

MRI与PET融合的阿尔茨海默病诊断综述

秦傲雪¹, 邵 博¹, 杨琳倩¹, 张子琦¹, 李峻源¹, 蔡浩然¹, 卢佳玉¹, 谭伟杰²

¹贵州大学大数据与信息工程学院, 贵州 贵阳

²贵州大学贵州省大数据实验室, 贵州 贵阳

收稿日期: 2026年9月10日; 录用日期: 2026年10月1日; 发布日期: 2026年10月14日

摘 要

本文梳理磁共振成像(MRI)与正电子发射断层成像(PET)多模态融合在阿尔茨海默病(AD)辅助诊断中的进展。检索PubMed、Web of Science、Google Scholar及中文期刊平台2011~2025年发表的文献, 初检420余篇, 纳入23篇代表性研究, 按数据与预处理、特征表征、融合层级和缺失模态学习归纳。MRI与PET提供结构-代谢互补信息, 但示踪剂对应不同生物学过程, 不宜未分层合并评价; 基于深度学习的特征级融合(双编码器、共享潜空间、交叉注意力)为主流策略; PET缺失时, 知识蒸馏与模态掩码可规避生成式补全的伪病理风险; 多数高准确率来自单一队列小样本, 受试者级划分与独立验证不足。MRI/PET融合有助于AD早期识别、认知正常(CN)与轻度认知障碍(MCI)分类及MCI转化预测, 但受制于样本量与外部验证不足, 应发展域自适应融合、纵向个体化预测与不确定性感知的模态补全, 并按FDG、 $A\beta$ 与Tau分层报告结果。

关键词

阿尔茨海默病, 磁共振成像, 正电子发射断层成像, 多模态融合, 深度学习

A Review of MRI-PET Fusion for Alzheimer's Disease Diagnosis

Aoxue Qin¹, Bo Shao¹, Linqian Yang¹, Ziqi Zhang¹, Lengyuan Li¹, Haoran Cai¹, Jiayu Lu¹, Weijie Tan²

¹College of Big Data and Information Engineering, Guizhou University, Guiyang Guizhou

²Guizhou Provincial Key Laboratory of Big Data, Guizhou University, Guiyang Guizhou

Received: September 10, 2026; accepted: October 1, 2026; published: October 14, 2026

Abstract

This review examines the progress of magnetic resonance imaging (MRI) and positron emission

文章引用: 秦傲雪, 邵博, 杨琳倩, 张子琦, 李峻源, 蔡浩然, 卢佳玉, 谭伟杰. MRI 与 PET 融合的阿尔茨海默病诊断综述[J]. 图像与信号处理, 2026, 15(4): 470-478. DOI: 10.12677/jisp.2026.154042

tomography (PET) multimodal fusion in the assisted diagnosis of Alzheimer's disease (AD). The literature published between 2011 and 2025 was searched in PubMed, Web of Science, Google Scholar, and Chinese-language journal platforms; more than 420 records were identified initially, and 23 representative studies were retained after screening. The evidence was organized by data and preprocessing, feature representation, fusion level, and missing-modality learning. MRI and PET provide complementary structural-metabolic information, but their tracers reflect distinct biological processes and should not be pooled without stratification; deep learning-based feature-level fusion through dual encoders, shared latent spaces, and cross-attention is the main-stream strategy; when PET is missing, knowledge distillation and modality masking avoid the pseudo-pathological risk of generative completion; and most high accuracies come from small samples in a single cohort, with subject-level splitting and independent validation remaining insufficient. MRI/PET fusion facilitates early AD identification, the classification of cognitively normal (CN), mild cognitive impairment (MCI), and AD, and MCI conversion prediction, but it is constrained by limited sample sizes and insufficient external validation; domain-adaptive fusion, longitudinal individualized prediction, and uncertainty-aware modality completion should therefore be developed, and results should be reported stratified by FDG, A β , and tau tracer.

