

DOI: 10.19650/j.cnki.cjsi.J2614923

下肢负载运动模式肌群差异化特征融合识别方法*

石 欣¹, 陈宇杰¹, 范智瑞¹, 秦鹏杰², 卢 灏¹

(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:针对下肢外骨骼在实际应用中因负载变化导致表面肌电信号(sEMG)产生规律性生理特征偏移,进而引起运动意图识别精度大幅下降的问题,提出一种基于生理肌群特性与双分支融合网络(BCM-ResNet)的下肢运动模式识别方法。首先,通过时频域分析定量揭示了负载诱导下的生理重构规律。利用凝聚型层次聚类算法证实了在 0~14 kg 范围,sEMG 特征空间呈现出边界清晰的“低、中、高”三簇分布特性,证明负载是驱动特征空间产生规律性位移的关键变量而非随机扰动。其次,针对大小腿肌群生理功能异质性,提出差异化特征提取策略:采用双向长短期记忆网络(BiLSTM)捕捉大腿主力肌群的强时序动态演化特征,利用多尺度卷积神经网络(Multi-scale CNN)提取小腿调节肌群的局部精细特征。构建双分支融合架构并引入多头注意力机制(MHA),实现运动意图与负载工况特征的动态解耦与加权融合,并利用残差网络(ResNet)提升深层特征的抽象能力。此外,本文对传感器配置进行了帕累托最优分析,确定了右腿单侧 12 通道的最优布局。实验表明,该方法在自建数据集上的平均识别准确率达 94.78%;同时,在包含 22 名受试者的国际公开数据集上验证了模型的泛化性能,准确率达 92.85%。最后,通过在边缘计算终端上的迁移性测试,验证了算法在亚毫秒级推理下的执行稳定性。该研究为外骨骼机器人在复杂负载环境下的精准意图识别提供了可靠的算法支撑。

关键词: 表面肌电信号;下肢运动识别;负载特征偏移;双分支融合网络;多头注意力机制

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

Pattern recognition of lower limb movement under load based on differentiation feature fusion of muscle groups

Shi Xin¹, Chen Yujie¹, Fan Zhirui¹, Qin Pengjie², Lu Hao¹

(1. School of Automation, Chongqing University, Chongqing 400044, China;

2. School of Artificial Intelligence, Shenzhen University, Shenzhen 518060, China)

Abstract: To address the significant decline in movement intention recognition accuracy caused by the regular physiological feature drift of surface electromyography (sEMG) signals under varying loads in lower limb exoskeleton applications, a recognition method based on muscle physiological characteristics and a bi-branch cross-scale multi-head attention residual network (BCM-ResNet) is proposed. First, the regular pattern of sEMG signal changes under load, which can be termed "physiological reconstruction", is quantitatively revealed through time-frequency analysis. Agglomerative hierarchical clustering confirms that the sEMG feature space exhibits distinct "low, medium, and high" cluster distributions within the 0~14 kg range. This finding demonstrates that load is a key variable driving the regular displacement of the feature space rather than a random disturbance. Secondly, a differentiated feature extraction strategy is proposed by considering the functional heterogeneity of the thigh and calf muscles. A bidirectional long short-term memory (BiLSTM) network is employed to capture the strong temporal dynamics of the thigh muscles (the primary power source), while a multi-scale convolutional neural network (Multi-scale CNN) is utilized to extract local fine-grained features of the calf muscles (the precision regulators). A bi-branch fusion architecture with a multi-head attention (MHA) mechanism is constructed to achieve dynamic decoupling and weighted fusion of intention and load features, utilizing a residual network (ResNet) to enhance the abstraction of high-level features. Additionally, the

收稿日期: 2026-02-02 Received Date: 2026-02-02

* 基金项目: 国家重点研发计划(2023YFB4704003)、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)项目资助

sensor configuration is optimized through Pareto analysis, determining a 12-channel unilateral layout on the right leg as the optimal setup. Experiments show that the proposed method achieves an average recognition accuracy of 94.78% on a self-built dataset and 92.85% on an international open-source dataset containing 22 subjects, validating the model's generalization performance. Finally, migration tests on an edge computing terminal verify the algorithm's execution stability under sub-millisecond inference latency. This research provides reliable algorithmic support for the precise intention recognition of exoskeletons in complex loading environments.

Keywords: sEMG; lower limb motion recognition; load feature drift; dual-branch fusion network; multi-head attention mechanism

0 引 言

下肢外骨骼助力系统作为助力系统,可与人的主观意图结合,实现可穿戴外骨骼人机交互,提升人体运载能力,降低机能消耗^[1-3]。该技术已经广泛应用于各个领域,包括装卸搬运^[4]、工厂生产等领域。为了更好的掌握用户的运动意图,表面肌电信号(surface electromyography, sEMG)被广泛应用于下肢运动意图的识别,它直接实时反映用户的肌肉活动水平,并且可以从皮肤中无创地记录^[5-7],与其他传感器相比,sEMG信号直接捕获从神经系统传输到肌肉细胞的电活动,具有易采集、提前于人体运动意图等优势。此外,大量证据表明,sEMG信号通常在肢体运动前 50~100 ms 产生^[8]。这种前瞻性特征使得基于 sEMG 的意图识别能够主动操作,从而更好地支持人机协调^[9]。因此,近年来,基于 sEMG 信号的下肢意图识别已成为学术研究的一个突出领域。然而,在外骨骼的穿戴和使用中,涉及到电源、电机的携带,以及物资装备的搬运等问题。不同的负载方式会改变人体的重心,从而影响步行姿态,改变肌肉群的发力模式^[10],进而影响意图识别判断的准确性,从而造成人机伤害。因此,设计差异负载状态下的肌电信号分析方法并构建稳定准确的运动模式识别模型成为亟待解决的问题。

基于 sEMG 的运动模式识别已经进行了许多重要的研究^[11],并且在机器学习和深度学习意图识别领域已经取得了较好的结果。

Gupta 等^[12]提出了一种与分类器相关的迭代特征选择算法,该算法对运动模式进行了分类,包括平地、上楼梯、下楼梯、上坡、下坡,所提算法的模式识别平均准确率为 97.87%。Zhou 等^[13]将肌电信号与加速度数据融合,通过多种神经网络对 4 种典型运动进行识别,在双向长短期记忆模型(bidirectional long short-term memory, BiLSTM)中取得最好识别准确率。Zhou 等^[14]提出了一种轻量级的深度卷积神经网络(deep convolutional neural networks, DCNN),用于将分离高频和低频后的肌电信号输入网络,对 8 种手势进行识别,减少了 20% 的计算时间,获得了 85.75% 的识别准确率。Leela-kittisin 等^[15]提出了一种以时间卷积网络(temporal convolutional

network, TCN)为核心的端对端分类识别模型,通过肌电信号对行走、跳跃、下楼梯和上楼梯等下肢活动进行区分,平均准确率达到了 97.08%。Li 等^[16]提出一种 CNN-LSTM 模型,针对肌电信号解码康复训练中不同负载下踝关节运动模式的问题,通过两步法进行识别,模型识别精度达到 93.50%。Liang 等^[17]提出了一种双分支融合网络的 CAD(CNN-attention-densenet)网络,用于分类下肢运动包括过渡模式和稳态模式在内的多种模式,模型识别精度达到 97.39%。

