

DOI: 10.13382/j.jemi.B2508557

# 融合周期自适应机制与知识蒸馏的步态识别

王梦迪<sup>1</sup> 马超<sup>1,2</sup> 王少红<sup>1,2</sup> 李沐<sup>1</sup> 徐浩文<sup>1</sup> 张海洋<sup>1</sup>

(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)

**摘要:** 为实现多用户、多节奏及多步态类型下的步态实时识别,提出一种融合周期自适应机制与知识蒸馏的步态识别方法。该方法综合考虑模型的识别精度与实时性,旨在提升下肢外骨骼系统在动态复杂环境下的适应能力。首先,设计基于周期谱图分析的自适应滑动窗口机制,根据信号的周期性动态调整窗口长度,以精准适应不同用户及动作节奏变化;其次,教师模型采用图神经网络(GNN)充分挖掘多通道IMU数据中的时空关系,将多层感知机(MLP)模型作为学生模型,通过知识蒸馏方法实现知识迁移。实验采用5类步态动作数据进行对比验证,在相同数据条件下,自适应滑动窗口方案将整体分类准确率由91.6%提升至94.2%,提高了2.6%;通过结合真实标签与教师模型的软标签,优化蒸馏损失函数参数,优化学生模型学习教师模型所蕴含的丰富特征和信息,其准确率提升至1.94%。同时,学生模型的平均单窗口识别时间由教师模型的17.4 ms缩短至4.9 ms,实时响应能力显著增强。实验结果表明,该方法在多用户、多节奏及多类型步态下均表现出良好的识别稳定性和泛化能力,兼具高精度与低延迟,具有良好的实用性和部署价值,适用于下肢外骨骼等对实时性和识别准确性要求较高的场景。

**关键词:** 步态实时识别;周期自适应机制;图神经网络(GNN);知识蒸馏

**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 fusion of periodic adaptive mechanism and knowledge distillation

Wang Mengdi<sup>1</sup> Ma Chao<sup>1,2</sup> Wang Shaohong<sup>1,2</sup> Li Mu<sup>1</sup> Xu Haowen<sup>1</sup> Zhang Haiyang<sup>1</sup>

(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)

**Abstract:** To achieve real-time gait recognition under multi-user, multi-cadence, and multi-gait-type conditions, a gait recognition method integrating a cycle-adaptive mechanism and knowledge distillation is proposed. This method comprehensively considers both recognition accuracy and real-time performance, aiming to enhance the adaptability of lower-limb exoskeleton systems in dynamic and complex environments. First, a cycle-adaptive sliding window mechanism based on spectrum analysis is designed to dynamically adjust the window length according to the signal's periodicity, precisely adapting to variations in users and gait cadences. Then, a graph neural network (GNN) is used as the teacher model to fully extract the spatiotemporal relationships in multi-channel IMU data, and a multi-layer perceptron (MLP) model is used as the student model. Knowledge transfer is achieved through knowledge distillation. Experiments were conducted using five types of gait data for comparison and validation. Under the same data conditions, the adaptive sliding window scheme improved the overall classification accuracy from 91.6% to 94.2%, an increase of 2.6%. By combining hard labels with soft labels from the teacher model and optimizing the distillation loss function parameters, the student model learned the rich features and information from the teacher model, improving accuracy by 1.94%. Meanwhile, the average recognition time per window for the student model was reduced from 17.4 ms (teacher model) to 4.9 ms, significantly enhancing real-time responsiveness. Experimental results show that the method demonstrates good recognition stability and generalization across multiple users, cadences, and gait types, combining high accuracy and low latency, with strong practicality and deployment value. It is suitable for scenarios such as lower-limb exoskeletons that require high real-time performance and recognition accuracy.

