

基于 EEG-TCNet 的运动想象脑电识别方法

李卫校^a, 凌六一^{a,b}

安徽理工大学 a. 电气与信息工程学院; b. 人工智能学院, 安徽 淮南 232001

摘要:目的 针对以深度学习为解码的方法在运动想象脑电信号识别过程中仅对原始的运动想象脑电信号进行特征提取而不进行样本扩充和往往采用单一尺度的卷积对多频段的运动想象脑电信号进行特征提取,无法充分发掘各频段之间相关性的问题,在主流 EEG-TCNet 解码方法的基础上提出了一种样本扩充和多尺度的解码方法。方法 首先,对运动想象脑电信号进行分割,以增加数据集样本数,将运动想象脑电信号等间隔下采样成 3 个不同的子序列,每个子序列都含有与原始运动想象脑电信号相同的数据特征;其次,使用 EEGNet 对每个子序列进行特征提取,对不同的子序列使用不同尺度的 EEGNet 以便提取不同频段的特征;之后,对每个经过 EEGNet 提取后的子序列采用一种基于卷积滑动的方法再进分割,充分挖掘每个子序列潜在的信息;再次,将每个处理后的子序列传入到时间卷积网络进行特征提取和降维;最后,对所有处理后的子序列进行拼接、平均操作,并传入到全连接层进行识别。**结果** 在公开的 BCI 竞赛数据集 IV-2a 上进行验证,所做出改进的网络相对于 EEG-TCNet、EEGNet 的解码准确度分别有 5.19% 和 7.7% 的提升。**结论** 证明所做出改进的网络在运动想象脑电信号识别任务中具有更理想的解码性能。

关键词: EEG-TCNet; 运动想象脑电信号; 卷积神经网络; 时间卷积网络

中图分类号: TP301 **文献标识码:** A **doi:** 10.16055/j.issn.1672-058X.2025.0001.016

Motor Imagery EEG Recognition Method Based on EEG-TCNet

LI Weixiao^a, LING Liuyi^{a,b}

a. School of Electrical and Information Engineering; b. School of Artificial Intelligence, Anhui University of Science and Technology, Anhui Huainan 232001, China

Abstract: Objective This study addresses the limitations of deep learning-based methods in recognizing motor imagery electroencephalography (EEG) signals, which primarily focus on feature extraction from raw signals without sample augmentation and often utilize single-scale convolutions to extract features from multi-band EEG signals. This approach fails to fully explore the correlations between different frequency bands. Therefore, a sample augmentation and multi-scale decoding method was proposed based on the mainstream EEG-TCNet decoding technique. **Methods** First, the motor imagery EEG signals were segmented to increase the number of samples in the dataset. The motor imagery EEG signals were downsampled at equal intervals into three different subsequences, with each subsequence containing the same data characteristics as the original motor imagery EEG signal. Next, EEGNet was used to extract features from each subsequence, employing different scales of EEGNet for different subsequences to capture features from various frequency bands. Afterward, a convolutional sliding method was applied to further segment each subsequence processed by EEGNet, fully exploring the latent information of each subsequence. Subsequently, each processed subsequence was fed into a temporal convolutional network for feature extraction and dimensionality reduction. Finally, all processed subsequences

收稿日期: 2023-09-12 **修回日期:** 2023-12-18 **文章编号:** 1672-058X(2025)01-0123-06

作者简介: 李卫校(1998—),男,安徽阜阳人,硕士研究生,从事运动想象脑电意图识别、深度学习研究。

通讯作者: 凌六一(1980—),男,安徽枞阳人,教授,博士,从事检测技术与智能信息处理研究。Email:lyling@aust.edu.cn.

引用格式: 李卫校,凌六一. 基于 EEG-TCNet 的运动想象脑电识别方法[J]. 重庆工商大学学报(自然科学版), 2025, 42(1): 123-128.

LI Weixiao, LING Liuyi. Motion imagery EEG recognition method based on EEG-TCNet[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(1): 123-128.

were concatenated and averaged, which were then input into a fully connected layer for recognition. **Results** The proposed improved network was validated on the public BCI Competition Dataset IV-2a, showing an increase in decoding accuracy of 5.19% and 7.7% compared with EEG-TCNet and EEGNet, respectively. **Conclusion** The improved network demonstrates better decoding performance in motor imagery EEG signal recognition tasks.

