



## 面向下肢外骨骼的运动意图识别算法研究

牛苗赫, 雷飞

引用本文:

牛苗赫, 雷飞. 面向下肢外骨骼的运动意图识别算法研究[J]. 智能系统学报, 2025, 20(2): 407-415.

NIU Miaohe, LEI Fei. Motion intention recognition algorithms for lower limb exoskeleton[J]. *CAAI Transactions on Intelligent Systems*, 2025, 20(2): 407-415.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202403025>

## 您可能感兴趣的其他文章

### 时空域融合的骨架动作识别与交互研究

Research on skeleton-based action recognition with spatiotemporal fusion and humanrobot interaction

智能系统学报. 2020, 15(3): 601-608 <https://dx.doi.org/10.11992/tis.202006029>

### 利用肌电信号求解关节力矩的研究及应用综述

A review of the research and application of calculating joint torque by electromyography signals

智能系统学报. 2020, 15(2): 193-203 <https://dx.doi.org/10.11992/tis.202001013>

### 仿猛禽视顶盖信息中转整合的加油目标跟踪

Aerial refueling target tracking using a falcon visual tectum information integrating like method

智能系统学报. 2019, 14(6): 1084-1091 <https://dx.doi.org/10.11992/tis.201909005>

### 多层卷积特征的真实场景下行人检测研究

Research on pedestrian detection based on multi-layer convolution feature in real scene

智能系统学报. 2019, 14(2): 306-315 <https://dx.doi.org/10.11992/tis.201710019>

### 触觉手势情感识别的超限学习方法

Extreme learning machine for emotion recognition of tactile gestures

智能系统学报. 2019, 14(1): 127-133 <https://dx.doi.org/10.11992/tis.201804029>

### 下肢外骨骼研究进展及关节运动学解算综述

Research progress of lower-limb exoskeleton and joint kinematics calculation

智能系统学报. 2018, 13(6): 878-888 <https://dx.doi.org/10.11992/tis.201804063>

DOI: 10.11992/tis.202403025

网络出版地址: <https://link.cnki.net/urlid/23.1538.tp.20250108.0921.009>

# 面向下肢外骨骼的运动意图识别算法研究

牛苗赫<sup>1</sup>, 雷飞<sup>2</sup>

(1. 北京工业大学 都柏林国际学院, 北京 100020; 2. 北京工业大学 信息科学技术学院, 北京 100020)

**摘要:** 随着人工智能和传感技术的快速发展, 下肢外骨骼技术在助力行走和运动辅助领域展现出巨大的潜力, 利用表面肌电 (surface myoelectricity, sEMG) 信号解码人体运动意图对实现人机运动的协调统一至关重要。然而, 由于 sEMG 信号具有时空差异和非线性动态的特点, 导致现有方法存在特征捕捉单一、识别准确率低等不足。针对上述问题, 提出一种基于多尺度卷积神经网络的运动意图感知模型。该模型采用多个差异卷积块提取 sEMG 信号的时间与空间尺度特征, 并利用多层深度网络捕捉 sEMG 信号的非线性动态特征。该模型针对离线肌电数据库的识别准确率达到 94%, 其中对全脚离地运动类别的识别准确率高达 98%。在人体穿戴下肢外骨骼进行在线运动意图识别实验中, 该模型的平均识别准确率超过 90%, 验证了其在下肢外骨骼意图识别领域的有效性。

**关键词:** 下肢外骨骼; 助力行走; 表面肌电信号; 人机运动; 多尺度; 卷积神经网络; 感知模型; 意图识别

**中图分类号:** TP391.4 **文献标志码:** A **文章编号:** 1673-4785(2025)02-0407-09

中文引用格式: 牛苗赫, 雷飞. 面向下肢外骨骼的运动意图识别算法研究 [J]. 智能系统学报, 2025, 20(2): 407-415.

英文引用格式: NIU Miaohe, LEI Fei. Motion intention recognition algorithms for lower limb exoskeleton[J]. CAAI transactions on intelligent systems, 2025, 20(2): 407-415.

## Motion intention recognition algorithms for lower limb exoskeleton

NIU Miaohe<sup>1</sup>, LEI Fei<sup>2</sup>

(1. Beijing-Dublin International College, Beijing University of Technology, Beijing 100020, China; 2. School of Information Science and Technology, Beijing University of Technology, Beijing 100020, China)

**Abstract:** The rapid advancement of artificial intelligence and sensing technology has highlighted the potential of lower-limb exoskeleton technology in assisted walking and motion assistance. Decoding human motion intention using surface myoelectric (sEMG) signals is essential for achieving coordination and unification of human-machine motion. However, owing to the spatiotemporal differences and nonlinear dynamics of sEMG signals, existing methods have limitations, such as single feature capture and low recognition accuracy. A motion intention perception model based on a multiscale convolutional neural network is proposed to solve these problems. The model uses multiple differential convolution blocks to extract the temporal and spatial scale features of sEMG signals. It utilizes a multi-layer deep network to capture the nonlinear dynamic features of sEMG signals. The recognition accuracy of this model for the offline EMG database is 94%, and that of the whole-foot off-ground motion category is 98%. The average recognition accuracy of this model is more than 90% in the experiment of online motion intention recognition using a lower-limb exoskeleton, which verifies its effectiveness in the field of lower limb exoskeleton intention recognition.

