

DOI: 10.19650/j.cnki.cjsi.J2614832

GenJAPNet: 基于非冗余肌肉协同特征的可泛化 关节角度预测网络用于下肢外骨骼*

张海容^{1,2}, 秦鹏杰³, 孙健铨¹, 白 昱², 田定奎¹

(1. 中国科学院深圳先进技术研究院 深圳 518055; 2. 长春理工大学电子信息工程学院 长春 130022;
3. 深圳大学人工智能学院 深圳 518060)

摘 要: 下肢外骨骼机器人在康复治疗 and 辅助行走方面发挥着重要作用, 其中, 准确的下肢关节角度预测是实现自然、协调步态的关键技术。然而, 由于表面肌电信号易受个体差异和运动模式变化的影响, 实现关节角度预测的跨任务泛化仍面临重大挑战。针对上述问题, 提出了一种面向跨任务泛化的下肢多关节角度预测框架, 包括一种非冗余肌肉协同特征提取算法和一个具有跨速度、跨受试者泛化能力的关节角度预测网络。首先, 特征提取算法使用非负矩阵分解从表面肌电信号中提取激活系数矩阵, 并进一步使用均匀流形逼近与投影算法进行非线性降维, 以获取更具辨别力的低维特征作为模型输入。其次, 关节角度预测网络通过预训练提取跨任务共享特征, 并使用新任务的少量样本微调, 实现对新任务的快速适应。基于自建数据集和公开数据集进行了特征提取方法对比实验、模型消融实验以及跨速度和跨受试者泛化实验。实验结果表明, 在自建数据集的跨速度实验中, 髋、膝关节角度预测误差范围为 $1.703^{\circ} \sim 2.790^{\circ}$, 相关系数均达到 0.98 以上, 相较于基线方法在预测精度与稳定性方面均有显著提升, 验证了本文方法的有效性和泛化性。最后, 进行了外骨骼辅助行走物理实验, 展示了所提方法在下肢外骨骼实际应用中的可行性与应用潜力。

关键词: 下肢外骨骼; 表面肌电信号; 肌肉协同; 角度预测

中图分类号: TH789 **文献标识码:** A **国家标准学科分类代码:** 510.80

GenJAPNet: A generalizable joint angle prediction network with non-redundant muscle synergy features for lower-limb exoskeletons

Zhang Hairong^{1,2}, Qin Pengjie³, Sun Jianquan¹, Bai Yu², Tian Dingkui¹

(1. Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China; 2. School of Electronic and Information Engineering, Changchun University of Science and Technology, Changchun 130022, China;
3. School of Artificial Intelligence, Shenzhen University, Shenzhen 518060, China)

Abstract: Lower-limb exoskeleton robots play an important role in rehabilitation training and walking assistance, where accurate lower-limb joint angle prediction is a key technology for achieving natural and coordinated gait. However, since surface electromyography (sEMG) signals are susceptible to individual differences and variations in movement patterns, achieving cross-task generalization for joint angle prediction remains a major challenge. To address the above issues, this paper proposes a cross-task generalization-oriented multi-joint angle prediction framework for the lower limb, which includes a non-redundant muscle synergy feature extraction algorithm and a joint angle prediction network with cross-speed and cross-subject generalization capabilities. First, the feature extraction algorithm employs non-negative matrix factorization to extract activation coefficient matrices from sEMG signals, and further uses the Uniform Manifold Approximation and Projection algorithm for nonlinear dimensionality reduction to obtain low-dimensional features with higher discriminative power as model inputs. Second, the joint angle prediction network extracts cross-task shared features through pre-training and leverages a small number of samples from new tasks for fine-tuning, enabling rapid adaptation to new tasks. Based on a self-

收稿日期: 2026-01-05 Received Date: 2026-01-05

* 基金项目: 国家自然科学基金 (62373346, 62403453)、国家重点研发计划 (2023YFB4704000)、深圳市科技计划 (KJZD20230923113801004, KJZD20230923115215032, JCYJ20250604182958078)、广东省基础与应用基础研究基金 (2025A1515011973) 项目资助

constructed dataset and a public dataset, this paper conducts feature extraction method comparison experiments, model ablation experiments, and cross-speed and cross-subject generalization experiments. Experimental results show that in cross-speed experiments on the self-constructed dataset, the prediction errors of hip and knee joint angles range from 1.703° to 2.790° , with correlation coefficients all exceeding 0.98. Compared with baseline methods, the proposed method achieves significant improvements in both prediction accuracy and stability, demonstrating its effectiveness and generalizability. Finally, physical experiments on exoskeleton-assisted walking are conducted, further validating the feasibility and application potential of the proposed method in practical lower-limb exoskeleton applications.

Keywords: lower-limb exoskeleton; surface electromyography; muscle synergy; angle prediction

0 引 言

下肢外骨骼机器人在辅助行走、康复训练以及日常功能增强等方面发挥着重要作用。它们不仅帮助下肢运动功能受限的患者恢复基本行走能力,还能为老年人提供运动支持,从而提高生活质量和独立性^[1-2]。作为外骨骼控制的关键组成部分,关节角度的准确预测至关重要,预测性能的提升直接推动外骨骼技术的发展和應用^[3]。表面肌电(surface electromyography, sEMG)信号反映神经肌肉的激活情况,与光学运动捕捉技术相比,具有无创性和可穿戴性的优势。此外,sEMG信号的变化通常先于运动学和动力学信号^[4],因此被广泛应用于人体运动意图预测,特别是在关节角度估计方面^[5-6]。

原始 sEMG 信号通常存在噪声且维度较高,这会削弱模型的性能和鲁棒性。因此,建模前通常需要通过特征提取来获取信号中的代表性特征。Turner 等^[7]从 sEMG 信号中提取了 8 种时域(time domain, TD)特征并进行对比,结果表明,Willison 振幅特征在所有模型中均表现最佳。Mosli 等^[8]提出了两种时频域特征提取算法,一种基于快速傅里叶变换,另一种基于小波变换。石欣等^[9]从 sEMG 信号中提取的时域特征能够捕捉信号强度,频域特征能够表征肌肉疲劳。但这些特征无法表示中枢神经系统对多块肌肉的耦合控制。此外,诸如小波分解等方法通常会生成大量特征,其中许多特征之间存在相似性或冗余。

