

基于震动信号的异常步态识别

汪成亮, 刘艺镛

(重庆大学计算机学院, 重庆 400044)

摘要: 异常步态的识别对老年人的健康看护有很大帮助. 现有的相关研究主要通过图像采集设备或穿戴设备获取相关特征信息进行识别, 这些方法大多都具有侵入性或对用户有较高的操作要求. 本文研究实现了一种基于脚步震动信号为识别源进行异常步态和跌倒检测的系统原型, 该系统通过本文设计的应用于大范围数据采集的多传感器协同信号采集方法采集信号, 从中分割出有效部分作为活动元, 去噪后再使用改进的动态时间规整算法 (Dynamic Time Warping, DTW) 计算出代表活动元之间差异性的异常指数, 接着由 K 最近邻 (K-Nearest Neighbor, KNN) 算法分类异常指数, 得到初步表征用户步态的推测值, 最后由隐马尔科夫模型 (Hidden Markov Model, HMM) 进一步处理推测值, 识别出用户的步态. 实验结果表明, 本文提出的方法能够有效在不同的步态模式下识别异常步态, 在稳定的环境中识别准确率达到 96%, 在具有不稳定地板的环境中准确率为 94%.

关键词: 异常步态识别; 动态时间规整算法; 隐马尔科夫模型; 震动信号; 嵌入式设备

基金项目: 国家自然科学基金 (No.61672115); 重庆市技术创新与应用发展专项重大主题专项 (No.cstc2019jscx-zdztzxX0037, No.cstc2019jscx-gksbX0038)

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112(2023)08-2088-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20210871

Recognition of Abnormal Gait Based on Vibration Signal

WANG Cheng-liang, LIU Yi-luo

(Computer School, Chongqing University, Chongqing 400044, China)

Abstract: The recognition of abnormal gait is of great help to the health care of the elderly. Existing related research mainly uses image acquisition equipment or wearable equipment to obtain relevant feature information for identification. Most of these methods are invasive or have high operational requirements for users. This paper studies and realizes a system prototype based on the detection of abnormal gait and fall based on foot vibration signals as the source of identification. This paper first designs a multi-sensor cooperative signal acquisition method to achieve a large range of signal acquisition, and separate the effective part from it as the active element. After the collected active elements are denoised, an improved dynamic time warping algorithm (DTW) is used to calculate the abnormal index representing the difference between active elements, then the abnormal index is classified by the K nearest neighbor (KNN) algorithm, and the inferred value that initially characterizes the user's gait is obtained. The inferred value is further processed by hidden Markov model (HMM) to identify the user's gait. The experimental results show that the method proposed in this paper can effectively identify abnormal gait in different gait modes, with an accuracy of 96% in a stable environment, and an accuracy of 94% in an environment with unstable floors.

Key words: abnormal gait recognition; dynamic time warping (DTW); hidden Markov model (HMM); vibration signal; embedded device

Foundation Item(s): National Natural Science Foundation of China (No.61672115); Chongqing Technology Innovation and Application Development Special Major Theme Project (No.cstc2019jscx-zdztzxX0037, No.cstc2019jscx-gksbX0038)

1 引言

开发一种基于行走产生的震动信号来监测老年人生活状况的智能家居系统是非常有意义的,有助于医生或家人了解其活动规律和生活状况。独居的人群,尤其是老年人,一旦发生跌倒等意外情况,无法得到及时的帮助。医学调查表明,在跌倒后如果得到及时救治,死亡风险概率可降低 80%,显著提高老年人的存活率。因此,快速检测跌倒事件的发生具有重大意义^[1]。除此以外,某些疾病的征兆也可以通过震动信号体现。例如,偏瘫患者步子的速度、节奏都会有变化,左右脚产生的震动信号也会变得不对称^[2]。通过分析震动信号来发现这些变化,从而提早发现,提早治疗,避免病情加重,对老年人的健康看护也会有很大的帮助。

现有的智能家居系统主要基于机器视觉、射频、穿戴设备以及声学来实现。基于机器视觉的智能家居系统对环境要求较高,如适当的光照条件、较少的障碍物,并且还可能存在侵犯隐私的问题;基于射频的方法需要大量布置传感器,从而达到较高的检测精度^[3],成本高且操作不够便利;基于穿戴设备的方法要求用户必须随身佩戴特定设备^[4],降低用户的舒适性,并且老年用户还可能忘记佩戴或佩戴错误,这时整个检测系统将因为无法获得正确的数据而失效;基于声学的方法要求环境中噪音处于较低的水平^[5],如果居住地点比较靠近噪音源(火车站、港口、高架路等),系统的准确率会受到较大的影响。震动信号不会被室内障碍物阻挡,不携带隐私信息,无需大量的传感器,无需被检测目标佩戴额外设备,对环境中的噪声容忍度较好。除此以外,基于震动信号的智能家居系统还能嵌入具有物联网(Internet of Things, IoT)的环境中^[6]。

本文设计了一种基于震动信号的嵌入式智能家居原型系统,通过采集用户行走以及跌倒的震动信号,将其作为活动元,得到活动元序列,并基于该序列来识别用户是否跌倒或出现异常步态。本系统需要解决以下两个主要问题。(1)步态多样性问题:足部因某些因素影响存在损伤的用户步态模式与正常人不同,这要求本系统在不同步态模式下均能检测出异常步态。(2)环境干扰问题:受到环境干扰而出现异常的活动元并不意味着用户出现了异常,这要求本系统在有一定干扰的环境中依旧能正确识别异常步态。本文提出的方法具有以下优势:(1)本文改进的 DTW-KNN 架构通过对用户自身的步态变化来识别异常步态,能够适应不同的步态模式;(2)使用 HMM 增加系统识别的准确率以及鲁棒性,在具有干扰的环境下依旧能取得较高的准确率。

本文的主要贡献如下:

(1)提出了一种基于震动的能够在不同步态模式下识别异常步态的方法。

(2)改进了的 DTW 计算方法,将欧氏距离改为“中心距离差”,并进行“分段比对”,使其能够应用于活动元的比对。

(3)构建了具有干扰的实验环境,并通过对比实验验证了本文所提原型系统的有效性。

2 相关工作

对于步态识别的研究,目前已有了一定的研究成果,其中最主要的是基于机器视觉和基于穿戴式设备的步态识别。基于震动信号的步态识别研究较少,主要集中在使用步态进行人员识别上,针对异常步态的识别比较欠缺。

