

基于图卷积分层时空注意力网络的运动想象分类模型

杨 塑¹, 汪曼青¹, 郜东瑞¹, 李芃锐², 汪 淳³

(1. 成都信息工程大学 计算机学院, 四川 成都 610225;
2. 电子科技大学 生命科学与技术学院, 四川 成都 611731; 3. 武汉东湖学院 计算机学院, 湖北 武汉 430072)

摘要: 随着脑机接口和深度学习发展, 基于脑电图(EEG)的运动想象(MI)解码技术得到了广泛研究, 但现有研究大多忽略了大脑不同区域间的协同作用, 且固定邻接矩阵无法有效捕捉复杂的图结构变化。为此, 提出一种基于图卷积的分层时空注意力网络(LAGA-Net), 包括浅层时空网络(LST)、高级时空注意力网络(ASTA)、基于图卷积的时空特征网络(GST)和注意力特征融合(AFF)分类器, 利用图网络表示脑电信号通道之间的关系, 通过动态注意力分数模拟通道间权重变化, 以提升关键特征提取能力。首先, 通过分层RNN与CNN学习细粒度特征; 其次, 通过ASTA增强局部特征; 最后, 使用图网络捕捉时空特征进行运动想象分类。在Physionet与CHO数据集上的实验表明, LAGA-Net在Physionet、CHO数据集上的被试独立和被试依赖的平均分类准确率为89.76%、89.24%和91.60%、91.41%, 优于其他分类方法, 提升了脑电图在运动想象分类中的准确性, 揭示了大脑不同通道及信息变化对解码结果的影响。

关键词: 运动想象分类; 图卷积; 时空网络; 注意力机制

DOI: 10.11907/rjdk.251184

中图分类号: TP391.14

文献标识码: A

文章编号: 1672-7800(2026)006-0056-08

扫描二维码阅读全文:



A Motor Imagination Classification Model Based on Graph Convolution Layer Spatiotemporal Attention Network

YANG Su¹, WANG Manqing¹, GAO Dongrui¹, LI Pengrui², WANG Chun³

(1. School of Computing, Chengdu University of Information Science and Technology, Chengdu 610225, China;
2. School of Life Sciences and Technology, University of Electronic Science and Technology, Chengdu 611731, China;
3. School of Computing, Wuhan Donghu University, Wuhan 430072, China)

Abstract: With the development of brain computer interfaces and deep learning, the decoding technology of motor imagery (MI) based on electroencephalography (EEG) has been widely studied. However, most existing research ignores the synergistic effects between different regions of the brain, and fixed adjacency matrices cannot effectively capture complex graph structural changes. To this end, a hierarchical spatiotemporal attention network based on graph convolution (LAGA-Net) is proposed, including shallow spatiotemporal network (LST), advanced spatiotemporal attention network (ASTA), graph convolution based spatiotemporal feature network (GST), and attention feature fusion (AFF) classifier. The graph network is used to represent the relationship between EEG signal channels, and dynamic attention scores are used to simulate the weight changes between channels, in order to improve the ability to extract key features. Firstly, fine-grained features are learned through hierarchical RNN and CNN; Secondly, enhance local features through ASTA; Finally, use graph networks to capture spatiotemporal features for motion imagery classification. Experiments on the Physionet and CHO datasets showed that LAGA-Net achieved average classification accuracies of 89.76%, 89.24%, 91.60%, and 91.41% for subject independent and subject dependent classification, respectively, outperforming other classification methods. This improved the accuracy of EEG in motor imagery classification and revealed the influence of different brain channels and information changes on decoding results.

Key Words: motor imagination classification; graph convolution; spatiotemporal network; attention mechanism

收稿日期: 2025-03-17

基金项目: 国家自然科学基金青年基金项目(82102175)

作者简介: 杨塑(1998-), 男, 成都信息工程大学计算机学院硕士研究生, 研究方向为脑机接口与深度学习; 汪曼青(1989-), 女, 博士, 成都信息工程大学计算机学院讲师, 研究方向为脑机接口; 郜东瑞(1987-), 男, 博士, 成都信息工程大学计算机学院副教授、硕士生导师, 研究方向为脑机接口; 李芃锐(1999-), 男, 电子科技大学生命科学与技术学院博士研究生, 研究方向为脑机接口与深度学习; 汪淳(1981-), 女, 武汉东湖学院计算机学院讲师, 研究方向为人工智能、机器学习。本文通讯作者: 汪淳。

