

无线传感器网络中数据密度相关度融合算法

袁 飞^{1,2†}, 詹宜巨³, 王永华⁴

(1. 广东技术师范学院 自动化学院, 广东广州 510665; 2. 中山大学 信息科学与技术学院, 广东广州 510006;

3. 中山大学 工学院, 广东广州 510006; 4. 广东工业大学 自动化学院, 广东广州 510006)

摘要: 无线传感器网络节点部署在复杂环境时, 节点间相关性无法通过节点间距离来准确描述。为了克服该缺陷, 本文提出了数据密度相关度公式。该公式反映了节点数据的 ε 邻域内数据的聚集程度, 也反映了该节点数据相对其 ε 邻域内数据的相对位置。同时, 将数据密度相关度公式应用到代表式数据融合算法中, 提出了数据密度相关度融合算法。该融合算法得到的相关区域具有相关区域内节点数据相关度大, 相关区域间节点数据相关度小的优点。仿真实验结果表明了该融合算法在数据准确性和能耗方面较基于 α -局部空间数据融合算法和基于皮尔森相关系数的数据融合算法优越。

关键词: 数据融合; 无线传感器网络; 相关性; 数据密度

中图分类号: TP273

文献标识码: A

Data density correlation degree based aggregation algorithm in wireless sensor network

YUAN Fei^{1,2†}, ZHAN Yi-ju³, WANG Yong-hua⁴

(1. School of Automation, Guangdong Polytechnic Normal University, Guangzhou Guangdong 510665, China;

2. School of Information Science and Technology, SUN-YAT SEN University, Guangzhou Guangdong 510006, China;

3. School of Engineering, SUN-YAT SEN University, Guangzhou Guangdong 510006, China;

4. School of Automation, Guangdong University of Technology, Guangzhou Guangdong 510006, China)

Abstract: Distance between sensor nodes can't reflect their correlation degree in wireless sensor network (WSN) as the sensor nodes are deployed in complex environment. In order to resolve this drawback, data density correlation degree (DDCD) is proposed in this paper. The DDCD is a spatial correlation measurement of a sensor node's data to its neighbor nodes' data. It could reflect the concentration degree of neighbor nodes' data. As well, it could describe relative position of a sensor node's data to its ε -neighborhood data. Based on this correlation degree, DDCD aggregation algorithm is presented to highlight that the representative data has a low distortion on the represented data in WSN. Additionally, simulation experiments with a real dataset are presented to evaluate the performance of the DDCD aggregation algorithm. The experimental results show that the resulting representative data achieved by DDCD aggregation algorithm have a lower data distortion than those achieved by the Pearson correlation coefficient based data aggregation algorithm or α -local spatial data aggregation algorithm. Moreover, the energy consuming of DDCD aggregation algorithm is less than those of the other two data aggregation algorithms.

Key words: data aggregation; wireless sensor networks; correlation degree; data density

1 引言(Introduction)

无线传感器网络是由部署于感知区域内的感知节点通过无线自组织方式组成的感知网络^[1-2]。其目的是通过各节点采集到的数据可靠而准确地描述感知区域内的物理特征。为此, 需要节点高密度覆盖感知区域, 但这样会造成节点数据的空间冗余。若所有节点感知信息都上传给汇聚(sink)节点, 那么描述事件的数据准确性提高不明显, 也会消耗过多的节点能量,

导致无线传感网络(wireless sensor network, WSN)寿命缩短。目前针对WSN中的数据冗余问题, 主要利用节点间相关性, 采用数据融合算法进行去冗余。

根据融合策略, 数据融合算法可分为网内查询式数据融合^[3-4]、压缩式数据融合^[5-6]和代表式数据融合^[7-10]。网内查询式数据融合的查询与应答时延较长, 特别是在大型无线传感器网络; 压缩式数据融合实现复杂, 实用性差; 代表式数据融合的融合数据精度受

收稿日期: 2013-10-31; 录用日期: 2014-05-07。

†通信作者。E-mail: eric.f.y@foxmail.com; Tel.: +86 18520035768。

基金项目: 国家自然科学基金资助项目(61071038); 广东省教育部产学研结合重点资助项目(2011A090200128)。

相关性描述方法影响较大。代表式数据融合方法是在允许一定数据误差前提下,选取局部代表节点,将其数据上传给 sink 节点,以降低数据传输量,本文即对代表式数据融合方法进行研究。

