



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象学报 中国图形学报

2022
03
VOL.27

ISSN1006-8961
CN11-3758/TB



医学图像及临床应用



第27卷第3期（总第311期）
2022年3月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院
主办单位 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

主 编 吴一戎
编辑出版 《中国图象图形学报》编辑出版委员会
通信地址 北京市海淀区北四环西路19号
邮 编 100190
电子信箱 jig@aircas.ac.cn
电 话 010-58887035
网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号
总 发 行 北京报刊发行局
订 购 全国各地邮局
海外发行 中国国际图书贸易集团有限公司
(邮政信箱: 北京399信箱 邮编: 100048)
印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian | Monthly, Started in 1996

Superintended by Chinese Academy of Sciences
Sponsored by Aerospace Information Research Institute, CAS
China Society of Image and Graphics
Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Wu Yirong
Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics
Address No. 19, North 4th Ring Road West, Haidian District, Beijing, P. R. China
Zip code 100190
E-mail jig@aircas.ac.cn
Telephone 010-58887035
Website www.cjig.cn


Distributed by Beijing Bureau for Distribution of Newspapers and Journals
Domestic All Local Post Offices in China
Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China)
Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB
ISSN 1006-8961
CODEN ZTTXFZ


国外发行代号 M1406
国内邮发代号 82-831
国内定价 60.00元



慢阻肺患者CT图像中肺内血管分割及定量分析(第0762页)



基于特征选择与残差融合的肝肿瘤分割模型(第0838页)



面向乳腺超声计算机辅助诊断的两阶段深度迁移学习(第0898页)

专刊封面展示了上海科技大学生物医学工程学院和上海联影智能医疗科技有限公司合作的脑影像智能分析方向研究成果。

《中国图象图形学报》医学图像及临床应用专刊简介

沈定刚, 刘天明, 周涛, 夏勇, 白相志, 王乾, 李刚, 徐寿平, 刘昊, 韩向娣 0653

综述

中国医学影像人工智能20年回顾和展望

蒋希, 袁奕宣, 王雅萍, 肖振祥, 朱美芦, 陈泽华, 刘天明, 沈定刚 0655

迁移学习在医学图像分类中的研究进展

黎英, 宋佩华 0672

生成对抗式网络及其医学影像应用研究综述

张颖麟, 胡衍, 东田理沙, 刘江 0687

基于深度学习的心脏磁共振影像超分辨率前沿进展

李书林, 冯朝路, 于鲲, 刘鑫, 江鑫, 赵大哲 0704

CT图像肺及肺病变区域分割方法综述

冯龙锋, 陈英, 周滔辉, 胡菲, 易珍 0722

计算机断层扫描图像

结构图注意力网络的新冠肺炎轻重症诊断

刘彦北, 李赫南, 张长青, 肖志涛, 张芳, 陈英, 高耀宗, 石峰, 单飞, 沈定刚 0750

慢阻肺患者CT图像中肺内血管分割及定量分析

赵宏, 李璋, 张杰华, 王琨, 孙家兴, 廖玺铭, 阎昱升, 钟正, 张鑫, 孙健, 于起峰, 葛俊辉 0762

基础信息保持和细节强化的胸部CT图像增强

张余, 张顺利, 白相志, 张利 0774

面向小样本股骨骨折分型的多视角注意力融合方法

张亚东, 汪玲, 兰海, 翟禹樵, 程洪 0784

三维多尺度嵌套U结构CT影像肺结节检测

许正奎, 张少敏, 支力佳, 周涛 0797

融合多尺度残差和注意力机制的特发性肺纤维化进展预测

陈舞, 孙军梅, 李秀梅 0812

COVID-19肺部CT图像多尺度编解码分割

陆倩杰, 柏正尧, 樊圣澜, 周雪, 许祝 0827

基于特征选择与残差融合的肝肿瘤分割模型

乔伟晨, 黄冕, 刘利军, 黄青松 0838

磁共振图像

面向多模态MRI脑胶质瘤区域三维分割与生存期预测的级联U-Net网络

余力, 刘霄雪, 闫朝阳, 李建瑞, 张志强, 黄轲, 徐军 0850

心脏动态MRI图像分割的时空多尺度网络

徐佳陈, 肖志勇 0862

融合跨阶段深度学习的脑肿瘤MRI图像分割

夏峰, 邵海见, 邓星 0873

融入平滑组稀疏化的脑部MRI图像分类

黄帅辉, 王金凤 0885

超声图像

面向乳腺超声计算机辅助诊断的两阶段深度迁移学习

贡荣麟, 施俊, 周玮珺, 汪程 0898

结合注意力机制的乳腺双模态超声分类网络

赵绪, 龚勋, 樊琳, 罗俊 0911

中医图像

视觉Transformer与多特征融合的脑卒中检测算法

赵琛琦, 王华虎, 赵涓涓, 冀伦文, 王麒达, 李慧芝, 赵紫娟 0923

多分支深度特征融合的中医脑卒中辅助诊断

王麒达, 冀伦文, 强彦, 王华虎, 赵琛琦, 李慧芝, 赵紫娟 0935

研究应用

多区域融合注意力网络模型下的核性白内障分类

章晓庆, 肖尊杰, Risa Higashita, 陈婉, 胡衍, 袁进, 刘江 0948

面向高度近视条纹损伤的深监督特征聚合网络

谭晓, 刁逸超, 陈新建, 石霏, 樊莹, 谢嘉受, 朱伟芳 0961

结合目标检测与匹配修正的手腕骨兴趣区域提取

毛科技, 汪敏豪, 陈立建, 陆伟, 武坤秀, 陈庆章, 赵小敏 0973

面向旷场实验视频分类的特征拼接矩阵学习方法


肖照林, 杨志林, 刘欢, 金海燕 0988

基于图像的介入器械前端变形建模与受力估计


任龙飞, 孟偲, 刘博, 白相志, 周付根 1001

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Segmentation and quantitative analysis of intrapulmonary vasculature in CT images from COPD patients(P0762)



Feature selection and residual fusion segmentation network for liver tumor(P0838)



Two-stage deep transfer learning for human breast ultrasound computer-aided diagnosis(P0898)

Review

- A 20-year retrospect and prospect of medical imaging artificial intelligence in China
Jiang Xi, Yuan Yixuan, Wang Yaping, Xiao Zhenxiang, Zhu Meilu, Chen Zehua, Liu Tianming, Shen Dinggang 0655
- Review of transfer learning in medical image classification
Li Ying, Song Peihua 0672
- A review of generative adversarial networks and the application in medical image
Zhang Yinglin, Hu Yan, Risa Higashita, Liu Jiang 0687
- Critical review of human cardiac magnetic resonance image super resolution reconstruction based on deep learning method
Li Shulin, Feng Chaolu, Yu Kun, Liu Xin, Jiang Xin, Zhao Dazhe 0704
- Review of human lung and lung lesion regions segmentation methods based on CT images
Feng Longfeng, Chen Ying, Zhou Taohui, Hu Fei, Yi Zhen 0722

Computerd Tomography Image

- Diagnosis of COVID-19 by using structural attention graph neural network
Liu Yanbei, Li Henan, Zhang Changqing, Xiao Zhitao, Zhang Fang, Wei Ying, Gao Yaozong, Shi Feng, Shan Fei, Shen Dinggang 0750
- Segmentation and quantitative analysis of intrapulmonary vasculature in CT images from COPD patients
Zhao Hong, Li Zhang, Zhang Jiehua, Wang Kun, Sun Jiaxing, Liao Ximing, Yan Yusheng, Zhong Zheng, Zhang Xin, Sun Jian, Yu Qifeng, Ge Junhui 0762
- Human chest CT image enhancement based on basic information preservation and detail enhancement
Zhang Yu, Zhang Shunli, Bai Xiangzhi, Zhang Li 0774
- Multi-view attention fusion method for few-shot femoral fracture classification
Zhang Yadong, Wang Ling, Lan Hai, Zhai Yuqiao, Cheng Hong 0784
- Detection of pulmonary nodules in three-dimensional multiscale nested U-structure computed tomography images
Xu Zhengxi, Zhang Shaomin, Zhi Lijia, Zhou Tao 0797
- Multi-scale residual and attention mechanism fusion based prediction for the progression of idiopathic pulmonary fibrosis
Chen Wu, Sun Junmei, Li Xiumei 0812
- Multiscale codec network based CT image segmentation for human lung disease derived of COVID-19
Lu Qianjie, Bai Zhengyao, Fan Shenglan, Zhou Xue, Xu Zhu 0827
- Feature selection and residual fusion segmentation network for liver tumor
Qiao Weichen, Huang Mian, Liu Lijun, Huang Qingsong 0838