利用肌电信号识别下肢无负载运动模式已经取得了重大进展,然而,在外骨骼的穿戴和使用中,必然会有负载对人体的影响,不同的负载会影响运动识别的精度,导致人机柔顺下降,产生恶劣的结果。Al-Timemy 等^[18]从 2 名受试人员的 12 个肌电信号通道进行负载研究,发现负载变化可能导致肌电信号识别准确度降低,最高可达 60%。Tang 等^[19]提出一种基于负载和 sEMG 的两步混合估计方法,先用 SVM 进行负载识别,再通过 BP 神经网络(back propagation neural network, BPNN)进行肌电信号识别,结果表明对解决负载变化的不利影响有帮助。Tian 等^[20]在研究腕部角度预测时,证明了随着负载的增加,识别精度会降低,提出了一种融合频域和时域特征的组合特征方法,通过对采集的 16 通道的 sEMG 信号融合均方根(root mean square, RMS)、中值频率(median frequency, MDF)和平均绝对值(mean absolute value, MAV)特征,基于广义回归神经网络(generalized regression neural network, GRNN)分类器识别,能够克服负载的增加,获得较高的识别精度。张贤富^[21]将肌电信号转化为二维灰度图,基于卷积神经网络(convolutional neural network, CNN)构建了差异场景下的识别系统,分别对不同速度、负载、负载方式等差异场景下的步态相位进行识别,总体步态识别效果较稳定。

目前现有的研究大多忽略了负载的影响,现有研究使用多模型针对负载意图识别进行研究,但计算量大,计算耗时较长,不利于人机柔顺性。为了解决上述挑战,本文提出了一种新的分类方法来识别差异负载下的下肢运动模式。具体地,收集了 5 种运动模式的 sEMG 数据。考虑到大小腿肌群的生理功能与信号特性差异,大腿肌群具有强时序性,小腿肌群具有更丰富的局部特征,采用经验分解法对肌群进行分解。提出了一种融合多尺度卷

积神经网络、双向长短期记忆网络 (bidirectional long short-term memory, BiLSTM)、多头注意力 (multi-head attention, MHA) 和 ResNet 网络模块的双分支融合网络 (BCM-ResNet), 用于提取肌电信号的多个特征, 包括运动特征和融合不同通道的相关特征, 然后将多通道 sEMG 信号根据肌群划分为两个流, 大腿肌群馈送到多尺度 CNN 中, 小腿肌群馈送到 BiLSTM 中, 用于不同肌群的特征提取, 利用注意力机制来增强融合的相关特征表示, 然后使用 ResNet 进行分类, 从而实现负载状态下运动模式的精准识别。

1 方法与实验

本文数据集包含公开数据集^[22]和自建数据集, 其中公开数据集仅作为验证本文模型的泛化性, 自建数据集为后续各项主要实验。自建数据集采集方面, 本文总共

使用了 12 个 sEMG 传感器, 全部放置在右腿上, 所选肌肉包括大腿肌群: 股二头肌 (biceps femoris, BF)、股外侧肌 (vastus lateralis, VL)、股薄肌 (gracilis, GC)、股内侧肌 (vastus medialis, VM)、半腱肌 (semitendinosus, ST)、半膜肌 (semimembranosus, SM)、股直肌 (rectus femoris, RF) 和阔筋膜张肌 (tensor fasciae latae, TFL), 小腿肌群: 外侧腓肠肌 (lateral gastrocnemius, LG)、内侧腓肠肌 (medial gastrocnemius, MG)、比目鱼肌 (soleus, SOL)、胫骨前肌 (tibialis anterior, AT), 如图 1 所示。在本章中, 识别框架主要由三大板块组成。首先, 系统地描述了传感器集成数据采集系统的配置、受试者信息以及包含差异化负载的实验方案。其次, 详细说明了数据集的预处理管道及基于生理特性的肌群划分方法。最后, 提出了一种结合多尺度 CNN、BiLSTM、MHA 和 ResNet 的双分支融合网络, 用于识别连续运动中的稳态和负载模式。




图1 所提出方法的体系结构概述

Fig. 1 Overview of the proposed method's architecture

1.1 实验过程

本研究选取 7 名男性和 3 名女性健全受试者 (年龄范围: 18~30 岁; 身高范围: 160.5~180.3 cm; 体重范围: 48~77 kg) 参与了本次研究, 所有受试者在实验开始前均被告知实验内容, 并签署知情同意书。10 名受试者在实验前都进行了体检, 以消除任何肌肉骨骼和神经疾病。在实验前他们被要求不要参加任何剧烈的上肢活动。实验方案获得了中国重庆重庆大学的批准。在实验之前, 记录人体特征 (年龄、身高和体重), 并向受试者介绍实

验程序。本实验使用英国 Biometrics Ltd. 生产的无线运动采集系统、IE230 无线 sEMG 传感器和 W150 无线双轴测角仪, 型号为 DataLITE, 如图 2 所示。sEMG 传感器采用可重复使用的集成干电极, 内置 1 000×信号放大器。W150 测角仪在 ±180° 范围测量膝关节和髋关节角度。两个传感器都以 1 000 Hz 的频率采样数据。DataLITE 系统用于同步所有多源数据采集。

在采集数据之前, 用酒精擦拭布清洁每个参与者的皮肤, 以防止皮肤杂质的干扰。使用双轴测角仪记录右腿的髋关节角度。




图2 传感器规格

Fig. 2 Sensor specifications

实验场景示意如图1中数据采集平台所示。共有5种常规运动模式,平地(pd)、上坡(sp)、下坡(xp)、上楼梯(slt)、下楼梯(xlt)。采用崔浩洋等^[23]的负载分布研究方法,该方法在自建数据集上进行了评估。受试者分别以背负、抱姿、提姿3种负载动作以低负载(0~6 kg)、中负载(7~10 kg)、高负载(11~14 kg)3种负载重量分别进行5种运动模式。在一个模式内,每次采集10 s,休息5 min后再进行下一组,在不同运动模式间提供10 min的休息以最大限度地减少肌肉疲劳。每种运动模式采集20组,将每个模式的角度数据根据步态进行周期划分,随后取每个周期的前100 ms作为样本,如图3所示。由于每个模式相同时间内产生的周期数不一样,平等地对每个模式取500个样本,每个样本由12个通道的肌肉数据组成,总共产生2 500个数据样本。




