

DOI: 10.13382/j.jemi.B2508642

基于运动姿态和表面肌电数据融合的多数据流神经网络步态识别

李 沐^{1,2} 马 超^{1,2} 姚 杰³ 苏 鹏^{1,2} 王梦迪^{1,2} 张海洋^{1,2} 徐浩文^{1,2}

(1. 北京信息科技大学机电工程学院 北京 100192; 2. 北京信息科技大学现代测控技术教育部重点实验室 北京 100192; 3. 北京航空航天大学生物与医学工程学院 北京 100191)

摘 要:针对步态识别方法中单模态信号在前进、后退与转弯等动态任务中易误判的问题,提出一种基于运动姿态信号与表面肌电(sEMG)信号融合的多数据流神经网络模型方法。采集下肢运动姿态与表面肌电信号,通过步态周期划分和对齐策略完成数据处理,从数据特性信息在时序结构、信号类型与表达维度上的异质性角度出发构建包括运动姿态的动态时序特征、sEMG的频域倍频程谱和时域直方图统计的特征信息。采用Transformer捕捉运动姿态信号的动态演化模式、双路多层感知机(MLP)分别提取sEMG在时域与频域上的局部响应特性,构建进行功能互补的多数据流神经网络模型,从而实现运动姿态与局部肌纤维活动信息的融合表达。结果表明,所建立的模型在前进、后退与转弯3类任务中的识别准确率分别提升了8%、6%与24%,显著改善了由动作边界模糊带来的误判问题,在准确性、泛化性方面具有更好的表现。该方法为多模态融合在复杂步态识别中的应用提供了研究参考和技术支撑,为高精度的步态识别系统设计提供了参考。

关键词: 步态识别; 运动姿态; 表面肌电; 数据融合; 多数据流神经网络

中图分类号: TP181; TN98 **文献标识码:** A **国家标准学科分类代码:** 510.4010

Gait recognition based on a multi-stream neural network fusing motion posture and surface electromyography data

Li Mu^{1,2} Ma Chao^{1,2} Yao Jie³ Su Peng^{1,2} Wang Mengdi^{1,2} Zhang Haiyang^{1,2} Xu Haowen^{1,2}

(1. School of Mechanical and Electrical Engineering, Beijing Information Science and Technology University, Beijing 100192, China; 2. Key Laboratory of Modern Measurement and Control Technology, Ministry of Education, Beijing Information Science and Technology University, Beijing 100192, China; 3. School of Biological Science and Medical Engineering, Beihang University, Beijing 100191, China)

Abstract: To address the problem of single-modal signals being prone to misclassification in dynamic tasks such as forward, backward, and turning, this paper proposes a multi-stream neural network model based on the fusion of motion posture signals and surface electromyography (sEMG) signals. Lower-limb motion posture and sEMG signals are collected and processed using a gait cycle segmentation and alignment strategy. Based on the heterogeneity of data characteristics in terms of temporal structure, signal type, and expression dimensions, feature information is constructed, including dynamic temporal features of motion posture, frequency-domain octave spectrum of sEMG, and time-domain histogram statistics. A Transformer is used to capture the dynamic evolution of motion posture signals, and a two-way multilayer perceptron (MLP) is used to extract local response characteristics of sEMG in the time and frequency domains, forming a multi-stream neural network structure with complementary feature representations to achieve the fused expression of motion posture and local muscle fiber activation information. Results show that the proposed model improves recognition accuracy by 8%, 6%, and 24% in forward, backward, and turning tasks, respectively, significantly reducing misclassification caused by blurred motion boundaries and demonstrating superior accuracy and generalization performance. This method provides research reference and technical support for the application of multimodal fusion in complex gait recognition, and provides a reference for the design of high-precision gait recognition systems.

Keywords: gait recognition; movement posture; surface electromyography; data fusion; multi-stream neural network

0 引言

步态识别广泛应用在健康监测、老年人护理、运动分析等领域中^[1]；智能传感技术和计算机技术的快速发展，使得步态识别的应用场景和潜力不断拓展。前进、后退、上楼、下楼等步态任务的有效识别、精准捕捉个体的步态变化，对实现康复治疗、智能辅具设计开发在病理机制和临床应用方面都有积极的价值和意义^[2]。

