

DOI: 10.19650/j.cnki.cjsi.J2514762

基于肌电信号的跨被试不变特征运动模式识别*

石欣¹, 黄良文¹, 梁飞¹, 唐佳¹, 秦鹏杰²

(1. 重庆大学自动化学院 重庆 400044; 2. 深圳大学人工智能学院 深圳 518060)

摘要:基于表面肌电信号(sEMG)的下肢运动意图识别技术在人机交互领域(HMI)展现出广阔的应用潜力。然而,由于表面肌电信号固有的个体差异性,被试间肌电特征分布存在显著域偏移,肌电识别系统在跨被试场景下的泛化性仍是难题。故提出一种空间注意力的双流时频卷积网络-门控特征解耦(CSACNN-GFD)方法。网络采用双分支时频输入结构,利用具有空间注意力的多尺度卷积模块捕捉多通道sEMG的空间相关性与时频动态特征,增强运动意图信息提取能力;构建具有互补机制的门控解耦模块,设计解耦损失函数约束特征提取与门控学习,实现深层表示空间下的自适应特征划分,完成运动相关与被试相关信息解耦,利用跨被试不变的运动特征进行模式识别。研究采集了10名受试者的5类常见下肢连续运动肌电数据,在留一被试交叉验证(LOSO)设置下与现有的泛化策略进行运动模式识别对比实验。CSACNN-GFD在新被试上的平均准确率为84.29%,并在公开数据集8类运动中进一步验证,平均准确率73.83%。相比于基线模型平均性能分别提升4.32%和6.55%。结果表明,CSACNN-GFD优于MIXUP、DANN、CORAL、以及DIFEX等对比方法。平均推理时间为9.57ms,具有良好的实时性。该方法提升了跨被试肌电识别系统的泛化性能,有助于人机交互技术的普适化发展。

关键词:肌电信号;深度学习;特征解耦;领域泛化;模式识别

中图分类号: TH70 **文献标识码:** A **国家标准学科分类代码:** 510.40

Cross-subject invariant feature-based pattern recognition using sEMG

Shi Xin¹, Huang Liangwen¹, Liang Fei¹, Tang Jia¹, Qin Pengjie²

(1. School of Automation, Chongqing University, Chongqing 400044, China; 2. School of Artificial Intelligence, Shenzhen University, Shenzhen 518060, China)

Abstract: Surface electromyography (sEMG)-based lower-limb motion intention recognition has been shown to hold broad application potential in the field of human-machine interface (HMI). However, owing to the inherent inter-subject variability of sEMG signals, significant domain shifts exist in feature distributions across subjects, which severely limits the generalization capability of sEMG recognition systems in cross-subject scenarios. To address this issue, a novel method named cross spatial attention-based dual-stream time-frequency convolutional neural network with gate-controlled feature decoupling (CSACNN-GFD) is proposed in this study. The proposed method adopts a dual-branch time-frequency input structure and employs a multi-scale convolution module integrated with spatial attention to capture the spatial correlation and time-frequency dynamic features of multi-channel sEMG signals, thereby enhancing the capability of motion intention information extraction. Furthermore, a gate-controlled feature decoupling module with a complementary mechanism is designed, together with a decoupling loss function to constrain both feature extraction and gate learning processes. This design enables adaptive feature partitioning in the deep representation space, realizing the disentanglement of motion-related features from subject-related features, and further performing pattern recognition using the cross-subject invariant motion features. In the experiments, sEMG data of five common continuous lower-limb movements were collected from ten subjects, and comparative experiments on motion pattern recognition were conducted against existing generalization strategies under the leave-one-subject-out (LOSO) cross-validation setting, with the results showing that the proposed CSACNN-GFD achieves an average accuracy of 84.29% on unseen subjects. Further

收稿日期: 2025-12-10 Received Date: 2025-12-10

* 基金项目: 国家重点研发计划(2023YFB4704000)、国家自然科学基金青年科学基金(62403453)、广东省基础与应用基础研究基金(2025A1515011973)、中国博士后科学基金(2024M76344)项目资助

validation on a public dataset with eight types of movements yields an average accuracy of 73.83%, improving the average performance by 4.32% and 6.55% respectively compared with the baseline models, and outperforming mainstream strategies including MIXUP, DANN, CORAL, and DIFEX. Meanwhile, the inference time of CSACNN-GFD is only 9.57 ms, demonstrating favorable real-time performance. The proposed method effectively enhances the generalization capability of cross-subject sEMG recognition systems, thus contributing to the universalization development of human-machine interaction technologies.

Keywords: sEMG; deep learning; feature decoupling; domain generalization; pattern recognition

0 引言

表面肌电信号(surface electromyography, sEMG)具有无创采集、运动信息丰富以及运动超前等特点。基于sEMG的运动模式识别技术被广泛地运用在康复机器人、外骨骼系统及智能假肢等人机交互系统当中^[1-4]。

以往的研究证明了肌电模式识别系统在已知被试上的有效性^[5-7]。其中基于深度网络的方法可以实现端到端的判别性特征提取和模式分类,这更便捷且性能更好, Sun等^[8]采用残差卷积网络(resnet18, RES18)对下肢10类动作进行分类,并考虑不同的预处理方式,包括滑动窗处理、时域处理、频域处理,最终达到95.34%的分类准确率, Tu等^[9]通过变分模态分解分解,并采用增强阈值算法处理变分模态函数后重建sEMG信号实现去噪处理,送入卷积网络(convolutional neural network, CNN)网络中进行特征提取,最终采用核极限学习机进行下肢运动模式分类,准确率达到95.90%。

然而现有下肢运动意图识别方法普遍具有主体特异性,其泛化能力受限,致使模型在跨被试场景下的识别性能难以得到保障。这是由于不同个体的脂肪组织深度、皮肤阻抗、身体质量指数以及体脂率均存在一定程度的差异,受这些因素的影响,sEMG信号的特征分布会随着不同的受试者而显著变化^[10-11],传统方法难以适配未知被试的信号模式,阻碍了肌电控制系统的推广应用^[12-14]。

近年来学者们针对这类问题提出了不同的解决方案, Jiang等^[15]对比了50种不同的肌电信号特征,通过特征组合的方式寻找鲁棒的特征集,在跨会话场景下,11类手势识别任务中达到91.9%的准确率。肌肉协同理论的研究表明了不同受试者在完成同一类动作时,具有相似的肌肉激活模式^[16-18]。Zhao等^[19]利用主成分分析和非负矩阵分解从预处理的肌电信号中提取协同激活特征,在跨被试条件下预测肘关节角度,预测准确率达到85%。Zhang等^[20]在下肢步态预测任务中提出了一种基于相关分量分析以提取与被试无关的特征,送入随机森林网络以实现鲁棒的运动识别。Fan等^[12]利用双编码器将肌电信号分解为任务特征与个性特征,并利用支持向量机、前馈网络等分类网络在跨被试的6类手势识别任务上取得83.61%准确率。