Magnetic Resonance Image

- Brain glioma tumor segmentation and survival prediction from multi-modality MRIs via cascaded U-Net
Yu Li, Liu Xiaoxue, Yan Chaoyang, Li Jianrui, Zhang Zhiqiang, Huang Yunzhi, Xu Jun 0850
- A spatio-temporal multi-scale network for cardiac dynamic MRI image segmentation
Xu Jiachen, Xiao Zhiyong 0862
- Cross-stage deep-learning-based MRI fused images of human brain tumor segmentation
Xia Feng, Shao Haijian, Deng Xing 0873
- Brain MRI image classification incorporating smooth group sparseness
Huang Shuaihui, Wang Jinfeng 0885

Ultrasound Image

- Two-stage deep transfer learning for human breast ultrasound computer-aided diagnosis
Gong Ronglin, Shi Jun, Zhou Weijun, Wang Cheng 0898
- Attention-based networks of human breast bimodal ultrasound imaging classification
Zhao Xu, Gong Xun, Fan Lin, Luo Jun 0911

Traditional Chinese Medical Image

- Cerebral stroke detection algorithm for visual Transformer and multi-feature fusion
Zhao Chenqi, Wang Huahu, Zhao Juanjuan, Ji Lunwen, Wang Qida, Li Huizhi, Zhao Zijuan 0923
- Multi-branch deep feature fusion method for traditional Chinese medicine intervened Human cerebral stroke aided diagnosis
Wang Qida, Ji Lunwen, Qiang Yan, Wang Huahu, Zhao Chenqi, Li Huizhi, Zhao Zijuan 0935

Research and Application

- Nuclear cataract classification based on multi-region fusion attention network model
Zhang Xiaoqing, Xiao Zunjie, Risa Higashita, Chen Wan, Hu Yan, Yuan Jin, Liu Jiang 0948
- Deep-supervision and feature-aggregation network for linear lesion segmentation of high myopia
Tan Xiao, Diao Yichao, Chen Xinjian, Shi Fei, Fan Ying, Xie Jiamin, Zhu Weifang 0959
- Hand-wrist region of interest extraction based on object detection and matching correction
Mao Keji, Wang Minhao, Chen Lijian, Lu Wei, Wu Kunxiu, Chen Qingzhang, Zhao Xiaomin 0973
- A spliced feature matrices learning method for open field test video classification
Xiao Zhaolin, Yang Zhilin, Liu Huan, Jin Haiyan 0988
- Image-based deformation modeling and force estimation of the front end of vascular interventional surgical apparatus
Ren Longfei, Meng Cai, Liu Bo, Bai Xiangzhi, Zhou Fugen 1001

中图法分类号: TP181 文献标识码: A 文章编号: 1006-8961(2022)03-0885-13

论文引用格式: Huang S H and Wang J F. 2022. Brain MRI image classification incorporating smooth group sparseness. Journal of Image and Graphics, 27(03):0885-0897(黄帅辉,王金凤. 2022. 融入平滑组稀疏化的脑部 MRI 图像分类. 中国图象图形学报, 27(03):0885-0897)[DOI:10.11834/jig.210367]

融入平滑组稀疏化的脑部 MRI 图像分类

黄帅辉, 王金凤*

华南农业大学数学与信息学院, 广州 510642

摘要: **目的** 阿尔茨海默症(Alzheimer's disease, AD)是主要的老年病之一,并正向年轻化发展。早期通过核磁共振(magnetic resonance imaging, MRI)图像识别 AD 的发病阶段,有助于在 AD 初期及时采取相关干预措施和治疗手段,控制和延缓 AD 疾病恶化。为此,提出了基于平滑函数的组 $L1/2$ 稀疏正则化(smooth group $L1/2$, SGL $1/2$)方法。**方法** 通过引入平滑组 $L1/2$ 正则化实现组内稀疏,并将原先组 $L1/2$ 方法中含有的非平滑的绝对值函数向平滑函数逼近,解决了组 $L1/2$ 方法中数值计算振荡和收敛难的缺点。SGL $1/2$ 方法能够在保持分类精度的前提下,加速对模型的求解。同时在分类方法中,引入一个校准 hinge 函数(calibrated hinge, Chinge)代替标准支持向量机(support vector machine, SVM)中的 hinge 函数,形成校准 SVM(calibrated SVM, C-SVM)用于疾病的分类,使处于分类平面附近的样本更倾向于分类的正确一侧,对一些难以区分的样本能够进行更好的分类。**结果** 与其他组级别上的正则化方法相比, SGL $1/2$ 与校准支持向量机结合的分类模型对 AD 的识别具有更高的分类性能,分类准确率高达 94.70%。**结论** 本文提出的组稀疏分类模型,实现了组间稀疏和组内稀疏的优点,为未来 AD 的自动诊断提供了客观参照。

关键词: 阿尔茨海默症(AD);组 $L1/2$ 稀疏正则化;校准支持向量机(C-SVM);结构化磁共振;组间稀疏;组内稀疏

Brain MRI image classification incorporating smooth group sparseness

Huang Shuaihui, Wang Jinfeng*

College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China

Abstract: **Objective** Alzheimer's disease (AD) is one of the most common irreversible neurodegenerative diseases. The main clinical manifestation is cognitive impairment, which usually occurs in the middle-aged and elderly stage. The diagnosis and recognition of AD is constrained of the inefficient experience and mis-diagnosis of clinicians. If the onset stage of AD can be targeted in early diagnosis, it will yield relevant interference and treatment measures to the early stage of AD. A high accuracy automatic detection algorithm will help clinicians to prevent and treat AD. **Method** Structured magnetic resonance imaging (S-MRI) is used to extract gray matter density characteristics of each subject after pre-treatment. A group $L1/2$ sparsity method based on smoothing function (SGL $1/2$) is illustrated. This smooth grouping sparsity method is based

收稿日期:2021-06-01;修回日期:2021-09-26;预印本日期:2021-10-08

*通信作者:王金凤 wangjinfeng@scau.edu.cn

基金项目:广州市智慧农业重点实验室建设项目(201902010081);广东省科技计划项目(2017A040406023);广州市科技计划项目(201804010353)

Supported by: Guangzhou Key Laboratory of Intelligent Agriculture (201902010081); Science and Technology Planning Project of Guangdong Province (2017A040406023); Science and Technology Planning Project of Guangzhou City (201804010353)

