

# 基于多传感器信息融合和迁移学习的下肢外骨骼运动意图预测研究

俞志鹏<sup>1,2</sup>, 王美玲<sup>3,4</sup>, 王成军<sup>1,2</sup>, 凌六一<sup>1,2\*</sup>, 金力<sup>1,2</sup>

- (1. 安徽理工大学人工智能学院, 安徽合肥 231131; 2. 安徽理工大学煤炭无人化开采数智技术全国重点实验室, 安徽淮南 232001;  
3. 仿生感知与先进机器人技术安徽省重点实验室, 安徽合肥 230031;  
4. 中国科学院合肥物质科学研究院智能机械研究所, 安徽合肥 230031)

**摘要:** 下肢外骨骼需要通过识别穿戴者的运动意图为穿戴者日常活动提供助力, 然而当前的研究很少关注能够提供新受试者意图信息的下肢运动模式预测. 为此, 本文提出了一种基于多传感器信息融合和迁移学习的下肢运动模式预测方法. 本文首先设计了一个下肢运动模式预测模型, 采用长短时记忆单元 (Long-Short Term Memory, LSTM) 提取表面肌电信号 (surface ElectroMyoGraphy, sEMG) 中的模式特征, 然后将 sEMG 的模式特征与关节角度特征融合预测下肢运动模式. 考虑到受试者之间的生理信号差异, 本文设计的迁移学习策略分两步训练预测模型, 第一步在源域受试者数据集上预训练模型, 第二步冻结 sEMG 模式特征提取器的网络权值, 并在目标域数据集上微调全连接层. 实验采集了受试者自由行走和穿戴外骨骼行走的数据. 通过预测时间长度为 100 ms 的实验可以得出, 所提出的方法分别能够有效提升新受试者自由行走状态下和穿戴外骨骼行走时 9.53% 和 8.29% 的运动模式预测准确率. 实验结果表明, 所提出方法可通过提升新受试者运动模式预测准确率, 从而保障下肢外骨骼可靠的人体运动意图感知.

**关键词:** 下肢外骨骼; 下肢运动模式预测; 表面肌电信号; 迁移学习; 多传感器信息融合

**基金项目:** 安徽理工大学高层次人才引进人才科研启动基金 (No.2023yjrc111); 仿生感知与先进机器人技术重点实验室开放基金 (No.AHFS2024KF06)

中图分类号: TP24; TP391

文献标识码: A

文章编号: 0372-2112(2025)06-1969-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20241134

## Locomotion Intention Prediction via Multi-Sensor Fusion and Transfer Learning for Lower Limb Exoskeletons

YU Zhi-peng<sup>1,2</sup>, WANG Mei-ling<sup>3,4</sup>, WANG Cheng-jun<sup>1,2</sup>, LING Liu-yi<sup>1,2\*</sup>, JIN Li<sup>1,2</sup>

(1. School of Artificial Intelligence, Anhui University of Science & Technology, Hefei, Anhui 231131, China;

2. State Key Laboratory of Digital Intelligent Technology for Unmanned Coal Mining, Anhui University of Science & Technology, Huainan, Anhui 232001, China;

3. Anhui Key Laboratory of Bionic Sensing and Advanced Robot technology, Hefei, Anhui 230031, China;

4. Institute of Intelligent Machinery, Hefei Institutes of Physical Science, Chinese Academy of Sciences, Hefei, Anhui 230031, China)

**Abstract:** Lower limb exoskeletons require the capability to identify the user's lower-limb motion intentions to provide support during daily activities. However, existing research rarely focuses on predicting locomotion modes that provide user intention for new subjects. To bridge this gap, this study proposes a novel method for lower-limb locomotion mode prediction based on multi-sensor signal fusion and transfer learning. The study first designs a prediction model that utilizes long-short term memory (LSTM) networks to extract pattern features from surface electromyography (sEMG) signals. These sEMG features are then fused with joint angle features to predict lower-limb locomotion modes. Considering the inter-subject variability in physiological signals, the method employs a two-step training process using transfer learning. First, the model is pre-trained on a source domain dataset. Next, the weights of the sEMG feature extractor are frozen, and the fully connected layers are fine-tuned using a target domain dataset. Experimental data are collected from subjects performing both normal walking and exoskeleton-wearing walking. Experimental results with a prediction time of 100 ms demonstrate

that the proposed method enhances motion pattern prediction accuracy by 9.53% during free walking and by 8.29% during exoskeleton-wearing walking for new subjects. These results suggest that the proposed approach can improve locomotion mode prediction accuracy for new subjects, thereby ensuring reliable human motion intention prediction in lower-limb exoskeletons.

**Key words:** lower limb exoskeleton; locomotion mode prediction; surface electromyography; transfer learning; multi-sensor information fusion

**Foundation Item(s):** Scientific Research Foundation for High-Level Talents of Anhui University of Science and Technology (No.2023yjrc111); Anhui Key Laboratory of Bionic Sensing and Advanced Robot Technology (No.AHFS2024KF06)

## 1 引言

下肢外骨骼可增强穿戴者的运动能力,常用于脑卒中、脊柱损伤等患者运动功能重塑的康复训练以及士兵运动能力的增强<sup>[1]</sup>。随着人们对外骨骼穿戴舒适性以及人机运动协调性要求的提高,人体运动意图感知逐渐成为研究者关注的重点<sup>[2]</sup>。下肢运动模式预测可以为下肢外骨骼提供当前穿戴者改变当前运动状态的意图,辅助穿戴者完成多种运动模式的动作,增强下肢外骨骼适应多种环境的能力。然而,错误的运动模式预测结果可能会使外骨骼与人体动作发生冲突,从而导致失衡跌倒<sup>[3,4]</sup>。在不同的运动环境中,不合适的运动模式可能会使外骨骼与环境发生碰撞导致人体受到伤害。

