

基于无线体域网的囚犯异常行为实时分析

杨璐璐 陈建新 周亮 魏昕

(南京邮电大学无线宽带通信与传感网技术教育部重点实验室 南京 210003)

摘要 随着无线传感技术的快速发展,无线体域网在远程医疗、智能家居等方面的应用日渐成为研究热点。监狱作为一个特殊场所,对囚犯的日常行为监控是必不可少的。准确而有效的监控系统能够在囚犯有异常行为发生时及时告警,这有助于监狱的管理,并阻止危险事故的发生。在监狱环境下,提出一种基于无线体域网的囚犯异常行为识别方法,即通过一个腕带式加速度传感器获取囚犯活动时的三轴加速度数据,采用分类算法判断是否有打架斗殴等异常行为发生。实验结果表明,该方法对异常行为的识别准确率能够达到95%。

关键词 无线体域网,异常行为识别,加速度传感器,特征提取,分类算法

中图法分类号 TP393 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.3.010

Real-time Analysis of Prisoner's Abnormal Behavior Based on Wireless Body Area Network

YANG Lu-lu CHEN Jian-xin ZHOU Liang WEI Xin

(Key Lab of Broadband Wireless Communication and Sensor Network Technology, Ministry of Education,
Nanjing University of Posts and Telecommunication, Nanjing 210003, China)

Abstract With the rapid development of wireless sensor technology, the application of wireless body area network in telemedicine and smart home gradually becomes the research hotspot. Prison is a special place, and the prisoner's daily behavior monitoring is essential. Accurate and effective monitoring system can alarm in time when abnormal behavior occurs, and it contributes to the management of prison and prevent dangerous accidents. In the prison environment, a method for prisoner's abnormal behavior recognition based on wireless body area network was presented. The three axis acceleration data are collected during the prisoner's movement through a wrist-worn acceleration sensor, and then the classification algorithms are used to recognize the activities to assess whether there are abnormal behaviors. The experimental results show that the recognition accuracy of the abnormal behaviors can reach 95%.

Keywords Wireless body area network, Abnormal activity recognition, Accelerometer, Feature selection, Classification algorithms

1 引言

对人体行为进行识别的研究可以追溯到20世纪90年代^[1]。行为识别的好处在于可以了解一个人的活动状态、活动强度、能量消耗等,在智能家居、老人监护、病人及运动员康复等领域有广阔的应用前景^[2,3]。在监狱环境下,在保护罪犯隐私的情况下对罪犯的行为识别有利于发现异常行为,阻止打架斗殴等恶性事件的发生,便于监狱管理,因此研究监狱环境下的异常行为识别具有重要意义^[4]。

2 相关工作

目前,人体行为识别的方法主要有两种,即基于视觉的行为识别和基于无线体域网的行为识别。基于视觉的行为识别因其监测范围有限,计算复杂,并且容易造成被监测者的个人

隐私泄露,在现实生活中并不能得到广泛应用^[5-8]。而随着微机电系统(Micro-Electromechanical System, MEMS)的快速发展,可穿戴式传感器因其体积小、重量轻、能耗小、携带方便等优点正越来越多地运用到无线体域网的行为识别研究当中。

为了提高行为识别的准确度,早期基于无线体域网的行为识别系统通常需要将多个传感器固定在人体的不同部位进行数据采集,如腰部、大腿、胸部、手臂、背部、手腕以及脚踝等。文献[9]将5个两轴加速度传感器分别固定在人体的脚踝、大腿、手腕、手臂、臀部,这种方法不仅系统能耗大、计算量大,而且大大降低了佩戴者的舒适度,会严重妨碍人类的日常生活。因此,现阶段越来越多的研究者针对单个加速度传感器的行为识别效果展开研究。Chernbumroong和Atkins将一个加速度传感器固定在手腕处收集加速度数据来区分坐

到稿日期:2014-05-07 返修日期:2014-07-02 本文受国家自然科学基金(61201165),泛在无线通信和无线传感器网络教育部重点实验室开放课题项目(NYKL201306),江苏省高校自然科学基金(13KJB510026),同济大学嵌入式系统与服务计算教育部重点实验室项目(ESSCKF201305)资助。

