

基于蓝牙动态特征的移动情境感知*

陈益强^{1,2}, 李秋实^{1,3}, 刘军发^{1,2+}, 胡琨^{1,4}, 陈振宇^{1,3}

¹(中国科学院 计算技术研究所, 北京 100190)

²(移动计算与新型终端北京市重点实验室, 北京 100190)

³(中国科学院 研究生院, 北京 100190)

⁴(湘潭大学 信息工程学院, 湖南 湘潭 411105)

Sensing Surrounding Contexts using Dynamic Bluetooth Information

CHEN Yi-Qiang^{1,2}, LI Qiu-Shi^{1,3}, LIU Jun-Fa^{1,2+}, HU Kun^{1,4}, CHEN Zhen-Yu^{1,3}

¹(Institute of Computing Technology, The Chinese Academy of Sciences, Beijing 100190, China)

²(Beijing Key Laboratory of Mobile Computing and Pervasive Device, Beijing 100190, China)

³(Graduate University, The Chinese Academy of Sciences, Beijing 100190, China)

⁴(College of Information Engineering, Xiangtan University, Xiangtan 411105, China)

+ Corresponding author: E-mail: liujunfa@ict.ac.cn

Chen YQ, Li QS, Liu JF, Hu K, Chen ZY. Sensing surrounding contexts using dynamic bluetooth information. Journal of Software, 2011, 22(Suppl. (2)): 137-146. <http://www.jos.org.cn/1000-9825/11034.htm>

Abstract: Traditional context-aware systems on mobile platform mainly focus on utilizing various localization based technologies to detect and recognize significantly meaningful places. However, they cannot intuitively describe the dynamic semantic context of the surroundings. In this paper, a novel context sensing approach is proposed to distinguish typical context based on dynamic Bluetooth information. The study builds a context classification model through observing the occurrence of ambient Bluetooth devices and dynamic statistical features extraction and further applied the model into inferring semantic social context based on Bluetooth traces from real-world personal lives. Evaluation results show, just based on dynamic Bluetooth information, the proposed feature extraction methods and DT (Decision Tree) can achieve an average accuracy of 86.8% for recognizing six representative short time-length contexts, which outperforms several traditional machine learning methods. In addition, the accuracy of long time-length context inferring can also reach 92% without any additional information but Bluetooth.

Key words: context-aware; bluetooth, dynamic; classification; context decision tree

摘要: 传统的情境感知系统多基于定位技术,以识别出重要的地点,但无法直观地描述用户所处的动态语义情境。提出了一种仅仅基于环境中动态蓝牙信息即可对情境进行准确感知的方法,即通过观察周围蓝牙设备的出现规律,提取多维动态特性,用以建立短时情境分类模型,并进一步将此模型运用到分析连续蓝牙轨迹,推断真实生活中的长时语义情境。针对实际环境中的6种典型情境的实验,其结果表明,仅基于动态蓝牙信息,提取的动态情景特征能

* 基金项目: 国家自然科学基金(61173066, 61070110); 北京市自然科学基金(4112056); 北京市教育委员会共建项目

收稿时间: 2011-07-20; 定稿时间: 2011-12-01

够有效体现各类移动情景特点,且情景决策树模型对于短时情景的平均识别准确率可达 86.8%,优于传统的其他几种模型方法.同时,基于短时情景的识别结果,综合推断出用户所处的长时间情境,其正确率可达 92%.

关键词: 情境感知;蓝牙;动态信息;分类模型;情景决策树

在用户与应用交互的过程中,用于识别一个实体所处状态的信息组成了情境.可信软件系统的一个基本要求是准确感知并恰当应对各类情境状态及其变化^[1].了解到用户的环境,应用系统就能够自适应地提供相关信息和增值服务^[2].因此,情境感知被认为是普适计算中不可或缺的一项技术.其中,基于移动终端的情境感知技术是目前普适计算领域的热点研究问题.

