

DOI: 10.19650/j.cnki.cjsi.J2514102

结合递归图与 LeNet 网络的足底压力身份识别方法*

袁田, 辛义忠

(沈阳工业大学信息科学与工程学院 沈阳 110142)

摘要:针对身份识别领域足底压力采集设备在传感器数量和位置配置方面存在的差异性,以及足底压力特征通常依赖于对步态周期数据进行完整分割所带来的时间成本增加问题,提出一种基于足底压力信号的无阈值递归图和 LeNet 网络的身份识别方法。首先使用自制足底压力采集设备,在常规混凝土地面采集 28 名无足部及下肢疾病的健康成年参与者无负重等干扰状态自然行走过程中的足底压力数据;再经数据重构算法对足底压力数据进行预处理,将其转化为无阈值递归图;最后将生成的图像作为 LeNet 网络的输入,完成特征提取与身份识别,并对单一区域及多区域组合方案的结果进行分析比较。实验结果表明,足跟内侧区域、足跟外侧区域、第二跖骨区域和大脚趾区域的组合身份识别性能以最少的传感器数量和高识别精度优于其他方案,其中准确率、精确率、召回率和 F_1 分数分别达到 99.25%、99.22%、99.39%、99.26%。不同区域的身份识别性能受行走过程中不同阶段和受力大小的影响,但随着区域数量的增加,该影响逐渐减弱。此外,实验结果还显示,使用足底压力信号的无阈值递归图进行身份识别的方法无需依赖严格的步态分割,依然能够保持较高的识别精度。为身份识别技术在生物特征识别领域的应用提供了新的思路与技术支持,在公共安全等领域具有潜在的应用价值。

关键词: 足底压力特征;无阈值递归图;LeNet 网络;身份识别

中图分类号: TH701 TP391 **文献标识码:** A **国家标准学科分类代码:** 510.40

Plantar pressure-based identity recognition method combining recurrent plot and LeNet network

Yuan Tian, Xin Yizhong

(School of Information Science and Engineering, Shenyang University of Technology, Shenyang 110142, China)

Abstract: Aiming at the variability in the number and positional configuration of sensors in plantar pressure acquisition devices within the field of identity recognition, as well as the issue of increased time cost arising from the conventional reliance on complete segmentation of gait cycle data for extracting plantar pressure features, this article proposes an identity recognition method based on threshold-free recurrence plots of plantar pressure signals and the LeNet neural network. Plantar pressure data are collected during natural, unloaded walking from 28 healthy adult participants without foot or lower limb pathologies. Data acquisition occurs on a standardized concrete surface using a custom-designed plantar pressure measurement system. The raw plantar pressure data are preprocessed using a data reconstruction algorithm to directly convert them into threshold-free recurrence plots. These generated images are then used as input to the LeNet network for feature extraction and identity recognition. Recognition performance across various single-region and multi-region configurations is systematically analyzed and compared. Experimental results show that the optimal configuration—combining the medial heel, lateral heel, second metatarsal head, and hallux regions—achieved superior identity recognition performance with minimal sensor deployment and high accuracy. Specifically, accuracy, precision, recall and F_1 -score attained 99.25%, 99.22%, 99.39%, and 99.26%, respectively. Recognition performance tends to be influenced by gait phase and plantar pressure magnitude. However, this effect progressively diminishes with increasing number of integrated regions. Furthermore, the proposed method maintains high recognition accuracy without requiring rigorous gait segmentation. It provides new ideas and technical support for the application of identity recognition technology in the field of biometric identification, and has potential application value in public safety and

收稿日期:2025-05-31 Received Date: 2025-05-31

* 基金项目:辽阳市“辽阳英才计划”“带土移植”创新团队项目(LYYC220501)资助

other fields.

Keywords: plantar pressure characteristics; threshold-free recurrence plot; LeNet network; identity recognition

0 引言

足底压力特征由于其非入侵、难以被伪造等特点在身份识别领域逐渐获得关注^[1]。传统的足底压力采集设备,如测力板和电子足印图,虽有一定效用,但难以满足自然日常环境下的实时连续监测需求。因此,研究人员转向可穿戴式足底压力测量设备,以期在自然环境中实现足底压力数据的采集^[2]。