Keywords: EEG-TCNet; motion imagery EEG signals; convolutional neural network; temporal convolution network

1 引言

脑机接口(Brain Computer Interface, BCI)作为一种前沿的科学技术,通过解码脑电信号从而实现对外部环境或设备的控制,能够改变人的生活方法,帮助功能障碍的患者进行康复训练^[1],然而,脑电信号低效的解码性能制约着脑机接口的广泛应用^[2]。

运动想象脑电(motor imagery electroencephalogram, MI-EEG)具有自发性和本质自然性,更适合作为脑机接口的控制信号。从事脑机接口的研究人员提出了大量的方法来对运动想象脑电信号进行特征提取,传统的机器学习算法包括提取时间域、频域和空间特征的自回归模型、小波变化、共空间模式及其变种、改进的KNN等算法^[3-6]。以深度学习作为解码的方法在计算机视觉^[7]和自然语言处理中取得良好的效果,研究人员也开始利用深度学习作为MI-EEG的解码方法。用于MI-EEG解码的常用结构包括卷积神经网络(Convolution Neural Networks, CNN)^[8],时间卷积网络(Temporal Convolution Networks, TCN)和其他变体^[9]。相比传统的机器学习方法,使用深度学习作为MI-EEG的解码方法,能够以更少的专家知识达到较好的解码精度。Veron等^[8]提出了一种紧凑的卷积神经网络EEGNet,通过使用深度卷积来提取不同导联之间的关系和使用深度可分离卷积提取时空信息来对MI-EEG进行解码。Thorir等^[9]提出了EEG-TCNet,是在EEGNet的基础上加入了TCN网络结构,EEG-TCNet网络的设计使用了较少的参数量,能够部署在边缘设备。Dalin等^[10]提出了一种基于图卷积递归注意网络G-CRAM,创新点在于将电极通道的位置信息嵌入到网络结构中,来对MI-EEG进行解码。

上述研究为MI-EEG的解码方法提供新的思路,为以后的研究提供了参考方向,同时这些研究也适用于其他类型脑电信号的解码,但无论是传统的机器学习还是深度学习都是对原始MI-EEG信号进行特征提取并没有进行样本扩充,同时,以深度学习作为解码方法大都使用单一尺度的卷积对MI-EEG进行处理。针对以上问题,在主流的EEG-TCNet解码方法的基础上提出了一种样本扩充和多尺度的解码方法,主要创新点:

(1) 为了保证MI-EEG的完整性,同时也能增加样本数,对MI-EEG等间隔下采样成3个子序列,每个

子序列都含有与原始MI-EEG相同的数据特征^[11];

(2) 针对以深度学习作为MI-EEG解码方法存在单一尺度的卷积无法对多频段的MI-EEG进行有效提取问题,使用多尺度的卷积对MI-EEG下采样的子序列进行特征提取;

(3) 为了挖掘经过不同尺度卷积处理后子序列的潜在信息,对处理后的子序列使用一种基于卷积的滑动窗口进行分割,增加子样本数。

在相同实验环境下,对EEG-TCNet所做出的改进,在BCI IV-2a数据集上解码精度平均提升了5.19%。

2 解码方法

2.1 EEG-TCNet网络结构

EEG-TCNet网络的设计沿用了EEGNet^[7]的设计思路,并在EEGNet的基础上加入了时间卷积网络,实验表明能够很好的提升MI-EEG的解码精度。

2.1.1 EEGNet网络结构

EEGNet网络的提出对运动想象脑电信号的解码提供了一个很好的思路,主要是采用了深度卷积来处理不同导联之间的信息。将MI-EEG传入到EEGNet,如图1所示,将输入的MI-EEG信号以图的形式传入到网络结构中,其中 C 表示实验过程中的电极通道数, L 表示每次实验截取的采样点数。整体过程如下:将特征图传入到 F_1 个卷积核大小为 $(1, K_c)$ 时间卷积(Temporal Conv),用于对MI-EEG时间维度进行特征提取,再加入批归一化层(Batch Normalization, BN)来调整权重数据分布以达到加速网络训练的目的;之后再传入到卷积深度为 D ,卷积核大小为 $(C, 1)$ 的深度卷积(Channel DW Conv),用来提取不同导联间的特征,再经过BN层加速网络收敛和指数线性单位(Exponential Linear Unit, ELU)激活函数增强网络的非线性拟合能力;再将通过一个大小为 $(1, P_1)$ 的平均池化层(average pooling layer, Avg. Pool)来实现降维;之后再特征图传入到 F_2 个卷积核大小为 $(1, K_s)$ 的二维空间卷积(Spatial Conv)来进行时空维度的特征融合,再经过BN层和ELU激活函数;为了进一步减少特征维度,最后再将特征图传入到大小为 $(1, P_2)$ 的Avg. Pool。EEGNet输出是对MI-EEG时空信息的高维特征提取,此时的时间序列长度为 T_c 。