WSN 的数据融合研究以节点数据相关性为基础,但目前对节点间相关性描述方法研究较少。普遍采用的节点间相关度公式为基于节点物理位置的相关度公式,该公式将节点相关度定义为节点间距离的单调递减非负函数。该相关度计算方法适用于简单环境,并能准确知道节点位置的情况。在实际应用场景中,节点感知精度、节点间噪声、部署位置和通信环境的不确定性,会导致该节点相关性描述方法不够准确。为了克服因位置和环境带来的相关度误差,文献[11]通过计算节点数据间的皮尔森相关系数(the pearson correlation coefficient, PCC)来描述节点相关度,但该相关性度量公式仅适合描述具有线性相关性的两节点,且应用到 WSN 数据融合时,需要各节点传递一定数量的原始数据给 sink 节点,增大了节点能耗。文献[12-13]则提出基于节点数据间统计特征的节点相关度公式,该度量方式应用到 WSN 数据融合时,存在成簇过程能耗过大、相关度计算复杂的问题。

本文针对 WSN 数据融合算法中节点相关性度量方法存在的问题,提出了数据密度相关度公式。同时,将该相关度公式应用到代表式数据融合中,提出了数据密度相关度融合算法,使得融合后,位于同一相关区域内的节点数据相关度大,位于不同相关区域内的节点数据相关度小。第 2 节将介绍数据密度相关度公式,并对其性质进行说明,第 3 节中,将对数据密度相关度融合算法进行介绍,第 4 节将采用 WSN 实测数据进行仿真实验,以说明数据密度相关度融合算法的有效性。

2 数据密度相关度(Data density correlation degree)

定义 1 假设节点 v 有 n 个邻居节点, 邻居节点分别为 v_1, v_2, \dots, v_n , 节点 v 的数据对象为 D , 其邻居节点的数据对象分别为 D_1, D_2, \dots, D_n . 如果 n 个数据对象中, 有 N 个数据对象到 D 的距离小于阈值 ε , 且 $\min\{n\} \leq N \leq n$, 那么节点 v 被称为核心节点。其中 $\min\{n\}$ 为数量阈值, ε 为数据阈值。到 D 的距离小于 ε 的区域被称为 D 的 ε 邻域。

直观来看, N 越大, 位于数据对象 D 的 ε 邻域内的数据对象越多, 节点 v 对于 D 的 ε 邻域内数据对象对应的节点具有更好的代表性。并且 ε 邻域内的节点数据对象越集中在 D 的周围, 节点 v 对 D 的 ε 邻域内数据对象对应的节点具有更好的代表性。同时, 数据对象 D 离 D 的 ε 邻域内数据对象的中心越近, v 的代表性也越强。因此, 为了全面描述节点 v 的数据对象 D 对其

邻居节点数据对象的代表性, 综合以上 3 方面, 提出了数据密度相关度(data density correlation degree, DDCD)公式。

定义 2 假设节点 v 有 n 个邻居节点, 邻居节点分别为 v_1, v_2, \dots, v_n , 节点 v 的数据对象为 D , 其邻居节点的数据对象分别为 D_1, D_2, \dots, D_n . n 个数据对象中, 有 N 个数据对象到 D 的距离小于阈值 ε , 那么节点 v 相对于其邻居节点的数据密度相关度如式(1)所示:

$$\text{Sim}(v) = \begin{cases} 0, & N < \min\{n\}, \\ a_1 \left(1 - \frac{1}{\exp(N - \min\{n\})} \right) + \\ a_2 \left(1 - \frac{d_\Delta}{\varepsilon} \right) + a_3 \left(1 - \frac{d}{\varepsilon} \right), & N \geq \min\{n\}, \end{cases} \quad (1)$$

其中: $\min\{n\}$ 为数量阈值, ε 为数据阈值, d_Δ 为 D 到其 ε 邻域内的 N 个数据对象中心的距离, d 为 D 到其 ε 邻域内各数据对象的距离的平均值; a_1, a_2 和 a_3 为权重系数, 且 $a_1 + a_2 + a_3 = 1$.

