

基于深度学习的阿尔茨海默病结构影像组学研究进展

高希春*, 刘国标, 黎浩良, 黄慈花, 许剑涛, 黄伟刚, 陈弘, 张建波, 谭志坚, 成程
广州市荔湾中心医院放射科, 广东 广州

收稿日期: 2025年9月23日; 录用日期: 2025年10月16日; 发布日期: 2025年10月24日

摘要

阿尔茨海默病(AD)作为全球范围内最常见的神经退行性疾病之一, 其早期诊断和治疗对改善患者生活质量至关重要。近年来, 深度学习(DL)技术的快速发展为AD的结构影像组学研究提供了新的机遇。本文通过系统检索PubMed、Web of Science、中国知网(CNKI)等数据库中2018~2024年发表的相关文献, 以“深度学习”“阿尔茨海默病”“结构磁共振成像”“影像组学”为核心关键词, 筛选出高质量研究文献82篇, 其中英文文献68篇、中文文献14篇, 重点分析基于深度学习技术在AD结构影像组学领域的多模态脑连接组信息融合、早期认知障碍检测及多阶段AD诊断的最新技术和成果。同时, 系统梳理不同深度学习架构在AD风险预测、轻度认知障碍(MCI)识别和AD患者分类中的应用, 指出当前研究面临的挑战并提出未来发展方向。旨在为相关领域研究者提供理论支持和技术参考, 推动基于结构影像组学的AD智能诊断技术发展。

关键词

深度学习, 阿尔茨海默病, 结构磁共振成像, 影像组学, 脑连接组, 轻度认知障碍

Research Progress on Structural Radiomics of Alzheimer's Disease Based on Deep Learning

Xichun Gao*, Guobiao Liu, Haoliang Li, Cihua Huang, Jiantao Xu, Weigang Huang, Hong Cheng, Jianbo Zhang, Zhijian Tan, Cheng Cheng

Department of Radiology, Liwan Central Hospital of Guangzhou, Guangzhou Guangdong

Received: September 23, 2025; accepted: October 16, 2025; published: October 24, 2025

*通讯作者。

文章引用: 高希春, 刘国标, 黎浩良, 黄慈花, 许剑涛, 黄伟刚, 陈弘, 张建波, 谭志坚, 成程. 基于深度学习的阿尔茨海默病结构影像组学研究进展[J]. 临床医学进展, 2025, 15(10): 2317-2325. DOI: 10.12677/acm.2025.15103015

Abstract

Alzheimer's disease (AD) is one of the most common neurodegenerative diseases worldwide, and its early diagnosis and treatment are crucial for improving patients' quality of life. In recent years, the rapid development of deep learning (DL) technology has provided new opportunities for structural radiomics research of AD. In this study, relevant literatures published from 2018 to 2024 were systematically searched in databases such as PubMed, Web of Science, and China National Knowledge Infrastructure (CNKI), with "deep learning", "Alzheimer's disease", "structural magnetic resonance imaging", and "radiomics" as core keywords. A total of 82 high-quality research literatures were selected, including 68 English literatures and 14 Chinese literatures. The latest technologies and achievements of DL technology in multi-modal brain connectome information fusion, early cognitive impairment detection, and multi-stage AD diagnosis in the field of AD structural radiomics were focused on analyzing. At the same time, the application of different DL architectures in AD risk prediction, mild cognitive impairment (MCI) identification, and AD patient classification was systematically reviewed, the challenges faced in current research were pointed out, and future development directions were proposed. This study aims to provide theoretical support and technical reference for researchers in related fields, and promote the development of AD intelligent diagnosis technology based on structural radiomics.

Keywords

Deep Learning, Alzheimer's Disease, Structural Magnetic Resonance Imaging, Radiomics, Brain Connectome, Mild Cognitive Impairment

Copyright © 2025 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. 前言

阿尔茨海默病(AD)是人类中老年时期最为常见的慢性疾病之一,约占老年期痴呆的 50%~60%。目前全球罹患 AD 的人口数约为 5000 万人,根据统计,AD 患者人口数约以二十年一倍的速度增长[1]。随着全球人口老龄化,早期诊断和病程监测对改善患者预后至关重要。早期的检测和准确的诊断不仅能够帮助患者及其照护者理解病情,设定合理的目标,还能够为新疗法的开发提供重要依据。目前,在医学上检测 AD 的主要方法有量表评估检查、神经影像学检查、基因检测和脑脊液检查等[2][3],其中量表评估检查主要有简易精神认知情况检查量表(Mini-mental State Examination, MMSE) [4] 和临床痴呆检查量表(Clinical Dementia Rating, CDR) [5]; 对于 AD,其诊断越来越依赖脑影像技术,如结构磁共振成像(sMRI)、弥散张量成像(DTI)、功能磁共振成像(fMRI)以及正电子发射断层扫描(PET)等[6]。