检索的文献中,Huang等^[3]使用可穿戴设备收集了行走过程中左脚的足跟内侧、足跟外侧、第一跖骨和第五跖骨等4个足底区域的足底压力数据。记录了4个完整周期的足底压力数据,并将这些数据应用于身份识别的研究中。Feng等^[4]则利用每只脚配备32个压力传感器的可穿戴设备,采集了覆盖两只脚的足底压力数据。随后,每只脚从中选取压力值最大的8个区域,并提取其在一个完整步态周期内的足底压力数据作为特征输入,采用支持向量机方法进行身份识别。此外,进一步分析了不同行走速度对识别结果的影响,以评估模型的鲁棒性。Yeh等^[5]通过6个压力传感器采集了右脚的足底压力数据,这些传感器分别覆盖了大脚趾、第一跖骨、第五跖骨、足外侧缘、足跟内侧和足跟外侧6个足底压力区域。在此基础上,提出了一种新颖的持续身份验证方法。该方法分为2个阶段:第1阶段采用原始数据分析流程,结合目标用户和其他用户的数据集构建分类器;第2阶段则基于第1阶段中识别出的相对优越的特征进行身份验证。该方法提高了识别准确率。Choi等^[6]使用16个压力传感器分别采集了两只脚的足底压力数据,采集部位包括大脚趾、大脚趾趾骨与第一跖骨的连接处、第一跖骨、小脚趾趾骨与第五跖骨的连接处、第五跖骨、足外侧缘上方、足跟内侧以及足跟外侧。同时,两只脚还分别使用了一个加速度计进行运动测量。分别基于一个步态周期中的足底压力数据、三轴加速度数据以及两种方式结合的数据进行分析。研究表明,单独使用足底压力数据的识别效果优于单独使用三轴加速度数据的效果,而通过结合两种数据的多模态方法能够显著提高身份识别的准确性。文献^[7]提出了利用每只脚配备9个压力传感器的方法,用于测量行走时覆盖大脚趾、5个跖骨、足外侧缘、足跟内侧和足跟外侧9个区域的足底压力数据。采集了包含一个步态周期的足底压力数据,并基于两只脚的压力数据进行身份识别。通过对比分析左脚、右脚以及两只脚融合数据的识别效果,发现基于单只脚压力数据的识别效果优于融合两只脚数据的结果。这一

发现对优化足底压力数据的特征选择和应用策略具有重要意义。周丙涛等^[8]利用带有8个压力传感器的鞋垫收集了行走过程中一只脚的足底压力数据,这些区域包括大脚趾、第一跖骨、第二跖骨、第四跖骨、足外侧缘上方、足跟内上侧、足跟外上侧及足跟。重点探讨了不同数量步态周期的数据对基于压力数据实现身份识别的影响。结果表明,使用包含3个和5个步态周期的数据较单一步态周期数据能够显著提高身份识别的准确率。Truong等^[9]使用了与文献^[6]中相同的可穿戴设备,收集了行走、上楼梯和下楼梯3种活动中的足底压力数据。在此基础上,提出了一种新颖的基于时间的特征提取方法,以生成新的手工特征用于身份识别和活动识别。此外,还探讨了步态周期数量增加对识别结果的影响。实验结果显示,随着步态周期数量的增加,身份识别和活动识别的准确率均显著提升。Chen等^[10]使用7个压力传感器,分别收集了行走时大脚趾、第四脚趾、第二跖骨、足中部、足跟上侧、足跟内侧和足跟外侧的足底压力数据。并计算了一个完整步态周期内足底压力的最大值、平均值和总和,将这些作为特征,使用支持向量机算法来检测步态周期内的相位。González等^[11]则运用了8个压力传感器,分别置于两只脚的大脚趾、第一跖骨、足外侧缘及足跟部位,收集7个完整步态周期的足底压力信息。计算步态周期内各相位的平均时长及其标准差,以此作为识别步态周期内不同相位的方法。Wang等^[12]在每只脚上分别使用4个压力传感器采集足跟区域、4个传感器采集跖骨区域以及2个传感器采集脚趾区域上下楼梯时的足底压力数据。选取了包括足跟触地时的峰值压力、脚趾离地时的峰值压力、足跟触底与脚趾离地时的峰值压力差、以及足跟触底与脚趾离地的时间差等在内的12个特征,并运用KNN算法进行分类。研究表明,该方法在识别上下楼梯活动中具有有效性。Li等^[13]采用装备有102个压力传感器的智能鞋垫,该鞋垫设计覆盖全足底,用于分别捕获两只脚在执行不同活动时产生的足底压力数据,并据此进行活动识别分析。孙东杰等^[14]研制了一种基于触觉传感阵列系统,每只脚有48个传感单元,提出基于支持向量机的动态足底压力分布分析方法用于异常状态预警。周丙涛等^[15]使用与文献^[8]相同的可穿戴设备用于不规范深蹲姿势识别研究,提出基于间歇稳态数据的连续压力数据分割方法,解决连续蹲姿数据的分割问题。席旭刚等^[16]将2个压力传感器置于足跟与前脚掌中心位置采集足底压力信号,联合腓肠肌肌电信号用于跌倒检测。解决单一信号识别率低的问题。孙巍伟等^[17]研制了一种足底压力采集设

备,其位置选择与文献[8]一致,用于跌倒检测。提出的云边协同判别方法提升检测精度。贾晓辉等^[18]设计了含32行16列共512个电容测力单元的高分辨率足底压力采集系统,提出基于人体模型映射与卷积神经网络的步态识别及意图感知方法,建立数据映射关系与数据库,实现对多种步态及状态的识别。

综上所述,尽管可穿戴式足底压力测量设备在利用足底压力特征进行生物特征分析领域已取得一定进展,但其设计仍存在一定的局限性。通过检索文献发现,多数研究所采用的可穿戴设备中,压力传感器的数量与位置配置呈现研究间的差异性。即便传感器数量相同,其布局也存在差异。这种差异引发了一个关键问题,即传感器位置的选择是否显著影响身份识别性能,以及如何在传感器数量、布局位置与性能间寻求最优配置仍是当前待解决的问题之一。此外,现有研究通常以完整步态周期的数据作为分析基础。这种方法需要额外的步骤对连续的足底压力数据进行相位分割,以提取完整的步态周期数据,再进行后续处理。这一额外的数据预处理过程增加了研究的复杂性,也进一步突显了对更高效特征提取方法的需求。

