



基于 GAF 和混合模型的运动想象分类研究

吕仁杰¹, 常文文^{1,2*}, 闫光辉^{1,2}, 聂文超¹, 郑磊¹, 郭斌³

(1. 兰州交通大学 电子与信息工程学院, 兰州 730070; 2. 甘肃省媒体融合技术与传播重点实验室, 兰州 730030;
3. 西北工业大学 计算机学院, 西安 710129)

摘要 针对运动想象脑-机接口的分类识别问题, 提出了一种结合格拉姆角场理论、卷积神经网络 (Convolutional Neural Networks, CNN) 和长短期记忆网络 (Long Short-Term Memory, LSTM) 的新模型。首先, 分别使用格拉姆角场中的格拉姆角和场与格拉姆角差场算法将一维运动想象脑电信号表示为二维图像; 然后, 设计针对性的浅层 CNN 和 LSTM 相结合的模型来识别该图像特征, 从而完成运动想象分类。在 BCI Competition IV 2a 公开数据集上就运动想象任务进行了四分类验证。实验结果表明, 在单被试和多被试的情况下, GASF-CNN-LSTM 模型和 GADF-CNN-LSTM 模型相比其他模型性能提升显著, 准确率均达 87.66% 以上, 最高准确率可达 99.09%。且针对运动功能障碍患者数据也能表现出良好的性能。对运动想象脑电信号的时间依赖性和对应特征的图像生成表征方法进行了探讨, 为运动想象脑电信号特征挖掘提供了新思路。

关键词 脑-机接口; 运动想象; 格拉姆角和场; 格拉姆角差场; 卷积神经网络

中图分类号 TP391 文献标志码 A DOI 10.12178/1001-0548.2023250

Research on Motor Imagery Classification Based on GAF and Hybrid Model

LYU Renjie¹, CHANG Wenwen^{1,2*}, YAN Guanghui^{1,2}, NIE Wenchao¹, ZHENG Lei¹, and GUO Bin³

(1. School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. Gansu Provincial Key Laboratory of Media Convergence Technology and Communication, Lanzhou 730030, China;

3. School of Computer Science, Northwestern Polytechnical University, Xi'an 710129, China)

Abstract As a paradigm of brain-computer interface, motor imagery has a broad application prospect in the field of medical rehabilitation. Due to the non-stationarity and low signal-to-noise ratio of Electroencephalograph (EEG) signals, how to effectively extract the features of motor imagery signals and achieve accurate recognition is a key issue in the motor imagery brain-computer interface technology. Aiming at the classification and recognition problem of motor imagery brain-computer interface, this paper proposes a new method combining Gramian Angular Field (GAF) theory, Convolutional Neural Networks, and Long Short-Term Memory (LSTM). First of all, The Gramian Angular Summation Field (GASF) and the Gramian Angular Difference Field (GADF) in GAF are used respectively. GADF algorithm represents one-dimensional motor imagery EEG signals into two-dimensional images. Then, a targeted shallow Convolutional Neural Network (CNN) model is designed to realize the recognition of the image features to complete the motor imagery classification. A 4-class validation on the BCI Competition IV 2a public dataset is performed on the motor imagery task. The experimental results indicate that, in both single-subject and multi-subject scenarios, the GASF-CNN-LSTM and GADF-CNN-LSTM models exhibit significant performance improvements compared to other state-of-the-art models. Their accuracies surpass 87.66%, with the highest accuracy reaching 99.09%. Moreover, these models demonstrate strong performance when handling data from patients with motor functional disorders, further confirming the effectiveness of the models. In this paper, the time dependence and the image generation and representation technology of the corresponding features of the motor image EEG are discussed, which provides a new idea for the feature mining of the motion image EEG.

Key words brain-computer interface; motor imagery; Gramian angular summation field; Gramian angular difference field; convolutional neural networks

收稿日期: 2023-10-07; 修回日期: 2024-04-25

基金项目: 国家自然科学基金 (62366028, 62466032); 甘肃省科技重大专项 (23ZDFA012); 甘肃省科技计划项目 (24JRRA256); 甘肃教育厅科技项目 (甘财教 2023-25 号); 甘肃省教育厅青年博士项目 (2023QB-038)

作者简介: 吕仁杰, 主要从事脑-机接口方面的研究。

*通信作者 E-mail: changww2013@126.com

脑-机接口 (Brain-Computer Interface, BCI) 是大脑与外部环境交互的直接通道, 能够为用户与外界建立沟通的桥梁^[1]。作为一种新型人机交互方式, 脑-机接口近年来备受研究者的关注。

运动想象作为 BCI 的一个范式, 主要使用感觉运动节律 (Sensorimotor Rhythm, SMR) 信号^[2]。当人进行肢体运动或想象肢体运动时, 大脑皮层感觉运动区域的 SMR 出现增加或降低的现象, 出现局部事件相关同步 (Event-Related Synchronization, ERS) 或事件相关去同步 (Event-Related Desynchronization, ERD)^[3-5], 运动想象脑-机接口系统可以通过 ERD/ERS 的不同来解码用户的运动意图, 从而控制外部设备。运动想象不需要外部刺激来诱发 EEG 的电位活动, 不需要额外的辅助硬件设备, 因此对用户和研究者而言使用更为方便快捷, 具有更广泛的研究前景^[6]。然而, 由于 MI 信号是非平稳性信号, 信号幅度微弱, 具有低信噪比的特性, 其信号容易受到噪声和伪迹的干扰。因此, 提高运动想象分类性能是一个具有挑战性的问题^[7]。

