

基于互信息与自适应图卷积的运动想象脑电信号识别

吴叶兰, 曹璞刚, 徐梦, 张跃, 廉小亲, 于重重
北京工商大学计算机与人工智能学院, 北京 100048

【摘要】针对运动想象脑电信号非线性特征提取困难、难以有效捕获脑电通道间功能连接关系的问题,提出一种基于互信息和自适应图卷积的运动想象脑电信号分类识别方法。首先,对原始运动想象脑电信号进行子频带划分,提取频域信息;然后,采用互信息神经估计方法构建邻接矩阵,获取脑电信号的非线性关系;最后,设计一种结合CBAM的自适应图卷积网络捕获各通道间的动态关联强度,实现空频特征提取。在BCI Competition IV 2a和BCI Competition III 3a数据集上,分别达到83.14%和88.19%的平均准确率,结果表明本文方法能有效获得脑电通道间功能连接关系,为运动想象脑电信号解码提供新思路。

【关键词】运动想象;脑电信号;自适应图卷积;互信息神经估计;特征提取

【中图分类号】R318;TN911.7

【文献标志码】A

【文章编号】1005-202X(2025)02-0232-08

Motor imagery electroencephalogram signal recognition based on mutual information and adaptive graph convolution

WU Yelan, CAO Pugang, XU Meng, ZHANG Yue, LIAN Xiaoqin, YU Chongchong

School of Computer and Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

Abstract: To address the challenges of extracting nonlinear features from motor imagery electroencephalogram (EEG) signals and effectively capturing functional connectivity between EEG channels, a classification and recognition method for motor imagery EEG signals is proposed based on mutual information and adaptive graph convolutional network. The proposed method extracts frequency domain information by sub-frequency banding on the original motor imagery EEG signals, uncovers the nonlinear relationships within EEG signals by an adjacency matrix constructed with mutual information neural estimation method, and finally achieve null-frequency feature extraction by capturing the dynamic correlation strength between channels with an adaptive graph convolutional network incorporating convolutional block attention module. On the BCI Competition IV 2a and BCI Competition III 3a datasets, the proposed method has average accuracies of 83.14% and 88.19%, respectively, demonstrating that it can effectively reveal functional connectivity between EEG channels, providing a new approach for decoding motor imagery EEG signals.

Keywords: motor imagery; electroencephalogram signal; adaptive graph convolution; mutual information neural estimation; feature extraction

前言

运动想象是脑-机接口(Brain-Computer Interface, BCI)的主要范式之一,通过解码来自中枢神经系统的电活动,实现大脑和外部设备的信息交互,

在智能医疗、虚拟现实、机器人控制等领域得到广泛应用^[1-2]。运动想象BCI系统的核心是运动想象脑电信号的解码,由于运动想象脑电信号具有非线性、非平稳、信噪比低、个体差异大等特点,如何挖掘出稳健、有价值的特征实现精确解码是极具挑战性的工作。

随着深度学习的快速发展,卷积神经网络(CNN)^[3]、长短期记忆网络(LSTM)^[4]、循环神经网络^[5]等深度学习方法逐步应用于脑电信号解码,取得较好的特征提取和分类效果。李海峰等^[6]提出用C-LSTM方法加强对运动想象脑电信号时序特征的利

【收稿日期】2024-10-26

【基金项目】跨行业协同应用与数据要素服务平台项目(CEIEC-2023-ZM02-0090)

【作者简介】吴叶兰,副教授,研究方向:智能信息处理、机器人技术,
E-mail: wuyel@th.btbu.edu.cn

用,获得93.6%的二分类识别准确率。Schirrmeister等^[7]提出Shallow ConvNet模型,利用时间卷积和空间滤波器获取原始脑电信号的时空特征,在不需要先验知识的情况下在二分类数据集上取得较好的分类效果。Li等^[8]提出双向ConvLSTM模型,在提取脑电信号时域特征时既保留CNN的特征提取能力,又结合LSTM的序列处理能力,在运动想象脑电信号四分类公开数据集上取得73.7%的准确率。Lawhern等^[9]使用深度可分离卷积构建EEGNet分类模型,可通用于运动想象、癫痫、情绪等脑电识别任务,在数据有限的情况下,EEGNet拥有更好的泛化性和更高的识别准确率。针脑电信号多维度特征利用不充分的问题,Zhao等^[10]提出一种3分支CNN,采用3种不同感受野大小的卷积网络提取时空特征并进行融合,获取更具表征能力的多维特征。Wu等^[11]提出一种分层的多尺度滤波器组卷积模型获取时间和空间特征,具有较好的鲁棒性。