足底压力身份识别技术在安防、医疗等领域具有重要的应用价值。以常规地面、无干扰条件下的识别效能为研究对象,为该技术在安防领域工程化落地提供基础性验证。

为此,本研究提出了一种基于无阈值递归图和LeNet网络的身份识别方法,该方法无需依赖完整步态周期数据的提取。同时,系统地分析了不同足底压力区域及其组合对身份识别性能的影响,为后续相关研究提供了理论依据和方法指导。

1 足底压力特征提取

1.1 数据采集

尽管基于足底压力进行生物特征分析领域的研究已取得一定进展,但公开数据集仍存在一定局限性。这些数据集集中在临床诊断^[19]和活动识别^[20]的领域。考虑到当前身份识别领域缺乏有效且公开的足底压力数据集,为了分析不同压力区域对身份识别的性能的影响,采用自制足底压力采集设备来进行数据采集。

自制足底压力采集设备参考了Xin等^[21]的设计,包括数据采集单元、供电单元、控制单元和蓝牙单元。考虑到Flexi Force A301压力传感器体积小、轻薄、以及高线性度的特点,数据采集单元使用Flexi Force A301压力传感器,其实物图如图1所示。

该传感器主要技术参数为:最大承载量程为445 N;有效测量区域直径达9.53 mm;响应时间 $<5 \mu\text{s}$;使用寿



图1 Flexi Force A301压力传感器实物

Fig. 1 Physical image of Flexi Force A301 pressure sensor

命超过十万次循环;且具备良好的测量重复性。输出电压 V_{out} 是由参考电压 $V_{ref-3.3}$ 和参考电阻 R_{ref} 决定的,其表示如式(1)所示。

$$V_{out} = -V_{ref-3.3} \cdot (R_{ref}/R_s) \quad (1)$$

式中: $V_{ref-3.3}$ 选取为 -3.3 V ; R_{ref} 为 $68 \text{ k}\Omega$ 。

采集设备的供电单元使用RT9167与4056芯片,确保稳定续航。控制单元以STM32F103C8T6为核心,通过调理电路实现8路传感器信号的放大与模数转换,经专用ADC通道同步采样。蓝牙单元使用HM-11 S BLE模块,通过HM-10虚拟串口与上位机连接实现无线通信。整体设计满足可穿戴便携性及测量需求,该采集设备实物图如图2所示。




图2 足底压力采集设备实物

Fig. 2 Physical image of plantar pressure acquisition device

Li等^[22]关于可穿戴步态识别系统的综述中描述了行走过程中足底压力主要分布,如图3所示。

为了深入研究各个压力区域在身份识别中的性能,将足底压力主要受力区域划分为8个不同的区域。考虑到个体足部在尺寸与形态上存在的差异,采用基于足底骨骼解剖结构的原则进行区域划分:区域1覆盖大脚趾区域,区域2对应第一跖骨分布范围,区域3覆盖第二跖骨对应区域,区域4对应第四跖骨所在位置,区域5位于



图3 足底压力主要分布区域

Fig. 3 Main distribution areas of plantar pressure

足外侧缘上方区域,区域6位于足外侧缘下方区域,区域7位于足跟外侧区域,区域8位于足跟内侧区域,如图4(a)所示。在数据采集阶段,要求参与者保持自然站立姿态于水平测试面,依据预定的骨骼结构定位方案确定各传感器精确位置如图4(b)所示,经固定校准后进行数据采集如图4(c)所示。

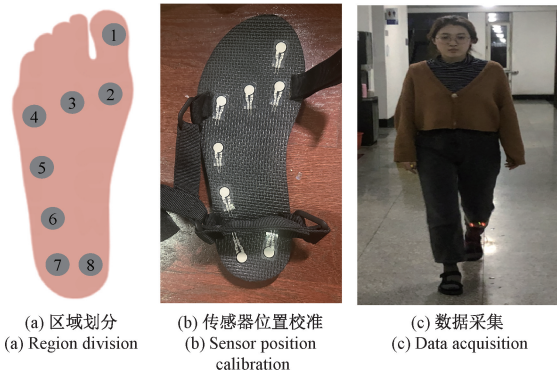


图4 区域划分及实验相关图示总览

Fig. 4 An overview of diagrams related to skeletal structure localization and experiments

1.2 足底压力信号无阈值递归图

递归图^[23]作为一种重要的分析工具,在时间序列信号的研究领域得到了广泛应用^[24]。该方法通过展示时间序列信号的内部自相关性,能够有效揭示信号的周期性、混沌性以及非平稳性等特征。在相关研究中,递归图常被用来深入分析信号的动态行为及其演化规律。鉴于研究对象为足底压力信号数据,这类数据属于典型的时间序列信号,因此选取递归图作为研究方法具有较强的针对性和适用性。

递归图的构建过程包括相空间重构和递归判据的处理。首先,对时间序列信号进行相空间重构,将其映射为

相点在高维空间中的分布。考虑一个由经过相空间重构的时间序列信号组成的集合 $\{X_i\}_{i=1}^n$ 。对于集合中的任意两个相点 X_i 和 X_j ,如果它们之间的距离小于给定阈值 ε ,则表示这两个点的状态非常接近,即运动状态出现递归,也称为两相点出现递归。若在矩阵 M 上记录这些递归的位置,则将出现递归的点赋值为1,并在图像上用黑色像素点表示。反之,如果两点之间未出现递归,则在矩阵 M 上赋值为0,并在图像上用白色像素点表示。这种需要给定阈值的递归图称为有阈值递归图。