运动想象根据特征提取算法的不同可以分为传统机器学习和深度学习两种。在传统机器学习方面, 最主要的特征提取算法是共空间模式^[8] (Common Spatial Pattern, CSP) 算法以及它的变种: 共空间频谱模式^[9] (Common Spatial Spectral Pattern, CSSP) 和滤波器组共空间模式^[10] (FBCSP) 等。上述传统的方法往往都需要预处理, 耗费时间的同时还需要依靠个人的经验以及先验知识。仅依靠个人经验以及先验知识很难应用于各种场景, 且鲁棒性较差, 最终导致 MI 信号识别准确率较低。

近年来, 随着深度学习在计算机视觉和语言识别领域的发展, 许多研究已经使用深度学习算法进行脑电信号处理。文献 [11] 提出了 3 种用于运动想象分类的卷积神经网络 (Convolutional Neural Network, CNN) 模型 (Shallow ConvNet, Deep ConvNet 和 Hybrid ConvNet), 相较于传统的 FCSP 准确率提升了 1.9%, 虽然提升不大, 但是证明了深度学习方法不亚于传统方法的效果。文献 [12] 提出浅层 CNN 模型 EEGNet, 直接处理原始脑电信号, 使用多个并行和串行的卷积滤波器进行特征提取, 相较于传统方法取得了更优的性能。文献 [13] 提出了一种 CNN 与长短期记忆网络 (Long Short-Term Memory, LSTM) 特征融合的算法, 使用 CNN 和 LSTM 分别提取空间和时间特征, 之后在全连接层进行特征融合, 在 BCI Competition IV

2a 公开数据集上平均准确率达 87.68%。文献 [14] 提出了一种多分支多尺度的卷积神经网络 (Multi-Memory Convolutional Neural Network, MMCNN), 使用不同卷积核大小以及多个分支进行特征提取, 最后整合多个特征进行 MI-EEG 分类任务。文献 [15] 提出了一种带有数据增强的混合尺度 CNN 架构 HS-CNN, 解决了单一卷积核限制分类准确率的问题, 在 BCI Competition IV 2a 公开数据集上平均准确率达 91.57%。文献 [16] 提出了一种结合不同数据增强技术的端到端 CNN 模型, 针对原始脑电信号, 使用 CNN-Attention-Dense 架构提取更深层次的特征, 在 BCI Competition IV 2a 数据集上平均准确率达 93.66%。

尽管深度学习模型目前已经有了很高的准确性, 但它通常不能可视化, 这对辅助诊疗有一定影响。因此, 很多研究者将 EEG 一维时间序列用二维表示, 然后放入卷积神经网络模型中进行 MI-EEG 分类任务, 其中最常见的方法是基于频谱特征的二维图像表示。如文献 [17] 提出了一种基于时频图和卷积神经网络分类的方法, 使用短时傅里叶变换将脑电信号转换为二维图像, 然后分别使用深度学习和机器学习的方法提取图像特征并进行分类。文献 [18] 提出了一种基于二次型时频分布 (Quadratic Time-Frequency Distributions, QTFD) 和密接型网络 (DenseNet) 的新型 MI-EEG 分类模型, 使用 QTFD 将脑电信号转换为时频图, 然后使用 DenseNet 充分提取时频图的纹理特征和深度特征。文献 [19] 利用小波变换将多通道脑电信号转换为二维时频图, 构建了一个两层的 CNN 模型进行特征提取与分类识别, 在 BCI Competition IV 2a 达到 85.29% 的平均准确率。将 EEG 表示为二维图像后, 用于图像分类的模型也可以应用到 BCI 的解码过程中, 但由于脑电信号是非线性的, 使用时频分布的二维表示过程中会忽略掉部分非线性信息, 且不能完整的保留脑电信号的时间信息, 进而影响模型分类性能。

目前, 已经有研究表明格拉姆角场 (Gramian Angular Field, GAF) 方法可以为时间序列保留更多的非线性特征以及时间^[20]。如文献 [21] 提出了一种结合 GAF 和递归图 (Recurrence Plot, RP) 用于精神分裂症分类模型, 使用 GAF 与 RP 方法将精神分裂症脑电数据转换为二维图像, 再结合图像分类中经典模型 VGGNet 进行分类识别。文献 [22] 提出了一种结合 GAF 和 DensNet 的语音想象脑-机

接口分类新模型,使用 GAF 算法将语音想象信号转换为图像后放入计算机视觉中的 DensNet 分类模型中进行分类,准确率达到 90.68%。这证明了 GAF 用于脑电信号分类的可行性,但是他们单独使用 CNN 模型往往提取的是局部特征,会忽略每个图像之间的时间相关性,进而降低准确率。

综上所述,GAF 方法弥补了基于时频分布的二维图像表示中重要信息丢失问题,能够为运动想象特征的识别提供更多的非线性及时间方面的信息,而这些特征以图像的形式展示出来,便于深度模型进行处理。因此,本文考虑脑电信号的非线性,使用 GAF 理论中的格拉姆角和场(Gramian Angular Summation Field, GASF)和格拉姆角差场(Gramian Angular Difference Field, GADF)将 BCI Competition IV2a 数据集中每个被试的运动想象信号表示为二维图像;然后,设计针对性的 CNN 模型来进行特征提取;最后,使用 LSTM 充分考虑每个图像之间的时间相关性,完成对二维图像表示的运动想象特征的分类识别。实验结果表明,本文方法优于其他运动想象脑电信号识别方法。

