

DOI:10.19651/j.cnki.emt.2517886

基于 1D-CNN-SVM 的下肢外骨骼步态信息识别研究^{*}

崔占贺¹ 艾莉莎² 马欣雨¹ 田天齐¹ 王松¹

(1. 北京邮电大学物联网监测预警应急管理部重点实验室 北京 100876;

2. 北京邮电大学网络与交换技术全国重点实验室 北京 100876)

摘要: 下肢外骨骼的步态识别是实现人机协同控制的关键技术,然而现有步态识别方法在处理一维时序数据时面临局部特征提取效率不足、小样本泛化能力弱以及模型计算开销大等挑战。针对上述问题,本文提出一种基于 1D-CNN-SVM 的混合模型,通过一维卷积神经网络(1D-CNN)自动提取一维时序数据的局部特征,并利用支持向量机(SVM)在小样本条件下实现高鲁棒性分类。实验结果表明,该模型在自定义步态数据集上的总识别率达到 99.00%,相较传统 SVM 模型和单一 1D-CNN 模型分别提升 5.67% 和 7.99%。另外该模型参数量仅为 26 156,单样本推理时间低至 0.06 ms,显著优于 1D-CNN-LSTM 混合模型。本研究为下肢外骨骼的步态识别提供了一种在小样本条件下依然兼具泛化能力、识别能力与轻量化的解决方案。

关键词: 下肢外骨骼;步态识别;支持向量机;一维卷积神经网络**中图分类号:** TN701 **文献标识码:** A **国家标准学科分类代码:** 510.1010

Gait information recognition study of lower limb exoskeleton based on 1D-CNN-SVM

Cui Zhanhe¹ Ai Lisha² Ma Xinyu¹ Tian Tianqi¹ Wang Song¹

(1. Key Laboratory of the Ministry of Emergency Management for Monitoring and Early Warning of the Internet of Things, Beijing University of Posts and Telecommunications, Beijing 100876, China; 2. National Key Laboratory of Network and Switching Technology, Beijing University of Posts and Telecommunications, Beijing 100876, China)

Abstract: Gait recognition of lower limb exoskeleton is a key technology to realize human-machine cooperative control, however, the existing gait recognition methods face the challenges of insufficient efficiency of local feature extraction, weak generalization ability of small samples, and high computational overhead of the model when dealing with one-dimensional time series data. Aiming at the above problems, this paper proposes a hybrid model based on 1D-CNN-SVM, which automatically extracts local features of 1D time-series data by a 1D convolutional neural network (1D-CNN) and realizes highly robust classification under small-sample conditions by using support vector machine (SVM). The experimental results show that the model achieves an overall recognition rate of 99.00% on the customized gait dataset, which is 5.67% and 7.99% higher than the traditional SVM model and the single 1D-CNN model, respectively. In addition, the number of parameters of this model is only 26 156, and the single-sample inference time is as low as 0.06 ms, which is significantly better than the hybrid 1D-CNN-LSTM model. This study provides a solution for gait recognition of lower limb exoskeleton that still combines generalization ability, recognition ability and light weight under small sample conditions.

Keywords: lower limb exoskeleton; gait recognition; support vector machine; one-dimensional convolutional neural network

0 引言

近年来,越来越多的下肢外骨骼逐渐进入大众的视野,被广泛应用于军事、工业和医疗康复领域。下肢外骨骼的

助力方式一般采用基于步态识别的协同助力,步态识别又分为步态模式识别和步态相位识别^[1],步态模式识别是指识别出不同场景下步行状态,而步态相位识别则是识别各步态周期中不同的阶段^[2]。不同的步态模式相位也不同,

收稿日期:2025-01-12

* 基金项目:中国高校科技期刊研究会专项(CUJS2024-GJ-A01)、北京邮电大学基本科研业务费(2024ZCJH06)项目资助

需要下肢外骨骼切换不同的控制参数,故步态模式识别的准确性直接影响下肢外骨骼的助力效果。人体在使用下肢外骨骼过程中会产生多种步态模式,如平地行走、跑步、上下坡、上下楼梯等。步态模式的多样性、环境的复杂性以及使用者个体差异使外骨骼系统面临着诸多挑战。

为优化下肢外骨骼步态识别的能力,研究人员尝试了各种算法模型。苏鸿等^[3]基于 XGBoost 算法,利用单个 IMU 采集不同步态下的足部运动数据,从原始数据中提取数据向量进行步态相位识别,结合贝叶斯算法对模型参数进行优化,最终得出测试集的平均准确率为 89.26%,精度为 89.64%,召回率为 89.26%,F1 值为 89.10%。高经纬等^[4]通过试验获得人体下肢姿态变化信号,利用决策树、随机森林、线性回归、支持向量机(support vector machine, SVM)等方法计算混淆矩阵以及精度分析,最终分析结果表明决策树相比于其他算法能够快速准确的判断出人体多种姿态变化。以上传统机器学习方法多依赖于人工特征工程,特征提取过程存在主观性,并且对动态变化和非平稳信号的适应性不足。