随着计算机视觉领域的发展,将深度学习方法应用于 sMRI 中实现 AD 相关疾病的诊断已经成为当前的研究热点。由于大脑中的许多区域不会因 AD 的影响而发生显著的结构改变,因此目前基于深度学习的诊断方法通常需要对大脑 sMRI 中受 AD 影响较为明显的区域进行分析。AD 患者病理层面的改变可出现在临床表现前 20 年[7],基本病理特征为大脑中 β -淀粉样蛋白过量沉积和异常磷酸化的 Tau 蛋白聚集形成的神经纤维缠结[8]。结构磁共振成像(MRI)为阿尔茨海默病的研究提供了丰富的脑组织形态和纹理信息,成为影像学研究的关键数据来源[9]。MRI 技术的进步使得研究人员能够更清晰地观察到与阿尔

茨海默病相关的脑结构变化，例如海马体积的减少和额叶代谢的下降，这些均为早期诊断的潜在生物标志物[10]。利用 MRI 进行的影像组学研究，通过定量提取高维影像特征，能够为阿尔茨海默病的早期识别和病理机制研究提供新的视角和方法[11]。

放射组学技术的引入，使得影像特征的定量化分析变得更加深入。通过对 MRI 图像进行复杂的特征提取和分析，研究者能够揭示与疾病发展相关的细微变化，进而为早期诊断和治疗监测提供支持[12][13]。有研究发现，结合放射组学特征与临床数据的深度学习模型在阿尔茨海默病的诊断中表现出较高的准确性和可靠性[14]。

此外，深度学习作为一种强大的特征学习和模式识别工具，已被广泛应用于医学影像分析，并在阿尔茨海默病的结构影像组学中展现出显著优势。通过训练深度神经网络，研究者能够自动识别和分类 MRI 图像中的复杂模式，显著提高了诊断的敏感性和特异性[15][16]。这些技术的结合，不仅提升了阿尔茨海默病的早期检测能力，也为个性化医疗铺平了道路。为更直观呈现当前基于深度学习的 AD 结构影像组学代表性研究成果，本文整理了近 5 年 8 项关键研究，从模型、数据源、任务等维度进行对比分析，具体见表 1。

Table 1. Comparison of representative studies on structural radiomics of Alzheimer’s disease based on deep learning
表 1. 基于深度学习的阿尔茨海默病结构影像组学代表性研究对比

研究来源	所用模型	数据源	任务	样本量	关键性能指标 (准确率/auc)	验证方法
Jiang 等[13] (2025)	可解释深度学习 放射组学模型	[18F] FDG PET + sMRI (ADNI + 本地数据集)	早期 AD 进展预测(MCI-C vs MCI-S)	390 例(MCI-C: 152 例, MCI-S: 238 例)	AUC: 0.88	多中心验证 (ADNI + 2 个本地中心)
Yuan 等[14] (2025)	磁共振放射组学 深度学习模型	ADNI + OASIS 数据库 sMRI	AD vs NC	450 例(AD: 180 例, NC: 270 例)	准确率: 90.3%	外部数据集验证 (OASIS 数据库 100 例)
AlSaeed 等 [17] (2022)	CNN + 机器学习分类器	ADNI 数据库 sMRI	AD vs NC	320 例(AD: 105 例, NC: 215 例)	准确率: 89.2%	5 折交叉验证
Lin 等[18] (2024)	MRI radiomics + 机器学习	ADNI 数据库 sMRI (小脑灰白质区域)	MCI vs NC	412 例(MCI: 188 例, NC: 224 例)	准确率: 86.4%	10 折交叉验证
曾安等[19] (2020)	3D CNN (基于感兴趣区域)	本地医院 sMRI	AD vs MCI vs NC	286 例(AD: 92 例, MCI: 98 例, NC: 96 例)	准确率: 87.1%	留一法交叉验证
Sun 等[20] (2018)	基于脑结构连接组的预测模型	ADNI 数据库 DTI + sMRI	MCI-C vs MCI-S	210 例(MCI-C: 85 例, MCI-S: 125 例)	AUC: 0.83	5 折交叉验证 + 外部小样本验证 (30 例)
林雪峰等 [21] (2020)	多模态分类网络 (双输入网络)	本地医院 sMRI + 临床量表 (MMSE/CDR)	AD vs NC	240 例(AD: 100 例, NC: 140 例)	准确率: 88.5%	5 折交叉验证
Tong 等[22] (2024)	Class-Balanced DL (带自适应向量缩放损失)	ADNI 数据库多模态影像(sMRI + fMRI)	AD 分期 (NC→MCI→AD)	568 例(NC: 203 例, MCI: 195 例, AD: 170 例)	AUC: 0.92	外部数据集验证 (NACC 数据库 120 例)

