

基于足底动力相数据和小波变换自适应分解的 下肢意图识别方法

苏本跃^{1†}, 宗文杰^{1,2}, 刘文瑶^{1,2}, 盛敏³

(1. 铜陵学院 数学与计算机学院, 安徽 铜陵 244061; 2. 安庆师范大学 计算机与信息学院, 安徽 安庆 246133;
3. 安庆师范大学 数理学院, 安徽 安庆 246133)

摘要: 人体下肢运动的步态周期由支撑相和摆动相构成, 但是, 现有的人体运动步态意图识别通常对摆动相进行特征提取, 对于支撑相的研究较少, 且多仅限于离散触地状态, 往往忽略了支撑相的连续细节信息. 鉴于此, 提出一种足底动力相数据驱动的智能下肢假肢意图识别方法. 考虑到人体对于地形转换的适应性姿态调整始于支撑相末期的足底动力相, 其作为连接支撑相与摆动相的过渡阶段, 在运动过程中参与能量释放, 故所提出方法提取完整足底动力相数据, 并结合摆动相前期数据, 定义目标数据时间窗. 采用 haar 小波变换来表征支撑相中隐藏的非平稳信号特征, 并基于足底蹬地的能量变化来自适应地确定小波分解层数, 通过相应小波系数来构建特征向量, 并使用支持向量机进行分类. 实验结果表明: 该方法在自采集数据集的 5 种稳态模式下识别率可达到 99.21%, 在 13 种综合运动模式下的识别率为 97.65%, 较基准方法提升了 1.69% 和 2.53%, 利用足底动力相阶段的数据辅助意图识别任务, 能够提高模型的识别率和鲁棒性.

关键词: 支撑相; 足底动力相; 小波变换; 自适应分解层数; 下肢运动意图识别; 惯性传感器

中图分类号: TP391 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2024.1515

引用格式: 苏本跃, 宗文杰, 刘文瑶, 等. 基于足底动力相数据和小波变换自适应分解的下肢意图识别方法 [J]. 控制与决策, 2025, 40(10): 3005-3018.

Lower limb prosthesis intention recognition method based on powered plantarflexion phase data and wavelet transform adaptive decomposition

SU Ben-yue^{1†}, ZONG Wen-jie^{1,2}, LIU Wen-yao^{1,2}, SHENG Min³

(1. College of Mathematics and Computer Science, Tongling University, Tongling 244061, China; 2. College of Computer and Information, Anqing Normal University, Anqing 246133, China; 3. College of Mathematics and Physics, Anqing Normal University, Anqing 246133, China)

Abstract: The gait cycle of lower limb movement in the human body is composed of the stance phase and the swing phase. However, existing methods for recognizing the gait intention of human movement usually extract features from the swing phase, with less research on the stance phase, and most of them are limited to discrete ground contact states, ignoring the continuous detailed information of the stance phase. Therefore, this paper proposes an intelligent lower limb prosthesis intention recognition method driven by the powered plantarflexion phase data. Considering that the adaptive posture adjustment of the human body to terrain changes begins in the powered plantarflexion phase at the end of the stance phase, which serves as a transitional phase connecting the stance phase and the swing phase, and participates in energy release during movement, this method extracts complete powered plantarflexion phase data and combines it with the early swing phase data to define the target data time window. Haar wavelet transform is used to represent the hidden non-stationary signal features in the stance phase, and the number of wavelet decomposition layers is adaptively determined based on the energy change of plantar push-off. Feature vectors are constructed using the corresponding wavelet coefficients, and support vector machines are used for classification. Experimental results show that the recognition rate of the proposed method can reach 99.21% in five steady-state modes of the self-collected dataset and 97.65% in 13 comprehensive motion modes, which is 1.69% and 2.53% higher than the benchmark method,

收稿日期: 2024-12-31; 录用日期: 2025-05-09.

基金项目: 安徽省高校优秀科研创新团队项目 (2023AH010056); 铜陵学院联合培养研究生创新基金项目 (23tlcx01).

†通信作者. E-mail: subenyue@sohu.com.

respectively. Utilizing the data from the plantar power phase to assist the intention recognition task improves the recognition rate and robustness of the model.

Keywords: stance phase; powered plantarflexion phase; wavelet transform; number of adaptive decomposition layers; lower limb motion intention recognition; inertial sensor

0 引言

在我国各类残疾人总数超过 8000 万,且多数截肢手术是针对下肢进行的^[1].随着下肢截肢人数的不断增加,人们对于下肢假肢模型对不同地形下应用的泛化性要求也越来越高^[2].但是,目前市面上已有的大多数下肢假肢产品以被动式为主,其关节不具备动力辅助功能.这意味着现有的下肢假肢为残疾人提供了一定的帮助,但是,在提高行走效率和减少能量消耗方面,仍然存在改进的空间^[3-5].由此可见,智能动力下肢假肢仍然是研究的重点和热点.

在动力型下肢假肢的研究中,对信号类型的选择主要分为机械运动信号和生物电信号,而在一些应用场景下,机械运动信号相比于生物电信号可能具有更好的稳定性^[6].但是,在实际使用过程中也存在一些局限和不足:如机械信号反映了人在运动过程中或与外部环境发生交互时的运动学和力学信息,但是仍然存在一定的滞后性,且在实际假肢使用中,机械间隙、穿戴不对称等问题均会加剧机械信号的滞后性^[7].在传感器的选择上,机械传感器的应用较为广泛,其中包括惯性测量单元(IMU)、压力传感器等,因为它们能够提供必要的运动学信息,同时对人体的干扰最小^[8-9],鉴于机械运动信号较为稳定且传感器为非侵入性,本文选择单一类型的惯性传感器作为信号采集设备.

对于目标数据时间窗的构建,现有意图识别研究的数据区域集中在摆动相前期上.摆动相前期是腿部肌肉和关节运动状态发生鲜明变化的阶段,此阶段运动意图显著,且此阶段中截肢者的患侧还未接触下一个地形,利用这一时间窗进行意图识别可以实现快速响应并减少延迟,为后续假肢控制提供更多的调整时间.Su等^[10]将摆动相前期的IMU数据输入卷积神经网络,对13种运动模式的识别准确率可达到94.15%;盛敏等^[11]采集摆动相前期时序数据并解算膝关节角,对几何特征提取了最值斜率来弥补统计特征不稳定性,融合几何与物理特征,对13种运动模式识别率可达到96.92%;目前,对于支撑相的研究相对较少,Liu等^[12]利用加速度计、陀螺仪和压力传感器等多源传感器,选择整个支撑相数据,利用隐马尔可夫模型对15种运动模式的识别率达到了95.8%.考虑到对上一步态周期而言,支撑相不仅是物理动作上的延续,也是生物力学、神经控

制和能量变化上的连续和交互过程,因此,支撑相在下肢假肢意图识别中的关键作用值得深入研究.

现有对支撑相的研究集中在地面反作用力上,通过压力鞋垫等压力传感器的形式,记录地面反作用力并将其应用于步态相位检测^[13-15].基于地面反作用力的步态相位识别具有准确性高,可为其他复杂的步态相位识别算法提供参考的优点^[16-17].然而,压力鞋垫所采集的信号表现形式通常为离散信号,其未能充分表征在支撑相中连续的运动信号.值得强调的是,人体运动在本质上是一个连续的时间序列事件,想要更精准、全面地捕捉和表征支撑相中所含的连续运动信息,仅仅依靠离散的压力信号是不够的.因此,本文结合惯性传感器采集支撑相连续的运动学数据,实时记录加速度、角速度的实时连续机械信号,为构建准确且全面的步态模型提供必要的数据支撑.

下肢假肢意图识别的另一个关键问题在于特征的选择和提取.与动态变化突出的摆动相相比,支撑相的整体运动幅度较为平和,较难在时域提取到合适的特征.但是在支撑相末期的足底动力相阶段,下肢实现重心转移并推动身体前进,此相位频域特征差异较为明显.尤其是足底蹬地阶段所产生的地面反作用力会以局部非平稳信号的方式表现,为此,本文采用haar小波变换来表征支撑相中隐藏的非平稳信号特征,基于足底蹬地的能量变化进行多尺度分析,精准地突出和捕捉局部非平稳信号中的特征^[18].过去的研究通常将小波作为阈值去噪的工具^[19].Sheng等^[20]利用双密度双树复小波挖掘了步态瞬时转换信息,对13种运动模式识别率可达97.36%,但是其小波分解层数依赖人工经验设定.为减少人为干预,兼顾小波变换的准确度与效率,本文提出基于足底蹬地能量变化的小波变换自适应分解算法,针对不同动作间能量变化阈值对小波分解层数进行计算,自适应得到最优小波分解层数.

