



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 图形学报

2021
09
VOL.26

ISSN1006-8961
CN11-3758/TB



“深度学习+智慧医疗”专刊



第26卷第9期（总第305期）
2021年9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



肺部影像解剖结构分割数据集及应用(第2111页)



LFSCA-UNet: 基于空间与通道注意力机制的肝纤维化区域分割网络(第2121页)



语义拉普拉斯金字塔多中心乳腺肿瘤分割网络(第2193页)

编者按 I

综述

深度医学图像配准研究进展: 迈向无监督学习

马露凡, 罗凤, 严江鹏, 徐哲, 罗捷, 李秀 2037

U-Net网络医学图像分割应用综述

周涛, 董雅丽, 霍兵强, 刘珊, 马宗军 2058

医学图像深度学习技术: 从卷积到图卷积的发展

唐朝生, 胡超超, 孙君顶, 司马海峰 2078

多尺度变换像素级医学图像融合: 研究进展、应用和挑战

周涛, 刘珊, 董雅丽, 霍兵强, 马宗军 2094

数据集论文

肺部影像解剖结构分割数据集及应用

覃文军, 李小硕, 周庆华, 刘盼, 杨金柱 2111

计算机断层扫描图像

LFSCA-UNet: 基于空间与通道注意力机制的肝纤维化区域分割网络

陈弘扬, 高敬阳, 赵地, 吴忌, 陈金军, 全显跃, 李欣明, 薛峰, 周沐瑶, 柏冰冰 2121

融合上下文和多尺度特征的胸部多器官分割

吉淑滢, 肖志勇 2135

注意力机制下密集空洞卷积的肺部图像分割

郭宁, 柏正尧 2146

融合注意力机制和特征金字塔网络的CT图像肺结节检测

张福玲, 张少敏, 支力佳, 周涛 2156

改进Faster R-CNN模型的CT图磨玻璃密度影目标检测

杨淑莹, 邓东升, 郑清春 2171

融合注意力机制与可变形卷积的多尺度骨病变检测

方成, 柏正尧 2181

磁共振图像

语义拉普拉斯金字塔多中心乳腺肿瘤分割网络

王黎, 曹颖, 郭顺超, 唐雷, 鄧子翔, 王荣品, 王丽会 2193

引入注意力机制和多视角融合的脑肿瘤MR图像U-Net分割模型

罗恺锴, 王婷, 叶芳芳 2208

集成注意力增强和双重相似性引导的多模态脑部图像配准

田梨梨, 程欣宇, 唐堃, 张健, 王丽会 2219

LRUNet: 轻量级脑肿瘤快速语义分割网络

何康辉, 肖志勇 2233

自适应多模态特征融合胶质瘤分级网络

王黎, 曹颖, 田梨梨, 陈祈剑, 郭顺超, 张健, 王丽会 2243

研究应用

面向运动想象脑电图识别的镜卷积神经网络

罗靖, 王耀杰, 刘光明, 王晓帆, 鲁晓峰, 黑新宏 2257

先验权重共享码本下内窥镜图像大肠病变分类

朱霆威, 李胜, 何熊熊 2270

融合空洞卷积与注意力的胃癌组织切片分割

陈颖锲, 李晗, 周雪婷, 万程 2281

视觉显著性的眼底图像视盘检测


吕鹏飞, 王莹, 王思齐, 于晓升, 吴成东 2293

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Pulmonary image anatomical structure segmentation dataset and applications(P2111)



LFSCA-UNet: liver fibrosis region segmentation network based on spatial and channel attention mechanisms(P2121)



Semantic Laplacian pyramids network for multicenter breast tumor segmentation(P2193)

Review

- Deep-learning based medical image registration pathway: towards unsupervised learning
Ma Lufan, Luo Feng, Yan Jiangpeng, Xu Zhe, Luo Jie, Li Xiu 2037
- U-Net and its applications in medical image segmentation:a review
Zhou Tao, Dong Yali, Huo Bingqiang, Liu Shan, Ma Zongjun 2058
- Deep learning-based medical images analysis evolved from convolution to graph convolution
Tang Chaosheng, Hu Chaochao, Sun Junding, Sima Haifeng 2078
- Research on pixel-level image fusion based on multi-scale transformation: progress application and challenges
Zhou Tao, Liu Shan, Dong Yali, Huo Bingqiang, Ma Zongjun 2094

Dataset

- Pulmonary image anatomical structure segmentation dataset and applications
Tan Wenjun, Li Xiaoshuo, Zhou Qinghua, Liu Pan, Yang Jinzhu 2111

Computerd Tomography Image

- LFSCA-UNet: liver fibrosis region segmentation network based on spatial and channel attention mechanisms
Chen Hongyang, Gao Jingyang, Zhao Di, Wu Ji, Chen Jinjun, Quan Xianxue, Li Xinming, Xue Feng, Zhou Muyao, Bai Bingbing 2121
- Integrated context and multi-scale features in thoracic organs segmentation
Ji Shuying, Xiao Zhiyong 2135
- The integration of attention mechanism and dense atrous convolution for lung image segmentation
Guo Ning, Bai Zhengyao 2146
- Detection of pulmonary nodules in CT images by combining an attention mechanism and a feature pyramid network
Zhang Fuling, Zhang Shaomin, Zhi Lijia, Zhou Tao 2156
- Ground-glass opacity target detection in CT scans based on improved Faster R-CNN model
Yang Shuying, Deng Dongsheng, Zheng Qingchun 2171
- Multi-scale bone lesion detection based on attention mechanism and deformable convolution
Fang Cheng, Bai Zhengyao 2181

Magnetic Resonance Image

- Semantic Laplacian pyramids network for multicenter breast tumor segmentation
WANG Li, CAO Ying, Guo Shunchao, Tang Lei, Kuai Zixiang, Wang Rongpin, Wang Lihui 2193
- U-Net segmentation model of brain tumor MR image based on attention mechanism and multi-view fusion
Luo Kaikai, Wang Ting, Ye Fangfang 2208
- Multimodal brain image registration with integrated attention augmentation and dual similarity guidance
Tian Lili, Cheng Xinyu, Tang Kun, Zhang Jian, Wang Lihui 2219
- LRUNet: a lightweight rapid semantic segmentation network for brain tumors
He Kanghui, Xiao Zhiyong 2233
- Adaptive multi-modality fusion network for glioma grading
Wang Li, Cao Ying, Tian Lili, Chen Qijian, Guo Shunchao, Zhang Jian, Wang Lihui 2243

Research and Application

- Mirror convolutional neural network for motor imagery electroencephalogram recognition
Luo Jing, Wang Yaojie, Liu Guangming, Wang Xiaofan, Lu Xiaofeng, He Xinhong 2257
- Colorectal lesion classification of endoscopic images based on priori weight shared codebook application
Zhu Tingwei, Li Sheng, He Xiongxiang 2270
- The fusing of dilated convolution and attention for segmentation of gastric cancer tissue sections
Chen Yingsi, Li Han, Zhou Xueting, Wan Cheng 2281
- Optic disc detection based on visual saliency in fundus image
Lyu Pengfei, Wang Ying, Wang Siqi, Yu Xiaosheng, Wu Chengdong 2293

中图法分类号: TP391.4 文献标识码: A 文章编号: 1006-8961(2021)09-2257-13

论文引用格式: Luo J, Wang Y J, Liu G M, Wang X F, Lu X F and Hei X H. 2021. Mirror convolutional neural network for motor imagery electroencephalogram recognition. Journal of Image and Graphics, 26(09): 2257-2269 (罗靖, 王耀杰, 刘光明, 王晓帆, 鲁晓锋, 黑新宏. 2021. 面向运动想象脑电图识别的镜卷神经网络. 中国图象图形学报, 26(09): 2257-2269 [DOI:10.11834/jig.210072])

