

DOI:10.3969/j.issn.1003-5060.2026.05.002

一种基于通道图卷积的手势识别框架

张有为, 王青山

(合肥工业大学 数学学院, 安徽 合肥 230601)

摘要:目前基于肌电信号的手势识别工作主要采用图像表示方法,而对图像进行全局特征提取难以捕捉多个通道信号间的相互影响。文章设计一种基于通道图卷积(channel graph convolution, CGC)的手势识别框架,用以挖掘多个通道信号间的关系。首先提出肌电信号的环形图表示,将相邻通道的手势信号有机地联系在一起;然后对环形图进行图卷积提取特征,并通过图的剪枝自适应选取重要特征;最后特征融合,进行手势识别。该框架在2个公开基准数据集 Ninapro DB1 和 Ninapro DB2 上进行了评估,分别取得 84.26% 和 86.42% 的识别准确率,性能达到先进水平。

关键词:手势识别;图神经网络;图卷积;肌电信号;深度学习

中图分类号:TP391.4

文献标志码:A

文章编号:1003-5060(2026)05-0585-06

A gesture recognition framework based on channel graph convolution

ZHANG Youwei, WANG Qingshan

(School of Mathematics, Hefei University of Technology, Hefei 230601, China)

Abstract: Currently, gesture recognition based on electromyography (EMG) signals primarily adopts image representation methods, making it difficult to capture the interactions between multiple channel signals through global feature extraction of images. This paper proposes a gesture recognition framework based on channel graph convolution (CGC), which aims to explore the relationships between multiple channel signals. Firstly, the paper proposes a circular graph representation of EMG signals, organically connecting signals from adjacent channels. Then, it performs graph convolution on the circular graph, and important features are adaptively selected through graph pruning. Finally, it conducts feature fusion for gesture recognition. The framework is evaluated on two publicly available benchmark datasets, Ninapro DB1 and Ninapro DB2, achieving recognition accuracies of 84.26% and 86.42%, respectively, demonstrating state-of-the-art performance.

Key words: gesture recognition; graph neural networks; graph convolution; electromyography (EMG) signals; deep learning (DL)

0 引言

肌电控制是一种通过采集和处理肌电信号来识别身体手势的技术,可实现对假肢、康复辅助器等外围设备的控制,为身体残疾或衰老者提供了改善生活质量的可能性。近年来,人们越来越关注使

用多通道肌电图(electromyography, EMG)信号开发肌电假肢,从EMG信号中获得的与底层肌肉神经活动相关的信息可用于解码目标肢体的运动。一般来说,已开发的用于分类手部运动的方法可分为传统机器学习(machine learning, ML)^[1-4]方法和深度学习(deep learning, DL)^[5-9]技术。

收稿日期:2024-04-17;修回日期:2024-06-13

基金项目:安徽省自然科学基金资助项目(2208085MF165)

作者简介:张有为(1995—),男,安徽六安人,合肥工业大学硕士生;

王青山(1975—),男,安徽合肥人,博士,合肥工业大学教授,博士生导师,通信作者, E-mail: qswang@hfut.edu.cn.

在机器学习方法中,由人类专家提取时域、频域或时频域^[10]等手工特征,并将其送到 ML 分类器中进行手势识别。然而,特征提取和选择可能会影响整体性能^[2],因此一些研究人员^[11]已经探索并集成了几个经典的特征集,这些特征集提供了 EMG 信号的多视图,以实现更高的手势识别准确性,如文献[4]、文献[12]中利用线性判别分析、支持向量机、随机森林以及主成分分析等不同分类器来增加模型的判别能力,并改善手势识别的性能。

在深度学习方法中,已有研究证明深度学习架构的自动特征提取能够获得更高的分类精度^[13-14]。文献[4]首次提出使用卷积神经网络(convolutional neural network, CNN)进行手势识别任务;另有研究^[10]采用了递归神经网络从 EMG 信号中提取时间特征,将手势识别视为序列建模任务。尽管深度神经网络在使用高密度 EMG 设备的手势识别中实现了高性能,但是其对于稀疏多通道 EMG 的手势识别能力仍然有限^[4,12,15]。

