

ISSN 1002-8331  
CODEN JGYYAT

# 计算机工程与应用

## Computer Engineering and Applications

中文核心期刊

中国科技核心期刊

中国科学引文数据库 (CSCD) 来源期刊

RCCSE中国核心学术期刊

《中国学术期刊文摘》源期刊

英国《科学文摘》(INSPEC) 收录期刊

俄罗斯《文摘杂志》收录期刊

美国《剑桥科学文摘》收录期刊

美国《乌利希期刊指南》收录期刊

波兰《哥白尼索引》收录期刊

《日本科学技术振兴机构数据库》收录期刊

4

2022年

CETC 华北计算技术研究所主办



中国计算机学会会刊

# 计算机工程与应用

Jisuanji Gongcheng yu Yingyong

第58卷 第4期 2022年2月15日

## 目次

### 热点与综述

|                          |                         |
|--------------------------|-------------------------|
| 乳腺X线图像计算机辅助诊断技术综述·····   | 陈智丽,高 皓,潘以轩,邢 风(1)      |
| 内容感知的图像重定向方法综述·····      | 郭迎春,张 萌,郝小可(22)         |
| 全同态加密文献计量分析研究·····       | 陈智罡,宋新霞,郑梦策,刘天成(40)     |
| 深度学习在场景文字识别技术中的应用综述····· | 刘艳菊,伊鑫海,李炎阁,张惠玉,刘彦忠(52) |
| 音乐情感识别研究综述·····          | 康 健,王海龙,苏贵斌,柳 林(64)     |

### 理论与研发

|                        |                         |
|------------------------|-------------------------|
| LET模型的时间语义编程语言·····    | 吴 昊,章 博,陈香兰,王 超,李 曦(73) |
| 动态罚函数法求解约束优化问题·····    | 原杨飞,党乾龙,徐 伟,刘玲玲,罗宇婷(83) |
| 融合改进天牛须搜索的教与学优化算法····· | 欧阳城添,周 凯(91)            |

### 网络、通信与安全

|                          |                              |
|--------------------------|------------------------------|
| 无线传感网络的广播时效性研究·····      | 王 梅,彭丹丹,张壮壮(100)             |
| 基于UWB的消防员室内协同定位算法·····   | 杨 刚,朱士玲,李 强,赵克松,赵 杰,郭 建(106) |
| 区块链中区块截留攻击的研究与分析·····    | 刘子州,程晓荣,王治博(118)             |
| 面向规避僵尸网络流量检测的对抗样本生成····· | 李沛洋,李 璇,陈俊杰,陈永乐(126)         |

### 模式识别与人工智能

|                                  |                              |
|----------------------------------|------------------------------|
| 改进YOLOv5的白细胞检测算法·····            | 王 静,孙紫云,郭 苹,张龙妹(134)         |
| 生成对抗网络在数据异常检测中的研究·····           | 庄跃生,林珊玲,林志贤,张永爱,郭太良(143)     |
| 基于非对称双路识别网络的步态识别方法·····          | 周潇涵,王修晖(150)                 |
| 基于中文发音视觉特点的唇语识别方法研究·····         | 何 珊,袁家斌,陆要要(157)             |
| 移动机器人改进激光SLAM算法研究·····           | 陈 丹,吴 欣(163)                 |
| 无先兆偏头痛3D-CNN辅助诊断算法·····          | 李 翔,魏本征,吴宏赟,李徐周,洪雁飞,丛金玉(169) |
| 多尺度特征DCA融合的海上船舶检测算法研究·····       | 潘 慧,段先华,罗斌强(177)             |
| <u>基于图卷积网络的运动想象识别·····</u>       | <u>许学添,蔡跃新(186)</u>          |
| 结合Bi-LSTM-CNN的语音文本双模态情感识别模型····· | 王兰馨,王卫亚,程 鑫(192)             |
| 自注意力机制和随机森林回归的视频摘要生成·····        | 李雷霆,武光利,郭振洲(198)             |
| 宫颈细胞细粒度分类方法·····                 | 苟明亮,秦明伟,姚远程(206)             |
| 基于孪生网络融合多模板的目标跟踪算法·····          | 杨 哲,孙力帆,付主木,张金锦,常家顺(212)     |

