

基于不确定性推理的活动识别方法研究

戴丹,管有庆,龚锐

(南京邮电大学物联网学院,江苏南京 210003)

摘要:活动识别已成为智能家居领域的研究热点,目前国内外有关活动识别方法的研究有很多,研究人员提出了不同的方法来进行活动建模和识别,可分为数据驱动方法和知识驱动方法。数据驱动方法容易受到维数的限制,并且需要大量的数据集来训练出活动模型。目前在有关活动识别研究的方法中缺少一种既能够考虑到异构数据之间的知识共享,又能够考虑到活动的不确定性的方法。该文将D-S理论(Dempster-Shafer theory,证据理论)和本体推理结合起来,在改进的证据合成规则的基础上提出了ER-OT(evidential reasoning-ontology,证据-本体推理)算法,解决了活动中的不确定性和推理结果之间的冲突。算法首先在加权分配的思想按重新定义的冲突系数对证据合成规则进行改进,在推理时推理机将推理信息同时输入到Jena本体推理和改进的证据推理模块,然后将推理结果按改进的证据合成规则进行合成得到最终的推理结果。实验结果表明,与现有的马尔可夫逻辑网络算法和传统的本体推理算法相比,该算法提高了不确定性活动的识别准确率。

关键词:活动识别;本体推理;D-S理论;智能家居;不确定性

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2022)01-0007-06

doi:10.3969/j.issn.1673-629X.2022.01.002

Activity Recognition Method Based on Uncertainty Reasoning

DAI Dan, GUAN You-qing, GONG Rui

(School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: Activity recognition has gradually become a research hotspot in the field of smart home. There are currently many researches on activity recognition methods at home and abroad. Researchers have proposed different methods for activity modeling and recognition, which can be divided into data-driven methods and knowledge-driven methods. Data-driven approaches are prone to dimensionality limitations and require large data sets to train active models. There is a lack of method that takes into consideration not only knowledge sharing between heterogeneous data but also uncertainty of activities in the research of activity recognition. In this paper, evidence theory and ontology reasoning are combined. Based on the improved rules of evidence synthesis, an algorithm of evidence ontology reasoning (ER-OT) is proposed to solve the conflict between uncertainty and reasoning results in activities. Firstly, in the idea of weighted distribution, the rules of evidence synthesis are improved according to the redefined conflict coefficient. In reasoning, the inference engine inputs the reasoning information into Jena ontology reasoning and improved evidence reasoning module at the same time, and then the reasoning results are synthesized according to the improved rules of evidence synthesis to get the final reasoning results. Experimental results show that compared with the existing Markov logic network algorithm and the traditional ontology reasoning algorithm, the proposed algorithm improves the recognition accuracy of uncertain activities.

Key words: activity recognition; ontology reasoning; D-S theory; smart home; uncertainty

0 引言

活动识别^[1]主要是实现对用户的活动感知,其实质是利用计算机对数据库中的低层次数据进行识别、理解和预测,推动从低层次数据到高层次语义活动的理解。一般低层次数据是指采集到的日志数据信息,如传感器的日志数据、服务器操作记录日志数据等

等^[2],这些数据仅仅反映了用户单纯的某个动作,例如打开厨房门、打开水龙头等简单的动作。从低层次数据中得到的信息会非常零碎,外部控制设备很难根据这些信息做出具体的智能控制,即活动识别基于这些低层次的数据特征识别出高层次的活动信息,完成从数据到用户活动的转变,使得控制器更加智能化和自

收稿日期:2021-01-29

修回日期:2021-05-31

基金项目:江苏省高校自然科学基金计划项目(05KJD520146)

作者简介:戴丹(1993-),女,硕士研究生,研究方向为信息技术及其在物流工程中的应用;管有庆,副研究员,硕士,硕导,研究方向为深度学习、通信网络等;通信作者:龚锐(1995-),男,硕士研究生,研究方向为点云深度学习。

