

基于加速度传感器的放置方式和位置无关运动识别

侯仓健 陈 岭 吕明琪 陈根才

(浙江大学计算机科学与技术学院 杭州 310027)

摘 要 传统基于加速度传感器的运动识别方法通常假设传感设备是固定放置的,当传感设备的放置方式或位置偏离预定设置时识别性能会受到极大影响。然而,在普适计算环境下使用最为广泛的传感设备——智能手机,通常无法预先固定其放置方式和位置。为解决此问题,提出了一种基于加速度传感器、与放置方式和位置无关的运动识别方法。该方法首先基于一种降维算法将原始三维加速度信号处理成与放置方式无关的一维信号,然后借鉴生物信息学中的“模体”(Motif)概念抽取一维信号中与放置位置无关的模式特征,最后基于模式特征构建向量空间模型(VSM)对运动进行识别。实验结果表明,该方法在不固定传感设备放置方式和位置条件下的运动识别率达到81.41%。

关键词 运动识别,传感器位置,加速度传感器,模体发现,普适计算

中图法分类号 TP311 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2014.10.017

Acceleration-based Activity Recognition Independent of Device Orientation and Placement

HOU Cang-jian CHEN Ling LV Ming-qi CHEN Gen-cai

(College of Computer Science and Technology, Zhejiang University, Hangzhou 310027, China)

Abstract Traditional activity recognition methods based on acceleration sensors generally have the assumption that the orientation and placement of sensing devices are fixed. But the recognition performance will be greatly affected when this assumption fails. However, mobile phones, the most widely used sensing devices in pervasive computing environments, are usually placed at unfixed orientation and placement. In this paper, an activity recognition method based on independent acceleration sensor orientation and placement was proposed to resolve this problem. First, the original 3D acceleration signals are processed into one-dimensional signals. Then, the concept ‘Motif’ from bioinformatics is borrowed to extract position-independent patterns from one-dimensional signals. Finally, Vector Space Model (VSM) based on extracted patterns is built to conduct activity recognition. Experimental results show that recognition rate of the method reaches to 81.41% under the condition of unfixed orientation and placement of sensing devices.

Keywords Activity recognition, Sensor placement, Accelerometer, Motif discovery, Pervasive computing

1 引言

近年来,利用加速度传感器进行人体运动识别在交互游戏^[1]、健康监测^[2]等领域有广泛的应用。同时,目前许多智能手机都集成了加速度传感器。由于智能手机总是被用户随身携带,且计算能力越来越强,因此利用智能手机中内置加速度传感器对人体运动进行识别^[3]越来越受到重视。

然而,传统利用加速度传感器进行人体运动识别^[4,5]的方法,要求加速度传感器必须以特定的方式固定在人体特定的位置,当不按照指定方式佩戴传感设备时会极大地影响识别的准确率。如 Daniel 等人^[6]的研究显示,单个加速度传感器不按照指定方式佩戴时识别准确率降低了20%左右。然而,传感设备在使用过程中很容易发生平移或旋转,偏离预定位置,导致识别性能下降。该现象在使用智能手机的情况下尤其严重,因为用户对智能手机的放置方式和位置的自由度

很高,且智能手机在用户运动过程中无法固定。

现有工作试图从不同角度解决这个问题,其中一部分尝试对传感设备放置方式和位置的变化进行感知。例如, Kunze 等人^[7]使用陀螺仪和加速度传感器的组合去分辨传感器的平移和旋转,并提出了一种启发式的方法来提高运动识别率。另一部分专注于利用加速度信号变化的具体特点来处理此问题。例如, Forster 等人^[8]使用在线无监督自校准算法找到分类的中心点。Daniel 等人^[6]和 Lester 等人^[9]采用多个加速度传感器的方式来提高识别率。Chavarriaga 等人^[10]假设传感器位置改变时加速度信号特征会产生偏移,通过 EM 算法在线估计偏移的大小。这些方法一方面可能需要更多的传感器,另一方面需要复杂的运算,不适合运行在智能手机上。