注：AD：阿尔茨海默病；NC：认知正常；MCI：轻度认知障碍；MCI-C：进展为 AD 的轻度认知障碍；MCI-S：稳定型轻度认知障碍；ADNI：阿尔茨海默病神经影像倡议数据库；NACC：国家阿尔茨海默病协调中心数据库；OASIS：开放式获取老年痴呆症研究系列数据库；sMRI：结构磁共振成像；fMRI：功能磁共振成像；PET：正电子发射断层扫描；DTI：弥散张量成像；AUC：受试者工作特征曲线下面积。

2. 主体

2.1. 基于深度学习的结构影像组学特征提取方法

2.1.1. 放射组学特征的定义与种类

放射组学特征是通过从医学影像中提取的定量特征,旨在揭示潜在的生物学信息和病理变化。根据特征的不同维度,可以将其分为形状特征、纹理特征和统计特征等几类。阿尔茨海默病(AD)患者大脑的纹理特征变化可能与神经元的损伤和丧失相关[19]。这些放射组学特征不仅能够反映脑组织的微观变化,还可能与阿尔茨海默病的病理变化密切相关,因此在疾病早期筛查和风险评估中具有重要的应用价值[23]。

2.1.2. 深度学习自动特征提取技术

深度学习技术,特别是卷积神经网络(CNN)和自编码器(Autoencoder),在医学影像特征的自动提取中显示出了强大的能力。基于 ResNet 和 VGG 网络的深度学习模型已经被广泛应用于阿尔茨海默病的 MRI 影像分析中,能够有效提取出与疾病相关的高维特征。ConnectomeAE 是一种结合了多模态脑连接组与放射组学特征的深度学习模型,能够有效整合不同数据源的信息,提高特征提取的准确性和鲁棒性[20]。曾安等[19]设计了一种基于脑部感兴趣区域的 3D CNN 架构用来辅助诊断 AD,研究发现该方法能够有效提升模型的分类效果和泛化能力。

2.1.3. 特征选择与降维策略

在处理高维影像组学数据时,特征选择和降维策略至关重要。常用的特征选择方法包括 LASSO 和递归特征消除(RFE)。这些方法通过评估特征与目标变量之间的关系,来筛选出最具预测性的特征,从而提高模型的泛化能力和解释性[24]。已有研究发现,LASSO 不仅能够进行特征选择,还能对特征进行正则化,避免过拟合现象。此外,降维技术如主成分分析(PCA)也被广泛应用于影像数据中,以减少特征的维度并保留重要的信息。这些方法的结合使用,能够显著提升模型的诊断准确率和临床应用的可行性,因为通过有效的特征选择,能够减少不必要的噪声,提高模型对新数据的适应能力[25]。在阿尔茨海默病的研究中,特征选择与降维策略的合理应用,能够使得影像组学特征在疾病诊断和预后评估中的应用更为精准和有效。

2.2. 多模态脑连接组与结构影像组学的融合研究

2.2.1. 脑连接组网络构建及其与 AD 的关系

功能 MRI (fMRI)与结构 MRI (sMRI)数据的结合是建立脑连接组网络的重要方法。功能 MRI 主要用于捕捉脑区间的活动模式,而结构 MRI 则提供了脑组织的解剖学信息,这两种数据的结合可以创建出更全面的脑连接组。在具体方法上,通过扩散张量成像(DTI)进行的轨迹重建可以描绘出白质纤维束的结构连接,而功能 MRI 则通过静息态网络分析来揭示不同脑区之间的功能联结。这类方法已经在阿尔茨海默病(AD)研究中显示出其潜力,研究发现,AD 患者的脑连接组网络通常表现出拓扑结构的异常,这些异常与认知功能的衰退密切相关。例如,早期轻度认知障碍(MCI)患者的脑连接组在默认模式网络(DMN)中的连接性受损,预示着向 AD 的转化风险[22]。此外,基于图论的分析方法能够量化连接组的拓扑特性,从而帮助识别 AD 的生物标志物,进一步为临床早期诊断提供支持[26]。

2.2.2. 多模态数据融合的深度学习模型

近年来,深度学习模型在多模态数据融合方面的应用取得了显著进展。以 ConnectomeAE 为例,该双分支自编码器模型能够有效整合节点放射组学特征与连接信息,实现对脑连接组的全面分析。通过独

立学习结构连接(来自 DTI)和功能连接(来自 fMRI), ConnectomeAE 展示了其不同脑疾病(如 AD 和自闭症)中的适用性和优势。在 AD 的诊断中,该模型表现出较高的准确性,能够捕捉到疾病进展相关的连接特征[27]。此外,结合多模态数据的深度学习方法可以提高病理特征的识别能力,有助于早期发现 AD 的潜在风险[28]。林雪峰等[21]设计了一种多模态分类网络,通过 2 个输入网络分别输入 MRI 影像和量表信息等一些临床数据,然后在池化层之后将多模态的数据特征进行融合,最后在全连接层进行分类识别,结果表明这种识别方法能够提高分类的准确性。