**Keywords:** lower limb exoskeleton; assisted walking; surface electromyography signals; human-machine movement; multi-scale; convolutional neural network; perceptual model; intention recognition

下肢外骨骼机器人是一种可穿戴式机器人系统, 通常由机械结构、传感系统、控制系统和电源

系统组成。下肢外骨骼基于仿生学原理, 在人体外部构建框架和驱动, 通过提供额外的力量 and 支撑来辅助个体进行运动<sup>[1]</sup>。而准确、时敏的运动意图感知是控制下肢外骨骼机器人的前提, 对实

收稿日期: 2024-03-25. 网络出版日期: 2025-01-08.

通信作者: 雷飞. E-mail: [leifei@bjut.edu.cn](mailto:leifei@bjut.edu.cn).

©《智能系统学报》编辑部版权所有

现人机运动的协调统一至关重要<sup>[2-3]</sup>。

随着传感技术的不断发展,利用人体各种信息进行感知预测的方法不断涌现。在利用物理信号进行感知预测方面,中科院研制出助力外骨骼机器人,利用足底三维力传感器检测足底压力变化来判断穿戴者的运动意图<sup>[4]</sup>。电子科技大学研究团队通过采集脚底压力和下肢关节转角等数据来判断人体实时步态相位<sup>[5]</sup>。哈尔滨工业大学设计的外骨骼机器人通过测量装在脚底的薄膜压力传感器数据来进行意图识别<sup>[6]</sup>。西北工业大学袁小庆等<sup>[7]</sup>提出一种融合人机交互力信号和位姿信号的运动意图识别算法。安庆师范大学研究团队利用惯性测量单元检测用户的运动意图<sup>[8]</sup>。物理信号来源于已完成的动作状态,无法提前判断人体运动意图,并且大多数方法采用预编程被动控制,没有将人体意图与步态控制有效结合起来。

人体表面肌电信号响应速度快,能够提前预测人体的运动状态,易于人机交互的实时控制。使用表面肌电信号解码人体运动意图成为当前研究的重点之一<sup>[9]</sup>。在利用表面肌电(surface myoelectricity, sEMG)信号进行感知预测方面,中科院自动化研究所研究团队利用多路表面肌电时序特征进行人体运动模式识别<sup>[10]</sup>。中国科学技术大学团队采用四通道表面肌电信号作为下肢外骨骼机器人的控制信号,提出一种基于网格搜索随机森林算法的分类方法<sup>[11]</sup>。中国科学院深圳先进技术研究院研究团队使用高密度表面肌电图实现了前臂运动的实时分类<sup>[12]</sup>。浙江大学设计了一种无线信号采集系统(wireless signal acquisition system, WAS),利用WAS采集sEMG和加速度数据进行踝足运动识别<sup>[13]</sup>。南京邮电大学设计了一种基于深度学习的sEMG手势识别系统<sup>[14]</sup>。南开大学研究团队设计了一种手部运动识别系统,仅利用3个通道的sEMG信号就可以实现对9种手部运动的精准分类<sup>[15]</sup>。安徽大学曾敏等<sup>[16]</sup>提出一种基于sEMG-Transformer的下肢多关节角度运动预测模型,并将其应用于下肢外骨骼机器人。利用sEMG信号解码人体运动意图的现有方法存在泛化能力差、捕捉特征单一问题,无法适应sEMG信号的非线性动态特性。

为了解决上述问题,本文提出一种多尺度运动意图感知模型,采用多尺度深度卷积网络提取sEMG时间和空间尺度特征,通过多层深度网络实现端到端学习,使模型动态适应sEMG信号的非线性特征。基于离线肌电数据库和人体穿戴下肢外骨骼在线运动实验,验证了该模型在运动意

图识别领域的有效性。

## 1 人体下肢运动肌电数据库构建

### 1.1 实验设备

数据采集系统包括肌电数据采集系统、脚底压力采集系统和数据采集同步触发装置。肌电数据采集系统由Delsys无线采样电极、实时通信基站和配套的Delsys Trigno Control Utility软件构成,如图1所示,该系统能够同时采集人体多块肌肉的肌电数据。脚底压力采集系统由myRIO控制器和脚底压力传感器构成,如图2所示,该系统可以实时记录脚底多个部位的的压力数据,通过数据分析可以判断出脚底各个部位是否与地面接触,从而判断人体当前所处的步态相位。将步态相位与肌电数据相对应,可以获得带标签的肌电信号样本,这些样本可以作为开发运动意图感知模型的训练数据。为保证各个设备的数据采集是同步进行的,采集时需借助同步触发装置来保证Delsys无线采样电极、Delsys通信基站、脚底压力传感器和myRIO控制器同时开始采集数据而不会发生延迟,同步触发器如图3所示。