与时频域特征不同,肌肉协同特征反映了中枢神经系统如何通过不同的协同模式协调多个肌肉^[10-11],具有很强的生理可解释性。非负矩阵分解(non-negative matrix factorization, NMF)是一种广泛用于肌肉协同提取的方法^[12-13]。Lyu 等^[14]使用 NMF 从 sEMG 信号中提取激活系数矩阵和肌肉协同矩阵用于时空特征建模,从而实现髌膝关节角度的连续预测。然而,由于多通道肌电信号之间的强相关性以及运动控制的固有冗余性,分解后的肌肉协同特征往往包含冗余信息。为了解决这个问题,Qin 等^[15-16]对分解后的激活系数矩阵进行了余弦相似度分析,并根据相似度大小区分冗余特征和非冗余特

征。然而,这种方法依赖于人工选择分割阈值。

实现从 sEMG 信号及其特征到关节角度的映射,是关节角度预测的核心所在。由于深度学习模型具有强大的非线性建模能力,因此在这一任务中得到了广泛应用。吴生彪等^[17]提出一种基于变分模态分解的 Informer 动态时序模型来预测多种运动模式下的下肢关节角度。Wei 等^[18]提出了一种三维卷积 Transformer 混合神经网络,将使用 sEMG 信号预测关节角度的问题视为一个序列到序列的转换问题,从而实现了快速准确的关节角度预测。Zhou 等^[19]提出了一种分层的脉冲注意力特征分解网络,使用脉冲稀疏注意力编码器和脉冲注意力特征分解模块来压缩和解码 sEMG 信号,从而有效降低了关节角度预测的推理成本。张娜等^[20]在深度森林和人工神经网络的混合模型中加入通道注意力机制,有效减少了关节角度预测误差。尽管上述模型实现了准确的关节角度预测,但它们对训练数据的个体特征的强烈依赖限制了它们对新受试者或新运动模式的适应性。为解决这一问题,石欣等^[21]提出一种空间注意力的双流时频卷积网络-门控特征解耦模型来提取跨受试者不变特征,但只在运动模式识别中验证了方法有效性。崔占贺等^[22]通过基于支持向量机的一维神经卷积网络实现小样本条件的泛化性步态识别,但是没有实现跨任务泛化的连续运动预测。Lin 等^[23]提出了一种基于对抗性迁移学习的能够进行旋转位置编码的 Transformer 模型,用于跨受试者关节运动的连续估计。Du 等^[24]提出了一种整合多模态的元-迁移学习框架,使模型仅用少量训练样本就能快速适应新个体。这种迁移学习方法能够有效解决跨受试者适应问题。然而,在单一框架内实现对不同运动速度和不同个体的快速适应,对实际外骨骼应用来说仍是一个关键挑战。

针对这些挑战,本文提出了一种泛化的下肢多关节角度预测框架,包含一种非冗余肌肉协同特征提取算法和一个能够实现跨速度和跨受试者泛化的关节角度预测模型。在特征提取阶段,首先通过 NMF 从 sEMG 信号中提取激活系数矩阵,然后使用均匀流形逼近与投影(uniform manifold approximation and projection, UMAP)对其进行降维处理,以消除冗余信息。角度预测模型由 1

个残差网络(residual network, ResNet)层、3个时间卷积网络-双向长短期记忆(temporal convolutional network-bidirectional long short-term memory, TCN-BiLSTM)模块和一个元学习器(meta-learner)组成,旨在捕捉局部特征、时空依赖并聚合信息。基于自建数据集的实验表明,非冗余肌肉协同特征优于其他特征,该框架不仅能够实现跨速度和跨受试者泛化,还通过外骨骼行走实验验证了其可行性。本研究的主要贡献为:

1)提出了一种非冗余肌肉协同特征提取算法。该算法从sEMG信号中提取具有生理可解释性和判别性的特征,且其性能优于传统时域特征。

2)构建了一种能够跨速度和跨受试者泛化的关节角度预测网络(generalizable joint angle prediction network,

GenJAPNet)。通过预训练提取共享特征及少样本微调策略,网络能够快速适应新任务。

3)通过特征对比实验、消融实验、跨速度和跨受试者实验以及外骨骼行走实验,验证了本研究方法的有效性和泛化能力。

1 方 法

如图1所示,本研究提出了一种新的框架,从sEMG信号中提取非冗余肌肉协同特征,并通过基于meta-learner的预训练与微调策略,实现对下肢多关节角度在跨速度和跨受试者条件下的预测。通过在四自由度外骨骼机器人上的实验,进一步验证了该方法的有效性。