基于机器视觉的方法大多是采用 2D 或者 3D 设备采集图像数据,利用图像处理技术处理数据。Yao 等^[7]使用多级卷积神经网络(Convolutional Neural Networks, CNN),从步态序列中提取骨架步态能量图像(Skeleton Gait Energy Image, SGEI)识别步态,增强识别的鲁棒性。Babaee 等^[8]对不完整步态周期图中的可用轮廓创建不完整能量图像(Gait Enrgy Image, GEI),使用深度自动编码器修复后进行识别。Nguyen 等^[9]基于 Kinect 提供的三维骨骼模型,得到了膝关节、踝关节和髌关节的屈曲度,并将其应用于异常步态的检测。Zhang 等^[10]利用 K-means 将视频中的步态特征聚成了 6 类,之后利用支持向量机(Support Vector Machine, SVM)对正常步态和两种异常步态进行了识别。Liao 等人^[11]提出了基于姿态的时空网络(Pose-based Temporal-Spatial Network, PTSN)的步态识别算法,采用长短时记忆网络(Long Short-Term Memory, LSTM)分析步态视频序列的时序特征。

基于穿戴式设备的方法大多是将数据采集组件集成到用户自身携带的物品上,如智能手机、鞋垫。Ronao 等^[12]提出了一种利用智能手机采集的加速度计和陀螺仪传感器数据进行人体姿态识别的两阶段连续隐马尔可夫模型(Continuous Hidden Markov Models, CHMM)方法。San-Segundo 等^[13]提出了一种基于隐马尔可夫模型的步态识别与分割系统,该系统利用智能手机的惯性信号来识别和分割 6 种不同的人体步态:走路、上楼、下楼、坐下、站立和躺下。Wang 等^[4]使用可穿戴式惯性传感器(Inertial Measurement Unit, IMU)记录髌关节和膝关节轨迹,提取特征用于区分病理步态模式与健康步态模式。Lin 等^[14]设计了一种压力传感器可覆盖足底约 80% 区域的智能鞋垫,以解决传统方法在提取步态特征时对用户造成的不适感,可应用于老年人跌倒检测和预防工伤(如建筑业)的领域。

基于震动信号的方法主要是使用特征方法:分割出踏步事件(step event),从中提取特征值,再根据特征值分类识别。文献[15]提出了可以通过脚步产生的震

动来识别行人,通过在地板上放置地震检波器采集脚步产生的震动信号,提取震动信号的特征后,使用分类器来识别每个提前在系统中注册过的用户.文献[16]使用了相似的方法,通过提取震动信号的特征值来识别注册过的用户.但作者使用了更多更智能的传感器,并在传感器节点之间引入投票系统,提高了识别的准确率,增加了对跌倒的识别.

本文将所提方法运行于计算资源受限的嵌入式平台.在基于机器视觉识别步态领域应用较多的深度学习由于计算量大、模型复杂、硬件需求高等原因而不能很好地应用于本研究,因此本研究仅使用一般的机器学习方法.

3 系统设计

3.1 研究问题解决策略

对于步态多样性问题,不同的用户可能具有不同的步态模式.特征方法难以寻找到能同时有效描述多

种步态模式的特征值;深度学习方法由于使用的数据量大、不易调整,也不能很好地应对这个问题.如图1中**b**组与**c**组所示的2种步态模式的活动元波形图,**b**组为正常用户,**c**组为模拟偏瘫用户,它们有着显著的区别:**b**组中每个活动元都有两个明显的波峰,分别为红框标出的第一波峰与绿框标出的第二波峰;**c**组中(**c1**)与(**c3**)和**b**组相似,紫框标注的为第一波峰,黄框标注的为第二波峰,但(**c2**)与(**c4**)的黄框位置变为一段相对平滑的波动,且黄框位置交替出现波峰与平滑波动.这说明,同一种步态模式的活动元之间具有一定的相似性和规律性,不同步态模式的活动元之间具有较大的差异.根据上述特点,本文改进了动态时间规整算法(DTW)来比对活动元的相似性,每个活动元都会与前两个活动元进行比对,分别计算出表示活动元差异性的异常指数,组成异常指数对,再经过最邻近结点算法(KNN)分类,给出该活动元是否属于异常步态或某种情况的推测值.