图1 肌电数据采集系统  
Fig. 1 EMG data acquisition system




图2 脚底压力采集系统  
Fig. 2 Foot pressure collection system



图3 同步触发装置  
Fig. 3 Synchronous trigger device



## 1.2 数据采集流程

本实验共招募了12名男性健康受试人员,年龄在22~26岁,身体素质良好,无下肢疾病。实验前需要为受试人员粘贴和佩戴实验所需设备,具体包括:在受试人员体表指定肌肉位置粘贴Delsys无线采样电极,如图4所示;在受试人员脚底指定位置粘贴脚底压力传感器,如图5所示。受试人员还需随身携带myRIO控制器及其电源。本次实验共采集9块肌肉的肌电信号,9块肌肉分别是股内侧肌、股外侧肌、腓肠肌内侧、腓肠肌外侧、股直肌、胫骨前肌、比目鱼肌、半腱肌和股二头肌长条头,这些肌肉的活动与下肢运动密切相关<sup>[17-18]</sup>,实验需要在这9块肌肉的位置粘贴Delsys无线采样电极。对于脚底压力信号,由于足跟骨和第一跖骨处是人体行走运动时足底的主要受力区域,从这2部分采集的数据可靠性高,可以用于对连续动作进行划分。因此,本实验选择采集脚底第一跖骨和足跟骨处的压力数据,在这2处粘贴脚底压力传感器。




图4 粘贴采样电极的身体部位

Fig. 4 Attach the body part of the sampling electrode




图5 足底压力的采集部位

Fig. 5 Plantar pressure collection site

本次实验采集的运动包括3.5 km/h行走、4.5 km/h行走、5.5 km/h行走,共计3种运动。在实验过程中,每名受试者按照要求以指定速度进行跑步机行走实验,受试者按照自身行为习惯进行运动,无特定动作要求。每种运动进行3组实验,每7 min为1组(中间5 min为稳定运动状

态),每组间休息5 min。实验结束后,对采集的原始数据进行离线存储。基于采集的脚底压力数据,将人体运动步态分为4类:脚跟着地、脚与地平、脚跟离地和全脚离地。结合同步采集的脚底压力信号、肌电信号以及采集实验过程的录像,确定受试者当前的运动相位,为相对应的肌电数据打标签,从而获得具有标签的肌电样本。整体的肌电数据集构建流程如图6所示。



图6 数据集构建流程

Fig. 6 Dataset construction process

## 1.3 肌电信号处理

### 1.3.1 信号预处理

肌电采集系统采集的原始肌电信号容易受到环境噪声、检测仪器的干扰,需要对原始肌电信号进行预处理。传统的肌电信号预处理方法一般会采用滤波、快速傅里叶变换、正则化等操作<sup>[18-20]</sup>,然而这些预处理方法一般会使原始肌电信号丢失部分信息。为最大程度地保留原始肌电信号的信息,本实验对原始肌电信号仅进行带通滤波和标准化处理<sup>[21-22]</sup>。带通滤波采用20~450 Hz的巴特沃思滤波器,主要目的是去除肌电信号中的高频干扰。带通滤波器的传递函数为

$$H(s) = \frac{H(j\omega)}{H\left(\frac{j(\omega_1 + \omega_2)}{2}\right)}$$

式中:  $H(j\omega)$  是巴特沃思滤波器的传递函数,  $H\left(\frac{j(\omega_1 + \omega_2)}{2}\right)$  是中心频率的增益。

标准化处理的主要目的是消除不同信号幅度之间的差异,便于后续数据处理和分析。首先查找出整个运动中每个完整步态肌电信号的最大值,计算所有最大值的平均值,将肌电信号中的每个数据点除以平均值,得到标准化后的肌电信号:

$$X_i = \frac{X'_i}{\frac{1}{N} \sum_{n=1}^N M_k}$$

式中:  $X'_i$  表示未标准化的肌电信号数值,  $M_k$  表示每个完整步态中肌电信号的最大值,  $N$  表示整个运动中完整步态的数量。

### 1.3.2 信号截窗

在将肌电信号传递给模型算法之前必须保证数据和算法的输入维度一致,本实验利用滑动时间窗对肌电数据进行分割处理<sup>[23]</sup>。实验采集了9个通道的肌电数据,利用滑动时间窗口将每个

通道的肌电数据分割成 200 个采样点的信号段, 每段信号间隔 20 个采样点, 经过分割后的信号是一张 9 行×200 列的肌电图矩阵。每个肌电样本的标签是依据当前窗口中出现次数最多的步态相位来划定的。因此, 1 张肌电图代表着 9 个通道、200 的采样点的肌电数据, 1 张肌电图与其对应的标签代表着 1 个肌电样本。