### 图形图像处理

|                              |                          |
|------------------------------|--------------------------|
| 基于改进YOLOv4的植物叶茎交点目标检测研究····· | 李文婧,徐国伟,孔维刚,郭风祥,宋庆增(221) |
| 改进的Cascade RCNN行人检测算法研究····· | 刘艳萍,刘 甜(229)             |
| 改进YOLOv5的苹果花生长状态检测方法·····    | 杨其晟,李文宽,杨晓峰,岳琳茜,李海芳(237) |
| 改进YOLOv5的SAR图像舰船目标检测·····    | 谭显东,彭 辉(247)             |

### 工程与应用

|                           |                          |
|---------------------------|--------------------------|
| 基于文本挖掘的上市公司财务风险预警研究·····  | 梁龙跃,刘 波(255)             |
| 基于关键点估计的抓取检测算法·····       | 关立文,孙鑫磊,杨 佩(267)         |
| A*初始化的变异灰狼优化的无人机路径规划····· | 曹建秋,张广言,徐 鹏(275)         |
| 在线订单分批及拣选路径规划模型及算法·····   | 闫 军,常 乐,封丽华(283)         |
| 针对合作型无人机的最优防相撞策略·····     | 张宏宏,甘旭升,孙静娟,王 宁,陈致远(290) |
| 基于RISC-V处理器的固件更新系统设计····· | 郭 俊,虞致国,洪广伟,顾晓峰(298)     |
| 智慧水务数据的私有链监管方法·····       | 简 春,卿晓霞,王 波(304)         |

|                                        |       |
|----------------------------------------|-------|
| 第十九届CCF中国信息系统及应用大会(WISA 2022)征文通知····· | (156) |
|----------------------------------------|-------|

## 基于图卷积网络的运动想象识别

许学添<sup>1</sup>, 蔡跃新<sup>2</sup>

1. 广东司法警官职业学院 信息管理系, 广州 510520

2. 中山大学孙逸仙纪念医院 耳鼻喉科 听力学与言语研究所, 广州 510120

**摘 要:**运动想象识别将大脑的神经活动信号转为编码输出以实现意念控制,是脑机接口的一个重要研究方向。近年来深度学习算法的应用进一步提高了运动想象识别的准确率,但是当前基于深度学习的运动想象分析都将多路脑电信号作为二维矩阵信号,忽视了不同节点的空间关联信息。为了解决这个问题,将图卷积网络算法应用到运动想象分类中,通过多个节点脑电信号的相关系数建立脑电图结构,提取脑电信号的时频域特征信息作为输入,再经过图卷积网络进行节点特征聚合以学习谱域特征,最后通过全连接层输出分类结果。该方法在BCI Competition IV Dataset 2a数据集上取得80.9%的准确率和0.74的kappa系数,相比其他方法可以充分学习时、频、谱域的特征信息,取得更好的识别效果,为运动想象脑机接口提供一种新的思路和方法。

**关键词:**图卷积网络(GCN);运动想象;深度学习;时频特征

**文献标志码:**A **中图分类号:**TP391 **doi:**10.3778/j.issn.1002-8331.2008-0404

## Motor Imagery Recognition Based on Graph Convolution Network

XU Xuetian<sup>1</sup>, CAI Yuxin<sup>2</sup>

1. Department of Information Administration, Guangdong Justice Police Vocational College, Guangzhou 510520, China

2. Institute of Hearing and Speech-Language Science, Department of Otolaryngology, Sun Yat-sen Memorial Hospital, Sun Yat-sen University, Guangzhou 510120, China

**Abstract:** Motor imagery recognition is an important research direction of brain-computer interface (BCI), which converts brain neural activity signals into code to realize mind control. In recent years, the application of deep learning algorithm further improves the accuracy of motor imagery recognition. However, the current motor imagery analysis based on deep learning takes multi-channel EEG signals as two-dimensional matrix signals, and ignores the different nodes spatial association information. To solve this problem, the graph convolution network (GCN) is applied to the classification of motor imagery. The EEG structure is established by the correlation coefficients of multiple nodes' EEG signals, and the time-frequency feature information of EEG signals is extracted as the input of GCN. Then, node time-frequency features are aggregated by graph convolution network to learn spectral domain features. Finally, the classification results are output through full connection layer. This method achieves 80.9% accuracy and 0.74 kappa coefficient on BCI Competition IV Dataset 2a. This method can fully learn the feature information of time, frequency and spectrum domain, and achieve better recognition effect. It provides a new idea and method for brain-computer interface of motor imagery.