动化。

因为用户活动的复杂性和多样性,如何使用计算机正确进行活动识别一直是智能家居领域的一个难点,总的来说可以分为这几个研究方向^[3]:活动的并发性、活动的不确定性以及数据的不确定性。活动的并发性是指用户可以同时进行几项活动,活动交错进行且没有时序性,例如用户可以在边打扫卫生的同时边收看电视节目或者用户在观看电视途中收到电话通知会暂停收看电视节目去接电话,接完电话再继续观看电视。这种情况下打扫和看电视是同时进行的,打电话和看电视是交错进行的活动,但是有些活动识别的方法并不能有效地识别出不按顺序执行的活动和没有时序性的活动,这些方法在解决活动的并发性上就产生了很大的局限性。活动的不确定性是指具有相同动作和传感器数据流程的活动有可能不同,即收集到的传感器数据有可能是一样的,但是却对应着多个不同的活动,例如用户打开厨房的水龙头开关有可能是在进行打扫的活动也有可能是在做饭,做饭和打扫都触发了同样的传感器。数据的不确定性是指因环境因素带来的传感器数据缺失等。这些数据是片面的具有不确定性的,因此在进行用户的活动识别时往往带来了一定程度上的困难。

总结国内外大量的活动识别研究方法,可分为数据驱动和知识驱动方法^[4]。数据驱动是基于学习的技术,基于学习的技术的优势是处理不确定性的能力,能够获得高准确率的活动识别。但是数据驱动易受到维数的限制,并且需要大量的初始训练数据集来训练活动模型。知识驱动方法利用先验知识建立语义活动模型,然后输入传感器数据对其进行推理,促进了语义活动模型和识别过程的发展。但是仍然有一些局限性,它对于时态信息建模的支持很少,且不能处理不确定性。Lester 等人^[5]应用数据驱动中的 HMM (hidden Markov model,隐马尔可夫模型)来构建用户的活动,提出了一种判定启发式方法来进行用户活动识别。Chen L 等人^[6]提出了一种构建本体模型的知识驱动的方法,解决了异构数据间的知识共享问题,但没有解决活动的不确定性问题。

该文在采用本体推理的基础上,融合改进的证据推理提出了一种 ER-OT 算法。本体推理主要是通过 Jena 推理机,证据推理主要是通过 D-S 理论 (Dempster-Shafer theory,证据理论)赋予缺失的传感器数据权重,然后与其他证据相结合。此外,通过重新定义的冲突系数来改进证据合成规则,改进的证据合成规则可以通过组合证据来解决冲突数据,最后应用于融合最终的推理结果,从而促进了活动识别过程。该推理算法既保持了本体推理的优势,又使其具有了

处理活动识别过程中不确定性的能力。

1 Dempster-Shafer 理论

D-S 理论被称为信念函数理论^[7],是由登普斯特 (Dempster)发展起来的一种不确定性理论,并由沙弗 (Shafer)进一步扩展。D-S 理论是贝叶斯理论的推广,在概率论中,命题 A 与它的补集 \bar{A} 构成一个完备集,即 $m(A) + m(\bar{A}) = 1$ 。但在实际问题中,人们对 A 的信任程度并不能反映出对 \bar{A} 的信任程度,即 $m(A) + m(\bar{A}) \leq 1$ 。D-S 理论能更好地模拟人类的不确定性处理和推理过程,所以该方法在传感器融合方面具有优势^[8],它基于以下概念和原则:

(1) 识别框架 (Θ)。

若存在一个需要判决的问题,该问题所有可能答案的有限集用 Θ 来表示, Θ 可以是数值变量,也可以是非数值变量,而且在这些答案中有且只有一个是正确的,则称 Θ 为识别框架,用数学语言表示为 $\Theta = \{\theta_1, \theta_2, \dots, \theta_i, \dots, \theta_n\}$,其中 θ_i 是 Θ 的一个事件或者一个元素, n 是 Θ 中元素的个数, $i = 1, 2, \dots, n$, Θ 的空间大小为 2^Θ 。

(2) BPA (basic probability assignment,基本概率分配函数)。

设 Θ 是识别框架, A 为识别框架 Θ 的任一子集,集函数 $m: 2^\Theta \rightarrow [0, 1]$,并且满足条件:

$$\begin{cases} m(\emptyset) = 0 \\ \sum_{A \subseteq \Theta} m(A) = 1 \end{cases} \quad (1)$$

式中, \emptyset 是空集, $m(A)$ 是对于事件 A 的基本信任分配值,表示 Θ 中的证据对 A 的信任程度。 A 为 Θ 下的子集,如果满足 $m(A) > 0$,那么就称 A 为焦元。焦元中包含 Θ 的元素的个数称为这个焦元的基。所有焦元的集合被称为该证据的核。