综上所述, 本文构建了一个下肢运动的 sEMG 数据集, 共包含 12 名受试者的肌电数据, 涵盖了 4 种步态相位: 脚跟着地、脚与地平、脚跟离地和全脚离地。每一个肌电样本的尺寸大小为 9 行×200 列。每个受试者的数据平均有 23 000 个样本, 数据集一共包含 276 000 个样本。

## 2 运动意图感知模型搭建

### 2.1 深度卷积网络框架

基于深度卷积网络<sup>[24-25]</sup>, 本文提出了一种多尺度运动意图感知模型, 该模型由特征提取器和分类器构成, 如图 7 所示。特征提取器包含了 4 个卷积块, 前 2 个卷积块使用 1×3 的卷积核函数, 后 2 个卷积块使用 3×3 的卷积核函数。通过在网络的不同层级使用不同大小、不同数量的卷积核, 模型能够更有效地学习肌电数据不同层面的表征, 从而提高模型的性能和表示能力。前 2 个卷积块使用了 1×2 的最大池化层, 主要用于降低特征图的尺寸, 并提取主要的空间特征。最大池化层通过选取区域内最大值来实现特征的子采样, 从而减少模型对空间位置的敏感性。需要注意的是, 后 2 个卷积块中不包含最大池化层。每个卷积块都包含了批归一化层和激活层。批归一化层通过对每个批次的肌电信号输入进行标准化, 有助于减少内部协变量偏移和梯度消失问题, 主要用于加速模型收敛并增强模型的鲁棒性。激活层采用 Softsign 函数, 可以有效引入非线性特征。分类器包含了 2 个全连接块, 用于将提取的肌电特征映射到最终的分类结果。第 1 个全连接块包含了全连接层、批归一化层、激活层和丢弃层, 第 2 个全连接块仅包含 1 个全连接层。全连接层能够捕捉肌电信号的全局特征和关联信息, 有助于进行分类任务。分类器的第 1 个全连接块包含了丢弃层, 用于随机丢弃部分神经元, 以避免过拟合, 丢弃层可以有效提高模型的泛化能力, 减少神经元之间的协同适应性。该模型的第 1 个全连接层包含了 100 个神经元, 第 2 个全连接层包含了 4 个神经元对应 4 个分类动作。

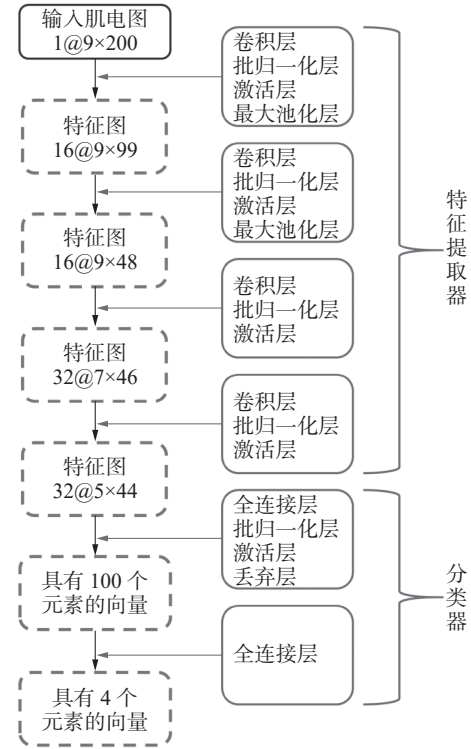


图 7 多尺度模型网络结构

Fig. 7 Multi-scale model network structure

综上所述, 本文提出了一种多尺度模型, 通过基于深度卷积网络的特征提取器和分类器的组合, 能够从肌电信号中提取核心特征并实现准确的动作分类。该模型利用了多尺度卷积操作、最大池化操作、批归一化和激活函数等技术, 以增强其对不同尺度特征的捕捉能力, 减少过拟合并增强模型的鲁棒性。

### 2.2 网络训练设置

多尺度模型的训练设置中, 采用了一系列优化策略和参数设置, 以提高模型的性能和训练效果。在训练过程中, 采用交叉熵损失作为目标函数<sup>[26-27]</sup>, 以度量模型预测结果和真实标签之间的差异。交叉熵损失的定义为

$$\mathcal{L}_{CE} = \mathbb{E}_{(\mathbf{x}, y) \in \mathcal{D}} \left[ - \sum_{c=1}^C \mathbf{1}[c = y] \log p^c(y|\mathbf{x}) \right]$$

式中:  $(\mathbf{x}, y)$  表示一个肌电样本,  $\mathbf{x}$  是肌电图,  $y$  是肌电样本的真实标签;  $C$  是类别总数,  $p^c(y|\mathbf{x})$  表示肌电样本是类  $c$  的概率;  $\mathbf{1}[a]$  是指示函数, 当  $a$  为真时,  $\mathbf{1}[a]$  为 1, 否则为 0。