Keywords

Alzheimer's Disease, Magnetic Resonance Imaging, Positron Emission Tomography, Multimodal Fusion, 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

阿尔茨海默病(Alzheimer's disease, AD)的病理改变可早于典型临床症状出现。轻度认知障碍(mild cognitive impairment, MCI)位于正常老化与痴呆之间,但并非所有 MCI 患者都会进展为 AD。2018 年提出的 NIA-AA 研究框架强调以淀粉样蛋白、Tau 和神经退行性改变描述 AD 生物学连续谱[1],使影像标志物在早期识别和分期中的作用进一步突出。

结构磁共振成像(magnetic resonance imaging, MRI)可测量灰质体积、皮层厚度和海马萎缩等解剖改变[2],具有空间分辨率高、无电离辐射的特点;正电子发射断层成像(positron emission tomography, PET)可通过 18F-氟脱氧葡萄糖反映脑葡萄糖代谢,或使用淀粉样蛋白、Tau 示踪剂观察分子病理[3]。两类影像的互补性为 AD 多阶段分类提供了结构-功能-病理联合证据。

传统研究主要依赖感兴趣区(region of interest, ROI)统计特征和浅层分类器。随着深度学习发展,多模态方法已拓展至三维卷积神经网络(3D convolutional neural network, 3D CNN)、堆叠式自编码器、注意力模型、Transformer、图神经网络及生成模型。已有综述肯定了 MRI/PET 融合潜力,同时指出样本量有限、异质性强和外部验证不足仍阻碍临床转化[4][5]。然而,这些综述多聚焦于融合方法的分类或准确率比较,较少关注示踪剂生物学差异对任务定义的影响、数据泄漏风险对结果可信度的侵蚀,以及缺失模态策略之间的系统比较。

本文以公开发表研究为基础,从数据与预处理、特征表征、融合层级、缺失模态学习和评价规范等方面展开归纳,着重审查各研究在实验设计上的可比性,而非简单比较不同队列、不同任务的最高准确率,以期后续研究提供方法学参考。

2. 方法

2.1. 文献检索与纳入原则

以 “Alzheimer’s disease” “MRI” “PET” “multimodal fusion” “deep learning” “missing modality” 及对应中文词为检索词，检索 PubMed、Web of Science、Google Scholar 和中文期刊平台中 2011~2025 年正式发表的研究(检索截至 2025 年 6 月)。初检获得文献 420 余篇，经标题和摘要筛选排除综述、会议摘要、预印本及与神经影像诊断关联较弱者，全文阅读后纳入 23 篇代表性研究。纳入标准为：研究对象包含 AD、MCI 或认知正常人群；至少使用 MRI 或 PET，重点纳入成对 MRI/PET 或缺失模态研究；报告分类、分期、MCI 转化或相关辅助诊断任务；方法与评价信息较完整。排除仅有摘要、重复发表、无法核实来源的研究。

2.2. 信息提取与分类框架

从纳入研究中提取数据来源、样本划分、影像模态、PET 示踪剂、预处理、输入表征、融合层级、分类任务和评价指标。方法按照数据级、特征级和决策级融合分类；对不完整数据进一步区分统计填补、跨模态生成、模态掩码和知识蒸馏。结果分析同时关注准确率、敏感度、特异度、F1 值和受试者工作特征曲线下面积(area under the receiver operating characteristic curve, AUC)，并审查是否采用受试者等级划分和独立队列测试。

3. 结果

3.1. 数据资源与影像互补性

阿尔茨海默病神经影像学倡议(Alzheimer’s Disease Neuroimaging Initiative, ADNI)是使用最广泛的纵向多中心队列，提供 MRI、FDG-PET、淀粉样蛋白 PET、Tau-PET、认知量表、遗传和体液标志物[6]。

开放获取系列影像研究(Open Access Series of Imaging Studies, OASIS) [7]；澳大利亚影像、生物标志物与生活方式研究(Australian Imaging, Biomarkers and Lifestyle, AIBL)包含 MRI、PET 与生物标志物，可作为跨队列验证的重要补充[8]。队列之间在扫描设备、诊断标准、人群结构和随访时间方面的差异，既构成域偏移，也为检验泛化能力提供条件。此外，NACC 等临床队列虽异质性较强，却可提供真实世界验证场景(表 1)。上述队列在扫描设备(1.5 T vs 3 T MRI)、诊断标准和随访时间上的差异，使得跨队列迁移时性能下降成为普遍现象。

