

DOI:10.19651/j.cnki.emt.2212520

# 基于离散小波变换的卷积自编码 运动想象脑电信号的分类<sup>\*</sup>

郭玉雪<sup>1,2</sup> 于洪丽<sup>1,2</sup> 么航<sup>1,2</sup> 杜博爱<sup>1,2</sup> 王春方<sup>3</sup>(1. 河北工业大学生命科学与健康工程学院 天津 300130; 2. 河北工业大学河北省生物电磁与  
神经工程重点实验室 天津 300130; 3. 天津市人民医院康复医学科 天津 300121)

**摘要:** 左右手运动想象脑电信号(MI-EEG)分类准确率低,制约了相关脑-机接口技术的发展。实验采集了16名健康受者的运动想象脑电信号,提出了一种基于离散小波变换(DWT)和卷积自编码(CAE)的运动想象脑电信号分类算法。利用离散小波变换将EEG转换成时频矩阵,输入到卷积自编码网络中进行脑电信号的特征分类。该算法在实验数据集和公开数据集上测试都得到了较好的分类结果,静息-想象左手、静息-想象右手、想象左手-想象右手3组EEG在实验数据集上分类准确率分别为97.36%、97.27%、86.82%,在公开数据集上分类准确率分别为99.30%、98.23%、92.67%。离散小波变换结合卷积自编码网络模型在左右手运动想象脑电信号分类应用中比其他深度学习方法(CNN、LSTM、STFT-CNN)性能更优。

**关键词:** 运动想象;离散小波变换;卷积自编码;深度学习

中图分类号: R339.4; R496 文献标识码: A 国家标准学科分类代码: 510.4030

## Classification of convolutional autoencoder motor imagery EEG signals based on discrete wavelet transform

Guo Yuxue<sup>1,2</sup> Yu Hongli<sup>1,2</sup> Yao Hang<sup>1,2</sup> Du Bo'ai<sup>1,2</sup> Wang Chunfang<sup>3</sup>(1. School of Health Sciences and Biomedical Engineering, Hebei University of Technology, Tianjin 300130, China;  
2. Hebei Key Laboratory of Bioelectromagnetics and Neural Engineering, Hebei University of Technology, Tianjin 300130, China;  
3. Rehabilitation Medical Department, Tianjin Union Medical Center, Tianjin 300121, China)

**Abstract:** The low classification accuracy of motor imagery EEG signals (MI-EEG) of the left and right hands limits the development of related brain-computer interface technology. The motor imagery EEG signals of 16 healthy subjects were collected experimentally. A discrete wavelet transform (DWT) and convolutional autoencoder (CAE) based classification algorithm for motor imagery EEG signals were proposed. The EEG signal is converted into a time-frequency matrix using a discrete wavelet transform and input to a convolutional autoencoder network for the feature classification of EEG signals. The algorithm obtained better classification results when tested on both the experimental dataset and the public dataset. The accuracy of the three classification groups of rest-imagine left hand, rest-imagine right hand, and imagine left hand-imagine right hand was 97.36%, 97.27%, and 86.82% on the experimental dataset, and 99.30%, 98.23%, and 92.67% on the public dataset. The discrete wavelet transform combined with the convolutional autoencoder network model outperforms other deep learning methods (CNN, LSTM, STFT-CNN) in classification applications of motor imagery EEG signals of left and right hand.

**Keywords:** motor imagery;discrete wavelet transform;convolutional autoencoder;deep learning

## 0 引言

脑-机接口(brain computer interface, BCI)是一种利用

大脑与外部设备的联系进行信息交流的技术<sup>[1]</sup>。运动想象(motor imagery, MI)是指大脑产生肢体动作意图而不执行,常见的有左手、右手、双脚和舌头等多种MI任务<sup>[2-3]</sup>。

收稿日期:2022-12-30

\*基金项目:国家自然科学基金(51877068,82102652)项目资助

近年来,基于运动想象的脑-机接口(MI-BCI)技术相关研究逐渐增多,脑电信号(electroencephalogram, EEG)分类作为其关键步骤,分类准确率不高制约了该技术的进一步应用推广。目前,静息态 EEG 与想象左手 EEG、静息态 EEG 与想象右手 EEG 的分类准确率已经取得很好的分类效果,但想象左手和想象右手的 EEG 分类准确率还有待提高<sup>[4-5]</sup>。因此,构建鲁棒性好的 EEG 分类模型,提高左右手运动想象脑电信号(MI-EEG)的分类准确率已成为当前研究的主要内容。

MI-EEG 处理主要包括原始数据的特征提取、分类等<sup>[6]</sup>。在特征提取的方法上,主要有基于时域、频域、时频域的分析方法<sup>[7-8]</sup>;傅里叶变换、功率谱密度等属于基于频域的分析方法<sup>[9-10]</sup>;小波变换、希尔伯特黄变换等属于基于时频域的分析方法<sup>[11-12]</sup>。在 MI 实验中,提取的 EEG 是一种非平稳的变量,因此仅从时域或频域的特征分析信号往往不能揭示信号中包含的全部信息,而时频分析可以有效地提取信号在时域的相关特征,同时反映出频域的信息。