近年来，机器学习算法、智能芯片和人工智能技术的快速发展，步态分析方法与技术在智能模型、信息融合和模型轻量化方面都有了很大的进步^[3]。研究人员将步态过程中的运动姿态、表面肌电 (surface electromyography, sEMG)、足底压力、步态图像信号，通过智能的神经网络用于步态任务和步态特征的识别中。比如，通过角度、角速度、加速度、足底压力、肌电 (electromyography, EMG) 信号来完成运动模式与步态阶段的分析^[4]。利用卷积神经网络模型分析足底压力，可以提取人们足部结构与地面接触的差力学特性，能够较好的实现个体身份区分^[5]。通过分析步态过程中 sEMG 信号的稳定特征信号、时序特性，在进行线性判别分析-粒子群优化-长短期记忆联合模型 (linear discriminant analysis-particle swarm optimization-long short-term memory, LDA-PSO-LSTM) 神经网络综合建模后，可以较好的实现典型步态相位的准确识别^[6]。同样，运动姿态信息在步态识别中也有着广泛的应用，通过提取运动过程中的典型为主运动曲线、运动图像，将其应用于维卷积神经网络、YOLO 等模型，则可以较好的实现前进、上楼、下楼等多种步态任务的分类识别，并在动态环境中展现出较强的鲁棒性与适应能力^[7]。

随着研究的深入，对易混淆的步态任务分类、步态相位划分等技术的准确性、实时性以及抗干扰性方面要求越来越高^[8-9]。前进和后退、前进和转弯、上坡和上楼等不同边界较为模糊的情况下相似步态任务的分类，单传感器难以全面捕捉受试者的运动特性并使分类结果产生一定的误判；多传感器信息融合的理论和技术为步态识别提供更全面、细致的数据支撑，增强步态分类的鲁棒性^[10]。利用支持向量机 (support vector machine, SVM) 与模糊 C 均值 (fuzzy C-means, FCM) 组合的 SVM-FCM 深度学习模型，融合人体下肢肌电信号与足底压力信号，能够提升复杂环境下外骨骼动态人机协同行走的交互能力^[11]。通过分析步态过程中足底压力与运动姿态信号，在结合了轻量梯度提升机算法 (light gradient boosting machine, LightGBM) 神经网络算法组合建模后，能够提升实际步态识别系统的效率与预测精度^[12]。同样的，采用基于梯度提升的机器学习算法中的极端梯度提升模型 (extreme gradient boosting, XGBoost)，分析并融合股直

肌表面肌电与加速度信号，可以实现低成本下可穿戴系统研究中对前进、上坡等步态的高精度识别^[13]。可以看出，现有的研究在模型的优化和算法的改进上取得了一定的成果，而对于如何精确处理和融合来自于不同传感器的数据，仍需要深入开展研究^[14]。

综上，研究面向步态任务识别下相似步态中所出现的易混淆问题，本文提出一种基于数据层融合与多数据流神经网络 (multi-stream neural network, MSNN) 模型的步态识别方法。通过步态周期划分和对齐策略对下肢运动姿态与表面肌电信号完成数据处理与周期匹配，构建功能互补的多数据流网络模型 (含 3 条特征分支)，利用信号在时序结构、类型与表达维度上的异质特性，在数据层实现 3 种信号的有效融合。最后通过 5 种不同步态任务的分类识别精度对比分析，验证方法的有效性。

1 数据融合方法

1.1 多模态识别的融合机制

在复杂步态识别中，融合多模态信号能够充分利用不同感知维度的信息互补性，有效提升对运动状态和动作意图表达能力，增强系统在边界模糊任务的判别精度与鲁棒性。多模态的理论基础归结为最大化模态组合对目标变量的信息增益^[15]。设 X_1 和 X_2 分别表示运动姿态信号与表面肌电信号的特征集合， Y 为步态任务标签，联合模态对分类目标的信息量表示为：

$$I(Y; X_1, X_2) = I(Y; X_1) + I(Y; X_2 | X_1) \quad (1)$$

式中： $I(Y; X_1)$ 表示运动姿态信号中所包含的关于任务标签的互信息量； $I(Y; X_2 | X_1)$ 表示在已知运动姿态信号特征条件下，sEMG 信号对任务标签带来的新增信息。若 $I(Y; X_2 | X_1) > 0$ ，则说明 sEMG 信号在识别中具备补充价值，两类信号间具有信息互补性。