无阈值递归图与有阈值递归图有所不同。无阈值递归图通过直接将不同相点之间的距离信息以明暗程度差异的形式可视化,因此更全面地保留了原始数据的信息。这种方法有效避免了依赖经验性阈值所可能导致的信息丢失问题,提升了特征提取的准确性与综合性。同时,由于保留了更丰富的信息,后续模型的训练能够从更高质量的输入数据中受益,有望实现更优的性能表现。基于以上优势,无阈值递归图能够清晰地呈现出足底压力信号在不同时间点上的变化和趋势。这种转换不仅保留了信号中的关键信息,还使得信号的特征更加直观和易于提取。因此,在递归图的转换过程中使用无阈值递归图的生成方法,以优化特征表示与模型性能。

假设一个经过相空间重构的时间序列信号集合 $\{X_i\}_{i=1}^n$,为了构建无阈值递归图,距离矩阵 D 中 $D_{i,j}$ 表示相空间内 X_i 和 X_j 两点间的距离。

然后,将距离矩阵 D 归一化到 $[0, 1]$ 的范围,得到归一化距离矩阵 N ,其元素表示如式(2)所示。

$$N(i,j) = \frac{D(i,j)}{\max(D)} \quad (2)$$

其中, $\max(D)$ 是距离矩阵 D 中的最大距离。

接下来,将归一化距离矩阵 N 转换成图像表示。将 N 中的每个元素值作为图像像素的明暗程度,较小的值对应较亮的像素,而较大的值对应较暗的像素。以此得到无阈值递归图 G ,其元素表示如式(3)所示。

$$G(i,j) = N(i,j), \forall i,j \in \{1,2,\dots,n\} \quad (3)$$

其中,图像 G 反映了时间序列信号集合中相点之间的距离信息。

1.3 LeNet神经网络设计

LeNet网络是一种专用于数字识别的卷积神经网络模型^[25]。基于多重因素权衡,被引入足底压力身份识别领域。首先,由于将足底压力信号转化为无阈值递归图后,数据呈现二维空间拓扑结构,与LeNet网络原设计所针对的手写数字图像具有相似的局部特征重复性与结构化特性,其卷积层与池化层的组合机制能够高效提取图像空间特征,且该网络卷积操作可针对性捕捉转换后递归图的稳定纹理与模式,为身份识别提供有效特征支撑;其次,相较于循环神经网络在处理二维图像结构时的低

效性,以及复杂深度模型因参数过大难以实现移动端实时识别的局限性,LeNet网络的轻量化设计在保证识别精度的同时显著降低计算成本,契合足底压力身份识别对可穿戴设备部署的实时性需求,符合通过减少计算资源消耗提升识别效率以适配实际应用场景的目标。改进后的网络结构如图5所示。




图5 LeNet网络结构示意图

Fig. 5 LeNet schematic diagram of the network architecture

改进的LeNet网络包含4个权重层,其中包括2个卷积层和2个全连接层。网络的输入是足底压力信号经过递归图计算后转化为 30×30 的灰度图像。首先,输入图像通过两个卷积层进行处理。为了增强图像边缘信息的保留,卷积操作采用了边界填充(padding)。每个卷积层之后都应用了ReLU激活函数,帮助引入非线性特性,提高网络的表达能力。随后,图像经过最大池化层(MaxPooling),池化窗口大小为 2×2 ,步长为2,旨在减少特征维度,压缩数据量,同时保留图像中的重要特征。接下来,经过卷积和池化层提取到的特征会被传递到全连接层。全连接层由两个层组成,分别包含256个和128个神经元,这些神经元的作用是将卷积层中提取的特征进行整合,并进行更高级的特征学习。在全连接层的输出之后,添加了一个Softmax层,用于将网络的输出转换为多分类结果,适用于后续的分类任务。

2 实验

2.1 实验数据

参与者共28名,均无任何影响行走的疾病,年龄在20~60岁。尽管已有文献表明,行走速度、路面条件及负重等因素均可能改变足底压力分布模式。但严格限定于混凝土地面上的正常行走,目的在于分析该特定条件下的各足底压力区域身份识别的性能。在实验过程中,每位参与者均在左脚佩戴自制的足底压力采集设备,行走过程中8个压力传感器同步采集足底压力数据。由于后续数据分割操作对步数一致性无特殊要求,实验设计聚焦于数据的代表性,兼顾规避参与者疲劳效应与时间效

率平衡,故设定每次实验连续行走3 min,每位参与者需完成50次重复测试。

步态周期可分为4个阶段,即落脚阶段、触地阶段、抬脚阶段和离地阶段如图6所示。其中,落脚阶段、触地阶段和抬脚阶段被统称为支撑相。离地阶段到下一次落脚阶段称为摆动相。在离地阶段,足底压力数据理论上应该为0,因此可以忽略不计。而在支撑相的3个阶段内,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6 步态周期的4个阶段