随着对分类技术的不断深入研究,学者提出了许多基于深度学习的 EEG 分类算法,其中卷积自编码器(convolutional autoencoder, CAE)网络应用广泛<sup>[13]</sup>。2011 年,Masci 等<sup>[14]</sup>首次提出 CAE,将原本自编码的内部结构用卷积的方法进行替代,在手写数据集 MNIST 和图像数据集 CIFAR10 得到了很好的分类结果。Daoud 等<sup>[15]</sup>利用 CAE 进行癫痫病灶定位,减小特征的维度并从 EEG 中提取判别性时空特征,平均准确率为 93.2%。An 等<sup>[16]</sup>提出了一种基于三维特征融合的 CAE 情绪识别算法,通过对多层感知机、卷积神经网络(convolutional neural network, CNN)和所提出的 CAE 比较,发现构造的 CAE 在情感识别方面具有较好的性能。随着对 CAE 的进一步研究,越来越多的学者将 CAE 应用于 MI-EEG 分类,左右手 MI-EEG 的分类精度得到了明显的提升。2021 年,Mirzaei 等<sup>[17]</sup>使用自适应稀疏表示计算 MI 各个 EEG 通道的连接矩阵,将 CAE 应用于构建的三维张量,与现有方法相比,所提出的方法具有良好的分类性能。CAE 不仅保留了自动编码器可以重构与原始数据相似输出的性能,还引入了卷积运算提取隐藏在信号中的空间信息的特性。

基于以上分析,本文提出了一种基于离散小波变换(discrete wavelet transform, DWT)的 CAE 网络架构。采用时频分析 EEG 的方法,将多通道数据融合成多维特征作为 CAE 的输入。所提方法和其他深度学习方法,如 CNN、长短时记忆网络(long short term memory, LSTM)、基于短时傅里叶变换(short-time fourier transform, STFT)的 CNN 网络,在实验数据集和公开数据集上分别进行了测试,以验证本文所提方法的有效性。

## 1 实验与数据预处理

### 1.1 运动想象实验设计

实验共招募了 16 名健康右利手受试者,所有受试者年龄在 20~25 岁之间,没有精神病史。该实验方案通过了河北工业大学生物医学伦理委员会的审核。

实验使用 Neuroscan EEG/ERP 系统记录 62 个头皮位置的 EEG 通道,这些位置按照国际 10~20 通道分布放置。本研究采用 Ag/AgCl 电极,电极用导电膏填充并贴在头部皮肤上。实验过程中要求电极阻抗小于 10 kΩ,参考电极和接地电极按照 Neuroscan4.3 用户手册放置。采样率为 1 000 Hz,放大倍数为 500。

实验过程中,受试者保持放松且无剧烈肢体运动。EEG 的采集是在一个光线弱、安静、无电磁干扰的房间中完成。受试者安静地坐在离屏幕 50 cm 的地方,将刺激物质(500 mL 饮料)放在正前方位置<sup>[18]</sup>。被试全程处于睁眼状态,在想象任务中,受试者必须不断想象用左手抓握和举起。实验流程如图 1 所示。具体实验过程为:

- 1) 实验开始,采集 5 min 静息态的 EEG。
- 2) 想象任务开始,被试盯着屏幕中央的白色“+”注视点,前 2 s 处于安静状态。2 s 时,计算机发出短促“嘟”的提示声(维持 1 s)。
- 3) 提示音后被试想象左手拿起水杯任务 3 min,“嘟”声提醒结束;休息 1 min。
- 4) “嘟”(1 s)提示音后,被试想象右手拿起水杯任务 3 min,“嘟”声提醒实验结束。

在 MI 实验过程中,实时采集被试的 EEG。

### 1.2 公开数据集

为了更好地证明本文提出的网络模型的泛化能力,从 GigaScience 数据库中选择了 1 个公开的数据集。该数据集包含 52 名受试者的 MI-EEG,平均年龄  $\pm$  SD 年龄 = 24.8  $\pm$  3.86 岁<sup>[19]</sup>。52 名受试者中有两名不是右利手,本研究中只使用了 50 名右利手受试者的 MI-EEG。所有参与者都签署了书面知情同意书,该实验得到了 Gwangju 科学技术研究院机构审查委员会的批准。

该数据集的实验过程为:受试者被安排坐在一把带有扶手的椅子上,让他们根据随机的提示对应地想象左手或者右手。实验开始时,在屏幕中心显示带有“+”的黑屏,表示想象任务开始,时间持续 2 s。当黑屏向受试者发出准备就绪的信号,受试者准备开始想象手部动作,两个指令中的一个(left hand 或 right hand)随机出现在屏幕上 3 s,受试者需要根据给出的指令想象相应的手部运动,当带有“+”的黑屏再次出现时,受试者停止想象随机休息 4.1~4.8 s,整个过程重复 100 次,个别被试重复了 120 次。

