

基于旋转模式的移动设备佩戴位置识别方法^{*}

时岳^{1,2}, 喻纯^{1,2}, 史元春^{1,2}

¹(清华大学 计算机科学与技术系,北京 100084)

²(清华信息科学与技术国家实验室(清华大学) 普适计算研究部,北京 100084)

通讯作者: 时岳, E-mail: shiyue625@gmail.com

摘要: 移动设备计算能力和传感能力的发展,使其可以为用户提供多种基于情境信息的服务。移动设备的佩戴位置作为一种重要的情境信息,影响着其他用户活动的识别效果和移动应用的自适应功能。分析得出当移动设备在不同身体部位佩戴时,旋转变化模式不同。提出了一种识别设备随身佩戴位置的方法。该方法使用加速计与陀螺仪两种传感器进行数据融合,计算出旋转半径、角速度幅度和重力加速度并提取特征。在分类时,使用随机森林作为分类器,并与使用支持向量机的方案进行了对比。为了检验其效果,在包含3种佩戴位置和13种用户活动种类的公开数据集上进行了实验。实验结果显示,该方法能够达到平均95.39%的交叉验证准确率;同时表明,在满足旋转占主要成分和重力加速度方向稳定的前提下,使用旋转变化信息和集成分类器有助于提高分类效果。与之前的方法相比,该方法可以更准确地对佩戴位置进行区分,并对新用户与新活动类型情况下的位置识别具备更强的泛化能力。

关键词: 佩戴位置;移动设备;惯性传感器;旋转模式

中图法分类号: TP391 文献标识码: A

中文引用格式: 时岳,喻纯,史元春.基于旋转模式的移动设备佩戴位置识别方法.软件学报,2013,24(8):1898–1908. <http://www.jos.org.cn/1000-9825/4409.htm>

英文引用格式: Shi Y, Yu C, Shi YC. On-Body position recognition method for mobile devices using rotation patterns. Ruan Jian Xue Bao/Journal of Software, 2013,24(8):1898–1908 (in Chinese). <http://www.jos.org.cn/1000-9825/4409.htm>

On-Body Position Recognition Method for Mobile Devices Using Rotation Patterns

SHI Yue^{1,2}, YU Chun^{1,2}, SHI Yuan-Chun^{1,2}

¹(Department of Computer Science and Technology, Tsinghua University, Beijing 100084, China)

²(Pervasive Computing Division, Tsinghua National Laboratory for Information Science and Technology (Tsinghua University), Beijing 100084, China)

Corresponding author: SHI Yue, E-mail: shiyue625@gmail.com

Abstract: The development of the computing power and sensing ability of mobile devices allows them to provide various context-adapted services to users. The on-body position of mobile devices, which is one kind of important context information, affects the recognition of other human activities and the adaptability of many mobile applications. The study provides a method to recognize the on-body positions of mobile devices, inspired by the analysis that different positions on the body have distinguishable rotation patterns. The research then fuses the data sensed by the accelerometer and the gyroscope to calculate the rotation radius, the magnitude of the angular velocity as well as the gravity acceleration and then extract a set of features. A classifier based on the Random Forest is used for classification and compared with the solution based on the support vector machine. To evaluate the method, the paper conducts an experiment on a public dataset with 3 types of positions and 13 types of activities. Results show that the method achieved an accuracy of 95.39% on average in the cross validation and indicate that when rotation is the main component in the movement and the direction of the

* 基金项目: 国家自然科学基金(61272230); 国家高技术研究发展计划(863)(2009AA01Z336); 清华大学自主科研项目(20111081113)

收稿时间: 2013-01-18; 定稿时间: 2013-03-29

gravity acceleration is stable, the information about rotation variation and the ensemble classifier are useful to improve the classification accuracy. Compared to previous works, it is able to classify the positions more precisely and has more generalization ability for new users and new activities.

Key words: on-body position; mobile device; inertial sensor; rotation pattern

以手机为代表的智能移动设备近年来取得了快速的发展,已经成为一种重要的交互媒介。通过增强计算能力和集成多种传感器,移动设备能够收集和识别用户和环境的情境信息,从而提供更好的应用服务和交互体验。例如,随用户佩戴的智能手机可以通过惯性传感器如加速计和陀螺仪获得用户的运动数据,进而可以识别用户所处的不同运动状态,如行走、跑动以及坐下等。通常,用户有多种可能的方式佩戴移动设备,包括固定在身体的某一部位或握在手中等。由于不同的佩戴位置会对识别模型和参数造成影响,基于用户运动情况提供服务的应用往往需要提醒用户将设备佩戴在指定位置。例如对于计步器应用,当佩戴在腰部时效果最理想,挂在胸口或口袋中会增大测量误差。其他很多近期发展的用于感知自我的可穿戴设备^[1-3]也都对佩戴位置有一定的要求,错误的佩戴往往会造成数据失效。例如对于 DuoFertility Monitor^[2],一款通过检测体温推断最佳受孕时间的应用,由于人身体不同部位体温变化有差异,需要佩戴者将其放置在腋下以达到精确的检测。有时在建立运动状态识别模型的过程中会针对不同佩戴位置分别考虑,实际使用过程中再由用户手动向应用指定。如在用户身上配置多个传感器以精确捕捉人运动情况的时候,需要将若干同样类型的传感器佩戴在用户身上的不同位置。在移动设备不能自动判断佩戴位置的情况下,无论是采用预先假设还是请用户指定的方式,都会影响交互的效果并且给用户增加负担。实现对佩戴位置的自动检测,可以提高可穿戴感知应用的可用性,使其能够提醒用户佩戴在正确的位臵而避免错误的操作。

