

# 基于手机传感器的人体活动识别综述



张春祥<sup>1</sup> 赵春蕾<sup>1</sup> 陈超<sup>1</sup> 罗辉<sup>2</sup>

1 天津理工大学计算机科学与工程学院 天津 300384

2 解放军信息工程大学电子技术学院 郑州 450002

(1449611075@qq.com)

**摘要** 人体活动存在于日常生活的各方面,人体活动识别(HAR)具有广泛的应用价值,并受到广泛关注。随着智能手机的逐步发展,传感器嵌入到手机中使手机更加智能,实现了更加灵活的人机交互。人们一般随身携带智能手机,因此手机传感器信号中有丰富的人体活动信息,通过提取手机传感器的信号便可以识别用户活动。相比基于计算机视觉等方法,基于手机传感器的人体活动识别更能体现人体运动的本质,并且具有成本低、灵活、可移植性强的特点。文中详细阐述了基于手机传感器的人体活动识别的研究现状,并对系统结构和基本原理进行了详细的描述和总结,最后分析了基于手机传感器的人体活动识别目前存在的问题以及未来发展的方向。

**关键词**:手机传感器;人体活动识别;模式识别;数据处理

**中图分类号** TP391

## Review of Human Activity Recognition Based on Mobile Phone Sensors

ZHANG Chun-xiang<sup>1</sup>, ZHAO Chun-lei<sup>1</sup>, CHEN Chao<sup>1</sup> and LUO Hui<sup>2</sup>

1 School of Computer Science and Engineering, Tianjin University of Technology, Tianjin 300384, China

2 School of Electronic Technology, PLA Information Engineering University, Zhengzhou 450002, China

**Abstract** All walks of life and daily life are affected by human activities. Human activity recognition (HAR) has a wide range of application, and has been widely concerned. With the gradual development of smart phones, sensors are embedded in the phone to make the phone more intelligent and realize more flexible man-machine interaction. Modern people usually carry smart phones with them, so there is a wealth of information about human activities in the signals of mobile phone sensors. By extracting signals from the phone's sensors, it is possible to identify users' activities. Compared with other methods on the strength of computer vision, HAR on account of mobile phone sensors can better reflect the essence of human movements, and has the characteristics of low cost, flexibility and strong portability. In this paper, the current situation of HAR based on mobile phone sensors is described in details, and the system structure and basic principles of the main technologies are described and summarized in details. Finally, the existing problems and future development direction of HAR based on mobile phone sensors are analyzed.

**Keywords** Mobile phone sensor, Human activity recognition, Pattern recognition, Data processing

## 1 引言

人体活动存在于日常生活的各方面,各行各业都离不开人们的活动,而人体活动识别一直受到研究人员的关注。随着社会经济的发展,人民生活水平不断提高,手机已经成为人们生活工作中必不可少的多功能工具。基于手机传感器的人体活动识别越来越受到研究人员的关注,并且在运动追踪、健康监测、人机交互、老年人监护等方面有着广泛的应用前景。

早在20世纪中期,价格高、不易携带的早期加速度传感器便开始尝试用于识别人体活动信息<sup>[1]</sup>,但实际效果很不理想。在20世纪中后期,传感器并未取得较大发展,其灵敏度低,稳定性差, Morris 在这样的情况下开始研究基于传感器

的人体活动识别<sup>[2]</sup>,但识别效果很差,研究一直处于停滞不前的状态。微电子技术的发展促使传感器体积变小,而传感器技术的成熟使得传感器价格降低,并且种类逐渐增多。研究人员可使用加速度计、陀螺仪、磁力计、气压计等内置于可穿戴设备的传感器来采集数据,但其仍然需要繁琐的设备穿戴。随着智能手机的出现,便携、供电、计算等方面的优势使得基于手机传感器的人体活动识别得到了众多研究人员的青睐。

根据获取数据方式的不同,人体活动识别主要有4种方式:基于视觉的<sup>[3-4]</sup>、基于WiFi信号的<sup>[5-6]</sup>、基于声音信号的<sup>[7-8]</sup>和基于传感器信号的<sup>[9-10]</sup>。前3种方式都具有较高的可行性,均可以对细粒度的人体活动进行识别,如用户对智能手机的按键识别,但是仍有不足之处。基于视觉的人体活动

收稿日期:2020-04-21 返修日期:2020-08-17 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:天津市自然科学基金(18JJCQNJC69900)

This work was supported by the Tianjin Natural Science Youth Fund (18JJCQNJC69900).

通信作者:赵春蕾(zeltjut@gmail.com)

识别容易受到环境的影响,如光照、角度等,而且对收集数据的摄像头布置有很高的要求,并且部署困难、成本高;基于WiFi信号的人体活动识别主要通过分析公共WiFi热点数据来进行识别,部署容易,但是检测困难,对检测者与WiFi热点的距离也有要求;基于声音信号的人体活动识别,可以通过智能手机上的麦克风和扬声器构成一个小型的声呐,通过分析声音信号来识别人体活动,但是容易受到周围环境噪声的影响。相比之下,传感器信号与人体活动关系更为密切,受环境因素影响很小,识别无需处于特定部署的环境中。当今社会处于信息时代,手机已经成为人们必不可少的随身物品,而手机传感器更能够凸显移动、便携的优势。因此,基于手机传感器的人体活动识别研究是十分有意义的。近年来,基于手机传感器的人体活动识别研究已经逐渐应用于许多领域。Wang等<sup>[11]</sup>利用加速度计、陀螺仪等手机传感器,使用随机森林和支持向量机等机器学习方法进行分类,通过识别按键动作特征的方式来进行用户认证,准确率高达95%。Ahmadi等<sup>[12]</sup>利用手机传感器,通过提取7种不同的用户日常活动特征来达到用户认证的目的,平均准确率在80%以上。将基于手机传感器的人体活动识别应用于用户认证,可以防止手机被窃取后隐私信息的泄露,从而保护用户的手机安全。Dianel等<sup>[13]</sup>使用手机传感器识别人体活动并提取特征,结合声音和位置信息,实现了10种身体健康指标的预测,并且误差率不超过临床基准。Katherine等<sup>[14]</sup>提出使用手机传感器来监测用户的心理健康。将基于手机传感器的人体活动识别应用于健康监测,可以通过开发App的方式使得日常的健康监测更加方便。另外,随着计算机计算能力的增强,研究人员正尝试用不同的复杂方法来提高识别的准确率。Chen等<sup>[15]</sup>提出了一个特征融合框架,将手工提取的特征与深度学习算法相结合,明显提高了人体活动识别的准确率。