针对以上问题,本文提出了一种基于加速度传感器、面向智能手机用户、与传感设备放置方式和位置无关的运动识别

到稿日期:2013-06-15 返修日期:2013-08-11 本文受国家“核高基”重大科技专项课题(2010ZX01042-002-003),中国自然科学基金(61202282,60703040,61332017),浙江省重大科技专项(2011C13042),浙江省自然科学基金(LY12F02046)资助。


侯仓健(1990—),男,硕士生,主要研究方向为普适计算、活动识别;陈 岭(1977—),男,博士,副教授,主要研究方向为普适计算、人机交互、数据库, E-mail: lingchen@cs.zju.edu.cn;吕明琪(1982—),男,博士,主要研究方向为普适计算、人机交互、数据库;陈根才(1950—),男,教授,博士生导师,主要研究方向为人工智能、数据库和计算机支持的协同工作等。

算法。首先,利用降维算法将原始三维加速度信号处理成与放置方式无关的一维信号,然后,借鉴生物信息学中的“模体”(Motif)概念,抽取一维信号中与放置位置无关的模式特征,最后,基于模式特征构建向量空间模型(VSM)对运动进行识别。本方法利用加速度信号本身变化的特点,找出加速度信号变化中不随传感设备放置方式和位置变化而改变的部分,从而解决非固定加速度传感器位置下的运动识别问题。

2 方法设计

2.1 降维的传感设备放置方式无关化

在日常生活中,智能手机常见的放置方式如图 1(a)所示。加速度传感器的 (x, y, z) 三轴的方向(如图 1(c)所示)与智能手机的放置方式有关,智能手机的放置方式会影响运动时加速度传感器各轴上的值。如图 1(b)所示,这是同一个人按照 4 种不同的放置方式将智能手机放置在裤子前口袋坐着时的加速度传感器信号。



(b) 智能手机以不同放置方式放置在裤子前口袋坐着时的加速度信号




图 1

解决因传感设备放置方式不同而造成信号差异问题的最简单的方法就是取加速度信号的模,即 $s_i = \sqrt{x_i^2 + y_i^2 + z_i^2}$ 。但是,这样处理仅仅考虑了原始信号的幅度,忽略了原始加速度信号的结构特征。因此,我们尝试用降维的方法对原始信号进行处理,将原始的 (x, y, z) 3 维的加速度信号降成一维的与设备放置方式无关的信号。

常见的降维方法有随机投影法(RP)、主成分分析法(PCA)和独立成分分析法(ICA)等。其中随机投影在高维度(如高于 2000 维)表现效果良好,但在低维度(如低于 30 维)的降维效果不如主成分分析法,由于加速度信号是 3 维的,因此对随机投影法不予考虑。

主成分分析法和独立成分分析法都是取原始信号各维度的线性组合,假设 n 个线性变量 $x_1, \dots, x_n$ 有 m 个成分 $c_1, \dots, c_m$, 其中 $m \leq n$, 则每一个成分可以表示为:


$$c_i = a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n (i=1, \dots, m) \quad (1)$$

其中, $a_{i1}, \dots, a_{im} (i=1, \dots, m)$ 为各成分的权重系数。

主成分分析法和独立成分分析法都对原始数据的背景知识没有要求,并且都可以提取出信号中最主要的“成分”。但是独立成分分析法不能够决定各独立成分的重要性,而主成分分析法可以根据计算过程中的特征值大小来决定各独立成分的重要性。因此,选择使用主成分分析法将原始加速度信号降至 1 维,从而得到与智能手机放置方式无关的信号。

2.2 基于模体发现的传感设备放置位置无关化

常见的智能手机放置位置有:胸口、上臂、裤子前口袋、裤子后口袋(如图 2(a)所示)。图 2(b)为智能手机按同一种放置方式 O1(见图 1(a))放置在身体不同位置走路时的加速度信号。通过分析人体运动发现,运动大多由周期性的往复动作构成,表现为加速度信号上周期性出现的相似子序列。因此,本文通过查找 1 维信号中周期性出现的相似子序列,找到不同放置位置传感设备加速度信号差异中的共性。