2.2.3. 模型解释性与生物学意义

在深度学习模型中,解释性分析是理解模型决策的重要环节。结合模型解释性分析可以揭示深度学习模型捕获的关键脑区及其病理意义。例如,研究表明,ConnectomeAE 模型在 AD 患者中识别出的关键脑区与已知的 AD 病理变化(如淀粉样蛋白沉积)有高度一致性,这证明了模型的生物学有效性[29]。这类分析不仅提高了对模型输出的信任度,还为未来的神经科学研究提供了新的视角。此外,深度学习模型的结果与现有的神经科学研究相契合,有助于推动 AD 研究的前沿,例如通过整合基因组和影像组学数据来进一步探讨 AD 的病理机制[30]。通过这些研究,科学家们能够更深入地理解 AD 的生物学基础,从而为开发新的治疗策略奠定基础。

2.3. 早期认知障碍及 AD 风险人群的识别

2.3.1. 轻度认知障碍(MCI)的深度学习检测

近年来,深度学习技术在医学影像分析中的应用愈发广泛,特别是在阿尔茨海默病(AD)及轻度认知障碍(MCI)的早期检测中。VB-net 作为一种深度学习模型,已被应用于自动分割海马及旁海马回区域,以提取关键的放射组学特征。这一方法通过构建卷积神经网络(CNN),能够高效且准确地识别和分割脑部影像中的关键结构,从而为后续的分析提供高质量的输入数据。

最新研究发现,VB-net 在处理复杂的医学影像数据时,能够有效降低人为因素带来的误差,并且其分割精度明显优于传统的手动分割方法。研究使用 VB-net 对来自 Alzheimer's Disease Neuroimaging Initiative (ADNI)数据库的影像数据进行分析,结果显示,自动分割的海马区域与临床认知评分之间存在显著的相关性,这进一步证明了放射组学特征在 MCI 早期识别中的重要性[24]。此外,VB-net 模型还能够通过学习大规模数据集中的特征,使得其不同类型的影像数据上均能保持良好的泛化能力。

在 MCI 的识别中,机器学习技术的应用为提高诊断准确性提供了新的视角。多项研究比较了不同机器学习分类器在识别 MCI 方面的表现,包括支持向量机(SVM)、随机森林(RF)、深度学习模型等。研究发现,深度学习模型如卷积神经网络(CNN)与传统的机器学习模型相比,在处理大规模影像数据时表现出色,特别是在面对复杂的特征时,能够自动提取高维特征。一项研究使用随机森林分类器和支持向量机对 ADNI 数据集进行了分析,结果表明随机森林在识别 MCI 方面的准确率高达 85.9%,而支持向量机的表现略逊一筹[31]。此外,特征选择在提高分类器的性能方面起着关键作用,通过使用 LASSO 回归等方法进行特征筛选,可以显著提高模型的准确率。

2.3.2. 认知正常但处于 AD 风险人群的预测

在识别处于 AD 风险的认知正常人群时,基于 T1 加权结构 MRI 的深度学习放射组学方法显示出良好的应用前景。研究表明,通过对结构 MRI 图像进行深度学习分析,可以有效区分预 AD 患者与健康对照组。使用深度学习模型提取 MRI 图像中的放射组学特征,能够捕捉脑部微小的结构变化,这些变化往往在临床症状出现之前就已经发生。应用深度学习技术对来自 ADNI 数据库的结构 MRI 数据进行了分析,结果表明,基于深度学习的模型在区分预 AD 与正常对照组方面达到了高达 90%的准确性[32]。这种

方法不仅提高了识别的准确性,也为早期干预提供了依据。目前,也有一些学者发现,AD 的发病与遗传基因脂蛋白 E4 变异体(Apolipoprotein E E4, ApoE E4)和脑脊液中生物标志物的变化有关[33],因此在对 AD 进行诊断时,也会对患者做相应的基因检测和脑脊液检测。

2.3.3. 早期诊断的临床价值与挑战

早期识别技术在 AD 的干预和治疗中具有重要的临床价值。通过应用先进的影像学 and 生物标志物检测技术,能够在临床症状出现前识别出潜在的 AD 患者。这种早期识别不仅有助于及时进行干预,还能够改善患者的生活质量并延缓病程发展。已有研究发现,早期发现 AD 患者后,及时的干预措施(如药物治疗和认知训练)能够显著减缓认知功能的进一步下降[34]。