杨璐璐(1991—),女,硕士生,主要研究方向为无线传感器网络,E-mail:1012041213@njupt.edu.cn;陈建新(1973—),男,博士,副教授,主要研究方向为无线可穿戴计算;周亮(1981—),男,博士,教授,主要研究方向为无线多媒体通信;魏昕(1983—),男,博士,副教授,主要研究方向为机器学习。

着、站着、躺着、走路和跑步 5 种行为^[1]；同样是区分这 5 种行为，Choi 和 LeMay 则将一个 Shimmer 节点固定在腰部来收集加速度数据^[10]；文献^[11]中识别的行为包括站着、行走、跑步、上下楼梯，因为涉及的都是腿部动作，所以将传感器节点固定在腿上。

采用加速度传感器进行行为识别的方法主要有阈值判别和模式识别两种。人类的不同行为例如击打、行走、坐着等，其加速度的大小及波动情况都有很大区别。阈值判别便是基于这种原理，通过设定有效的阈值来识别各类行为。文献^[10]将一个加速度传感器节点固定在腰部，通过对 X 轴和 Y 轴的倾角以及 X 轴加速度的标准差设定阈值来识别走、站、坐、躺、跑等行为，准确率达到 95%。这种基于阈值的识别方法具有计算量小、能耗低的优点，但是由于不同年龄段、不同健康状况下的人体行为大不相同，设定的阈值不能自适应于各类人群，具有一定局限性。

用于行为识别的分类算法主要有支持向量机 (Support Vector Machine, SVM)^[2,12-14]、K-近邻算法 (K-Nearest Neighbors, KNN)^[11,15]、决策树算法 (Decision Tree, DT)^[2,4,11,16]、朴素贝叶斯 (Naive Bayes, NB)^[2,17]、隐型马尔科夫模型 (HMM, Hidden Markov Model)^[18]、人工神经网络 (Artificial Neural Networks, ANN)^[4,18] 等。常用于行为识别的加速度特征值包括时域的均值、方差、标准差、轴相关系数，以及频域的频谱能量、频谱熵等^[1,19]。

文献^[2]选用三轴加速度的均值、方差、能量、最大值、最小值等作为特征值，分析比较了线性判别分析 (Linear Discrimination Analysis, LDA)、NB、SVM、DT 4 种分类算法的行为识别准确率，实验结果表明 SVM 的识别效果最好，准确率可以达到 95% 以上；Chernbumroong 和 Atkins 则分析比较了 C4.5 决策树和 ANN 用于识别坐、站、躺、走、跑 5 种行为时的准确率^[1]；文献^[11]选用三轴加速度的均值、方差、能量以及功率谱密度的统计特性作为特征值，分析比较了 KNN、支持向量数据描述 (Support Vector Data Description, SVDD)、高斯一类分类器用于单个行为识别的准确率，以及 DT、KNN、加权支持向量机 (Weighted Support Vector Machine, WSVM) 用于多个行为识别的准确率。文献^[18]选用三轴加速度的均值和方差作为特征值，将 ANN 和 HMM 算法相结合，对人体一些日常行为如站立、左下、躺下等进行识别，其平均准确率为 80.5%。

与之前的研究工作不同的是，本文将对监狱囚犯的打架、斗殴等异常行为的识别效果进行分析，即通过在人体手腕处佩戴一个三轴加速度传感器来获取人体运动时的三轴加速度数据，对这些数据进行校正后提取其特征值，然后使用 SVM、KNN、DT、NB 来分析当人体有疑似打架、斗殴行为发生时的识别效果。

3 异常行为识别分析

囚犯在监狱中的活动范围有限，其正常行为基本就是行走和坐着，而其打架斗殴行为一般表现为手的击打和脚踢，因此我们选择击打、脚踢、行走、坐着 4 种行为用于囚犯异常行为的识别分析。这 4 种行为可以通过某些有效的时域或频域特征值来进行区分，所以我们首先要采集这 4 种行为的三轴加速度数据，对这些数据进行校正后提取其特征值，取其中一部分数据作为训练数据，采用分类算法构建分类模型，另一部

分数据作为测试数据送入分类模型，观察其行为识别效果。异常行为识别分析的流程如图 1 所示。




图1 异常行为识别系统流程

3.1 数据采集

本实验采用 Shimmer 用于三轴加速度数据的采集，Shimmer 是一个无线传感器平台，最初是为可穿戴式医疗传感应用而开发。其因体积小 (53mm×32mm×15mm)、重量轻 (22g)、功耗小等优点，目前在可穿戴式计算领域得到广泛应用^[10]。