Table 1. Common data resources for multimodal AD studies

表 1. AD 多模态研究常用数据资源

数据资源	主要数据	典型任务	优势	主要限制
ADNI	MRI、FDG/A β /Tau-PET、CSF、量表、遗传	CN/MCI/AD 分类、MCI 转化	纵向、多中心、模态丰富	PET 缺失及阶段差异明显
OASIS	MRI 为主，部分队列含 PET 和临床资料	正常老化、认知下降、痴呆	开放性高、年龄跨度较大	成对 MRI/PET 相对较少
AIBL	MRI、PET、认知与生物标志物	A β 状态、MCI 和 AD 识别	适合独立队列验证	样本与访问条件有限
NACC 等临床队列	临床、神经心理与影像子集	痴呆鉴别、真实世界验证	临床异质性较强	协议和缺失模式复杂

3.2. 不同 PET 示踪剂的融合任务特点

不同 PET 示踪剂对应 AD 连续谱中的不同生物学过程，不能被视为同质输入或可互换的预测目标。

融合设计应首先明确 PET 提供的是神经退行性、淀粉样蛋白还是 Tau 证据,并据此选择任务标签、时间窗和评价指标。

FDG-PET: 反映脑葡萄糖代谢和突触功能异常,是文献中最常用的 PET 模态。其与 MRI 萎缩模式的互补性已在多项研究中得到验证:后扣带回和楔前叶的代谢低下常早于结构萎缩出现,使 FDG-PET 在 MCI 转化预测中具有独特价值。然而,代谢低下并非 AD 特异——路易体痴呆和额颞叶痴呆同样表现为 FDG 摄取降低,这要求融合模型在多分类任务中谨慎区分。此外,血糖水平、注射后采集时间和重建协议差异可能引入系统性偏倚,跨中心验证时尤其需要校准参考区。

淀粉样蛋白 PET: 提供 $A\beta$ 病理负荷,适合 A/T/N 分型和临床前期风险分层。由于 $A\beta$ 沉积可早于明显萎缩十余年,任务设计不应将 PET 阳性简单等同于临床痴呆。这一模态已有大量综述覆盖,本文仅指出一个实际问题:不同示踪剂(如 PiB、Florbetapir、Flutemetamol)的量表可比性尚未完全统一,部分容积效应和阈值定义的差异使得跨研究比较存在困难。融合时可将 MRI 作为疾病阶段与神经退行性背景,检验模型是否真正利用 $A\beta$ 沉积与萎缩之间的时间错位信息。

Tau-PET: 更接近神经元纤维缠结的区域分布,与症状严重度和局部萎缩通常具有更直接的空间对应。这使得 Tau-PET 在疾病分期和进展速度预测方面颇具前景。但其应用仍面临若干前沿争议:离靶结合(如脉络丛和黑质的非特异性摄取)可能干扰融合模型的区域特征提取;第一代(Flortaucipir)与第二代(PI-2620, MK-6240)示踪剂的结合特性差异,使得基于不同代际示踪剂训练的模型不可直接比较。目前 Tau-PET 的纵向重复扫描数据仍然有限,融合评价应以空间对应性和外部队列泛化为主,而非仅报告分类准确率。

基于上述差异,FDG、 $A\beta$ 和 Tau 融合研究不宜在未分层的情况下合并报告;至少应按示踪剂、任务阶段和标签定义报告结果,并比较单模态、双模态及示踪剂特异基线。

3.3. 预处理与特征表征

3.3.1. 预处理流程

多模态融合首先要求统一空间。T1 加权 MRI 通常经过偏置场校正、去颅骨、组织分割和模板配准;PET 需进行运动与衰减校正,再刚性配准到同一受试者 MRI,并依据参考区域计算标准摄取值比。任何自动流程均应结合可视化质量控制,排除明显畸变、覆盖不完整和错误分割。若同一受试者具有多个随访时间点,数据集划分必须以受试者为单位,避免纵向扫描跨越训练集和测试集。

3.3.2. 特征表征

ROI 表征利用解剖图谱提取灰质体积、皮层厚度或脑区平均 PET 摄取值,能够降低维度并提供脑区解释。Zhang 等[9]将 MRI、PET 和脑脊液标志物进行多核融合,在 ADNI 队列上验证了多模态信息相较于单模态的互补优势,这也是较早系统比较多模态增益的工作之一。ROI 特征的局限在于依赖图谱质量,且无法捕捉脑区内部的局部纹理变化。

