光电技术及应用

DOI：10.16818/j.issn1001－5868.2023090601

基于维度注意力与多尺度卷积网络的脑电分类方法研究

谷学静[1,2]，杨赵辉[1,2*]，郭宇承[2,3]，许金钢[1]

（1. 华北理工大学 电气工程学院，河北 唐山 063210；2. 唐山市数字媒体工程技术研究中心，河北 唐山 063000；
3. 华北理工大学 机械工程学院，河北 唐山 063210）

摘　要： 针对脑电信号的非平稳性、时变复杂和分类准确率较低的问题，以及传统机器学习方法在提取复杂特征方面的不足，提出了一种基于维度注意力机制的多尺度时空卷积神经网络分类模型（DIMS-CNN），旨在提高分类准确率，以更好地适用于实际应用场景。首先，对数据进行带通滤波和去伪迹，并进行了降采样和通道选择等预处理；随后，将经过处理的数据输入构建的时空卷积模型中，为了进一步增强网络的特征提取能力，加入了时序和通道的多维度注意力机制以及正则化技术；对于数据量不足的问题，采用了频带互换的方法进行数据增强，且提高了模型的泛化性能。分别在HGD数据集和实验室自采集数据集上进行验证，获得了90.97％和90.21％的平均分类准确率，发现所提方法在分类准确率上有显著提高。

关键词： 脑电信号；深度学习；卷积网络；注意力机制；频带互换

中图分类号： TN911.73　**文章编号：** 1001－5868(2024)01－0152－07

EEG Classification Based on Dimensional Attention and Multi-scale Convolutional Networks

GU Xuejing[1,2], YANG Zhaohui[1,2], GUO Yucheng[2,3], XU Jingang[1]

(1. College of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, CHN;
2. Tangshan Digital Media Engineering Technology Research Center, Tangshan 063000, CHN;
3. College of Mechanical Engineering, North China University of Science and Technology, Tangshan 063210, CHN)

Abstract: This study proposes a spatio-temporal dynamic multiscale convolutional neural network (DMS-CNN) classification model based on a dimensional attention mechanism to improve classification accuracy and applicability to practical scenarios, in order to address the problems of non-stationarity, time-varying complexity, and low classification accuracy of electroencephalogram (EEG) signals, as well as the shortcomings of traditional machine learning methods in extracting complex features. First, the data are bandpass-filtered to eliminate artifacts and pre-processed using downsampling and channel selection. The processed data are then input into the constructed spatiotemporal convolution model, to further enhance the feature extraction capability of the network and multidimensional attention mechanisms of timing. This is followed by the incorporation of channel and regularization technology. To address the problem of insufficient data, a frequency-band exchange method is used to enhance the data, thereby improving the generalization performance of the model. Average classification accuracies of 90.97％ and 90.21％ were obtained for the HGD and self-collected laboratory datasets, respectively. Compared with other algorithms, the classification accuracy of this method was significantly

收稿日期：2023－09－06.

基金项目：河北省自然科学基金高端钢铁冶金联合研究基金专项项目(F2017209120)；唐山市沉浸式虚拟环境基础创新团队项目(18130221A).

* **通信作者：**杨赵辉

improved.

Key words：EEG；deep learning；CNN；attention mechanism；band interchange

0　引言

脑机接口(Brain-Computer Interface，BCI)是一种使大脑能够与外部设备直接进行信息交互的技术，将人脑与外部设备紧密连接在一起[1]。BCI 作为一门新兴的跨学科领域，受到了越来越多的关注[2]。其中，运动想象脑电信号(Motor imagery Electroencephalogram，MI-EEG)已成为脑机接口(BCI)领域中备受关注的重要范式之一[3]。