(3) 信任函数。

D-S 理论中的信任函数定义为 Bel,它表示在当前环境下,对某假设集合所信任的程度。在识别框架 Θ 上基于 BPA 的信任函数的定义为:

$$\text{Bel}(A) = \sum_{B \subseteq A} m(B) \quad (2)$$

式中, $\text{Bel}(A)$ 称为事件 A 的信任值,表示事件 A 中所有子集 B 的基本信任分配之和,即对 A 的最低信任程度。根据定义可以得出空集的信任值为 0。

(4) 似然函数。

似然函数的定义为 Pl,又被称为不可驳斥函数或上限函数,一般通过似然函数来描述对集合为非假的信任程度,即为对事件 A 的怀疑程度。在识别框架 Θ

上基于 BPA 的似然函数的定义为:

$$Pl(A) = 1 - Bel(\bar{A}) = \sum_{B \cap A \neq \emptyset} m(B) \quad (3)$$

或:

$$Pl(A) \geq 1 - Bel(\bar{A}) \quad (4)$$

其中,在 Θ 中的事件 A ,根据基本概率分配 BPA 可以计算出其信任函数 $Bel(A)$ 和似然函数 $Pl(A)$,其中 $Bel(A)$ 表示对事件 A 为真的信任程度, $Pl(A)$ 表示对事件 A 为非假的信任程度,且 $Pl(A) \geq Bel(A)$,所以其信任区间可表示为 $[Bel(A), Pl(A)]$ 。

D-S 合成规则是证据推理完成信息融合过程的核心,它可以表示出证据间的联合作用。如果给定了同一识别框架下几组不同证据的基本概率分配函数即质量函数,且这几组证据不是完全互相冲突的,那么就可以利用 D-S 合成规则计算出这几组证据联合作用下的联合质量函数。D-S 理论的合成主要包括两组证据的合成和多组证据的合成,两组证据的 D-S 理论合成规则定义如下^[9]:

设 m_i 表示识别框架 Θ 下第 i 组证据的基本概率分配函数, $i = 1, 2, \dots, n$ 为证据组数。对于第一组、第二组两组证据进行合成:

$$m(C) = m_1 \oplus m_2 = \frac{\sum_{A \cap B = C} m_1(A)m_2(B)}{1 - K} \quad (5)$$

其中:

$$K = \sum_{A \cap B = \emptyset} m_1(A)m_2(B) = 1 - \sum_{A \cap B \neq \emptyset} m_1(A)m_2(B) \quad (6)$$

其中, A 、 B 分别为 m_1 、 m_2 的焦元,表示第一组证据的基本概率分配函数; K 表示证据之间的冲突系数,反映了证据间的冲突程度。 K 越大代表证据之间的冲突越大。若 $K = 1$ 则表示证据之间完全冲突, $K = 0$ 则表示证据完全不冲突。

多组证据的 D-S 理论合成规则如下:

$$m(Z) = m_1 \oplus m_2 \oplus \dots \oplus m_n = \frac{\sum_{A \cap B \cap \dots \cap N = Z} m_1(A)m_2(B) \dots m_n(N)}{1 - K} \quad (7)$$

其中:

$$K = \sum_{A \cap B \cap \dots \cap N = \emptyset} m_1(A)m_2(B) \dots m_n(N) \quad (8)$$

其中, A 、 B 和 N 分别为 m_1 、 m_2 和 m_n 的焦元, $m_i (i = 1, 2, \dots, n)$ 表示识别框架 Θ 下第 i 组证据的基本概率分配函数, K 表示证据之间的冲突系数。

例 1:假设 2 个传感器对同一个活动进行识别,认为活动可能是睡觉 (A),打扫 (B) 和洗澡 (C) 中的一种,则识别框架 $\Theta = \{A, B, C\}$,两组证据的基本概率函数如下:

$$M_1: m_1(A) = 0.9, m_1(B) = 0.1, m_1(C) = 0$$

$$M_2: m_2(A) = 0, m_2(B) = 0.1, m_2(C) = 0.9$$

则按照 D-S 理论合成规则可得 $K = 0.99$, $m(A) = 0$, $m(B) = 1$, $m(C) = 0$,从证据合成后的结果可以得到,两组证据对 B 的可信度很低,但是合成后却得到了 B 是确定事件,产生了不合理的结果,所以证据在完全冲突或严重冲突时,传统的 D-S 理论合成规则可能会得到错误的合成结果,因此下面提出了一种 D-S 理论的改进方法。