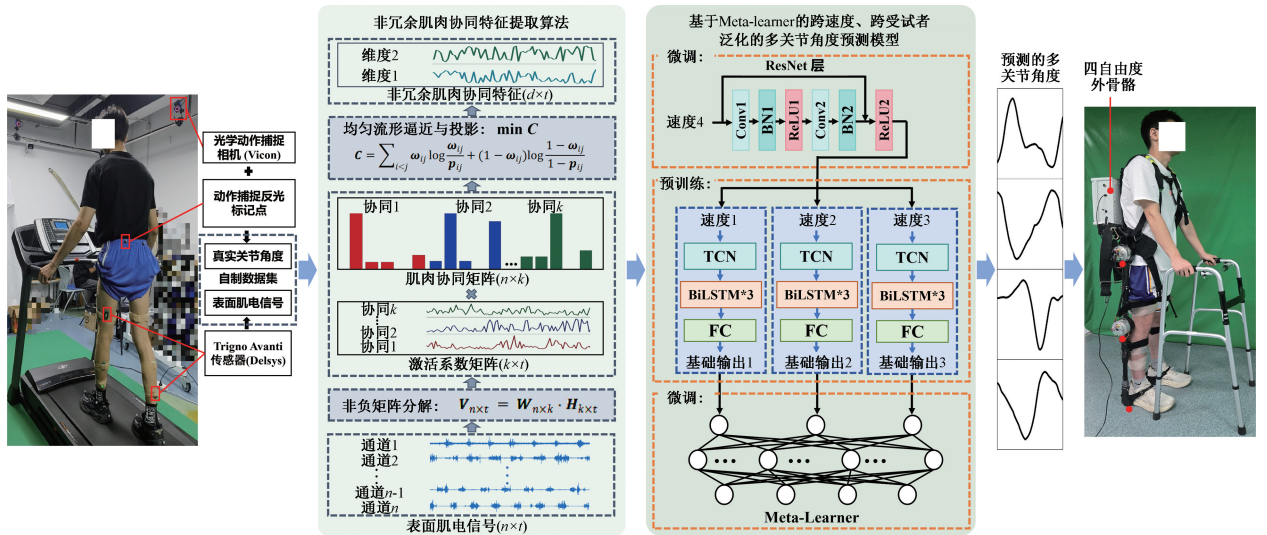


图1 本研究方法的整体流程

Fig. 1 Overall flowchart of the proposed method

1.1 基于NMF-UMAP的神经激活非冗余特征提取算法

在特征提取过程中,采用NMF-UMAP算法从sEMG信号中提取非冗余肌肉协同特征。首先使用NMF提取反映人类运动控制模式的激活系数矩阵。然后,使用非线性降维方法UMAP对激活系数矩阵进行降维,从而得到更低维、更稳定且更具判别性的特征。

sEMG信号($V_{n \times t}$)通过NMF分解为一个肌肉协同矩阵($W_{n \times k}$)和一个激活系数矩阵($H_{k \times t}$),其中肌肉协同矩阵表示每块肌肉在不同肌肉协同模式中的贡献度,而激活系数矩阵则表示每个协同模式在不同时间点的激活程度。

$$V_{n \times t} = W_{n \times k} \cdot H_{k \times t} \quad (1)$$

式中: n 表示sEMG的通道数量; t 表示时间序列的长度; k 表示肌肉协同数量。

由于不同协同模式之间存在相关性,且原始信号中

包含噪声和个体差异,所以通过NMF分解获得的激活系数矩阵通常包含冗余信息。UMAP是一种非线性降维算法,它能够近似高维数据的流形结构,并将其投影到低维空间,在保留局部邻域关系的同时保持全局分布。为了提取更具判别性的特征,本研究使用UMAP来降低激活系数矩阵的维度,从而获得非冗余的肌肉协同特征($x_{d \times t}, d < k$)。

$$x_{d \times t} = \text{UMAP}(H_{k \times t}) \quad (2)$$

式中: d 表示激活系数矩阵经过降维处理后的特征维度。

1.2 基于meta-learner的多关节角度预测模型结构

使用NMF-UMAP算法提取非冗余肌肉协同特征,然后使用窗口大小为300、步长为10的滑动窗口对其进行处理,并作为角度预测模型的输入。GenJAPNet网络的组成包括多个用于预训练以提取共享特征的TCN-BiLSTM模块以及用于微调以适应少样本新任务的

ResNet 层和 meta-learner。

ResNet 层由两个卷积核大小为 3 的卷积层、两个批量归一化层、两个线性整流单元 (rectified linear unit, ReLU) 以及一个残差连接组成。残差连接将输入与卷积块的输出相加,并将其和传递给后续模块。

TCN-BiLSTM 模块由时间卷积网络 (temporal convolutional network, TCN)、3 层堆叠的双向长短期记忆网络 (bidirectional long short-term memory, BiLSTM) 和一个全连接层组成。该 TCN 包含 3 个时间卷积块,每个卷积块包含两个卷积核大小为 3 的扩张因果卷积层和一个残差连接。最终的全连接层将提取的特征映射到输出空间。

Meta-learner^[25] 是包含两个 ReLU 激活函数的 3 层全连接神经网络。从 ResNet 层提取的特征被输入到 3 个并行的 TCN-BiLSTM 模块后产生 3 个独立的基础预测结果。然后,3 个基础输出沿特征维度拼接作为新特征输入 meta-learner,经进一步训练后生成最终的关节角度预测结果。

1.3 训练策略

在预训练阶段,使用 3 种步速的数据分别训练 3 个并行的 TCN-BiLSTM 模块。经过特征提取后,非冗余肌肉协同特征分别被输入到一个 TCN-BiLSTM 模块中,使得每个模块能够学习得到不同的初始参数。这一阶段使 TCN-BiLSTM 模块能够捕捉到不同行走速度下的共享特征。

在微调阶段,冻结 3 个预训练的 TCN-BiLSTM 模块的参数,仅更新 ResNet 层和 meta-learner 的参数。对于新速度或新受试者,模型仅需 30% 的数据就能实现有效的适应。输入特征经过 ResNet 层处理后被传递到 3 个预训练的 TCN-BiLSTM 模块中以获得 3 个基础预测。Meta-learner 整合预测结果,并生成最终的关节角度输出,从而实现跨速度和跨受试者的快速适应。

例如,在受试者 S1 的跨速度实验中,GenJAPNet 使用 1.0、2.0 和 3.0 km/h 步速下的数据进行预训练,使用 1.5 km/h 步速下的 30% 的数据进行微调。这表明模型能够在少样本情况下泛化至未见过的新速度。

2 实验与结果

本文在实验中选用均方根误差 (root mean square error, RMSE) 和相关系数 (correlation coefficient, CC) 作为关节角度预测性能的统一评估指标。

2.1 实验数据与实验设置

1) 自建数据集

采集 3 名健康受试者在 1.0、1.5、2.0、2.5、3.0 和 3.5 km/h 这 6 种步速下行走时的下肢肌肉 sEMG 信号及

髋膝关节角度数据。同时,来自下肢肌肉损伤受试者 S4 的有限数据也按相同方式采集。如图 1 所示,数据采集过程中,在受试者下肢 8 块肌肉上布置电极,并采用 Trigno avanti 传感器 (美国 Delsys) 以 1 000 Hz 的采样频率记录 sEMG 信号。8 块肌肉包括股直肌、胫骨前肌、股内侧肌、股外侧肌、股二头肌、半腱肌、腓肠肌和比目鱼肌。通过 VICON 运动捕捉系统获取髋膝关节角度。在下肢固定 16 个标记点构建 Plug-inGait 模型,以 100 Hz 的采样频率记录运动过程中各标记点的 X、Y、Z 坐标,并通过动态模型计算关节角度。两种采集设备通过硬件触发实现同步。

