

面向传感网可信检测的协同感知策略^①

肖克江^{②***} 王睿^{*} 崔莉^{③*}

(^{*}中国科学院计算技术研究所 北京 100190)

(^{**}中国科学院大学 北京 100190)

摘要 为了提高基于传感器网络的目标检测的检测精度和尽可能延长网络的寿命,将满足用户对检测精度要求的检测定义为可信检测,并提出了一种面向可信检测的协同感知策略。该策略首先对传感器的相关性及感知能力差异性进行定量分析,发现它们与传感器簇的感知性能的关联性,为实现传感器的协同选择提供依据;然后用一种分布式传感器协同选择方法进行传感器协同选择:根据传感器相关性、感知能力差异性及剩余能量来计算节点的重要性,之后按节点重要性选择合适的传感器。试验表明,与传统方法相比,该策略既能更好地满足用户对检测精度的要求,又能在实现能量均衡、延长网络寿命上取得更好的效果。

关键词 无线传感器网络, 能量均衡, 可信检测, 协同感知, 传感器相关性

0 引言

很多基于传感网的应用如感知覆盖^[1]、目标检测与识别^[2]、目标跟踪^[3]等,对目标感知精度都有较高的要求,同时要求网络生命周期最大化。这种满足用户对感知精度的要求的检测是可信检测,类似于文献[4]中定义的可信感知。比如,在智能交通的应用^[5]中,对车辆的检测精度和网络能耗都有较高的要求。因此,满足用户对检测精度的要求的同时保证传感器节点之间的能量均衡就变得很有必要。

为了实现可信检测和能量均衡,需要选择合适的传感器(节点)协同工作。而为了进行传感器选择,我们需要量化和识别传感器簇的感知能力。通常情况下,传感器簇的感知能力与传感器之间的相关性及单个传感器的感知能力差异性有关。传感器

相关性指的是原始数据相关性或者分类器决策的相关性^[6]。传感器相关性包括处于不同位置的同种传感器之间的相关性及不同种传感器之间的相关性。传感器相关性是由时空相关性及传感器本身硬件自身特性导致的。感知能力的差异性指的是在真实部署的网络环境中同质或者异质传感器之间的感知能力存在差异性,这主要是由传感器自身特性及部署的特定网络环境引起的^[7]。现有的研究很多都假设所有传感器具有相同的感知能力或者忽略了传感器之间相关性对传感器簇感知能力的影响^[2, 8]。还有一些研究^[9]试图纠正用来自不同传感器感知数据的差异性来克服传感器感知能力的差异性,或者通过传感器感知能力的差异性提供可信感知^[10],但是没有考虑传感器(节点)之间的能量均衡。与此相反,本文充分利用传感器相关性、单个传感器感知能力的差异性及节点剩余能量选择合适的传感器簇以实现可信检测,既满足用户对检测精度

① 国家自然科学基金(61379134)资助项目。

② 男,1984 年生,博士生;研究方向:无线传感器网络信息融合,协同感知;E-mail: xiaokejiang@ict.ac.cn

③ 通讯作者,E-mail: lcui@ict.ac.cn

(收稿日期:2015-03-14)

的需求,同时保证网络能量的均衡。但是,为了选择合适的传感器进行可信检测会面临两大挑战:一是如何在真实部署的网络中识别单个传感器和传感器簇的感知能力。为了满足用户对检测精度的需求和提供可信检测,我们必须能够量化和区分单个传感器和传感器簇的感知能力,使得传感器簇内的传感器有效地协同工作,然而单个传感器感知能力的差异性及相关性给这一过程带来了困难;二是如何设计分布式的传感器选择方法以满足用户对检测精度的需求,同时能够保持传感器之间的能量均衡。通常单个传感器的能力有限,而传感器通过分簇而聚集在一起对检测精度的提升有显著的作用。此外,这种簇内传感器之间的协同可以节省网络的能量和计算资源,并获得较高的感知精度,实现能量均衡。针对以上挑战,本文提出了一种面向可信检测的协同感知策略。该策略首先利用机器学习的方法对真实部署的网络环境中的传感器的相关性及单个传感器感知能力的差异性进行定量分析,为传感器协同选择提供指导,然后用基于传感器相关性、感知能力差异性及节点剩余能量的分布式传感器协同选择方法选择合适的传感器协同工作,以满足用户对感知精度的需求,同时考虑节点的剩余能量以实现传感器节点之间的能量均衡,从而最大化网络的生命周期。试验证明,该方案在可信检测和网络寿命方面的效果优于传统方法。

1 相关工作

目前,基于传感器网络的应用中,有一些关于传感器或者节点选择问题的研究。比如,为了节省能耗, k -覆盖^[11,12]通常会选择 k 个节点去覆盖一个监测点,让剩余节点处于睡眠状态,而文献[13]提出了一种用于人体运动跟踪的高能效的传感器选择方法。该方法利用扩展卡尔曼滤波估计目标运动状态,并用一个过程模型处理遗漏的检测对象。文献[14]对传感器节点的调度问题进行了研究以选择合适的传感器节点,使其处于活动状态。该文献根据一些资源约束条件提出了一种最佳的调度算法以增强数据效用。还有一些研究工作利用模态特殊

感知模型和基于协同的融合模型来选择传感器^[15],但是这种模态特殊感知模型使得异质传感器之间的协同变得很困难,这是因为它们必须要为各个模态传感器的数据分别进行训练,而且这些模型还依赖于一些不切合实际的感知假设。此外,还有一些方法利用卡尔曼滤波的方法^[16]或者多伯努利随机有限集合框架进行传感器选择^[17]以用于目标跟踪。然而这些工作忽视了单个传感器感知能力的差异性及相关性对传感器(节点)选择的影响。

另外,还有一些基于传感器感知能力差异性的传感器选择方法^[10],它们通过单个传感器感知能力的差异性来选择传感器,感知任务集中在感知能力最强的一些传感器或者节点上。但是,这些方法没有考虑传感器之间的能量均衡以及传感器相关性。类似地,文献[4]提出了一种基于传感器感知能力差异性的可信感知方法,但是它是一种集中式的方法。此外,还有一些工作^[18]为了实现网络能量均衡以延长网络寿命,将节点剩余能量作为传感器节点选择的一个重要依据,根据传感器与检测目标之间的距离来衡量该传感器的性能,但是没有考虑传感器相关性及感知能力差异性对所选择的传感器簇性能的影响。