### 1.3 数据预处理

本文采用实验数据集 16 名受试者和公开数据集 50 名受试者的额叶(FP1、FP2、AF3、AF4、F7、F5、F3、F1、F2、

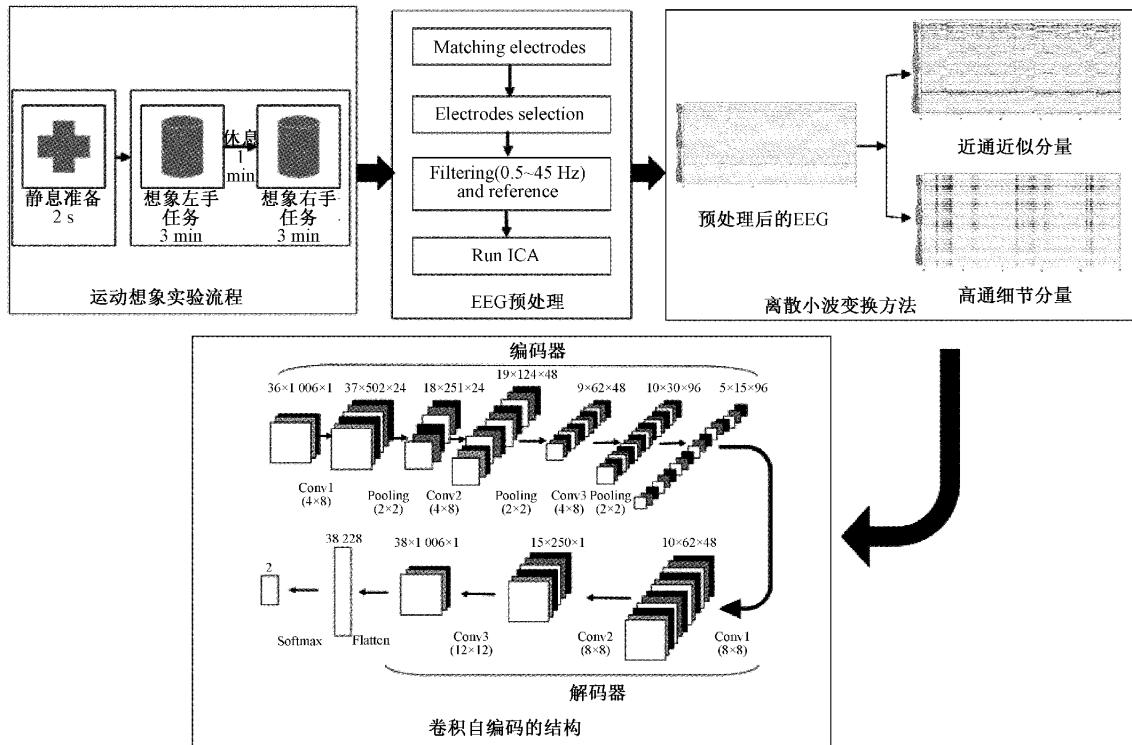


图 1 EEG 处理流程图

F4、F6、F8、FT7、FC5、FC3、FC1、FC2、FC4、FC6、FT8)、中央区(C5、C3、C1、C2、C4、C6、CP5、CP3、CP1、CP2、CP4、CP6)、颞叶(T7、TP7、T8、TP8)3个脑区共36个导联的EEG,对其进行滤波(0.5~45.0 Hz)、重参考及独立成分分析(independent component analysis,ICA)去除干扰信号和伪迹等。

## 2 深度学习框架

结合EEG的非平稳特性以及深度学习算法的良好分类性能,本文提出了基于DWT的CAE神经网络。该网络首先对预处理后的EEG进行DWT运算得到时频矩阵,然后将特征矩阵输入结合CNN和自编码的架构进行特征提取,最后将得到的特征向量送入Softmax分类层进行分类,图1展示了本文针对MI-EEG分类的处理流程。

### 2.1 离散小波变换

DWT<sup>[20]</sup>是一种新的时频分析方法,其特点是:通过时间变化突出问题在某些方面的特性,对时间(空间)频率的局部化进行分析,基本小波通过伸缩平移运算对信号(函数)进行多尺度细化,最终将信号分解成一系列的低通近似分量和高通细节分量。DWT是对短时傅里叶变换局部化思想的继承和发展,解决了Fourier变换中遇到的困难,是Fourier变换后科学研究的一大突破。

设  $f(t)$  为实验采集的离散 EEG,  $f(t)$  的 DWT 公式为:

$$C_{j,k}(f, \varphi_{j,k}) = 2^{-\frac{j}{2}} \sum_{n=-\infty}^{\infty} f(n) \bar{\varphi}(2^{-j}n - k) \quad (1)$$

$f(t)$  的离散小波逆变换公式为:

$$f(t) = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} C_{j,k} \varphi_{j,k}(t) = \sum_{j=-\infty}^{\infty} f(t) \quad (2)$$

其中,  $j$  表示频率分辨率,  $k$  表示时间平移量,  $\varphi_{j,k}(t) = 2^{-\frac{j}{2}} \bar{\varphi}(2^{-j}t - k)$  是小波序列,  $\varphi(t)$  为小波基函数,  $\bar{\varphi}$  是  $\varphi$  的共轭运算。

利用 Mallat 算法,对信号进行有限层分解,即:

$$f(t) = A_L + \sum_{j=1}^L D_j \quad (3)$$

其中,  $L$  表示分解层数,  $A_L$  表示近似分量,  $D_j$  表示不同分解层的细节分量。

本文对原始 EEG 进行 DWT 运算把 EEG 分为  $A_L$  和  $D_j$ , 然后将近似分量和细节分量融合输入到 CAE 网络中。

### 2.2 卷积自编码

卷积运算在信号处理中被广泛使用,基于卷积运算的 CNN 可以从 EEG 中直接学习特征和分类,可以达到比浅层算法更高的精度<sup>[21]</sup>。由于自编码网络具有很好的非线性处理能力,能够很好地揭示高维数据的低维化结构,因此在高维非线性数据的深层特征提取中有着广泛的应用<sup>[22]</sup>。本文提出了一种基于卷积结构和自编码网络的融合模型,对 MI-EEG 进行特征提取和分类。

该方法将原本自编码的内部结构用卷积的方法进行替代,利用卷积的局部感受野和权值共享特性保持 EEG

的空间局部性。CAE 对数据的处理过程主要由编码与解码两部分组成, 输入信息经过编码得到潜在映射, 再经过解码得到与原始数据相似的输出, 通过不断优化输出数据与原始数据的损失学习参数使得网络性能最佳。

CAE 的结构如图 1 所示, 在编码器部分, 使用一个三层卷积架构提取特征, 经过三层卷积和下采样, 将特征数量减少到一定的特征维度。在解码器部分, 使用提取的特征通过反卷积重构样本信号, 最后将重构的信号输入到 softmax 层进行分类, CAE 的结构参数如表 1 所示。

