

# 基于非负矩阵分解的 EEG-TCNet 运动想象分类

张学军<sup>1,2</sup>, 石宝明<sup>1</sup>

(1. 南京邮电大学电子与光学工程学院、柔性电子(未来技术)学院, 南京 210023; 2. 南京邮电大学射频集成与微组装技术国家地方联合工程实验室, 南京 210023)

**摘要:** 针对深度学习进行脑电信号 (Electroencephalogram, EEG) 的运动想象分类时, 未利用通道特征研究通道之间相关性, 以及没有充分发掘频率、时间和空间信息等问题, 提出了一种基于非负矩阵分解 (Nonnegative matrix factorization, NMF) 的时间卷积网络 (Temporal convolutional network, TCN) 与紧凑型卷积神经网络 EEGNet 相结合的分类方法, 记为 NTEEGNet, 以相对少量的参数来提高运动想象分类的性能。模型的 NMF 能更好地提取通道特征, 且充分地利用了频率、时间和空间等信息; 同时, 在 TCN 的作用下, 网络的感受野呈指数级增加, 从而能在较少的参数下具有更强的特征提取能力。在 BCI Competition IV 2a 数据集上的实验结果表明, NTEEGNet 的分类准确率达到 83.99%, 在 EEG-TCNet 的基础上提升了 6.64%。

**关键词:** 运动想象; 深度学习; 卷积神经网络; 非负矩阵分解; 时间卷积网络

**中图分类号:** TP391 **文献标志码:** A

## EEG-TCNet for Motor Imagery Classification Based on Nonnegative Matrix Factorization

ZHANG Xuejun<sup>1,2</sup>, SHI Baoming<sup>1</sup>

(1. College of Electronic and Optical Engineering & College of Flexible Electronics (Future Technology), Nanjing University of Posts and Telecommunications, Nanjing 210023, China; 2. Nation-Local Joint Project Engineering Lab of RF Integration & Micropack-age, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

**Abstract:** In response to the limitations of deep learning approaches in motor imagery classification using electroencephalogram (EEG) signals, such as the failure to explore inter-channel correlations and fully exploit frequency, temporal, and spatial information, this study proposes a classification method named NTEEGNet, which combines nonnegative matrix factorization (NMF) with temporal convolutional network (TCN) and one compacted convolutional neural network named EEGNet to enhance the performance of motor imagery classification with a relatively small number of parameters. The NMF component of the model effectively extracts channel features and fully utilizes frequency, temporal, and spatial information. Additionally, the network's receptive field increases exponentially under the action of TCN, leading to stronger feature extraction capabilities with fewer parameters. Experimental results on the BCI Competition IV 2a dataset demonstrate that NTEEGNet can achieve an impressive classification accuracy of 83.99%, improved by 6.64% on the basis of EEG-TCNet.

**基金项目:** 国家自然科学基金 (61977039)。

**收稿日期:** 2024-06-18; **修订日期:** 2024-09-24

**Key words:** motor imagery; deep learning; convolutional neural network (CNN); nonnegative matrix factorization (NMF); temporal convolutional network (TCN)

## 引 言

脑电图 (Electroencephalogram, EEG) 是一种记录大脑电活动的技术,它通过在头皮上放置电极,测量记录大脑皮层神经元的电位差信号,最后将信号分解为不同频率的脑电波获取信息<sup>[1]</sup>。与其他技术相比,EEG 由于其低风险、低成本、高时间分辨率以及便携性而被广泛使用<sup>[2]</sup>。

运动想象 (Motor imagery, MI) 是指在没有实际运动的情况下,通过想象来模拟和重新创造运动的过程<sup>[3]</sup>。当一个人想象执行某个动作时,会在他大脑中激活与该动作相关的神经网络,将运动想象与脑电图相结合,即 MI-EEG,个体可以通过脑电图来了解运动想象时脑部的信息<sup>[4]</sup>。目前,MI-EEG 不仅广泛应用于中风恢复、脊髓恢复、光标控制和假肢控制等医疗领域,而且在车辆控制、无人机控制、环境控制及虚拟游戏等非医疗领域也得到广泛使用,因此 MI-EEG 在康复医学和脑成像方面具有广阔的应用前景<sup>[5]</sup>。但是 MI-EEG 仍然面临一些挑战,一方面是 EEG 信号中各种伪迹导致的信号噪声与干扰使得信号质量下降,准确性降低;另一方面是在头皮上测量 MI-EEG 会导致较低的空间分辨率,这意味着它无法提供精确的脑区定位和深层脑电活动的信息<sup>[6]</sup>。