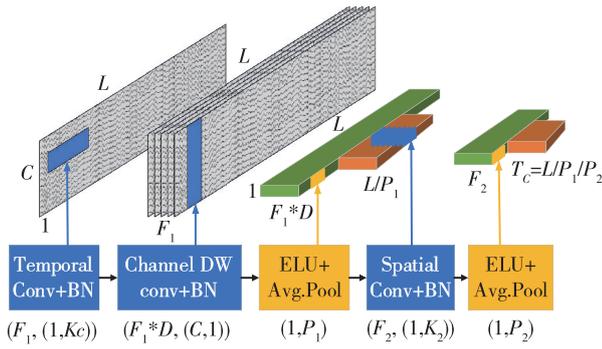


图 1 EEGNet

Fig. 1 EEGNet

2.1.2 TCN 网络结构

TCN 模块的设计结合了残差网络和扩张因果卷积,将 TCNet 中的 ReLU 激活函数改为处理 MI-EEG 常用的 ELU 激活函数。每个残差块是由两个扩张因果卷积 (Dilated Causal Conv, DCC) 组成,每个 DCC 后都加入 BN 层和 ELU 激活函数。扩张因果卷积的设计思路是为了迎合时序问题中保证某一时刻的输出只依赖于当前和历史时刻输入的需求,同时也能够实现增加感受野 (Receptive Field Size, f_{RFS})。

$$f_{RFS} = 1 + 2 \cdot (K_T - 1) \cdot (2^L - 1) \quad (1)$$

其中, K_T 是卷积核的大小, L 表示残层数。 K_T 和 L 的选择应当满足 $f_{RFS} \geq T_c$, 才能使得所有的输入信息都被利用到。

TCN 的结构如图 2 所示,将特征图经过两个残差连接的 TCN 网络,其中,前一个残差的卷积数量为 F_T , 卷积核大小为 K_T , 扩张率 d 为 1, 后一个残差的卷积数量为 F_T , 卷积核大小为 K_T , 扩张率 d 为 2, 为了加速网络收敛和非线性拟合能力, 在每个卷积后面都加上 BN 和 ELU 激活函数, 只需输出最后一个神经元的值就可包含了输入序列的所有信息, 使用 TCN 网络不仅可以有效地提取特征, 同时也能实现降维, 最后将特征图传入到一个输出为 4 的全连接层进行分类, 得到预测结果。

