

DOI: 10.19650/j.cnki.cjsi.J2107986

基于足底压力传感器与深度学习的生物身份识别*

周丙涛, 陈世强, 程宇阳, 谭林立, 向 勉
(湖北民族大学新材料与机电工程学院 恩施 445000)

摘 要:近年来研究表明,足底压力可以反映人体的特征,在生物识别上具有广阔的前景。本研究探讨了足底压力进行身份识别的可行性和方法论。本文使用带有8个压力传感器的鞋垫收集了14名志愿者14 000多个压力数据作为数据集,利用无监督学习探讨了分类的科学性,并讨论了地面状况对于压力数据的影响。采用卷积神经网络(CNN)作为分类器,对分类性能进行了评价,研究了步态分割和多步态周期对提高精度的影响。实验结果表明,使用分割后的数据分类准确率为98.8%,而没有分割的为93.6%,当使用3个和5个步态周期进行分类时,准确率提升到99.4%和99.8%。结果表明,用CNN对分割后的数据并选择多个步态周期进行分类在利用足底压力进行身份识别方面具有良好实用价值。

关键词:生物识别;卷积神经网络;步态特征;足底压力

中图分类号: TH823 TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.2099

Biometric identification based on plantar pressure sensor and deep learning

Zhou Bingtao, Chen Shiqiang, Cheng Yuyang, Tan Linli, Xiang Mian

(School of Advanced Materials and Mechatronic Engineering, Hubei Minzu University, Enshi 445000, China)

Abstract: According to recent research, plantar pressure can reflect various characteristics of the human body, which is promising for biometric identification. In our study, the feasibility and methodology of biometric identification by plantar pressure is discussed. Insoles with eight pressure sensors are used to collect over 14 000 steps of 14 participant as database. After that, the scientificity of classification is discussed by unsupervised learning, and the influence of ground conditions on pressure data is discussed. Convolutional neural network (CNN) is used as the classifier to evaluate the classification performance, and the effects of gait segmentation and multiple gait cycles on improving the accuracy are studied. Experimental results show that the accuracy of data classification after segmentation is 98.8%, while that without segmentation is 93.6%. When using 3 and 5 gait cycles for classification, the accuracy rise up to 99.4% and 99.8%. The results suggest that CNN with segmented data and selecting multiple gait cycles for classification has practical value in biometric identification utilizing plantar pressure.

Keywords: biometric identification; convolutional neural networks; gait feature; plantar pressure

0 引 言

足底压力可以有效地反映人体足部的结构、力学特性、身体姿态和其他信息^[1-3],在医学、生物力学和人体工程学等领域有着广泛的应用^[4-12],一些研究表明,行走时足底压力的变化可以反映人体的健康状况或疾病康复情况^[13-15]。在运动学方面,足底压力被用于人体运动的分

析,例如,可以用来预测和评价人体在运动过程中的姿态,从而进行运动姿态纠正^[16]。

生物识别在日常生活中发挥着越来越重要的作用,如考勤管理、安全保护、社区服务、医疗、交通等。传统的生物特征识别包括指纹识别、人脸识别、指静脉识别、手掌静脉识别、虹膜识别、语音识别等。目前,基于步态的生物特征识别研究主要集中于对人体运动^[17]的视觉观察,而基于足底压力的研究较少,多集中于代数分析,而

收稿日期:2021-05-24 Received Date: 2021-05-24

* 基金项目:恩施州科技计划项目(2019001062)、湖北民族大学高水平科研成果校内培育项目(PY21022)、2021年大学生创新创业训练计划项目(X202110517262)资助