为了动态调整学习率, 采用指数衰减法<sup>[28-29]</sup>, 初始学习率设置为 0.5, 衰减系数设置为 0.95。每个训练周期结束时, 学习率按照衰减系数进行更新, 这样的设置可以逐渐降低学习率, 使模型在训练后期更加稳定。优化算法选择了自适应时刻估计法 (adaptive moment estimation, Adam)<sup>[30]</sup>。

Adam 算法可以计算每个网络参数的自适应学习率,结合动量和自适应梯度缩放,从而加快模型的收敛速度并提高学习效果。网络的训练周期设置为 200,每次迭代训练时样本的数量设置为 100,这样的设置在一定程度上可以平衡训练速度和内存消耗。在整个过程中,网络的训练和测试均在 GeForce RTX 3060 Ti 上完成。

### 3 运动意图识别实验

#### 3.1 基于离线数据库意图感知实验

##### 3.1.1 方法内对比实验

利用采集的离线肌电数据库进行感知模型的训练与测试,本文设计了 4 种不同配置的运动感知模型,通过对比实验来验证本文所提出多尺度模型的有效性。这 4 种运动意图感知模型具有相同的设置,均包含 4 个卷积层,唯一不同的是卷积层的核函数大小不一样,如表 1 所示。

表 1 4 种模型的卷积层设置

Table 1 Convolutional layer settings for four models

模型	卷积层1	卷积层2	卷积层3	卷积层4
多尺度模型	1×3	1×3	3×3	3×3
对比模型1	1×3	3×3	3×3	3×3
对比模型2	1×3	1×3	1×3	3×3
对比模型3	3×3	3×3	3×3	3×3

利用相同的训练集和测试集数据,对这 4 种模型进行训练和测试,结果显示它们均能够收敛。在训练过程中,4 种模型的训练损失均逐渐降低,3 种模型的最小训练损失小于 1,如图 8 所示。其中本文提出的多尺度模型的训练损失最低,接近 0.1,而对比模型 3 的训练损失最低只能达到 1.12。在整个训练周期中,4 种模型在测试集上的识别准确率逐渐增加,3 种模型的测试准确率超过 90%,如图 9 所示。其中本文提出的多尺度模型的测试准确率最高,约为 94%;对比模型 1 与对比模型 2 的测试准确率相近,分别为 91.86% 和 91.67%;而对比模型 3 的测试准确率最低,仅达到 86.81%。实验结果验证了多尺度模型的有效性。为进一步观察多尺度模型的分类效果,绘制了其分类的混淆矩阵,如图 10 所示。本文提出的多尺度模型在 4 种类别运动中的识别准确率均超过 90%,其中脚跟离地的识别准确率达到 96%,全脚离地类别的识别准确率达到 98%。结果表明多尺度模型具有较高的识别准确率。




图 8 4 种模型的训练损失

Fig. 8 Training loss for four models




图 9 4 种模型的测试准确率

Fig. 9 Test accuracy for four models




图 10 多尺度模型的混淆矩阵

Fig. 10 Confusion matrix of multi-scale model

##### 3.1.2 方法间对比实验

为了进一步说明多尺度模型的优越性,将该模型与一些分类算法进行了比较。这些分类算法包括一维卷积神经网络 (1D convolutional neural networks, 1D-CNN)、循环神经网络 (recurrent neural network, RNN) 和门控循环单元 (gated recurrent units, GRU)。其中,1D-CNN 利用一维卷积核提取每个通道肌电数据的特征,并将所有通道的特征整合,最终实现步态分类。RNN 善于提取时间序列特征,具有参数共享和循环连接的特点。GRU 是 RNN 网络的一种变体,引入了更新门与复位



门,一定程度上弥补了RNN梯度消失的问题。各个算法均应用了贝叶斯超参数寻优,以确保每种算法的性能达到最高水平。

1) 1D-CNN由3个卷积块和3个全连接层组成,其中每个卷积块包含了1个一维卷积层、1个一维批量归一化层、1个ReLU激活函数层和1个一维最大池化层。

2) RNN包含了1个单向RNN层和2个全连接层,最后使用Softmax来计算每个输出类别的概率。

3) GRU包含了1个单向GRU层和2个全连接层,最后使用Softmax来计算每个输出类别的概率。

这些算法与多尺度模型(multi-scale model, MSM)将在本文的肌电数据集上进行性能评估。本文选择了3个性能指标:准确率、精确率和召回率。具体公式分别为

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FN} + N_{FP} + N_{TN}} \times 100\%$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \times 100\%$$

$$R = \frac{N_{TP}}{N_{TN} + N_{TP}} \times 100\%$$

式中:  $N_{TN}$ 、 $N_{FN}$  分别为真阴性和假阴性的数量;  $N_{TP}$ 、 $N_{FP}$  分别为真阳性和假阳性的数量。

方法间的对比实验结果如表2所示。1D-CNN模型3个性能指标均最低,这可能是由于一维卷积只能提取单个通道的特征,而无法提取不同通道之间的关联特征导致的。RNN与GRU均能够很好地处理时间序列的肌电数据,并能够有效捕捉序列中的时序信息,其准确率分别为90.86%和91.23%。相比之下,基于多尺度卷积网络的模型能够同时捕捉肌电数据时间和空间维度的特征,这大大提高了模型的适应性。多尺度模型在3种统计指标中表现均最优异。

