

High-Efficiency Routing Data Collection of Dual Multicast Tree Based on the Projection Vector^{*}

LIU Hui, LI Zejun^{*}

(Computer Science Department, Hunan Institute of Technology, Hengyang Hunan 421002, China)

Abstract: The present node data gathering algorithm is complex, and its routing binding effect is not ideal, and it cannot meet the high energy node data collection of wireless sensor network, whereas compressed sensing theory has the merits of fault tolerance and simple coding. Based on compressed sensing and its merits, the method that high-efficiency routing data collection of dual multicast tree based on the projection vector in sensor networks is proposed. It combines Bayes compressed sensing theory with sensor route that the problem of existing algorithm is solved, that is, the sensor is sensitive to energy consumption. The basic idea of the algorithm is to firstly seek energy efficient and appropriate routing optimal projection according to the initial observation vector, and secondly use the node coefficient of minimum energy consumption and the principal component of generalized vector as the target node and the principle of maximum differential entropy change for node optimal projection coefficient, and lastly use reverse multicast routing structure in the problem of Sink and the target node routing. Theoretical and simulation results indicate that it has obtained better reconstruction effect of simulation under the condition of ensuring energy consumption, which has a certain practical value on wireless sensor communication.

Key words: compressed sensing; measurement vector; projection coefficient; multicast tree; data gathering

EEACC: 6150P

doi: 10.3969/j.issn.1004-1699.2013.04.025

基于投影矢量的双组播树高效路由数据收集^{*}

刘 卉, 李泽军^{*}

(湖南工学院计算机与信息科学学院, 湖南 衡阳 421002)

摘 要: 现有的节点数据收集算法复杂度高, 与路由结合效果不理想, 且不能满足无线传感器网络高效能量的节点数据收集, 而压缩感知理论具有容错性好、编码简单的优点。基于压缩感知的特性, 提出了一种传感器网络中基于投影矢量的双组播树高效路由数据收集, 该算法将贝叶斯压缩感知理论与传感器路由相结合, 解决现有算法不能满足传感器对能耗敏感的问题。算法的基本思想首先根据初始观测矢量来寻求能量高效并得到合适路由的最优投影。然后利用节点系数能耗最小与广义矢量的主分量作为目标节点, 采用微分熵改变量最大的原则进行求解节点最佳投影系数, 最后在 Sink 与目标节点路由问题上采用正逆向组播树进行路由构造。理论和仿真结果表明在保证能耗的条件下取得了较好的重建仿真效果, 对无线传感器通信具有一定的实用价值。

关键词: 压缩感知; 观测矢量; 投影系数; 组播树; 数据收集

中图分类号: TP393

文献标识码: A

文章编号: 1004-1699(2013)04-0570-07

无线传感器数据收集的关键问题是如何实现高效的数据处理和传感器路由。在保证传感器节点覆盖范围内节点的部署比较密集, 给传感器数据的收集带来很大的冗余量。因此传感器数据收集除了考虑高效的数据传输, 还需要考虑数据的有效处理达到减少传感器内部能耗问题。在复杂的地理环境中

构建不同路由以及不同数据特性情况下, 如何设计高效地数据处理与传感器路由相结合并使传感器网络 (WSN) 的能量、算法复杂度以及效率最优是目前传感器主要研究内容。目前国内外关于传感器网络节点数据收集的方法有很多, 数据收集算法一般可以划分时间驱动型、事件驱动型以及混合型^[1-2]等,

项目来源: 国家自然科学基金重点项目 (60933009); 湖南教育厅科学研究项目 (12C0655, 11C0375)

收稿日期: 2012-12-22 修改日期: 2013-03-07

不同的数据收集算法以及网络通信协议对传感器网络结构的影响差异很大,如薛亮,关新平等^[3]提出了事件驱动的能量均衡多流聚合路由,该算法依据网络层次图选举区域中心节点,降低了数据到达基站的延迟的传感器路由。但该算法在恒定的区域范围内以及数据分布在较均匀范围内,适用性不强。传感器路由又划分为汇聚传感器路由和主导型路由。不同的路由方式对数据处理的复杂性不同。