由于运动想象脑电信号(MI-EEG)的非平稳性、非线性、非周期性和时变复杂等特点[4]，因此选取有效的特征提取算法和分类算法是解决当前问题的关键。当前机器学习特征提取算法主要是通过提取信号的时频域特征、空域特征以及非线性特征来实现[5]。时频域特征的提取算法主要有小波包变换、快速傅里叶变换和 S 变换等，共空间模式以及各种改良版的共空间模式是现在主要的空域特征提取方法，非线性特征的提取主要利用微分熵、排列熵和模糊熵等信息熵方法；提取特征之后的分类算法主要包括支持向量机、随机森林和 K 近邻等。虽然传统机器学习方法在脑电信号特征提取与分类方面取得了不错的成效，但是其局限性是需要丰富的先验知识且时间复杂度高，不适用于对实时性要求较高的外部应用控制[6]。

随着深度学习网络在图像处理和计算机视觉方面的快速发展，研究者开始将深度学习方法应用到脑电信号分类处理中[7]。深度学习的主要特点是采用端到端模式，可以减少预处理的难度和省略人工提取特征的过程，在网络中将提取特征与分类过程融到一起，在一定程度上简化过程与降低时间复杂度，提高实时性能。在小样本数据集分类方面，许学添等[8]提出了一种基于时空特征的卷积网络，该网络能够自主学习时空滤波器的参数，以提取有价值的多路信号时空特征，这为解决小样本问题提供了一个有效的方法。Wang 等[9]在原有的 EEGNet 基础上引入了特征图嵌入的方法，以提高网络对原始脑电信号的解码能力，通过这种改进，成功地提高了分类准确率。Song 等[10]使用动态图卷积神经网络(DGCNN)对 SEED 数据特征进行二次特征提取与分类，最终达到 90.40%的准确率，但跨被试准确率为 79.00%，该模型泛化能力有待提高。李红利等[11]提出的时间序列增强与多尺度特征提取方法提高了模型的鲁棒性。这个方法允许在不改变时序长度的情况下增加训练数据量，从而更好地适应不同的情况。Han 等[12]的并行卷积神经网络(PCNN)结构展示了一种多层次的特征提取方法，通过引入三种不同的卷积核子模型，优化了模型性能。

鉴于深度学习算法在脑电特征分类中的卓越效果，本文提出一种基于维度注意力机制的多尺度时空卷积神经网络分类模型(DIMS-CNN)到运动想象脑电信号分类中，并使用频带互换的方法进行训练数据增强，提高了模型的泛化性能和降低模型过拟合风险，本网络的特点是网络轻量化，具有较好的实时性，在 HGD 数据集和实验室自采集数据集上进行验证。

1　实验数据与预处理

本实验采用 HGD 数据集和实验室自采集数据集来验证本文模型的有效性。

1.1　HGD 数据集

所用的 HGD[13]数据集包括 128 个通道，记录了 14 位受试者进行运动想象时的脑电信号，包含 4 种不同类型的运动想象任务：想象左手运动、想象右手运动、想象双脚运动以及休息状态(无运动)，数据采样率为 500 Hz。该数据集的每个被试都进行了 13 次采集，而每次采集包括 80 次实验。因此，每个被试总共采集了 1 040 次实验数据。在每次实验中，从−0.5～4 s 的时间段被选取，以供模型的训练和测试使用。通常，实验的前 11 次(共 880 次实验)被分配为训练集，而最后的 2 次实验(共 160 次实验)则用作验证集[14]。

1.2　自采集数据集

该数据集实验设备采用 Neuroscan 脑电采集分析系统作为信号采集设备，整个系统由 SynAmps2/RT 放大器、64 通道电极帽、Curry7 分析软件及两台计算机组成，其中两台计算机分别用来记录大脑皮层生物电和呈现刺激材料。该实验选择了 2 名男性 Y1 与 L2，1 名女性被试 S3，均为右利手且具备正常的视力。实验采集 64 通道实验数据，采样频率

为 500 Hz。每名被试采集 23 次实验，每次实验包括随机进行想象左手运动、想象右手运动、想象双脚运动和想象舌部运动任务，每种任务 10 次，共 920 次实验，其中前 19 次做训练模型，后 4 次用作模型测试。每次实验进行 8 s，当 $t=1$ s 时给予声音刺激开始实验，并在屏幕出现十字提示；当 $t=2$ s 时开始进行运动想象，依照屏幕随机出现的图像进行想象，实验范式如图 1 所示。