当前,解决 MI-EEG 相关问题的方法主要分为传统机器学习 (Machine learning) 和深度学习 (Deep learning)。在依赖于手动提取特征的传统机器学习方法中,滤波器组公共空间模式 (Filter bank common spatial pattern, FBCSP) 及其变体在 MI-EEG 分类中取得了最佳性能<sup>[7]</sup>。与传统方法相比,深度学习不仅可以处理大规模数据,从大量数据中提取更多的信息并学习到更复杂的模式和关系,还能进行自动特征学习,从原始数据中学习 to 更具有区分性的特征,无需人工干预<sup>[8]</sup>。近年来,主流的深度学习网络模型包括深度前馈神经网络,也称多层感知机 (Multilayer perceptron, MLP)、卷积神经网络 (Convolutional neural network, CNN)、循环神经网络 (Recursive neural network, RNN)、生成对抗网络 (Generative adversarial network, GAN)、自编码器等,以及这些网络的变体<sup>[9]</sup>。最近,一种 CNN 的变体——时间卷积网络 (Temporal convolutional network, TCN) 被专门用于时间序列的建模和分类。与其他网络相比,TCN 不但能够在参数和内存使用量 (Memory access cost, MAC) 数量线性增加的情况下指数级地扩展其感受野大小,而且还具有稳定的梯度传播与时间并行性<sup>[10]</sup>。非负矩阵分解 (Nonnegative matrix factorization, NMF) 作为提取特征的一种方法,可以将原始矩阵分解为两个非负矩阵,这两个矩阵可以看作是原始数据在特定特征空间上的表示<sup>[11]</sup>。当 TCN 与 NMF 结合时,能够更好地增强模型的表达能力和可解释性,适用于各种时序数据分析和建模任务。

本文在紧凑型神经网络 EEGNet 与 TCNet 基础上,通过 NMF 进行特征筛选,提出了一种基于 NMF 的改进型 EEG-TCNet 模型。该模型通过 NMF 提取数据中关于运动想象的基本特征向量,再通过 EEG-TCNet 对这些特征向量进一步进行特征提取与分类。NMF 提供了对通道特征的解释性,EEG-TCNet 不仅具有出色的时间建模能力,能够有效地捕捉和学习时间序列数据中的动态模式和关系,而且还因为引入 EEGNet,从而实现了对于 EEG 数据的空间特征建模,可更有效地提取 EEG 信号中的空间模式和特征。最后,将这些特征进行融合,综合考虑频率、时间和空间信息,可使运动想象任务能更准确地完成识别和分类。

## 1 相关工作

### 1.1 运动想象分类方法

基于机器学习的传统运动想象分类方法主要包括:数据采集、特征提取、特征选择、分类和测试等

过程。对采集到的数据进行特征提取后,通常会获得时域、频域特征。传统分类方法基本上是手工提取特征并分类,例如使用相关性分析(Correlation analysis)、主成分分析(Principal component analysis, PCA)等,并结合线性判别分析(Linear discriminant analysis, LDA)或支持向量机(Support vector machine, SVM)等分类器<sup>[12]</sup>。

然而,传统分类方法存在一些缺点,比如手工提取特征无法充分捕捉到运动想象任务中的复杂模式和动态变化,维度增加时会大量增加计算复杂度并导致过拟合或泛化能力下降,以及对噪声和非平稳性的敏感性会导致分类器性能降低等。因此,CNN、RNN和深度信念网络(Deep belief network, DBN)等深度学习分类方法逐渐成为主流的分类方法。一些研究还提出了其他几种用于分类运动想象任务的深度学习模型<sup>[13]</sup>。如Xu等<sup>[14]</sup>提出了一种基于限制玻尔兹曼机(Restricted Boltzmann machine, RBM)的DBN模型用于特征提取和支持向量机并分类;Hassanpour等<sup>[15]</sup>提出了一种堆叠自编码器(Stacked auto-encoder, SAE),使用频率特征对运动想象任务进行分类。在其他研究中,研究人员试图使用递归神经网络从MI-EEG信号中提取时间信息。例如,Kumar等<sup>[16]</sup>提出了一种结合FBCSP特征和SVM分类器的长短期记忆(Long short-term memory, LSTM)模型;Luo等<sup>[17]</sup>采用了FBCSP特征,并将其用作门控递归单元(Gate recurrent unit, GRU)模型的输入。

## 1.2 CNN在运动想象上的应用

与DBN和RNN相比,CNN具有参数共享和局部连接的特点,它可以在整个输入数据上使用相同的权重,从而大大减少模型的参数量,而且还可以仅关注输入数据的局部区域,从而降低了模型对输入数据的要求和计算复杂性。对于需要按照时间顺序逐步处理输入数据的RNN来说,CNN可以通过卷积层和池化层的操作来并行计算地处理输入数据,从而加速模型的训练和推理过程<sup>[18]</sup>。总而言之,CNN的优势在于对复杂模式的学习能力、参数共享和局部连接的设计以及数据增强和自适应性的特点,使其在运动想象上的应用具有很大的潜力。