式(1)所述数据密度相关度, 具有如下性质:

- 1) $\text{Sim}(v)$ 随着 N 的增大而增大;
- 2) $\text{Sim}(v)$ 随着 d_Δ 的减小而增大;
- 3) $\text{Sim}(v)$ 随着 d 的减小而增大;
- 4) $\text{Sim}(v) \in [0, 1]$.

由定义 2 及 $\text{Sim}(v)$ 的性质可知, 数据阈值 ε 保证了 $\text{Sim}(v)$ 不受不相关数据的影响, 数量阈值 $\min\{n\}$ 保证了节点 v 具有代表性时, 其数据的 ε 邻域内最少的数据对象个数。为了说明定义 2 的数据密度相关度的有效性, 假设节点 $v_0, v_1, v_2, \dots, v_n$ 的二维数据对象分别为 $D_0, D_1, D_2, \dots, D_n$, 且各数据对象 D_1, D_2, \dots, D_n 位于 D_0 的 ε 邻域内, 由式(1)求得 v_0 相对于其数据的 ε 邻域内数据对象对应节点的相关程度 $\text{Sim}(v_0)$ 。对于数据对象集合内各数据对象的分布, 可以用图 1 所示的示意图进行说明。

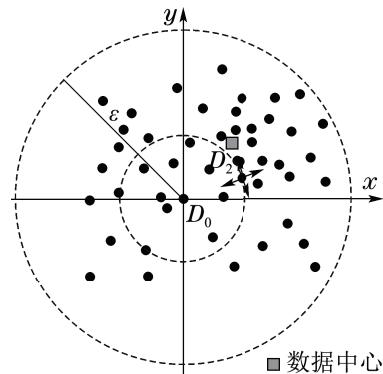


图 1 各数据对象分布示意图

Fig. 1 Sketch map of distribution of data objects

图 1 中, 当 D_0 越靠近数据中心时, D_0 对该数据集的相关性越强, 越能代表该数据集合。但对于同样

的 d_Δ , D_0 可能位于图1中的稀疏区域或者密集区域。因此,引入 d 来区分 D_0 是位于稀疏区域还是密集区域。当 d 较小时, D_0 位于密集区域, 反之, 则位于稀疏区域。当某个数据对象向着 D_0 移动时, d_Δ 和 d 均减小, 反之亦然。当某个数据对象绕着 D_0 向稀疏区域移动时, d_Δ 减小, d 保持不变, 由以上分析可知, 定义2中的数据密度相关度公式不仅反映了数据对象在 D_0 周围的聚集程度, 还反映了 D_0 周围的数据分布情况。

3 数据密度相关度融合算法(Data density correlation degree aggregation algorithm)

数据密度相关度融合算法的目的是选取合适的局部代表节点, 将代表节点的采样值传递给sink节点。为了选取合适的局部代表节点, 将数据密度相关度作为衡量节点的代表性指标, 提出了相应数据融合算法。

WSN被建模为无向图 $G = (V, E)$, 其中: V 为节点构成的节点集合, E 为WSN中所有连接构成的边集。 V 中节点*i*的天线为全向天线, 其通信半径为 $\alpha(i)$ 。节点*i*通信半径内的节点构成的集合 $N(i)$ 为节点*i*的邻居节点集合。

数据密度相关度融合算法可以分为3个过程, 分别为传感器节点类型计算(sensor type calculation, STC)过程、局部簇构建(local cluster construction, LCC)过程和全局代表节点选择(global representative sensor node selection, GRS)过程。

STC过程中, 节点*i*($i \in V$)根据邻居节点发送过来的数据, 通过定义1判断自身是否为核心节点, 并根据式(1)计算节点*i*的数据密度相关度 $\text{Sim}(i)$ 。同时, 节点*i*将位于节点*i*数据的 ε 邻域内的数据对象对应的节点号保存到 $\text{NodeSet}(i)_{\text{inner}}$, 将位于节点*i*数据的 ε 邻域外的数据对象对应的节点号保存到 $\text{NodeSet}(i)_{\text{outer}}$ 。