on the common group $L1/2$ ($GL1/2$) method. $GL1/2$ method can aid Group Lasso method to select high correlation feature group without sparse the selected feature group, so it can remove some redundant features in redundant group and surviving group simultaneously. However, this group sparsity method has the difficulties of oscillation and convergence because it contains non-smooth absolute value function. The selected $SGL1/2$ method uses a smooth function to approximate the non-smooth absolute value function of the traditional $GL1/2$ method. The sparse model becomes a smooth model, which can quickly converge to the optimal value. Meanwhile, these regularization benchmark need to group features in advance at the group scale. In order to obtain scientific grouping of human brain features, a registered anatomical automatic labeling (AAL) template, which registers the original AAL template into the standard template, so that the obtained AAL template has the same spatial distribution as each pre-processed targeting image. Based on this grouping template, each region is regarded as a group. All voxels in each region are targeted as the features of each group for group sparing. In respect of classification method, a calibrated hinge is opted to substitute the hinge loss function in SVM (calibrated SVM, C-SVM). C-SVM can make the points near the classification plane more inclined to the correct side of the classification. We select four classification methods, which are support vector machine (SVM), calibrated support vector machine (C-SVM), linear classification and logistic regression. C-SVM uses a calibrated hinge loss function to replace the hinge loss function of traditional support vector machine, and then classifies the features of AD and cognitive normal (CN) control group via a simple classification function. The analyzed results illustrates that the classification accuracy of C-SVM reaches 91.06%. We select C-SVM as the benchmark, and the $SGL1/2$ group sparse method is integrated based on registered AAL template to form the main classification method. **Result** The key demonstration is selected from the “ADNI1: Complete 2Yr 1.5T” dataset of Alzheimer’s disease neuroimaging initiative (ADNI) for training and testing, and compared the classification performance with the classification model combined with $GL1/2$ and $SGL1/2$ group level regularization methods. The calibration support vector machine classification model has a good classification effect on the recognition of AD based on $SGL1/2$ group sparsity method. In the control group of AD and CN control group, the classification accuracy reaches 94.70%. In order to show the generalization of the model, we also selected Cuingnet data sets from relevant for classification literatures. The results also confirmed that the illustrated model had qualified classification effect. In the control group of AD and CN, the accuracy rate reached 91.97%. In terms of the features of each group segmented by the registered AAL group template, the C-SVM model is used to classify, and the classification effect of each group region is obtained. We select six regions with the best classification effect, and compare the results of the targeted illustrated model. **Conclusion** The demonstrated $SGL1/2$ group sparse classification model is based on AAL grouping template proposed in this research. The priorities of inter group sparse and intra group sparse are evolved. The high correlation features of high correlation group are selected in all human brain regions, and realize the accurate location of high correlation brain regions with AD, which provides a benchmark for the automatic diagnosis of AD further.

Key words: Alzheimer’s disease (AD); smooth group $L1/2$; calibrated support vector machine (C-SVM); structured magnetic resonance imaging; inter group sparsity; intra group sparsity

0 引言

阿尔茨海默症 (Alzheimer’s disease, AD) (Mattson, 2004) 是一种由于大脑神经细胞死亡造成的不可逆的神经退行性疾病, 在临床上主要体现为智能损害。针对受试者是否患病或病情程度的不同, 主要分为认知正常 (cognitive normal, CN)、轻度认知功能障碍 (mild cognitive impairment, MCI) 和 AD 3 种。患者在 AD 的治疗过程中使用的一些治疗 AD 的药物只能在某种程度上延缓病情的恶化。因此, 实现

AD 早期诊断, 对 AD 的诊断与预防都有着至关重要的作用。现阶段由于没有系统化的诊断方式, 医生临床对 AD 诊断和后续治疗经常采用观察法, 但受人为影响较大, 不仅效率低下, 还容易造成误判 (Sakkalis, 2011)。因此, 智能化区分 AD 发展阶段是帮助临床医生预防和治疗 AD 的重要步骤。

核磁共振成像 (magnetic resonance imaging, MRI) (Frisoni 等, 2010; Feng 等, 2021; Lee 等, 2019) 是一种常见的生物标志物, 具有无创性、可用性以及对疾病发作后大脑变化的高度敏感性, 并具有高空间分辨率的脑形态可视化能力等一系列优点 (Lin,

2000), 是研究 AD 引起的各种脑结构和形态学变化的理想工具, 通常用于诊断 AD 的标准临床评估 (陈弘扬 等, 2021)。MRI 分为结构 MRI (structural MRI, s-MRI) 和功能 MRI (functional MR, f-MRI), 本文研究 s-MRI, 对 MRI 而言, 能够获取的图像数量通常远小于图像的特征维度, 并且图像中的许多特征与学习任务并不相关, 即具有小样本高维度的特性。对此, 如果先验知识不足, 可以考虑对大脑全体结构 (de Magalhães Oliveira 等, 2010; Liu 等, 2013) 的特征进行分析, 这种方法通过将每个结构的描述压缩成标量或低维表示, 并忽略其结构内部的详细信息, 从而获取关于整体的特征。此外如果可以结合一些标准的脑部模板进行配准, 将每个受试者图像映射到同一标准空间中, 再分别提取目标特征, 将大幅提升结构内的相关性, 以获取更为合理的特征分布。这些标准大脑模板通常将大脑分为若干个区域, 如 116 个区域的自动解剖标准模板 (anatomical automatic labeling, AAL) (Tzourio-Mazoyer 等, 2002)。

选择所有体素特征进行分类不是一个理想的选择。通过特征选择步骤 (Fung 和 Stoeckel, 2007) 或稀疏诱导范数 (时中荣 等, 2017) 降低特征数量和维度, 不仅能够提高分类精度, 还能产生更具临床意义的结果。

组级别上的范数针对特征进行分组, 以特征组为单位进行操作, 进行特征组间的稀疏和选取相关特征组。传统组稀疏正则化方法 (group lasso, GL) 是以组为级别的一种稀疏方法 (Yuan 和 Lin, 2006; Meier 等, 2008), 可以针对每个解剖组进行稀疏, 排除一些冗余的组, 但不能对组内特征进行稀疏, 因此无法去除组内一些冗余特征。针对此问题, 组 L1/2 稀疏正则化 (group L1/2, GL1/2) (Liu 等, 2016) 通过将 GL 中组内的非稀疏平方范数换成能实现稀疏效果的 L1/2 范数进行解决, 组 L1/2 稀疏正则化不仅可以去除冗余的组, 还可以对选取组的组内特征再次进行稀疏, 从而选取更为准确的特征, 以提升预测准确性。但这种方法仍有局限性, 由于包含一个非平滑的绝对值函数, 在数值计算中将会引起振荡, 很难收敛。

本文使用平滑的组 L1/2 稀疏正则化 (smooth groupL1/2, SGL1/2) (Li 等, 2018; Alemu 等, 2019; Fan 等, 2020) 方法, 将原先组 L1/2 方法中含有的非平滑的绝对值函数向平滑函数逼近, 解决组 L1/2 方

法中数值计算振荡和收敛难的缺点。在本研究中, 组级别使用经过与标准模板配准过的 AAL116 模板的各结构区域作为分组模板, 其配准流程如图 1 所示, 然后提取每个结构区域的体素作为各自的组, 在这种基础上实现对组级别上的正则化效果。本文将配准后的 AAL 模板分成的每个区域各当做一组, 每组中含有该组中所有的体素特征。同时通过 SGL1/2 结合 C-SVM 对每组的特征进行选择 and 分类, 将原先 GL1/2 方法中含有的非平滑的绝对值函数向平滑函数逼近, 解决 GL1/2 方法中数值计算振荡和收敛难的缺点。




图1 AAL 模板标准化过程图

Fig. 1 AAL template standardization process map
((a) AAL template map; (b) standard template map;
(c) standard AAL template map)

1 基于组稀疏方法的分类模型

本文对 GL、GL1/2 和 SGL1/2 这 3 种组级别上的正则化方法进行研究。

1.1 基于组稀疏化方法的特征提取

GL 主要处理的是组间的稀疏关系, 而对组内没有稀疏关系。GL 可以用于去除一些不相关组, 以达到减少数据特征维度、提升分类性能的目的。GL 的函数定义为

$$GL(\mathbf{x}) = \sum_{g=1}^G \beta_g \|\mathbf{x}_g\|_2 \quad (1)$$

式中, g 表示第 g 个组, β_g 表示第 g 个组的组权重, $\mathbf{x}_g$ 表示第 g 个组的特征。可以看到 GL 可以用于对组间的稀疏, 但不能对幸存组的组内特征进行稀疏。同时, 它的导函数可以近似为

$$\rho_{GL} = \max\left(0, \left(1 - \frac{\lambda \beta_g \alpha}{\|\mathbf{x}_g\|_2}\right) \mathbf{x}_g\right) \quad (2)$$