**Key words:** graph convolution network (GCN); motor imagery; deep learning; time-frequency feature

脑-机接口(brain-computer interface, BCI)作为大脑神经活动与外部物理世界的连接桥梁,将大脑活动信息转为计算机指令,从而控制外部设备,可以有效地帮助残疾人、老年人等活动能力受限的人。脑电图(electroencephalogram, EEG)由于其低成本和非入侵等优点,在

BCI系统中得到最多的应用与研究<sup>[1]</sup>。基于EEG的运动想象分类与识别是脑机接口的一个重要研究方向,特别是近年来,结合深度学习算法,BCI系统的发展取得了巨大的进展<sup>[2]</sup>。

运动想象EEG识别经历了从早期的特征统计到结

**基金项目:**国家自然科学基金青年科学基金(81600808);广东省普通高校特色创新项目(2020KTSCX272);广东省普通高校青年创新人才类项目(2018GkQNCX036)。

**作者简介:**许学添(1984—),男,硕士研究生,副教授,CCF会员,研究领域为深度学习、脑电信号处理, E-mail: hmllyxxt@163.com; 蔡跃新(1984—),男,博士,副教授,研究领域为大脑神经科学。

**收稿日期:**2020-08-26 **修回日期:**2020-11-02 **文章编号:**1002-8331(2022)04-0186-06

合机器学习算法进行分类识别<sup>[3-5]</sup>,再到当前的深度学习阶段,识别效果在不断提高,特别是结合深度学习算法,可以自主学习信号不同层次的特征,避免人工参与的特征工程,因此在识别准确率上取得较大的突破。利用深度学习自主提取样本抽象特征的能力,许多研究将卷积神经网络(convolutional neural networks, CNN)、长短期记忆网络(long short-term memory, LSTM)、深度玻尔兹曼机(deep Boltzmann machine, DBM)等方法应用到运动想象脑电分析中,并取得较好的识别效果。Schirrmeister等<sup>[6]</sup>研究了一系列不同结构的卷积神经网络,设计用于解码原始脑电图中想象或执行运动的不同模型;Lu等<sup>[7]</sup>提出了一种基于受限玻尔兹曼机(restricted Boltzmann machine, RBM)的深度学习算法,通过快速傅里叶变换和小波包分解得到脑电图信号的频域表示,输入三层RBM与一个额外的输出层叠加,完成分类任务;Wang等<sup>[8]</sup>将运动想象EEG时间序列分割为等长的片段,并计算均值,再通过一组空间滤波器以确定不同节点通道的权重,最后输入LSTM网络进行分类;胡章芳等<sup>[9]</sup>设计了一个多层卷积双向LSTM型递归网络,利用多层的卷积神经网络提取EEG信号的频域特征,再用LSTM网络提取时域特征,最后完成分类;唐智川等<sup>[10]</sup>将脑电信号事件相关去同步和事件相关同步模式下的EEG功率值作为分类特征建立矩阵,再用CNN网络进行学习分类。