面向运动想象脑电图识别的镜卷神经网络

罗靖, 王耀杰, 刘光明, 王晓帆, 鲁晓锋, 黑新宏*

1. 西安理工大学计算机科学与工程学院, 西安 710048; 2. 陕西省网络计算与安全技术重点实验室, 西安 710048

摘要: **目的** 脑电图(electroencephalogram, EEG)是一种灵活、无创、非侵入式的大脑监测方法, 广泛应用于运动想象脑机接口系统中, 运动想象脑电图识别精度是决定系统性能的关键因素。然而由于脑电图采集时间长、个体差异大等原因, 导致单个受试者可用于模型训练的样本数量少, 严重影响了卷积神经网络在脑电图识别任务中的表现。为此, 本文提出一种镜卷神经网络(mirror convolutional neural network, MCNN)模型, 使用集成学习与数据扩增方法提高运动想象脑电图识别精度。**方法** 在训练阶段, 基于源脑电通过互换左右侧脑电通道构造镜像脑电, 并与源脑电一起用于源卷积网络训练, 有效扩增了训练样本; 在预测阶段, 复制已训练源卷积网络作为镜像卷积网络, 将测试集中的源脑电输入源卷积网络, 构造的镜像脑电输入镜像卷积网络, 集成源卷积网络与镜像卷积网络输出的类别预测概率, 形成最终类别预测。**结果** 为了验证模型的有效性和通用性, 基于3种不同运动想象脑电图识别卷积网络模型分别构造镜卷神经网络, 并在第4届脑机接口大赛2a与2b数据集上进行实验验证。实验结果与原始模型相比, 运动想象四分类和二分类准确率分别平均提高了4.83%和4.61%, 显著提高了识别精度。**结论** 本文面向运动想象脑电图识别, 提出了镜卷神经网络模型, 通过集成学习与数据扩增方法提高运动想象识别精度, 有效改善了运动想象脑机接口性能。

关键词: 脑机接口(BCI); 运动想象; 镜卷神经网络(MCNN); 脑电图(EEG); 数据扩增; 集成学习

Mirror convolutional neural network for motor imagery electroencephalogram recognition

Luo Jing, Wang Yaojie, Liu Guangming, Wang Xiaofan, Lu Xiaofeng, Hei Xinhong*

1. School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China;
2. Shaanxi Key Laboratory for Network Computing and Security Technology, Xi'an 710048, China

Abstract: Objective Apart from the neuromuscular system, the brain-computer interface (BCI) has provided an alternative way to convey the intention of the brain. For patients who have lost their ability to control their bodies, the BCI technique can recognize the state of the brain and send control order to external assistive devices, assisting patients in their daily lives. For healthy people, the BCI technique can greatly improve multimedia and video game experience and has promising commercial value. Electroencephalogram (EEG) is a flexible and noninvasive brain monitoring method that has been widely used in BCI systems based on motor imagery. The performance of such systems mainly depends on the classification accuracy of motor imagery EEG. In a motor imagery BCI system, EEG signals are recorded when a subject is imaging a spe-

收稿日期: 2021-02-07; 修回日期: 2021-06-01; 预印本日期: 2021-06-08

* 通信作者: 黑新宏 heixinhong@xaut.edu.cn

基金项目: 国家自然科学基金项目(61906152, 62076201, 61976177); 陕西省重点研发计划项目(2021GY-080)

Supported by: National Natural Science Foundation of China(61906152, 62076201, 61976177); Key Research and Development Program of Shanxi Province, China(2021GY-080)

cific movement, such as tongue, hand, or foot movement. Motor imagery is classified according to EEG signals. However, owing to long EEG collection time and obvious individual differences, the number of training samples belonging to one subject is small, seriously affecting the performance of convolutional neural network models in EEG recognition tasks. This paper proposes a mirror convolutional neural network (MCNN) that uses ensemble learning and data augmentation methods to improve the recognition accuracy of motor imagery EEG. **Method** The proposed MCNN model can be built on the basis of any motor imagery EEG recognition convolutional neural network (CNN) model. At the training stage, a sufficient number of samples ensure the successful training of an EEG recognition model. For a CNN-based method, training a CNN model needs large number of training samples to have good performance because of the numerous parameters that must be trained. However, the number of training samples in an EEG recognition task is usually small compared with that in a natural image classification task. Therefore, enlarging the number of EEG in a training set is a simple but efficient way to improve the effect of CNN model training. In this paper, we first proposed a mirror EEG construction method to enlarge a training set. A mirror EEG was constructed according to a source EEG by exchanging the left-side and right-side channels of the source EEG. For the left/right hand motor imagery-based EEG, the label of mirror EEG was set opposite to the label of the source EEG because event-related desynchronization and synchronization occur on the contralateral side of the brain. For other types of motor imagery EEG, for instance, feet or tongue motor imagery, the label of the mirror EEG was set in the same manner as the label of the source EEG. At the training stage, the source EEG and mirror EEG constructed on the basis of the source EEG were combined into an enlarged training set to train the source CNN model. This data augmentation method effectively expanded the training samples. At the prediction stage, MCNN improved the EEG recognition performance with the ensemble learning method. Specifically, the trained source CNN model is copied as the mirror CNN model. The source EEG is input into the source CNN model and the mirror EEG was input into the mirror CNN model. The average output category prediction probability of source CNN model and mirror CNN model was the final category prediction probability. In this way, the ensemble learning idea was applied without extra training session. **Result** To verify the effectiveness and universality of the proposed MCNN model, we constructed it according to three different motor imagery recognition CNN models, namely, the EEGNet, Shallow ConvNet, and Deep ConvNet. Experimental verification was performed on the Brain-Computer Interface Competition IV datasets 2a and 2b. Compared with the results obtained using the original model, the experimental results indicated that the accuracy of the four-category and two-category classification schemes for motor imagery increased by 4.83% and 4.59%, respectively, showing significant improvements. Enhanced performance was observed in different source CNN models, filters, and datasets. **Conclusion** The MCNN model was proposed for the EEG recognition of motor imagery BCI. The ideas of ensemble learning and data augmentation were applied to the design of the MCNN. The result showed that the MCNN considerably improved four-category and two-category motor imagery classification performance. Therefore, the proposed MCNN can greatly improve the performance of motor imagery-based BCIs.

Key words: brain-computer interface (BCI); motor imagery; mirror convolutional neural network (MCNN); electroencephalogram (EEG); data augmentation; ensemble learning

0 引言

脑电图 (electroencephalogram, EEG) 是一种灵活、无创、非侵入式的大脑监测方法, 基于脑电图的运动想象 (motor imagery) 识别是决定运动想象脑机接口 (brain computer interface, BCI) 系统性能的关键技术。运动想象脑机接口需要在受试者执行特定的运动想象任务时采集其脑电图, 根据脑电图识别运动想象内容, 然后将识别结果转换为命令以控制外围设备 (Edelman 等, 2019; Penaloza 和 Nishio,

2018)。脑电图具有低信噪比和低空间分辨率等特点, 因此, 从脑电图中提取有效判别特征是运动想象识别系统成功的关键 (Luo 等, 2019)。

基于运动想象识别的应用特征, 现有方法分为基于频谱特征、基于共空间模式 (common spatial pattern, CSP) 和基于神经网络的方法。基于事件相关去同步 (event-related desynchronization, ERD) 和事件相关同步 (event-related synchronization, ERS) 检测, 将时频分析技术用于运动想象 BCI 提取频谱特征 (杨默涵 等, 2017)。Morioka 等人 (2015) 使用经验模式分解、离散小波变换和小波包分解等频谱分