在节点数据收集的问题处理中,不同的节点数据收集方法对传感器路由以及数据的处理结果具有不同效果。传统数据在具体应用中,如小波变换、LTP编码、数据挖掘等^[4]算法。这些算法的数据处理计算量大,复杂度高且与传感器路由结合的效果不理想。目前研究较多的如利用聚集函数进行数据处理,该算法在利于数据传输以及算法的复杂度较小,但由于不需考虑数据的中间交换过程导致原始数据结构的丢失。而提升小波的数据处理能保留原始数据结构但数据的中间变换过程太复杂。压缩感知理论^[4]是近年来出现的一种崭新的信号采样和重构的理论工具,只要采集的信号是可压缩的或者具有稀疏性(或可变换),就可以采用投影将高维数据空间映射到低维数据空间,从而降低数据处理的复杂度,然后通过优化少数的投影中重构原始信息即压缩感知理论重构的信号具有继承性,从而极大地减少了数据的存储、数据传输的代价和信号的处理时间。由于压缩感知算法具有数据的编码鲁棒性较好,能保留原始数据而无需对中间变换过程的处理以及编码的复杂性较低等特性。这些特性对无线传感器的发展具有巨大的推动作用,目前关于压缩感知算法与传感器网路路由相结合的研究还处于初始状态。针对传感器网络以及压缩感知算法的特点,提出了一种基于投影矢量的双组播树高效路由数据收集。

1 问题描述

在无线传感器数据收集算法中重点需要解决的问题是如何根据无线传感器网络路由来设计能量高效的投影矢量,设计的节点数据收集算法能满足传感器路由的需求和传感器能耗问题以及网络重建效果。目前既能满足路由又具有低能耗且计算复杂度低的投影矢量属于 NP-难问题。该模型将求解问题转化为三个子问题。即投影目标节点集的确定、节点集的建立以、传感器路由结构的设计以及投影参数的设定。

2 压缩感知的投影矢量信号重建原理

由于贝叶斯框架具有信号的原始数据估算值和

后验概率分布函数以及误差估算函数等特性,这里采用贝叶斯压缩感知算法对信号进行重建^[5]。假设噪声高斯分布,则概率密度函数可表达为:

$$p(e_m) = \prod_{i=1}^m N(e_i | 0, \sigma^2)$$

其中 m 为观察投影值个数, e_m 为观察噪声。 σ^2 为高斯分布方差。则多元高斯似然的表达式为:

$$p(y|z, \sigma^2) = (2\pi\sigma^2)^{-\frac{m}{2}} \exp\left(-\frac{1}{2\sigma^2} |y - \Phi z|^2\right) \quad (1)$$

其中 y 为观测矢量, z 为稀疏权值, 假定先验概率密度服从 0 均匀分布, 则表达式可改为:

$$p(z, \alpha) = (2\pi)^{-n/2} \prod_{i=1}^n \alpha^{n/2} \exp(-\alpha_i z_i^2 / 2) \quad (2)$$

其中 α 表示超参数, 在矢量矩阵中每个 α 独立控制每个 Z 的强度。在矢量 Y 观测已知的情况下, Z 后验概率密度函数^[5]可表达为:

$$p(z|y, \alpha, \sigma^2) = \frac{p(y|z, \sigma^2)p(z|\alpha)}{p(y|\alpha, \sigma^2)} \quad (3)$$

由于式(3)符合多元高斯分布 $N(u, \Sigma)$, u 为均值, Σ 为协方差, 也即可以表达为:

$$\Sigma = (A + \sigma^{-2} \Phi^T \Phi)^{-1} \quad (4)$$

$$u = \sigma^{-2} \Sigma \Phi^T y \quad (5)$$

其中 Φ 为观测矩阵, 则 A 表示的矩阵为:

$$A = \begin{bmatrix} \alpha_1 & 0 & \cdots & 0 \\ 0 & \alpha_2 & \cdots & 0 \\ 0 & 0 & \cdots & \cdots \\ 0 & 0 & \cdots & \alpha_n \end{bmatrix}$$

