

应用多模态磁共振影像基于多层感知机的 轻度认知障碍分类识别方法

周伟斌¹ 陈振鹏² 李海云³

摘要 目的 轻度认知障碍(mild cognitive impairment, MCI)是阿尔茨海默病(Alzheimer's disease, AD)的前驱阶段, MCI包括稳定型轻度认知障碍(stable mild cognitive impairment, sMCI)与进展型轻度认知障碍(progressive mild cognitive impairment, pMCI)。准确区分sMCI与pMCI对于AD临床早期诊断干预至关重要。**方法** 本文提出了一种应用多模态多图谱基于多层感知机模型的MCI分类识别方法, 用于sMCI与pMCI分类识别。应用FreeSurfer, 从结构磁共振成像(structural magnetic resonance imaging, sMRI)影像数据中计算得到的形态学特征参数包括大脑皮层分割区域厚度均值、表面积、灰质体积、沟壑深度、褶皱指数以及指定解剖区域的体素强度均值。采用DPABI, 从静息态功能磁共振成像(resting state functional MRI, rs-fMRI)影像数据中计算得到的功能特征参数包括低频振幅和局部一致性。采用岭回归进行特征参数筛选, 并根据岭回归输出的系数矩阵确定最具区分度的脑区。**结果** 建立的方法在ADNI数据集上进行了10折交叉验证。集成来自sMRI和rs-fMRI两种模态影像的特征参数, sMCI与pMCI的分类识别准确率为82.7%, AUC为93.0%。实验结果发现内嗅皮层、颞叶厚度和体积、海马、海马旁回的体素强度均值等形态学特征具有明显组间差异。**结论** 构建的分类识别方法具有潜在的区分sMCI与pMCI的能力。融合结构磁共振和静息态功能磁共振影像模态特征集成多图谱能够显著地提高模型对MCI分类识别性能。

关键词 轻度认知障碍; 多模态磁共振影像; 多模态融合; 多图谱融合; 多层感知机

DOI: 10.3969/j.issn.1002-3208.2026.02.002.

中图分类号 R318.04 **文献标志码** A **文章编号** 1002-3208(2026)02-0119-08

本文著录格式 周伟斌, 陈振鹏, 李海云. 应用多模态磁共振影像基于多层感知机的轻度认知障碍分类识别方法[J]. 北京生物医学工程, 2026, 45(2): 119-126. ZHOU Weibin, CHEN Zhenpeng, LI Haiyun. Classification and recognition of mild cognitive impairment using multimodal magnetic resonance imaging based on multi-layer perceptron[J]. Beijing Biomedical Engineering, 2026, 45(2): 119-126.

Classification and recognition of mild cognitive impairment using multimodal magnetic resonance imaging based on multi- layer perceptron

ZHOU Weibin¹, CHEN Zhenpeng², LI Haiyun³

¹ Medical Engineering Department, Beijing Jishuitan Hospital, Capital Medical University, Beijing 100035;

² Qingdao Academy of Chinese Medical Sciences, Shandong University of Traditional Chinese Medicine, Qingdao, Shandong Province 266112;

³ School of Biomedical Engineering, Capital Medical University, Beijing 100069

Corresponding authors: CHEN Zhenpeng (E-mail: m18366108084@163.com);

LI Haiyun (E-mail: haiyunli@ccmu.edu.cn)

【Abstract】 Objective Mild cognitive impairment (MCI) is the prodromal stage of Alzheimer's disease (AD). MCI includes stable mild cognitive impairment (sMCI) and progressive mild cognitive impairment (pMCI). It is very important to distinguish sMCI and pMCI accurately for the early diagnosis and intervention of AD. **Methods** In this paper, a multi-modal and multi-atlas MCI classification recognition method based on multi-layer perceptron was proposed to differentiate pMCI from sMCI. Applying FreeSurfer, the morphological characteristic parameters derived from structural magnetic resonance imaging (sMRI) data were achieved including average cortical thickness, surface area, gray matter volume, sulcal depth, and folding index, as well as the average voxel intensity of specific anatomical regions. Adopting DPABI, the functional characteristic parameters derived from resting state functional MRI (rs-fMRI) data were obtained including amplitude of low frequency fluctuations (ALFF) and regional homogeneity (ReHo). In addition, ridge regression was applied for characteristic parameters selection, and the brain regions with the most distinguishing features were determined based on the coefficients matrix of ridge regression output. **Results** The proposed method was cross-validated by 10 fold on the ADNI dataset, integrating the characteristic parameters from two modalities of sMRI and rs-fMRI, the accuracy of distinguishing between sMCI and pMCI was 82.7%, with an AUC of 93.0%. In addition, it was found that the thickness and volume of entorhinal cortex and temporal lobe, and the mean value of voxel intensity of hippocampus and parahippocampal gyrus had significant differences between groups. **Conclusions** The proposed method has the potential to distinguish pMCI from sMCI. The performance of MCI classification recognition can be significantly improved by incorporating modality features of structural MRI and rs-fMRI and integrating multi-atlas.