目前已有一些基于移动终端的情境感知方法,这些研究成果大多是利用手机获得 GPS,GSM,WiFi 等无线射频信号,挖掘出对用户而言重要的地点或探测其运动模式^[3,4].但实际上,用户所需要的并不一定是位置的物理地址信息,而是位置的语义信息,例如“办公室”、“超市”等.这些不同语义情境间的一个重要特点在于其局部环境的动态信息,如环境中的人员密度、流动情况等.然而,现有方法大多基于静态的无线信息(信号的覆盖区域固定),得到的位置信息是对周围环境的静态描述,因此无法具体而直接地描述用户所处环境的语义情境.

本文旨在利用环境动态信息,感知用户所处语义情境.蓝牙是一种极其普及的无线通信技术,已成为绝大多数移动设备的标准配置.蓝牙设备的一项重要功能是在不同的情境中,用户查询到的邻近蓝牙设备会呈现不同的特征,如图 1 所示,用户周围蓝牙设备的数量和变化规律,可以在一定程度上反映用户周围环境的动态信息,继而可以用来推断用户所处的语义情境.

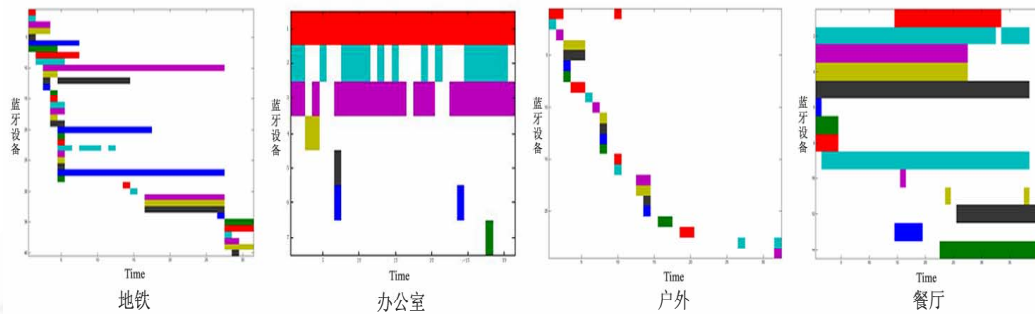


Fig.1 The BT trace of typical contexts. The horizontal axis shows time, and the longitudinal axis shows different BT devices

图 1 典型情境下的蓝牙轨迹图.横轴为时间,纵轴为出现的不同蓝牙设备

本文第 1 节对已有的蓝牙情景感知工作进行回顾.第 2 节介绍本文工作中,蓝牙动态特征的有效提取方法.第 3 节介绍基于实际蓝牙数据的短时情境识别模型及长时语义情景推断方法,给出定量实验的结果.第 4 节对本文工作进行总结和展望.

1 蓝牙情景感知研究现状

尽管蓝牙技术发明的初衷是为了进行短距离的通信.然而,研究者们注意到了蓝牙在查询邻近设备方面的性质,将其作为传感器,运用到了了解用户的接触与周围环境感知的研究中.这包括了识别用户日常生活模式、推测关系以及推断重要社交情境等,但是这些工作仅基于邻近蓝牙设备的数量,缺乏对其所代表的动态交互信息进一步的分析与运用^[5,6].

第一个利用蓝牙技术并基于手机平台去推断社交情境的代表性研究就是 MIT 的 Reality Mining 项目^[5].这个项目证明,利用标准的配备有蓝牙模块的手机,就可以获得大量的情境信息,并用来推测用户的行为模式和生活规律.研究人员主要基于蓝牙设备的数量进行分析,并利用隐马尔可夫模型,以区分“home”,“office”和“elsewhere”.Reality Mining 在利用蓝牙技术性质方面,起到开拓性的作用,对以后的相关研究产生了重要影响,

但相对来说还比较粗略,并没有深入挖掘蓝牙的特性.一些研究人员基于 Reality Mining 项目的数据库,进行日常生活模式的研究^[7].这些研究利用蓝牙作为邻近传感器(proximity sensors)以确定用户周围人群的数量,并将此作为日常生活模式的一个属性.这些工作同样只是利用了蓝牙信息中的设备数量特征,而并没有充分地利用其他动态信息.