为避免原始数据中的噪声干扰,对数据进行预处理。首先,检查数据中是否存在非有限值,然后去除直流偏移。接着,使用四阶巴特沃斯带通滤波器 (20~450 Hz) 对 sEMG 信号进行滤波,以去除低频运动伪影和高频噪声,然后进行全波整流。在此基础上,使用四阶巴特沃斯低通滤波器 (6 Hz) 提取 sEMG 信号包络,最后将对 sEMG 信号降采样,实现与关节角度时间对齐。

2) 公开数据集

为弥补自建数据集中受试者数量较少的不足,并进一步验证所提方法在不同数据集下的泛化性能,本文引入 Georgia Institute of Technology 发布的公开数据集^[26]进行补充实验。该数据集包含在 0.50、0.85、1.25 和 1.55 m/s 这 4 种步速下采集的下肢运动数据,包括右下肢 11 块肌肉的 sEMG 信号和踝、膝、髋关节角度数据。实验中,采用 Biometrics Ltd. 表面肌电系统在受试者右下肢主要肌群布置 11 通道电极以 1 000 Hz 的采样频率采集 sEMG 信号。同时,用测角器以 1 000 Hz 的采样频率同步记录踝、膝、髋关节角度。为保证数据质量,数据集已对不同类型信号进行预处理。其中,sEMG 信号经 20~400 Hz 带通滤波以抑制运动伪差及高频噪声,关节角度信号采用 20 Hz 低通滤波进行平滑处理。在此基础上,选取其中 5 名受试者的数据用于后续实验与分析。

2.2 特征提取算法对比实验

为了验证提出的非冗余肌肉协同特征提取算法的有效性,在自建数据集上进行了特征对比实验。使用不同的特征提取算法从 sEMG 信号中提取不同特征,并将其作为模型输入。通过比较髋膝关节角度的预测性能来评估不同特征的有效性。实验中使用的模型是包含 3 个时间卷积模块的 TCN 网络,其卷积核大小为 3。其他特征提取算法从 sEMG 信号中提取平均绝对值 (mean absolute value, MAV)、均方根 (root mean square, RMS) 和波形长度 (waveform length, WL) 等 TD 特征。

在本研究的 NMF-UMAP 特征提取算法中,NMF 的肌肉协同数量和 UMAP 的目标维度是两个关键参数。通过网格搜索优化,基础模型为具有 3 个时间卷积模块、卷

积核大小为 3 的 TCN。实验结果表明,NMF 的肌肉协同数量选择为 8,UMAP 的目标维度选择为 5,可获得最佳预测性能的非冗余特征。

如表 1 所示,是所有受试者使用不同特征提取算法在 6 种步速下获得的预测结果的平均值。在几乎所有关节上,NMF-UMAP 特征提取算法均表现出优于其他算法

的预测性能,这表明 NMF-UMAP 能够有效提取具有判别性的非冗余肌肉协同特征。例如,在右侧髋关节上,NMF-UMAP 的预测误差 RMSE 为 2.656 8°,相比 NMF 的 3.043 7°降低了 12.71%,相比 MAV 的 4.433 8°降低了 40.08%,相比 RMS 的 4.515 3°降低了 41.16%,相比 WL 的 4.961 5°降低了 46.45%,体现出其显著的性能优势。

表 1 特征提取算法性能比较
Table 1 Performance comparison of feature extraction algorithms

算法	统计	RMSE/(°)				CC			
		左髋	左膝	右髋	右膝	左髋	左膝	右髋	右膝
MAV	Mean	4.246 4	6.181 5	4.433 8	6.590 3	0.922 8	0.927 0	0.898 9	0.910 6
	SD	0.557 7	0.767 1	0.656 6	0.992 4	0.035 6	0.039 1	0.073 0	0.067 1
RMS	Mean	4.448 9	6.208 8	4.515 3	6.571 3	0.889 2	0.915 3	0.880 9	0.908 4
	SD	0.834 1	0.985 0	0.724 2	1.060 8	0.097 3	0.067 2	0.107 6	0.071 8
WL	Mean	4.879 4	7.151 1	4.961 5	7.395 7	0.891 1	0.900 3	0.884 0	0.907 2
	SD	0.672 0	0.814 4	0.723 1	1.005 3	0.063 3	0.049 4	0.085 8	0.052 3
NMF	Mean	3.046 8	5.340 4	3.043 7	4.736 8	0.955 4	0.948 7	0.961 1	0.962 3
	SD	0.526 3	0.875 6	0.555 3	1.089 7	0.027 3	0.029 2	0.022 4	0.020 3
NMF-UMAP	Mean	2.820 9	5.058 9	2.656 8	4.388 2	0.964 0	0.955 4	0.970 5	0.969 4
	SD	0.448 5	0.885 0	0.455 9	1.024 7	0.019 1	0.014 4	0.015 6	0.016 8

2.3 消融实验

为验证本研究方法的有效性,在自建数据集 S1、S2 和 S3 这 3 名受试者的跨速度关节角度预测任务中进行了消融实验。对于每名受试者,使用速度 1.0、2.0 和 3.0 km/h 的步速数据进行预训练,随后使用新速度 1.5、2.5 和 3.5 km/h 下的 30% 数据分别进行微调。消融实验的设计为:

1) 无特征提取模块(NonF):移除 NMF-UMAP 肌肉协同特征提取模块,直接将原始 sEMG 信号作为 GenJAPNet 模型的输入。

2) 无预训练模块(NonT):移除 TCN-BiLSTM 模块,在提取肌肉协同特征后,直接使用 ResNet 层和 meta-learner 进行训练和关节角度预测。