图3 样本窗口的示例分区

Fig. 3 Example partition of the sample window

1.2 数据预处理

表面肌电信号属于微弱生物电信号,故其对外部干扰具有高度敏感性。因此,为提升信号质量而进行sEMG信号分析前,降噪预处理环节不可或缺。其中工频干扰一般由工频电源所产生,一般以50 Hz存在^[24];由皮肤与传感器之间摩擦产生的运动伪影干扰一般介于1~10 Hz。根据以前的研究表明,肌电信号的主要能量分布区间在20~300 Hz^[25]因此在本研究中,引入了巴特沃斯带通滤波器和陷波滤波器。该带通滤波器配置有20 Hz下载截止频率,300 Hz的上截止频率和六阶设计。陷波滤波器以50 Hz为中心。

1.3 总体框架模型

本文提出了一种准确分类差异负载下下肢运动的新方法。本研究将大小腿肌群区分开进行特征提取,由于大腿肌群作为下肢运动的主要发力肌,是人体力量输出与大范围运动的核心载体,其肌电信号具有显著的长时序动态演化特征,应用BiLSTM的双向时序建模来可精准捕捉这一特性及负载下的时序依赖关系;小腿肌群于小肌群,作为动作稳定与精细调节的核心,信号以局部瞬时激活模式为主,应用多尺度13×1卷积核来高效地提取不同时间粒度的局部特征,适配负载诱导的短时空变异;为了适配大小腿异质性特征,应用MHA动态权重分配强化关键特征,捕捉肌群协同激活关系,相比简单拼接提升负载扰动鲁棒性,输出更具判别力的融合特征。最后应用ResNet借残差连接破解深层梯度衰减,深度挖掘MHA融合的跨肌群协同特征,强化负载不变判别信息,高效实现运动模式精准分类。

1) 双向长短期记忆网络

BiLSTM模型是一种双向长短期记忆网络,通过同时处理序列的正向和反向信息来捕捉上下文依赖关系。相比于LSTM,BiLSTM新增后向时序建模,可同时捕捉大腿肌群肌电信号的激活上升沿与衰减沿特征,完整还原负载下肌肉发力的全时序动态过程,避免LSTM单向建模遗漏后向依赖信息,显著提升时序特征表征的完整性与负载鲁棒性。BiLSTM由LSTM单元组成;每个LSTM单元由一个输入门、一个遗忘门、一个输出门和一个存储单元组成^[26]。图1中双支融合网络框架显示了LSTM单元的结构,可以用式(1)~(5)表示:

$$f_t = \sigma(W_f \cdot [h_{t-1} \cdot x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1} \cdot x_t] + b_i) \quad (2)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_c \cdot [h_{t-1} \cdot x_t] + b_c) \quad (3)$$

$$o_t = \sigma(W_o \cdot [h_{t-1} \cdot x_t] + b_o) \quad (4)$$

$$h_t = o_t \tanh(c_t) \quad (5)$$

其中, σ 是激活函数; h_{t-1} 是前一刻的单位状态; x_t 是当前时刻的输入; f_t 表示遗忘门向量; i_t 表示输入门向量; c_t 表示细胞状态向量; o_t 表示输出门向量; h_t 是当前时刻单位的输出; W_f 、 W_i 、 W_c 和 W_o 是权重矩阵; b_f 、 b_i 、 b_c 和 b_o 并且是偏差向量。

2) 多尺度卷积

小腿肌群在动作中维持平衡,赋值变化不剧烈,因此用多尺度卷积可以捕捉局部以及全局特征。其中sEMG作为典型的一维时间序列,1D卷积可以在时间轴上直接进行特征抽象,提取反映运动形态的包络信息,避免了2D卷积带来的冗余计算,并且通过滑动窗口机制,能够精准捕捉小腿肌群在动作精细调节过程中产生的局部瞬时激活模式。串行结构通过逐层非线性变换压缩冗余信息、强化判别特征,既保留CNN局部建模的高效性,又通

过深度堆叠提升对负载扰动下细微模式的捕捉能力,为跨肌群融合提供精准的局部特征支撑^[27]。

多尺度卷积通过串行3个13×1卷积核通过逐层递进的特征转换适配小腿肌群信号特性,多尺度卷积结构如图1中双支融合网络框架所示;首个卷积核捕捉基础局部激活模式,后续卷积在其输出上提取更抽象的局部特征。贴合的肌群CNN模型不同层可以表示为:

(1)卷积层:

$$y(i,j) = f(\sum \sum x(m,n) \times w(i-m,j-n) + b) \quad (6)$$

式中: $y(i,j)$ 是 (i,j) 处的输出特征映射元素; $x(m,n)$ 是 (m,n) 处的输入特征映射元素; $w(i-m,j-n)$ 是滤波器权重; f 是激活函数。

(2)池化层:

$$y(i,j) = \text{pool}(x(i \times s:i \times s + k, j \times s:j \times s + k)) \quad (7)$$

式中: pool 是池化函数; s 是步长; k 是卷积核大小。

(3)全连接层:

$$\mathbf{y} = f(\mathbf{w} \times \mathbf{x} + \mathbf{b}) \quad (8)$$

式中: $\mathbf{w}$ 是权重矩阵; $\mathbf{x}$ 是输入向量; $\mathbf{b}$ 是偏置矢量; f 是激活函数; $\mathbf{y}$ 是估计的力。

(4)输出层:

$$\mathbf{y} = f(\mathbf{w} \times \mathbf{x} + \mathbf{b}) \quad (9)$$

3)多头注意力机制

MHA 是指建立在自注意力机制之上的增强方法。注意力机制同时捕捉肌肉协同激活关联,避免简单拼接的信息冗余。而多头注意力机制通过多头并行计算,可同时关注大小腿异质性特征的不同子空间,相比单头注意力更全面捕捉多维度特征交互,能有效提升融合特征的判别力与鲁棒性。

当计算注意力矩阵时,MHA 机制将输入张量 $\mathbf{X}$ 划分为 h 个子张量,每个子张量都有不同学习的注意力信息。对于每个子张量,执行自注意力计算以获得输出张量 $\mathbf{Q}_i$ 。最后,将 h 个输出张量拼接在一起,得到最终的输出张量 $\mathbf{O}$ 。 $\mathbf{X} \in \mathbf{R}^{d \times d}$ 表示输入张量; $\mathbf{Q} \in \mathbf{R}^{d \times d}$, $\mathbf{K} \in \mathbf{R}^{d \times d}$ 和 $\mathbf{V} \in \mathbf{R}^{d \times d}$ 分别代表学习到的 D 维查询、键和值向量; h 表示头数^[28]。假设输入序列为 $x_1, x_2, x_3, \dots$, 则 MHA 计算为: $\text{MultiHead}(\mathbf{X}) = \text{Concat}(\text{head}_1, \dots, \text{head}_h) \mathbf{W}^0$, head_1 是第一注意力头; $\mathbf{W}^0$ 表示线性投影的权重参数。每个注意力头是通过使用式(10)对 $\mathbf{Q}$ 、 $\mathbf{K}$ 和 $\mathbf{V}$ 进行自注意力计算得到的:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right) \mathbf{V} \quad (10)$$