**Keywords:** real-time recognition; cycle-adaptive mechanism; graph neural network (GNN); knowledge distillation

## 0 引言

全球人口老龄化进程加速导致由运动系统损伤、脑血管疾病及脊髓损伤等引发的下肢功能障碍患者数量显著上升,对康复辅助技术提出了更高要求。下肢外骨骼机器人作为一种新兴的智能辅助设备,在康复训练、残疾人日常行走以及增强人体运动能力方面展现出巨大的应用前景。人体运动意图识别作为外骨骼系统智能控制的核心环节,直接决定其对用户动作的响应精度与控制流畅性<sup>[1]</sup>。目前意图识别方法主要包括基于生物力学信号<sup>[2]</sup>、生物电信号<sup>[3-4]</sup>及多模态融合信号<sup>[5-6]</sup>的方法,相关研究在步态检测与识别方面已取得一定成果。例如,苏鸿等<sup>[7]</sup>针对下肢外骨骼应用中的关键问题,开展了基于单个IMU的步态相位识别研究;Zhu等<sup>[8]</sup>利用加速度计和陀螺仪获取步态数据,进一步结合人机耦合力矩优化外骨骼控制策略;Guo等<sup>[9]</sup>基于EEG脑电信号分析步态过程中动态的皮层活动,提出了全步态周期内的EEG测量方法。此外,步态识别中分类模型的选择对整体系统的精度与鲁棒性具有重要影响。传统机器学习方法<sup>[10]</sup>在步态识别中发挥了重要作用,尤其在特征提取与分类策略方面展现出出色性能。近年来,研究者广泛引入深度学习技术,如卷积神经网络(CNN)<sup>[11]</sup>、长短时记忆网络(LSTM)<sup>[12]</sup>、图神经网络(graph neural network, GNN)<sup>[13]</sup>以及Transformer<sup>[14]</sup>等,显著提升了对复杂动作模式的识别精度。

现有研究在实时步态识别方面仍面临两方面挑战:1)实时运动意图识别常依赖多模态传感器采集时频域特征,具有较高复杂性和滞后性,同时由于不同用户及不同运动状态特征差异明显,使其稳定性不足,难以满足实时识别的需求;2)当前多数识别模型在准确率与实时性之间难以兼顾,简单分类器计算开销虽小,却难以刻画复杂步态特征,而深度模型虽具更强建模能力,却因计算负担过重而难以满足高精度控制的实时响应需求。

针对上述问题,本研究通过以下方向提升实时步态识别的性能:1)通过自适应机制实现对不同用户、多种运动节奏及多样步态模式的适应,从而提升特征表达的完整性与识别稳定性;2)通过知识迁移策略,将复杂模型中学习到的多通道步态特征关系迁移至轻量级模型,以兼顾识别精度与计算效率,满足实时识别需求。

## 1 研究方法

### 1.1 滑动窗口自适应策略

本文提出基于信号归一化与周期谱分析的滑动窗口自适应策略。首先对原始信号进行归一化,消除幅值差

异;然后通过周期谱估计主周期长度,动态调整滑动窗口大小,确保每个窗口完整覆盖步态周期,在此基础上,结合归一化信号和主周期长度,动态计算当前最优滑动窗口长度,实现实时更新,从而提升特征提取的完整性和识别精度,有效适应个体差异和动作状态变化。

#### 1) 滑动窗口参数对识别准确率的影响

窗口是指每次提取特征时使用的连续帧数,窗口过小可能截断步态周期,影响分类准确率;窗口过大会增加系统延迟,降低实时性。步长表示每次窗口移动的距离,步长小可以提高识别频率,但计算量大;步长大则计算快,但可能漏掉重要信息。本文通过实验分析滑动窗口宽度对动态距离估计误差的影响,确定适合的参数设置<sup>[15]</sup>。在窗口长度(1~200帧)和滑动步长(1~70帧)范围展开分析,评估不同参数对分类精度和延迟的影响。图1为不同窗口大小下的准确率变化,图2为步长对准确率的影响。




图1 窗口大小与准确率之间的关系

Fig. 1 Relationship between window size and accuracy




图2 步长与准确率之间的关系

Fig. 2 Relationship between step size and accuracy

#### 2) 数据归一化消除幅值差异

受试者因身高、体重等体型差异,即便执行相同动作,传感器信号仍存在明显差异。图3为两名受试者在相同动作下的信号对比。

假设原始信号序列为 $\mathbf{x} = [x_1, x_2, \dots, x_N]$ ,其归一化后的信号 $\mathbf{x}' = [x'_1, x'_2, \dots, x'_M]$ 通过线性映射计算得到:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$




图 3 两名受试者在相同动作下的角加速度对比  
Fig. 3 Comparison of angular acceleration between two subjects under the same action

如图 4 所示,经过归一化处理各受试者的信号幅值被缩放至  $[0, 1]$ ,有助于统一尺度处理,提升模型在不同个体间的稳定性。




图 4 归一化处理后不同受试者相同动作下角加速度对比  
Fig. 4 Comparison of angular acceleration between subjects performing the same action after normalization