1 实验数据及预处理

1.1 数据集简介

本文实验采用了 BCI Competition IV 2a 数据集^[23]以及首都医科大学宣武医院提供的脑卒中患者运动想象数据集^[24],用于进行运动想象任务的识别。

BCI Competition IV 2a 数据集包含 9 名被试,脑电数据包括了 22 个脑电通道和 3 个眼电通道,采样率为 250 Hz,实验范式如图 1 所示。在该实验过程中,被试需要进行 4 种运动想象任务,即分别想象左手、右手、舌头、双脚的运动,每名受试者在不同的时间点记录 2 组实验数据,每组总共包括 6 个试次,每次测试包含 48 个试次(即:4 类动作,每类动作随机进行 12 次,共 $4 \times 12 = 48$),则每组实验数据共包含 288 ($6 \times 48 = 288$) 个试次。由于其中一组实验没有标签,因此只采用有标签的一组。




图 1 BCI competition IV 2a 实验范式

首都医科大学宣武医院提供的脑卒中患者运动

想象数据集包含 50 名患有急性脑卒中的被试,脑电数据集包含 29 个电极通道、2 个眼电通道以及 1 个参考电极,采样率为 500 Hz。该实验中被试需要分别想象左手和右手抓握球形物体,每次测试包含 40 个试次。

1.2 数据预处理与环境配置

针对上述公开数据集的预处理同其他脑电信号处理流程类似,在尽可能保留原始信息的前提下,为了获取高质量的数据,前期对数据进行了去除眼电和其他伪迹的处理,之后使用四阶零相位 Butterworth 带通滤波器来获得和感知运动节律最相关的 EEG 频段,主要包括 alpha 波(8~12 Hz)和 beta 波(13~30 Hz)。文中对脑电数据的预处理用基于 EEGLAB 和 Python 的工具包完成,CNN-LSTM 模型用基于 Tensorflow 的框架搭建。使用 GASF 方法和 GADF 方法生成的二维图像分别按 8:1:1 的比例划分为训练集、验证集和测试集。所有网络模型训练和测试均在配备 Nvidia 4 090 GPU 的服务器上完成。

2 研究方法

2.1 分类模型整体框架

本文提出的基于格拉姆角和场和 CNN-LSTM 的运动想象分类模型技术路线如图 2 所示。首先,将经过预处理后的一维运动想象脑电信号使用 GAF 理论中的 GASF 和 GADF 算法编码为二维图像特征;然后,使用 CNN 模型进行特征提取;最后利用 LSTM 对 CNN 提取到的特征进行时序建模,并通过全连接层和输出层完成分类识别。

2.2 格拉姆角场算法

格拉姆角场(GAF)是一种能将一维时间序列表示为二维图像的方法,可以保证原始时序信号的时间依赖,并且可以更全面地了解脑电信号在不同时段上的变化。格拉姆角场方法具体过程如下。

1) 标准化

将给定的时间序列 $X = \{x_1, x_2, \dots, x_n\}$ 的 n 个实际观测值重新缩放到 $[-1, 1]$ 。

$$\tilde{X}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (1)$$

式中, \tilde{X}_i 表示整合到区间 $[-1, 1]$ 的结果; x_i 为 X 的第 i 个采样数据点, $1 \leq i \leq n$; $\max(X)$ 和 $\min(X)$ 表示数据集中的最大值和最小值。