目前基于深度学习的脑电信号分析,主要是将EEG信号当作二维矩阵,或者将EEG信号的特征转为图像(时频图、FRMI图等),再通过CNN、LSTM等经典的深度学习算法进行特征提取,这些样本对象均为欧式空间的规则数据,对节点已经进行了默认的排序,在提取抽象、高层的EEG信号特征时没有考虑大脑不同区域神经元之间的关联信息,也即节点的空间结构信息在研究中是被忽略的。图卷积网络(graph convolution network, GCN)<sup>[11-12]</sup>是在非欧式空间结构数据上的深度学习,将传统的离散卷积思想应用在图结构上以获取节点特征信息在图结构上不同层次的谱域表示,能够充分考虑节点自身的特征信息及节点之间的关联信息,更详细深入地描述图信息数据。图卷积网络目前已经在交通预测、信息传播、社交关系、生物结构、动作建模等领域得到广泛应用<sup>[13-17]</sup>。多路导联电极采集的EEG数据,每个电极节点上的EEG信号代表了所在大脑区域的神经活动信息,可以抽象为一个由点集和边集组成的图,因此图卷积网络也适合分析多节点的EEG信号。将图卷积网络应用到运动想象脑电信号分析中,结合不同节点EEG信号的时频特征和节点间的图谱特征,可以从全脑域空间的关联中去学习、提取有价值的高层特征信息,以提高运动想象的识别准确率。本文的基本思路是通过不同通道的EEG信号的相关性建立大脑图结构,再将每

个电极上的EEG信号时频特征作为每个节点的输入特征,通过GCN网络进行训练,完成不同运动想象动作的识别。

## 1 基于图卷积网络的运动想象分类模型

### 1.1 图卷积网络

图卷积网络分为谱域图卷积网络和空域图卷积网络<sup>[11-12]</sup>,其中谱域图卷积网络是在图论的基础上发展而来,根据图谱理论和卷积定理将数据从空域转到谱域进行卷积处理,具有严格的理论基础。本文采用图谱卷积模型ChebNet<sup>[18]</sup>来进行EEG图信息识别。

为了对局部输入维度可变,输入排列无序的图结构数据进行卷积操作。Bruna等<sup>[19]</sup>首次提出了利用拉普拉斯矩阵来完成谱域图卷积。对于 $N$ 个顶点的无向图 $G=\{E, V, W\}$ ,其中 $V$ 是顶点的集合, $E$ 是边的集合, $W \in \mathbb{R}^{N \times N}$ 是该图的邻接矩阵。该图的度矩阵为 $D \in \mathbb{R}^{N \times N}$ ,  $D_{ii} = \sum_j W_{ij}$ ,该图的拉普拉斯矩阵 $L = D - W$ ,归一化的拉普拉斯矩阵 $L = I_n - D^{-1/2} A D^{-1/2}$ ,  $I_n$ 为单位矩阵。对 $L$ 特征分解得到 $L = U \Lambda U^T$ ,其中 $U = (u_1, u_2, \dots, u_n) \in \mathbb{R}^{N \times N}$ 为 $L$ 的特征向量矩阵, $\Lambda = \text{diag}(\lambda_0, \lambda_1, \dots, \lambda_n) \in \mathbb{R}^{N \times N}$ 为特征值对角矩阵, $u_i \in \mathbb{R}^N, i = 1, 2, \dots, n$ ,为 $L$ 的特征向量, $\lambda_i$ 为对应的特征值。在谱域, $x_1, x_2$ 两个信号的图卷积定义为:

$$x_1 *_{\mathcal{G}} x_2 = U((U^T x_1) \odot (U^T x_2)) \quad (1)$$

因此对于输入信号 $x$ ,经过卷积核滤波器 $g \in \mathbb{R}^n$ 的图卷积运算定义为:

$$x *_{\mathcal{G}} g = U(U^T x \odot U^T g) \quad (2)$$

如果将 $g$ 表示为 $g_{\theta} = \text{diag}(U^T g)$ ,则 $x$ 的图卷积运算可以简化为:

$$x *_{\mathcal{G}} g_{\theta} = U g_{\theta} U^T x \quad (3)$$

谱域卷积都是基于式(3)或者改进而来的。ChebNet图卷积网络用切比雪夫(Chebyshev)多项式代替谱域的卷积核, $g_{\theta}$ 定义为 $g_{\theta} = \sum_{i=0}^K \theta_i T_i(\tilde{\Lambda})$ ,其中 $\tilde{\Lambda} = 2\Lambda/\lambda_{\max} - I_n$ ,切比雪夫多项式为 $T_i(x) = 2xT_{i-1}(x) - T_{i-2}(x)$ ,  $T_0(x) = 1$ ,  $T_1(x) = x$ ,因此ChebNet图卷积运算为:

$$x *_{\mathcal{G}} g_{\theta} = U(\sum_{i=0}^K \theta_i T_i(\tilde{\Lambda})) U^T x \quad (4)$$