多模态特征之间在采样频率、结构维度、时序形态与生理意义等方面存在显著异质性，统一嵌入映射策略可解决直接拼接原始特征时引发空间冗余、尺度不一致与混叠问题^[16]。设原始模态分别为 $X_1 \in R^{d_1}$ 、 $X_2 \in R^{d_2}$ ，映射函数为：

$$\phi_1: X_1 \rightarrow R^{d_1}, \phi_2: X_2 \rightarrow R^{d_2} \quad (2)$$

优化目标为最小化嵌入空间的模态分布差异：

$$\min_{\phi_1, \phi_2} \text{Dist}(\phi_1(X_1), \phi_2(X_2)) \quad (3)$$

其中， $\text{Dist}(\cdot)$ 采用欧氏距离、Kullback-Leibler 散度或分布对齐损失等度量方式，约束不同模态在嵌入空间的结构一致性，有效避免特征冲突，提升模型对融合表示的判别能力。

信息瓶颈 (information bottleneck, IB) 在多模态压缩与判别建模中，进一步控制冗余，从而增强模型的泛化能

力^[17]。目标函数为:

$$L_{IB} = \min I(X; T) - \beta I(T; Y) \quad (4)$$

式中: X 为原始模态输入; T 为压缩后的嵌入表示; Y 为目标任务标签; β 为调控压缩程度与任务保留信息的平衡系数。

多模态特征与步态标签的互信息结构如图1所示。运动姿态特征主要反映动态轨迹与动作节律, sEMG 则揭示神经驱动与肌肉响应机制。区域 C 代表交叉信息构成融合后的判别核心, 在面对前进、后退和转弯等边界模糊任务中, 体现了模态间在时间分布、信号维度与感知机制上的互补性, 姿态信号提供的动态结构信息与肌电信号表达的生理驱动机制协同作用, 从而实现更全面的运动建模与更强的步态判别鲁棒性。




图1 多模态特征与步态标签的互信息结构

Fig. 1 Mutual information structure of multimodal features and gait labels

研究中结合相似步态易混淆特性, 围绕运动姿态与 sEMG 信号建模、特征空间对齐与信息压缩来构建融合策略。通过互信息理论刻画运动姿态与 sEMG 信号在任务判别中的互补性, 统一嵌入映射解决模态异构带来的结构不一致问题, 引入信息瓶颈约束压缩冗余、保留判别关键信息, 为后续模型设计、实验分析提供理论支持。

在模型实现层, 多模态融合通常依托多数据流 (multi-stream) 神经网络结构完成。通过为不同模态或不同特征域构建独立分支, 使互信息增益、嵌入对齐和信息压缩等机制在网络表征空间中得到有效落实^[18-19], 从而提升跨模态特征的互补利用效率^[20-21]。因此, 针对运动姿态的时序特征、sEMG 时域统计特征与频域谱特征, 本文构建3条特征分支, 实现异质特征的解耦表达与融合, 为步态识别模型提供结构基础。

1.2 数据融合策略

为提升模型对前进、后退与转弯等动态任务的区分能力, 从特征表征能力与信息解耦角度出发, 构建融合输入的多模态特征向量。针对运动姿态信号中欧拉角易受积分误差与噪声干扰的问题, 筛选 Z 轴加速度、 Y 轴加速度与 X 轴角速度3类信号作为输入特征, 以提高其鲁棒性与判别性。针对 sEMG 的非平稳性与跨域特征差异, 构建3类形式: 1) 包络时序特征, 用于保留激活模式的时序结构; 2) 频域倍频程谱特征, 用于捕捉跨频带的稳定性

信息; 3) 时域直方图特征, 用于增强对局部幅值变化的建模。

特征融合过程如图2所示。考虑到运动姿态与 sEMG 信号在采样频率与时间长度上的差异, 直接对其任一模态进行对等的重采样将带来显著信息损失或计算负担, 难以兼顾判别能力与模型效率。本文在周期边界对齐基础上, 保持各模态原始时间分辨率, 分别采用 Transformer 与多层感知机 (multi-layer perceptron, MLP) 提取时序动态结构与多域肌电特征, 并统一映射至 1×64 维的嵌入空间, 为后续多流融合提供结构一致的输入基础。




图2 特征融合过程

Fig. 2 Feature fusion process

2 多数据流神经网络模型

2.1 模型构建

多数据流神经网络模型的步态识别流程如图3所示。针对前进、后退与转弯等任务中的动态结构与肌电响应特征差异, 构建多数据流神经网络模型以实现多模态数据融合识别。模型输入由经预处理后的3类特征构成: 1) 运动姿态信号中筛选出的三轴特征 (Z 轴加速度、 Y 轴加速度、 X 轴角速度), 构成 3×128 的时序输入;