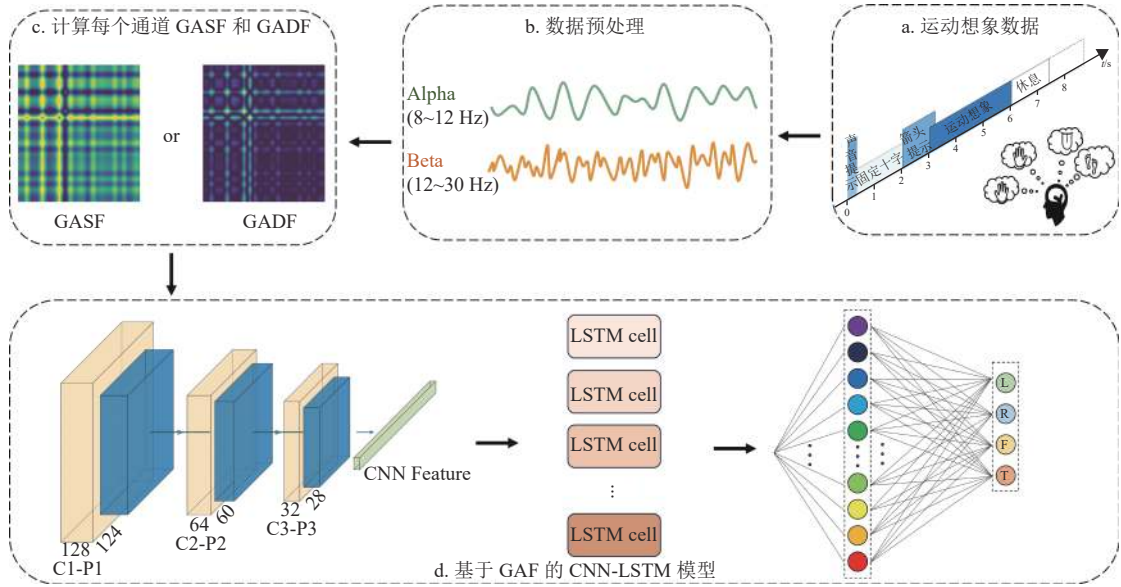


图 2 技术路线图

2) 时间序列重编码

使用式 (2) 将整合后的时间序列 \tilde{x}_i 在坐标系中重新进行编码定位, 映射到极坐标系中。

$$\begin{cases} \phi = \arccos(\tilde{X}_i) & -1 \leq \tilde{X}_i \leq 1 \\ r = \frac{t_i}{N} & t_i \in \mathbb{N} \end{cases} \quad (2)$$

式中, ϕ 为编码后的角度; r 为定位点至极坐标原点的距离; t_i 是 x_i 对应的的时间戳; N 表示时间序列总长度。式 (2) 使得生成的图像能够确保较好的时间相关性且包含丰富的特征。

3) 二维图像表示

根据步骤 2) 生成极坐标图后, 使用不同定位点之间的角度和值和角度差值生成 GASF 和 GADF 来表示不同时间间隔内的时间相关性。

$$\mathbf{GASF}_{(i,j)} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cos(\phi_1 + \phi_2) & \cdots & \cos(\phi_1 + \phi_j) \\ \cos(\phi_2 + \phi_1) & \cos(\phi_2 + \phi_2) & \cdots & \cos(\phi_2 + \phi_j) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\phi_i + \phi_1) & \cos(\phi_i + \phi_2) & \cdots & \cos(\phi_i + \phi_j) \end{bmatrix} \quad (3)$$

$$\mathbf{GADF}_{(i,j)} = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \sin(\phi_1 - \phi_2) & \cdots & \sin(\phi_1 - \phi_j) \\ \sin(\phi_2 - \phi_1) & \sin(\phi_2 - \phi_2) & \cdots & \sin(\phi_2 - \phi_j) \\ \vdots & \vdots & \ddots & \vdots \\ \sin(\phi_i - \phi_1) & \sin(\phi_i - \phi_2) & \cdots & \sin(\phi_i - \phi_j) \end{bmatrix} \quad (4)$$

式中, $\mathbf{GASF}_{(i,j)}$ 和 $\mathbf{GADF}_{(i,j)}$ 分别表示格拉姆角和场与格拉姆角差场; ϕ_i 表示步骤 2) 处理后得到的

角度。

通过上述 3 个步骤即可将预处理后的 BCI competition IV 2a 数据集 22 个脑电通道的一维 EEG 时间序列表示为二维图像。图像中的像素点表示的是各数据点之间的相关性。以一段预处理后 8~12 Hz 的 C3 通道脑电信号为例, 如图 3 所示。该段信号中存在几个较为明显的波峰, 当波峰出现时, GADF 和 GASF 算法生成的二维特征图中出现颜色较浅的交叉特征 (图 3 橙色标注部分); 而出现较大的波峰时, 二维特征图中呈现出较为明显的交叉特征 (图 3 红色标注部分)。因此, GAF 算法可以将脑电信号的变化完整地映射到二维图像中。

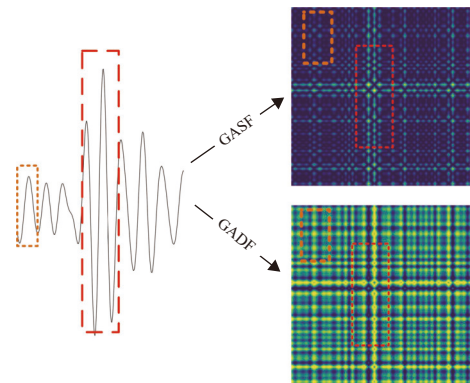


图 3 GAF 映射说明

2.3 CNN-LSTM 模型设计

使用 GASF 和 GADF 将一维 EEG 运动想象信号表示为二维图像后, 很多用于图像分类的模型也可以用于运动想象脑电信号解码过程中, 如计算

机视觉领域用于图像分类的几个经典模型: ResNet、VGG 和 GoogLeNet 等。但是这些模型通常都需要大规模的数据集进行训练, 而脑电数据集通常都较小, 即使使用 GASF 和 GADF 方法表示成二维图像, 得到的图像数量也达不到好的训练效果。因此, 本文设计了一个浅层的 CNN-LSTM 模型, 模型框架图如图 2d 所示。本研究设计的 CNN 模型由三层卷积层、三层池化层和一层全连接层组成, LSTM 由模型由 64 个 LSTM cell 和全连接层组成。其中加入 L2 正则化和批量归一化 (Batch Normalization) 来减少过拟合。为了验证本文提出的框架是否能够充分提取深层特征, 设计不同框架的 CNN 模型进行实验验证, 实现细节如表 1 所示。随着卷积层和池化层层数的增加, 分类准确

率也随之提升, 但达到三层卷积层和三层池化层之后, 分类准确率达到最高且不再增加, 如图 4 所示。结合训练集和测试集的分类准确率与损失, 本文实验中选择三层卷积层、三层池化层和 LSTM 结构能够充分提取脑电信号二维图像特征。