(a) 常见的 4 个智能手机放置位置; (b) 将智能手机按同一种摆放方式 O1 分别放在身体的 4 个位置走路时的加速度信号

图 2

在一组时间序列中频繁出现的模式与生物信息学中“模体”^[11]的概念非常类似,本文将 1 维加速度信号中频繁出现的子序列模式称为模体,而模体发现即是在 1 维加速度信号中挖掘重复出现的相似片段的过程。Chiu 等人^[12]的研究表明直接在连续数据上进行模体发现是一项计算密集型运算,不适合在智能手机终端运算。因此,为了高效率地进行模体发现,本文基于符号化聚合近似(SAX)方法对连续数据进行离散化处理。

符号化聚合近似^[13]是在分段累积近似(PAA)基础上提出的一种有效的时间序列数据离散化方法,运用时间序列内在的统计规律将连续数据转化为符号序列(即字符串)。

通过这种方法可将长度为 n 的时间序列转化成长度为 w 的 SAX 词, SAX 词字母表的大小为 a (如图 3 所示的 SAX 离散化处理示例中, $n=40, w=10, a=3$, 则转化得到的 SAX 词为 acbacbabcb)。SAX 方法在保留数据局部信息的同时有较高的压缩率,对噪声有较高的承受能力,分段过程既实现了消除噪声,又实现了数据平滑处理。




图 3 将长度为 40 的时间序列转换成词长为 10、字母表大小为 3 的 SAX 词 acbacbabcb

假定模体长度为 m , SAX 词长度为 w , SAX 字母表大小为 α , 模体发现算法的输入为降维后的 1 维加速度信号, 算法首先以步进长度 1 来滑动大小为 m 的窗口, 将窗口中的子序列转换成 SAX 词, 并将得到的词加入到哈希表中 (哈希表以 SAX 词为键, 以 SAX 词对应的词频为值)。然后, 统计每个 SAX 词出现的次数, 取出出现次数最多的 k 个词及其词频 (参数组 (m, w, α, k) 的设置方法将在第 3 节讨论), 得到的词所对应的原始序列即为模体。模体发现算法的伪代码如下。

Motif Discovery Algorithm

Input: 原始时间序列 series, 子序列窗口大小 m , SAX 词长度 w , SAX 字母表大小 α

Output: 模体对应的 SAX 词及词频

1. 滑动窗口当前起始位置 currPosition, SAX 词词频哈希表 saxTable
2. while (currPosition+m) < series 长度 do
3. subseries=取出当前滑动窗口包含的子序列;
4. SAXWord=将当前子序列转化为长度为 w 、字母表大小为 α 的 SAX 词;
5. 更新 saxTable 中 SAXWord 的词频;
6. currPosition++;
7. end while
8. return saxTable 中词频最高的 k 个 SAX 词及其词频。

2.3 运动识别

在每一个运动中得到其模体对应的 SAX 词及词频后, 借鉴文本分类中的方法, 构建向量空间模型, 使用向量空间模型将运动表示为模体对应的 SAX 词与其权重组成的向量, 在此基础上对运动进行分类。

向量空间模型是关于文档表示的一个统计模型, 该模型用词作为文档表示的坐标, 以向量的形式把文档表示为多维空间的一个点, 词表示向量中的各个分量。

本文将每个运动信号序列看成一个文档, 信号序列模体对应的 SAX 词及其词频看成文档中的词及其词频, 在向量空间模型中, 每个信号序列都被表示成如下的向量形式:

$$D=(d_1, d_2, \dots, d_k) \quad (2)$$

其中, d 表示的是对应 SAX 词在信号序列中的权重。权重的计算采用 $tf-idf$ 公式:

$$d_i=tf_i \times idf_i=tf_i \times \log\left(\frac{N}{df_i+1}\right) \quad (3)$$

其中, tf (term frequency) 表示 SAX 词 i 的词频, N 表示所有的信号序列的数目, df (document frequency) 表示出现过 SAX 词 i 的信号序列数目。

在得到运动信号序列的向量表示后, 基于一系列正确标注运动类型的向量, 可采用机器学习技术训练分类器, 并使用该分类器对新的运动进行识别。

3 实验

本文使用智能手机 Google Nexus S (Android 系统) 作为加速度信号采集设备, 通过自行编写的软件录制运动时加速度传感器的信号, 信号的采样频率为 25 Hz。