同时,随身佩戴位置也是移动应用实现自适应交互的重要情境信息。佩戴位置的改变,在一定程度上反映用户使用设备状态的改变,体现着对不同服务的需求。应用服务可以依此改变自身的工作状态以优化交互体验。例如,当发现用户将播放器佩戴在手臂上时,推测有可能用户正在从事体育运动,播放器可以开启与体育运动模式有关的应用与配置,如播放相应的背景音乐等。再比如,当用户使用无线耳机接听电话时,如果检测到原本放置于口袋或者书包中的手机被用户拿到耳旁,可以推断可能是由于耳机信号不好而自动切换到听筒通话模式。感知佩戴位置还有助于节约能耗。比如,当检测到手机的位置从手持转变为放置于衣袋中时,屏幕显示可以关闭以节约电量,同时可以适当提高铃声的音量与开启振动模式以防漏接来电。通过提供佩戴位置作为情境信息,可以支持上层应用的开发者建立更为智能的手机应用。

利用移动设备集成的三维加速计可以对佩戴位置进行推断。佩戴在不同位置时所具有的运动模式可以对加速计获得的运动加速度产生影响。之前已有一些研究通过提取加速度变化的不同特征并设计相应的分类器对佩戴位置进行检测^[4-6]。虽然这些方法取得了一定的效果,但是还存在不足以及进一步提升的空间。之前的方法往往基于用户处于行走过程中这一应用场景,对识别方法的可用范围做出了限定,缺乏对用户从事新活动类型情况下方法的评测。此外,随着陀螺仪作为另外一种惯性传感器越来越普及地与加速计一同集成在移动设备中,其检测到的三维角速度数据与三维加速度可以形成互补,从而能够更加全面地了解佩戴部位的运动情况。通过融合两种传感器观测到的运动信息,有可能进一步提高佩戴位置的识别精度并降低计算量。

本文提出了一种基于旋转模式区别的移动设备佩戴位置的检测方法,扩展了时岳等人在 2011 年发表在 Ubicomp 论文集上的佩戴位置识别技术^[7]。该方法设计目标是:根据从事先标定佩戴位置的训练集中学习的模式,对同一位置集合的新数据实例进行预测。根据利用角速度与加速度形成互补可以进一步提高识别效果的假设,该方法使用集成于移动设备之上的加速计和陀螺仪,提出了一组基于角速度幅度和旋转半径的特征以融合二者所分别采集的加速度和角速度信息,并结合 Park 等人^[4]采用的基于重力加速度的特征组成特征集。使用以上特征的原理主要是考虑人在运动时不同部位会围绕不同关节旋转,比如在手持移动电话时手会围绕肩关节与肘关节转动,不同部位会有相异的旋转模式并且体现在旋转半径、角速度幅度和重力加速度方向的变化上。这种体现在不同位置的旋转模式有助于对位置进行区分。随后,在所提出的特征集基础之上,基于随机森林(random forest)^[8]设计了分类器,并与支持向量机(support vector machine)的方法^[4]进行了对比。该方法面向提高

识别精度,对新活动类型进行泛化以及降低特征空间维数的挑战,做出了以下贡献:

- 提出了融合加速计和陀螺仪数据进行佩戴位置识别的一种新方法;
- 通过实验对比发现,增加基于角速度幅度和旋转半径的特征可以提高位置识别的准确率;
- 采用随机森林设计的分类器与使用支持向量机相比可以获得更好的佩戴位置识别效果;
- 所提出的位置识别方法对新用户和新活动的泛化识别能力有所提高.

本文首先回顾已有研究中进行用户行为识别和佩戴位置检测的技术和方法,然后详细阐述基于旋转模式的佩戴位置检测方法的原理和设计,接下来描述实验并分析结果,最后对本文工作做出总结.

1 相关工作

加速计能够检测加速度的变化,通过佩戴在身体的各个部位,可被广泛用于用户动作检测.之后,随着陀螺仪在移动设备中日益普及,一些研究开始关注结合使用加速计与陀螺仪以提升识别效果.由于不同位置在同一动作下运动模式有所区别,为了提高动作检测方法的适用性,研究者进一步考虑对佩戴位置进行自动区分.在解决这些问题的过程中,除了设计符合问题特点的特征空间描述待识别的动作或者位置以外,还需要对分类器进行选取和优化.本节将对在以上方面所开展的典型工作进行回顾和总结.

研究者使用各种加速计佩戴的方案解决家居生活、运动、医疗看护等领域的感兴趣活动识别问题.Bao 等人^[9]首先使用了多个二轴加速计进行多种动作的识别.在他们的工作中,5 个加速计被固定到身体的不同部位,通过从加速度数据提取时域和频域特征对动作进行区分,并在一个包含 20 个活动种类的数据集上进行测试.他们的工作为后续研究提供了基准的方法.随后,Ravi 等人^[10]尝试使用单一加速计对动作进行识别,并通过对比发现,多票数法(plurality voting)可以相对取得更好的效果.他们的工作考虑到人的胯部反映了人躯干的运动,选取其作为佩戴位置.齐娟等人^[11]应用加速计与无线网络信号,提出了一种低功耗行为识别方法. Kwapisz 等人^[12]聚焦于使用手机检测与人行走相关的活动,包括行走、慢跑、上楼梯等.在实验中,手机被放置在用户的前裤口袋中.除了将活动检测应用于日常活动和运动以外,很多研究还致力于使用加速计检测特殊应用领域的感兴趣活动,如医疗看护^[13-15]、空间事件^[16].其中,很多工作都对传感器的佩戴位置有特殊的要求,从而对佩戴位置识别的研究提出了需求.