表 1 不同框架实现细节

框架	卷积层数	池化层数	滤波器数
C-P-Fc	1	1	128
(C-P) \times 2-Fc	2	2	128/64
(C-P) \times 3-Fc	3	3	128/64/32
(C-P) \times 4-Fc	4	4	256/128/64/32
(C-P) \times 5-Fc	5	5	512/256/128/64/32

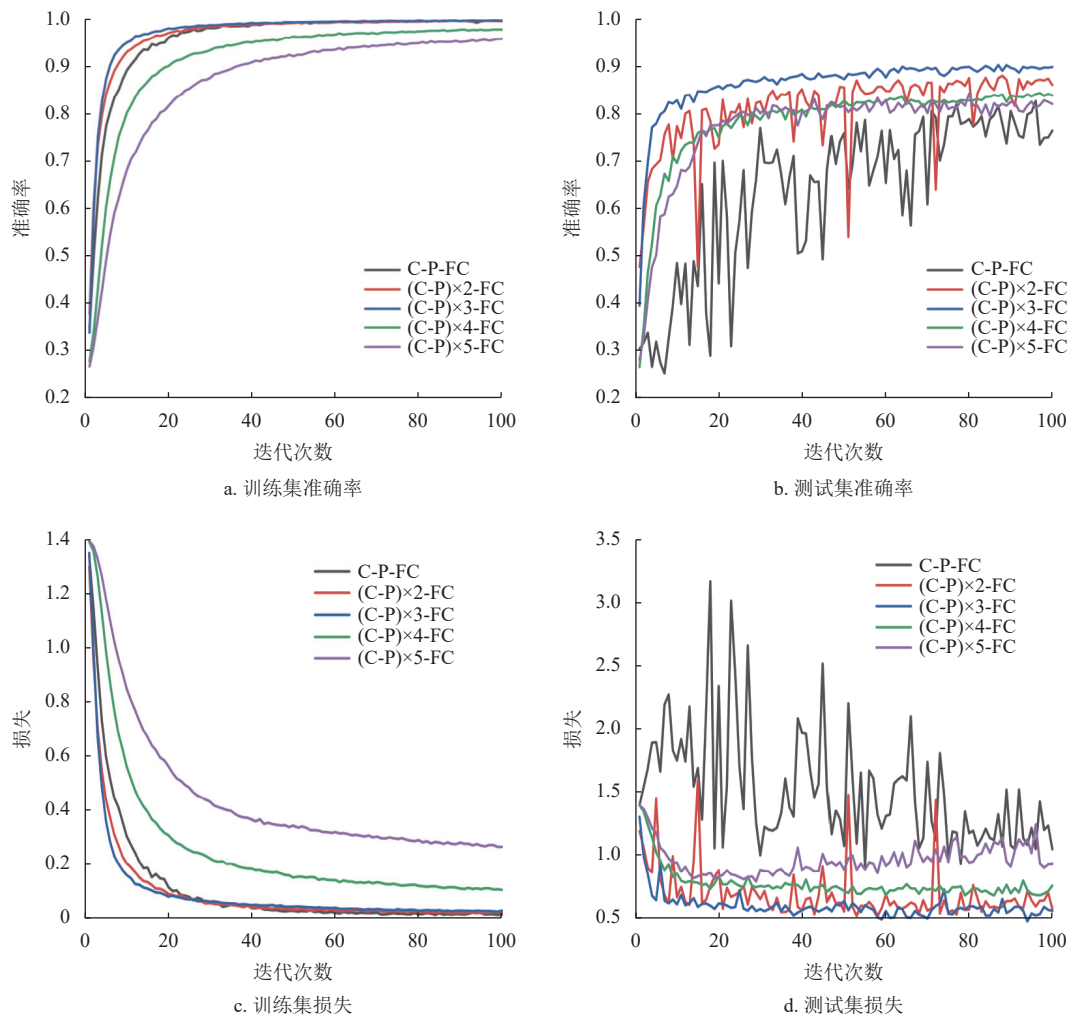


图 4 不同框架训练集/测试集准确率与损失

3 结果分析及讨论

3.1 基于 GAF 的二维图像特征分析

为了检验 GAF 方法将一维脑电信号表示为二

维图像的特征质量, 验证其是否能用于运动想象任务分类, 随机选择 BCI Competition IV 2a 数据中被试 5 的四分类运动想象脑电信号 (A05.gdf) 进

行分析。首先, 预处理脑电信号; 然后, 提取 22 个脑电通道内的数据, 使用 GASF 和 GADF 算法将其转换为二维图像, 以便观察随时间变化的特征。

如图 5 所示, 在进行不同运动想象任务时, 使用 GASF 和 GADF 生成的不同运动想象任务图像, 以及相同运动想象任务的不同通道之间 (这里仅展示 C3、Cz 和 C4 通道) 的图像都有着很明显的颜色、纹理等差异。那么, 可以使用计算机视觉领域的图像分类方法进行不同运动想象任务分类, 使用 CNN 从图像中提取更多的高级特征。由于深度学习技术在计算机视觉和图像分类领域的方法已经非常成熟, 将脑电信号表示为图像, 能够从图像中高效地提取更多特征, 更容易区别不同运动想象分类任务, 从而提高分类性能。