下肢运动模式预测在面向外骨骼应用时需要考虑两方面的功能目标以及新用户适应性需求。一方面,下肢外骨骼的实时运动需要稳定阶段和过渡阶段的连续预测。稳定阶段保持着相同运动模式,具有稳定的周期性步态。然而,过渡阶段下肢运动进行着从一种模式向另一种模式的变化,步态逐渐发生着微小或者突然的改变<sup>[5-7]</sup>。步态过渡不仅给下肢外骨骼的运动模式切换提供了时间,其过渡期间复杂的步态变化同时也给运动模式预测带来了挑战。另一方面,下肢运动模式预测围绕人体运动意图输出结果,应提供提前于运动的预测。特别地,当为外骨骼的平滑过渡设计控制算法时,及时地提供运动意图尤为重要<sup>[8,9]</sup>。然而,相较于识别当前的运动模式,提前于运动的意图预测向预测时间提出了更高要求。除功能目标外,下肢运动模式预测往往面临着训练样本外的新受试者,个体差异性存在于预测输入采集的受试者数据中<sup>[10]</sup>。采集大量新受试者数据重新训练预测模型会给用户和系统带来沉重的训练负担。如何保障新受试者运动模式预测的可靠性,提升下肢运动模式预测的适用人群范围,是下肢运动模式预测在针对功能目标开展设计时需要考虑的关键问题。当前研究者主要从采用不同传感器及其组合的角度设计算法,开展下肢运动模式预测研究。

当前下肢运动模式预测的研究常采用表面肌电信号以及加速度信号、角度信号等惯性信号感知人体运

动。肌电信号因有着先于动作 30~150 ms 发生的特点被研究者关注<sup>[11]</sup>。Kyeong 等人<sup>[12]</sup>提取表面肌电信号的时频域特征,采用 SVM(Support Vector Machine)在足跟着地前识别上下楼梯、上下斜坡、水平行走等运动模式来提供运动预测,然而该方法未考虑运动模式之间的过渡。Afzal 等人<sup>[13]</sup>分析 sEMG 中的肌肉能量并将它作为神经特征用于预测运动模式,然而肌肉能量存在的较大受试者差异性使能量矩阵参数面向新受试者时需要重新训练。Fu 等人<sup>[14]</sup>提取对表面肌电信号(surface Electromyography, sEMG)的时频域特征,采用时序神经网络预测下肢连续运动,然而该方法未考虑 sEMG 信号的个体差异性,仅为训练集内的受试者提供预测。Gao 等人<sup>[15]</sup>基于 IMU(Inertial Measurement Unit)计算关节轨迹变化,然后分析地形倾角,从而为运动模式提供预测。基于地形倾角的预测表明 IMU 中蕴含着可靠的地形信息可用于运动模式预测。Su 等人<sup>[16]</sup>采用卷积网络提取 IMU 信号的深度特征,在运动模式的过渡段提供识别结果。然而 IMU 信号滞后于动作发生,难以及时提供运动意图。席旭刚等人<sup>[17]</sup>融合 sEMG 和加速度信号并改进支持向量机识别行走、上下楼梯等运动模式,结果表明采用多传感器信息融合能够提升运动模式识别准确率。Peng 等人<sup>[18]</sup>基于 sEMG 和 IMU 使用多层级传感器识别稳定和过渡阶段的运动模式,采用隐马尔可夫模型融合识别结果,然而该方法仅在运动模式切换前提供最长 70 ms 的预测。除 sEMG 和惯性信号外,还有研究者考虑结合其他机械传感器(如压力单元<sup>[19]</sup>和电容传感器<sup>[20]</sup>)预测人体运动模式。

先前的研究采用多种传感器开展下肢运动模式预测,重点关注运动模式的稳定段和过渡段。当前在考虑提升新受试者的运动意图检测方面,Le 等人<sup>[21]</sup>比较了 IMU 和压力单元的卷积特征新受试者适应性,研究结果表明 IMU 和压力单元的传感器组合具有较好的新受试者运动模式识别能力。然而该研究忽略了能够提供意图信息 sEMG 以及个体差异性。Zhang 等人<sup>[22]</sup>基于对抗训练思想,通过分阶段设置训练目标完成分类器的训练,提升了跨受试者运动模式的识别准确性。然而该项研究仍需采集大量新受试者数量,增加额外的训练负担。此外,这两种方法仅识别当前的运动模式,没有

考虑提前于运动的预测. 总体来说,当前的运动模式预测研究仍然存在着忽略受试者生理信号个体差异性、预测不及时等问题,没有为新受试者提供提前于运动的意图预测. 因此,有必要提出一种可以适用于不同受试者的预测模型,提供提前于运动的意图预测.

本文基于多传感器信号融合和迁移学习,提出了一种下肢运动意图预测方法. 本文首先设计一个下肢运动模式预测模型,该模型采用长短时记忆单元(Long-Short Term Memory, LSTM)提取 sEMG 的模式特征,将 sEMG 的模式特征与关节角度特征融合预测下肢运动模式. 然后采用迁移学习策略在源域受试者数据上预训练模型,接着冻结表面肌电信号模式特征提取器的网络权值,最后在目标域数据集上微调全连接层. 据我们所知,这是第一次探索 sEMG 深度时序特征对新受试者下肢运动模式预测任务的可迁移性,为新受试者提供提前于运动的意图预测.

本文的主要贡献如下:

(1)基于多传感器信号融合和迁移学习提出了一种下肢运动模式预测方法,可以为源域数据集外新受试者的自由行走和穿戴外骨骼行走提供运动模式预测.

(2)揭示了 EMG 和关节角度融合对提前于运动的意图预测任务的贡献.

(3)通过自由行走和穿戴外骨骼行走实验,评估了所提出方法对跨受试者情况下面向相同运动模式内和不同运动模式之间过渡的运动模式预测性能提升效果.

