

9-2-2020

Embedded Power Optimization Method Based on User Behavior

Wang Hai

School of Information Science and Technology, Northwest University, Xi'an 710127, China;

Gao Ling

School of Information Science and Technology, Northwest University, Xi'an 710127, China;

Dongqi Chen

School of Information Science and Technology, Northwest University, Xi'an 710127, China;

Ren Jie

School of Information Science and Technology, Northwest University, Xi'an 710127, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Embedded Power Optimization Method Based on User Behavior

Abstract

Abstract: In recent years, with the rapid development of embedded device represented by mobile phone and tablet computer, low power technology has been one of the hotspots in the embedded research field. Because the battery capacity of embedded device is limited due to its restricted volume and weight, there are often users suffering the problem that their phone battery being dead. There are many research directions in embedded low power field at present. *The relationship between low power and user behavior recognition was aimed, which started with recognizing user behavior using machine learning and then obtains the user's daily usage habits in specific behavior. Part of device components could be turned off or Dynamic Interactive Optimize Strategy was applied to reduce the power consumption.*

Keywords

embedded system, low power, user behavior recognition, machine learning

Recommended Citation

Wang Hai, Gao Ling, Chen Dongqi, Ren Jie. Embedded Power Optimization Method Based on User Behavior[J]. Journal of System Simulation, 2015, 27(2): 320-326.

一种基于用户行为的嵌入式功耗优化方法

王海, 高岭, 陈东棋, 任杰

(西北大学信息科学与技术学院, 西安 710127)

摘要: 随着以手机、平板电脑等为代表的嵌入式设备的飞速发展, 嵌入式低功耗问题已经成为了一个研究热点。经常有用户在户外面临手机没电所带来的问题, 目前主要给嵌入式设备供电的电池却受到其体积、重量等因素的制约, 只能提供有限的电量。从用户行为识别出发, 用机器学习的方法识别设备用户当前的行为状态, 根据既定的策略来获取该行为状态下用户对设备的使用习惯, 进而通过主动关闭设备不使用的部件或者提醒用户应用动态交互优化策略来降低设备功耗。

关键词: 嵌入式系统; 低功耗; 行为识别; 机器学习

中图分类号: TP3-05

文献标识码: A

文章编号: 1004-731X (2015) 02-0320-07

Embedded Power Optimization Method Based on User Behavior

Wang Hai, Gao Ling, Chen Dongqi, Ren Jie

(School of Information Science and Technology, Northwest University, Xi'an 710127, China)

Abstract: In recent years, with the rapid development of embedded device represented by mobile phone and tablet computer, low power technology has been one of the hotspots in the embedded research field. Because the battery capacity of embedded device is limited due to its restricted volume and weight, there are often users suffering the problem that their phone battery being dead. There are many research directions in embedded low power field at present. *The relationship between low power and user behavior recognition was aimed, which started with recognizing user behavior using machine learning and then obtains the user's daily usage habits in specific behavior. Part of device components could be turned off or Dynamic Interactive Optimize Strategy was applied to reduce the power consumption.*

Keywords: embedded system; low power; user behavior recognition; machine learning

引言

在即将步入物联网时代的今天, 嵌入式设备已经非常普及。据工信部调查显示, 截止 2013 年 3 月, 中国的手机用户数量已经达到了 11.46 亿。

然而很多用户对设备的能耗问题并没有一个很好的认识, 在使用手机时或多或少的有一些这样

的习惯: 让一些不使用的程序仍在后台运行, 断开 WiFi 网络后没有及时关闭 WiFi 部件, 在室内铃声音量过大或者屏幕过亮等等。这些小习惯虽然单独不会浪费手机多少电, 但是综合起来却是一个导致你的设备电池电量急剧下降的原因, 这些功耗也被称之为无效功耗^[1]。

据调查统计, 这些增加设备能耗的使用习惯来源主要包括以下几个方面: (1) 用户根本没有注意到这个问题; (2) 为了使用方便不想经常手动改变设备设置; (3) 随时能充电, 不在意电池电量。虽然无效功耗引起的单独一台嵌入式设备的电量减