体素和图像级表征保留局部细节,3D CNN 可直接学习三维空间模式,但参数量和显存开销较大;2D 切片模型可借助自然图像预训练,却可能损失跨切片关系。Wen 等[10]对 ADNI 上的 CNN 分类方法进行了系统性复现实验,发现当统一预处理、受试者等级划分和基线控制后,部分方法报告的高准确率出现 3~8 个百分点的下降,提示不规范实验设计对结果的乐观偏倚不容忽视。

3.4. 多模态融合方法

3.4.1. 数据级融合

数据级融合将空间对齐后的 MRI 与 PET 作为不同通道输入,或通过小波变换等方式生成融合图像。

该方法结构直接,但 MRI 和 PET 在物理意义、强度范围、空间分辨率和噪声分布上差异明显。若配准存在偏差,低层拼接会把错误对应传递至后续网络。在配准质量较高、成对样本充足且模态预处理一致条件下,数据级融合仍可作为基线方案。

3.4.2. 特征级融合

特征级融合是当前 MRI/PET 多模态研究的主流策略。其核心思路是通过双分支网络分别编码 MRI 和 PET 的模态特有信息,再在特征空间建立交互。Suk 等[11]较早将深度玻尔兹曼机引入该框架,提升至 95.35%,较单模态 MRI (92.38%)与 PET (92.20%)提高约 3 个百分点,验证了深度特征相较于手工 ROI 特征的增益。此后,Zhou 等[12]提出阶段式深度网络,先学习单模态表征,再利用不同模态组合逐级融合,从而能够使用具有不同模态可用性的样本——这一设计的关键贡献在于,它避免了为每位受试者强制补全所有模态,同时强调了按受试者划分交叉验证的重要性。

近年来的 3D CNN 与 Transformer 组合利用卷积提取局部结构,以自注意力建模跨脑区全局关系。Tang 等[13]的可视化结果显示,海马旁回等内侧颞叶区域对分类贡献较高,与神经病理学已知敏感区一致。Abdelaziz 等[14]进一步提出多尺度方法,通过自注意力和交叉注意力融合不同空间尺度及不同模态,在保留全脑背景的同时关注局部病变。不过,这类复杂结构在成对样本不足 300 对的小队列中存在过拟合风险,双编码器的参数量远超单模态基线,未必优于简单的 ROI 特征拼接。

基于 ROI 的堆叠式自编码器在小样本场景中仍有价值。以解剖图谱定义的脑区体积和 PET 平均摄取值为输入,逐层贪婪预训练可学习共享潜空间;通过对某一模态施加随机零掩码,编码器被迫利用另一模态恢复互补信息,从而在不显式生成缺失数据的前提下提升鲁棒性。这一策略的优势在于计算开销低且可解释性强,但其有效性依赖于脑区划分的准确性,且对部分容积效应敏感。

3.4.3. 决策级融合与多任务学习

决策级融合分别训练 MRI 与 PET 分类器,再对类别概率加权或集成。其模块化特性使得模态缺失时易于降级运行,但跨模态交互仅发生在输出端,限制了低层和中层信息融合。Thung 等[15]构建多输入多输出网络,使不同模态组合对应的子任务共享参数,在 MRI 完整而 PET 不完整的数据中实现多阶段诊断,无需为每位受试者强制补全所有模态。多任务学习可联合 CN/MCI/AD 分类、认知量表回归和 MCI 转化预测,共享疾病进程表征;当任务噪声和难度差异较大时,动态调整损失权重以减少负迁移是一个尚未完全解决的问题。

3.5. 缺失模态学习

在真实临床场景中,PET 缺失是常态而非例外——受限于成本和辐射暴露,相当比例的受试者仅有 MRI。如何利用不完整数据提升诊断性能,已成为近年来的研究热点。

Li 等[16]较早利用 3D CNN 从 MRI 估计缺失 PET,证明了跨模态映射能够扩大可用样本量。该方法的关键不在于合成影像的视觉相似度,而在于是否保持了疾病相关的区域差异——Li 等的研究表明,即使合成 PET 在视觉上较为模糊,将其与真实 MRI 共同输入分类器仍可改善性能,因为网络主要利用的是跨模态的统计依赖关系而非像素级细节。Pan 等[17]采用三维循环一致生成对抗网络学习 MRI 与 PET 之间的映射,并将合成 PET 与真实 MRI 共同用于多实例诊断和 MCI 转化预测;Lin 等[18]进一步以三维可逆生成对抗网络实现双向映射,减少生成器数量。