2) sEMG 包络信号在频域下提取 4 类不同分辨率的倍频程谱图(1/3、1/12、1/24、1/48),用于刻画肌肉激活的频率响应模式;3) sEMG 在时域构建的直方图统计特征,联合 Mean 与 Std 形成 12 维统计描述,用于反映幅值分布与激活结构差异。




图3 多数据流神经网络模型下的步态识别流程

Fig.3 Gait recognition process under multi-data-stream neural network model

在模型中,运动姿态分支采用 Transformer 的时序建模框架。输入特征经线性投影至 64 维嵌入空间,结合位置编码增强时间依赖性,通过 3 头自注意力的 Transformer-Encoder 模块提取高阶时序动态关系与周期变化结构,最终通过平均池化压缩为 1×64 的固定维度表示。

针对两类频域的 sEMG 特征,从其特征结构稳定、维度低的特性出发,分别构建两条轻量化 MLP 分支进行编码。频谱特征通过短时傅里叶变换(short-time Fourier transform, STFT)获取不同频段肌电能量分布,反映肌肉活化的频域模式;直方图特征则通过幅值分段统计联合均值与标准差,提取局部放电特征与整体激活形态。两

类特征经两层 MLP 映射至 1×64 的嵌入向量,完成与姿态分支在表示空间上的结构对齐。

最终三路特征都分别映射为 1×64 的特征向量,组合为 3×64 的模态 token 序列,输入至模态级 Transformer 模块以实现语义关联与互补关系,融合后的全局特征经分类器输出步态识别结果。

2.2 步态数据获取

为系统评估提出的数据融合策略及多数据流神经网络结构在步态任务分类中的有效性,设计了多组对比实验,分别考察不同信号组合与网络结构对分类性能的影响,进而验证融合方法在提升识别精度、减少任务混淆方面的实际效果。实验包括如下 5 种主要设置:1) 基线模型,选取惯性测量单元(inertial measurement unit, IMU)信号中降维后的 3 类动态特征(Z 轴加速度、Y 轴加速度、X 轴角速度),通过 Transformer 模型进行训练;2) 通过将 IMU3 个主要特征与 sEMG 原始包络信号进行融合,输入双 Transformer 网络进行训练,验证肌电信号对步态识别的辅助作用;3) 通过将 IMU3 个主要特征与 sEMG 频域特征融合,分别输入 Transformer 和 MLP 网络进行训练,探讨频域信息在提升动态任务区分能力中的作用;4) 通过 IMU3 个主要特征与 sEMG 时域融合,分别输入 Transformer 和 MLP 网络进行训练,分析肌肉激活模式在步态识别中的贡献;5) 通过 IMU3 个主要特征与 sEMG 的时域与频域特征融合,结合多数据流神经网络模型结构进行训练,最终实现精度与效率的平衡。

实验过程中将 IMU 佩戴于右侧小腿胫骨前方,采集位姿信号;sEMG 传感器则固定于右侧股直肌腹部区域,用于记录运动中肌肉的电激活过程。最终 5 种步态任务,进行实验 200 人次,获得实验数据 2 400 组,每种步态任务 400 组以上。

实验数据的采集流程如下:

- 1) 对受试人讲述实验过程,签署知情同意书。
- 2) 实验前,受试者穿着宽松衣物,确保传感器贴附稳定、不受外部遮挡。
- 3) 每位受试者进行约 2 min 热身,以避免冷启动导致的肌电信号异常。
- 4) 实验过程中,受试者按照指令完成 5 种步态任务:前进、后退、上楼、下楼和转弯,每种任务重复采集 20 组以上样本。
- 5) 使用蓝牙连接传感器与上位机系统,实现数据的实时采集、解码与保存。

采集到的原始信号均具有良好的周期与信噪比,所有受试者运动状态稳定、步态自然,满足后续深度学习模型对时序特征稳定性与表达完整的要求,为提出的特征融合与分类方法提供了可靠数据支撑。

3 结果分析

实验数据分析环境为 Windows11, Python 3.9, PyTorch 2.0.1。硬件配置为处理器为 Intel Core i9-13980HX, GPU 为 NVIDIA GeForce RTX 4060。最终,模型的设置参数 lr 设定为 0.000 5, $batch_size$ 设定为 32, $epochs$ 设定为 50, 优化器设定为 Adam。