式中, λ 是正则化参数, β 是组权重, α 为近似梯度的步长。

GL1/2 范数有利于解决 GL 只能对组间进行稀疏而不能对组内特征稀疏的问题,它将 GL 中组间的结合方式从 L1 方法改变为一个 L1/2 方法,而组内从 L2 方法改变为一个 L1 方法。从而对组内特征能够进行稀疏选择且兼顾防止过拟合的效果。因此 GL1/2 既能去除冗余的特征组,又能够对幸存组的组内特征进行稀疏选择,以得到强相关组的强相关特征,最后经过分类模型训练,得到更好的分类精度。GL1/2 的函数定义为

$$GL_{\frac{1}{2}}(\mathbf{x}) = \sum_{g=1}^G \beta_g \sqrt{\|\mathbf{x}_g\|_1} \quad (3)$$

其导函数可近似为

$$\rho_{GL_{\frac{1}{2}}} = \max\left(0, \left(1 - \frac{\lambda \beta_g \alpha}{2 \|\mathbf{x}_g\|_1^{\frac{1}{2}}}\right) \text{sign}(\mathbf{x}_g)\right) \quad (4)$$

式中, β_g 表示不同组之间的权重,用于权衡每个组对分类的影响, sign 为符号函数。

SGL1/2 范数是对 GL1/2 的一种平滑逼近,虽然 GL1/2 不仅能去除冗余的特征组,还能够对幸存组的组内特征进行稀疏选择,但它与 L1/2 正则化类似,其定义为

$$\|\mathbf{x}\|_{\frac{1}{2}} = \sum_{g=1}^G \sqrt{\|\mathbf{x}_g\|_1} \quad (5)$$

由此可见, GL1/2 的缺点是涉及一个非光滑的绝对值函数,导致数值计算出现振荡,收敛分析困难。SGL1/2 提出对 GL1/2 中非光滑的绝对值函数进行平滑逼近,使得能够更快收敛和计算平稳。

SGL1/2 的函数定义为

$$GL_{\frac{1}{2}}(\mathbf{x}) = \sum_{g=1}^G \beta_g \sqrt{\|f(\mathbf{x}_g)\|_1} \quad (6)$$

SGL1/2 的导函数变为

$$\rho_{SGL_{\frac{1}{2}}} = \max\left(0, \left(1 - \frac{\lambda \beta_g \alpha}{2 \|f(\mathbf{x}_g)\|_1^{\frac{1}{2}}}\right) f'(\mathbf{x}_g)\right) \quad (7)$$

式中, $f'(\mathbf{x}_g)$ 为 $f(\mathbf{x}_g)$ 的导函数。SGL1/2 提出将 GL1/2 中的 $|\mathbf{x}|$ 用一个平滑函数 $f(x)$ 替代,其定义为

$$f(\mathbf{x}) = \begin{cases} |\mathbf{x}| & |\mathbf{x}| \geq c \\ -\frac{1}{8c^3}x^4 + \frac{3}{4c}x^2 + \frac{3}{8}c & |\mathbf{x}| < c \end{cases} \quad (8)$$

式中, c 为一个很小的正数, $f(\mathbf{x}) \in \left[\frac{3}{8}c, +\infty\right]$,

$f'(\mathbf{x}) \in [-1, 1]$, $f''(\mathbf{x}) \in \left[0, \frac{3}{2c}\right]$ 。

本文中特征提取均根据配准后 AAL 模板划分的脑区组进行提取,将获取各组的灰质密度体素作为各组的特征,如图 2 所示,受试者的大脑图像经过预处理后获得的灰质图像也与标准模板进行配准,以保证 AAL 分组模板和受试者大脑存在相同空间分布。将同样空间分布的 AAL 模板和受试者灰质图像进行定位,对所有受试者图像都在相同定位区域提取各脑区特征,这种方法可以很好地降低受试者个体的差异性,保证研究中提取的特征实用可靠。




图 2 图像预处理和各脑区组特征提取过程图

Fig. 2 Image preprocessing and feature extraction of brain regions ((a) original MRI map; (b) preprocessed gray matter map; (c) registered AAL template; (d) localization of AAL brain regions on gray matter map)

1.2 分类模型建立

支持向量机 (support vector machine, SVM) (Cortes 和 Vapnik, 1995) 是一种通过监督学习方式

对数据进行二元分类的广义线性分类器,其决策边界是对学习样本求解的最大边距超平面。支持向量机采用损失函数与最大边距项进行结合,通过求解

最小化问题来计算最优权重 $\mathbf{w}_{\text{opt}}$ 和偏置参数 $\mathbf{b}_{\text{opt}}$, 具体为

$$\{\mathbf{w}_{\text{opt}}, \mathbf{b}_{\text{opt}}\} = \operatorname{argmin} \frac{1}{n} \sum_{i=1}^n \mathcal{L}_{\text{lossfun}}(u)^2 + \frac{1}{2} \lambda_1 \|\mathbf{w}\|_2^2 \quad (9)$$

$$u = \mathbf{y}_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + \mathbf{b}) \quad (10)$$

式中, $\|\mathbf{w}\|_2^2$ 表示最大边距惩罚项, 它能够更好地进行分类的划分, 大边距惩罚项假设每个特征是独立的。 λ_1 是一个非负的参数, 表示最大边距惩罚。 权重 $\mathbf{w}$ 的维数与特征向量 $\mathbf{x}_i$ 的维数相同, $\mathbf{y}_i$ 是该疾病真实标签, $\mathbf{b}$ 为偏差。 传统的基于铰链损失函数的 SVM 模型具有良好的分类性能, 但对于两类间边界较模糊的情况, 仍有待提高。

采用基于一种校准 hinge (calibrated hinge, Chinge) 损失函数的 SVM (calibrated SVM, C-SVM) 作为终端分类器, 在特征提取模块的基础上完成 AD 的分类识别。 模型构建流程如图 3 所示。 C-SVM 采用 Chinge 作为损失函数, 具体为

$$\mathcal{L}_{\text{lossfun}}(u) = \mathcal{L}_{\text{Chinge}}(u) = 1 - \frac{1 + \max(0, u)}{2 + \text{abs}(u)} \quad (11)$$




图3 主要分类流程图

Fig.3 Main flow-process diagram

Chinge 函数分布如图 4 所示。当 $u > 0$ 时, u 越大, Chinge 损失越小; 当 $u \leq 0$ 时, u 越小, Chinge 损失越大。因此这个校准损失函数可以给分类超平面处于预测正确的一侧更小的损失, 给分类超平面处于预测错误的一侧更大的损失, 它从侧面向分类平面输出更大的损失。从而确保靠近超平面的样本的预测结果倾向于分布在正确的一侧。

此外, 对于单纯 SVM 模型来说, 权重是一个系数向量, 其中大部分是非零项 (Sun 等, 2018)。本研究选取的数据集是一个高维小样本数据, 因此选择




图4 Chinge 损失函数分布图

Fig.4 The distribution chart of Chinge loss function

所有体素特征进行分类是一个不太理想的选择, 特征数量过多、维度过大对程序运行有极大影响, 而且对分类效果没有多大提升, 甚至可能降低。因此, 为了减少样本特征数量, 降低运算成本, 本文采用基于配准的 AAL116 模板作为分组模板, 以大脑区域的灰质密度体素作为特征, 结合 SGL1/2 正则化的 C-SVM 分类模型, 这种模型的总代价函数定义为

$$f_{\text{SGL}_{\frac{1}{2}}} = \frac{1}{n} \mathcal{L}_{\text{Chinge}}(\mathbf{y}_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + \mathbf{b}))^2 + \frac{1}{2} \lambda_1 \|\mathbf{w}\|_2^2 + \lambda_2 \sum_{g=1}^G \beta_g \|f(\mathbf{w}_g)\|_{\frac{1}{2}} \quad (12)$$

该模型结合了校准 SVM 和 SGL1/2 的各自优点, 能够在保证分类效果的同时, 找到大脑特征关键区域中的关键体素, 具有很好的可解释性。对校准支持向量机函数定义和 SGL1/2 正则化模型分析可知, $f_{\text{SGL}_{\frac{1}{2}}}$ 模型是可微的, 能够使用梯度下降的方法进行极小化, 可以大幅减小模型求解的复杂度。