参与实验的共有 10 名健康的大学在校生 (8 男 2 女), 分别将智能手机按照 4 种不同的放置方式放在他们身体的 4 个不同位置: 胸口口袋、上臂位置、裤子前口袋、裤子后口袋, 进行以下 5 种运动: 坐着、走路、跑步、上楼、下楼。为了更贴近日常的活动行为, 实验人员在坐着时可以适当地活动, 如调整

坐姿等, 走路等运动时可以按照不同的速度进行。每种运动的时长约 3 分钟左右, 每个实验人员大约录制了 2.5 小时的数据, 共有约 22 小时的数据。

根据文献[4], 本文将数据处理的滑动窗口设为 6s, 即 150 个采样点, 步进为 3s, 对每个窗口中的数据运用本文提出的方法进行处理。运动识别时的分类器采用 WEKA 中提供的 C4.5 决策树。

3.1 参数设置

在上文中提到需要设置参数 (m, w, α, k) , 即模体长度 m , SAX 词长度 w , SAX 字母表大小 α , 模体个数 k , 参数的设置对本文提出的方法有很大程度的影响, 若将 SAX 词或 SAX 字母表设置得太小, 则许多特性不一样的时间序列会离散化成同一个 SAX 词, 若将 SAX 词或 SAX 字母表设得太大, 则类似的时间序列可能会对对应到不同的 SAX 词, 这些都是需要避免的。

Keogh 的研究^[12]指出对于任意的数据集将 SAX 字母表的大小设为 3 或者 4 都是适用的并且可能是最好的。因此, 在本文提出的方法中, 将 SAX 字母表大小设为 3。模体的长度一般由用户指定, SAX 词长的最佳值与数据集和模体长度有关。由于人运动时运动周期大约需要 1~2s, 同时录制数据的频率是 25 Hz, 因此可以将模体的长度设为 25~50, 本文选择的模体长度为 40。为了得到合适的 SAX 词长, 使用胸口数据作为训练数据, 各位置的数据作为测试数据, 调整 SAX 词长, 得到的实验结果如图 4 所示。实验结果表明在 SAX 词长较小时, 随着 SAX 词长的增加, 各位置运动识别准确率上升, 在 SAX 词长超过 12 后, 虽然在训练数据集上 (即胸口数据) 的识别准确率上升, 但是在其他数据集上识别准确率呈现下降趋势。




图4 随着 SAX 词长变化各位置识别准确率; 使用胸口数据作为训练数据

针对模体个数的选择, 将放置位置为上臂的数据作为训练数据, 各放置位置的数据作为测试数据, 实验结果如图 5 所示。实验结果显示模体个数对识别准确率的影响不大, 随着模体个数的增加, 识别准确率上升缓慢, 并且在模体个数达到 10 左右的时候上升趋势开始趋于稳定。




图5 随着模体个数变化各位置识别准确率; 使用上臂位置数据作为训练数据

因此,在进行运动识别时可以选模体长度为 40、SAX 词长为 12、SAX 字母表大小为 3、模体个数为 10 这组参数。

3.2 不同放置方式下的结果

为验证经过降维处理之后的信号确实与传感设备放置方式无关,对不同放置方式得到的实验数据,采用其中一种放置方式得到的数据进行训练,并用全部放置方式得到的数据进行测试(4 种放置方式见图 1(a))。在实验中选用的参数 $(m, w, \alpha, k) = (40, 12, 3, 10)$ 。得到的实验结果如表 1—表 4 所列,表中行代表训练放置方式,列代表测试放置方式,表格的第 i 行第 j 列代表采用第 i 种放置方式得到的数据进行训练,第 j 种放置方式得到的数据进行测试。

从实验结果可以看出,在所有放置位置上采用降维的方法处理信号后识别准确率均能达到 71%以上,平均准确率达到 85.05%,这表明降维可以有效降低手机放置方式对信号变化的影响。

表 1 上臂的各种摆放方式测试结果(%)