另外一些工作主要集中在衡量与查询到的蓝牙设备间的交互关系上.Wireless Rope^[8]利用手机上的蓝牙装置,通过在某次国际会议上采集到的蓝牙信息,分析不同用户间的熟悉程度.同时他们也证明,熟悉或陌生人的高动态变化状态与社交行为也有密切的关系.Witten 等人^[9]则利用蓝牙信息,找出用户在日常生活中能够经常遇见的陌生人,并命名为“熟悉的陌生人”.MMM2 Project^[10]分析蓝牙轨迹信息,建议用户与哪些人分享与环境信息相关的照片.Jukka 等人^[11]则提出一个确定模型,通过蓝牙轨迹,确定用户的身份和工作类型.与这些工作不同的是,本文工作的目标在于通过分析局部动态蓝牙信息推测当前用户情境的语义信息,而不侧重于分析具体的与每个设备间的关系.

与本文工作最为类似的是 BlueSense^[12]和 Ryo 等人的工作^[6].BlueSense 的工作主要分为两部分.首先,文献[12]的作者通过实验证明,在扫描时间超过 5.12s,即可查询到范围内 80%的蓝牙设备;超过 10.24s,则基本可查询到所有的蓝牙设备.之后,他们利用近邻蓝牙设备的变化情况,通过聚类或滑动窗口的算法分析蓝牙轨迹,探测情境事件(episode)的变化信息.但是,它并没有指出每个情境事件的语义信息.此外,BlueSense 根据蓝牙设备的具体地址,将场景进行分类,即具有相同地址的场景为一类,而没有提取特征,依据其动态特性进行分类.因此,这种分类方法仅适用于静态场景,如办公室中,而很难运用于动态场景.Ryo 等人则通过对比不同情境下用户周围蓝牙设备的特征信息,证明了存在利用蓝牙分析用户情境的可能性.然而,他们并没有将其具体实现,即根据动态蓝牙信息进行情境分类.

综上对国内外研究现状的介绍和分析,可以得到以下结论:

- 目前推断位置信息的主流算法大多是基于静态的 RF 信息或者灯光色彩等物理信息,得到的是对周围环境的静态描述,对环境中的动态信息,特别是人员流动信息的研究则较少.
- 缺乏对情境语义信息的分析.现有的算法大多是找到某个具体位置,但无法对该位置的情境语义信息进行具体描述,即此位置代表什么样的逻辑意义,必须借助于其他信息(如具有标签的地图,或根据时间逻辑进行推断),才能发挥作用.这严重限制了情境感知在相关领域的应用.
- 没有充分挖掘蓝牙信号特征所代表的情境信息.目前,蓝牙已成为绝大多数移动设备的标准配置,但目前对于蓝牙的研究尚不充分,大多是用其得到邻近蓝牙设备的数量,缺乏对其所代表的动态交互信息的分析与运用.

2 蓝牙动态特征提取方法

为了能够尽可能地反映出用户所处环境的情境特征和动态信息,本文实验设计了有效的蓝牙特征向量.为了更好地说明特征的提取与表达,对相关参数进行了定义,见表 1.

Table 1 The definition of basic parameters

表 1 基本参数定义

N	每个采样周期中出现的蓝牙设备数目
N_s	每个时间槽内出现的固定蓝牙设备数目
N_m	每个时间槽内出现的移动蓝牙设备数目
N_{all}	每个时间槽内出现的不同蓝牙设备的数目 $N_{all}=N_s+N_m$
N_{new}	与上个采样周期相比,当前采样周期中新出现的蓝牙设备数目

首先,由于蓝牙信息特征具有明显的时序相关性,因此必须从连续的几个采样周期中提取特征,而不能独立地处理一个采样周期.本文定义一个时间槽(timeslot)为 t ,它由 w 个采样周期组成,并在此时间槽内提取特征值同时给出情境分类结果.即时间槽 t 为最小的处理单元,一个时间槽对应一个情境类型.

需要特别说明的是,在特征提取与分类训练之前,剔除了一个时间槽内没有查询到任何蓝牙设备的空数据.

即在训练和测试数据集中,对于任意一个时间槽 $t, N_{all} \neq 0$. 在下一节, 本文将针对这种空数据情况单独加以分析.

本文实验提取了 6 种蓝牙信号特征, 分为以下 4 类.