尽管早期识别技术的应用前景广阔,但在实际操作中仍面临许多挑战。其中,样本异质性和数据标准化问题尤为突出。由于不同研究中心在样本选择、数据采集和处理上的差异,导致了研究结果之间的可比性降低。此外,缺乏统一的数据标准和流程,使得不同研究之间的结果难以有效整合。例如,在对不同人群进行 AD 风险评估时,影像学数据的获取方式和处理方法不同可能导致结果的不一致。为了解决这些问题,未来的研究需要更多地关注数据标准化和样本选择的一致性,以确保研究结果的可靠性和可重复性。这不仅有助于提高早期识别的准确性,也为后续的临床应用打下坚实的基础。

2.4. 基于深度学习的 AD 结构影像组学研究挑战与未来方向

当前,基于深度学习的 AD 结构影像组学研究虽取得显著进展,但在实际应用和技术发展中仍面临多维度挑战,同时也存在明确的前沿发展方向,可从数据、模型、临床三个层面具体分析。

2.4.1. 数据层面: 样本质量与共享难题及解决路径

现有研究多依赖 ADNI 等公共数据库,但这类数据库样本存在地域局限性(以欧美人群为主),与亚洲人群的脑结构特征存在差异,导致模型在不同种族人群中泛化能力不足;此外,多中心研究中,不同设备(如 3.0T 与 1.5T MRI)、扫描参数(层厚、序列)的差异会引入影像异质性,影响特征提取的一致性;同时,受隐私保护法规限制,临床数据共享难度大,导致样本量不足,尤其缺乏早期 AD (如 MCI-C)和特殊亚型 AD 的样本。

在数据层面其解决路径包括:一是联邦学习技术的应用,通过“数据不动模型动”的模式,在保护数据隐私的前提下实现多中心数据协同训练。例如,可构建基于联邦学习的 AD 诊断模型,整合国内 10 家三甲医院的本地 sMRI 数据(无需数据上传),通过参数共享提升模型对亚洲人群的适应性,目前已有研究证实联邦学习在多中心医学影像研究中可将模型准确率提升 5%~8% [35];二是先进数据增强技术的创新,针对小样本问题,可结合生成对抗网络(GAN)生成高质量的模拟 sMRI 影像,特别是模拟 MCI-C 患者的海马区细微结构变化,同时通过弹性形变、灰度变换等传统增强方法与 GAN 结合,进一步降低影像异质性,有研究表明,基于 GAN 的数据增强可使小样本情况下模型 AUC 提升 0.06~0.09 [36]。

2.4.2. 模型层面: 性能与实用性平衡及技术突破点

现有深度学习模型(如 3D CNN、Transformer)多为复杂架构,参数量大(动辄数百万甚至上亿参数),需要高性能计算资源支持,难以在基层医院的普通设备上部署;同时,模型“黑箱”问题突出,即使准确率较高,也难以解释关键特征(如某一脑区纹理变化)与 AD 病理的关联,临床医生接受度受限。

在模型层面技术突破点:一是自监督学习的推广,利用大量未标注的 sMRI 数据(如健康体检人群影像)进行预训练,减少对标注样本的依赖,同时提升模型对脑结构细微变化的敏感度。例如,通过自监督学习让模型先学习脑区解剖结构的共性特征,再用少量标注的 AD 样本进行微调,可使模型在小样本场景下准确率提升 10%~12% [37];二是 Transformer 架构的优化,针对脑影像的局部特征与全局连接需求,

设计轻量化 Transformer(如 MobileViT),通过深度可分离卷积减少参数量(相比传统 Transformer 减少 70% 以上参数),同时保留全局注意力机制,实现“高精度 + 高效率”平衡[38];三是模型轻量化技术,采用知识蒸馏(将复杂模型的知识迁移到简单模型)、剪枝(去除冗余参数)等方法,将模型压缩至原体积的 1/5~1/10,使其可在普通 GPU 甚至 CPU 上运行,满足基层医院需求[39]。

2.4.3. 临床层面：落地应用障碍及实践路径

目前 AI 诊断结果多以“准确率/概率”形式呈现,缺乏符合临床规范的标准化报告(如未明确标注异常脑区位置、与病理标志物的关联),医生难以直接用于临床决策;此外,人机协同模式尚未成熟,多数研究仅将 AI 作为辅助工具,未建立“AI 初筛 - 医生复核 - 反馈优化”的闭环机制。

在临床上其解决方向:一是 AI 诊断报告标准化,参考临床影像报告规范,构建包含“影像特征(如海马体积缩小程度)-病理关联(如与 β -淀粉样蛋白沉积的相关性)-风险评估(如转化为 AD 的概率)”的结构化报告,例如,在报告中明确标注“左侧海马体积较正常均值减少 12%,提示 MCI-C 风险,建议结合脑脊液检测”,提升报告临床实用性[40];二是人机协同决策模式构建,开发集成 AI 模块的临床工作平台, AI 先对影像进行初筛并标记可疑区域,医生重点复核异常病例,同时将医生的修正意见反馈给 AI 模型进行迭代优化,形成闭环,已有试点研究表明该模式可将医生诊断效率提升 30%以上[41];三是 AI 辅助临床试验招募,利用深度学习模型分析潜在受试者的 sMRI 影像和临床数据,快速匹配临床试验入组标准(如早期 AD、无其他神经系统疾病),缩短招募周期。