同一被试者中,不同情况下人体的步频可能会有显著波动,例如走路速度变化、疲劳状态或环境影响等,也会导致步态周期长度  $\tau_p$  出现变化。如图 5 所示,灰色曲线为同一被试者在不同步频条件下的原始步态信号。通过归一化处理,信号由灰色调整为蓝色曲线,归一化后的数据在尺度和形态上更加一致,有助于提高后续识别模型的鲁棒性和泛化能力。




图 5 同一受试者不同步频下传感器数据对比  
Fig. 5 Comparison of sensor data at different cadences for the same subject

### 3) 周期谱图法确定主周期长度

为确保滑动窗口完整覆盖步态周期,本文采用周期

谱分析估算主周期长度,并以功率谱分析辅助验证。功率谱<sup>[16]</sup>反映信号在各频率上的能量分布,通过对带通滤波后的信号进行傅里叶变换提取主频率,其倒数用于周期估计。图 6 为前进步态的功率谱分析过程;周期谱分析则在计算功率谱后取对数,再执行逆傅里叶变换,得到周期谱图,并从中提取主周期对应的峰值位置作为周期估计,如图 7 所示。通过对比两种方法提取的周期长度,为滑动窗口提供更合理的参数依据。该周期时间被用于设定滑动窗口的长度,实现对不同行为模式和个体差异的自适应适配。




图 6 前进步态信号的功率谱图  
Fig. 6 Power spectrum of the forward gait signal




图 7 前进步态信号的周期谱图  
Fig. 7 Cepstrum of the forward gait signal

### 4) 动态窗口更新策略

结合归一化信号和主周期长度  $\tau_p$ ,动态计算当前最优滑动窗口长度  $W$ 。

$$W = \partial \tau_p + \beta (1 - |x'_{rms}|) \quad (2)$$

式中:  $\tau_p$  为周期谱分析确定的主周期长度;  $x'_{rms}$  表示归一化信号的均方根值,用于反映信号的幅值稳定性;  $\partial$   $\beta$  为经验调整系数

当幅值较大且稳定时,  $|x'_{rms}|$  接近 1,补偿项接近 0,窗口大小主要由周期决定,不做额外延长;当幅值较小或不稳定时,  $|x'_{rms}|$  较小,补偿项较大,窗口长度适当增加,有助于累积更多信息,提高特征鲁棒性。

## 1.2 GNN

传统的序列建模方法(如 CNN、LSTM)在处理 IMU 步态数据时,通常忽略了不同身体部位之间的结构依赖关系,难以捕捉大腿、小腿与足部之间的动态协同模式<sup>[17]</sup>。为此,本文引入 GNN 对多部位传感器数据进行建模,以更好地挖掘下肢各部位之间的空间结构和信息传递路径。

本研究中使用 3 个 IMU 传感器,分别安装于大腿、小腿与足部,构建图结构  $G = (V, E)$ 。其中,节点集合为:

$$V = \{v_{\text{thigh}}, v_{\text{shank}}, v_{\text{foot}}\} \quad (3)$$

边集合  $E$  定义为表示人体连接关系的静态拓扑结构:

$$E = \{(v_{\text{thigh}}, v_{\text{shank}}), (v_{\text{shank}}, v_{\text{foot}})\} \quad (4)$$

每个节点的初始输入特征为对应传感器采集的时间序列信号。GNN 模型通过邻居节点之间的信息传递机制实现节点特征的更新<sup>[18]</sup>,基本传播公式为:

$$h_i^{(l+1)} = \sigma\left(\sum_{j \in N(i)} W^{(l)} h_j^{(l)} b^{(l)}\right) \quad (5)$$

多层 GNN 通过传递和融合大腿、小腿、足部 3 个传感器的运动特征,提取身体各部位的关联信息。图 8 中深蓝色点标出了这 3 个传感器的位置,代表了图神经网络中的节点。融合后的特征被送入分类器,用于识别步态动作。




图 8 节点图结构中传感器位置示意图

Fig. 8 Sensor placement diagram in the node graph structure

## 1.3 知识蒸馏

知识蒸馏是指将知识从繁琐的教师模型转移到轻量级的学生模型,相比于硬标签通过从软标签上的学习,学生可以获得更好的训练表现。根据迁移学习方法不同可以分为目标蒸馏<sup>[19]</sup>和基于特征蒸馏<sup>[20]</sup>的算法两个大方向。本次采用 GNN 作为教师模型,使用多层感知机(MLP)作为学生模型,通过学习 GNN 输出的概率分布