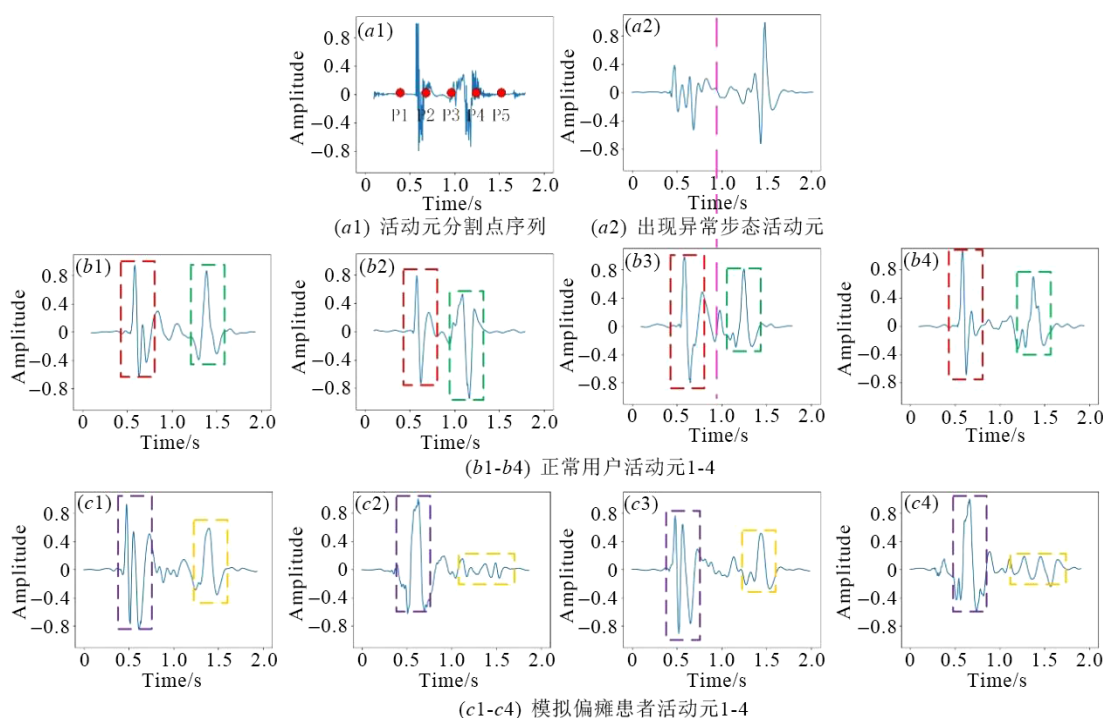


图1 活动元示意图

对于环境干扰问题,如踩踏到一块松动的地板,此时使用单个活动元的推测值去识别用户的步态^[15,17]将会导致一些原本属于正常步态的活动元被分类为异常步态.但这种干扰仅影响当前活动元而不会影响后续的活动元,若将邻近的复数活动元综合为一个整体进行识别,便能在一定程度上修正受干扰活动元的识别结果.根据上述特点,本研究使用隐马尔科夫模型(HMM)来识别用户的步态.活动元经过DTW-KNN的

运算后,得到的结果是一个推测值的序列,称为推测序列.HMM可同时使用复数推测值进行一次识别,大多数情况下可以修正受干扰活动元的识别结果.

除步态多样性问题与环境干扰问题以外,本研究还需解决以下3个问题.

(1)噪声问题.噪声是所有采集到的数据都包含的成分.建筑物自身的晃动,空调、电扇等电器的震动都会产生背景噪声,从而影响我们采集到的活动元.本研

究使用小波变换去噪来消除背景噪声^[18]。

(2)活动元分割问题. 在实际环境中,采集的数据多数为背景噪声,少数为需要分割保存的活动元. 现有的分割方法仅能识别出活动元的开始^[19],无法准确识别结束. 直接设定阈值分割活动元的也会因噪声影响而不够稳定. 本文设计了基于二阶矩的方法来检测分割活动元.

(3)检测范围问题. 单个传感器能够采集到较强信号的范围(本文中约为半径4 m)有限,大范围的检测需要多传感器协同采集数据,各传感器采集到的数据可能会不一致. 本文设计了一种活动元择优算法来解决这一问题.

3.2 系统总体架构

本文设计的原型系统分为以下几个模块:数据采集模块、去噪模块、推测模块以及决策模块. 图2展示

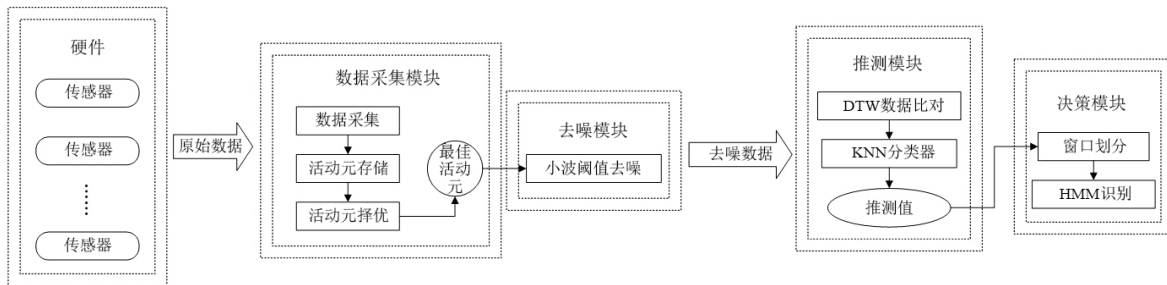


图2 系统架构图

3.3 硬件传感器

用于采集震动数据的硬件包括作为边缘节点的传感器单元和作为中心节点的计算机. 边缘节点如图3中的边缘节点图所示. 每个边缘节点由3个主要部件构成:地震检波器、放大器、BeagleBone 开发板(简称BB板). 地震检波器是直接采集震动模拟信号的传感器,采样频率约为200 Hz;放大器可将采集到的信号放大,增加信噪比;BB板是嵌入式单片机,可以运行各种处理程序. 布置边缘节点时,使用蜡油将检波器固定在地板上,可以更好地采集到高频震动信号^[20].

3.4 数据采集模块

3.4.1 活动元分割

$S_n = \{x_1, x_2, x_3, \dots, x_{n-1}, x_n\}$ 表示采样序列, $x_i (1 \leq i \leq n)$ 表示 i 时刻的采样值. 在本研究中,采样值的取值范围为 $0 \leq x_i \leq 1.8$.

活动元表示一个采样序列的有效部分,即包含有用户活动信息的子序列. 本研究使用基于二阶矩方法来计算分割点 p , 分割点 p 需满足以下条件:

$$m_2 = \frac{1}{N} \sum_{i=p}^{p+N} (x_i - \mu)^2 \geq \delta \quad (1)$$

其中, N 是处理的整个窗口的大小, $\mu = \frac{1}{N} \sum_{i=p}^{p+N} x_i$.

了各模块之间的相互关系以及各模块所包含的部分. 硬件部分由传感器单元组成,使用Wi-Fi构成交互网络. 数据采集模块通过基于二阶矩的活动元分割方法以及活动元择优算法,减少数据传输量,协同多传感器工作,扩大系统检测范围. 去噪模块使用小波阈值去噪方法来消除背景噪声,提高活动元信噪比. 推测模块为DTW-KNN架构,首先使用改进的DTW计算出活动元的异常指数对,再经过KNN分类得到该活动元的推测值. 决策模块使用HMM来分析推测序列,识别用户的步态.

硬件传感器之间使用Wi-Fi形成交互网络,在本文设计的活动元分割方法以及择优算法的支持下,极大地减少了网络中传输的数据量,Wi-Fi足够保证传输的稳定性以及速度,且便于嵌入任何带有Wi-Fi的环境.