图 5 不同通道 GADF 和 GASF 二维图像

3.2 单被试与多被试分析

为了验证本文算法的模型性能, 对 BCI Competition IV 2a 中 9 名被试进行单被试分析和多被试分析。各个被试以及多个被试的 GASF-CNN-LSTM 和 GADF-CNN-LSTM 的准确率和 Kappa 系数数值如表 2 所示。

表 2 单被试与多被试的 Acc 和 Kappa %

被试	GASF-CNN-LSTM	GADF-CNN-LSTM
	ACC(Kappa)	ACC(Kappa)
S1	96.65 (95.53)	96.91 (95.88)
S2	98.85 (98.47)	97.52 (96.69)
S3	98.39 (97.86)	99.09 (98.79)
S4	95.78 (94.38)	98.19 (97.59)
S5	91.39 (88.50)	97.31 (96.16)
S6	93.59 (91.46)	96.46 (95.27)
S7	97.21 (96.27)	93.09 (90.77)
S8	89.97 (86.61)	96.91 (95.88)
S9	88.88 (85.17)	94.30 (92.40)
S1+S2+...+S9	87.66 (83.55)	89.53 (86.03)

结果显示, 单被试情况下, GADF-CNN-LSTM 方

法最高准确率达到 99.09%, 最低准确率为 93.09%, 平均准确率为 96.64%。GASF-CNN-LSTM 方法最高准确率达到 98.39%, 最低准确率为 88.88%, 平均准确率为 94.52%。多被试情况下 GASF-CNN-LSTM 方法达到了 87.66%, GADF-CNN-LSTM 方法达到了 89.53%。如图 6 所示为多被试情况下 GADF-CNN-LSTM 和 GASF-CNN-LSTM 的分类结果对应的混淆矩阵, 能更加直观地说明本文模型的性能。

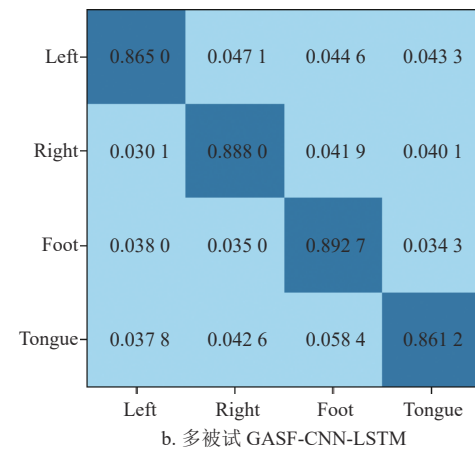
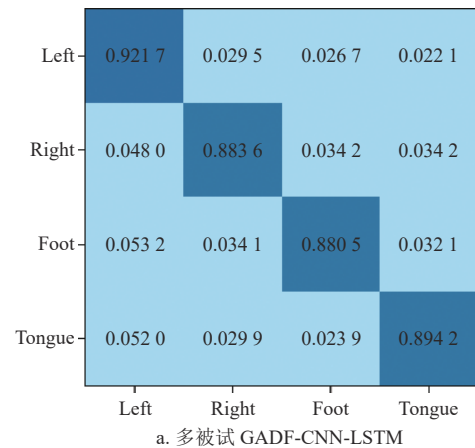


图 6 多被试两种方法的混淆矩阵

实验结果表明, GASF-CNN-LSTM 方法准确率普遍比 GADF-CNN-LSTM 低。原因如 2.2 小节中所示 GADF 是使用两个角度的差来表示像素点的颜色值, GASF 是使用两个角度的和来表示像素点的颜色值。由于颜色映射的不同, GADF 方法生成的图像相较于 GASF 方法生成的图像颜色更丰富, 且包含更多的细节, 如图 5 所示。

3.3 通道数对分类性能的影响分析

为了进一步验证模型的鲁棒性, 随机选择两个被试 S5 和 S9 对如图 7 所示的 3 个脑电通道 (C3、

C4、Cz)、13 个脑电通道 (C3、C4、Cz 相邻的所有通道) 以及 22 个脑电通道进行对比实验, 实验结果如表 3 所示。

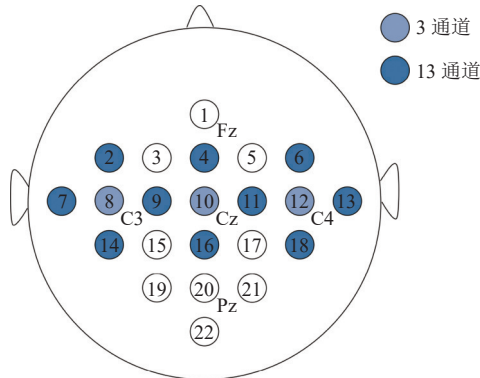


图 7 不同通道的选择

表 3 不同通道数下 GADF-CNN-LSTM 方法准确率 %

方法	S5		S9	
	ACC(Kappa)		ACC(Kappa)	
GADF-CNN-LSTM(22channels)	97.31 (96.16)		94.30 (92.40)	
GASF-CNN-LSTM(22channels)	91.39 (88.50)		88.88 (85.17)	
GADF-CNN-LSTM(13channels)	98.11 (97.48)		87.98 (83.93)	
GASF-CNN-LSTM(13channels)	97.68 (96.91)		89.10 (85.47)	
GADF-CNN-LSTM(3channels)	63.21 (60.32)		60.39 (56.95)	
GASF-CNN-LSTM(3channels)	55.36 (40.11)		53.85 (41.01)	