析方法从基于运动想象的脑电图中提取特征。实验结果表明,高阶小波包分解与多尺度主成分分析降噪相结合的方法获得了最佳的识别性能。Zheng 等人(2020)分析了脑电图与运动想象相关的功率谱,提取跨阶段或跨受试者的共享特征,将与原始数据最相关的特征迁移并用于训练分类模型。共空间模式及其变体在运动想象 BCI 中取得了巨大成功。CSP 旨在搜索最佳空间滤波器,最大化一类脑电图的方差并同时最小化另一类脑电图的方差(Lemm 等,2005)。很多 CSP 变种方法提出并用于运动想象分类(孟明 等,2016)。滤波器组共空间模式(filter bank CSP, FBCSP)算法首先使用覆盖 4~40 Hz 频率范围的 9 个带通滤波器处理脑电图,再使用 CSP 算法分别提取特征,经过特征选择后输入朴素贝叶斯分类器用于训练与分类。基于 FBCSP 的运动想象识别方法表现优异,在第四届脑机接口大赛 2a 数据集和 2b 数据集(Ang 等,2012)中赢得了冠军。Luo 等人(2020)提出一种基于集成支持向量学习的方法,以结合基于类别差异引导子带滤波器的 CSP 特征和时空差异特征的优点,提高运动想象分类精度。随着深度学习的发展,相关算法用于运动想象识别任务,基于卷积神经网络(convolutional neural network, CNN)的运动想象识别方法展现出良好的实验效果(郑云飞和陈霸东,2019)。Sakhavi 等人(2015)提出一种将 CNN 与静态能量网络相结合的方案,以提取脑电图的动态能量表示,在运动想象脑电分类中取得了很好的实验效果。Tabar 和 Halici(2017)使用一种结合脑电图的时间、频率和位置信息的 CNN 输入新形式,提出一种由卷积层和最大池化层组成的浅层 CNN 和一种结合堆叠式自动编码器的深层 CNN,用于运动想象分类。Schirmer 等人(2017)提出具有不同结构和设计选择的 CNN 模型 EEGDecoding,实现脑电图解码,用于运动想象或运动执行的识别。实验结果表明,提出的 Shallow ConvNet 和 Deep ConvNet 网络结构的性能优于其他结构,且批标准化(Ioffe 和 Szegedy, 2015)、Dropout(Srivastava 等, 2014)和 ELU(exponential linear units)(Clevert 等, 2015)等深度学习技术可以明显改善模型性能。Lawhern 等人(2018)提出的 EEG-Net 是一个紧凑的卷积网络,在 P300 视觉诱发电位(P300 visual-evoked potentials)、错误相关负反馈(error-related negativity responses)、运动相关皮质电

位(movement-related cortical potentials)和感觉运动节律(sensory motor rhythms)等 BCI 范式上均表现出色。Dai 等人(2020)提出一种混合卷积尺度网络,并采用新的数据扩增方法用于网络模型训练,取得了很高的分类精度。

虽然基于 CNN 的运动想象识别模型与传统方法相比已经取得一定突破,但由于脑电图采集时间长,个体差异明显,导致对特定受试者可用于训练的数据量有限,严重影响了 CNN 模型在脑电图识别任务中的性能。因此,增加训练集中的脑电图数量是提高模型训练效果的一种简单有效的方法。Zhang 和 Liu(2018)针对脑电图分类进行数据扩增,使用条件深度卷积生成对抗网络(conditional deep convolutional generative adversarial network)生成人造脑电图。实验结果表明,该数据扩增方法将运动想象脑电图分类的准确率从 83% 提高到 86% 左右。Wang 等人(2018)将高斯噪声添加到训练数据中获得人造脑电图样本,并在两个情感分类公共数据集上进行了测试。使用这种数据扩增方法,在 SEED 数据集上,LeNet 模型的准确率从 49.6% 提高到 74.3%, ResNet 模型的准确率从 34.2% 提高到 75.0%。在 MAHNOB-HCI 数据集上,ResNet 模型的准确率从 40.8% 增加到 45.4%。O'Shea 等人(2017)和 Ullah 等人(2018)使用重叠窗口作为增加脑电图训练样本数量的一种方式,实验结果表明,通过更小的移动生成更多的训练样本,能够使模型性能得到显著提高。脑电图数据扩增方法很多,但没有针对运动想象脑机接口的简单有效数据扩增方法。另外集成学习方法可以通过结合多个模型取得优于单个模型的性能,但通常需要额外训练多个模型。

本文提出一种基于镜卷积神经网络的运动想象脑电识别算法,通过构造镜像脑电图有效扩增训练样本数量,解决样本数量少对 CNN 训练质量的制约,并在不增加模型参数个数的前提下,通过集成学习方法提高运动想象分类的性能。具体地,首先通过源脑电图左右脑半球的脑电通道互换构造镜像脑电图,用于扩增运动想象训练数据集。在预测阶段,将已训练源模型复制形成镜像模型,源脑电图输入源模型,镜像脑电图输入镜像模型,结合源模型与镜像模型的输出类别概率形成最终预测类别。镜卷积神经网络结构具有通用性,可以基于不同 CNN 模型构建。为了验证提出的镜卷积神经网络的有效性和

通用性,在实验中使用 EEGNet (Lawhern 等,2018)、Shallow ConvNet 和 Deep ConvNet (Schirmer 等,2017) 等运动想象识别 CNN 模型构建卷积神经网络模型,并基于第四届脑机接口大赛数据集 2a 和 2b 对模型进行评价。

1 镜卷积神经网络模型

1.1 模型训练阶段

由于模型中包含大量待训练参数,因此性能优秀的 CNN 模型通常需要大量样本用于模型训练。但是,脑电图识别任务的训练样本数量通常比自然图像分类任务少很多,严重影响了 CNN 模型在运动想象任务中的表现。训练样本数量是制约卷积神经网络在运动想象脑电识别问题上能否成功的关键。本文提出镜像脑电图的构造方法,有效扩增了训练集样本数量。

运动想象会使局部皮质神经元兴奋性程度发生变化,从而改变局部脑电节律能量 (Meirovitch 等,2015)。这种时间锁定的频域能量变化通常可以使用频谱分析相关技术进行监测 (Kumar 和 Inbarani,2017)。频率能量降低称为事件相关去同步化,频率能量增加称为事件相关同步化 (Pfurtscheller 和 da Silva,1999)。例如,左手或右手的运动想象会在大脑对侧感觉运动区中引起事件相关去同步化现象,同时,事件相关同步化在大脑同侧感觉运动区中出现,然后事件相关同步化出现在大脑对侧感觉运动区 (Pfurtscheller 和 da Silva,1999)。因此,事件相关

去同步化与事件相关同步化现象出现在大脑感觉运动区的位置是运动想象分类的重要依据。事件相关去同步化与事件相关同步化现象的监测已广泛应用于运动想象分类,大多数基于频谱特征的方法 (Luo 等,2016) 和基于共空间模式的方法 (Ang 等,2012) 都以此为理论基础。由于事件相关去同步化与事件相关同步化现象出现在大脑的哪一侧是左右侧运动想象的重要表现,因此如果调换源脑电图左右脑半球的脑电通道,那么与源脑电图相比,事件相关去同步化与事件相关同步化现象会出现在对侧,而对应的左右两类运动想象内容应该相反。在双脚运动想象期间,大脑辅助运动区域 (supplementary motor area) 后部和初级运动皮层 (primary motor cortex) 中负责双脚的区域被激活 (Ehrsson 等,2001),中部纵裂区出现事件相关去同步化与同步化现象 (Pfurtscheller 和 da Silva,1999)。在舌头运动想象期间,前运动区域和初级运动皮层中左右对称负责舌头的区域被激活 (Ehrsson 等,2001)。从现有研究可以看出,这两种运动想象在大脑中并没有出现对侧优势,因此调换左右两侧脑电不会影响其运动想象内容。基于以上分析,本文提出镜像脑电图构造方法。