作者简介: 王海(1977-), 男, 博士, 讲师, 研究方向为低功耗嵌入式系统、云计算; 高岭(1964-), 男, 博士, 教授, 研究方向为云计算、网络安全、嵌入式系统; 陈东棋(1988-), 男, 博士, 研究方向为低功耗嵌入式系统、机器学习。

收稿日期: 2014-07-10 修回日期: 2014-10-26
项目基金: 国家自然科学基金(61373176); 教育部博士点基金(20116101110016); 陕西省自然科学基金(2012JQ8047); 陕西省工业攻关项目(2014K05-42)

<http://www.china-simulation.com>

少并不能引起用户多大的关心,但是其对整个社会带来的能耗开支却是巨大的,这不得不引起我们的关注。针对这个问题,本文提出了这样的解决思路:利用机器学习来判断用户目前的行为状态,并根据不同用户在不同状态下的设备使用习惯来对设备做一些主动的调整或者提示用户是否要手动调整,这样不仅可以保证设备处于最优最节能的运行状态,而且所做的优化对用户几乎是透明的。

1 嵌入式低功耗研究现状

目前在嵌入式低功耗领域,对功耗的优化都是从硬件级、编译级、和指令级这 3 个方向出发的。

硬件级的功耗优化主要是从动态功耗入手,使用动态电源管理策略或者动态可变电压 DVS 和动态可变频率 DFS^[2]来控制动态功耗。另外还有 Su Ching-long 等人^[3]将地址线采用格雷编码和冷调度 (cold scheduling)的方法使得电路每拍的信号翻转次数减少,从而降低了动态功耗。针对指令级的功耗优化,目前如下代表成果。Sreraman 等人^[4]实现的一个向量化编译器,采用了循环技术来分析识别数据的并行性;夏宏等人^[5]提出了一种基于 cache 可重组技术以及数据符号压缩技术的低功耗 D-cache 设计方法,降低了 cache 的功耗。编译级功耗优化主要包括了静态编译优化和动态编译优化。Mahmut 等人^[6]利用代码优化来提高内存 Bank 的局部性,从而减少内存访问带来的功耗。静态编译技术还包括了数据到硬件平台的划分^[7]以及代码内联等 Code Size 优化技术^[8]等。而动态编译优化则有 IBM 的 Toshio 等提出基于代码区域的 java 即时编译技术来进行内联和数据流的优化^[9]。

目前国内外对嵌入式低功耗的研究主要集中在上述方面,而情景感知和嵌入式低功耗的交叉领域还是属于空白。

2 用户行为与使用习惯

本文中提出的用户行为的概念是来源于情景感知研究领域^[10]。情景感知主要研究的是实体的情景信息。如图 1 所示,一个学生的情景信息会包

括其所处的位置,交通方式,天气情况,行为等等。

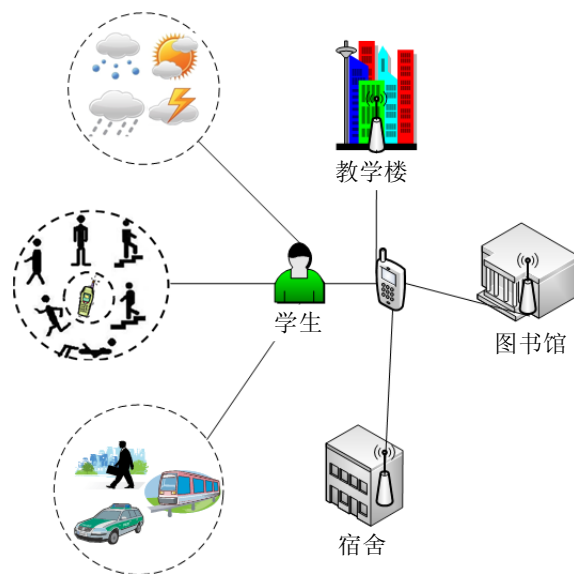


图 1 学生的几个情景信息

2.1 用户行为分析

本文所做的研究只是选取了情景信息中的用户行为这一个因素。然而只是单纯的用户行为研究目前也是一大难点,一些学者在这方面的研究也已经有了一定的成果。例如 Reddy.S 等人^[11]使用移动电话的传感器来判断用户的交通方式,其准确率已经达到了 93.6%。