我们使用100 ms大的窗口(约20个采样值, $N=20$)来计算活动元的分割点. 当 m_2 大于设置的阈值 δ 时,则判定该点是分割点. 阈值设置为背景噪声标准差的3倍,即对一个不含有活动元的背景噪声采样序列 $S_m = \{y_1, y_2, y_3, \dots, y_{m-1}, y_m\}$, 阈值 δ 定义为

$$\delta = \varepsilon \sqrt{\frac{\sum_{i=1}^m (y_i - \bar{y})^2}{m-1}} \quad (2)$$

其中, \bar{y} 为样本均值, ε 为阈值系数. 本研究中设定 $\varepsilon=3$. 突发噪声越大,则选取的 ε 越大.

经过分割点计算后,将会得到分割点序列 $P_s = \{p_1, p_2, p_3, \dots, p_{s-1}, p_s\}$, $p_j (1 \leq j \leq s)$ 表示第 j 个分割点的值. 分割点序列示意图如图1(a1)所示,对于一个活动元,得到的分割点序列为 $p_1 \sim p_5$, 但仅需 p_1 与 p_5 两个有效点即可分割出该活动元, $p_2 \sim p_4$ 均为冗余点. 对于一个分割点序列,满足下列条件的 p_{j+1}, p_j 为有效点:

$$p_{j+1} - p_j \geq \gamma N, \quad 2 \leq j < j+1 \leq s-1$$

其中, γ 为间隔系数. 本研究中 $\gamma=3$. 特别地,首尾两点 (p_1 与 p_s) 始终为有效点. 得到的有效点序列 P_i 中,每两个有效点分割出一个活动元,即活动元 A_i 为

$$A_i = S_{p_{2i-1}, p_{2i}} = \{x_{p_{2i-1}}, x_{p_{2i-1}+1}, x_{p_{2i-1}+2}, \dots, x_{p_{2i}-1}, x_{p_{2i}}\},$$

$$p \in P_i, 1 \leq i \leq \frac{t}{2}$$

仅通过一个活动元不足以让中心节点判断哪个边缘节点上传的活动元最优,还需要信号能量来帮助选择.本研究采用快速傅里叶变换(Fast Fourier Transform, FFT)将活动元从时域变换到频域然后计算能量,能量在总体上反映了整个信号的强度,活动元 A_i 对应的能量 E_i 定义如下:

$$E_i = \sum |x_i|^2, x_i \in \text{COFFT}(A_i) \quad (3)$$

其中,COFFT(A_i)表示 A_i 进行FFT运算后的系数.

边缘节点最终将上传活动元与其能量的二元组 $AE_i=(A_i, E_i)$ 到中心节点,中心节点将完成下一步工作:活动元择优.

3.4.2 活动元择优

本文设计的活动元择优算法中所有边缘节点通过网络时间协议与中心节点保持时间同步.中心节点为每个边缘节点创建一个数据保存区域,边缘节点每次分割出活动元后,发送到中心节点的数据包括活动元及其能量.中心节点通过对比该次接收到的所有活动元的能量,选取具有最大能量的活动元保留.其算法流程如算法1所示.

算法1 活动元择优算法

```

Input: sensor socket list sl
Output: NULL(put the best signal bss into a queue oq)
1. for c in sl:
2.   create queue sqi = NULL; //创建活动元存储队列
3. while not END:
4.   wait until get a new signal nsi; //等待接收一个新的活动元
5.   if sqi is NULL:
6.     sqi.put(nsi); //若节点对应的队列为空,则存储活动元
7.   else:
8.     bss = NULL;
9.     for each sqi:
10.      if sqi is not empty:
11.        jsi = sqi.get();
12.        bss = maxEnergy(bss, jsi); //取bss与jsi较大者
13.     oq.put(bss);
14.     sqi.put(nsi);
15. return NULL

```

算法1输入为连接传感器的socket列表sl,列表中的每个元素都是一个传感器的socket对象,通过该对象即可从传感器获取数据.筛选出的活动元写入oq队列,供系统下一步取用.第1~2行为sl的每个对象创建一个数据保存队列.第3行为程序结束的条件.第4行为等待边缘节点发送活动元.第5~6行意味着如果某个对象的数据队列是空的,那么直接存入数据,这种情

况出现在该对象前一次接收的活动元刚被处理后.第8~14行为处理一次活动元的步骤,从所有不空的数据队列中选择具有最大能量的活动元存入oq队列,再将本次接收到的活动元放入对应的传感器队列.

3.5 去噪模块

为了提高信噪比,本研究使用小波阈值去噪来自适应地去除噪声.但阈值并不固定,而是根据信号中小波系数最大的一项来决定相对阈值,因为这一项系数通常是活动元引起的.如图1中(a1)所示,背景噪声并不局限于某一特定的频率.因此直接使用高通滤波器^[21]不能得到理想的结果.去噪结果如图1(b2)所示,信号中的噪声明显减少,可以进行下一步的分析.

3.6 推测模块

推测模块为DTW-KNN架构,为适应活动元的比对,本文对DTW算法进行了两点改进:一是将欧氏距离改进为中心距离差;二是使用分段比对.

本研究将DTW中的距离函数定义为中心距离差,表示为

$$f(x_i, y_i) = |x_i| - |y_i|$$

进行比对的活动元首先会被调校至 x 轴,这时 x_i 与 y_i 的绝对值表示活动元采样值距 x 轴的距离.活动元的某部分可能关于 x 轴对称,如图1(b2)绿框部分与其余同组活动元刚好是关于 x 轴对称的,但其本质上依旧是相同的震动,采用普通的欧氏距离会使(b2)活动元的异常指数偏大,从而影响推测值.改进为中心距离差是一个更加合理的做法.

DTW的动态规划计算过程中对活动元的拉伸或挤压会导致活动元在频域的特点难以得到体现,正常与异常活动元的异常指数也不会有足够大的差别.文献[20]指出,步态描述了一个人行走方式,体现了一个人四肢的运动特征,完整的一个步子是从后脚跟撞击地面开始,一直到前脚掌离开地面那一刻结束.在这整个过程中伴随着一系列肌肉的伸缩:踝部背屈肌的伸长,腓肠肌和比目鱼肌的伸长,然后是腓肠肌和比目鱼肌的收缩^[20].这说明一个活动元可以被划分为更多更细的阶段.基于上述分析,在进行DTW计算时,活动元会被划分为几块分别进行计算,再将每块的结果求和.活动元划分的示意如图1中(a2)和(b3)所示.(b3)为正常活动元,(a2)为异常活动元.两个活动元将会在粉色虚线被划分,左右分别对比,有助于提高活动元的分类准确率.