引入深度学习的研究较少。足底压力的分类可以从二分类到复杂的身份识别,分析方法也可以从数值分析到深度学习神经网络。

Munoz-Organero 等^[18]使用足底压力传感器来进行膝关节疼痛的早期临床诊断,他们的实验结果表明,当测试人员的重心从前脚掌移动到后脚跟时,膝盖疼痛的测试者的重心动态再分布与非疼痛的相比有较大差异。因此,步态压力可以反映膝关节的状况,通过步态压力数据可以进一步对测试者进行分类。同时 Munoz-Organero 等^[19]另一项研究也很类似,只使用了4个压力传感器,分类的对象是中风者。他们方法的设计基于全差量和 L1 distances,一共进行了14组实验,结果显示脚的4个部分(足弓、脚趾、脚掌和脚跟)对于重建足底压力模式很有意义。Pradhan 等^[20]提出了一种方法来衡量老年人是否容易摔倒,他们利用足底压力识别模型进行分类计算,该模型的最大正确率为92.93%,可用于临床应用。上述的这些研究依赖于数学分析,在一定的条件下是可靠的,同时也证明了足底压力可以有效地反映人的特征。Nguyen 等^[21]提出了一种对于行走场景进行分类的方法,即平地行走、下坡、上坡、下楼梯和上楼梯,他们让测试者穿着带有8个压力传感器的鞋子采集数据,在分析步长模式的基础上提出了3个新的特征来表征活动,并利用k-最近邻算法来进行分类,错误率只有2.16%。Jeong 等^[22]也做了相似的研究,不同的是他们的分类方法是多类支持向量机算法,最终准确率为95.2%。许多研究运用了更多的运动信息来提高模型的分类能力。比如 Luo 等^[23]利用足底压力信号和大腿肌肉表面肌电图识别不同速度和着陆条件下的运动姿态,他们使用多层感知器作为分类器,平均分类准确率接近90%。Choi 等^[24]提出了一种同时使用足底压力和加速度数据的方法,采用非线性判别分析技术对14名受试者3分钟的步行记录进行了分析,并将数据分割为单个步态周期,对数据进行矢量化、降维,最终达到95.00%的平均分类正确率。Yeh 等^[25]用类似的方法完成了身份识别,他们使用了朴素贝叶斯算法和支持向量机的高斯径向基函数,可以实现96.6%的识别准确率。Ivanov 等^[26]提出了一种利用卷积神经网络(convolutional neural networks, CNN)进行身份识别的方法,一共收集了59名参与者的数据样本,每个样本都包含左右步态特征向量,每个特征向量由9组足底压力和6组加速度数据组成,样本帧长度为500,他们的平均准确率为93.3%,在本文作者看来,他们的研究缺乏对步态周期进行分割。

在本文看来,步态周期的分割对生物特征识别有很大的帮助。虽然表面肌电、加速度等辅助信息对识别是有帮助的,但会提高穿戴设备的成本,同时穿戴设

备的尺寸也不得不扩大^[27-28]。为了解决这些问题,提高准确率,本文提出了一种将足底压力分析与深度学习相结合的方法,首先使用自制的足底压力采集系统来收集数据集,并对于人类步行的足底压力进行区域划分和切片研究,提取3组足底压力特征进行分类可行性的验证,并讨论了地面状况对于足底压力数据曲线的影响,最后建立了一个基于CNN的网络进行分类,讨论了数据分割的意义,提出了一种基于多步态周期的身份识别方法,以提高识别的准确性。

1 数据采集系统与预处理

本文使用了的带有8个电容压力传感器的鞋垫(LENSTAR, 中国)如图1所示。这8个压力传感器分布在足底的不同部位,分别是脚趾(1)、近节指骨(5)、侧弓(2,3,4)和足跟(6,7,8)。传感器嵌在鞋垫上方。数据采集系统选用8通道数字转换模块,型号为MY2901,国内设计生产(LENSTAR, China),采样频率为100 Hz。数据传输采用无线串口模块AS100DS(Ashining, China),串口波特率为115.2 kbps。




图1 鞋垫压力传感器

Fig. 1 Sensor insoles

研究一共有14名参与者,年龄在20岁到60岁之间,男女都有,脚码在39~42之间,参与者没有患任何影响行走的疾病。每个参与者被要求穿上有传感器鞋垫的鞋子,自然地行走100多步,数据采集系统收集了14 000多条压力信息,数据采集地点选择在平整的混凝土地面,地面光滑平整,质地坚硬,能够避免地面不平整或是柔软给分类识别结果带来的影响。为了探索地面状况对于足底压力采集的影响,本研究还采集了3组数据,分别是同一位参与者在混凝土地面、凹凸不平的运动场草坪和柔软的沙地上行走所采集的压力数据。本研究向所有参与者介绍了安全预防措施,并获得了每个参与者的同意。