虽然深度学习算法在脑电信号解码中取得一定成效,但传统的CNN、LSTM等深度学习算法是按欧式空间数据处理方法对脑电信号进行特征提取,没有考虑脑电电极分布的非欧空间特性,忽略大脑不同区域神经元之间的关联性^[12]。图卷积网络(Graph Convolution Network, GCN)是用于非欧空间结构数据上的神经网络架构,能充分考虑节点自身特征及节点间的关联信息。由于运动想象脑电信号具有非欧特征,且不同脑电通道间有连接关系,因此有研究将GCN应用于运动想象脑电信号信号分析中。许学添等^[13]提出将GCN应用于运动想象脑电信号识别任务,从全脑域提取空域特征,在四分类数据集上得到80.9%的识别准确率。杨淑莹等^[14]提出一种通道选择和特征融合方法,利用梯度提升决策树选择重要通道,结合GCN提取频域特征,有利于避免重要特征丢失。李珍琦等^[15]提出一种融合注意力的多维特征GCN架构,包含时频、频空两个分支,可以提取时频空三域的融合特征,在四分类数据集上获得81.6%的识别准确率。

上述图卷积方法的邻接矩阵大都利用脑电信号的线性相关性构建的,忽略脑电信号的非线性特征。互信息作为一种信息论度量方法,能捕捉非线性关系^[16],而不是局限于线性关系,适用于复杂的脑电信号分析。因此,本研究提出一种基于互信息与自适应图卷积(Mutual Information Adaptive Graph Convolutional Network, MI-AGCN)的运动想象脑电信号信号解码方法,采用互信息估计构建脑电信号的邻接矩阵,建立通道间的依赖关系,设计一种结合

注意力机制(Convolutional Block Attention Module, CBAM)的自适应GCN,挖掘通道间的功能连接关系,提取全脑空频特征。在两个具有代表性的运动想象数据集上进行试验,结果表明所提方法可有效提高运动想象脑电信号分类准确率。

1 运动想象脑电信号分类方法

1.1 MI-AGCN模型

本研究针对运动想象脑电信号非线性特征提取困难、难以有效捕获脑电通道间功能连接关系的问题,提出MI-AGCN方法,模型的整体结构如图1所示。首先,将原始运动想象脑电信号划分为9个子频带,给模型提供先验的频域信息,利用空域滤波得到主要的脑电通道成分以提升信噪比。然后,对预处理后的信号进行互信息估计,采用互信息神经估计(Mutual Information Neural Estimation, MINE)方法,用神经网络逼近不同脑电通道间互信息的上确界,捕获脑电通道间的真实依赖关系。设计一种自适应GCN,充分考虑脑电通道的互信息特定关系、整体共性和个体差异,构建邻接矩阵 A 、 B 和 C ,以实现图连接的自适应动态调整,提取更具判别性的空频特征,同时采用CBAM从通道和空间特征两个角度对显著区域关注,提升空频特征质量。最后,将提取的空频特征送入全连接层,得到最终的分类结果。

1.2 运动想象脑电信号预处理

本质上,区分不同的运动想象动作可以通过事件相关同步(ERS)和事件相关去同步(ERD)来实现^[17-18],与运动想象相关的ERD/ERS现象明显存在于 α (8~13 Hz)和 β (14~26 Hz)频带中,为保留运动想象脑电信号不同频带中的ERD/ERS模式,受FBCSP算法的启发^[19],对原始运动想象脑电信号进行子频带划分和空域滤波。

使用9个重叠的Chebyshev Type II带通滤波器构建滤波器组,每个频带的带宽为6 Hz,总体频带范围为4~42 Hz(4~10、8~14、...、36~42 Hz)。用共空间模式对每个子频带进行空域滤波:

$$\mathbf{Z}_{b,i} = \bar{\mathbf{W}}_b^T \mathbf{E}_{b,i} \quad (1)$$

其中, $\mathbf{Z}_{b,i}$ 是经空域滤波后的信号, $\mathbf{E}_{b,i} \in \mathbb{R}^{c \times t}$ 表示第 b 个频带的脑电样本 i , c 是脑电通道数, t 是每个通道的采样点数, $\bar{\mathbf{W}}_b$ 是共空间模式投影矩阵, T 是转置。 $\bar{\mathbf{W}}_b$ 通过式(2)的特征值分解获得:

$$\Sigma_{b,1} \mathbf{W}_b = (\Sigma_{b,1} + \Sigma_{b,2}) \mathbf{W}_b \mathbf{D}_b \quad (2)$$

其中, $\Sigma_{b,1}$ 和 $\Sigma_{b,2}$ 分别是第 b 个频带下第一类和第二类想象任务的协方差矩阵估计值, \mathbf{D}_b 是由 $\Sigma_{b,1}$ 的特征值