表 1 CAE 的结构参数

层	通道	尺寸	卷积核大小	步长	填充值
Input	1	$36 \times 1 006$	—	—	—
Conv1	24	$37 \times 502$	$4 \times 8$	$1 \times 2$	$2 \times 2$
Relu	24	$37 \times 502$	—	—	—
Maxpool	24	$18 \times 251$	$2 \times 2$	$2 \times 2$	0
Conv2	48	$19 \times 124$	$4 \times 8$	$1 \times 2$	$2 \times 2$
Relu	48	$19 \times 124$	—	—	—
Maxpool	48	$9 \times 62$	$2 \times 2$	$2 \times 2$	0
Conv3	96	$10 \times 30$	$4 \times 8$	$1 \times 2$	$2 \times 2$
Relu	96	$10 \times 30$	—	—	—
Maxpool	96	$5 \times 15$	$2 \times 2$	$2 \times 2$	0
Conv1	48	$10 \times 62$	$8 \times 8$	$1 \times 4$	$1 \times 1$
Relu	48	$10 \times 62$	—	—	—
Conv2	24	$15 \times 250$	$8 \times 8$	$1 \times 4$	$1 \times 1$
Relu	24	$15 \times 250$	—	—	—
Conv3	1	$38 \times 1 006$	$12 \times 12$	$1 \times 4$	$1 \times 1$
Tanh	1	$38 \times 1 006$	—	—	—
Flatten	—	38 228	—	—	—
Fully-Connected	—	1 024	—	—	—
Softmax	—	2	—	—	—

### 1) 编码器

编码系统主要包括 3 个卷积层和 3 个池化层。卷积层的作用是从不同的输入中提取特征信息, 公式如下:

$$a_s^l = f(a^{l-1} \times w_s^l + b_s^l) \quad (4)$$

式中:  $a_s^l$  表示第  $l$  个卷积层, 第  $s$  个卷积核的输出特征;  $a^{l-1}$  表示第  $l$  层的输入特征矩阵;  $w_s^l$  表示权重参数;  $b_s^l$  表示偏置量;  $f(\cdot)$  为非线性激活函数, 本文采用了 ReLU 和 Tanh 两种激活函数。池化层的作用是降低卷积层输出信息的维度, 减少参数的数量。主要有最大池化和平均池化两种方式, 在本研究中, 采用最大池化, 即选择区域中最大的特征值来代表该区域, 具体公式如下:

$$y^l = \max(x_{(i,j)}^l) \quad (5)$$

式中:  $(i, j)$  代表采样区域的大小;  $x_{(x,y)}^l$  代表采样区域内所有元素;  $\max(\cdot)$  代表选取区域内的最大元素值。3 个池化层都使用  $2 \times 2$  的等宽采样区域。

### 2) 解码器

解码器由 3 个反卷积层和激活函数组成。反卷积首先通过将特征边缘补 0 增加特征的大小, 然后通过反转卷积核实现卷积, 恢复之前的 EEG<sup>[23]</sup>。反卷积层可以捕捉特征的许多细节完成对输入数据的重建, 改善了特征扩展造成的特征信息稀疏的问题。

经过编码和解码后是 1 个 Flatten 层, Flatten 层的作用是将  $38 \times 1 006 \times 1$  的特征矩阵展平成一维特征向量, 并将其送入到分类层。

### 3) 分类层

Softmax 层是分类层, 首先将 Flatten 层的输出向量通过权重矩阵加权求和, 然后通过 Softmax 激活函数将多个输出特征映射到区间  $(0,1)$ , 确保分类概率值之和为 1。具体公式如下:

$$z_i = a^{l-1} \times w_i + b_i \quad (6)$$

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{i=1}^m e^{z_i}} \quad (7)$$

式中:  $w_i$  代表第  $i$  个输出节点的权重矩阵;  $b_i$  代表第  $i$  个输出节点的偏置量;  $a^{l-1}$  代表输入的特征向量;  $z_i$  代表权重矩阵加权求和后的输出值;  $m$  代表分类的类别数目。

## 3 结果分析

为了验证基于 DWT 的 CAE 网络的性能, 本文选用实验数据集 16 名被试和公开数据集 50 名被试的 36 个电极通道的 MI-EEG。对原始 EEG 进行预处理, 把数据分为静息态、想象左手、想象右手 3 部分做二分类, 探究深度学习网络在数据集上的性能。

实验数据集共 16 名受试者, 采集了每个受试者的 5 min MI 前静息态、3 min 的想象左手任务态、3 min 的想象右手任务态的 EEG, 为了保证数据的准确性以及用于深度学习分类的一致性, MI 前静息态、想象任务态均选取 160 s。对实验数据集受试者的 MI-EEG 进行切片, 使得每个 EEG 矩阵大小为  $36 \times 1 000$ , 整个实验数据集的 MI 前静息态、想象左手任务态、想象右手任务态样本总数均为 2 560。公开数据集有 50 名受试者, 其中 47 名受试者进行了 100 轮 MI 实验, 3 名受试者进行了 120 轮 MI 实验。该数据集中每个受试者包含了 60 s 左右的 MI 前静息态和 3 s(100 轮或者 120 轮)的 MI 任务态 EEG, 为了和实验数据集保持一致, 把公开数据集的 EEG 矩阵也切分成  $36 \times 1 000$ , 整个公开数据集的 MI 前静息态的 EEG 样本个数为 1 657, 想象左手任务态的 EEG 样本个数为 7 674, 想象右手任务态的 EEG 个数为 7 673。