2 基于证据和本体推理的不确定推理方法

2.1 证据理论的改进

因为 D-S 理论用于信息融合时,可能会出现不合常理甚至错误的结论,即当 D-S 理论所需要的各组证据合理时,利用 D-S 理论的合成规则能够得到理想的合成结果,而当证据间冲突过大即冲突系数 K 过大时,会得到有悖常理的合成结果^[10]。所以国内外学者提出了很多改进办法,如墨菲 (Murphy) 提出了一种修改证据模型但是并不改变 D-S 理论合成规则的经典算法^[11],其主要思想是将算术平均证据作为新证据,并利用 D-S 理论合成规则进行合成。

基于上述改进方法,可应用加权分配^[12]的思想将智能家居中的传感器收集的多组证据赋予不同的权重,一组被其他证据高度支持的证据应赋予较高的权重,而一组与其他证据冲突较高的证据应赋予较低的权重,计算公式如下:

$$m(Z) = \sum m_i(A)\omega_1 + m_2(B)\omega_2 + \dots + m_n(N)\omega_n \quad (9)$$

其中, $\omega_1, \omega_2, \dots, \omega_n$ 表示 m_1, m_2, \dots, m_n 对应的加权系数。

例 2:假设识别框架 $\Theta = \{A, B, C\}$,两组证据的基本概率函数如下:

$$M_1: m_1(A) = 0.99, m_1(B) = 0, m_1(C) = 0.01$$

$$M_2: m_2(A) = 0.01, m_2(B) = 0, m_2(C) = 0.99$$

由加权分配的思想将 ω_1 设为 0.5, ω_2 设为 0, ω_3 设为 0.5,按加权合成规则可得 $m(A) = 1$, $m(B) = 0$, $m(C) = 1$, $K = 0.9901$ 。可以看出在证据严重冲突的情况下基于以上的合成规则的改进方法,冲突系数依旧不能清楚表述证据之间冲突的程度,所以提出在加权分配的基础上引入明氏距离^[13]函数来解决这一问题,对冲突系数重新进行了定义,冲突系数的定义公式如式(12)所示。

假设识别框架 $\Theta = \{Z_1, Z_2, \dots, Z_M\}$, Z 为识别框架的焦元, a 和 b 分别为基于焦元 Z 的各组证据的基本概率分配函数,证据体 m_i 、 m_j 的定义如式(10)

所示:

$$m_i(Z) = \begin{cases} a_1 & Z = Z_1 \\ a_2 & Z = Z_2 \\ \dots & \\ a_M & Z = Z_M \end{cases} \quad m_j(Z) = \begin{cases} b_1 & Z = Z_1 \\ b_2 & Z = Z_2 \\ \dots & \\ b_M & Z = Z_M \end{cases} \quad (10)$$

根据明氏距离函数得到 m_i 、 m_j 之间的距离 $d(m_i, m_j)$ 的定义, 如式(11)所示。

$$d(m_i, m_j) = \left(\sum_{m=1}^M |a_m - b_m|^n \right)^{1/n} \quad (11)$$

式中, a_m 和 b_m 分别为基于焦元 Z_m 的各组证据的基本概率分配函数, 当 $n=1$ 时为曼哈顿距离, 当 $n=2$ 为欧氏距离^[14], 当 $n \rightarrow \infty$ 时为切比雪夫距离^[15]。

基于明氏距离函数重新定义的冲突系数 K_{res} 为:

$$K_{res} = \begin{cases} \frac{d(m_i, m_j)}{2}, & K = 0 \\ 0, & d(m_i, m_j) = 0 \\ \frac{2K \cdot d(m_i, m_j)}{K + d(m_i, m_j)}, & K \neq 0 \text{ 且 } d(m_i, m_j) \neq 0 \end{cases} \quad (12)$$

结合加权分配法的证据推理算法处理有矛盾冲突的证据, 步骤如下:

Step1: 读入两组证据 m_i 和 m_j ;

Step2: 按重新定义的冲突系数计算冲突系数 K_{res} , 判断 K_{res} 是否大于设定的阈值, 如果大于阈值则是冲突证据, 跳到 Step4; 否则跳到 Step3;