Fig. 6 Four phases of the gait cycle

自制的足底压力采集设备收集到的一个完整的步态周期信号如图7所示,即从落脚阶段开始到再次落脚为止。

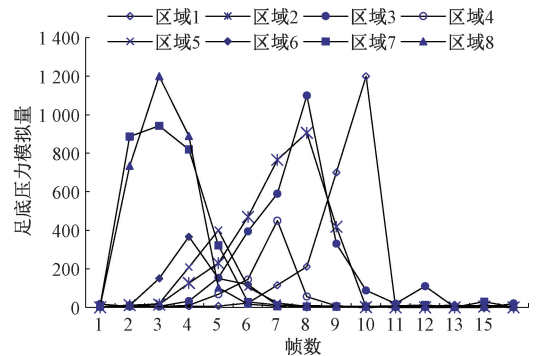


图7 一个步态周期信号(左脚)

Fig. 7 A gait cycle signal (left foot)

根据足底压力采集设备的设计,压力区域1的数据表示足趾区域,压力区域2、3、4、5表示脚掌区域,压力区域6、7、8表示脚跟区域。如图8所示,支撑相足底压力呈现3阶段动态演化特征:落脚阶段脚跟区域出现峰值压力;触地阶段脚掌压力显著上升,同伴伴随脚跟压力锐减及重心前移;抬脚阶段足趾区域产生瞬时压力峰值。通过支撑相内足底压力变化特点有效验证了所使用的足底压力采集设备在测量人体行走时足底压力数据的有效性。

2.2 数据预处理

原始实验数据为连续3 min内8个足底压力区域对应8个传感器采集的压力时间序列。为开展后续分析,需对数据进行分割,确保各片段至少包含一个周期。结




图 8 一个步态周期不同区域的压力信号

Fig. 8 Pressure signals from different regions during a gait cycle

合无阈值递归图转换与 LeNet 网络输入参数需求,将分割后的子片段统一设定为 30 个采样点,为提升数据利用率,采用 50% 重叠的滑动窗口技术对 8 个传感器采集的原始 3 min 数据进行分割,分割后的子片段如图 9 所示。




图 9 足底压力数据分割后子片段

Fig. 9 Sub-segments of plantar pressure data after segmentation

再分别将分割后的 8 个传感器对应的足底压力数据使用无阈值递归图转换方法生成对应的 8 个 30×30 的灰度图像如图 10 所示,最终形成系列无阈值递归图作为 LeNet 网络输入。无阈值递归图通过相空间重构将一维时间序列映射为二维纹理,保留周期突变等非线性特征,同步提取时空耦合特征,相较于原始一维时序,其二维表示更适配 LeNet 网络的卷积运算架构。




图 10 足底压力 8 个区域的无阈值递归图转换

Fig. 10 Threshold-free recurrence plot transformation for 8 regions of plantar pressure

2.3 实验结果

实验评价环节选取了机器学习领域常用的 4 种指标来评价网络模型:准确率 (Accuracy, A)、精确率 (Precision, P)、召回率 (Recall, R) 和 F_1 分数。定义分别为:

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

$$P = \frac{TP}{TP + FP} \quad (5)$$

$$R = \frac{TP}{TP + FN} \quad (6)$$

$$F_1 = 2 \frac{P \times R}{P + R} \quad (7)$$

其中, TP 、 TN 、 FP 、 FN 为混淆矩阵统计量,通过模型预测结果与样本真实标签比对获得。 TP 表示真正例,表示将正类样本正确预测为正类的样本数; TN 表示真负例,表示将负类样本正确预测为负类的样本数; FP 表示假正例,表示将负类样本预测为正类的样本数; FN 表示假负例,表示将正类样本预测为负类的样本数。

为了研究不同压力区域身份识别的性能,进行了对比实验。数据集包含 28 名参与者的行走足底压力数据,共 182 000 个子片段。将数据集平均分为 10 组进行身份识别分析,每组包含 28 名参与者的行走足底压力 18 200 个子片段,通过重复度量分析了 8 个足底压力区域的身份识别结果。对于仅使用单一区域方案进行身份识别的总体平均 A 值、 P 值、 R 值和 F_1 值,分别为 82.80%、82.97%、82.99% 和 82.49%。身份识别结果如表 1 所示。重复度量分析表明,各区域足底压力特征对身份识别的结果 ($F_{7,63} = 221.655, p < 0.000 01$) 存在显著性差异。事后成对比较发现,表现最优秀的压力区域是区域 8 和 3,其次是区域 7 和 1,然后依次为区域 2、6、5 和 4。

表 1 不同压力区域身份识别结果对比

Table 1 Comparison of identity recognition results for different pressure regions (%)

足底压力区域	A	P	R	F_1
1	85.38	85.64	85.55	85.38
2	83.40	83.86	83.93	83.44
3	89.85	90.37	90.05	90.07
4	72.85	73.04	73.15	72.28
5	75.00	75.34	74.75	74.62
6	80.18	79.67	81.03	78.71
7	84.58	84.51	84.40	84.23
8	91.18	91.36	91.10	91.15
平均值	82.80	82.97	82.99	82.49

为研究压力区域组合对身份识别性能的影响,除上述 8 种单一区域外,依次分析了 28 种两区域组合、56 种三区域组合、70 种四区域组合、56 种五区域组合、28 种六区域组合、8 种七区域组合及 1 种八区域组合,形成了