随后,一些研究表明,陀螺仪在动作识别过程中可以与加速计的使用形成互补.Kunze 等人^[17]利用陀螺仪只对旋转运动敏感而不受平移运动影响的特点,在动作识别中使用陀螺仪滤除与旋转无关的部分.Bourk 等人^[18]提出了基于角速度阈值的方法对跌倒和日常活动进行区分.他们将一个二轴陀螺仪固定在躯干上,使用陀螺仪所检测到的跌倒时躯干角速度进行区分.Li 等人^[19]的研究发现,结合陀螺仪与加速计能够有效地提高跌倒行为的检测效果.Lee 等人^[20]同样考虑了肢体执行动作时旋转模式变化的区别,并使用陀螺仪与加速计融合检测行走类别的活动.陀螺仪在旋转占运动主要成分的特殊领域活动中会起到更为主要的作用.Holleczek 等研究者^[21]将陀螺仪安装在滑雪板上,用以检测滑雪者的关键动作变化.由于陀螺仪能够更好地检测运动中旋转分量的变化,涉及到全身整体或者局部肢体较明显的转动时,融合陀螺仪与加速计数据有可能达到更好的识别效果.

佩戴位置识别虽然也是利用加速计所采集的数据,但是由于识别目标不同,需要重新设计有效的特征集和分类器.Kunze 等人^[5]提出了由加速度均方根、四分位数、频域能量、频率熵等特征分量组成的特征集,并采用决策树(C4.5)对佩戴位置进行分类.Amini 等人的工作^[6]根据走步所造成的加速度变化的冲击提出了一组特征,并使用支持向量机(SVM)来设计分类器.之后,Park 等人^[4]提出使用在水平方向和垂直方向加速度幅度低频分量结合重力在轴和面的投影所形成的特征对佩戴位置进行判别.其实验结果表明:其中,重力在 3 个轴和面所形成的投影能够对佩戴位置给出更为显著的区分.在实验中,还将 SVM 与之前使用的 C4.5 进行了对比并发现:前者对于位置判别问题能够达到更好的效果.在之前方法的基础上,本文考虑旋转的运动模式可以对识别效果进一步提高的可能而对方法进行了扩展,提出了基于旋转半径和角速度幅度的特征集.同时,在所提出假设的框架下保留了从重力加速度提取的特征.另外,之前的方法往往需要预先识别出用户处于行走的状态或只针对行走的场景进行了测试,本文在实验中考虑了独立于活动的测试方法,即训练集中不包含测试集中的活动种类.以此

考察该方法在不同活动种类下的泛化性能。在分类器方面,本文还考虑到相关工作中的集成识别方法在一些活动识别问题中取得了相对更好的效果,引入随机森林(random forest)作为分类器识别佩戴位置。在实验中对比了随机森林与支持向量机的分类效果,并利用随机森林对特征的重要性进行了评价。

2 基于旋转模式的佩戴位置识别方法

本文所提出的方法考虑了人在活动过程中不同身体部位转动模式的差异。不同佩戴部位在人的活动过程中会产生平动和转动两种类型的变化。当移动设备佩戴在用户的某个部位时,集成在设备上的惯性传感器会感知到由各种外力共同作用的合力所导致的运动参数变化。合成的运动主要可以分为身体相对于环境的整体运动和肢体相对于身体的局部运动。其中,平动受身体整体运动的影响较大,而由局部肢体运动模式不同所引起的平动变化很多时候相对并不显著。对于转动,在活动过程中,肢体会相对于关节发生旋转,躯干的活动也会包含转动成分。由于不同部位具有不同的结构,这种相对于关节的旋转会呈现不同的模式。这种不同可以体现在 3 个方面:

- 佩戴部位到旋转轴的距离即旋转半径的变化会有所不同。例如,对于佩戴在手腕上的传感器,它所检测到的旋转是由肘关节和肩关节共同支配的,相应的旋转半径也会随着手腕到肩关节距离的变化而改变。
- 在运动发生时,不同部位角速度的变化会有所区别。
- 佩戴位置相对于重力方向的倾斜也会不一致。

利用这 3 种可能的区别,可以提取对应的特征对佩戴位置进行判别。

为了利用以上 3 点不同,首先获得旋转半径、角速度和重力加速度。作为两种惯性传感器,加速计和陀螺仪可分别获得 3 轴的加速度和 3 个轴向的角速度。在对加速度和角速度进行采样之后,可以通过刚体运动模型近似计算旋转半径与角速度幅度。另外,由于加速计采样结果包含重力分量,重力加速度向量可由对加速度低通滤波近似地获得。对于每个时间窗口,在获得了以上数据之后,可以分别提取一组反映其变化特点的由时域与频域特征组成的特征集;最后,由于佩戴位置在时序上的变化不明显,分类阶段考虑采用非时序的分类器进行判别。由相关文献中的结果可知,在一般的行为识别中,支持向量机(SVM)与随机森林(RF)效果较好,本文在分类方法设计中分别考虑这两种分类器并在实验中进行比较。综上所述,本文所采用的识别流程如图 1 所示。

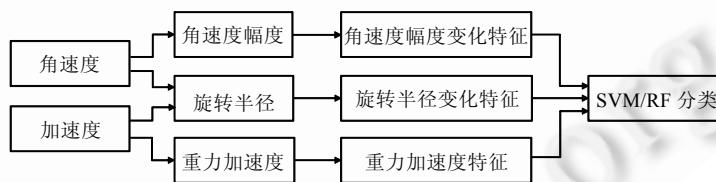


Fig.1 Process of on-body position recognition

图 1 佩戴位置识别流程

2.1 旋转半径的近似计算

在物理圆周运动模型中,可以用旋转半径以及角速度这两个物理量对旋转情况进行描述,其中,旋转半径是质心到旋转轴的距离。如果考虑刚体模型,将人肢体的运动视为围绕关节发生的刚体运动,则当移动设备被放置在身体的某个部位的时候,它运动的旋转半径会与其到最近关节的距离有关。同时,角速度反映了绕轴旋转的快慢程度,与关节的活动能力有关。因此,旋转半径与角速度的变化模式会体现不同位置的特点。对于瞬时的角速度,可以从陀螺仪直接观测。旋转半径需要根据运动学模型近似计算得到。

对于一个运动中的物体,其加速度 \mathbf{a} 可以分解为旋转轴所处质点的加速度 \mathbf{a}_{cg} 、由角加速度产生的切线加速度 \mathbf{a}_t 和导致切线速度方向改变的向心加速度 \mathbf{a}_n 这 3 个向量的和:

$$\mathbf{a} = \mathbf{a}_{cg} + \mathbf{a}_t + \mathbf{a}_n \quad (1)$$

其中, \mathbf{a}_t 和 \mathbf{a}_n 与旋转半径和角速度有关.