2 足底压力数据分析

2.1 单步态循环的足底压力分析

一个完整的步态周期包括支撑周期和摆动周期^[12]。在摆动周期期间,足底压力的数据理论上应该为0,可以忽略不计。而在支撑周期,随着人体重心的移动,足底压力的分布也应该有规律地发生变化。图2是本文收集到的一个完整步态周期。




图2 单步态周期信号

Fig. 2 Single gait cycle signal

足底区域的划分遵循传感器鞋垫的设计,信号通道1的压力数据表示足趾区域,通道2、3、4、5表示前脚掌区域,通道6、7、8表示脚跟区域如图3所示。




图3 不同区域的足底压力数据

Fig. 3 Plantar pressure by divided areas

如图3所示,在摆动周期后,脚跟区的压力首先达到峰值。然后前脚掌的压力上升,脚跟区的压力急剧下降,人体重心从脚跟转移到前脚掌。然后,脚跟区的压力消退,前脚掌压力减小,足趾区域出现短暂的压力峰值,人体重心集中在脚尖。据此,支撑期可分为3个阶段如图4所示,落脚阶段、触地阶段和抬脚阶段。

基于上述步态周期分析,本文从单个步态周期中提取以下3个关于步态压力的特征:

1) 3个阶段的足底压力值,反映了人体的体重与重心分布特点。



图4 步态周期的三个阶段

Fig. 4 Phases of gait cycle

2) 3个阶段所占的比例,反映了人体行走的抬脚、落脚、触地的习惯以及脚底的结构。

3) 3个阶段之间的间隔,以压力急剧上升的点作为分界线来计算间隔,也可以反映人体行走的习惯。

以上3个特征反映了人体行走时的动态与静态特点,可以用来验证足底压力生物特征识别的可能性。

2.2 足底压力生物特征识别的可行性验证


本文利用摆动周期(压力接近0)对连续压力数据进行分段。根据分割数据,所有步态周期的帧数在45~70之间。为了消除参与者行走速度不同的影响,本文通过均匀采样将每个步态周期的帧数设置为45帧,最后选取了4名参与者提供的50个步态周期的数据来验证上述3个特征。采用K-means算法进行分类实验,选取高维欧氏距离作为失真函数,输入数据维数为3,分类数为4,判断公式如下:

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (1)$$

TP (true positive)表示被模型预测为正的样本数量, FP (false positive)表示被模型预测为负的样本的个数。 FN (false negative)表示被模型预测为正的负样本。 TN (true negative)表示被模型预测为负的正样本。实验结果如下:

1) 3个阶段的足底压力值

输入分类器的数据维数为3,表示3个区域的平均压力值如图5所示。






图 5 足底压力的分类结果

Fig. 5 Classification result of the plantar pressure

2) 3 个阶段所占的比例

输入分类器的数据维数为 3, 表示 3 个足底区域的波峰的宽度如图 6 所示。




图 6 阶段所占的比例的分类结果

Fig. 6 Classification result of the proportions of phases

3) 3 个阶段之间的间隔

输入分类器的数据维数为 3, 表示 3 个足底区域压力急剧上升之间的间隔帧数, 阶段之间间隔的分类结果如图 7 所示。




图 7 阶段之间间隔的分类结果

Fig. 7 Classification result of the interval between phases

以上实验数据如表 1 所示。

在上述实验中, 5 组数据的 F1-score 为 75.05%, 说明了个体足底压力存在差异而且可以进行有效分类。根据以上验证结果, 本文引入深度学习方法, 以提取更多有效的特征。一个步态周期的格式为 45×8 (每个步态周期包含 45 帧, 每帧包含 8 个压力值)。

表 1 不同特征的分类结果

Table 1 Performance for different features %

分类特征	准确率				
	No1	No2	No3	No4	平均值
足趾区压力	74	88	81	82	81.25
前脚掌区压力	72	68	80	76	74.00
脚跟区压力	78	81	86	81	81.50
阶段占比	67	68	75	71	70.25
阶段间隔	66	74	62	71	68.25