TCN是CNN的变体,专门用于时间序列建模和分类,它在许多序列相关任务中优于其他递归网络,如LSTM和GRU。与典型的CNN相比,TCN可以指数级地扩展感受野的大小,参数的数量线性增加,并且与RNN不同,它不会受到消失或爆炸梯度的影响。Ingolfsson等<sup>[19]</sup>提出了一种名为EEG-TCNet的TCN模型,该模型将TCN与EEGNet架构相结合,有助于提高运动想象分类的准确性,并降低过拟合风险。

NMF最初由Lee等<sup>[20]</sup>用于脸部图像,通过将输入的非负矩阵分解成基向量和相应的权值来实现,随后,它开始逐渐用于盲源分离和各种分类问题。在EEG分析中,NMF用于估计时间和频率分量以预测癫痫发作<sup>[21]</sup>;对于静态和动态功能连接,也可以使用NMF提取特征<sup>[22]</sup>;刘明宇等<sup>[23]</sup>还使用NMF从EEG信号中提取与注意力相关的特征。

## 2 基于NMF的EEG-TCNet

### 2.1 非负矩阵分解

NMF是一种矩阵分解方法,基本思想为:对于任意给定的一个非负矩阵 $C$ ,NMF算法能够将 $C$ 分解两个非负矩阵 $W$ 和 $H$ ,其中 $W$ 为分解后的系数矩阵, $H$ 为分解后的基向量矩阵,将 $W$ 输入模型中进行训练,再结合 $H$ 进行验证预测。

在使用NMF前,首先对预处理后的EEG数据进行标准化。然后,通过短时傅里叶变换

(Short-time Fourier transform, STFT)将 EEG 数据转化为频谱图,即

$$Y(t, f) = \int y(\tau) h(\tau - t) e^{-j2\pi f\tau} d\tau \quad (1)$$

式中: $h(\cdot)$ 为窗口函数, $y(\cdot)$ 为输入的信号。为了满足矩阵非负性,变换后的频谱图为 STFT 的幅度平方,即 $S = |Y(t, f)|^2$ ,从而获得非负矩阵 $C$ 。

最后,通过 NMF 分解矩阵 $C$ ,获得 $n$ 个非负矩阵 $W$ 与 $H$ ( $n$ 为通道数量),使得满足

$$C = WH \quad (2)$$

式中 $W$ 为可变的系数矩阵,送入后续网络用于训练。

结合系数矩阵 $W$ ,就可以获得原始矩阵的 EEG 通道权重,再将数据输入 EEG-TCNet 网络时,可提高判别准确率。此外,TCN 是一种适用于时序数据的神经网络结构,可以通过卷积操作捕捉时序数据中的局部和全局依赖关系<sup>[24]</sup>。TCN 具有平移不变性和多层感知机的优势,可以有效地对时序数据进行建模。结合 NMF 和 TCN,可以充分利用 NMF 提取的低维特征,并通过 TCN 进行时序建模,从而更好地理解 and 预测时序数据。

## 2.2 EEG-TCNet 网络模型

### 2.2.1 EEGNet 网络结构

EEGNet 具有优良的特征提取能力和强大的关联性,其中采用的深度可分离卷积层能够有效地提取时域和空域特征,而且深度可分离卷积层与全连接层相结合,能将这些特征与分类任务关联起来,表现出更强大的分类性能。如图 1 所示,将预处理后的数据传输到网络结构中,其中 $C$ 表示输入 MI-EEG 数据的通道数量, $T$ 表示每次实验的采样点数。EEGNet 的整体结构如下:首先,输入的数据经过卷积核数量为 $F_1$ 、大小为 $(1, K_E)$ 时间卷积层提取数据的时间特征,再通过权重归一化加速训练过程并提高模型的泛化能力;其次,经过卷积核数量为 $2 \times F_1$ 、大小为 $(C, 1)$ 的深度卷积层提取不同通道的特征并且捕捉不同通道之间的空间相关性,接着进行权重归一化与 ReLU 激活函数加速收敛速度后,再通过大小为 $(1, 8)$ 的池化层进行降维;最后,经过卷积核数量为大小为 $F_2$ 、大小为 $(1, 16)$ 的可分离卷积层,减少模型参数并且进行时空特征融合,再进行权重归一化与 ReLU 函数激活后送入大小为 $(1, 8)$ 的池化层。经过 EEGNet 对数据的时空特征提取后,输出数据的时间序列长度为 $T_C$ 。