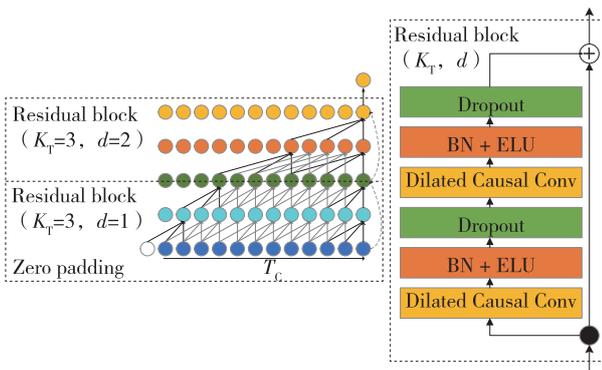


图 2 时间卷积网络

Fig. 2 Temporal convolutional network

2.2 改进的 EEG-TCNet

单一尺度的卷积大小无法对复杂多频的 MI-EEG 进行有效提取, 采用不同尺度大小的卷积核对 MI-EEG 的提取就显得重要, 然而, 直接对长序列的原始 MI-EEG 进行多尺度特征处理, 会增加网络的计算量, 因此, 将 MI-EEG 拆分成 N 个子序列, 用不同的尺度的卷积核去处理每一个子序列, 为了保证时间序列的完整性, 这 N 个子序列应具有与原始序列相同的数据特征, 因此, 将 MI-EEG 等间隔采样成 N 个子序列时, 每个子序列都含有与原始序列的相同的数据特征。基于这种想法, 设计一种改进的 EEG-TCNet, 如图 3 所示。将 MI-EEG 等间隔分成 3 个子序列, 每个子序列使用不同卷积核大小的 EEGNet 来提取 MI-EEG 不同频段的特征。MI-EEG 是以 250 Hz 的采样率进行信号采集, 当使用卷积核大小为 $(1, K_c)$ 的时间卷积进行特征提取时, 能够提取 $250/K_c$ 以上的频率信息, K_c 是时间轴上的滤波器长度。在所改进的网络中 K_c 的取值分别为 16、32、64, 因此每一个时间卷积分别能提取 16、8、4 Hz 以上的频率信息和 0.064、0.128 和 0.256 s 的时间特征, 相比于单一尺度的卷积更能充分挖掘 MI-EEG 的物理特征信息, 使用更小的 P_1 、 P_2 的池化层是为了保留每个子序列更多的信息特征。

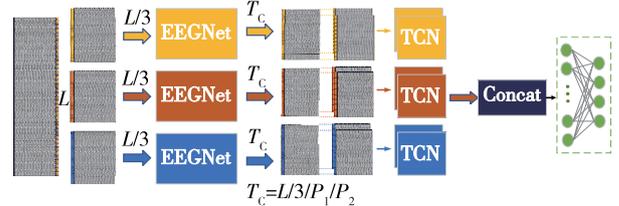


图 3 改进的 EEG-TCNet

Fig. 3 Improved EEG-TCNet

2.2.1 滑动窗口

经过改进的 EEGNet 网络特征提取后的每个子序列都含有不同频段的数据特征, 为了挖掘每个子序列潜在的信息, 对经过 EEGNet 处理后的子序列采用一种基于卷积的滑动窗口的方法, 能够增加子序列的样本集。对每个子序列在时间维度上使用一个长度为 T_w , 步长为 1 的卷积滑动窗口进行切分, 假设滑动窗口的数量为 W , 相对应的 T_w 应满足 $T_w = T_c - W + 1$, 这样每个子序列被分割成 W 个序列, 能够实现增加子序列样本集的目的。将每个子序列传入到 TCN 网络结构中去提取特征和降维, 之后将所有的子序列进行拼接、平均操作再传入到全连接层进行预测, 各解码方法参数如表 1 所示。

表 1 网络参数

Table 1 Network parameters

参 数	EEGNet	EEG-TCNet	改进的 EEG-TCNet
L	1 125	1 125	1 125
F_1	8	8	16
K_c	128	32	64,32,16
D	2	2	2
C	22	22	22
P_1	8	8	5
F_2	16	16	32
K_2	32	16	16,8,4
P_2	16	8	6
T_c	8	17	12
K_T	—	4	3
L	—	2	2
F_T	—	12	32
Dropout	—	0.3	0.3
N	—	—	3
W	—	—	4

“—”:相应的解码方法没有这个参数

3 仿真实验与结果分析

3.1 数据集与预处理

研究选择的是 BCI 竞赛运动想象的脑电数据 BCI IV-2a, BCI IV-2a 数据集共有 9 名被试者, 每个被试者被要求进行两次 sessions 测试, 将其中一个 session 作为训练集, 另一个 session 作为测试集; 每次实验持续 8 s, 包括准备阶段、给出提示、做出运动想象和休息 4 个部分。每次实验的提示在左手运动、右手运动、双脚运动和舌头运动 (简称为: left hand, right hand, feet, tongue) 中选择, 每种提示随机进行 72 次, 因此每个受试者在每个 session 进行了 72×4 次实验。在收集数据时采用 250 Hz 采样率, 同时也进行 0.5~100 Hz 的带通滤波和 50 Hz 的凹陷滤波。研究中选择 22 个 EEG 电极通道, 每次实验选择运动想象结束时前截取 4.5 s, 共记 1 125 个采样点。

3.2 训练过程

实验过程的训练和测试过程在 Nvidia GTX 3060 12GB 的 GPU 上进行, 使用 PyTorch 框架搭建网络结构。使用 Adam 优化器、交叉熵损失函数和 1000 次迭代次数, 权重损失率设置为 0.001, 初始学习率为 0.001, 学习率更新方式为余弦退火函数。

