

面向情境感知的不确定性数据融合策略

李向阳, 李玲娟, 陈建新, 徐小龙

(南京邮电大学 计算机学院, 江苏 南京 210003)

摘要:情境感知计算是对传感器感知的数据进行融合从而得到用户情境信息的过程。文中针对传感器数据存在的不确定性问题,在 Context Toolkit 模型的基础上提出了一种面向情境感知的数据融合策略,把数据融合分为底层融合和高层融合,在这两层上分别采用模糊逻辑和动态贝叶斯网络的数据融合方法。仿真实验结果表明,这种将模糊逻辑和动态贝叶斯网络相结合的策略能有效地处理情境感知过程中的不确定数据和信息,从而提高情境感知计算的容错性和准确度。

关键词:情境感知;数据融合;模糊逻辑;动态贝叶斯网络

中图分类号:TP274

文献标识码:A

文章编号:1673-629X(2012)02-0127-04

Strategy of Uncertainty Data Fusion for Context-Awareness

LI Xiang-yang, LI Ling-juan, CHEN Jian-xin, XU Xiao-long

(College of Computer, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: Context-aware computing is a process of fusing sensor data to perceive the user's context information. Considering the uncertainty property of sensor data, it proposes a context-aware data fusion strategy based on the Context Toolkit model, classifying the data fusion into two layers: the lower layer fusion and the high layer fusion. In these two layers, the fuzzy logic theory and DBN data fusion algorithm are used respectively. Simulation results show that this combined approach can not only effectively tackle with the uncertain data and information during the context awareness process, but also improve the fault-tolerance and accuracy of context awareness.

Key words: context-aware; data fusion; fuzzy logic; DBN

0 引言

情境感知计算的主要功能是把从传感器感知的原始数据转换成易懂的情境信息,而对传感器感知的数据进行融合是情境感知的重要手段。目前,面向情境感知的数据融合是一个研究热点。由于测量误差、网络传输错误等因素的存在,从无线传感器传来的数据往往是不确定的、模糊的^[1],传统的数据融合技术已经不能满足情境感知的需求,情境感知计算给数据融合带来了新的要求和挑战。

为此,文中对面向情境感知的不确定性数据融合策略进行了研究。基于情境感知模型 Context Toolkit^[2],通过改进,提出了一种新的数据融合策略,该策略在对不确定性数据的处理上,采用了模糊逻辑和动态贝叶斯网络相结合的方法。文中还设计了一个简单的情境感知应用实例来验证该策略的有效性。

1 情境感知的概念及模型

情境是表征和描述实体状态或情形的任何信息,实体可以是人、位置或是应用和用户之间交互的有关对象,包括用户和应用本身^[3,4]。用户位置、当前环境、用户的计划或是行程等都是情境信息。

情境感知是指计算系统能自动地感知和应用情境信息,并据此做出决策和提供响应或服务^[5]。

现有的情境感知建模研究中,有的采用分层的模型^[6,7],有的采用面向对象的模型^[8,9],还有的使用了工具箱模型。

文献[2]中的 Context Toolkit 是情境感知计算比较成功的一种模型。它采用了分层和模块化的设计,共包括以下几个部分:

传感器:主要负责感知物理的情境信息。

部件:传感器的代理,为情境感知应用提供一个统一的组件接口。

翻译:把数据转换成抽象的情境信息。

汇聚中心:对多源信息进行聚合。

Context Toolkit 模型最显著的特点是对情境信息进行预处理以消除其在具体格式上的差异,通过采用情境部件和情境翻译对情境信息进行抽象,可以有效

收稿日期:2011-07-12;修回日期:2011-10-17

基金项目:国家重点基础研究发展计划(973计划)课题(2011CB302903)

作者简介:李向阳(1985-),男,江苏徐州人,硕士研究生,主要研究方向为数据融合技术;李玲娟,教授,研究方向为数据挖掘、分布式计算、数据融合等。

地将情境信息的获取和情境信息的使用分离开来,从而简化情境感知系统的设计。

但是,Context Toolkit 模型由于缺少数据融合的支持,在应用中有以下方面的不足:不支持不确定数据,默认情境信息都是精确的;系统在运算过程中需处理许多冗余的数据,造成了资源的浪费。

2 不确定性数据融合策略

数据融合是情境感知计算中的重要环节^[10],为了解决原有 Context Toolkit 模型不支持不确定信息、存在冗余等问题,文中基于此模型提出了一种面向情境感知的数据融合策略,该策略包括模型和两级融合方法,能够更好地为情境感知计算服务,提高情境感知系统的容错能力和准确性。