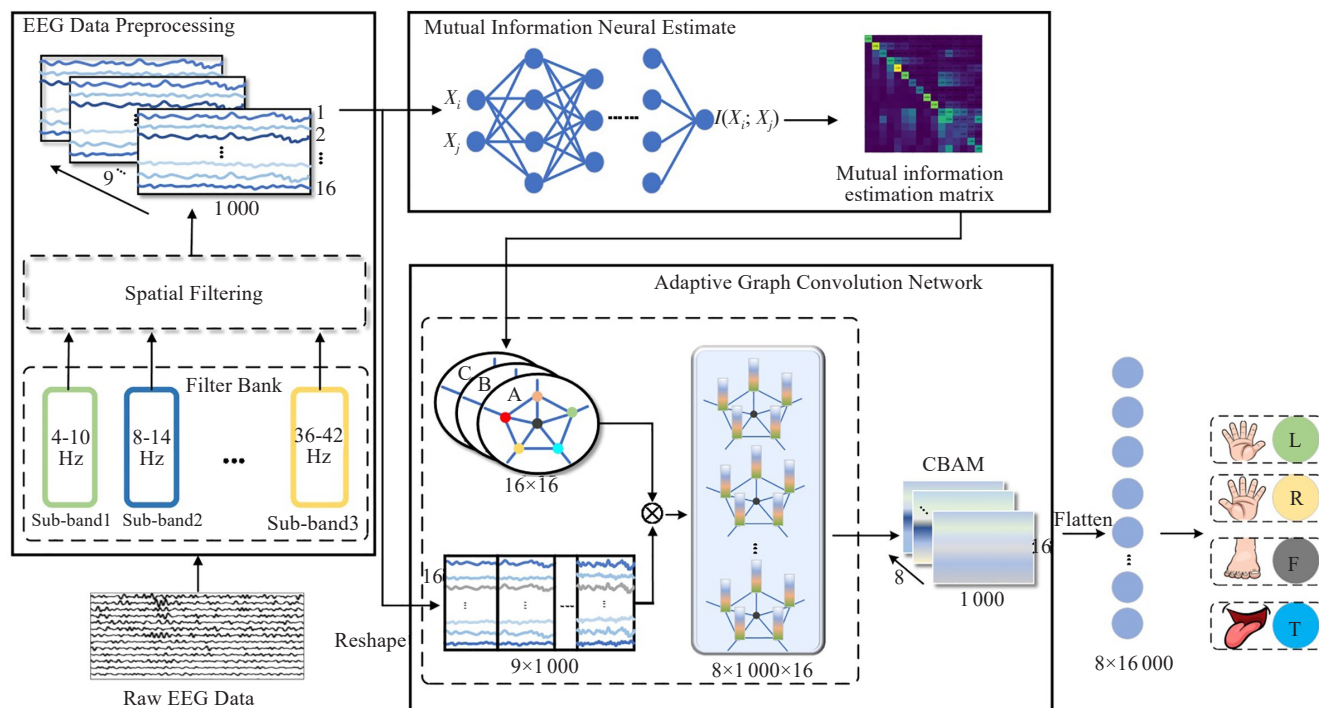


图1 MI-AGCN模型结构
Figure 1 MI-AGCN model structure

构成的对角阵。选取 $\bar{W}_b \in \mathbb{R}^{c \times c}$ 中的前 n 列和后 n 列向量构成空域滤波器 \bar{W}_b 。

对四分类任务采用一对多策略,将其中一类想象任务看作第一类,其余几类想象任务共同看作第二类,最终求取的空域滤波器 \bar{W}_b 共包含 $k \times 2 \times n$ 个向量,令 $k=4$ (对应四分类), $n=2$, 因此,空间滤波后的脑电通道数为16。将9组频带信号均进行空域滤波,形成 $9 \times 16 \times 1\,000$ 的输入数据。

1.3 MINE 方法

互信息是信息论中的重要概念,能衡量非线性的相关关系^[20],本研究采用MINE方法^[21]量化脑电通道间的相关性。随机变量 X 和 Y 的互信息定义为:

$$I(X; Y) = P_{XY}(x, y) \log \int \frac{P_{XY}(x, y)}{P_X(x)P_Y(y)} dx dy \quad (3)$$

其中, $P_{XY}(x, y)$ 是联合概率分布, $P_X(x)$ 和 $P_Y(y)$ 是边缘概率分布。由于概率分布计算困难, MINE 方法采用 Donsker-Varadhan 表示^[22], 用神经网络来逼近互信息的上确界。具体而言, 将随机变量 X 和 Y 的互信息 $I(X; Y)$ 定义为联合分布 P_{XY} 与边缘分布 P_X 和 P_Y 乘积之间的 KL 散度 (Kullback-Leibler Divergence):

$$I(X; Y) = D_{KL}(P_{XY} \| P_X P_Y) \quad (4)$$

其中, D_{KL} 为 KL 散度, 在 Donsker-Varadhan 表示中, 对于任意函数 T , 有如下关系:

$$D_{KL}(P_{XY} \| P_X P_Y) \geq \sup_{T \in \mathcal{F}} E_{P_{XY}}[T] - \log(E_{P_X P_Y}[e^T]) \quad (5)$$

其中, T 表示满足可积性条件的任意函数, \sup 表示取上限操作, E 表示求期望操作。当选择一个函数 T 时, 对应了 KL 散度 (即互信息) 的一个下界。由于神经网络具有强大的函数逼近能力, 函数 T 可用神经网络 $T_\theta(X, Y)$ 来表示, $I(X; Y)$ 的估计 $\hat{I}(X; Y)$ 定义为:

$$\hat{I}(X; Y) = \sup_{\theta \in \Theta} E_{P_{XY}}[T_\theta(X, Y)] - \log(E_{P_X P_Y}[e^{T_\theta(X, Y)}]) \quad (6)$$