进行目标蒸馏,在降低模型计算复杂度的同时保持较高的识别精度<sup>[21]</sup>。

在目标蒸馏中,教师模型通过引入温度系数  $T$ ,对其输出的 logit 进行 Softmax 平滑处理,生成概率分布以指导学生模型训练。Softmax 函数的数学表达式如下:

$$q(Z_n)^{(k)} = \frac{\exp(Z_n^{(k)}/T)}{\sum_{m=1}^K \exp(Z_n^{(m)}/T)} \quad (6)$$

式中:  $q(Z_n)^{(k)}$  表示第  $k$  个类别的预测概率;  $Z_n^{(k)}$  表示类别  $k$  的原始输出;  $T$  为温度系数。

软损失是在  $T=t$  下,计算学生模型输出概率分布与教师模型软标签之间的交叉熵得到的,如式(7)所示,  $q_j^t$  表示学生模型在温度  $t$  下输出的概率分布。

$$L_{\text{soft}} = - \sum_{j=1}^N p_j^t \log q_j^t \quad (7)$$

硬标签是在温度系数  $T=1$ ,使用真实标签与学生模型输出概率分布之间的交叉熵损失,数学表达式如式(8)所示。

$$L_{\text{hard}} = - \sum_{j=1}^N c_j \log q_j^t \quad (8)$$

其中,  $c_j$  为真实标签。将软标签和硬标签进行结合,得到蒸馏损失函数,如式(9)所示。

$$L_{\text{KD}} = \alpha L_{\text{soft}} + (1 - \alpha) L_{\text{hard}} \quad (9)$$

其中,  $\alpha$  表示超参数。通过同时利用真实标签与软标签进行训练,学生模型能够在保持轻量结构的同时充分学习到教师模型的深层知识,实现更高效、准确的识别性能。

## 1.4 人体步态实时识别模型

首先,通过 IMU 传感器采集大腿、小腿和足部的多通道角速度数据,并划分为训练集、验证集和测试集。随后对原始数据进行极值滤波和归一化处理以提升数据质量。采用基于周期谱图的滑动窗口自适应策略,通过对傅里叶功率谱取对数并进行逆变换,提取周期谱并确定主周期长度,从而动态调整窗口大小,适应不同用户和步态节奏变化。接下来,训练 GNN 作为教师模型,分别通过 Softmax ( $T=1$ ) 和 Softmax ( $T=t$ ) 得到硬标签与软标签,构建知识蒸馏损失函数训练轻量级学生模型。在部署阶段,根据自适应窗口长度提取的实时信号片段被输入学生模型,实现高效准确的步态识别,流程如图 9 所示。

## 2 实时步态分析

### 2.1 试验流程

本研究采用维特智能 WT901C IMU 传感器,通过蓝牙模块进行传输<sup>[22]</sup>,采样频率为 50 Hz,分别部署于受试者右腿的大腿、小腿和足部,采集三轴加速度、角速度及角度等多维运动数据(位置示意图如图 10 所示)。实验

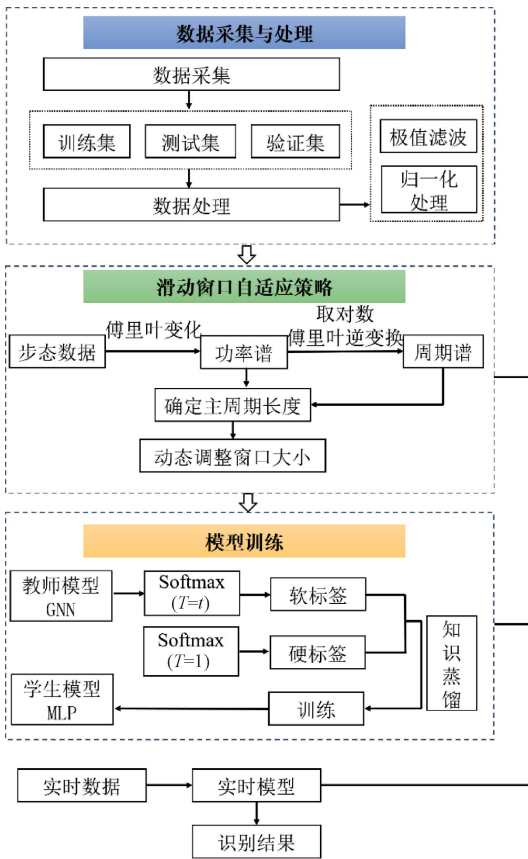


图 9 人体步态实时识别流程

Fig. 9 Real-time human gait recognition flowchart




图 10 设备在人体分布

Fig. 10 Device placement on the human body

选取了 8 位身体指标不同的人员进行实验测试,采集前进、后退、上楼、下楼和转弯 5 种步态数据(图 11),每种步态共采集超过 500 人次的完整步态周期。受试者具体身体指标如表 1 所示。