知识蒸馏提供了不显式生成 PET 的替代方案。多模态教师将共享疾病知识迁移至单模态学生,使其在仅有 MRI 时仍可获得接近双模态的性能。Kwak 等[19]于 2025 年提出跨模态互知识蒸馏框架,报告了在不同模态可用性的患者亚组中稳定的性能提升。值得注意的是,该框架中教师与学生之间的蒸馏是双

向的——学生的单模态表征也反馈至教师，形成互学习机制。这类方法避免了合成影像的伦理和可靠性争议，但仍依赖于高质量的多模态教师模型和概率校准。

3.6. 代表性研究的综合比较

为便于比较，表 2 汇总了代表性研究在融合方式、典型实现、优势和局限方面的差异。从表中可以看出，特征级融合在完整模态场景下性能上限较高，但模型复杂度也最大；生成补全和蒸馏/掩码策略则面向 PET 缺失的真实场景，分别以牺牲影像保真度和依赖教师模型为代价换取数据利用率提升。

在国内研究方面，张烁等[20]以双分支 3D-ResNeXt 提取高层特征并进行多模态融合，针对 CN、MCI 与 AD 三分类开展辅助诊断，体现了三维表征在中文医学影像研究中的应用。Rallabandi 等[21]在多个二分类任务中报告了较高准确率，但不同工作在样本量(58~370 对)、划分比例和图像融合方式上差异明显，直接比较准确率的意义有限。一项 2025 年的多视角多模态研究[22]进一步指出，数据稀缺、类别不平衡和跨机构异质性仍是主要瓶颈。

Table 2. Applicability of MRI-PET fusion strategies
表 2. MRI/PET 融合策略的适用性比较

融合方式	典型实现	优势	局限	适用场景
数据级	通道堆叠、融合图像	结构简单、端到端	易传播配准误差和强度差异	成对影像质量高
特征级	双编码器、共享潜空间、交叉注意力	互补交互充分、性能上限较高	复杂且易过拟合	完整 MRI/PET 为主
决策级	概率加权、投票、集成	模块化、便于降级	深层交互不足	模态可用性不固定
生成补全	CNN、GAN、扩散模型	可利用缺失 PET 病例	可能产生伪病理信息	MRI 可用而 PET 缺失
蒸馏/掩码	教师 - 学生、模态丢弃	无需输出合成影像	依赖教师并需校准	面向真实不完整模态

4. 讨论

4.1. 结果可比性与数据泄漏

AD 与认知正常对照之间的差异较明显，二分类结果通常高于 CN/MCI/AD 三分类及稳定 MCI 与进展 MCI 鉴别。Pellegrini 等[23]对 2018 年前发表的 111 篇神经影像机器学习研究进行系统综述，发现多数研究依赖 ADNI 等单一队列，部分研究还将同期认知测验结果纳入算法，分类准确率可能被高估。

在本文纳入的研究中，受试者等级划分和外部验证的执行情况同样参差不齐。部分研究仅在 ADNI 上进行五折或十折交叉验证，未使用 AIBL 或 OASIS 进行独立测试；部分研究虽报告了准确率，但未给出敏感度、特异度、F1 值、AUC 及 95%置信区间，难以评估分类的平衡性。模型间比较若未统一诊断标签、PET 示踪剂、预处理和测试集合，其准确率差异可能主要反映实验设计而非方法本身。

4.2. 多中心异质性与临床泛化

扫描设备、磁场强度、重建核、PET 示踪剂、参考区和人群构成都会引起域偏移。在 ADNI 与 AIBL 之间，MRI 扫描仪厂商和磁场强度(1.5 T vs 3 T)的差异已被证实可导致灰质体积估计的系统性偏移；PET 示踪剂和重建协议的差异则进一步叠加。ComBat 等统计协调方法最初用于基因组学跨批次校正，在神经影像中的应用表明，它能在保留疾病效应的同时降低中心间方差，但过度协调可能同时削弱真实的疾病信号——尤其是当疾病组与对照组在各中心的分布不均衡时。域对抗学习通过在特征空间中消除中心标识信息实现适配，其优势在于不修改原始影像，但训练不稳定且对目标域标签的依赖程度尚有争议。