其中, $T_\theta(X, Y)$ 是由神经网络实现的函数, θ 是神经网络的参数集合, Θ 是参数空间, $E_{P_{XY}}$ 表示求解在联合分布下对函数 $T_\theta(X, Y)$ 的期望, $E_{P_X P_Y}$ 表示求解在边缘分布乘积下对 $e^{T_\theta(X, Y)}$ 的期望。

在算法实现上, 需要从分布 P_{XY} 和 $P_X P_Y$ 中采样, 通过神经网络 $T_\theta(X, Y)$ 计算样本的函数值, 使用梯度上升方法优化神经网络的参数 θ , 找到使下界尽可能大的函数, 最大化 $\hat{I}(X; Y)$, 以逼近互信息的真实值。

1.4 自适应 GCN

GCN 能聚合图结构数据周围节点的信息来更新自身节点信息^[23], 利用该性质可将脑电信号各通道之间的信息进行聚合以捕捉通道间关联性。用 GCN 处理脑电信号, 必须先构建运动想象脑电信号的拓扑结构。设无向脑电信号连接图表示为 $G = \{V, E, A\}$, 其中 $V = \{v_1, v_2, \dots, v_n\}$ 表示节点集, v_n 表示电极通道, E 是连接各节点之间的边集, 且

$\{v_i, v_j\} \in E$ 。为得到两两通道间的相关程度,获取运动想象脑电信号的非线性特征,计算通道间的互信息构建边集 E ,得到邻接矩阵 A :

$$A = \begin{bmatrix} I(X_1; X_1) & \cdots & I(X_1; X_{16}) \\ \vdots & \ddots & \vdots \\ I(X_{16}; X_1) & \cdots & I(X_{16}; X_{16}) \end{bmatrix} \quad (7)$$

其中, $I(X_i; X_j)$ 是通道 X_i, X_j 的互信息。由于运动想象是一个动态过程,除了考虑脑电通道间的相关性,还需考虑通道的整体共性和个体差异,受文献[24]启发,本研究设计了邻接矩阵 B 和 C :

$$B = (1 - r)B + r \frac{\partial \text{Loss}}{\partial B} \quad (8)$$

$$C = \text{soft max}(f_{in}^T W_{\theta}^T W_{\phi} f_{in}) \quad (9)$$

其中, $B \in \mathbb{R}^{N \times N}$ 是所有样本共享的邻接矩阵,用来保存通道间的共性信息,为可训练参数,随模型训练动态更新, r 为学习率,Loss为模型训练过程中产生的损失。 $C \in \mathbb{R}^{N \times N}$ 是和样本数据相关的邻接矩阵,为每个输入数据分配独特的连接强度, W_{θ}, W_{ϕ} 表示两个 1×1 的卷积。

利用邻接矩阵 A, B, C 构建自适应图卷积层,实现图连接权重的自适应调整,更好地提取深层空频特征。获取的空频特征 \hat{f}_{cs} 为:

$$\hat{f}_{cs} = W_{1 \times 1} * \left(\tilde{D}^{-\frac{1}{2}} A \tilde{D}^{-\frac{1}{2}} + B + C \right) f_{in} \quad (10)$$

其中, \tilde{D} 是 A 的度矩阵,实现对 A 的标准化。图2给出自适应图卷积层的实现细节,将自适应图卷积层、批归一化(BN)层和ReLU激活函数组成基础的GCN模块,对多个GCN模块进行堆叠,构成完整的自适应图卷积网络(AGCN)。

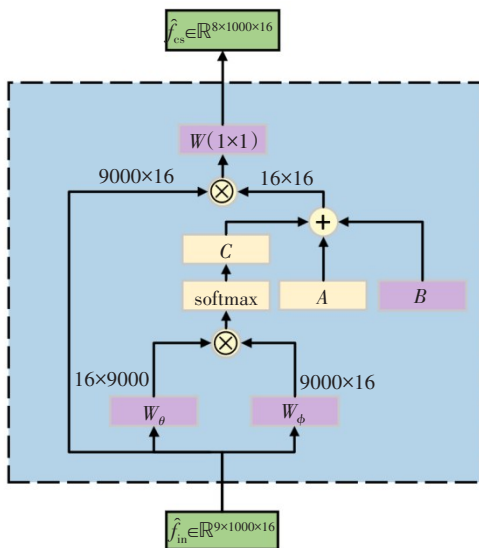


图2 自适应图卷积层示意图

Figure 2 Schematic diagram of adaptive graph convolution layer

2 数据集与实验设置

2.1 数据集

本研究使用的实验数据为BCI Competition IV 2a和BCI Competition III 3a四分类(左手、右手、双脚、舌头)运动想象数据集。BCI Competition IV 2a使用22个电极进行数据采集,包含9名受试者(编号A01~A09),每名被试共进行12轮运动想象采集,采样频率为250 Hz,每一轮4种运动想象类型任务各采集12次,故每名被试有576次运动想象实验样本。实验截取4 s运动想象脑电信号数据,生成 $22 \times 576 \times 1000$ 的输入数据,训练集和测试集按照8:2进行划分,即训练集维度为 $22 \times 460 \times 1000$,测试集为 $22 \times 116 \times 1000$ 。BCI Competition III 3a包含3名受试者(编号K3、K6、L1),K3包含360组样本,其余被试包含240组样本。每次任务想象时长持续4 s,采样频率为250 Hz,共包含60个通道的脑电信号。为与BCI Competition IV 2a数据集通道保持一致,选取靠近头皮中央区域的22个电极,如图3所示,训练集和测试集按照8:2进行划分。