2 实现及分析

将 AAL116 模板作为分组模板, 以大脑区域的灰质密度体素作为特征, 结合 SGL1/2 正则化的 C-SVM 分类模型, 对经过预处理的 ADNI (Alzheimer's disease neuroimaging initiative) 数据集通过交叉验证进行训练和测试, 获取测试的分类效果, 并使用该分类模型对其他数据集进行重新训练与测试, 对比分类效果以验证模型的泛化性能。

2.1 数据预处理

使用的数据均来自阿尔茨海默病神经成像计划 (ADNI) 数据集 (<http://adni.loni.usc.edu>)。ADNI 的研究对象来自美国和加拿大的 50 多个地点, 主要目的是测试磁共振成像 (MRI)、正电子发射断层扫描 (positron emission tomography, PET)、其他生物标志物以及临床和神经心理学评估相结合是否可以应用于度量轻度认知损害 (MCI) 和早期阿尔茨海默病

(AD)的识别。

实验选取 ADNI 中公开的 ADNI1 : Complete 2Yr 1.5 T 的部分数据集 (Wyman 等,2013),MRI 图像为 T1 加权的 1.5 T MR 图像,共选择 511 例来自不同受试者的数据,包括 AD 患者 145 名, MCI 患者 209

名和正常对照 (control normal, CN) 组成员 157 名。在性别成分中,AD 男性 65 名,女性 80 名; MCI 男性 111 名,女性 98 名; CN 男性 65 名,女性 92 名。所选受试者详细情况如表 1 所示,其中 MMSE 表示简易精神状况检查(后同)。

表 1 ADNI 数据集的人员分布情况统计
Table 1 Distribution of ADNI datasets

类型	数量	年龄分布 (均值 ± 方差[范围])	性别分布 (M:男,F:女)	MMSE (均值 ± 方差[范围])
AD	145	77.4 ± 7.8 [56 - 91]	65M/80F	21.1 ± 5.1 [2 - 28]
MCI	209	76.1 ± 6.3 [55 - 91]	111M/98F	26.4 ± 3.1 [8 - 30]
CN	157	77.7 ± 6.1 [60 - 92]	65M/92F	29.2 ± 1.0 [24 - 30]

注:[] 中括号内的值分别代表数据集实际年龄分布范围和 MMSE 值分布范围。

采用 SPM (statistical parametric mapping) (骆姚星 等,2003) 对 MRI 图像提取的灰质体素特征进行计算,全过程使用 SPM 的默认参数。

另外,本研究选取 Cuingnet 等人 (2013) 的 Cuingnet 数据集进行测试,以比较模型的泛化性能。

在这个数据集中,509 名受试者都来自 ADNI,包括 162 例 CN、137 例 AD、76 例将在 18 个月内转为 AD 的 MCI (MCIc) 和 134 例保持稳定的 MCI (MCIs)。Cuingnet 数据集的特征描述如表 2 所示。

表 2 Cuingnet 数据集的人员分布情况统计
Table 2 Distribution of Cuingnet dataset

类型	数量	年龄分布 (均值 ± 方差[范围])	性别分布 (M:男,F:女)	MMSE (均值 ± 方差[范围])
AD	137	76.0 ± 7.3 [55 - 91]	67M/70F	23.2 ± 2.0 [18 - 27]
MCIc	76	74.8 ± 7.4 [55 - 88]	43M/33F	26.5 ± 1.9 [23 - 30]
MCIs	134	74.5 ± 7.2 [58 - 91]	84M/50F	27.2 ± 1.7 [24 - 30]
CN	162	76.3 ± 5.4 [60 - 90]	76M/86F	29.2 ± 1.0 [25 - 30]

注:[] 中括号内的值分别代表数据集实际年龄分布范围和 MMSE 值分布范围。

由于测试的不同脑部结构大小不一,在对图像进行特征提取前需进行预处理。本研究使用 SPM 软件在 MATLAB 平台对受试者的 sMRI 图像数据进行标准的数据预处理操作,获得不同大脑区域的灰度体积作为训练模型的输入特征。对每个 sMRI 图像数据的预处理流程如图 5 所示。首先对图像进行 AC-PC 校准 (Talairach 和 Tournoux, 1988), AC-PC 为前连合 (anterior commissure, AC) 后缘中点至后连合 (posterior commissure, PC) 前缘中点的连线,又称 AC-PC 线,在脑立体定位断层解剖研究中多以此线为基线。在这步操作中,先将图像的原点设置为中心,再将其注册到 MNI (montreal neurological institute) 空间中。之后对校正后的脑图进行去颅骨和分割处理,获取去除非脑组织的图像。然后对图像进行配准,配准使用的模板是剥离颅骨的 Colin27 模

板 (Aubert-Broche 等,2006),以获取更加清晰、高分辨率的空间模板。配准过后进行分割获取灰质图像,并对灰质图像结构进行归一化等一系列操作。

2.2 实验设置

实验环境在单机系统搭建,处理器为 Intel (R) Core (TM) i7-8750H CPU @ 2.20 GHz (2201 MHz), 32 GB 内存,通过 MATLAB2019a 进行相关实验的运行。在实验中,将预处理过的 ADNI 数据集分成 3 个对比组,分别为 AD 与 CN, AD 与 MCI 以及 CN 与 MCI。同时为了避免训练过程中的过拟合,使用 K-折交叉验证法 (Wu 等,2010; James 等,2013),并在数值训练中选择 K 值为 10,即 10 折交叉验证。采用准确度 (accuracy, ACC)、接受者工作特征曲线 (receiver operating characteristics curve, ROC) 下的面积 (area under curve, AUC)、灵敏度 (sensitivity,




图 5 图像预处理过程

Fig. 5 Image preprocessing process

((a) original MRI map; (b) AC-PC calibration; (c) skull removal; (d) segmentation and registration)

SEN)、特异性 (specificity, SPE)、精确率 (precision)、召回率 (recall)、几何平均值 (geometric mean, Gmean) 和 F1 分数 (F1-score) 等指标对分类性能进行评价。在实际 AD 分类中一般会出现 4 种情况: 若一个样本是 AD 类 (以下称为正类) 且预测为正类, 即为真正类 (true positive, TP); 若一个实例是非 AD 类 (以下称为负类) 但预测为负类, 即为假负类 (false negative, FN); 若一个实例是负类但预测为正类, 即为假正类 (false positive, FP); 若一个实例是负类且预测为负类, 即为真负类 (true negative, TN)。根据这 4 种分类, 使用的评价指标的具体定义为

$$f_{\text{ACC}} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (13)$$

$$f_{\text{AUC}} = \frac{\sum \text{rank}_i - \frac{(TP + TN) \times (TP + TN + 1)}{2}}{(TP + TN) \times (FP + FN)} \quad (14)$$

式中, $\sum \text{rank}_i$ 表示所有正样本的序号值之和。

$$f_{\text{recall}} = f_{\text{Sen}} = \frac{TP}{TP + FN} \times 100\% \quad (15)$$

$$f_{\text{Spe}} = \frac{TN}{TN + FP} \times 100\% \quad (16)$$

$$f_{\text{precision}} = \frac{TP}{TP + FP} \times 100\% \quad (17)$$

$$f_{\text{Gmean}} = \sqrt{f_{\text{recall}} \times f_{\text{Spe}}} \times 100\% \quad (18)$$

$$f_{\text{F1}} = \frac{2 \times f_{\text{precision}} \times f_{\text{recall}}}{f_{\text{precision}} + f_{\text{recall}}} \times 100\% \quad (19)$$

2.3 实施及结果分析

首先验证 SVM 算法采用不同损失函数对数据分类性能的影响, 以获取对数据集分类效果较好的模型; 之后对比在组级别上的 GL、GL1/2 范数和

SGL1/2 范数结合稀疏范数选择特征的分布和分类性能的效果; 而后使用结合 SGL1/2 范数的校准支持向量机 (C-SVM) 模型, 对更困难的对照组进行分类, 并获取其分类效果; 最后对 Cuingnet 数据集进行测试。