令 $\tilde{L} = 2L/\lambda_{\max} - I_n$ ,则 $T_i(\tilde{L}) = U T_i(\tilde{\Lambda}) U^T$ ,ChebNet图卷积运算可以简化为:

$$x *_{\mathcal{G}} g_{\theta} = \sum_{i=0}^K \theta_i T_i(\tilde{L}) x \quad (5)$$

ChebNet图卷积不需要对拉普拉斯矩阵做特征分解,而且卷积核只有 $K+1$ 个可学习的参数,参数的复杂度被大大降低,可以大大提高运算速度。

### 1.2 系统模型框架

图1为本文基于图卷积网络的运动想象分类模

型。首先根据多路导联节点所采集的 EEG 信号建立 EEG 图信息,包括 EEG 图结构和 EEG 信号特征;之后将 EEG 信号特征作为图卷积层的输入特征。图卷积层首先经过 ChebNet 卷积计算,之后经过激活层利用 Rule 函数进行非线性变化,再经过批标准化(batch normalization, BN)层对可学习参数进行归一化处理,加快训练的收敛速度,最后再经过池化层进行降采样操作,减少运算量,防止过拟合。本项目设置两层图卷积层,提取 EEG 图信息的高层特征信息,最后再经过一个全连接层和 Softmax 层输出运动想象分类(左右手、脚、舌头等)。




图1 基于图卷积网络的运动想象分类模型  
Fig.1 Motion imagery classification model based on graph convolution network

2 运动想象脑电数据及特征提取

2.1 EEG 大脑网络

将每个导联电极定义为图中的一个节点,多路 EEG

信号就能抽象为一个由点集和边集组成的图  $G=(V,E)$ , 其中  $V$  为节点的集合,对应导联节点,  $E$  为边的集合, 该图的邻接矩阵为  $W$ , 节点  $i$  和节点  $j$  的权重  $\omega_{i,j}$  通过其所采集的 EEG 信号的皮尔逊相关系数来表示,计算如下:

$$\omega_{i,j} = \frac{\text{COV}(EEG_i, EEG_j)}{\sqrt{D(EEG_i)}\sqrt{D(EEG_j)}}$$

(6)

其中,  $EEG_i$  和  $EEG_j$  分别为第  $i$  个节点和第  $j$  个节点的 EEG 信号时间序列,  $D$  为方差, COV 为协方差。

2.2 EEG 脑电特征提取

本文分段获取 EEG 信号的时频特征作为图卷积网络的节点输入特征,主要分为时域特征和频域特征。时域特征包括 EEG 信号的标准差、均方根、信息熵三个指标。频域特征主要计算 EEG 信号在  $\delta$ 、 $\theta$ 、 $\alpha$ 、 $\beta$  四个频段的能量谱值。时频特征的计算如表 1。因此每个节点的输入特征为  $x=(x_{rms}, x_{std}, x_{ent}, x_{E\delta}, x_{E\theta}, x_{E\alpha}, x_{E\beta})$ , 所有特征在经标准差标准化之后再输入图卷积网络。

2.3 实验数据介绍

本文的实验数据集采用的是 BCI Competition IV Dataset 2a (<http://www.bbc.de/competition/iv/>), 运动想象的类型有 4 种,分别为左手、右手、脚和舌头。数据采集电极分布如图 2 所示,单极记录所有信号,共有 22 个 EEG 通道和 3 个 EOG 通道,以左乳突为参照,右乳突为地信号。信号采样频率为 250 Hz,带通滤波范围为 0.5~