图3 BCI Competition III 3a电极通道图

Figure 3 BCI Competition III 3a electrode channel map

2.2 实验设置及评价指标

模型在Python3.8环境中基于PyTorch1.13.1深度学习框架搭建,利用GeForce 3060 GPU计算。表1为模型的参数设置,所有实验最终结果为5次实验的均值。

为评估模型性能,测量了以下4个指标。其中, True Positive(TP)表示真正类,即样本的真实类别是正类,并且模型识别的结果也是正类; False Negative(FN)表示假负类,即样本的真实类别是正类,但是模型将其识别为负类; False Positive(FP)表示假正类,即样本的真实类别是负类,但是模型将其识别为正类; True Negative(TN)表示真负类,即样本的真实类别是负类,并且模型将其识别为负类。

表1 模型参数设置
Table 1 Model parameter settings

参数	设置
Optimizer	Adam
Loss function	Categorical Cross-entropy
Learning rate	0.01
Batch size	16
Epochs	100

(1)Acc(准确率):正确分类的样本数与总样本数之比。

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}$$

(11)

(2)Kappa:用于描述分类器的性能较随机预测的提升程度。Kappa值为-1.0~1.0,该值越大,模型的分类性能越好。

$$Kappa = \frac{p_o - p_e}{1 - p_e}$$

(12)

其中, p_o 指每一类正确分类样本数量之和除以总样本数,即 Acc;假设每一类正确样本的数量为 a_1,a_2,\cdots,a_c ,预测出的每一类样本个数为 b_1,b_2,\cdots,b_c ,总样本个数为 n ,则 $p_e = \frac{a_1 \times b_1 + a_2 \times b_2 + \dots + a_n \times b_n}{n^2}$ 。

(3)Precision(精确率):指模型正确预测正样本的数量在所有预测为正样本中的比例。

$$Precision = \frac{TP}{TP + FP}$$

(13)

(4)Recall(召回率):分类器查找正样本的能力。

$$Recall = \frac{TP}{TP + FN}$$

(14)

3 实验结果与分析

3.1 分类结果与分析

本研究提出的MI-AGCN模型在2个数据集上所有被试的分类结果如表2所示。在BCI Competition IV 2a数据集中,平均准确率和Kappa系数分别达到83.14%、0.775,最高分类准确率达到98.28%、最高Kappa系数达到0.977;在BCI Competition III 3a数据集上有88.19%的平均准确率和0.843的kappa系数,最高分类准确率达到100%、Kappa系数达到1.000,取得较好的分类效果,表明模型能有效捕捉不同运动想象类别的关键空频特征,分类的准确性和一致性较高。从精确率和召回率指标分析,对于BCI Competition IV 2a数据集,4种运动想象任务的精确率和召回率均值均在81%以上,表明模型在预测4种分类(左手、右手、双脚、舌头)时,能正确区分不同类别,整体上有较高的精确性,较高的召回率也说明模型对不同类别样本的敏感度较高,较少遗漏实际属于各类别的样本。在BCI Competition III 3a数据集中,K3被试的精确率和召回率都达到100%,表明K3被试对应的脑电信号可能具有非常显著的特征,且模型的特征提取方法有效,能很好地检测到实际属于各类别运动想象的脑电信号;而K6被试的右手精确率很低,可能原因是该被试在进行右手运动想象时产生的脑电信号特征不够明显,与其他类别运动想象的脑电信号差异较小,导致模型难以准确区分。

表2 MI-AGCN模型分类结果
Table 2 MI-AGCN model classification results

数据集	被试	准确率/%	Kappa	精确率/%				召回率/%			
				左手	右手	双脚	舌头	左手	右手	双脚	舌头
BCI Competition IV 2a	A01	86.21	0.816	96.55	96.55	68.97	82.76	90.32	90.32	83.33	80.00
	A02	69.83	0.598	51.72	72.41	89.66	65.52	53.57	56.76	92.86	82.61
	A03	95.69	0.943	89.66	100.00	93.10	100.00	100.00	93.55	100.00	90.62
	A04	76.72	0.690	89.66	72.41	82.76	62.07	66.67	80.77	77.42	90.00
	A05	81.03	0.747	93.10	93.10	62.07	75.86	77.14	75.00	90.00	88.00
	A06	64.65	0.528	64.90	60.42	68.69	67.11	66.21	59.99	65.51	66.90
	A07	98.28	0.977	100.00	100.00	93.10	100.00	100.00	100.00	100.00	93.55
	A08	92.24	0.897	89.66	96.55	93.10	89.66	92.86	87.50	96.43	92.86
	A09	83.62	0.782	86.21	65.52	82.76	100.00	86.21	86.36	77.42	85.29
	平均	83.14	0.775	84.61	84.11	81.58	82.55	81.44	81.14	87.00	85.54
BCI Competition III 3a	K3	100.00	1.000	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00
	K6	72.92	0.639	75.00	33.33	91.67	91.67	75.00	80.00	64.71	78.57
	L1	91.67	0.889	83.33	100.00	83.33	100.00	90.91	92.31	100.00	85.71
	平均	88.19	0.843	86.11	77.78	91.67	97.22	88.64	90.77	88.24	88.09