3) 无 meta-learner(NonM):移除 meta-learner,将预训练模块的基础输出直接通过全连接层映射为关节角度。

如表 2 所示,是 3 名受试者跨速度关节角度预测任务中的消融实验结果。从整体性能看,本文提出的方法在 RMSE 和 CC 两项指标上均优于所有消融方法,证明了整体架构的有效性与良好的泛化性。与 NonF 相比,本文方法在髋关节和膝关节上的平均 RMSE 分别降低了 14.5% 和 15.1%,这表明 NMF-UMAP 模块能有效提取更具判别力的肌肉协同特征。与 NonT 相比,本文方法带来的性能提升最为显著,髋关节和膝关节上的平均 RMSE

分别降低了 56.1% 和 63.9%,这充分证明了 TCN-BiLSTM 模块在捕捉跨任务共享的时序特征上的关键作用。与 NonM 相比,本文方法在髋关节和膝关节上的 RMSE 分别降低了 12.7% 和 23.5%,说明在跨速度的少样本新任务上,meta-learner 能实现快速有效的适应,从而提升了模型的泛化性能。

2.4 跨速度与跨受试者实验

本研究在自建数据集和公开数据集上开展了跨速度实验和跨受试者实验,以验证所提方法的泛化性和有效性。在跨速度实验中,将本方法与其他 4 种基线方法进行对比来评估其性能优势。为验证少样本条件下知识迁移的有效性,在跨受试者实验中,与使用少样本数据直接进行建模与预测的方法进行对比。

1) 跨速度实验的实验设置

在自建数据集上,对于受试者 S1、S2 和 S3,分别使用 1.0、2.0 和 3.0 km/h 步速下提取的非冗余特征对 3 个 TCN-BiLSTM 模块进行预训练,训练完成后冻结其参数,再分别使用 1.5、2.5 和 3.5 km/h 步速下的有限样本对 ResNet 层和 meta-learner 进行微调。在公开数据集上,对每名受试者采用留一速度的验证方法,即依次选取其中 3 种速度的数据进行预训练,剩余一种速度作为新的目标任务,利用该速度下的少量样本进行微调并测试模型性能。在对比实验中,选择了 4 种用于关节角度预

表 2 各受试者内跨速度实验下的消融结果

Table 2 Ablation results under cross-speed experiments within each subject

方法	统计	RMSE/(°)				CC			
		左髌	左膝	右髌	右膝	左髌	左膝	右髌	右膝
本研究	Mean	1.849 4	2.790 4	1.703 1	2.451 9	0.987 2	0.987 7	0.989 1	0.990 7
	SD	0.334 7	0.436 9	0.375 6	0.324 1	0.004 2	0.004 8	0.006 5	0.005 6
NonF	Mean	2.162 0	3.285 3	2.029 3	3.156 2	0.981 7	0.981 7	0.984 4	0.984 8
	SD	0.426 5	0.427 9	0.395 8	0.414 6	0.008 5	0.007 6	0.007 7	0.007 6
NonT	Mean	4.209 9	7.733 5	3.965 0	6.904 7	0.934 0	0.900 8	0.943 6	0.937 5
	SD	1.147 9	1.996 8	1.536 0	2.669 9	0.020 2	0.053 2	0.028 0	0.025 8
NonM	Mean	2.117 4	3.646 9	2.055 7	3.550 4	0.983 1	0.978 1	0.984 0	0.980 2
	SD	0.279 9	0.365 5	0.411 4	0.335 7	0.007 2	0.008 0	0.008 6	0.009 1

测的代表模型作为基线方法,包括基于分位数回归的TCN-BiLSTM 混合模型 (quantile-regression temporal convolutional network-bidirectional long short-term memory hybrid model, QRTCN-BiLSTM)^[27]、注意力机制的卷积-长短时记忆网络 (convolutional neural network-long short-term memory-attention mechanism, CNN-LSTM-Attention)^[28]、Informer^[29]和基于门控循环单元的非线性自回归带外输入网络 (nonlinear autoregressive with exogenous inputs, NARX)^[30]。

2) 跨受试者实验的实验设置

在自建数据集的跨受试者实验中,使用受试者 S1 在 1.0、2.0 和 3.0 km/h 步速下提取的非冗余特征对 3 个 TCN-BiLSTM 模块进行预训练,并在完成后冻结其参数。然后,分别使用剩余受试者 S2、S3 和 S4 在 1.5、2.5 和 3.5 km/h 步速下的有限样本对 ResNet 层和 meta-learner 进行微调。在公开数据集的跨受试者实验中,使用其中一名受试者的数据进行预训练,分别使用剩余 4 名受试者的少量样本数据进行微调与测试。在无知识迁移的条件下,为适应少样本数据,调整模型结构。简化 TCN-BiLSTM 模块,该模块由两个时间卷积块和单层 BiLSTM 组成,同时对 meta-learner 的输入进行了相应调整,其他模块保持不变。

3) 自建数据集上跨速度和跨受试者实验结果

如图 2 所示,是自建数据集上跨速度实验对比结果的箱线图,图 2 中连接线代表所有预测结果的平均值,圆点表示不同受试者在不同速度下的预测结果。箱体上方的星号表示本研究方法与基线方法之间的统计显著性差异,其中“ns”表示 $p>0.05$,“*”表示 $p<0.05$,“**”表示 $p<0.01$,“****”表示 $p<0.001$ 。

实验结果表明,本研究方法在跨速度关节角度预测任务中的性能优于所有基线方法。具体而言,本研究方法在左右髌膝关节上均取得了最低 RMSE,其平均值分




图 2 自建数据集上跨速度实验及基线方法对比结果
Fig. 2 Results of cross-speed experiments and baseline method comparisons on the self-built dataset

别为 1.849 4°、2.790 4°、1.703 1°和 2.451 9°,相应的平均 CC 值分别为 0.987 2、0.987 7、0.989 1 和 0.990 7。相较于次优基线方法 QRTCN-BiLSTM,4 个关节上的平均 RMSE 下降了 52.19%。上述结果表明,本研究方法能够在不同关节上进行更准确且稳定的关节角度预测。此外,从图 2 中数据点分布可以看出,本研究方法的预测结