受到图卷积网络(graph convolutional net-

work, GCN)^[16]的启发,本文提出一种基于通道图卷积(channel graph convolution, CGC)的手势识别框架。该框架首先对图表示的肌电信号进行图卷积编码,充分考虑相邻通道之间肌电信号的相互关系;然后进行图剪枝,筛选出重要的通道;最后融合保留的特征用于手势识别。此外,通过实验将该模型与其他机器学习方法及深度学习方法的性能进行比较。

1 数据集及框架设计

通道图卷积 CGC 手势识别框架如图 1 所示。该框架主要由 1 个卷积编码器、2 个 GCN 模块、1 个 TopK 剪枝模块和融合单元组成。首先,EMG 信号通过卷积编码器得到各个通道的编码,根据通道间的相互关系建立所有通道的图表示并得到关系矩阵,通过该关系矩阵进行图卷积以提取特征,这些特征构成一个新的特征图;然后,对该特征图进行剪枝,自适应筛选重要特征,并再次通过图卷积进行特征提取;最后,将所有通道的向量相加,进行全图特征融合,得到手势的最终编码表示,从而实现手势识别。




图 1 通道图卷积 CGC 手势识别框架

1.1 数据集

在本文工作中,使用了 Ninapro 数据库^[3-4]的第 1 个子数据库 Ninapro DB1 和第 2 个子数据库 Ninapro DB2。Ninapro DB1 收集了 8 个手部姿势、12 个手指动作、9 个手腕动作、23 个抓握和功能性动作等 27 个受试者的 52 个手势动作。Ninapro DB2 收集了来自 40 个受试者的 50 个手势动作。

由于传感器直接采集到的原始信号有工频噪声、心电伪迹和运动伪迹等噪声,上述数据集已经

对噪声等进行了初步处理^[3]。

1.2 数据预处理

1) 低通滤波。本文分析了 2 个数据集的频谱,并确定了与运动相关的频带。随机抽取的 1 个动作的 3 个样本频谱分析如图 2 所示。从图 2 可以看出,随着频率接近 0 Hz,信号幅度急剧增加,表明信号中与运动最相关的频率接近 0 Hz。为了公平比较模型的性能,本文参考文献[3]、文献[4]的方法,对信号应用了 1 Hz 的巴特沃斯低通滤波器。




图2 手势信号的频谱图

2) U-Law 归一化。U-Law 归一化对输入信号应用了非线性压缩,特别适用于保持低幅度信号的完整性,公式如下:

$$F(x_i^t) = \text{sign}(x_i^t) \frac{\ln(1 + u |x_i^t|)}{\ln(1 + u)} \quad (1)$$

其中:sign 为符号函数; x_i^t 为第 i 通道在时间 t 的 EMG 信号值; u 是一个超参数,设置为 256。

3) 样本分割。对于肌电控制系统中的连续手势识别,需要将信号按一定窗口大小分割成多个样本。对于 Ninapro DB1 和 Ninapro DB2,本文参考文献[3-4],分别使用 200 ms 和 150 ms 的窗口对样本分割,分割后的样本记为:

$$X = \{x_1, x_2, \dots, x_c, \dots, x_L\}, \\ x_c \in \mathbf{R}^d, 1 \leq c \leq L.$$

其中: L 为信号的通道数; x_c 为第 c 个通道的肌电信号; d 为分割后每个通道在单个时间窗口中采样点的个数,表示向量 x_c 的维度。

1.3 卷积编码器

卷积编码器由 2 个卷积块堆叠而成,每个卷积块由一维卷积、BatchNorm^[17] 和 ReLU^[18] 组成。本文使用了一个 1×3 的卷积核进行一维卷积,步幅为 1,填充为 1。该卷积核通过滑动窗口在不同时间对输入信号进行卷积,捕捉信号在时间维上的运动信息。一维卷积函数 conv 定义如下:

$$\text{conv}(x_c[t_1:t_2]) = w \otimes x_c[t_1:t_2] \quad (2)$$

非线性函数 ReLU 是深度神经网络中常用的激活函数,主要为神经网络引入非线性能力,使得网络具备更强的表示能力,其公式定义如下:

$$\text{ReLU}(x) = \begin{cases} x, & x \geq 0; \\ 0, & \text{其他} \end{cases} \quad (3)$$

每个通道的信号分别通过卷积编码器得到

$$Y = \{y_1, y_2, \dots, y_c, \dots, y_L\}, y_c \in \mathbf{R}^D, 1 \leq c \leq L.$$