Shimmer 平台内部集成了一个三轴加速度传感器 MMA7361，其灵敏度范围为 ±(1.5~6)g。另外，Shimmer 平台还包括一个工作在 8MHz 的低功率中央处理单元 MSP430，10kB 的内存和 48kB 的闪存，同时还包含一个 2GB 的 MicroSD 作为外部存储，用来收集和获取 Shimmer 内部集成的传感器所感知的生理参数和环境变量。Shimmer 平台支持 Zigbee 和 Bluetooth 两种无线传输模式，可以将从传感器获取的数据传送到个人电脑。

本实验中，首先将 Shimmer 平台用腕带固定在右手腕处，并将 Shimmer 平台与个人电脑上的蓝牙设备相连接，Shimmer 平台便可通过蓝牙串口与个人电脑进行通信。此时利用个人电脑上的 Shimmer 连接程序打开该串口便可读取三轴加速度数据，如图 2 所示。因为当一些打架斗殴行为发生时，加速度数据波动范围较大，因此将三轴加速度传感器 MMA7361 的灵敏度设置为 -6g+6g，数据的采样频率设置为 50Hz。



图2 数据采集过程

随着时间的推移，加速度数据会产生一定的漂移，因此还要利用 Shimmer 9 个自由度校正程序对原始加速度数据进行校正，再将校正后的加速度数据用于异常行为识别。若不进行数据校正，我们所得的原始加速度将是不可信的，进而也无法得到可靠的行为识别结果。

3.2 特征分析

各种各样的数据特征被用于基于三轴加速度的行为识别中，例如时域的均值、方差、标准差，以及频域的频谱能量、频谱熵等。本实验将校正后的三轴加速度数据分别划分为多个连续窗口，窗口长度为 100，相邻窗口之间有 50% 的重叠。根据式 (1)~式 (3)，按窗口提取三轴加速度数据的均值、方差、标准差作为行为识别的特征值。

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (1)$$

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (2)$$

$$\sigma = \frac{1}{n} \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3)$$

3.3 分类算法

本实验分析比较了 SVM、KNN、DT、NB 4 种分类算法用于异常行为识别的识别效果。SVM 是由 Cortes 和 Vapnik 根据统计学习理论提出的一种新的学习方法,它的最大特点是根据结构风险最小化准则,以最大化分类间隔构造最优分类超平面来提高学习机的泛化能力,较好地解决了非线性、高维数、局部极小点等问题^[12]。KNN 是一种基于实例的分类方法。该方法就是找出与未知样本 x 距离最近的 k 个训练样本,把 x 归这为 k 个样本中多数属于的那一类^[15]。DT 是以实例为基础的归纳学习算法,它着眼于从一组无次序、无规则的实例中推理出以 DT 表示的分类规则。构造 DT 的目的是找出特征值和类别间的关系,用它来预测未知样本的类别。它采用自顶向下的递归方式,在决策树的内部节点进行属性的比较,并根据不同属性值判断从该节点向下的分支,在决策树的叶节点得到结论。NB 是基于独立假设的贝叶斯定理的简单概率分类^[16],其原理是通过某对象的先验概率,利用贝叶斯公式计算出其后验概率,即该对象属于某一类的概率,选择具有最大后验概率的类作为该对象所属的类^[17]。

4 实验结果与分析

我们选择了 20 至 25 岁之间的男生和女生各两名,用于击打、脚踢、行走、坐立 4 种行为的数据采集,每个人每种行为的持续时间为 4 分钟。Shimmer 连接程序将接收到的数据存为 csv 文件,用于后续处理。对击打、脚踢、行走、坐着 4 种行为的采样数据进行校正后的结果如图 3—图 6 所示。

由图 3—图 6 可以看出,当有击打行为发生时三轴加速度的波动范围较大。因为传感器平台固定在人体手腕处,所以脚踢时三轴加速度会有波动,但相对于击打时要小很多。人类行走时手臂会自然的前后摆动,所以行走时的三轴加速度也会有一定波动,并且其波动范围与脚踢时的大致相同。坐着时的三轴加速度就比较平稳,波动较小。