2.3 地面状况对于足底压力数据的影响

足底压力受到两个方面的影响, 一是脚底给传感器的向下的压力, 二是地面受到压力后的反馈。为探究地面的不平整度或柔软度对于足底压力的影响, 本研究采集了一组数据: 单个参与者在不同地面状况 (硬质混凝土地面、凹凸不平的运动场草坪、柔软的沙地) 下行走的足底压力数据, 以下 20 个步态周期的平均压力值曲线:

1) 硬质混凝土地面

如图 8 所示, 足底压力曲线符合前文的分析, 压力的大小由脚跟转移到前脚掌, 最后到脚趾, 可以明显从中观测出步态周期的 3 个阶段。




图 8 硬质混凝土地面的足底压力数据

Fig. 8 Plantar pressure on concrete floor

2) 凹凸不平的运动场草坪

如图 9 所示, 足底压力曲线受到了草坪的不平整度的影响, 压力不再呈现具有规律的 3 个阶段, 其主要原因是地面的不平整度在一定程度上影响了脚底对于压力传感器的作用。




图 9 运动场草坪的足底压力数据

Fig. 9 Plantar pressure on playground lawn

3) 柔软的沙地

如图 10 所示,足底压力曲线能够清晰地显示出步态周期的 3 个阶段,但由于受到柔软地面的影响,在落脚的阶段,脚跟压力还未消散时,前脚掌压力就已经上升,原因是柔软的沙地在压力作用下变形,对于鞋底形成了包裹,分散了脚跟的压力。




图 10 柔软沙地的足底压力数据

Fig. 10 Plantar pressure on soft sand

通过上述分析,地面的不平整度、硬度对于足底压力有较大影响,主要体现在改变了压力曲线的整体形态,在基于足底压力的身份识别中属于严重的干扰因素,固本研究采取恒定的地面条件,即坚硬、平整的混凝土地面来进行数据采集,完成对于身份识别的探讨。

3 基于足底压力的身份识别

在足底压力分类中,常用的深度学习分类器是 CNN^[26]。CNN 网络是图像识别中常用的网络,其最大的优点是能有效地提取图像中的关键特征。我们将步态信息表示为像素大小为 45×8 的图像,选用 4 个参与者,每人 50 个步态周期的数据取平均值,并用彩色图表示,结果如图 11 所示。




图 12 本文设计的 CNN 结构

Fig. 12 The proposed CNN architecture

Ivanov 等^[26]使用了和本文相似的方法,他们的输入维数设计为 500×30,并没有进行步态分割。为了验证数据分割的重要性,本文设计了一个比较组,使用维数为 45×8 的数据作为本文设计的 CNN 的输入,没有刻意地进行数据分割。

对于身份识别,识别方法也很重要。针对人体单步步态的偶发性,本文又提出了一种采用多个步态周期有




图 11 不同参与者 (a,b,c,d) 单周期压力图

Fig. 11 Single cycle pressure diagram of different participants (a, b, c, d)

如图 11 所示,可以得出结论,这 4 个参与者的身份信息可以通过图像进行区分,比如说 A 中的第 5 列像素, C 中的第 2 列像素与其他的明显不同,对于 CNN 来说,提取这些特征是非常容易的。

本文选择由 2 个卷积层、1 个 max-pooling 层、1 个 global average pooling 层和 2 个 Dense 层组成的 CNN 架构。输入向量的长度是 45×8 通道。特征提取块之后是一个具有 softmax 操作的全连接层,在 Dense 层之前添加 2 个 dropout 层作为正则化,以减少过拟合,损失函数采用 Ada-delta 优化器的交叉熵函数如图 12 所示。

效提高步态精度的方法,即使用 Mode(众数)来表示最终

$$F_C = \text{Mode}(F_{c1}:F_{cn}) \quad (2)$$

F_C 表示样本集 C 的分类结果,样本集 C 由样本 F_{c1} 到 F_{cn} 组成, $(F_{c1}:F_{cn})$ 表示它们的分类结果。在我们的研究中,设置了两组实验, n 分别为 3 和 5。