镜像脑电图是通过源脑电图左右脑半球的脑电通道互换位置得到的,如图 1 所示。图中 Fz、Cz、Pz 为 10—20 国际标准导联系统中电极位置,左侧颞骨乳突为参考 (Ref.),右侧颞骨乳突接地 (GND)。图中 C3 和 C4 通道分别是源脑电图的第 8 和第 12 通道,而在镜像脑电图中分别是第 12 和第 8 通道。这样,在左右手运动想象脑电图中,与源脑电图相比,




图 1 通过左右脑半球的脑电通道互换构造镜像脑电图

Fig. 1 Mirror EEG signals are constructed through exchanging of EEG channels from the left and right hemispheres

事件相关去同步化与事件相关同步化现象出现在镜像脑电图的对侧,因此,镜像脑电图的运动想象标签设置为与源脑电图的运动想象标签相反。例如源脑电标签为右手运动想象,对应镜像脑电标签则设置为左手运动想象,反之亦然。而在舌头和双脚等其他运动想象脑电图中,镜像脑电图的左右通道互换并不改变运动想象标签。在模型训练中,将包含源脑电图样本与镜像脑电图样本的训练集用于运动想象分类 CNN 模型的训练,训练好的运动想象分类 CNN 模型称为源模型。在模型训练中同时应用源脑电和镜像脑电也可以强调左右侧感觉运动区之间的脑电图差异,这是左右运动想象分类的重要基础,同时抑制了左右侧运动想象分类不相关的特性,因此对提高左右侧运动想象分类任务精度效果显著。

1.2 模型预测阶段

集成学习方法是一类高级的机器学习方法,通过训练多个基本模型并将其组合以解决问题,组合多个基本模型的集成模型比单个模型更准确。集成学习方法在许多实际任务中取得了很大成功,典型代表是 bagging 类和 boosting 类方法 (Zhou, 2012)。通常,集成学习方法需要利用多个训练周期得到多个基本模型,而本文利用镜卷积神经网络结构基于单个训练周期得到的单个基本 CNN 模型完成集成学习,在不增加训练成本的情况下提高模型预测精度。首先,复制已训练源模型作为镜像运动想象分类模型,源模型与镜像模型共同构成了镜卷积神经网络模型。因此,镜卷积神经网络模型的源模型与镜像模型的结构和参数相同。其次,构造镜像脑电图用于辅助源脑电图的识别,将测试集中的源脑电图输入源模型,镜像脑电图输入镜像模型,如图 2 所示。




图2 镜卷积神经网络示意图

Fig.2 Schematic diagram of mirror convolutional neural network

在左右手运动想象脑电图中,镜像脑电图与源脑电图相比,事件相关去同步化与事件相关同步化现象出现在大脑的对侧半球,所以镜像脑电图左手运动想象的预测概率相当于源脑电图右手运动想象的预测概率,反之亦然。因此,源模型和镜像模型的左右手运动想象输出预测概率交换并求平均,其他运动想象输出预测概率对应求平均,形成最终预测概率。在左手、右手、双脚和舌头四分类运动想象任务中,最终预测概率计算公式为

$$\begin{bmatrix} P_l \\ P_r \\ P_f \\ P_t \end{bmatrix} = \begin{bmatrix} \frac{P_l^s + P_r^m}{2} \\ \frac{P_r^s + P_l^m}{2} \\ \frac{P_f^s + P_f^m}{2} \\ \frac{P_t^s + P_t^m}{2} \end{bmatrix} \quad (1)$$

式中, P_l, P_r, P_f, P_t 分别是左手、右手、双脚与舌头运动想象的最终预测概率, $P_l^s, P_r^s, P_f^s, P_t^s$ 分别代表左手、右手、双脚与舌头运动想象的源模型输出概率, $P_l^m, P_r^m, P_f^m, P_t^m$ 分别代表左手、右手、双脚与舌头运动想象的镜像模型输出概率。最后,源脑电图的预测标签是最终预测概率最大的类别,计算公式为

$$I = \operatorname{argmax} P_i, i \in \{l, r, f, t\} \quad (2)$$

式中, I 是最终预测标签,下标 i 为类别标签 (l, r, f, t 分别代表左手、右手、双脚与舌头运动想象)。

由于 CNN 模型输出视为样本属于每个类别的概率,此操作是一种概率集成过程,而具有较大集成概率的类别将成为最终的预测标签。因此通过镜卷积神经网络结构,在不增加模型参数个数的前提下,利用集成学习方法提高了模型性能。

2 镜卷积神经网络的实例化

本文提出的镜卷积神经网络模型可以应用于任何运动想象识别 CNN 模型。为了验证镜卷积神经网络模型的有效性和通用性,在实验中使用 EEGNet (Lawhern 等, 2018) 和 EEGDecoding 的 Shallow ConvNet 和 Deep ConvNet (Schirrneister 等, 2017) 等流行的运动想象识别 CNN 模型。EEGNet 具有 3 个卷积层和 1 个全连接层,并应用批标准化、Drop out、最大池化和 ELU 激活函数 (Clevert 等, 2015), 依据 EEG-

Net 的感觉运动节律数据集实验结果,本文选用卷积核大小为 (2×32) 和 (8×4) 的模型。EEGDecoding 测试了4种运动想象 CNN 模型结构,本文仅选用其中分类效果更好的 Shallow ConvNet 和 Deep ConvNet。其中受 FBCSP 算法流程启发的 Shallow ConvNet 具有2个卷积层和1个完全连接的层,平方函数设置为激活函数。Deep ConvNet 是具有5个卷积层和1个全连接层的更深的 CNN,并且使用了 ELU 激活功能。在 EEGDecoding 模型中,应用了最大池化、Dropout 和批标准化等技术。

为了充分利用 CNN 模型的特征学习能力,仅对脑电图进行最少的预处理。实验使用 4.5 s 的脑电图段,采集自出现运动想象提示之前的 0.5 s 到之后的 4 s。用 4~38 Hz 或 0~38 Hz 两种带通滤波器对脑电图进行滤波,作为 CNN 模型输入(Schirrmeyer 等,2017)。每个模型的参数均按原文献设置,在训练阶段使用 Adam 优化方法(Kingma 和 Ba, 2014)。为了减少随机性和批次数量的影响,本文使用最大准确率与平均准确率来评估模型的精度。

本文实验基于 Braindecode 脑电处理工具箱(Schirrmeyer 等,2017)和 Pytorch 深度学习框架(Paszke 等,2019)实现,实验在 NVIDIA GeForce GTX 3090 GPU 上进行,显存为 24 GB,平台内存为 32 GB。

3 数据集

3.1 第4届国际脑机接口大赛数据集 2a

第4届国际脑机接口大赛数据集 2a(简称 2a 数据集)涉及4类基于脑电图的运动想象识别任务(Tangemann 等,2012),包含来自9个受试者的运动想象脑电图。对于每个受试者,训练阶段和测试阶段的数据采集自不同日期,各记录了288条脑电图(每个类别72条脑电图)。脑电图采集时,根据屏幕上的提示,受试者执行了4种不同类型的运动想象任务(左手,右手,舌头和双脚运动想象),同时采集22个通道的脑电图,使用的电极位置采用 10—20 国际标准导联系统,如图1左图所示。脑电图的采样率为 250 Hz,放大器的分辨率为 100 μ V。在每条脑电图采集中,提示均在 2 s 时出现在屏幕上,而运动想象任务的执行时间为 3~6 s,将 0.5~100 Hz 带通滤波器和 50 Hz 陷波滤波器用于预处理