1.4 肌电信号的通道图嵌入表示与图卷积

某一个电极采集到的信号,是肌肉中多个运动细胞单元释放的动作电位在皮肤表面呈现的空间上综合叠加的结果^[19]。因此,当前电极处的肌电信号会受到其周围电极信号的影响。为了考虑这种相互影响,采集信号时电极的分布显得尤为重要。

对于本文使用的公开数据集,其电极安排^[20]如下:对于 Ninapro DB1,前 8 个电极在肘关节的前臂周围等距分布,其余 2 个电极被放置在指浅屈肌和指浅伸肌的主要活动点上;对于 Ninapro DB2,增加了 2 个电极,分别放置在肱二头肌和肱三头肌的主要活动点上。在这种电极的分布下,与某个手部动作相关的肌肉所产生的电信号便能够被相关位置的电极采集。

通过观察监测不同类型肌肉主要活动点的电极分布发现,若将所有电极投影到手臂的横切面上,则它们的排列呈现近似均匀的环形结构。这种环形结构能够描述邻近位置电极处信号的相互影响关系。

因此,本文将经过卷积编码器出来的通道信号表示为 $G=(Y, A)$,其中 Y 为顶点的集合, A 为表示图的邻接矩阵。 $y_c \in Y$ 定义为图 G 的一个顶点, $A_{ij} = \{y_i, y_j\}$ 表示为连接顶点 y_i 和 y_j 的边。邻接矩阵 A 是一个 $L \times L$ 的矩阵。若 A_{ij} 为 A 中元素,则 $A_{ij}=1$,否则 $A_{ij}=0$ 。本文定义的邻接矩阵如下:

$$A_{ij} = \begin{cases} 1, & |i-j| \bmod L = 1 \text{ 或 } 2; \\ 0, & \text{其他} \end{cases} \quad (4)$$

当通道 i 与 j 相邻或间隔 1 个通道时,通道 i 与通道 j 之间被定义一条边,即当前电极信号所代表的顶点仅与最近的 2 个电极信号所代表的顶点具有连接的边,如图 1 的 GCN Block1 中所示。在进行特征提取时,由于每个通道仅考虑与相邻的 4 个通道进行计算,这点由通道图卷积来实现,其层间传播规则如下:

$$\mathbf{H}^{(l+1)} = \sigma\left(\tilde{\mathbf{P}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{P}}^{-\frac{1}{2}} \mathbf{H}^{(l)} \mathbf{W}^{(l)}\right) \quad (5)$$

其中: $\sigma(\cdot)$ 表示激活函数,这里采用的是非线性函数 ReLU; $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N$,为添加了自连接的无向图 $\mathbf{G}$ 的邻接矩阵, $\mathbf{I}_N$ 为单位矩阵; $\tilde{\mathbf{P}}_{ii} = \sum_j \tilde{\mathbf{A}}_{ij}$; $\mathbf{W}^{(l)} \in \mathbf{R}^{D \times D}$ 为可训练权重矩阵; $\mathbf{H}^{(l)} \in \mathbf{R}^{L \times D}$ 为第 l 层 L 个顶点的特征矩阵,每个顶点都包含 D 个特征, $\mathbf{H}^{(0)} = \mathbf{Y}$ 。

1.5 TopK 剪枝

池化层是深度学习神经网络中的一种常用层,通常通过某种操作来减少特征图的空间维度,同时保留重要的特征信息。例如,在图像表示中,通常对局部窗口取最大值或者平均值来选取该窗口中的特征。针对本文提出的通道图表示方法,本文设计了 TopK 剪枝的方法来实现从 L 个通道中选取最重要的 k 个通道。