Step3: 按 D-S 理论合成规则对证据进行合成, 跳到 Step5;

Step4: 使用加权分配法处理冲突证据;

Step5: 如果证据合成未结束, 跳到 Step2 继续合成, 否则结束。

2.2 ER-OT 算法

ER-OT 算法的流程如图 1 所示。

在 ER-OT 算法的本地推理中, 主要是应用 Jena 推理机^[16]进行本地推理。首先对传感器数据信息进行分类, 列出各种可能推测的结果, 再将这些信息与推测结果根据某种算法映射起来, 并计算出每个独立结果的可能性。要对用户正在进行的活动进行推测, 首先要对从传感器收集到的传感器信息按照其可能对应的推理结果进行分类。比如, 用户活动的推理结果“睡觉”, 那么就要将对应的可能能够作为判断依据的传感器数据信息归为一类, 其可能是加速度传感器、光敏传感器或者心率传感器等。归类之后, 就会按照某一原始的推理算法推算出用户在睡觉的可能性。

证据推理就是融合动作上下文来计算活动的信任度, 由低级的动作上下文来推断出高级的活动信息。

可以将 D-S 理论中的证据理解为知识库中的低级本体, 而活动识别中的高级本体能对应的就是 D-S 理论中的识别框架集合。然后, D-S 理论会根据每个不同的证据, 以及每个证据单独的支持的 Bel 函数根据信任度函数和合成规则将本体推理和证据推理的结果进行合成, 最后得出每个支持的证据的信任度。只需要选取其中信任度最高的前一项或者两项, 就是所要得到的推理结果。

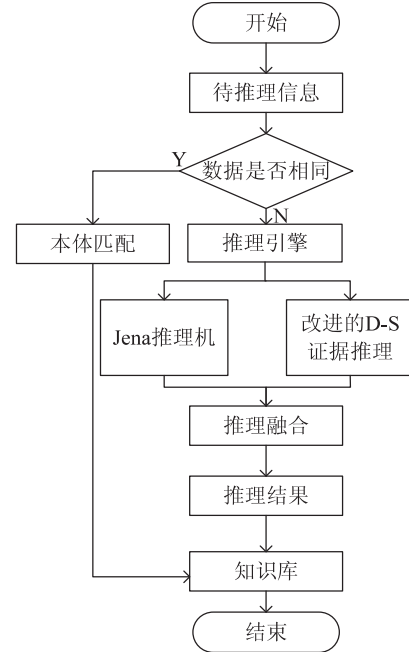


图 1 ER-OT 算法流程

ER-OT 算法基本思想概述为:

Step1: 一旦触发推理模块, 判断输入的信息。

Step2: 如果输入的数据无法和知识库中的数据进行本体匹配, 将推理信息输入到 Jena 本体推理机和改进的证据推理算法中, 两者会分别得出相应的推理结果, 跳到 Step3; 如果输入的数据可以和知识库中的数据进行本体匹配, 则将匹配的数据存入到知识库中并更新本体数据, 跳到 Step4。

Step3: 将推理结论用改进的 D-S 理论合成规则进行结论的合成后输出最终推理结果, 同时也将推理结果存入知识库中以方便以后提取。

Step4: 将匹配到的数据以及推理出的结果存入知识库中, 从而得出最终的推理结果。

3 模拟实验结果与分析

实验重点在于验证 ER-OT 算法在解决活动识别中的不确定性问题的实用性, 并与现有的算法 (如 MLN, 本体 (ontology) 等) 在 CASAS (center for advanced studies in adaptive systems, 自适应系统高级研究中心) 数据集下进行比较。通过下面实验可知, 基于 ER-OT 算法的活动识别方法能很好地解决活动中的不确定

性,并且优于其他的推理方法。

3.1 实验环境及数据集介绍

实验环境是基于 eclipse, Jena, Matlab 2016b 和 Protégé 5.0 的。日常活动数据集收集于华盛顿州立大学的 CASAS 项目^[17],活动数据集(ADL)记录了传感器的开关时间和位置等。智慧空间分为四个区域:休息室、卫生间、厨房和餐厅。