DTW计算得到的异常指数对再输入KNN分类器中,即可得到推测值.推测值仅与用户本身的步态相关,是用户自身步态变化情况的体现.推测值组成的推测序列会继续输入HMM决策模型中,用于识别用户的步态.

3.7 决策模型

HMM模型是由一个5元组描述的,表示为

$$\lambda = (N, M, \pi, A, B)$$

或简写为

$$\lambda = (\pi, A, B)$$

其中, N 为隐藏状态的有限集合, M 为观测值的有限集合, π 为初始状态概率分布, A 为状态转移矩阵, B 为观测值概率分布矩阵(混淆矩阵). 其中, 参数集 $\lambda = (\pi, A, B)$ 需要使用 Baum-Welch 算法来训练得到, 根据观测到的序列来找到最可能产生该观测序列的隐藏状态序列则需要 Viterbi 算法求解. 本研究的 HMM 模型定义如下.

3.7.1 隐藏状态集合

在 HMM 解码问题中, 隐藏状态不能经过直接观测得到, 是属于待发现求解的有限集合. 在本研究的背景中, 隐藏状态则是不能透过推测序列直接得到用户步态, 如正常态、异常态、跌倒. 上述 3 种状态即是本研究隐藏状态集合中的全部状态.

3.7.2 观测值集合

观测值集合是解码问题中求解隐藏状态集的重要已知条件, 每个隐藏状态有一定的概率产生出可能的观测值. 本研究的观测值集合即为推测模块的所有输出结果.

3.7.3 参数训练以及活动识别

前文已提到 HMM 模型的参数集 $\lambda = (\pi, A, B)$ 是由 Baum-Welch 算法训练得到的, Baum-Welch 算法是最大期望 EM 算法的一个特例. 该算法属于非监督学习算法, 以观测值序列为输入, 产生该观测值序列的隐藏状态序列是未知的, 无需输入. 算法首先对 HMM 的参数进行初始估计, 然后通过给定的数据评估这些参数的价值并减少它们所引起的错误来重新修订这些参数. 在本研究的测试环境中, 通过调整测试地面的木板组合来达到模拟实际环境中可能出现的情况. 训练过程如算法 2 所示.

算法 2 HMM 参数训练算法

Input: Raw activity element list for training rae , Number of hidden states n

Output: parameters $\lambda = (\pi, A, B)$

1. whole_data = [];
2. lengths = [];
3. data_size = len(rae);
4. wae = wavelet(rae); //将原始数据进行去噪
5. for w_i in wae:
6. $fw_i = \text{DTW-KNN}(w_i)$;
7. $l_i = \text{len}(fw_i)$;
8. whole_data.append(fw_i);
9. lengths.append(l_i);
10. $\lambda = \text{Baum-Welch}(\text{whole_data}, \text{lengths}, n)$; //Baum-Welch 算法接收三个参数: 训练数据组列表, 每组训练数据长度, 隐藏状态数
11. return λ ;

算法 2 输入为采集的原始脚步数据列表 rae 与隐藏状态数 n , rae 的每个元素都是一次完整的行走数据, 隐藏状态数量 $n=3$, 对应 3 个隐藏状态. 输出为 HMM 的 3 个参数 λ . 第 1~3 行创建并初始化算法的相关数据; 第 4 行对原始数据进行去噪; 第 5~9 行用 DTW-KNN 对 rae 中的每一组数据进行计算, 并将结果以及该组数据的长度各自保存下来; 第 10 行使用前面得到的 DTW-KNN 计算结果、数据长度以及隐藏状态的数量进行训练; 第 11 行返回得到的参数.

经过参数训练后, 得到了 HMM 决策模型. 再使用 Viterbi 算法, 即可识别步态. 该算法是通过动态规划的方法来寻找出现概率最大的隐藏状态序列(被称为 Viterbi 路径). 步态识别过程如算法 3 所示.

算法 3 步态识别算法

Input: Raw activity element queue aq , Window size ws

Output: Gait status list gl

1. cogList = [·]
2. while len(cogList) < ws : //向 cogList 添加数据直到与窗口大小一致
3. $rs = aq.get(\cdot)$;
4. $wrs = \text{wavelet}(rs)$;
5. $cog = \text{DTW-KNN}(wrs)$;
6. cogList.append(cog);
7. $gl = \text{Viterbi}(\text{cogList})$;
8. return gl

算法 3 输入为原始的活动元数据队列 aq , 识别的窗口大小 ws , 输出为识别的步态列表 gl . 第 1 行声明一个存储列表, 用来存储单次识别的推测值; 第 2~6 行循环地从原始数据中取出活动元, 将其去噪, 进行 DTW-KNN 计算后, 加入存储列表中, 直到识别列表达到定义的窗口大小; 第 7~8 行将识别列表中的数据使用 Viterbi 算法进行识别, 并返回识别结果.

3.8 系统时间复杂度分析

一次完整的步态识别需要先后经过活动元分割, 活动元择优, 去噪, 推测模块以及决策模块才能完成. 设活动元的平均长度为 n , 各模块复杂度如下.

活动元分割: 由式(1)与式(3)可得, 时间复杂度为

$$O\left(\frac{1}{N}n \cdot O(1)\right) + O(n \log n) + O(n) = O(n \log n)$$

活动元择优: 由于传感器数量较少且固定, 根据算法 1 可知, 时间复杂度为 $O(1)$. 去噪是基于小波变换进行的, 复杂度即为小波变换的时间复杂度 $O(n \log n)$.

推测模块: DTW 时间复杂度为 $O(n^2)$, KNN 时间复杂度基于单样本维度 k 与样本数量 m , 本研究中 $O(k \log m) = O(2 \log m) = O(\log m)$, 总时间复杂度为 $O(n^2) + O(\log m)$.

决策模块:HMM使用Viterbi算法进行识别,设隐藏状态数量为 Q ,识别窗口大小为 P ,则时间复杂度为 $O(PQ^2)$.