近年来,随着深度学习的发展,卷积神经网络(convolutional neural network, CNN)、循环神经网络(recurrent neural network, RNN)以及长短期记忆网络(long-and short-term memory networks, LSTM)被广泛用于端到端的步态识别。Kang 等^[5]从均方根误差分析的角度切入,利用卷积神经网络,将步态识别的均方根误差控制在 $5.04\% \pm 0.79\%$ 。Xia 等^[6]构建了 CNN-BiLSTM 模型,首先使用 CNN 提取步态特征,再通过双向长短期记忆网络提取序列化步态信息,最后通过 softmax 分类层实现步态分类识别,最终模型平均识别准确率比单一 LSTM 网络高 0.417%。尽管以上深度学习网络在特征自动提取方面表现优异,但也存在以下问题。首先,多数深度学习模型主要应用于图像或者文本,对一维时序数据的局部特征捕捉效率较低,并且存在冗余计算。其次,深度学习模型依赖大规模标注数据,而下肢外骨骼的应用场景繁杂,受试者个体差异显著,可获取的标注数据规模有限,传统深度学习模型的全连接层容易在小样本的条件下陷入过拟合。

基于上述研究现状,现有方法在一维信号的特征高效提取、小样本条件下步态分类的鲁棒性以及计算轻量化三方面存在不足,制约了下肢外骨骼步态识别的实用化进程。如何设计一种兼顾局部特征自适应学习与小样本泛化能力的轻量级模型,成为提升外骨骼系统性能的关键挑战。

针对以上问题,本文提出一种基于 1D-CNN-SVM 的混合模型,1D-CNN 直接解析原始时序数据,通过卷积核在时间维度的滑动自适应捕捉步态周期中的关键局部特征,摒弃了传统方法依赖人工特征的主观性局限。在此基础上,引入 SVM 替代传统全连接层,基于统计学理论的结构风险最小化原则,在小样本条件下构建最优超平面,可有效避免过拟合现象。此外,1D-CNN 相比传统 CNN 大幅降低

卷积参数,结合低计算复杂度的 SVM,使得整体模型更加轻量化。

1 1D-CNN 和 SVM 算法研究

1.1 一维卷积神经网络

一维卷积神经网络是一种模拟人脑的前馈神经网络,作为典型之一的深度学习方法,通常由输入层、卷积层、池化层、全连接层的输出层构成^[7]。输入层定义了输入的数据形状,便于模型其他部分的结构化设计,确保后续层可以正确接收和处理数据。卷积层一般由若干个卷积核组成,计算局部加权和,提取局部特征,并且可以在输入数据的不同部分共享权重。池化层的作用为减少数据的尺寸,保留其重要特征,从而降低计算复杂度,减小过拟合风险。最大池和平均池是最为常见的两种池化方法。全连接层主要作用为综合卷积层提取的局部特征,形成全局特征表示,并通过激活函数学习输入特征与输出标签之间的复杂映射关系。输出层生成最终预测结果,对于不同的问题采用不同的激活函数,如回归问题常用线性激活函数,分类问题常用 softmax 函数,1D-CNN 基本结构如图 1 所示。

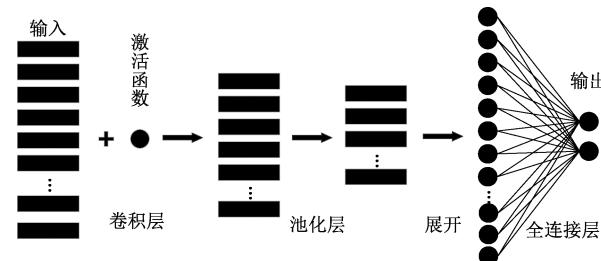


图 1 CNN 基本结构

Fig. 1 Basic structure of CNN

1D-CNN 卷积公式如式(1)所示。

$$y(t) = \sum_{i=0}^K x(t+i) \cdot \omega(i) \quad (1)$$

其中, $y(t)$ 是在时间步 t 的输出, $x(t)$ 是在时间步 t 的输入信息, $\omega(i)$ 是卷积核在位置 i 处的权重, K 是卷积核的大小。