近些年,有一些研究利用传感器相关性选择传感器用于事件检测或识别。比如,文献[19]提出了一种高能效的传感器选择方法用于两跳协作传输,该方法利用传感器之间的空间相关性以最小化总的能量开销。类似地,文献[20]利用时空相关性进行传感器节点选择以得到可以容忍的失真通信。文献[6]提出的人体活动识别系统(PBN),通过利用 K-L 离散分析传感器之间的相关性,除去冗余的传感器,以减少需要通信和计算的开销。文献[21]提出 ACE(acquisition context engine)方法,它是一种中间件,利用相关性来减少由于干扰背景带来的感知代价以支持连续场景感知。但是这些工作没有充分地探索和分析单个传感器感知能力差异性对传感器协同工作的影响。此外,Keally 等人[22]还提出利用分类器决策相关性来选择互补的分类器用于人体活动的识别。但是它们没有考虑传感器节点之间的能量均衡以延长网络寿命。

2 总体设计

如图 1 所示,本文针对上述相关研究工作的不足,利用 Wisconsin SensIT^[3] 车辆检测数据对传感器感知能力差异性及相关性进行定量分析,并依此提出了一种面向可信检测的协同感知策略以实现可信检测和能量均衡,主要内容包括两部分:

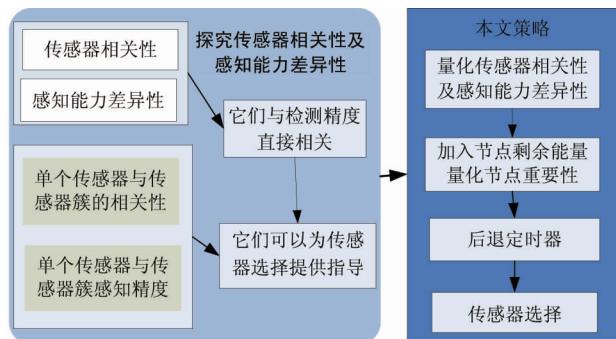


图 1 总体设计

(1) 探究传感器相关性和感知能力差异性。首先,对传感器之间的相关性及感知能力的差异性进行定量分析;然后,分别对单个传感器与传感器簇之间的相关性、单个传感器与传感器簇的检测精度的关系进行定量分析。上述的定量分析表明感知能力差异性和传感器相关性可以为传感器协同选择提供指导。

(2) 基于传感器相关性、感知能力差异性及节点剩余能量的传感器协同选择方法。首先,量化节点上各传感器之间的相关性及单个传感器的感知能力;然后,根据节点上传感器相关性及单个传感器的感知能力计算相应节点的能力;最后,根据节点的能力与剩余能量计算节点的重要性,利用后退定时器(back-off timer)及节点重要性设计分布式传感器协同选择算法。

3 探究感知能力差异性与传感器相关性

本节将探究如何充分利用传感器相关性及单个传感器感知能力差异性按需选择合适的传感器,目的是在关键位置提供可信检测,比如监控车流量等。

本研究利用 SensIT 试验数据集^[3] 在关键位置“X”进行车辆检测。如图 2 所示,试验场景中共有 23 个传感器节点,每个节点上有声音、震动、红外三种传感器,每个传感器的采样频率为 4960Hz。原始传感器数据和真实数据(ground truth)作为输入,在 PC 机上进行数据驱动的无线传感器网络仿真试验。此外,我们假设各个节点是低功耗的传感器节点(比如 Crossbow Micaz),通过 802.15.4 协议进行通信。尽管无线传感器网络中的通信经常丢包,但是因为本文主要集中在目标检测精度上,所以假设通信是可靠的。

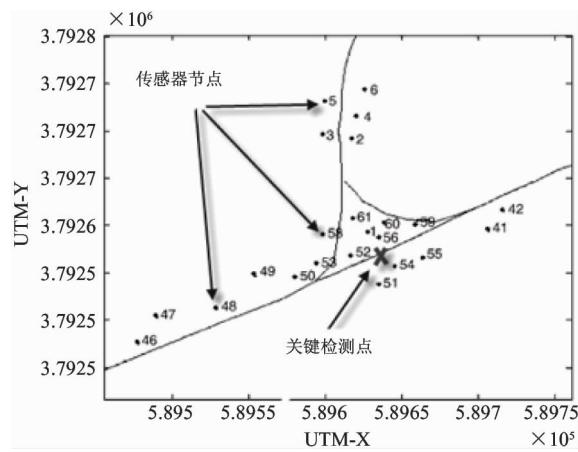


图 2 传感器节点部署^[3],其中“X”为关键检测点

本研究将每个 0.75s 数据段作为一个样本数据,总共使用 1360 个样本数据进行试验。当车辆被检测到时,我们将根据单个传感器或者传感器簇的数据来判断是否有车辆出现。根据文献[10],给定 n 个训练样本和一个簇(大小为 k),最近矩心(Nearest Centroid)方法的训练开销为 $O(n \cdot k)$,可以取得较高性能和较低的复杂度。在之前的研究用皮尔逊相关系数(Pearson correlation coefficient)来量化体域网(body sensor networks)中的原始数据的相关性。因此,我使用 Nearest Centroid 法来学习传感器(簇)的感知能力,利用皮尔逊相关系数量化传感器相关性。

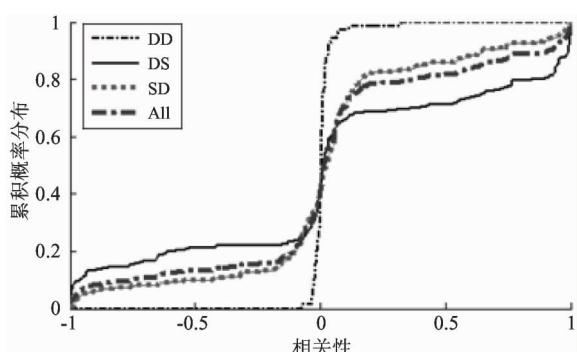
下面,首先对传感器相关性及单个传感器的感知能力进行定量分析;然后,对单个传感器与传感器簇的相关性进行分析,并对该相关性与单个传感器加入该簇后对该簇的感知精度的提升量之间的关系进行

分析;最后,对传感器簇的感知精度进行定量分析。

3.1 传感器相关性

这里利用 SensIT 原始数据及皮尔逊相关系数定量分析单个传感器之间的相关性,即:同种节点上的不同传感器之间相关性(SD)的累积概率分布、不同节点上的同种传感器之间相关性(DS)的累积概率分布、不同节点上的不同传感器之间相关性(DD)的累积概率分布及总的相关性(All)的累积概率分布。