0 引言

近年来,脑机接口(Brain-Computer Interface, BCI)在医学工程和康复领域的应用日益广泛,基本原理是通过获取大脑信号作为指令来控制外部设备^[1]。脑电图(Electroencephalogram, EEG)作为一种非侵入性、易于采集且风险低、成本相对较低的技术,成为了最常用的脑信号获取方式^[2,3]。其中,运动想象(Motor Imagery, MI)作为脑机接口的核心应用,指的是在没有实际执行运动的情况下,通过脑电活动反映个体的运动意图^[4]。

在康复和医疗应用中,运动想象不仅能帮助患者恢复身体功能,还能有效促进神经修复,在与外部设备交互中通过运动想象,即使没有实际的身体动作,BCI也能实时反映受试者的运动意识,但实现运动想象的精确解码仍存在许多困难。例如,传统脑机接口系统通常依赖受试者进行实际运动,对部分患者尤其是行动不便的患者而言极为困难。尽管,传统机器学习技术(线性判别分析、支持向量机等)在MI-EEG数据的分类中取得了一定的成果,但仍面临着一些挑战,尤其是在大规模数据的处理与噪声干扰问题上。传统方法通常通过特征提取(如CSP)处理数据,随着数据规模扩大,特征提取的计算复杂度随之增加,将导致分类精度下降^[5]。虽然,滤波器组共空间模式(Filter Bank Common Spatial Pattern, FBCSP)能在多个频段上同时提取特征,降低计算复杂度,但在高噪声环境中,如何提升分类精度仍是一个亟待解决的问题。

近年来,深度学习方法,特别是卷积神经网络(Convolutional Neural Network, CNN),在MI分类任务中效果明显。CNN通过局部特征提取能力,能有效识别EEG信号中的复杂模式,因此被广泛应用于脑电图解码中^[6-8]。此外,长短期记忆网络(Long Short Term Memory Network, LSTM)利用门控机制调节信息流,有助于捕捉信号中的长期依赖关系。然而,单独使用CNN缺乏时间序列信息的捕捉能力,单独使用循环神经网络(Recurrent Neural Network, RNN)会忽略空间信息。因此,将CNN与RNN相结合的端到端模型,在运动想象分类中具有重要的应用潜力。

尽管,卷积神经网络和循环神经网络已在运动想象领域取得了较好的成绩,但仍存在一定的局限性。特别是,在跨个体的分类任务中,模型的泛化能力往往受到限制。为了解决这一问题,Transformer等新方法开始受到关注,主要利用注意力机制处理长距离依赖关系,在机器翻译等领域取得了突破性进展^[9-11]。例如,基于Transformer的运动想象分类模型(如S3T)在跨个体任务中效果良好^[12]。为此,本文提出了一种基于注意力机制的改进模型,旨在进一步提升MI的分类性能。除了模型结构上的改进,脑功能区的交互性也是运动想象研究中研究重点。脑功能分区是将大脑不同区域与其特定功能进行关联的过程,这

些区域通常分为前额叶、额叶、顶叶、颞叶和枕叶^[13]。传统的EEG分析通常依赖单一通道的信号,研究表明EEG信号中不同通道之间的动态交互与协同作用,对准确解读脑电图至关重要^[14-16]。

然而,传统的图结构分析依赖固定的邻接矩阵,无法充分捕捉脑区之间的动态变化。图神经网络(Graph Neural Network, GNN)因处理节点间复杂依赖关系的优势,逐渐成为EEG数据分析的关键工具。相较于传统方法而言,图神经网络能自适应调整邻接矩阵,可有效应对脑电信号中复杂且动态变化的交互性。为此,本文提出一种基于图神经网络的改进模型,以更好地捕捉脑区之间的协同作用,提升运动想象分类精度。本文创新点和贡献如下:①将图卷积与时空注意力相结合。在基于图卷积的分层时空注意力网络(LAGA-Net)中引入时空注意力机制,旨在动态捕捉大脑不同区域间的复杂协同作用。相较于传统方法仅考虑空间关系或时间特征的优势在于,LAGA-Net通过图卷积网络(Graph Convolutional Network, GST)捕捉脑电信号的时空特征,通过时空注意力机制学习对细粒度特征;②动态注意力机制。相较于静态的固定邻接矩阵而言,LAGA-Net采用时空注意力机制,在训练过程中动态调整不同脑区通道的权重,使网络能更精确地关注运动想象任务中关键的脑区和时刻,以提升分类准确率。