上述研究表明sEMG信号中往往包含两项耦合信息,一部分是仅与任务相关的,具有跨被试一致性,如肌肉协同激活特征。另一部分为被试内个体特异性信息,源于肌肉解剖结构、发力习惯等差异。为实现鲁棒的下肢运动分类模型,以适应未知个体,其关键目标是提取出具有跨被试不变的运动特征。尽管现有研究已在特征优化与解耦方面取得一定进展,但仍存在亟待解决的局限:现有解耦策略主要集中于高密度肌电图的上肢手势分类任务,且依赖手工提取特征。在针对稀疏多通道系统的下肢运动中,手工特征容易因原始信息丢失而导致特征表示能力不足,进而制约了模型的跨被试鲁棒性。同时现有的编码器-解码器解耦方法引入了额外的重构过程,增加了训练过程复杂性和不稳定性。为此,文章提出一种与深度网络集成的空间注意力双流时频卷积网络-门控特征解耦(cross spatial attention-based dual-stream time-frequency convolutional neural network with gate-controlled feature decoupling, CSACNN-GFD)方法,首先构建空间注意力双流时频卷积网络,采用双分支的时频输入,从肌电信号时域与频域两种互补视角提取深层运动特征表示,进一步提出一种门控特征解耦方法,利用设计的解耦损失和门控机制实现特征维度的动态分配,自适应地选择与运动相关的不变特征信息,解耦的特征在门控机制下具有互补性,避免了额外的重构约束,具有更好的训练稳定性。在自建数据集和公开数据集中进行了实验验证,该方法平均准确率84.29%、73.83%,推理时间9.57 ms,提升了模型在跨被试场景下的分类性能,同时具有良好的实时性。

1 数据预处理

1.1 sEMG 信号采集

研究招募10名健康受试者,共包含8名男性和2名女性,身高1.63~1.85 m,年龄22~30岁,体重50~82 kg。使用由英国Biometrics Ltd.生产的无线sEMG传感器,如图1(a)和(b)所示,采样频率设置为1 000 Hz。从右腿12块肌肉采集数据,包含股二头肌、股外侧肌、腓肠肌外侧、比目鱼肌、股薄肌、股内侧肌、半腱肌、胫骨前肌、半膜肌、股直肌、阔筋膜张肌和内侧腓肠肌。在数据收集之前,每位受试者的皮肤均用酒精擦拭物清洁,以防

止皮肤杂质的干扰。实验场景示意图如图1(c)所示。研究包括5类日常常见的下肢运动:平地行走(land walk, LW)、上坡(ramp ascent, RA)、下坡(ramp descent, RD)、上楼(stair ascent, SA)和下楼(stair descent, SD)。每类动作重复10~20次,以消除不同运动地形物理距离差异造成的样本量不均问题;每组动作完成后休息2~5 min,以适配不同受试者肌肉疲劳耐受度差异,防止疲劳干扰。该实验方案已获深圳大学人体医学伦理委员会批准(PN-202500202),并已获得所有参与者的知情同意。




图1 数据采集系统与实验场景

Fig. 1 Data acquisition system and experimental scenarios

Camargo等^[21]提供的综合下肢生物力学开源数据集包含丰富的运动模式和可穿戴传感器数据,其中10名受试者的肌电数据被用于方法对比验证,共包含11块肌肉,具体为臀中肌、右外斜肌、半腱肌、股薄肌、股二头肌、股直肌、股外侧肌、股内侧肌、比目鱼肌、胫骨前肌、股外侧肌等11块肌肉。对应快速、正常、慢速平地行走(1.45、1.17、0.88 m/s)、上楼、下楼、上坡、下坡、站立等8类运动模式。

1.2 数据预处理

肌电信号的频谱分布在20~500 Hz^[22],为了减少运动伪影和环境干扰,采用20~350 Hz的带通滤波器进行滤波,使用50 Hz陷波滤波器去除工频干扰;根据以往的研究,数据窗长在32~300 ms可以满足实时性要求同时保留数据的有效信息^[23-24],采用增量为50 ms,窗长250 ms的重叠滑窗进行数据分割。分割完成后,对具有多数的运动类别样本进行随机欠采样确保样本均衡。自建数据集中每名被试每类动作保留960份样本,共计48 000个样本对应5类运动模式。公开数据集处理流程一致,样本量不足的运动类别维持原有数据分布。

2 不变运动特征提取方法 CSACNN-GFD

2.1 空间注意力卷积网络 CSACNN

现有研究表明肌电信号频谱中含有丰富的运动信息并具有鲁棒性^[25-26]。时域信号能够揭示肌肉活动的瞬时变化和动态收缩,反应肌电信号中时间序列信息^[27]。为从肌电信号中获得丰富且具备跨被试鲁棒的动作表征信息,构建了空间注意力双流时频卷积网络,采用双分支的时频输入,从时域与频域互补视角提取肌电特征信息。分支一输入原始肌电图,分支二输入短时傅里叶变换(short-time Fourier transform, STFT)后的肌电时频图,设连续信号 $s(t)$,窗函数为 $g(t)$,则信号在时间 τ 处频率 f 上的STFT定义如式(1),其中 $w=2\pi f$,依据文献[23,28]的参数设定,采用32 ms的分析窗口,利用汉宁窗及50%重叠率进行STFT变换,并截断尾部填充数据。

$$STFT(\tau, f) = \int_{-\infty}^{+\infty} s(t) g(t - \tau) e^{-j\omega t} dt \quad (1)$$

网络具体结构如图2所示,在时域分支中采用一维卷积而频域分支采用二维卷积以适配对应数据维度。每一层均采用3类不同大小卷积核以丰富特征信息,同时,多尺度卷积特征经拼接后,通过批归一化(batch normalization, BN)抑制分布偏移、高斯激活函数(Gaussian error linear unit, GELU)引入非线性。考虑到肌电通道对应不同下肢肌肉,蕴含肌群中的空间关系。利用空间注意力机制(cross spatial attention, CSA)分组学习的方式,提取不同通道和不同尺度之间的空间特征信息^[29],从而捕获肌群间的协同关系,为模型提供更丰富的特征聚合。采用自注意力机制强化双支路特征向量之间的作用关系,利用多层感知机(multilayer perceptron, MLP)构建门控激活值 $g_p, g_s \in [0, 1]^k$,在式(14)的约束下完成特征解耦,获取跨被试不变的运动特征进行模式分类,提升模型在新被试上的意图识别性能。