在运动中的旋转分量为主要成分的时候, 可以由公式(1)忽略 \mathbf{a}_{cg} 从而得到:

$$\mathbf{a} = \mathbf{a}_t + \mathbf{a}_n \quad (2)$$

其中, \mathbf{a}_t 可以表示为角加速度 $\frac{d\omega}{dt}$ 与旋转半径 \mathbf{r} 的外积. 这里, 角加速度与旋转半径都采用三维的向量表示. 角加速度与角速度的方向一致, 为所绕旋转轴的方向.

$$\mathbf{a}_t = \frac{d\omega}{dt} \times \mathbf{r} \quad (3)$$

\mathbf{a}_n 等于角速度 ω 与切向速度的外积, 而切向速度可以表示为 $\omega \times \mathbf{r}$, 故而可以得到:

$$\mathbf{a}_n = \omega \times (\omega \times \mathbf{r}) \quad (4)$$

由于切线加速度和向心加速度正交, 加速度的幅度的平方由公式(2)可以表示为二者幅度的平方和:

$$\mathbf{a}^2 \approx \mathbf{a}_n^2 + \mathbf{a}_t^2 \quad (5)$$

由公式(3)与公式(4)得到:

$$\mathbf{a}_t = \frac{d\omega}{dt} \cdot \mathbf{r} \quad (6)$$

$$\mathbf{a}_n = \omega^2 \mathbf{r} \quad (7)$$

将公式(6)、公式(7)代入公式(5), 可以近似地得到:

$$\mathbf{a} \approx \sqrt{\left(\frac{d\omega}{dt} \cdot \mathbf{r}\right)^2 + \omega^4 \mathbf{r}^2} \quad (8)$$

从公式(8)中提取 \mathbf{r} , 可以计算其幅度为

$$\mathbf{r} \approx \sqrt{\sqrt{\left(\frac{d\omega}{dt}\right)^2 + \omega^4}} \quad (9)$$

通过以上分析可以看出, 旋转半径的幅度可以通过加速度与角速度的幅度近似地计算. 每次数据采样时, 首先对加速度进行低通滤波更新重力加速度向量, 再将其从加速度向量中分离. 然后按照角速度的单位向量分离得到正交于角速度的加速度分量, 最后计算其幅度得到 \mathbf{a} . 对于 $d\omega$, 由当前角速度幅度 ω_t 减去上一次角速度采样在当前角速度方向上的投影 ω_{t-1} 获得. dt 为相邻两次采样的时间间隔. 由于预先假设是旋转占主要成分, 如果所得旋转半径幅度超出正常范围, 则说明此时 \mathbf{a}_{cg} 不能忽略, 要将在这种情况下所得的结果滤除, 只留下旋转半径幅度在合理范围内的采样.

2.2 特征向量组

在对信号进行预处理之后, 由于旋转半径幅度的变化、角速度幅度的变化和重力加速度分别从不同侧面反映了佩戴位置的特点, 所以从这 3 个变量各提取一组特征向量共同描述旋转模式. 其中, 旋转半径幅度和角速度幅度都是一维向量, 选取刻画其统计特性的均值、方差、中值、峰度、偏度以及 3 个四分位数(25%, 50%, 75%) 作为特征分量. 在频域上, 首先在减去均值之后进行傅里叶变换, 获得各个频域上的分量; 然后计算描述频谱形状的频谱矩心 C 和反映频谱集中程度的频谱滚降 R , 计算公式为

$$C = \frac{\sum m |X(m)|}{\sum |X(m)|} \quad (10)$$

$$\sum_{m=0}^R |X(m)| = 0.8 \sum |X(m)| \quad (11)$$

其中, m 为频谱分量的个数, $X(m)$ 表示频谱分量的值. 由此, 旋转半径与角速度各形成一个由 10 个分量组成的特征向量 \mathbf{X}_r 与 \mathbf{X}_ω 特征集合见表 1.

重力加速度向量反映了佩戴位置相对于重力方向的倾斜程度. 在 Park 等人的工作中, 利用重力加速度向量计算了其在 3 个轴和 3 个平面的投影形成的特征向量 \mathbf{X}_G :

$$\mathbf{X}_G = (|g_x|, |g_y|, |g_z|, \sqrt{g_x^2 + g_y^2}, \sqrt{g_y^2 + g_z^2}, \sqrt{g_z^2 + g_x^2}) \quad (12)$$

在本文中,基于他们的工作,使用 \mathbf{X}_G 描述重力加速度.最终,形成描述旋转模式的特征向量($\mathbf{X}_r, \mathbf{X}_\omega, \mathbf{X}_G$).

Table 1 Feature set for magnitude of rotation radius and angular velocity

表 1 旋转半径和角速度幅度特征集

特征分量	个数
均值	1
方差	1
中值	1
峰度	1
偏度	1
四分位数	3
频谱矩心	1
频谱滚降	1
总计	10

2.3 分类器设计

由于佩戴位置的变化并没有明显的时序关系,在设计分类器时,考虑选用非时序分类器.之前的工作表明,使用支持向量机在位置识别问题上可以得到很好的结果^[7].此外,随机森林^[8]作为集成方法的一种,被用于很多分类和识别问题,并起到了很好的效果^[22,23].但是,尚没有工作应用它解决佩戴位置问题,并与其它分类器进行对比.为此,我们分别选用了支持向量机与随机森林,并在实验中比较二者的分类能力.