图 3 校正后的击打时的三轴加速度数据




图 4 校正后的脚踢时的三轴加速度数据




图 5 校正后的行走时的三轴加速度数据




图 6 校正后的坐着时的三轴加速度数据

从采集的 4 个人的 4 种行为的加速度数据中,我们对每个人的每种行为随机选取 12000 个样本,即每种行为 48000 个样本。然后对每种行为利用 3.2 节的方法进行特征提取,形成一个 958×9 的特征矩阵。图 7 示出击打、脚踢、行走、坐着的三轴加速度数据的均值、方差和标准差。可以看出,击打行为的特征值与其他 3 种的行为区别明显,而脚踢时与行走时的均值、方差、标准差区别不太明显,坐着时手的放置位置与行走时也有很大区别,波动也较小,因此坐着时的均值和标准差与行走时也有明显区别。




图 7 三轴加速度数据的均值、方差、标准差

从每种行为的特征矩阵中选取 50% 组成 479×9 特征矩阵作为训练数据,用于构建分类模型,剩余的 479×9 的特征矩阵作为测试数据,用于验证行为识别效果。表 1 列出采用 SVM、KNN、DT、NB 4 种分类算法时,击打、脚踢、行走、坐着中的每种行为与其他 3 种行为的识别准确率。因击打和脚踢同为异常行为,行走和坐着同为正常行为,于是表 2 分析比较了击打、脚踢与正常行为、行走、坐着与异常行为,采用 4 种分类算法时的识别准确率。

表 1 各行为与其他 3 种行为的识别准确率

	击打-其他	脚踢-其他	行走-其他	坐着-其他
SVM	97.70%	95.09%	97.44%	99.63%
KNN(K=5)	100%	96.29%	96.35%	99.84%
DT	100%	94.15%	93.95%	99.48%
NB	99.63%	74.43%	83.04%	99.32%

表2 异常行为与正常行为之间的识别准确率

	击打-正常	脚踢-正常	行走-异常	坐着-异常
SVM	99.51%	96.31%	96.59%	99.63%
KNN(K=5)	100%	95.06%	95.13%	99.93%
DT	100%	92.14%	91.86%	99.30%
NB	99.79%	82.67%	77.38%	99.23%

由表1和表2可知,SVM和KNN两种分类算法的行为识别准确率较高,各情况下的行为识别准确率都能达到95%以上,DT的识别准确率稍差,而NB的识别效果最差,脚踢和其他3种行为、行走和异常行为的识别准确率都不到80%。

而在采用同一种分类方法对各类情况进行行为识别时,脚踢与其他、脚踢与异常行为、行走与其他以及行走与异常行为这4种情况下的识别准确率是相对较低的。这是因为Shimmer传感器平台是固定在手腕处,当观测者有脚踢或行走行为发生时,传感器的三轴加速度数据会有一定的波动,不会像坐着时那么平稳,但又不会像击打时变化那么剧烈(如图3—图6所示),因此在脚踢和行走两种行为同时存在时会造成误判,降低了行为识别的准确率。

结束语 本文对基于无线体域网的囚犯打架斗殴等异常行为识别进行分析。收集典型的打架斗殴行为如击打、脚踢以及正常行为如行走、坐着的三轴加速度数据,将收集到的数据进行校正后提取特征值,形成特征矩阵。从特征矩阵中选取一部分作为训练数据,另一部分作为测试数据,采用SVM、KNN、DT、NB 4种分类算法对训练数据进行学习,构建相应分类模型对测试数据进行分类。结果表明,采用SVM和KNN算法时行为识别的准确率可以达到95%以上,有些甚至可以达到100%。本方法的特点是硬件设计体积小、重量轻、低功耗、易于携带,但是训练数据的学习阶段和测试数据的分类阶段都是离线的,还不能满足实际应用要求,因此我们将对异常行为的在线识别展开研究。