图 3 表明同种模态的传感器之间的相关性存在很大的差异性,这种差异性与传感器自身特性和局部环境特性相关。此外,由于时空相关性,物理距离上较近的传感器之间的相关性较大。然而,很多传统的协同感知方法忽略了这些观察结果。如图 3 所示,由于传感器自身的特性,有 45% 的不同节点上的同种传感器的相关性小于 -0.6 或者大于 0.1。从图 3 也可以看出不同模态的传感器之间的相关性也存在很大的差异性:有 20% 的同种节点上的不同传感器的相关性为 0,超过 20% 的相关性大于 0.5 或者小于 -0.5。总体(All)上有 30% 样本的相关性大于 -0.1 或者小于 0.1,有 20% 样本的相关性小于 -0.6 或者大于 0.6。



DD—不同节点不同传感器的相关性;DS—不同节点同种传感器的相关性;SD—同种节点不同传感器的相关性;All—SD + DS + DD

图 3 在 Wisconsin 部署情况下的传感器相关性的累积概率分布

3.2 感知能力差异性

本节定量分析单个传感器的感知能力(检测准确率)。声音、震动、红外传感器的检测正确率的累积概率分布如图 4 所示。

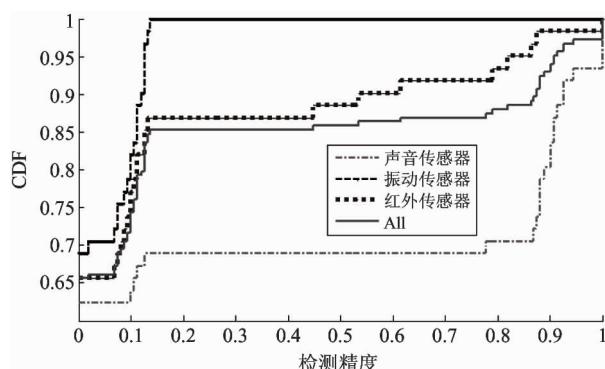


图 4 传感器检测精度的累积概率分布

图 4 表明同种模态传感器的感知能力存在很大的差异性,这种差异性与传感器本身特性和动态网络环境相关联。由于感知能力的差异性,单个传感器在不同的环境中表现出了不同的感知能力。然而,传统的协同感知方法^[4]往往忽略了这种差异性,它们经常会使用感知能力太小或者太大的传感器来进行目标检测,这样的检测正确率较低或者带来较大的能量开销,因此很难以较低的代价提供较高的检测精度以满足用户需求。图 4 也表明,不同种模态传感器的感知能力也存在很大的差异性。如图 4 所示,有 60% 的声音传感器的检测精度小于 50%,而有 80% 的震动传感器的检测精度小于 50%。而一些模态特殊感知模型用于检测覆盖,使得异质传感网中的传感器协同感知变得很困难。因此,传感器感知能力差异性普遍存在于真实网络环境中。

3.3 相关性及差异性对传感器簇感知性能的影响

根据上述分析结果可以看出,传感器相关性及单个传感器感知能力的差异性在真实部署的环境中是普遍存在的。下面将讨论这种相关性与感知能力的差异性对传感器簇感知性能的影响。

一方面,本研究讨论单个传感器与传感器簇的相关性。如图 5 所示,本研究随机产生了 3800 个簇,簇大小为 1~10 个传感器,分析了单个传感器与传感器簇的决策相关性的大小与该传感器加入该簇后检测精度增加量的关系,利用 Nearest Centroid 学习单个传感器和传感器簇的检测精度。为了计算决策相关性,每个正确的决策被记录为 1,每个错误的决策被记录为 0。图 5 表明,如果一个新的传感器加

入一个已经存在的传感器簇,当该传感器和传感器簇的相关性为0时,该传感器加入后对检测精度的提升量最大。

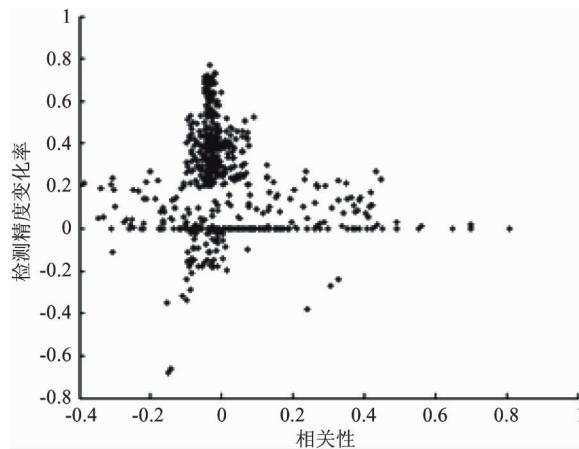


图5 单个传感器与传感器簇的相关性与该传感器对其精度提升量的关系图

另一方面,本文对单个传感器的检测精度与传感器簇的检测精度之间的关系进行定量分析。如图6所示,有少量的单个传感器有较高的检测精度:有5%的单个传感器的检测精度超过90%。在这种情况下,单个传感器往往能够满足用户的需求,不需要加入新的传感器协同工作。但是,根据图6也可以发现有超过60%的单个传感器只能得到小于50%的检测精度,而有超过50%的传感器簇能够达到90%的检测精度。因此,在很多情况下,传感器簇的检测精度高于单个传感器的检测精度。

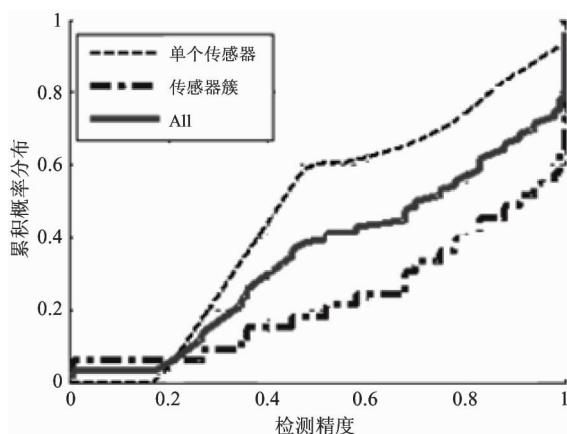


图6 单个传感器及传感器簇的分类精度的累积概率分布

通过上面的分析,可以发现传感器簇的感知精度与传感器相关性及单个传感器的感知能力有关。根据上面的分析,还可以得出以下结论:(1)在真实网络环境中进行目标检测,传感器相关性及单个传感器感知能力在同种模态和异种模态传感器之间都存在较大的差异性;(2)传感器和传感器簇的相关性为0时,该传感器加入后对检测精度的提升量最大;(3)在很多情况下,传感器簇的检测精度高于单个传感器的检测精度,也就是说在大部分情况下,需要选择多个传感器协同工作。