LCC过程中, 根据STC过程中产生的信息, 向其邻居节点发送标志信息。若某节点*i*为核心节点, 则该节点向 $\text{NodeSet}(i)_{\text{inner}}$ 内节点发送标志信息($i, 1, \text{Sim}(i)$), 向 $\text{NodeSet}(i)_{\text{outer}}$ 内的节点发送标志信息($i, -1, \text{Sim}(i)$); 若某节点*i*为非核心节点, 则该节点向其邻居节点发送标志信息($i, 0, \text{Sim}(i)$)。各节点完成标志信息发送与接收后, 保存接收到的数据密度相关度最大的值及对应节点号。另外, 若某节点*i*为核心节点, 则将其数据的 ε 邻域内数据对象对应的节点号保存到局部相关簇集合 $\text{ClusterSet}(i)$ 中; 若该节点接收到的标志信息中第2位为“1”, 则将该节点接收到的标志信息中的节点号保存到局部相关簇集合 $\text{ClusterSet}(i)$ 中。

GRS过程中, 若某个节点*i*保存的最大DDCD对应的节点号不是其自身, 则节点*i*向其局部相关簇集合 $\text{ClusterSet}(i)$ 中各节点发送其保存的最大DDCD及最大DDCD对应的节点号。接收到最大DDCD及节点号后, 各节点进行DDCD比较。若自身保存的最大

DDCD小于接收到的最大DDCD, 则用接收到的最大DDCD及对应节点号更新各节点保存的最大DDCD及对应节点号。该过程重复进行, 直到不再进行最大DDCD更新。该过程结束时, 保存着同样的最大DDCD及对应节点号的节点位于同一相关区域内, 从而实现了代表式数据融合相关区域的形成。

执行以上3个过程后的WSN节点, 被分为了代表节点、独立节点和成员节点。代表节点为核心节点, 且其保存的最大DDCD对应的节点号与自身节点号一致的节点。独立节点是非核心节点, 且局部相关簇集合 $\text{ClusterSet}(i)$ 为空的节点。成员节点是其保存的最大DDCD对应节点与自身不一致的节点。其中代表节点和独立节点负责采集数据并通过能量有效路径, 发送给sink节点, 成员节点作为中间节点, 负责传递代表节点或独立节点传递过来的数据, 或者处于休眠状态。

4 仿真与性能分析(Simulation and performance analysis)

实验中采用了Lausanne Urban Canopy Experiment (LUCE)测量联盟于2006年实际采集到的温度为节点数据对象^[14]。以代表节点数据与被代表节点数据之间的相对误差作为融合效果的衡量指标, 通过对比DDCD融合算法、PCC融合算法和 α -局部空间(α -local spatial, α -LS)融合算法^[13]的融合效果来说明DDCD融合算法的有效性。

定义3 若 $m+1$ 个节点被融合算法划分到同一相关区域内, 各节点数据分别为 $D_0, D_1, D_2, \dots, D_m$, D_0 为该相关区域的代表节点的数据, 那么以 D_0 为代表数据的相关区域内相对误差均值为

$$\bar{E} = \frac{\sum_{i=1}^m e_i}{m}, \quad (2)$$

其中 $e_i = |D_i - D_0|/D_i$, 为 D_0 与 D_i 之间的相对误差。

若WSN融合算法具有很好的融合效果, 各个相关区域的相关区域内相对误差均值均较小, 那么可以用式(3)所示的全局相对误差均值来衡量融合算法效果:

$$\bar{E}_g = \frac{\sum_{i=1}^k \bar{E}_i}{k}, \quad (3)$$

其中: k 为WSN中相关区域数量, \bar{E}_i 为第*i*个相关区域的相关区域内相对误差均值。

4.1 融合效果比较(Aggregation performance comparison)

LUCE测量联盟在测量气象数据时, 其节点部署情况如图2所示。图2中星号表示节点到其最近的邻居节点的距离不超过30 m的节点, 方框表示节点到其最近

的邻居节点的距离超过30 m的节点。从图2可以看出, 星号节点有65个, 方框节点有15个。星号所在区域, 节点分布密集, 方框节点区域, 节点分布稀疏。由于数据融合算法是针对密集覆盖的节点, 所以仿真实验中, 采用30 m作为节点通信半径, 使得大部分节点有多个邻居节点。对于稀疏区域的节点, 则在保证节点连通性的前提下, 增大其通信半径。