从实践角度看,中心留一验证(leave-one-center-out)或 ADNI 训练、AIBL/OASIS 测试是目前评估泛化能力较为可行的方案。然而,现有研究中采用此类设计的仍属少数,且按年龄、性别、教育程度和疾病严重程度等亚组分层报告者更为罕见,致使模型在特定人群中的可靠性难以判断。

4.3. 可解释性

多模态模型的解释不应停留在“模型关注了哪些脑区”,还应回答“每一模态贡献了多少、何时发生互补、何时只是重复或冲突”。注意力权重是最常用的可解释性工具,但它不能自动等同于因果解释——例如,一个融合模型可能将高注意力权重分配给脑室扩大区域(因其在 MRI 上对比度显著),而实际诊断信息却来自 PET 代谢下降。因此,注意力结果仍与海马、内嗅皮层、后扣带回和颞顶叶等已知敏感区域进行一致性分析,并检验其对配准扰动和随机初始化的稳定性,才具有参考价值。

在模态贡献层面,模态消融和分支级集成梯度是两种较为实用的方法:前者通过移除某一模态观察预测变化,后者量化各分支对最终决策的梯度贡献。将两者结合,可以在总体与个体两个层面区分 MRI 独有、PET 独有及两者协同的证据。对于协同与冗余信息,跨模态相似性矩阵和脑区级交互图可提供直观的可视化,但这类方法在 MRI/PET 融合文献中的应用仍处于早期阶段。

4.4. 不确定性量化与临床决策

当两模态结论冲突、PET 缺失、图像质量较差或输入偏离训练分布时,模型仅给出类别标签远远不够——临床决策需要知道预测本身有多可信。模态级置信度和校准后的预测概率是两个关键输出:前者标识信息来源的可靠性,后者衡量预测概率与真实频率的一致性。温度缩放等校准方法在自然图像分类中已较为成熟,但在医学影像多模态场景中仍缺乏系统验证。一个理想的系统应在高不确定性时主动拒绝预测或提示人工复核,而非强行给出可能误导的分类结果。

4.5. 未来研究方向

基于上述讨论,未来研究可沿三个方向推进。第一,域自适应与扫描协议泛化。核心问题在于区分设备/协议差异与真实疾病效应:统计协调、域对抗、测试时适配和域泛化各有适用条件,比较时采用中心留一及独立队列验证,并报告分中心与分示踪剂性能,比单纯在单一队列上追求高准确率更有意义。

第二,纵向个体化预测。横断面 CN/MCI/AD 标签将连续病程离散化,难以反映个体进展速度。将多时间点 MRI/PET 与认知轨迹、APOE 等遗传信息结合,通过时序模型或联合纵向-生存模型预测转化时间,并以时间依赖 AUC 和个体风险误差评价,可能更贴近临床实际需求。这一方向的技术选择包括循环神经网络、Transformer 时序编码器以及生存分析模型,但成对纵向 MRI/PET 数据的稀缺是主要瓶颈。

第三,不确定性感知的缺失 PET 补全。针对 PET 缺失场景,一个兼顾生成保真度和下游诊断性能的补全框架,其训练目标应联合体素/结构相似性、脑区摄取值一致性和诊断损失;测试时同时报告生成不确定性和预测校准度,并与零掩码和知识蒸馏等非生成方案进行公平比较。若采用扩散模型等生成组件,还需通过独立消融明确其对区域病理保持和最终诊断的增量贡献,避免以视觉上逼真的合成影像替代临床有效性证据。

5. 结论

MRI 与 PET 分别从脑结构和代谢或分子病理层面描述 AD,多模态特征学习可为 CN、MCI 和 AD 分类及转化预测提供互补证据。现有方法已由 ROI 特征和浅层融合发展至 3D CNN、深度玻尔兹曼机、Transformer、多尺度注意力、生成补全和知识蒸馏。特征级融合具有较强的跨模态交互能力;生成式补全和蒸馏为 PET 缺失提供了可行路径。未来研究应沿三条可检验路径推进:构建能够适应中心、扫描仪、

采集与重建协议差异的域自适应融合模型；联合静态影像、纵向临床量表和基因信息开展个体化进展预测；面向 PET 缺失建立同时优化图像保真度、区域病理一致性和下游诊断性能、并输出校准不确定性的补全框架。与此同时，结果需按 FDG、 $A\beta$ 与 Tau 示踪剂分层，报告模态贡献、协同与冗余证据以及受试者级外部验证，以推动 MRI/PET 融合模型向可信临床辅助诊断转化。