2.2 门控特征解耦方法 GFD

对任意肌电样本 $X_i \in \mathbb{R}^{C \times T}$, C 代表通道数, T 为时间步长,对应运动类别 $y \in Y$ 以及被试 $d \in D$ 。通过特征提取器 f 从肌电信号中获取特征向量 $z = f(x) \in \mathbb{R}^k$, k 为特征向量维度。根据以往的研究, z 中包含运动特征信息 z_p 和个性特征信息 z_s ,若 $I(z_p; Y) \gg I(z_s; Y)$, $I(z_s; D) \gg I(z_p; D)$,则满足运动特征与个性特征相互独立、无冗余关联^[30],其中 $I(\cdot)$ 代表互信息。文章将解耦过程转换为自适应的特征选择问题,即通过动态调整 z 各维度的激活程度实现对特征向量在不同维度上的分配。利用多层感知机和注意力机制设计了可学习的门控解耦模块 $G(\cdot)$,其目的是学习一组门控权重系数 $g_p, g_s \in [0, 1]^k$ 。

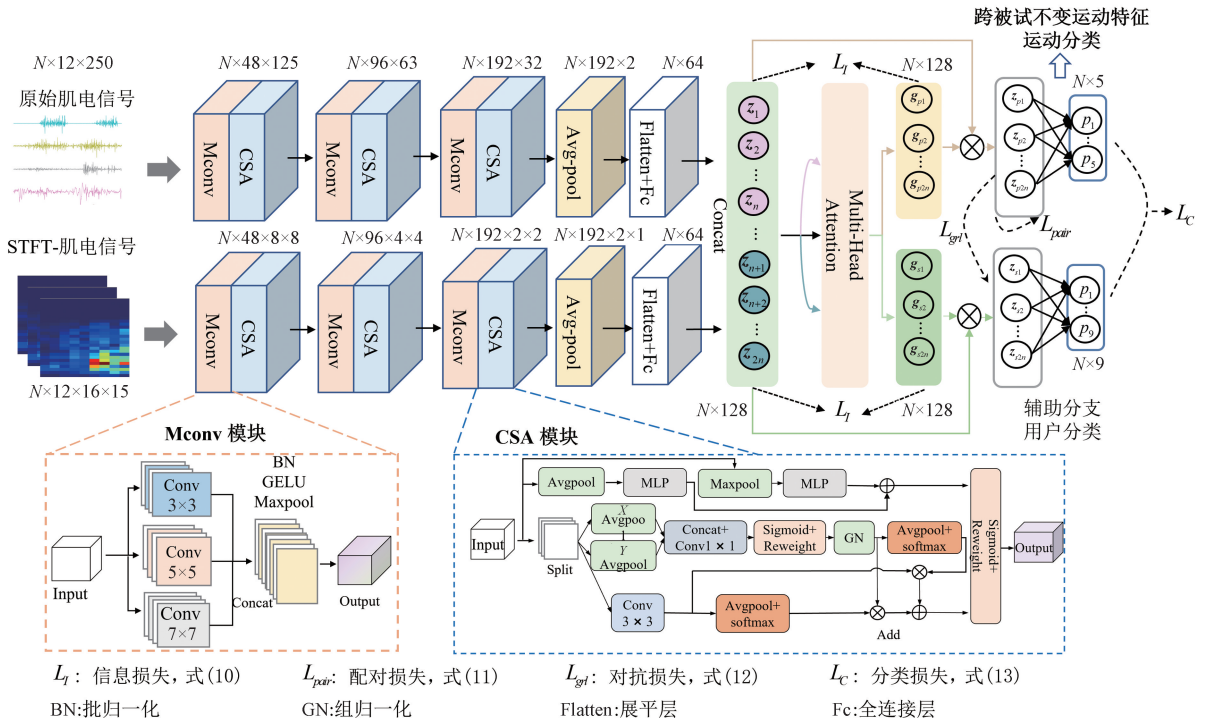


图2 不变运动特征提取方法结构

Fig. 2 Structure diagram of invariant motion feature extraction method

定义解耦后的特征如式(2)所示, \odot 代表点乘。

$$\begin{cases} z_p = z \odot g_p \in \mathbb{R}^k \\ z_s = z \odot g_s \in \mathbb{R}^k \end{cases} \quad (2)$$

式(3)保证了任意维度在动作相关和个体相关的两个分支上所分配的权重和为1,从而实现在特征层面上的动态归属划分, $\sigma(\cdot)$ 为sigmoid激活函数, z_1 和 z_2 对应时频两条支路特征。

$$\begin{cases} g_p = \sigma \left(\frac{((W_1(z_1) + b_1) \odot (W_2(z_2) + b_2))}{\sqrt{d_k}} \right) \\ (W_3(z) + b_3) \\ g_s = 1 - g_p \end{cases} \quad (3)$$

若解耦后的特征 z_p 保留了 z 中的运动信息,则满足式(4),即:

$$I(z_p; Y) \approx I(z; Y) \quad (4)$$

定义互信息差值为 Δ 如式(5)所示。

$$\Delta = I(z_p; Y) - I(z; Y) = H(Y|z_p) - H(Y|z) \quad (5)$$

展开式(5)可得:

$$\Delta = \sum_{z,y} p(z,y) \log(p(y|z)) - \sum_{z_p,y} p(z_p,y) \log(p(y|z_p)) \quad (6)$$

对于任意离散概率分布 P 和 Q ,其相对熵 KL 散度 (Kullback-Leibler divergence) 如式(7)所示,它反应分布

之间的差异性。

$$D_{KL}(P \parallel Q) = \sum_{x \in X} P(x) \log \left(\frac{P(x)}{Q(x)} \right) \quad (7)$$

对于 $z_p = G(z)$,其中 $G(\cdot)$ 取决于门控参数,结合式(6)和(7),互信息差值 Δ 可转换为式(8),即:

$$\Delta = E_z [D_{KL}(p(y|z) \parallel p(y|z_p))] \quad (8)$$

则利用 KL 散度构建信息损失 L_I ,如式(9)所示。

$$L_I = E_z [D_{KL}(P(y|z) \parallel P(y|z_p)) + D_{KL}(P(d|z) \parallel P(d|z_s))] \quad (9)$$

构建运动分类器 f_p ,辅助分类器 f_s 以估计概率分布 $P(\cdot)$,在批次训练中估计信息损失 L_I ,式(10)等价于式(9)。通过最小化 L_I 来确保 z_p 不丢失类别信息而 z_s 不丢失个性信息。

$$L_I = E_z \left[f_p(z) \log \frac{f_p(z)}{f_p(z_p)} + f_s(z) \log \frac{f_s(z)}{f_s(z_s)} \right] \quad (10)$$