### 3 实验与结果分析

#### 3.1 基于周期谱图的自适应窗口方法及其实验验证

实验中,针对 MLP 模型比较了固定窗口大小与基于

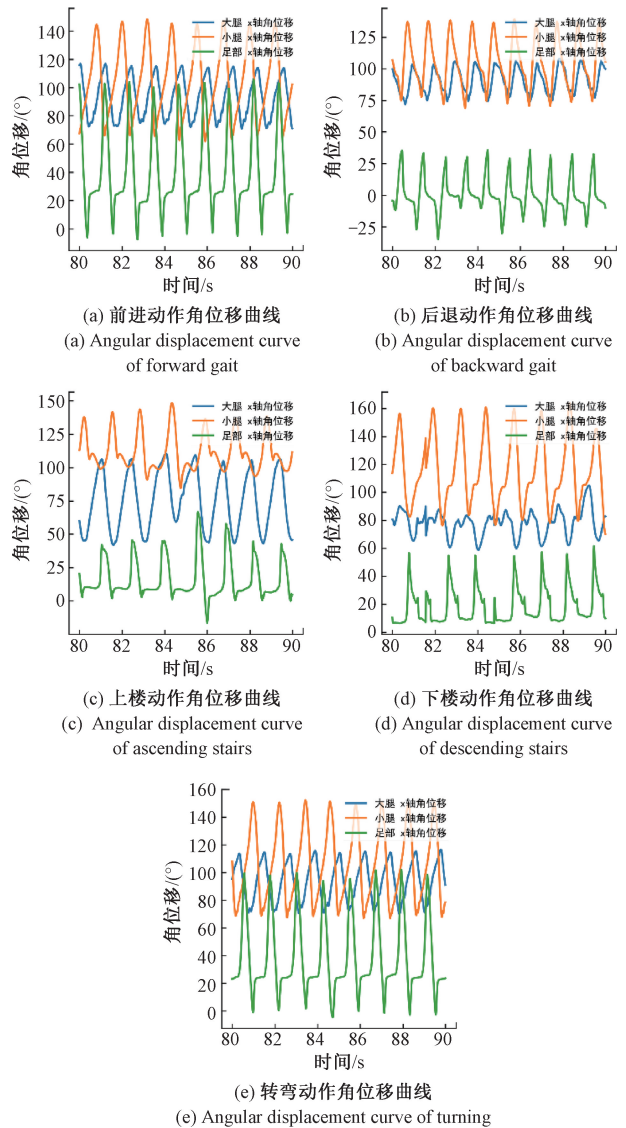


图 11 不同步态角位移曲线

Fig. 11 Angular displacement curves of different gait patterns

表 1 受试者身体指标信息  
Table 1 Demographic and physical information of participants

测试人员	身高/cm	性别	体重/kg	年龄
A	184	男	85	24
B	172	男	66	25
C	178	男	78	28
D	185	男	92	27
E	172	男	62	23
F	163	女	52	26
G	165	女	55	23
F	168	女	58	24

训练数据周期分析确定的自适应窗口大小两种方法在步态分类任务中的性能差异。如表 2 和 3 所示,自适应窗

口方法在大多数动作类别上均实现了更高的精确率 (precision) 和召回率 (recall), 从而使得整体 F1-score 显著提升。固定窗口方法的总体分类准确率为 91.6%, 而自适应窗口方法提升至 94.2%。这表明自适应窗口更准确地捕捉了不同步态动作的周期特征, 有效避免了固定窗口可能带来的信息丢失或冗余问题。

表 2 固定窗口策略下各动作类别的分类性能指标

Table 2 Classification performance metrics of each gait category under fixed window strategy

类别	准确率	召回率	F1 分数
前进	0.87	0.89	0.87
后退	0.90	0.98	0.95
上楼	0.96	0.89	0.91
下楼	0.93	0.8	0.88
转弯	0.92	0.90	0.89

表 3 自适应窗口策略下各动作类别的分类性能指标

Table 3 Classification performance metrics of each gait category under adaptive window strategy