目前,基于手机传感器的人体活动识别主要分为3个部分,如图1所示。首先收集手机传感器的数据,然后对数据进行一系列的处理,主要有数据预处理、特征提取与选择,最后通过手机传感器数据建立模板或者进行统计分析后,对人体活动进行分类识别。

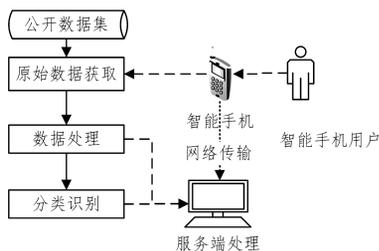


图1 人体活动识别的一般步骤

Fig. 1 General steps for human activity recognition

本文第2节介绍了系统实现需要获取数据的方法和主要问题;第3节介绍了常用的手机传感器数据处理的方法;第4节介绍了人体活动分类识别的常用方法;最后总结全文。

## 2 原始数据获取

获取传感器数据的数据采集模块,现在主流的IOS苹果手机<sup>[16-17]</sup>和Android手机<sup>[18-19]</sup>均可以通过编程来持续获得其内置传感器对应的传感器数据,内置传感器主要是加速度计

和陀螺仪,其中使用得较多的还有重力加速度计、磁强计和压强计。将采集到的数据通过网络传输到服务器,以便进行下一阶段的数据处理和分类识别。在采集样本数据时,需要在采集手机传感器数据之前采集参与者的预期活动类别、智能手机放置位置等信息,用以统计分析。而在采集预测数据时,只需要持续获取手机内置传感器的数据,用以分类预测。采集大量对应人类活动的手机传感器数据是一个十分繁琐的过程,公开数据集的寻找和数据集的扩展是十分有必要的。

### 2.1 公开数据集

数据集的获取是基于手机传感器的人体活动识别中最为关键的一步,不同数据集的采集方式、参与者的情况和采样活动种类等不尽相同。因此,适合不同数据集的分类方法可能各不相同。基于手机传感器的人体活动的常用数据集如表1所列。

表1 公开数据集  
Table 1 Public datasets

数据库	实验人数	活动种类	传感器种类
WISDM	29	18	加速度计、陀螺仪
Actitracker	36	6	加速度计
Kwapisz	29	6	加速度计、GPS
Shoab 2013	4	6	加速度计、磁力计、重力加速度、GPS
Shoab 2014	4	6	加速度计、陀螺仪、重力加速度、磁力计

WISDM数据集<sup>[20]</sup>是由29名参与者通过手机内置加速度计和陀螺仪采集的18种人体活动中的传感器数据;Actitracker数据集<sup>[21]</sup>由36名参与者把手机放在衣兜里,对加速度计数据进行采样;Kwapisz数据集<sup>[20]</sup>是由29名参与者将Android手机放在裤子前口袋中,以20Hz的采样频率采集GPS、加速度计的数据;Shoab 2013数据集<sup>[22]</sup>是由4名年龄在25~30岁之间的男性参与者将各自配备的4部三星智能手机Galaxy S2,放置并固定在裤子口袋、腰带、右手臂和右手腕,分别采集处于不同位置时手机内置的多个传感器的数据;Shoab 2014数据集<sup>[23]</sup>是由10名25~30岁之间的男性参与者各自使用5个智能手机,同时收集来自加速度计、陀螺仪、磁力计和重力加速度的手机传感器数据,手机分别置于裤子右口袋、裤子左口袋、腰带、右上臂和右手腕5个不同的位置。

### 2.2 数据集扩充

生活中的人体活动十分复杂,活动类别也很丰富,但是,目前针对基于手机传感器的人体活动识别,研究的种类往往只有几种,如散步、慢跑、上楼、下楼、坐、站等常见的人体活动,所采集的数据量也很有限,并且数据的采集需要耗费大量精力。因此,数据集的可靠扩展对人体活动识别具有重要意义。常见的数据集扩充方法主要有多个数据集进行融合和基于生成对抗网络<sup>[24]</sup>的数据集扩充。

#### 2.2.1 基于多个数据集融合的方法

对多个数据集进行融合,首先需要分析选取的多个数据集,确定活动集合,筛选出相同或者类似的活动;然后,确定使用的手机传感器类型,统一数据格式,对于不同采样率的数据集可以采用线性插值<sup>[25]</sup>的方法,将数据集重采样到统一的高频率下;再将数据样本中标签名与定义活动集合名称进行统一,实现标签重定义;最后,对数据进行统一整合。上述方法不仅适用于公开数据集的融合,也适用于将自己采集的数据集与公开数据集的融合。通过这样的整合可以解决数据集数

据不足的问题,但是这种方法需要大量的人工干预,操作繁琐,且扩充的数据集普遍存在分布不均匀的问题。

### 2.2.2 基于生成对抗网络的方法

生成式对抗网络(GAN)由生成器和鉴别器组成,结构如图2所示。其采用二人零和博弈思想,是一种无监督学习方法。生成器是为了生成样本数据,而且需要尽量把生成的数据包装成为一个逼真的样本输出,让鉴别器判定为真样本。将鉴别器比作一个0-1二分类器,当输出值大于0.5时,判定样本数据为真,小于0.5时则判定为假。生成器与鉴别器的最终目的是相反的,训练的过程也是二者博弈的过程。最后我们期待的结果是生成器取得胜利,鉴别器无法区分真假样本<sup>[26]</sup>。如果实验样本集中的数据量较少,可以考虑采用GAN的方法扩充数据集。生成器使用循环神经网络(RNN),可以契合人体活动时传感器数据的时序特征。训练完成后,将生成器提取出来,不断输入随机变量,便可以产生不同的可靠数据,从而扩充数据集。这种方法实现了扩充数据集的自动性,避免了繁琐的人工干预,但是模型不易于理解。