针对左右手 MI-EEG 的分类问题, 本文采用了 4 个指标对模型性能进行评估, 分别是准确率(accuracy)、灵敏度(sensitivity)、精确率(precision)和 F1-score, 具体公式如下<sup>[24-25]</sup>。准确率是指所有预测中的正确个数占样本总数

的比率;灵敏度是指被预测为正样本的个数占所有实际为正样本数的比率;精确率是指所有被预测为正样本数量中,实际为正样本的个数所占的百分比;F1-score 值是精确率和灵敏度的调和平均值,4 个指标都可以从混淆矩阵中计算得到<sup>[26]</sup>。真阴性(true negative, TN)代表预测为负样本,实际也为负样本的结果数;假阴性(false negative, FN)代表预测为负样本,实际为正样本的结果数;假阳性(false positive, FP)代表预测为正样本,实际为负样本的结果数;真阳性(true positive, TP)代表预测为正样本,实际也为正样本的结果数。

$$\text{accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

$$\text{sensitivity} = \frac{TP}{TP + FN} \quad (9)$$

$$\text{precision} = \frac{TP}{TP + FP} \quad (10)$$

$$F1\text{-score} = \frac{2 \times \text{precision} \times \text{sensitivity}}{\text{precision} + \text{sensitivity}} \quad (11)$$

### 3.1 4 个评估指标结果分析

为了验证 DWT-CAE 网络模型具有的优势,本文计算了四种深度学习分类算法的准确率、灵敏度、精确率和 F1 值,结果如表 2、3 所示。数据集静息-想象左手、静息-想象右手和想象左手-想象右手 3 组二分类,默认前者是负样本,后者是正样本。从表 2、表 3 可以看出,实验数据集静息-想象左手、静息-想象右手、想象左手-想象右手 3 组的准确率分别为 97.36%、97.27%、86.82%,公开数据集静息-想象左手、静息-想象右手、想象左手-想象右手 3 组的准确率分别为 99.30%、98.23%、92.67%,DWT-CAE 的准确率、灵敏度、精确率以及 F1 值都是最高的,证明了相对于 CNN、LSTM、STFT-CNN,该算法不仅在实验数据集上的性能最好,而且在公开数据集上也得到了较好的分类效果。

表 2 本文方法与其他分类方法在实验数据上的评价指标比较结果

%

评价指标	方法	静息-想象左手	静息-想象右手	想象左手-想象右手
准确率	CNN <sup>[27]</sup>	85.06	86.91	52.34
	LSTM <sup>[28]</sup>	55.47	57.13	54.69
	STFT-CNN <sup>[29]</sup>	92.77	96.88	73.93
	DWT-CAE	<b>97.36</b>	<b>97.27</b>	<b>86.82</b>
灵敏度	CNN <sup>[27]</sup>	89.45	90.75	78.48
	LSTM <sup>[28]</sup>	57.14	58.10	57.76
	STFT-CNN <sup>[29]</sup>	99.19	99.07	78.73
	DWT-CAE	<b>99.44</b>	<b>99.24</b>	<b>90.04</b>
精确率	CNN <sup>[27]</sup>	88.62	89.74	67.35
	LSTM <sup>[28]</sup>	59.70	64.93	50.00
	STFT-CNN <sup>[29]</sup>	91.04	99.44	78.73
	DWT-CAE	<b>99.25</b>	<b>97.39</b>	<b>84.33</b>
F1 值	CNN <sup>[27]</sup>	89.03	90.24	72.49
	LSTM <sup>[28]</sup>	58.39	61.32	53.60
	STFT-CNN <sup>[29]</sup>	94.94	99.26	78.73
	DWT-CAE	<b>99.35</b>	<b>98.31</b>	<b>87.09</b>

### 3.2 混淆矩阵结果分析

为了进一步分析所提方法对 MI-EEG 的分类效果,本文计算数据集在 CNN、LSTM、STFT-CNN、DWT-CAE 四种分类方法下的混淆矩阵,如图 2、3 所示。混淆矩阵的横轴表示真实的类别标签,纵轴表示预测的类别标签,对角线表示真实标签和预测标签相同的元素即 MI 类别被正确预测的比率,而非对角线表示 MI 类别被错误预测的比率。从图 2 可以看出,LSTM 方法在静息、左手及右手 MI-EEG 的识别率均小于 65%,CNN 方法在静息、左手及右手 MI-EEG 的识别率在 80% 左右,误分率最高达到了 72.57%,CNN 和 LSTM 的网络性能较差,可能是 CNN 和 LSTM