表2 不同方法的实验结果

方法	准确率	精确率	召回率
1D-CNN	87.93	86.81	90.13
RNN	90.86	91.63	93.24
GRU	91.23	91.74	92.13
MSM	94.00	95.54	93.82

综上所述,本文提出的多尺度模型首先采用2个 $1 \times 3$ 的卷积层提取肌电信号时间维度的特征,然后利用2个 $3 \times 3$ 的卷积层进一步提取肌电信号时间和空间维度的特征,取得了最佳的实

验结果。通过方法内和方法间的对比实验分析,验证了多尺度模型在肌电信号识别任务中的有效性。

### 3.2 在线运动意图识别实验

#### 3.2.1 下肢外骨骼与实验控制台

下肢外骨骼主要由控制单元、驱动单元、腰带、鲍登绳、小腿绑带和脚跟弹簧体组成,如图11所示。整个外骨骼系统的工作原理是通过上层控制算法检测人体步态,利用力传感器实时反馈脚跟的拉力信号,控制单元根据反馈的信号生成下一时刻电机的位移指令,电机接受指令后拉动鲍登绳对人体踝关节提供助力,从而实现下肢外骨骼协助人体进行运动。



图11 下肢外骨骼结构

Fig. 11 Lower limb exoskeleton structure

腰带是整个外骨骼结构的核心部分,驱动单元、控制单元和电池都通过S形扣固定在腰带上。鲍登绳产生的内力也通过小腿和大腿之间的连接带传至腰部。驱动单元内部装有无刷直流电机,用来驱动鲍登绳对踝关节提供助力。控制单元是系统的大脑,内部包含了主控制单元、力传感器变送器、printed circuit board分电板等部件,它主要负责处理力传感器反馈的信号,并生成下一时刻的控制指令。鲍登绳及其外壳是助力驱动的重要中间载体,电机主轴带动槽轮旋转,从而牵引鲍登绳实现驱动。小腿绑带用于固定鲍登绳外壳的末端,实现对鲍登绳的位置约束。脚跟弹簧体为末端执行机构,通过鲍登绳拉动弹簧带动脚踝来达到助力效果。

在线实验控制台如图12所示。在线实验开始前将利用离线数据库训练完的模型写入NVIDIA Jetson TX2(TX2)设备中。在线实验时,利用计算机将实时采集的原始肌电数据发送至TX2套件中,利用套件中的数据处理程序对肌电数据进行实时的预处理和滑动窗口采样,处理完成的肌电数据输入多尺度模型中进行识别分类。TX2与下肢外骨骼控制单元通过TCP/IP通信,TX2将依据实时肌电数据识别的结果发送至外骨骼的上层控制单元,以实现对外骨骼的实时控制。




图 12 在线实验控制台  
Fig. 12 Online experiment console

### 3.2.2 运动意图识别在线实验

实验前需要对实验设备进行连接,并为受试人员粘贴传感器,粘贴传感器的具体流程和部位与数据采集时保持一致。根据文献[31-32],本文设置了3种不同的速度步行试验,以模拟现实生活中速度的不均匀变化。准备完成后,受试人员穿戴下肢外骨骼进行跑步机行走实验,行走速度分别为3.5、4.5、5.5 km/h。每种速度下的运动持续5 min,组间视疲劳程度进行充分休息,共有3名受试人员参与实验。最后依据模型对每种运动持续5 min 识别准确率的平均值进行实验结果分析。

实验结果如图13所示,3名受试者穿戴下肢外骨骼进行在线运动时,多尺度模型的识别准确率保持在较高水平。在3种类型实验中,多尺度模型在受试者4.5 km/h行走的测试表现最佳,识别准确率均超过91.5%。受试人员2在所有实验中的在线识别准确率达到最佳效果,模型的识别准确率均超过90%,特别是在4.5 km/h行走的实验中,识别准确率达93.1%。




图 13 在线测试准确率统计  
Fig. 13 Online test accuracy statistics

针对受试人员2的所有在线实验,绘制出其在在线识别的混淆矩阵,如图14所示。可以看出,在4种类别中,模型在线识别的准确率均超过90%,针对全脚离地类别的识别准确率达到97%。




图 14 在线运动的混淆矩阵

Fig. 14 Confusion matrix for online movements

综上所述,在线意图实验中,多尺度模型能够精准识别受试者的运动类别,并保持较高的准确率,验证了本文所提出基于多尺度卷积网络运动意图感知模型的有效性,并证明了该模型在下肢外骨骼实际控制中具有良好的应用潜力。