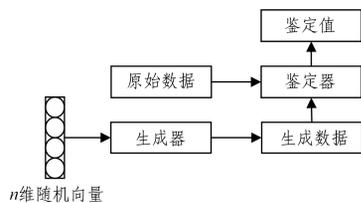


图2 GAN结构

Fig.2 Structure of GAN

### 2.3 传感器位置

人体活动时,肢体的活动方式各不相同。显然,当传感器放置在人体不同的位置时,传感器数据的变化也各不相同。对于特定的人体活动,我们可以找到最具识别意义的传感器数据源,这在之前的可穿戴传感器的研究中已经得到证实。Khan等<sup>[27]</sup>采集加速度传感器数据时将传感器固定在胸前和裤子口袋两个位置,分类识别时采用相同的算法,其分类识别准确率明显不同,证明了传感器佩戴位置对算法性能存在影响,进一步表明了传感器佩戴位置对传感器数据源信息的影响巨大。Kefer等<sup>[28]</sup>将传感器固定在手腕和手肘,利用传感器数据进行手势识别,经过对比证明,将传感器固定于手腕的效果更好,表明传感器位置对人体活动识别的精度有很大影响。

由于手机的移动性,用户随身携带手机时存放的位置会有不同。我们需要解决人体活动识别中手机位置改变对分类识别效果的影响,解决方案主要有两种:1)训练一个强鲁棒性模型,使其识别效果不受手机位置信息的影响;2)训练分层模型,先识别手机存放的位置,然后根据存放位置的不同构建不同的人体活动识别模型。Wang等<sup>[29]</sup>将传感器时序数据转化到频域,提取频域的特征值,消除位置信息对时序数据的影响,然后进行活动识别,但是这种方式的识别准确率太低,无法满足实际需求。这种方法需要将收集的样本全部进行频域转换,并且计算量大,难以实现实时性。近年来,分层识别模型的识别方式逐渐得到了研究人员的关注。Henar等<sup>[30]</sup>通过调用安卓手机上的多种内置传感器,可以准确识别出手机

的存放位置,如此收集到的传感器样本便可以自动加入位置信息,之后再利用加入位置信息的样本训练模型,分类准确率明显提高。结果证明,分层识别方法可以很好地消除传感器位置信息对活动识别的影响。

## 3 数据处理

首先需要将手机传感器获取的数据进行数据处理,才能够使下一步的分类识别更加准确。数据处理主要包括数据预处理、特征提取与特征选择。

### 3.1 数据预处理

数据预处理是基于手机传感器的人体活动识别中不可或缺的一步,主要是为了简化后续处理并提高准确率。数据预处理操作主要有平滑去噪、数据切割、重采样和归一化等。

#### 3.1.1 平滑去噪

系统信号采集时人体抖动和系统测量都会产生大量的噪声,并且在采集常用的加速度计数据时,需要排除加速度中重力加速度的影响,因此需要对数据进行滤波去噪。对于传感器信号的去噪,可以采用的滤波器多种多样,其中主要有移动均值滤波器<sup>[27,31]</sup>、高斯滤波器<sup>[32]</sup>、巴特沃斯滤波器<sup>[33]</sup>和3阶滑动平均滤波器<sup>[34]</sup>。这些传统的方法在滤除随机噪声方面均可取得很好的效果,但是需要构建滤波模型。而小波去噪只需要对传感器信号进行小波分解和重构便可以完成滤波,因此逐渐得到了研究人员的关注。文献<sup>[35]</sup>在研究步态识别时,利用小波去噪的方式对提取的加速度信号进行处理,明显解决了信号抖动和毛刺问题。由于人体活动时加速度计中的重力加速度分量属于低频信号,文献<sup>[36-37]</sup>使用低通滤波器对线性加速度分量与重力加速度分量进行了分离,有效地消除了加速度中重力加速度的影响。

#### 3.1.2 数据切割

在采集样本数据时,采取视频和手机传感器同步监控用户的方式,可以根据时间对准的方式准确地切割出一段时间间隔内用户活动类别与手机传感器时间序列的对应。这种采集方式能够直接采集多种活动,自然地观察到多种活动之间过渡时手机传感器信号的变化,但切割时需要大量的人工干预。常用的方法还有通过用户提前输入预期活动,用手动方式告知采集开始和采集结束,以此来直接获得一种活动的手机传感器序列数据。这种方式采集繁琐,但是切割容易。

在实际采集预测数据时,对于单个活动的开始时间和结束时间是不明确的,需要连续不断地收集手机传感器信号。因此,收集到的信号数据有多个活动,且信号太长,无法直接进行分类识别,因此数据切割是十分必要的。数据切割需要将较长的数据流切割为长度相似的数据样本,这样有利于后续的特征提取和分类识别。滑动窗口法是目前主要的数据切割方法,需要设定窗口大小和窗口覆盖率。该方法主要是估计一个人体活动的大致时间为一个窗口大小,连续切割采集到的手机传感器的时序数据,切割后的一个窗口大小的传感器序列数据为一个预测数据样本。文献<sup>[38]</sup>在研究中改变了滑动窗口的大小,系统识别准确率明显改变。结果显示,滑动窗口过短或者过长,均会导致识别准确率降低。在大部分情况下,将滑动窗口大小设置为2s左右时效果较好,证明了窗口大小会影响系统识别的精度。窗口覆盖率指两个相邻窗口

间的重叠程度。一般情况下,需要设定适合的窗口覆盖率来有效地减弱活动之间过渡的影响。窗口覆盖率通常设定为50%,详情请见文献[39],也有其他一些非常规的选择,详情请见文献[34]和文献[40]。

### 3.1.3 重采样和归一化

常用的预处理方法还有重采样和归一化。对传感器信号重采样是将时间序列从一个频率转换为另一个频率的过程。同一种人体活动持续时间会因动作的快慢而不同,导致在同一频率下收集到的样本数据点数不同,因此需要对数据进行重采样操作来统一信号长度,以便进行后续的特征提取和分类识别。文献[41]在进行手势识别的过程中对加速度信号进行重采样,消除了不同参与者活动速度的差异。在采集传感器信号时,参与者在进行同一种人体活动时的用力差异会导致信号振幅有所不同,这时归一化技术便可以通过限定振幅大小的方式来解决这一问题。文献[42]对跑、站立、跳和走路这4种常见的人体活动进行识别时,将采集到的加速度样本数据按照活动种类分别进行了归一化,排除了用力差异的影响。