3.1 周期匹配

研究使用 IMU (LPMS-B2) 和 EMG (w2) 两类传感器设备进行步态数据的采集。IMU 采样频率为 100 Hz, EMG 采样频率为 500 Hz。实验中, IMU 传感器安装在受试者右腿小腿前侧, EMG 传感器则安装在右腿大腿股直肌部位, 采集的数据分别为运动姿态信号和 sEMG 信号, 其中 IMU 传感器三轴方向定义如下: X 轴为右侧面至左侧面的方向, Y 轴为足面至头部的方向, Z 轴为背部至前躯干的方向。

运动姿态信号预处理流程如下: 1) 卡尔曼滤波。去除信号中高频噪声与低频偏差; 2) 提取 X 轴角度信息作为周期划分特征点; 3) 提取 X 轴极小值点, 作为步态周期的结束点及下一周期的起始点; 4) 各周期数据采用 Z -score 标准化处理; 5) 重采样至 $N_1 = 128$, 便于后续模型训练。图 4 所示为前进运动姿态划分周期情况。




图 4 前进运动姿态划分周期

Fig. 4 Forward motion posture division cycle

sEMG 信号预处理流程如下: 1) 4 阶带通滤波, w 为 20~240 Hz, 去除环境电噪及非目标肌群信号成分; 2) 取包络, 化为更清晰周期性波动的信号; 3) 周期划分。由摆动相最高点定位至 sEMG 包络的峰值, 结合生理节律, 设定 0.7~1.3 s 步态周期时长, 取包络峰值后多个局部极小值中最小值作为周期终点, 排除站立不稳等非理想动作的干扰; 4) 各周期数据采用归一化处理; 5) 重采样至 $N_2 = 512$, 便于后续模型训练。图 5 所示为前进 sEMG 包络后划分周期情况。

在多传感器信号融合中, 周期匹配对齐可以保障数据的有效整合与关联建模。针对采样频率差异、时延偏




图 5 前进 sEMG 包络后划分周期

Fig. 5 Dividing the cycle after the forward sEMG envelope

移与周期结构不一致等问题, 现有方法主要包括基于重采样的时间轴调整^[22]、基于时间戳与交叉相关的同步校正^[23], 及基于深度学习的特征级对齐^[24]。

研究中, 针对运动姿态信号与 sEMG 信号的采样频率与采集长度的差异问题以及数据处理中升降采样对分模型计算的影响问题, 应用周期数量引导的拓扑对齐方法进行周期对齐。通过统计两类信号的周期数, 并结合 sEMG 中肌肉激活与能量变化的关键点, 反向定位至姿态信号中波动显著的结构点, 完成周期映射与对齐, 有效避免信息损失与维度冗余, 保障后续融合建模的时序一致性。

图 6~9 所示为上楼与下楼任务中, 运动姿态信号与 sEMG 信号经周期划分后的对齐后的可视化结果。其中黄色区域为肌肉活动最特殊、姿态变化最剧烈的区段, 作为周期映射的关键锚点。通过周期对齐可见, 上楼任务中存在周期遗漏(图 6 中区域 A), 需根据 sEMG 节律补齐; 下楼任务检测到多余周期(图 8 中区域 A), 做剔除处理, C13、C14 误划的周期(图 9 中区域 B), 做合并处理。通过分析结果, 两类信号在对齐表现出一致的节律节拍结构, 下肢动作运动曲线变化与肌纤维激活行为之间的时间时域映射关系良好, 无需修改原始采样结构的前提下完成跨模态信号周期同步与拓扑性对齐, 为特征维度映射与多流融合建模提供统一时序基础。




图 6 上楼运动姿态信号划分周期

Fig. 6 Stair climbing motion gesture signal division cycle

3.2 准确率与分类可视化结果

为了全面评估模型在步态任务中的表现, 采用混淆




图 7 上楼 sEMG 包络后划分周期

Fig. 7 Stair ascent sEMG envelope and cycle segmentation




图 8 下楼运动姿态信号划分周期

Fig. 8 Stair descent sEMG envelope and cycle segmentation




图 9 下楼 sEMG 包络后划分周期

Fig. 9 Stair descent sEMG envelope and cycle segmentation

图 10 所示为基线模型分类情况、图 11 所示为结合频域和时域与多数据流神经网络模型下的结果,模型在前进、后退、转弯 3 类边界模糊动作中具备较强判别力,误判率显著下降。