## 2 数据获取

本文设计的外骨骼平台如图 1(a)所示,其刚性结构由 7 个连杆组成,通过每条腿的髋关节、膝关节和踝关节连接. 外骨骼在双腿的髋关节和膝关节处设置 Maxon 公司 EC60 伺服电机,通过控制关节的屈曲与伸展驱动外骨骼在矢状面的运动. 外骨骼的踝关节具有被动自由度,可完成外展与内收活动. 多传感器信息采集系统如图 1(b)所示,包含 sEMG 传感器、惯性传感器(IMU)以及足底压力单元 3 种传感器. 本文采用 Sichiray 公司的四通道 sEMG 采集设备采集穿戴者的表面肌电信号,选择股直肌、股外侧肌、股二头肌、半腱肌作为表面肌电信号源. 实验采用 WitMotion 公司的 IMU 采集穿戴者的运动学信息,将 3 个 IMU 分别放置于穿戴者侧面的腰部、大腿、小腿处,采集矢状面的运动信息. 实验通过 Flexiforce 的 A201 压力传感单元采集行走过程中足跟和跖骨处的压力. IMU 和足底压力的采集频率为 100 Hz,通过蓝牙通信传输数据至上位机. sEMG 信号的采集频率为 1 000 Hz,通过串口通信传递数据至上位机. 数据同步通过上位机数据读取实现.

本文实验建立两个数据集,第一个数据集采集受




图 1 外骨骼样机及多传感器信息采集系统

试者在未进行外骨骼穿戴时的自然步态数据,招募了 8 名受试者,包含 6 名男性和 2 名女性,平均年龄为  $28.4 \pm 5.2$  岁. 第二个数据集采集受试者穿戴外骨骼运动时的步态数据,根据受试者意愿邀请了自由行走试验中的 4 名受试者参与试验,包含 3 名男性和 1 名女性,平均年龄为  $26 \pm 2.1$  岁. 外骨骼在试验时工作在随动控制模式,通过最小化交互力跟随人体运动<sup>[23]</sup>. 试验开始前,受试者首先需要熟悉穿戴传感器行走,然后穿戴经过调整和适配的下肢外骨骼,并进行数分钟行走训练,熟悉外骨骼设备.

本文实验采集 5 种生活中常见的运动模式及过渡段数据,分别为水平行走(Level Walking, LW)、上楼梯(Up Stairs, US)、下楼梯(Down Stairs, DS)、上斜坡(Ramp Ascent, RA)、下斜坡(Ramp Down, RD). 采集实验分别在 10 m 长的水平走道,12 个台阶的楼梯,具有  $10^\circ$  倾角的 8 m 长斜坡上进行. 为了采集行走过程中不同模式间的过渡段数据,斜坡和楼梯地形实验的开始和结果阶段都包含有 3 m 的水平行走. 每名受试者需要在 5 种运动模型上完成 10 次试验.

## 3 下肢运动模式预测方法

下肢运动模式预测方法包含数据预处理、多模态信息融合模型构建以及迁移学习策略 3 个部分.

### 3.1 数据预处理

针对 sEMG 采集过程中的噪声,采用六阶巴特沃斯滤波器滤除 50 Hz 电力线干扰信号. 考虑到 sEMG 的有效信号在 20~300 Hz 范围内,采用带通滤波保持信号的有效成分. 文中运动模式间的过渡段定义为从上一个运动模式的足跟触地开始到下一个运动模式的足跟触地结束,该过渡段数据的提取通过足底压力检测实现. 输入数据的标签分配方式如图 2 所示,将滑动窗口末端到预测时间长度内的运动模式作为该滑动窗口的预测真实标签.

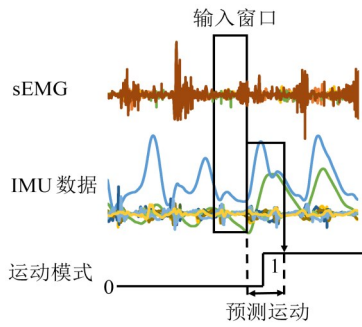


图2 数据标签分配

### 3.2 多模态信息融合模型构建

sEMG 信号是动作电位序列时间和空间上的叠加,反映着肌肉之间有序协作形成的运动,与运动之间存在较强的非线性关系<sup>[24]</sup>. LSTM 具有长短期信息记忆功能,擅长捕捉时间序列中的依赖关系.在先前的研究中,通过 LSTM 提取的 sEMG 时序特征在面向动作识别、相位估计、角度预测等多个任务时表现出优于手工特征、全连接特征及卷积特征的识别或预测性能<sup>[25-27]</sup>.这表明 LSTM 擅长从 sEMG 时间序列中提取任务相关的时序特征.因此,本文采用 LSTM 为下肢运动模式预测提取 sEMG 的时序特征.

多模态信息融合模型结构分为特征提取和识别网络两个部分,如图 3 所示.该模型采用滑动窗口提取 sEMG 和关节角度两种输入信号.针对 sEMG 的特征提取部分,首先根据训练集中 sEMG 每个通道的数据计算均值和标准差,然后对滑动窗口内 4 个通道的表面肌电信号进行 Z-score 标准化,根据时间发生的顺序将标准化的肌电信号依次送入 LSTM 网络. LSTM 网络<sup>[28]</sup>用于提取 sEMG 的模式特征,其结构具有 2 个 LSTM 层,每个 LSTM 的隐藏层都具有 128 个神经元.第二部分为信息融合部分,首先将 IMU 采集到的角速度等信息解算为关节角度<sup>[29]</sup>,然后将提取到的表面肌电信号模式特征与髋关节和膝关节角度信息送入模型的网络融合层,拼接成一个新的特征送入全连接网络.全连接网络包含 3 个全连接层,各层的神经元数量分别为 256、128 和 64.除最后一层外,每个全连接层后依次设有 Batch-Norm 层、ReLU 激活函数以及 Dropout 层.全连接层后的 BatchNorm 层用于加快网络训练<sup>[30]</sup>,ReLU 激活函数用于防止梯度消失<sup>[31]</sup>,设置的 Dropout 层防止过拟合<sup>[32]</sup>.模型中 LSTM 和全连接网络的层数、神经元个数以最小化相同受试者预测误差为目标通过训练和测试确定.下肢运动模式预测模型通过全连接网络学习表面肌电信号、关节角度信号与即将到来的运动模式之间的关系.