## 3.2 特征提取与选择

为了对人体活动进行深层次的描述,特征提取和选择是十分关键的技术,常结合机器学习等统计分析方法使用,其位于预处理和分类识别操作之间,对分类识别的效果影响很大。特征提取和选择过程在不同的研究中具有很大的差别,人体活动的种类和选取的分类模型不同,需要提取的特征就会有差异。

### 3.2.1 特征提取

人体活动时的传感器信号主要有时域特征、频域特征和时频特征这3类。除此之外,将时间序列的传感器信号转化到图像空间,应用计算机视觉的方法提取到的图像特征也逐渐受到研究人员的关注。在不同的研究细节中,我们发现新颖的特征往往可以更好地描述人体活动,提高识别的准确率。

时域特征反映信号的分布,直接对传感器时序数据提取特征,提取方法简单、计算量小,比较适合对实时性要求较高的场合,十分适用于基于手机传感器的人体活动识别研究。信号的统计特征应用最为广泛,主要有均值、标准差、方差等。此外,还有一些时域特征比较常用,例如均方根、自回归系数、互相关系数等,可以对振动信号波形进行更为细致的表征。

与时域特征观察信号变化幅度不同,频域特征通过观察功率谱来提取特征。进行频域特征提取时,首先需要将提取的信号从时域转化到频域,因此计算量很大。时域转化到频域的方法主要有快速傅里叶变换(FFT)和离散余弦变换(DCT),以往的研究中大多采用FFT的方式。比较常见的频域特征有FFT系数、功率谱密度、能量谱密度和频域熵等。频域特征能够很好地描述人体活动的周期重复性,对提升人体活动识别准确率有很大的帮助。

时频分析法相对于前两种方法出现较晚,小波变换是时频分析法的主要手段。与传统的FFT相比,小波变换是时间和频率的局部变换,本质上是利用一簇不同尺度的小波信号叠加来表示原始信号,解决了傅里叶变换不能解决的许多问题,常用的特征有小波能量等。

将时间序列数据编码为图像数据,特征重构成为将人体

活动识别问题转化成图像分类问题<sup>[43]</sup>。常用的图像编码方式有格拉姆角场数据处理算法、马尔可夫转换区数据处理算法、频谱图 Spectrogram 数据处理算法等。这种方法在将传感器时序数据转化为图像之后,还要结合图像处理才能实现分类识别,这是一个相当复杂的过程,需要大量的计算。

除了经常使用到的特征和方法之外,新颖特征的研究也是十分有必要的,这类特征有时更能符合特定的人体活动识别,有助于提高识别率。在自回归模型的基础上,文献[42]提出了比较新颖的特征。在研究实时的人体活动识别系统时,文献[44]在贝叶斯曲线的基础上提出了曲线面积特征。利用已知的物理知识,文献[45]提出了一种根据加速度计算的失重特征,在垂直方向上的活动识别中有很好的表现。

### 3.2.2 特征选择

目前,已提出的描述人体活动的传感器信号特征有很多。在特定的研究中需要对特征进行选择,可以去除冗余特征,减少不必要的计算,而且通过特征选择之后,训练出来的模型泛化能力更强。在选择特征时,要考虑特征之间是否存在冗余以及特征能否描述所要识别的人体活动。特征选择的一般过程如图3所示,主要包括4个过程。

(1)生成过程:生成候选的特征子集。生成过程其实是一个搜索过程,这个过程主要有完全搜索、启发式搜索和随机搜索3种策略,可以从以下3种情况开始:没有特征、所有特征和随机特征子集。在前两种情况下,每次迭代可以增加、删除特征;在第三种情况下,每次迭代随机增加或者删除特征。

(2)评价函数:评价特征子集的好坏。根据评价准则的不同,评价函数可以分为过滤式方法、封装式方法和嵌入式方法。过滤式方法按照发散性或者相关性对各个特征进行评分,通过设置阈值大小或者特征个数来选择特征,在机器学习前便可以得到结果,计算简单,如Relief-F<sup>[46]</sup>等,是最常用的方法;封装式方法根据目标函数每次选择若干特征或者排除若干特征,该过程在机器学习的过程中进行,计算复杂度高,得到的效果较好;嵌入式方法使用某些机器学习的算法和模型进行训练,得到各个特征的权值系数,并根据权值大小选择特征。

(3)停止条件:决定停止的时刻。生成过程和评价函数可能会对怎么选择停止条件产生影响,停止条件有以下4种选择:达到预定义的最大迭代次数;达到预定义的最大特征数;增加(删除)任何特征不会产生更好的特征子集;评价准则判定为最优特征子集。

(4)验证过程:特征子集是否有效。验证过程并不是特征选择本身的一部分,但是选择出的特征必须是有效的。因此,需要使用不同的测试集和学习方法来验证选择出来的特征子集,然后比较这些验证结果。

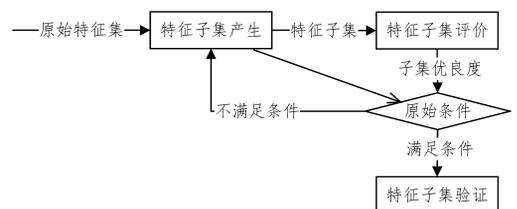


图3 特征选择的一般过程

Fig. 3 General process of feature selection

## 4 分类识别

分类识别是基于手机传感器的人体活动识别的核心,由于不同的分类模型在不同研究对象中的分类效果是不同的,因此我们需要选择合适的分类模型。在模式识别领域的早期,产生了基于模板匹配的分类识别方法。随着科学技术的

发展和计算的能力的提高,基于手机传感器的人体活动识别中使用得最广泛的一种识别方法是基于统计分析的识别方法。目前传统机器学习是构建分类器最常用的方法,除了传统机器学习方法之外,近年来深度学习也开始用于基于手机传感器的人体活动识别中。表2对人体活动识别研究中常用的分类方法进行了对比。