## 4 结束语

针对下肢外骨骼机器人的上层控制算法,本文提出了一种基于多尺度深度卷积网络的运动意图感知模型。通过在网络的不同层级使用差异卷积模块,模型能够更有效地学习肌电信号不同层级的表征,极大提高了模型的性能和表示能力。同时,该模型引入了多层深度网络实现了端到端学习,提高了模型的适应性和灵活性。离线消融实验结果表明,与传统单尺度模型相比,本文提出的多尺度模型具有较高的准确率。在人体穿戴下肢外骨骼进行在线运动意图识别实验中,该模型能够准确识别人体的步态相位,验证了其在实际应用中的有效性和稳定性。由于肌电信号的个体差异性导致算法应用于新用户时,模型性能急剧下降,极大阻碍了意图识别算法在外骨骼控制系统中的应用。未来,将进一步研究算法的自适应策略,以解决跨个体问题的阻碍。同时,将进一步研究超参数对于模型性能的影响以及算法的实时性能。

## 参考文献:

- [1] 白雪,梁文渊,王强,等. 下肢外骨骼机器人研究进展及趋势[J]. 中国科技信息, 2023(17): 146-149.  
BAI Xue, LIANG Wenyuan, WANG Qiang, et al. Research progress and trend of lower limb exoskeleton robot[J]. China science and technology information, 2023(17): 146-149.



- [2] 张洋, 谭昕, 程闯. 基于表面肌电信号的下肢运动识别[J]. *机电工程技术*, 2023, 52(9): 69–73, 151.  
ZHANG Yang, TAN Xin, CHENG Chuang. Lower limb motion recognition based on surface EMG signals[J]. *Mechanical & electrical engineering technology*, 2023, 52(9): 69–73, 151.
- [3] MILETI I, TABORRI J, TORRICELLI D, et al. Artificial neural network for the identification of postural instability in subject wearing lower limb exoskeleton[C]//2022 IEEE International Conference on Metrology for Extended Reality, Artificial Intelligence and Neural Engineering. Rome: IEEE, 2022: 651–655.
- [4] 田双太. 一种可穿戴机器人的多传感器感知系统研究[D]. 合肥: 中国科学技术大学, 2011.  
TIAN Shuangtai. Research on multi-sensor sensing system of wearable robot[D]. Hefei: University of Science and Technology of China, 2011.
- [5] 张倩. 下肢外骨骼康复机器人的机构设计与分析[D]. 成都: 电子科技大学, 2013.  
ZHANG Qian. Mechanism design and analysis of lower limb exoskeleton rehabilitation robot [D]. Chengdu: University of Electronic Science and Technology of China, 2013.
- [6] 蒋靖. 下肢助力外骨骼机构设计与研究[D]. 哈尔滨: 哈尔滨工业大学, 2014.  
JIANG Jing. Design and research of lower extremity assisted exoskeleton mechanism [D]. Harbin: Harbin Institute of Technology, 2014.
- [7] 袁小庆, 邹缓, 吴涛, 等. 基于运动意图识别的上肢助力外骨骼复合控制方法研究[J]. *机械工程学报*, 2023, 59(15): 73–82.  
YUAN Xiaoqing, ZOU Huan, WU Tao, et al. Compound control method for human-powered augmentation upper exoskeleton based on motion intent recognition[J]. *Journal of mechanical engineering*, 2023, 59(15): 73–82.
- [8] SU Benyue, WANG Jie, LIU Shuangqing, et al. A CNN-based method for intent recognition using inertial measurement units and intelligent lower limb prosthesis[J]. *IEEE transactions on neural systems and rehabilitation engineering*, 2019, 27(5): 1032–1042.
- [9] 丁其川, 熊安斌, 赵新刚, 等. 基于表面肌电的运动意图识别方法研究及应用综述[J]. *自动化学报*, 2016, 42(1): 13–25.  
DING Qichuan, XIONG Anbin, ZHAO Xingang, et al. A review on researches and applications of sEMG-based motion intent recognition methods[J]. *Acta automatica sinica*, 2016, 42(1): 13–25.
- [10] 佟丽娜, 侯增广, 彭亮, 等. 基于多路 sEMG 时序分析的人体运动模式识别方法[J]. *自动化学报*, 2014, 40(5): 810–821.  
TONG Lina, HOU Zengguang, PENG Liang, et al. Multi-channel sEMG time series analysis based human motion recognition method[J]. *Acta automatica sinica*, 2014, 40(5): 810–821.
- [11] SONG Ge, WANG Yucheng, WANG Mingming, et al. Lower limb movement intent recognition based on grid search random forest algorithm[C]//Proceedings of the 3rd International Conference on Robotics, Control and Automation. Chengdu: ACM, 2018: 225–229.
- [12] WEI Yue, GENG Yanjuan, YU Wenlong, et al. Real-time classification of forearm movements based on high density surface electromyography[C]//2017 IEEE International Conference on Real-time Computing and Robotics. Okinawa: IEEE, 2017: 246–251.
- [13] ZHOU Congcong, YANG Lilin, LIAO Heng, 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] SHEN Shu, GU Kang, CHEN Xinrong, et al. Gesture recognition through sEMG with wearable device based on deep learning[J]. *Mobile networks and applications*, 2020, 25: 2447–2458.
- [15] REN Xina, SOO Y G, ODAGAKI M, et al. sEMG-based hand motion recognition system using RMSR and AR model[C]//2017 36th Chinese Control Conference. Dalian: IEEE, 2017: 5410–5415.
- [16] ZENG Min, GU J, FENG Ying. Motion prediction based on sEMG- transformer for lower limb exoskeleton robot control[C]//2023 International Conference on Advanced Robotics and Mechatronics. Sanya: IEEE, 2023: 864–869.
- [17] WEI Baichun, YI Chunzhi, ZHANG Qi, et al. ActiveSelf-HAR: incorporating self-training into active learning to improve cross-subject human activity recognition[J]. *IEEE internet of things journal*, 2024, 11(4): 6833–6847.
- [18] ANDERSON F C, PANDY M G. Individual muscle contributions to support in normal walking[J]. *Gait & posture*, 2003, 17(2): 159–169.
- [19] AYACHI M, SEDDIK H. Overview of EMG signal pre-processing and classification for bionic hand control[C]//2022 IEEE Information Technologies & Smart Industrial Systems. Paris: IEEE, 2022: 1–6.
- [20] DE LUCA C J, KUZNETSOV M, GILMORE L D, et al. Inter-electrode spacing of surface EMG sensors: reduction of crosstalk contamination during voluntary contractions[J]. *Journal of biomechanics*, 2012, 45(3): 555–561.
- [21] 杜妍辰, 孙洁, 汪晓铭, 等. 一种基于表面肌电信号映射人体下肢运动意图的方法[J]. *生物医学工程学进展*, 2023, 44(2): 158–162.