为确保解耦后运动特征具有跨被试不变性,在同一个批次内,选取样本对 x_c^i, x_c^j ,对应解耦的运动特征 z_p^i, z_p^j 以及个性特征 z_s^i, z_s^j 。通过对比学习的方式强化跨被试同类动作特征的一致性^[31],如式(11)所示。

$$L_{pair} = -\frac{1}{N} \sum_{i=1}^N \log \left(\frac{\sum_{j \in \mathcal{P}(i)} \exp(s_{ij}/\gamma)}{\sum_{j \in \mathcal{N}(i)} \exp(s_{ij}/\gamma)} \right) \quad (11)$$

其中, s_{ij} 为动作特征 z_p^i 和 z_p^j 的余弦相似度。 $\mathcal{P}(i)$

代表样本 x_c^i 的同类集合, $\mathcal{N}(i)$ 为对比类集合, γ 控制类内的聚集程度。

同时 z_p 被送入辅助分类器, 通过梯度反转层 (gradient reversal layer, GRL) 迫使辅助分类器无法利用 z_p 识别被试, 确保运动特征不包含个性信息^[32]。

$$L_{grl} = -\frac{1}{N} \sum_{i=1}^N \left[\sum_{k=1}^D d_k \log(f_s(GRL(z_p^i))) \right] \quad (12)$$

式中: N 为批次大小; D 为被试数量。

通过上述损失约束完成特征解耦过程, 确保从 z 中分解出非冗余且跨被试不变的运动特征 z_p 、个性特征 z_s 。构建有监督的运动分类和辅助用户分类两项任务, 利用交叉熵 L_{CE} 构建分类损失 L_c 以确保特征在分类任务上的判别性, 其中 β 取 0.1 作为辅助分支。

可以注意到, 解耦的特征是互补的, 可以便捷地进行重组。对任意动作特征和个性特征进行交叉重组完成运动分类训练。该过程一方面确保了运动分类任务仅依赖于动作特征 z_p , 减少个性信息中所携带的运动信息, 这和解耦的目标是一致的。另一方面该过程可作为数据增强的方式, 提供更丰富的数据集合, 以提升模型的泛化性能。

$$L_c = L_{CE}(f_p(z_p^i, z_p^{i+j}); y_i) + \beta L_{CE}(f_s(z_s^i); d_i) \quad (13)$$

最终的损失 L 如式 (14) 所示, 其中, $\lambda_1, \lambda_2, \lambda_3$ 的值分别为 0.6、0.3、0.1。

$$L = L_c + \lambda_1 L_{pair} + \lambda_2 L_{grl} + \lambda_3 L_I \quad (14)$$

3 实验

实验均在 64-bit 的 windows 操作系统上进行, 设备为 13 代 Intel (R) Core (TM) i7-13700H processor) 配备 16 GB 内存和 NVIDIA GTX 4060 显卡。训练采用 Adam 优化器, 批次大小为 128, 初始学习率 0.001 2, 采用带最

小学习率约束的余弦退火学习率调度器, 最小学习率为 0.000 01^[33], 训练 50 个 epoch。采用留一验证策略, 每次选择 1 名被试作为测试集, 剩余 9 名被试作为训练集, 对应十折测试。

3.1 评价指标

文章利用式 (15) ~ (18) 所定义的指标评估模型性能, TP 和 TN 代表模型正确分类的正例数和负例数, 而 FP, FN 代表模型错误分类的正例数和负例数。为了验证性能提升的显著性, 采用 Friedman 进行全局检验以判断方法间的总体差异, 若检验结果显著, 使用单侧 Wilcoxon 符号秩检验进行事后分析, 采用 Holm-Bonferroni 校正, 所有分析均使用 Python 中的 Scipy 和 Statsmodels 实现, 显著水平均设为 $p < 0.05$ 。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (15)$$

$$Precision = \frac{TP}{TP + FP} \quad (16)$$

$$Recall = \frac{TP}{TP + FN} \quad (17)$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (18)$$

3.2 特征解耦可视化

如图 3 所示, 利用热力图, 对 3 名被试的 3 类运动进行特征解耦可视化, 解耦后得到两类特征, 其中动作特征对应 z_p , 个性特征对应 z_s 。其中被试一在训练过程中未涉及。

结果显示, 不同被试完成同一动作时, 动作特征其热力分布呈现相似性, 如图 3 中相同颜色方框标注所示。同一被试完成不同动作时, 其动作特征表现差异性, 这确保了运动分类的有效性。此外, 解耦得到的个性特征

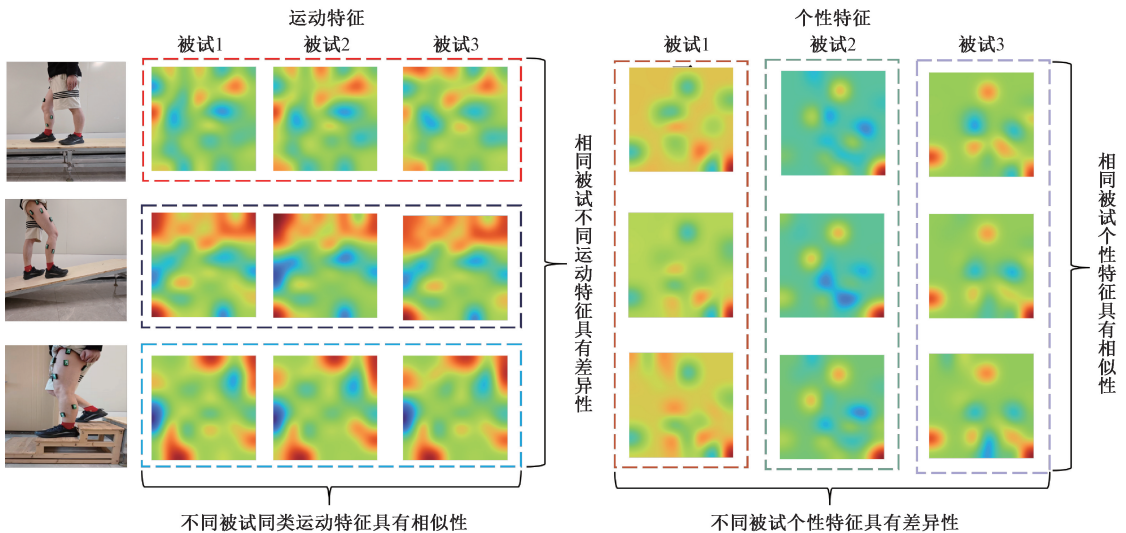


图 3 特征解耦可视化

Fig. 3 Feature decoupling visualization

在不同运动中保持相似性,这与个体固有的生物标识相契合^[12]。上述可视化结果验证了特征解耦方法的有效性。这与以往的研究类似,即不同被试完成同类任务时,会具有相似的肌肉激活模式^[16],这为跨被试场景下实现鲁棒的模式识别提供了重要基础。