式中: d_k 表示 $\mathbf{Q}$ 的维度大小; $\mathbf{K}$ 用于缩放注意力的大小。

在单头注意力计算基础上,多头注意力为每个注意力头独立投影生成专属的查询、键、值向量并计算各自的注意力输出:

$$\text{head}_i = \text{Attention}(\mathbf{X}\mathbf{Q}_i, \mathbf{X}\mathbf{K}_i, \mathbf{X}\mathbf{V}_i), i = 1, \dots, h \quad (11)$$

$$\mathbf{Q}_i = \mathbf{X}\mathbf{W}_i^Q, \mathbf{K}_i = \mathbf{X}\mathbf{W}_i^K, \mathbf{V}_i = \mathbf{X}\mathbf{W}_i^V, i = 1, \dots, h \quad (12)$$

式中: $\mathbf{W}_i^Q \in \mathbf{R}^{d \times hQ}$, $\mathbf{W}_i^K \in \mathbf{R}^{d \times hK}$, $\mathbf{W}_i^V \in \mathbf{R}^{d \times hV}$ 和是学习到的投影矩阵; $\mathbf{Q}_i$ 、 $\mathbf{K}_i$ 和 $\mathbf{V}_i$ 分别是第 i 个注意头的查询、键和值向量。

4) ResNet 网络模块

为了进一步从 MHA 输出的融合特征中提取高阶判别性信息,本研究引入了残差网络(ResNet)模块。尽管 MHA 能够捕捉跨肌群的特征关联,但融合后的特征在高维空间中可能仍包含部分冗余噪声。传统的深层卷积网络容易面临梯度消失或爆炸的问题,导致性能退化。ResNet 通过引入跳跃连接,允许梯度在反向传播中直接流向浅层,有效解决了这一问题。

在本研究的框架中,ResNet 模块主要由堆叠的残差块组成。一个残差块的输出 $\mathbf{y}$ 可以表示为:

$$\mathbf{y} = \mathbf{F}(\mathbf{x}, \{\mathbf{W}_i\}) + \mathbf{x} \quad (13)$$

其中, $\mathbf{x}$ 和 $\mathbf{y}$ 分别代表残差块的输入和输出向量, $\mathbf{F}(\mathbf{x}, \{\mathbf{W}_i\})$ 表示学习到的残差映射 + $\mathbf{x}$ 是恒等跳跃连接,直接将输入加到残差分支的输出上。这种结构使得网络只需学习输入与输出之间的残差,降低了学习难度。

具体而言,根据表1的参数设置,本文构建了包含4个残差块的轻量化 ResNet 模块。每个残差块后均接 ReLU 激活函数以增强非线性表达能力。经过残差块处理后的特征序列,通过自适应平均池化层压缩为固定维度的全局特征向量,最后送入 Softmax 层进行5种运动模式的概率预测。

5) 模型参数设置

拟议的双分支融合识别网络的结构与参数配置如表1所示。

特征提取层采用双分支并行架构:针对大腿肌群的时序特征,设计双层双向 LSTM 分支,均采用双向传播机制捕捉双向时序依赖,最终通过 1×1 卷积层将特征维度压缩至 64 通道;针对小腿肌群的局部特征,构建3层一维卷积分支,卷积核大小统一设为 13,通过上采样恢复至 100 时间步,确保双分支特征维度匹配。双分支特征经通道维度拼接后输入多头注意力层,通过 LayerNorm 层归一化特征分布,强化关键时序特征的权重分配。分类器采用 ResNet 架构,包含4个残差块,所有残差块均采用 ReLU 作为激活函数,末端通过自适应平均池化层将特征压缩至 1×1 维度。为防止过拟合,次要肌肉卷积分支每层后引入丢弃率为 0.3 的 Dropout 层,优化器选用 AdamW,并采用 ReduceLROnPlateau 策略动态调整学习率;训练过程中设置早停机制,进一步提升模型泛化能力。该参数配置有效平衡了特征提取的充分性与模型复杂度,适配肌电信号的时序-空间特征特性。

表 1 双分支融合识别网络参数

Table 1 Parameters of the dual-branch fusion recognition network

序号	类型	输出维度	卷积核大小	滤波器数量	激活函数
0	Input	[32, 12, 100]	—	—	—
1	Frature split	Major: [32, 8, 100] Minor: [32, 4, 100]	—	—	—
2	Major Branch	—	—	—	—
3	2×BiLSTM + 1×1 Conv	[32, 64, 100]	—	64	—
4	Minor Branch	—	—	—	—
5	Conv1d×3 + Upsample	[32, 32, 100]	13	32	RELU
6	Concatenation + Multi-Head Attention	[32, 96, 100]	—	96	LayerNorm
7	ResNet Blocks + AdaptiveAvgPool1d	[32, 256, 1]	3	256	RELU
8	output	[32, 5]	—	—	Softmax

1. 4 评估指标

使用准确率 (Accuracy)、召回率 (Recall)、精确率 (Precision) 和 F1 分数 (F1-Score) 来评估下肢运动模式方法的分类性能。这些指标的相应计算为：

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$
 (14)

$$Recall = \frac{TP}{TP + FN}$$
 (15)

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

$$F_1 - Score = \frac{2(Precision \times Recall)}{Precision + Recall}$$
 (17)

其中，TP 表示正确识别的真阳性数，TN 表示正确识别出的真阴性数，FP 表示阴性样本被错误分类为阳性的假阳性数，FN 表示阳性样本被错误归类为阴性的假阴性数。

2 实验结果及分析

本研究中使用的硬件环境由 AMD Ryzen9 7945HX with Radeon Graphics 组成，运行频率为 2. 5 GHz，NVIDIA GeForce RTX 4060 Laptop GPU。软件环境由 python3. 9. 19 和 pytorch 1. 12. 0 和 CUDA 11. 6 组成。该数据集包含 2 500 个样本，分为训练 (80%，2 000 个样本) 和测试集 (20%，500 个样本)，确保对模型的可概化性进行严格评估。目标函数是交叉熵损失，使用 Adam 优化器，学习率为 0. 000 1。在整个模型训练过程中使用相同的目标函数、优化器和超参数。目标函数采用交叉熵损失，优化器为 AdamW，初始学习率设为 0. 001，并引入权重衰减系数 0. 000 1。学习率通过 ReduceLROnPlateau 调度器自适应调整。模型训练全程保持目标函数、优化器及超参数的一致性。