2.3.1 校准铰链损失函数对分类模型的性能影响

选取线性损失函数、逻辑损失函数、hinge 损失函数和 Chinge 损失函数进行对比, 验证基于不同损失函数的 SVM 模型对测试数据的分类性能。在数据集中对 AD 与 CN 对照组进行比较, 结果详见表 3。可以看出, Chinge 函数比其他损失函数具有更好的分类效果。C-SVM 的准确率高达 91.06%, 与 hinge 作为损失函数的标准 SVM 相比, 分类准确率提高了 2.65%, 同时高于线性分类的 90.40% 和逻辑回归的 83.77%。依据此结果, 本实验选择以 Chinge 为损失函数的 C-SVM 作为分类模型, 在接下来的测试中结合其他模型进行训练和测试。

表 3 不同模型的分类效果

Table 3 Classification effect of different models

分类方法	ACC	AUC	SPE	SEN
C-SVM (Chinge)	0.910 6	0.964 6	0.937 9	0.885 4
SVM(hinge)	0.884 1	0.951 8	0.910 3	0.859 9
线性分类	0.904 0	0.959 0	0.937 9	0.872 6
逻辑回归	0.837 7	0.914 1	0.875 9	0.802 5

注: 加粗字体为各列最优结果, 分类方法的括号内为损失函数。

2.3.2 组级别的稀疏化方法比较

根据组稀疏范数的定义, 在组级别的稀疏范数的分类模型中, 由于组稀疏的约束作用, 将倾向选择

与 AD 分类相关性较大的部分脑部区域,使得选中的每个区域内的体素相对集中,从而更好地展示与 AD 疾病有关的大脑区域。为了验证组稀疏范数的分类效果,选取 GL、GL1/2 和 SGL1/2 3 种组稀疏范数进行对比。图 6 展示了基于 AAL 模板的 GL 和 SGL1/2 校准支持向量机模型在大脑区域选取的重要分类区域,其中 λ_2 是用于控制组稀疏范数的超参数。可以看出,海马、海马旁回、舌回和梭状回等区域对于 AD 的分类非常重要,这些组方法基本上都选取了这些区域。不同的是, SGL1/2 方法对选中区域内的一些体素进行了稀疏,去除了一些相关度较低的体素,选中的脑部区域如表 4 所示。图 6(a) — (c) 是 C-SVM + SGL1/2 模型,能够选取高相关脑区的高相关体素,在加大正则化项惩罚时,只会去除相对相关度低的脑区和相关度高的脑区中相对相关度低的体素,因此红色标注区域会近似对称;图 6

(d) — (f) 是 C-SVM + Group Lasso (GL) 模型,仅针对组间进行稀疏,一旦认为某些脑区相对其他脑区相关性低时,将去除整个脑区中的所有体素。因此在加大正则化项惩罚时,会依次去除相对相关性低的完整脑区,导致惩罚较大时红色标注区域不完全对称的视觉效果。组级别范数的 C-SVM 在 AD 与 CN 上的分类性能如表 5 所示,图 7 是基于 AAL 模板的组方法模型分类性能比较。结合表 5 和图 7 可以看出,以 AAL 为分组模板的 SGL1/2 校准支持向量机有一个更好的分类效果,平均运行时间最短,而 GL1/2 + C-SVM 平均运行时间最长,这是由于 GL1/2 的不稳定性引起的。GL 的稀疏效果没有 SGL1/2 强,因此存在更慢的迭代求解速度。SGL1/2 范数是对 GL1/2 的一种平滑逼近,二者的组稀疏效果大致相同,但是改进的平滑 GL1/2 范数 SGL1/2 能够使函数更快收敛,防止数据发生振荡。




图 6 基于 AAL 模板分组的组稀疏模型选中的组特征区域

Fig. 6 AAL template grouping based group feature regions selected by different group sparsity models

((a) SGL1/2 and $\lambda_2 = 0.0001$; (b) SGL1/2 and $\lambda_2 = 0.002$; (c) SGL1/2 and $\lambda_2 = 0.05$;

(d) GL and $\lambda_2 = 0.001$; (e) GL and $\lambda_2 = 0.01$; (f) GL and $\lambda_2 = 0.1$)

表 4 基于 SGL1/2 的 C-SVM 模型(本文模型)在 ADNI 的数据集上选择的脑区

Table 4 Selected brain regions of C-SVM model based on SGL1/2 (proposed model) in ADNI dataset

脑区编号	中文名称	脑区命名
3	左背外侧额上回	Frontal_Sup_L
37	左海马	Hippocampus_L
38	右海马	Hippocampus_R
39	左海马旁回	ParaHippocampal_L
40	右海马旁回	ParaHippocampal_R
41	左杏仁核	Amygdala_L
42	右杏仁核	Amygdala_R
43	左距状裂周围皮层	Calcarine_L
48	右舌回	Lingual_R
55	左梭状回	Fusiform_L
56	右梭状回	Fusiform_R
83	左颞极:颞上回	Temporal_Pole_Sup_L
89	左颞下回	Temporal_Inf_L

注:按 AAL 模板编号从小到大排序。

表 5 组级别范数的 C-SVM 在 AD 与 CN 上的分类性能
Table 5 Classification performance of group level norm C-SVM on AD and CN

组方法	ACC	AUC	SEN	SPE	平均时间/s
GL	0.940 4	0.978 6	0.937 9	0.942 7	738.11
GL1/2	0.947 0	0.977 4	0.951 7	0.942 7	103.402
SGL1/2	0.947 0	0.978 8	0.944 8	0.949 0	446.77

注:加粗字体为各列最优结果。




图 7 基于 AAL 模板的组方法模型的性能比较

Fig. 7 Classification performance comparison of group method models based on AAL template

2.3.3 对较难分辨的对照组的分类效果测试
本文结果表明平滑稀疏化在组级别上是有效

的,使得特征选择更加聚集,获取与疾病高度相关的局部区域,有更好的分类效果。前文比较了脑部形态差异最大的 AD 与 CN 组,在实际中,很多病患通常处在介于 AD 和 CN 之间的 MCI 状况,临床表现通常没有 AD 患者严重,这种状态与其他两种状态也更难进行区分,分类边界较为模糊。为了进一步验证模型性能,对 AD 组与 MCI 组、CN 组与 MCI 组进行分类测试,分组模板仍使用 AAL 模板,对比 GL 和 SGL1/2 两种组稀疏方法,结果如表 6 所示,表 6 中时间为平均求解时间。可以看出,在 AD 与 MCI 对照组中,SGL1/2 模型分类准确率为 71.47%,高于 GL 模型的 70.62%,平均运行时间较 GL 减少 269.34 s,效率提升 33.53%;在 MCI 与 CN 对照组中,SGL1/2 模型准确率为 78.81%,比 GL 模型高 1.97%,时间效率比 GL 提高 38.30%。

AD 与 MCI、CN 与 MCI 的分类效果分别如图 8 和图 9 所示。可以看出,基于 SGL1/2 范数的分类模型的性能都明显高于基于 GL 范数的分类模型。由此可见,基于 SGL1/2 的 C-SVM 模型在更困难的对照组中也能体现良好的分类效果,这对模型的可靠性是一个强有力的支持。

2.3.4 在 Cuingnet 数据集的分类性能

为了验证本文模型的泛化能力,使用 Cuingnet 数据集对本文模型进行训练和测试。根据不同疾病状态分为不同对照组,即 CN 与 MCI、AD 与 MCI 以及 MCIc 与 MCIs。其中,MCI 组由 MCIc 和 MCIs 合并而成。通过调整正则化项的超参数,在训练数据上进行重新优化,其他参数和其他模型一致,完成训练后再进行测试。本文模型与无稀疏操作和 GL 稀疏化两种方法的对比结果如表 7 所示,表 7 中时间为平均求解时间。可以看出,在所有对照组中,SGL1/2 的分类性能在大部分情况都高于其他模型的性能,仅在 CN 与 MCI 组呈较为接近状态,求解时间均大幅降低,在 AD 与 MCI 组和 CN 与 MCI 组中,在保持高于或近乎持平的分类性能前提下,时间效率较 GL 方法提升了近 60%,优势明显。同时,基于组范数的 C-SVM 的各项分类性能都优于无范数的 C-SVM 模型,同时 SGL1/2 略优于 GL,基于 SGL1/2 的 C-SVM 模型在 Cuingnet 数据集上也能相较于其他正则化范数达到更好的效果,这充分说明了该模型应对其他数据集时具有较强的泛化能力。