2.1 数据融合模型

文中提出的数据融合模型如图 1 所示,它在 Context Toolkit 的原有模块和分层的基础上,加入了数据融合的支持,并将数据融合分为底层融合和高层融合,底层融合主要采用模糊逻辑的方法来消除传感数据的不确定性,在高层融合中采用动态贝叶斯网络的方法来进一步消除推理过程中的不确定性信息。在处理不确定性数据方面,模糊逻辑^[11]能够有效地把连续的数据分成离散变量的模糊集,而贝叶斯方法在这方面比较欠缺,但是贝叶斯网络^[12]的推理能力比较强。因此综合运用这两种方法不仅能保持各自的优点,还能够取长补短。

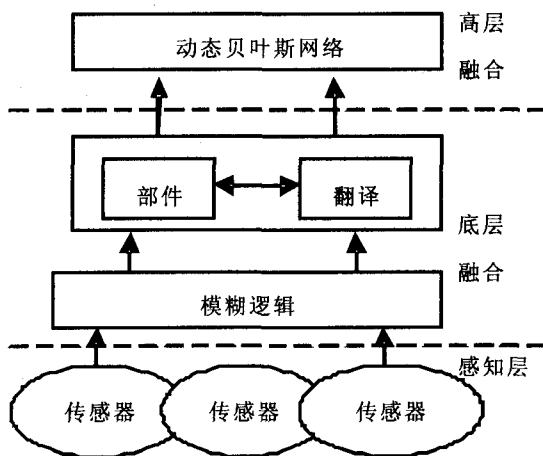


图 1 数据融合模型

2.2 底层融合方法

底层融合的主要功能是消除传感器采集数据的不确定性,考虑到传感器数据大部分都是一些具有连续观察值的数据,并且被监测对象的状态本身也具有较强的模糊性,如果只是由单一的传感器根据报警阈值进行简单的二元判决,以此来决定监测对象的状态往往是不准确的,因此采用模糊逻辑的方法对这些数据

进行模糊分类是比较合适的。

可以把监测对象分为 n 种状态,状态的集合可表示为: $U = \{u_1/\text{状态 } 1, u_2/\text{状态 } 2, \dots, u_n/\text{状态 } n\}$; 监测对象所用传感器的集合用 V 表示,即: $V = \{v_1/\text{传感器 } 1, v_2/\text{传感器 } 2, \dots, v_m/\text{传感器 } m\}$; 由传感器 v_i ($i = 1, 2, \dots, m$) 推断为集合 U 中的状态 u_j ($j = 1, 2, \dots, n$) 的可能性记为 r_{ij} , r_{ij} 即为 v_i 对 u_j 的隶属程度,这样可构造出模糊关系矩阵 $R = (r_{ij})_{m \times n}$; 在监测过程中,各传感器对设备状态的决策所做的贡献是不同的, a_i ($i = 1, 2, \dots, m$) 为传感器权重,模糊向量 $A = (a_1, a_2, \dots, a_m)$ 表示各种传感器判断的可信度; 经过模糊变换得到的 B 是监测对象所处状态的可能性,如式 (1) 所示。

$$B = (b_1, b_2, \dots, b_n) = A * R =$$

$$(a_1, a_2, \dots, a_m) \bullet \begin{bmatrix} r_{11} & r_{12} & r_{13} & \dots & r_{1n} \\ r_{21} & r_{22} & r_{23} & \dots & r_{2n} \\ r_{31} & r_{32} & r_{33} & \dots & r_{3n} \\ \dots & \dots & \dots & \dots & \dots \\ r_{m1} & r_{m2} & r_{m3} & \dots & r_{mn} \end{bmatrix} \quad (1)$$

B 中的各元素 b 的计算式如式 (2) 所示

$$b_j = (a_1 * r_{1j}) + (a_2 * r_{2j}) + (a_3 * r_{3j}) + \dots + (a_m * r_{mj}), j = (1, 2, \dots, n) \quad (2)$$

2.3 高层融合方法

高层融合的主要功能是解决推理过程中产生的模糊信息,从而得出更加准确的推断。经过底层融合的传感器数据虽然模糊性得到一定的消除,但是这些数据并不是精确的,在系统推理过程中仍然会产生一些模糊的信息,使用动态贝叶斯网络的方法能有效地解决这个问题。

一个贝叶斯网络是一个有向无环图,由代表变量的结点及连接这些结点的有向边构成,其中每个结点代表一个属性或者数据变量,结点间的弧代表属性间的概率依赖关系。

贝叶斯网络采用概率计算表达不确定性:

$$P(A|B)P(B) = P(AB) \quad (3)$$

式 (3) 表示事件 A 和 B 同时发生的概率是 B 发生的概率和在 B 条件下 A 的概率的乘积。同时也可以推导出式 (4) 的形式:

$$P(A|B) = P(B|A)P(A)/P(B) \quad (4)$$

动态贝叶斯网络是静态贝叶斯网络的拓展,观测到的样本数据随着时间的变化而变化。动态贝叶斯网络把观测到的数据按照时间片来划分,每一个时刻 T 都可以看成是一个静态的贝叶斯网络,而在计算 T 时刻的概率时,要考虑到它的相邻时刻 ($T-1$ 和 $T+1$) 的状态。