1.2 支持向量机

支持向量机是一种监督学习模型,主要用于小样本下的分类问题^[8],由 Vapnik 在统计学习理论的基础上提出,主要用于解决分类和非线性函数估计问题,其主要目的是在多维空间中找到一个或者多个超平面把数据点分隔成不同的类,以最大化类间的边界。对于线性可分的数据,可以用直线或者超平面完全分开,使得各个类别的样本到超平面的最短距离最大化。对于非线性的数据,则需要通过引入核函数将数据映射到一个高维空间,在高维空间中将数据变成线性可分的数据,从而在高维空间中实现线性分割^[9]。

假设训练样本为 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$, 则

超平面可以表达为式(2):

$$\omega \cdot x + b = 0 \quad (2)$$

其中, x 为输入向量, ω 为权值向量, b 是阈值。

于是, 最大间隔问题可转化为优化问题, 目标函数如下:

$$\begin{cases} \min \frac{1}{2} \|\omega\|^2 \\ s.t. y_i(\omega \cdot x_i + b) \geq 1, \quad i = 1, 2, \dots, n \end{cases} \quad (3)$$

处理非线性的数据的方法是引入核函数, 常用的核函数如下:

1) 线性核函数

$$K(x, x_i) = x^T x_i \quad (4)$$

2) 多项式核函数

$$K(x, x_i) = (gx^T x_i + r)^d \quad (5)$$

其中, g 和 r 为核函数参数。

3) 高斯核函数

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (6)$$

其中, σ 为核函数参数。

4) Sigmoid 核函数

$$K(x, x_i) = \tanh(gx^T x_i + r) \quad (7)$$

核函数的选择对于 SVM 模型的正确准和识别速度有非常大的影响。为确定最合适的核函数, 实验时不指定核函数, 采用定义参数网格形式由模型选取准确率最高的核函数。

1.3 1D-CNN-SVM 模型

1D-CNN 的优势是具有强大特征提取能力, 能够自动学习数据中复杂的特征, 但是对于少量训练数据, 分类效果较差, 并且全连接层还可能出现过拟合的情况。SVM 对小样本和高维数据有很好的泛化能力, 能够在高维空间中找到最佳分离超平面, 分类效果好, 模型不容易过拟合, 但是对于原始的高维输入数据特征提取能力不足, 并且对噪声和非线性问题的处理需要依赖核函数选择。

因此, 在 1D-CNN 和 SVM 算法模型的基础上, 对其优点进行整合, 构建 1D-CNN-SVM 算法模型, 模型结构如图 2 所示。

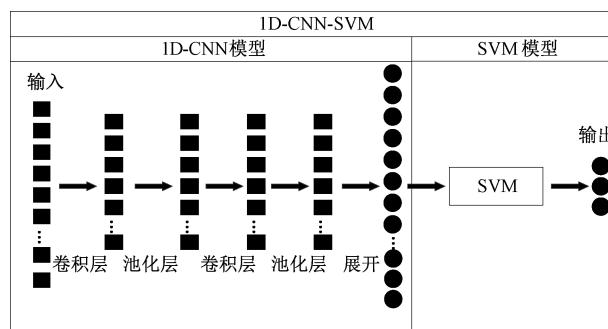


图 2 1D-CNN-SVM 模型结构

Fig. 2 Structure of 1D-CNN-SVM model

该模型结构分为 1D-CNN 和 SVM 两部分, 其中 1D-CNN 由 2 个卷积层和 2 个池化层构成, 相比于标准结构去掉了全连接层, 展开后直接导入 SVM 中进行分类训练。

2 数据处理及特征提取

2.1 确定信号源

人体在进行下肢运动时需要多块肌肉群的协同作用, 不同的步态发力肌肉群也不同, 为使采集的表面肌电(surface electromyography, EMG) 数据与步态强相关, 选取合适的肌肉就尤其关键。并且 sEMG 信号在一定程度上可作为分析肌肉疲劳状态的指标^[10]。根据研究可知, 人体在进行平地行走时, 腓肠肌与股直肌为最主要的肌肉, 股外肌、股中肌、股内肌收缩程度依次递减。上下坡或上下楼梯时, 主要发力肌肉为腓肠肌、胫骨前肌、股直肌、股二头肌, 其中腓肠肌和股直肌在不同坡度的试验过程中收缩最为敏感^[11]。腓肠肌位于小腿后侧肌群, 主要功能是辅助踝关节屈伸, 在下肢步态运动起到支撑蹬地的作用。股直肌位于大腿前侧肌群, 主要作用于膝关节的外伸和髋关节的屈曲^[12]。综合分析, 最终选定腓肠肌和股直肌作为信号采集肌肉, 肌肉位置如图 3 所示。