综上所述,系统整体的时间复杂度应为 $O(n \log n) + O(1) + O(n \log n) + O(n^2) + O(\log m) + O(PQ^2) = O(n^2) + O(PQ^2) + O(\log m)$.

在实际应用中, Q 与 P 远小于 n ,则 $O(PQ^2) \ll O(n^2)$, m 的取值为定值,系统时间复杂度可认为是 $O(n^2)$,足够满足实时性要求.

4 实验验证

4.1 实验设置

本实验搭建的实验环境如图3所示.测试地面由70 cm×70 cm的木板拼接而成,每块木板底部有5个木桩支撑脚,分别位于木板的四角及中心处.木板之间使用绞铁片在背面连接,如图3中的木板连接图所示.值得注意的是,并不是所有邻接木板之间都使用了绞铁片连接,整个测试地面由若干木板组组成,每个木板组包含若干木板,属于同一个木板组的邻接木板之间均使用绞铁片连接,而木板组之间不使用绞铁片连接.若需要模拟一块松动的地板,则将对应的木板调整为“动

板”:略微垫高某个支撑脚,让木板处于不平衡的晃动状态.本实验环境主要用于模拟较大的检测范围以及存在干扰的情况,在日常使用中,可视地面的不同改变边缘节点的分布密度,以获取较强的信号.

边缘节点分布在整个测试区域的四角以及中心区域,如图3中的实验环境图所示.每个木板组都至少由一个边缘节点负责采集数据.节点之间通过Wi-Fi网络连接,中心节点通过安全外壳协议(SSH)控制边缘节点,接收并存储采集的活动元.

本实验设计的步态模式有两种:(1)常人模式(NOR模式),模拟一个无任何疾病的一般用户;(2)跛子模式(CRI模式),模拟一个右脚偏瘫的用户.每种步态模式都包含正常步态、异常步态以及跌倒.异常步态的模拟方法为让任意一只脚在行走时放松肌肉,出现略带摇晃的特点,另一只脚尽可能地保持原来的行走方式.

4.2 活动元分类实验

为验证本文提出的DTW-KNN架构的有效性,本实验将与特征方法^[15,17]对比多项指标.特征方法的特征值在时域和频域分别选择:时域下选择标准差、熵、峰值、最大峰值的前后部分信号;频域下选择频谱质心、峰的位置和幅度、功率谱密度^[15].




图3 实验介绍图

表1展示了DTW进行一次计算的平均时间、异常指数与占用空间随分段大小的变化情况.该实验使用了400个NOR模式正常活动元.分段大小指进行DTW计算时,每次进行比对的采样值数量;平均计算时间指进行多次测试后,完成一次活动元比对的平均时间;异常指数变化率指在该分段大小下计算结果相对于直接计算时的增长率;空间变化率指在该分段大小下计算占用空间相对于直接计算时的增长率.由于单个活动元的持续时间几乎都小于2 s,因此分段大小为400时即代表直接计算的情况.从表1中可以看出,随着分段大小的不断缩小,平均计算时间不断缩短,计算速度逐渐提升,但速度的提升率逐渐降低,最终识别速度较直

接计算提升了约10倍;异常指数逐渐增加,在分段大小为300,200,50时出现了“断崖式”上升,最终变化率已接近20%;占用的空间不断减少,但分段大小为50时又略微增加.当划分组小于50时(未在表中列出),继续缩小分段大小对计算速度的提升很小,但异常指数会大幅增加,空间占用也会有小幅度增加,因此最终选择分段大小为50.

特征方法的平均计算时间为0.065 s,占用的空间为DTW的3~4倍.DTW与特征方法计算几乎同速,空间占用较小,说明本文改进的DTW的计算性能较特征方法更好.

表2展示了在NOR与CRI两种步态模式下,DTW

表1 DTW 计算时间,异常指数变化率、空间变化率随分段大小变化

分段大小	400	350	300	250	200	150	100	50
平均计算时间/s	0.85	0.64	0.48	0.36	0.25	0.17	0.12	0.08
异常指数变化率/%	0	0.35	1.6	2.7	9.0	10.5	13.3	19.8
空间变化率/%	0	-19.7	-35.0	-38.5	-49.7	-60.6	-64.9	-63.7

表2 CRI,NOR 模式下两种框架分别用SVM,KNN 训练时间对比

步态模式	架构	分类器	准确率/%	精确率/%	召回率/%	F1 分数/%	平均训练时间/s	平均分类时间/s
NOR	DTW	SVM	87.21	86.02	84.50	86.38	1.56	0.02
		KNN	91.54	90.46	89.74	90.30	0.15	0.09
	特征方法	SVM	73.25	77.32	74.56	72.81	35.78	0.07
		KNN	70.50	71.64	71.82	70.31	0.33	0.21
CRI	DTW	SVM	88.10	85.82	83.15	84.19	1.72	0.03
		KNN	90.34	91.18	90.56	89.96	0.17	0.08
	特征方法	SVM	55.44	56.13	55.74	54.60	34.97	0.07
		KNN	63.80	64.29	63.52	62.21	0.31	0.20

与特征方法分别在SVM分类器与KNN分类器中的相关指标,使用的数据70%用于训练,30%用于测试,KNN的k值设定为9. 相关分析如下.

在NOR模式的实验中,使用了NOR模式200个正常活动元以及200个异常活动元. 表2中可以看出,对DTW而言,KNN除平均分类时间较SVM多0.07 s外,其余指标均好于SVM;对特征方法而言,SVM除训练时间远长于KNN外,其余指标都高于KNN. 特征方法SVM相比于DTW-KNN,各项指标都低20%左右. 出现这样的差距主要是由于特征方法SVM将40%~50%的异常活动元错误分类为正常活动元,而DTW-KNN几乎不会出现这样的错误.

在CRI模式的实验中,使用了CRI模式200个正常活动元以及200个异常活动元. 从表2中可以看出,DTW-KNN与NOR模式下的指标几乎相当,特征方法SVM相较于NOR模式下的指标有大幅的下降,说明DTW-KNN能够适应步态模式的变化,而特征方法SVM则不具备该适应能力.