支持向量机通过找到使类间差距最大的超平面进行分类,具有很好的泛化能力.其中,核函数的使用可以使 SVM 基于数据构建非线性模型.为了利用支持向量机解决分类问题,需要指定核的类型,并确定核计算过程中所使用的参数.常用的核函数包括径向基函数、多项式函数、S 型函数等.在对比的基准方法中^[4],使用加权径向基函数作为支持向量机的核.为了与以前的结果进行对比,我们设计核函数为 $\mathbf{X}_r, \mathbf{X}_\omega, \mathbf{X}_G$ 这 3 个特征向量组各自径向基函数的和:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_{i,r} - x_{j,r}\|^2}{2\sigma_r^2}\right) + \exp\left(-\frac{\|x_{i,\omega} - x_{j,\omega}\|^2}{2\sigma_\omega^2}\right) + \exp\left(-\frac{\|x_{i,G} - x_{j,G}\|^2}{2\sigma_G^2}\right) \quad (13)$$

其中,参数 $\sigma_r, \sigma_\omega, \sigma_G$ 仍然通过计算训练集向量两两距离的中位数后,将结果的一半作为参数确定.

随机森林是以若干决策树作为弱分类器,并通过它们投票决定分类的一种集成方法.每个决策树都使用特征集的一个随机选择的个数为 n 的子集,在选择特征分裂后一般不进行剪枝.由于其结构特点,随机森林也具有良好的泛化特性并且对噪声不敏感.此外,使用随机森林还可以对特征的重要性做出评价.在使用随机森林进行分类的过程中,主要需要确定的是特征随机选取的个数和决策树的个数.在本文的方法中,取每次选择特征个数为 $\lfloor N/3 \rfloor$,其中, N 为特征向量数.而随机森林的个数则通过实验进行估算.图 2 是对第 3 节所述数据测试得到的袋外数据误差随着决策树个数增长的变化情况.根据测试结果,设置决策树个数为 200.

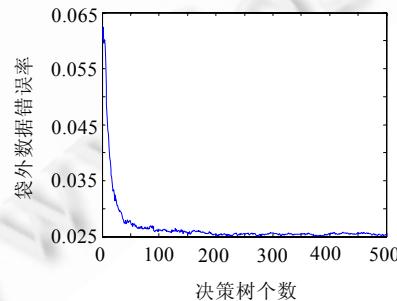


Fig.2 Change of the out-of-bag error rate with the increasing number of the decision tree

图 2 袋外错误率随着决策树个数增长的变化

3 实验评测

在实验中希望对本文提出的结合角速度幅度、旋转半径、重力加速度变化特征的方法在如下几个方面的性能进行评测:

- (1) 在不同特征集组合下,方法对佩戴位置区分能力的比较;
- (2) 不同分类器的使用对分类能力的影响;
- (3) 对于最优的特征集组合,每个特征集对分类的重要程度;
- (4) 所提出的最优方案与基准方法对新用户佩戴位置识别泛化能力的比较;
- (5) 所提出的最优方案与基准方法对新活动佩戴位置识别泛化能力的比较;
- (6) 最优方案具体识别效果分析.

其中,区分能力采用分类的准确率衡量,即正确判断佩戴位置的样本占所有样本的百分比;特征集的重要程度采用随机森林方法内部估计所得的特征重要性衡量;对最优方案的具体识别效果的分析,包括分析在交叉验证、新用户、新活动情况下的混淆矩阵.在所对比的基准方法中^[4],特征集选用的是加速度两个方向上幅度的低频分量组成的 \mathbf{X}_{HV} 加上 \mathbf{X}_G ,分类器采用的是以加权径向基函数为核的支持向量机,具体已分别在相关工作和分类器设计中加以论述.下面首先讨论实验所采用的数据集、实验的程序环境以及实验流程.随后展示评测结果并对结果进行讨论.

3.1 实验方法

在实验中,采用公开数据集 PAMAP2(physical activity monitoring data set)^[24]对方法进行测试.数据集包括 9 名用户(平均年龄 27.22 岁)佩戴 3 个运动传感器从事 13 项活动(日常生活和体育运动中常见的活动)过程中所记录的传感器数据.佩戴传感器的位置包括手腕、胸口和脚踝.用户按照事先拟定的脚本依次完成每个活动,每个传感器在数据采集过程中以 100Hz 的频率采集三维加速度和角速度.标注的数据时长一共约 8 小时.该数据集的特点在于,用户在佩戴传感器的过程中从事了多项活动,可以用于对比方法对新活动的泛化能力,同时也满足位置识别方法对测试新用户泛化能力的要求.

实验程序采用 MATLAB 编写,其中,支持向量机基于 LIBSVM 3.12^[25]实现,随机森林基于开源程序包 randomforest-matlab^[26]实现.在实验中,特征的提取基于长为 512 个采样点的时间窗口,窗口之间有 50% 的覆盖,即移动步长为 256 个采样点.考虑到数据的采样频率为 100Hz,每个时间窗口包括时长为 5.12s 的数据.在数据中,由于一名用户的数据时长明显小于其他用户,实验中去除这名用户的数据.另外,由于数据集在真实的场景中使用无线设备录制,存在个别的无效数据,也在特征的计算过程中予以过滤.对于每个时间窗口,按照图 1 所示的流程提取不同的特征并形成组合,进而训练和测试分类器.所有特征都进行了包括按照 2 倍四分位数间距标准化异常值和归一化的预处理.最终,实验数据包含有 22 756 个特征向量的实例.由于行为数据采集成本较高,在设计分类方法时,会关心在限制训练数据规模时的分类性能,由此,在每次训练时对实例进行间隔采样,选取同一组 8 000 个实例对比不同方案进行训练.