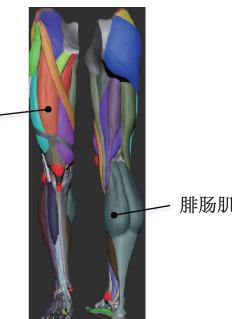


图 3 股直肌和腓肠肌示意图

Fig. 3 Schematic diagram of the rectus femoris and gastrocnemius muscles

在人体步态识别的信息源选择上, 膝关节角度可作为分析人体步态特征的依据^[13]。相比于其他惯性数据信息, 膝关节角度更为直观, 更容易理解和处理, 而且不容易被其他因素干扰, 能够获得较为精确的数据来表征当前的运动模式^[14]。膝关节角度采集方法如下: 用两个惯性数据采集器分别采集小腿和大腿的摆动角度信息, 再根据小腿和大腿的角度间接求出膝关节的角度, 具体计算方式如图 4 所示。

图 4 为人体下肢运动过程中可能会出现的两种下肢姿态, 其中 θ_1 为膝关节角度, θ_2 为小腿转动角度, θ_3 为大腿转动角度, θ_1 的两种情况计算公式如下:

$$\theta_{11} = 180^\circ - \theta_2 - \theta_3 \quad (8)$$

$$\theta_{12} = 180^\circ - \theta_2 + \theta_3 \quad (9)$$

2.2 数据预处理

在采集 sEMG 和惯性数据信息时, 因为噪声的来源很

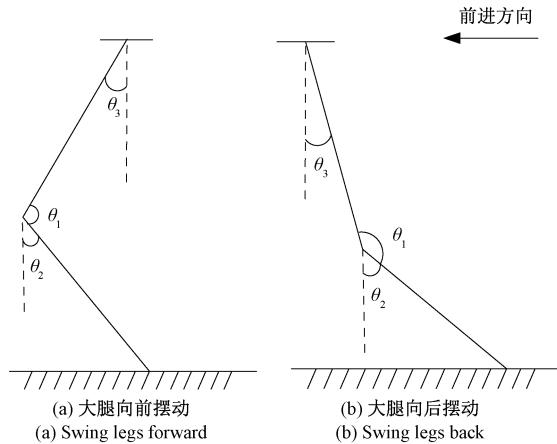


图 4 下肢各关节角度示意图

Fig. 4 Schematic diagram of the angles of the joints of the lower limbs

广,无法从源头上避免噪声,并且如果噪声过大甚至会对信息分析造成极大的影响。所以需对原始信息进行滤波处理。巴特沃斯滤波的优点是通频带频率响应曲线平坦限度最大、单调递减无波纹产生,阻频带频率响应曲线逐渐下降为零,这些优点使其在信息处理上有着广泛的应用^[15]。巴特沃斯低通滤波公式如下:

$$|H(j\omega)|^2 = A(\omega^2) = \frac{1}{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}} \quad (10)$$

式中: ω_c 为截止频率(Hz), n 为滤波器阶次。

1)sEMG 信息预处理

大量试验表明 sEMG 信息有意义的信息频段主要集中在 50~300 Hz^[16],因此设计四阶巴特沃斯带通滤波对 sEMG 原始信息进行滤波处理,截止频率设为 50~300 Hz。

滤波前后的 sEMG 信息如图 5 所示,其中图 5(a)为原始 sEMG 信息,图 5(b)为滤波后的 sEMG 信息。可以看到大量噪声已被去除,提高了信息质量,为后续数据处理工作打好了基础。

2)惯性数据预处理

在对人体下肢角度原始信息进行滤波处理前,需要对其进行傅里叶变换,绘制其频域信息的频谱图,查看其频域信息在频谱图上的分布,从而对其进行相应的滤波处理,原始数据频谱图如图 6 所示。