基金项目

2025 年贵州大学创新创业训练计划项目(项目编号 gzusc2025026)。

参考文献

- [1] Jack, C.R., Bennett, D.A., Blennow, K., Carrillo, M.C., Dunn, B., Haeberlein, S.B., *et al.* (2018) NIA-AA Research Framework: Toward a Biological Definition of Alzheimer's Disease. *Alzheimer's & Dementia*, **14**, 535-562. <https://doi.org/10.1016/j.jalz.2018.02.018>
- [2] Frisoni, G.B., Fox, N.C., Jack, C.R., Scheltens, P. and Thompson, P.M. (2010) The Clinical Use of Structural MRI in Alzheimer Disease. *Nature Reviews Neurology*, **6**, 67-77. <https://doi.org/10.1038/nrneurol.2009.215>
- [3] Johnson, K.A., Minoshima, S., Bohnen, N.I., *et al.* (2013) Appropriate Use Criteria for Amyloid PET: A Report of the Amyloid Imaging Task Force, the Society of Nuclear Medicine and Molecular Imaging, and the Alzheimer's Association. *Alzheimer's & Dementia*, **9**, e1-e16. <https://doi.org/10.1016/j.jalz.2013.01.002>
- [4] Christodoulou, R., Woodward, A., Pitsillos, R., Ibrahim, R. and Georgiou, M. (2025) Artificial Intelligence in Alzheimer's Disease Diagnosis and Prognosis Using PET-MRI: A Narrative Review of High-Impact Literature Post-Tauvid Approval. *Journal of Clinical Medicine*, **14**, Article 5913. <https://doi.org/10.3390/jcm14165913>
- [5] Zhang, R., Sheng, J., Zhang, Q., Wang, J. and Wang, B. (2025) A Review of Multimodal Fusion-Based Deep Learning for Alzheimer's Disease. *Neuroscience*, **576**, 80-95. <https://doi.org/10.1016/j.neuroscience.2025.04.035>
- [6] Weiner, M.W., Veitch, D.P., Aisen, P.S., Beckett, L.A., Cairns, N.J., Green, R.C., *et al.* (2013) The Alzheimer's Disease Neuroimaging Initiative: A Review of Papers Published since Its Inception. *Alzheimer's & Dementia*, **9**, e111-e194. <https://doi.org/10.1016/j.jalz.2013.05.1769>
- [7] Marcus, D.S., Wang, T.H., Parker, J., Csernansky, J.G., Morris, J.C. and Buckner, R.L. (2007) Open Access Series of Imaging Studies (OASIS): Cross-Sectional MRI Data in Young, Middle Aged, Nondemented, and Demented Older Adults. *Journal of Cognitive Neuroscience*, **19**, 1498-1507. <https://doi.org/10.1162/jocn.2007.19.9.1498>
- [8] Ellis, K.A., Bush, A.I., Darby, D., De Fazio, D., Foster, J., Hudson, P., *et al.* (2009) The Australian Imaging, Biomarkers and Lifestyle (AIBL) Study of Aging: Methodology and Baseline Characteristics of 1112 Individuals Recruited for a Longitudinal Study of Alzheimer's Disease. *International Psychogeriatrics*, **21**, 672-687. <https://doi.org/10.1017/s1041610209009405>
- [9] Zhang, D., Wang, Y., Zhou, L., Yuan, H. and Shen, D. (2011) Multimodal Classification of Alzheimer's Disease and Mild Cognitive Impairment. *NeuroImage*, **55**, 856-867. <https://doi.org/10.1016/j.neuroimage.2011.01.008>
- [10] Wen, J., Thibau-Sutre, E., Diaz-Melo, M., Samper-González, J., Routier, A., Bottani, S., *et al.* (2020) Convolutional Neural Networks for Classification of Alzheimer's Disease: Overview and Reproducible Evaluation. *Medical Image Analysis*, **63**, Article 101694. <https://doi.org/10.1016/j.media.2020.101694>
- [11] Suk, H.I., Lee, S.W. and Shen, D. (2014) Hierarchical Feature Representation and Multimodal Fusion with Deep Learning for AD/MCI Diagnosis. *NeuroImage*, **101**, 569-582. <https://doi.org/10.1016/j.neuroimage.2014.06.077>
- [12] Zhou, T., Thung, K.H., Zhu, X. and Shen, D. (2019) Effective Feature Learning and Fusion of Multimodality Data Using Stage-Wise Deep Neural Network for Dementia Diagnosis. *Human Brain Mapping*, **40**, 1001-1016. <https://doi.org/10.1002/hbm.24428>
- [13] Tang, Y., Xiong, X., Tong, G., Yang, Y. and Zhang, H. (2024) Multimodal Diagnosis Model of Alzheimer's Disease Based on Improved Transformer. *BioMedical Engineering OnLine*, **23**, Article No. 8. <https://doi.org/10.1186/s12938-024-01204-4>
- [14] Abdelaziz, M., Wang, T., Anwaar, W. and Elazab, A. (2025) Multi-Scale Multimodal Deep Learning Framework for Alzheimer's Disease Diagnosis. *Computers in Biology and Medicine*, **184**, Article 109438. <https://doi.org/10.1016/j.compbiomed.2024.109438>
- [15] Thung, K., Yap, P. and Shen, D. (2017) Multi-Stage Diagnosis of Alzheimer's Disease with Incomplete Multimodal Data via Multi-Task Deep Learning. In: Cardoso, M., *et al.*, Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 160-168. https://doi.org/10.1007/978-3-319-67558-9_19