3.3 其他方法与结果对比

为了验证所做出改进的 EEG-TCNet 相对 EEGNet 和 EEG-TCNet 具有更好的解码性能, 将这 3 种方法在相同环境下进行测试, 每个受试者的测试精度如表 2

所示以准确度 p 和 k -score 作为评价指标。图 4 为 EEGNet 对 BCI IV-2 解码的平均混淆矩阵, 图 5 为 EEG-TCNet 对 BCI IV-2a 解码的平均混淆矩阵, 图 6 为改进后的 EEG-TCNet 对 BCI IV-2a 解码的平均混淆矩阵。从表 2 可以看出改进的 EEG-TCNet 在 BCI IV-2a 数据集上的平均准确度比 EEG-TCNet 高 5.19%, 比 EEGNet 高 7.7%, 有更高的 k -score 得分, 标准差为 7.21%, 比 EEGNet 和 EEG-TCNet 少 5.24% 和 4.11%, 具有较小的误差波动, 更具有鲁棒性。相比于 EEG-TCNet, 所改进的网络对受试者 2、4、5、6、7 的解码精度, 有 4% 以上的明显的提升, 受试者 1、8 都有略微的提升, 但对受试者 3 的解码精度却有 1.09% 的降低。从图 4、图 5、图 6 中不难看出, 所改进的 EEG-TCNet 在每类运动想象识别中都优于 EEG-TCNet, 更加优于 EEGNet, 同时也能说明, 所做出改进的网络对 MI-EEG 的解码具有优越性。

表 2 不同方法的准确度对比

Table 2 Accuracy comparison of different methods

受试者	EEGNet		EEG-TCNet		改进的 EEG-TCNet	
	$p/\%$	k -score	$p/\%$	k -score	$p/\%$	k -score
1	84.34	0.7912	84.70	0.7960	86.83	0.8244
2	59.36	0.4581	58.66	0.4488	74.91	0.6655
3	91.94	0.8925	94.14	0.9219	93.04	0.9072
4	60.53	0.4737	67.98	0.5731	82.02	0.7603
5	73.91	0.6521	75.36	0.6715	79.71	0.7295
6	59.07	0.4543	65.58	0.5411	71.16	0.6155
7	90.61	0.8748	90.25	0.87	94.58	0.9277
8	82.66	0.7688	83.39	0.7785	84.50	0.7933
9	78.79	0.7172	83.71	0.7828	83.71	0.7828
Mean	75.69	0.6759	78.20	0.7093	83.39	0.7785
St. D.	12.45	0.1660	11.32	0.1509	7.21	0.0962