因此,基于上面得出的结论,本文将综合考虑感知能力差异性和传感器相关性来量化传感器节点的能力以选择合适的传感器用以目标检测。

4 分布式传感器协同选择算法

本节首先形式化要解决的问题,然后设计分布式传感器协同选择方法来解决该问题。

4.1 问题形式化

本研究定义一组传感器节点 $\mathbb{N} = \{n_1, n_2, n_3, \dots, n_k\}$, 每个节点 $n_i \in \mathbb{N}$ 上有 κ_i 个传感器,所有的传感器集合为 $\nabla = \{s_1^1, s_1^2, s_1^3, \dots, s_1^{\kappa_1}, s_2^1, s_2^2, s_2^3, \dots, s_2^{\kappa_2}, \dots, s_n^1, s_n^2, s_n^3, \dots, s_n^{\kappa_n}\}$, 其中 s_i^m 是节点 n_i 上的第 m 个传感器。通过目标检测精度(DR)来衡量传感器簇 $\mu(\mu \subset \nabla)$ 的感知能力,而目标检测精度通过机器学习算法得到。传感器相关性通过皮尔逊相关系数来量化。由于无线传感器网络的资源是受限的,实现传感器节点之间的能量均衡是一个很重要的问题。传感器节点 n_i 的剩余能量被定义为其在 T 时刻的初始能量减去节点 n_i 总的能量开销。因此,本文研究如何通过最大化剩余能量来选择传感器,即最大化剩余能量并满足用户对检测精度的要求。那么,最佳的传感器选择问题可以描述为:选择一个传感器子集 μ , 最大化 \mathfrak{R}_{\min} 并满足 $\Gamma(\mu) \geq DR$, 其中 DR 是用户要求的检测精度。因此这个问题可以形式化如下:

$$\text{Maximize } \mathfrak{R}_{\min} \quad (1)$$

$$\text{s. t. } \Gamma(\mu) \geq DR \quad (2)$$

$$\mathfrak{R}_i - \sum_{\mu} e_{iu} x_{iu} \leq \mathfrak{R}_{\min}, \quad i = 1, \dots, n \quad (3)$$

$$x_{iu} \in \{0, 1\}, u \in N^* \quad (4)$$

其中, $\Gamma(\mu)$ 指的是传感器簇 μ 对满足用户检测精度要求的贡献的大小, 因此我们用检测精度来量化传感器簇 μ 的效用 $\Gamma(\mu) = 1 - \gamma(\mu)$, $\gamma(\mu)$ 是检测错误率。本文衡量开销 e_{iu} 为活动传感器采样时间和传输能耗^[23]。式(3)可以保证所有节点的剩余能量大于等于最小剩余能量 \mathfrak{R}_{\min} 。

4.2 分布式传感器协同选择算法

本节提出了一种分布式传感器选择方法来解决 4.1 节定义的问题。在传感器选择过程中, 先选择节点, 然后选择节点上的传感器, 直到所选择的传感器簇能满足用户对检测精度的需求为止。具体来讲, 首先根据节点的重要性以一种竞争的方式选择节点, 而节点的重要性是根据节点上传感器的感知能力、传感器相关性及节点的剩余能量来计算的。其中最重要的节点成为信息融合节点。然后, 由信息融合节点建立传感器簇, 并将该节点上对满足用户需求有贡献的传感器加入到传感器簇中。如果当前的传感器簇满足不了用户的需求, 其他候选节点会根据节点重要性以一种竞争的方式被选择, 并将其上对满足用户需求有贡献的传感器加入到当前传感器簇中, 直到满足用户需求为止。因为每个传感器节点维护着一个应用层的反馈机制, 比如车辆跟踪应用, 以一种类似于文献[10]中的方法提供事件的真实值。所以, 传感器簇的感知能力可以通过 Nearest Centroid 和传感器簇中所有传感器的历史数据学习得到。本文是从节点和事件驱动的角度介绍分布式传感器选择方法, 类似于文献[10]中的设计机制, 但是在进行传感器选择的过程中, 文献[10]只考虑感知能力的差异性, 而没有考虑传感器相关性及节点剩余能量。此外, 只选择对满足用户需求有贡献的传感器^[10], 即检测精度大于 60% 的传感器。下面我们首先量化节点重要性, 然后介绍基于节点重要性的传感器选择方法。

(1) 量化节点的重要性

利用 Nearest Centroid 学习节点 n_i 上的每个传感器 s_i^m 的感知能力来量化各节点 n_i 的检测性能 $\Delta h(n_i)$ 。具体来讲, 每个节点决定该节点上的各个传感器对满足用户需求的贡献度的大小 $\Delta \gamma$, 它是

一个实数, 大小在 0 到 1 之间。 $\Delta \gamma$ 越接近 0 表示传感器 s_i^m 对满足用户需求的贡献越小, 反之则越大。 $\Delta \gamma(s_i^m)$ 和 $\Delta h(n_i)$ 定义如下:

$$\Delta \gamma(s_i^m) = 1 - \gamma_m(s_i^m) \quad (5)$$

$$\Delta h(n_i) = \sum_{i=1}^{\kappa_i} \Delta \gamma(s_i^m) \quad (6)$$

其中 $\gamma_m(s_i^m)$ 是传感器 s_i^m 的检测错误率。

然后, 利用皮尔逊相关系数来量化传感器之间的相关性。在本文中, 通过传感器相关性来识别传感器对目标检测的贡献。两个传感器之间的相关性可以定义为

$$\rho(s_i^m, s_i^u) = \frac{\text{cov}(s_i^m, s_i^u)}{\sigma(s_i^m) \cdot \sigma(s_i^u)} \quad (7)$$

单个节点上的传感器的相关性可以定义为

$$\rho(n_i) = \sum_{1 \leq m, u \leq \kappa_i, m \neq u} |\rho(s_i^m, s_i^u)| \quad (8)$$

其中, $\text{cov}(s_i^m, s_i^u)$ 是传感器 s_i^m 和 s_i^u 历史数据的协方差; $\sigma(s_i^m)$ 和 $\sigma(s_i^u)$ 分别是传感器 s_i^m 和 s_i^u 历史数据的标准差。