类别	准确率	召回率	F1 分数
前进	0.92	0.91	0.90
后退	0.93	0.98	0.95
上楼	0.97	0.91	0.93
下楼	0.97	0.91	0.93
转弯	0.95	0.92	0.92

### 3.2 知识蒸馏的有效性分析

初步使用知识蒸馏训练后的模型的训练效果如图 12、13 所示。教师模型在训练集的平均准确率为 98.44%, 而学生模型初始在训练集的平均准确率为 94.2%。




图 12 各模型损失函数变化曲线

Fig. 12 Loss function curves of various models

为提升学生模型性能, 使用硬标签的交叉熵损失函数和软目标之间的交叉熵损失函数, 引导学生模型学习教师模型。最终学生模型的准确率成功提升至 96.14%。同时, 学生模型由于模型复杂程度较低, 其计算量和参数




图 13 各模型准确率对比曲线

Fig. 13 Comparison of accuracy curves for various models

量较教师模型减少, 所以平均单窗口识别时间从教师模型的 17.4 ms 降至 4.9 ms, 推理速度提升约 3.56 倍。

通过结果可以看出, 通过知识蒸馏训练后的模型能够充分利用复杂模型所蕴含的丰富特征和信息, 在保持了较小的计算量和参数量同时, 提升了准确率, 可以获得性能与效率的双重效果。

### 3.3 准确率分析与分类可视化

为进一步分析模型分类性能, 绘制了混淆矩阵与 t-SNE 可视化图, 如图 14、15 所示, 通过直观方式展示了不同动作类别之间的预测效果。结果表明, 多数类别之间的混淆较少, 仅“前进”与“转弯”之间存在一定程度的误判, 原因是动作在空间维度和角度特征上的具有一定的相似性, 在 t-SNE 可视化图, 不同动作类别形成了明显分离的聚类簇, 进一步验证了所提取的滑窗特征在 5 类动作间具有良好的判别能力, 能够有效支持后续的分类任务。




图 14 优化后学生模型的混淆矩阵

Fig. 14 Confusion matrix of the optimized student model

### 3.4 性能评估

本研究使用维特智能 WT901C 惯性测量单元 (IMU)

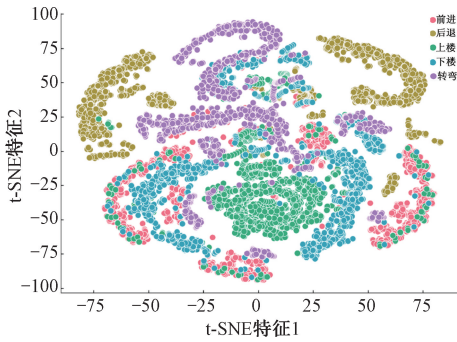


图 15 步态数据的 t-SNE 降维可视化  
Fig. 15 t-SNE visualization of gait data after dimensionality reduction

作为数据采集设备,采样频率设置为 50 Hz,实时记录人体在不同动作下的运动数据。实验场景包括一个具有 12 阶、每阶高 16 cm 的标准楼梯,用于模拟日常生活中的上楼和下楼行为。配备 NVIDIA GeForce RTX 4060 GPU(8 GB 显存),运行 Windows 10 操作系统,为数据采集与处理提供高效计算支持,实时性测试如图 16 所示。