通过式(4)和式(5)可以将后验概率密度函数转化为参数 α 和 σ^2 的后验估算问题。由于 Z 具有稀疏性, 因此可以采用一般的迭代来进行函数估算, 即:

$$\alpha_i^{new} = \frac{r_i}{u_i^2}, i \in \{1, 2, \dots, N\} \quad (6)$$

其中 u 为式(5)的后验均值, $r_i = 1 - \alpha_i \Sigma_{ii}$, Σ_{ii} 则为矩阵中对角线元素。其噪声迭代方程可表达为:

$$\sigma_{new}^2 = \frac{\|y - \Phi u\|_2^2}{m - \sum_{i=0}^n r_i} \quad (7)$$

以上公式可以看出 $u, \Sigma, \alpha^{new}, \sigma^2$ 的函数都是相互作用。因此可以采用迭代进行求解。直到迭代条件终止。在 X 后验函数已知的情况下。根据高斯理论可以得出 x 的微分熵表达式:

$$H(x) = - \int p(x) \log p(x) dx = -\frac{1}{2} \log |A + \sigma^2 \Phi^T \Phi| + \text{cost} \quad (8)$$

其中 cost 为一增加的常量。由式(8)可以得出 Y 新

的 X 微分熵的变化量:

$$\Delta h(x) = \frac{1}{2} \lg |A + \frac{1}{\sigma^2} \Phi^T \Phi| - \left(\frac{-1}{2} \right) \lg |A + \sigma^2 \Phi^T \Phi| \quad (9)$$

对 Φ 行满秩阵进行分解得到:

$$\Phi = u \begin{bmatrix} s & 0 \\ & v^t \end{bmatrix}$$

其中 $v \in R^{n \times m}$, s 为对角矩阵。通过简化可以得到 X 微分熵的变化量为:

$$\Delta h(x) = \frac{1}{2} \lg \left(1 + \frac{1}{\sigma^2} \frac{r_{m+1}^t v v^t \Gamma \Sigma \Gamma^t v v^t r_{m+1}}{r_{m+1}^t v v^t r_{m+1}} \right) \quad (10)$$

式(10)即为增加新的 Y 观测值, X 的不稳定变化量减少。根据式(10)可以得到最大化 $\Delta h(x)$ 时的投影矢量 r_{m+1} 的表达式:

$$r_{m+1} = \arg \max \frac{r^t v v^t \Gamma \Sigma \Gamma^t v v^t r}{r^t v v^t r} \quad (11)$$

根据以上表达式可以得到结合贝叶斯的压缩感知节点数据收集算法的步骤:

(1) 在节点区域中使用压缩感知算法求解初始矢量 Y 作为观测矢量矩阵;

(2) 利用贝叶斯计算稀疏矢量 Z 的期望值 u 以及 Σ ;

(3) 根据式(11)计算最优投影矢量 r_{m+1} , 重构得到新的观测矢量 Y ;

(4) 根据实际需求进行重建并满足 $y \triangleq \begin{bmatrix} y \\ y_{new} \end{bmatrix}$ 和

$\Phi \triangleq \begin{bmatrix} \Phi \\ r_{m+1} \end{bmatrix}$ 进行迭代, 直到满足较佳效果则终止, 否则, 转入(2)。

上述节点收集算法所得到的投影观测矢量不具有路由结构, 且数据的分布较稠密, 因此需要对数据进行目标节点集的优化以及路由的设定才能构成稀疏投影矢量。

3 投影矢量的双组播树高效路由算法

3.1 确定目标节点数据集

在压缩感知目标数据收集算法中, 为得到目标区域的哪些节点进行数据收集, 这里从特征矢量的节点集选择角度进行分析, 并从其中得到节点的选择。根据第3节的压缩感知理论, 可求得微分熵 X 减少量最大的投影矢量。在贝叶斯算法中还给出了 X 的后验函数密度。从矩阵的角度可以看出要使得式(11)的目标函数 r_{m+1} 最大, 可以转化为求解 $v v^t \Gamma \Sigma \Gamma^t v v^t$ 广义矩阵的特征向量, 其向量的求解为一下推导。