3.2 结 果

实验首先比较了本文所提出的基于旋转的特征组合($\mathbf{X}_r, \mathbf{X}_\omega, \mathbf{X}_G$)与基准方法中所提出的加速度频谱+重力加速度的特征组合($\mathbf{X}_{HV}, \mathbf{X}_G$)对准确率所造成的影响.对于每种特征组合,都分别使用支持向量机与随机森林分类器进行训练和测试.在测试中,使用 10 折交叉验证的方法,包括所有用户和活动类型.实验结果如图 3 所示,从图中的对比可以看出:本文所提出的基于旋转的特征组合可以取得更好的效果;同时,随机森林在两种特征组合下的性能都优于支持向量机.具体来说,本文所提出的旋转特征组合在利用随机森林作为分类器时可以达到平均 95.39% 的正确率,而加速度频谱+重力加速度的特征组合在支持向量机作为分类器的情况下可以达到 88.29% 的正确率.

为了分析基于旋转的特征组合中新提出的分量($\mathbf{X}_r, \mathbf{X}_\omega$)相对于之前使用的重力加速度分量 \mathbf{X}_G 的重要程度,我们使用随机森林的内部估计方法对二者的重要性进行了对比.在随机森林的设计中,对每个特征 i 重要性的

度量通过如下的方式给出:对袋外数据的第 i 个特征添加随机噪声,然后对比前后平均正确率下降的程度^[8].为了给出更为直观的对比,我们将分别属于重力加速度和旋转半径+角速度幅度的特征重要程度相加,如图 4 所示.从中可以看出:前者比后者相对体现出更大的重要性;同时,旋转特征对进一步提高准确率也发挥了显著的作用.

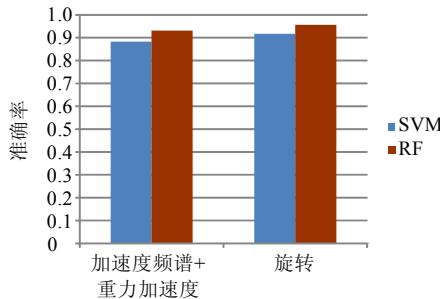


Fig.3 Comparison of accuracy between different feature set and classifier combinations

图 3 不同特征集与分类器组合的准确度对比

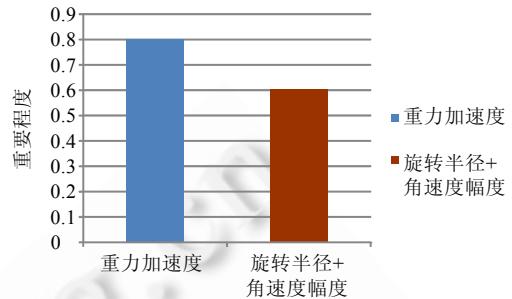


Fig.4 Comparison of importance between feature subsets of rotation

图 4 旋转特征子集重要程度对比

对新用户的泛化能力,我们采用留一验证法与基准方法进行对比.在每轮测试中,选取 1 名用户的数据作为测试集,将剩余 7 名用户的数据作为训练集.两种方法的测试结果对比如图 5 所示.其中,所提出的结合 3 种旋转特征集以及使用随机森林分类器的方法平均正确率为 91.29%,显示了其对新用户的泛化能力.同时,通过对比也可以看出,与基准方法相比,在面向新用户进行位置识别方面有更好的效果.

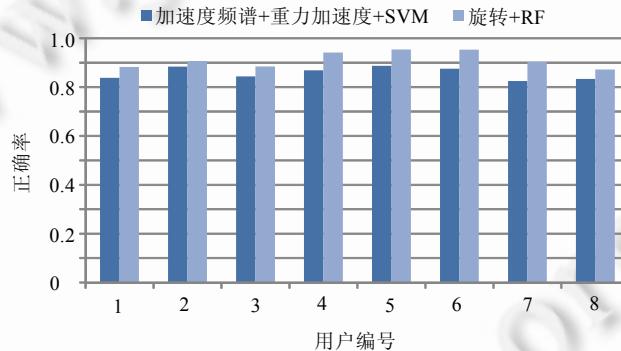


Fig.5 Comparison of accuracy under the leave-one-user-out evaluation

图 5 用户留一评测正确率对比

对于不同活动的泛化能力,我们同样使用留一验证法进行测试.每次选取一项活动的数据作为测试集,将剩余活动的数据作为训练集.对比结果如图 6 所示,在绝大多数情况下,本文工作所提出的方法对佩戴位置具有更好的分类能力.平均正确率为 85.98%,主要影响正确率下降的原因在于,当发生平躺这一动作时的分类效果很差.在平躺时,用户需要发生旋转与重力加速度方向的假设都受到了影响,超出了分类方法所限定的有效范围.

表 2 列出了所提出的方法在 3 种测试条件下对于佩戴位置的混淆矩阵.从表 2 中可以看出,误分类发生的情况主要是其他位置被误识别为手腕的位置,特别是在新活动的情况下.造成这个问题的一个可能的原因是手腕的活动较为灵活,模式覆盖的范围比较广,导致其他位置的实例被误识别为手腕.