- DU Yanchen, SUN Jie, WANG Xiaoming, et al. A method of human lower limb motion intention mapping based on surface electromyography[J]. *Progress in biomedical engineering*, 2023, 44(2): 158–162.
- [22] WU Yi, FOURN E, BESNIER P. A planar quad-band band-pass filter employing dual-mode band-stop resonators[C]//2021 IEEE MTT-S International Microwave Filter Workshop. Perugia: IEEE, 2021: 1–3.
- [23] DENG Yaping, JIA Hao, LI Pengcheng, et al. A deep learning method based on long short term memory and sliding time window for type recognition and time location of power quality disturbance[C]//2018 Chinese Automation Congress. Xi'an: IEEE, 2018: 1764–1768.
- [24] BAO Tianzhe, ALI RAZA ZAIDI S, XIE Shengquan, 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.
- [25] SAITO K, WATANABE K, USHIKU Y, et al. Maximum classifier discrepancy for unsupervised domain adaptation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 3723–3732.
- [26] WANG Kun, HUANG Yining, XU Lichao, et al. Decoding of pre-movement EEG patterns using cross-entropy loss-based ensemble learning[C]//2022 16th ICME International Conference on Complex Medical Engineering. Zhongshan: IEEE, 2022: 260–263.
- [27] CHO J W, KIM D J, JUNG Y, et al. MCDAL: maximum classifier discrepancy for active learning[J]. *IEEE transactions on neural networks and learning systems*, 2023, 34(11): 8753–8763.
- [28] KONAR J, KHANDELWAL P, TRIPATHI R. Comparison of various learning rate scheduling techniques on convolutional neural network[C]//2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science. Bhopal: IEEE, 2020: 1–5.
- [29] IIDUKA H. Appropriate learning rates of adaptive learning rate optimization algorithms for training deep neural networks[J]. *IEEE transactions on cybernetics*, 2022, 52(12): 13250–13261.
- [30] LLUGSI R, EL YACOUBI S, FONTAINE A, et al. Comparison between Adam, AdaMax and AdamW optimizers to implement a weather forecast based on neural networks for the Andean city of Quito[C]//2021 IEEE Fifth Ecuador Technical Chapters Meeting. Cuenca: IEEE, 2021: 1–6.
- [31] RAY N T, KNARR B A, HIGGINSON J S. Walking speed changes in response to novel user-driven treadmill control[J]. *Journal of biomechanics*, 2018, 78: 143–149.
- [32] RAFFALT P, GUUL M K, NIELSEN A, et al. Economy, movement dynamics, and muscle activity of human walking at different speeds[J]. *Scientific reports*, 2017, 7(1): 43986.

#### 作者简介:



牛苗赫, 硕士研究生, 主要研究方向为机器学习、计算生物学与生物信息学。E-mail: [949400110@qq.com](mailto:949400110@qq.com)。



雷飞, 副教授, 博士, 主要研究方向为计算机视觉、智能控制。主持国家试点项目 1 项, 获批发明专利 6 项, 发表学术论文 30 余篇, 出版教材 3 部。E-mail: [leifei@bjut.edu.cn](mailto:leifei@bjut.edu.cn)。