3.3 分类性能测试

通过 t 分布随机邻域嵌入 (t-distributed Stochastic Neighbor Embedding, t-SNE) 对测试样本的原始肌电特征以及解耦后的动作特征 z_p 与个性特征 z_i 进行特征可视化,如图 4 所示,不同形状代表不同运动,不同颜色对应不同被试。原始肌电特征不同类别间存在显著混淆,解耦后可以发现运动特征在潜在空间中按形状(运动类

别)聚集,便于运动分类器构建清晰决策边界以完成分类任务,其中圆形与矩阵特征点存在最多的特征重叠,对应 LW 和 RA 运动存在分类混淆。个性特征在特征空间中则按颜色聚集(不同被试),而运动类别(不同形状)呈现混淆状态。文章利用虚线标注了相应的决策边界,以对应 10 名被试的个性特征和运动特征。值得注意的是,个性空间中存在部分特征重叠现象。这一方面源于肌电信号本身固有的信号混叠、噪声干扰等特性;另一方面是肌电特征中可能包含未显式处理的外界冗余干扰,而训练过程中模型更聚焦于运动模式分类任务,通过构建运动配对损失 L_{pair} 强化运动特征的紧凑性,这会促使将冗余干扰特征归属至个性特征中,导致该区域特征混淆。




图 4 不同被试运动特征与个性特征可视化

Fig. 4 Visualization of motion and private feature decoupled for different subjects

图 5 为一号被试为测试样本所对应的 5 类运动混淆矩阵,在 LW 与 RA 类别中,存在 13.67% 的分类混淆,这可能是因为较小的坡度下,平地行走和上坡在肌肉发力模式和激活特征上具有高度相似性,个体差异因素导致了决策边界更难划分。

3.4 模型对比实验

为进一步验证文章所提出的 CSACNN-GFD 模式识

	LW	RA	RD	SA	SD
LW	78.07	13.67	4.04	2.55	1.67
RA	9.33	88.33	0.00	2.22	0.12
RD	1.44	0.11	86.56	1.00	10.89
SA	0.73	1.51	0.00	95.56	2.20
SD	2.83	0.00	8.24	2.46	86.47
	LW	RA	RD	SA	SD

图 5 新被试(一号)5类运动混淆矩阵

Fig. 5 Confusion matrix of five types of motions for the new subject (No. 1)

别方法在跨被试场景下的有效性,进行了以下对比实验。选用近年来在肌电意图识别领域优秀的方法作为基准模型,包括残差卷积网络^[8]、基于小波时频图双流输入的 (convolutional neural network-gated recurrent unit, CNN-GRU)^[27]、结合卷积和长短时记忆网络 (convolutional neural network-long short-term memory, CNN-LSTM)^[34]、基于梅尔频谱图输入的堆叠卷积网络 (efficient concatenated convolutional neural network, E2CNN)^[35]、以及基准模型 (multi-scale convolutional neural network, MCNN)。无泛化策略下进行十折交叉验证,采用交叉熵损失训练,结果如图 6 和表 1 所示。




图 6 不同分类模型的跨被试性能对比实验

Fig. 6 Comparative experiments on cross-subjects performance of different classification models

表1 跨被试运动模式识别方法对比实验

Table 1 Cross-subject motion recognition method comparison experiment

(%)

实验模型	方法	Acc	Pre	Rec	F1
原始模型	RES18	77.02±7.98	79.34±6.81	77.03±7.98	76.70±7.35
	MCNN	77.78±5.94	78.67±5.47	77.81±5.95	76.83±5.67
	CNN-LSTM	76.39±7.07	77.89±6.71	76.39±7.06	76.34±6.80
	E2CNN	77.20±7.40	77.69±7.01	77.19±7.40	78.05±7.16
	CNN-GRU	78.51±5.76	79.56±5.33	78.51±5.76	78.79±5.64
	CSACNN(本文方法)	79.97±5.45	80.66±5.01	79.96±5.45	80.06±5.87
采用不同策略训练	MIXUP	81.42±7.41	82.25±6.75	81.47±7.43	81.53±8.05
	CORAL	81.94±6.01	82.89±5.64	81.98±6.03	81.93±6.87
	DANN	81.53±6.63	82.71±5.94	81.55±6.59	81.60±6.45
	DIFEX	82.45±6.15	84.27±5.67	82.40±6.23	82.55±6.64
	GFD(本文方法)	84.29±4.20	84.90±3.88	84.30±4.19	84.47±4.50

文章所提出的 CSACNN 模型相较于 RES18、CNN-LSTM、E2CNN、CNN-GRU, 平均分类准确率提升 2.95% ($p=0.084$)、3.58% ($p=0.0391$)、2.77% ($p=0.084$)、1.46% ($p=0.0391$)。同时相比与 MCNN, 空间注意力机制使模型分类准确率提升 2.19% ($p=0.0192$), 结果表明额外的频谱输入对跨被试泛化性能是有益的, 这在 CSACNN 与 CNN-GRU 中均有体现, 具有更好的分类性能, 并在不同被试间具有更好的稳定性。

表2中对比了不同模型的计算复杂度, 尽管 CSACNN 在参数量和训练时间上高于部分模型, 但其推理时间仅为 9.01 ms, 满足 50 ms 增量滑窗下的实时性要求。

表2 计算复杂度对比实验

Table 2 Comparison experiment of computational complexity

实验模型	方法	参数量/ M	训练时间/ (s·epoch ⁻¹)	推理时间/ (ms·sample ⁻¹)
原始模型	RES18	0.98	9.31	10.15
	MCNN	0.42	9.07	7.85
	CNN-LSTM	0.28	4.72	4.37
	E2CNN	0.15	8.50	5.67
	CNN-GRU	0.17	5.26	4.90
	CSACNN (本文方法)	0.48	10.44	9.01
采用不同 泛化策略 训练	MIXUP	0	9.83	7.81
	CORAL	0	13.20	8.52
	DANN	0	9.48	8.93
	DIFEX	0.22	17.65	7.85
	GFD(本文方法)	0.023	15.40	9.57