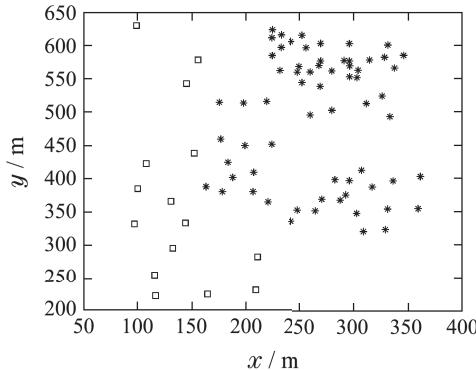


图2 LUCE中节点分布图

Fig. 2 Distributions of sensor nodes in LUCE

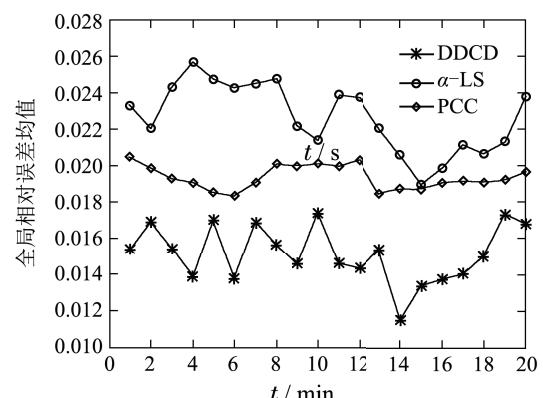
实验中选取的数据为2007年1月1日采集的数据, 并且将每两分钟内温度均值作为一个采样值, 选取连续30次的采样值为仿真实验数据。仿真实验中, 需要先对DDCD融合算法中的数据阈值, 数量阈值和权重值进行设置。在本实验中, 由于节点通信半径为30 m, 大部分星号节点在该通信半径内的邻居节点数目为4或者5个, 所以数量阈值minPts设置为2。由于数据阈值增大时, WSN网络内的全局相对误差均值会随之增大。因此, 在实验中对数据阈值预设值对应的全局相对误差均值进行衡量, 若其无法满足要求, 则将数据阈值减小, 直到满足用户对全局相对误差均值的要求。本文实验中, 数据阈值设置为0.4, 可以满足全局相对误差均值要求。DDCD公式中, 第2项在描述节点数据相关程度时, 其重要性相对另外两项更大。第3项描述节点数据在邻居节点数据中的分布情况, 其重要性较第1项大。因密集区域内各节点数据的 ε 邻域内的节点数据差别不大, 而使得第1项重要性最小, 因此设置权重系数时, 按照各项的重要性, 分别设置为 $a_1 = 1/6$, $a_2 = 1/2$, $a_3 = 1/3$ 。

PCC融合算法中, PCC相关系数阈值为0.9。 α -LS融合算法中, 最小权重阈值为0.6, 此时其独立节点数占7%。图3显示了各融合算法在各采样时刻的融合结果。图3(a)所示为各融合算法的全局相对误差均值, 图3(b)所示为各融合算法的代表节点数量, 图3(c)所示为各融合算法的独立节点数量。

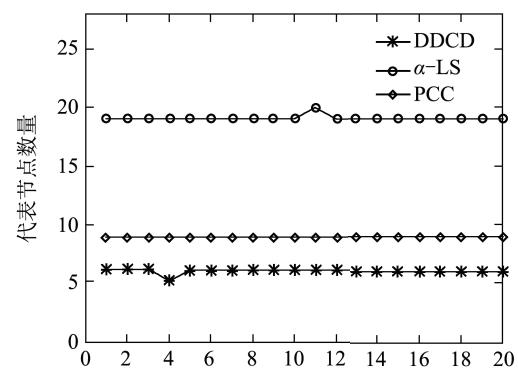
由图3(a)可知, DDCD融合算法的全局相对误差均值相对其它两种融合算法是最小的, 说明了DDCD融合算法的融合效果相对PCC融合算法和 α -LS融合算