(1) 蓝牙设备数量

在一个时间槽内, 蓝牙设备数量 N_{all} 反映了环境中蓝牙设备的密度. 大多数情况下, 设备密度与周围人群的密度有直接的关系.

(2) 固定设备出现比率

如上文所述, 通过采集到的信号设备信息, 本文将蓝牙设备分为固定设备(台式机, 笔记本电脑等)和移动设备(手机, PDA, 平板电脑, 耳机等). 定义在一个时间槽中固定设备出现的比率 R_s 为

$$R_s = \frac{N_s}{N_{all}} \quad (1)$$

由于在室内工作环境中往往会出现较多的固定设备, 因此, 固定设备比率对于区分室内工作状态与其他状态非常有效.

(3) 蓝牙设备的变化属性

首先, 定义一个采样周期的设备变化率 C 为 N_{new}/N . 在时间槽 t 中, 本文采用变化率的均值和标准方差这两个特质值来表示此时间槽的蓝牙设备变化属性. 均值为整个时间槽中变化率的平均值(从第 2 个采样周期开始计算):

$$\bar{C} = \frac{1}{w-1} \sum_i^{w-1} C_i \quad (2)$$

标准方差为

$$\sigma_c = \sqrt{\frac{1}{w-1} \sum_i^{w-1} (C_i - \bar{C})^2} \quad (3)$$

蓝牙设备的变化属性反映了环境中蓝牙设备的流动情况.

(4) 蓝牙设备的持续属性

在一个时间槽中, 每个设备在 w 个采样周期出现的次数定义为这个设备的持续时间 $D(0 \leq D \leq w)$. 若定义持续阈值为 $D_{min}(D_{min} \leq w)$, 对于某个设备 j , 当 $D_j \geq D_{min}$ 时, 则定义设备 j 为持续设备. 持续设备的数量以 N_d 表示. 本文用持续时间均值和持续设备出现比率来反映此时间槽中蓝牙设备的持续属性. 均值为整个时间槽中所有设备的平均持续时间:

$$\bar{D} = \frac{1}{N_{all}} \sum_j^{N_{all}} D_j \quad (4)$$

持续设备的比率为

$$R_d = \frac{N_d}{N_{all}} \quad (5)$$

蓝牙设备的持续属性在一定程度上反映出用户是处在相对静态还是动态的情况中. 综合来看, 蓝牙设备的变化属性和持续属性共同反映出此时间段内局部环境的动态变化信息.

3 蓝牙情景感知实验

3.1 蓝牙数据采集与实验环境

本文基于移动手机终端进行了数据采集工作, 实时收集当前环境中的蓝牙设备数据, 采样周期为 30s. 在 3 个月的时间里, 采集得到的可用蓝牙数据训练样本超过 20 小时, 每个情境超过 200 分钟. 同时, 本文实验中还安排 3 位手机用户, 在其正常生活中采集了 3 星期~4 星期的全天蓝牙轨迹, 并记录其活动信息. 本实验要求用户优先选择 6 种情境类型中的 1 种进行描述所处情境, 但并没有要求必须局限于这 6 种. 通过信号采集软件, 我们在 6 种典型情境中采集蓝牙训练数据. 其中, “办公室” 主要为在研究人员所在办公室中采集的蓝牙信息数据, “刷

院”包括在电影院、剧院中采集的数据。“公共交通”主要是指地铁和公交车,“餐厅”是指普通餐厅(非包厢),“户外”是指在户外散步或行走,“购物”数据则包括商场和超市。为了避免噪声数据,本文采集的数据均是在确定的场景中,例如,“剧院”数据是在电影(演出)开始后采集。此外,本文还注意到了某些情境可能会出现多种状况,例如,“公共交通”数据既包含了高峰时的公交数据,也包含了非高峰时间段的数据。

本文实验涉及到另一个关键的问题是在真实生活中能否查询到足够的蓝牙设备,以保证情境推断算法的运用。对此进行了初步统计,图2示意了某用户一星期采集到的蓝牙设备密度图。结合实验数据和图2可以看出,在大多数公共场合,可以查询到丰富的蓝牙设备,而当用户处在较为空旷的空间,或者周围变化率很低且邻近人数数量稀少时,可能采集不到任何蓝牙信息。经过统计,本实验中蓝牙空白的时间段占全部时间长的比率平均为24.2%。另外,周围人数与蓝牙设备数量之间大致成正比关系。这也可以证明,本文工作具有较好的实验前提。