设广义特征向量为 R , $A = v v^t \Gamma \Sigma \Gamma^t v v^t$, $B = v v^t$, B

为 n 阶的正交矩阵, 即可以得到 $AR = \lambda BR$, 对 B 进行分解可以得到下三角矩阵即: $B = GG^t$, 代入 $AR = \lambda BR$ 得到 $AR = \lambda GG^t R$, 令 $S = G^{-1} A (G^{-1})^t$, $w = G^t R$, 整理得到 $Sw = \lambda w$, λ 为矩阵的特征值, 则所求的特征向量 R_i 的表达式为:

$$R_i = (G^{-1})^t w_i \quad (i=1, 2, \dots, n) \quad (12)$$

在节点数据收集, L 绝对值最大的分量为主导作用, 其余的分量只起到修饰作用, 因此从特征矢量的角度选择节点数据收集即选择 L 绝对值最大的分量。为动态确定选择 L 绝对值最大的分量作为目标节点集, 应该考虑节点的能量比重, 假设节点的能量门阈为 E_{th} , 特征矢量为 $R = [R_1, R_2, \dots, R_n]$, 使得 $L = \min l$ 。根据以下公式可以得到:

$$\text{s. t. } \sum_{k=1}^l |R_{ik}|^2 > E_{th}, i_k \in \{1, 2, \dots, n\} \quad (13)$$


则总能量可以表示为: $p_i = \sum_{j=1}^m |\Phi_{ij}|$, 我们以系数总能量最小为目标函数的 L 个节点组成目标节点集。通过重构来得到最佳的数据节点。

3.2 节点路由结构


采用传统的路由结构不能保证路由的高效以及数据的连通, 一般采用的方法^[6]为增加节点以保证节点连通性, 但增加节点势必带来数据量的增大, 能量的消耗过大, 采用压缩感知的投影矢量都将节点投影到统一的目标区域中, 因此不会增加数据量的处理程度。在压缩感知算法进行投影观察后, Sink 将根据拓扑结构将含有系数的数据包发送给传感节点, 传感节点按照一定规则投影到目标区域。并将数据返回到 Sink 形成回路。常见的路由方式有线性路由、树形路由、单环路路由等^[7]。

在图1中, 每个节点(除了末端节点外)数据包进行2次收发信息而只进行1次投影, 共进行18次收发通信和9个投影的节点数据。造成能量的浪费。在图2环形方式路由, 每个节点数据只需要1次收发信息, 共进行13次收发通信和12个投影的节点数据因此能量效率较高, 但该方式对目标节点分散和节点密度较高时, 路径也会增加, 时延较大。图3采用的树形方式路由, 每个节点(除了末端节点外)数据包同样进行2次收发信息而只进行1次投影。树形方式的跳数较少但同样造成能量的浪费。图4采用树形与环形相结合的新路由, 该方式同时具有树形和环形的优点。其思想是将离 Sink 节点最远的目标节点为界限划分为2个组播树。每个树采用环形的方式进行路由。2个组播树与传统的组播树的区别是:(1)传统的组播树采用是整个


组播树完全覆盖目标节点,而该组播树只需要求解2个组播树对目标节点的并集即可,优化了数据复杂度。(2)该组播树除了叶子节点外,其余每个节点是分离的。(3)每个树采用环形的方式进行路由,因此节点不存在上下游关系。不需要改变原数据包结构。