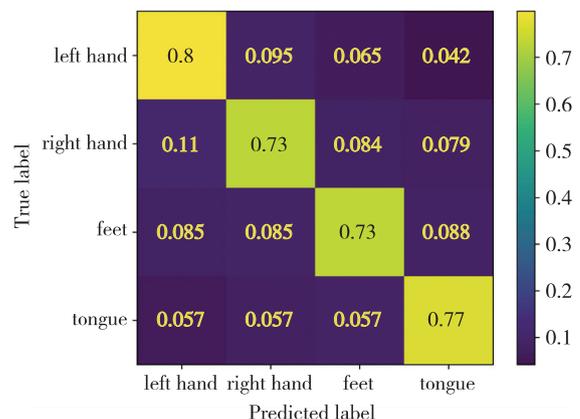


图 4 EEGNet 对 BCI IV-2a 的平均混淆矩阵

Fig. 4 Average confusion matrix of EEGNet for BCI IV-2a

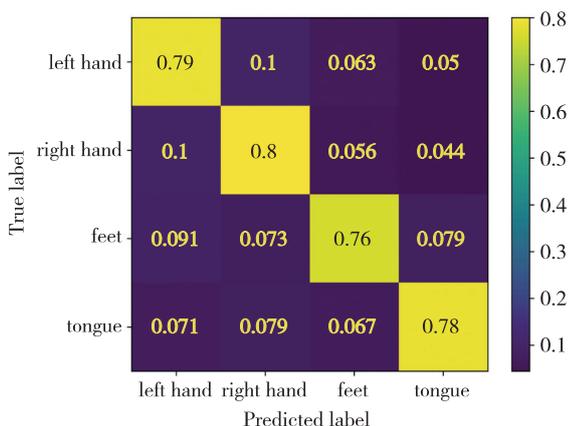


图 5 EEG-TCNet 对 BCI IV-2a 平均混淆矩阵

Fig. 5 Average confusion matrix of EEG-TCNet for BCI IV-2a

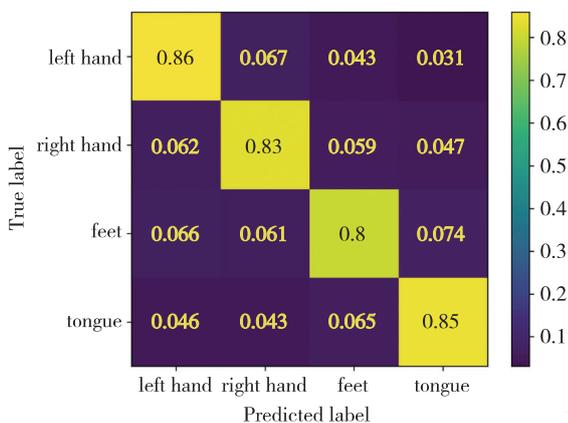


图 6 改进的 EEG-TCNet 对 BCI IV-2a 的平均混淆矩阵

Fig. 6 Average confusion matrix of improved EEG-TCNet for BCI IV-2a

3.4 滑动窗口的数量对 MI-EEG 解码性能的影响

滑动窗口的数量决定了增加子序列样本的倍数,为了选择合适的滑动窗口数量设置了不同组实验,实验结果如表 3 所示,增加一个合适的窗口能够增加解码性能,当滑动窗口设置为 4 时,解码性能最优。从表 3 中 $W=1$ 可以看出,未对子序列进行分割,只增加多尺度的网络结构也能提升解码精度。

表 3 滑动窗口的数量对解码性能的影响

Table 3 Effects of the number of sliding windows on decoding performance

受试者	W						
	1	2	3	4	5	6	7
1	84.34	85.41	86.48	86.83	86.12	86.83	88.26
2	70.32	73.14	75.27	74.91	74.20	75.62	75.62
3	90.84	91.21	92.31	93.04	92.67	92.67	92.67
4	78.95	81.14	80.26	82.02	82.02	80.26	79.82

续表(表3)

受试者	W						
	1	2	3	4	5	6	7
5	80.07	79.35	79.35	79.71	79.35	78.99	76.09
6	68.37	69.77	69.77	71.16	69.77	71.16	73.02
7	91.70	93.50	94.58	94.58	94.95	93.86	94.58
8	84.87	80.81	83.03	84.50	83.39	82.66	82.66
9	83.71	82.20	84.09	83.71	84.09	82.20	81.44
Mean	81.46	81.84	82.79	83.39	82.95	82.69	82.68
St. D.	7.61	7.19	7.37	7.21	7.56	7.02	7.21

3.5 其他方法与结果对比

为了进一步验证所做出改进的 EEG-TCNet 具有更高的解码性能,对比了其他方法对 BCI IV-2a 数据集上的分类准确度,如表 4 所示,优于许多现有的解码方法。

表 4 不同方法的解码性能对比

Table 4 Comparison of decoding performance of different methods

解码方法	准确度($p/\%$)
G-CRAM ^[10]	60.11
DeepCNN ^[13]	70.10
FBCSP ^[15]	73.70
MCNN ^[12]	75.70
MSMFCNN ^[17]	75.80
EEG-TCNet ^[9]	77.35
MS-AMF ^[16]	79.90
TSCNN ^[14]	80.09
改进的 EEG-TCNet	83.39

4 结论

研究针对传统算法无法充分利用原始 MI-EEG 的问题,提出一种样本扩充和多尺度的解码方法。为了保证 MI-EEG 时间序列的完整性,同时又能增加样本数,将 MI-EEG 等间隔下采样为 3 个子序列,每个子序列都含有与原始序列相同的数据特征,使用不同尺度的 EEGNet 对不同的子序列进行特征提取,以便提取不同频段的特征,再将每个子序列采用一种基于卷积滑动的方法进行分割充分挖掘每个子序列潜在的信息,之后将每个分割后的子序列传入到 TCN 中,来进一步地提取特征和降维,最后将每个处理后的子序列进行拼接、平均操作后传入到全连接层进行识别。并进一步验证了使用卷积滑动的方法对 MI-EEG 解码性能的影响,选择一个合适的窗口数量能进一步提升解码准