Fig.2 The density illustration of BT devices collected by one user

图2 某用户一星期采集到的蓝牙设备密度图

软件工具方面,本文利用开源机器学习工具 Weka 工具包,基于提取出的蓝牙特征,采用了最近邻(KNN)、支持向量机(SVM)、Adaboost、径向基函数神经网络(RBFNN)以及决策树(decision tree,简称 DT)等算法分别建立了短时情景分类器模型,并进行了对比分析。

3.2 蓝牙情境感知分类实验

3.2.1 几种蓝牙情境感知分类模型比较

实验中比较了5种常用的机器学习算法,以观察各类基于蓝牙信息的情境分类器的表现,实验结果见表2。本实验中时间槽长度设定为5分钟。

Table 2 The classification accuracy of several algorithms (%)

表2 不同算法的分类准确率(%)

		办公室	剧院	户外	餐厅	商场	公共交通	平均
KNN	查准率	100	85.3	76.7	61.7	56.7	51.7	71.46
	查全率	93.3	89.7	66.7	66.1	63	47.7	72.2
AdaBoost	查准率	94.9	96.4	25.3	24.5	24.5	25	48.4
	查全率	93.3	96	40	20	20	20	48.25
SVM	查准率	100	79.5	58.9	81.8	76	61.1	76.2
	查全率	95	94.2	93.3	60	63.3	55	76.8
RBFNN	查准率	98.3	97.4	73.8	63.6	66.1	44.6	74
	查全率	96.7	88.4	80	58.3	61.7	48.3	72.2
DT	查准率	100	92.6	87.1	79.5	77.6	84.1	86.8
	查全率	90	100	95.7	86.8	83.3	63.3	86.5

通过5种算法的对比可以看出,情景决策树算法的表现最好,平均准确率达到86.8%。以下相关参数变化实验都基于决策树模型来进行。

3.2.2 时间槽长度对分类精度的影响

时间槽的长度 t 是蓝牙特征提取中最重要的参数。时间槽的长度过长或者过短,都有可能掩饰蓝牙信息在反映环境动态信息方面的特性。同时,时间槽的长度也将直接影响分类器在实际系统运用中的实时性。

这里分别设定 t 为 90 秒(3 个采样周期)、3 分钟(6 个采样周期)、5 分钟(10 个采样周期)和 10 分钟(20 个采样周期),并以决策树算法为例,评估其分类表现.各个情境类型的分类正确率结果如图 3 所示.




Fig.3 The classification accuracy of different timeslots

图 3 不同时间槽的分类正确率

从图 3 可以看出,时间槽的长度直接影响分类结果的准确率,这也证明了蓝牙特征具有很强的时序相关性.具体分析如下:

(1) 对于周围环境较为平稳的情境(如办公室,剧院,餐厅),只需要较短的时间周期就可以识别.对于“办公室”情境,随着时间槽的增长,识别率还略有下降.这主要是因为,当时间槽较短时,往往是一段非常平稳的序列.当时间拉长,可能会出现人员走动的情况,此时有可能将其划分到其他情境,导致识别率的下降.

(2) 对于周围环境的动态信息比较复杂的情境,需要较长的时间周期才能够表现出其动态变化规律.例如当时间槽从 90 秒延长至 3 分钟时,“公共交通”、“购物”和“户外”这 3 种情境的识别率均大幅提高;当时间槽从 3 分钟延长至 5 分钟时,“公共交通”和“购物”的识别率依然有较明显的提高.

(3) 当时间槽达到一定长度时,分类准确率趋于稳定.当时间槽从 5 分钟延长至 10 分钟时,除“公共交通”情境类型外,其他情境类型的分类查全率均没有明显变化.从总体的准确率来看,当时间槽为 90 秒、3 分钟、5 分钟和 10 分钟时,准确率分别为 0.742,0.843,0.865 和 0.871.可见,当时间槽长度达到 3 分钟时,准确率已经不再有明显的提高;当达到 5 分钟时,就趋于稳定.