综上所述,本文的主要内容如下:1)对运动步态周期的支撑相部分进行生物力学分析,探究足底动力相的连续运动数据在下肢假肢运动意图识别系统中的重要性;2)针对本文定义的目标数据时间窗,利用小波变换挖掘此阶段的隐藏特征,并基于小波能量特征决策不同运动类型下的小波变换最优层数.

1 运动步态分析

1.1 步态周期划分

人体下肢运动具有一定规律性和周期性,据此可定义步态周期,且可将步态周期划分为不同的阶段.水平地面条件下的步态周期定义为从一只脚的后跟着地开始,终止于同侧脚的下次脚后跟着地.通常一个步态周期包括脚尖离地和脚跟触地两个事件,并由此分为支撑相和摆动相两个步态相位^[21],如图1所示.

在一个步态周期中,支撑相决定了人体行走的姿态,是人体行走步态控制的主要环节,根据美国麻

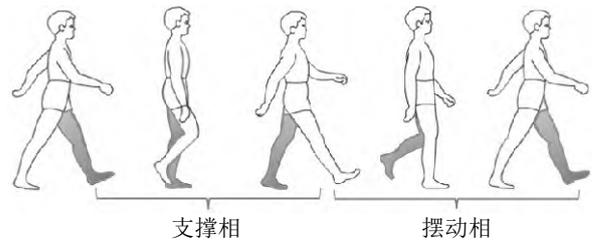


图1 步态周期示意图

省理工学院 Herr 等^[22]关于步态周期的研究可进一步将支撑相划分为3个子相:足底控制相(CP),约占7%;背屈控制相(CD),约占33%;足底动力相(PP),约占22%,如图2所示.

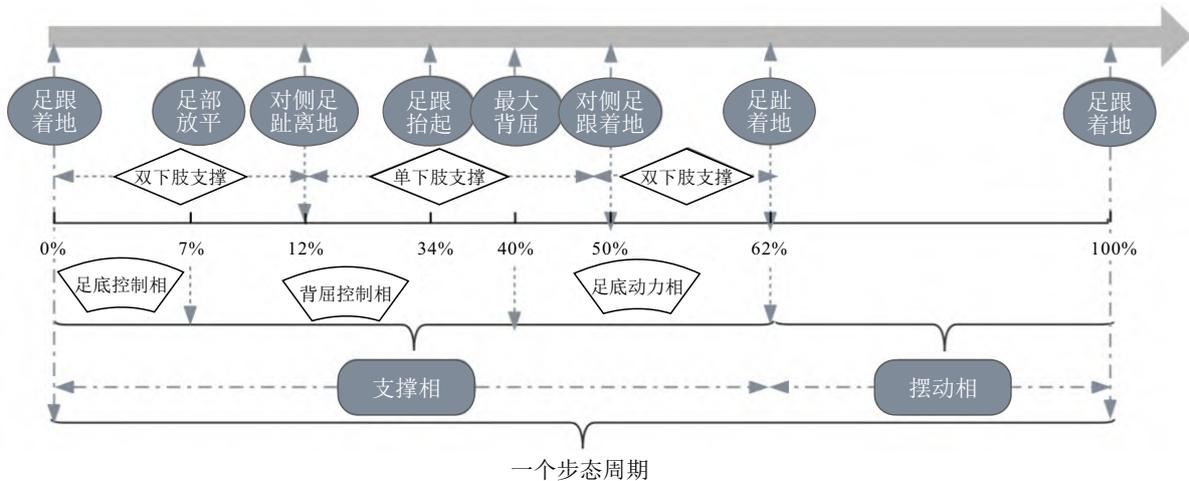


图2 单个步态周期的步态事件以及步态相位划分

在一个步态周期中,支撑相占比超过了一半以上的时间,其为人体提供了稳定性,确保人体在运动过程中不会摔倒,并协调双侧下肢的交替支撑和摆动,实现平稳地行走或奔跑.

在支撑相的前中期,足跟着地承担能量的吸收和缓冲,足部放平起到姿势调整和维持平衡的作用;而在支撑相末期,下肢为推动身体前进积蓄能量,对即将到来的摆动相做出姿态调整,以维持身体稳定,此阶段伴随有明显的动力学变化,如地面反作用力的变化、关节角度的连续调整等,因此,本文重点关注支撑相末期的足底动力相阶段.

1.2 运动模式划分

本文采用文献 [23] 中关于运动模式分类的框架,其中涵盖了5种在恒定地形下保持不变的稳态步态以及8种从一种初始运动状态过渡到不同地形下新运动状态的转换步态,如表1所示.每个动作重复10遍,直至所有的13种模式全部完成.

本文采用的惯性传感器如图3(a)所示.分别将IMU绑定在受试者健侧的大腿、小腿、脚踝处,与截肢者的患侧相比,健侧往往反映了截肢者的真实意

表1 13类运动模式

编号	运动模式	运动模式描述
1	行走-上楼	平地行走至上楼转换
2	行走-下楼	平地行走至下楼转换
3	行走-上坡	平地行走至上坡转换
4	行走-下坡	平地行走至下坡转换
5	上坡-行走	上坡到平地行走转换
6	下坡-行走	下坡到平地行走转换
7	上楼-行走	上楼到平地行走转换
8	下楼-行走	下楼到平地行走转换
9	行走	平地行走
10	上楼	稳步上台阶
11	下楼	稳步下台阶
12	上坡	稳步上坡
13	下坡	稳步下坡

图^[6,10,23]. IMU 安装位置和方向如图3(b)所示:虚线为截肢者患侧,实线为截肢者健侧.

2 方法

本文将转换步中健侧腿所采集的足底动力相与摆动相前期的IMU数据相结合,使用小波变换的时频信号处理方法,并根据小波变换后小波近似系数

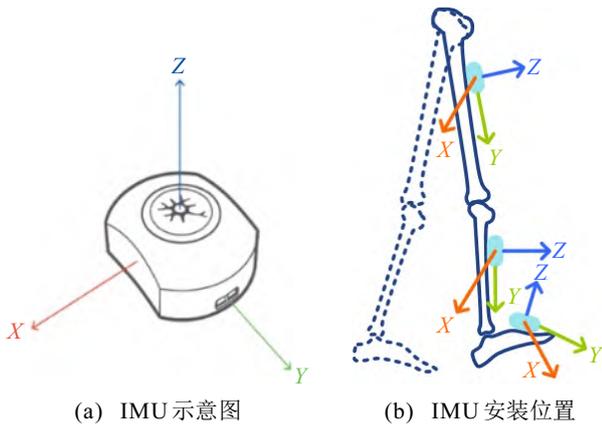


图3 惯性传感器

的能量变化差分来自适应决策最优小波分解层数,对转换阶段运动细节特征进行有效提取和分类识别,以完成对截肢者运动行为的实时预测,所提出算法框架如图4所示.