因此, 节点 n_i 可以通过量化单个传感器感知能力和传感器相关性来计算节点的能力。一个节点能力越强, 说明其满足用户需求的可能性就越大; 而能力越强的节点, 其节点上的传感器的感知能力强的可能性就越大。节点的能力(综合考虑传感器感知能力差异性及相关性时的效用)可以计算如下:

$$\Lambda(n_i) = (1 - a) \times \Delta h(n_i) / \kappa_i + a \times \sum_{1 \leq m, u \leq \kappa_i, m \neq u} (1 - |\rho(s_i^m, s_i^u)|) / C_{\kappa_i}^2 \quad (9)$$

其中 a 是一个权重常数。为了实现传感器节点之间的能力均衡, 本文利用节点的能力及其剩余能量 $\mathfrak{R}(n_i)$ 来衡量节点的重要性 $\ell(n_i)$, 并根据节点的重要性来选择传感器。节点的重要性计算如下:

$$\ell(n_i) = \Lambda(n_i) \times \mathfrak{R}(n_i) / \mathfrak{R}_{\text{init}}^i \quad (10)$$

其中, $\mathfrak{R}_{\text{init}}^i$ 是节点 n_i 的初始能量, $\mathfrak{R}(n_i) / \mathfrak{R}_{\text{init}}^i$ 将节点剩余能量归一化。每个节点根据其重要性 $\ell(n_i)$ 设置不同的回退定时器(backoff timer), $\ell(n_i)$ 越大, 则 backoff timer 越短。因此通过这种方法可以分布式地选择最佳的传感器簇, 满足用户对检测精度需要的同时保证节点之间的能量均衡。

(2) 基于节点重要性的传感器选择

下面是协作传感器选择算法

 Collaborative Sensor Selection Algorithm

```

Input: All sensors  $\nabla$  on nodes  $\mathbb{N} = \{n_1, n_2, n_3, \dots, n_n\}$ 
Output: A sensor cluster  $\mu (\mu \subset \nabla)$ 

1 for  $i = 1$  to  $n$ 
2     Learning the sensing capability and correlation of sensors on node  $n_i$  using history observations.
3     Compute node capability  $A(n_i)$  by Eq. (9)
4     Compute node importance  $\ell(n_i)$  by Eq. (10) and set backoff timer of the node  $n_i$  using  $\ell(n_i)$ 
5 end for
6 if back-off timer fires on node  $n_i$  and no cluster exists then
7      $n_i$  create sensor cluster  $\mu$  and add its sensors to  $\mu$ ;
8     Set  $n_i$  as the fusion node and compute  $1 - \gamma(\mu)$ 
9     if  $1 - \gamma(\mu) \geq DR$  then
10        User requirement is met and the cluster  $\mu$  is formed;
11        The sensor selection process ends
12    end if
13 else
14     if  $1 - \gamma(\mu) < DR$  then
15         /* More collaboration is needed */
16         Update  $\ell(n_i)$  using Eq. (10) and (14)
17         Set timer using  $\ell(n_i)$ ; sensors on  $n_i$  competes to join the cluster  $\mu$ .
18     end if
end if
    
```

根据这一算法,当节点 n_i 的时钟首先结束时, n_i 声明自己为信息融合节点建立一个传感器簇 μ , 并将节点 n_i 上的传感器加入到 μ 中。后续节点时钟结束后会声明自己为成员节点,并将其上的传感器加入到 μ 中。上述两种情况,只有能为满足用户需求做贡献的传感器才能加入到簇 μ 中(检测精度大于 60% 的传感器)。我们利用 Nearest Centroid 和传感器簇中的所有传感器的历史数据学习传感器簇 μ 的感知能力(目标检测正确率)。如果当前传感器簇满足不了用户对检测精度的需求,其他节点 n_j 会根据节点的重要性将其上的传感器以一种竞争的方式加入传感器簇中。

首先,当节点 n_j 试图将其上的传感器加入到已有传感器簇 μ 时,该节点量化其上的各传感器 s_j^m 对满足用户需求的贡献 $\Delta\gamma_m$, 根据如下公式

$$\Delta\gamma(\mu, s_j^m) = \gamma(\mu) - \gamma(\mu \cup s_j^m) \quad (11)$$

计算得到。然后,计算节点 n_j 的检测性能 $\Delta h(\mu, n_j)$, 计算方法为

$$\Delta h(\mu, n_j) = \sum_{1 \leq m \leq \kappa_j} \Delta\gamma(\mu, s_j^m) \quad (12)$$

计算节点 n_j 上的传感器与已有传感器簇中的传感器的相关性 $\rho(\mu, n_j)$, 用下式计算:

$$\rho(\mu, n_j) = \sum_{1 \leq m \leq \kappa_j} |\rho(\mu, s_j^m)| \quad (13)$$

根据上述计算结果,计算综合考虑传感器感知能力差异性及相关性时的效用(节点 n_j 的能力 $A(n_j)$),计算如下:

$$A(n_j) = (1 - a) \cdot \Delta h(n_j, \mu) / \kappa_j + a \cdot \sum_{1 \leq m \leq \kappa_j} (1 - |\rho(\mu, s_j^m)|) / C_{\kappa_j}^2 \quad (14)$$

最后,根据式(14)和(10)更新节点的 n_j 重要性 $\ell(n_j)$, 并根据该重要性设置后退定时器以竞争加入已有传感器簇 μ 。当传感器簇中的传感器协同工作进行目标检测时,在每个采样间隔成员节点先进行本地决策,然后将本地决策发送到信息融合节点,在融合节点使用投票方法(weight majority voting method)做最终的决策。

5 仿真结果及分析

为了验证本文提出的协同感知策略的有效性,我们在 Wisconsin SensIT 车辆检测数据集^[3]上进行了充分的试验。下面首先介绍参数设置及试验方法,然后介绍试验结果及相关分析。

5.1 参数设置及试验方法

根据 SensIT^[3] 的试验情况,共有 20 个车次(pass)。其中第一个 pass 用于训练,后续的 pass 用于测试。本试验中,本研究是对坐标为 (589630, 37925) 的检测点附近的目标进行检测,利用其周围的 12 个节点对目标进行感知。利用第一个 pass 经过这 12 个节点时的感知数据进行训练,利用剩余的 pass 的数据进行测试。用于目标检测的特征为 CPA,即每个 0.75s 数据段的方差(variance)。该 CPA 特征的提取是基于声音的能量 level。其它参数设置与第 3 节相同。