由图 6 可以得出人体下肢角度频域信息主要分布在 6 Hz 以下,所以设计四阶巴特沃斯低通滤波对人体下肢角度原始信息进行滤波处理,截止频率为 6 Hz。

滤波前后人体下肢角度信息如图 7 所示。

2.3 特征提取

目前特征参数的选择一般分为时域特征和频域特征,特征提取是进行步态识别检测的重要步骤,并且识别正确率和识别速度都与特征参数的选择有必然的联系。

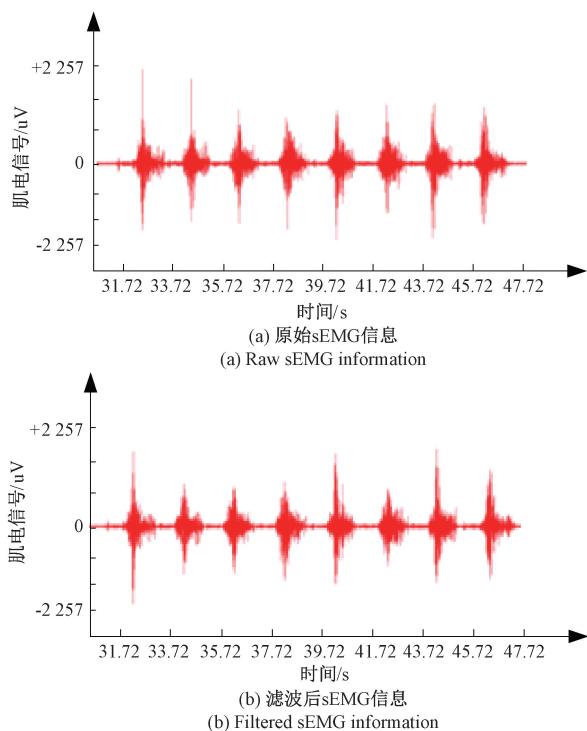


图 5 滤波前后 sEMG 信号

Fig. 5 sEMG signal before and after filtering

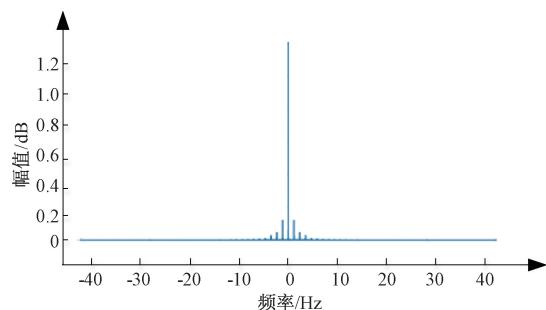


图 6 原始数据频谱图

Fig. 6 Spectrogram of raw data

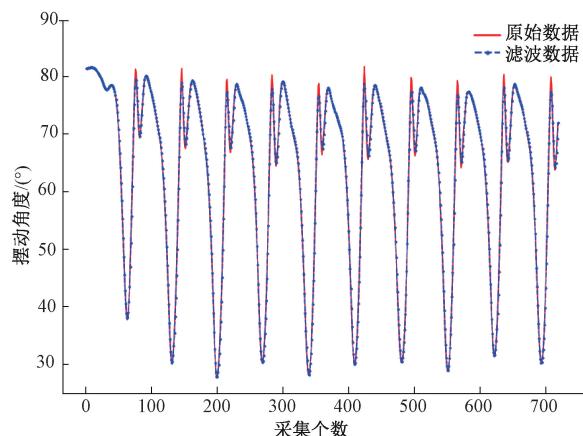


图 7 角度数据滤波前后对比

Fig. 7 Angle data filtering before and after comparison

1)时域特征提取

时域特征是指信息在时间上的表现,主要反映信息在时间轴上的变化情况。在膝关节角度信息和sEMG信息时域特征的选择上,除了均值、均方根、方差等这些常见的时域特征外,还根据其不同的信息特点选择了不同的时域特征值。膝关节角度信息额外选取了峰度和偏度作为特征值,sEMG信息额外选取了积分肌电值作为特征值,因为sEMG信息通常具有一定的非线性和随机性质,峰度和偏度可能会受到影响。

(1)均方根 RMS,可用来衡量信息的能量或幅度大小,数学表达式如下:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (11)$$

(2)方差 VAR,可用来衡量信息的离散程度,数学表达式如下:

$$VAR = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (12)$$

其中, \bar{x} 为每组信息的平均值。

(3)均值 MEAN,信息在一定时间段内的平均值,数学表达式如下:

$$MEAN = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (13)$$

其中,N 表示数据的总个数,n 表示数据当前的个数, $|x_n|$ 表示数据的绝对值。

(4)积分肌电值 IEMG,是 sEMG 信息在时间轴上的积分值,可用来表示肌肉活动总量,数学表达式如下:

$$IEMG = \int_{t_1}^{t_2} |x(t)| dt \quad (14)$$

其中, t_1 为起始时间, t_2 为截止时间。

(5)峰度 K,是描述数据分布尖锐程度的度量,反映了数据在均值附近的集中情况,数学表达式如下^[17]:

$$\hat{K} = \frac{\frac{1}{N} \sum_{i=1}^N (x(i) - \bar{x})^4}{\left(\frac{1}{N} \sum_{i=1}^N (x(i) - \bar{x})^2 \right)^2} \quad (15)$$

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x(i) \quad (16)$$

(6)偏度 S,是描述数据分布不对称性的度量,反映了分布的形状相对于正态分布的偏斜程度,数学表达式如下:

$$\hat{S} = \frac{\frac{1}{N} \sum_{i=1}^N (x(i) - \bar{x})^3}{\left(\frac{1}{N} \sum_{i=1}^N (x(i) - \bar{x})^2 \right)^{\frac{3}{2}}} \quad (17)$$