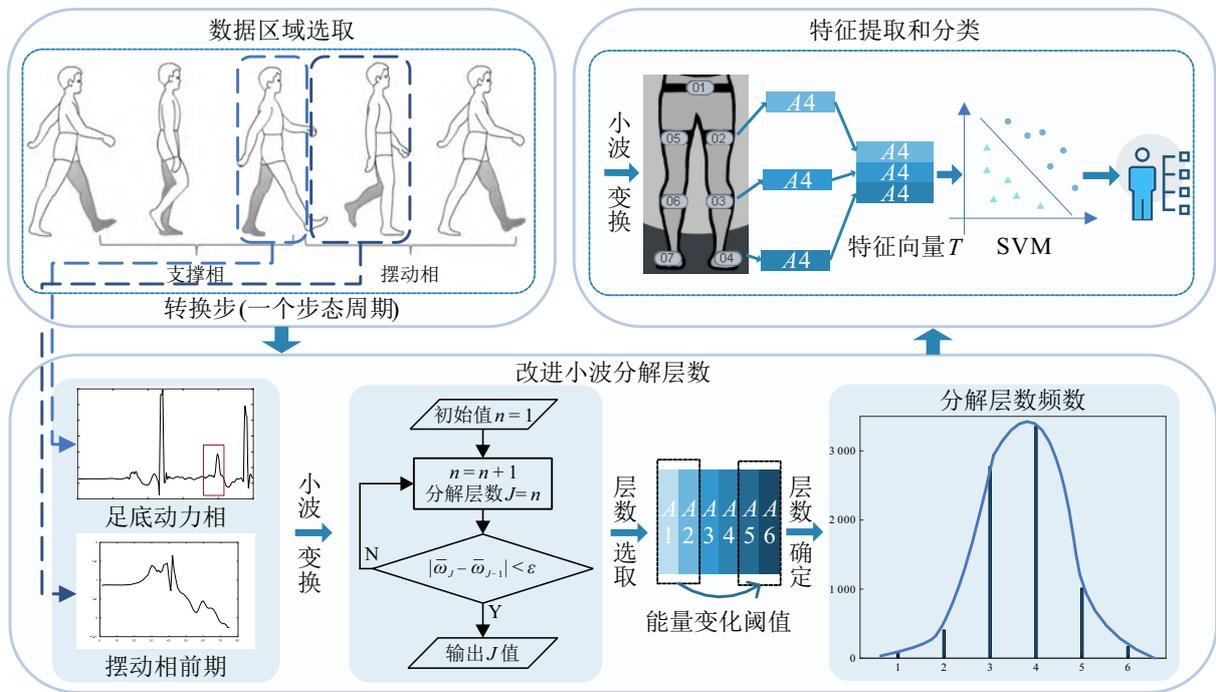


图4 本文意图识别算法框架

2.1.1 支撑相步态分析

在支撑相,截肢者为维持身体的平衡稳定,其身体内部复杂的生物力学机制发挥了重要作用,髌、膝、踝关节协同调整角度和力矩分配,骨骼与肌肉系统通过精密协作,体现出高度的生理协调性和动态互动^[25-26].支撑相步态相位划分如图5所示.其中:足底动力相作为连接支撑相与摆动相的过渡阶段,在运动过程中参与能量释放,在蹬地动作中不仅推动身体前进,还使得下肢在离地后获得向前和向上运动的加速度和角速度,这一初速度连同重力和惯性的作用,共同维持了摆动相的运动轨迹^[27].

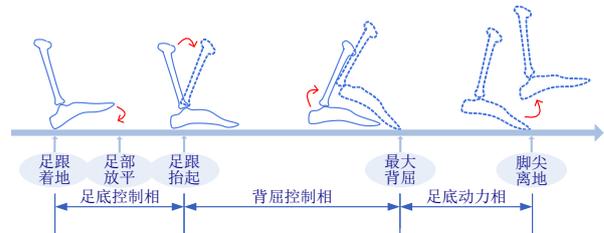


图5 支撑相步态相位划分示意图

在本节中,本文重点关注如何通过整合支撑相末期的足底动力相和摆动相前期的信号来预测未来的运动模式,并通过自适应小波变换提取特征,接下来的两节,将详细阐述和讨论这一过程的具体实施步骤和方法.

2.1 步态相位选择

意图识别在残疾人交互系统中扮演着核心角色.为了对即将到来的地形变化进行高效、及时地识别,定义目标数据时间窗显得尤为关键,其直接关系到意图识别系统反应速度与识别精度的平衡.摆动相因其动态变化相比于支撑相更为显著,被认为是预测后续运动走向的关键依据^[23-24].事实上,摆动相的摆腿动作不仅受到肌肉直接驱动,还显著地受到支撑相的影响.因此,本文在先前对摆动相研究的基础上,试图进一步挖掘支撑相关键信息.

能够更早地预见截肢者的运动意图。

2.1.2 足底动力相生物力学

足底动力相是支撑相的一个重要子相,其是指在一个步态周期中,当一只脚着地并支撑身体负重时,另一只脚脚掌开始离开地面的阶段。其中足底动力相主要包括推动和脱地两个关键动作:推动即人体通过足趾关节背伸来将身体向前推进,并储存能量在肌肉中,此动作过程犹如弹簧蓄能,通过此阶段足底蹬地力量大小的改变可以实现推动身体前进至不同的地形;脱地即人体脚掌由后跟滚动至前脚掌,实现重心转移离开地面的过程,此动作中下肢肌肉群协同释放储存的能量,且与地面反作用力的大小成正比。通过以上两个关键动作,人体能够实现持续的步行动作,并保持平稳地移动。

对于足底动力相的信息数据获取,除常见的方法,通过对下肢动力学数据以压力传感器直接采集,也可以间接通过运动学数据进行表征^[28]。根据牛顿第二定律,物体所受的净外力(F)与其产生的加速度(a)间存在显著比例关系。本文所绑定在2号(大腿)、3号(小腿)、4号(脚踝)处3个节点的传感器Z轴数据如图6所示。由图6可见:在地形转换期间,足底触地点前的足底动力相阶段,其加速度与较为稳定的足底控制相相比,出现了显著的加速度变化过程,这也揭示了足底动力相阶段的推动动作包含的能量变化以及地面反作用力大小能够通过惯性传感器所采集的加速度来表征。

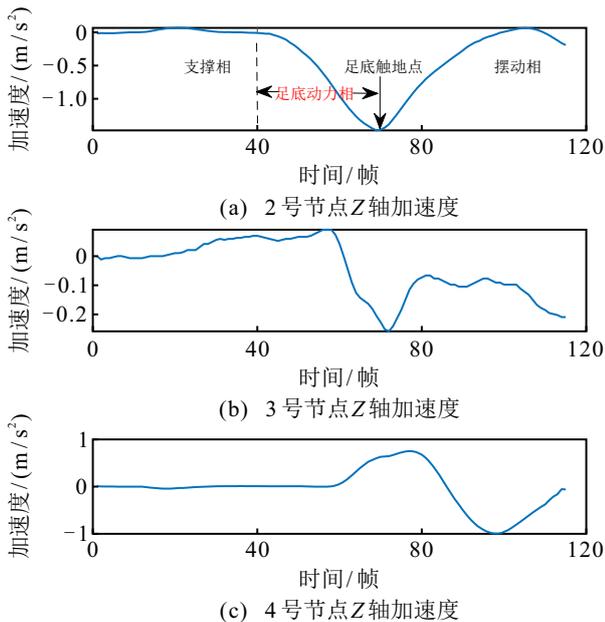


图6 足底动力相阶段的加速度变化

从实际应用场景考虑,对于可预见的地形变化,截肢者对自身步伐做出适应性调整始于支撑相,而

并非传统意义上的摆动相。对于不同地形改变,人体需要将下肢移动至合理的地形位置以适应不同地形间的过渡,保持躯干稳定,如图7所示。

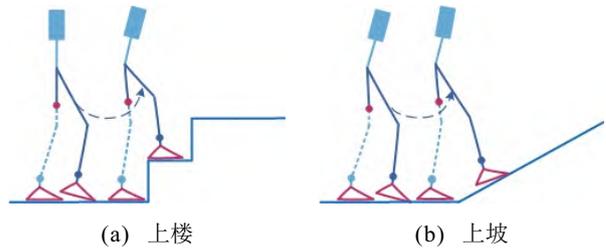


图7 不同地形下足底动力相运动轨迹变化差异示意图

从能量变化角度考虑,在基于肌电信号的研究中,腓肠肌被认为在足底动力相阶段具有明显活动,且呈规律性变化。特别是在推动阶段,足底通过地面反作用力积累并将动能转化为弹性势能储存,使得人体改变重心向前推进,随后在脱地阶段,腓肠肌释放储存的弹性势能,转化为下肢离地向前摆动的动能,有效推动步态周期交替。在进入摆动相后,即处于较长的静息状态^[29]。

在对8种转换模式的分析中,本文根据Noitom Perception Legacy动作捕捉系统采集的足底触地状态序列确定转换步的起始点,即健侧脚尖离地时刻,并以此时刻前后分别截取数据。不同传感器设备的采样频率不同,且不同受试者的运动步态存在差异,因此所截取的窗口长度大小不同。由于本文所使用的可穿戴传感器设备采样频率为96 Hz,受试者的平均步态周期长度约为225帧,据此本文设定经验优化后的摆动相前期约为45帧数据,足底动力相约为30帧数据,作为本文的目标数据时间窗,长度约为75帧。设定固定窗口长度数据如图8所示。

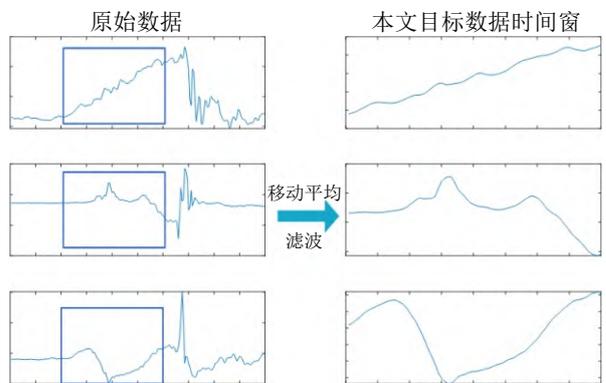


图8 窗口大小示意图

通过结合足底动力相和摆动相前期两个关键相位数据,能够捕捉人体行走意图的关键事件,模拟两个不同步态间转变过程,使得模型能够准确判断当前步态周期的同时,也能预见即将发生的步态变化。

2.2 基于能量分布的小波变换自适应分解

支撑相阶段下肢整体运动幅度相较于摆动相而言更小, 人体姿态整体变化较为平缓且特征不易提取, 但是其中蕴藏着丰富的能量变化. 鉴于支撑相统计特征难以凸显, 本文采用小波变换的信号处理方法来表征支撑相中隐藏的非平稳信号, 在小波域更好地提取支撑相中所隐藏的运动学特征, 定位和量化信号在时间和频率上的瞬态变化, 同时挖掘足底动力相阶段的能量分布以及释放过程.