本文基于自建数据集与国际公开数据集开展了多维度的定性与定量实验，旨在全面评估所提出的 BCM-ResNet 模型在差异负载场景下的下肢运动意图识别性能。1)通过随机森林算法定量分析了负载诱导下的肌电特征演化规律，阐明了核心肌群特征随负载变化的偏移机制。2)开展了消融实验与参数灵敏度分析，量化探讨了多尺度卷积核的尺度因子、数量分布以及网络深度对特征提取能力的贡献。3)针对系统实用性进行了传感器配置优化实验，确定了在识别精度与系统开销之间实现帕累托最优的 12 通道单侧布局方案。4)通过跨受试者的公开数据集对比实验，验证了模型在异质生理特征下的泛化鲁棒性。5)与现有的主流时空特征分类模型及最新的负载识别模型进行对比，评估了本文算法在分类准确率与特征解耦能力上的先进性。6)通过高性能工作站与边缘计算平台的迁移性测试，量化分析了算法在不同算力环境下的推理延迟与执行一致性，验证了系统的工程实用价值。

2. 1 差异负载重量肌电信号特征分析

为直观表征负载对下肢肌电信号的影响，本文以股外侧肌 VL 为例，图 4 展示了受试者在同种动作模式下 (以下坡为例)，不同负载强度的通道 10 与其余通道的 sEMG 信号对比。

从图 4 中可以明显观察到，随着负载重量的增加，各通道信号的整体幅值包络呈现明显的扩张趋势。如通道 10 的股外侧肌 VL，其在低负载下的放电脉冲较为稀疏且幅值较低；随着负载增至高强度，VL 肌肉的信号变得极度密集，且波峰幅值包络明显扩张。这种原始波形在时域上的能量显著增强，为后续发生负载诱导的特征空间偏移提供了最直观的物理证据。

为了进一步区分负载对人体的影响，本文通过凝聚型层次聚类法将其聚为 3 类，由图 5 可知，样本点在特征空间内并未呈现随机散布，而是表现出显著的空间分




图 4 不同负载下的 sEMG 曲线
Fig. 4 sEMG curve under different loads

簇特性与流形演变,每一类之间类类边界清晰,类间相似度较高。

2.2 公开数据集验证与模型泛化性分析

为进一步验证本文提出的 BCM-ResNet 模型在不同受试者群体及异质传感器数据下的泛化性能与鲁棒性,本文引入了目前国际公认的下肢运动公开数据集^[22]进行对比实验。该数据集包含了 22 名健康受试者在平地行走、上下坡及上下楼梯等多种地形条件下的全下肢肌电与运动学数据,具有极高的样本多样性。

本文在该数据集上在保持模型超参数一致的前提下,进行了迁移训练与性能评估,实验数据如表 2 所示。BCM-ResNet 在准确率、精确率、召回率及 F1 分数 4 项核心指标上均优于对比模型,平均准确率达 92.85%,较典型时序模型 BiLSTM 提升了 4.9%。深入分析表明,尽管公开数据集中包含大量的非稳态步态信号与地形切换瞬时的特征扰动,本文模型仍展现出较强的建模能力。这得益于双分支结构对异质特征的分离提取:BiLSTM 分支有效追踪了下肢运动的长时序演化规律,而 Multi-scale CNN 分支则精准捕捉了地形切换瞬间的局部特征。多头注意力机制通过动态权重的分配,在特征融合阶段有效抑制了运动切换产生的信号噪声,证明了该算法




图 5 凝聚型层次聚类样本散点图
Fig. 5 Agglomerative hierarchical clustering sample scatter diagram

在真实复杂地形环境下实现外骨骼意图识别的可靠性与泛化潜力。

2.3 不同尺度卷积核的影响

基于 4 块小腿肌肉的 sEMG 信号,分析了不同尺度卷积核的多尺度特征提取和融合对下肢运动识别性能的影响。采用各种模型进行特征提取,表示为

表 2 对比方法在 EMG 下肢模式识别公开数据集上的性能对比

模型	Accuracy	Precision	Recall	F1-score
BiLSTM	0.876 9±0.012 8	0.880 4±0.012 3	0.875 9±0.012 9	0.877 9±0.012 6
DCNN	0.881 2±0.0130	0.884 5±0.012 5	0.880 5±0.013 1	0.882 0±0.012 8
TCN	0.907 3±0.012 2	0.910 8±0.011 8	0.906 4±0.012 3	0.908 5±0.012 0
CNN-LSTM	0.819 5±0.011 5	0.824 0±0.010 8	0.818 0±0.011 8	0.820 5±0.011 2
CAD	0.865 1±0.012 9	0.868 6±0.012 4	0.864 2±0.013 0	0.866 3±0.012 7
本文模型	0.928 5±0.006 5	0.903 0±0.006 8	0.898 5±0.007 3	0.900 5±0.007 1

CNN(9,9,9)、CNN(11,11,11)、CNN(13,13,13)、CNN(15,15,15)、CNN(15,13,11)给出了从5次交叉验证中获得的

最优模型的平均性能指标。如表3所示。

表 3 不同尺度卷积核对比

Table 3 Comparison of convolutional kernels at different scales

模型	Accuracy	Precision	Recall	F1-score
CNN(9,9,9)	0.940 5±0.008 9	0.943 2±0.007 9	0.940 0±0.008 8	0.940 8±0.009 8
CNN(11,11,11)	0.944 0±0.006 1	0.946 0±0.004 9	0.943 6±0.006 1	0.944 8±0.006 6
CNN(13,13,13)	0.947 8±0.007 2	0.946 5±0.007 5	0.945 8±0.007 3	0.947 2±0.008 1
CNN(15,15,15)	0.941 7±0.008 7	0.942 8±0.008 4	0.941 2±0.008 8	0.942 0±0.008 8
CNN(15,13,11)	0.935 7±0.016 0	0.936 8±0.015 1	0.935 2±0.014 9	0.936 8±0.015 6

很明显,随着卷积核大小的增加,准确性、加权精度、加权召回率、加权 F1 值最初表现出上升趋势,在 CNN(13,13,13)中分别在 0.947 8、0.946 5、0.945 8 和 0.947 2 达到峰值,然后呈下降趋势。此外,图 6 描述了基于测试集上 12 块肌肉的 sEMG 信号的 LLMR 的 CNN(13,13,13)的混淆矩阵。




图 6 混淆矩阵

Fig. 6 confusion matrix

矩阵包含表示每个预测类别的样本计数的数值。结果表明,CNN(13,13,13)在各种运动的个体间识别中表现出高精度。出现这种现象可归因于较大的卷积核尺度 13 有效匹配了高频 sEMG 信号的时域特性,能够完整覆盖肌肉激活的爆发相位,提升了局部特征的表征能力;其次,3 层同尺度卷积的堆叠形成了深层时域感受野,在通过最大池化层抑制高频噪声的同时,实现了对小腿肌群精细调节动作的高阶非线性映射;最后,该尺度在特征对齐过程中能够更好地抑制负载变化引入的信号伪影,增强了特征的负载鲁棒性。