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x(i) \quad (18)$$

2)频域特征提取

频域特征是指信息在频率上的表现和特征,通过傅里叶变换将时域信息转换为频域信息,反映信息在不同频率

成分上的分布情况。频域特征中最常使用的为平均频率 MPF 和中值频率 MDF,故选取 MPF 和 MDF 为膝关节角度信息和 sEMG 信息的频域特征。

(1)平均频率 MPF,指的是信息在频谱中的能量按频率加权平均的频率,反映了信息在频率上的集中程度和分布情况。数学表达式如下:

$$MPF = \frac{\int_0^\infty f \cdot PSD(f) df}{\int_0^\infty PSD(f) df} \quad (19)$$

其中, f 为信息频率, $PSD(f)$ 为信息的功率谱密度函数。

(2)中值频率 MDF,是频谱中频率能量按大小排序后的中间值所对应的频率,可以用来衡量信息频谱的中心位置,数学表达式如下:

$$MDF = \frac{1}{2} \int_0^\infty PSD(f) df \quad (20)$$

2.4 归一化处理

数据归一化是将不同尺度的数据转换到相同尺度上的一种基于数学规则的数据处理方法,目的是为了确保特征之间具有可比性,避免某些特征在计算过程中占据主导地位,最终得到标准化、无量纲化的数据。

下面是数据归一化两种常用的方法:

1)min-max 标准化

该方法采用线性变换的方式,将原始数据映射到[0,1]区间内,数学表达式如下:

$$x' = \frac{x - \min}{\max - \min} \quad (21)$$

其中,min 为最小值,max 为最大值

2)Z-score 标准化

数学表达式如下:

$$x' = \frac{x - mean}{\sigma} \quad (22)$$

其中,mean 为平均值, σ 为标准差。

min-max 标准化方法在使用过程中,最大值和最小值非常容易受异常点的影响,这种方法鲁棒性较差,适合传统精确小数据场景。对于 Z-score 标准化方法而言,如果具有一定的数据量,少量的异常点对于平均值的影响并不大,进而对于方差的影响也不会大,所以选择 Z-score 作为归一化处理方法。

3 试验方法及结果分析

3.1 步态数据采集试验方案设计

试验由 10 名健康志愿者完成,其中 8 名男生、2 名女生,身高范围在(172±8)cm,年龄范围在(22±2)岁,体重范围在(55±10)kg,志愿者的身高均满足外骨骼样机调节范围,且试验前两个月内均没有受过任何肌肉和骨骼方面的损伤。sEMG 信息使用智芸薇无线肌电测试系统进行采

集,采集前需要通过专用肌电贴将肌电测试模块固定于股直肌和腓肠肌表面,并与无线信息接收器及配套软件结合使用。膝关节角度信息采集使用 Xsens DOT 精密运动追踪系统进行采集,使用时将信息传感器通过绑带固定在小腿和大腿处,分别输出小腿和大腿的姿态角。

志愿者需要在身穿下肢外骨骼的情况下采集进行平地行走、上楼梯和下楼梯 3 种步态模式下的步态信息,每人共采集 300 组步态周期数据,其中 3 种步态模式各 100 组,每采集 20 组数据休息 5 分钟避免肌肉疲劳。为降低因速度导致的步态差异性,保证志愿者步速一致,采用节拍器控制步速,最终共得到 3 000 组周期数据。3 种步态采集试验如图 8 所示。



图 8 3 种步态数据采集示意图

Fig. 8 Schematic diagram of three gait data acquisition

3.2 对比实验

为全面验证 1D-CNN-SVM 模型在自适应特征提取能力、小样本下的泛化能力以及计算效率方面的优越性,本文共设计了 4 组实验,1 组基准实验,3 组对比实验,实验设置如表 1 所示。实验数据来源于所采集的 sEMG 信号和膝关节角度信号,经过预处理后作为原始数据集。具体实验设计如下:

实验 1) 传统 SVM 模型。采用人工特征工程对原始数据集进行特征处理。通过滑动窗口对原始数据集进行特征提取,每次滑动提取窗口内数据的时域和频域特征,窗口大小为 1.2 s,步长为 0.6 s。对数据进行归一化,将归一化后的数据按照 4 : 1 的比例分为训练集和测试集,对训练集进行主成分分析,选择保留 95% 以上的主成分。构造 SVM 算法模型,选择高斯函数为核函数,惩罚参数 C 为 0.1,核函数参数 gamma 为 0.5。将训练集导入 SVM 模型中进行训练,并在测试集上进行验证。