2.2.1 基于足底动力相的小波时频分析

足底动力相作为支撑相与摆动相过渡的桥梁,

承担着能量释放的任务, 为预测下一步行动提供了关键线索. 此阶段涉及快速能量变化的动力学过程, 而小波变换提供了一种时频局部化的信号分析方法, 能够精确捕捉足底动力相能量快速转换的动力学过程.

小波变换可以将信号分解为不同频率部分, 通过小波系数来表达原始信号与小波基函数在不同尺度和位置上的相似性^[30]. 将原始信号进行小波分解, 能够得到一系列的细节系数和近似系数, 如图 9 所示.

从信号成分上看, 低层次分解的近似系数中含

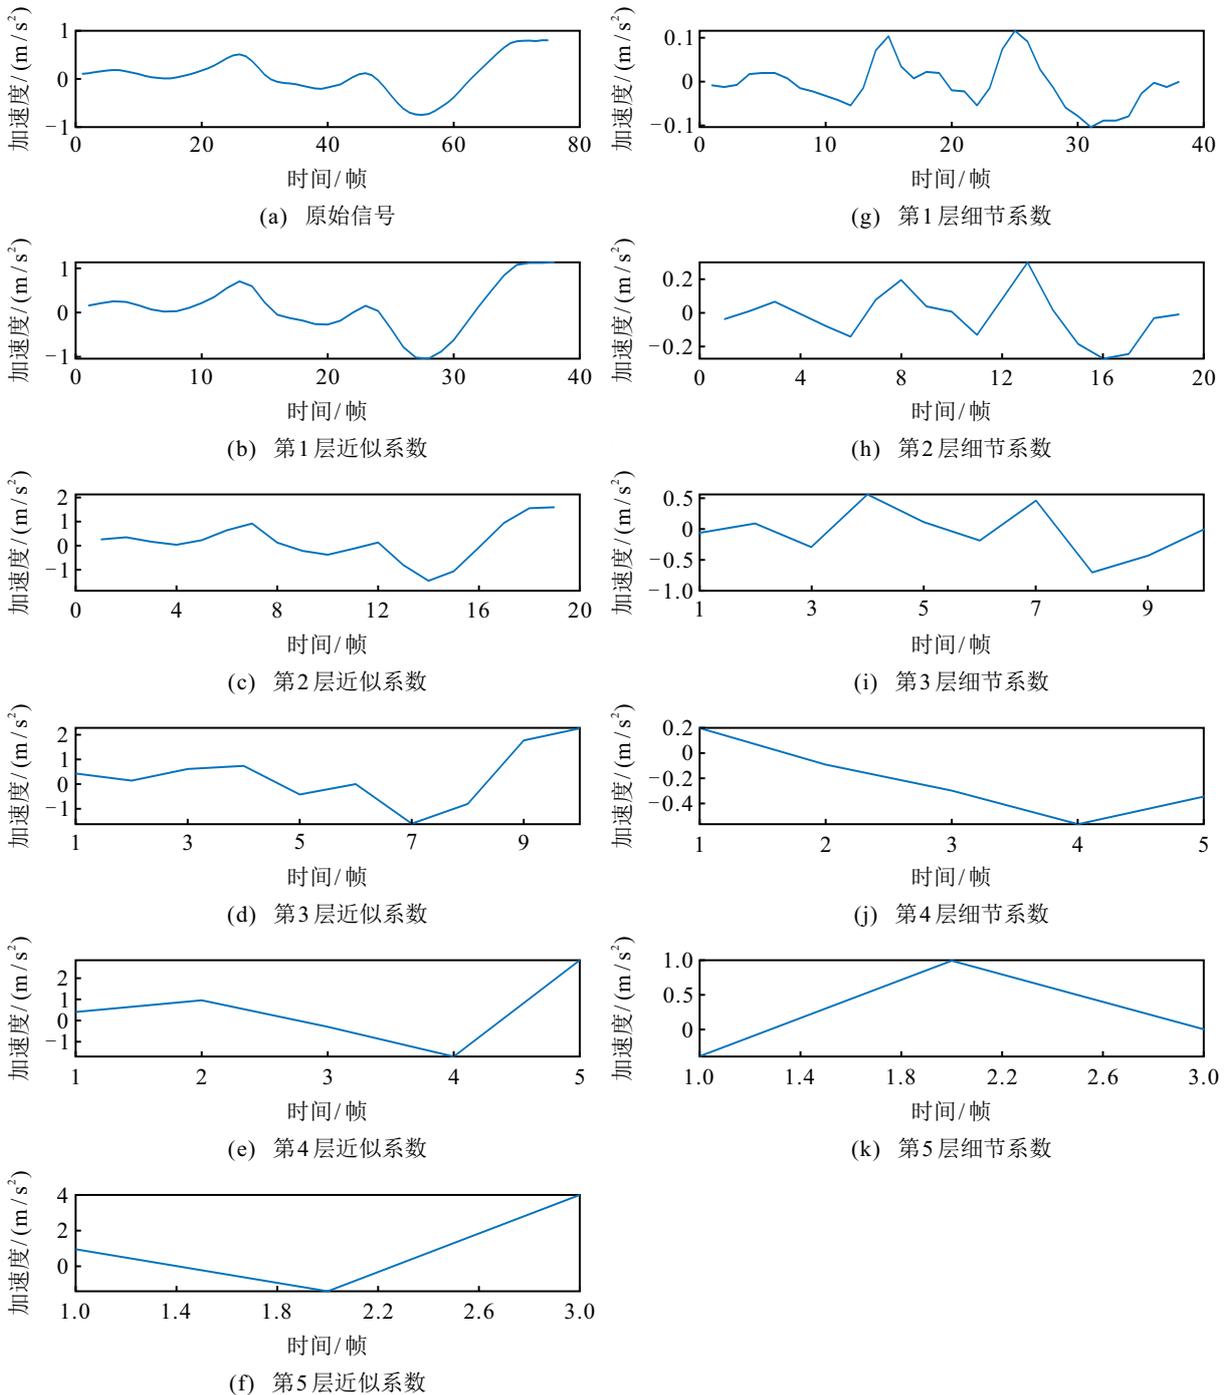


图9 原始信号多层小波分解示意图

有噪声较多, 随着分解层数的增加, 细节系数中包含的噪声越来越少, 信号有效信息增多, 能够较好地表达原始信号的能量突变以及信号的尖峰. 但是当分解层数较大时, 小波为了追求更深层次的频率分析, 其近似系数会为了保留低频信息而不得不牺牲越来越多的高频细节, 从而出现失真的现象, 导致小波系数无法较好地表达原始信号信息^[31].

对于小波变换的尺度函数

$$\varphi_{j,k}(t) = 2^{-\frac{j}{2}}\varphi(2^{-j}t - k), j, k \in \mathbf{Z} \quad (1)$$

和小波函数

$$\psi_{j,k}(t) = 2^{-\frac{j}{2}}\psi(2^{-j}t - k), j, k \in \mathbf{Z}, \quad (2)$$

信号 $f(t) \in L^2(\mathbb{R})$ 的多分辨率分析的分解公式为

$$f(t) = \sum_k c_{j,k}\varphi_{j,k}(t) + \sum_{j=j_0}^{\infty} \sum_k d_{j,k}\psi_{j,k}(t), \quad (3)$$

其中 $c_{j,k}$ 和 $d_{j,k}$ 分别为近似系数和细节系数. 对于近似系数, 会继续分解再次得到近似系数和细节系数; 而对于细节系数则不再分解.

2.2.2 基于能量分布的小波分解层数计算

为了确定信号最优的分解层数, 本文通过近似小波系数能量变化 (AWCEC) 作为指标来衡量小波分解的程度, 通过每个小波系数的平方和来表征信号的能量, 如下所示:

$$E_j = \sum_{i=1}^{\frac{2n}{2^j}} |cA_i|^2. \quad (4)$$

其中: 设原始信号长度为 $2n$; 面对不同的分解层数 j , 近似系数的个数为 $\frac{2n}{2^j}$; cA_i 为原始信号分解 j 层的第 i 个小波近似系数; E_j 为分解 j 层的小波近似系数的能量.

如图 10 所示: 信号的主要能量集中在近似系数, 随着分解层数的增加, 近似系数所含能量占比逐层降低, 而细节系数所含能量占比逐层上升.