为验证所提模型的先进性,与7种算法进行总体分类效果的对比。如表3所示,所提方法在两个数据集上的平均分类准确率和Kappa系数均优于CSP^[25]、FBCSP^[26]、Deep ConvNet^[7]、Shallow ConvNet^[7]、EEGNet^[9]等经典算法,相比于最新提出的EEG-Conformer^[27]、Light Conv-Net^[28]模型,本文方法在两个数据集上也均取得了最高的结果。同时,本

文方法的标准差也较低,说明在不同被试中可以取得相对稳定的分类结果,这是因为本文方法采用互信息估计构建的邻接矩阵能同时捕获运动想象脑电信号的线性和非线性特征,通过自适应GCN获取运动想象任务期间不同通道的动态关联性,得到更好的解码效果。

表3 不同方法分类结果比较($\bar{x}\pm s$)
Table 3 Comparison of classification results of different methods (*Mean±SD*)

模型	BCI Competition IV 2a		BCI Competition III 3a	
	准确率/%	Kappa	准确率/%	Kappa
CSP+SVM ^[25]	63.22±17.18	0.508±0.230	69.90±16.86	0.598±0.224
FBCSP+SVM ^[26]	69.25±15.49	0.589±0.206	75.69±14.66	0.675±0.195
Shallow ConvNet ^[7]	79.21±11.87	0.722±0.158	80.08±14.39	0.734±0.191
Deep ConvNet ^[7]	75.65±14.58	0.675±0.194	81.57±8.614	0.754±0.114
EEGNet ^[9]	70.49±15.68	0.606±0.209	76.84±14.26	0.691±0.190
EEG-Conformer ^[27]	79.18±9.629	0.722±0.128	81.93±10.03	0.759±0.133
Light ConvNet ^[28]	74.54±12.20	0.659±0.164	87.36±0.783	0.831±0.104
本文方法	83.14±11.42	0.775±0.169	88.19±13.87	0.843±0.185

3.2 邻接矩阵分析

运动想象脑电信号不同通道间的相关强度不同,体现了脑功能的变化,构建的GCN如果能充分捕捉到通道间的关联性,就能得到更好的解码效果。为验证本文方法设计的邻接矩阵的有效性,与传统的皮尔逊系数构造邻接矩阵的方法进行分类结果对比,结果如表4所示,两种方法除邻接矩阵A构造不同外,邻接矩阵B、C和模型结构等均不变。从总体分类效果看,互信息估计方法的平均分类准确率要优于皮尔逊系数方法;从个体表现看,对于大部分被试,互信息估计得到的分类结果都优于皮尔逊系数,仅个别被试(如A01、K6)的皮尔逊系数结果好于互信息估计,这是因为皮尔逊系数仅是衡量通道之间的线性相关性,而互信息不仅能捕捉通道间的线性关系,还能捕捉非线性关系,能更准确地衡量脑电通道间的相关程度。同时,互信息估计不依赖于变量的具体数值分布,而是基于概率分布关系,相比皮尔逊系数对噪声和异常值具有更强的鲁棒性,更适合处理复杂的脑电信号,在分类准确率上表现更好。

3.3 连接性可视化分析

为分析MI-AGCN对运动想象脑电信号不同通道间的功能连接关系的影响,对GCN的权边进行可视化。图4展示了4个被试的脑功能连接关系,图中

表4 皮尔逊系数-GCN与互信息-GCN对比实验(%)

Table 4 Comparisons of Pearson's coefficient-GCN and mutual information-GCN (%)

被试	皮尔逊系数-GCN	互信息-GCN
A01	87.93	86.21
A02	67.24	69.83
A03	93.10	95.69
A04	76.72	76.72
A05	73.28	81.03
A06	56.90	64.65
A07	96.55	98.28
A08	87.07	92.24
A09	82.76	83.62
K3	97.22	100.0
K6	81.25	72.92
L1	89.58	91.67
平均	82.47	84.41

外圈为脑电通道编号,内圈线条表示不同通道之间的连接性能,线条颜色越深表示通道间的关联性越大。图4中,任意两通道均有连接关系,为提升可视化效果,去除关联性小的通道连接。可以看出,同一

被试不同通道间的连接强度不同,这是因为邻接矩阵包含了任意两通道间的互信息值,互信息不仅能更好地捕捉脑电信号不同脑区之间的非线性关系,还能衡量不同脑区间的信息共享程度,在构建图边时,可以识别出脑电信号中信息冗余较少、互补性较