对于跌倒的识别,由于跌倒的活动元相对于任何其他活动元都是极大的不同,错误分类的概率极低,可以在DTW-KNN的训练数据中添加若干跌倒的活动元,然后直接在本模块中进行识别. 如表3所示,使用了带有跌倒的NOR模式活动元进行测试. 从表3中可以看出,正常活动元与异常活动元存在一些错误分类,但均不会识别为跌倒,跌倒本身也不存在错误识别.

综上所述,本文提出的DTW-KNN架构能够在不同步态模式下对包含跌倒在内的活动元准确分类. 进一

表3 带有跌倒数据的混淆矩阵

实际		正常			异常			跌倒	
分类	正常	异常	跌倒	正常	异常	跌倒	正常	异常	跌倒
数量	104	19	0	5	112	0	0	0	7

步识别用户的步态,处理实际环境中可能出现的干扰,还需要使用HMM模型.

4.3 步态识别实验

在该实验中,步态分为正常步态和异常步态两种. 正常步态意味着用户正在以设定的正常步态模式行走,异常步态意味着用户采用了设定的异常模拟方式行走.

表4展示了两种步态模式分别在稳定与不稳定的实验环境中,推测模块的各项指标对比. 在不稳定的实验环境中,动板数量约占15%,分布尽量均匀. 从表4中可以看出,在不稳定的实验环境中,NOR模式下的各项指标下降约5%,CRI模式下各项指标下降约8%. 经分析,若某个活动元受到动板影响,那么包括该活动元在内的接连3个活动元的推测值都会受到影响,且具有一定的规律性. 对于具有这种特点的影响,使用HMM将能够提高识别的正确率.

表4 不稳定环境下,NOR与CRI模式下DTW-KNN的指标

步态模式-环境	准确率/%	精确率/%	召回率/%	F1 分数/%
NOR-稳定	91.54	90.46	89.74	90.30
NOR-不稳定	85.19	86.64	85.67	85.4
CRI-稳定	90.34	91.18	90.56	89.96
CRI-不稳定	82.18	83.73	82.51	82.94

表5展示了HMM识别的准确率随窗口大小的变化,实验的数据为NOR与CRI两种步态模式的混合推测序列,同时包含正常步态与异常步态,实验环境是稳定的(无动板). 推测序列中70%的推测值用于训练,30%用于测试. 窗口大小是HMM单次识别的推测值数量. 从表5中可以看出,窗口大小为1时,准确率仅32%,远远低于其他窗口大小;窗口大小为2,4,6,8个推测值时,准确率均在93%以上,超过了推测模块的准

准确率;在窗口大小为4时达到最大准确率96%;之后随着窗口大小增加,准确率略有下降.考虑到窗口大小增加会同时引起识别延迟的增加,本实验将窗口大小定为4.

表5 稳定环境下,各窗口大小下的HMM的准确率

窗口大小	1	2	4	6	8
准确率	32%	93%	96%	95%	94%

图4展示了在4种步态模式-环境的情况下,推测模块与HMM识别准确率对比.从图4中可以看出,使用HMM能够将推测模块的准确率提高5%~12%.在推测模块出现最多错误推测的CRI-不稳定环境下,HMM识别的准确率依旧高达94%.图4中还展示了不同情况下HMM的更正率.更正率是本文定义的一个新指标,定义为HMM修正的推测值数量除以错误的推测值数量.该指标衡量了HMM修正受干扰活动元识别结果的能力.更高的更正率意味着HMM的鲁棒性与适应性更强.在各种情况下,HMM均有较好的修正效果,平均更正率为88.75%.综上所述,使用HMM能够有效提高系统整体识别的准确率,并增强整个系统的鲁棒性.

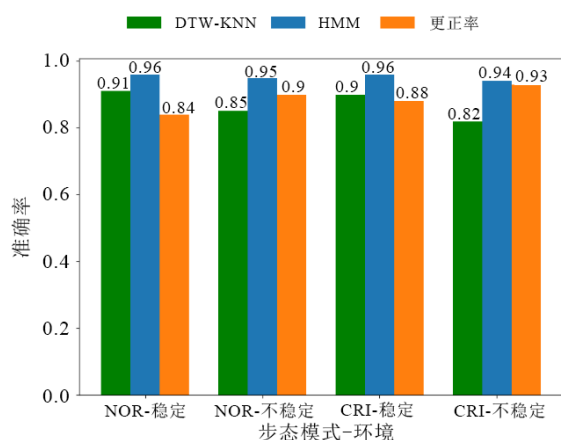


图4 DTW-KNN与HMM准确率对比图

表6展示了LSTM与本文方法进行对比的指标.考虑到嵌入式平台性能较弱,数据仅一维且数据量小,决定将设计的LSTM模型参数量控制在20M以内,模型组成为“卷积层+LSTM层+全连接层”,各层的层数以及参数调整在总参数量20M以内进行.数据中均不带有跌倒,只进行正常步态的二分类任务.“LSTM准确率(原始数据)”指直接使用采集到的活动元数据进行分类,这些数据维度为150~300,在输入到LSTM中时均补足维度到300.“LSTM准确率(处理数据)”指输入到LSTM中的数据为经过本文DTW处理后的数据,这些数据为固定的二维数据.从表6中数据可以看出,使用原始数据的LSTM分类准确率很低,使用经过处理的数据后准确率有了较大的提升.经分析,除了数据量小以

外,一维数据带有的噪声也有较大影响.实际采集到的数据带有无法预测的噪声,无法通过“无噪-加噪-训练去噪”的方法实现.但是这些噪声在具有先验知识的情况下能够较好地去除和降低影响,这也是使用处理数据的LSTM准确率得以提高的原因之一.上述对比既说明了本文所提方法的有效性,也体现了带入先验知识处理数据的优势.