采集的脑电图,在采集到的脑电图中,将异常脑电图标记为“Artifacts”。

3.2 第4届国际脑机接口大赛数据集 2b

第4届国际脑机接口大赛数据集 2b(简称 2b 数据集)包含来自9个受试者的两类运动想象任务(左手和右手运动想象)的脑电图(Tangemann 等,2012)。对于每个受试者,脑电图采集自不同日期的5个阶段,其中前3个阶段用做训练集,后两个阶段用做测试集。前2个阶段会在屏幕上显示提示采集脑电图而没有反馈,而后3个阶段基于笑脸反馈采集脑电图。每个阶段从通道 C3、Cz 和 C4 采集 120~160 条脑电图,采样频率为 250 Hz,异常脑电图人工标记为“Artifacts”。将 0.5~100 Hz 带通滤波器和 50 Hz 陷波滤波器用于预处理收集的脑电图,由于脑电图采集阶段设置不同,本文模型训练时仅使用第3阶段采集的脑电图,模型测试使用第4和第5阶段采集的脑电图。

4 实验结果与分析

4.1 镜卷积神经网络模型与原始模型的运动想象四分类精度比较

首先测试镜卷积神经网络模型在 2a 数据集上的四分类运动想象识别性能,并将镜卷积网络性能与原始卷积网络进行比较,结果如表1所示。由于训练通常收敛于500次迭代内,因此将训练的最大迭代次数设置为700,使用700次迭代内的最大测试准确率,501~600次迭代之间的平均测试集准确率(100次迭代平均准确率)和501~700次迭代之间的平均测试集准确率(200次迭代平均准确率)3种识别精度度量,以减少随机性和批次数量对识别精度的影响。实验结果为5次实验的平均值。镜卷积网络和原始网络模型的性能通过两者准确率之差进行衡量。

从表1可以看出:1)镜卷积神经网络模型在 2a 数据集四分类任务中表现优秀。与原始模型相比,最大准确率、100次和200次迭代平均准确率分别平均提高了4.55%、4.83%和4.79%。2)镜卷积神经网络结构对 EEGNet 模型的分性能提高最大。3)基于 Shallow ConvNet 和 0~38 Hz 带通滤波器的镜卷积网络在 2a 数据集四分类任务中表现最佳,100次和200次迭代平均准确率分别为78.73%和

表 1 镜卷积神经网络模型(MCNN)与原始模型在 2a 数据集的运动想象四分类精度比较
Table 1 Comparison of the four-category motor imagery classification accuracy on
2a dataset between MCNN and original model

模型	最大准确率			100 次迭代平均准确率			200 次迭代平均准确率		
	原始模型	MCNN	提高	原始模型	MCNN	提高	原始模型	MCNN	提高
EEGNet-0 Hz	69.41	75.28	5.86	64.59	70.50	5.91	64.79	70.61	5.83
Shallow-0 Hz	78.67	82.51	3.83	74.51	78.73	4.21	74.66	78.81	4.15
Deep-0 Hz	77.99	80.42	2.43	72.41	75.73	3.32	72.61	75.91	3.30
EEGNet-4 Hz	61.77	70.67	8.90	55.30	64.58	9.28	55.53	64.70	9.17
Shallow-4 Hz	79.44	80.45	1.01	75.43	76.09	0.65	75.57	76.23	0.66
Deep-4 Hz	63.52	68.80	5.28	58.22	63.82	5.60	58.27	63.89	5.61
平均	71.80	76.35	4.55	66.74	71.57	4.83	66.90	71.69	4.79

注:加粗字体表示各列最优结果。

78.81%。4)镜卷积神经网络对运动想象识别性能的提高具有通用性,独立于原始 CNN 模型与预处理带通滤波器。

Shallow-0 Hz 在实验中效果最好,9 位受试者实验结果的混淆矩阵如图 3 所示。可以看出,镜卷积神经

网络所有类别的分类精度都有一定幅度提高。Shallow-0 Hz 的原始模型与镜卷积神经网络模型对各受试者运动想象分类精度(100 次迭代平均准确率)比较如图 4 所示。可以看出,镜卷积网络模型对运动想象分类精度提升明显,其中对 6 号受试者提升最大。




图 3 镜卷积神经网络与原始模型在 2a 数据集四类运动想象分类任务中的混淆矩阵比较

Fig. 3 Comparison of confusion matrix on 2a dataset for four-category motor imagery classification tasks between MCNN and original model((a) original model; (b) MCNN)

4.2 镜卷积神经网络模型与原始模型的运动想象二分类精度比较

在二分类运动想象任务中基于 2a 和 2b 数据集对镜卷积神经网络与原始模型的表现进行比较,同样采用了 EEGNet、Shallow ConvNet 与 Deep ConvNet 第 3 种卷积模型作为原始模型,结果如表 2 和表 3

所示。在 2a 数据集中,对四分类运动想象仅使用左右手运动想象样本参与实验,完成二分类任务。采用最大测试准确率、100 次和 200 次迭代平均准确率评价模型分类效果。实验结果为 5 次实验的平均值。

从表 2 和表 3 可以看出:1)镜卷积神经网络模型在运动想象二分类任务中同样表现优秀,与原始




图4 镜卷积神经网络与原始模型在2a数据集中
各受试者4类运动想象分类精度的比较

Fig.4 Comparison of four-category motor imagery
classification accuracy on 2a dataset for each
subject between MCNN and original model

模型相比,最大准确率、100次和200次迭代平均准

确率分别平均提高了3.97%、4.59%和4.53%。2) 镜卷积神经网络在2a数据集中对EEGNet-4 Hz模型
的分类性能提高最大,平均准确率提高了9.49%
和9.39%,在2b数据集中对Deep ConvNet-0 Hz模
型的分类性能提高最大,平均准确率提高了6.68%
和6.63%。3)基于Shallow ConvNet和0~38 Hz带
通滤波器的镜卷积神经网络在2a数据集二分类任务中
表现最佳,平均准确率为89.15%和89.24%;基于
Deep ConvNet和0~38 Hz带通滤波器的镜卷积网
络在2b数据集二分类任务中表现最佳,平均准确率
为87.09%和87.12%。4)镜卷积神经网络对运动
想象识别性能的提高具有通用性,独立于原始CNN
模型与预处理带通滤波器。

表2 镜卷积神经网络模型(MCNN)与原始模型在2a数据集的运动想象二分类精度比较

Table 2 Comparison of two-category motor imagery classification accuracy on
2a dataset between MCNN and original model

模型	最大准确率			100次迭代平均准确率			200次迭代平均准确率		
	原始模型	MCNN	提高	原始模型	MCNN	提高	原始模型	MCNN	提高
	/%								
EEGNet-0 Hz	83.80	89.37	5.57	80.27	86.06	5.79	80.47	86.19	5.72
Shallow-0 Hz	88.83	91.37	2.55	86.08	89.15	3.07	86.16	89.24	3.08
Deep-0 Hz	85.94	88.56	2.62	82.20	85.59	3.40	82.38	85.69	3.30
EEGNet-4 Hz	79.37	88.04	8.67	74.62	84.10	9.49	74.98	84.37	9.39
Shallow-4 Hz	89.81	90.23	0.42	86.45	86.56	0.11	86.69	86.68	0.00
Deep-4 Hz	76.31	83.30	6.99	71.03	79.89	8.86	71.12	79.98	8.86
平均	84.01	88.48	4.47	80.11	85.23	5.12	80.30	85.36	5.06

注:加粗字体表示各列最优结果。

表3 镜卷积神经网络模型(MCNN)与原始模型在2b数据集的运动想象二分类精度比较

Table 3 Comparison of two-category motor imagery classification accuracy on
2b dataset between MCNN and original model