○ 普通节点 ● sink
● 目标节点 ⊗ 路由节点
图1 线性路由拓扑结构



○ 普通节点 ● sink
● 目标节点 ⊗ 路由节点
图2 环形路由拓扑结构



○ 普通节点 ● sink
● 目标节点 ⊗ 路由节点
图3 树形路由拓扑结构



○ 普通节点 ● sink
● 目标节点 ⊗ 路由节点
图4 树形与环形相结合拓扑结构

3.3 构造双组播树

组播树的构造算法^[8-10]较多,如 MPH 算法,KMB 算法等,但目前压缩感知算法下的组播树节点分离算法研究较少。假定目标节点为 D ,图 $G=(v,e)$,传感器节点的集合为 $v=\{v_i,i=1,2,\dots,n\}$,在构造具有相同叶子节点的双组播树时为使树的代价最小且投影矢量具有稀疏性并使节点总数尽量最少。做如下定义: δ_i 表示 v_i 是否属于目标节点 D 中,当 $\delta_i=1$ 表示 v_i 属于目标节点 D , $\delta_i=0$ 表示 v_i 不属于目标节点 D 。 r_{ij} 表示节点 v_i 加入那棵组播树。当 $r_{i1}=1$ 表示加入第1棵组播树,当 $r_{i2}=1$ 表示加入第2棵组播树,否则表示其他情况。 η_i 代表 v_i 的子节点。当 $\eta_i=1$ 时表示有子节点,当 $\eta_i=0$ 时表示无子节点。 h_i 为组播树的跳数。 T_1,T_2 为2棵组播树,为得到最小的 $T_1 \cup T_2$,则问题可描述^[11]为:

$$\text{s. t. } \forall v_i \in D, \sum_{j \in (1,2)} r_{ij} > 0 \quad (14)$$

$$\forall v_i \in T_1 \cup T_2, \eta_i + \sum_{j \in (1,2)} r_{ij} = 2 \quad (15)$$

$$\forall v_i \in \{v_j | \eta_j = 0\}, \delta_i(1 - \eta_i) = 1 \quad (16)$$

$$\forall v_i \in v - (T_1 \cup T_2), \sum_{j \in (1,2)} r_{ij} = 0 \quad (17)$$

其中 η 用于判断 v_i 是否存在子节点, δ_i 用于判断 v_i 是否为目标节点。为得到满足要求的2棵组播树使得节点总数最小且投影矢量的能耗尽量减少。式(14)表示目标节点必需被其中一棵组播树覆盖。式(15)表示节点要么是叶子节点,要么只能属于一棵组播树。式(16)表示 D 中的节点可以作为叶子节点存在。式(17)表示其他节点。

组播树的建立是让尽可能多的节点共享树形链路,即组播树代价最小的问题可转化为树节点总和最小的问题。由于篇幅问题这里只介绍双组播树中一种逆向组播树的构造(即叶子节点将数据发送到 Sink 节点的组播树。正向组播树的构造和逆向组播树的构造原理一样。逆向组播树的构造的思路为在 $G=(v,e)$ 中,组建 T_1 使得得 T_1 上的节点最小,然后在新图 $G'=(v',e')$ 中, v' 为叶子节点跳数为1的节点集和除 V 中非叶子节点集。 e' 为删除 $(v-v')$ 的新边集。在新 $G'=(v',e')$ 中,以 Sink 节点为源节点,取 T_1 中跳数大于1的叶子的集合 D' 。 $D'=\{v_i | v_i \in T_1, \eta_i=0, h_i > 1\}$ 。由于 T_2 的构造是删除 T_1 节点,因此正逆向组播树是分离的。算法采用迭代的方式进行构造逆向组播树,其算法描述如下:

输入:图 $G=(v,e)$,目标节点集合 D

输出:代价 C 的逆向组播树 T_1

(1)初始化时, $T_{1,0}=\{s\}$,在 $t=0$ 时 T_1 中仅包含 s 。

$c_{1,0}=0, D_{1,0}=0$ 。

(2) 利用 *Dijkstra* 在时间 t 时, 将目标节点 v_i 节点加入到 $T_{1,t}$, 得到最短路径与代价 c_i 。则总代价记为 $c_{1,t}+c_i$ 。

(3) 对于剩下的节点按照由近到远的原则依次加入到树中, 设新增加的目标节点的代价为 \bar{c}_i , 则此时代价为 $c_{1,t}+c_i+\bar{c}_i$ 。