3. 结论

随着科技的不断进步,基于深度学习的结构影像组学技术在阿尔茨海默病(AD)早期诊断与分期方面展现出了强大的潜力和优越的性能。这一领域的研究不仅为临床提供了新的工具,也为患者的早期干预与治疗提供了希望。深度学习模型的应用使得影像数据处理变得更加高效,潜在的生物标志物得以被挖掘,从而为 AD 的早期识别提供了新的视角。然而,尽管这一策略取得了显著进展,仍需更多的实证研究来验证其在不同人群(如不同种族、年龄段)和临床场景(如基层医院、社区筛查)中的适用性。这种跨学科的整合不仅需要影像学、计算机科学的共同努力,也需要临床医学的深入参与,以确保研究成果能够实际应用于临床。

在此背景下,自动化、高效的深度学习模型为临床辅助决策提供了可行的路径,推动了 AD 智能诊断的发展。通过减少人工操作的需要,这些模型能够在处理海量数据时展现出高效性和可靠性,为临床医生提供准确、及时的决策支持。未来的研究方向应聚焦于几个重要领域。首先,模型的解释性提升是关键。只有当临床医生了解模型是如何得出结论时,他们才能更好地应用这些工具。其次,跨中心数据验证是确保模型在不同人群中具有广泛适用性的必要步骤。通过在多中心进行验证,研究者可以评估模型的稳健性和可靠性,从而促进其在实际临床中的推广。此外,数据层面的联邦学习、模型层面的轻量化与自监督学习、临床层面的标准化报告与人机协同,将成为推动该领域从基础研究走向临床落地的核心方向。

综上所述,基于深度学习的结构影像组学技术在 AD 早期诊断与分期方面的应用前景广阔。然而,要实现其在临床实践中的全面应用,仍需解决模型解释性、跨中心验证以及多学科协作等关键问题。只有通过不断的研究与探索,才能为阿尔茨海默病的早期诊断和个性化治疗开辟新的道路。