【Keywords】 mild cognitive impairment; multimodal magnetic resonance imaging; multimodal fusion; multi-atlas fusion; multilayer perceptron

0 引言

轻度认知障碍 MCI (mild cognitive impairment, MCI) 是一种介于正常人和阿尔茨海默病 AD (Alzheimer's disease, AD) 之间的过渡状态, 是 AD 的前驱阶段, 临床主要表现为认知功能轻度受损和记忆障碍。MCI 患者大脑在一定程度上存在与 AD 相似的病理改变^[1], 如大脑结构萎缩、淀粉样蛋白水平升高和神经纤维缠结异常等。未进行临床干预的 MCI 患者 5 年转化为 AD 的概率高达 40%^[2-3]。MCI 又可以分为稳定型轻度认知障碍 (stable MCI, sMCI) 和进展型轻度认知障碍 (progressive MCI,

pMCI)。在随访期 (通常为 36 个月) 内转化为 AD 的 MCI 被认定为 pMCI, 而在随访期内未转化为 AD 的 MCI 被认定为 sMCI^[4-6]。MCI 发病隐匿, 症状不明显, 难以进行准确的临床诊断识别。

目前, 不少研究分别采用结构磁共振成像 (structural magnetic resonance imaging, sMRI)、静息态功能磁共振成像 (resting state functional MRI, rs-fMRI) 以及多模态磁共振成像数据, 基于机器学习或深度学习算法对 MCI 分类识别进行了探索, 取得了不少有参考价值的结果。Cho 等^[7]从 ADNI 数据集中获取了 72 例 pMCI 和 131 例 sMCI 样本, 利用 sMRI 影像数据计算了大脑皮层厚度作为特征输入, 构建了基于线性判别分析的 MCI 识别模型, 交叉验证后 sMCI 与 pMCI 的识别准确率达到了 71.2%。Li 等^[8]利用 sMRI 影像数据计算了右侧大脑半球所有顶点的厚度、表面积、皮层体积、沟壑深度、曲率作为特征输入, 构建了基于线性支持向量机的 MCI 识别模型, 留一法 (leave-one-out) 交叉验证后 MCI 与正常对照组 (normal control, NC) 的识别准确率为 80.0%。Ma 等^[9]利用 sMRI 数据计算了灰质体积、雅可比行

基金项目: 北京市自然科学基金 (L192044) 资助

作者单位: 1 首都医科大学附属北京积水潭医院医学工程部 (北京 100035)

2 山东中医药大学青岛中医药科学院 (山东青岛 266112)

3 首都医科大学生物医学工程学院 (北京 100069)

通信作者: 陈振鹏, E-mail: m18366108084@163.com;

李海云, E-mail: haiyunli@ccmu.edu.cn

列式值、皮层厚度、褶皱系数、沟壑深度和分形维度作为特征输入,构建了基于随机森林的MCI识别模型,十折交叉验证后MCI与NC的识别准确率达到80%。Buvaneswari等^[10]从ADNI数据集中获取了68例AD、69例MCI、73例NC,利用rs-fMRI影像数据计算了脑功能特征作为输入,构建了基于核函数支持向量回归的NC、MCI、AD三分类模型,交叉验证后三分类准确率达到98.5%。董国昭等^[11]应用rs-fMRI数据计算了时域变换灵活性和空间分布广泛性两个动态图论特征,构建了基于支持向量机的分类器,研究发现主观认知下降患者在额上回、楔前叶等认知相关脑区的动态图论特征较之于正常受试者有显著减弱,且动态图论特征的分类准确率优于传统静态图论特征。Hojjati等^[12]从ADNI数据集中获取了18例pMCI、62例sMCI样本,从sMRI中计算了皮层厚度和皮层体积两种形态学特征,从rs-fMRI中计算了功能连接矩阵。结合sMRI和rs-fMRI两种模态的特征参数,构建了SVM模型进行sMCI与pMCI分类识别,分类识别准确率达到96.9%。然而,应用sMRI和rs-fMRI两种模态影像数据基于机器学习和深度学习建模的MCI分类识别方法还存在一些问题。其中,一些方法仅考虑脑形态学特征或脑功能特征,采用的特征数量较少,可能不足以全面表达MCI的影像特征,这会导致模型难以学习到数据的多种特征,从而影响识别性能。不少方法虽然具有较高的识别性能,但主要针对AD、MCI和NC的分类识别。有研究对sMCI与pMCI进行分类识别,准确率达到96.9%,其pMCI样本仅18例,样本量太小很可能发生了过拟合。目前sMCI与pMCI分类识别仍然是一个挑战。准确区分sMCI与pMCI仍是临床亟待解决的AD早期诊断识别的关键问题。