1 本文方法

1.1 整体框架

网络整体框架由浅层时空网络(Shallow Spatiotemporal Network, LST)、高级时空注意力网络(Advanced Spatiotemporal Attention Network, ASTA)、基于图卷积的时空特征网络(Graph Convolutional Spatiotemporal Feature Network, GST)和注意力特征融合(Attention Feature Fusion, AFF)分类器组成,如图1所示。浅层时空网络用于捕获局部脑区的细粒度特征;高级时空注意力网络用于增强局部脑区的细粒度特征;基于图卷积的时空特征网络用于创建自适应邻接矩阵,以获取不同节点之间的空间特征;注意力特征融合分类器使用注意力机制融合和分类时空特征。

1.2 子模块

1.2.1 浅层时空网络

浅层时空网络的关键在于其多层次结构。首先,通过并行卷积层和循环层,将其作为浅层时空网络的一层;其次,进行多层次叠加,将前一层的输出作为下一层的输入,以逐层提取更深层次的细粒度时空特征。单层卷积神经网络的计算公式为:

$$Y = f(W \cdot X + b) \quad (1)$$

式中: W 表示权重矩阵; X 表示输入值; b 表示偏移量; f 表示激活函数; Y 表示输出值。

隐藏层的计算公式如式(2)所示。输出层是一个全连




Fig. 1 Overall framework of the model

图1 模型整体框架

接层,每个节点都和隐藏层的每个节点相连,计算公式如式(3)所示。

$$S_t = f(U \cdot X_t + W \cdot S_{t-1}) \quad (2)$$

$$O_t = g(V \cdot S_t) \quad (3)$$

式中: X_t 为 t 时刻的输入; U 为输入 x 的权重矩阵; W 为上一次的值作为这一次的输入的权重矩阵; f 为激活函数; S_t 为隐藏层的输出; V 为输出层的权重矩阵; g 为激活函数; S_t 为隐藏层的输出; O_t 为输出层的输出。

最终,浅层时空网络一层的输出为:

$$Z = Y + O_t \quad (4)$$

式中: Z 为最终输出; Y 为卷积层输出; O_t 为循环层输出。

1.2.2 高级时空注意力网络

首先,通过浅层时空网络提取到一个初级时空特征 Z ;其次,构建一个由注意力机制组成的深层时空网络,主要由时间注意力与空间注意力构成。时间注意力(Temporal Attention, TA)在神经网络中,用于识别时间序列数据中不同时间步之间的重要性和相互关系,核心在于提升模型对时间序列数据中长期依赖关系和动态模式的理解。操作流程为:

步骤1:输入。将浅层时空网络提取到的特征 Z 降维得到一个一维的序列 X_t 。

步骤2:特征提取。通过循环神经网络对不同时间步进行特征提取。

$$h_t = R(X_t, h_{t-1}) \quad (5)$$

式中: h_t 为时间步 t 对应的隐藏状态; X_t 为时间步 t 的输入; h_{t-1} 为前一个时间步的隐藏状态; R 为循环神经网络。

步骤3:计算注意力分数,即计算不同时间步之间的关联系数。先计算各时间步之间的注意力权重, e_{ij} 表示时间步 i 和时间步 j 间的关联程度;再计算每个时间步 i 对时间

步 j 的注意力分数 a_{ij} 。

$$e_{ij} = \tanh(W_a[h_i, h_j] + b_a) \quad (6)$$

式中: W_a 、 b_a 为训练得到的参数; $[h_i, h_j]$ 为时间步 i 与 j 隐状态的拼接; $\tanh$ 为激活函数。

$$a_{ij} = \frac{\exp(e_{ij})}{\sum_{k=1}^T \exp(e_{ik})} \quad (7)$$

式中: a_{ij} 为时间步 i 对时间步 j 的注意力分数; $\exp(e_{ij})$ 为对时间步 i 与 j 之间的关联程度进行指数化,目的是放大关联度较强的得分。

步骤4:加权池化。筛选不同时间步之间关联程度较高的一部分信息。先使用计算得到的注意力权重 a_{ij} 对时间步 j 的隐状态 h_j 进行加权池化,得到时间步 i 的加权和输出;再将所有时间步的加权池化结果拼接成一个新的表示 Y_t 进行输出。

$$c_i = a_{ij}h_j \quad (8)$$

$$Y_t = [c_1; c_2; \dots; c_T] \quad (9)$$

式中: c_i 为经过加权池化后的输出,表示时间步 i 对其他时间步信息的加权; a_{ij} 为注意力权重; h_j 为 j 时刻对应的隐藏状态。

步骤5:输出。

空间注意力(Spatial Attention, SA)是一种提升神经网络对空间特征关注的机制,常用于处理图像或视频等具有空间结构的数据。该机制通过生成关注特定区域的权重,以强调重要的空间信息,操作流程为:

(1):输入特征,即浅层时空网络的输出 Z 。

(2):生成并计算注意力权重。首先,通过全局平均池化计算出一个权重(见式(10));其次,使用激活函数将其转化为注意力权重(见式(11))。

$$\hat{h} = \frac{1}{T} \sum_{t=1}^T h_t \quad (10)$$

$$k = \sigma(\text{ReLU}(W \cdot \hat{h} + b)) \quad (11)$$

式中: h_t 为时间步 t 对应的隐藏状态; T 为时间步总数; $\hat{h}$ 为隐藏状态的平均值; k 为权重系数; W 为卷积核; b 为偏置项; σ 为激活函数(通常为sigmoid函数);ReLU为修正线性单元激活函数。

(3):对特征图进行加权。将输入特征图与注意力权重进行逐元素相乘,得到特征图中最重要区域的信息,即将输入特征 Z 与权重系数 k 相乘得到加权后的特征 Y_s 。

$$Y_s = Z \cdot k \quad (12)$$

(4):输出。

1.2.3 基于图卷积的时空特征网络

图卷积网络是一种专用于处理图结构数据的神经网络,特别适合于空间结构的数据,例如社交网络、分子结构、交通网络等,使模型能有效捕捉不同节点之间的空间特征。本文将应用于脑电空间结构中,设计多层图卷积获取节点之间的关系即通道之间的关系,以捕捉局部脑电之间的关系。具体为,在每层图卷积中,节点特征会与其邻居节点的特征进行聚合,优势在于使用自适应邻接矩阵(本文使用注意力分数作为邻接矩阵),以动态捕获不同通道间的信息,具体流程如下:

步骤1:输入。将高级时空注意力网络的输出 Y_t, Y_s 分别作为图卷积的输入 X ,通过线性变换得查询(Query, Q)、键(Key, K)和值(Value, V)。

$$Q = XW_QK = XW_KV = XW_V \quad (13)$$

式中: W_Q, W_K, W_V 为不同的权重矩阵。

步骤2:计算注意力分数。对于每个通道 i ,通过查询 Q_i 和键 K_i 的点积计算得到 Attention_i 注意力分数(即注意力权重)。

$$\text{Attention}_i = \frac{Q_i K_i^T}{\sqrt{d_k}} \quad (14)$$

式中: d_k 为一个缩放因子,用来防止点积过大。

步骤3:应用softmax。应用softmax函数对注意力分数进行归一化。

$$\alpha_i = \text{softmax}(\text{Attention}_i) \quad (15)$$

步骤4:加权求和。使用归一化后的注意力权重 α_i 加权求和 V_i 。

$$\text{Output}_i = \alpha_i V_i \quad (16)$$

步骤5:输出结果。将各个头的输出连接起来,通过一个线性变换得到最终的输出表示。

$$A = \text{Concat}(\text{Output}_1, \text{Output}_2, \dots, \text{Output}_h) \quad (17)$$

步骤6:图卷积操作。将高级时空注意力网络的输出 Y_t, Y_s 分别作为图卷积的输入 X ,即可得到具有通道结构信息的时间和空间特征 g_t, g_s 。

$$g = \sigma(AW) \quad (18)$$

式中: σ 为sigmoid激活函数; A 为通过注意力分数计算出来的邻接矩阵; X 为输入特征; W 为可学习权重矩阵; g 为经过图卷积后的特征表示。

1.2.4 注意力特征融合分类器

AFF是一种为了提升模型对多模态数据的处理能力,而提出的结合注意力机制的特征融合方法。融合过程为:

步骤1:特征提取。将图卷积得到的时空特征 g_t, g_s 作为输入 X 。

步骤2:使用注意力机制计算每个特征的权重。先通过线性变换得到查询(Query)、键(Key)和值(Value),如式(13)所示;再计算每个特征的权重。

$$\alpha = \text{softmax}\left(\frac{QK_i^T}{\sqrt{d_k}}\right) \quad (19)$$

式中: α 为计算得到的归一化注意力权重; d_k 为缩放因子; K_i^T 为 t 时刻键 K 的转置; Q 为查询,softmax为激活函数。

步骤3:对特征进行加权,将注意力权重与输入特征进行点积,以加权特征。

$$X' = \alpha \cdot X \quad (20)$$

式中: X' 为加权后的特征; α 为注意力权重; X 为输入特征。

步骤4:通过拼接的方式对时间与空间特征进行整合。将加权后的时间特征 X'_t 与空间特征 X'_s 进行拼接,得到最终融合特征 g_{fusion} 。

$$g_{\text{fusion}} = \text{Concat}(X'_t, X'_s) \quad (21)$$

2 实验结果与分析

2.1 数据集

2.1.1 Physionet数据集

Physionet数据集由109名志愿者的原始时间序列脑电图数据组成,本文选取其中数据较好的90个被试,采样频率为160 Hz。每个被试先进行两次1 min的静息,再进行3次2 min的任务。任务由以下4个子任务组成:①张开和收紧左拳或右拳;②想象张开和收紧左拳或右拳;③张开和收紧双拳或双脚;④想象张开和收紧双拳或双脚。

实验范式:试验开始前2 s,要求被试进行一次2 s静息。在 $t=0$ s时,屏幕上提示要求被试执行一个4 s的运动想象任务。在 $t=4$ s时,要求被试再次进行一次2 s静息,随后进行下一次运动想象任务。

2.1.2 CHO数据集

CHO数据集由52名被试的原始时间序列脑电图数据组成,每个被试都参加了相同的实验任务,分别对左手和右手进行运动想象。

实验范式:在正式运动想象任务前,先进行2 s静息,再进行3 s的左右手运动想象任务,最后进行一次2 s静息。

2.2 模型参数

超参数在训练过程中起着至关重要的作用,用于控制训练算法的行为和表现。分类模型的超参数是指在模型训练前需设定一些变量、定义网络结构,LAGA-Net的超参

数如表 1 所示。

Table 1 LAGA-Net network hyperparameters

表 1 LAGA-Net 网络超参数

超参数名称	超参数值
激活函数	Sigmoid, ReLU, Softmax
学习率	0.000 05
损失函数	CrossEntropyLoss
优化器	Adam
epochs 数量	200
Batch_size	20, 64
随机失活	0.2

本文使用准确度 (ACC) 和标准差 (σ) 评估模型性能。

$$ACC = \frac{\sum_{i=1}^n TP_i / I_i}{n} \quad (22)$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n}} \quad (23)$$

式中: TP_i 为预测为正样本的数量; I_i 为正样本数量; x_i 为样本值; μ 为样本平均值; n 为样本总量。

2.3 比较实验

2.3.1 评估方法

所提模型通过以下两种方法进行评估: ①基于主题的评估 (特定于主题); ②独立于主题的评估。对于独立于主题的评估, 本文采用跨主题评估方法, 称为“留一主题法” (即跨被试评估)。在这种方法中, 模型经过多次训练和评估, 训练次数等于主题数量, 每次训练中选择一个主题用于评估, 其余的主题用于训练模型。

2.3.2 实验结果

四分类比较模型包括: ①CP-MixedNet 是一种基于振幅扰动数据增强的运动图像脑电图解码方法; ②RLA-CNN 是一种基于残差学习注意力网络的运动意图识别方法; ③CNN+LSTM 是一种结合 CNN 与 LSTM 网络的混合深度网络, 能提取和学习 MI 脑电信号的空间、时间特征; ④S3T 通过依赖注意力机制的小型方法, 来感知 EEG 信号的时空特征并进行解码; ⑤GAT 模型引入注意力机制, 为每个节点的邻居赋予不同权重, 以改善 GCN 模型在图神经网络上的表现。

二分类比较模型包括: ①EEGNet 设计了一个紧凑、实用的 CNN, 通过深度可分离卷积对 EEG 进行分类; ②ConvNet 是一种基于 CNN 的深度学习模型进行 EEG 解码的方法; ③MIDNN 是一种基于 DNN 模型的分类模型, 从原始脑电图信号中提取光谱特征作为 MIDNN 模型的输入特征; ④EEGNet Fusion 是基于具有三支 EEGNet 架构的 CNN; ⑤S3T 依赖注意力机制感知 EEG 信号的时空特征进行解码; ⑥GAT 模型引入注意力机制, 为每个节点的邻居赋予不同的权重, 以改善 GCN 模型在图神经网络上的表现。