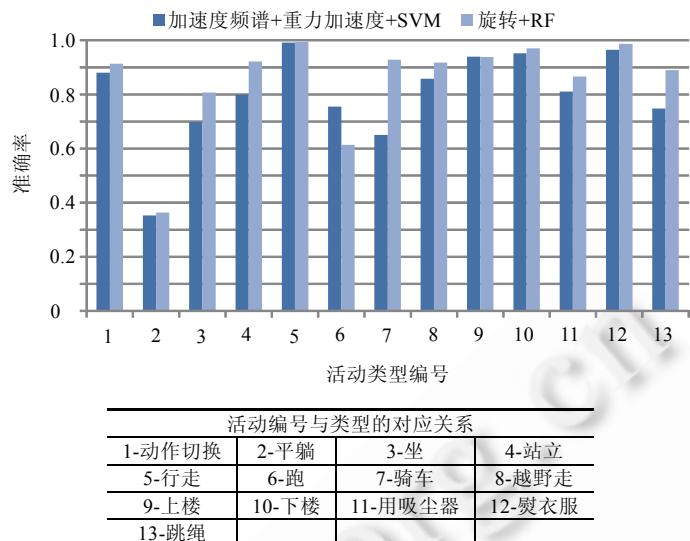


Fig.6 Comparison of accuracy under the leave-one-activity-out evaluation

图 6 新活动类型留一评测正确率对比

Table 2 Confusion matrix of the position recognition method (%)
表 2 位置识别方法的混淆矩阵 (%)

		预测类别								
		交叉验证			新用户			新活动类别		
		手腕	胸口	脚踝	手腕	胸口	脚踝	手腕	胸口	脚踝
实际类别	手腕	92.84	4.05	3.11	89.22	5.98	4.80	87.48	6.10	6.43
	胸口	1.64	98.19	0.17	3.50	95.76	0.74	11.42	87.35	1.23
	脚踝	4.78	0.66	94.56	8.82	3.79	87.39	12.01	5.97	82.01

3.3 讨 论

通过结果的对比分析可以看出,对于随身佩戴位置识别问题,考虑体现在旋转中的特征可以增强识别效果。基于这个思路,从旋转半径和角速度幅度提取的特征分量在分类过程中起到了重要的作用。而且,结合随机森林分类器的使用,与使用支持向量机相比所得到的效果也有所提升。通过进一步对比可以看出,这种方法对新用户和新活动也具有可扩展性。其中,对不同用户准确率的变化较小,说明不同用户同一位置的运动模式具有相似性;同时,对新活动种类识别效果有时却出现较大的变化。这是因为在某一位置的运动模式与所进行的运动存在一定的相关性,所提取的特征组合也不能完全独立于这种影响。但是对于绝大多数种类的新活动,在满足旋转或是重力加速度方向的前提下,本文所提出的使用旋转模式结合随机森林分类器的方法仍具备很强的区分位置的能力。总体来说,实验结果支持了导言中的假设。本文的实验也支持了前面工作所获得的结果——重力加速度方向可以体现不同佩戴位置的运动特点。与之前的方法相比,本文进一步考虑另外一种运动传感器——陀螺仪所观测的角速度信息。加速度与角速度可以形成互补,从而更为全面地刻画运动情况。利用从旋转半径和角速度幅度所提取的特征集,除了更能体现不同部位的运动特点之外,与加速度频谱信息相比减少了特征空间的维数,更加有利于对分类器的训练,解决维数过高所可能带来的问题。

本文方法性能最好的情况在于同时满足旋转明显和重力加速度方向稳定的条件。很多移动设备的设计在同一位置佩戴的时候基本保持方向不变,如计步器别在衣兜的边缘。但是也存在很多情况不能对移动设备的方向做出假设。这时,由于旋转半径和角速度幅度的计算与方向无关,从中提取的特征集会发生更为重要的作用,弥补单纯重力加速度方向假设不满足的情况。

本文提出的方法进行特征计算和预测的时间在毫秒量级,随着移动设备如智能手机的计算能力日益增强,对佩戴位置的识别完全可以在移动设备上实时进行,从而可以进一步为上层应用的开发者提供一个使用此情境信息的接口,向其他活动识别和自适应交互提供服务。此外,方法设计中所使用的加速计与陀螺仪数据的融合方法也可以应用于其他情境信息的识别中。

4 结论和未来工作

本文设计了一种检测移动设备随身佩戴位置的方法。该方法考虑了不同佩戴位置在动作发生过程中旋转模式的不同,从加速计和陀螺仪传感器中计算获得旋转半径、角速度幅度和重力加速度,并从中提取了一组特征,再结合随机森林分类器对佩戴位置进行分类。实验结果表明,该方法在满足旋转明显和重力加速度方向稳定的条件下,可以有效地对佩戴位置进行区分,并对新用户和新活动具有泛化能力。与之前的工作相比,准确率得到了进一步的提高。该方法可用于提高用户动作识别算法的适用性以及移动交互应用的自适应性,进而提供更好的交互体验。未来会进一步考虑将该方法实现为手机应用,并且采集其他实际使用过程中的数据进一步提升方法的性能。

References:

- [1] Fitbit. <http://www.fitbit.com/>
- [2] Duofertility monitor. <http://www.duofertility.com/>
- [3] JawBone. <https://jawbone.com/>
- [4] Park JG, Patel A, Curtis D, Teller S, Ledlie J. Online pose classification and walking speed estimation using handheld devices. In: Proc. of the 2012 ACM Conf. on Ubiquitous Computing. ACM Press, 2012. 1–10. [doi: 10.1145/2370216.2370235]
- [5] Kunze K, Lukowica P, Junker H, Tröster G. Where am I: Recognizing on-body positions of wearable sensors. In: Proc. of the 1st Int'l Conf. on Location- and Context-Awareness. Springer-Verlag, 2005. 264–275. [doi: 10.1007/11426646_25]
- [6] Amini N, Sarrafzadeh M, Vahdatpour A, Xu WY. Accelerometer-Based on-body sensor localization for health and medical monitoring applications. *Pervasive and Mobile Computing*, 2011, 7(6):746–760. [doi: 10.1016/j.pmcj.2011.09.002]
- [7] Shi Y, Shi YC, Liu J. A rotation based method for detecting on-body positions of mobile devices. In: Proc. of the 13th Int'l Conf. on Ubiquitous Computing. ACM Press, 2011. 559–560. [doi: 10.1145/2030112.2030212]
- [8] Breiman L. Random forests. *Machine Learning*, 2001, 45(1):5–32. [doi: 10.1023/A:1010933404324]
- [9] Bao L, Intille SC. Activity recognition from user-annotated acceleration data. In: Ferscha A, ed. Proc. of the Pervasive Computing. Berlin, Heidelberg: Springer-Verlag, 2004. 1–17. [doi: 10.1007/978-3-540-24646-6_1]
- [10] Ravi N, Dandekar N, Mysore P, Littman ML. Activity recognition from accelerometer data. In: Proc. of the 17th Conf. on Innovative Applications of Artificial Intelligence. AAAI Press, 2005. 1541–1546.
- [11] Qi J, Chen YQ, Liu JF, Sun Z. Power-Efficient activity recognition based on multi-modal information sensing and fusion. *Ruan Jian Xue Bao/Journal of Software*, 2010, 21:39–50 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/10005.htm>
- [12] Kwapisz JR, Weiss GM, Moore SA. Activity recognition using cell phone accelerometers. *ACM SIGKDD Explorations Newsletter*, 2010, 12(2):74–82. [doi: 10.1145/1964897.1964918]
- [13] Shi Y, Shi YC, Wang X. Fall detection on mobile phones using features from a five-phase model. In: Proc. of the Ubiquitous Intelligence & Computing and the 9th Int'l Conf. on Autonomic & Trusted Computing. IEEE, 2012. 951–956. [doi: 10.1109/UIC-ATC.2012.100]
- [14] Zhang T, Wang J, Xu L, Liu P. Fall detection by wearable sensor and one-class svm algorithm. In: Huang DS, ed. Proc. of the Intelligent Computing in Signal Processing and Pattern Recognition. Berlin, Heidelberg: Springer-Verlag, 2006. 858–863. [doi: 10.1007/978-3-540-37258-5_104]
- [15] Yavuz GR, Kocak ME, Ergun G, Alemdar H, Yalcin H, Incel OD, Akarun L, Ersoy C. A smartphone based fall detector with online location support. In: Proc. of the PhoneSense. 2010.
- [16] Hu JF, Jin BH, Zhuo W, Chen HB, Zhang LF. Spatial event detection of optimization. *Ruan Jian Xue Bao/Journal of Software*, 2011, 22:147–156 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/11035.htm>

- [17] Kunze K, Lukowicz P. Dealing with sensor displacement in motion-based onbody activity recognition systems. In: Proc. of the 10th Int'l Conf. on Ubiquitous computing. ACM Press, 2008. 21–24. [doi: 10.1145/1409635.1409639]
- [18] Bourke AK, Lyons GM. A threshold-based fall-detection algorithm using a bi-axial gyroscope sensor. Medical Engineering & Physics, 2008,30(1):84–90. [doi: 10.1016/j.medengphy.2006.12.001]
- [19] Li Q, Stankovic JA, Hanson M, Barth A, Lach J. Accurate, fast fall detection using gyroscopes and accelerometer-derived posture information. In: Proc. of the 6th Int'l Workshop on Wearable and Implantable Body Sensor Networks. IEEE, 2009. 138–143. [doi: 10.1109/BSN.2009.46]
- [20] Lee SW, Mase K. Activity and location recognition using wearable sensors. Pervasive Computing, 2002,1(3):24–32. [doi: 10.1109/MPRV.2002.1037719]
- [21] Holleczek T, Schoch J, Arnrich B, Tröster G. Recognizing turns and other snowboarding activities with a gyroscope. In: Proc. of the 2010 Int'l Symp. on Wearable Computers. IEEE, 2010. 1–8. [doi: 10.1109/ISWC.2010.5665871]
- [22] Fan MM, Gravem MDD, Cooper MDDM, Patterson DJ. Augmenting gesture recognition with erlang-cox models to identify neurological disorders in premature babies. In: Proc. of the 2012 ACM Conf. on Ubiquitous Computing. ACM Press, 2012. 411–420. [doi: 10.1145/2370216.2370278]
- [23] Staiano J, Lepri B, Aharony N, Pianesi F, Sebe N, Pentland A. Friends don't lie-infering personality traits from social network structure. In: Proc. of the 2012 ACM Conf. on Ubiquitous Computing. ACM Press, 2012. 321–324. [doi: 10.1145/2370216.2370266]
- [24] Reiss A, Reiss S. Introducing a new benchmarked dataset for activity monitoring. In: Proc. of the 16th Int'l Symp. on Wearable Computers. IEEE, 2012. 109–110. [doi: 10.1109/ISWC.2012.13]
- [25] Chang CC, Lin CJ. LIBSVM: A library for support vector machines. ACM Trans. on Intelligent Systems and Technology, 2011, 2(27):1–27. [doi: 10.1145/1961189.1961199]
- [26] Randomforest-Matlab. <https://code.google.com/p/randomforest-matlab/>

附中文参考文献:

- [11] 齐娟,陈益强,刘军发,孙卓.融合多模信息感知的低功耗行为识别.软件学报,2010,21:39–50. <http://www.jos.org.cn/1000-9825/10005.htm>
- [16] 胡佳锋,金蓓弘,禚伟,陈海彪,张利锋.空间事件的检测及优化策略.软件学报,2011,22:147–156. <http://www.jos.org.cn/1000-9825/11035.htm>



时岳(1986—),男,北京人,博士生,主要研究领域为普适计算。

E-mail: shiyue625@gmail.com



史元春(1967—),女,博士,教授,博士生导师,CCF 高级会员,主要研究领域为人机交互,普适计算。

E-mail: shiyc@tsinghua.edu.cn



喻纯(1984—),男,博士,助理研究员,CCF 会员,主要研究领域为人机交互。

E-mail: yc2pcg@gmail.com