### 3.3 迁移学习训练策略

为了提升多传感器信息融合预测模型的新受试者

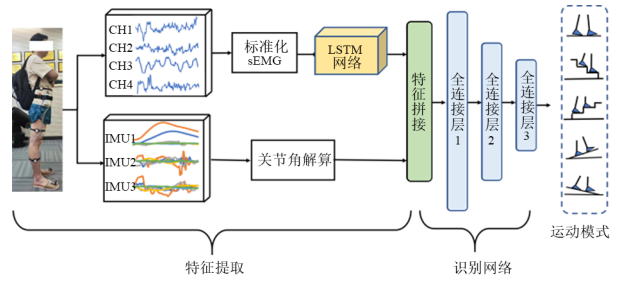


图3 基于多模态信息融合的运动模式预测网络

运动模式预测能力,本文采用迁移学习策略将源域受试者的运动模式预测模型迁移至目标域受试者.迁移学习策略如图 4 所示,首先在源域受试者数据集上训练预测模型.为了保障在源域中学习到的知识不被遗忘,将用于提取肌电信号模式特征的 LSTM 网络权值冻结.当训练目标域模型时,采用迁移的源域特征提取器提取目标域受试者包含模式信息的 sEMG 时序特征,采用源域模型的权值对目标域模型的全连接层进行初始化,使用少量新受试者数据对目标域模型的全连接层进行微调,最后在新受试者上验证下肢运动模式预测能力.预测模型参数的训练采用交叉熵损失函数,如式(1)所示:

$$\text{loss}(x, y) = E_{(x, y) \in (X, Y)} \sum_{c=1}^M -I(c=y) \log P_i(c|x) \quad (1)$$

其中,  $E$  表示计算期望,  $I(c=y)$  是符号函数,  $P_i(c|x)$  为预测样本  $i$  的类别为  $c$  的概率.

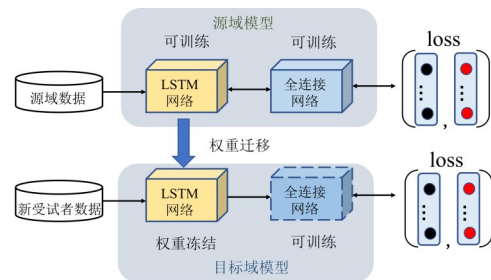


图4 迁移学习训练

### 3.4 评估准则和统计分析

本文面向运动模式内和运动模式间的过渡评估下肢运动模式预测模型性能,计算运动模式过渡情况下的总体准确率和运动模式类别准确率.准确率的计算方式如式(2)所示:

$$\text{Acc}_{\text{total}} = \frac{\sum_{i=1}^N I(\hat{y}_i = y_i)}{N} \quad (2)$$

其中,  $\hat{y}_i$  表示样本  $i$  的预测结果,  $y_i$  为样本  $i$  的真实标签,  $N$  为样本总数.

为了分析本文所提出的方法在运动模式预测上的有效性,采用 t-检验以及 Wilcoxon 秩和检验开展统计分

析.  $p < 0.05$  的统计结果认为存在显著性差异.

## 4 实验及结果

### 4.1 实验

本文在第二节构建了两个数据集. 第一个数据集包含 8 位受试者自由行走时的运动数据, 第二个数据集收集了 4 位受试者穿戴外骨骼行走时的运动数据. 实验首先采用自由行走数据集开展跨受试者的下肢运动模式预测方法性能验证, 并完成目标域预测模型的训练; 然后选取同时参与两个数据集采集试验的受试者, 验证其在自由行走状态下的目标域预测模型面向穿戴外骨骼行走时的下肢运动模式预测性能. 穿戴外骨骼数据实验的目的在于验证所提出方法在采集少量新用户自然行走数据的情况下提升穿戴外骨骼时下肢运动模式预测准确性的能力.

为确定预测模型的网络层数和神经元个数, 使用自由行走数据集通过随机留一法选取 7 位受试者构建超参数选择数据集, 随机选取数据集中所有受试者的 80% 数据作为超参数训练集, 剩下的 20% 数据用于超参数选择的测试. 预测模型的输入采用时间长度为 150 ms 的滑动窗口, 滑动步长为 20 ms, 运动模式的预测时间长度为 100 ms. 预测网络的训练采用 Adam 优化器, 每次网络更新输入的批量样本数为 128, 并设置 0.001 的初始网络权值学习率. Drop 层设置 0.2 的遗忘概率. 网络的训练采用 PyTorch 深度学习框架, 使用具备英特尔 i7-13700K 处理器、64 G 运行内存和英伟达 GTX4080GPU 的硬件系统.

本文关注下肢运动模式预测面向新受试者的预测性能提升. 为此, 将自由行走数据集中采集到的每位受试者数据采用留一法交叉验证的方式轮流作为测试集, 其余受试者的数据作为训练集. 预测模型的训练分为源域预测模型训练和目标域预测模型训练两个部分. 源域预测模型训练迭代 500 次训练集. 目标域预测模型采用 1 次试验采集的数据作为训练数据. 由于只

需要在全连接层上更新权值, 目标域预测模型训练的网络更新采用 128 的批量样本输入, 迭代学习训练数据 100 次. 为了验证所提出方法对穿戴外骨骼时下肢运动模式预测能力的有效性, 选取同时参与自由行走和穿戴外骨骼行走的受试者, 将其在自由行走实验中被作为新受试者时的目标域预测模型直接用于穿戴外骨骼行走的预测性能测试.

下肢运动模式预测方法的有效性验证考虑多传感器信息融合和迁移学习 (Transfer Learning, TL) 两种因素, 选取采用 sEMG 为唯一信号输入源且无迁移学习 (sEMG-based)、采用多传感器信息融合且无迁移学习 (Fusion-based)、采用 sEMG 为唯一信号输入源且有迁移学习 (sEMG with TF) 3 种方法作为基准方法进行对照. 采用 sEMG 为唯一信号输入源的网络与预测网络具有相同的网络结构与训练方式, 无迁移学习的预测网络采用与迁移学习相同的数据训练. 为了验证冻结预测模型不同部分对预测任务的影响, 选择无冻结和冻结全连接层作为对照开展实验. 此外, 本文还与现有的方法进行对比. 选取文献[21]中使用 IMU 和压力单元组合的预测方法以及文献[22]中基于对抗训练的预测方法, 并采用与文献中相同的模型配置以及数据划分进行自由行走和穿戴外骨骼数据的运动模式预测实验, 比较预测性能.

