下降等神经疾病识别任务中的结构解释性<sup>[32]</sup>；而 GeCoA 模型则通过几何对齐蒸馏路径，引导模型在深层融合中保留判别性强的中间表征<sup>[24]</sup>，实现在准确率与解释性之间的有效平衡。

### 3 结论与展望

判别学习作为推动多模态医学数据融合从数据驱动走向任务导向建模的关键路径，已在癌症预后、神经退行性疾病识别和精神障碍分类等场景中展现出优越的判别性能与临床适应性。其在特征选择、模态对齐、冗余抑制和任务优化等方面提供了系统性策略，显著提升了融合模型的准确性、鲁棒性与可解释性，弥补了传统生成式方法和统计模型在处理异构模态时的表达力不足。然而，现有判别学习方法仍面临多重挑战：融合结构日益复杂、建模成本高昂、缺乏统一的可解释机制，以及对模态缺失与数据异步等现实条件适应性不足。这些瓶颈严重制约了其在多中心临床应用中的广泛部署。未来的研究应聚焦于构建轻量化、结构透明、机制统一的判别融合框架，推动其向可扩展、可信赖、通用化的医学智能系统演进。

面向未来，判别学习在多模态医学融合中的发展将呈现知识引导、结构高效与智能可信三大趋势。融合机制将从纯数据驱动迈向医学知识与因果推理赋能，实现语义约束下的结构对齐与判别增强；建模方面，轻量化结构如稀疏 Transformer、可微结构搜索 (Neural Architecture Search, NAS) 将提升在资源受限环境下的适应性；同时，数字孪生等个体化模拟技术将为多模态诊疗提供微观支持。为实现临床落地，判别学习还需强化隐私保护、不确定性感知与可解释机制，构建可验证、可采信的“人机协同”医学智能体系。

#### 参考文献

- [1] ZHANG L, LIN L, LI J. Multi-view clustering by CPS-merge analysis with application to multimodal single-cell data[J]. *PLoS Computational Biology*, 2023, 19(4): e1011044.
- [2] LIPPITT W, CARLSON NE, ARBET J, et al. Limitations of Clustering with PCA and Correlated Noise[J]. *Journal of Statistical Computation and Simulation*, 2024, 94(10): 2291-2319.
- [3] ELKARAMI B, ALKHATEEB A, QATTOUS H, et al. Multi-omics Data Integration Model Based on UMAP Embedding and Convolutional Neural Network[J]. *Cancer Informatics*, 2022(21): 1631216531.
- [4] AKKAYA U M, KALKAN H. A New Approach for Multimodal Usage of Gene Expression and Its Image Representation for the Detection of Alzheimer's Disease[J]. *Biomolecules*, 2023, 13(11): 1563.
- [5] 陈友元. 基于激光诱导击穿光谱与深度学习的癌细胞及组织的判别方法研究 [D]. 成都: 四川大学, 2023.
- [6] 陈亮, 孙卫强, 邓宏勇, 等. 基于属性知识嵌入的 LDA 模型在中药推荐中的应用 [J]. *上海中医药大学学报*, 2024, 38(4): 38-47.
- [7] LI R, YANG J, LI L, et al. Integrating Multilevel Functional Characteristics Reveals Aberrant Neural Patterns during Audiovisual Emotional Processing in Depression[J]. *Cerebral Cortex*, 2021, 32(1): 1-14.
- [8] BI X A, HU X, XIE Y, et al. A novel CERNNE approach for predicting Parkinson's Disease-associated genes and brain regions based on multimodal imaging genetics data[J]. *Medical Image Analysis*, 2021(67): 101830.
- [9] VEDAEI F, MASHHADI N, ALIZADEH M, et al. Deep learning-based multimodality classification of chronic mild traumatic brain injury using resting-state functional MRI and PET imaging[J]. *Frontiers in Neuroscience*, 2023(17): 1333725.
- [10] TANG Y, DING J, CHEN Y, et al. Anxiety disorder identification with biomarker detection through subspace-enhanced hypergraph neural network[J]. *Neural Networks*, 2025(187): 107293.
- [11] GU X, CHEN Y, TONG W. KARAN: Mitigating Feature Heterogeneity and Noise for Efficient and Accurate Multimodal Medical Image Segmentation[J]. *Electronics (Basel)*, 2024, 13(23): 4594.
- [12] ZHOU H, ZHOU F, CHEN H. Cohort-Individual Cooperative Learning for Multimodal Cancer Survival Analysis[J]. *IEEE Transactions on Medical Imaging*, 2025, 44(2): 656-667.
- [13] YANG S, LAN Q, ZHANG L, et al. Multimodal cross-scale context clusters for classification of