法有较好的融合效果。图3(b)中, DDCD融合算法得到的代表节点的数量比PCC融合算法得到的代表节点数量略少, 比 α -LS融合算法得到的代表节点数量少很多。在 α -LS融合算法中, 代表节点需要满足以下两个条件之一: 1) 代表节点的空间相关权重应该是其邻居节点空间相关权重中最大; 2) 簇代表节点的邻居节点中不存在代表节点。对于高密度覆盖的WSN, 满足第1个条件的节点为各高密度覆盖区域中空间相关权重最大的点, 数量少。对于第2个形成簇头的条件, 只要某节点的邻居节点中无代表节点, 该节点便成为了代表节点。满足第2个条件的代表节点较多。因此, α -LS融合算法的代表节点数会较另外两种融合算法多。同时, 由图3(c)可以看出, DDCD融合算法得到的独立节点数量比PCC融合算法和 α -LS融合算法得到的独立节点数量小, PCC融合算法的独立节点数明显比另外两种融合算法得到的节点数多。主要因为在该时间段内, 由各个节点的数据得到的相邻节点之间的PCC值大部分较小。

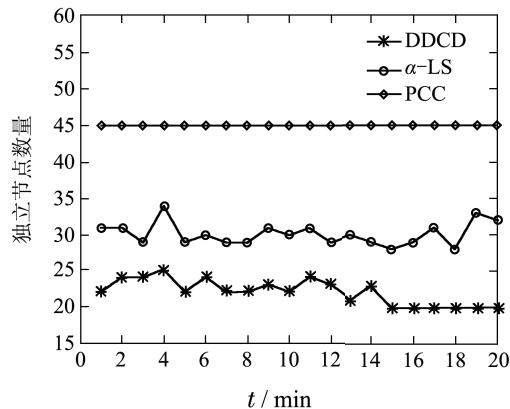
综合图3各结果可以看出, 在代表节点对相关区域内其他节点的代表性方面, DDCD融合算法性能优于另外两种融合算法。并且DDCD融合算法中, 需要进行数据上传的节点数比另外两种融合算法的数据上传节点数少, 相对能耗少。所以, DDCD融合算法数据精度较高、上传数据量较少, 具有更好性能。



(a) 全局相对误差均值



(b) 代表节点数量



(c) 独立节点数量

图3 融合结果比较

Fig. 3 Comparison of aggregation results

4.2 融合算法有效性比较(Comparison on validity of different aggregation algorithms)

WSN中代表式数据融合算法在实际应用时,在某个时刻,根据各节点采集的数据,得到代表节点和独立节点,再由代表节点和独立节点负责感知环境,并将感知数据上传给sink节点。在该时刻之后的一段时间内,WSN内的代表节点和独立节点保持不变,并感知与上传多轮数据。该数据采集方式下,数据上传时间段内,需要各节点的数据变化较小。为了说明DDCD融合算法在实际应用中的有效性,本小节实验将对该情况下DDCD融合算法、PCC融合算法和 α -LS融合算法的数据准确性进行比较。实验中,选取3个不同起始时刻进行融合,得到代表节点和独立节点,再对该时刻及其之后19个采样时刻的全局相对误差均值进行了比较。在选取的时间段内,各节点的数据变化较小。在PCC融合算法中,各个节点上传19个采样时刻的数据给sink节点后,计算得到相关区域、代表节点和独立节点。各代表节点和独立节点再在之后的10个采样时刻进行数据上传。实验得到的全局相对误差均值如图4所示。