从信号能量来看, 随着层数的继续增加, 细节系

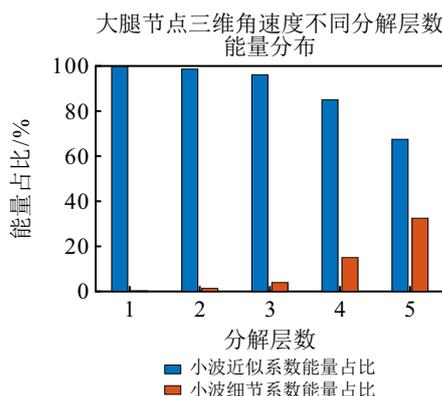


图10 小波系数在不同分解层数下能量占比示意图

数中有效信号的能量越来越多, 由于有效信号的能量远远大于噪声信号, 细节系数能量将呈现显著增大趋势^[32], 这也是小波分解达到最优尺度的标志.

本文提出了一种基于能量的最优小波分解层数算法, 具体地, 针对足底动力相和摆动相前期数据, 信号经过一维离散小波变换分解层后, 为了反映不同动作身体不同部位传感器的能量变化差异性, 对相邻层数的小波近似系数能量做差分运算, 如下所示:

$$\Delta E = (\Delta E_1, \Delta E_2, \dots, \Delta E_{j-1}), \quad (5)$$

其中 $\Delta E_n = E_{j+1} - E_j$.

若相邻两层的小波近似系数的一阶差分过大, 则判定分解出现失真. 本文根据信号相邻两层小波近似系数的能量一阶差分来判断小波分解层数, 其中能量阈值的设定求解如下所示:

$$\bar{x} = \mu = \frac{\sum_j E_j}{j}. \quad (6)$$

分解层数的确定如后文算法 1 所示, 阈值取值如表 2 所示. 当 $\Delta E_n > \xi$ 时, 判定分解完成.

表2 不同节点能量变化阈值 %

加速度			角速度		
2号节点	3号节点	4号节点	2号节点	3号节点	4号节点
8.4	14.8	5.2	17.7	9.6	17.9

2.2.3 基于区间估计的最优小波分解层数

根据能量变化阈值所得到的不同动作最优小波分解层数如图 11 所示. 基于能量的小波分解层数整体服从正态分布, 由此可以计算总体均值置信度为 0.95 的置信区间, 得到最优小波分解层数置信区间.

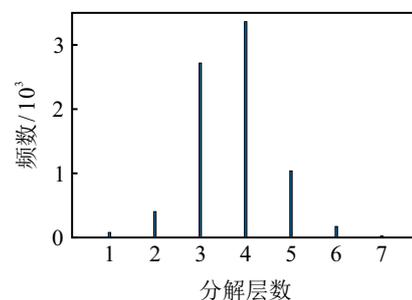


图11 基于能量的最优小波分解层数频数

基于参数估计法, 将得到的小波分解频数作为样本, 由中心极限定理可知, 当样本数量足够大时, 样本均值呈近似正态分布. 当置信水平固定时, 估计样本数越大, 置信区间长度越小, 估计越准确. 本文每个受试者的每个动作分别产生加速度和角速度两个维度上的最优小波分解层数.

若 $[\hat{\theta}_1(x), \hat{\theta}_2(x)]$ 为参数 θ 估计的区间, 对于给定的 $0 < \theta < 1$, 有

$$P(\hat{\theta}_1(x) \leq \theta \leq \hat{\theta}_2(x)) \geq 1 - \alpha, \quad (7)$$

则 $[\hat{\theta}_1(x), \hat{\theta}_2(x)]$ 为置信度 $1 - \alpha$ 下的置信区间。

结合以上定义可知, 小波分解层数样本数据为 $J = [J_1, J_2, \dots, J_N]$, 已知其服从近似正态分布 $N(\mu, \frac{\sigma^2}{n})$, 条件满足 $-\infty < \mu < \infty, \sigma^2 > 0$, 样本均值为 $\bar{x} = \mu = \sum_{j=1}^J E_j$, 样本方差为

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2,$$

本文设置 $1 - \alpha = 95\%$ 的置信度(显著性水平), 由于总体是大样本, 可根据下式完成置信区间估计(confidence interval estimate):

$$I_c = \left[\bar{x} - z_{\frac{\alpha}{2}} \frac{\sigma^2}{\sqrt{n}}, \bar{x} + z_{\frac{\alpha}{2}} \frac{\sigma^2}{\sqrt{n}} \right]. \quad (8)$$

通过上述参数估计法得到的基于正态分布的95%置信区间为 $[3.6842, 3.7241]$, 由于分解层数需要设定为整数值, 且分解至第4层产生的近似系数序列相较于第3层更短, 较短的特征向量能够减少计算复杂度, 并从参数估计的相合性分析, 若一个统计量是未知参数的一致估计, 则随着采样值数量的增加, 在大样本条件下, 统计量收敛于真值。因此, 本文设定第4层作为整体最优小波分解层数。

2.2.4 支持向量机

支持向量机作为强分类器模型, 尤其擅长处理小样本数据、非线性问题以及高维分类任务, 其核心机制是通过构建最大间隔的线性分类器来解决优化问题。核函数是SVM的关键因素之一。本节采用以径向基函数为核函数的SVM模型, 函数的形式如下所示:

$$K(x, x_1) = \exp \left[-\frac{\|x - x_1\|^2}{2\sigma^2} \right], \quad (9)$$

其中 σ 为核半径。

注1 式(9)中参数 σ 通过算法自动搜索, 根据训练样本不同而发生变化。SVM对于参数 σ 的变化通常呈指数级敏感: 较大的 σ 值可能会带来模型的过拟合; 而较小的 σ 值会导致模型过于简单, 出现欠拟合的情况, 且对于标准化后的数据, 90%以上的最优 σ 值落在 $[2^{-5}, 2^5]$ 范围内^[33-34]。因此, 为了确定其最优参数, 防止过拟合和欠拟合的发生, 本文给出 σ 初始的经验取值为 2^5 , 然后对训练集进行多次 K 次分组进行测试, 根据初始 σ 得到初始准确率, 随后以固定步长搜索更新 σ 的值, 经过最多 K 次迭代, 选取准确

率最大时所对应的 σ 值, 得到核半径 σ 的最优值。

本节所提出的基于足底动力相数据和小波变换自适应分解的下肢假肢意图识别方法如算法1所示。

算法1 基于足底动力相数据和小波变换自适应分解的下肢意图识别算法。

输入: 健侧大腿、小腿、脚3个节点的三轴角速度、加速度数据序列 y ;

输出: 识别精度Acc.

step 1: 选取 y 中足底动力相与摆动相前期的 k 帧(本文 $k = 75$)构建目标时间窗 y_1 ;

step 2: 滤波后对 y_1 进行 j 层小波分解, 计算小波近似系数能量 $\omega_1, \omega_2, \dots, \omega_j$;

step 3: 使用一阶差分计算原始信号进行小波变换后, 相邻两层小波近似系数所含能量变化 $|\omega_j - \omega_{j-1}| < \xi$ ($j \geq 2$);

step 4: 确定所有样本基于能量变化的小波分解层数 $J = [J_1, J_2, \dots, J_N]$;

step 5: 计算所有小波分解层数在95%置信度下的置信区间范围 $I_c = \left[\bar{x} - z_{\frac{\alpha}{2}} \frac{\sigma^2}{\sqrt{n}}, \bar{x} + z_{\frac{\alpha}{2}} \frac{\sigma^2}{\sqrt{n}} \right]$;

step 6: 根据置信区间确定最终最优小波分解层数 J_{best} ;

step 7: 对原始信号进行 J_{best} 层小波分解, 取 J_{best} 层的近似小波系数构成特征向量;

step 8: 使用SVM分类器进行训练和测试;

step 9: 输出识别精度Acc.