结果显示, 在 22 通道和 13 通道的情况下, S5 和 S9 被试准确率变化不大, 但是在 3 通道的情况下准确率大幅度下降, 原因是将一维时间序列转换为图像后使用深度学习进行图像分类, 而深度学习进行图像分类往往需要大规模的数据集。在 3 通道时生成的图片数量远小于 13 通道和 22 通道的图片数量, 尽管本文设计的是一个浅层的 CNN-LSTM 模型, 但在 3 通道时生成图片仍然无法满足模型训练需求。基于全脑 22 个脑电通道的识别效果远高于只选择运动感知脑区少数电极数据的结果, 这也给我们关于运动想象的研究提供了一个新思路, 研究不应该只局限在运动感知脑区, 运动的感知、动作的执行需要全脑各个脑区的配合协同, 特别是基于深度学习模型的运动想象分类过程中, 更应该充分考虑全脑区信号的特征。

3.4 针对急性脑卒中患者运动想象分析

目前, 大多数运动想象脑机接口的研究都侧重于健康受试者, 而对于运动障碍患者的研究相对较

少。运动想象技术主要应用于治疗运动功能障碍患者。因此, 为了进一步验证模型的泛化性, 并评估运动想象技术在不同人群中的适用性和效果。本文对急性脑卒中患者进行了运动想象任务的实验分析。选取前五名被试进行分析, 实验结果如图 8 所示。最高准确率可达 82.31%, 而 GADF-CNN-LSTM 和 GASF-CNN-LSTM 的平均准确率分别达到了 78.15% 和 76.91%, 相比运动想象脑电的识别效果, 在真实患者身上的解码性能会差一些, 但识别率达到了 76% 以上, 表明本文设计的模型在解码运动功能患者的脑电信号方面表现出良好的效果。




图 8 急性脑卒中患者准确率

3.5 不同分类模型对比分析

为了进一步验证本文提出的模型性能, 与几种运动想象分类算法进行对比, 这几种算法包括: QTFD-DenseNet^[18]、小波变化时频图+CNN^[19]、MMCNN^[14]、HS-CNN^[15]、DA-end-to-end-CNN^[16], 如表 4 所示。这些研究工作均使用了 BCI Competition IV 2a 公开数据集。为了更加清晰地表示本文方法对四分类任务的分类性能, 分别绘制了多被试的 GADF-CNN-LSTM 和 GASF-CNN-LSTM 方法的混淆矩阵, 如图 6 所示。结果表明, 本方法的分类性能优于其他方法且达到了 88.88%~99.09% 的准确率, 证明了使用 GAF 将运动想象任务信号表示为二维图像有利于脑电信号解码。原因有 3 点。1) 对于大脑这个复杂/动态系统可以更容易获得 GAF 图像, 并且 GAF 图像中包含有关时间尺度的重要信息, 保留脑电信号的非线性特征。2) 深度学习在计算机视觉领域大放异彩, 将脑电信号表示为图像后, 使用图像分类的方法使得脑电信号分类变得更加简单, 从而降低脑电信号分类的复杂度。3) 浅层的 CNN-LSTM 模型更适合于 MI-EEG 小规模数据集的分类。

表4 不同算法分类的准确率

%

被试	QTFD-DenseNet	小波变换时频图+CNN	MMCNN	HS-CNN	DA-end-to-end-CNN	GADF-CNN-LSTM	GASF-CNN-LSTM
S1	78.85	85.71	82.1	90.07	95.38	96.91	96.65
S2	66.73	78.57	59.8	80.28	91.25	97.52	98.85
S3	82.14	92.15	92.8	97.08	91.25	99.09	98.39
S4	64.91	95.67	69.0	89.66	96.12	98.19	95.78
S5	60.88	89.20	87.3	97.04	95.05	97.31	91.39
S6	43.24	85.12	68.5	87.04	94.62	96.46	93.59
S7	87.25	79.23	89.2	92.14	91.22	93.09	97.21
S8	83.64	81.28	91.4	98.51	90.54	96.91	89.97
S9	83.93	80.67	92.6	92.31	97.50	94.30	88.88
Avg	72.40	85.29	81.41	91.57	93.66	96.64	94.52

4 结束语

使用 CNN-LSTM 提取 GASF 和 GADF 图像的纹理特征和更深层次的抽象特征进行运动想象脑电信号分类识别, 单被试下分类准确率均在 88.88% 以上, 最高准确率可达 99.09%, 多被试下准确率也达到了 87.66% 和 89.53%, 相较于其他算法有明显的优势。针对全脑区 22 个电极和运动感知区中少数电极的对比分析表明, 运动的感知、运动的执行需要全脑各个脑区的协同来完成, 不应该只局限于运动感知脑区。特别是基于深度学习模型的运动想象分类过程中, 更应该充分考虑全脑区信号的特征。针对急性脑卒中患者的脑电信号解码, 本文模型也表现出良好性能, 这对运动功能障碍患者的康复和治疗具有重大的意义。研究结果不仅证明了 GAF 算法和 CNN-LSTM 模型结合对运动想象特征识别的有效性, 也扩展了运动想象特征分析方法, 为脑电信号特征表示和识别提供了新思路, 对基于脑电信号的分类任务研究也具有一定的参考价值。