智能家居场景下的传感器包括检测人体压力的 PIR(pyroelectric infrared sensor for human body,人体热释电红外传感器)传感器和“物品传感器”,每个区域内的 PIR 传感器用于检测用户是否存在,“物品传感器”用于指示给定对象的状态,例如“门传感器”用于表示门的打开或关闭。采用 ADL 和 ADL-D 两组数据集进行验证,其中 ADL 为用户顺序执行活动的数据集,ADL-D 为用户不遵循特定顺序执行活动的数据集。

收集了 20 个测试人员的 5 种日常活动:(1)打扫(180 s);(2)吃饭(120 s);(3)休闲活动(240 s);(4)洗漱(60 s);(5)睡觉(720 s),包括 6 438 条数据。表 1 给出了 5 种用户顺序执行的活动及其描述。

表 1 5 种用户顺序执行的活动

编号	活动	描述
Activity1	吃饭	用户到饭厅吃东西
Activity2	休闲	用户看电视
Activity3	打扫	用户去厨房打扫
Activity4	洗漱	用户去浴室洗漱
Activity5	睡觉	用户回卧室睡觉

实验中阈值代表某一项活动中证据的强度,范围为 $[0,1]$,其中 0 表示没有证据,1 表示确定性,在这里设置为 0.5,表示要求至少有一半的证据来断定用户在进行某个活动。用改进的证据推理和本体推理的算法推理出结果后,按照本体推理权重系数 0.3,D-S 理论权重系数 0.7 再对推理结果用 D-S 理论合成公式进行合成^[18]。

3.2 实验结果与分析

使用 F1 作为评价标准,F1 的计算方法如公式(13)所示。

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (13)$$

其中,准确率 $\text{Precision} = \text{TP}/(\text{TP} + \text{FP})$ 、召回率 $\text{Recall} = \text{TP}/(\text{TP} + \text{FN})$,TP 表示正确识别的活动数目,FP 表示错误识别的活动数目,FN 表示没有识别出的活动数目。按顺序执行的活动得出的最终推理结果的准确率如表 2 所示,参与者在执行活动时不遵循特定顺序最终推理结果的准确率如表 3 所示。

表 2 利用 ADL 数据集进行活动识别的准确率

编号	ER-OT	Ontology	MLN
Activity1	0.95	0.95	0.90
Activity2	0.85	0.70	0.85
Activity3	0.80	0.30	0.85
Activity4	1.00	0.95	1.00
Activity5	0.95	0.85	0.90
平均准确率	0.91	0.75	0.90

表 3 利用 ADL-D 数据集进行活动识别的准确率

编号	ER-OT	Ontology	MLN
Activity3	0.85	0.55	0.85
Activity5	0.95	0.75	0.90
Activity1	0.90	0.75	0.90
Activity4	1.00	0.65	0.95
Activity2	0.90	0.65	0.90
平均准确率	0.92	0.67	0.90

将 ER-OT 算法与 Ontology 算法以及 MLN 算法进行对比实验。其中 Ontology 算法使用 Protégé 5.0 构建活动本体,并用 Jena 推理机进行推理,完成实验。MLN 算法则使用工具 Tuffy^[19]来实现。

如表 2 和表 3 所示,因为传感器数据在传输中的丢失导致的不确定性,Ontology 算法在两个数据集除打扫外的所有活动中均表现良好。ER-OT 算法融合了改进证据推理的推理结果,提高了准确率。表 2 中可以看出 ER-OT 算法量化了传感器数据中的不确定性,提高了在不遵循特定顺序执行活动的活动识别准确率,并且优于其他两个算法。总体而言,在实验所考虑的大多数活动中,ER-OT 算法的活动识别准确率均优于 Ontology 算法和 MLN 算法。

由图 2 可知,ER-OT 算法在识别 Activity1、Activity4 以及 Activity5 时优于其他算法,但在识别 Activity2 和 Activity3 时,ER-OT 算法和 MLN 算法由于其规则采用人工定义,且用户活动打扫和休闲活动执行方式具有多样性的特点,因此同 Ontology 算法一样,F1 值较低,但也优于其他算法。




图 2 ADL 数据集下活动识别的 F1 值




图3 ADL-D数据集下活动识别的F1值

在ADL-D数据集下,各方法的F1值如图3所示。各方法的F1值均有下降,但ER-OT算法在识别活动Activity1、Activity2、Activity3、Activity4以及Activity5时仍保持最高的F1值。