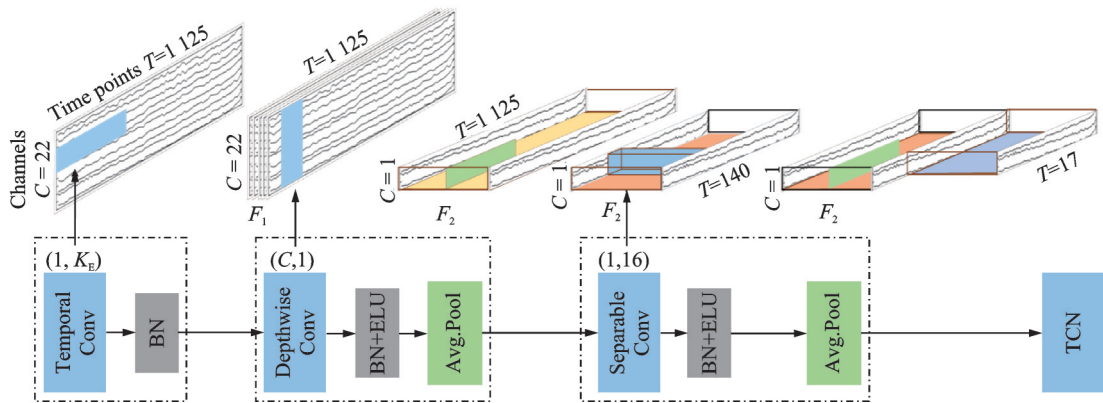


图1 EEGNet 网络模型

Fig.1 EEGNet network model

2.2.2 TCN 网络结构

TCN的主要结构如图2所示,其核心思想是通过堆叠一系列1D卷积层来建立对时间序列的建模,主要由残差网络与扩展因果卷积组成。图中ELU表示指数线性单元。因果卷积的要求是输出与输入相同长度,因此,TCN使用1D全卷积网络(Fully convolutional network, FCN)架构,其中每个隐藏层与输入层大小相同,并添加零填充长度(内核大小 $k-1$ )以保持后续层与上一层相同的长度。此外,因果卷积为单向结构,当前的数据与未来的数据无关。简单地说, $t$ 时刻的输出仅取决于 $t$ 时刻以及之前的输入。

常规因果卷积只能在网络深度上线性增加其感受野大小,因此TCN使用扩展因果卷积来获得更大的感受野。如图3所示,这允许卷积时的时间输入存在间隔采样,采样率受膨胀因子 $d$ 控制,使得网络有效窗口的大小随着层数呈指数级增长,即与网络深度成指数比例的方式增加其感受野。

残差连接被证明是训练深层网络的有效方法,它可使网络以跨层的方式传递信息。TCN的残差网络由两层组成,每层都由空洞因果卷积、批归一化层、非线性层以及Dropout层组成。尽管TCN只有1D卷积,但仍然能够通过将第二维度视为深度维度来处理2D特征图。残差连接将输入添加到输出特征图,并检查输入和输出的深度是否不同,然后进行 $1 \times 1$ 卷积<sup>[25]</sup>。如图3所示,用于将两个残差块堆叠在一起。

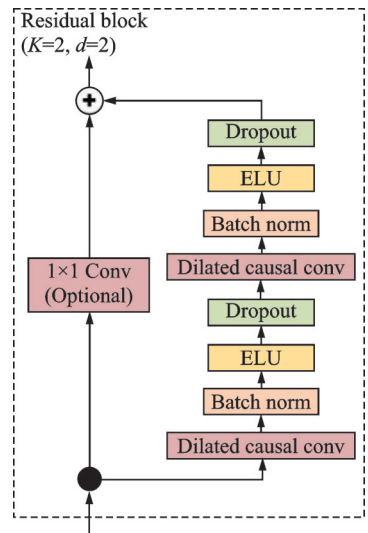


图2 TCN残差块  
Fig.2 TCN residual block

通过堆叠残差块,每个后续块中的膨胀因子呈指数增大,导致感受野大小随每个残留块呈指数增加。因此,TCN的感受野大小(Receptive field size, RFS)可表示为

$$RFS = 1 + 2(K_T - 1)(2^L - 1) \tag{3}$$

式中: $K_T$ 表示内核大小, $L$ 为残差块的数量。

本文TCN与其他TCN的不同在于:首先,卷积时使用批量归一化而不是权重归一化,因为批量归一化被证明在各种大型规模网络上比使用权重归一化得到的结果准确性更高;其次,由于ELU在EEG-TCNet的激活功能方面表现出更好的性能,因此本文使用ELU激活而不是线性单元ReLU。




图3 空洞卷积原理图  
Fig.3 Principle diagram of dilated convolution

2.2.3 NTEEGNet 网络结构

NTEEGNet网络模型如图4所示。原始数据经过预处理后,先进行STFT,并将STFT频谱图进行NMF分解,得到的权重矩阵作为EEGNet的输入,通过2D时间卷积学习频率特征、逐通