### 4.2 结果

表 1 给出了基于多传感器融合和迁移学习的运动模式预测方法、采用 sEMG 为唯一信号输入源以及无迁移学习方法的下肢运动模式预测准确率. 从表 1 中结果可以得出, 在自由行走和穿戴外骨骼行走的情况下, 采用迁移学习和多传感器信息融合的方法都能提升下肢运动模式预测准确率. 基于多传感器融合和迁移学习方法的预测准确率除了在水平行走运动模式下与无迁移的传感器融合方法以及采用 sEMG 为唯一信号输入源的结果没有显著性差异外, 都显著优于无迁移学习方法和采用 sEMG 为唯一信号输入源准确率 ( $p < 0.05$ ).

表 1 基于多传感器信息融合和迁移学习方法与基准方法的下肢运动模式预测准确率比较(括号内为标准差)

单位: %

运动模式	自由行走				穿戴外骨骼行走			
	sEMG-based	Fusion-based	sEMG with TF	Fusion with TF	sEMG-based	Fusion-based	sEMG with TF	Fusion with TF
水平行走	66.35(2.88)	70.77(4.00)	68.99(3.57)	71.32(4.19)	58.66(8.21)	65.44(6.75)	68.17(12.14)	70.98(8.41)
上楼梯	10.51(2.30)	60.03(6.74)	20.52(3.42)	68.10(2.98)*	6.78(2.03)	56.27(4.59)	11.02(4.15)	59.48(5.98)*
下楼梯	16.43(7.56)	52.11(9.14)	33.82(7.04)	64.53(4.52)*	22.44(5.07)	36.47(9.95)	22.69(12.86)	51.82(5.74)*
上斜坡	18.62(6.12)	55.67(5.24)	21.03(7.97)	61.35(2.74)*	16.13(10.75)	33.24(8.56)	20.91(13.67)	46.96(3.32)*
下斜坡	16.35(4.43)	39.50(9.76)	35.72(8.05)	56.26(7.58)*	16.93(4.10)	26.09(4.73)	24.17(10.03)	45.16(8.16)*

注: \*表明采用基于迁移学习方法的结果与采用 sEMG 和无迁移学习方法的结果存在显著性差异.

图 5 给出了相同模式内稳定阶段的基于多传感器融合和迁移学习方法与基准方法的下肢运动模式准确率. 从图 5 可以得出, 在自由行走和穿戴外骨骼行走的两种

情况下, 所提出的预测方法在楼梯地形和斜坡地形上能够显著提升无迁移学习方法和采用 sEMG 为唯一信号输入源的预测准确率 ( $p < 0.05$ ). 而对于水平地面的运动,

所提出的预测方法除了在穿戴外骨骼行走时优于基于 sEMG 的方法外,与其他基准方法无显著性差异.




图5 相同运动模式内的下肢运动模式预测准确率

图6给出了下肢不同运动模式间过渡的基于多传感器融合和迁移学习的方法与基准方法的运动模式预测准确率.在自由行走和穿戴外骨骼行走时,所提出的预测方法在楼梯地形和斜坡地形向水平地面过渡以及水平地面向楼梯地形和斜坡地形过渡时的运动模式预测准确率都显著优于无迁移学习方法和采用 sEMG 为唯一信号输入源的预测准确率( $p < 0.05$ ).




图6 不同运动模式间过渡的下肢运动模式预测准确率

图7给出了通过选取多传感器融合型的不同组成部分冻结权值开展迁移学习的预测准确性比较.相较于预测网络权值无冻结以及仅冻结全连接层(Multi-layer Perceptron, MLP),所提出方法选择冻结提取 sEMG 特征的 LSTM 网络并进行迁移学习训练能够在自由行走和穿戴外骨骼行走两种情况下取得更高的预测准确性( $p < 0.05$ ).

图8给出了基于多传感器融合和迁移学习的运动模式预测方法在自由行走时新受试者运动模式内和运动模式间过渡的预测混淆矩阵.对于运动模式内稳定阶段的预测,所提出的方法水平行走预测准确性都高于其他模式类别.而在运动模式间的过渡阶段,所提出的方法除了不易预测从水平行走走到上斜坡的运动外,对目标运动的预测准确性都高于其他模式类别.

表2展示了基于多传感器融合和迁移学习的预测方法在各个受试者自由行走和穿戴外骨骼时运动模式






图7 冻结网络不同组成部分的下肢运动模式预测准确率



(a) 相同运动模式内的预测混淆矩阵



(b) 运动模式间过渡的预测混淆矩阵

图8 自由行走状态下运动模式预测混淆矩阵

内、运动模式间以及总体的预测准确率.从表2中可以看出,在各个受试者上运动模式内的准确率都高于运动模式间过渡的预测准确率,自由行走时的运动模式预测准确性高于穿戴外骨骼行走时的预测准确性.

表3展示了所提出方法对相同受试者内以及新受试者的下肢运动模式预测准确率.从表3中可以看出,采用少量新受试者数据并基于迁移学习可以提升运动模式预测的准确率,而相同受试者内的预测准确性高于新受试者识别准确性.

表4给出了本文提出方法与现有方法在自由行走和穿戴外骨骼行走状态下的下肢运动模式预测结果比较.从表4中结果可知,本文提出的方法使用较少的新受试者训练数据得到的下肢运动模式预测结果都显著优于现有方法的结果( $p < 0.05$ ),并且本文的方法提供了 100 ms 的预测时间.