4 分类实验结果分析与展望

4.1 分类实验结果

实验所使用的数据集包含 14 个参与者共超过 14 000 个步态周期,将数据按 5:1 的比例分为训练集和测试集。学习率选用 0.005,每个批次 batch size = 10,训练 100 个 epochs,每个模型训练 5 次。结果表明,训练准确度在 20 epochs 时稳定下来。实验一共分为 4 组,分别为:CNN 训练分割后的数据、CNN 训练未分割的数据,以及引入多个步态周期来提升准确度的两组,多个步态周期的数量为 3 和 5。我们记录了模型在训练过程中训练集准确率(train_acc)和训练集 loss(train_loss)的变化。表 2 为统计检验结果,4 次实验的分类准确率,图 13 为表 2 的详细数据。图 14 显示了 train_acc 曲线,图 15 显示了 train_loss 曲线。

表 2 分类实验结果汇总

Table 2 Statistical testing of all experiments

No	分类模型	是否进行数据分割	分类步态周期数量	准确率%	标准差
1	CNN	是	1	93.6	0.197
2	CNN	否	1	98.8	0.004
3	CNN	是	3	99.4	0.003
4	CNN	是	5	99.8	0.002




图 13 分类准确率详细数据

Fig. 13 Detail data of statistical testing




图 14 训练集准确率演变曲线

Fig. 14 Train_acc curve




图 15 训练集 loss 演变曲线

Fig. 15 Train_loss curve

4.2 分类实验结果分析

从表 2 和图 13(a) 可以清楚地看出,进行数据分割后准确率比分割前提高了 5.2%,并且从图 14、15 可以看出,模型收敛速度也更快。步态压力的分割对于分类准确率很有帮助。如表 2 和图 13(b) 所示的数据,用于分类的样本集数量也很重要,随着数量的增加准确率有大幅度上升的趋势,当数量为 5 的情况下,准确率提高到 99.8%。

表 3 显示了本文的研究结果与近年来其他研究结果的对比。结果表明,在最简单的硬件条件和最小的数据维数下,本文的研究获得了最高的精度。和 Choi 等^[24] 的实验对比,我们的优势主要体现在数据处理模型上。Choi 等^[24] 的方法是将多模型特征向量输入分类器进行分类,显然分类能力不如深度学习。与 Ivanov 等^[26] 的实验相比,我们的主要优势是步态的分割,尽管 CNN 是能够从复杂的高维数据中提取有用的信息,但也需要更多的神经元和更多的训练周期,这就增加了时间和对硬件的需求。最后,选择多个数量的分类样本也可以大大提高识别的准确性,在模型和数据库条件相同的情况下,该方法的选择对实际推广非常有帮助。

4.3 展望

生物特征识别的有效性取决于两个方面,一是需要获得足够的生物特征信息,二是数据处理工具的能力,足

表 3 近年研究对比

Table 3 Comparison of recent studies

研究	传感器情况	模型	数据结构	样本数	准确率/%
本文研究	压力传感器 8 个	CNN	分割后 45×8	5	99.8
本文研究	压力传感器 8 个	CNN	分割后 45×8	1	98.8
文献[24]	压力传感器 8 个 加速度计 3 个	NLDA	分割后 63×16	1	95.0
文献[26]	压力传感器 9 个 加速度计 6 个	CNN	未分割后 30×500	1	92.9

底压力生物特征识别的准确性和效率也是基于这两个方面。

我们研究中使用的鞋垫包含 8 个压力传感器,一个样本的帧数为 45。8 个压力传感器只能大致展现脚底压力的分布,脚底的形状、骨骼结构因人而异,要体现这些数据,应使用更敏感、数量更多的传感器。同时,单个步态周期中帧数的增加也会提高最终的分类精度,这就需要更先进的硬件条件、更高频率的数据采集系统和更高传输速度的传输系统。同时对信息精细化的过度追求也使可穿戴设备的成本增加,这些都是需要综合考虑的结果。