表2 分类方法对比  
Table 2 Comparison of classification methods

分类方法	优点	缺点
动态时间翘曲	1)无需训练模型,对于数据量需求不大;2)只需对比测试模板与样本模板的相似程度即可;3)耗时少,实时性强	1)在类别较多的情况下分类结果不佳;2)对于序列的长短敏感性太高;3)鲁棒性差
决策树	1)模型易于理解;2)测试数据集时处理速度很快;3)扩展性很好,树的大小独立于数据库大小	1)容易过拟合;2)对于缺失数据处理困难;3)忽略了特征之间的关联性
K近邻	1)理论简单,容易实现;2)加入新数据不必重新训练模型	1)对于大容量数据集,计算量过大;2)样本数据的不平衡对分类器的效果影响很大;3)K值的良好选择不易
朴素贝叶斯分类器	1)仅仅是特征概率的数学运算,训练和识别的速度很快;2)支持增量式运算,可以实时对新增样本进行训练;3)模型容易理解	假设特征之间相互独立,而传感器数据特征之间具有较强的相关性
隐马尔可夫模型	1)可以直接使用传感器序列数据进行模型训练;2)分类效果好,训练容易	1)模型复杂,不易理解;2)计算代价很大
支持向量机	1)对小样本、非线性问题的效果很好;2)泛化能力强;3)可以很好解决高维数据集	1)对缺失数据十分敏感;2)核函数的选择不易
深度学习	1)可以自动提取深层次的隐含特征;2)泛化能力强,分类准确度高	1)模型复杂,不容易理解;2)训练耗时,计算量很大;3)对样本数据量的需求很大

### 4.1 基于模板匹配的识别方法

基于模板匹配的活动识别一般采用的技术是动态时间规整算法(Dynamic Time Warping, DTW)。DTW算法首先需要建立模板库,用来存储每个类别的样本模板。我们可以把每个样本模板表示为 $\{\mathbf{R}(1), \mathbf{R}(2), \mathbf{R}(3), \dots, \mathbf{R}(m), \dots, \mathbf{R}(M)\}$ ,其中 $\mathbf{R}(m)$ 为第 $m$ 个数据帧的特征向量, $M$ 为模板的数据帧总数。类似的要预测的样本可以表示为 $\{\mathbf{T}(1), \mathbf{T}(2), \mathbf{T}(3), \dots, \mathbf{T}(n), \dots, \mathbf{T}(N)\}$ :其中 $\mathbf{T}(n)$ 为第 $n$ 个数据帧的特征向量, $N$ 为模板的数据帧总数。若要使测试向量的时间轴( $i$ )非线性映射到其模板向量时间轴( $j$ ),则需要取时间规整函数,如式(1)所示:

$$y = \omega(i) \quad (1)$$

计算两个向量之间的最优匹配路径 $Dist$ ,如式(2)所示:

$$Dist = \min_{\omega(i)} \sum d[\mathbf{T}(i), \mathbf{R}(\omega(i))] \quad (2)$$

其中, $d[\mathbf{T}(i), \mathbf{R}(\omega(i))]$ 是测试向量 $\mathbf{T}(i)$ 与模板向量 $\mathbf{R}(j)$ 之间的距离。当 $N=M$ 时,可以考虑测试模板与样本模板能否对应起来或者直接计算 $Dist$ 。当 $N < M$ 时,需要通过线性映射的方式解决模板数据长度不同的问题,计算测试模板与映射样本模板得到的 $\{\mathbf{R}(1), \mathbf{R}(2), \dots, \mathbf{R}(N)\}$ 之间的 $Dist$ 距离。通过比较计算出来的测试样本与多个模板样本的最优匹配路径距离,来识别分类。这样,DTW算法就将全局优化的复杂问题转化为局部优化的多个问题。Li<sup>[17]</sup>通过使用DTW算法分析加速度传感器数据来识别手势活动,获得了较好的分类效果,并且通过利用斜率来界定曲线路径的方式,优化DTW算法,使得耗时更少,识别精度更高。当样本数量很少,且分类类别也较少时,使用DTW算法来识别人体活动是一种很好的选择。但是DTW算法的鲁棒性很差,用户、设备等方面的改变需要重新设置模板才能取得较好的效果,而且传感器

数据的长度对分类影响很大。

### 4.2 基于传统机器学习方法的识别方法

目前传统机器学习方法是分类识别中最为常用的方法。在基于手机传感器的人体活动识别中,应用的方法很多。这些方法可以通过有限的样本构建出鲁棒性较强的分类模型,具有较强的实用性。

#### 4.2.1 决策树

决策树是一种典型的树形结构,由内部节点、叶节点和有向边组成。内部节点表示一个特征或属性,叶节点表示一个类。在决策树中,每个决策都可能会引出至少两个事件,决策树训练得到的分类规则能够被表达成若干个if-then的组合。其中ID3, C4.5, CART均为决策树中比较常见的算法。Quinlan<sup>[47]</sup>提出的ID3算法引入了信息增益的统计量,解决了决策树节点上的属性分配问题,使决策树的实用性增强,但是ID3算法在用信息增益选择属性时会偏向选择取值多的属性。文献<sup>[48]</sup>使用根据ID3改进的C4.5算法,用信息增益率来选择属性,弥补了ID3算法的不足,通过加速度计和重力加速度计的传感器数据进行常见生活中的人体活动识别,通过与其他算法进行比较,C4.5算法在很多情况下能获得较高的识别精度。CART采用基于最小距离的基尼指数估计函数,非常灵活,允许部分错分样本。随机森林是基于CART的一种分类器,文献<sup>[10]</sup>使用随机森林算法,通过获取传感器数据,来推测用户在智能手机上的按键,获得了不错的分类效果。在大多数情况下,随机森林算法在人体活动识别中能够取得较好的结果,常作为实验结果的对比分类器。