首先, 基于四分类的 Physionet 数据集进行实验。不同模型在 MI-EEG 四分类任务中的平均准确度和标准差如

表 2 所示。由此可知, 所提模型在性能上优于过去两年内提出的其他模型, 标准差明显低于其他模型, 在稳定性方面表现较好。其次, 基于二分类的 CHO 数据集进行实验。不同模型在 MI-EEG 二分类任务中的总体准确度如表 3 所示。由此可知, LAGA-Net 模型在二分类研究上优于其他所有模型, 且标准差都优于其他模型, 证明了本文模型相较于近两年提出的其他模型, 准确度和稳定性都更强。

Table 2 Comparison of different models in four-class classification tasks

表 2 不同模型在四分类上的研究比较

Models	Accuracy/%	Std	Subject
FBCSP-CNN ^[17]	72.35	13.54	90
CP-MixedNet ^[18]	75.60	6.13	90
RLA-CNN ^[19]	77.65	6.89	105
CNN+LSTM ^[20]	82.06	12.05	90
DFL ^[21]	82.66	11.10	90
S3T ^[12]	84.75	12.69	90
GAT ^[22]	83.18	9.31	90
LAGA-Net	89.76	4.56	90

Table 3 Comparison of different models in binary classification tasks

表 3 不同模型在二分类上的研究比较

Models	Accuracy/%	Std	Subject
EEGNet ^[23]	77.12	11.67	52
ConvNet ^[24]	80.42	17.63	52
MIDNN ^[25]	82.22	3.55	52
MSCNN ^[26]	83.14	11.82	52
EEGNet Fusion ^[23]	82.97	8.49	52
S3T ^[12]	83.01	12.21	52
GAT ^[22]	84.65	5.26	52
LAGA-Net	91.60	2.42	52

综上, 所提网络的准确性不管是在主题相关的情况下, 还是在个体较少、跨被试的情况下都具有明显优势, 在所有数据集的测试中, 所提方法相较于现有方法效果更好。同时, 本文方法的 std 处于较低的状态, 意味着网络在进行运动想象解码时具有较好的稳定性。

2.3.3 计算成本

除了比较分类准确度和标准差外, 计算成本也体现了模型的解码性能。为了更好地比较所提网络相较于其他方法在计算成本方面的优势, 在两个数据集上进行耗时比较, 如表 4 所示。需要强调的是, 本文比较的是独立被试实验, 即测试一个被试所需的时间。由表 4 可知, LAGA-Net 相较于比较方法, 在耗时上的优越性能明显, 在 Cho、Physionet 上的平均测试运行时间分别为 3.08 s、3.28 s。

Table 4 Testing time of different methods on two datasets

表 4 在两个数据集上不同方法的测试时间

数据集	Channel C	LAGA-Net/s	MSCNN ^[25] /s	EEGNet Fusion ^[22] /s	S3T ^[12] /s
Cho	64	3.08±0.06	4.02±0.37	4.43±0.05	5.42±0.08
Physionet	64	3.28±0.03	4.57±0.06	3.89±0.07	4.65±0.30

2.4 消融实验

本文通过消融实验研究 LST、ASTA、GST、AFF 模块对 MI-EEG 分类效果的影响,具体为使用 Physionet 数据集中的被试 5 和 CHO 数据集中的被试 8 进行实验,结果如表 5 所示。由此可知,缺失 GST 模块后模型性能下降最明显;使用 GST 模块但不使用注意力分数作为邻接矩阵的网络,性能也下降了不少,但仍相较于不使用 GST 模块的网络分类性能更高。实验证明,图网络及使用注意力分数生成的动态邻接矩阵对模型的重要性明显,LST、ASTA、GST、AFF 在不同程度上都有助于网络对运动想象进行解码。

2.5 聚类实验

为了深入探讨构建的网络提取特征的判别能力,使用 t-SNE 可视化学习到的特征。t-SNE 将提取的 EEG 特征可

Table 5 Performance comparison of missing different sub modules

表 5 缺失不同子模块的性能比较

	四分类		二分类	
	Accuracy	Std	Accuracy	Std
LAGA-Net	89.76	4.56	91.60	2.42
Network without LST	84.64	5.81	83.25	2.73
Network without ASTA	84.28	5.62	82.91	3.37
Network without GST	81.11	8.17	80.77	5.44
Network with GST not use Attention score	84.75	7.31	83.37	4.75
Network without AFF	85.37	5.23	84.52	4.08