确度。实验结果表明:在 BCI IV-2a 数据集上,所做出改进的网络结构,相比于 EEG-TCNet 和 EEGNet 分别有 5.19%和 7.7%的提升,也能说明所改进的网络具有更理想的解码性能。后续的研究将传统的机器学习的方法与所改进 EEG-TCNet 相结合,来进一步地提升 MI-EEG 的解码精度。

参考文献(References):

- [1] SHI K, HUANG R, MU F, et al. A novel multimodal human-exoskeleton interface based on EEG and EMG activity for rehabilitation training [C]//Proceedings of the International Conference on Robotics and Automation. Piscataway: IEEE Press, 2022: 8076-8082.
- [2] AHMED I, JEON G, PICCIALI F. From artificial intelligence to explainable artificial intelligence in industry 4.0: a survey on what, how, and where [J]. IEEE Transactions on Industrial Informatics, 2022, 18(8): 5031-5042.
- [3] TARAN S, BAJAJ V. Motor imagery tasks-based EEG signals classification using tunable-Q wavelet transform [J]. Neural Computing and Applications, 2019, 31(11): 6925-6932.
- [4] KEVRIC J, SUBASI A. Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system[J]. Biomedical Signal Processing and Control, 2017, 31: 398-406.
- [5] LOTTE F, GUAN C. Regularizing common spatial patterns to improve BCI designs: unified theory and new algorithms[J]. IEEE Transactions on Bio-Medical Engineering, 2011, 58(2): 355-362.
- [6] THEJASWINI B M, SATHEESHA T Y, BHAIRANNAWAR S. EEG classification using modified KNN algorithm [C]//Proceedings of the International Conference on Applied Intelligence and Sustainable Computing. Piscataway: IEEE Press, 2023: 1-4.
- [7] 张苒苒, 刘恒. 基于潜在特征重构和注意力机制的人脸图像修复[J]. 重庆工商大学学报(自然科学版), 2023, 40(2): 73-78.
ZHANG Tong-tong, LIU Heng. Face image restoration based on latent feature reconstruction and attention mechanism[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2023, 40(2): 73-78.
- [8] 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.
- [9] 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 the IEEE International Conference on Systems, Man, and Cybernetics. Piscataway: IEEE Press, 2020: 2958-2965.
- [10] ZHANG D, CHEN K, JIAN D, et al. Motor imagery classification via temporal attention cues of graph embedded EEG signals [J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(9): 2570-2579.
- [11] LIU M, ZENG A, CHEN M, et al. Scinet: Time series modeling and forecasting with sample convolution and interaction [J]. Advances in Neural Information Processing Systems, 2022, 35(35): 5816-5828.
- [12] AMIN S U, ALSULAIMAN M, MUHAMMAD G, et al. DeepLearning for EEG motor imagery classification based on multi-layer CNNs feature fusion[J]. Future Generation Computer Systems, 2019, 101: 542-554.
- [13] SCHIRRMESTER 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.
- [14] 褚亚奇, 朱波, 赵新刚, 等. 基于时空特征学习卷积神经网络的运动想象脑电解码方法[J]. 生物医学工程杂志, 2021, 38(1): 1-9.
CHU Ya-qi, ZHU Bo, ZHAO Xin-gang, et al. Convolutional neural network based on temporal-spatial feature learning for motor imagery electroencephalogram signal decoding [J]. Journal of Biomedical Engineering, 2021, 38(1): 1-9.
- [15] HERSCHE M, RELLSTAB T, SCHIAVONE P D, et al. Fast and accurate multiclass inference for MI-BCIs using large multiscale temporal and spectral features[C]//Proceedings of the 2018 26th European Signal Processing Conference. Piscataway: IEEE Press, 2018: 1690-1694.
- [16] LI D, XU J, WANG J, et al. A multi-scale fusion convolutional neural network based on attention mechanism for the visualization analysis of EEG signals decoding[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering: a Publication of the IEEE Engineering in Medicine and Biology Society, 2020, 28(12): 2615-2626.
- [17] WU H, NIU Y, LI F, et al. A parallel multiscale filter bank convolutional neural networks for motor imagery EEG classification [J]. Frontiers in Neuroscience, 2019, 13: 1275.

责任编辑:代小红