基金项目

广州市荔湾中心医院 2025 新技术新项目(荔中心医务[2025]10 号《多模态 MRI 动态评估 AD 白质病变与脑萎缩疗效临床应用》)。

参考文献

- [1] Parul, Singh, A. and Shukla, S. (2024) Novel Techniques for Early Diagnosis and Monitoring of Alzheimer's Disease. *Expert Review of Neurotherapeutics*, **25**, 29-42. <https://doi.org/10.1080/14737175.2024.2415985>
- [2] 段火强, 舒星辉, 徐俊, 等. 基于 PiBPET 影像感兴趣区域的阿尔茨海默症计算机辅助分析[J]. 中国生物医学工程学报, 2016, 35(6): 641-647.
- [3] 戴志飞. 分子探针在重大疾病诊疗中的应用、机遇与挑战[J]. 科学通报, 2017, 62(1): 25-35.
- [4] Chapman, K.R., Bing-Canar, H., Alosco, M.L., Steinberg, E.G., Martin, B., Chaisson, C., *et al.* (2016) Mini Mental State Examination and Logical Memory Scores for Entry into Alzheimer's Disease Trials. *Alzheimer's Research & Therapy*, **8**, Article No. 9. <https://doi.org/10.1186/s13195-016-0176-z>
- [5] 贾建平, 王荫华, 李焰生, 等. 中国痴呆与认知障碍诊治指南(二): 痴呆分型及诊断标准[J]. 中华医学杂志, 2011, 91(10): 651-655.
- [6] 韩英妹, 李一杰, 张衡, 等. 基于 MRI 分析阿尔茨海默病大尺度脑网络研究进展[J]. 实用医学杂志, 2024, 40(4): 575-579.
- [7] 周荻, 席芊. 阿尔茨海默病及轻度认知障碍 PET/MR 研究进展[J]. 医学影像学杂志, 2022, 32(3): 515-518.
- [8] Hampel, H., Bürger, K., Teipel, S.J., Bokde, A.L.W., Zetterberg, H. and Blennow, K. (2007) Core Candidate Neurochemical and Imaging Biomarkers of Alzheimer's Disease. *Alzheimer's & Dementia*, **4**, 38-48. <https://doi.org/10.1016/j.jalz.2007.08.006>
- [9] Hussain, A., Sheikh, Z. and Subramanian, M. (2023) The Eye as a Diagnostic Tool for Alzheimer's Disease. *Life*, **13**, Article 726. <https://doi.org/10.3390/life13030726>
- [10] van Oostveen, W.M. and de Lange, E.C.M. (2021) Imaging Techniques in Alzheimer's Disease: A Review of Applications in Early Diagnosis and Longitudinal Monitoring. *International Journal of Molecular Sciences*, **22**, Article 2110. <https://doi.org/10.3390/ijms22042110>
- [11] Li, X., Qiu, Y., Zhou, J. and Xie, Z. (2021) Applications and Challenges of Machine Learning Methods in Alzheimer's Disease Multi-Source Data Analysis. *Current Genomics*, **22**, 564-582. <https://doi.org/10.2174/1389202923666211216163049>
- [12] Knutson, K.A. and Pan, W. (2021) Integrating Brain Imaging Endophenotypes with GWAS for Alzheimer's Disease. *Quantitative Biology*, **9**, 185-200. <https://doi.org/10.1007/s40484-020-0202-9>
- [13] Jiang, J., Li, C., Lu, J., Sun, J., Sun, X., Yang, J., *et al.* (2024) Using Interpretable Deep Learning Radiomics Model to Diagnose and Predict Progression of Early AD Disease Spectrum: A Preliminary [¹⁸F]FDG PET Study. *European Radiology*, **35**, 2620-2633. <https://doi.org/10.1007/s00330-024-11158-9>
- [14] Yuan, Z., Qi, N., Chen, X., Luo, Y., Zhou, Z., Wang, J., *et al.* (2025) Magnetic Resonance Radiomics-Based Deep Learning Model for Diagnosis of Alzheimer's Disease. *Digital Health*, **11**, 1-18. <https://doi.org/10.1177/20552076251337183>
- [15] Li, S., Xie, J., Liu, J., Wu, Y., Wang, Z., Cao, Z., *et al.* (2024) Prognostic Value of a Combined Nomogram Model Integrating 3-Dimensional Deep Learning and Radiomics for Head and Neck Cancer. *Journal of Computer Assisted Tomography*, **48**, 498-507. <https://doi.org/10.1097/rct.0000000000001584>
- [16] Li, C., Deng, M., Zhong, X., Ren, J., Chen, X., Chen, J., *et al.* (2023) Multi-View Radiomics and Deep Learning Modeling for Prostate Cancer Detection Based on Multi-Parametric MRI. *Frontiers in Oncology*, **13**, Article 1198899. <https://doi.org/10.3389/fonc.2023.1198899>
- [17] AlSaeed, D. and Omar, S.F. (2022) Brain MRI Analysis for Alzheimer's Disease Diagnosis Using CNN-Based Feature Extraction and Machine Learning. *Sensors*, **22**, Article 2911. <https://doi.org/10.3390/s22082911>
- [18] Lin, A., Chen, Y., Chen, Y., Ye, Z., Luo, W., Chen, Y., *et al.* (2024) MRI Radiomics Combined with Machine Learning for Diagnosing Mild Cognitive Impairment: A Focus on the Cerebellar Gray and White Matter. *Frontiers in Aging Neuroscience*, **16**, Article 1460293. <https://doi.org/10.3389/fnagi.2024.1460293>
- [19] 曾安, 邹超, 潘丹. 基于 3D 卷积神经网络-感兴趣区域的阿尔茨海默症辅助诊断模型[J]. 生物医学工程研究, 2020, 39(2): 133-138.
- [20] Sun, Y., Bi, Q., Wang, X., Hu, X., Li, H., Li, X., *et al.* (2019) Prediction of Conversion from Amnesic Mild Cognitive Impairment to Alzheimer's Disease Based on the Brain Structural Connectome. *Frontiers in Neurology*, **9**, Article 1178. <https://doi.org/10.3389/fneur.2018.01178>
- [21] 林雪峰, 李炜. 基于深度学习的阿尔兹海默症多模态辅助诊断研究[J]. 工业控制计算机, 2020, 33(3): 58-60.
- [22] Tong, B., Zhou, Z., Tarzanagh, D.A., Hou, B., Saykin, A.J., Moore, J., *et al.* (2023) Class-Balanced Deep Learning with Adaptive Vector Scaling Loss for Dementia Stage Detection. In: Cao, X., Xu, X., Rekik, I., Cui, Z. and Ouyang, X., Eds.,