表 2 不同受试者的下肢运动模式预测准确率 单位:%

受试者	运动模式内	运动模式间	总体
1	58.41	52.14	57.62
2	62.44	56.74	61.85
3	68.62	64.52	68.52
4	74.37	70.13	74.31
5	72.89	67.77	72.59
6	59.76	53.54	59.01
7	63.27	59.64	63.21
8	60.16	56.27	60.00
5(exo)	60.11	54.59	59.54
6(exo)	53.54	49.34	53.21
7(exo)	56.83	52.15	56.42
8(exo)	52.65	44.71	51.37

## 5 讨论

### 5.1 基于多传感器信息融合和迁移学习的下肢运动模式预测方法有效性

实验结果表明,本文提出的基于多传感器信息融合和迁移学习方法能够有效提升新受试者面向自由行走以及穿戴外骨骼时的运动模式预测准确性,从而为下肢外骨骼日常场景的辅助助力提供重要的运动意图信息.图7的实验结果表明,预测模型中sEMG的特征提取部分具有较好的新受试者泛化能力,可以通过迁移学习提升新受试者下肢运动模式预测能力.对表1中自由行走以及穿戴外骨骼行走的实验结果综合分析后可以得出,所提出方法相较于基准方法平均提升了采用sEMG为唯一信号源且无迁移学习预测方法(sEMG-based)34.68%的准确率、采用多传感器信号融合且无迁移学习预测方法(Fusion-based)14.07%的准确率、采用sEMG为唯一信号源且使用迁移学习预测方法(sEMG with TF)26.89%的准确率.总体上,采用多传感器信息融合的方法相较于只采用sEMG为唯一信号源的方法能够提升3.37%~48.5%的下肢运动模式预测准确率,采用迁移学习方法相较于无迁移学习能够提升4.8%~49.1%的预测准确率.实验结果表明,采用多

传感器信息融合的方法和迁移学习方法都能显著提升下肢运动模式预测准确率( $p < 0.01$ ).由表3中相同受试者和新受试者的预测结果比较可知,采用sEMG为唯一信号源的预测方法难以向新受试者的自由行走和穿戴外骨骼运动提供可靠的运动预测,这可能是受试者之间的生理信号差异较大以及提前于运动的意图预测容易受到sEMG个体性差异影响的缘故.尽管基于sEMG的预测存在难度,但本文通过多传感器信息融合以及迁移学习提升了预测的准确性,从而为新受试者自由行走以及穿戴外骨骼时的运动模式预测可靠性提供保障.

### 5.2 运动模式内和运动模式间的预测结果分析

本文考虑了5种运动模式以及运动模式之间过渡的预测.从表1和图5可知,将自由行走和穿戴骨骼行走两种情况的下肢运动模式预测考虑在内,所提出方法在楼梯和斜坡地形上的预测准确率都显著高于基准方法的预测准确率( $p < 0.01$ ).水平行走在下肢运动模式预测的5种运动模式中预测准确率最高,所提出方法的预测准确率高出无迁移的传感器融合方法以及采用sEMG为唯一信号输入源的方法0.55%~12.32%.在水平运动模式内的过渡中,所提出方法的预测准确率与基准方法的结果无明显差异( $p = 0.101$ ).这表明相较于楼梯和斜坡地形的运动,水平行走上的运动模式更易被识别,并且个体之间的运动模式相似性相对较高,这与文献[33]和文献[12]中的结果一致.由图6可知,无论是自由行走还是穿戴骨骼行走的实验,所提出的方法在每种运动模式间过渡预测中的准确率都显著高于基准方法,并且采用多传感器融合的方法和迁移学习方法都能显著提升下肢运动模式预测准确率( $p < 0.01$ ).在运动模式间的过渡中,从水平走向其他运动模式过渡的预测准确率低于其他模式向水平行走过渡的准确率.由图8(b)的预测结果分布可知,从水平行走开始过渡段的错误预测主要分布在水平行走.这表明相较于其他运动模式,预测方法更容易捕捉水平行走的运动模式特征.水平走向上坡的过渡相比于其他模式

表 3 相同受试者和新受试者的下肢运动模式预测准确率比较(括号内为标准差)

单位:%

受试者	sEMG-based	Fusion-based	sEMG with TF	Fusion with TF
相同受试者	75.86(8.17)	85.26(6.91)	—	—
新受试者	25.65(10.66)	55.62(7.18)	36.02(7.69)	64.32(8.55)
新受试者(exo)	24.19(11.04)	43.51(10.92)	29.4(10.58)	54.88(9.32)

表 4 与现有方法的比较

方法	传感器	方法	新受试者数据/%	预测准确率/%	预测准确率(exo)/%	预测时间/ms
Le等人 <sup>[21]</sup>	IMU+足底压力	迁移卷积层	30	59.15	50.47	0
Zhang等人 <sup>[22]</sup>	EMG+IMU	对抗训练	70	56.88	45.30	0
本文方法	EMG+IMU	迁移LSTM	10	64.32	54.88	100

的过渡预测难度较大,这可能是由于上斜坡的步态与水平行走更相似<sup>[34]</sup>。根据表2可知,尽管不同受试者因个体性差异面向预测任务时产生了不同的预测结果,每位受试者运动模式内的预测准确性都要高于运动模式间的预测准确性。总体上,所提出的方法在自由行走状态下的运动模式内和运动模式间过渡预测平均准确率分别为67.88%和61.43%,而在穿戴外骨骼情况下的模式内和模式间预测平均准确率分别为60.43%和51.54%。

### 5.3 自然行走与穿戴外骨骼行走的预测结果比较

本文采集少量新受试者自然行走数据开展迁移学习,并验证新受试者预测模型面向穿戴外骨骼行走时的运动模式预测能力。由表2可知,本文方法对同一受试者自然行走的运动模式预测准确性都要高于穿戴外骨骼运动时的预测准确性。实验结果表明,自然行走状态下的运动模式预测性能表现优于穿戴外骨骼行走下的运动模式预测性能。根据表3可以得出,总体上,本文提出的迁移学习方法有效提升了自由行走和穿戴外骨骼行走9.53%和8.29%的预测准确率( $p < 0.01$ )。并且本文提出的预测方法面向穿戴外骨骼行走的预测任务时,降低了自由行走10.56%的新受试者运动模式预测准确率,但仍然超过基准方法11.37%~30.69%的预测准确率。穿戴外骨骼时的人机交互因素(如外骨骼结构刚性、驱动方式以及控制方法等)可能会是自然步态发生改变的原因,从而影响运动模式预测<sup>[35]</sup>。对于新受试者自由行走的预测,迁移学习方法仅需采集新受试者在各种地形上一次行走数据即可完成训练。而对于穿戴外骨骼的预测,无须使用穿戴外骨骼的行走数据训练,可直接使用新受试者的预测模型为穿戴外骨骼行走提供运动模式预测,减免再次采集新受试者穿戴外骨骼行走数据的负担。