图 10 运动姿态下基线模型可视化

Fig. 10 Visualization of the baseline model under motion posture




图 11 融合 3 类特征可视化

Fig. 11 Visualization of the fusion of three types of features

3.3 消融实验分析

通过不同的消融实验来分析每个关键模块的贡献,评估所提出的多数据流神经网络模型下的步态识别方法的有效性。实验从多模态融合的角度出发,系统考察了不同特征组合对模型性能的影响。如表 1 所示,给出了包括基线模型、sEMG 原始包络信号、sEMG 信号频域下 4 种倍频程和时域的直方图共 11 种特征方法的实验结果。

表 1 不同实验下分类准确率

Table 1 Classification accuracy under different conditions

实验	运动姿态	时域	频域	前进	后退	上楼	下楼	转弯	平均/%
A	✓	-	-	0.82	0.89	0.92	1.00	0.72	87.0
B	✓	-	-	0.84	0.92	0.97	0.98	0.90	92.2(↑5.2)
C	✓	-	✓	0.84	0.88	0.96	0.98	0.81	89.4(↑2.4)
D	✓	-	✓	0.95	0.88	0.97	0.96	0.75	90.2(↑3.2)
E	✓	-	✓	0.90	0.88	0.95	0.98	0.83	90.8(↑3.8)
F	✓	-	✓	0.77	0.88	0.95	0.98	0.87	89.0(↑2.0)
G	✓	✓	-	0.91	0.88	0.96	0.96	0.87	91.6(↑4.6)
H	✓	✓	✓	0.90	0.95	0.95	0.95	0.96	94.2(↑7.2)
I	✓	✓	✓	0.90	0.93	0.95	0.94	0.80	90.4(↑3.4)
J	✓	✓	✓	0.88	0.90	0.92	0.95	0.87	90.4(↑3.4)
K	✓	✓	✓	0.96	0.91	0.92	0.96	0.72	89.4(↑2.4)

其中实验 A~K 分别是 5 类不同实验,实验 A 为 3 类运动姿态信号作为基线模型;实验 B 为基线模型结合 sEMG 原始包络信号后验证肌电信号与运动姿态信号的互补性与实验方案的可行性;实验 C~F 分别为基线模型结合 sEMG 的 1/3、1/12、1/24、1/48 这 4 种倍频程下的频域情况;实验 G 验证了时域的直方图情况对于运动姿态信号的互补性情况;实验 H~K 为基线模型结合 4 种频域与时域情况下的最终模型,实验结果表明,本文提出的方法在识别率上均有一定的提升。

3.4 小结

从实验结果来看,基线模型在整体分类精度上表现尚可,但在前进、后退与转弯等动态任务之间存在明显混淆,尤其是在需快速姿态变换或方向调整的情境中,准确率显著下降。这表明单一运动姿态信号在区分某些边界模糊步态方面存在信息瓶颈,难以全面反映受试者的复杂运动模式。通过引入 sEMG 包络信号并构建双流网络后,性能得到明显提升,特别在转弯等任务中准确率显著上升,验证了肌电信号对位姿特征的有效补充。sEMG 反映下肢肌肉群的神经激活状态,提供了运动姿态难以捕捉的运动控制信息,实现了跨模态的互补增强。由于原始 sEMG 包络信号维度高、波动性强,模型在训练过程中计算开销增加,影响收敛效率和部署性能。进一步地通过对 sEMG 频域信号进行倍频程特征提取,模型在保证有效信息表达的同时大幅降低了数据冗余。其中 1/24 倍频程的频域划分在多类任务上表现稳定,兼顾分类精度与模型复杂度,体现了较强的实用潜力。相比之下,sEMG 时域直方图特征结构简洁、维度稳定,能够捕捉周期内部的肌肉激活模式变化,显著改善了前进、后退等任务之间的误判情况,说明该类统计特征对运动状态具有良好的判别能力。最终构建的多数据流神经网络模型,在同时引入 sEMG 的时域与频域特征基础上,有效整合了序列型和非序列型信号,展现出在 5 类任务中的最优性能。该结构充分利用了多模态数据间的互补性,在准确率、稳定性和泛化能力等方面均优于其他模型设置,特别是在解决易混步态中效果显著,在前进、后退和转弯的准确率上分别提升了 8%、6% 与 24%,显著改善了由动作边界模糊带来的误判问题,整体平均准确率提升了 7.2%。研究结果进一步验证了多模态融合在步态识别领域的研究价值,并为后续模型轻量化与部署优化提供了理论基础与实践依据。