2.4 传感器配置优化与系统开销分析

在下肢外骨骼控制系统中,传感器的数量与布局直接影响穿戴便捷性、计算开销及识别性能。本研究将 12 个传感器集中布置于受试者右腿,包括大腿 8 通道,小腿

4 通道,主要基于下肢运动的生物力学对称性考量。由于健康个体在稳态步态中左右腿具有高度的功能映射关系,单侧肢体的高密度信号采集能够比双侧稀疏采集更深层次地捕捉肌群间的协作特征,且能显著降低跨肢体信号传输的硬件同步相位误差,确保异质特征在时间维度上的高度对齐。此外,这种布局在保证生理信息完整性的前提下,有效降低了硬件系统的穿戴复杂度与同步开销。为验证 12 通道配置的帕累托最优性,本节对比了 10~14 通道下的性能表现。

如表 4 所示,识别性能随通道数增加呈现先显著提升后趋于饱和的趋势:当通道数从 10 增至 12 时,准确率由 0.913 1 显著提升至 0.947 8,F1 分数同步优化,证明 12 通道已能充分表征复杂负载下的肌肉协同模式。然而,进一步增至 13、14 通道时,性能增益迅速收敛,仅提升约 0.04%~0.09%,冗余通道引入的信息增量未能弥补特征维数增加带来的模型收敛压力。在系统开销方面,单样本推理时间随通道数近似线性增长,14 通道较 12 通道增加约 15.8% 的计算耗时,更多通道不仅增长时间较多还会提升硬件穿戴复杂度与能耗,降低便携性与用户舒适度。

综上,本文 12 通道配置在识别精度与系统实时性、穿戴便捷性之间实现最优平衡,兼具高精度识别与轻量化工程价值。

2.5 双分支融合识别网络 t-SNE 图分析

为了直观地评估所提出的双分支融合识别网络在特征提取与整合过程中的有效性,本文将测试数据集输入到训练好的网络中,并提取了关键层的特征映射进行分析。具体而言,提取了多尺度 CNN 分支的第 1、第 2 和第 3 层、双分支拼接后的融合层(Fused layer)、多头注意力层(MHA layer)以及最终的 ResNet 层的输出特征。随后,采用 t-分布随机邻域嵌入(t-SNE)算法将高维特征向量降维至二维空间以实现可视化分布,结果如图 7 所示。

如图 7(a)~(c)所示,在多尺度 CNN 进行局部特征提取的初始 3 个阶段,5 种运动模式(上坡、下坡、上楼、

表 4 传感器配置对比

Table 4 Sensor configuration comparison

模型	通道数	Accuracy	Precision	Recall	F1-score	识别时间/ms
弱化配置 A	10	0.913 1±0.010 4	0.914 4±0.011 7	0.912 4±0.010 5	0.914 4±0.010 5	0.139 8
弱化配置 B	11	0.929 8±0.008 7	0.932 4±0.008 3	0.929 2±0.008 8	0.930 0±0.009 2	0.143 3
本文配置	12	0.947 8±0.007 2	0.946 5±0.007 5	0.945 8±0.007 3	0.947 2±0.008 1	0.148 5
冗余配置 A	13	0.948 2±0.006 9	0.947 1±0.007 8	0.946 2±0.008 2	0.946 6±0.007 6	0.161 0
冗余配置 B	14	0.948 7±0.007 1	0.947 6±0.007 4	0.946 9±0.007 8	0.947 2±0.007 5	0.172 0




图 7 不同层的使用 t-SNE 的模型特征提取可视化

Fig. 7 Visualization of feature extraction using t-sne at different layers

下楼、平地)的特征分布呈现出显著的混沌状态。各类别的样本点相互交织、重叠严重,并未形成清晰的聚类簇。这一现象主要归因于原始 sEMG 信号在不同负载条件下具有高度的非线性与不稳定性,且单纯的小腿局部特征在浅层网络中尚未形成具有足够判别力的语义信息,导致不同运动模式间的特征边界模糊不清。

然而,当大腿肌群的时序特征与小腿肌群的局部特征在融合层(图 7(d))进行拼接后,特征分布开始出现初步的分离迹象。这表明结合大小腿肌群的异质性特征,能够互补地描述负载下的下肢运动状态,为后续的分类提供了更丰富的信息基础。

随着特征流经 MHA 层(图 7(e)),模式分离的趋势变得愈发明显。得益于多头注意力机制对关键特征通道的动态权重分配与噪声抑制,同类运动模式的样本点开始紧密聚集,类间距离显著增大。最终,在利用 ResNet 层(图 7(f))完成深层特征抽象后,所有 5 种运动模式均

被清晰地分离,形成了界限分明、互不重叠的独立簇群。这有力地证明了本研究提出的 BCM-ResNet 模型在复杂负载场景下,能够从多通道肌电信号中提取出高阶判别性特征,有效克服了负载变化带来的干扰,实现了对下肢连续运动模式的精准识别。

2.6 双分支融合识别网络的消融实验

为了验证所提出的双分支融合识别网络中各模块的有效性,在测试集上进行了一系列消融实验,具体性能指标如表 5 所示。实验以标准的 ResNet 作为基准模型,其分类准确率为 92.50%。

首先,在基准模型上分别引入了针对不同肌群特性的特征提取模块。结果显示,用于大腿肌群时序特征提取的 BiLSTM-ResNet 和用于次要肌群空间特征提取的 CNN-ResNet,其准确率分别提升至 93.81% 和 94.29%。这验证了本研究提出的“差异化分解”策略的有效性:大腿肌群作为主要发力源,具有强时序性,适合 BiLSTM 提

表 5 双分支融合识别网络消融实验

Table 5 Ablation study results of the dual-branch fusion recognition network

模型	Accuracy	Precision	Recall	F1-score
ResNet	0.925 0±0.012 2	0.927 6±0.012 1	0.924 4±0.011 9	0.925 2±0.011 6
BiLSTM-ResNet	0.938 1±0.002 9	0.939 2±0.003 3	0.937 6±0.002 9	0.939 2±0.002 7
CNN-ResNet	0.942 9±0.008 9	0.944 8±0.007 9	0.942 4±0.009 0	0.943 6±0.009 7
BiLSTM-MHA-ResNet	0.941 7±0.004 4	0.943 6±0.003 6	0.941 2±0.004 2	0.942 4±0.004 2
CNN-MHA-ResNet	0.944 5±0.012 0	0.945 2±0.011 5	0.944 0±0.012 1	0.944 8±0.011 7
CNN-BiLSTM-ResNet	0.946 4±0.007 5	0.946 4±0.007 0	0.946 0±0.007 6	0.948 0±0.007 6
BCM-ResNet	0.947 8±0.007 2	0.946 5±0.007 5	0.945 8±0.007 3	0.947 2±0.008 1

取;而小腿肌群负责精细调节,具有丰富的局部特征,适合 CNN 提取。依据生理特性将信号分解并送入特定的特征提取流,比将所有通道统一处理能更有效地捕捉负载下的运动本质,分别克服负载带来的时序动态变化和局部模式变异。

其次,为了验证多头注意力机制在特征增强方面的作用,本文在各单分支中加入了 MHA 模块。实验数据表明,BiLSTM-MHA-ResNet 和 CNN-MHA-ResNet 的准确率进一步提升至 94.17% 和 94.45%。这证明了 MHA 能够有效聚焦于关键特征通道,抑制负载噪声,通过动态权重分配强化关键特征,从而提升模型的特征表达能力。