3 实验与结果

3.1 实验设备与方案

本文采用Noitom Perception Legacy动作捕捉系统, 如图12所示。该系统每个节点分别集成有一个三轴加速度传感器和一个三轴陀螺仪, 能够实时同步采集人体全身21个关键点的运动数据, 这些数据涵盖了加速度、角速度、线速度、位移、四元数表示的姿态以及足部触地状态等多个参数维度。系统设定的采样频率为96 Hz, 且具有宽广的动态测量范围, 其中加速度量程高达24 g, 而角速度量程则可达2000 dps, 本实验仅使用该系统中大腿、小腿、脚



图12 Noitom Perception Legacy 动作捕捉设备

踝处3个节点的加速度、角速度数据。

由于残疾人数据涉及隐私、伦理等问题,且数据获取十分困难,本文仅采集到1名胫骨截肢者的真实运动数据,如图13(a)所示。其余数据均来自10名健康受试者(5男5女,18~30岁,158~183cm,40~86kg),如图13(b)所示。在实验正式开始前,健康受试者被要求佩戴完整的可穿戴式传感器设备,并在左侧腿部穿戴模拟器,模拟左腿胫骨截肢者在平地、上坡、下坡、上楼以及下楼5种不同的地形上行走,进行适应性训练,减少健康受试者在模拟步态时产生的心理和生理差异。



(a) 截肢者数据采集 (b) 模拟者数据采集

图13 数据采集示意图

实验场景包括一组由8级台阶构成的高度为16cm的楼梯以及一段长度为6m、坡度为10°的斜坡区域。自采集数据集共包含1430个样本。其中:1300个来自健康人的模拟截肢者数据,130个为从胫骨截肢者采集的数据。该研究方案于2019年3月获得了中国安庆师范大学伦理委员会的批准,在实验采集前,受试者完全知情且自愿参与实验,并在医生的指导下进行了实验数据的采集。

3.2 实验结果

3.2.1 身体健全受试者模拟实验

对于10名健康受试者的模拟数据,通过执行本节算法进行仿真实验,实验结果如下:若只考虑平地行走、上坡、下坡、上楼、下楼单独的这5种稳态模式,本节算法的实验结果(识别率)为99.12%。图14为稳态模式分类结果的混淆矩阵。其中:模型对于上楼和下坡这两种稳态模式的识别率达到了100%,所有被错分的样本集中出现在上坡、下楼和平地行走3类运动模式上。而转换模式的识别率可达到较高的99.20%。由图15可知,对于走-上楼、走-上坡和走-下楼、走-下坡这类运动相似度较高的转换模式,这些运动模式的起始动作较为接近,区分度较低,导

致所提出模型难以完全区分。

真实类 \ 预测类	上坡	上楼	下坡	下楼	走
上坡	97			1	2
上楼		100			
下坡			100		
下楼		1		99	
走	1				99

图14 健康受试者5种稳态模式混淆

真实类 \ 预测类	上坡-走	上楼-走	下坡-走	下楼-走	走-上坡	走-上楼	走-下坡	走-下楼
上坡-走	99	1						
上楼-走		100						
下坡-走			100					
下楼-走			1	99				
走-上坡					99	1		
走-上楼					1	99		
走-下坡							99	1
走-下楼							2	98

图15 健康受试者8种转换模式混淆矩阵

在13种运动模式下,模型的总体识别率为97.65%,相较于单独对稳态模式以及转换模式进行识别时效果有所下降,但是整体识别率相对较高。图16为13种运动模式的混淆矩阵。由图16可见,对于综合运动模式下主要的错误分类出现在区分当前步态是稳态模式还是转换模式中,对于转换步与稳态

真实类 \ 预测类	上坡	上坡-走	上楼	上楼-走	下坡	下坡-走	下楼	下楼-走	走	走-上坡	走-上楼	走-下坡	走-下楼
上坡	98	1						1					
上坡-走		99			1								
上楼			100										
上楼-走			4	96									
下坡					94	6							
下坡-走					3	97							
下楼							95	3	1				1
下楼-走							3	97					
走									100				
走-上坡										99	1		
走-上楼		1								1	98		
走-下坡										2		97	1
走-下楼										1		2	97

图16 健康受试者13种运动模式混淆矩阵

步的区分,模型不能很好地辨别不同地形转换的最后一步转换步,而对于其他模式已经能够得到很好的分类.

3.2.2 胫骨截肢受试者实验

由于截肢者数据获取难度较大,且出于对截肢者隐私保护,本研究仅在一个截肢者身上进行了真实运动数据的采集记录,即共在本文的实验条件环境下,对13种运动模式重复了10遍,收集了130个数据样本,相对身体健全的模拟受试者而言,样本量较小,但是能够初步验证所提出算法的有效性.胫骨截肢者13种运动模式混淆矩阵如图17所示.

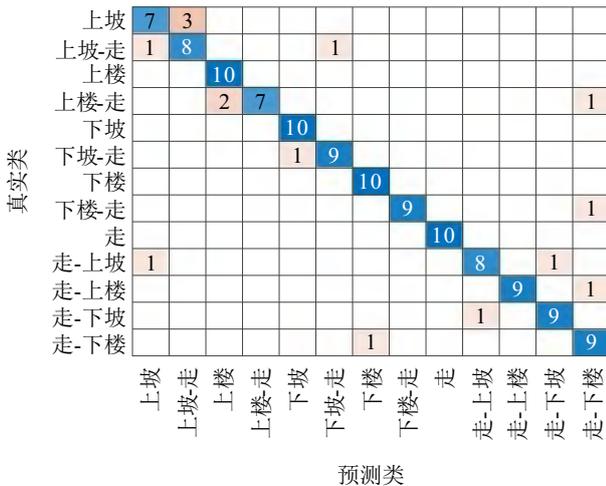


图17 胫骨截肢者13种运动模式混淆矩阵

实验结果显示,对于该受试者的5种稳态模式、8种转换模式以及13种综合运动模式,识别准确率分别达到了100%、89.82%和88.54%,其中稳态模式的识别率较好.在8种转换模式中,主要的识别错误出现在上坡和上坡-走、上楼与上楼-走两个转换动作间.对于上坡与上坡-走之间的误分类,可能是由于不同坡度的倾斜角度不同,较小的倾斜角度可能导致不同的运动模式识别边界模糊.其次,在实验设计过程中,为保护胫骨截肢者在数据采集过程中的安全,没有规定胫骨截肢者按照既定的迈步顺序进行实验数据的采集,而是在保证安全的前提下,按照自身的自然迈步顺序进行数据采集,这可能使得在上楼和上坡这两个地形转换的转换步中,胫骨截肢者对地形过渡的肢体调整方式相似度较高,导致模型的错误分类.在13种综合运动模式的识别中,上坡-走的转换模式与稳态上坡运动模式间的识别率较低,考虑到这几种运动模式间有着较高的类间相似性,因此错分率偏高.

此外,本文自采集数据集中仅包含1位胫骨截肢者,训练数据样本较少,可能会导致结果不理想.值得注意的是,与健康受试者模拟实验不同,截肢者

在执行不同运动模式间的转换时,会遵循经验主动调整步幅,以保证在转换模式期间的身体稳定和自身安全.确保健侧腿率先接触改变的地形,这种适应性调整旨在维持身体姿态平衡,可有效防止因地形改变导致的跌倒,正如平地行走向上楼的转换一般先发生在健侧.

3.3 实验分析

3.3.1 评价指标

本节运用10折交叉验证($K = 10$)评估算法的性能.最终取10次测试结果的均值作为算法各项性能指标的评估值.在分类任务中,常用的评估指标包括准确率(Accuracy)、精确率(Precision)、召回率(Recall)、 F_1 分数(F_1 score)4项指标,这些指标能够分别从不同角度衡量模型的性能,有

$$Accuracy(\%) = \frac{TP + TN}{TP + TN + FP + FN}, \quad (10)$$

$$Precision(\%) = \frac{TP}{TP + FP}, \quad (11)$$

$$Recall(\%) = \frac{TP}{TP + FN}, \quad (12)$$

$$F_1 \text{ score}(\%) = 2 \times \frac{Precision \times Recall}{Precision + Recall}. \quad (13)$$

其中:TP为被正确地预测为正类的实例数量,TN为被正确地预测为负类的实例数量,FP是被错误地预测为正类的实例数量,FN为被错误地预测为负类的实例数量.

所提出方法在4种不同评价指标下的评价结果如表3所示.实验结果表明:所提出算法在识别不同类型的运动模式时表现较优,特别是在稳态模式以及转换模式的单独识别任务中泛化能力较强,出现误分类的情况较少,且均能够达到99%以上的准确率,在其余3个指标精确率、召回率、 F_1 分数上整体较优;在13种综合运动模式下,总体准确率略低于单独考虑稳态与转换模式时的性能,但是仍然保持在高水平,显示出模型在面对更复杂、更全面的运动模式集合时拥有较强的泛化能力,且相比于基准方法分别提升了1.69%、2.53%,验证了所提出方法的有效性.