-
- [16] Li, R., Zhang, W., Suk, H., Wang, L., Li, J., Shen, D., *et al.* (2014) Deep Learning Based Imaging Data Completion for Improved Brain Disease Diagnosis. In: Golland, P., Hata, N., Barillot, C., Hornegger, J. and Howe, R., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 305-312. https://doi.org/10.1007/978-3-319-10443-0_39
- [17] Pan, Y., Liu, M., Lian, C., Zhou, T., Xia, Y. and Shen, D. (2018) Synthesizing Missing PET from MRI with Cycle-Consistent Generative Adversarial Networks for Alzheimer's Disease Diagnosis. In: Frangi, A., Schnabel, J., Davatzikos, C., Alberola-López, C. and Fichtinger, G., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 455-463. https://doi.org/10.1007/978-3-030-00931-1_52
- [18] Lin, W., Lin, W., Chen, G., Zhang, H., Gao, Q., Huang, Y., *et al.* (2021) Bidirectional Mapping of Brain MRI and PET with 3D Reversible GAN for the Diagnosis of Alzheimer's Disease. *Frontiers in Neuroscience*, **15**, Article ID: 646013. <https://doi.org/10.3389/fnins.2021.646013>
- [19] Kwak, M.G., Mao, L., Zheng, Z., Su, Y., Lure, F. and Li, J. (2025) A Cross-Modal Mutual Knowledge Distillation Framework for Alzheimer's Disease Diagnosis: Addressing Incomplete Modalities. *IEEE Transactions on Automation Science and Engineering*, **22**, 14218-14233. <https://doi.org/10.1109/tase.2025.3556290>
- [20] 张烁, 张荣, 郭颖婕, 余红梅. 基于 3D 残差网络的阿尔茨海默病辅助诊断模型研究[J]. 中国卫生统计, 2024, 41(6): 883-888, 892.
- [21] Subramanyam Rallabandi, V.P. and Seetharaman, K. (2023) Deep Learning-Based Classification of Healthy Aging Controls, Mild Cognitive Impairment and Alzheimer's Disease Using Fusion of MRI-PET Imaging. *Biomedical Signal Processing and Control*, **80**, Article 104312. <https://doi.org/10.1016/j.bspc.2022.104312>
- [22] Feng, J., Zhao, X., Liu, Z., Ding, Y. and Wang, F. (2025) A Multi-View Multimodal Deep Learning Framework for Alzheimer's Disease Diagnosis. *Frontiers in Neuroscience*, **19**, Article ID: 1658776. <https://doi.org/10.3389/fnins.2025.1658776>
- [23] Pellegrini, E., Ballerini, L., Hernandez, M.d.C.V., Chappell, F.M., González-Castro, V., Anblagan, D., *et al.* (2018) Machine Learning of Neuroimaging for Assisted Diagnosis of Cognitive Impairment and Dementia: A Systematic Review. *Alzheimer's & Dementia: Diagnosis, Assessment & Disease Monitoring*, **10**, 519-535. <https://doi.org/10.1016/j.dadm.2018.07.004>