最后,本文评估了双通道融合架构的整体性能。当联合 BiLSTM 和 CNN 分支时,模型准确率达到 94.64%,已优于所有单分支模型,证明了大小腿肌群特征具有显著的互补性。而完整的 BiLSTM-CNN-MHA-ResNet 模型取得了最优性能,准确率高达 94.78%,F1 分数达到 0.947 2。相较于去除 MHA 的双通道版本,准确率提升了约 0.5%,再次印证了 MHA 在特征融合阶段的重要性。MHA 通过加权融合跨肌群特征,显著增强了不同负载下

相似运动模式的特征分离度。综上所述,消融实验充分证明了本研究提出的各模块均对提升运动模式识别性能做出了积极贡献。

2.7 与现有技术的比较

表 6 和 7 比较了该方法与多种传统机器学习分类器和使用 sEMG 信号进行动作分类的先进深度学习分类器的分类性能和计算复杂度。

表 6 与现有方法的计算复杂性比较

Table 6 Comparison of computational complexity with existing methods

模型	参数量/M	训练时间/s	识别时间/ms
BiLSTM ^[13]	0.574 7	24.700 0	0.100 9
DCNN ^[14]	12.327 5	69.580 0	0.172 4
TCN ^[15]	0.878 9	32.740 0	0.086 6
CNN-LSTM ^[16]	14.720 0	32.496 0	0.126 0
CAD ^[17]	0.091 7	60.750 0	0.213 7
本文模型	1.307 2	42.410 0	0.148 5

表 7 与现有方法的性能比较

Table 7 Performance comparison with existing methods

序号	方法	年份	Accuracy	Precision	Recall	F1-score
1	BiLSTM ^[13]	2021	0.888 1±0.014 0	0.888 4±0.012 2	0.887 2±0.013 0	0.889 6±0.013 2
2	DCNN ^[14]	2023	0.904 7±0.008 9	0.907 6±0.007 9	0.904 0±0.009 3	0.905 2±0.009 3
3	TCN ^[15]	2022	0.903 6±0.005 8	0.905 6±0.005 9	0.902 8±0.006 1	0.904 0±0.006 1
4	CNN-LSTM ^[16]	2023	0.863 1±0.010 5	0.865 2±0.010 9	0.862 0±0.011 4	0.863 2±0.011 4
4	CAD ^[17]	2025	0.940 5±0.008 4	0.942 0±0.008 8	0.940 0±0.008 5	0.942 0±0.008 9
5	本文模型	2025	0.947 8±0.007 2	0.946 5±0.007 5	0.945 8±0.007 3	0.947 2±0.008 1

根据表 7 和图 8,显然本研究中的 BiLSTM-CNN-MHA-ResNet 模型在 Accuracy、Precision、Recall 和 F1-score 方面均获得最高,分别为 0.947 8、0.946 5、0.945 8、

0.947 2。这超过了 BiLSTM、DCNN、TCN、CNN-LSTM、CNN-Attention-DenseNet,这些模型表现出强大的分类能力。具体来说,这些指标分别比 BiLSTM 高出 6.31%、




图 8 各种方法的对比

Fig. 8 Comparison effect diagrams of various methods

6.28%、6.36%和6.36%,显示出模型的显著提升。结果表明,所提出的 BCM-ResNet 模型在多种负载等级与负载方式下均能保持极高的识别精度,表现出优异的分类准确性与对负载扰动的鲁棒性。相比于对比模型,本方法能够更稳定地提取跨负载场景下的判别性特征。

在计算复杂度与实时性方面,如表 6 所示本文提出的 BCM-ResNet 在识别准确率 94.78% 与推理时间 0.148 5 ms 之间达到了最优平衡。相比于纯 BiLSTM 模型,虽然引入了 CNN 和 MHA,但由于采用了差异化肌群处理策略,推理速度并未显著下降。这证明了该模型在保证实时性的前提下,通过深度特征融合有效克服了负载扰动带来的性能衰减,具有极高的工程实用价值。鉴于 sEMG 信号通常比肢体动作提前 50~100 ms 产生,且加上信号预处理和分解的时间,所提方法的总处理时间远低于这一时间窗口。这确保了在运动发生前提供足够的时间余量来控制外骨骼系统,从而在理论上增强了人机协同的顺应性与安全性。

2.8 硬件平台迁移性与算法稳定性分析

为评估 BCM-ResNet 在不同工业应用场景下的表现,

本研究选取了两套算力梯度差异显著的硬件平台进行迁移性测试:平台 A 为配备高性能显卡的工作站,代表高通量数据处理场景;平台 B 为移动便携式计算平台。实验结果如表 8 所示。

表 8 不同硬件平台比较		
Table 8 Comparison of different hardware platforms		
硬件平台	准确率	推理时间/ms
平台 A	0.947 8	0.148 5
平台 B	0.943 1	0.219 5

在保持模型结构参数一致的前提下,BCM-ResNet 在两个平台上的识别准确率偏差仅为 0.47%,证明了该算法具有极高的数值稳定性。在实时性指标上,尽管平台 B 的算力弱于平台 A,但其单次推理延迟仍稳定在 0.2 ms 左右,远低于人体运动识别的实时反馈阈值。实验证明,本研究提出的 BCM-ResNet 方法对计算资源的需求具有良好的弹性,不依赖于高性能计算环境,在不同硬件架构下均能保持极高的计算一致性与执行效率,展现了优异的硬件自适应能力。

3 结 论

本文提出了一种基于 sEMG 信号的新型运动模式分类方法,用于识别不同负载条件下的下肢连续运动模式。针对大小腿肌群的生理异质性,采用了基于生理功能的差异化特征提取策略。通过 BiLSTM 和多尺度 CNN 分别处理大腿的时序特征和小腿的局部特征,有效缓解了负载变化引起的信号非线性扰动,并增强了模型在复杂负载场景下的特征表示能力。提出了一个结合双向长短期记忆网络(BiLSTM)、多尺度卷积神经网络(CNN)、多头注意力机制(MHA)和残差网络(ResNet)的双分支融合识别网络,用于从 sEMG 信号中提取并融合不同肌群通道的双侧特征。共收集 10 名受试者在 3 种负载方式及不同负重重量下的 5 种运动模式数据。使用准确率、精确率、召回率和 F1 分数 4 个指标来评估模型的性能。实验结果显示,所提方法的平均识别准确率为 94.78%,显著优于其他 5 种先进方法。模型的推理时间仅为 0.148 5 ms,远低于 sEMG 信号产生的机电延迟(50~100 ms),满足实时应用需求。同时,所提出的方法在不同负载重量(0~14 kg)的复杂场景下展示了良好的鲁棒性。