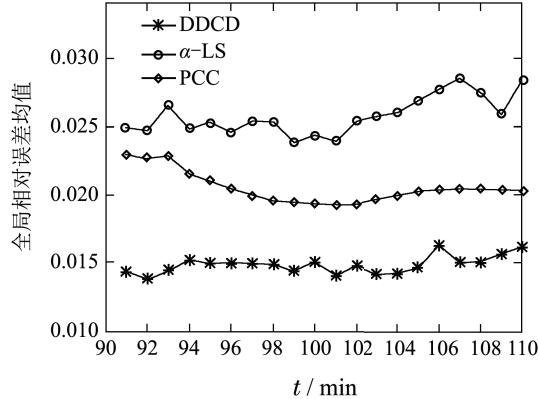
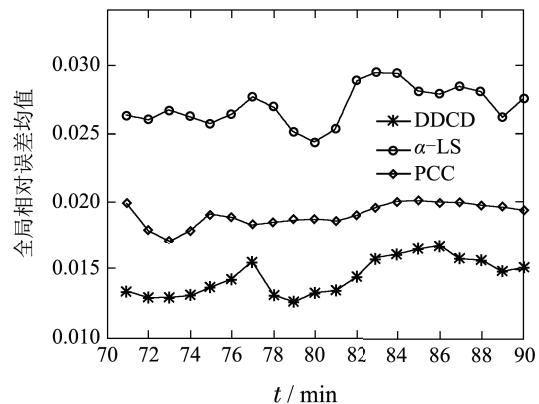
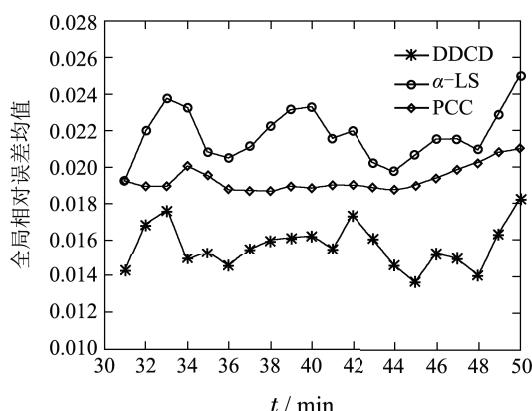


图4 不同起始时刻融合效果对比

Fig. 4 Aggregation performance for different methods with different starting time labels

图4中,各起始时刻,DDCD融合算法得到的数据准确性比另外两种融合算法的数据准确性均好。之后的19个采样时刻,DDCD融合算法的数据准确性一直比另外两种融合算法好,且准确性变化不大。而PCC融合算法得到的数据准确性随着采样时刻的不同,变化较大。主要因为PCC融合算法是通过计算一段时间内多个采样时刻数据的线性相关系数来衡量节点之间的相关性,起始时刻的选取对线性相关系数影响较大。

4.3 融合算法能耗分析(Analysis on energy consuming of different aggregation algorithms)

代表式数据融合算法的目的是通过选择合适的代表节点和独立节点,在一定误差允许下尽可能准确描述监控区域,且能降低网络能耗。因此对实验中的3种融合算法进行了能耗分析。由于融合算法主要区别在代表节点和独立节点的选择过程,主要分析该过程中各融合算法的能耗。根据相关区域的建立过程,融合算法可以分为分布式和集中式两种。DDCD融合算法和 α -LS融合算法属于分布式融合算法,PCC融合算法属于集中式融合算法。对于分布式融合算法,各节点只需发送感知数据给邻居节点和1到几轮的标志信息给局部簇成员节点。在 α -LS融合算法中,需要发送3轮信息给邻居节点,节点能耗与DDCD融合算法能

耗基本一致, 但其得到的代表节点和独立节点数目总数比DDCD融合算法得到的代表节点和独立节点数总数大得多, 会导致数据上传过程中能耗明显多于DDCD融合算法的能耗。对于PCC融合算法, 在其得到相关区域之前, 需要各节点将多轮感知数据上传给sink节点, 以计算各节点之间的相关系数, 该感知数据上传过程将消耗过多能量。因此, DDCD融合算法在得到相关区域过程中的能耗比 α -LS融合算法能耗基本一致, 在数据上传过程中能耗会明显小于 α -LS融合算法, 相对于PCC融合算法, DDCD融合算法在得到相关区域过程和数据上传过程中的能耗均具有明显优势。

5 结论(Conclusions)

针对WSN数据融合算法中, 节点相关性度量公式存在的缺陷, 本文提出了数据密度相关度公式, 该公式能够反映节点数据的 ε 邻域内数据的密集程度, 以及该节点数据相对其 ε 邻域内数据的位置。