### 5.4 和现有方法的比较

当前研究中,Le等人<sup>[21]</sup>和Zhang等人<sup>[22]</sup>关注了面向新受试者的下肢运动模式预测。本文关注新受试者自由行走和穿戴外骨骼行走的运动模式预测,通过实验与现有方法进行比较。实验结果如表4所示,相较于Le等人<sup>[21]</sup>提取IMU和足底压力的卷积特征进行迁移,本文使用LSTM提取sEMG时序特征使用了比Le等人<sup>[21]</sup>的方法少20%的新受试者训练数据,并且在新受试者自由行走和穿戴外骨骼行走的下肢运动模式预测任务中取得了高于Le等人<sup>[21]</sup>的方法5.17%和4.41%的预测准确率( $p < 0.05$ )。Zhang等人<sup>[22]</sup>的对抗训练方法使用了70%的新受试者进行训练,增加了新受试者数据采集和系统的训练负担。本文使用10%新受试者数据取得了高于Zhang等人<sup>[22]</sup>的方法自由行走情况下7.44%运动模式预测准确率以及穿戴外骨骼行走

9.58%的运动模式预测准确率( $p < 0.05$ )。除此之外,两种现有方法的预测时间长度为0 ms,即仅识别当前的运动模式。本文提出的方法提供了100 ms的预测时间长度,能够提供提取于运动的意图预测。

### 5.5 未来工作

本文基于多传感器信息融合和迁移学习提出了一种下肢运动模式预测方法,为新受试者的自由行走和穿戴外骨骼运动提供运动意图信息。本文设计了结构简单的LSTM网络提取sEMG的运动模式特征,并基于迁移学习方法预测新受试者的运动模式。尽管所提出的方法能够有效提升新受试者的自由行走以及穿戴外骨骼行走的运动模式预测准确率,但预测准确率仍有待提升。未来将进一步改进预测模型结构如引入注意力机制,采用小样本学习思想利用更少的新受试者数据提升预测性能。除此之外,本文采用刚性结构的外骨骼,具有质量大且不易携带的缺点,可能会给用户带来负担。未来将考虑设计轻便且用户接受度更高的柔性外骨骼并设计合适的控制算法,开展下肢运动模式预测研究,提升预测方法的应用价值。

## 6 结论

本文提出了一种基于多传感器信息融合和迁移学习的下肢运动模式预测方法,为新受试者的自由行走和穿戴外骨骼行走提供运动意图预测。本文首先设计了一个运动模式预测模型,采用LSTM提取sEMG的模式特征,并将sEMG的模式特征与关节角度特征融合预测下肢运动模式。然后设计迁移学习策略通过在源域受试者数据上预训练模型,冻结表面肌电信号模式特征提取器的网络权值,最后在目标域数据集上微调全连接层完成迁移学习训练。实验采集了包含水平行走、上下楼梯和上下斜坡的5种运动模式及其过渡段数据。自由行走以及穿戴外骨骼行走的运动模式预测实验结果表明,所提出基于多传感器信息融合和迁移学习的下肢运动模式预测方法能够在给定少量新受试者数据的情况下,有效提升新受试者自由行走和穿戴外骨骼行走的运动模式预测准确率。本文提出的方法可以通过多传感器信息融合和迁移学习提升新受试者的运动模式预测准确率,从而保障下肢外骨骼可靠的运动意图感知。

### 参考文献

- [1] LEE H, FERGUSON P W, ROSEN J. Chapter 11 lower limb exoskeleton systems: Overview[J]. *Wearable Robotics*, 2020, 1: 207-229.
- [2] LI L L, CAO G Z, LIANG H J, et al. Human lower limb motion intention recognition for exoskeletons: A review[J].