针对sMCI与pMCI分类识别,本文提出了一种应用多模态多图谱基于多层感知机模型的MCI分类识别方法,应用ADNI数据库中多模态磁共振影像计算得到脑形态学特征、静息态脑功能特征,构建了基于多层感知机多模态多图谱的MCI分类识别模型,用于sMCI与pMCI分类识别,并对sMCI与pMCI分类识别进行了实验探索。

1 材料与方法

本文采用多层感知机MLP为主干模型,应用

sMRI和rs-fMRI影像数据分别计算获取脑形态特征参数和脑功能特征参数,采用AAL、BN246和Aseg三种脑图谱以及Schaefer 100、Aparc和DKTatlas三种皮层分割图谱进行特征映射,构建一种应用多模态多图谱基于多层感知机模型的MCI分类识别方法,用于sMCI与pMCI分类识别。首先应用FreeSurfer从sMRI影像数据中计算得到形态学特征参数,主要包括大脑皮层分割区域厚度、表面积、灰质体积、沟壑深度、褶皱指数以及指定解剖区域的体素强度均值。然后采用DPABI从rs-fMRI影像数据中计算得到静息态脑功能特征参数,主要包括低频振幅和局部一致性。进一步应用岭回归方法进行特征参数筛选,同时根据岭回归输出的系数矩阵确定最具区分度的脑区。最后应用MLP模型对sMCI与pMCI进行分类识别。方法流程图如图1所示。

1.1 数据采集和预处理

本文数据采用阿尔茨海默病神经影像学计划ADNI (Alzheimer's disease neuroimaging initiative, ADNI)数据集^[13]。ADNI是一项纵向多中心研究,旨在开发临床、成像、遗传和生化生物标志物,用于AD的早期检测和跟踪。所有的参与者都给予了他们的知情同意,研究方案由每个参与机构的伦理委员会批准。描述诊断标准的详细信息可以在www.adni-info.org上找到。

在ADNI数据集中选取了151例同时具有sMRI和rs-fMRI两种影像模态数据的MCI被试,其中118例sMCI、33例pMCI。被试人口统计学信息如表1所示。

应用FreeSurfer工具软件^[14]对sMRI影像进行预处理以及形态学特征计算。FreeSurfer的处理流程主要包括:(1)运动矫正;(2)转化;(3)体素强度标准化;(4)颅骨去除;(5)皮层下分割;(6)皮层表面提取;(7)球面配准;(8)形态学特征计算。计算得到的形态学特征包括体素强度均值(voxel intensity mean, VIM)、沟壑深度(sulcal depth, SD)、褶皱系数(gyri index, GI)、灰质体积(gray matter volume, GMV)、皮层厚度均值(cortical thickness average, CTA)和表面积(surface area, SA)。

应用Dpabi工具软件^[15]对rs-fMRI影像进行预处理以及功能磁共振特征计算。Dpabi的处理流程




图 1 多模态多图谱基于多层感知机模型的MCI分类识别方法流程图

Figure 1 Flowchart of multi-modal multi-atlas multi-layer perceptron model based MCI classification and recognition method

包括:(1)切片时间层矫正;(2)头动矫正;(3)标准化;(4)平滑;(5)线性趋势去除;(6)信号去噪;(7)时域滤波;(8)功能磁共振特征计算。计算得到的功能磁共振特征包括局部一致性 ReHo (regional homogeneity, ReHo) 指数^[16]和低频振幅 ALFF (amplitude of low frequency fluctuations, ALFF) 指数^[17]。