#### 4.2.2 K近邻

K近邻算法是一种基本的分类与回归算法。在基本实现上,使用的是多数表决的惰性学习过程,核心就是使用一种距

度量。它并没有学出判别模型,也没有算出一个新东西,而是简单地统计距离目标点最近的  $K$  个节点中数目最多的标签并将其赋予目标点。文献[49]利用传感器信息对爬楼梯等动作进行识别,将  $K$  近邻和其他算法进行比较, $K$  近邻分类器得到了最好的识别效果。但是这种方法对于  $K$  值的选取比较苛刻,容易受到样本数据中孤立点的影响,因此分类结果不稳定。

#### 4.2.3 朴素贝叶斯分类器

朴素贝叶斯分类器假设特征属性之间相互独立,然后结合条件概率和贝叶斯算法,对预测样本求取属于每个类别的概率,最后通过比较概率大小来获得最终的分类识别结果。

$$p(y_i | x) = \frac{p(x | y_i) p(y_i)}{p(x)} = \frac{\prod_{i=1}^m p(\alpha_i | y_i)}{p(x)} \quad (3)$$

其中,  $y$  是类别,  $x$  是待分类项,  $\alpha$  是  $x$  的各项特征属性。文献[46]在研究人体日常活动识别时采用多种分类算法进行分类识别,结果表明朴素贝叶斯分类器的分类效果最好。文献[50]在进行基于加速度传感器的室内行为监测的研究时使用朴素贝叶斯分类器,最终获得了较高的识别率。朴素贝叶斯分类器的稳定性较好,在几种简单活动的识别中有较好的识别效果,但其要求特征之间互相独立,有悖于事实。

#### 4.2.4 隐马尔可夫模型

隐马尔可夫模型 (Hidden Markov Model, HMM) 考虑到了数据的时序性,因此十分适用于基于手机传感器的人体活动识别研究。隐马尔可夫模型描述了一个含有隐含未知参数的马尔可夫过程,其结构如图 4 所示。图 4 中,  $x$  表示隐含状态(如  $M_1, M_2, M_3, M_4$ )间的转换概率,  $y$  表示隐含状态到可观测状态(如  $N_1, N_2, N_3, N_4$ )的输出概率。在具体的分类识别过程中,需要预测的分类结果为隐含状态,收集的训练样本集为可观测状态。文献[51]在进行跌倒检测的研究时,通过采集的加速度时序数据,训练出来的 HMM 模型识别率接近 100%。文献[52]在研究老人活动监控时仅采集加速度传感器的数据,使用 HMM 模型识别老人日常生活活动,分类准确率高达 99%。隐马尔可夫模型可以直接对原始数据进行学习,分类效果较好,但是计算代价大,模型不易理解。

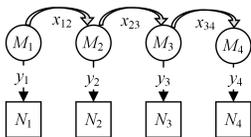


图 4 隐马尔可夫模型

Fig. 4 Hidden Markov model

#### 4.2.5 支持向量机

支持向量机 (Support Vector Machine, SVM) 是通过学习样本求解的最大边距超平面的方式实现分类。SVM 不仅可以解决线性分类问题,通过改变核函数,还可以解决非线性分类问题,在特征空间内建立超曲面。文献[53]在识别婴儿活动时,使用加速度传感器和压力传感器采集样本,使用 SVM 进行分类时准确率很高。SVM 可以更好地解决样本量小和特征维度高的分类识别问题,但是也存在模型不易理解和核函数的选择问题。

### 4.3 基于深度学习的识别方法

深度学习源于神经网络的研究,建立模拟人类大脑的神经连接结构,学习样本数据的内在规律和深层次表示,从而进行分类识别。传统机器学习容易出现泛化能力不足的问题,而深度学习结构更为复杂,泛化能力增强,但是需要大量的样本训练,计算耗时。

近年来,深度学习已经成为机器学习领域中主要的研究方向,在基于深度学习的人体活动识别方面的应用也逐渐受到关注,主要方法有卷积神经网络 (Convolutional Neural Networks, CNN) 和循环神经网络 (Recurrent Neural Network, RNN)。CNN 使预处理简单化,由于网络的局部连接和空间共享特性,对比传统的机器学习方法,其自动提取传感器特征进行人体活动识别,成为了一种高效的识别方法。文献[54]提出了一种基于部分权值共享的 CNN 方法,利用 3 个公开数据集集中的传感器数据识别人体活动,结果表明准确率高于传统机器学习的方法。RNN 由于梯度消失的原因只能有短期记忆,长短期记忆网络 (Long Short-Term Memory, LSTM) 通过精妙的门控制将短期记忆与长期记忆结合起来,并且一定程度上解决了梯度消失的问题。手机传感器序列数据具有时序性,相比 CNN, LSTM 能够提取到传感器数据的深层次时序性特征,从而获得更好的分类效果。Zheng 等[55]利用智能手机内置传感器采集的时序数据,在进行 9 种常用的人体活动识别时,对比了 LSTM、常用的传统机器学习方法和 CNN,结果证明 LSTM 在识别准确率上有明显的提高。

**结束语** 本文对基于手机传感器的人体活动识别的系统框架、基本流程和关键方法做了详细的介绍,可以了解到基于手机传感器的人体活动识别在识别流程上比较成熟,分类精度也达到了较好的效果,但仍然需要进一步的研究。

(1) 现有的研究只能对某些简单的动作进行识别,在限定某种场景的情况下才能有较高的识别率。今后我们需要对复杂活动进行进一步的探索。

(2) 目前建立的通用性模型鲁棒性不足,大部分研究没有考虑传感器位置变化、传感器数据采集设备差距以及用户个体性差异等因素的影响。今后在建立强鲁棒性模型方面还需要进一步的研究。

(3) 智能手机中有内置传感器,由于利用侧通道攻击可以获取用户隐私,因此存在隐私安全问题。有必要研究如何在不影响传感器性能和用户体验的情况下,保护用户的隐私。

(4) 基于手机传感器的人体活动识别不仅要考虑识别的准确性,通常还要考虑系统的实时性和手机的耗电问题,这样才会有较大的应用价值。因此,研究兼顾识别准确率、系统实时性和手机耗电问题的识别方法,将是今后研究的重点。

### 参考文献

- [1] SAUNDERS J B, IMNAN V T, EBERHART H D. The major determinant in normal and pathological gait[J]. Journal of Bone & Joint Surgery-american Volume, 1953, 35(3): 543-558.
- [2] MORRIS J R. Accelerometry-A technique for the measurement of human body movement[J]. Journal of Biomechanics, 1973, 6(6): 729-736.