对1~8区域组合数量的完整覆盖。针对两区域组合身份识别任务,将网络模型输入层维度由 $30 \times 30 \times 1$ 扩展为 $30 \times 30 \times 2$ 以适配组合特征输入,其余网络架构保持不变。其他多区域组合方案以此类推,通过增加相应通道数实现多源特征融合。

两区域组合的身份识别结果整体优于单一区域方案,其总体平均 A 、 P 、 R 和 F_1 值分别达到了92.63%、93.07%、92.90%和92.84%。通过分析各区域在两区域组合方案中的影响发现,单一区域方案中表现较好的区域在两区域组合方案中仍然起到了重要作用。两区域组合方案中分别计算包含各区域的每7种组合的平均性能结果如表2所示,观察结果表明,各区域在两区域组合方案中的身份识别性能与单一区域方案中基本一致,其中表现最优秀的区域仍然是区域8和区域3。在两区域组合方案中,组合(3,8)身份识别的 A 、 P 、 R 和 F_1 分别达到了97.30%、97.46%、97.21%和97.31%,优于其他组合方案。其次是组合(7,8)方案和组合(3,7)方案。表现最差的组合方案是组合(4,5)。这一结果从另一方面表明,每个区域在身份识别性能上的差异在两区域组合中仍然存在。

表2 不同压力区域在两区域组合身份识别结果中性能对比

Table 2 Performance comparison of different pressure regions in two-region combined identity recognition

两区域组合中 各压力区域	results (%)			
	平均 A	平均 P	平均 R	平均 F_1 分数
8	96.19	96.27	96.25	96.22
3	94.54	94.70	94.58	94.56
1	93.36	93.69	93.39	93.30
7	92.86	93.21	93.00	92.90
2	92.57	92.93	92.80	92.79
6	91.07	91.35	91.10	90.93
5	90.84	91.74	91.82	91.67
4	89.63	90.69	90.26	90.32

2) 三区域组合方案的身份识别结果优于单一区域方案和两区域组合方案。在56种组合方式下,身份识别的平均 A 、 P 、 R 和 F_1 分别达到了95.96%、95.92%、95.85%和95.78%。计算包含各区域的每21种组合的平均性能结果均在94.85%~96.33%。在三区域组合方案中,组合(1,3,8)表现最佳,身份识别的 A 、 P 、 R 和 F_1 分别达到了99.00%、99.04%、99.03%和99.02%。相较之下,组合(4,5,6)表现最差,身份识别的 A 、 P 、 R 和 F_1 分别为93.00%、92.99%、92.85%和92.73%。

3) 四区域组合方案共70种组合方式,身份识别的平均 A 、 P 、 R 和 F_1 值分别达到了97.25%、97.30%、97.31%和97.29%。四区域组合方案身份识别结果较单一区域方案、两区域组合方案和三区域组合方案均有提升。其中最优组合是组合(1,3,7,8),其身份识别的 A 为99.25%、 P 为99.22%、 R 为99.39%、 F_1 为99.26%。此外,组合(1,2,7,8)、组合(1,2,3,7)和组合(1,2,3,8)身份识别性能各指标也均在99.00%左右。最差的组合是组合(2,3,4,6),评价指标 A 为93.50%、 P 为93.76%、 R 为93.60%、 F_1 为93.60%。

4) 五区域组合方案身份识别平均 A 值为98.43%、 P 值为98.50%、 R 值为98.55%、 F_1 值为98.50%。其中最优组合是组合(1,2,3,7,8),其身份识别的 A 为99.27%、 P 为99.26%、 R 为99.32%、 F_1 为99.28%。结果表现优于前几种组合方案,各区域间身份识别的差异在五区域组合方案中逐渐减弱。

5) 六区域组合整体身份识别平均 A 值为98.51%、 P 为98.54%、 R 值为98.57%、 F_1 值为98.54%。其中最优组合是组合(1,2,3,5,7,8),其身份识别的 A 为99.25%、 P 为99.25%、 R 为99.33%、 F_1 为99.29%。整体趋势与五区域组合方案相似。

6) 七区域组合共8组方案,身份识别平均 A 值为99.19%、 P 值为99.16%、 R 值为99.28%、 F_1 值为99.21%。

7) 八区域组合只有一种情况,身份识别 A 值为99.25%、 P 值为99.2%、 R 值为99.40%、 F_1 值为99.31%。

综上所述,随着压力区域数量的增加,身份识别性能呈现非线性提升趋势。如图11所示,两区域组合方案较单一区域方案平均身份识别准确率提升11.87%;三区域方案较两区域方案平均身份识别准确率提升3.60%;四区域方案较三区域方案平均身份识别准确率提升1.30%。区域数量达到4个之后,性能相对稳定。身份识别性能提升能力减弱。




图11 不同压力区域组合身份识别性能对比

Fig. 11 Comparison of identity recognition performance among combinations of different pressure regions