为了验证本文方法的有效性,选择了 3 个传统的对比方法即 WoPack 方法、CollSen 方法、AllSen 方法以及基于传感器相关性和传感器感知能力选择传

感器而不考虑能量均衡的 EasiCSN 方法进行对比研究。WoPack 方法^[10]是基于各传感器及传感器节点的感知能力设计的一种分布式的传感器选择方法,该方法通过选择感知能力最强的一些传感器节点协同工作使得活动的传感器节点数量最少,从而最小化网络的能量开销。该方法没有考虑传感器之间的相关性及传感器之间的能量均衡,从而影响了网络的生命周期。CollSen 方法^[21]根据传感器之间的相关性来选择传感器,使得选择的传感器簇中的传感器相关性最小,从而获得最大的信息量,同时最小化网络能量开销,但该方法没有考虑单个传感器感知能力的差异性。AllSen 方法在目标检测的过程中,所有的传感器及节点都处于活动状态,参与目标检测,与本文方法不同之处在于该方法不考虑传感器的选择问题。

为了验证本文方法的有效性,本研究定义了以下 4 种性能评价指标:(1) 目标检测准确率(DA):
 $DA = n/N$, n 是正确检测到目标的样本数量, N 是总的检测样本数量。一个检测样本就是一个 CPA 特征,该特征是从一个时间间隔(time interval)中提取出来的,一个 time interval 是 0.75s。该指标是评价本文方法性能的重要指标。(2) 能量开销:衡量能量开销是通过活动节点的采样时间和传输能量来计算的,类似于文献[23]中的方法。因为本文中使用的是 Micaz 节点,根据文献[24],当其处于活动状态时,其功率为 145.044mW,又因为一次采样的总时间为 0.75s,因此一次检测的总能耗为 0.11J。(3) 生命周期:指的是网络中第一个传感器节点能量耗尽的时间,它是衡量传感器节点之间能量均衡的重要指标。(4) 剩余能量标准差:它反映了网络中节点剩余能量的离散度,它是衡量节点之间能量均衡的另外一个指标。此外,根据机器学习方法对历史数据的学习,发现式(9)中的权重参数 $a = 0.6$ 时,EasiCSN 方法的在不同的节点数时检测正确率比其他方法要高。因此,在下面的试验中参数 a 设置为 0.6。

5.2 试验结果及分析

在本节中,首先将本文方法的检测正确率(检测精度)与其它方法进行对比分析。然后,将本文

方法的需求满足率(DRmet)和能量开销与其它方法进行对比分析。最后,评估本文方法的能量均衡策略,并与其它方法进行对比分析。

(1) 检测正确率

因为在 AllSen 方法中,所有的传感器和节点都参与目标检测,都处于活动状态,所以这里只对比如 EasiCSN、WoPack 和 CollSen 方法随着节点数量增加时的目标检测准确率。如图 7 所示,在不同的节点数量的情况下,EasiCSN 方法的检测精度比 WoPack 和 CollSen 方法的检测精度高,并且这三种方法的检测精度都随着节点数量的增加而提高。这是因为 EasiCSN 方法综合考虑了传感器相关性和单个传感器的感知能力,它们的结合能真实地反映出传感器簇的感知能力,而 CollSen 方法和 WoPack 方法分别只考虑了其中一个方面,体现不了传感器簇的真实感知能力,它们选出的传感器不是最佳的。

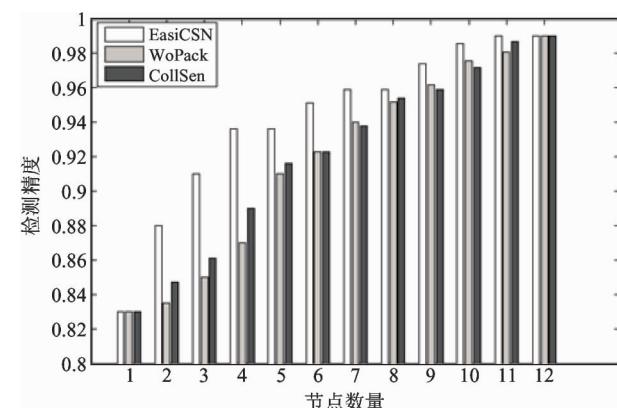


图 7 不同节点数目时的检测精度

(2) 不同用户需求下的检测准确率与能量开销

在这里将比较本文方法、EasiCSN 方法与传统方法(WoPack 方法、CollSen 方法和 AllSen 方法)在用户的不同目标检测精度(DR)需求($DR = 0.85$, $DR = 0.90$, $DR = 0.95$)时的检测精度与能量开销,并进行对比分析。

如图 8 所示,当用户需求 $DR = 0.85$ 时,本文方法的检测精度小于 EasiCSN 方法,这是因为本文方法需要考虑节点的剩余能量,选择出的传感器并不一定是能力最强的。WoPack 方法的检测精度大于 CollSen 方法,是因为传感器相关性比单个传感器的

感知能力更能体现出传感器簇的感知能力。而且随着用户需求的增加,参与检测的传感器数量增加,检测精度也逐渐提高,各方法所选择的传感器簇中相同传感器的数量增加,因此在用户需求 $DR = 0.90$ 和 0.95 时,EasiCSN、WoPack 和 CollSen 方法的检测精度很接近。因为 AllSen 方法会选择所有传感器参与目标检测,因此该方法的检测精度是最大的,且用户需求增加时其检测精度不变。

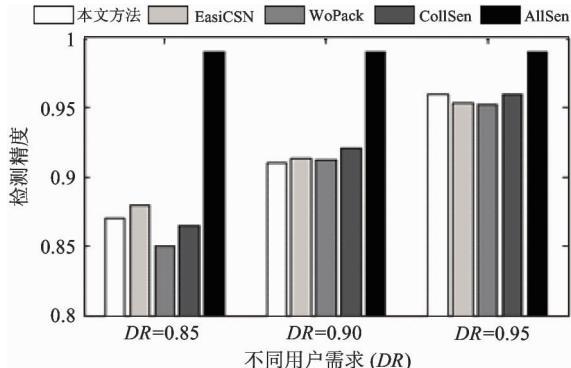


图 8 不同用户需求(DR)时的检测精度

如图 9 所示,当所选择的传感器簇在不同的用户需求的情况都满足用户需求时,EasiCSN 的能量开销比 WoPack, CollSen 和 AllSen 方法低,这是因为 EasiCSN 根据传感器相关性和单个传感器感知能力的差异性选择感知能力最强的传感器簇,使得活动的节点数量最少。本文方法的能量开销在 $DR = 0.95$ 时比 EasiCSN 和 CollSen 方法大,这是因为本文方法具有能量均衡机制,所有选出了的传感器簇可能不是感知能力最强的,其活动节点数量比 EasiCSN 和 CollSen 方法多。此外,因为 AllSen 方法使得