- IEEE Sensors Journal, 2023, 23(24): 30007-30036.
- [3] LI Z J, LI X, LI Q J, et al. Human-in-the-loop control of soft exosuits using impedance learning on different terrains[J]. IEEE Transactions on Robotics, 2022, 38(5): 2979-2993.
- [4] REN X Q, LI Z J, ZHOU M C, et al. Human intention-aware motion planning and adaptive fuzzy control for a collaborative robot with flexible joints[J]. IEEE Transactions on Fuzzy Systems, 2023, 31(7): 2375-2388.
- [5] UCHITOMI H, HIROBE Y, MIYAKE Y. Three-dimensional continuous gait trajectory estimation using single Shank-Worn inertial measurement units and clinical walk test application[J]. Scientific Reports, 2022, 12(1): 5368.
- [6] ZHANG S Q, PAN J H, LI L. Non-linear changes of lower extremity kinetics prior to gait transition[J]. Journal of Biomechanics, 2018, 77: 48-54.
- [7] 汪成亮, 刘艺镏. 基于震动信号的异常步态识别[J]. 电子学报, 2023, 51(8): 2088-2097.  
WANG C L, LIU Y L. Recognition of abnormal gait based on vibration signal[J]. Acta Electronica Sinica, 2023, 51(8): 2088-2097. (in Chinese)
- [8] KIM J, LEE G, HEIMGARTNER R, et al. Reducing the metabolic rate of walking and running with a versatile, portable exosuit[J]. Science, 2019, 365(6454): 668-672.
- [9] BAUD R, MANZOORI A R, IJSPEERT A, et al. Review of control strategies for lower-limb exoskeletons to assist gait[J]. Journal of Neuroengineering and Rehabilitation, 2021, 18(1): 119.
- [10] DONALDSON B, BAYNE H, BEZODIS N E. Within-subject repeatability and between-subject variability in posture during calibration of an inertial measurement unit system [J]. ISBS Proceedings Archive, 2021, 39(1): 224.
- [11] LI K X, ZHANG J H, WANG L F, et al. A review of the key technologies for sEMG-based human-robot interaction systems[J]. Biomedical Signal Processing and Control, 2020, 62: 102074.
- [12] KYEONG S, FENG J R, RYU J K, et al. Surface electromyography characteristics for motion intention recognition and implementation issues in lower-limb exoskeletons[J]. International Journal of Control, Automation and Systems, 2022, 20(3): 1018-1028.
- [13] AFZAL T, IQBAL K, WHITE G, et al. A method for locomotion mode identification using muscle synergies[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2017, 25(6): 608-617.
- [14] FU P W, ZHONG W J, ZHANG Y Y, et al. Predicting continuous locomotion modes via multidimensional feature learning from sEMG[J]. IEEE Journal of Biomedical and Health Informatics, 2024, 28(11): 6629-6640.
- [15] GAO F, LIU G Y, LIANG F Y, et al. IMU-based locomotion mode identification for transtibial prostheses, orthoses, and exoskeletons[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(6): 1334-1343.
- [16] SU B Y, WANG J, LIU S Q, 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.
- [17] 席旭刚, 汤敏彦, 张自豪, 等. 融合表面肌电和加速度信号的下肢运动模式识别研究[J]. 电子学报, 2017, 45(11): 2735-2741.  
XI X G, TANG M Y, ZHANG Z H, et al. Lower limb motion recognition based on the fusion of sEMG and acceleration signal[J]. Acta Electronica Sinica, 2017, 45(11): 2735-2741. (in Chinese)
- [18] PENG F, ZHANG C, XU B G, et al. Locomotion prediction for lower limb prostheses in complex environments via sEMG and inertial sensors[J]. Complexity, 2020, 2020(1): 8810663.
- [19] LIU Z J, LIN W, GENG Y L, et al. Intent pattern recognition of lower-limb motion based on mechanical sensors[J]. IEEE/CAA Journal of Automatica Sinica, 2017, 4(4): 651-660.
- [20] ZHENG E H, WANG Q N. Noncontact capacitive sensing-based locomotion transition recognition for amputees with robotic transtibial prostheses[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2017, 25(2): 161-170.
- [21] LE D, CHENG S H, GREGG R D, et al. Transfer learning for efficient intent prediction in lower-limb prosthetics: A strategy for limited datasets[J]. IEEE Robotics and Automation Letters, 2024, 9(5): 4321-4328.
- [22] ZHANG K G, WANG J, DE SILVA C W, et al. Unsupervised cross-subject adaptation for predicting human locomotion intent[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(3): 646-657.
- [23] ZHOU X, YU Z, CHEN D, et al. Experimental research on follow-up control of lower limb exoskeleton robot; proceedings of the ISMSEE 2022[C]//The 2nd International Symposium on Mechanical Systems and Electronic Engineering. Frankfurt: VDE, 2022: 1.
- [24] 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. (in Chinese)
- [25] NEENU R, TITUS G. Comparative Study of CNN and LSTM-Based Hand Gesture Classification Using EMG Signals[M]//Artificial Intelligence in Telemedicine. Boca Raton: CRC Press, 2023: 83-96.
- [26] SONG Q Z, MA X J, LIU Y L. Continuous online prediction of lower limb joints angles based on sEMG signals by deep learning approach[J]. Computers in Biology and Medicine, 2023, 163: 107124.
- [27] XIONG D Z, ZHANG D H, ZHAO X G, et al. Deep learning for EMG-based human-machine interaction: A review[J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(3): 512-533.
- [28] SHERSTINSKY A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. Physica D: Nonlinear Phenomena, 2020, 404: 132306.
- [29] HAMDY M M, AWAD M I, ABDELHAMEED M M, et al. Lower limb motion tracking using IMU sensor network[C]//2014 Cairo International Biomedical Engineering Conference (CIBEC). Piscataway: IEEE, 2014: 28-33.
- [30] SANTURKAR S, TSIPRAS D, ILYAS A, et al. How does batch normalization help optimization? [EB/OL]. (2019-08-15)[2025-05-10]. <https://arxiv.org/abs/1805.11604v5>.
- [31] AGARAP A. Deep learning using rectified linear units (relu)[EB/OL]. (2019-02-27)[2025-05-10]. <https://arxiv.org/abs/1803.08375>.
- [32] HAHN S, CHOI H. Understanding dropout as an optimization trick[J]. Neurocomputing, 2020, 398: 64-70.
- [33] WEI C F, WANG H, HU F, et al. Single-channel surface Electromyography signal classification with variational mode decomposition and entropy feature for lower limb movements recognition[J]. Biomedical Signal Processing and Control, 2022, 74: 103487.
- [34] GU H, LI W D, LI J. Knee and ankle kinematics in different walking conditions[C]//2016 International Conference on Advanced Robotics and Mechatronics (ICARM). Piscataway: IEEE, 2016: 266-270.
- [35] LI Z J, ZHANG T, HUANG P B, et al. Human-in-the-loop cooperative control of a walking exoskeleton for following time-variable human intention[J]. IEEE Transactions on Cybernetics, 2024, 54(4): 2142-2154.

### 作者简介



俞志鹏 男,1995年3月出生于安徽省淮南市. 博士,现为安徽理工大学人工智能学院讲师. 主要研究方向为人机交互与康复机器人.  
E-mail: pengyz@aust.edu.cn



凌六一 男,1980年7月出生于安徽省枞阳县. 博士,现为安徽理工大学人工智能学院教授,博士生导师. 主要研究方向为检测技术与智能信息处理.  
E-mail: lyling@aust.edu.cn



王美玲 女,1986年1月出生于安徽省安庆市. 博士,现为中国科学院合肥物质科学研究院智能机械研究所副研究员. 主要研究方向为机器人与智能装备.  
E-mail: mlwang@iamt.ac.cn