表3 运动模式分类在不同评价指标下的结果 %

运动模式	Accuracy	Precision	Recall	F_1 score
5种稳态模式	99.25	98.67	99.40	99.32
8种转换模式	99.19	99.52	99.01	99.25
13种运动模式	97.65	99.16	99.03	99.07

3.3.2 对比实验

为验证所提出算法的有效性,评估不同意

别方法间的优劣,本文对比实验结果如表4所示.其中:已有研究^[20,23]中所采用的技术路线与本文相同,在相同的传感器类型及数量、传感器安装位置、分类器、运动模式种类下,本文所选择的数据区域和信号特征表现出了较高的识别精度,验证了足底动力相在下肢假肢意图识别系统中的重要作用.由于缺少公开残疾人数据集,受限于不同的传感器类型以及实验环境,表4列举了文献[13-15]相关算法从应用层面进行比较,通过对比可知,在没有使用额外压力传感器的情况下,本文所选择的单一类型的传感器避免了传感器间的信号干扰以及异质数据融合的问题,

同时,针对不同的步态周期子相进行分析,筛选在意图识别系统中具有判别性的关键相位,能够提升计算效率,减少噪声干扰,且在13种运动模式取得较高识别率的情况下兼顾了计算效率.

3.3.3 消融实验

针对13种运动模式,为其特征选择和性能进行评估,设计了如下目标数据时间窗消融实验,如表5所示.其中:在本文所选择的摆动相前期和足底动力相两个关键相位的基础上,也对比了基于统计特征(均值、方差、最值)与小波低频系数作为特征输入分类器的效果.

表4 本文方法与实验结果对比

文献	传感器类型/数量	数据区域	传感器位置	机械信号特征	分类器	运动模式种类		识别精度/%
						稳态	转换	
Zhu等 ^[13]	1个惯性传感器, 2个压力传感器	100 ms 滑动窗口	患侧	最值, 均值等	GBDC	—	8	95.10
Liu等 ^[14]	2个惯性传感器, 1个压力传感器	50 ms 滑动窗口	健侧	大腿相图形状、 膝关节角轨迹等	ANN	5	—	99.16
Zheng等 ^[15]	2个惯性传感器, 1个压力传感器	100 ms 滑动窗口	患侧	大腿角度, 最值角度差	LDA	7	8	98.04
苏本跃等 ^[23] (base)	3个惯性测量单元	摆动相前期	健侧	均值, 方差, 最值	SVM	5	8	95.50
Sheng等 ^[20]	3个惯性测量单元	摆动相前期	健侧	DTCWT5层低频系数	SVM	5	8	97.27
本文方法	3个惯性测量单元	足底动力相、摆动相前期	健侧	haar小波4层低频系数	SVM	5	—	99.21
						—	8	99.19
						5	8	97.65

表5 目标数据时间窗消融实验

数据区域	特征	Accuracy/%	Precision/%	Recall/%	F ₁ score/%	t/s
摆动相前期	均值、方差、最值	95.18	98.35	95.98	97.12	0.0154
足底动力相	均值、方差、最值	82.77	79.42	79.31	79.09	0.0145
摆动相前期+足底动力相	均值、方差、最值	94.71	97.63	96.24	96.81	0.0211
摆动相前期	小波4层低频系数	95.24	98.90	97.98	98.40	0.0276
足底动力相	小波4层低频系数	82.05	82.36	80.89	81.18	0.0204
摆动相前期+足底动力相	小波4层低频系数	97.65	99.16	99.03	99.07	0.0311

从特征表现来看,仅使用摆动相前期的统计特征已能够实现较高的分类性能,展现出良好的识别能力.但是,当合并两个数据区域的统计特征时,分类性能并没有出现进一步提升的趋势,而是从原始95.18%的识别率降低至94.71%,这可能是由于足底动力相的时域特征变化较少,在均值、方差、最值这类统计特征上并没有提供有效的特征信息,反而由于IMU信号体现出摆动相前期与足底动力相的互补性对于提高整体识别效果的重要性.然而,将特征选择转向小波变换提取的低频系数时,分类性能出现了显著跃升.这表明小波低频系数在捕捉下肢假肢运动模式细微变化和独特特征方面的优越性.

在时间复杂度方面,尽管使用小波低频系数作为特征会导致计算成本略有增加,但是考虑到其带来的显著性能提升,额外计算开销的时间远早于截肢者假肢的地形转换运动前进行,满足实时性的应用场景.

不同小波分解层数下的对比实验结果如表6所示.针对不同的小波分解层数,可以看出:模型在小波分解层数为4时表现出了较好的性能,较低的分解层数如1~3层时会造成信息丢失,较高的分解层数如5~7层则会导致过拟合以及计算资源的浪费.尽管1~3层的分解结果在多个评价指标下也较优,但是,考虑到第4层小波分解层数能够带来较

短的特征向量, 从而在分类器方面减少计算开销, 在时间复杂度方面具有优势, 快速响应用户输入, 为后续假肢控制提供了更充足的准备时间, 这也验证了自适应小波变换层数所得到的第4层为最优小波分解层数。

表6 小波分解层数消融实验

小波分解层数	Accuracy/%	Precision/%	Recall/%	F_1 score/%	t/s
1	96.70	99.36	98.95	99.13	0.1399
2	97.15	98.95	99.31	99.11	0.0806
3	97.29	99.05	98.76	98.88	0.0322
4	97.65	99.16	99.03	99.07	0.0204
5	97.14	99.00	98.81	98.87	0.0109
6	95.72	95.39	98.28	96.75	0.0079
7	86.80	88.88	92.14	90.25	0.0061

4 讨论与展望

收集截肢者的真实运动数据面临着显著的挑战, 其中包括隐私保护、参与者招募等多方面因素, 且受限于当前研究方向尚未发表公开数据集。因此, 所提出算法在残疾人样本量方面存在一定的缺陷, 增加截肢者样本数量对于提高模型的泛化能力和可靠性至关重要。在后续实验规划中, 将进一步考虑通过滑动窗口对截肢者数据进行数据增强, 另一方面积极加强与医疗机构间的合作, 扩大数据来源。在采集过程中确保参与者的隐私安全, 并遵循伦理标准。其次, 不同人群存在显著的数据差异, 包括不同年龄段、性别、运动能力的人群数据均会对实验结果造成较大的影响, 本文数据集所考虑的年龄段从18~30岁, 范围跨度较小, 应考虑扩大年龄跨度, 并增加受试者样本量。对于不同运动能力的受试者, 其运动表现不同, 对实验过程中所采集到的数据也有着重要影响, 在后续扩大截肢者样本量的过程中, 还需要考虑如截肢部位、残肢状态、截肢年限等对于截肢者运动数据的影响。

在算法的鲁棒性方面, 所提出算法仅针对当前数据集下的测试环境, 其中包括在常见的5种稳态地形以及8种转换地形上进行了初步验证, 且取得了较好的效果。但是, 在更加复杂和变化多端的实际环境中, 算法的表现仍有待进一步考察。为此, 未来的工作将致力于扩展更复杂的实验环境, 包括更多地形环境(如草地、瓷砖、水泥地、木质地板等)以及长时步态序列周期在多种地形转换下的意图识别, 以此增加模型鲁棒性。

在所提出算法方面, 没有选择自适应学习特征的深度学习, 而是使用了传统的机器学习, 是由于深度学习在当前小样本的数据集下尚未体现出其优势,

在后续的工作中, 在增加截肢者数据量的基础上, 将深入探索深度学习在意图识别中的潜力, 进一步提升模型性能。

综上所述, 尽管当前的研究取得了一定成果, 但是, 在样本规模、应用场景广度和技术深化等方面仍然有许多工作要做。未来的研究将继续围绕这些问题展开, 旨在开发出更加高效、可靠的下肢假肢意图识别系统。

5 结论

本文针对支撑相进行了深入分析, 结合足底动力相和摆动相前期运动数据, 从提升识别精确度和运动过渡平滑性的角度出发, 分别针对下肢假肢意图识别问题提出了步态相位选择算法和基于能量的小波分解自适应层数算法, 为下肢假肢的意图预测提供了信息补充。进一步地, 利用小波变换有效提取了足底动力相特征, 验证了所提出方法在下肢假肢意图识别方面的有效性。

参考文献 (References)

- [1] Mohanty R K, Mohanty R C, Sabut S K. A systematic review on design technology and application of polycentric prosthetic knee in amputee rehabilitation[J]. *Physical and Engineering Sciences in Medicine*, 2020, 43(3): 781-798.
- [2] 杜沁龙, 霍鑫, 郑凯, 等. 基于态势图序列的多智能群体意图识别[J]. *控制与决策*, 2024, 39(9): 2941-2949. (Du Q L, Huo X, Zheng K, et al. Intention recognition for multiple agents based on situation map sequence[J]. *Control and Decision*, 2024, 39(9): 2941-2949.)
- [3] 王显. 下肢假肢运动意图识别系统搭建与算法研究[D]. 吉林: 吉林大学, 2023: 1-87. (Wang X. Research on construction and algorithm of motion intention recognition system for lower limb prosthesis[D]. Jilin: Jilin University, 2023: 1-87.)
- [4] Finucane S B, Hargrove L J, Simon A M. Functional mobility training with a powered knee and ankle prosthesis[J]. *Frontiers in Rehabilitation Sciences*, 2022, 3: 790538.
- [5] 苏本跃, 倪钰, 盛敏, 等. 基于改进卷积神经网络的动力下肢假肢运动意图识别[J]. *控制与决策*, 2021, 36(12): 3031-3038. (Su B Y, Ni Y, Sheng M, et al. Intent recognition of power lower-limb prosthesis based on improved convolutional neural network[J]. *Control and Decision*, 2021, 36(12): 3031-3038.)
- [6] 王启宁, 郑恩昊, 陈保君, 等. 面向人机融合的智能动力下肢假肢研究现状与挑战[J]. *自动化学报*, 2016, 42(12): 1780-1793. (Wang Q N, Zheng E H, Chen B J, et al. Recent progress and challenges of robotic lower-limb prostheses for human-robot integration[J]. *Acta Automatica Sinica*,