表 6 基于 SGL1/2 的 C-SVM 模型在困难对照组上的分类结果

Table 6 Classification performance of C-SVM model based on SGL1/2 in more difficult control group

对照组	稀疏方法	ACC	AUC	SEN	SPE	时间/s
AD 与 MCI	GL	0.706 2	0.801 3	0.724 1	0.693 8	803.32
	SGL1/2	0.714 7	0.803 3	0.737 9	0.698 6	533.98
CN 与 MCI	GL	0.768 4	0.831 7	0.793 1	0.751 2	784.50
	SGL1/2	0.788 1	0.859 9	0.827 6	0.760 8	484.05

注:加粗字体为对比组中各项性能的最优结果。




图 8 基于 SGL1/2 的 C-SVM 模型在 AD 与 MCI 的分类效果
Fig. 8 Classification effect of C-SVM model based on SGL1/2 in AD and MCI




图 9 基于 SGL1/2 的 C-SVM 模型在 CN 与 MCI 的分类效果
Fig. 9 Classification effect of C-SVM model based on SGL1/2 in CN and MCI

表 7 基于 SGL1/2 的 C-SVM 模型在 Cuingnet 数据集上的分类性能

Table 7 Classification performance of C-SVM model based on SGL1/2 on Cuingnet dataset

对照组	稀疏方法	ACC	AUC	SEN	SPE	时间/s
AD 与 CN	-	0.899 7	0.955 4	0.897 8	0.901 2	678.69
	GL	0.916 4	0.967 2	0.912 4	0.919 8	730.65
	SGL1/2	0.919 7	0.963 3	0.912 4	0.925 9	428.31
AD 与 MCI	-	0.639 8	0.686 1	0.678 8	0.614 3	1 361.82
	GL	0.648 4	0.702 3	0.678 8	0.628 6	1 698.31
	SGL1/2	0.651 3	0.713 5	0.686 1	0.628 6	520.52
CN 与 MCI	-	0.680 1	0.772 2	0.734 6	0.638 1	1 177.65
	GL	0.685 5	0.791 3	0.746 9	0.638 1	1 448.78
	SGL1/2	0.682 8	0.778 9	0.740 7	0.638 1	499.44
MCIc 与 MCI	-	0.628 6	0.667 2	0.684 2	0.597 0	468.97
	GL	0.661 9	0.679 8	0.723 7	0.626 9	649.78
	SGL1/2	0.661 9	0.687 6	0.710 5	0.634 3	359.18

注:加粗字体为对比组中各项性能的最优结果;“-”表示未使用组稀疏方法。

3 基于 AAL 模板的各特征组独立分类效果比较

为进一步了解与 AD 高度相关的单独脑部区域

对区分 AD 的效果,以 AAL 分组模板对进行分组的各组特征使用单独分类函数进行分类,对左右脑平均分类排名前 27 的脑部各区域及同一区域左右脑区的分类效果进行对比,结果如图 10 所示。其中,分类效果最好的右舌回(Lingual_R)、右海马旁回

(ParaHippocampal_R)、右海马(Hippocampus_R)、右梭状回(Fusiform_R)、左颞下回(Temporal_Inf_L)和左背外侧额上回(Frontal_Sup_L)6个脑区的具体分类效果如图11所示。

将高相关的单独组区域得到的最佳结果与基于SGL1/2正则化的C-SVM模型进行比较,如表4和图11所示,可以发现这种组稀疏方法也基本选

中了本文模型获取的分类准确率排名前6的脑区,证明了该组方法的可靠性。同时,本文模型在基于AAL模板中获得的分类准确率为94.70%,比高相关单独组经过非组稀疏的最佳分类准确率高2.32%,这一结果同样很好地证明了多个脑区之间存在一定的相关性,它们共同影响AD的发病。




图 10 单独分类模型在 AAL 模板中左右脑区域分类准确率比较
Fig. 10 Comparison of classification accuracy between left and right brain in AAL template




图 11 分类准确率排名前 6 的脑区
Fig. 11 Brain regions with top 6 classification accuracy

4 与现有方法比较

为了进一步验证本文基于 SGL1/2 组稀疏方法的 C-SVM 分类模型性能优越性,与多核学习方法 (multiple kernel learning, MKL) (Ben Ahmed 等, 2017)、3 维卷积神经网络 (3D convolutional neural networks, 3D-CNN) (khvostikov 等, 2018)、SVM + GL + SAR (spatial anatomical regularization) (Sun 等, 2018)、deep CNNs (convolutional neural networks) (Aderghal 等, 2018)、3 维卷积神经网络与长短期记忆网络 (3D convolutional neural networks—long short-term memory, C3d-LSTM) (Li 等, 2020) 和 SVM + ROICSE (ROI-based contourlet subband energy (Feng 等, 2021) 等 AD 诊断方法在 ADNI 数据库上进行对

比,以诊断准确率(ACC)为评判指标,结果如表8所示。可以看出,本文模型具有更好的分类效果。

表 8 不同方法分类性能比较

Table 8 Comparison of classification performance of different methods	
模型	ACC
MKL(Ben Ahmed 等,2017)	0.902 0
3D-CNN(Khvostikov 等,2018)	0.829 0
SVM + GL + SAR(Sun 等,2018)	0.893 0
deep CNNs(Aderghal 等,2018)	0.925 0
C3d-LSTM(Li 等,2020)	0.927 8
SVM + ROICSE(Feng 等,2021)	0.935 7
本文	0.947 0

注:加粗字体表示最优结果。

5 结 论

本研究提出基于解剖平滑分组的 $L_{1/2}$ 正则化方法,并结合校准支持向量机组合成分类框架,实现对阿尔茨海默症(AD)的分类。这种平滑解剖分组稀疏的方法以流行的 Group Lasso 为原型,针对性地解决了 Group Lasso 不能对每个解剖组内的特征进行稀疏的缺点,达到可以同时去除冗余组和相关组内一些冗余特征的效果。此外,针对组级别上的正则化范数提出了经过配准后的 AAL 模板,将每个区域作为一组,每个区域内所有体素作为每组的特征进行组稀疏。然后在提出的 C-SVM 框架中以组为级别进行训练,最后预测出受试者是否患有 AD。实验结果表明,本文模型结果比其他稀疏范数有更好的结果,分类准确率最高达 94.70%。同时,选中的权重分布较为集中,能够更好地发现与疾病高度相关的区域,增强了可解释性。根据权重图的分布情况可以将选定脑部区定位到 AD 相关的脑部区域,并且选择的区域也会较为集中。根据当前的知识可知,海马旁回、舌回和梭状回是与 AD 高度相关区域,权重图在这些区域也展现了较高的相关性,这为实验结果的合理性提供了有效支持。

参考文献 (References)