图2 电极示意图  
Fig.2 Electrode diagram

表1 EEG 信号时频特征

Table 1 Time frequency features of EEG signal

| 域  | 特征  | 公式                                                                                            | 描述                                                                                                                                            |
|----|-----|-----------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------|
| 时域 | 均方根 | $x_{rms} = \sqrt{\sum_{i=1}^N x(i)^2 / n}$                                                    | $x(i)$ 为 EEG 时间序列的第 $i$ 个数值, $N$ 为序列长度                                                                                                        |
| 时域 | 标准差 | $x_{std} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x(i) - \mu)^2}$                                    | $\mu$ 为 EEG 时间序列的均值                                                                                                                           |
| 时域 | 信息熵 | $x_{ent} = -\sum_{i=1}^N p_i \log p_i$                                                        | $p_i$ 为 EEG 时间序列的第 $i$ 个数值所占序列总和的比例                                                                                                           |
| 频域 | 能量谱 | $x_E = \sum_{w \in band}  F(w) ^2$<br>$F(w) = \sum_{i=0}^{N-1} x(i) e^{-j\frac{2\pi}{N} i w}$ | $F(w)$ 为 EEG 信号的离散傅里叶变换,其中 $band$ 为频带范围,取 4 个频带的能量谱值,分别为 $\delta$ 频段[0.1, 4]、 $\theta$ 频段[4, 8]、 $\alpha$ 频段[8, 13]、 $\beta$ 频段[13, 30],单位 Hz |

100 Hz,放大器的灵敏度被设置为 100 μV,另外一个 50 Hz陷波滤波器被用来抑制线噪声。

数据采集范式如图3所示。在每一次实验开始(0 s),会发有蜂鸣声,之后屏幕出现一个固定的“十”字光标,持续 2 s,之后出现运动想象标识,持续 1.25 s,在第 3 s到 6 s为运动想象阶段,之后休息,开始下一次实验。数据集总共有 9 个人,每个人进行 6 轮的运动想象采集,每一轮 4 种运动想象类型实验各 12 次,因此每个人总共有 288 次的运动想象实验样本作为训练数据集。另外还有相同数量的测试数据集。




图3 实验EEG数据采集范式  
Fig.3 Experimental paradigm of EEG data

3 实验及结果分析

3.1 模型参数设置及训练

采用早停法(early stopping)来进行模型训练,以获取最优的泛化性能,防止过拟合。将训练数据集的 30% 作为验证数据集,训练时只训练剩下的 70% 数据,训练停止的条件为:(1)以 10 个 epoch 为一个训练周期,在一个训练周期后,在验证集上验证测试结果,如果连续 5 个训练周期验证数据集的最低误差值都没有变化,则停止训练;(2)超过最大训练次数 500,则停止训练。模型训练 batch 大小设置为 60,反向传播训练,使用自适应动量估计优化器(adaptive moment estimation, Adam)进行参数学习,学习速率为 0.000 1,采用交叉熵(cross entropy)指标作为损失函数。

停止训练后对测试数据集进行检验,由准确率 Accuracy 和 kappa 系数来衡量分类结果。准确率为运动想象正确识别的比例,kappa 系数为:

kappa = (p0 - pe) / (1 - pe) (7)

其中,kappa 系数的计算基于混淆矩阵, p0 即为分类准确率, pe 为预期与实际一致性的概率。kappa 系数用来表示分类识别的一致性级别,如表 2 所示。

表2 kappa系数一致性  
Table 2 kappa coefficient consistency

| kappa系数范围 | 级别   |
|-----------|------|
| 0~0.20    | 极低   |
| 0.21~0.40 | 一般   |
| 0.41~0.60 | 中等   |
| 0.61~0.80 | 高度   |
| 0.81~1.00 | 几乎完全 |

3.2 模型参数分析

图卷积层是本文运动想象分类模型的核心,其参数设置决定了分类的准确率。ChebNet 的卷积核具有严格的空 间局部性,其中切比雪夫多项式的阶数 K 就是卷积核的“感受半径”, K 值越大,节点就能获取更多其他节点的特征信息进行聚合,但是也会加入更多的无关信息。另外,图卷积层的数量,也会影响模型分类的准确率。不同的切比雪夫多项式的阶数 K 和图卷积层数对模型 的分类性能影响如图 4 所示,当 K 取值为 2,图卷积层的层数取 2 时,可以得到最佳的分类准确率。