2.4 实验结果分析

在单一区域方案中,不同区域的身份识别性能存在显著差异。查阅相关文献可知,正常人在行走过程中各阶段的主要受力特点分别为:落脚阶段足跟内侧受力最大,触地阶段第二跖骨处受力最大,抬脚阶段大脚趾处受力最大^[26]。实验结果表明,区域8的表现最优,这主要归因于该区域在行走过程中承受落脚阶段的主要压力。相比之下,区域3在脚跟离地后的触地阶段承受主要压力,而区域1则在抬脚阶段承受主要压力。进一步分析表明,在不同阶段的主要受力区域中,落脚阶段的主要受力区域识别性能显著高于触地阶段主要受力区域的识别性能,而触地阶段主要受力区域的识别性能又优于抬脚阶段主要受力区域的识别性能。在两区域组合方案中,不同阶段的主要受力区域组合表现较好。其中,区域8和3的组合在身份识别性能上最为优越。此外,触地阶段区域7和8的组合也表现出较好的性能。因此,两区域组合方案的性能依然受到行走过程中不同阶段和受力大小的影响。在三区域组合方案中,不同阶段的主要受力区域组合表现同样良好。其中,区域8、3和1的组合在身份识别性能上最为优越。三区域组合的身份识别性能依然受到行走过程中不同阶段和受力大小的影响。此外,组合是否包含行走过程中不同阶段主要受力区域也非常重要。包含不同阶段的主要受力区域意味着涵盖了整个支撑相内各阶段主要受力区域的时空耦合信息。随着区域数量的增加,身份识别性能受行走过程中不同阶段和受力大小的影响逐渐减弱,但这种影响依然存在。

研究结果与近年来相关研究成果的对比如表3所示。

表3 近年研究对比

Table 3 Comparison of recent studies

文献	传感器数量	是否需要分割完整步态周期	包含步态周期数量	A/%
本文	1	否	1	91.18
本文	4	否	1	99.25
本文	8	否	1	99.25
[3]	4	是	4	96.93
[4]	16	是	1	96.00
[6]	16	是	1	<95.00
[7]	9	否	1	93.30
[8]	8	是	1	93.60
[8]	8	是	5	99.60
[9]	16	是	1	82.36
[9]	16	是	8	97.10

结果表明,针对无需严格划分完整步态周期的足底压力数据,使用结合无阈值递归图与LeNet网络的识别方法,在数据维数最小化和硬件条件最简化的情况下,实现了较高的身份识别准确率。

相比表中所列文献,仅使用4个传感器便能够获得更高的准确率。其中,尽管文献[8]基于包含5个完整步态周期的数据的识别结果略高于该结果,但提出的结合无阈值递归图和LeNet网络的方法无需依赖严格的步态周期分割,而是可以在步态周期内的任意时间点开始采集数据,只需确保数据包含一个完整的步态周期即可。此外,即使在仅使用4个传感器的情况下,该方法仍能够在在一个步态周期内实现比文献[8]中使用8个传感器更高的识别准确率。

3 结论

针对身份识别领域足底压力特征通常存在完整步态周期依赖问题,提出基于无阈值递归图与LeNet网络的识别方法。实验结果表明,该方法无需数据分割限制,在步态周期内任意起点截取足底压力数据的条件下仍有较高识别准确率。通过分析传感器配置与识别性能发现:1)单一区域方案中,支撑相内落脚阶段、触地阶段和抬脚阶段的主要受力区域身份识别性能具有阶段特异性,识别性能呈现递减趋势。这种阶段特异性在多区域组合方案中依然存在。2)多区域组合方案中,实验结果验证了多阶段信息融合的必要性和重要性。组合方案通过捕获连续阶段压力转移特征,增强了时空耦合信息。其中包含完整支撑相的组合方案性能突出。足跟内侧、足跟外侧、第二跖骨及大脚趾构成核心贡献区域,其四区域方案较单一区域方案识别率提升8.82%,同时较全足底方案减少50%的传感器用量。研究证实传感器数量与识别性能呈现边际效益递减规律,为足底生物特征识别系统的低功耗优化设计提供了关键理论依据与实验支撑。在常规混凝土地面、无干扰条件下实现了高精度的足底压力身份识别,为该项技术在安防领域的潜在应用提供了有力的技术支撑。

参考文献

- [1] GIRÃO N S, MULLER M, RAMOS DE ARRUDA L V R. A new biometric identification system based on plantar pressure[J]. IEEE Sensors Journal, 2023, 23(15): 16900-16906.
- [2] WAN CH SH, WANG L, PHOHA V V. A survey on gait recognition[J]. ACM Computing Surveys, 2018, 51(5): 1-35.
- [3] HUANG B F, CHEN M, HUANG P F, et al. Gait