3.2.3 蓝牙设备数目对分类精度的影响

基于情景决策树模型,将时间槽长度设定为 5 分钟,分别统计了每个时间槽中的蓝牙设备数量和各个分类结果的正确率,结果如图 4 所示.

由图 4 可以综合看出,环境中查询到的蓝牙设备越多,越能得到更可信的分类结果.另一方面,蓝牙设备数目的增长对整体准确率提升的影响会逐步减小,当一个时间槽中的蓝牙设备数量达到 10 个以上时,就基本可以得到稳定的分类结果.图中也存在整体准确率“>15”小于“6~10”的情况,这是因为最大设备区间中缺乏“剧院”类型,从而影响了整体表现.对于“户外”情境类型,当设备数目增长时,可能会削弱其特征,更易与其他情况类型相混淆,因此准确率会有所下降.




Fig.4 The classification accuracy of different number of BT devices

图 4 不同蓝牙设备数区间的分类正确率

3.2.4 不同情境的识别混淆矩阵分析

通过上文可以看出,各种情境类型的识别率差异较大.有些情境相对较容易识别,有些则相对困难.为了分析各个情境类型在分类效果上的差异,本文采用了混淆矩阵的表示方式.同样,时间槽长度设定为 5 分钟.表 3 和表 4 分别为查准率和查全率的混淆矩阵.

Table 3 The confusion matrix of precision

表 3 查准率混淆矩阵

查准率(%)		Predicted context					
		公共交通	户外	购物	餐厅	剧院	办公室
Ground truth	公共交通	84.1	3.1	11.2	16.2	1.2	0
	户外	0	87.1	4.0	0	0	0
	购物	7.6	9.8	77.6	0	0	0
	餐厅	8.3	0	0	79.5	6.2	0
	剧院	0	0	2.3%	0	92.6	0
	办公室	0	0	4.9	4.3	0	100

Table 4 The confusion matrix of recall

表 4 查全率混淆矩阵

查全率(%)		Predicted context					
		公共交通	户外	购物	餐厅	剧院	办公室
Ground truth	公共交通	63.3	5.7	12	17.7	1.3	0
	户外	0	95.7	4.3	0	0	0
	购物	5.7	11	83.3	0	0	0
	餐厅	6.3	0	2.5	86.8	4.4	0
	剧院	0	0	0	0	100	0
	办公室	0	0	5.3	4.7	0	90

综合表 3 和表 4,并根据相关的实际数据,本文分析了各个情境类型的特点,特别是检查了分类错误的的数据,得到以下结论:

(1) 从查准率和查全率来看,“剧院”和“办公室”的分类结果最为准确.这说明,相对静态的情境更容易识别,这也与本文预料的结果相符.其中,“办公室”情境中往往有较多的固定设备,因此可以通过固定设备出现比率 R 来判断,当满足 R 值较大时即可被分类为“办公室”,查准率达到 100%;但在个别时段,也可能出现人员走动的情况,因此一些“办公室”情境会被错分至“购物”或“餐厅”.而“剧院”表现出的特征是环境信息非常平稳.分类器极易识别,因此查全率达到 100%;但可能其他情境特征在某些时段也会呈现平稳的特征,因此被错分至此情境中.

事实上,通过实验也能够表明,如果时间槽的长度足够长,则“剧院”的查准率也能达到 100%.

(2) “户外”的分类识别率仅次于“剧院”和“办公室”.这主要是因为,当处于“户外”情境时,用户本身处于持续移动状态,因此其邻近信息会一直发生改变,环境信息的变化最为剧烈.反映在蓝牙信息特征值上,就是蓝牙设备密度稀疏,变化率最高,持续设备比率最低.最有可能与“户外”混淆的是“购物”类型.这也与真实的场景相符.