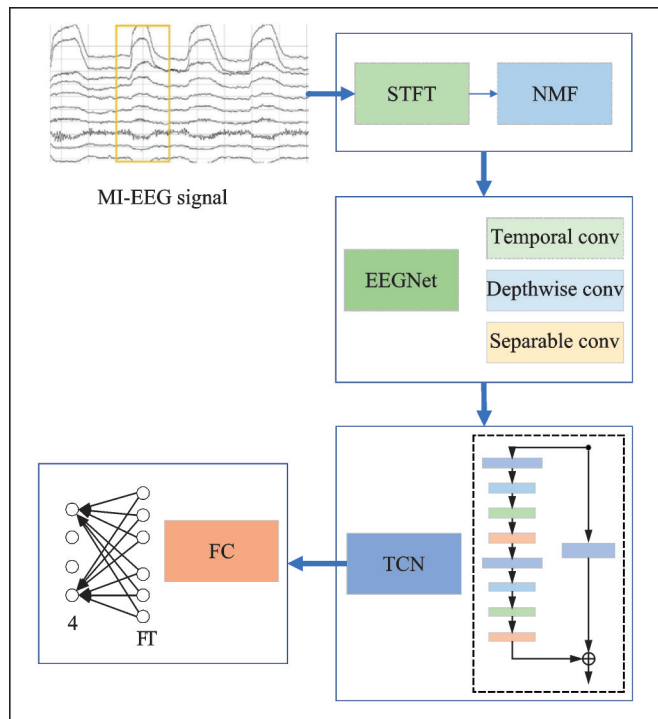


图4 NTEEGNet网络模型

Fig.4 NTEEGNet network model

道卷积学习空间特征,最后通过可分离卷积进行逐点卷积操作。将EEGNet的输出进行通道压缩后,输入TCN中进行特征提取,再经过全连接层进行预测。NTEEGNet网络模型的参数如表1所示。

### 3 实验与结果

#### 3.1 数据集

本文选用BCI Competition IV 2a数据集,该数据集被认为是MI-EEG解码的基准数据集<sup>[26]</sup>,由格拉兹理工大学于2008年创建。数据集包含9名受试者,受试者在实验过程中需要进行4种不同的运动想象任务,包括左手(1类)、右手(2类)、双脚(3类)和舌头(4类)。采集数据时使用25个通道,包括22个EEG通道,3个EOG通道,其中EOG通道的数据不参与分类。实验采样频率为250 Hz,并在0.5 Hz和100 Hz之间进行带通滤波。该数据集由每个受试者在两个不同日期记录的Session组成,其中一个用于训练,另一个用于测试,且每个Session包含288个试验。在根据EOG数据标记后,将包含伪迹的试验(占数据的9.41%)从数据集中剔除。

#### 3.2 数据预处理

EEG数据的时间范围是从MI提示之前0.5 s到MI结束,时间序列共计4.5 s。采样率保持在250 Hz,并且不应用附加的带通滤波。根据训练集的统计数据,通过去除均值和缩放到每个通道的单

表1 NTEEGNet网络模型参数

Table 1 Model parameters of NTEEGNet network

卷积层	卷积核数量	卷积核大小	输出
时间卷积	$F_1$	$(1, K_E)$	$(F_1, C, T)$
深度卷积	$F_1 \times D$	$(C, 1)$	$(F_1 \times D, 1, T//8)$
可分离卷积	$F_2$	$(1, 16)$	$(F_2, 1, T//16)$
TCN	$F_T$	$K_T$	$F_T$

位方差来应用标准化。在进行 NMF 处理前,首先进行 STFT,获得 STFT 后的幅度平方频谱图,再进行 NMF 分解,提取通道权重。

### 3.3 实验与结果分析

#### 3.3.1 模型训练

实验在 NVIDIA RTX 3050 GPU、i7-12700H 的硬件设备上进行,使用 Pytorch 架构进行训练和测试。训练时,使用交叉熵损失函数、Adam 优化器以及 CosineAnnealingLR 进行学习率自适应, CosineAnnealingLR 根据余弦函数调整学习率。实验训练时,设置初始学习率为 0.001,迭代次数为 750 次。虽然本次实验对不同主题采用不同学习率,但为了确保模型有更好的泛化能力,并未进行独立受试者实验。

#### 3.3.2 结果分析

本次实验使用固定架构对数据进行训练,对所有受试者选择相同的超参数,然后分别训练和测试每个受试者。在训练集上对超参数进行交叉验证搜索,得到以下对所有受试者表现最佳的架构:  $F_1=8, F_2=16, K_E=32, K_T=4, D=2, F_T=12, p_e=0.2, p_i=0.3$ , 其中  $p_e$  与  $p_i$  分别为 EEGNet 和 TCNet 的 Dropout。9 位受试者的测试精度如图 5 所示,评价指标为准确率和  $F_1$ -score,受试者的准确率和  $F_1$ -score 均值分别在 80% 和 0.8 之上,除受试者 2 可能因为出现运动想象盲现象<sup>[27]</sup>而导致准确率较低外,其余受试者准确率均保持较高水平,这表明 NTEEGNet 对 MI-EEG 的解码具有优越性。