1.2 基于脑图谱的脑形态学和功能特征映射计算

本文利用特定脑区的形态学特征以及功能磁共振特征进行 sMCI 与 pMCI 分类识别,不同脑区根据脑图谱 (Atlas) 划定,课题组选取 AAL、BN246 和 Aseg 三种脑图谱以及 Schaefer 100、Aparc 和 DKTatlas 三种皮层分割图谱,并通过如下公式计算特定脑区的形态学特征以及功能磁共振特征:

表 1 被试人口统计学信息

Table 1 Demographic profiles of the participants

分组	数量	年龄	性别	MMSE
sMCI	118	72.0 (7.5) [90.1, 56.2]	67M/51F	28.4 (1.2)
pMCI	33	72.8 (6.9) [89.2, 55.4]	15M/18F	24.3 (1.7)

注:()内表示标准差;[]内表示最大值和最小值;M表示男性;F表示女性;MMSE表示迷你精神状态检查分数。

$$F_r = [f_r^1, \dots, f_r^n, \dots, f_r^N] \quad (1)$$

式中: F 表示构建的分类模型的输入特征向量; f 表示形态学特征或者功能磁共振特征; f_r 表示CTA、SA、GMV、SD、GI、VIM、ALFF或者ReHo; N 表示脑图谱中共有 N 个脑区; n 表示指定的第 n 个区域。式(1)中 f_r^n 计算公式如下:

$$f_T^n = \text{sum}(f_T \otimes A_n) / \text{sum}(A_n) \quad (2)$$

式中: A 表示脑图谱或皮层分割图谱; A_n 表示特定区域掩模mask(只有第 n 个区域值为1,其他区域为0)。本研究利用Neuromap工具^[18]将DPABI计算出的ALFF和ReHo指数映射到大脑皮层,采用32 k个顶点描述皮层空间ALFF和ReHo指数。

1.3 基于多层感知机模型的MCI分类识别方法

本文应用岭回归对计算得到的特定解剖区域形态学特征以及功能磁共振特征进行初步筛选,获取区分度较高的特征参数。采用多层感知机MLP为主干分类模型,为了增强特征参数的表达能力,MCI分类识别方法采用多层感知机以数据驱动的方式自动学习复杂的特征表示。岭回归通过Python机器学习库scikit-learn中Ridge组件实现,设置的超参数包括alpha设置为1.0,拟合截距设置为True,标准化设置为False,解释器设置为auto自动选择。多层感知机模型由输入层、隐藏层、激活层和输出层组成。

1.4 实验

采用10折交叉验证来评估构建的分类算法的性能,其中90%数据用于训练,10%用于验证。采用固定随机种子方式确保实验结果的可复现性。构建的模型采用Adam优化器、学习率(learning rate, LR)设置为0.000 1、Batch-Size设置为16来训练模型。深度学习框架选择sklearn.neural_network模块中MLPclassifier组件。由于模型参数量小,输入特征维度低,M2MLP采用CPU训练模型。

2 结果

本文采用4种度量标准来评估构建的分类算法的性能:(1)准确率ACC(accuracy, ACC);(2)灵敏度SEN(sensitivity, SEN);(3)特异性SPE(specificity, SPE);(4)ROC曲线下面积(area under the curve, AUC)。

2.1 基于不同形态特征及其融合的分类识别实验结果

应用Aparc皮层分割图谱,集成左侧大脑半球CTA、GI、GMV、SD、SA 5种形态学特征参数,利用构建的分类算法对sMCI与pMCI进行分类识别。不同形态学特征的分类识别性能如表2所示,ROC曲线如图2所示。

表2 不同形态学特征的分类识别性能

Table 2 The classification performance of different morphological features

特征	sMCI 与 pMCI				
	特征数量	准确度	灵敏度	特异性	AUC
GMV	14	0.709	0.201	0.917	0.69
GI	18	0.698	0.048	0.964	0.621
SD	16	0.71	0.086	0.966	0.605
SA	14	0.706	0.016	0.988	0.555
CTA	15	0.759	0.396	0.908	0.762
All_metrics	73	0.751	0.451	0.875	0.743