(3) “公共交通”情境类型在所有情境中的分类效果最不理想,查全率只有 63.3%,这也影响到整体的结果.通过实验可以看出,大量的“公共交通”数据被分到其他类型.原因在于,在真实场景中,“公共交通”可能出现的场景非常多变,特别是高峰期与非高峰期差异极大,这也导致了“公共交通”类型中的蓝牙数据特征非常复杂.反映到实际场景中,当车厢内人数较少、变化较快时,易与“购物”甚至“户外”类型混淆;而当周围人数较多、一定时间内变化不大时,又容易与“餐厅”混淆,甚至在极端情况时(如堵车),被误分到“剧院”类型.

3.3 蓝牙真实语义情景推断实验

本文进一步将建立的短时分类模型运用到实际中的真实语义情景推断.所指的真实语义情境是指发生在特定地点、具有一定逻辑意义的较长时间活动.在本文中,一个情境事件需持续 5 分钟以上才被考虑.

为了能够精细地探测切换边界,同时提高情境推断的准确度,本文提出了基于滑动窗口和上下文约束的轨迹分析规则方法.滑动窗口的长度为一个训练时间槽(w 个采样周期),滑动步长为 1 分钟.主要分为两个步骤:识别每分钟的情境类型和推断当前语义情境.

首先,识别每分钟的情境类型:当每次滑动窗口更新时,均使用分类模型给出此窗口的情境类型,因此每分钟(除第 1 分钟以外)将 $w/2$ 次进入到滑动窗口中,并由 $w/2$ 个分类结果中出现次数最多的情境类型确定这一分钟的情境识别结果.

其次,推断当前的情境事件:如果当前分钟的情境类型与之前一致,则认为上一个情境事件延续至当前时刻.如果不一致,则说明情境可能出现变化.为了避免误判断,本文定义了一个缓冲区间,该区间由假定的切换边界开始,长度为情境事件最小长度(5 分钟).根据区间内可能出现的不同情况,具体分为以下两种:1) 在缓冲区间中,如果某个情境类型出现了一半以上的时间,则整个缓冲区间由该情境类型决定.2) 在缓冲区间中,如果没有一个情境类型占多数情况,则当前情境事件由上一个情境事件类型所决定.如果之前情境事件为相对静态情境(办公室,剧院,餐厅),那么此时出现的分类混乱,表明情境已经出现了明显变化,本文将这一缓冲区间的情境推断为“户外”.如果上一个情境事件为相对动态情境(户外,公共交通,商场),那么很难推断此时是否出现了情境变化.鉴于蓝牙信息的敏感性,本文在推断时仍延续上一个情境事件,即认为情境没有发生变化.

对上述推断方法,本文设计了相应的验证准则:如果算法正确推断出情境出现的时间和内容,则记为 Correct.相反,如果探测出情境发生变化,但识别成错误的情境类型,则标注为 False;如果没有被探测到情境事件的变化,则标注为 Missed;当误报情境发生变化,即一个连续情境事件并错分成多个情境事件,则标注为 Divided.表 5 所示为实验得到的情境推断结果.可以看出,对 3 位不同的用户,本文的算法都能够推断出绝大多数情境事件,正确推断情境的时间长度,平均占总情境长度的 92%.另一方面,在实际中出现最多的错误为 Divided,超过了其他两种错误类型的总和.这反映出基于蓝牙信息的情境识别算法对于情境信息的波动非常敏感,容易出现一段完整的情境被误拆分的现象.

Table 5 The context inference results of different users

表 5 不同用户的情境推断结果

	Correct	False	Divided	Missed
用户 1	176	15	54	11
用户 2	141	11	46	19
用户 3	110	9	23	4
总体	427	35	123	34

4 结束语

本文旨在通过观察邻近蓝牙设备,得到环境中的动态信息,特别是周围人群与流动信息,以直观地获得用户所处情境.本文针对 6 种典型情境,建立了基于局部动态蓝牙信息的情境分类模型,并将模型运用到实际的日常情境分析当中.本文总结出动态蓝牙信息在移动情境感知计算中表现出如下几个特点:

- 通过局部动态蓝牙信息,可以获得大量有用的情境信息,包括邻近人员的密度和流动,以及与周围环境的交互状态等.这些信息能够明显地反映出环境的动态特性,并直观和可靠地推断出所处情境,而这些是其他传感器很难替代的.