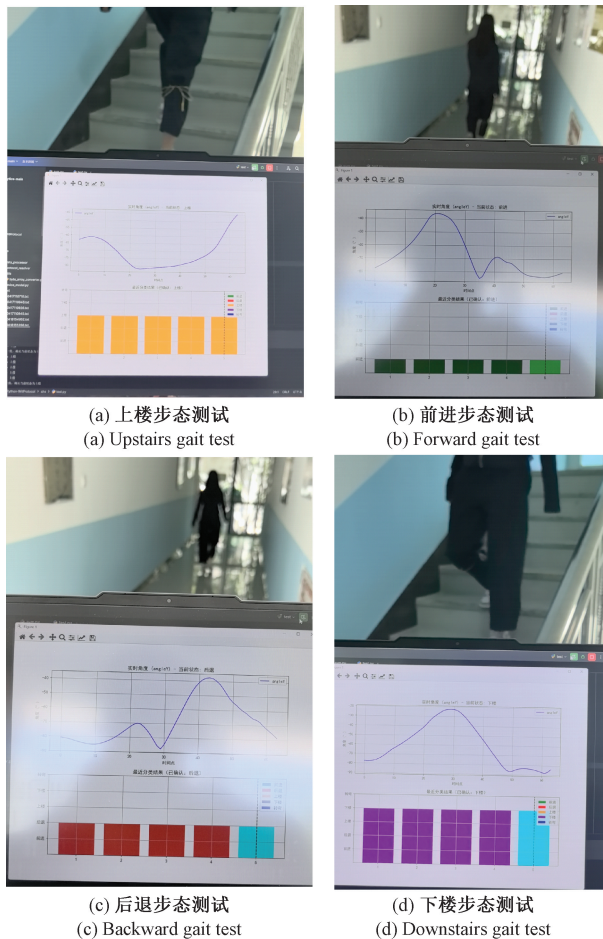


图 16 步态识别系统实时性分析测试  
Fig. 16 Real-time performance analysis of the gait recognition system

在实际测试过程中,发现前进和转弯的识别容易出现错误,原因在于动作特征相似。前进和转弯的动作在某些情况下具有相似的加速度或角速度模式,尤其是在转弯时步态的变化较小,这导致分类模型难以有效区分这两种动作。

### 4 结 论

本研究提出了一种结合周期自适应机制与知识蒸馏策略的实时步态识别方法,利用 IMU 传感器采集的人体步态数据,实现多种步态模式的高精度分类。设计了一种基于周期谱图分析的自适应滑动窗口策略,首先对数据进行极值滤波、归一化处理,之后根据周期谱图法估计主周期长度,动态调整窗口大小,以适应不同个体和不同步频条件下变化。为了提升动作分类模型的准确率和效率,首先在 MLP 模型上采用自适应策略代替固定窗口方法。在相同数据集上的实验结果表明,此改进提升了模型性能,分类准确率从 91.6% 提升到 94.2%,具有更高的准确率和召回率。随后,引入 GNN 作为教师模型,通过结合真实标签与软标签,将教师模型学习到的丰富特征和信息迁移给 MLP 学生模型,最终使 MLP 学生模型准确率提至 96.14%。实现学生模型在保持较小计算量和参数量同时,仍具有较高的精度。

在工程应用方面,本研究为下肢外骨骼机器人的智能控制提供了坚实的技术支持。步态识别系统结合自适应滑动窗口策略,能够动态调整窗口大小,适应不同个体的步态周期变化,从而具备较强的通用性和适应性,满足多样化人群的使用需求。该系统适用于康复医疗、运动辅助等多个领域,能够广泛应用于各种复杂环境。随着多传感器融合和算法优化的不断推进,基于 KD-GNN-MLP 的识别框架有望进一步增强系统的适用范围和稳定性,推动智能外骨骼技术的普及和发展。

### 参考文献

[ 1 ] 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 Y, TAN X, CHENG CH. Lower-limb motion recognition based on surface electromyography signals [J]. Mechanical & Electrical Engineering Technology, 2023, 52(9): 69-73, 151.

[ 2 ] LUO M, DONG X, YU H, et al. Lateral walking gait phase recognition for hip exoskeleton by denoising autoencoder-LSTM [ J ]. Computational and Structural Biotechnology Journal, 2025, 28: 50-62.