单个传感器无法准确的进行用户行为识别,比如加速度计多用于检测用户状态,及交通工具的震动情况, GPS 可用于检测用户的移动速度, WIFI 可用于测量室内的位置信息,麦克风、温度、亮度、湿度传感器等能对用户周围情景进行综合识别。基于异构传感器数据融合的行为识别是近年来的研究热点。德国的 Gerald Bieber 小组研究基于加速度计和麦克风的日常行为识别^[12]。文献[12-14]选择融合加速度计和 GPS 信息来进行交通模式的识别,加速度计适合检测运动特性,但难以区分用户是静止还是在交通工具上处于相对静止状态。GPS 适合检测速度特性。文献[12]将人的日常行为分为静止、走路、跑步、上下楼梯、跌倒等,用通过监测传感器记录测 6 种行为的数据,进行行为识别。用户的手机穿戴位置也影响行为检测的结果,因为

身体各部位的运动规律不同^[13]，导致特征数据差异。文献[14]利用 PCA 提取不同位置的共性特征，采用高置信度识别样本，迭代更新识别模型。

本文主要是针对不同行为下的不同用户习惯而提出相应的低功耗策略，经过前期调查和对用户使用习惯的分析发现，过于复杂的用户行为对本文的研究基本是没有意义的，比如像跌倒行为对判断用户是否使用手机基本没有价值。因此我们精简了情景信息概念中的用户行为，提出了简单用户行为的概念，包括了以下五种日常行为：静止、步行、奔跑、骑车、乘坐机动车。这五类行为是日常行为中最具代表性和区分性的，对我们的低功耗研究也最具价值。

2.2 不同用户行为的低功耗策略研究

要制订不同用户行为下的低功耗策略，我们先得掌握不同用户在不同行为下的使用习惯。据艾媒咨询(iiMedia Research)2013 年 2 月的调查报告显示，2012 年中国手机用户年龄分布如图 2 所示。




图 2 中国 2012 年手机用户年龄分布

从图中可以看出，目前手机用户呈现年轻化，而另一项对智能手机用户的调查进一步显示了智能手机的使用群体基本集中在 20-30 岁之间^[15]。手机用户年轻化所带来的使用习惯的革命对功耗优化是有指导意义的。20-30 岁之间的用户是智能 3G 的最大消费群体，这一群体的使用习惯主要集中在四个方面：传统通信、影音娱乐、游戏以及社交网络。而这些习惯所带来的就是手机耗电主要集中在了屏幕、音频部件、射频发射器和处理器。针对这

些部件的功耗优化，已经有了一些比较成熟的方法。我们提出建立一个低功耗优化策略库来包含这些已有的优化策略，在不同的行为下，将启动库中适合的优化策略来降低当前的设备功耗。例如在室内环境时，可以降低设备的音量和屏幕亮度；在跑步时可以自动关闭网络，降低 CPU 频率等。

文献[15]中的另一项调查还表明了，大学生习惯在开会、上课、吃饭、休息等间隙时间玩手机。手机的随时随地性打破了时间和空间的限制，是破碎化程度最高的媒体，它彻底占领了大学生破碎化的时间。而我们针对不同行为下用户使用习惯的调查也表明了静止状态是用户最常使用手机的时段；跑步、开车、骑自行车这些行为中手机被使用的很少；而在步行，乘坐公交和出租车时又会有部分用户使用手机通信、娱乐或者社交功能。针对目前用户的使用习惯，我们提出动态交互优化策略 (Dynamic Interactive Optimize Strategy)，自动优化不影响或者对用户体验影响很低的功能，而对性能和用户体验影响较大的优化采取动态交互的方式，提醒用户选择或者放弃优化。以此来达到既不影响用户体验又能达到低功耗的目的。如图 3 所示。