强的通道对,有助于减少冗余连接,突出对分类有重要意义的脑区之间的连接关系,进而提高模型的计算效率和分类性能。同时,不同被试的通道连接强度各不相同,表明存在个体差异。

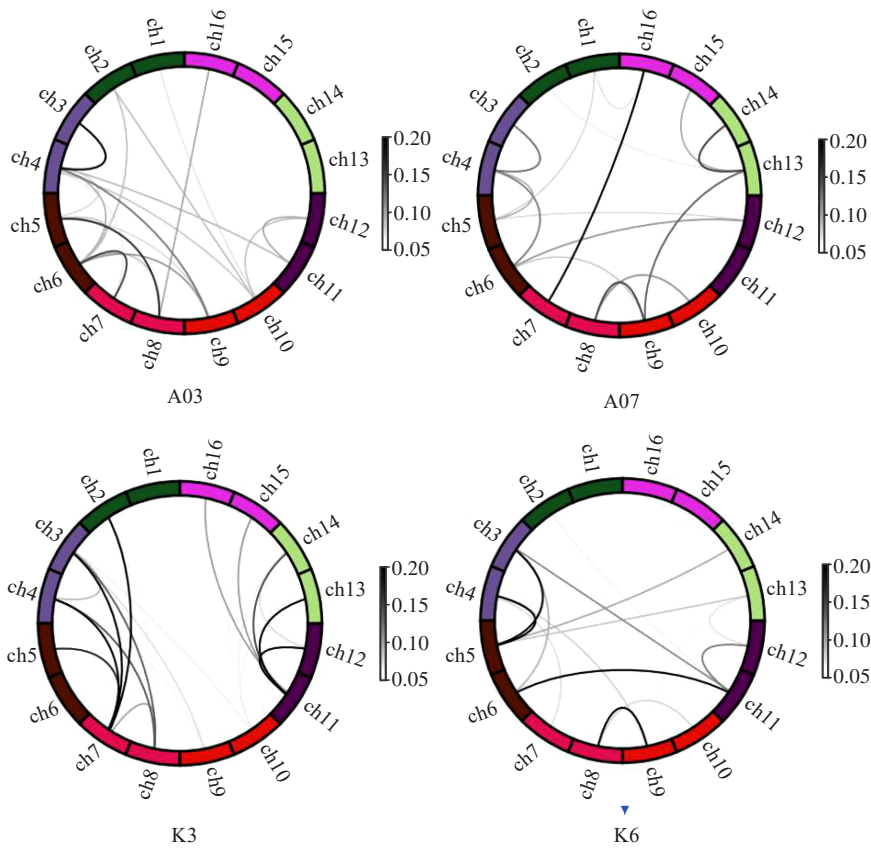


图4 功能连接可视化
Figure 4 Functional connectivity visualizations

4 结 论

本研究提出一种基于互信息估计与自适应GCN的运动想象脑电信号解码算法。对原始脑电数据进行频段划分、滤波,提高信噪比,通过MINE方法构建脑电通道间的邻接矩阵,获取脑电信号的非线性关系,并结合自适应GCN和注意力机制,捕捉脑电通道的互信息特定关系、整体共性和个体差异,有效提取运动想象脑电信号的空频特征。实验结果表明所提方法在BCI Competition IV 2a和BCI Competition III 3a数据集上的分类性能均取得显著提升,优于现有其他方法。未来工作将致力于提升模型的泛化性,同时考虑在数据量有限情况下如何提升模型的分类性能,以实现高效稳定的脑电信号解码。

【参考文献】

[1] 邱爽,张裕坤,吴晨瑶,等. 基于精细运动想象的脑机接口技术研究进展[J]. 人工智能, 2021(6): 40-50.
Qiu S, Zhang YK, Wu CY, et al. Research progress of brain-computer interface technology based on fine motor imagery [J]. Artificial Intelligence View, 2021(6): 40-50.

[2] Herff C, Heger D, de Pesters A, et al. Brain-to-text: decoding spoken phrases from phone representations in the brain[J]. Front neurosci, 2015, 9: 217.

[3] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks [C]//Proceedings of the 25th International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2012: 1097-1105.

[4] Shi XJ, Chen ZR, Wang H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting [C]// Proceedings of the 28th International Conference on Neural Information Processing Systems. Cambridge, MA, USA: MIT Press, 2015: 802-810.

[5] Zaremba W, Sutskever I, Vinyals O. Recurrent neural network regularization[EB/OL]. (2015-02-19)[2024-05-01]. <https://arxiv.org/abs/1409.2329>.

[6] 李海峰,徐聪,马琳. 基于C-LSTM模型的端到端多粒度运动想象脑电信号分析方法[J]. 信号处理, 2018, 34(8): 883-890.