3.5 泛化策略对比实验

上述模型在新被试上的性能难以满足要求, 即肌电信号的个体差异性导致了模型性能的退化^[13,32]。为进一步验证文章提出策略的有效性, 对比了4类在肌电模式识别领域的泛化策略, 包括领域对抗网络(domain-adversarial neural network, DANN)^[32]、混合数据增强(mixup data augmentation, MIXUP)^[36]、协方差对齐(correlation alignment, CORAL)^[37]、域不变特征挖掘(domain-invariant feature exploration, DIFEX)^[38]。其中 MIXUP 通过凸组合数据增强的方式提升模型在未知被试上的泛化性能; CORAL 对齐不同被试的特征协方差矩阵强化模型在新被试上的性能; DANN 通过梯度反转的方式提取域不变的运动特征; DIFEX 利用蒸馏学习和特征对齐, 同步探索被试内和被试间不变特征, 利用教师模型在训练过程学习肌电特征的频域表示以获得更充分的特征空间。

由表1以及图7得出, 文章所提出的 GFD 策略使新被试上平均准确率从 79.97% 提升至 84.29%, 相比于 MIXUP、CORAL、DANN、DIFEX 分别提升 2.87% ($p=0.0039$)、2.36% ($p=0.0059$)、2.76% ($p=0.0273$)、1.84% ($p=0.0420$)。




图7 不同泛化策略对比

Fig. 7 Comparison of different generalization strategies

MIXUP 仅从源域数据层面进行线性增强,难以适配个体间差异显著的非线性协变量偏移场景;CORAL 与 DANN 致力于在特征空间上对齐不同域之间的特征分布,却忽视了特征内部复杂的成分纠缠问题。模型难以在去除被试差异与保留运动模式之间找到最优平衡,往往追求域不变性而模糊了细粒度的运动特征,限制了模型的泛化上限。相比之下,所提 GFD 机制借鉴了 DIFEX 中时频泛化特征互补的思想,更通过显式的特征分离机制和交叉重组的分类训练,从特征分布对齐与强化运动判别信息双维度提升模型的泛化性能。同时 GFD 仅在基准模型的基础上增加域分类器和门控解耦器,它可以

便捷地集成到深度特征提取网络中,据表 2 可得,GFD 额外增加的参数量相对较少,具有较好的训练效率以及推理性能。

表 3 展示了不同方法在新被试上的测试性能,其中 3 号具有 88.4% 的最高性能。而 4 号用户为 73.6%,这可能是因为 4 号在生理参数上更具差异性,更高的身高与体重,此外机电特征差异性还受到肌肉收缩力大小、收缩方式等多种因素的干扰,这间接反映了肌电信号中个体差异所带来的泛化难题^[13]。在差异性最大的 4 号中,所提出的方法使模型分类性能提升 8.5%,且不涉及新被试数据,提升了模型的泛化下界。

表 3 不同泛化策略在不同被试下的分类准确率

Table 3 Classification accuracy of different generalization strategies across different subjects

方法	被试编号									
	1	2	3	4	5	6	7	8	9	10
Ori	0.830	0.791	0.820	0.651	0.817	0.845	0.797	0.807	0.817	0.822
MIXUP	0.862	0.804	0.854	0.615	0.824	0.879	0.827	0.832	0.844	0.801
CORAL	0.852	0.802	0.869	0.661	0.861	0.860	0.824	0.816	0.831	0.817
DANN	0.851	0.783	0.871	0.659	0.776	0.878	0.833	0.792	0.843	0.867
DIFEX	0.860	0.839	0.849	0.652	0.841	0.855	0.830	0.841	0.827	0.851
本文方法	0.867	0.830	0.884	0.736	0.849	0.882	0.853	0.837	0.847	0.843

3.6 解耦策略消融实验

如表 4 所示,文章对所提出的解耦策略损失函数进行消融对比,其中 L_c^{rec} 为包含交叉重组样本的运动分类损失,其余采用原始样本。可以发现仅增加信息损失 L_I 或配对损失 L_{pair} 对分类性能的提升有限, L_I 用于确保信息的充分性,但无法保证动作特征的非冗余性,配对损失 L_{pair} 通过类内对比的方式寻找跨被试一致性的运动特征,从而去除冗余干扰信息。此外对抗学习 L_{grl} 可以进一步减少动作特征中的个性信息。在辅助分类分支中,有监督的训练确保了被试分类器的有效性,而梯度反转层迫使辅助分类器无法利用动作特征完成身份识别,这间接反应动作特征中不包含个性信息,从而提升运动特征在不同被试中的泛化性能。更重要的是,对抗学习强迫了运动特征和个性特征具有差异性,以避免门控值 $G(\cdot)$ 处于相同的非零参数导致的退化问题,即运动特征和个性特征仅在模值上具有差异性,此时 z_p 和 z_s 包含相似信息。保留所构建的解耦损失相互作用取得最好的性能。

表 4 解耦策略消融实验

Table 4 Ablation study on decoupling strategy

方法	L_I	L_{pair}	L_{grl}	L_c^{rec}	准确率/%
1	×	×	×	×	79.97±5.45
2	√	×	×	×	79.82±5.74
3	×	√	×	×	80.87±5.38
4	√	√	×	×	81.55±4.37
5	√	√	√	×	82.18±4.41
6	√	√	√	√	84.29±4.20

3.7 不同训练被试数量下的性能测试

为了评估训练样本的多样性对模型泛化能力的影响,对比了基准模型与 CSACNN-GFD 在不同训练被试数量下的性能表现。实验结果如图 8 所示,图 8 中阴影部




图 8 不同训练被试数量下的分类性能

Fig. 8 Classification performance under different numbers of training subjects

分对应两个模型各自的标准差。CSACNN-GFD 的分类性能在引入第 2 名被试后,性能出现显著提升。这一现象归因于模型中对比损失机制 L_{pair} , 在多被试场景下,通过跨被试的配对优化,模型能够有效强化不同被试之间动作特征的相似性,抑制个体特异性信息的干扰。最终结果表明,增加训练被试数量能提升模型的泛化性能,但也伴随更高的数据采集成本和训练复杂度。值得注意的是,得益于特征解耦策略,CSACNN-GFD 在较少训练数据下即可取得优于基准模型的性能。这表明该策略能更有效地捕捉运动不变特征,能更好地均衡被试数量与泛化性能。

3.8 公开数据集性能测试

如表 5 所示,文章所提出的方法在公共数据集中平均识别准确率为 73.83%,主要原因在于公共数据集采用细粒度的标注策略,将平地行走划分为多个不同的速度类别,不同速度样本间存在极高的特征相似性。文章所提出的方法,优于对比策略,相比于基线模型,实现了 6.55% 的精度提升。在此基础上,后续可利用无监督自适应策略进行校正,以进一步提升模型在新被试上的性能^[39]。模型初始性能有限导致校正过程往往依赖大量样本^[13],该方法提升了模型的泛化下界,这对减少后续的校准样本量需求,提升校准效率和校准性能是有益的^[40]。