- 动态蓝牙信息表现出细粒度和高敏感的特性.由于蓝牙技术的覆盖范围小,而且可以同时查询所有的邻近蓝牙设备,因此,它可以感知到局部小区域环境中细微的变化,特别是探测动态的情境和静态的情境之间的转换.

- 基于蓝牙感知情境方法的主要缺陷在于,它容易受到客观因素的影响.当局部环境中的蓝牙设备数量稀少时,则会极大地影响准确率.因此,基于蓝牙感知情境方法的鲁棒性不强,无法适用于任意场合.

下一步,我们将深入研究蓝牙与移动终端其他通道信息的融合,并在此基础上探索基于情境信息的应用与原型系统.

References:

- [1] Huang Y, Yu JP, Ma XX, Tao XP, Lü J. Monitoring properties of open environments. *Journal of Software*, 2011,22(5):865–876 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/3800.htm> [doi: 10.3724/SP.J.1001.2011.03800]
- [2] Mo T, Li WP, Wu ZH, Chu WJ. Framework of context-aware based service system. *Chinese Journal of Computers*, 2010,33(11): 2084–2092 (in Chinese with English abstract).
- [3] Kim DH, Kim Y, Estrin D, Srivastava MB. SensLoc: Sensing everyday places and paths using less energy. In: *Proc. of the ACM SenSys 2010*. 2010. 43–56.
- [4] Yang G. *Discovering significant places from mobile phones—A mass market solution*. LNCS 5801, Berlin: Springer-Verlag, 2009. 34–49.
- [5] Eagle N, Pentland A. Reality mining: Sensing complex social systems. *Personal and Ubiquitous Computing*, 2006,10(4):255–268.
- [6] Nishide R, Ushikoshi T, Nakamura S, Kono Y. Extracting social contexts from Bluetooth detection logs. In: *Supplemental Proc. of the ACM UbiComp 2009*. 2009. 228–230.
- [7] Farrahi K, Gatica-Perez D. Learning and predicting multimodal daily life patterns from cell phones. In: *Proc. of the ACM ICMI-MLMI 2009*. 2009. 277–280.
- [8] Paulos E, Goodman E. The familiar stranger: Anxiety, comfort, and play in public places. In: *Proc. of the ACM CHI 2004*. 2004. 223–230.
- [9] Witten IH, Frank E. *Data Mining: Practical Machine Learning Tools and Techniques*. 2nd ed., San Francisco: Morgan Kaufmann Publishers, 2005.
- [10] Nair R, Davis M. Bluetooth pooling to enrich co-presence information. In: *Adjunct Proc. of the ACM UbiComp 2005*. 2005.
- [11] Perkio J, Tuulos V, Hermersdorf M, Nyholm H, Salminen J, Tirri H. Utilizing rich bluetooth environments for identity prediction and exploring social networks as techniques for ubiquitous computing. In: *Proc. of the IEEE/WIC/ACM WI 2006*. 2006. 137–144.
- [12] Kim DH, Cho DK. BlueSense: Detect individuals, location and regular activities from Bluetooth signals. <http://urban.cens.ucla.edu/cs219/BlueSense.pdf>

附中文参考文献:

- [1] 黄宇,余建平,马晓星,陶先平,吕建.开放环境特性感知技术. *软件学报*,2011,22(5):865–876. <http://www.jos.org.cn/1000-9825/3800.htm> [doi: 10.3724/SP.J.1001.2011.03800]
- [2] 莫同,李伟平,吴中海,褚伟杰.一种情境感知服务系统框架. *计算机学报*,2010,33(11):2084–2092.



陈益强(1973—),男,湖南湘潭人,博士,研究员,博士生导师,CCF 会员,主要研究领域为人机交互,普适计算.



胡琨(1987—),男,硕士,主要研究领域为人机交互,普适计算.



李秋实(1986—),男,硕士,主要研究领域为人机交互,普适计算.



陈振宇(1985—),男,博士生,助理研究员,CCF 学生会员,主要研究领域为人机交互,普适计算.



刘军发(1973—),男,博士,助理研究员,CCF 会员,主要研究领域为人机交互,普适计算.

www.jos.org.cn

www.jos.org.cn