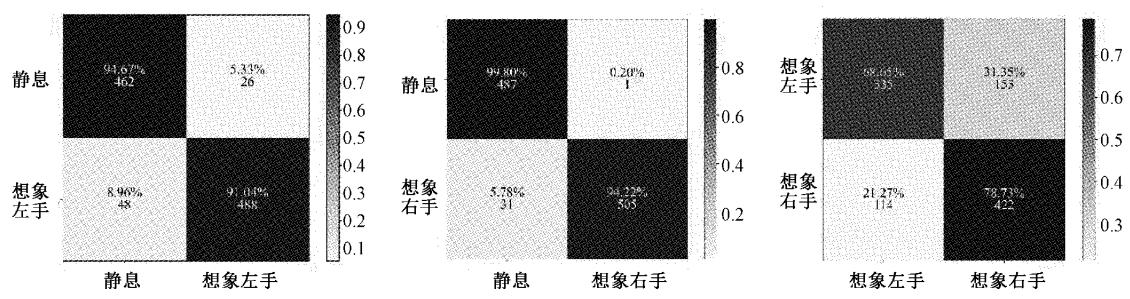
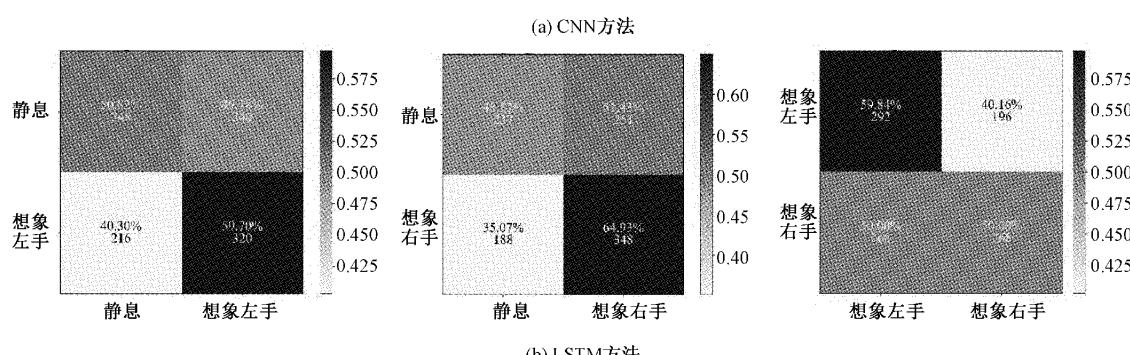
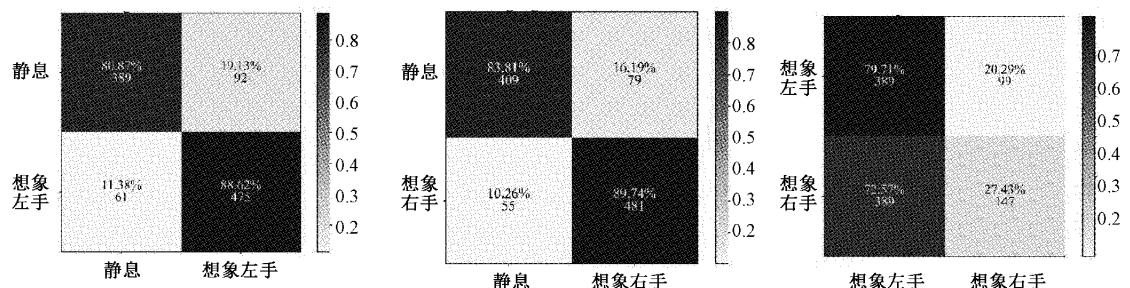
提取的空间特征可分性有限,无法进一步提高 EEG 的识别准确率。STFT-CNN 在静息、左手及右手的 MI-EEG 识别率均比 CNN 模型高,由此说明 STFT 提取的特征有利于分类。DWT 是对 STFT 的继承和改进,CAE 是对 CNN 和自编码器的融合和改善,因此 DWT-CAE 在数据集上的分类效果较好,可以进一步提取具有较高可分性的 EEG 特征,提高 MI-EEG 的识别率。

从图 3 可以看出,CNN 模型和 LSTM 模型在静息态的识别率都在 65% 以下,在想象左手任务态、想象右手任务态的识别率在 90% 左右,这是因为公开数据集的正负样本比例较大,样本量多的 EEG 识别率高,样本量少的 EEG

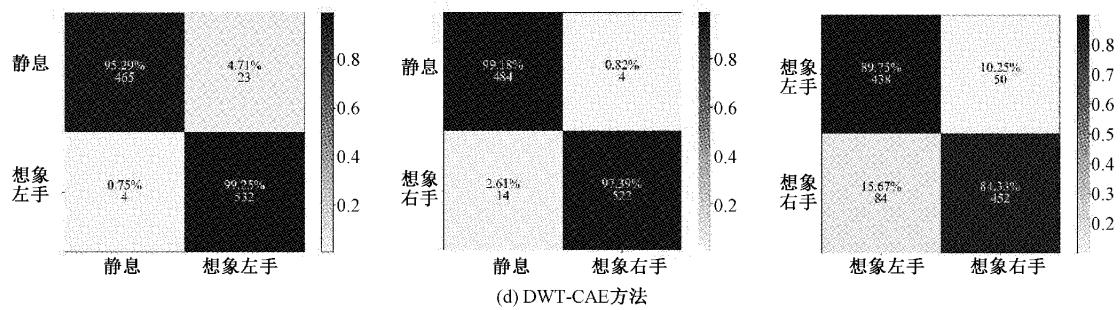
表 3 本文方法与其他分类方法在公开数据上的评价指标比较结果

%

评价指标	方法	静息-想象左手	静息-想象右手	想象左手-想象右手
准确率	CNN <sup>[27]</sup>	88.58	89.82	73.25
	LSTM <sup>[28]</sup>	89.39	89.93	64.42
	STFT-CNN <sup>[29]</sup>	94.91	99.20	77.52
	DWT-CAE	<b>99.30</b>	<b>98.23</b>	<b>92.67</b>
灵敏度	CNN <sup>[27]</sup>	93.82	97.32	74.44
	LSTM <sup>[28]</sup>	91.73	91.98	63.03
	STFT-CNN <sup>[29]</sup>	85.24	87.73	50.54
	DWT-CAE	<b>97.93</b>	<b>98.27</b>	<b>92.52</b>
精确率	CNN <sup>[27]</sup>	97.91	98.96	84.77
	LSTM <sup>[28]</sup>	96.14	95.26	72.11
	STFT-CNN <sup>[29]</sup>	99.68	97.86	98.46
	DWT-CAE	<b>98.99</b>	<b>99.74</b>	<b>93.06</b>
F1 值	CNN <sup>[27]</sup>	95.82	98.13	79.27
	LSTM <sup>[28]</sup>	93.89	93.59	67.27
	STFT-CNN <sup>[29]</sup>	91.90	92.52	66.80
	DWT-CAE	<b>98.46</b>	<b>99.00</b>	<b>92.79</b>