注:All_metrics表示集成CTA、GI、GMV、SD、SA五种结构磁共振影像形态特征参数。加粗字体为每列最优值。




图2 不同形态学特征的ROC曲线

Figure 2 ROC curves of different morphological features

2.2 基于sMRI和rs-fMRI两种模态特征以及两种模态特征集成的分类识别实验结果

分别应用sMRI和rs-fMRI两种影像模态特征及两种模态特征集成,利用构建的MCI分类识别方法对sMCI与pMCI进行分类识别。sMRI影像模态特征包括应用Aparc、DKTatlas、Schaefer100三种皮层分割图谱映射获得的CTA、SD、SA、GI、GMV、VIM 5种特征参数。rs-fMRI影像模态特征包括利用AAL、BN246、Aseg三种脑图谱映射获取的ALFF、ReHo。不同模态的分类识别性能如表3所示。ROC曲线如图3所示。

3 讨论

AD早期诊断识别对其临床预期至关重要,准确区分sMCI与pMCI是临床亟待解决的AD早期诊断识别的关键问题,目前sMCI与pMCI分类识别仍然是一个挑战。准确分类识别sMCI与pMCI可以实现AD早发现、早诊断、早干预,从而能够阻止或延

表 3 sMRI 和 rs-fMRI 两种影像模态特征及其合并特征的分类性能比较

Table 3 Comparison of classification performance of sMRI and rs-fMRI two modal features and their combined features

影像模态	sMCI 与 pMCI				
	特征数量	准确度	灵敏度	特异性	AUC
sMRI	312	0.788	0.424	0.889	0.729
rs-fMRI	280	0.761	0.333	0.881	0.751
sMRI+rs-fMRI	579	0.827	0.666	0.872	0.93

注:加粗字体为每列最优值。




图 3 sMRI 和 rs-fMRI 两种模态特征以及两种模态特征集成的 ROC 曲线

Figure 3 ROC curves of sMRI and rs-fMRI two modal features and the two modal feature integration

缓 MCI 患者认知功能的进一步下降,取得较好的临床预期。本文提出了一种应用多模态多图谱基于多层感知机模型的 MCI 分类识别方法,用于 sMCI 与 pMCI 分类识别。该方法采用多层感知机 MLP 为主干分类模型,分别应用 sMRI 和 rs-fMRI 两种影像模态特征及两种模态特征集成。值得一提的是,采用了 AAL、BN246 和 Aseg 三种脑图谱以及 Schaefer 100、Aparc 和 DKAtlas 三种皮层分割图谱进行特征脑区映射。其中, sMRI 影像模态特征包括应用 Aparc、DKAtlas、Schaefer100 三种皮层分割图谱映射获得的 CTA、SD、SA、GI、GMV、VIM 5 种特征参数。rs-fMRI 影像模态特征包括利用 AAL、BN246、Aseg 三种脑图谱映射获取的 ALFF、ReHo。比较全面地捕捉了不同尺度脑区的形态学和静息态脑功能特征信息。应用岭回归方法进行特征筛选,有效地去除了特征冗余。创建的方法有效地结合了两种影像模态特征,应用多种脑图谱进行特征映射,

特别是利用多层感知机作为主干分类模型以数据驱动的方式自动学习复杂的特征表示。相比于传统机器学习模型设定特定的核函数或者构建多个决策树,多层感知机模型可以通过调整层数、神经元数、激活函数等方式调整模型架构,从而具有更好的灵活性,有利于提升模型对 pMCI 与 sMCI 分类识别性能。

有研究表明 MCI 中存在不同程度的大脑皮层神经元退化, MCI 患者大脑皮层厚度也会随着大脑皮层的神经元减少和损害而变薄。实验发现基于单一影像模态,单一脑图谱应用皮层厚度特征在一定程度上能够分类识别 sMCI 与 pMCI。这与已有的研究结论具有一致性^[19]。此外,神经退行性疾病通常会导致大脑中多种解剖区域体积发生变化(海马、杏仁核、内嗅皮层等)^[20]。这种变化趋势在 MCI 阶段也可以检测到,因此体积指标具有识别 MCI 的潜力。除皮层厚度和解剖区域体积外,其他形态学特征参数也具有不同程度的 MCI 分类识别潜力。集成多种形态学特征可以提升 sMCI 与 pMCI 的分类识别性能。主要原因在于:①信息互补。不同形态学特征之间存在互补信息。例如皮层厚度反映大脑皮层外缘的厚度,褶皱系数描述了大脑皮层的拓扑复杂性,神经退行性疾病均会导致二者的异常变化。因此,集成多种形态学特征有助于模型捕获更多的信息,从而形成更全面的特征表示。这有助于提升模型对于复杂数据模式的识别能力。②泛化能力。多种形态学特征的集成有助于构建更加稳健和泛化的模型。模型能够从多个方面学习大脑的结构特性,进而使得模型在遇到未知数据时具有更好的适应性和预测能力。③在一些情况下,利用多种特征进行模型训练可以有效地缓解过拟合问题。多种特征提供的丰富信息可以帮助模型更好地泛化到新的未见过的数据,减少模型对于训练数据的过度拟合。