如图4所示,在实验所考虑的大多数活动中包括顺序执行活动的数据集ADL和不遵循特定顺序执行活动的数据集ADL-D中,ER-OT算法的平均准确率均优于Ontology算法和MLN算法。




图4 ADL和ADL-D数据集各方法的平均准确率

4 结束语

该文提出了一种混合式推理算法(ER-OT),将改进的证据推理与基于Jena推理机的本体推理相结合,应用于智能家居场景下的活动识别中,解决了活动的不确定性与推理结果间的冲突。实验表明,设计的不确定性推理方法具有较高的推理准确性。在未来的工作中,希望能够通过大数据、云计算等技术进一步提高推理的准确性。

参考文献:

- [1] PREECE S J, GOULERMAS J Y, KENNEY L P J, et al. Activity identification using body-mounted sensors - a review of classification techniques [J]. *Physiological Measurement*, 2009, 30(4): R1-33.
- [2] 吴浩坚. 基于马尔科夫逻辑网络的活动识别系统研究与实现[D]. 广州: 中山大学, 2015.
- [3] CHAHUARA P, PORTET F, VACHER M. Context-aware decision making under uncertainty for voice-based control of

- smart home [J]. *Expert Systems with Applications*, 2017, 75(11): 63-79.
- [4] 苏雷. 智能家居中基于概率软逻辑的人类活动识别方法[D]. 大连: 大连海事大学, 2018.
- [5] LESTER J, CHOUDHURY T. A hybrid discriminative/generative approach for modeling human activities [C]// *Proceedings of the nineteenth international joint conference on artificial intelligence*. Edinburgh, Scotland, UK: Morgan Kaufmann Publishers Inc, 2005.
- [6] CHEN L, NUGENT C D, WANG H. A knowledge-driven approach to activity recognition in smart homes [J]. *IEEE Transactions on Knowledge & Data Engineering*, 2012, 24(6): 961-974.
- [7] SENTZ K. Combination of evidence in Dempster-Shafer theory [R]. [s. l.]: Sandia National Laboratories, 2002.
- [8] 杨延宇. 多传感器数据融合在温室监控系统中应用的研究[D]. 沈阳: 东北大学, 2015.
- [9] YAGER R R. On the Dempster-Shafer framework and new combination rules [J]. *Information Sciences*, 1987, 41(2): 93-137.
- [10] 杨永旭. 基于D-S证据和模糊集理论的多源信息融合算法研究[D]. 兰州: 兰州理工大学, 2011.
- [11] MURPHY C A, LANGRISH C L, CHEN Y, et al. Divergent pro- and antiinflammatory roles for IL-23 and IL-12 in joint autoimmune inflammation [J]. *Journal of Experimental Medicine*, 2003, 198(12): 1951-1957.
- [12] 吕悦晶, 宋向勃, 张蕾, 等. 一种加权改进的D-S证据推理算法[J]. *计算机应用与软件*, 2011, 28(10): 30-33.
- [13] XIAN Sidong, SUN Weijie, XU Sihan, et al. Fuzzy linguistic induced OWA Minkowski distance operator and its application in group decision making [J]. *Pattern Analysis & Applications*, 2016, 19(2): 325-335.
- [14] 刘瑞元. 加权欧氏距离及其应用[J]. *数理统计与管理*, 2002, 21(5): 17-19.
- [15] KLVE T, LIN T T, TSAI S C, et al. Permutation arrays under the Chebyshev distance [J]. *IEEE Transactions on Information Theory*, 2010, 56(6): 2611-2617.
- [16] 谭月辉, 肖冰, 陈建泗, 等. Jena推理机制及应用研究[J]. *河北省科学院学报*, 2009, 26(4): 14-17.
- [17] MANZANO-FISCHER P, LIST R, CEBALLOS G, et al. Avian diversity in a priority area for conservation in North America: the Janos-Casas Grandes Prairie Dog Complex and adjacent habitats in northwestern Mexico [J]. *Biodiversity & Conservation*, 2006, 15(12): 3801-3825.
- [18] 张阔. 情境感知技术中不确定推理的研究与应用[D]. 北京: 北京工业大学, 2017.
- [19] TAI Y W, TAN P, BROWN M S. Richardson-lucy deblurring for scenes under a projective motion path [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(8): 1603-1618.