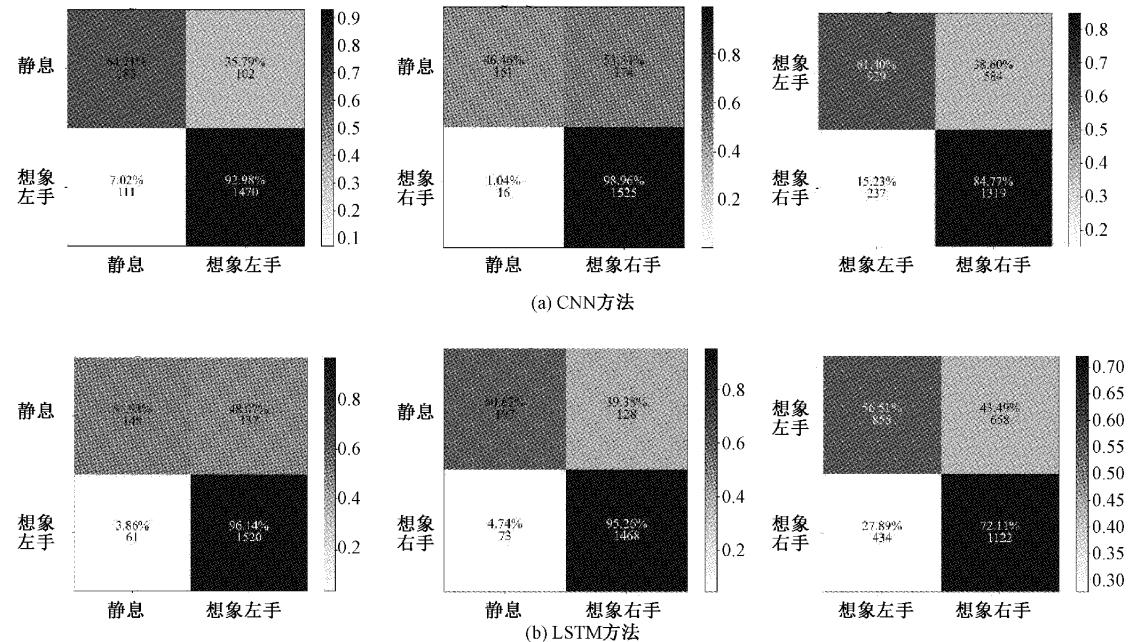


(c) STFT-CNN 方法



(d) DWT-CAE 方法

图 2 实验数据集在 CNN、LSTM、STFT-CNN、DWT-CAE 方法下的混淆矩阵



(a) CNN 方法

(b) LSTM 方法

(c) STFT-CNN 方法

(d) DWT-CAE 方法

图 3 公开数据集在 CNN、LSTM、STFT-CNN、DWT-CAE 方法下的混淆矩阵

识别率低。从图 3(d)可以看出,DWT-CAE 改善了因正负比例大准确率低的问题,静息态、想象左手、想象右手的识别率都在 90% 以上,公开数据 MI-EEG 在 DWT-CAE 模型上的准确率达到了最高。

## 4 结 论

本文通过 DWT 将 MI-EEG 转换成时频矩阵输入到 CAE 网络中进行特征提取和分类。通过实验结果分析, DWT-CAE 与目前常见的深度学习方法相比, 改善了因为正负样本比例较大分类准确率低的问题, 在实验数据和公开数据都得到了较好的分类性能。该方法在左手和右手 MI-EEG 的分类和识别中有一定的优势, 为多类别 MI-EEG 提供了有效的分类方法。