图4 阶数 K 和图卷积层数  
Fig.4 Order K and GCN layers

3.3 实验结果

对于 BCI Competition IV Dataset 2a 数据集,本文所介绍的图卷积网络模型取得的准确率和 kappa 系数如表 3 所示。9 名受试者 4 种运动想象类型的识别准确率 达到 80.9%,平均 kappa 系数为 0.74,能够取得较好的分类效果。

表3 9名受试者实验结果  
Table 3 Experimental results of 9 subjects

| 受试者      | 准确率/% | kappa 系数 |
|----------|-------|----------|
| Subject1 | 91.7  | 0.90     |
| Subject2 | 67.4  | 0.56     |
| Subject3 | 92.7  | 0.90     |
| Subject4 | 79.4  | 0.69     |
| Subject5 | 70.4  | 0.61     |
| Subject6 | 62.1  | 0.49     |
| Subject7 | 92.7  | 0.90     |
| Subject8 | 87.2  | 0.83     |
| Subject9 | 84.3  | 0.79     |
| mean     | 80.9  | 0.74     |

9 名受试者在测试数据集上的分类结果混淆矩阵如图 5 所示。每个子图为每名受试者的混淆矩阵,横、纵坐标代表预测和实际的运动想象分类类型(LH、LR 为左、右手,F 为脚,T 为舌头),中间数值为对应分类概率。根据 kappa 系数,有 4 名受试者取得了几乎完全一致的识别效果,有 3 名受试者取得高度一致的识别效果, Subject2 和 6 受试者的识别效果相对较差(中等识别




图5 受试者分类结果混淆矩阵

Fig.5 Confusion matrix of subject classification results

效果),主要是由于脑电信号采集时干扰较大、不稳定和样本数量不足。另外,由于图卷积网络属于非结构化数据的深度学习算法,其本质是收集网络中不同节点的特征进行聚合和传递,进而选择节点最优的高层抽象特征,因此如果样本数量不足会导致无法训练学习到最佳的谱域和时频域特征,影响算法的泛化性能。

3.4 方法比较

为了评价验证本文所提出图卷积模型的有效性,与其他文献的方法进行比较,分类的准确率如表4所示。

表4 不同方法比较结果  
Table 4 Comparison results of different methods

| 方法              | 准确率/% |
|-----------------|-------|
| FBCSP           | 65.8  |
| FDBN            | 72.2  |
| Shallow ConvNet | 73.7  |
| Hybrid ConvNet  | 71.6  |
| AX-LSTM         | 76.5  |
| 本文方法            | 80.9  |

FBCSP<sup>[3]</sup>属于经典CSP算法的改进,主要是利用脑电信号矩阵找到一组最优空间滤波器进行投影,再结合机器学习分类算法进行识别;FDBN<sup>[7]</sup>通过快速傅立叶变换和小波包分解获取EEG信号的频域数据,再利用三个波尔兹曼机来训练;Shallow ConvNet和Hybrid ConvNet<sup>[6]</sup>采用两种类型的CNN网络来处理EEG数据,

Shallow ConvNet卷积核长度较长,网络层数较少,Hybrid ConvNet卷积核长度较短,网络层数多;AX-LSTM<sup>[8]</sup>采用时间序列的符号化表示EEG数据,再通过信道加权引入一组空间滤波器作为隐藏层,将其输出反馈给LSTM网络以完成分类识别。本文则是将EEG脑电图转化为图结构信息,再利用图卷积神经网络来学习图谱域和时频域信息,完成运动想象分类,在四分类问题上可以取得较好的分类效果。

4 结束语

本文提出了一种基于图卷积网络的EEG信号运动想象识别方法,根据多路导联节点采集的EEG信号建立节点的关联图结构,并提取每个节点上EEG信号的时频特征作为输入特征进行谱域图卷积运算,获取大脑图信息的高层、抽象特征,最后通过全连接层输出想象分类结果。在BCI Competition IV Dataset 2a数据集上取得80.9%的准确率和0.74的kappa系数。本文方法在提取EEG信号特征时既考虑信号的时频特征,又结合节点网络的谱域空间信息,因此能取得较好的分类效果,为多路EEG信号的运动想象分类识别提供一种新的思路。