表6 LSTM与本文方法指标对比

指标	NOR-稳定	NOR-不稳定	CRI-稳定	CRI-不稳定
训练数据量	100	120	120	150
验证数据量	60	70	50	100
LSTM准确率(原始数据)/%	78	74	75	71
LSTM准确率(处理数据)/%	87	85	86	83
本文方法准确率/%	96	95	96	94

5 结束语

本文针对目前研究较少的基于震动信号的异常步态识别提出了一种方法.该方法具有以下特点:(1)基于成本较低、性能受限的嵌入式平台开发,可直接嵌入具有Wi-Fi的环境中,使用便捷,价格低廉;(2)着重于应对步态模式的多样性以及实际环境中可能存在的干扰,能够适应不用步态模式的用户,对环境要求较低;(3)使用经典的机器学习方法,适用于低性能嵌入式平台的同时,对数据和底层算法都有了更全面的解释,便于理解,更适合进一步迭代开发和复用;(4)各个组件具有高度的自定义性和独立性,软硬件方面的裁剪改动均十分便利.实验证明本方法能有效在不同步态模式下识别异常步态,在四种步态模式-环境下的平均识别准确率为95.25%,能够修正88.75%的受干扰推测值.

参考文献


- [1] PIERLEONI P, BELLI A, PALMA L, et al. A high reliability wearable device for elderly fall detection[J]. IEEE Sensors Journal, 2015, 15(8): 4544-4553.
- [2] 田皓宇, 马昕, 李贻斌. 基于骨架信息的异常步态识别方法[J]. 吉林大学学报(工学版), 2022, 52(4): 725-737.
TIAN H Y, MA X, LI Y B. Skeleton-based abnormal gait recognition: A survey[J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(4): 725-737. (in Chinese)
- [3] ZENG Y Z, PATHAK P H, MOHAPATRA P. WiWho: WiFi-based person identification in smart spaces[C]//2016 15th ACM/IEEE International Conference on Information

- Processing in Sensor Networks (IPSN). Piscataway: IEEE, 2016: 1-12.
- [4] WANG X C, RISTIC-DURRANT D, SPRANGER M, et al. Gait assessment system based on novel gait variability measures[C]//2017 International Conference on Rehabilitation Robotics (ICORR). Piscataway: IEEE, 2017: 467-472.
- [5] GEIGER J T, KNEIBL M, SCHULLER B W, et al. Acoustic gait-based person identification using hidden Markov models[C]//Proceedings of the 2014 Workshop on Mapping Personality Traits Challenge and Workshop. New York: ACM, 2014: 25-30.
- [6] HE S M, XIE K, CHEN W W, et al. Energy-aware routing for SWIPT in multi-hop energy-constrained wireless network[J]. IEEE Access, 2018, 6: 17996-18008.
- [7] YAO L X, KUSAKUNNIRAN W, WU Q, et al. Robust CNN-based gait verification and identification using skeleton gait energy image[C]//2018 Digital Image Computing: Techniques and Applications (DICTA). Piscataway: IEEE, 2019: 1-7.
- [8] BABAE M, LI L W, RIGOLL G. Gait recognition from incomplete gait cycle[C]//2018 25th IEEE International Conference on Image Processing (ICIP). Piscataway: IEEE, 2018: 768-772.
- [9] NGUYEN T N, HUYNH H H, MEUNIER J. Skeleton-based abnormal gait detection[J]. Sensors, 2016, 16(11): 1792.
- [10] ZHANG H, YE C. RGB-D camera based walking pattern recognition by support vector machines for a smart rollator[J]. International Journal of Intelligent Robotics and Applications, 2017, 1(1): 32-42.
- [11] LIAO R J, CAO C S, GARCIA E B, et al. Pose-based temporal-spatial network (PTSN) for gait recognition with carrying and clothing variations[C]//Chinese Conference on Biometric Recognition. Cham: Springer, 2017: 474-483.
- [12] RONA O C A, CHO S B. Human activity recognition using smartphone sensors with two-stage continuous hidden Markov models[C]//2014 10th International Conference on Natural Computation (ICNC). Piscataway: IEEE, 2014: 681-686.
- [13] SAN-SEGUNDO R, BLUNCK H, MORENO-PIMENTEL J, et al. Robust human activity recognition using smartwatches and smartphones[J]. Engineering Applications of Artificial Intelligence, 2018, 72: 190-202.
- [14] LIN F, WANG A S, ZHUANG Y, et al. Smart insole: A wearable sensor device for unobtrusive gait monitoring in daily life[J]. IEEE Transactions on Industrial Informatics, 2016, 12(6): 2281-2291.
- [15] PAN S J, WANG N N, QIAN Y Q, et al. Indoor person identification through footstep induced structural vibration [C]//Proceedings of the 16th International Workshop on Mobile Computing Systems and Applications. New York: ACM, 2015: 81-86.
- [16] CLEMENTE J, SONG W Z, VALERO M, et al. Indoor person identification and fall detection through non-intrusive floor seismic sensing[C]//2019 IEEE International Conference on Smart Computing (SMARTCOMP). Piscataway: IEEE, 2019: 417-424.
- [17] CLEMENTE J, LI F Y, VALERO M, et al. Smart seismic sensing for indoor fall detection, location, and notification [J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(2): 524-532.
- [18] 汪成亮, 郑诚, 曾卓. 基于软件定义智能的睡眠动作识别[J]. 电子学报, 2021, 49(1): 85-89.
- WANG C L, ZHENG C, ZENG Z. Sleep action recognition based on software-defined intelligence[J]. Acta Electronica Sinica, 2021, 49(1): 85-89. (in Chinese)
- [19] PAN S J, BONDE A, JING J, et al. BOES: Building occupancy estimation system using sparse ambient vibration monitoring[C]//Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2014. San Diego: SPIE, 2014: 406-421.
- [20] Pan S J, TONG Y, MOSTAFA M, et al. FootprintID: Indoor Pedestrian Identification through Ambient Structural Vibration Sensing[C]//2017 ACM Interact. Mob. Wearable Ubiquitous Technol (UBICOMP). New York: ACM, 2017: 89-120.
- [21] CHEN W Q, GUAN M N, WANG L, et al. FLoc: Device-free passive indoor localization in complex environments [C]//2017 IEEE International Conference on Communications (ICC). Piscataway: IEEE, 2017: 1-6.

作者简介



汪成亮 男, 1975年5月生, 四川资阳人. 博士. 现为重庆大学计算机学院教授, 博士生导师. 主要研究领域为复杂系统智能控制、无线网络及RFID研究与应用等.
E-mail: wangcl@cqu.edu.cn



刘艺镛 男, 1996年11月生, 重庆人. 硕士. 主要研究方向为智能家居、震动信号分类处理.
E-mail: lyldwangyi@163.com