实验 2) 1D-CNN 模型。不对原始数据进行人工特征工程,直接对原始数据进行归一化,将归一化后的数据按照 4 : 1 的比例分为训练集和测试集,训练集也不进行任何特征工程。构造 1D-CNN 算法模型,包含 2 个卷积层、2 个池化层、1 个 Dropout 层以及 2 个全连接层,设置学习率为 0.001,丢弃率为 0.5,激活函数为 ReLU,训练 500 个

epoch。将训练集导入 1D-CNN 模型训练,并在测试集上进行验证。

实验 3) 1D-CNN-LSTM 模型。不对原始数据集进行人工特征工程,将归一化后的数据按照 4 : 1 的比例分为训练集和测试集,训练集也不进行任何特征工程。构造 1D-CNN-LSTM 算法模型,包含 2 个卷积层、2 个池化层、2 个 LSTM 层、1 个 Dropout 层以及 2 个全连接层,设置学习率为 0.001,丢弃率为 0.5,激活函数为 ReLU,训练 500 个 epoch。将训练集导入 1D-CNN-LSTM 模型训练,并在测试集上进行验证。

实验 4) 1D-CNN-SVM 模型。不对原始数据集进行人工特征工程,将归一化后的数据按照 4 : 1 的比例分为训练集和测试集。构造 1D-CNN-SVM 算法模型,包含 2 个卷积层、2 个池化层、1 个展平层。将展平后的特征数据直接导入 SVM 模型中,SVM 模型参数与实验 1 的模型参数保持一致。将训练集导入 1D-CNN-SVM 模型训练,并在测试集上进行验证。

表 1 对比实验组别设置

Table 1 Comparison of experimental group setting

对比组别	实验组别	验证目标
A	1	1D-CNN 优越的特征提取能力
	4	
B	2	小样本下 SVM 步态识别的鲁棒性
	4	
C	3	1D-CNN-SVM 模型的轻量性
	4	

3.3 试验结果及分析

为充分了解各个模型在测试集上的性能,不仅要观察模型在测试集上的总识别率,还要分别观察模型对 3 种步态的单一识别率,以及模型的参数量和单样本推理时间。表 2 为各个模型在测试集上的识别结果。

表 2 各模型识别结果信息

Table 2 Information on the identification results of each model

名称	SVM	1D-CNN	1D-CNN-LSTM	1D-CNN-SVM
步态 0	100.00%	94.68%	100.00%	100%
步态 1	86.21%	90.38%	100.00%	100%
步态 2	92.92%	88.24%	98.17%	97.14%
总识别率/%	93.33	91.01	99.33	99.00
参数量	10 680	91 011	979 843	26 156
单样本推理时间/ms	0.07	0.10	0.35	0.06

由表 2 的结果可得出,对比组别 A 中,SVM 步态识别的总识别率为 93.33%,与 1D-CNN-SVM 总识别率相比降

低了5.67%，并且在步态1的识别率上SVM仅为86.21%，而1D-CNN-SVM达到了100%。这一差异表明，传统人工特征工程难以充分捕捉步态特征，而1D-CNN端到端的特征学习能力显著提升了模型的特征提取能力。

对比组别B中，1D-CNN-SVM模型总识别率较1D-CNN提高了7.99%，尤其在步态2的识别上，1D-CNN-SVM显著优于1D-CNN。依据实验结果可得出在小样本的条件下，SVM有效约束了决策边界，避免了1D-CNN全连接层可能导致的过拟合现象，具有更强的鲁棒性和泛化能力。

对比组别C中，1D-CNN-LSTM模型相比于1D-CNN-SVM模型参数量提高了37倍，但准确率仅提高0.33%，并且单样本推理时间提高了5.8倍。该结果表明，1D-CNN-SVM模型在不丢失识别精度的前提下，显著降低了模型复杂度和计算时间，证明了该模型在小样本数据量的前提下确实是一个具有较高识别率的轻量级模型。

4 结 论

本研究提出了一种基于1D-CNN-SVM的下肢外骨骼步态识别模型，通过一维卷积神经网络自动提取一维时序信号的局部特征，并结合支持向量机在小样本条件下实现高鲁棒性分类。实验结果表明：