本文还将该相关度公式应用到代表式数据融合算法中, 提出了数据密度相关度融合算法。该融合算法根据节点的数据密度相关度, 将数据密度相关度强的节点划分到同一相关区域内, 并在相关区域内找到数据密度相关度最大的节点作为代表节点, 进行数据的感知与上传。仿真实验结果表明DDCD融合算法在数据精确度和能耗方面都较 α -LS融合算法和PCC融合算法性能优越。

参考文献(References):

- [1] YICK J, MUKHERJEE B, GHOSAL D. Wireless sensor network survey [J]. *Computer Networks*, 2008, 52(12): 2292 – 2330.
- [2] OLIVEIRA L M, RODRIGUES J J. Wireless sensor networks: a survey on environmental monitoring [J]. *Journal of Communications*, 2011, 6(2): 1796 – 2021.
- [3] MADDEN S, FRANKLIN M J, HELLERSTEIN J M, et al. TAG: a tiny aggregation service for ad-hoc sensor networks [J]. *ACM SIGOPS Operating Systems Review*, 2002, 36(SI): 131 – 146.
- [4] MADDEN S, SZEWCZYK R, FRANKLIN M J, et al. Supporting aggregate queries over ad-hoc wireless sensor networks [C] //Proceedings of the Fourth IEEE Workshop on Mobile Computing Systems and Applications. New York: IEEE, 2002: 49 – 58.
- [5] ZHENG J, WANG P, LI C. Distributed data aggregation using slepian-wolf coding in cluster-based wireless sensor networks [J]. *IEEE Transactions on Vehicular Technology*, 2010, 59(5): 2564 – 2574.
- [6] CRISTESCU R, BEFERULL-LOZANO B, VETTERLI M. On network correlated data gathering [C] //Twenty-third Annual Joint Conference of the IEEE Computer and Communications Societies. Hong Kong: IEEE, 2004: 2571 – 2582.
- [7] VURAN M C, AKAN Ö B, AKYILDIZ I F. Spatio-temporal correlation: theory and applications for wireless sensor networks [J]. *Computer Networks*, 2004, 45(3): 245 – 259.
- [8] RAJESWARI A, KALAIVAAANI P. Energy efficient routing protocol for wireless sensor networks using spatial correlation based medium access control protocol compared with IEEE 802.11 [C] //Proceedings of 2011 International Conference on PACC. Coimbatore: IEEE, 2011: 1 – 6.
- [9] VURAN M C, AKYILDIZ I F. Spatial correlation-based collaborative medium access control in wireless sensor networks [J]. *IEEE/ACM Transactions on Networking*, 2006, 14(2): 316 – 329.
- [10] SHAH G, BOZYIGIT M. Exploiting energy-aware spatial correlation in wireless sensor networks [C] //Proceedings of the 2nd International Conference on 2007 Communication Systems Software and Middleware. Bangalore: IEEE, 2007: 1 – 6.
- [11] CARVALHO C, GOMES D G, AGOULMINE N, et al. Improving prediction accuracy for WSN data reduction by applying multivariate spatio-temporal correlation [J]. *Sensors*, 2011, 11(12): 10010 – 10037.
- [12] YUAN J, CHEN H. The optimized clustering technique based on spatial-correlation in wireless sensor networks [C] //Proceedings of IEEE Youth Conference on 2009 Information, Computing and Telecommunication. Beijing: IEEE, 2009: 411 – 414.
- [13] MA Y, GUO Y, TIAN X, et al. Distributed clustering-based aggregation algorithm for spatial correlated sensor networks [J]. *IEEE Sensors Journal*, 2011, 11(3): 641 – 648.
- [14] BARRENETXEA G, HENRI D F, MEIER R, et al. Environmental Data: Sensors [Z]. <http://lcav.epfl.ch/cms/lang/en/pid/86035>, 2013.

作者简介:

袁飞 (1984-), 男, 博士研究生, 目前研究方向为无线传感器网络、数据相似性, E-mail: eric_f_y@foxmail.com;

詹宜巨 (1955-), 男, 博士, 教授, 博士生导师, 目前研究方向为自动识别技术、物联网以及智能信息处理, E-mail: zhanyiju@mail.sysu.edu.cn;

王永华 (1979-), 男, 博士, 讲师, 目前研究方向为物联网、RFID智能识别以及智能信号处理, E-mail: wangyonghua@gdut.edu.cn.