本研究提出的 BCM-ResNet 模型有效提升了下肢外骨骼在多变负载工况下的意图识别精度。未来的研究将进一步探索该算法在工业助力外骨骼及复杂山地物流运输场景中的应用,重点优化模型对不同物理环境特征的自适应调节能力,以构建更加智能、稳健的人机协作系统。

参考文献

- [1] CHIU Y, WU Y, CHEN D, et al. Design of motion capture system-aided lower limb exoskeleton [J]. *Advances in Mechanical Engineering*, 2025, 17(6): 16878132251349638.
- [2] CHEN Y, MIAO SH, CHEN G, et al. Learning to assist different wearers in multitasks: Efficient and individualized human-in-the-loop adaptation framework for lower-limb exoskeleton [J]. *IEEE Transactions on Robotics*, 2024, 40: 4699-4718.
- [3] ZHANG W J, ZHAN Y J, JU W J, et al. A novel quasi-passive non-anthropomorphic lower limb exoskeleton for load-bearing[J]. *IEEE Robotics and Automation Letters*, 2024, 9(11): 9891-9898.
- [4] TIAN Y T, CHEN CH J, WU X J, et al. A rigid-flexible coupled lower limb exoskeleton for enhancing load-bearing ambulation[J]. *Biomimetics*, 2025, 10(11): 757.
- [5] KIGUCHI K, HAYASHI Y. An EMG-based control for

an upper-limb power-assist exoskeleton robot [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2012, 42(4): 1064-1071.

- [6] 黄秋慧,刘正芳.基于表面肌电信号的康复护理机器人人机交互技术[J].*自动化与仪器仪表*,2025(5): 167-171.
HUANG Q H, LIU ZH F. Human computer interaction technology of rehabilitation nursing robot based on sEMG signal[J]. *Automation and instrumentation*, 2025(5): 167-171.
- [7] 石欣,黄良文,梁飞,等.基于肌电信号的跨被试不变特征运动模式识别[J].*仪器仪表学报*,2026,47(2): 244-255.
SHI X, HUANG L W, LIANG F, et al Cross subject invariant feature motion pattern recognition based on EMG signal [J]. *Chinese Journal of Scientific Instrument*, 2026,47(2): 244-255.
- [8] ARTEMIADIS P. EMG-based robot control interfaces: Past, present and future[J]. *Advances in Robotics & Automation*, 2012, 1(2): 1-3.
- [9] 石欣,余可祺,敖钰民,等.基于下肢 sEMG 的疲劳模糊增量熵表征方法研究[J].*仪器仪表学报*,2024, 45(5):271-280.
SHI X, YU K Q, AO Y M, et al. Research on fatigue fuzzy incremental entropy characterization method based on sEMG of lower limbs[J]. *Chinese Journal of Scientific Instrument*, 2024,45(5): 271-280.
- [10] 赵功赫,曲峰,杨辰,等.躯干不同负重方式对人体步行的生物力学影响[J].*体育学刊*,2017,24(2): 128-134.
ZHAO G H, QU F, YANG CH, et al. Biomechanical effects of different trunk loading methods on human walking [J]. *Journal of Physical Education*, 2017, 24(2): 128-134.
- [11] SONG T, YAN ZH, GUO SH, et al. Review of sEMG for robot control: Techniques and applications [J]. *Applied Sciences*, 2023, 13(17): 9546.
- [12] GUPTA R, AGARWAL R. Single channel EMG-based continuous terrain identification with simple classifier for lower limb prosthesis[J]. *Biocybernetics and Biomedical Engineering*, 2019, 39(3): 775-788.
- [13] ZHOU C C, YANG L L, LIAO H, et al. Ankle foot motion recognition based on wireless wearable sEMG and acceleration sensors for smart AFO [J]. *Sensors and Actuators A: Physical*, 2021, 331: 113025.
- [14] ZHOU B, FENG N SH, WANG H, et al. Non-invasive dual attention TCN for electromyography and motion data fusion in lower limb ambulation prediction[J]. *Journal of*

Neural Engineering, 2022, 19(4): 046051.

[15] LEELAKITTISIN B, TRAKULRUANGROJ M, SANGNARK S, et al. Enhanced lightweight CNN using joint classification with averaging probability for sEMG-based subject-independent hand gesture recognition[J]. IEEE Sensors Journal, 2023, 23(17): 20348-20356.

[16] LI M, WANG J L, YANG SH Q, et al. A CNN-LSTM model for six human ankle movements classification on different loads[J]. Frontiers in Human Neuroscience, 2023, 17: 1101938.

[17] 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: 2536114.

[18] AL-TIMEMY A H, BUGMANN G, ESCUDERO J, et al. A preliminary investigation of the effect of force variation for myoelectric control of hand prosthesis[C]. 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2013: 5758-5761.

[19] TANG ZH CH, YU H N, CANG SH. Impact of load variation on joint angle estimation from surface EMG signals[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2016, 24(12): 1342-1350.

[20] TIAN J R, LI CH CH, LI C Q, et al. Improving wrist angle recognition accuracy under different load conditions[C]. 2019 IEEE 9th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems, 2019: 1267-1272.

[21] 张贤富. 面向多人机差异场景的肌电步态识别影响研究及应用[D]. 杭州: 浙江大学, 2019.

ZHANG X F, Research and application of EMG gait recognition for multiple human-machine difference scenes[D]. Hangzhou: Zhejiang University, 2019.

[22] 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.

[23] 崔浩洋. 基于下肢表面肌电信号的差异负载运动模式识别研究[D]. 重庆: 重庆大学, 2024.

CUI H Y, Research on differential load motion pattern recognition based on lower limb surface electromyography[D]. Chongqing: Chongqing University, 2024.

[24] DE LUCA C J. Surface electromyography: Detection and recording[J]. DelSys Incorporated, 2002, 10(2): 1-10.

[25] ZHANG L, LIU G, HAN B, et al. sEMG based human

motion intention recognition[J]. Journal of Robotics, 2019, 2019: 1-12.

[26] WEN L Q, XU J C, LI D L, et al. Continuous estimation of upper limb joint angle from sEMG based on multiple decomposition feature and BiLSTM network[J]. Biomedical Signal Processing and Control, 2023, 80: 104303.

[27] WAHID A, ULLAH K, IRFAN ULLAH S, et al. sEMG-based upper limb elbow force estimation using CNN, CNN-LSTM, and CNN-CRU models[J]. IEEE Access, 2024, 12: 128979-128991.

[28] CHANG CH, MA G X, ZHANG J H, et al. Investigation on the cnn-lstm-mha-based model for the heating energy consumption prediction of residential buildings considering active and passive factors[J]. Energy, 2025: 137508.

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 networks.



陈宇杰, 2024年于重庆大学获得学士学位, 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: 202413131134@stu.cqu.edu.cn

Chen Yujie received his B. Sc. degree from Chongqing University in 2024. 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, 主要研究方向为多模态人机交互。

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

Qin Pengjie received his B. Sc. degree from Chongqing University of Science and Technology in 2015, and 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.