- Aderghal K, Khvostikov A, Krylov A, Benois-Pineau J, Afdel K and Catheline G. 2018. Classification of Alzheimer disease on imaging modalities with deep CNNs using cross-modal transfer learning//Proceedings of the 31st IEEE International Symposium on Computer-Based Medical Systems. Karlstad, Sweden; IEEE: 345-350 [DOI: 10.1109/CBMS.2018.00067]
- Alemu H Z, Zhao J H, Li F and Wu W. 2019. Group $L_{1/2}$ regularization for pruning hidden layer nodes of feed forward neural networks. IEEE Access, 7: 9540-9557 [DOI: 10.1109/ACCESS.2018.2890740]
- Aubert-Broche B, Evans A C and Collins L. 2006. A new improved version of the realistic digital brain phantom. NeuroImage, 32(1): 138-145 [DOI: 10.1016/j.neuroimage.2006.03.052]
- Ben Ahmed O, Benois-Pineau J, Allard M, Catheline G and Ben Amar C. 2017. Recognition of Alzheimer's disease and mild cognitive impairment with multimodal image-derived biomarkers and multiple kernel learning. Neurocomputing, 220: 98-110 [DOI: 10.1016/j.neucom.2016.08.041]
- Chen H Y, Gao J Y, Zhao D, Wang H Z, Song H and Su Q H. 2021. Review of the research progress in deep learning and biomedical image analysis till 2020. Journal of Image and Graphics, 26(3): 475-486 (陈弘扬, 高敬阳, 赵地, 汪红志, 宋红, 苏庆华. 2021. 深度学习与生物医学图像分析 2020 年综述. 中国图象图形学报, 26(3): 475-486)
- Cortes C and Vapnik V. 1995. Support-vector networks. Machine Learning, 20(3): 273-297 [DOI: 10.1023/A: 1022627411411]
- Cuingnet R, Glaunès J A, Chupin M, Benali H and Colliot O. 2013. Spatial and anatomical regularization of SVM: a general framework for neuroimaging data. IEEE Transactions on Pattern Analysis and Machine Intelligence, 35(3): 682-696 [DOI: 10.1109/TPAMI.2012.142]
- De Magalhães Oliveira P P Jr, Nitrini R, Busatto G, Buchpiguel C, Sato J R and Amaro E Jr. 2010. Use of SVM methods with surface-based cortical and volumetric subcortical measurements to detect Alzheimer's disease. Journal of Alzheimer's Disease, 19(4): 1263-1272 [DOI: 10.3233/JAD-2010-1322]
- Fan Q W, Niu L and Kang Q. 2020. Regression and multiclass classification using sparse extreme learning machine via smoothing group $L_{1/2}$ regularizer. IEEE Access, 8: 191482-191494 [DOI: 10.1109/ACCESS.2020.3031647]
- Feng J W, Zhang S W and Chen L N. 2021. Extracting ROI-based contourlet subband energy feature from the sMRI image for Alzheimer's disease classification. IEEE/ACM Transactions on Computational Biology and Bioinformatics, online: 1-1 [DOI: 10.1109/TCBB.2021.3051177]
- 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(2): 67-77 [DOI: 10.1038/nrneurol.2009.215]
- Fung G and Stoeckel J. 2007. SVM feature selection for classification of SPECT images of Alzheimer's disease using spatial information. Knowledge and Information Systems, 11(2): 243-258 [DOI: 10.1007/s10115-006-0043-5]
- James G, Witten D, Hastie T and Tibshirani R. 2013. An Introduction to Statistical Learning: with Applications in R. New York, USA: Springer
- Khvostikov A, Aderghal K, Benois-Pineau J, Krylov A and Catheline G. 2018. 3D CNN-based classification using sMRI and MD-DTI images for Alzheimer disease studies [EB/OL]. [2021-05-01]. <https://arxiv.org/pdf/1801.05968v1.pdf>
- Lee B, Ellahi W and Choi J Y. 2019. Using deep CNN with data permutation scheme for classification of Alzheimer's disease in structural magnetic resonance imaging (sMRI). IEICE Transactions on Information and Systems, E102.D(7): 1384-1395 [DOI: 10.1587/transinf.2018EDP7393]
- Li F, Zurada J M and Wu W. 2018. Smooth group $L_{1/2}$ regularization for input layer of feedforward neural networks. Neurocomputing, 314:

- 109-119 [DOI: 10.1016/j.neucom.2018.06.046]
- Li W, Lin X F and Chen X. 2020. Detecting Alzheimer's disease based on 4D fMRI: an exploration under deep learning framework. *Neurocomputing*, 388: 280-287 [DOI: 10.1016/j.neucom.2020.01.053]
- Lin W L. 2000. Principles of magnetic resonance imaging: a signal processing perspective [book review]. *IEEE Engineering in Medicine and Biology Magazine*, 19(5): 129-130 [DOI: 10.1109/EMMB.2000.870245]
- Liu M H, Suk H I and Shen D G. 2013. Multi-task sparse classifier for diagnosis of MCI conversion to AD with longitudinal MR images // The 4th International Workshop on Machine Learning in Medical Imaging. Nagoya, Japan: Springer: 243-250 [DOI: 10.1007/978-3-319-02267-3_31]
- Liu S C, Zhang J S, Liu J M and Yin Q Y. 2016. $L_{1/2,1}$ group sparse regularization for compressive sensing. *Signal, Image and Video Processing*, 10(5): 861-868 [DOI: 10.1007/s11760-015-0829-6]
- Luo Y X, Tang Y Y, Wu J L and Song H S. 2003. Introduction of brain functional imaging analysis software SPM. *Chinese Journal of Medical Imaging Technology*, 19(7): 926-928 (骆姚星, 唐一源, 伍建林, 宋鹤山. 2003. 脑功能成像分析软件 SPM 使用介绍. *中国医学影像技术*, 19(7): 926-928) [DOI: 10.3321/j.issn:1003-3289.2003.07.057]
- Mattson M P. 2004. Pathways towards and away from Alzheimer's disease. *Nature*, 430 (7000): 631-639 [DOI: 10.1038/nature02621]
- Meier L, Geer S V D and Bühlmann P. 2008. The group lasso for logistic regression. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 70(1): 53-71 [DOI: 10.1111/j.1467-9868.2007.00627.x]
- Sakkalis V. 2011. Review of advanced techniques for the estimation of brain connectivity measured with EEG/MEG. *Computers in Biology and Medicine*, 41 (12): 1110-1117 [DOI: 10.1016/j.compbiomed.2011.06.020]
- Shi Z R, Wang S and Liu C C. 2017. Sparse representation via $L_{2,p}$ norm for image classification. *Journal of Nanjing University of Science and Technology*, 41(1): 80-89 (时中荣, 王胜, 刘传才. 2017. 基于 $L_{2,p}$ 矩阵范数稀疏表示的图像分类方法. *南京理工大学学报*, 41(1): 80-89) [DOI: 10.14177/j.cnki.32-1397n.2017.41.01.011]
- Sun Z, Qiao Y C, Lelieveldt B P F and Staring M. 2018. Integrating spatial-anatomical regularization and structure sparsity into SVM: improving interpretation of Alzheimer's disease classification. *NeuroImage*, 178: 445-460 [DOI: 10.1016/j.neuroimage.2018.05.051]
- Talairach J and Tournoux L. 1988. Co-Planar Stereotaxic Atlas of the Human Brain: 3-Dimensional Proportional System: an Approach to Cerebral Imaging. New York, USA: Thieme Medical Publishers
- Tzourio-Mazoyer N, Landeau B, Papathanassiou D, Crivello F, Etard O, Delcroix N, Mazoyer B and Joliot M. 2002. Automated anatomical labeling of activations in SPM using a macroscopic anatomical parcellation of the MNI MRI single-subject brain. *NeuroImage*, 15(1): 273-289 [DOI: 10.1006/nimg.2001.0978]
- Wu W, Li L, Yang J and Liu Y. 2010. A modified gradient-based neuro-fuzzy learning algorithm and its convergence. *Information Sciences*, 180(9): 1630-1642 [DOI: 10.1016/j.ins.2009.12.030]
- Wyman B T, Harvey D J, Crawford K, Bernstein M A, Carmichael O, Cole P E, Crane P K, DeCarli C, Fox N C, Gunter J L, Hill D, Killiany R J, Pachai C, Schwarz A J, Schuff N, Senjem M L, Suhy J, Thompson P M, Weiner M, Jack C R Jr and Alzheimer's Disease Neuroimaging Initiative. 2013. Standardization of analysis sets for reporting results from ADNI MRI data. *Alzheimer's and Dementia*, 9(3): 332-337 [DOI: 10.1016/j.jalz.2012.06.004]
- Yuan M and Lin Y. 2006. Model selection and estimation in regression with grouped variables. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 68 (1): 49-67 [DOI: 10.1111/j.1467-9868.2005.00532.x]

作者简介



黄帅辉, 1997年生, 男, 硕士研究生, 主要研究方向为医学图像识别。

E-mail: 13979445473@163.com



王金凤, 通信作者, 女, 副教授, 主要研究方向为机器学习和图像识别。

E-mail: wangjinfeng@scau.edu.cn