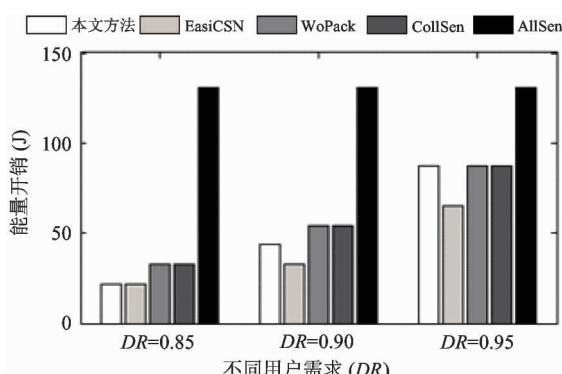


图 9 不同用户需求(DR)时的能量开销

所有节点都处于活动状态以参与目标检测,所以该方法的能量开销比其他方法都大。

(3) 能量均衡

在此将对比分析不同方法在不同用户需求时的生命周期及节点剩余能量的标准差,以此来分析本文方法的能量均衡的效果。我们假设各个节点的初始能量为 20J,根据文献[19],进行一次目标检测需要的能量是 0.11J。

图 10 表明本文方法的生命周期在每轮迭代时比其他方法长,这是因为本文方法具有能量均衡机制,而其他方法只根据相应的参数选择传感器,而没有考虑能量均衡的问题。而且随着 DR 的增加,本文方法的生命周期因为活动节点数量的增加而逐渐变短,这是因为随着用户需求的增加,在每轮迭代时选择出的传感器数量增加(节点的数量也随着增加),即需要参与感知和决策的传感器节点的数量增加。而随着用户需求 DR 的增加,传统方法的生命周期保持不变,且比本文方法的生命周期短,这是因为它们没有考虑节点的剩余能量,在每轮迭代时使用同一个传感器簇,导致少量传感器节点的能量过度消耗。而本文方法考虑了节点的剩余能量,根据节点的能力及剩余能量在每轮迭代时轮换选择不同的传感器簇,从而避免了少量节点能量的过度消耗,进而延长了网络的生命周期。

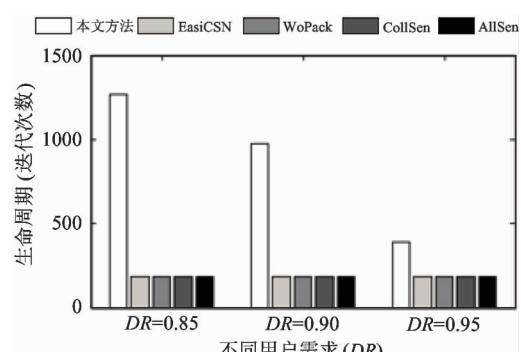


图 10 不同用户需求(DR)时的生命周期
(iteration rounds)

图 11、图 12、图 13 表明 EasiCSN、WoPack 和 CollSen 方法的剩余能量标准差在不同的 DR 情况下都比本文方法和 AllSen 方法大。这是因为 AllSen 方法在每轮迭代时所有的传感器都参与检测,而本

文方法则具有能量均衡机制。但是根据图 9 可知 AllSen 方法的能量开销很大,且根据图 10 可知其生命周期与 EasiCSN、WoPack 和 CollSen 相同。因此,与传统方法相比,本文方法可以实现传感器之间的能量均衡,延长网络寿命。

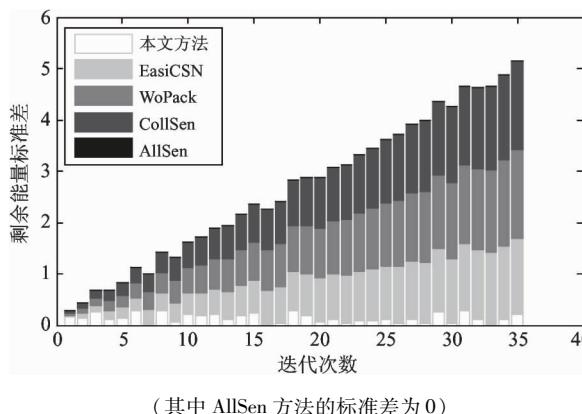


图 11 $DR = 0.85$ 的剩余能量标准差

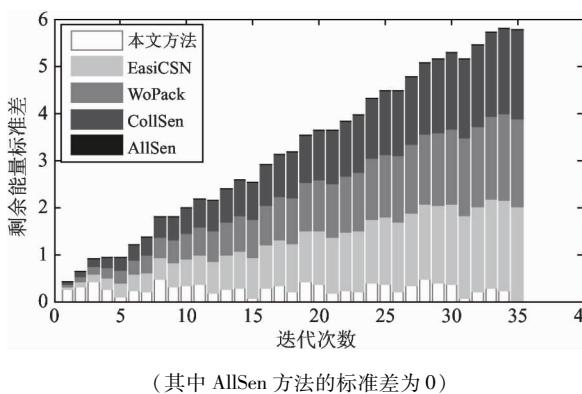


图 12 $DR = 0.90$ 的剩余能量标准差

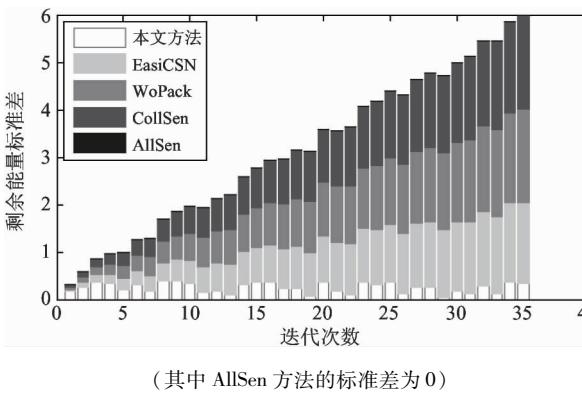


图 13 $DR = 0.95$ 的剩余能量标准差

6 结 论

传统协同目标检测方法由于传感器相关性及感知能力差异性而不能选择合适的传感器(节点)协同工作,难以实现系统能量均衡,也不能满足用户对检测精度的要求。针对这种情况,本文对传感器相关性及感知能力差异性进行了定量分析,为传感器协同选择提供指导,以求选择更合适的传感器,在此基础上提出了一种基于传感器相关性、感知能力差异性及节点剩余能量的传感器协同选择方法。该方法能够根据传感器相关性及单个传感器感知能力衡量传感器簇的性能,可以真实反映传感器簇的感知能力,依此选出的传感器簇可以满足用户对检测精度的需求。该方法还考虑网络中节点的剩余能量保证网络中传感器节点能量均衡,以延长网络寿命。该方法的有效性已通过 SensIT 车辆监测数据集测试得到验证。下一步,将在本研究部署的真实系统里对本文提出的方法进行验证。