	O1	O2	O3	O4
O1	94.39	79.56	77.66	74.47
O2	71.64	98.39	74.45	74.47
O3	76.68	81.76	96.31	71.77
O4	73.69	81.56	76.14	94.20

表 2 胸口的各种摆放方式测试结果(%)

	O1	O2	O3	O4
O1	95.61	86.36	83.85	88.46
O2	90.31	94.79	84.54	83.11
O3	93.80	86.36	97.31	82.22
O4	91.47	87.27	83.16	96.56

表 3 裤子前口袋的各种摆放方式测试结果(%)

	O1	O2	O3	O4
O1	84.62	85.14	81.58	76.74
O2	87.50	83.78	78.95	77.91
O3	87.50	83.78	84.21	78.70
O4	84.62	85.14	81.58	91.86

表 5 各摆放位置测试结果对比(%)

	上臂			胸口			裤子前口袋			裤子后口袋		
	本文	传统	偏移估算	本文	传统	偏移估算	本文	传统	偏移估算	本文	传统	偏移估算
上臂	91.55	89.59	45.49	76.36	35.48	51.63	72.76	23.38	44.21	80.26	37.49	50.56
胸口	78.36	24.91	46.99	91.94	90.38	47.28	76.60	31.48	41.18	82.01	37.90	46.61
裤前袋	78.55	38.42	47.61	79.44	17.49	46.78	94.87	95.14	56.48	82.72	24.20	49.44
裤后袋	77.20	47.66	47.52	75.54	31.38	46.36	69.87	41.90	45.14	94.60	93.44	51.86

结束语 本文提出了一种与智能手机放置方式及位置无关的人体运动识别方法。首先使用降维的方法得到和智能手机放置方式无关的信号;然后利用模体发现找到信号中与手机放置位置无关的子序列,并建立 VSM 模型去识别人体运动。本文设计了实验来对方法进行评估,当智能手机放置在同一位置以任意方式摆放时运动平均识别率达到 85.05%,智能手机任意放置时平均识别率达到 81.41%。基于非固定位置加速度传感器的运动识别准确率的提升使得智能手机在一定程度上可以替代固定在身体上的加速度传感器,大大方便用户的使用,对于利用智能手机进行健康监护等具有指导意义。在现有工作中,我们假设智能手机是贴身放置的,并未考虑智能手机放置在不和人体接触的背包、手提包等时的情况,未来拟针对更多的摆放方式和摆放位置进一步改进该部分工作。

表 4 裤子后口袋的各种摆放方式测试结果(%)

	O1	O2	O3	O4
O1	96.13	81.54	87.19	84.50
O2	81.47	94.32	86.36	88.75
O3	81.29	81.37	95.93	84.50
O4	77.10	84.96	84.71	96.94

3.3 不同放置位置下的结果

为验证基于模体的运动识别方法确实与传感设备放置位置无关,对 4 个常见放置位置得到的实验数据,采用其中一个放置位置的实验数据(任意放置方式)进行训练,并使用全部的实验数据进行测试。在实验中选用参数 $(m, w, \alpha, k) = (40, 12, 3, 10)$ 。同时,为与现有工作进行比较,在同样的实验数据上使用传统提取特征的方法^[4](实验中使用的特征有均值、方差、平方差、中值、最大值、最小值、范围、均方根、相关系数、过零率、信号幅度区、信号向量幅值、熵、能量、频域熵)以及加速度信号偏移估算的方法^[10]进行实验,几种方法的实验结果对比如表 5 所列。

由实验结果可以看出,本文提出的方法平均准确率达到 81.41%,传统方法的平均准确率为 47.52%(在非训练位置的准确率基本不超过 50%),文献[10]中方法平均准确率为 47.82%(在各个位置的准确率稳定在 50%左右)。文本提出的方法平均识别准确率比传统方法提升了 33.90%,特别是在非训练位置上运动识别的平均准确率比传统方法高出 44.83%。文献[10]中的方法通过偏移加速度的特征来降低不同放置位置造成的影响,但是一方面其不考虑放置方式的影响(同一放置位置下的特征分布也会因放置方式不同而不同),另一方面不同位置上运动特征的大小和变化幅度差异很大,导致在智能手机这种非固定的加速度传感设备上的识别效果不好,本文提出的方法比文献[10]中的方法平均准确率提高了 33.59%。