参考文献

- [1] Lara O D, Labrador M A. A survey on human activity recognition using wearable sensors[J]. Communications Surveys & Tutorials, IEEE, 2013, 15(3): 1192-1209
- [2] Park C, Kim J, Choi H-J. A watch-type human activity detector for the aged care[C]// 2012 14th International Conference on Advanced Communication Technology (ICACT). IEEE, 2012: 648-652
- [3] 王荣,章韵,陈建新. 基于三轴加速度传感器的人体跌倒检测系统设计与实现[J]. 计算机应用, 2012, 32(5): 1450-1452
- [4] Chernbumroong S, Atkins A S, Yu H. Activity classification using a single wrist-worn accelerometer[C]// 2011 5th International Conference on Software, Knowledge Information, Industrial Management and Applications (SKIMA). IEEE, 2011: 1-6
- [5] 杜友田,陈峰,徐文立,等. 基于视觉的人的运动识别综述[J]. 电子学报, 2007, 35(1): 84-90
- [6] Vaidehi V, Ganapathy K, Mohan K, et al. Video based automatic fall detection in indoor environment[C]// 2011 International Conference on Recent Trends in Information Technology (ICRTIT). IEEE, 2011: 1016-1020
- [7] 王孝平,谢维成. 人体运动异常行为监测[J]. 西华大学学报: 自然科学版, 2012, 30(6): 22-25
- [8] 王亮,胡卫明,谭铁牛. 人运动的视觉分析综述[J]. 计算机学报, 2002, 25(3): 225-237
- [9] Bao L, Intille S S. Activity recognition from user-annotated acceleration data[M]// Pervasive computing. Springer, 2004: 1-17
- [10] Choi S, LeMay R, Youn J-H. On-board processing of acceleration data for real-time activity classification[C]// 2013 IEEE Consumer Communications and Networking Conference (CCNC). IEEE, 2013: 68-73
- [11] Yang J, Wang S, Chen N, et al. Wearable accelerometer based extendable activity recognition system[C]// 2010 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2010: 3641-3647
- [12] Cortes C, Vapnik V. Support-vector networks [J]. Machine learning, 1995, 20(3): 273-297
- [13] Varkey J P, Pompili D, Walls T A. Human motion recognition using a wireless sensor-based wearable system[J]. Personal and Ubiquitous Computing, 2012, 16(7): 897-910
- [14] 徐川龙,顾勤龙,姚明海. 一种基于三维加速度传感器的人体行为识别方法[J]. 计算机系统应用, 2013(6): 132-135
- [15] Larose D T. k-Nearest Neighbor Algorithm [J]. Discovering Knowledge in Data: An Introduction to Data Mining, 2005: 90-106
- [16] Safavian S R, Landgrebe D. A survey of decision tree classifier methodology[J]. IEEE transactions on systems, man, and cybernetics, 1991, 21(3): 660-674
- [17] Zhang H. The optimality of naive Bayes[J]. AAAI, 2004, 1(2): 3
- [18] Zhu C, Sheng W. Recognizing human daily activity using a single inertial sensor[C]// 2010 8th World Congress on Intelligent Control and Automation (WCICA). IEEE, 2010: 282-287
- [19] Siirtola P, Laurinen P, Haapalainen E, et al. Clustering-based activity classification with a wrist-worn accelerometer using basic features[C]// IEEE Symposium on Computational Intelligence and Data Mining, 2009(CIDM'09). IEEE, 2009: 95-100
- [4] Brad Karp, Kung H T. GPSR: Greedy Perimeter Stateless Routing for Wireless Networks[C]// Proceedings of MobiCom. 2000: 243-253
- [5] Cadger F, Curran K, Santos J, et al. A survey of geographical routing in wireless ad-hoc networks[J]. Communications Surveys & Tutorials, IEEE, 2013, 15(2): 621-653
- [6] Sobrinho J L, Quelhas T. A theory for the connectivity discovered by routing protocols [J]. IEEE/ACM Transactions on Networking, 2012, 20(3): 677-689
- [7] Chen W, Guha R K, Kwon T J, et al. A survey and challenges in routing and data dissemination in vehicular ad hoc networks[J]. Wireless Communications and Mobile Computing, 2011, 11(7): 787-795
- [8] 曹生林,马旭. 基于区域的可控路由模型[J]. 计算机科学, 2013, 40(10): 104-108
- [9] 王向华,覃征,杨慧杰,等. 基于当前统计模型的模糊自适应跟踪算法[J]. 兵工学报, 2009, 30(8): 1089-1093
- [10] 贾航川,吕娜. 一种基于两跳自适应信标的航空 GPSR 协议[J]. 重庆邮电大学学报, 2014, 26(4): 335-340
- [11] 郭鑫,葛凤翔,郭良浩. 改进的自适应 Kalman 滤波及其在水声机动目标跟踪中的应用[J]. 声学学报, 2011, 36(6): 611-618

(上接第38页)