- [3] KELLOKUMPU V,ZHAO G,PIETIKAINEN M. Human activity recognition using a dynamic texture based method[C]// British Machine Vision Conference, USA; IEEE, 2008, 1: 1-10.
- [4] YOUSAF M H, HABIB H A. Virtual Keyboard; Real-Time Finger Joints Tracking for Keystroke Detection and Recognition [J]. Arabian Journal for Science and Engineering, 2014, 39(2): 923-934.
- [5] YI W, XINLI J, RONGYU C, et al. Robust Indoor Human Activity Recognition Using Wireless Signals [J]. Sensors, 2015, 15(7): 17195-17208.
- [6] LI M, MENG Y, LIU J, et al. When CSI Meets Public WiFi: Inferring Your Mobile Phone Password via WiFi Signals[C]// the 2016 ACM SIGSAC Conference on Computer and Communications Security, New York; ACM, 2016: 1068-1079.
- [7] NANDAKUMAR R, GOLLAKOTA S, WATSON N. Contactless Sleep Apnea Detection on Smartphones[C]// the 13th Annual International Conference, New York; ACM, 2015: 22-24.
- [8] LEUNG X, TANFORD S, JIANG L. Is a picture really worth a thousand words[J]. Journal of Hospitality and Tourism Technology, 2017, 8(1): 19-38.
- [9] HONG F, WEI M, YOU S, et al. Waving authentication: your smartphone authenticate you on motion gesture[C]// Proc of ACM Conference on Human Factors in Computing Systems, New York; ACM Press, 2015: 263-266.
- [10] SEN S, GROVER K, SUBBARAJU V, et al. Inferring smartphone keypress via smartwatch inertial sensing[C]// IEEE International Conference on Pervasive Computing & Communications Workshops, Kona; IEEE, 2017: 685-690.
- [11] WANG Y, WU C, ZHENG K, et al. Improving Reliability: User Authentication on Smartphones Using Keystroke Biometrics[J]. IEEE Access, 2019, 7(7): 26218-26228.
- [12] AHMADI S S, RASHAD S, ELGAZZAR H. Machine Learning Models for Activity Recognition and Authentication of Smartphone Users[C]// the 2019 IEEE 10th Annual Ubiquitous Computing, New York; Electronics & Mobile Communication Conference (UEMCON), 2019: 561-567.
- [13] DANIEL K, JOAN C, KEVIN C, et al. A multimodal smartphone sensor system for behaviour measurement and health status inference[J]. Information Fusion, 2020, 53: 43-54.
- [14] KATHERINE M, SPACHOS P, PLATANIOTIS K N. Smartphone-Based Wellness Assessment Using Mobile Environmental Sensors[J]. IEEE Systems Journal, 2020, 1(1): 1-11.
- [15] CHEN Z, JIANG C, XIANG S, et al. Smartphone Sensor-Based Human Activity Recognition Using Feature Fusion and Maximum Full a Posteriori[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(7): 3992-4001.
- [16] BERCHTOLD M, BUDDE M, GORDON D, et al. ActiServ: Activity Recognition Service for mobile phones[C]// 2010 International Symposium on Wearable Computers (ISWC 2010), Seoul; IEEE Computer Society, 2010: 1-8.
- [17] LI Y. 3D gesture recognition based on dynamic template matching algorithm for intelligent wearable devices[J]. Chinese Journal on Internet of Things, 2019, 000(001): 97-105.
- [18] GONG L, ZHAO Y, CHAOCAN X, et al. Robust Light-weight Magnetic-based Door Event Detection with Smartphones[J]. IEEE Transactions on Mobile Computing, 2018, 18(11): 2631-2646.
- [19] AHMED A, MAHAMOD I, ROSDIADDEE N, et al. On the Best Sensor for Keystrokes Inference Attack on Android[J]. Procedia Technology, 2013, 9(9): 989-995.
- [20] KWAPISZ J R, WEISS G M, MOORE S A. Activity recognition using cell phone accelerometers[J]. Acm Sigkdd Explorations Newsletter, 2011, 12(2): 74-82.
- [21] WEISS G M, LOCKHART J W, PULICKAL T, et al. Actitracker: A Smartphone-Based Activity Recognition System for Improving Health and Well-Being[C]// IEEE International Conference on Data Science & Advanced Analytics, Montreal; IEEE, 2016: 682-688.
- [22] SHOAI B M, SCHOLTEN H, HAVINGA P J M. Towards physical activity recognition using smartphone sensors[C]// IEEE International Conference on Ubiquitous Intelligence & Computing & IEEE International Conference on Autonomic & Trusted Computing, Vietri sul Mare; IEEE Computer Society, 2013: 80-87.
- [23] SHOAI B M, BOSCH S, INCEL O, et al. Fusion of Smartphone Motion Sensors for Physical Activity Recognition[J]. Sensors, 2014, 14(6): 10146-10176.
- [24] ZHANG Y. A survey on generative adversarial networks[J]. Electronic Design Engineering, 2018, 26(5): 34-37, 43.
- [25] POWELL M J D. A Direct Search Optimization Method That Models the Objective and Constraint Functions by Linear Interpolation[J]. Advances in Optimization & Numerical Analysis, 1994, 275(275): 51-67.
- [26] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Networks[J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [27] KHAN A M, LEE Y K, LEE S, et al. Accelerometer's position independent physical activity recognition system for long-term activity monitoring in the elderly[J]. Medical & Biological Engineering & Computing, 2010, 48(12): 1271-1279.
- [28] KEFER K, HOLZMANN C, FINDLING R D. Evaluating the Placement of Arm-Worn Devices for Recognizing Variations of Dynamic Hand Gestures [J]. Journal of Mobile Multimedia, 2017, 12(3): 225-242.
- [29] WANG C, ZHANG J Z, WANG Z, et al. Position-independent activity recognition model for smartphone based on frequency domain algorithm[C]// International Conference on Computer Science & Network Technology, Dalian; IEEE, 2013: 396-399.
- [30] HENAR M, BERNARDOS A M, JOSUE I. Activity logging using lightweight classification techniques in mobile devices[J]. Personal & Ubiquitous Computing, 2013(4): 675-695.
- [31] YANG J. Toward Physical Activity Diary; Motion Recognition Using Simple Acceleration Features with Mobile Phones[C]// Proceedings of the 1st international workshop on Interactive multimedia for consumer electronics, Beijing; Association for Computing Machinery, 2009: 1-10.
- [32] CHO S J, CHOI E S, AND BANG W C, et al. Two-stage recognition of raw acceleration signals for 3-D gesture-understanding