从研究中知道,使用相同的数据,简单 K-means 分类器和 CNN 的结果有显著差异。神经网络在信息提取中起着重要作用。使用更好的神经网络也是一种前景,例如 CNN 可以提取单个足底压力等值线图的信息,然后以帧的形式输入到 LSTM(long short-term memory)中。神经网络的训练也是非常重要的,尤其是对于像 CNN 这样的深度学习网络,训练数据量也决定了最终模型的准确性,如果可以减少传输系统的能源消耗,结合手机的云数据,则可以收集到大量的足底压力数据。

在我们的研究中也证明了选择多个数量的分类样本可以提高分类精度,则连续实时的步态检测具有很大的前景,可以想象随着步态周期的增加,识别的准确性会不断提高。

5 结 论

本文研究了基于足底压力的步态信息在身份识别中的有效性。首先使用带有 8 个压力传感器的鞋垫,为 14 名参与者收集了超过 14 000 步作为数据集。然后对每个步态周期的数据进行分析 and 分割。然后将分离出来的数据采样为单个周期 45 帧,通过非监督学习验证了足底压力信息用于身份识别的可能性,并讨论了地面状况对于足底压力数据的影响。最后评估了常用的神经网络结构 CNN 的分类性能,研究了数据分割对识别精度的影

响,探讨了多步态周期对提高识别精度的能力的影响。结果表明,采用多步态周期对于分割后的数据使用 CNN 进行分类是一种基于很好的分类选择。

参考文献

- [1] CASTRO F, SAVARIS W, ARAUJO R, et al. Plantar pressure measurement system with improved isolated drive feedback circuit and ANN: Development and characterization [J]. IEEE Sensors Journal, 2020, 20(19): 11034-11043.
- [2] MEI Q, GU Y, XIANG L, et al. Foot shape and plantar pressure relationships in shod and barefoot populations[J]. Biomechanics and modeling in mechanobiology, 2019, 19: 1211-1224.
- [3] QAISER Z, FARAZ A, JOHNSON S. Feasibility study of a rapid evaluate and adjust device (READ) for custom foot orthoses prescription[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(2): 1760-1770.
- [4] 贾晓辉, 王涛, 刘今越, 等. 基于人体模型映射的步态识别及意图感知方法[J]. 仪器仪表学报, 2020, 41(12): 236-244.
JIA X H, WANG T, LIU J Y, et al. Gait recognition and intention perception method based on human body model mapping[J]. Chinese Journal of Scientific Instrument, 2020, 41(12): 236-244.
- [5] WANG L, JONES D, CHAPMAN G J, et al. A review of wearable sensor systems to monitor plantar loading in the assessment of diabetic foot ulcers [J]. IEEE Transactions on Biomedical Engineering, 2020, 67(7): 1989-2004.
- [6] BELVEDERE C, GIACOMOZZI C, CARRARA C, et al. Correlations between weight-bearing 3D bone architecture and dynamic plantar pressure measurements in the diabetic foot[J]. Journal of Foot and Ankle Research, 2020, 13(1): 1-11.
- [7] ZHENG J, CAO H, CHEN D, et al. Designing deep reinforcement learning systems for musculoskeletal modeling and locomotion analysis using wearable sensor feedback[J]. IEEE Sensors Journal, 2020, 20(16): 9274-9282.
- [8] HEGDE N, BRIES M, SWIBAS T, et al. Automatic recognition of activities of daily living utilizing insole-based and wrist-worn wearable sensors[J]. IEEE Journal of Biomedical and Health Informatics, 2018, 22(4): 979-988.
- [9] HUA R, WANG Y. A customized convolutional neural network model integrated with acceleration-based smart insole toward personalized foot gesture recognition[J].