参 考 文 献

- [1] Xing G L, Wang X R, Zhang Y F, et al, Integrated coverage and connectivity configuration for energy conservation in sensor net- works. *ACM Trans on Sensor Networks*, 2005, 1(1):36- 72
- [2] Gu L, Jia D, Vicaire P, et al. Lightweight detection and classification for wireless sensor networks in realistic environments. In: Proceedings of the 3rd International Conference on Embedded Networked Sensor Systems, New York, USA, 2005. 205-217
- [3] Duarte M, Hu Y. Vehicle classification in distributed sensor networks. *J Parallel Distrib Comput*, 2004, 64(7): 826-838
- [4] Keally M, Zhou G, Xing G. Watchdog: confident event detectionin heterogeneous sensor networks. In: Proceedings of the 16th IEEE Real- Time and Embedded Technology and Applications Symposium, Stockholm, Sweden, 2010. 279-288
- [5] Wang R, Zhang L, Xiao K J, et al. EasiSee: real-time vehicle classification and counting via low-cost collaborative sensing. *IEEE Trans on Intelligent Transportation*

- Systems, 2014, 15(1) : 414-424
- [6] Matthew K, Zhou G, Xing G L. PBN: towards practical activity recognition using smartphone-based body sensor networks. In: Proceedings of the 9th ACM Conference on Embedded Networked Sensor Systems, Seattle, USA, 2011. 246-259
- [7] Hwang J, He T, Kim Y. Exploring in-situ sensing irregularity in wireless sensor networks. In: Proceedings of the 5th International Conference on Embedded Networked Sensor Systems, New York, USA , 2007. 289-303
- [8] Yan T, He T, Stankovic J A. Differentiated surveillance for sensor networks. In: Proceedings of the 1st International Conference on Embedded Networked Sensor Systems, New York, USA, 2003. 51- 62
- [9] Tan R, Xing G, Liu X, et al. Adaptive calibration for fusion-based wireless sensor networks. In: Proceedings of IEEE INFOCOM, San Diego, USA, 2010. 1-9
- [10] Keally M, Zhou G, Xing G L, et al. Exploiting sensing diversity for confident sensing in wireless sensor networks. In: Proceedings of IEEE INFOCOM, Shanghai China, 2011. 1719-1727
- [11] Abrams Z, Goel A, Plotkin S. Set k-cover algorithms for energy efficient monitoring in wireless sensor networks. In: Proceedings of the 3rd International Symposium on Information Processing in Sensor Networks, New York, NY, USA , 2004. 424-432
- [12] Hsin C, Liu M. Network coverage using low duty-cycled sensors: random & coordinated sleep algorithms. In: Proceedings of the 3rd International Symposium on Information Processing in Sensor Networks, New York, USA 2004. 433-442
- [13] Tham C K, Han M D. Information-Driven sensor selection for energy-efficient human motion tracking. In: Proceedings of the IEEE International Conference on Distributed Computing in Sensor Systems, Cambridge, USA, 2013. 11-19
- [14] Hu W, Rourke D, Kusy B, et al. A virtual sensor scheduling framework for heterogeneous wireless sensor networks. In: Proceedings of the IEEE 38th Conference on Local Computer Networks (LCN), 2013, Sydney, Aus-tralia, 2013. 655-658
- [15] Varshney P. Distributed Detection and Data Fusion, Springer, 1996. 36-118
- [16] Shen X J, Varshney P K. Sensor selection based on generalized information gain for target tracking in large sensor networks. *IEEE Transactions on Signal Processing*, 2014, 62(2) :363-375
- [17] Gostar A K, Hoseinnezhad R, Bab-Hadiashar A. Robust multi-Bernoulli sensor selection for multi-target tracking in sensor networks. *IEEE Signal Processing Letters*, 2013, 20(12) : 1167-1170
- [18] Liu L, Ming A, Ma H, et al. A binary-classification-tree based framework for distributed target classification in multimedia sensor networks. In: Proceedings of IEEE INFOCOM, Orlando, USA, 2012. 594-602
- [19] Yan T F, Zhang J F, Xie W, et al. An energy-efficient sensor selection strategy based on spatial correlation for wireless sensor networks. In: Proceedings of the 6th International Conference on Wireless Communications and Signal Processing, Hefei, China, 2014. 1-6
- [20] Kritpolviman K M, Sukhothai T. Correlation region and node selection identification for redundant WSNs: Merging spatio- temporal correlation based-location with distortion effects. In: Proceedings of the 13th International Symposium on Communications and Information Technologies, Surat Thani, 2013. 638-642
- [21] Nath S. ACE: exploiting correlation for energy-efficient and continuous context sensing. In: Proceedings of the 10th International Conference on Mobile Systems, Applications, and Services, New York, USA, 2012. 29-42
- [22] Keally M, Zhou G, Xing G, et al. Remora: Sensing re-source sharing among smartphone-based body sensor net-works. In: Proceedings of the IEEE/ACM 21st Interna-tional Symposium on Quality of Service, Montreal, QC 2013. 1-10
- [23] Shnayder V, Hempstead M, Chen B, et al. Powertossim: Efficient power simulation for tinyos applications, 2004
- [24] Jung T, Teixeira T, Savvides A. Sensor node lifetime analysis: models and tools. *ACM Trans on Sensor Networks*, 2009, 5(1) : 1-33

Collaborative sensing for confident detection in wireless sensor networks

Xiao Kejiang^{***}, Wang Rui^{*}, Cui Li^{*}

(^{*}Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190)

(^{**}University of the Chinese Academy of Sciences, Beijing 100190)

Abstract

To improve the accuracy of the target detection based on wireless sensor networks and maximize lifetime of the networks, the study defined the detection meeting the detecting accuracy requirement of users as the confident detection, and presented a collaborative sensing scheme for confident detection. Firstly, the scheme quantitatively analyzes sensors' correlation and sensing diversity to find their connections with the sensing performance of sensor clusters; and then selects more suitable sensors to improve the detecting performance and energy balance among sensors by using a distributed collaborative sensor selection method below: performing the sensor selection according to the node importance obtained by the computation of sensors' correlation, sensing diversity and remanent energy. The experimental results demonstrate that the performance of the proposed scheme is superior to existing methods in terms of the detecting accuracy and the energy balance or network lifetime.

Key words: wireless sensor networks, energy balance, confident detection, collaborative sensing, sensor correlation