首先,使用一个可训练的投影向量 $\mathbf{p}$ 用于自适应学习重要的通道。给定一个特征向量 $\mathbf{h}_i^{(l)}$ 表示 $\mathbf{H}^{(l)}$ 的第 i 个顶点,其在归一化的投影向量 $\mathbf{p}$ 上的投影是 $z_i = \mathbf{h}_i^{(l)} \mathbf{p} / \|\mathbf{p}\|$,表示顶点 i 的信息量。为了保留原始图中与运动最为相关的信息,选取向量 $\mathbf{z}$ 中前 k 大的数值的下标作为特征选择的依据。具体来说,逐层传播规则定义为:

$$\begin{aligned} \mathbf{z} &= \mathbf{H}^{(l)} \mathbf{p} / \|\mathbf{p}\|, \\ i_{dx} &= \text{rank}(\mathbf{z}, k) \\ \tilde{\mathbf{z}} &= \text{sigmoid}(\mathbf{z}(i_{dx})) \\ \tilde{\mathbf{H}}^{(l)} &= \mathbf{H}^{(l)}(i_{dx}, :) \\ \mathbf{A}^{(l+1)} &= \mathbf{A}^{(l)}(i_{dx}, i_{dx}) \\ \mathbf{H}^{(l+1)} &= \tilde{\mathbf{H}}^{(l)} \odot (\tilde{\mathbf{z}} \mathbf{1}_D^T) \end{aligned} \quad (6)$$

其中: k 为新图中选择的顶点数量; $\mathbf{1}_D \in \mathbf{R}^D$ 是大小为 D 的向量,所有分量都为 1; $\odot$ 表示按元素进行矩阵乘法。 $\text{rank}(\mathbf{z}, k)$ 表示先对顶点进行由大到小的排序,表示通道的重要程度,然后返回 $\mathbf{z}$ 中前 k 大值的索引,这个索引就是新图顶点的索引;然后利用这个索引对新图和邻接矩阵进行提取,也就是 $\mathbf{A}^{(l)}(i_{dx}, i_{dx})$ 和 $\mathbf{H}^{(l)}(i_{dx}, :)$; $\mathbf{z}(i_{dx})$ 提取具有索引 i_{dx} 的 $\mathbf{z}$ 中的值,再使用 sigmoid 激活函数引入非线性。

1.6 特征融合与分类

将经过 GCN Block2 得到的多个通道信号通过加法进行特征融合,得到输入肌电信号的最终表示 $\mathbf{x}' \in \mathbf{R}^D$;然后通过 Linear&Softmax 层获得概率分布输出,进行分类。设 C 为手势类别数量,将 Linear 的输出记为 $\mathbf{y}' = (y_1', y_2', \dots, y_C')$,即

$$\mathbf{y}' = \mathbf{W}^T \mathbf{x}' + \mathbf{b} \quad (7)$$

其中: $\mathbf{W} \in \mathbf{R}^{D \times C}$; $\mathbf{b}$ 为偏置项。Linear 层用于将信号的维度映射为手势类别的数量。将 Softmax 的输出记为 $\mathbf{p} = (p_1, p_2, \dots, p_C)$,即

$$p_j = \frac{e^{y_j'}}{\sum_{i=1}^C e^{y_i'}}, \quad 1 \leq j \leq C \quad (8)$$

Softmax 在这里主要通过归一化的手段将向量的每个数值转化为概率值。

2 实验与结果

本节对所提出的 CGC 手势识别框架进行性能评价,具体包括训练与评估指标、窗口大小对 CGC 性能的影响、不同模块对 CGC 性能的影响、CGC 与其他模型性能的对比。

2.1 训练与评估指标

分类过程包括预处理、窗口化、特征提取和分类。大约 1/3 的运动重复用于创建测试集(对于 NinaPro DB1 为重复 2、5、7,对于 NinaPro DB2 为重复 2、5),而其余的重复用于创建训练集。框架训练是在 i5 12400F, 32 GiB RAM, NVIDIA RTX 3060 下通过 PyTorch 完成的,训练模型用 Adam 作为优化器,优化器学习率设置为 0.001,训练的迭代次数设置为 256,批次大小为 64。

本文使用的评估指标定义为每个实验中正确分类的区段数与测试区段总数之间的比率。

2.2 窗口大小对 CGC 性能的影响

本文采用 5 种不同的窗口大小进行实验,分别为 100、150、200、250、300 ms,以 10 ms 的固定步长分割样本。对随机选择的 6 位受试者进行实验,结果如图 3 所示。




图 3 窗口大小对识别准确率的影响

从图3可以看出:随着窗口大小从100 ms增加到300 ms, Ninapro DB1 的识别准确率呈现出平稳的变化趋势,而 Ninapro DB2 的识别准确率则呈现出总体上升的趋势;对于 Ninapro DB1,每个个体的最高与最低最优识别准确率之间的平均差异为0.02~0.05,而对于 Ninapro DB2,最高识别准确率仅比100 ms窗口上的识别准确率高出0.10。