- IEEE Sensors Letters, 2020, 4(4): 2475-1472.
- [10] SI W, YANG G, XIANG G C, et al. Gait identification using fractal analysis and support vector machine [J]. Soft Computing, 2018, 23(19): 9287-9297.
- [11] MERRY K J, et al. Classifying sitting, standing, and walking using plantar force data [J]. Medical & Biological Engineering & Computing, 2021, 59: 257-270.
- [12] YANG G, TAN W, JIN H, et al. Review wearable sensing system for gait recognition [J]. Cluster Computing, 2018, 22(2): 3021-3029.
- [13] REFAI M I M, VAN BEIJNUM B J F, BUURKE J H, et al. Gait and dynamic balance sensing using wearable foot sensors [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(2): 218-227.
- [14] CHEN H, CAO L, LI Z, et al. Evaluation on diabetic plantar pressure data-set employing auto-segmentation technologies [J]. Neural Computing and Applications, 2018, 32: 11041-11054.
- [15] DOMINGUES M F, ALBERTO N, LEITAO C J, et al. Insole optical fiber sensor architecture for remote gait analysis— an e-health solution [J]. IEEE Internet of Things Journal, 2019, 6(1): 207-214.
- [16] DING M, NAGASHIMA M, CHO S G, et al. Control of walking assist exoskeleton with time-delay based on the prediction of plantar force [J]. IEEE Access, 2020, 8: 138642-138651.
- [17] SINGH J P, JAIN S, ARORA S, et al. Vision-based gait recognition: A survey [J]. IEEE Access, 2018, 6: 70497-70527.
- [18] MUNOZ-ORGANERO M, LITTLEWOOD C, PARKER J et al. Identification of walking strategies of people with osteoarthritis of the knee using insole pressure sensors [J]. IEEE Sensors Journal, 2017, 17(12): 3909-3920.
- [19] MUNOZ-ORGANERO M, PARKER J, POWELL L, et al. Sensor optimization in smart insoles for post-stroke gait asymmetries using total variation and L1 distances [J]. IEEE Sensors Journal, 2017, 17(10): 3142-3151.
- [20] PRADHAN A, KURUGANTI U, CHESTER V. Biomechanical parameters and clinical assessment scores for identifying elderly fallers based on balance and dynamic tasks [J]. IEEE Access, 2020, 8: 193532-193543.
- [21] NGUYEN NC, BUI DT, PHUC HT, et al. Classification of five ambulatory activities regarding stair and incline walking using smart shoes [J]. IEEE Sensors Journal, 2018, 18(13): 5422-5428.
- [22] JEONG G M, TRUONG P H, CHOI S I. Classification of three types of walking activities regarding stairs using plantar pressure sensors [J]. IEEE Sensors Journal, 2017, 17(9): 2638-2639.
- [23] LUO R, SUN S, ZHANG X, TANG Z, et al. A low-cost end-to-end sEMG-based gait sub-phase recognition system [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(1): 267-276.
- [24] CHOI S I, MOON J, PARK H C. User identification from gait analysis using multi-modal sensors in smart insole [J]. Sensors, 2019, 19: 3785.
- [25] YEH K H, SU C, CHIU W, et al. I walk therefore i am: Continuous user authentication with plantar biometrics [J]. IEEE Commun. Mag. 2018, 56(2): 150-157.
- [26] IVANOV K, MEI Z, PENEV M, et al. Identity recognition by walking outdoors using multimodal sensor insoles [J]. IEEE Access, 2020, 8: 150797-150807.
- [27] ANWARY M A R, YU H, VASSALLO M. Gait evaluation using procrustes and euclidean distance matrix analysis [J]. IEEE Journal of Biomedical and Health Informatics, 2020, 23(5): 2021-2029.
- [28] JARCHI D, POPE J, LEE T K M, et al. A review on accelerometry based gait analysis and emerging clinical applications [J]. IEEE Reviews in Biomedical Engineering, 2018, 29(11): 177-194.

作者简介



周丙涛(通信作者), 2014 年于武汉工程大学获得学士学位, 2016 年于华中科技大学获得硕士学位, 现为湖北民族大学助教, 主要研究方向为人工智能和智能装备研究。
E-mail: zbt_hbmzu@163.com

Zhou Bingtao (Corresponding author) received his B. Sc. degree from Wuhan Institute of Technology in 2014, and received his M. Sc. degree from Huazhong University of Science and Technology in 2016. He is currently an assistant at Hubei Minzu University. His main research interests include artificial intelligence and intelligent equipment.