4 结 论

本文提出了一种基于运动姿态和 sEMG 信号融合的方法,利用多数据流神经网络模型结构,解决了步态识别中不断变换步态任务中前进、后退和转弯误判的问题,达

到了较高的识别精度。在数据处理方面,对 sEMG 信号进行了针对性的处理优化,提出了一种基于包络特征的预处理与周期划分策略,有效提升了信号分段的准确性与周期对齐的一致性。通过在特征选择、周期匹配及多流建模方面的系统设计,最终实现了 5 类步态任务的高精度识别,显著降低了关键任务之间的误判率。本文在多模态信号融合建模与步态周期对齐机制设计方面具有一定的理论价值,为后续多源异构时序信号的高效表示与联合建模提供了新思路;同时在轻量级可部署的人体运动识别系统构建方面具备较强的应用潜力,为智能穿戴、运动康复、行为监测等领域的实际需求提供了方法支持。未来的研究会进一步优化该模型的计算效率,以适应实时步态监测和低功耗设备的需求,同时探索其在上坡、下坡、跑步等更广泛运动任务中的应用潜力。

参考文献

- [1] MUNUSAMY V, SENTHILKUMAR S. Emerging trends in gait recognition based on deep learning: A survey[J]. PeerJ Computer Science, 2024, 10: e2158.
- [2] 高毅,何森. 密集遮挡条件下的步态识别[J]. 光学精密工程, 2023, 31(2): 263-276.
GAO Y, HE M. Gait recognition under dense occlusion conditions[J]. Optics and Precision Engineering, 2023, 31(2): 263-276.
- [3] 付明凯,王少红,马超. 基于 DenseNet 模型的步态相位识别研究[J]. 电子测量技术, 2025, 48(1): 119-128.
FU M K, WANG SH H, MA CH. Research on gait phase recognition based on DenseNet model [J]. Electronic Measurement Technology, 2025, 48(1): 119-128.
- [4] LI J, WANG Q. Multi-modal bioelectrical signal fusion analysis based on different acquisition devices and scene settings: Overview, challenges, and novel orientation [J]. Information Fusion, 2022, 79: 229-247.
- [5] 周丙涛,陈世强,程宇阳,等. 基于足底压力传感器与深度学习的生物身份识别[J]. 仪器仪表学报, 2021, 42(7): 108-115.
ZHOU B T, CHEN SH Q, CHENG Y Y, et al. Biometric identification based on plantar pressure sensor and deep learning[J]. Chinese Journal of Scientific Instrument, 2021, 42(7): 108-115.
- [6] CAI S, CHEN D, FAN B, et al. Gait phases recognition based on lower limb sEMG signals using LDA-PSO-LSTM algorithm[J]. Biomedical Signal Processing and Control, 2023, 80: 104272.
- [7] LI M, MA CH, WANG SH H. Research on gait