(4) 选择使总代价最小的 v_i 加入到 $T_{1,t}$, 进入下一个时刻 $t+1, D_{1,t+1}=D_{1,t}-v_i$ 。

(5) 重复(2)~(4), 直到组播树包含所有目标节点。

该算法中, 总共需要进行 n 次迭代, 故迭代的复杂度为 $O(n^3)$, 而每次迭代的复杂度为 $O(n^2)$, 故该算法的复杂度为 $O(n^2+n^3)$ 。其具体组播路由的示意图如图5所示。




图5 组播树的路由构建

根据图5得出的数据节点ID, 上游节点集, 下游节点集以及投影系数的表如表1所示。

表1 路由及系数表

节点ID	上游节点集	下游节点集	投影系数
s	1	7	N. A
1	2,6	s	r_1
2	3,4,5	1	r_2
3	9	2	r_3
4	9	2	r_4
5	9	2	r_5
6	7	1	r_6
7	s	6,8	r_7
8	7	9	r_8
9	8	3,4,5	r_9

根据路由得出的组播树, 则压缩感知收集算法的终止条件可以依据数据的最大不确定度作为指标来控制。其中 $\beta = \max_i \beta_i \triangleq 1 - \alpha_i \sum_{ii}$ 假定门限 $\beta_{th} > \beta$ 时则收集算法终止。

4 实验与数据分析

4.1 实验环境及数据

实验中采用双核 3.2GHZ 的 PC, 实验中的参

数设置为传感器设定的区域为圆形区域, 其半径 $R=100$ m, 传感器节点的传输半径为 $r=10$ m, 利用随机函数在区域中随机均匀分布数据, Sink 位于区域中心。数据通信过程中忽略信道噪音及访问冲突。观测矢量的总长度设为 $M=120$, 采集数据的轮数为 $m \sim m_0, m_0$ 为初始观测矢量长度。为接近实际数据, 这里由计算机产生的数据不具有稀疏性。数据只存在相关性。本文压缩感知节点投影矢量算法的构建与其他经典的算法如 Adaptive Compressive Sensing 算法不同, 首先采用单位耗能的信息增量选择节点和路由。 $Q(P) = \frac{\Delta h(p)}{E(p)}$, 其中 $E(p)$ 表示路径能耗, 选择最大特征量对应的 L 个主成分并且系数能量最小的 L 个节点作为目标节点。其次, Adaptive Compressive Sensing 算法采用单播路由, 本文采用的是正逆向双播路由的方式。投影的信息量更充分, 得到的信息更多。在实验中 $d_{i,j}$ 表示节点 i 与 j 距离, 其相关性 $c_{ij} = e^{-\beta d_{i,j}}$, 其中 β 表示相关程度, 因此可以得到数

据相关矩阵, $C = \begin{bmatrix} c_{11} & \cdots & c_{1n} \\ \cdots & \cdots & \cdots \\ c_{n1} & \cdots & c_{nn} \end{bmatrix}$, 根据 Cholesky 分

解可以得到数据矢量 X 的表达式为 $x = Gn_0 + n_s, n_0$ 为随机矢量, 这里的重建误差用 err 表示, 设原始数据矢量 x , 重建数据矢量 χ 表示。则重建误差^[12]可表示为:

$$err = \frac{\sum_{i=1}^n (x_i - \chi_i)^2}{\sum_{i=1}^n x_i^2} \quad (18)$$

4.2 实验仿真与数据分析

实验中选择无线传感器节点的三个性能指标即重建误差, 能耗以及算法复杂度进行数据仿真分析。其重建误差如图6所示, 这里与经典的算法 OMP、BCS (Bayesian Compressive Sensing)、Adaptive BCS 进行比较。




图6 节点数量与重建误差关系图

在图6中明显可以看出,重建误差随着节点数的增加而增加,但OMP比基于贝叶斯理论的重建误差要大得多。在节点数量较多的情况下,本文的压缩感知投影矢量算法比Adaptive BCS算法的重建误差减少约2.5%。这是因为Adaptive BCS在贝叶斯理论中重复使用基函数的原因,在选择下一跳时Adaptive BCS算法总是选择Sink的邻跳点,使得采集的信息量十分有限。另一方面,Adaptive BCS算法没有考虑节点数据之间的相关性。本文采用微分熵改变的最大量的原则,以此来求解路径上每个节点对应的最佳投影系数。以得到较好的重建误差。