[ 3 ] 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.
- [ 4 ] ZENG D, QU C, MA T, et al. Research on a gait detection system and recognition algorithm for lower limb exoskeleton robot[J]. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 2021, 43(6): 298.
- [ 5 ] ZHAN H, KOU J, CAO Y, et al. Human gait phases recognition based on multi-source data fusion and BILSTM attention neural network [ J ]. *Measurement*, 2024, 238: 115396.
- [ 6 ] CHEN W, LI J, ZHU S, et al. Gait recognition for lower limb exoskeletons based on interactive information fusion [ J ]. *Applied Bionics and Biomechanics*, 2022, 2022(1): 9933018.
- [ 7 ] 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. Lower-limb gait phase recognition based on XGBoost [ J ]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37 ( 3 ): 95-101.
- [ 8 ] ZHU L, WANG Z, NING Z, et al. A novel motion intention recognition approach for soft exoskeleton via IMU[J]. *Electronics*, 2020, 9(12): 2176.
- [ 9 ] GUO X, ZHAO S, YU L, et al. Neural correlates of abnormal cortical gait control in Parkinson's disease: a whole-gait-cycle EEG study [ J ]. *IEEE Transactions on Biomedical Engineering*, 2023, 71(2): 400-409.
- [ 10 ] 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. Intelligent human gait detection and recognition algorithm based on machine learning [ J ]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(3): 49-55.
- [ 11 ] 许振齐, 朴燕, 康继元, 等. 融合 3D-CBAM 和跨时间尺度特征分析的步态识别方法 [ J ]. *电子测量与仪器学报*, 2025, 39(2): 32-40.
- XU ZH Q, PIAO Y, KANG J Y, et al. Gait recognition method based on 3D-CBAM and cross-time scale feature analysis [ J ]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(2): 32-40.
- [ 12 ] SHU T X. Sensory data prediction using spatiotemporal correlation and LSTM recurrent neural network [ J ]. *Instrumentation*, 2019, 6(3): 10-17.
- [ 13 ] WU B, CHEN W, LIU D, et al. MyoStep: Feature-based GNN model for estimating knee joint angles by fusing signals from sEMG and IMU [ J ]. *IEEE Sensors Journal*, 2025.
- [ 14 ] LE H, PHAM H. Learning to estimate critical gait parameters from single-view RGB videos with transformer-based attention network [ C ]. 2024 IEEE International Symposium on Biomedical Imaging ( ISBI ). IEEE, 2024: 1-5.
- [ 15 ] 罗清华, 焉晓贞, 彭宇, 等. 基于滑动窗口模式匹配的动态距离估计方法 [ J ]. *仪器仪表学报*, 2015, 36(3): 499-506.
- LUO Q H, YAN X ZH, PENG Y, et al. Dynamic distance estimation method based on sliding window pattern matching [ J ]. *Chinese Journal of Scientific Instrument*, 2015, 36(3): 499-506.
- [ 16 ] 何群, 邵丹丹, 王煜文, 等. 基于多特征卷积神经网络的运动想象脑电信号分析及意图识别 [ J ]. *仪器仪表学报*, 2020, 41(1): 138-146.
- HE Q, SHAO D D, WANG Y W, et al. Analysis and intention recognition of motor imagery EEG signals based on multi-feature convolutional neural network [ J ]. *Chinese Journal of Scientific Instrument*, 2020, 41(1): 138-146.
- [ 17 ] TIAN H, MA X, WU H, et al. Skeleton-based abnormal gait recognition with spatio-temporal attention enhanced gait-structural graph convolutional networks [ J ]. *Neurocomputing*, 2022, 473: 116-126.
- [ 18 ] QIN Z, LIU Y, JI P, et al. Fusing higher-order features in graph neural networks for skeleton-based action recognition [ J ]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 35(4): 4783-4797.
- [ 19 ] YANG C, AN Z, ZHOU H, et al. Online knowledge distillation via mutual contrastive learning for visual recognition [ J ]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(8): 10212-10227.
- [ 20 ] 宋涛, 张景涛, 李泂泂, 等. 知识增强的特征编辑重建蒸馏 [ J ]. *中国图象图形学报*, 2025, 30(1): 161-172.
- SONG T, ZHANG J T, LI W W, et al. Knowledge-enhanced feature editing and reconstruction distillation [ J ]. *Journal of Image and Graphics*, 2025, 30(1): 161-172.
- [ 21 ] 黄友文, 胡燕芳, 魏国庆. 融合知识蒸馏与迁移学习的小样本学习方法 [ J ]. *计算机应用与软件*, 2025, 42(4): 319-325, 334.
- HUANG Y W, HU Y F, WEI G Q. Few-shot learning method combining knowledge distillation and transfer learning [ J ]. *Computer Applications and Software*, 2025, 42(4): 319-325, 334.
- [ 22 ] 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.

## 作者简介



**王梦迪**, 2022 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研究生, 主要研究方向为机器学习、步态识别、康复医疗。

E-mail: 15530805819@ 163. com

**Wang Mengdi** received her B. Sc. degree from Shijiazhuang Tiedao University in 2022. She is now a M. Sc. candidate at Beijing Information Science and Technology University. Her main research interests include machine learning, gait recognition, and rehabilitation medicine.



**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副研究员, 主要研究方向为机械系统动力学与机械系统故障诊断。

E-mail: mach2006@ 126. com

**Ma Chao** (Corresponding author) received his B. Sc. degree from the Shenyang Institute of Aeronautical Engineering in 2003 and Ph. D. degree from the Beijing Institute of Technology in 2009. He is now an associate research fellow at Beijing Information Science and Technology University. His main research interests include mechanical dynamics and fault diagnosis of mechanical systems.