合并多个脑图谱映射特征能够提升分类模型的分类识别准确率,实验选取皮层厚度进行 sMCI 与 pMCI 分类识别时,构建的模型在合并多个图谱下均取得了最好的准确度、灵敏度和 AUC。集成多种脑图谱能够提升模型分类识别性能的主要原因如下。①多样性。多个图谱可以提供多样性和全面性的信息,例如 BN246 脑图谱按照脑功能划分脑区,

Aseg脑图谱按照解剖区域划分脑区。因此多个脑图谱能够帮助MLP模型同时学习到大脑结构和功能的多样化信息。②特征提取。集成多个图谱可以提供更丰富的特征,有助于模型更准确地识别影像中的模式和异常。更丰富的特征集可以增强模型的泛化能力。③增强模型的稳健性。通过整合来自多个图谱的信息,模型的稳健性和灵敏度提高,即使存在一定冗余特征的情况下依然能够作出准确的预测。

融合sMRI和rs-fMRI两种模态特征能够显著提升模型对sMCI与pMCI的分类识别性能,sMCI与pMCI的分类识别准确率达到82.7%,AUC达到了93.0%。模型分类识别性能显著提升的原因主要在于:①sMRI和rs-fMRI之间存在信息互补。sMRI揭示MCI的大脑萎缩和解剖结构变化,rs-fMRI聚焦大脑活动和功能连接信息的改变。合并两种模态可以让MLP从不同角度理解大脑的状态,从而更准确地进行分类和预测。②增强泛化能力。多模态数据可以提高模型的泛化能力。在面对未知、新的或异质的数据时,结构和功能信息的融合可以帮助模型更好地适应和预测,从而提高模型的稳健性和可靠性。

课题组计算了皮层厚度对sMCI与pMCI分类识别的权重系数。基于皮层厚度的分类识别结果中,发现内嗅皮层、前楔叶区域组间差异最明显,可以作为评判MCI严重程度的生物标志物,同样发现海马、海马旁回在sMCI与pMCI对照组之间具有明显组间差异。

尽管课题组的MCI分类识别方法取得了较好的效果,但相对于Hojjati等^[12]提出的基于支持向量机SVM的MCI分类识别模型(AUC=0.98),本课题组的分类识别性能(AUC=0.93)有待于进一步提升,然而,两者样本量的不同可能是一个原因。Hojjati采用的样本量为sMCI 62例,pMCI 18例,与本文的样本量(sMCI 118例,pMCI 33例)相差较大。本文方法在样本量更充分的前提下取得了比较可靠的pMCI与sMCI分类识别结果,在一定程度上说明了本文模型的可靠性和鲁棒性。另外,Hojjati等采用了Dosenbach脑图谱以及Destrieux皮层分割图谱,应用这些脑图谱可能更加有效地提取了分类特征。

4 结论

本文提出了一种应用多模态多图谱基于多层感知机模型的MCI分类识别方法,用于sMCI与pMCI分类识别。应用sMRI和rs-fMRI两种模态影像基于多图谱特征映射计算对pMCI与sMCI进行了分类识别实验研究,准确率为82.7%,AUC为93.0%。集成结构磁共振和静息态功能磁共振两种影像模态融合多图谱特征映射能够显著地提高模型对MCI分类识别性能。构建的分类算法具有潜在的区分sMCI与pMCI的能力。