参考文献

- [1] Kang H, Woo Lee C, Jung K. Recognition-based gesture spotting in video games[J]. Pattern Recognition Letters, 2004, 25(15): 1701-1714
- [2] Tentori M, Favela J. Activity-aware computing for healthcare[J]. Pervasive Computing, IEEE, 2008, 7(2): 51-57
- [3] 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
- [4] Bao L, Intille S S. Activity recognition from user-annotated acceleration data[M]//Pervasive Computing. Springer Berlin Heidelberg, 2004: 1-17
- [5] Ravi N, Dandekar N, Mysore P, et al. Activity recognition from accelerometer data[C]//AAAI. 2005: 1541-1546

(下转第 94 页)

与 SLSA 方法相比,STMLRC 方法不仅考虑主题空间映射矩阵的稀疏性,也考虑了数据在主题空间中的分布特性(要求数据在主题空间中呈现出更好的聚类特性),因此所构造的主题空间具有更好的分类性能。为了考察低秩约束所带来的影响,本文在 colon-cancer 数据集上对比了 STMLRC 方法和 SLSA 方法所学习的主题空间的分类性能。实验结果如表 4 所列。

数据集 (算法)	20NG		colon-cancer	
	SLSA	STMLRC	SLSA	STMLRC
10 维	74.20%	76.00%	81.33%	83.33%
100 维	91.39%	86.12%	81.33%	100%
500 维	93.66%	93.58%	91.67%	100%
1000 维	92.61%	95.66%	91.83%	100%
2000 维	93.88%	94.29%	93.67%	100%

数据集 (算法)	20NG		color-cancer	
	SLSA	STMLRC	SLSA	STMLRC
10 维	1.4%	1.34%	97.11%	52.09%
100 维	0.56%	0.59%	95.70%	32.27%
500 维	0.31%	0.57%	91.80%	6.49%
1000 维	0.24%	0.59%	88.29%	3.27%
2000 维	0.14%	0.43%	83.40%	1.66%

(上接第 79 页)

- 程中涉及到矩阵的 SVD 分解,映射矩阵学习阶段仍需要较大的计算量。在后面的研究中,如何提高映射矩阵的计算速度是未来的一个重要研究方向。

- [1] Dumais S T, Latent Semantic Analysis[J]. Annual Review of Information Science and Technology, 2005, 38(1): 188-230
- [2] Deerwester S, Dumais S T, Furnas G W, et al. Indexing by latent semantic analysis[J]. Journal of the American Society for Information Science, 1990, 41(6): 391-407
- [3] Chen X, Qi Y, Bai B, et al. Sparse Latent Semantic Analysis[C]//SIAM 2011 International Conference on Data Mining. 2011
- [4] Liu G, Lin Z, Yu Y. Robust subspace segmentation by low-rank representation[C]//Proceedings of the 26th International Conference on Machine Learning. Haifa, Israel. Citeseer, 2010
- [5] Liu Guang-can, Lin Zhou-chen, Yan Shui-cheng, et al. Robust Recovery of Subspace Structures by Low-Rank Representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(1): 2233-2246
- [6] Zhuang Lian-sheng, Gao Hao-yuan, Lin Zhou-chen, et al. Non-Negative Low Rank and Sparse Graph for Semi-Supervised Learning[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 2012
- [7] Lin Z, Chen M, Wu L, et al. The augmented Lagrange multiplier method for exact recovery of corrupted low-rank matrices[R]. UIUC Technical Report UILU-ENG-09-2215. 2009
- [8] Candès E. Compressive sampling[C]//Proceedings of the International Congress of Mathematicians. 2006
- [9] Candès E, Li X, Ma Y, et al. Robust principal component analysis[J]. Journal of the ACM, 2011, 58(3)
- [10] <http://people.csail.mit.edu/jrennie/20Newsgroups/>
- [11] http://www.csie.ntu.edu.tw/~cjlin/libsvmtools/datasets/multiclass.html#rcv1_multiclass
- [12] Chang C, Lin C. LIBSVM: a library for support vector machines [OL]. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 2001

- 94 •