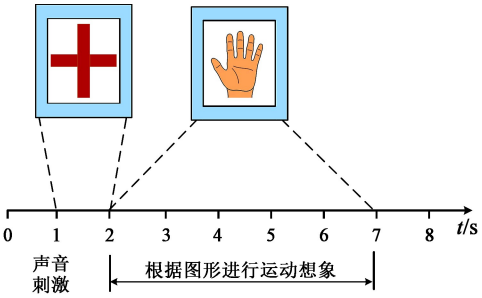


图 1 自采集 BCI 实验范式

1.3 实验预处理

运动想象分类识别前，要对数据进行预处理，旨在提高信号质量以便更好地支持后续分析任务。首先，在通道选择方面，我们采用了包含 44 个电极通道的数据，这些通道覆盖了与运动皮层相关的脑区，这样可以为后续的深度学习网络提供更多丰富的特征信息。接下来，为了降低计算复杂度和减少冗余信息，将采样率降低至 250 Hz。由于脑电图(EEG)信号中的有用信息主要分布在 8～30 Hz 的频率范围内，因此我们使用巴特沃斯带通滤波器对数据进行 8～30 Hz 滤波。最后，应用独立成分分析(ICA)来去除数据中的噪声和干扰信号，从而进一步提高数据质量。

2 算法

2.1 频段互换数据增强

训练集中充足的数据量可以提升网络训练效果，让网络模型可以提取到更多特征，从而提升最终模型的分类精度。数据增强算法的核心在于能够提高深度网络模型对有限数据的利用率，而无需增加实质数据。它通过原始数据的形态特征构造人工数据，将这些人工数据整合到原始数据中。这一策略的目标是提升模型的泛化能力，同时降低模型的过拟合风险[15]。

使用传统滑动窗口裁剪脑电数据存在特征丢失问题，在一定程度上影响实验效果。对此，本研究提出了一种科学有效的数据增强方法，即频带互换。该方法基于快速傅里叶算法将信号分解为 4 个频率带：8～12 Hz，12～16 Hz，16～24 Hz，24～30 Hz。然后随机交换同标签的两组数据中的任意两个频段，并将它们整合为一组新的数据。图 2 展示了该数据增强方法的详细流程，这种方法有望提高实验结果的准确性。

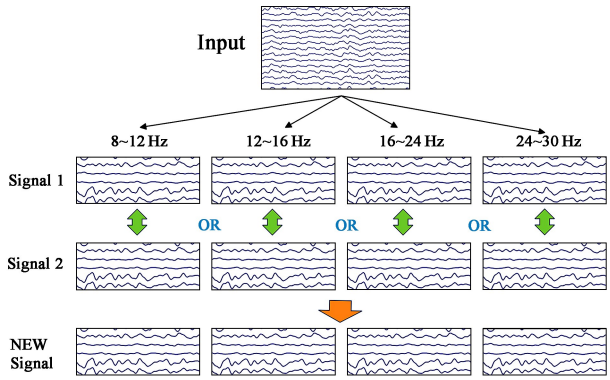


图 2 频带互换模型

2.2 多尺度时序卷积特征提取

多尺度卷积(Multi-Scale Convolution)是卷积网络中的一种特征提取技术，通过在同一卷积层中使用多个不同大小的卷积核来同时捕捉多个尺度的信息，可以更全面地扩大网络感受野，以增强网络对多尺度对象或结构的识别能力。

本文为应对不同脑电信号采集范式的不同时间序列，通过构建 1×64，1×128，1×256 和 1×512 这 4 个不同大小的卷积核来处理运动想象脑电信号的时间序列，这样融合后的特征图包含了来自不同尺度的时序信息，可以得到更多的特征，以增强模型的泛化能力。本文所提的多尺度时序卷积特征提取模型如图 3 所示。