果更为集中,具有更强的稳定性和泛化能力。图 2 中的统计显著性表明,本文方法相较于基线方法在多数关节上均具有高度显著性。综上,实验结果验证了本研究方法在解决跨速度关节角度预测问题方面的有效性。

如图 3 所示,是自建数据集上跨受试者实验对比结果,图 3 中柱状图表示平均值,误差棒表示标准差,柱状图上方的星号表示本研究方法与基线方法间的统计显著性。在跨受试者实验中,本研究方法在所有关节上均优于基线方法。对于左髋、左膝、右髋和右膝关节,本研究方法的平均 RMSE 分别为 2.216 0°、3.450 7°、2.247 0°和 3.237 6°,对应的平均 CC 值均超过 0.98。此外,本研究方法中更小的误差棒表明实验结果更加集中,展示出更高的稳定性。在大多数情况下,统计显著性 p 值均小于 0.001,验证了本研究所用的知识迁移策略有效地增强了跨受试者的泛化能力,同时凸显了知识迁移在解决少样本问题方面的优势。




图 3 自建数据集上跨受试者实验及基线方法对比结果
Fig. 3 Results of cross-subject experiments and baseline method comparisons on the self-built dataset

4) 公开数据集上跨速度和跨受试者实验结果

如图 4 所示,是公开数据集上跨速度实验对比结果

的箱线图,实验结果表明,所提方法的跨速度关节角度预测性能同样优于所有基线方法,具有高度显著性。在踝、膝、髋关节上的 RMSE 平均值分别为 1.992 7°、4.093 6°和 2.265 5°,相较于其他基线方法平均降低了 38.76%、54.24%和 45.05%,对应的 CC 平均值分别为 0.929 0、0.978 3 和 0.972 2。上述结果证明了所提方法在不同数据集上的泛化能力。同时,图 4 中本研究方法更集中的数据点分布表明,所提方法在不同受试者不同速度条件下的具有更好的稳定性。此外,膝关节因运动幅度大、周期性强, RMSE 普遍高于髋关节和踝关节,但 CC 也较高。而踝关节因其活动范围较小, RMSE 值较低,但其运动复杂度更高,导致 CC 值更低。




图 4 公开数据集上跨速度实验及基线方法对比结果
Fig. 4 Results of cross-speed experiments and baseline method comparisons on the public dataset

如图 5 所示,是公开数据集上跨受试者实验的对比结果柱状图,所提方法在踝、膝、髋关节上均显著优于基线方法。所提方法在踝、膝、髋关节上的平均 RMSE 分别为 2.060 5°、4.601 3°和 2.383 3°,平均 CC 值均超过 0.93。此外,与踝关节和髋关节相比,跨受试者时的膝关节预测性能下降更为明显,可能是因为膝关节运动更易受个体差异影响。




图5 公开数据集上跨受试者实验及基线方法对比结果

Fig. 5 Results of cross-subject experiments and baseline method comparisons on the public dataset

3 四自由度外骨骼机器人实验验证

为了进一步验证本文方法的有效性,使用外骨骼机器人进行物理实验验证。该外骨骼具有四自由度,总重量约为 30 kg,整体高度约为 1.6 m。关节布局模拟人体下肢结构,每条腿设有髋关节、膝关节和踝关节,其中髋关节和膝关节为主动驱动,可实现屈伸运动;踝关节为被动万向关节,可完成背屈/跖屈及内翻/外翻动作。外骨骼的大腿和小腿部分设计为可调长度,以适应不同身高的穿戴者。躯干、大腿及小腿处配备了固定结构,用于增强佩戴的贴合性与稳定性。外骨骼的主动驱动关节集成了电机、驱动器和编码器,可实时记录关节角度和角速度。为提高实验安全性,外骨骼背包顶部配有紧急停止装置,可在出现异常情况时立即切断驱动输出,保障受试者安全。

3.1 预测步态的获取

本实验使用自建数据集的数据进行实验以获取预测

关节角度。在受试者 S3 内进行跨速度实验,使用步速 2.5、3.0 和 3.5 km/h 的数据进行预训练,分别使用步速 1.0、1.5 和 2.0 km/h 的 30% 数据进行微调得到 3 种步速对应的左右髋膝关节预测角度。在受试者 S4 上进行跨受试者实验,使用受试者 S1 在 1.0、2.0 和 3.0 km/h 步速下的数据进行预训练,使用受试者 S4 在 1.0、1.5 和 2.0 km/h 步速下的有限数据进行微调得到 3 种步速对应的左右髋膝关节预测角度。

由于预测关节角度为连续时间序列,缺乏明确起止标志且存在一定波动,直接用于外骨骼驱动可能导致轨迹突变或超出安全范围,因此需进行预处理。首先,根据角度周期特性划分步态周期并选取稳定片段;随后进行平滑处理以抑制高频抖动。为实现平稳启停,在序列起始与结束阶段采用六次多项式插值构建过渡轨迹,并通过中间时刻约束限制关节角度在安全范围内。最终,将处理后的髋、膝关节角度序列转换为标准步态文件,用于外骨骼执行。

3.2 跨速度实验的物理验证

如图 6 所示,受试者 S3 穿戴外骨骼成功执行了 3 种步速下的预测步态。执行过程中,采集了 3 种步速下外骨骼左右髋膝关节的反应步态轨迹。




图6 受试者 S3 穿戴外骨骼执行 3 种步速下的跨速度预测步态

Fig. 6 Subject S3 wearing the exoskeleton executing cross-speed predicted gaits at three different walking speeds

如图 7 所示,反应步态轨迹呈现出连续性、周期性、平滑性的良好运动特征,验证了本研究提出的跨速度关节角度预测方法在外骨骼应用中的可行性。

此外,分别采集了 3 种步速下穿戴外骨骼与无外骨骼情况下下肢肌肉的 sEMG 信号,并计算两种情况下 sEMG 信号的 RMS 值,以未穿戴外骨骼情况下的 RMS 作为基准进行归一化。如图 8 所示,穿戴外骨骼情况下的 sEMG 信号的 RMS 在 3 种步速下相较于无外骨骼分别下降了 37.39%、5.31% 和 39.49%,说明外骨骼在执行预测步态时能够减轻受试者的肌肉负担。此外,不同步速下