参考文献

- [1] 周震,景斌. 基于体素的和基于形变的形态学测量在轻度认知障碍识别上的比较研究[J]. 北京生物医学工程, 2021, 40(5): 494-498, 511.
Zhou Z, Jing B. Comparative study of voxel-based and deformation-based morphometry in the identification of mild cognitive impairment [J]. Beijing Biomedical Engineering, 2021, 40(5): 494-498, 511.
- [2] Grundman M, Petersen RC, Ferris SH, et al. Mild cognitive impairment can be distinguished from Alzheimer disease and normal aging for clinical trials [J]. Archives of Neurology, 2004, 61(1): 59-66.
- [3] Misra C, Fan Y, Davatzikos C. Baseline and longitudinal patterns of brain atrophy in MCI patients, and their use in prediction of short-term conversion to AD: results from ADNI [J]. Neuroimage, 2009, 44(4): 1415-1422.
- [4] Lian C, Liu M, Zhang J, et al. Hierarchical fully convolutional network for joint atrophy localization and Alzheimer's disease diagnosis using structural MRI [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 42(4): 880-893.
- [5] Samper-González J, Burgos N, Bottani S, et al. Reproducible evaluation of classification methods in Alzheimer's disease: Framework and application to MRI and PET data [J]. NeuroImage, 2018, 183: 504-521.
- [6] Huang Y, Xu J, Zhou Y, et al. Diagnosis of Alzheimer's disease via multi-modality 3D convolutional neural network [J]. Frontiers in Neuroscience, 2019, 13: 509.
- [7] Cho Y, Seong JK, Jeong Y, et al. Individual subject classification for Alzheimer's disease based on incremental learning using a spatial frequency representation of cortical thickness data [J]. NeuroImage, 2012, 59(3): 2217-2230.
- [8] Li S, Yuan X, Pu F, et al. Abnormal changes of

- multidimensional surface features using multivariate pattern classification in amnesic mild cognitive impairment patients [J]. *Journal of Neuroscience*, 2014, 34(32): 10541–10553.
- [9] Ma Z, Jing B, Li Y, et al. Identifying mild cognitive impairment with random forest by integrating multiple MRI morphological metrics [J]. *Journal of Alzheimer's Disease*, 2020, 73 (3): 991–1002.
- [10] Buvanewari PR, Gayathri R. Detection and classification of Alzheimer's disease from cognitive impairment with resting-state fMRI[J]. *Neural Computing and Applications*, 2023, 35: 22797–22812.
- [11] 董国昭, 曾晓天, 杨柳, 等. 基于动态图论特征的阿尔茨海默病早期预测[J]. *北京生物医学工程*, 2019, 38(6): 560–567.
- Dong GZ, Zeng XT, Yang L, et al. Early prediction of Alzheimer disease based on dynamic graph theory [J]. *Beijing Biomedical Engineering*, 2019, 38(6): 560–567.
- [12] Hojjati SH, Ebrahimzadeh A, Khazaei A, et al. Predicting conversion from MCI to AD by integrating rs-fMRI and structural MRI[J]. *Computers in Biology and Medicine*, 2018, 102: 30–39.
- [13] Jack Jr CR, Bernstein MA, Fox NC, et al. The Alzheimer's disease neuroimaging initiative (ADNI): MRI methods [J]. *Journal of Magnetic Resonance Imaging*, 2008, 27 (4): 685–691.
- [14] Fischl B. FreeSurfer[J]. *NeuroImage*, 2012, 62(2): 774–781.
- [15] Yan CG, Wang XD, Zuo XN, et al. DPABI: data processing & analysis for (resting-state) brain imaging[J]. *Neuroinformatics*, 2016, 14(3): 339–351.
- [16] Zang Y, Jiang T, Lu Y, et al. Regional homogeneity approach to fMRI data analysis[J]. *NeuroImage*, 2004, 22(1): 394–400.
- [17] Zou QH, Zhu CZ, Yang Y, et al. An improved approach to detection of amplitude of low-frequency fluctuation (ALFF) for resting-state fMRI: fractional ALFF [J]. *Journal of Neuroscience Methods*, 2008, 172(1): 137–141.
- [18] Markello RD, Hansen JY, Liu ZQ, et al. Neuromaps: structural and functional interpretation of brain maps[J]. *Nature Methods*, 2022, 19(11): 1472–1479.
- [19] Teipel SJ, Grothe M, Lista S, et al. Relevance of magnetic resonance imaging for early detection and diagnosis of Alzheimer disease [J]. *Medical Clinics of North America*, 2013, 97(3): 399–424.
- [20] Moon SW, Lee B, Choi YC. Changes in the hippocampal volume and shape in early-onset mild cognitive impairment[J]. *Psychiatry Investigation*, 2018, 15(5): 531–537.

(2024-11-16收稿, 2025-02-03修回)