参考文献:

[1] MINGUILLON J, LOPEZ-GORDO M A, PELAYO F. Trends

- in EEG-BCI for daily-life: requirements for artifact removal[J]. Biomedical Signal Processing and Control, 2017, 31: 407-418.
- [2] ABDULKADER S, ATIA A, MOSTAFA M. Brain computer interfacing: applications and challenges[J]. Egyptian Informatics Journal, 2015, 16(2): 213-230.
- [3] ANG K K, CHIN Z Y, WANG C C, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b[J]. Frontiers in Neuroscience, 2012, 29(6): 39-48.
- [4] SHAHID S, PRASAD G. Bispectrum-based feature extraction technique for devising a practical brain-computer interface[J]. Journal of Neural Engineering, 2011, 8(2): 025014.
- [5] LU N, YIN T. Motor imagery classification via combinatorial decomposition of ERP and ERSP using sparse non-negative matrix factorization[J]. Journal of Neuroscience Methods, 2015, 249: 41-49.
- [6] SCHIRRMMEISTER R, SPRINGENBERG J, FIEDERER L, et al. Deep learning with convolutional neural networks for EEG decoding and visualization[J]. Human Brain Mapping, 2017, 38(11): 5391-5420.
- [7] LU N, LI T, REN X, et al. A deep learning scheme for motor imagery classification based on restricted Boltzmann machines[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2017, 25(6): 566-576.
- [8] WANG P, JIANG A, LIU X, et al. LSTM-based EEG classification in motor imagery tasks[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2018, 26(11): 2086-2095.
- [9] 胡章芳, 崔婷婷, 罗元, 等. 基于CBLSTM算法的脑电信号特征分类[J]. 计算机工程与应用, 2019, 55(24): 110-116.  
HU Z F, CUI T T, LUO Y, et al. EEG signal classification algorithm based on CBLSTM[J]. Computer Engineering and Applications, 2019, 55(24): 110-116.
- [10] 唐智川, 张克俊, 李超, 等. 基于深度卷积神经网络的运动想象分类及其在脑控外骨骼中的应用[J]. 计算机学报, 2017, 40(6): 1367-1378.  
TANG Z H, ZHANG K J, LI C, et al. Motor imagery classification based on deep convolutional neural network and its application in exoskeleton controlled by EEG[J]. Chinese Journal of Computers, 2017, 40(6): 1367-1378.
- [11] WU Z H, PAN S R, CHEN F U, et al. A comprehensive survey on graph neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(1): 4-24.
- [12] ZHANG Z W, CUI P, ZHU W W, et al. Deep learning on graphs: a survey[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(1): 249-270.
- [13] KIPF T, WELLMING M. Semi-supervised classification with graph convolutional networks[C]//2017 International Conference on Learning Representations, 2017.
- [14] YING R, YOU J, MORRIS C, et al. Hierarchical graph representation learning with differentiable pooling[C]//2018 Conference and Workshop on Neural Information Processing Systems, 2018: 4805-4815.
- [15] FOUT A, BYRD J, SHARIAT B. Protein interface prediction using graph convolutional networks[C]//2017 Conference and Workshop on Neural Information Processing Systems, 2017: 6530-6539.
- [16] QI S Y, WANG W G, JIA B X, et al. Learning human-object interactions by graph parsing neural networks[C]//2018 European Conference on Computer Vision, 2018: 407-423.
- [17] CUI Z Y, HENRICKSON K, KE R M, et al. Traffic graph convolutional recurrent neural network: a deep learning framework for network-scale traffic learning and forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(11): 4883-4894.
- [18] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering[C]//2016 Conference and Workshop on Neural Information Processing Systems, 2016: 3844-3852.
- [19] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and locally connected networks on graphs[C]//3rd International Conference on Learning Representations, 2014.