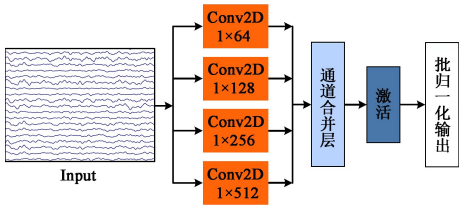


图 3 多尺度时序卷积模块

2.3 维度注意力机制

注意力机制(Attention Mechanism)是深度学习中一种关键的技术，它模拟了人类的注意力机制，在脑电信号中允许模型在处理序列数据任务时更加智能地关注和加权不同部分的信息。其核心思想是根据输入数据的重要性从而动态调整模型的注意

力，使其能够在不同时间步上分配不同的注意力权重。在本文所提的 DIMS-CNN 分类模型中，每一层卷积之后均添加了相应的注意力机制，本文称为维度注意力机制。

1）时序注意力机制

在时序多尺度卷积层之后添加了时序注意力。首先，通过自适应平均池化操作将输入数据中的时间维度进行概括，得到一个全局的时间特征；然后，送入一个小型的全连接层，用于生成每个通道的权重因子。最后，将这些权重因子与原始输入数据加权，以得到经过注意力机制调整后的特征数据。

2）通道注意力机制

在逐通道卷积层和空间卷积层后均添加了通道注意力。首先使用全局平均池化层对输入数据进行空间维度的概括，得到每个通道的全局特征；然后将全局特征传递到一个小型全连接层中以生成每个通道的权重因子；最后，将这些权重因子应用到原始输入数据的每个通道上，得到通过通道注意力机制调整后的特征数据。

本文模型中运用的维度注意力机制，其主要目的是通过自适应地调整输入数据中的各个序列和通道的权重，以提高有用特征的表示能力，减少噪声对模型的干扰，增强模型对关键信息的关注，减少噪声的影响，从而提高了模型的泛化性能和最终的分类准确率。

2.4　DIMS-CNN 网络模型

本文所提出的 DIMS-CNN 网络模型由频段互换数据增强模块、多尺度特征提取模块、时空特征提取模块，以及全连接层分类模块构成，各模块中包含平均池化层、维度注意力机制与正则化层，如图 4 所示。

多尺度特征提取模块中包含两层卷积，第一层多尺度时序卷积层主要作用是捕捉不同时间尺度下的特征，它通过在不同时间窗口上进行卷积操作，可以识别信号中不同频率和时间范围内的特征；第二层卷积是逐通道卷积层，用于对每个输入通道进行单独的卷积操作，可以有效地减少参数量，降低计算复杂度，同时保留通道之间的特征关系。在时空特征提取模块中的空间卷积层是对上一层输出的特征进行卷积操作，从而提取输入特征中的空间信息和更高级的特征，其后加上批归一化层，可以加速模型训练并提高模型的稳定性。模型中的平均池化层主要是为了减小时间维度的长度来减少参数量，从而降低计算复杂性，并增强模型的平移不变性。正则化层在 DIMS-CNN 模型中的作用是增加模型的稳定性，防止过拟合以及促进模型的收敛，并提高模型的泛化能力，使其更好地适应训练数据，这对于有效地训练深度神经网络非常重要，在网络的最后通过全连接层执行分类任务。