视觉化为二维嵌入维度,如图 2 所示。由此可见,消融实验中的模型和最近研究的模型聚类效果较分散,没有图卷积网络的简化模型聚类效果最差,所提模型的聚类效果最好。为此,使用 LAGA-Net 提取脑电特征,对运动想象分类具有不错的解码效果。




Fig. 2 Four category t-SNE results

图 2 四分类 t-SNE 结果

2.6 脑拓扑图结果

本文利用脑拓扑图呈现不同频带在相应 MI 任务中的通道激活程度,以揭示局部域间的潜在协同合作模式。在 Physionet 数据集上,显示 4~8 Hz、8~12 Hz、12~30 Hz 频带的电极通道的特征激活程度,以呈现其与特定 MI 任务的相关性,如表 6 所示。由此可知,不同频带对应的电极通道在同一 MI 任务下呈现的激活程度存在显著差异,同一频带对应的电极通道在不同 MI 任务下呈现的激活程度差异也十分显著。

同时,通过脑拓扑图直观反映 HSTA-HNet 对脑功能区间的潜在协同合作模式的捕捉效果,如表 6 所示。由此可知,该网络可捕捉特定任务下的特定频带的区域间合作模式,可提升 MI-EEG 的解码性能,呈现出更多的中央沟

与外周区域的合作关系。具体为,以往工作已发现中央沟(特别是 C3、C4)与顶叶区域最能反映 MI 的过程,本文深入挖掘出中央沟与外周区域的合作模式,证明了该研究能揭示局部域间的潜在协同合作模式。



2.7 混淆矩阵

本文在四分类实验中分析了 Physionet 数据集中被试 5 的混淆矩阵,如图 3 所示。其中,图 3(a)为 LAGA-Net 的混淆矩阵,图 3(b)为缺少浅层时空网络的混淆矩阵,图 3(c)为缺少高级时空注意力网络的混淆矩阵,图 3(d)为缺少基于图卷积的时空特征网络的混淆矩阵,图 3(e)为缺少注意力特征融合分类器的混淆矩阵。


由图 3 可见,本文网络左手、右手和双手的分类效果均优于消融实验中的其他简化模型,但双脚的分类效果略微差,原因为双脚的运动涉及更复杂的大脑运动模式,例

Table 6 Brain topology results


表6 脑拓扑结果




(a)




(b)



(c)



(d)



(e)

Fig. 3 Four class confusion matrix

图3 四分类混淆矩阵

如中央顶叶区域是躯体感觉皮层的一部分,负责运动控制的调节,特别是双脚的运动涉及躯体的平衡,因此分类性能略微差,而非模型结构的原因。

同时,缺少浅层时空网络、高级时空注意力网络和注意力特征融合分类器的混淆矩阵的模型分类效果相较于完整模型较差,特别是缺少图卷积的时空特征网络的混淆矩阵的分类效果急剧下滑,证明了图卷积时空网络的重

要性。

3 结语

本文提出一种图网络与注意力机制相结合的运动想象分类模型 LAGA-Net,在学习细粒度特征的同时增强了局部特征表示。首先,引入图卷积帮助模型动态捕捉大脑

不同区域间的复杂协同作用;其次,采用时空注意力机制,在训练过程中动态调整不同脑区通道的权重,使网络能更精确地关注运动想象任务中的关键脑区和时刻,提升分类准确率。

在Physionet和cho数据集上的实验表明,所提模型具有较高的精度,具备良好的泛化能力和鲁棒性。同时,消融实验证明了图网络和使用注意力分数生成的邻接矩阵对模型分类的重要性。此外,在脑拓扑图实验中揭示了各模块对解码判别性特征的分布影响和在不同MI任务上局部域间的潜在协同合作模式。

然而,LST通过分层CNN与RNN提取局部特征后,使用GST再次对空间关系进行建模,可能会导致部分特征重复计算,未来可引入特征选择机制减少这一影响;ASTA将时间和空间注意力分开设计,可能会忽略时空特征的联合依赖性,未来可考虑联合建模时空注意力机制,以更好地捕捉时空信息的协同作用。

参考文献:

- [1] SANTHANAM G, RYU S I, BYRON M Y, et al. A high-performance brain-computer interface[J]. *Nature*, 2025, 31: 96-104.
- [2] DECETY J. The neurophysiological basis of motor imagery [J]. *Behavioural Brain Research*, 1996, 77: 45-52.
- [3] GAO D, ZHANG H, LI P, et al. A local-ascending-global learning strategy for brain-computer interface [C]// *Proceedings of the AAAI Conference on Artificial Intelligence*, 2024: 10039-10047.
- [4] ALTAHERI H. Deep learning techniques for classification of electroencephalogram (EEG) motor imagery (MI) signals: a review [J]. *Neural Computing and Applications*, 2023, 35(20): 14681.
- [5] MULLER-GERKING J, PFURTSCHER G, FLYVBJERG H. Designing optimal spatial filters for single-trial EEG classification in a movement task [J]. *Clinical Neurophysiology*, 1999, 110(5): 787-798.
- [6] LIN C T, CHUANG C H, HUNG Y C, et al. A driving performance forecasting system based on brain dynamic state analysis using 4-D convolutional neural networks [J]. *IEEE Transactions on Cybernetics*, 2020, 51(10): 4959-4967.
- [7] AMIN S U, ALSULAIMAN M, MUHAMMAD G, et al. Deep learning for EEG motor imagery classification based on multi-layer CNNs feature fusion [J]. *Future Generation Computer Systems*, 2019, 101: 542-554.
- [8] ALTUWAIJRI G A, MUHAMMAD G, ALTAHERI H, et al. A multi-branch convolutional neural network with squeeze-and-excitation attention blocks for EEG-based motor imagery signals classification [J]. *Diagnostics*, 2022, 12(4): 995.
- [9] SUN J, XIE J, ZHOU H. EEG classification with transformer-based models [C]// *IEEE 3rd Global Conference on Life Sciences and Technologies*, 2021: 92-93.
- [10] PAN Y T, CHOU J L, WEI C S. MATT: a manifold attention network for EEG decoding [DB/OL]. <https://arxiv.org/abs/2210.01986>.
- [11] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [DB/OL]. <https://arxiv.org/pdf/1706.03762v6>.
- [12] SONG Y, JIA X, YANG L, et al. Transformer-based spatiotemporal feature learning for EEG decoding [DB/OL]. <https://arxiv.org/abs/2106.11170>.
- [13] DING Y, ROBINSON N, TONG C, et al. LGGNet: learning from local-global-graph representations for brain-computer interface [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 7: 9773-9786.
- [14] BASSETT D S, SPORNS O. Network neuroscience [J]. *Nature Neuroscience*, 2017, 20(3): 353.
- [15] LYU J, JIANG X, LI X, et al. Holistic atlases of functional networks and interactions reveal reciprocal organizational architecture of cortical function [J]. *IEEE Transactions on Biomedical Engineering*, 2014, 62(4): 1120-1131.
- [16] LYU J, NGUYEN V T, DERMEER V J, et al. Nway decomposition: towards linking concurrent EEG and fMRI analysis during natural stimulus [C]// *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2017: 382-389.
- [17] BANG J S, LEE M H, FAZLI S, et al. Spatiotemporal feature representation for motor imagery classification using convolutional neural networks [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(7): 3038-3049.
- [18] LI Y, ZHANG X R, ZHANG B, et al. A channel-projection mixed-scale convolutional neural network for motor imagery EEG decoding [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(6): 1170-1180.
- [19] WANG T, MAO J, AO R, et al. Residual learning attention CNN for motion intention recognition based on EEG data [C]// *IEEE Biomedical Circuits and Systems Conference*, 2021: 1-6.
- [20] ZHANG R, ZONG Q, DOU L, et al. A novel hybrid deep learning scheme for four-class motor imagery classification [J]. *Journal of Neural Engineering*, 2019, 16(6): 66004.
- [21] YANG L, SONG Y, MA K, et al. Motor imagery EEG decoding method based on a discriminative feature learning strategy [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021, 29: 368-379.
- [22] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks [DB/OL]. <https://arxiv.org/abs/1710.10903>.
- [23] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces [J]. *Journal of Neural Engineering*, 2018, 15(5): 56013.
- [24] SCHIRRMESTER R T, SPRINGENBERG J T, FIEDERER L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization: convolutional neural networks in EEG analysis [J]. *Human Brain Mapping*, 2017, 38(11): 5391-5420.
- [25] TIWARI S, GOEL S, BHARDWAJ A. MIDNN—a classification approach for the EEG based motor imagery tasks using deep neural network [J]. *Applied Intelligence*, 2022, 52: 4824-4843.
- [26] TANG X, LI W, LI X, et al. Motor imagery EEG recognition based on conditional optimization empirical mode decomposition and multi-scale convolutional neural network [J]. *Expert Systems with Applications*, 2020, 149: 113285.

(责任编辑:刘嘉文)