表 5 公开数据集对比实验

Table 5 Public dataset comparison experiment

(%)

实验模型	方法	Acc	Pre	Rec	F1
原始模型	RES18	65.13±8.36	63.52±9.27	65.10±7.58	62.15±9.60
	MCNN	64.45±9.27	65.10±7.89	64.38±8.19	63.31±7.49
	CNN-LSTM	65.07±8.12	63.32±7.35	65.86±7.32	63.75±7.85
	E2CNN	64.97±9.03	62.63±8.19	64.29±7.64	62.39±7.73
	CNN-GRU	65.19±7.95	65.39±8.07	65.12±7.78	64.99±7.94
	CSACNN(本文方法)	67.28±8.58	66.97±8.81	65.54±8.67	65.21±8.60
采用不同策略训练	MIXUP	68.03±8.69	65.72±8.57	67.98±9.02	65.87±9.02
	CORAL	68.59±9.20	67.15±10.38	68.05±9.51	66.67±9.53
	DANN	69.32±10.39	68.33±8.02	67.41±9.04	68.22±9.25
	DIFEX	70.35±8.91	67.89±7.57	66.90±8.64	67.05±8.99
	GFD(本文方法)	73.83±7.37	71.04±8.31	70.90±8.67	70.67±8.50

4 结 论

针对跨被试场景下肌电模式识别系统性能低的问题,文章提出一种基于深度网络和门控解耦机制的跨被试不变特征运动模式识别方法,在无需新被试校准样本的前提下,模型即可有效泛化到新受试者中,提升了跨被试肌电模式识别系统的可迁移性与实用价值。

为了从肌电信号中获得丰富且具备跨被试鲁棒的特征信息,设计了一种空间注意力的双流时频卷积网络,从时域和频域互补角度提取特征信息,并利用不同大小的卷积核提升模型的感受域,结合空间注意力机制增强不同通道与尺度特征的交互关联,为后续动作识别与跨域泛化提供了高质量特征。其次,通过构建的门控解耦机制以及解耦损失,自适应地完成特征解耦,确保运动特征的充分性和跨被试不变性,实验验证

了该方法的有效性,在自建数据集中和公开数据集中平均识别准确率为 84.29% 和 73.83%,优于现有的下肢肌电模式识别泛化策略。

尽管文章提出的方法提升了跨被试场景下肌电信号模式识别的准确性,但考虑到所涉及的场景和群体相对单一,方法仍存在局限性。未来将采集多样化被试群体的肌电数据,考虑跨会话差异、疲劳状态等导致域偏移的因素,丰富实际应用场景与运动模式,结合无监督的在线迁移策略,以提升方法的实用性。

参考文献

- [1] QIN P J, SHI X, ZHANG CH M, et al. Continuous estimation of the lower-limb multi-joint angles based on muscle synergy theory and state-space model[J]. IEEE Sensors Journal, 2023, 23(8): 8491-8503.
- [2] 林恒,李玉榕,施正义,等. 基于力度无关鲁棒特征的

- 肌电手势识别方法[J]. 仪器仪表学报, 2022, 43(5): 183-190.
- LING H, LI Y R, SHI ZH Y, et al. EMG gesture recognition method based on robust feature independent of strength[J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 183-190.
- [3] LIU Y H, LI X Y, YANG L, et al. A CNN-transformer hybrid recognition approach for semg-based dynamic gesture prediction[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3273651.
- [4] 刘强, 李玉榕, 杜国川, 等. 基于 sEMG 信号的关节力矩 NARX 预测模型[J]. 仪器仪表学报, 2022, 43(11): 123-131.
- LIU Q, LI Y R, DU G CH, et al. NARX prediction model of joint torque based on sEMG signal[J]. Chinese Journal of Scientific Instrument, 2022, 43(11): 123-131.
- [5] WEI W T, WONG Y K, 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.
- [6] LIANG F, QIN P J, SHI X, et al. A novel method of lower limbs locomotion transition and steady modes classification based on sEMG signals[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-14.
- [7] LING L Y, WEI L Y, FENG B, et al. A lightweight multi-scale convolutional attention network for lower limb motion recognition with transfer learning[J]. Biomedical Signal Processing and Control, 2025, 99: 106803.
- [8] SUN J H, WANG Y F, HOU J, et al. Deep learning for electromyographic lower-limb motion signal classification using residual learning[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2024, 32: 2078-2086.
- [9] TU J, DAI Z X, ZHAO X, et al. Lower limb motion recognition based on surface electromyography [J]. Biomedical Signal Processing and Control, 2023, 81: 104443.
- [10] BAO T ZH, ZAIDI S A R, XIE SH Q, et al. Inter-subject domain adaptation for CNN-based wrist kinematics estimation using sEMG[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 1068-1078.
- [11] O'KEEFFE R, YANG J H, MEHRDAD S, et al. Lower-limb non-parametric functional muscle network: Test-retest reliability analysis [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 2953-2963.
- [12] FAN J H, JIANG X Y, LIU X Y, et al. Surface EMG feature disentanglement for robust pattern recognition[J]. Expert Systems with Applications, 2024, 237: 121224.
- [13] 李自由, 赵新刚, 张弼, 等. 基于表面肌电的意图识别方法在非理想条件下的研究进展[J]. 自动化学报, 2021, 47(5): 955-969.
- LI Z Y, ZHAO X G, ZHANG B, et al. Review of sEMG-based motion intent recognition methods in non-ideal conditions [J]. Acta Automatica Sinica, 2021, 47(5): 955-969.
- [14] LIU X Y, LI G T, ZHOU X H, et al. A weight-aware-based multisource unsupervised domain adaptation method for human motion intention recognition[J]. IEEE Transactions on Cybernetics, 2025, 55(7): 3131-3143.
- [15] JIANG X Y, LIU X Y, FAN J H, et al. Optimization of HD-sEMG-based cross-day hand gesture classification by optimal feature extraction and data augmentation [J]. IEEE Transactions on Human-Machine Systems, 2022, 52(6): 1281-1291.
- [16] AJIBOYE A B, WEIR R F. Muscle synergies as a predictive framework for the EMG patterns of new hand postures [J]. Journal of Neural Engineering, 2009, 6(3): 036004.
- [17] 郑楠, 李玉榕, 张文萱, 等. 基于特定任务肌肉协同的用户无关肌电手势识别研究[J]. 仪器仪表学报, 2021, 42(9): 253-261.
- ZHENG N, LI Y R, ZHANG W X, et al. User-independent EMG gesture recognition based on task-specific muscle synergy[J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 253-261.
- [18] AO X H, WANG F, WANG R N, et al. Muscle synergy analysis for gesture recognition based on sEMG images and Shapley value[J]. Intelligence & Robotics, 2023, 3(4): 495-513.
- [19] ZHAO D ZH, MA Y H, MENG J Y, et al. MCR-ALS-