图 7 受试者 S3 在 1.0、1.5 和 2.0 km/h 步速下执行预测步态时外骨骼左右髋、膝关节的反应轨迹

Fig. 7 Response trajectories of the left and right hip and knee joints of the exoskeleton while Subject S3 executes predicted gaits at walking speeds of 1.0, 1.5, and 2.0 km/h




图 8 3 种步速下受试者 S3 穿戴外骨骼与无外骨骼情况下下肢肌肉 sEMG 信号的 RMS

Fig. 8 RMS of lower-limb muscle sEMG signals with and without the exoskeleton at three different walking speeds

RMS 降幅存在差异,表明外骨骼助力效果与步态动态特性及运动强度密切相关。

3.3 跨受试者实验的物理验证

如图 9 所示,受试者 S4 穿戴外骨骼成功执行了步速 1.0、1.5 和 2.0 km/h 下的预测步态。

如图 10 所示,是受试者 S4 在 3 种不同步速下穿戴外骨骼行走时采集的左右髋膝关节的反应步态轨迹。图 10 中轨迹变化形态与人体步态过程中关节的屈伸规律一致,且无明显突变,验证了本研究提出的跨受试者泛化的关节角度预测方法的可靠性。

此外,同样采集了受试者 S4 在 3 种步速下穿戴外骨




图 9 受试者 S4 穿戴外骨骼执行 3 种步速下的跨受试者预测步态

Fig. 9 Subject S4 wearing the exoskeleton executing cross-subject predicted gaits at three different walking speeds




图 10 受试者 S4 在 1.0、1.5 和 2.0 km/h 步速下执行预测步态时外骨骼左右髋、膝关节的反应轨迹

Fig. 10 Response trajectories of the left and right hip and knee joints of the exoskeleton while Subject S4 executes predicted gaits at walking speeds of 1.0, 1.5, and 2.0 km/h

骼与无外骨骼时下肢肌肉的 sEMG 信号,计算其 RMS 值并进行归一化。如图 11 所示,穿戴外骨骼情况下的 sEMG 信号的 RMS 在 3 种步速下相较于无外骨骼分别下降了 29.52%、54.38% 和 54.16%,验证了外骨骼在执行预测步态时对受试者具有显著的辅助效果。此外,与受试者 S3 相比,肌肉激活水平下降程度略有差异,表明外骨骼助力效果受个体差异影响。但是两名受试者在不同步速下均表现出 RMS 下降趋势,说明所提方法在不同个体间具有较好的适用性和稳定性。

通过受试者 S3 和 S4 成功完成的外骨骼上机实验,验证了本研究提出的跨速度、跨受试者泛化的下肢关节角度预测方法能够在有限数据条件下实现准确的关节角




图 11 3 种步速下受试者 S4 穿戴外骨骼与无外骨骼情况下下肢肌肉 sEMG 信号的 RMS

Fig. 11 RMS of lower-limb muscle sEMG signals with and without the exoskeleton at three different walking speeds

度预测,并为下肢受伤患者在使用外骨骼完成日常行走任务时提供有效的支持。

4 结 论

在本研究中,提出了一种具有跨速度和跨受试者泛化能力的下肢多关节角度预测方法。该方法由基于神经激活的非冗余肌肉协同特征提取算法与基于 meta-learner 的多关节角度预测模型组成。为了验证所提出方法的有效性,开展了一系列实验。特征对比实验表明,该特征提取算法优于传统的时域特征。消融实验、跨速度和跨受试者实验的结果进一步验证了本文方法在关节角度预测上的准确性和泛化性。最后,使用外骨骼执行预测步态的物理行走实验证实了本文方法的可行性和可靠性。尽管本研究方法缓解了跨任务泛化和数据有限的问题,但它仍然依赖于大量数据的预训练来获取足够的先验知识。在未来工作中,将进一步拓展跨任务泛化能力,应用到更复杂的运动模式,如上下楼梯等运动模式。

参考文献

[1] 石欣,唐佳,范智瑞,等. 下肢外骨骼电机超调预测-优化双阶段补偿控制策略[J]. 仪器仪表学报, 2025, 46(11): 158-172.
SHI X, TANG J, FAN ZH R, et al. Prediction-optimization dual-stage compensation control strategy for lower limb exoskeleton motor overshoot [J]. Chinese Journal of Scientific Instrument, 2025, 46 (11): 158-172.
[2] TIAN D K, LI W T, LI J K, et al. Self-balancing exoskeleton robots designed to facilitate multiple rehabilitation training movements[J]. IEEE Transactions

on Neural Systems and Rehabilitation Engineering, 2024, 32: 293-303.
[3] ZHANG H R, QIN P J, BAI Y, et al. A generalized approach for multi-joint angle prediction of the lower limb in multi-task scenarios of different wearers [J]. IEEE Sensors Journal, 2026, 26(6): 8547-8560.
[4] TERAMAE T, NODA T, MORIMOTO J. EMG-based model predictive control for physical human-robot interaction: Application for assist-as-needed control [J]. IEEE Robotics and Automation Letters, 2017, 3 (1): 210-217.
[5] XIONG D ZH, 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.
[6] XIONG D ZH, ZHANG D H, CHU Y Q, et al. Intuitive human-robot-environment interaction with EMG signals: A review [J]. IEEE/CAA Journal of Automatica Sinica, 2024, 11(5): 1075-1091.
[7] TURNER A, SHIEFF D, DWIVEDI A, et al. Comparing machine learning methods and feature extraction techniques for the emg based decoding of human intention [C]. 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society, 2021: 4738-4743.
[8] MOSLHI A M, ALY H H, ELMESSIERY M. The impact of feature extraction on classification accuracy examined by employing a signal transformer to classify hand gestures using surface electromyography signals [J]. Sensors, 2024, 24(4): 1259.
[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 lower limb sEMG [J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 271-280.
[10] TING L H, MCKAY J L. Neuromechanics of muscle synergies for posture and movement [J]. Current Opinion in Neurobiology, 2007, 17(6): 622-628.
[11] D'AVELLA A, LACQUANITI F. Control of reaching movements by muscle synergy combinations [J]. Frontiers in Computational Neuroscience, 2013, 7: 42.
[12] RABBI M F, PIZZOLATO C, LLOYD D G, et al. Non-