模型	最大准确率			100次迭代平均准确率			200次迭代平均准确率		
	原始模型	MCNN	提高	原始模型	MCNN	提高	原始模型	MCNN	提高
	/%								
EEGNet-0 Hz	82.41	86.28	3.88	80.03	83.74	3.70	80.08	83.75	3.67
Shallow-0 Hz	85.15	87.86	2.71	83.26	86.26	3.00	83.36	86.31	2.95
Deep-0 Hz	83.18	88.44	5.27	80.41	87.09	6.68	80.49	87.12	6.63
EEGNet-4 Hz	78.49	82.71	4.22	75.18	80.97	5.79	75.45	81.03	5.58
Shallow-4 Hz	80.42	82.10	1.68	78.38	79.93	1.56	78.39	79.97	1.57
Deep-4 Hz	80.60	83.65	3.06	77.82	81.67	3.85	77.85	81.68	3.83
平均	81.71	85.17	3.47	79.18	83.28	4.10	79.27	83.31	4.04

注:加粗字体表示各列最优结果。

综合表1—表3的实验结果可以发现,镜卷积神经网络模型对EEGNet模型效果改善最为明显,对Deep ConvNet网络次之,对Shallow ConvNet网络改善最小。运动想象脑电图识别问题是一个典型的小样本问题,例如在2a数据集中每位受试者的训练集包含了4类共288幅脑电图,2b数据集中每位受试者的训练集包含了2类120~160条脑电图,每个类别训练样本数量均在70左右。因此使用参数个数或层数较多的卷积神经网络时,训练样本个数不足就成为限制模型训练效果的瓶颈。本文提出的镜卷积神经网络模型通过数据扩增与概率集成的方法改善模型性能,因此对参数个数和层数更多的EEGNet与Deep ConvNet模型的提升效果更加显著。

4.3 数据扩增与概率集成对运动想象分类精度的改善

为了验证提出的镜卷积神经网络在训练阶段利用构造镜像脑电图进行数据扩增和在预测阶段利用镜卷积网络模型结构进行概率集成两种设置对运动想象脑电分类精度的影响,分别对仅使用数据扩增后的训练集对源模型进行训练和仅在预测阶段使用概率集成两种实验设置的分类效果进行测试比较。因为测试集最大准确率不能反映训练阶段的总体表现,且表1—表3中100次与200次迭代平均准确率非常接近,因此仅将100次迭代平均准确率作为分类结果评价指标。

基于2a数据集测试运动想象四分类效果的实验结果如表4所示,基于2a和2b数据集测试运动想象二分类效果的实验结果如表5和表6所示。可以看出:1)如果仅在预测阶段使用概率集成,与原始模型相比,准确率提高不明显。主要因为镜像脑电图没有用于模型训练,模型没有基于镜像脑电图的特点进行优化,直接将测试集镜像脑电图用于测试阶段识别精度不高,因此影响了概率集成的实验效果。2)仅使用数据扩增,准确率提高显著。主要因为使训练样本数量增大了一倍,使模型充分训练。另外由于镜像脑电图的构造方法,在模型训练中同时应用源脑电图和镜像脑电图也可以强调左右感觉运动区域之间的差异,这是左右运动想象分类的重要基础,同时抑制了与左侧和右侧运动想象分类不相关的特性。3)使用数据扩增训练集后,使用概率集成方法可以进一步提高运动想象识别精度。

表4 数据扩增与概率集成在2a数据集上对四分类运动想象分类精度的改善

Table 4 The accuracy improvement of four-category motor imagery classification on 2a dataset provided by data augmentation and probability ensemble

模型	原始模型	仅数据扩增	仅概率集成	/%	
				MCNN	
EEGNet-0 Hz	64.59	67.57	65.03	70.50	
Shallow-0 Hz	74.51	77.72	74.03	78.73	
Deep-0 Hz	72.41	74.58	71.80	75.73	
EEGNet-4 Hz	55.30	62.62	57.02	64.58	
Shallow-4 Hz	75.43	75.85	73.94	76.09	
Deep-4 Hz	58.22	62.03	59.07	63.82	
平均	66.74	70.06	66.81	71.57	

注:加粗字体表示各列最优结果。

表5 数据扩增与概率集成在2a数据集上对二分类运动想象分类精度的改善

Table 5 The accuracy improvement of two-category motor imagery classification on 2a dataset provided by data augmentation and probability ensemble

模型	原始模型	仅数据扩增	仅概率集成	/%	
				MCNN	
EEGNet-0 Hz	80.27	85.11	79.96	86.06	
Shallow-0 Hz	86.08	88.15	84.54	89.15	
Deep-0 Hz	82.20	84.85	81.64	85.59	
EEGNet-4 Hz	74.62	83.32	74.79	84.10	
Shallow-4 Hz	86.45	85.84	84.19	86.56	
Deep-4 Hz	71.03	78.87	72.50	79.89	
平均	80.11	84.36	79.60	85.23	

注:加粗字体表示各列最优结果。

表6 数据扩增与概率集成在2b数据集上对二分类运动想象分类精度的改善

Table 6 The accuracy improvement of two-category motor imagery classification on 2b dataset provided by data augmentation and probability ensemble

模型	原始模型	仅数据扩增	仅概率集成	/%	
				MCNN	
EEGNet-0 Hz	80.03	83.46	83.35	83.74	
Shallow-0 Hz	83.26	86.15	84.61	86.26	
Deep-0 Hz	80.41	86.91	84.39	87.09	
EEGNet-4 Hz	75.18	80.25	78.33	80.97	
Shallow-4 Hz	78.38	79.55	80.15	79.93	
Deep-4 Hz	77.82	80.96	80.68	81.67	
平均	79.18	82.88	81.92	83.28	

注:加粗字体表示各列最优结果。

4.4 镜卷积神经网络在多受试者运动想象脑电分类任务中的表现

运动想象脑电图在受试者之间差异很大,因此基于运动想像的脑机接口研究主要集中于建立单受试者模型。但是,单受试者模型仅适用于目标受试者,用于其他受试者则表现不佳。为验证镜卷积神经网络模型在多受试者运动想象脑电分类任务中的表现,在 2a 数据集上对四分类运动想象脑电识别进行测试、在 2a 和 2b 数据集上对二分类运动想象脑电识别进行测试。具体地,与仅使用某一受试者的训练数据和测试数据用于模型训练与测试不同,实验使用某一数据集中所有受试者的训练数据进行模

型训练,仅训练一个多受试者模型,所有受试者的测试数据用于模型测试。因为训练集中数据大幅度增加,模型一般在 300 次迭代内收敛,因此设置最大迭代次数为 500,并使用 500 次迭代内的最大测试准确率、301 ~ 400 次迭代之间的平均测试集准确率(100 次迭代平均准确率)、301 ~ 500 次迭代之间的平均测试集准确率(200 次迭代平均准确率)3 种识别精度度量,以减少随机性和批次数量对识别精度造成的影响,具体结果如表 7—表 9 所示。

从表 7—表 9 可以看出:1) 镜卷积神经网络模型可以提高多受试者运动想象识别精度。2) 与单受试者运动想象识别相比,镜卷积神经网络模型在多

表 7 镜卷积神经网络模型(MCNN)与原始模型在 2a 数据集上的多受试者运动想象四分类精度比较
Table 7 Comparison of multisubject four-category motor imagery classification accuracy on 2a dataset between MCNN and original model