- based muscle synergy extraction method combined with LSTM neural network for motion intention detection[J]. *Frontiers in Neurorobotics*, 2023, 17: 1174710.
- [20] ZHANG S, LIN J N, YOU Y G, et al. Robust motion estimation with user-independent sEMG features extracted by correlated components analysis[J]. *Measurement & Control*, 2023, 56(1/2): 432-441.
- [21] CAMARGO J, RAMANATHAN A, FLANAGAN W, et al. A comprehensive, open-source dataset of lower limb biomechanics in multiple conditions of stairs, ramps, and level-ground ambulation and transitions[J]. *Journal of Biomechanics*, 2021, 119: 110320.
- [22] ZHANG L, LIU G, HAN B, et al. sEMG based human motion intention recognition[J]. *Journal of Robotics*, 2019, 2019: 3679174.
- [23] OSKOEI M, HU H SH. Myoelectric control systems—a survey[J]. *Biomedical Signal Processing and Control*, 2007, 2(4): 275-294.
- [24] QIN P J, SHI X. Evaluation of feature extraction and classification for lower limb motion based on semg signal[J]. *Entropy*, 2020, 22(8): 852.
- [25] SU T Y, TAN X, JIANG X Y, et al. A dynamic balanced single-source domain generalization model for cross-posture myoelectric control[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2025, 33: 255-265.
- [26] 石欣, 敖钰民, 范智瑞, 等. 基于 sEMG 的下肢连续运动切换态实时识别方法[J]. *仪器仪表学报*, 2024, 45(4): 165-174.
- SHI X, AO Y M, FAN ZH R, et al. Real-time recognition method of switching states of continuous lower limb movements based on sEMG[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(4): 165-174.
- [27] LI J W, ZHANG B, WANG ZH H, et al. Optimizing sEMG-based gesture recognition under nonideal conditions through a robust deep learning approach[J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 1-13.
- [28] RABIN N, KAHLON M, MALAYEV S, et al. Classification of human hand movements based on EMG signals using nonlinear dimensionality reduction and data fusion techniques[J]. *Expert Systems with Applications*, 2020, 149: 113281.
- [29] OUYANG D L, HE S, ZHANG G ZH, et al. Efficient multi-scale attention module with cross-spatial learning[C]. 2023 IEEE International Conference on Acoustics, Speech and Signal Processing, 2023: 776-780.
- [30] YU X, TSENG H H, YOO S, et al. INSURE: An information theory inspired disentanglement and purification model for domain generalization[J]. *IEEE Transactions on Image Processing*, 2024, 33: 3508-3519.
- [31] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations[C]. 37th International Conference on Machine Learning, 2020: 1597-1607.
- [32] COTE-ALLARD U, CAMPBELL E, PHINYOMARK A, et al. Interpreting deep learning features for myoelectric control: A comparison with handcrafted features[J]. *Frontiers in Bioengineering and Biotechnology*, 2020, 8: 158.
- [33] LOSHCHILOV L, HUTTER F. SGDR: Stochastic gradient descent with warm restarts[C]. 5th International Conference on Learning Representations, 2017.
- [34] BAI D CH, LIU T, HAN X H, et al. Multi-channel sEMG signal gesture recognition based on improved CNN-LSTM hybrid models[C]. 2021 IEEE International Conference on Intelligence and Safety for Robotics, 2021: 111-116.
- [35] QURESHI M F, MUSHTAQ Z, REHMAN M Z U, et al. E2CNN: An efficient concatenated CNN for classification of surface EMG extracted from upper Limb[J]. *IEEE Sensors Journal*, 2023, 23(8): 8989-8996.
- [36] HE CH M, TAN T F, FAN X J, et al. Noise-residual Mixup for unsupervised adversarial domain adaptation[J]. *Applied Intelligence*, 2023, 53(3): 3034-3047.
- [37] SHI H J, JIANG X Y, DAI CH Y, et al. EMG-based multi-user hand gesture classification via unsupervised transfer learning using unknown calibration gestures[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024, 32: 1119-1131.
- [38] SU T Y, TAN X, JIANG X Y, et al. A dynamic balanced single-source domain generalization model for cross-posture myoelectric control[J]. *IEEE Transactions*

on *Neural Systems and Rehabilitation Engineering*, 2025, 33: 255-265.

- [39] ZHONG X C, WANG Q S, LIU D, et al. Plug-and-play sEMG-driven hand gesture recognition with subdomain adaptation for exoskeleton rehabilitation gloves[J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 3502881.
- [40] LI X H, ZHANG X, CHEN X, et al. A unified user-generic framework for myoelectric pattern recognition: Mix-up and adversarial training for domain generalization and adaptation [J]. *IEEE Transactions on Biomedical Engineering*, 2023, 70(8): 2248-2257.

作者简介



石欣(通信作者),2003年和2010年于重庆大学分别获得硕士学位和博士学位。现为重庆大学教授、博士生导师,主要研究方向为智能控制、无线传感网络。
E-mail:shixin@cqu.edu.cn

Shi Xin (Corresponding author) received his M.Sc. and Ph.D. degrees both from Chongqing University in 2003 and 2010, respectively. He is currently a professor and Ph.D. advisor at Chongqing University. His main research interests

include intelligent control and wireless sensor network.



黄良文,2023年于合肥工业大学获得学士学位。现于重庆大学攻读硕士学位,主要研究方向为模式识别与信号处理。

E-mail:202313021026@stu.cqu.edu.cn

Huang Liangwen received his B.Sc. degree from Hefei University of Technology in 2023. He is currently pursuing his M.Sc. degree at Chongqing University. His main research interests include pattern recognition and signal processing.



秦鹏杰,2015年于重庆科技大学获得学士学位,2023年于重庆大学获得博士学位。现为深圳大学人工智能学院助理教授。主要从事多模态人机交互研究。

E-mail:pj.qin@szu.edu.cn

Qin Pengjie received his B.Sc. degree from Chongqing University of Science and Technology in 2015, his Ph.D. degree from Chongqing University in 2023. He is currently an assistant professor at the School of Artificial Intelligence, Shenzhen University. His main research interest includes multimodal human-computer interaction.