图 6 为不同 Epoch 下的实验结果,可以看出,750 次为最佳训练次数。为了证明 NMF 和 EEG-TCNet 在运动想象解码过程的有效性,本文还进行了消融实验。实验中分别从 NTEEGNet 模型中删除 NMF、EEGNet 和 TCNet 部分,按照 750 次进行训练,以证明各部分在实验中的作用。消融实验去除各部分后的混淆矩阵图如图 7 所示。从图中可知,与 NTEEGNet 相比,去除各部分后,分类效果均有所下降。

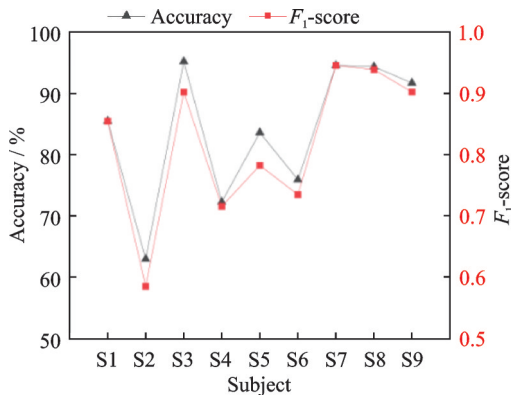


图 5 各受试者平均准确率及  $F_1$ -score 得分

Fig.5 Average accuracy and  $F_1$ -score of each subject

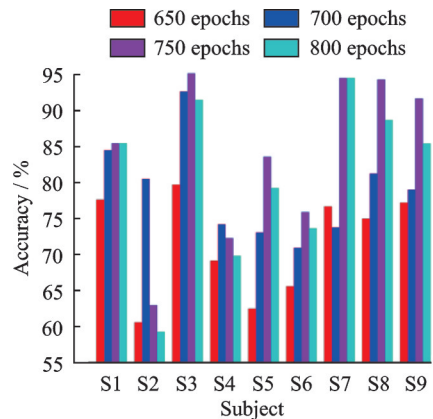


图 6 不同训练轮数下各受试者的准确率

Fig.6 Accuracy of each subject under different training epochs

表 2 总结了不同受试者在不同模型下的准确率,可以看出 NTEEGNet 对 9 个受试者进行分类时表现出较高的鲁棒性,并达到了 83.99% 的准确率,均高于 EEGNet 网络(11.59%)和 EEG-TCNet 网络(6.64%)。相较于其他模型在个别对象上表现不佳的结果,例如受试者 2、4 和 5, NTEEGNet 网络显示出明显的改善,进而展现出其优良的性能。

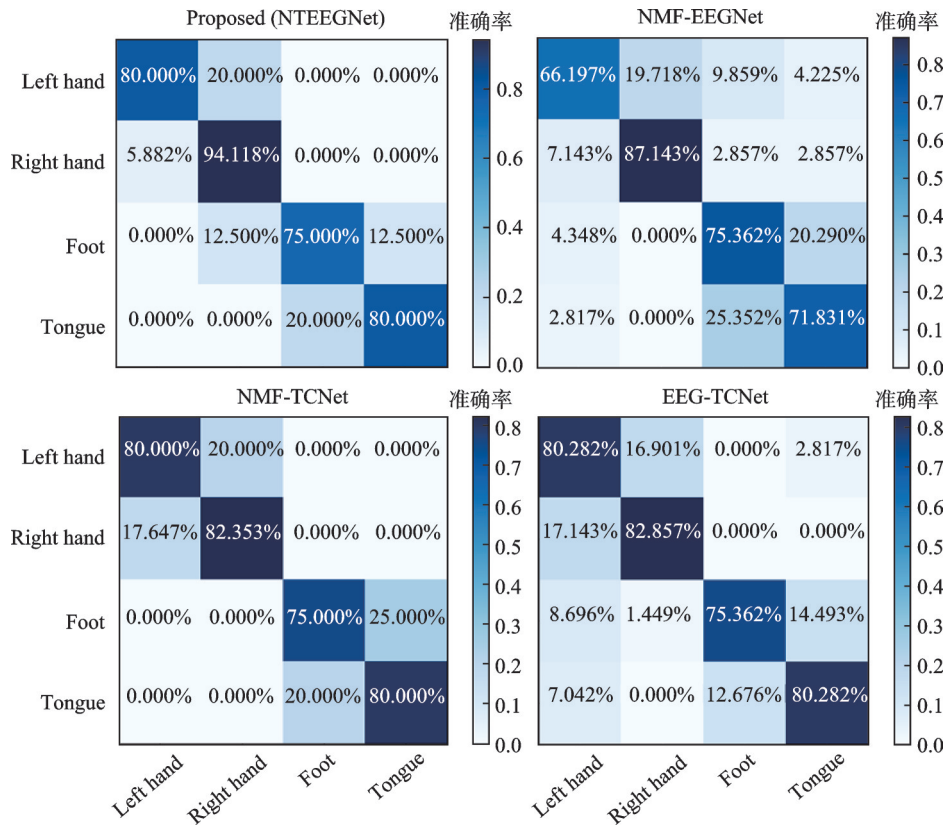


图7 消融实验中去除各部分的混淆矩阵

Fig.7 Confusion matrix after removing each part in ablation experiments

表2 不同模型在BCI Competition IV 2a数据集上的分类准确度

Table 2 Classification accuracy of different models on the BCI Competition IV 2a dataset