本研究的一个主要目标是预测截肢者的意图,并将其用于操控一款灵巧、自动供电的假肢手,截肢者能够根据需求以自然、灵活的方式操控假肢。对于肌电控制系统来说,响应时间对假肢的灵活操控至关重要,较短的时间窗口可以提供更多的决策机会,并缩短系统响应时间。结果显示,随着时间窗口的减小,本文方法在较短时间窗口上的性能仅略微下降,这有助于提高肌电控制系统的实时性能。

2.3 不同模块对 CGC 框架性能的影响

本文对 CGC 手势识别框架的2个重要模块进行了消融实验。

首先,为了探究本文提出的框架中 CGC 的影响,将完整模型的性能与删除 CGC 的变体在2个基准数据集上进行比较。随机选择另外6名受试者进行实验,结果如图4所示。从图4可以看出,没有 CGC 模块的框架识别准确率下降了0.03~0.05,说明 CGC 能够有效地捕捉到不同通道手势信号之间的关系。




图4 不同模块对 CGC 性能的影响

其次,为了评估模型中 TopK 剪枝的影响,将完整模型的性能与将其替换为期货激活函数的变体进行比较。本文应用了2个不同的非线性激活函数,即 ReLU 和 LeakyReLU,如图4所示,可以观察到,当替换了 TopK 剪枝模块后,所有受试者的识别准确率都下降了约0.03。这一结果表明,TopK 剪枝可以捕捉来自稀疏通道的肌电信号变化模式,过滤掉不重要的通道特征,从而有效提高

模型性能。

2.4 CGC 框架与其他模型性能的对比

本文将提出的 CGC 手势识别框架模型与手势识别中现有的基于图像表示的机器学习和深度学习模型进行性能比较,结果见表1所列。

表1 不同模型的性能比较

模型	数据集	手势类别数量	受试者人数	识别准确率/%
文献[4]CNN	Ninapro DB1	52	27	66.59
文献[10]LSTM	Ninapro DB1	52	27	75.45
文献[15]ALCNet	Ninapro DB1	52	27	81.80
文献[12]CNN	Ninapro DB2	49	40	78.71
文献[21]ML	Ninapro DB2	11	40	81.93
文献[22]CviT	Ninapro DB2	49	40	80.02
本文 CGC	Ninapro DB1	52	27	84.26
本文 CGC	Ninapro DB2	11	40	88.70
本文 CGC	Ninapro DB2	49	40	86.42

Ninapro DB1 数据集上,传统的 CNN 模型的识别准确率为66.59%,LSTM 模型的平均识别准确率为75.45%,而 ALCNet 模型的平均识别准确率达到81.80%;相较之下,本文 CGC 模型的识别准确率达到84.26%,比传统的 CNN 和 LSTM 分别提高了17%和9%。在 Ninapro DB2 数据集上,基于机器学习方法的模型获得了81.93%的识别准确率,基于深度学习方法的 CNN 和 CviT 模型分别获得了78.71%和80.02%的识别准确率;而 CGC 模型的识别准确率比机器学习方法提高了约7%,比模型深度学习方法提高了约6%。结果表明,CGC 模型是一种有效的手势识别方法,并在 Ninapro DB1 和 Ninapro DB2 上表现出了优异的性能。

3 结 论

本文提出了一种新颖的手势信号通道图表示方法,并提出了用于手势识别的 CGC 框架。该框架能够在通道图上图卷积进行特征提取,并通过 TopK 剪枝捕捉重要的通道特征。在2个公开数据集 Ninapro DB1 和 Ninapro DB2 上的实验结果说明,相较于现有模型,该框架在手势识别任务上能取得更高的准确率。但本文还没有探讨手势识别的响应时间及其他电极排列方式对模型性能的影响,这些将在未来工作中进行研究。

[参 考 文 献]