- modeling for human identification [C]. 2007 IEEE International Conference on Robotics and Automation, 2007:4833-4838.
- [4] FENG Y, GE Y J, SONG Q J. A human identification method based on dynamic plantar pressure distribution[C]. 2011 IEEE International Conference on Information and Automation, 2011:329-332.
- [5] YE H K H, SU CH H, CHIU W, et al. I walk, therefore I am: Continuous user authentication with plantar biometrics[J]. IEEE Communications Magazine, 2018, 56(2):151-157.
- [6] CHOI S I, MOON J, PARK H C, et al. User identification from gait analysis using multi-modal sensors in smart insole[J]. Sensors, 2019, 19(17):3785.
- [7] IVANOV K, MEI ZH Y, PENEV M, et al. Identity recognition by walking outdoors using multimodal sensor insoles[J]. IEEE Access, 2020, 8:150797-150807.
- [8] 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.
- [9] TRUONG P H, YOU S, JI S H, et al. Adaptive accumulation of plantar pressure for ambulatory activity recognition and pedestrian identification [J]. Sensors, 2021, 21(11):3842.
- [10] CHEN W H, XU Y J, WANG J H, et al. Kinematic analysis of human gait based on wearable sensor system for gait rehabilitation [J]. Journal of Medical and Biological Engineering, 2016, 36:843-856.
- [11] GONZÁLEZ I, NIETO-HIDALGO M, MORA J, et al. A dual approach for quantitative gait analysis based on vision and wearable pressure systems [C]. Ambient Assisted Living, 2015:206-218.
- [12] WANG C, KIM Y, LEE S H, et al. Activity and safety recognition using smart work shoes for construction worksite[J]. Transactions on Internet and Information Systems, 2020, 14(2):654-670.
- [13] LI X Y, LIU X ZH, ZENG W H, et al. Carbon fiber—based smart plantar pressure mapping insole system for remote gait analysis and motion identification [J]. Advanced Materials Technologies, 2023, 8 (16): 2300095.
- [14] 孙东杰,宋爱国. 基于传感阵列的动态足底压力分布测量系统[J]. 仪器仪表学报, 2022, 43(6):83-91.
- SUN D J, SONG AI G. A dynamic plantar pressure distribution measurement system based on sensor array[J]. Chinese Journal of Scientific Instrument, 2022, 43(6):83-91.
- [15] 周丙涛,向勉,汪涛,等. 基于足底压力的不规范深蹲姿势识别[J]. 仪器仪表学报, 2021, 42(12):110-117.
- ZHOU B T, XIANG M, WANG T, et al. Detection of common incorrect squats based on sensor insoles [J]. Chinese Journal of Scientific Instrument, 2021, 42(12):110-117.
- [16] 席旭刚,武昊,左静,等. 基于 sEMG 与足底压力信号融合的跌倒检测研究 [J]. 仪器仪表学报, 2015, 36(9):2044-2049.
- XI X G, WU H, ZUO J, et al. Study on fall detection based on surface EMG and plantar pressure signal fusion[J]. Chinese Journal of Scientific Instrument, 2015, 36(9):2044-2049.
- [17] 孙巍伟,梁毅玮,毛亦鹏,等. 基于多传感信息融合的跌倒监测系统开发 [J]. 电子测量技术, 2024, 47(22):94-103.
- SUN W W, LIANG Y W, MAO Y P, et al. Development of a fall detection system based on multi-sensor information fusion[J]. Electronic Measurement Technology, 2024, 47(22):94-103.
- [18] 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, Gait recognition and intention perception method based on human body model mapping[J]. Chinese Journal of Scientific Instrument, 2020, 41(12):236-244.
- [19] WANG CH G, EVANS K, HARTLEY D, et al. A systematic review of artificial neural network techniques for analysis of foot plantar pressure [J]. Biocybernetics and Biomedical Engineering, 2024, 44(1):197-208.
- [20] ASL E F, EBADOLLAHI S, VAHIDNIA R, et al. Statistical database of human motion recognition using wearable IoT—a review [J]. IEEE Sensors Journal,

2023, 23(14):15253-15304.

- [21] XIN Y ZH, LIU CH H. Motion detection system based on plantar pressure distribution [C]. First International Conference on Information Sciences, Machinery, Materials and Energy, 2015:98-102.
- [22] LI W CH, LU W Q, SHA X P, et al. Wearable gait recognition systems based on MEMS pressure and inertial sensors: A review [J]. IEEE Sensors Journal, 2022, 22(2):1092-1104.
- [23] DAS P, CHATTERJEE S, KOLEY C. Recurrence plot aided partial discharge detection framework employing HFCT sensor and customized convolutional neural network [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2024, 31(6):2947-2955.
- [24] FAWAZ H I, FORESTIER G, WEBER J, et al. Deep learning for time series classification: A review [J]. Data Mining and Knowledge Discovery, 2019, 33(4):917-963.
- [25] YADAV B, INDIAN A, MEENA G. Recognizing off-line devanagari handwritten characters using modified lenet-5 deep neural network [J]. Procedia Computer Science, 2024, 235:799-809.
- [26] HESSERT M J, VYAS M, LEACH J, et al. Foot pressure distribution during walking in young and old adults [J]. BMC Geriatrics, 2005, 5(1):8.

作者简介



袁田,分别在2009年和2017年于沈阳理工大学获得学士和硕士学位,现为沈阳工业大学博士研究生,主要研究方向为生物特征识别和机器视觉检测。

E-mail: yuantian@ sut. edu. cn

Yuan Tian received her B. Sc. and M. Sc. degrees from Shenyang Ligong University in 2009 and 2017, respectively. She is currently a Ph. D. candidate at Shenyang University of Technology. Her main research interests include biometric identification and machine vision.



辛义忠(通信作者),分别在1997年和2004年于沈阳工业大学获得学士和硕士学位,2010年于日本高知工科大学获得博士学位,现为沈阳工业大学教授,博士生导师,主要研究方向为生物特征识别、机器视觉检测和人机交互。

E-mail: xyz@ sut. edu. cn

Xin Yizhong (Corresponding author) received his B. Sc. and M. Sc. degrees both from Shenyang University of Technology in 1997 and 2004, respectively, and received his Ph. D. degree from Kochi University of Technology, Japan in 2010. He is currently a professor and a Ph. D. advisor at Shenyang University of Technology. His main research interests include biometric identification, machine vision and human-computer interaction.