受试者	EEGNet <sup>[28]</sup>	Multi-branch 3D CNN <sup>[29]</sup>	EEG-TCNet <sup>[19]</sup>	Zhang et al. <sup>[12]</sup>	MSFNet <sup>[30]</sup>	NTEEGNet	%
S1	79.51	78.47	85.77	89.68	83.68	85.45	
S2	56.25	52.77	65.02	75.08	74.15	62.96	
S3	88.89	89.93	94.51	93.2	90.68	95.19	
S4	80.90	66.66	64.91	77.82	76.90	72.26	
S5	57.29	61.11	75.36	73.27	78.83	83.58	
S6	53.82	60.41	61.40	65.74	68.04	75.91	
S7	91.67	90.62	87.36	88.73	88.30	94.55	
S8	81.25	82.29	83.76	90.77	79.52	94.34	
S9	79.17	84.37	78.03	85.87	84.16	91.67	
Mean	72.40	74.70	77.35	82.24	80.47	83.99	

#### 4 结束语

本文提出了一种基于NMF的EEG-TCNet模型,能对MI-BMI进行准确分类。模型在对数据ST-FT处理后,进行NMF分解,再通过EEGNet学习频率、空间特征,最后输入TCNet中进行训练,在提取特征的同时,获得更大的感受野,并且增强了整个网络的鲁棒性。训练结果的平均准确率为83.99%,由



于其只需要少量的参数,且泛化能力较强,也可推广到其他的 MI 数据集上。在未来实验中,还可以通过增加注意力机制模块或使用混合尺度卷积等方法来提高分类效果,且在该模型由于数据集较小导致分类效果不理想的情况下,也可以通过循环平移的方法来扩充数据,从而提高分类效果。

#### 参考文献:

- [1] SUN B, ZHANG H, WU Z, et al. Adaptive spatiotemporal graph convolutional networks for motor imagery classification[J]. *IEEE Signal Processing Letters*, 2021, 28: 219-223.
- [2] SHI T, REN L, CUI W. Feature extraction of brain-computer interface electroencephalogram based on motor imagery[J]. *IEEE Sensors Journal*, 2020, 20(20): 11787-11794.
- [3] DU B, LIU Y, TIAN G. Improving motor imagery EEG classification by CNN with data augmentation[C]//*Proceedings of 2020 IEEE 19th International Conference on Cognitive Informatics & Cognitive Computing*. Beijing, China: IEEE, 2020: 111-118.
- [4] ZHANG R, ZHANG N, CHEN C, et al. Motor imagery EEG classification with self-attention-based convolutional neural network[C]//*Proceedings of 2022 7th International Conference on Intelligent Informatics and Biomedical Science (ICIIBMS)*. [S.l.]: IEEE, 2022, 7: 195-199.
- [5] XU B, ZHANG L, SONG A, et al. Wavelet transform time-frequency image and convolutional network-based motor imagery EEG classification[J]. *IEEE Access*, 2019, 7: 6084-6093.
- [6] LI X, PENG M, CHEN S, et al. EEG motor imagery classification based on multi-spatial convolutional neural network[C]//*Proceedings of the 5th International Conference on Artificial Intelligence and Big Data (ICAIBD)*. Chengdu, China: [s.n.], 2022: 433-437.
- [7] MUSALLAM Y K, ALFASSAM N I, MUHAMMAD G, et al. Electroencephalography-based motor imagery classification using temporal convolutional network fusion[J]. *Biomedical Signal Processing and Control*, 2021, 69: 102826.
- [8] 王洪涛, 邹鹤良, 李达强. 基于左右手运动想象的在线算法设计与应用[J]. *数据采集与处理*, 2013, 28(6): 828-833.  
WANG Hongtao, ZOU Heliang, LI Daqiang. Left/right hand motor imagery based online algorithm design and its application [J]. *Journal of Data Acquisition and Processing*, 2013, 28(6): 828-833.
- [9] MA X, CHEN W, PEI Z, et al. A temporal dependency learning CNN with attention mechanism for MI-EEG decoding[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31: 3188-3200.
- [10] LU N, YIN T, JING X. A temporal convolution network solution for EEG motor imagery classification[C]//*Proceedings of 2019 IEEE 19th International Conference on Bioinformatics and Bioengineering (BIBE)*. Athens, Greece: IEEE, 2019: 796-799.
- [11] NUGUMANOVA A, AKHMED-ZAKI D, MANSUROVA M, et al. NMF-based approach to automatic term extraction[J]. *Expert Systems with Applications*, 2022, 199: 117179.
- [12] ZHANG L, WANG M, WANG L, et al. A dual attention and improved loss function based MI-EEG signal classification model[C]//*Proceedings of the 6th International Conference on Artificial Intelligence and Big Data (ICAIBD)*. Chengdu, China: [s.n.], 2023: 917-921.
- [13] LI M A, PENG W M, YANG J F. Key band image sequences and a hybrid deep neural network for recognition of motor imagery EEG[J]. *IEEE Access*, 2021, 9: 86994-87006.
- [14] XU J, ZHENG H, WANG J, et al. Recognition of EEG signal motor imagery intention based on deep multi-view feature learning[J]. *Sensors*, 2020, 20(12): 3496.
- [15] HASSANPOUR A, MORADIKIA M, ADELI H, et al. A novel end-to-end deep learning scheme for classifying multi-class motor imagery electroencephalography signals[J]. *Expert Systems*, 2019, 36(6): e12494.
- [16] KUMAR S, SHARMA R, SHARMA A. OPTICAL+: A frequency-based deep learning scheme for recognizing brain wave signals[J]. *PeerJ Computer Science*, 2021, 7: e375.
- [17] LUO T, ZHOU C, CHAO F. Exploring spatial-frequency-sequential relationships for motor imagery classification with recurrent neural network[J]. *BMC Bioinformatics*, 2018, 19: 1-18.