图 3 动态交互优化策略模型

最顶层是数据获取，利用嵌入式设备自带的传感器来获取用户的速度和加速度两个情景信息。获取的数据传递给第二层进行行为预测，通过机器学习中的决策树方法对用户数据做类别的划分，将用户行为分类为静止、步行、跑步、骑车和乘坐机动车。最底层是优化策略库层，在第二层将用户行为

分类之后, 根据不同行为模式下的使用习惯来调用相关的功耗优化策略进行优化。

3 用户行为识别

用户行为的识别一直是情景感知研究方向的一大难点和热点。本章将介绍我们通过采集用户数据来对简单用户行为进行识别, 进而用动态交互优化策略来进行功耗优化。

目前通过手机传感器对用户行为的研究成果并不是很多。Reddy S 等人^[11]研究了利用 Bluetooth, WiFi, GSM, Accelerometer 和 GPS 这些传感器单独或者组合的形式来判断用户当前的行为, 结果表明使用 GPS 和 Accelerometer 组合的准确率高于其他任何两个传感器的组合, 如果再加入一个传感器最多只会增加 0.6% 的准确率, 但是却会增加额外的系统开销。

选用 GPS 和 Accelerometer 这两个传感器本质上就是获取用户的移动速度(通过 GPS 获取)和加速度(通过 Accelerometer 传感器获取)。对于速度差别较大的用户行为, 用速度即可区分; 速度相近的行为, 再使用加速度来判断不同的行为。因此我们的实验中搜集了 GPS 和 Accelerometer 这 2 个传感器的数据, 然后使用机器学习(Machine Learning)的方法来对简单用户行为做分析。

3.1 用户行为数据的采集

实验所需的用来判断用户行为的数据为速度和加速度。为了使用手机传感器来取得用户的速度和加速度, 我们开发了一款基于 Android 系统的工具, 来取得 GPS 部件和 Accelerometer 传感器的数据, 并计算速度和加速度。对于速度的计算, 选取两个时间点, 通过 GPS 部件提供的两个时间点之间的距离除以时间片长度来得到; 而 Accelerometer 传感器获取到的是一个三维方向的加速度, 坐标系的表示如图 4 所示。获取到 x , y , z 3 个方向的加速度之后我们通过公式 $a = \sqrt{x^2 + y^2 + z^2}$ 来计算用户的加速度。




图 4 Android 加速度传感器坐标系

将工具装载到项目的实验机中, 分别测试了静止、步行、奔跑、骑车、乘坐机动车五种简单行为下的加速度和速度。

3.2 数据预处理

在用户行为中, 例如用户在乘坐公交车时, 遇到红灯或者到站等情况, 其速度值就会降到 0。如表 1 中的数据, 速度为 0 的训练样本在分类时会成为孤立点, 这种情况下我们需要对收集的源数据进行预处理, 根据决策树的先剪枝思想^[16], 可以将阈值以下的数值剔除, 防止训练样本的过学习。

表 1 乘坐公交车的数据片段

序号	速度	加速度
1	11.125 36	1
2	11.705 4	1
3	0	1
4	18.488 85	1
5	10.145 44	1
6	0	1
7	13.720 03	1
8	5.317 061	1
9	3.544 981	1

而在要预测的数据中出现这种孤立的样本时, 如果只根据单独的数据来预测的话它就会被错误的识别成其他行为了, 对此我们提出一种连续取样的策略来解决这种情况: 要判断某个待预测数据, 取样它之后 N 个待预测样本, 如果其中预测结果最多的为机动车, 而有几个样本预测为静止或者步行, 则可以认为目前用户是处于乘坐机动车的状态。