综上所述，本文所提网络的主要特点是网络深度较浅，从而具有较好的实时性，并且该网络的设计也有助于减少过拟合，提高模型泛化性能。

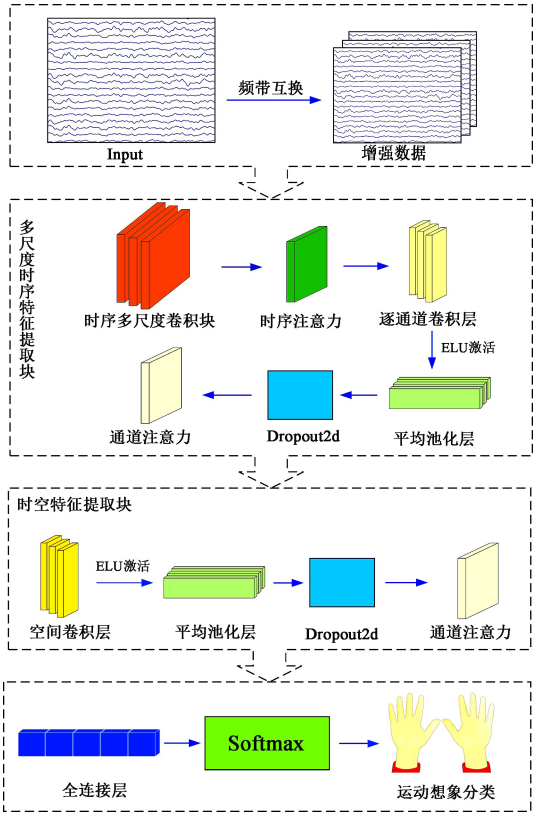


图 4　DIMS-CNN 网络模型

3　结果分析

3.1　环境配置

本文使用所提模型在 HGD 数据集与实验室自采集数据集上对每个被试进行单独的训练和验证。模型运行环境的计算机相关配置如表 1 所示。

表 1　环境配置

类别	详细信息
CPU	Intel(R) Xeon(R) Platinum 8255C CPU@2.50 GHz
GPU	RTX 3080
显存/G	10
内存/G	40
Python	3.9
Pytorch	2.0.0(GPU)
CUDA	11.8

3.2 实验结果

HGD 数据集共有 14 个被试，由于第 14 名被试实验数据不全，故只选择前 13 名被试用作实验结果分析。为评估所提模型的识别性能，以各被试实验的准确率和 Kappa 系数作为评价指标，Kappa 系数可用于一致性检验和衡量分类精度。

本文所提的深度学习分类模型方法在 13 名被试上的分类准确率和 Kappa 系数值如图 5 和图 6 所示，13 名被试的平均分类准确率达到 90.97%，可知能取得较好的分类效果，其中个别被试效果略差，主要原因是脑电信号采集时干扰较大，样本量不充足，导致无法训练得到最佳特征。

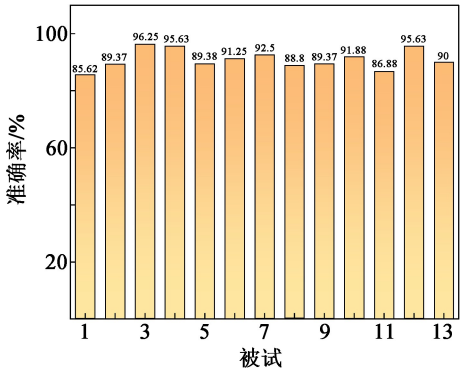


图 5 HGD 数据集 13 名被试分类准确率

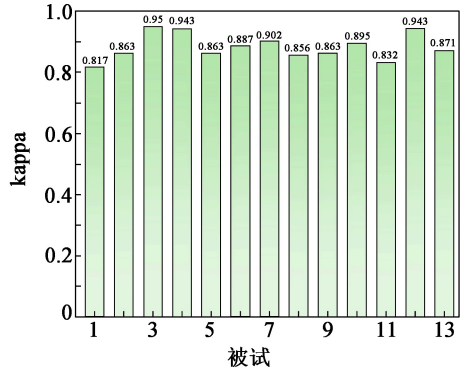


图 6 HGD 数据集 13 名被试 Kappa 值

3.3 消融实验

为研究维度注意力机制和频带交换数据增强在整个模型中的作用，构建了除去维度注意力的网络、除去数据增强的网络以及同时除去注意力机制和数据增强的基础网络 Base_CNN 网络。在同实验环境情况下应用 HGD 数据集进行验证并与本文所提的 DIMS-CNN 网络进行比较，最终结果如图 7 所示。可以看出维度注意力机制和频带交换数据增强算法提高网络分类准确率效果十分显著，且明显看出维度注意力机制在模型中对准确率的提高要强于频带交换模块，展现了提升有效特征权重、减弱不必要和错误特征信息的重要性。