## 参考文献

- [1] TANG Z C, LI C, WU J F, et al. 面向脑-机接口基于改进的共同空间模式方法的单次运动想象脑电分类(英文)[J]. *Frontiers of Information Technology & Electronic Engineering*, 2019, 20(8): 1087-1099.
- [2] 刘拓, 叶阳阳, 王坤, 等. 运动想象脑电信号分类算法的研究进展[J]. 生物医学工程学杂志, 2021, 38(5): 995-1002.
- [3] KHARE S K, BAJA V. A facile and flexible motor imagery classification using electroencephalogram signals [J]. *Computer Methods and Programs in Biomedicine*, 2020, 197: 105722, DOI: 10.1016/j.cmpb.2020.105722.
- [4] ZHANG K S, ROBINSON N, LEE S W, et al. Adaptive transfer learning for EEG motor imagery classification with deep Convolutional Neural Network [J]. *Neural Networks*, 2021, 136: 1-10.
- [5] HE Q, DU S, ZHANG Y Y, et al. Classification of motor imagery based on single-channel frame and multi-channel frame[J]. *Chinese Journal of Scientific Instrument*, 2018, 39(9): 20-29.
- [6] SUN B, ZHAO X, ZHANG H, et al. EEG motor imagery classification with sparse spatiotemporal decomposition and deep learning [J]. *IEEE Transactions on Automation Science and Engineering*, 2021, 18(2): 541-551.
- [7] 李端玲, 成苈委, 于功敬, 等. 融合小波包和神经网络的脑电信号处理方法[J]. 北京邮电大学学报, 2021, 44(3): 94-99.
- [8] XU J C, ZHENG H, WANG J H, et al. Recognition of EEG signal motor imagery intention based on deep multi-view feature learning [J]. *Sensors*, 2020, 20(12): 3496, DOI: 10.3390/s20123496.
- [9] 郁东瑞, 周晖, 冯李逍, 等. 基于特征融合和粒子群优化算法的运动想象脑电信号识别方法[J]. 电子科技大学学报, 2021, 50(3): 467-475.
- [10] MENG X J, QIU S, WAN S H, et al. A motor imagery EEG signal classification algorithm based on recurrence plot convolution neural network[J]. *Patter Recognition Letters*, 2021, 146: 134-141.
- [11] YANG J, GAO S H, SHEN T. A two-branch CNN fusing temporal and frequency features for motor imagery EEG decoding[J]. *Entropy*, 2022, 24(3): 376, DOI: 10.3390/e24030376.
- [12] SADIQ M T, YU X J, YUAN Z H. Exploiting dimensionality reduction and neural network techniques for the development of expert brain-computer interfaces [J]. *Expert Systems with Applications*, 2021, 164: 114031, DOI: 10.1016/j.eswa.2020.114031.
- [13] SAKHAVI S, GUAN C T, YAN S C. Learning temporal information for brain-computer interface using convolutional neural networks [J]. *IEEE Transactions Neural Networks and Learning Systems*, 2018, 29(11): 5619-5629.
- [14] MASCI J, MEIER U, CIRESAN D, et al. Stacked convolutional auto-encoders for hierarchical feature extraction [C]. *21st International Conference on Artificial Neural Networks*, 2011, 6791: 52-59.
- [15] DAOUD H, BAYOUMI M. Semi-supervised learning for epileptic focus localization using deep convolutional autoencoder[C]. *2019 IEEE Biomedical Circuits and Systems Conference(Biocas 2019)*, 2019.
- [16] AN Y L, HU SH, DUAN X Y, et al. Electroencephalogram emotion recognition based on 3D feature fusion and convolutional autoencoder[J]. *Frontiers in Computational Neuroscience*, 2021, 15: 743426, DOI: 10.3389/fncom.2021.743426.
- [17] MIRZAEI S, GHASEMI P. EEG motor imagery classification using dynamic connectivity patterns and convolutional autoencoder [J]. *Biomedical Signal Processing and Control*, 2021, 68: 102584, DOI: 10.1016/j.bspc.2021.102584.
- [18] CATTAI T, COLONNESE S, CORSI M C, et al. Phase/amplitude synchronization of brain signals during motor imagery BCI tasks [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021, 29: 1168-1177.
- [19] CHO H, AHN M, AHN S, et al. EEG datasets for motor imagery brain-computer interface [J]. *Gigascience*, 2017, 6(7): 1-8.
- [20] HA K W, JEONG J W. Motor imagery EEG

- classification using capsule networks [J]. Sensors, 2019, 19(13): 2854, DOI: 10.3390/s19132854.
- [21] OLIVAS-PADILLA B E, CHACON-MURGUIA M I. Classification of multiple motor imagery using deep convolutional neural networks and spatial filters [J]. Applied Soft Computing, 2019, 75(1): 461-472.
- [22] 刘炎, 龚思哲, 王福利, 等. 基于堆叠有监督降噪自编码的运行状态评价[J]. 仪器仪表学报, 2022, 43(4): 271-281.
- [23] WANG Y H, LIU J, LI Y, et al. Hierarchically supervised deconvolutional network for semantic Video segmentation[J]. Pattern Recognition, 2017, 64(1): 437-445.
- [24] CHANG H L, YANG J M. Automated selection of a channel subset based on the genetic algorithm in a motor imagery brain-computer interface system [J]. IEEE Access, 2019, 7: 154180-154191.
- [25] CHANG H L, YANG J M. Genetic-based feature selection for efficient motion imaging of a brain-computer interface framework [J]. Journal of Neural Engineering, 2018, 15(5): 56020, DOI: 10.1088/1741-2552/aad567.
- [26] JANA G C, SWETAPADMA A, PATTNAIK P K. Enhancing the performance of motor imagery classification to design a robust brain computer interface using feed forward back-propagation neural network[J]. Ain Shams Engineering Journal, 2018, 9(4): 2871-2878.
- [27] TAYEB Z, FEDJAEV J, GHABOOSI N, et al. Validating deep neural networks for online decoding of motor imagery movements from EEG signals [J]. Sensors, 2019, 19(1): 210, DOI: 10.3390/s19010210.
- [28] SARWAR A, JAVED K, KHAN M J, et al. Enhanced accuracy for motor imagery detection using deep learning for BCI [J]. CMC-Computers Materials & Continua, 2021, 68(3): 3825-3840.
- [29] 彭禹, 宋耀莲. 基于 STFT 的卷积神经网络在 MI-EEG 分类中的应用[J]. 电子测量技术, 2021, 44(6): 36-41.

### 作者简介

郭玉雪,硕士研究生,主要研究方向为生物电磁技术。  
E-mail: 3057543974@qq.com

于洪丽(通信作者),工学博士,教授,主要研究方向为生物电磁技术、脑科学与神经工程等。  
E-mail:yhlzyn@126.com

么航,硕士研究生,主要研究方向为生物电磁技术。  
E-mail: 191169094@qq.com

杜博爱,硕士研究生,主要研究方向为生物电磁技术。  
E-mail: duboaik@163.com

王春方,硕士研究生,主要研究方向为生物信号处理和神经康复。  
E-mail: chfwang@tju.edu.cn