3.3 决策树介绍及分类算法的选择

决策树算法发展到今天已经形成了几种比较成熟的分枝划分标准, 包括了直接划分法、信息熵增益、最短距离划分等, 发展到 ID3 方法达到了一个顶峰。ID3 算法是把信息熵增益作为划分标准, 公式比较复杂, 计算量大, 当数据较多时很耗费系统资源。在本论文中我们选用了 J48 算法, 该算法严格来说是 ID3 算法的一个改进版, 其具有如下优点: 分类规则易于理解, 准确率高。而其缺陷在于不能应用于训练集过大的样本。本文的样本空间并不复杂, 所以正适合 J48^[16]算法。

4 实验及结果分析

4.1 实验平台

本实验的硬件选用了小米科技的 MiOne 手机, 搭载的系统为 MIUI2.3.6f(稳定版)。软件平台为我们自行编写的基于 Android 系统的程序。程序 MyGpsAcc 用来收集用户的加速度和速度, 并按照 Weka 要求的格式存成文件, 程序 MyDataForecast 用来将新的数据样本根据已生成的决策树做行为的预测分类。

4.2 实验结果

我们将预处理之后的不同行为模式的数据样本分别选取 50 组, 即总共 250 组数据, 用 Weka 中的 J48 算法进行分类, 结果如下。

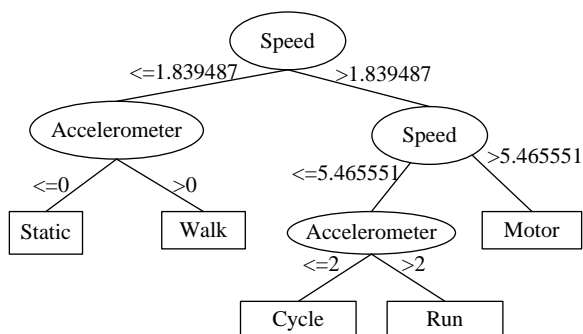


图 4 训练样本分类结果决策树

图 4 中决策树表示, J48 算法计算了速度和加速度的阈值, 将 250 组训练样本分为了静止、步行、

奔跑、骑车和乘坐机动车 5 类, 分类正确的实例有 236 个, 分错的有 14 个, 正确率达到了 94.4%, 因为本文中选用的是简单日常行为, 所以训练样本分类的准确率要略高于文献[11]中的 93.6%。

训练样本决策树生成之后, 另外取未经预处理的实验数据 250 组, 分别包括了静止、步行、奔跑、骑车和乘坐机动车这 5 类行为模式各 50 组连续的数据。这些数据用得到的决策树来预测并和实际情况作比对的结果如表 2 所示。

表 2 预测结果

用户行为	样本总量	预测正确 1	预测正确 2
静止	50	50	50
步行	50	45	50
跑步	50	37	47
骑车	50	31	42
乘坐机动车	50	34	37

在上表中, 5 类简单行为下的待预测数据分别为 50 组, 预测正确 1 表示用生成的决策树对单独每组数据做预测的正确数量, 其预测正确的数据有 197 组, 正确率为 78.8%。预测正确 2 表示用 3.3 小节中提出的连续取样的策略来预测的结果。这里将 N 设定为 7, 其预测正确的数据有 226 组, 正确率为 90.4%。由此可以看出, 用生成的决策树做行为的预测, 单独对每组数据预测的准确率可以达到 78.8%, 而使用连续取样策略之后则达到了 90.4%, 而且这个正确率会随着 N 值设定的增大而继续提高, 但是 N 值设定的增大也会相应提高计算所需的系统开销。

4.3 用户数据迁移

在本文的研究问题中, 一个最大的困难就是用户数据迁移, 即如何将既有的训练结果应用到其他用户的行为预测中去。在这一节中基于陈义强在个性化健康普适服务中的自适应迁移学习思想提出以下的思路来解决这个问题。

首先要训练一个固定的行为识别模型, 即文中提到的训练样本生成的决策树; 然后收集新用户的数据并将它们根据行为识别模型分到相应的类中;