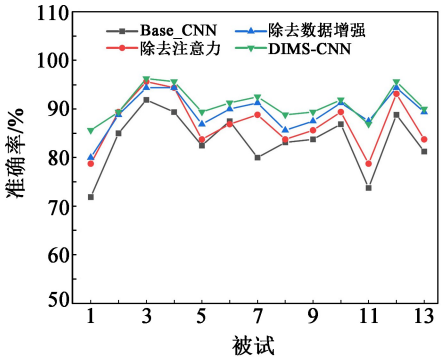


图 7 消融实验结果

3.4 网络模型对比

为验证模型效果，在相同实验环境下将本文模型与 DeepCNN 网络、EEGNet 网络和 Shallow ConvNet 网络进行单被试对比（这里选择 HGD 数据集被试），以分类准确率和 Kappa 系数为评价指标。结果如表 2 所示，可知本文所提模型具有较好的分类效果。

表 2 不同网络模型对比

方法	DeepCNN[16]	EEGNet[17]	Shallow ConvNet[16]	本文模型
准确率/%	90.62	85	91.87	95.63
Kappa	0.879	0.81	0.89	0.943

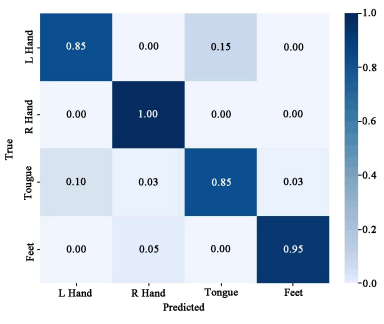
3.5 算法模型稳定性分析

为进一步验证本文所提运动想象脑电信号分类模型的性能，将在实验室自采集的数据集上对本文所提模型进行再次验证，3 个被试所得分类准确率和 Kappa 系数如表 3 所示，可知 3 名被试的准确率均在 90%左右。可见本文所提模型具有很好的稳定性和泛化性能。

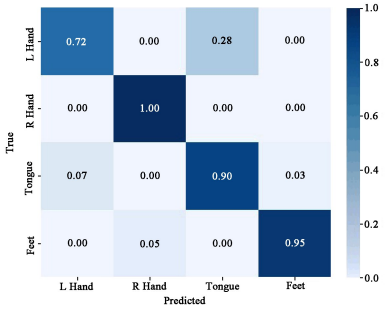
表 3 自采集数据集结果

参数	Y1	L2	S3	平均值
准确率	91.25	89.38	90	90.21
Kappa	0.887	0.863	0.871	0.874

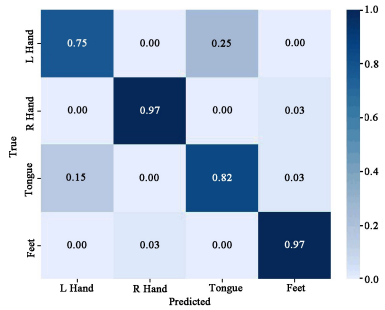
3 名被试在测试数据集上的结果混淆矩阵如图 8所示，可见本文所提的模型在右手、脚部、舌头识别



(a) 被试 Y1



（b）被试 L2



（c）被试 S3

图 8　自采集数据 3 名被试混淆矩阵

效果较好，左手相比其他的识别效果虽略差一些，但仍有不错的效果。综上所述，本文所提模型具有很好的稳定性和泛化性能。

4　结束语

针对运动想象现有问题，本文提出了一种基于维度注意力机制的多尺度时空卷积神经网络分类模型（DIMS-CNN），并针对模型训练过程中脑电数据量不足的问题，采用了频带互换的方法进行数据增强，从而降低模型训练过拟合问题和提高模型的泛化性能。使用 HGD 数据集与实验室自采集数据对模型进行验证，分别得到 90.97％和 90.21％的平均分类准确率。实验表明本文所提方法与其他算法相比，提高了脑电同一区域不同动作的分类准确率，且网络深度较浅，具有轻量化特性，从而具有较好的实时性，能更好地实现运动想象分类的目的。在未来研究中，可以基于现有成果将该方法继续优化，更好的应用于康复设备或其他医疗康复领域中。

参考文献：

[1] 何兴霖，赵　丽，边　琰，等. 基于 BP 神经网络的运动想象脑电信号分类研究[J]. 电子测量技术，2022，45(21)：123-129.
He Xinglin，Zhao Li，Bian Yan，et al. Research on classification of motion image EEG signals based on BP neural network[J]. Electronic Measurement Technology，2022，45(21)：123-129.