- 2016, 42(12): 1780-1793.)
- [7] Luo S L, Meng Q L, Li S J, et al. Research of intent recognition in rehabilitation robots: A systematic review[J]. *Disability and Rehabilitation Assistive Technology*, 2024, 19(4): 1307-1318.
- [8] Huang H, Zhang F, Hargrove L J, et al. Continuous locomotion-mode identification for prosthetic legs based on neuromuscular-mechanical fusion[J]. *IEEE Transactions on Biomedical Engineering*, 2011, 58(10): 2867-2875.
- [9] 陈辉, 任志刚, 冯祖仁, 等. 基于IMU和运动学的四足机器人对角支撑状态估计算法[J]. *控制与决策*, 2024, 39(9): 2894-2902.
(Chen H, Ren Z G, Feng Z R, et al. State estimation for diagonal support of quadruped robot based on IMU and kinematics[J]. *Control and Decision*, 2024, 39(9): 2894-2902.)
- [10] 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.
- [11] 盛敏, 夏安琪, 王可林, 等. 基于几何与物理特征融合的智能下肢假肢运动意图识别[J]. *控制与决策*, 2022, 37(4): 953-961.
(Sheng M, Xia A Q, Wang K L, et al. Movement intention recognition of intelligent lower limb prosthesis based on the fusion of geometric and physical features[J]. *Control and Decision*, 2022, 37(4): 953-961.)
- [12] 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.
- [13] Zhu L, Wang Z, Ning Z G, et al. A novel motion intention recognition approach for soft exoskeleton via IMU[J]. *Electronics*, 2020, 9(12): 2176.
- [14] Liu Y, An H L, Ma H X, et al. Novel feature extraction and locomotion mode classification using intelligent lower-limb prosthesis[J]. *Machines*, 2023, 11(2): 235.
- [15] Zheng E H, Wan J C, Gao S Y, et al. Adaptive locomotion transition recognition with wearable sensors for lower limb robotic prosthesis[J]. *IEEE/ASME Transactions on Mechatronics*, 2024, 29(1): 279-289.
- [16] Salis F, Bertuletti S, Bonci T, et al. A method for gait events detection based on low spatial resolution pressure insoles data[J]. *Journal of Biomechanics*, 2021, 127: 110687.
- [17] Manchola M D S, Bernal M J, O Munera M, et al. Gait phase detection for lower-limb exoskeletons using foot motion data from a single inertial measurement unit in hemiparetic individuals[J]. *Sensors*, 2019, 19(13): 2988.
- [18] 唐向宏, 李齐良. 时频分析与小波变换[M]. 北京: 科学出版社, 2008.
(Tang X H, Li Q L. Time-frequency analysis and wavelet transform[M]. Beijing: Science Press, 2008.)
- [19] Zhang P, Zhang J X, Elsabbagh A. Lower limb motion intention recognition based on sEMG fusion features[J]. *IEEE Sensors Journal*, 2022, 22(7): 7005-7014.
- [20] Sheng M, Wang W J, Tong T T, et al. Motion intent recognition in intelligent lower limb prosthesis using one-dimensional dual-tree complex wavelet transforms[J]. *Computational Intelligence and Neuroscience*, 2021: 5631730.
- [21] Au S, Berniker M, Herr H. Powered ankle-foot prosthesis to assist level-ground and stair-descent gaits[J]. *Neural Networks*, 2008, 21(4): 654-666.
- [22] Herr H M, Grabowski A M. Bionic ankle-foot prosthesis normalizes walking gait for persons with leg amputation[J]. *Proceedings of the Royal Society B: Biological Sciences*, 2012, 279(1728): 457-464.
- [23] 苏本跃, 王婕, 刘双庆, 等. 惯性动捕数据驱动下的智能下肢假肢运动意图识别方法[J]. *自动化学报*, 2020, 46(7): 1517-1530.
(Su B Y, Wang J, Liu S Q, et al. An improved motion intent recognition method for intelligent lower limb prosthesis driven by inertial motion capture data[J]. *Acta Automatica Sinica*, 2020, 46(7): 1517-1530.)
- [24] 盛敏, 刘双庆, 王婕, 等. 基于改进模板匹配的智能下肢假肢运动意图实时识别[J]. *控制与决策*, 2020, 35(9): 2153-2161.
(Sheng M, Liu S Q, Wang J, et al. Real-time motion intent recognition of intelligent lower limb prosthesis based on improved template matching technique[J]. *Control and Decision*, 2020, 35(9): 2153-2161.)
- [25] Asif M, Tiwana M I, Khan U S, et al. Advancements, trends and future prospects of lower limb prosthesis[J]. *IEEE Access*, 2021, 9: 85956-85977.
- [26] Versluys R, Beyl P, Van D M, et al. Prosthetic foot: State-of-the-art review and the importance of mimicking human ankle-foot biomechanics[J]. *Disability and Rehabilitation Assistive Technology*, 2009, 4(2): 65-75.
- [27] 俞志鹏. 下肢康复外骨骼人体运动意图识别研究[D]. 合肥: 中国科学技术大学, 2023: 52-71.
(Yu Z P. Research on human motion intention recognition of lower limb rehabilitation exoskeleton[D]. Hefei: University of Science and Technology of China, 2023: 52-71.)
- [28] Nazarahari M, Khandan A, Khan A, et al. Foot angular kinematics measured with inertial measurement units: A reliable criterion for real-time gait event detection[J]. *Journal of Biomechanics*, 2022, 130: 110880.
- [29] Nordin M. Basic biomechanics of the musculoskeletal system[J]. *Lippincott Williams & Wilkins Google Scholar*, 2001, 2: 267-275.
- [30] 苏本跃, 张利, 何清旋, 等. 基于小波特征匹配的短时人体行为识别[J]. *系统仿真学报*, 2023, 35(1): 158-168.
(Su B Y, Zhang L, He Q X, et al. Short-time human activity recognition based on wavelet features matching[J]. *Journal of System Simulation*, 2023, 35(1): 158-168.)
- [31] 刘嘉辉, 秦仙蓉, 王玉龙, 等. 基于双树复小波变换与

- 样本熵的自适应降噪法[J]. 振动、测试与诊断, 2022, 42(2): 285-291.
(Liu J H, Qin X R, Wang Y L, et al. Adaptive denoising of monitoring signal based on dual-tree complex wavelet transform and sample entropy[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(2): 285-291.)
- [32] 余本富, 王维博, 郑永康, 等. 基于自适应分解层数和阈值的小波去噪算法[J]. 传感器与微系统, 2017, 36(12): 126-129.
(Yu B F, Wang W B, Zheng Y K, et al. Wavelet denoising algorithm based on adaptive decomposition number of layers and threshold[J]. Transducer and Microsystem Technologies, 2017, 36(12): 126-129.)
- [33] Chang C C, Lin C J. LIBSVM: A library for support vector machines[J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 1-27.
- [34] 周绍磊, 廖剑, 史贤俊. 基于 Fisher 准则和最大熵原理的 SVM 核参数选择方法[J]. 控制与决策, 2014, 29(11): 1991-1996.
(Zhou S L, Liao J, Shi X J. SVM parameters selection method based on Fisher criterion and maximum entropy principle[J]. Control and Decision, 2014, 29(11): 1991-1996.)

作者简介

苏本跃 (1971-), 男, 教授, 博士后, 主要研究方向为模式识别、人工智能, E-mail: subenyue@sohu.com;

宗文杰 (1999-), 男, 硕士生, 主要研究方向为模式识别, E-mail: zongwenjie1110@163.com;

刘文瑶 (2000-), 女, 硕士生, 主要研究方向为模式识别, E-mail: 1328604930@qq.com;

盛敏 (1975-), 女, 教授, 博士, 主要研究方向为模式识别、图像处理, E-mail: msheng0125@aliyun.com.