- mental disorders using functional and structural MRI[J]. *Neural Networks*, 2025(185): 107209.
- [14] XIE J, ZHONG W, YANG R, et al. Discriminative fusion of moments-aligned latent representation of multimodality medical data[J]. *Physics In Medicine and Biology*, 2023, 69(1): 015015.
- [15] LI W, LIU T, FENG F, et al. BTSSPro: Prompt-Guided Multimodal Co-Learning for Breast Cancer Tumor Segmentation and Survival Prediction[J]. *IEEE Journal of Biomedical and Health Informatics*, 2024, 28(12): 7322-7331.
- [16] ISMAIL W N, RAJEENA P. PF, Ali MAS. MULTforAD: Multimodal MRI Neuroimaging for Alzheimer's Disease Detection Based on a 3D Convolution Model[J]. *Electronics (Basel)*, 2022, 11(23): 3893.
- [17] GUO H, JIAN S, ZHOU Y, et al. Discriminative analysis of schizophrenia patients using an integrated model combining 3D CNN with 2D CNN: A multimodal MR image and connectomics analysis[J]. *Brain Research Bulletin*, 2024(206): 110846.
- [18] ZHOU Q, CHEN T, ZOU H, et al. Uncertainty-aware incomplete multimodal fusion for few-shot Central Retinal Artery Occlusion classification[J]. *Information Fusion*, 2024(104): 102200.
- [19] CHEN C, LI Z, KOU KI, et al. Comprehensive Multisource Learning Network for Cross-Subject Multimodal Emotion Recognition[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2025, 9(1): 365-380.
- [20] SUN H, LIU R, CAI W, et al. Reliable object tracking by multimodal hybrid feature extraction and transformer-based fusion[J]. *Neural Networks*, 2024(178): 106493.
- [21] TU R, ZHANG D, LI C, et al. Multimodal MRI segmentation of key structures for microvascular decompression via knowledge-driven mutual distillation and topological constraints[J]. *International Journal of Computer Assisted Radiology and Surgery*, 2024, 19(7): 1329-1338.
- [22] YI T, LI W, WEI W, et al. Limbic/paralimbic connection weakening in preschool autism-spectrum disorder based on diffusion basis spectrum imaging[J]. *European Journal of Neuroscience*, 2025, 61(1): e16615.
- [23] FENG Z, SUN Y, QIAN L, et al. Design a Novel BCI for Neurorehabilitation Using Concurrent LFP and EEG Features: A Case Study[J]. *IEEE Transactions on Biomedical Engineering*, 2022, 69(5): 1554-1563.
- [24] WANG Y, ZHEN L, TAN TE, et al. Geometric Correspondence-Based Multimodal Learning for Ophthalmic Image Analysis[J]. *IEEE Transactions on Medical Imaging*, 2024, 43(5): 1945-1957.
- [25] ZHAO J, HUANG H, WANG C, et al. Dual contrastive learning for synthesizing unpaired fundus fluorescein angiography from retinal fundus images[J]. *Quantitative Imaging in Medicine and Surgery*, 2024, 14(3): 2193-2212.
- [26] YU Z, YANG X, SWEETING GL, et al. Identify diabetic retinopathy-related clinical concepts and their attributes using transformer-based natural language processing methods[J]. *BMC Medical Informatics and Decision Making*, 2022, 22(Suppl 3): 255.
- [27] LIU F, YUAN S, LI W, et al. Multi-task joint learning network based on adaptive patch pruning for Alzheimer's disease diagnosis and clinical score prediction[J]. *Biomedical Signal Processing and Control*, 2024(95): 106398.
- [28] YUAN Z, HUANG Z, LI C, et al. Multimodal fusion model for diagnosing mild cognitive impairment in unilateral middle cerebral artery steno-occlusive disease[J]. *Frontiers in Aging Neuroscience*, 2025(17): 1527323.
- [29] RAMANARAYANAN S, PALLA A, RAM K, et al. Generalizing supervised deep learning MRI reconstruction to multiple and unseen contrasts using meta-learning hypernetworks[J]. *Applied Soft Computing*, 2023(146): 110633.
- [30] DAI P, SHI Y, ZHOU X, et al. Identification of multimodal brain imaging biomarkers in first-episode drugs-naive major depressive disorder through a multi-site large-scale MRI consortium data[J]. *Journal of Affective Disorders*, 2025(369): 364-372.
- [31] ZHENG X, WANG M, HUANG K, et al. Global and cross-modal feature aggregation for multi-omics data classification and application on drug response prediction [J]. *Information Fusion*, 2024(102): 102077.
- [32] XI Z, LIU T, SHI H, et al. Hypergraph representation of multimodal brain networks for patients with end-stage renal disease associated with mild cognitive impairment[J]. *Mathematical Biosciences and Engineering*, 2023, 20(2): 1882-1902.
- [33] SHETTY S, ANANTHANARAYANA VS, MAHALE A, et al. SMC-CNN: Stacked Multi-Channel Convolution Neural Network for Predicting Acute Brain Infarct from Magnetic Resonance Imaging Sequences[J]. *IEEE Access*, 2024(12): 171112-171142.

(责任编辑:王力)