- recognition by using 1DCNN based on lower limb kinematic posture data [C]. 10th International Symposium on Test Automation & Instrumentation, 2024.
- [8] 黄灶荣, 王春宝, 韦建军, 等. 脑卒中患者异常步态的识别分类技术[J]. 人工智能与机器人研究, 2023, 12(2): 84-96.
- HUANG Z R, WANG CH B, WEI J J, et al. Recognition and classification technology of abnormal gait in stroke patients [J]. Artificial Intelligence and Robotics Research, 2023, 12(2): 84-96.
- [9] 苏鸿, 马超, 苏鹏, 等. 基于 XGBoost 的下肢步态相位识别研究[J]. 电子测量与仪器学报, 2023, 37(3): 95-101.
- SU H, MA CH, SU P, et al. Research on lower limb gait phase recognition based on XGBoost[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 95-101.
- [10] ZHANG M, LIU D, WANG Q, et al. Gait pattern recognition based on plantar pressure signals and acceleration signals [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-15.
- [11] 汪步云, 缪龙, 吴臣, 等. 肌电和足压信息融合的外骨骼步态识别[J]. 兵器装备工程学报, 2024, 45(1): 278-287.
- WANG B Y, MIAO L, WU CH, et al. Exoskeleton gait recognition based on electromyography and plantar pressure information fusion [J]. Journal of Ordnance Equipment Engineering, 2024, 45(1): 278-287.
- [12] 张晓东. 基于足底压力和姿态信息融合的人体步态识别研究[D]. 天津: 天津理工大学, 2021.
- ZHANG X D. Research on human gait recognition based on fusion of plantar pressure and posture information [D]. Tianjin: Tianjin University of Technology, 2021.
- [13] 吴平平. 基于股直肌表面肌电和加速度信息融合的步态识别方法[D]. 合肥: 合肥工业大学, 2019.
- WU P P. Gait recognition method based on fusion of rectus femoris surface electromyography and acceleration information [D]. Hefei: Hefei University of Technology, 2019.
- [14] 高经纬, 马超, 姚杰, 等. 基于机器学习的人体步态检测智能识别算法研究[J]. 电子测量与仪器学报, 2021, 35(3): 49-55.
- GAO J W, MA CH, YAO J, et al. Research on intelligent recognition algorithm for human gait detection based on machine learning [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(3): 49-55.
- [15] HUANG Y, DU C, XUE Z, et al. What makes multi-modal learning better than single (provably) [J]. Advances in Neural Information Processing Systems, 2021, 34: 10944-10956.
- [16] 何强, 王学涛, 李欣, 等. 基于多模态特征和多分类器融合的前列腺癌放疗中直肠并发症预测模型[J]. 南方医科大学学报, 2019, 39(8): 972-979.
- HE Q, WANG X T, LI X, et al. Prediction model of rectal complications in prostate cancer radiotherapy based on multi-modal features and multi-classifier fusion [J]. Journal of Southern Medical University, 2019, 39(8): 972-979.
- [17] 辛奕辰, 李时冲, 陈斌, 等. 融合图信息瓶颈与 Transformer 的时序知识图谱推理方法[J]. 计算机科学, 2026, 53(4): 393-405.
- XIN Y CH, LI SH CH, CHEN B, et al. Temporal knowledge graph reasoning method combining graph information bottleneck and Transformer [J]. Computer Science, 2026, 53(4): 393-405.
- [18] SIMONYAN K, ZISSERMAN A. Two-stream convolutional networks for action recognition in videos [J]. ArXiv preprint arXiv:1406.2199, 2014.
- [19] FEICHTENHOFER C, PINZ A, ZISSERMAN A. Convolutional two-stream network fusion for video action recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1933-1941.
- [20] LI M D, YU C, WANG X. Skeleton-based action recognition with a triple-stream graph convolutional network [C]. 4th International Conference on Electronic Information Technology and Computer Engineering, 2020: 524-528.
- [21] XIA L, WEN X. Multi-stream network with key frame sampling for human action recognition [J]. Journal of Supercomputing, 2024, 80(9): 11958-11988.
- [22] 李广盛, 郑建立, 车霞静. 降低数据稀疏性的多维时序序列时间戳对齐方法[J]. 智能计算机与应用, 2022, 12(4): 135-139.
- LI G SH, ZHENG J L, CHE X J. Timestamp alignment method for multi-dimensional time series to reduce data sparsity [J]. Intelligent Computer and Applications, 2022, 12(4): 135-139.
- [23] RHUDY M. Time alignment techniques for experimental

sensor data [J]. International Journal of Computer Science & Engineering Survey, 2014, 5(2): 1-14.

[24] SCHÜTZ N, BOTROS A, SINGLE M, et al. Deep canonical correlation alignment for sensor signals [J]. ArXiv preprint arXiv:2106.03637, 2021.

作者简介



李沐, 2020 年于石家庄铁道大学获得学士学位, 现为北京信息科技大学现代测控技术教育部重点实验室研究生, 主要研究方向为步态识别与应用。

E-mail: limu2023@126.com

Li Mu received his B. Sc. degree from Shijiazhuang Tiedao University, Shijiazhuang in 2020. He is now a M. Sc. candidate at Key Laboratory of Modern Measurement and Control Technology, Ministry of Education, Beijing Information Science and Technology University. His main research interests include

gait recognition and its applications.



E-mail: mach2006@126.com

马超 (通信作者), 2003 年于沈阳航空工业学院获得学士学位, 2009 年于北京理工大学获得博士学位, 现为北京信息科技大学现代测控技术教育部重点实验室副研究员, 主要研究方向为机械系统动力学与生物力学。

Ma Chao (Corresponding author) received his B. Sc. degree from Shenyang Institute of Aeronautical Engineering in 2003, and Ph. D. degree from Beijing Institute of Technology in 2009. He is now an associate researcher at Key Laboratory of Modern Measurement and Control Technology, Ministry of Education, Beijing Information Science and Technology University. His main research interests include mechanical system dynamics and mechanical system fault diagnosis.