[1] ESPOSITO D, RICCIARDI C, VINCI G, et al. A piezoresistive

- array armband with reduced number of sensors for hand gesture recognition[J]. *Frontiers Neurorobot*, 2020, 13: 114.
- [2] TAVAKOLI M, BENUSSI C, ALHAIS LOPES P, et al. Robust hand gesture recognition with a double channel surface EMG wearable armband and SVM classifier[J]. *Biomedical Signal Processing and Control*, 2018, 46: 121-130.
- [3] ATZORI M, GIJSBERTS A, CASTELLINI C, et al. Electromyography data for non-invasive naturally-controlled robotic hand prostheses[J]. *Scientific Data*, 2014, 1: 140053.
- [4] ATZORI M, COGNOLATO M, MÜLLER H. Deep learning with convolutional neural networks applied to electromyography data: a resource for the classification of movements for prosthetic hands[J]. *Frontiers Neurorobot*, 2016, 10: 9.
- [5] TONG L, ZHANG M, MA H, et al. sEMG-based gesture recognition method for coal mine inspection manipulator using multistream CNN[J]. *IEEE Sensors Journal*, 2023, 23(10): 11082-11090.
- [6] BOTROS F S, PHINYOMARK A, SCHEME E J. Electromyography-based gesture recognition: is it time to change focus from the forearm to the wrist? [J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(1): 174-184.
- [7] ZABIHI S, RAHIMIAN E, ASIF A, et al. TraHGR: transformer for hand gesture recognition via electromyography[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31: 4211-4224.
- [8] ZOU Y, CHENG L. A transfer learning model for gesture recognition based on the deep features extracted by CNN[J]. *IEEE Transactions on Artificial Intelligence*, 2021, 2(5): 447-458.
- [9] RAHIMIAN E, ZABIHI S, ASIF A, et al. FS-HGR: few-shot learning for hand gesture recognition via electromyography[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021, 29: 1004-1015.
- [10] HU Y, WONG Y, WEI W, et al. A novel attention-based hybrid CNN-RNN architecture for sEMG-based gesture recognition[J]. *PLoS ONE*, 2018, 13(10): e0206049.
- [11] WEI W, DAI Q, WONG Y, et al. Surface-electromyography-based gesture recognition by multi-view deep learning[J]. *IEEE Transactions on Biomedical Engineering*, 2019, 66(10): 2964-2973.
- [12] ZHAI X L, JELFS B, CHAN R H M, et al. Self-recalibrating surface EMG pattern recognition for neuroprosthesis control based on convolutional neural network[J]. *Frontiers in Neuroscience*, 2017, 11: 379.
- [13] GENG W, DU Y, JIN W, et al. Gesture recognition by instantaneous surface EMG images[J]. *Scientific Reports*, 2016, 6(1): 36571.
- [14] WEI W, WONG Y, DU Y, et al. A multi-stream convolutional neural network for sEMG-based gesture recognition in muscle-computer interface[J]. *Pattern Recognition Letters*, 2019, 119: 131-138.
- [15] WANG L, FU J, ZHENG B, et al. Research on sEMG-based gesture recognition using the attention-based LSTM-CNN with stationary wavelet packet transform [C]//*Proceedings of the 2022 4th International Conference on Advances in Computer Technology, Information Science and Communications*. [S. l.]: IEEE, 2022: 1-6.
- [16] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. *IEEE Transactions on Neural Networks*, 2009, 20(1): 61-80.
- [17] SEGU M, TONIONI A, TOMBARI F. Batch normalization embeddings for deep domain generalization[J]. *Pattern Recognition*, 2023, 135: 109-115.
- [18] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[C]//*Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*. [S. l.]: IEEE, 2011: 315-323.
- [19] CARBONARO M, MEIBURGER K M, SEONI S, et al. Physical and electrophysiological motor unit characteristics are revealed with simultaneous high-density electromyography and ultrafast ultrasound imaging[J]. *Scientific Reports*, 2022, 12: 8855.
- [20] GIJSBERTS A, ATZORI M, CASTELLINI C, et al. Movement error rate for evaluation of machine learning methods for sEMG-based hand movement classification[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2014, 22(4): 735-744.
- [21] XIONG D, ZHANG D, ZHAO X, et al. Learning non-euclidean representations with SPD manifold for myoelectric pattern recognition[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, 30: 1514-1524.
- [22] SHEN S, WANG X, MAO F, et al. Movements classification through sEMG with convolutional vision transformer and stacking ensemble learning[J]. *IEEE Sensors Journal*, 2022, 22(13): 13318-13325.

(责任编辑 胡亚敏)