参考文献

- [1] GAO X R, WANG Y J, CHEN X G, et al. Interface, interaction, and intelligence in generalized brain-computer interfaces[J]. *Trends in Cognitive Sciences*, 2021, 25(8): 671-684.
- [2] LOTTE F, CONGEDO M, LÉCUYER A, et al. A review of classification algorithms for EEG-based brain-computer interfaces[J]. *Journal of Neural Engineering*, 2007, 4(2): R1-R13.
- [3] NEUPER C, WÖRTZ M, PFURTSCHELLER G. ERD/ERS patterns reflecting sensorimotor activation and deactivation[J]. *Progress in Brain Research*, 2006, 159: 211-222.
- [4] PFURTSCHELLER G. Functional brain imaging based on ERD/ERS[J]. *Vision Research*, 2001, 41(10/11): 1257-1260.
- [5] TANG Z C, YU H N, LU C F, et al. Single-trial classification of different movements on one arm based on ERD/ERS and corticomuscular coherence[J]. *IEEE Access*, 2019, 7: 128185-128197.
- [6] 陈小刚, 杨晨, 陈菁菁, 等. 脑机接口技术发展新趋势: 基于 2019—2020 年研究进展[J]. *科技导报*, 2021, 39(19): 56-65.
CHEN X G, YANG C, CHEN J J, et al. Hot topics review of brain-computer interface in 2019-2020[J]. *Science & Technology Review*, 2021, 39(19): 56-65.
- [7] PADFIELD N, ZABALZA J, ZHAO H M, et al. EEG-based brain-computer interfaces using motor-imagery: Techniques and challenges[J]. *Sensors*, 2019, 19(6): 1423.
- [8] WANG Y J, GAO S K, GAO X R. Common spatial pattern method for channel selection in motor imagery based brain-computer interface[C]//*Proceedings of the IEEE Engineering in Medicine and Biology 27th Annual Conference*. New York: IEEE, 2006: 5392-5395.
- [9] KUMAR S, SHARMA A, TSUNODA T. Subject-specific-frequency-band for motor imagery EEG signal recognition based on common spatial spectral pattern[C]//*Pacific Rim International Conference on Artificial Intelligence*. Cham: Springer, 2019: 712-722.
- [10] ANG K K, CHIN Z Y, ZHANG H H, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface[C]//*Proceedings of the IEEE International Joint Conference on Neural Networks*. New York: IEEE, 2008: 2390-2397.
- [11] SCHIRRMMEISTER R T, SPRINGENBERG J T, FIEDERER L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization[J]. *Human Brain Mapping*, 2017, 38(11): 5391-5420.
- [12] 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): 056013.
- [13] LI H L, DING M, ZHANG R H, et al. Motor imagery EEG classification algorithm based on CNN-LSTM

- feature fusion network[J]. *Biomedical Signal Processing and Control*, 2022, 72: 103342.
- [14] JIA Z Y, LIN Y F, WANG J, et al. MMCNN: A multi-branch multi-scale convolutional neural network for motor imagery classification[C]//Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer, 2021: 736-751.
- [15] DAI G H, ZHOU J, HUANG J H, et al. HS-CNN: A CNN with hybrid convolution scale for EEG motor imagery classification[J]. *Journal of Neural Engineering*, 2020, 17(1): 016025.
- [16] LASHGARI E, OTT J, CONNELLY A, et al. An end-to-end CNN with attentional mechanism applied to raw EEG in a BCI classification task[J]. *Journal of Neural Engineering*, 2021, 18(4): 0460e3.
- [17] TAWHID M N A, SIULY S, WANG H, et al. A spectrogram image based intelligent technique for automatic detection of autism spectrum disorder from EEG[J]. *PLoS One*, 2021, 16(6): e0253094.
- [18] 金晶, 杨益雕, 孙浩, 等. QTFD 与 DenseNet 相结合的运动想象分类方法[J]. *信号处理*, 2023, 39(8): 1443-1454.
JIN J, YANG Y D, SUN H, et al. QTFD and DenseNet based motor imagery classification method[J]. *Journal of Signal Processing*, 2023, 39(8): 1443-1454.
- [19] XU B G, ZHANG L L, SONG A G, et al. Wavelet transform time-frequency image and convolutional network-based motor imagery EEG classification[J]. *IEEE Access*, 2019, 7: 6084-6093.
- [20] WANG Z G, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks[C]//Workshops at the Twenty-ninth AAAI Conference on Artificial Intelligence. [S.l.]: AAAI, 2015: 40-46.
- [21] KO D W, YANG J J. EEG-based schizophrenia diagnosis through time series image conversion and deep learning[J]. *Electronics*, 2022, 11(14): 2265.
- [22] ISLAM M M, SHUVO M M H. DenseNet based speech imagery EEG signal classification using gramian angular field[C]//Proceedings of the 5th International Conference on Advances in Electrical Engineering. New York: IEEE, 2019: 149-154.
- [23] TANGERMANN M, MÜLLER K R, AERTSEN A, et al. Review of the BCI competition IV[J]. *Frontiers in Neuroscience*, 2012, 6: 55.
- [24] LIU H J, WEI P H, WANG H C, et al. An EEG motor imagery dataset for brain computer interface in acute stroke patients[J]. *Scientific Data*, 2024, 11(1): 131.

编辑 税红