3 实验与分析

3.1 模型设计

文中设计了具体的面向情境感知的应用:乘客到站下车提醒。实际情景可以描述为:乘客身上穿戴加速度传感器,并且手持一个带有GPS功能的智能手机,加速度传感器通过蓝牙与智能手机进行通讯。可通过GPS定位乘客的位置,利用加速度传感器感知乘客的身体运动状况,如果乘客到达目的地忘记下车,系统发出下车提醒。

用加速度传感器判定乘客状态的方法是:首先对加速度传感器采集的数据进行模糊化处理,将其转换成能够代表乘客状态的一个模糊概念,例如可以把乘客的状态分为(NoMoving, SlightMoving, BigMoving),对乘客状态的模糊子集采用三角形隶属函数描述。

定义加速度传感器乘客状态的隶属度函数为:

$$r(\text{NoMoving}) = \begin{cases} 1 & \theta < x \leq a \\ b - x/b - a & a \leq x \leq b \\ 0 & b \leq x \end{cases} \quad (5)$$

$$r(\text{SlightMoving}) = \begin{cases} 0 & x \leq a \\ x - a/b - a & a \leq x \leq b \\ c - x/c - b & b \leq x \leq c \\ 0 & c \leq x \end{cases} \quad (6)$$

$$r(\text{BigMoving}) = \begin{cases} 0 & x \leq b \\ x - b/c - b & b \leq x \leq c \\ 1 & c \leq x \end{cases} \quad (7)$$

3.2 数据融合处理

首先采集实验的样本数据,实验者下车和静坐不动时,加速度传感器采集到的加速度记录情况分别如图2和图3所示。

通过分析采集的样本数据,可以将式(5)~(7)中的参数置为:θ=1.0,a=1.2,b=1.6,c=2.0。




图2 下车时加速度数据曲线

对图2的曲线进行采样,可以得到100个采样点数据,对这些数据进行模糊分类,可以得到模糊状态集合: B=(0.07,0.12,0.81)。对图3的曲线进行采样,同样可以获得100个采样数据,对数据进行模糊分类后,得到的模糊状态集合为: B=(0.61,0.36,0.03)。




图3 静止时加速度数据曲线

设事件A为:用户正在下车,可以得到数据

$$P(\text{Nomoving}/A) = 0.07 \quad P(\text{Nomoving}/\bar{A}) = 0.61$$
$$P(\text{Slightmoving}/A) = 0.12 \quad P(\text{Slightmoving}/\bar{A}) = 0.36$$

$$P(\text{Bigmoving}/A) = 0.81 \quad P(\text{Bigmoving}/\bar{A}) = 0.03$$

可以把2.3节中的B事件分解为: B₁(Nomoving), B₂(Slightmoving), B₃(Bigmoving)。

根据以下公式:

$$P(H_i|E) = \frac{P(E|H_i)P(H_i)}{\sum_j P(E|H_j)P(H_j)} \quad (8)$$

有:

$$P(A/B_1) = P(B_1/A)P(A)/P(B_1/A)P(A) + P(B_1/\bar{A})P(\bar{A})$$

$$P(A/B_2) = P(B_2/A)P(A)/P(B_2/A)P(A) + P(B_2/\bar{A})P(\bar{A})$$

$$P(A/B_3) = P(B_3/A)P(A)/P(B_3/A)P(A) + P(B_3/\bar{A})P(\bar{A})$$

分两次采集到的传感器数据分别如表1和表2所示,其中各T_i之间的时间间隔是200ms,表2的数据的采集时间滞后于表1。

表1 采集数据之一

采样时刻	传感器1	传感器2	传感器3
T1	1.5189	1.5455	1.5322
T2	1.3815	1.1919	1.0023
T3	1.2118	1.2234	1.2176
T4	1.1063	1.6001	1.3440
T5	2.4374	1.9923	3.0362
T6	1.4294	1.6084	1.5189
T7	1.4652	1.4146	1.4399
T8	1.2312	1.2251	1.2201
T9	1.0101	1.1121	1.0537
T10	1.7073	1.4375	1.5724

利用公式(5)至(7)对表1和表2的数据分别进行模糊分类处理,可以得到乘客在不同采样时刻的状态;根据全概率公式: P(A)=P(B₁)P(A/B₁)+P(B₂)P(A/B₂)+P(B₃)P(A/B₃),可以计算出下车概率;利用动态贝叶斯的原理,对上式计算出的P(A)进行修正,可以得到更加合乎事实的下车概率曲线。