- [18] 徐晴, 葛成, 蔡标, 等. 基于深度学习的癫痫脑电信号分类[J]. 数据采集与处理, 2022, 37(4): 787-797.  
XU Qing, GE Cheng, CAI Biao, et al. EEG signal classification of epilepsy based on deep learning[J]. *Journal of Data Acquisition and Processing*, 2022, 37(4): 787-797.
- [19] INGOLFSSON T M, HERSCHE M, WANG X, et al. EEG-TCNet: An accurate temporal convolutional network for embedded motor-imagery brain-machine interfaces[C]//Proceedings of 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Toronto, ON, Canada: IEEE, 2020: 2958-2965.
- [20] LEE D, SEUNG H S. Algorithms for non-negative matrix factorization[C]//Proceedings of International Conference on Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2000.
- [21] STOJANOVIĆ O, KUHLMANN L, PIPA G. Predicting epileptic seizures using nonnegative matrix factorization[J]. *PLoS One*, 2020, 15(2): e0228025.
- [22] ZHOU T, KANG J, CONG F, et al. Stability-driven non-negative matrix factorization-based approach for extracting dynamic network from resting-state EEG[J]. *Neurocomputing*, 2020, 389: 123-131.
- [23] 刘明宇, 王珏, 郑崇勋, 等. 应用非负矩阵分解方法提取注意力相关脑电特征[J]. 生物物理学报, 2006(1): 67-72.  
LIU Mingyu, WANG Yu, ZHENG Chongxun, et al. Using non-negative matrix fact factorization to extract attention-related EEG features[J]. *Acta Biophysica Sinica*, 2006(1): 67-72.
- [24] GURVE D, DELISLE-RODRIGUEZ D, BASTOS T, et al. Motor imagery classification with covariance matrices and non-negative matrix factorization[C]//Proceedings of the 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). [S.l.]: IEEE, 2019: 3083-3086.
- [25] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. (2018-05-16). <https://arXiv.org/pdf/1803.01271.pdf>.
- [26] ALTAHERI H, MUHAMMAD G, ALSULAIMAN M. Physics-informed attention temporal convolutional network for EEG-based motor imagery classification[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(2): 2249-2258.
- [27] BRUNNER C, LEEB R, MÜLLER-PUTZ G R, et al. BCI Competition 2008-Graz data set A[EB/OL]. (2022-08-12). <https://ampz.tugraz.at/~bci/database/001-2014/description.pdf>.
- [28] 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.
- [29] ZHAO X, ZHANG H, ZHU G, et al. A multi-branch 3D convolutional neural network for EEG-based motor imagery classification[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(10): 2164-2177.
- [30] WANG C, WU Y, WANG C, et al. MSFNet: A multi-scale space-time frequency fusion network for motor imagery EEG classification[J]. *IEEE Access*, 2024, 12: 8325-8336.

#### 作者简介:



张学军 (1969-), 男, 博士, 教授, 硕士生导师, 研究方向: 智能信息处理、深度学习、脑电和脑磁信号处理与研究、脑机接口, E-mail: xjzhang@njupt.edu.cn。



石宝明 (2001-), 通信作者, 男, 硕士研究生, 研究方向: 脑电信号处理与研究、深度学习, E-mail: 2770583580@qq.com。

(编辑: 王静)