- cell phones[C]//The 10th International Workshop on Frontiers in Handwriting Recognition. Nijme Gen,2006:1-6.
- [33] ZHANG Y, MARKOVIC S, SAPIR I, et al. Continuous Functional Activity Monitoring Based on Wearable Tri-axial Accelerometer and Gyroscope[C]//5th International Conference on Pervasive Computing Technologies for Healthcare (PervasiveHealth) and Workshops. Dublin;IEEE,2011:370-373.
- [34] KHAN A M, LEE Y K, LEE S Y, et al. Human Activity Recognition via an Accelerometer-Enabled-Smartphone Using Kernel Discriminant Analysis[C]//2010 5th International Conference on Future Information Technology (FutureTech). Busan: IEEE,2010:1-6.
- [35] TU B, GU L, TAI R, et al. Gait recognition using adaptive waveletdenoising and SIFT descriptors [J]. Journal of Chinese Computer Systems,2018,39(6):254-258.
- [36] BOURKE, ALAN K, et al. Optimum gravity vector and vertical acceleration estimation using a tri-axial accelerometer for falls and normal activities[C]//2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Boston;IEEE,2011:7896-7899.
- [37] NOOR M, SALCIC H M Z, WANG K K. Dynamic sliding window method for physical activity recognition using a single tri-axial accelerometer[C]//2015 IEEE 10th Conference on Industrial Electronics and Applications (ICIEA). Auckland: IEEE, 2015:102-107.
- [38] ORESTI B, JUAN-MANUEL G, MIGUEL D, et al. Window Size Impact in Human Activity Recognition[J]. Sensors,2014,14(4):6474-6499.
- [39] YANG J, WANG S, CHEN N, et al. Wearable Accelerometer Based Extendable Activity Recognition System[C]//IEEE International Conference on Robotics & Automation. Anchorage: IEEE,2010:3641-3647.
- [40] ARIF M, BILAL M, KATTAN A, et al. Better Physical Activity Classification using Smartphone Acceleration Sensor[J]. Journal of Medical Systems,2014,38(9):95-104.
- [41] KELA J, KALLIO S. Accelerometer-based gesture control for a design environment[J]. Personal and Ubiquitous Computing, 2006,10(5):285-299.
- [42] HE Z, JIN L. Activity Recognition from Acceleration Data Based on Discrete Cosine Transform and SVM[C]//2009 IEEE International Conference on Systems, Man and Cybernetic. San Antonio:IEEE,2009:5041-5044.
- [43] WANG Z, OATES T. Imaging time-series to improve classification and imputation[J]. Computer Science,2015,3(27):3339-3345.
- [44] TAPIA E M, INTILLE S, HASKELL W, et al. Real-Time Recognition of Physical Activities and Their Intensities Using Wireless Accelerometers and a Heart Rate Monitor[C]//2007 11th IEEE International Symposium on Wearable Computers. Boston;IEEE,2007:37-40.
- [45] HE Z, LIU Z, JIN L, et al. Weightlessness feature-a novel feature for single tri-axial accelerometer based activity recognition [C]//2008 19th International Conference on Pattern Recognition. Tampa;IEEE,2008:1-4.
- [46] NATTHAPON P, SURAPA T, EKAWIT N, et al. Analysis of Optimal Sensor Positions for Activity Classification and Application on a Different Data Collection Scenario[J]. Sensors,2017,17(4):774-783.
- [47] QUINLAN J R. Induction of decision trees [J]. Machine Learning,1986,1(1):81-106.
- [48] ERMES M, J PÄRKKA, MANTYJARVI J, et al. Detection of Daily Activities and Sports With Wearable Sensors in Controlled and Uncontrolled Conditions[J]. IEEE Transactions on Information Technology in Biomedicine,2008,12(1):20-26.
- [49] SONG W, ADE C, BROXTERMAN R, et al. Activity recognition in planetary navigation field tests using classification algorithms applied to accelerometer data[C]//2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. San Diego;IEEE,2012:1586-1589.
- [50] USLU G, ALTUN O, BAYDERE S. A Bayesian approach for indoor human activity monitoring[C]//2011 11th International Conference on Hybrid Intelligent Systems (HIS). Melacca: IEEE,2011:324-327.
- [51] TONG L, SONG Q, GE Y, et al. HMM-Based Human Fall Detection and Prediction Method Using Tri-Axial Accelerometer [J]. IEEE Sensors Journal,2013(5):1849-1856.
- [52] LI A, JI L, WANG S, et al. Physical activity classification using a single triaxial accelerometer based on HMM[C]//IET International Conference on Wireless Sensor Network 2010 (IET-WSN 2010). Beijing;IEEE,2010:155-160.
- [53] NAM Y, PARK J W. Child Activity Recognition Based on Cooperative Fusion Model of aTriaxial Accelerometer and a Barometric Pressure Sensor [J]. IEEE Journal of Biomedical and Health Informatics,2013,17(2):420-426.
- [54] ZENG M, NGUYEN L T, YU B, et al. Convolutional Neural Networks for Human Activity Recognition using Mobile Sensors[C]//6th International Conference on Mobile Computing, Applications and Services. Austin:IEEE,2014:197-205.
- [55] ZHENG Y, LI F, ZHANG L, et al. Human posture detection method based on long short term memory network[J]. Journal of Computer Applications,2018,38(6):1568-1574.



**ZHANG Chun-xiang**, born in 1995, master student, is a member of China Computer Federation. His main research interests include data analysis and cyber security.



**ZHAO Chun-lei**, born in 1979, Ph.D, associate professor, is a member of China Computer Federation. Her main research interests include cyber security and so on.