- Li HF, Xu C, Ma L. End-to-end multi-granular motor imagery EEG signal analysis method based on C-LSTM model[J]. Journal of Signal Processing, 2018, 34(8): 883-890.
- [7] Schirrmeister RT, Springenberg JT, Fiederer LD, et al. Deep learning with convolutional neural networks for EEG decoding and visualization[J]. Hum Brain Mapp, 2017, 38(11): 5391-5420.
- [8] Li L, Sun N. Attention-based DSC-ConvLSTM for multiclass motor imagery classification [J]. Comput Intell Neurosci, 2022, 2022: 8187009.
- [9] Lawhern VJ, Solon AJ, Waytowich NR, et al. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces [J]. J Neural Eng, 2018, 15(5): 056013.
- [10] Zhao XQ, Zhang HM, Zhu GL, et al. A multi-branch 3D convolutional neural network for EEG-based motor imagery classification[J]. IEEE Trans Neural Syst Rehabil Eng, 2019, 27(10): 2164-2177.
- [11] Wu H, Niu Y, Li F, et al. A parallel multiscale filter bank convolutional neural networks for motor imagery EEG classification [J]. Front Neurosci, 2019, 13: 1275.
- [12] Tian WL, Li M, Ju XY, et al. Applying multiple functional connectivity features in GCN for EEG-based human identification[J]. Brain Sci, 2022, 12(8): 1072.
- [13] 许学添, 蔡跃新. 基于图卷积网络的运动想象识别[J]. 计算机工程与应用, 2022, 58(4): 186-191.
- Xu XT, Cai YX. Motor imagery recognition based on graph convolution network [J]. Computer Engineering and Applications, 2022, 58(4): 186-191.
- [14] 杨淑莹, 国海铭, 李欣. 基于通道选择和多维特征融合的脑电信号分类[J]. 计算机应用, 2023, 43(11): 3418-3427.
- Yang SY, Guo HM, Li X. EEG classification based on channel selection and multi-dimensional feature fusion [J]. Journal of Computer Applications, 2023, 43(11): 3418-3427.
- [15] 李珍琦, 王晶, 贾子钰, 等. 融合注意力的多维特征图卷积运动想象分类[J]. 计算机科学与探索, 2022, 16(9): 2050-2060.
- Li ZQ, Wang J, Jia ZY, et al. Attention-based multi-dimensional feature graph convolutional network for motor imagery classification [J]. Journal of Frontiers of Computer Science & Technology, 2022, 16(9): 2050-2060.
- [16] 湛慧苗, 曾宣威, 吕浩铵, 等. 基于互信息的帕金森病脑皮层功能连接[J]. 科学技术与工程, 2022, 22(33): 14652-14658.
- Zhan HM, Zeng XW, Lü HA, et al. Brain cortical functional connectivity in Parkinson's disease based on mutual information[J]. Science Technology and Engineering, 2022, 22(33): 14652-14658.
- [17] Pfurtscheller G, Aranibar A. Evaluation of event-related desynchronization (ERD) preceding and following voluntary self-paced movement[J]. Electroencephalogr Clin Neurophysiol, 1979, 46(2): 138-146.
- [18] Pfurtscheller G, Lopes da Silva FH. Event-related EEG/MEG synchronization and desynchronization: basic principles [J]. Clin Neurophysiol, 1999, 110(11): 1842-1857.
- [19] Ang KK, Chin ZY, Wang CC, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b [J]. Front Neurosci, 2012, 6: 39.
- [20] Kinney JB, Atwal GS. Equitability, mutual information, and the maximal information coefficient [J]. Proc Natl Acad Sci U S A, 2014, 111(9): 3354-3359.
- [21] Belghazi MI, Baratin A, Rajeshwar S, et al. Mutual information neural estimation [C]//Proceedings of the 35th International Conference on Machine Learning. Chia Laguna Resort, Sardinia, Italy: PMLR, 2018: 531-540.
- [22] Donsker MD, Varadhan SR. Asymptotic evaluation of certain Markov process expectations for large time. IV [J]. Commun Pure Appl Math, 1983, 36(2): 183-212.
- [23] Tang XL, Zhang J, Qi YD, et al. A spatial filter temporal graph convolutional network for decoding motor imagery EEG signals [J]. Expert Syst Appl, 2024, 238, Part C: 121915.
- [24] Shi L, Zhang YF, Cheng J, et al. Two-stream adaptive graph convolutional networks for skeleton-based action recognition [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2019: 12018-12027.
- [25] Koles ZJ, Lazar MS, Zhou SZ. Spatial patterns underlying population differences in the background EEG [J]. Brain Topogr, 1990, 2(4): 275-284.
- [26] Ang KK, Chin ZY, Zhang HH, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface [C]//2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence). Piscataway, NJ, USA: IEEE, 2008: 2390-2397.
- [27] Song YH, Zheng QQ, Liu BC, et al. EEG conformer: convolutional transformer for EEG decoding and visualization [J]. IEEE Trans Neural Syst Rehabil Eng, 2023, 31: 710-719.
- [28] Ma XZ, Chen WH, Pei ZC, et al. A temporal dependency learning CNN with attention mechanism for MI-EEG decoding [J]. IEEE Trans Neural Syst Rehabil Eng, 2023, 31: 3188-3200.

(编辑:谭斯允)