表 2 采集数据之二

采样时刻	传感器 1	传感器 2	传感器 3
T1	2.4322	2.8814	2.0119
T2	1.8576	1.8787	1.8998
T3	1.2122	0.5303	0.7633
T4	2.8876	3.1472	2.9917
T5	1.2573	1.2584	1.9206
T6	2.7035	3.0537	2.5418
T7	1.6977	1.7556	1.8135
T8	2.1819	2.2427	2.2977
T9	2.8842	3.0685	2.9795
T10	1.8400	1.8636	1.8872

按以上步骤对表 1 和表 2 计算出来的乘客下车概率曲线分别如图 4 和图 5 所示。




图 4 概率曲线 1




图 5 概率曲线 2

通过概率曲线可以推出乘客的运动状态。在图 4 中,由于乘客在连续的采样时刻其运动概率都比较低,因此可以将此时的乘客状态认定为乘客没在下车;同理,根据图 5 的概率曲线,可以认定乘客的状态为正在下车。以此为进一步结合车子的实际运行情况决定是否提醒用户下车提供依据。

在对表 1 和表 2 数据的处理过程中,文中首先利用模糊逻辑的方法,对采集的数据进行过滤,消除部分不在处理范围内的数据(例如表 2 中 T3 时刻采集的数据),并把数据转化成模糊状态。然后利用动态贝叶斯的方法,对模糊化之后的数据进行进一步的处理。由于表 1 中的 T5 时刻采集的数据明显大于其他时刻的值,属错误数据,如果仅用静态贝叶斯方法计算,会做出错误的判断。文中采用动态贝叶斯的方法,在确定 T5 时刻的运动状态时,参考了 T4 和 T6 时刻的运动状况,最后得出合理的运动概率,屏蔽了 T5 时刻错误

数据的干扰。因此可以得出结论,采用模糊逻辑的方法可以有效地消除传感器数据的不确定性,降低传感器的误报率;采用动态贝叶斯的方法,能够屏蔽一些错误数据的干扰,从而提高系统的容错度和准确性。

4 结束语

文中提出了一种面向情境感知的不确定性数据融合策略,通过采用模糊逻辑的方法有效地解决了底层感知数据的不确定性;在上层推理中,采用动态贝叶斯网络方法,进一步消除了推理过程中的不确定性信息,从而提高了情境感知应用的容错性和准确度。

需要指出的是,值得在减小动态贝叶斯的先验概率偏差方面做进一步研究。

参考文献:

- [1] Christos A, Odysseas S. Context Fusion: Dealing with Sensor Reliability [C]//IEEE International Conference on Mobile Adhoc and Sensor Systems. [s. l.]: [s. n.], 2008: 1-6.
- [2] Dey A K, Abowd G D, Salber D. A Conceptual Framework and a Toolkit for Supporting the Rapid Prototyping of Context-aware Application [J]. Human-Computer Interaction, 2001, 16 (2): 97-106.
- [3] Terry W. Architecture for Context [J]. Human-Computer Interaction, 2001, 16 (2): 401-419.
- [4] Wu Huadong. Sensor Data Fusion for Context Aware Computing Using Dempster-Shafer Theory [D]. Pittsburgh: The Robotics Institute Carnegie Mellon University, 2003.
- [5] Moeiz M, Chakib T, Chokriben A. Architecture Survey of Context-Aware Systems in Pervasive Computing Environment [J]. Ubiquitous Computing and Communication Journal, 2008, 3 (3): 1-9.
- [6] Nirmalya R, Gautham P, Sajal K D. A Middleware Framework for Ambiguous Context Mediation in Smart Healthcare Application [C]//Third IEEE International Conference on WiMob. [s. l.]: [s. n.], 2007: 72-75.
- [7] 吉海星, 白跃彬, 戴光利, 等. 支持上下文感知服务的中间件原型 [J]. 计算机应用研究, 2007, 24 (11): 243-247.
- [8] 赵琳. 面向 SAAS 的上下文感知数据过滤模型与匹配算法研究 [D]. 杭州: 浙江大学, 2010.
- [9] Dey A K, Abowd G D. A Software Engineering Framework for Context Aware Pervasive Computing [C]//Proceedings of the Second IEEE Annual Conference on Pervasive Computing and Communications. [s. l.]: [s. n.], 2004: 77-86.
- [10] Wu Huadong, Siegel M, Ablay S. Sensor Fusion for Context Understanding [C]//IEEE Instrumentation and Measurement Technology Conference. Anchorage: [s. n.], 2002: 21-23.
- [11] 李昕, 佟绍成, 张军. 基于模糊逻辑的多传感器数据融合方法研究 [J]. 微计算机信息, 2009, 25 (5-1): 129-131.
- [12] 张波. 基于模糊动态贝叶斯网络的辐射源威胁估计 [J]. 计算机工程与应用, 2010, 46 (12): 242-244.