1D-CNN-SVM总识别率达到了99.00%，相较于传统SVM提高了5.67%验证了端到端特征学习的优越性。

在步态2的识别中，1D-CNN-SVM显著优于单一1D-CNN，证明了SVM在小样本条件下的泛化能力。

1D-CNN-SVM的参数量和单样本推理时间均显著低于1D-CNN-LSTM，更满足嵌入式外骨骼系统的实时性要求。

综上所述，1D-CNN-SVM在特征自适应提取、小样本条件下的高鲁棒性以及计算效率之间实现了良好的平衡，为下肢外骨骼的步态识别提供了一种高效、可靠的解决方案。

参考文献

- [1] 孙晓强,于旭东.下肢外骨骼机器人步态识别系统综述[J].人工智能,2024(1):66-80.
- [2] SUN X Q, YU X D. A review of gait recognition systems for lower limb exoskeleton robots [J]. Artificial Intelligence, 2024,(1):66-80.
- [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.
- [4] FU M K, WANG SH H, MA CH. A study on gait phase recognition based on Densenet model [J]. Electronic Measurement Technology, 2025, 48 (1): 119-128.
- [5] 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.
- [6] 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.
- [7] 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.
- [8] KANG I, MOLINARO D D, DUGGAL S, et al. Real-time gait phase estimation for robotic hip exoskeleton control during multimodal loco-motion[J]. IEEE Robotics and Automation Letters, 2021, 6(2): 3491-3497.
- [9] XIA Y X, LI J Q, YANG D, et al. Gait phase classification of lower limb exoskeleton based on a compound network model [J]. Symmetry, 2023, 15(1): 163.
- [10] 李广帅,苏娟,李义红.基于改进Faster R-CNN的SAR图像飞机检测算法[J].北京航空航天大学学报,2021,47(1):159-168.
- [11] LI G SH, SU J, LI Y H. Aircraft detection algorithm for SAR images based on improved Faster R-CNN[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021,47(1):159-168.
- [12] 李俊卿,刘若尧,何玉灵,等.VMD和SO优化SVM的光纤复合海缆故障诊断研究[J].电子测量技术,2023,46(22):8-16.
- [13] LI J Q, LIU R Y, HE Y L, et al. Fault diagnosis study of fiber optic composite submarine cable with VMD and SO optimized SVM [J]. Electronic Measurement Technology, 2023, 46(22): 8-16.
- [14] KUMAR S D, ESAKKIRAJAN S, BAMA S, et al. A microcontroller based machine vision approach for tomato grading and sorting using SVM classifier [J]. Microprocessors and Microsystems, 2020, 76: 103090.
- [15] 姚贺龙,吕东澔,张勇,等.基于傅里叶分解方法的肌肉疲劳状态分类研究[J].电子测量与仪器学报,2023,37(6):48-58.
- [16] YAO H L, LYU D H, ZHANG Y, et al. A study on muscle fatigue state classification based on Fourier decomposition method [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (6): 48-58.
- [17] 马珮冬.人体负重行走过程中能量消耗和下肢肌肉用

- 力方式研究[D]. 北京:北京体育大学,2021.
- MA P D. Research on energy consumption and lower limb muscle exertion mode during human weight-bearing walking[D]. Beijing: Beijing Sport University, 2021.
- [12] MARTÍN-FUENTES I, OLIVA-LOZANO J M, MUYOR J M. Electromyographic activity in deadlift exercise and its variants. A systematic review [J]. PloS One, 2020, 15(2): e0229507.
- [13] 马越,丁浩. 人行走过程中膝关节角度特征研究[J]. 刑事技术,2019,44(4):322-326.
- MA Y, DING H. Research on the characteristics of knee joint angle during human walking [J]. Criminal Technology, 2019, 44(4): 322-326.
- [14] 曹雨冬,李慧,陈怡,等. 面向人体关节角度预测的运动意图识别方法研究[J]. 电子测量与仪器学报,2023, 37(6):22-30.
- CAO Y D, LI H, CHEN Y, et al. Research on motion intention recognition method for human joint angle prediction [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (6): 22-30.
- [15] 杨辉. 巴特沃斯低通滤波器的设计与仿真分析[J]. 电子产品世界,2022,29(12):79-81.
- YANG H. Design and simulation analysis of Butterworth low-pass filter [J]. Electronic Product World, 2022, 29(12): 79-81.
- [16] CHADA S, TARAN S, BAJAJ V. An efficient approach for physical actions classification using surface EMG signals[J]. Health Information Science and Systems, 2019, 8(1):3.
- [17] 谭哲雯,雷可君,杨喜,等. 一种基于偏度和峰度联合检测的频谱感知算法[J]. 吉首大学学报(自然科学版), 2023, 44(6):14-19.
- TAN ZH W, LEI K J, YANG X, et al. A spectrum sensing algorithm based on joint detection of skewness and kurtosis[J]. Journal of Jishou University(Natural Science Edition), 2023, 44(6): 14-19.

作者简介

崔占贺,硕士研究生,主要研究方向为机器人智能感知与控制。

E-mail:1458699403@qq.com

艾莉莎,副编审,主要研究方向为网络公共信息管理。

E-mail: ailisha@bupt.edu.cn

马欣雨,硕士研究生,主要研究方向为机器人智能感知与控制。

E-mail:3296753685@qq.com

田天齐,博士研究生,主要研究方向为智能感知与控制、多传感器信息融合。

E-mail: 939356103@qq.com

王松(通信作者),副教授,主要研究方向为群智感知、复杂系统、智能制造。

E-mail: wongsang@bupt.edu.cn