接着用 K-means 算法^[17-18]调整每个类的中心; 最后修正决策树的阈值生成新的分类模型。

修正决策树之后进一步实验验证迁移学习的效果如表 3 中所示, 其中预测正确 1 为用户 A 未经过修正的决策树直接来预测用户 B 的行为的结果, 预测正确 2 为修正决策树后再次预测用户 B 的行为的结果, 使用的都是对数据的单独预测, 并未采用连续取样策略。从结果可以得出, 使用用户 A 的决策树直接预测用户 B 的行为, 所得到的正确率只有 52.8%, 修正决策树之后准确率又提高到了 73.6%。

表 3 迁移学习预测结果

用户行为	样本总量	预测正确 1	预测正确 2
静止	50	50	50
步行	50	24	37
跑步	50	17	33
骑车	50	18	34
乘坐机动车	50	23	30

5 能耗优化

用户行为识别之后, 需要对功耗优化策略库中的策略进行实际耗电量的测试。现在智能手机的屏幕越来越大, 而文献[15]的调查中也发现屏幕已经成为了智能手机耗电量的主要部件。因此选定功耗优化策略库中“调整屏幕亮度”来做实际耗电量的测试。而选用的测试设备为 MiOne 型号的智能手机, 具体参数详见表 4。

表 4 屏幕不同亮度下的耗电量

屏幕亮度	测量时间/min	总耗电量/%	耗电量/min
5 级	120	34	0.283%
4 级	120	23	0.192%
3 级	120	15	0.125%
2 级	120	13	0.108%
1 级	120	11	0.092%

表 4 所示的数据为重启手机并将其设置成离线模式, 即关闭所有数据通信服务, 并且不运行除了系统之外的任何程序的情况下, 实际测得的 120 min 内不同屏幕亮度等级下的耗电量。

对模拟现实情况的一段行为序列进行实际优

化的测试, 早晨出门上班的一种情况: 步行-乘坐机动车-步行-静止。根据前文中的调查分析可以发现步行、跑步和骑车行为下用户使用手机的时间比较少, 而乘坐机动车和静止的时候往往是用户使用手机的高峰期。因此, 在用户乘坐机动车时和静止状态时, 分别应用功耗优化策略库中的“调整屏幕亮度”策略, 根据环境亮度适当的降低屏幕的亮度。在实际测试中, 设定在乘坐机动车时播放 30 min 视频, 屏幕亮度调整为 2 级, 在静止时, 播放 10 min 视频, 屏幕亮度调整为 1 级; 而对照实验则是乘坐机动车时播放 30 min 视频, 静止时播放 10 min 视频, 屏幕亮度一直设定为 4 级。实验获取到的耗电量绘制成曲线如图 5 所示。




图 5 屏幕亮度优化前后的耗电量曲线

从实验结果可以看出, 在上述这一行为序列中, 通过合理应用“调整屏幕亮度”策略, 使得 40 分钟的手机使用时间内, 电量的消耗降低了 5%, 而该结果是在其他条件都保持不变的前提下测得的, 所以只是屏幕亮度这单一要素调整所导致的实验结果, 从而验证了本文提出的相关理论。另外针对其他功耗优化策略, 降低电量消耗的结果没有调整屏幕亮度那么显著, 但也都是有效的。

6 结论

介绍了嵌入式低功耗领域目前的主要研究内容, 提出了将情景感知领域中的用户行为识别和设备低功耗相结合的思路。首先验证了使用手机 GPS 和加速度计传感器对用户行为进行识别的可行性和准确性, 根据行为识别的结果, 选用了功耗优化

策略库中的“调整屏幕亮度”这条策略来做实际的功耗优化测试，验证了功耗优化的可行性。

参考文献:

- [1] Abhinav P, Abhilash J, Charlie H Y, Samuel P M. What is keeping my phone awake? Characterizing and Detecting No-Sleep Energy Bugs in Smartphone Apps. [C]// Proc. of the 10th International Conference on Mobile Systems, Applications, and Services. New York, USA: ACM, 2012: 267-280.
- [2] 夏军, 郑建宏. 嵌入式系统的动态电源管理架构 [J]. 单片机与嵌入式系统应用, 2005, 1(1): 8-10, 24.
- [3] Su C, Tsui C, Despain A M. Low power architecture design and compilation techniques for high-performance processors [C]// Proc of Comcon Spring'94. San Francisco, CA, USA: IEEE, 1994: 489-498.
- [4] Sreraman N, Govindarajan R. A vectorizing compiler for multimedia extensions [J]. International Journal of Parallel Programming (S0885-7458), 2000, 28(4): 363-400.
- [5] 夏宏, 苏林萍. Cache 低功耗技术研究 [J]. 计算机工程与应用, 2005, 41(23): 118-120.
- [6] Mahmut T Kandemir. Reducing Energy Consumption of Multiprocessor SoC Architectures by Exploiting Memory Bank Locality [J]. ACM Transactions on Design Automation of Electronic Systems (TODAES) (S1084-4309), 2006, 11(2): 410-441.
- [7] Wu, D., Al-Hashimi, B.M., Eles, P, Scheduling and Mapping of Conditional Task Graph for the Synthesis of Low Power embedded Systems [J]. IEEE Proceedings of Computers and Digital Techniqu (S1350-2387), 2003, 150(5): 262-273.
- [8] Zhuge Q, Shao Z, Xiao B, Sha E H-M. Design space minimization with timing and code size optimization for embedded DSP [C]// First IEEE/ACM/IFIP International Conference on Hardware/Software Codesign and System Synthesis, 2003, Newport Beach, CA, USA. USA: IEEE, 2003: 144-149.
- [9] Suganuma T, Yasue T, Nakatani T. A region-based compilation technique for a Java just-in-time compiler [J]. ACM SIGPLAN Notic (S0362-1340), 2003, 38(5): 312-323.
- [10] Dey A K. Providing architectural support for building context-aware are applications [D]. Atlanta, USA: Georgia Institute of Technology, 2000.
- [11] Reddy S, Mun M, Burke J, Hansen D, Srivastava M. Using mobile phones to determine transportation modes [C]// ACM Trans. Sensor Netw. 6, 2, Article 13(February 2010). USA: ACM, 2010: 27.
- [12] Yiqiang Chen, Juan Qi, Zhuo Sun, and Qiong Ning. Mining user goals for indoor location based services with low energy and high qos [J]. Computational Intelligence (S0824-7935), 2010, 26(3): 318-336.
- [13] Zhongtang Zhao, Yiqiang Chen, Junfa Liu, Zhiqi Shen, Mingjie Liu. Cross-People Mobile-Phone Based Activity Recognition [C]// IJCAI'11 Proceedings of the Twenty-Second international joint conference on Artificial Intelligence. Palo Alto, California 94303, USA: AAAI Press, 2011, Vol 3: 2545-2550.
- [14] Yiqiang Chen, Zhongtang Zhao, Shuangquan Wang, Zhenyu Chen. Extreme Learning Machine based device displacement free activity recognition model [J]. Soft Computing (S1432-7643), 2012, 16(9): 1617-1625.
- [15] 钱正. 大学生手机使用行为研究—基于武汉大学学生手机调查数据的分析 [J]. 广告大观(理论版), 2012, 1(1): 27-30.
- [16] 张学工. 模式识别 [M]. 第三版. 北京: 清华大学出版社, 2010, 8: 137-138.
- [17] 雷小锋, 谢昆青, 林帆, 等. 一种基于 K-Means 局部最优性的高效聚类算法 [J]. 软件学报, 2008, 19(7): 1683-1692.
- [18] 汪中, 刘贵全, 陈恩红. 一种优化初始中心点的 K-means 算法 [J]. 模式识别与人工智能, 2009, 22(2): 299-304.