[2] 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.

[3] Wang C，Wu Y，Wang C，et al. MI-EEG classification using Shannon complex wavelet and convolutional neural networks [J]. Applied Soft Computing，2022，130：109685.

[4] 谷学静，宋　杨，李　峰，等. 基于小波包融合微分熵的运动想象脑电信号处理[J]. 激光杂志，2022，43(6)：126-130.
Gu Xuejing，Song Yang，Li Feng，et al. Motion imaging EEG signal processing based on wavelet packet fusion differential entropy[J]. Laser J.，2022，43(6)：126-130.

[5] Fan C，Yang H，Hou Z，et al. Bilinear neural network with 3-D attention for brain decoding of motor imagery movements from the human EEG[J]. Cogn. Neurodyn.，2021，15：181-189.

[6] 苏靖然，李秋生. 基于三维特征图和改进 DenseNet 的脑电情绪识别方法[J]. 石河子大学学报（自然科学版），2023，41(3)：381-389.
Su Jingran，Li Qiusheng. EEG emotion recognition method based on 3D feature map and improved DenseNet[J]. J. of Shihezi University（Natural Science Edition），2023，41(3)：381-389.

[7] Khademi Z，Ebrahimi F，Kordy H M. A review of critical challenges in MI-BCI：from conventional to deep learning methods[J]. J. Neurosci Methods，2022，383：109736.

[8] 许学添，蔡跃新. 基于时空特征卷积神经网络的运动想象脑电信号识别方法[J]. 计算机应用与软件，2022，39(10)：71-76.
Xu Xuetian，Cai Yuexin. Motion imaging EEG signal recognition method based on spatiotemporal feature convolutional neural network[J]. Computer Applications and Software，2022，39(10)：71-76.

[9] Wang H，Yu H，Wang H. EEG_GENet：A feature-level graph embedding method for motor imagery classification based on EEG signals[J]. Biocybernet Biomed Eng.，2022，42(3)：1023-1040.

[10] Song T F，Zheng W M，Song P，et al. EEG emotion recognition using dynamical graph convolutional neural networks[J]. IEEE Trans. on Affective Computing，2020，11(3)：532-541.

[11] 李红利，刘浩雨，陈虹宇，等. 基于时间序列数据增强的运动想象脑电多尺度特征提取分类[J]. 生物医学工程学杂志，2023，40(3)：418-425.
Li Hongli，Liu Haoyu，Chen Hongyu，et al. Multi-scale feature extraction and classification of motion image EEG based on time series data enhancement [J]. J. of Biomedical Engineering，2023，40(3)：418-425.

[12] Han Y，Wang B，Luo J，et al. A classification method for

EEG motor imagery signals based on parallel convolutional neural network[J]. Biomed Signal Process Control, 2022, 71: 103190.

[13] Schirrmeister 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] 刘 京, 赵 薇, 董泽浩, 等. 融合多尺度自注意力机制的运动想象信号解析[J]. 计算机科学与探索, 2023, 17(6): 1427-1440.

Liu Jing, Zhao Wei, Dong Zehao, et al. Motion imagination signal analysis with multi-scale self-attention mechanism[J]. J. of Computer Science and Exploration, 2023, 17(6): 1427-1440.

[15] 于子航. 基于深度学习的运动想象脑电信号分类研究[D]. 长春: 吉林大学, 2023.

Yu Zihang. Research on classification of motor imagination EEG signals based on deep learning[D]. Changchun: Jilin University, 2023.

[16] Schirrmeister 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.

[17] Lawhern V J, Solon A J, Waytowich N R, et al. EEGNet: A compact convolutional network for EEG-based brain computer interfaces[J]. J. of Neural Engineering, 2016, 15(5): 056013.1-056013.17.

作者简介:

谷学静(1972—),女,博士,教授,研究方向包括虚拟现实、人机交互,以及脑机接口等。