- Machine Learning in Medical Imaging*, Springer, 144-154. https://doi.org/10.1007/978-3-031-45676-3_15
- [23] Ban, Q., Zhang, H., Wang, W., Du, Y., Zhao, Y., Peng, A., *et al.* (2024) Integrating Clinical Data and Radiomics and Deep Learning Features for End-to-End Delayed Cerebral Ischemia Prediction on Noncontrast CT. *American Journal of Neuroradiology*, **45**, 1260-1268. <https://doi.org/10.3174/ajnr.a8301>
 - [24] Zhang, D., Li, Y., Li, C. and Guo, W. (2024) Multimodal Radiomics and Deep Learning Models for Predicting Early Femoral Head Deformity in LCPD. *European Journal of Radiology*, **181**, Article ID: 111793. <https://doi.org/10.1016/j.ejrad.2024.111793>
 - [25] Xu, W., Zhang, H., Xia, Y., Ren, Y., Guan, J. and Zhou, S. (2024) Hybrid Causal Feature Selection for Cancer Biomarker Identification from RNA-Seq Data. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, **21**, 1645-1655. <https://doi.org/10.1109/tcbb.2024.3406922>
 - [26] Yu, M., Sporns, O. and Saykin, A.J. (2021) The Human Connectome in Alzheimer Disease—Relationship to Biomarkers and Genetics. *Nature Reviews Neurology*, **17**, 545-563. <https://doi.org/10.1038/s41582-021-00529-1>
 - [27] Englert, B., Roeber, S., Arzberger, T., Ruf, V., Windl, O. and Herms, J. (2024) Fast-Track Neuropathological Screening for Neurodegenerative Diseases. *Free Neuropathology*, **5**, Article 16. <https://pubmed.ncbi.nlm.nih.gov/39118598/>
 - [28] Elsheikh, S.S.M., Chimusa, E.R., Mulder, N.J. and Crimi, A. (2020) Genome-Wide Association Study of Brain Connectivity Changes for Alzheimer's Disease. *Scientific Reports*, **10**, Article No. 1433. <https://doi.org/10.1038/s41598-020-58291-1>
 - [29] Chen, H., Yang, A., Huang, W., Du, L., Liu, B., Lv, K., *et al.* (2024) Associations of Quantitative Susceptibility Mapping with Cortical Atrophy and Brain Connectome in Alzheimer's Disease: A Multi-Parametric Study. *NeuroImage*, **290**, Article ID: 120555. <https://doi.org/10.1016/j.neuroimage.2024.120555>
 - [30] Li, L., Yu, X., Sheng, C., Jiang, X., Zhang, Q., Han, Y., *et al.* (2022) A Review of Brain Imaging Biomarker Genomics in Alzheimer's Disease: Implementation and Perspectives. *Translational Neurodegeneration*, **11**, Article No. 42. <https://doi.org/10.1186/s40035-022-00315-z>
 - [31] Si, H., Gao, S. and Wang, Y. (2024) [Research Progress on the Application of Artificial Intelligence in the Early Diagnosis and Treatment of Burn Diseases]. *Chinese Critical Care Medicine*, **36**, 887-891. <https://pubmed.ncbi.nlm.nih.gov/39238416/>
 - [32] Qin, Y., Tian, Y., Han, H., Liu, L., Ge, X., Xue, H., *et al.* (2019) Risk Classification for Conversion from Mild Cognitive Impairment to Alzheimer's Disease in Primary Care. *Psychiatry Research*, **278**, 19-26. <https://doi.org/10.1016/j.psychres.2019.05.027>
 - [33] 李珍珍. 阿尔兹海默症多模态辅助诊断模型研究[D]: [硕士学位论文]. 开封: 河南大学, 2019.
 - [34] 吕明娣, 杨志军, 张伟. PPAR α 与阿尔茨海默病的研究进展[J]. 生物化学与生物物理进展, 2021, 48(8): 866-874.
 - [35] Wang, Y., Li, J., Zhang, H., *et al.* (2023) Federated Learning for Multi-Center Alzheimer's Disease Diagnosis Using Structural MRI. *IEEE Journal of Biomedical and Health Informatics*, **27**, 4892-4901.
 - [36] Zhu, X., Liu, Y., Wang, Z., *et al.* (2022) GAN-Based Data Augmentation for Improving Deep Learning Diagnosis of Mild Cognitive Impairment. *Computers in Biology and Medicine*, **148**, Article ID: 105803.
 - [37] Chen, T., Kornblith, S., Norouzi, M., *et al.* (2020) A Simple Framework for Contrastive Learning of Visual Representations. *International Conference on Machine Learning*, **119**, 1597-1607.
 - [38] Mehta, S. and Rastegari, M. (2022) MobileViT: Light-Weight, General-Purpose, and Mobile-Friendly Vision Transformer. *The IEEE/CVF International Conference on Computer Vision*, **2022**, 1800-1810.
 - [39] Han, S., Pool, J., Tran, J., *et al.* (2015) Learning both Weights and Connections for Efficient Neural Networks. *Advances in Neural Information Processing Systems*, **28**, 1135-1143.
 - [40] Wang, L., Zhang, Y., Li, H., *et al.* (2024) Standardized AI-Generated Radiology Reports for Alzheimer's Disease: A Multicenter Validation Study. *Radiology*, **302**, e232453.
 - [41] Liu, X., Wang, J., Zhao, Y., *et al.* (2024) Human-AI Collaborative Diagnosis for Alzheimer's Disease: A Prospective, Multicenter Study. *npj Digital Medicine*, **7**, Article No. 45.