- negative matrix factorisation is the most appropriate method for extraction of muscle synergies in walking and running[J]. *Scientific Reports*, 2020, 10(1): 8266.
- [13] ZHAO K K, ZHANG ZH SH, WEN H Y, et al. Muscle synergies for evaluating upper limb in clinical applications: A systematic review[J]. *Heliyon*, 2023, 9(5): 16202.
- [14] LYU C, LIU Y, CHEN Y, et al. sEMG-based lower limb joint angle prediction with muscle synergy spatio-temporal fusion and DWCIT model[J]. *IEEE Sensors Journal*, 2025, 25(14): 27155-27165.
- [15] 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.
- [16] LU W J, MA H T, ZENG D X. Performance of a novel muscle synergy approach for continuous motion estimation on untrained motion[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024, 32: 3554-3564.
- [17] 吴生彪, 游涛, 桂家政. 基于 VMD-Informer 和表面肌电信号的下肢关节角度预测[J]. *电子测量技术*, 2026, 49(7): 151-160.
- WU SH B, YOU T, GUI J ZH. Prediction of lower limb joint angles based on VMD-Informer and surface electromyography signals[J]. *Electronic Measurement Technology*, 2026, 49(7): 151-160.
- [18] WEI Z J, ZHANG ZH Q, XIE SH Q. A transformer framework informed by muscle anatomy and sequence-to-sequence translation for continuous joint kinematics prediction using sEMG[J]. *IEEE Journal of Biomedical and Health Informatics*, 2025, 30(2): 1140-1152.
- [19] ZHOU X, LIN CH, WANG C, et al. sEMG-based joint angle estimation via hierarchical spiking attentional feature decomposition network[J]. *IEEE Robotics and Automation Letters*, 2025, 10(3): 2176-2183.
- [20] 张娜, 张明进, 王晓冬, 等. 基于表面肌电信号的手指关节角度估计方法[J]. *电子测量与仪器学报*, 2023, 37(8): 60-70.
- ZHANG N, ZHANG M J, WANG X D, et al. Finger joint angle estimation method based on surface electromyography signal[J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(8): 60-70.
- [21] 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-based motion pattern recognition using electromyographic signals[J]. *Chinese Journal of Scientific Instrument*, 2026, 47(2): 244-255.
- [22] 崔占贺, 艾莉莎, 马欣雨, 等. 基于 1D-CNN-SVM 的下肢外骨骼步态信息识别研究[J]. *电子测量技术*, 2025, 48(12): 71-78.
- CUI ZH H, AI L SH, MA X Y, et al. Research on gait information recognition of lower limb exoskeleton based on 1D-CNN-SVM[J]. *Electronic Measurement Technology*, 2025, 48(12): 71-78.
- [23] LIN CH, HE ZH. A rotary transformer cross-subject model for continuous estimation of finger joints kinematics and a transfer learning approach for new subjects[J]. *Frontiers in Neuroscience*, 2024, 18: 1306050.
- [24] DU G M, ZHU H Q, DING ZH, et al. Meta-transfer-learning-based multimodal human pose estimation for lower limbs[J]. *Sensors*, 2025, 25(5): 1613.
- [25] CAO W J, LI CH Y, YANG L J, et al. A fusion network with stacked denoise autoencoder and meta learning for lateral walking gait phase recognition and multi-step-ahead prediction[J]. *IEEE Journal of Biomedical and Health Informatics*, 2024, 29(1): 68-80.
- [26] 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.
- [27] WANG L L, WANG Y X, GUO F, et al. Lower limb joint angle prediction based on multistream signaling and quantile regression, temporal convolution network-bidirectional long short-term memory network neural network[J]. *Machines*, 2024, 12(12): 901.
- [28] WANG ZH, CHEN H, YANG F L, et al. Accurate prediction of knee joint angles using a hybrid CNN-LSTM-Attention network from surface electromyography[C]. 2024 IEEE International Conference on Robotics and Biomimetics, 2024: 2233-2240.
- [29] ZHOU H Y, ZHANG SH H, PENG J Q, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[C]. 35th AAAI Conference on

Artificial Intelligence. 2021, 35(12): 11106-11115.

[30] SHI X, ZHANG J Y, QIN P J, et al. Angle estimation for lower limb joint movement based on vmd-narx algorithm[C]. 2021 IEEE International Conference on Real-time Computing and Robotics, 2021: 474-479.

作者简介



张海容,2023 年于青岛大学获得学士学位,现为中国科学院深圳先进技术研究院实习生、长春理工大学研究生,主要研究方向为信号与信息处理和人工智能。
E-mail:2023100766@ mails. cust. edu. cn

Zhang Hairong received her B. Sc. degree from Qingdao University in 2023. She is currently a research intern at the Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, and a postgraduate student at Changchun University of Science and Technology. Her main research interests include signal and information processing and artificial intelligence.



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 in the School of Artificial Intelligence at Shenzhen University. His main research interest includes multi-modal human-machine interaction.



田定奎(通信作者),2012 年于长江大学获得学士学位,2017 年于太原理工大学获得硕士学位,2022 年于北京理工大学获得博士学位。现为中国科学院深圳先进技术研究院副研究员,主要研究方向包括

外骨骼与机器人系统集成、运动控制以及人体运动意图感知。

E-mail:dk. tian1@ siat. ac. cn

Tian Dingkui (Corresponding author) received his B. Sc. degree from Yangtze University in 2012, his M. Sc. degree from Taiyuan University of Technology in 2017, and his Ph. D. degree from Beijing Institute of Technology in 2022. He is currently an associate researcher in the Shenzhen Institute of Advanced Technology at Chinese Academy of Sciences. His mian research interests include exoskeleton and robotic system integration, motion control, and human motion intention perception.