模型	最大准确率			100 次迭代平均准确率			200 次迭代平均准确率		
	原始模型	MCNN	提高	原始模型	MCNN	提高	原始模型	MCNN	提高
	/%								
EEGNet-0 Hz	70.83	70.67	-0.16	68.75	68.67	-0.08	68.66	68.87	0.22
Shallow-0 Hz	75.05	74.85	-0.21	73.10	72.31	-0.78	72.95	72.46	-0.50
Deep-0 Hz	73.95	74.32	0.37	71.38	72.58	1.20	71.40	72.57	1.16
EEGNet-4 Hz	63.40	66.74	3.35	59.34	63.31	3.98	60.01	63.50	3.49
Shallow-4 Hz	68.50	68.81	0.32	65.34	66.37	1.04	65.39	66.39	1.00
Deep-4 Hz	59.24	64.18	4.94	56.78	62.11	5.33	56.77	62.01	5.24
平均	68.50	69.93	1.43	65.78	67.56	1.78	65.86	67.63	1.77

注:加粗字体表示各列最优结果。

表 8 镜卷积神经网络模型(MCNN)与原始模型在 2a 数据集上的多受试者运动想象二分类精度比较
Table 8 Comparison of multisubject two-category motor imagery classification accuracy on 2a dataset between MCNN and original model

模型	最大准确率			100 次迭代平均准确率			200 次迭代平均准确率		
	原始模型	MCNN	提高	原始模型	MCNN	提高	原始模型	MCNN	提高
	/%								
EEGNet-0 Hz	88.18	88.98	0.80	86.36	87.83	1.47	86.49	87.88	1.40
Shallow-0 Hz	90.00	89.18	-0.82	87.49	88.10	0.61	87.61	88.17	0.56
Deep-0 Hz	89.20	88.30	-0.90	87.47	87.14	-0.33	87.52	87.10	-0.42
EEGNet-4 Hz	85.34	87.19	1.85	83.65	86.08	2.43	83.70	86.18	2.48
Shallow-4 Hz	87.39	88.12	0.73	84.69	86.83	2.13	84.86	86.89	2.03
Deep-4 Hz	81.14	83.23	2.08	79.11	81.97	2.86	79.17	82.03	2.86
平均	86.88	87.50	0.62	84.80	86.33	1.53	84.89	86.38	1.49

注:加粗字体表示各列最优结果。

表9 镜卷积神经网络模型(MCNN)与原始模型在2b数据集上的多受试者运动想象二分类精度比较

Table 9 Comparison of multisubject two-category motor imagery classification accuracy on
2b dataset between MCNN and original model

模型	最大准确率			100次迭代平均准确率			200次迭代平均准确率		
	原始模型	MCNN	提高	原始模型	MCNN	提高	原始模型	MCNN	提高
EEGNet-2b-0 Hz	84.20	85.30	1.10	83.26	84.55	1.29	83.25	84.52	1.28
Shallow-2b-0 Hz	83.75	84.62	0.87	83.01	84.03	1.02	83.07	84.11	1.04
Deep-2b-0 Hz	85.39	86.59	1.20	84.19	85.45	1.26	84.18	85.43	1.24
EEGNet-2b-4 Hz	79.54	81.42	1.87	78.03	80.90	2.87	78.22	80.89	2.67
Shallow-2b-4 Hz	78.06	80.63	2.57	76.89	79.95	3.06	76.88	80.04	3.16
Deep-2b-4 Hz	79.70	81.46	1.76	78.23	79.62	1.39	78.19	79.61	1.42
平均	81.77	83.34	1.56	80.60	82.42	1.82	80.63	82.43	1.80

注:加粗字体表示各列最优结果。

受试者运动想象识别任务中对原始模型精度的提高幅度明显下降,而且在个别实验设置中出现了精度下降现象。主要因为在多受试者运动想象识别中使用多受试者脑电图用于模型训练,训练样本数量大幅增加,模型训练相对充分,而镜卷积神经网络模型在小样本问题上表现更加出色。

5 结 论

由于运动想象脑电图采集难度大,且受试者间差异显著,导致对特定受试者可用的训练数据有限,极大影响了CNN模型在运动想象分类任务中的表现。为了提高分类精度,本文提出了一种基于镜卷积神经网络的运动想象脑电识别算法,在不增加模型参数个数的前提下,通过集成学习和数据扩增解决样本数量不足对模型的制约,以提高运动想象分类的性能。具体地,首先通过源脑电图左右脑半球的脑电通道互换构造镜像脑电图扩增数据集,并用于运动想象识别CNN模型训练。在预测阶段,将已训练源模型复制形成镜像模型,源脑电图输入源模型,镜像脑电图输入镜像模型,结合源模型与镜像模型的输出类别概率形成最终类别概率输出。镜卷积神经网络独立于具体CNN模型结构,为了验证提出的镜卷积神经网络的效率和通用性,本文在实验中使用了3个流行的脑电图运动想象识别CNN模型构建镜卷积神经网络,并利用第四届脑机接口大赛的2a和2b数据集对模型进行评价。实验结果与原始模型相比,运动想象四分类和二分类准确率分别提高了4.83%和4.59%,显著提高了识别精度。但镜卷积神经网络模型在多受试者运动想象任务中对识别精度提高不明显,在之后的研究工作中,将重点基于受试者个体差异性,对多受试者运动想象任务进行研究。

始模型相比,运动想象四分类和二分类准确率分别提高了4.83%和4.59%,显著提高了识别精度。但镜卷积神经网络模型在多受试者运动想象任务中对识别精度提高不明显,在之后的研究工作中,将重点基于受试者个体差异性,对多受试者运动想象任务进行研究。

参考文献 (References)

- Ang K K, Chin Z Y, Wang C C, Guan C T and Zhang H H. 2012. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b. *Frontiers in Neuroscience*, 6: #39 [DOI: 10.3389/fnins.2012.00039]
- Clevert D A, Unterthiner T and Hochreiter S. 2015. Fast and accurate deep network learning by exponential linear units (ELUs) [EB/OL]. [2021-01-07]. <https://arxiv.org/pdf/1511.07289.pdf>
- Dai G H, Zhou J, Huang J H and Wang N. 2020. HS-CNN: a CNN with hybrid convolution scale for EEG motor imagery classification. *Journal of Neural Engineering*, 17(1): #016025 [DOI: 10.1088/1741-2552/ab405f]
- Edelman B J, Meng J, Suma D, Zurn C, Nagarajan E, Baxter B S, Cline C C and He B. 2019. Noninvasive neuroimaging enhances continuous neural tracking for robotic device control. *Science Robotics*, 4(31): #6844 [DOI: 10.1126/scirobotics.aaw6844]
- Ehrsson H H, Naito E and Roland P E. 2001. Activation of human motor cortices during mental motor imagery of hand, foot and tongue movements. *NeuroImage*, 13(S6): #1158 [DOI: 10.1016/S1053-8119(01)92479-6]
- Ioffe S and Szegedy C. 2015. Batch normalization: accelerating deep network training by reducing internal covariate shift [EB/OL]. [2021-

- 02-11]. <https://arxiv.org/pdf/1502.03167.pdf>
- Kingma D P and Ba J L. 2014. Adam: a method for stochastic optimization [EB/OL]. [2021-04-23]. <https://arxiv.org/pdf/1412.6980.pdf>
- Kumar S U and Inbarani H H. 2017. PSO-based feature selection and neighborhood rough set-based classification for BCI multiclass motor imagery task. *Neural Computing and Applications*, 28(11): 3239-3258 [DOI: 10.1007/s00521-016-2236-5]
- Lawhern V J, Solon A J, Waytowich N R, Gordon S M, Hung C P and Lance B J. 2018. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 15(5): #056013 [DOI: 10.1088/1741-2552/aace8c]
- Lemm S, Blankertz B, Curio G and Müller K R. 2005. Spatio-spectral filters for improving the classification of single trial EEG. *IEEE Transactions on Biomedical Engineering*, 52(9): 1541-1548 [DOI: 10.1109/TBME.2005.851521]
- Luo J, Feng Z R, Zhang J and Lu N. 2016. Dynamic frequency feature selection based approach for classification of motor imageries. *Computers in Biology and Medicine*, 75: 45-53 [DOI: 10.1016/j.combiomed.2016.03.004]
- Luo J, Wang J, Xu R and Xu K L. 2019. Class discrepancy-guided sub-band filter-based common spatial pattern for motor imagery classification. *Journal of Neuroscience Methods*, 323: 98-107 [DOI: 10.1016/j.jneumeth.2019.05.011]
- Luo J, Gao X, Zhu X B, Wang B, Lu N and Wang J. 2020. Motor imagery EEG classification based on ensemble support vector learning. *Computer Methods and Programs in Biomedicine*, 193: #105464 [DOI: 10.1016/j.cmpb.2020.105464]
- Meirovitch Y, Harris H, Dayan E, Arieli A and Flash T. 2015. Alpha and beta band event-related desynchronization reflects kinematic regularities. *Journal of Neuroscience*, 35(4): 1627-1637 [DOI: 10.1523/JNEUROSCI.5371-13.2015]
- Meng M, Zhu J Q, She Q S, Ma Y L and Luo Z Z. 2016. Two-level feature extraction method for multi-class motor imagery EEG. *Acta Automatica Sinica*, 42(12): 1915-1922 (孟明, 朱俊青, 余青山, 马玉良, 罗志增. 2016. 多类运动想象脑电信号的两级特征提取方法. *自动化学报*, 42(12): 1915-1922) [DOI: 10.16383/j.aas.2016.c160122]
- Morioka H, Kanemura A, Hirayama J I, Shikauchi M, Ogawa T, Ikeda S, Kawanabe M and Ishii S. 2015. Learning a common dictionary for subject-transfer decoding with resting calibration. *NeuroImage*, 111: 167-178 [DOI: 10.1016/j.neuroimage.2015.02.015]
- O'Shea A, Lightbody G, Boylan G and Temko A. 2017. Neonatal seizure detection using convolutional neural networks//Proceedings of the 27th IEEE International Workshop on Machine Learning for Signal Processing (MLSP). Tokyo, Japan: IEEE: 1-6 [DOI: 10.1109/MLSP.2017.8168193]
- Paszke A, Gross S, Massa F, Lerer A, Bradbury J, Chanan G, Killeen T, Lin Z M, Gimelshein N, Antiga L, Desmaison A, Köpf A, Yang E, DeVito Z, Raison M, Tejani A, Chilamkurthy S, Steiner B, Fang L, Bai J J and Chintala S. 2019. PyTorch: an imperative style, high-performance deep learning library [EB/OL]. [2021-01-07]. <https://arxiv.org/pdf/1912.01703v1.pdf>
- Penaloza C I and Nishio S. 2018. BMI control of a third arm for multi-tasking. *Science Robotics*, 3(20): #1228 [DOI: 10.1126/scirobotics.aat1228]
- Pfurtscheller G and da Silva F H L. 1999. Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, 110(11): 1842-1857 [DOI: 10.1016/S1388-2457(99)00141-8]
- Sakhavi S, Guan C T and Yan S C. 2015. Parallel convolutional-linear neural network for motor imagery classification//Proceedings of the 23rd European Signal Processing Conference (EUSIPCO). Nice, France: IEEE: 2736-2740 [DOI: 10.1109/EUSIPCO.2015.7362882]
- Schirmmeister R T, Springenberg J T, Fiederer L D J, Glasstetter M, Eggenberger K, Tangermann M, Hutter F, Burgard W and Ball T. 2017. Deep learning with convolutional neural networks for EEG decoding and visualization. *Human Brain Mapping*, 38(11): 5391-5420 [DOI: 10.1002/hbm.23730]
- Srivastava N, Hinton G, Krizhevsky A, Sutskever I and Salakhutdinov R. 2014. Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1): 1929-1958
- Tabar Y R and Halici U. 2017. A novel deep learning approach for classification of EEG motor imagery signals. *Journal of Neural Engineering*, 14(1): #016003 [DOI: 10.1088/1741-2560/14/1/016003]
- Tangermann M, Müller K R, Aertsen A, Birbaumer N, Braun C, Brunner C, Leeb R, Mehring C, Müller K J, Müller-Putz G R, Nolte G, Pfurtscheller G, Preissl H, Schalk G, Schlögl A, Vidaurre C, Waldert S and Blankertz B. 2012. Review of the BCI competition IV. *Frontiers in Neuroscience*, 6: #55 [DOI: 10.3389/fnins.2012.00055]
- Ullah I, Hussain M, Qazi E U H and Aboalsamh H. 2018. An automated system for epilepsy detection using EEG brain signals based on deep learning approach. *Expert Systems with Applications*, 107: 61-71 [DOI: 10.1016/j.eswa.2018.04.021]
- Wang F, Zhong S H, Peng J F, Jiang J M and Liu Y. 2018. Data augmentation for EEG-based emotion recognition with deep convolutional neural networks//Proceedings of the 24th International Conference, MMM 2018. Bangkok, Thailand: MMM: 82-93 [DOI: 10.1007/978-3-319-73600-6_8]
- Yang M H, Chen W Z and Li M Y. 2017. Multiple feature extraction based on ensemble empirical mode decomposition for motor imagery EEG recognition tasks. *Acta Automatica Sinica*, 43(5): 743-752 (杨默涵, 陈万忠, 李明阳. 2017. 基于总体经验模态分解的多类特征的运动想象脑电识别方法研究. *自动化学报*, 43(5): 743-752) [DOI: 10.16383/j.aas.2017.c160175]

Zhang Q Q and Liu Y. 2018. Improving brain computer interface performance by data augmentation with conditional Deep Convolutional Generative Adversarial Networks [EB/OL]. [2021-01-07]. <https://arxiv.org/pdf/1806.07108.pdf>

Zheng M M, Yang B H and Xie Y L. 2020. EEG classification across sessions and across subjects through transfer learning in motor imagery-based brain-machine interface system. Medical and Biological Engineering and Computing, 58(7): 1515-1528 [DOI: 10.1007/s11517-020-02176-y]

Zheng Y F and Chen B D. 2019. Least p-norm based broad learning system. Pattern Recognition and Artificial Intelligence, 32(1): 51-57 (郑云飞, 陈霸东. 2019. 基于最小 p-范数的宽度学习系统. 模式识别与人工智能, 32(1): 51-57) [DOI: 10.16451/j.cnki.issn1003-6059.201901007]


Zhou Z H. 2012. Ensemble Methods: Foundations and Algorithms. Boca Raton: CRC Press [DOI: 10.1201/b12207]

作者简介



罗靖, 1989 年生, 男, 讲师, 主要研究方向为脑机接口、机器学习。

E-mail: luojing@xaut.edu.cn



黑新宏, 通信作者, 男, 教授, 主要研究方向为安全关键计算机系统、人工智能。

E-mail: heixinhong@xaut.edu.cn

王耀杰, 男, 硕士研究生, 主要研究方向为脑机接口、机器学习。E-mail: 2201221092@stu.xaut.edu.cn

刘光明, 男, 讲师, 主要研究方向为计算机生物学、复杂网络。E-mail: liugm@xaut.edu.cn

王晓帆, 男, 副教授, 主要研究方向为统计分析理论、机器学习。E-mail: wangxfok@xaut.edu.cn

鲁晓锋, 男, 副教授, 主要研究方向为计算机视觉及模式识别、智能计算。E-mail: luxiaofeng@xaut.edu.cn