在性能的另一指标是通信代价即节点能耗,这里的节点能耗指发送数据包的总次数和包长度来衡量,忽略传感采集和Sink能耗。其节点数与能耗的关系如图7所示。




图7 节点数与能耗关系

从图7可以看出,OMP的能耗最大,这里由于OMP算法采用的是随机矩阵作为投影矩阵,因此投影矢量是稠密的,造成大量能量浪费。Adaptive CS的能耗最小,由于其自适应投影的每一次采集一个节点的信息。而本文为了得到更多的信息,因而能耗约比Adaptive CS大8%左右,但其重建性能要高6%以上。

在算法复杂度上,实验中采用仿真时间作为参考对象,其仿真时间与节点关系如图8所示。




图8 仿真时间与节点关系

由于OMP没有采用自适应机制,因而仿真时间极短,Adaptive BCS的仿真时间比OMP要大,这是因为Adaptive BCS算法给每一次投影都进行了重

建。但本文的算法在要比Adaptive BCS与OMP算法高,但增加的时间是用于组建正逆向双播路由所导致的。而Adaptive BCS的时间主要是由于贪心算法所引起的。

5 结束语

传感器网络高效能量的数据收集是制约传感器发展的关键因素之一,而压缩感知理论具有容错性好、编码简单的优点,本文将贝叶斯压缩感知理论与传感器路由相结合,解决现有算法不能满足传感器对能耗敏感的问题,算法根据初始观测矢量来寻求能量高效并得到合适路由的最优投影。在算法中采用了节点系数能耗最小与广义矢量的主分量作为目标节点。在求每一个节点最佳投影系数时采用微分熵改变量最大的原则进行求解,在Sink与目标节点路由问题上采用正逆向组播树进行路由构造。算法保证能耗的条件下取得了较好的重建仿真效果,对无线传感器通信具有一定的实用价值。由于算法是假设Sink能耗及节点用于传感采集能耗忽略不计的情况进行的,以后的实验将考虑以上因素在内进行路由设计与能耗均衡。

参考文献:

- [1] Lin F Y S, Chiu P L. A Near-Optimal Sensor Placement Algorithm to Achieve Complete Coverage-Discrimination in Sensor Networks [J]. IEEE Communications Letters, 2008, 9(1): 43-45.
- [2] Ammari H M, Das S K. Joint k -Coverage, Duty-Cycling, and Geographic for Warding in Wireless Sensor Networks [J]. IEEE Symposium on Computers and Communications, Sousse, Tunisia Jul 2009. 487-492.
- [3] 薛亮,关新平,袁亚洲. 无线传感器网络中事件驱动的能量均衡多流聚合路由算法[J]. 控制与决策, 2012, 17(2): 65-70.
- [4] Babacan S D, Molina R, Katsaggelos A K. Bayesian Compressive Sensing Using Laplace Priors [J]. IEEE Transactions on Image Processing, 2010, 19(1): 53-63.
- [5] 赵士彬,姚素英,徐江涛. 基于压缩感知的低功耗高效率CMOS图像传感器设计[J]. 传感技术学报, 2011, 27(8): 1070-1081.
- [6] 任彦,张思东,张宏科. 无线传感器网络中覆盖控制理论与算法[J]. 软件学报, 2009, 21(3): 422-433.
- [7] 王展,王雪,毕道伟. 无线传感器网络动态节点选择优化策略[J]. 计算机研究与发展, 2010, 45(10): 188-195.
- [8] 邓正伟,李锋. 自底向上的应用层组播树重构算法[J]. 计算机工程, 2011, 37(2): 105-107.
- [9] 李午阳,高德远,何颖,等. 一种高稳定性应用层组播树构建算法[J]. 计算机工程, 2011, 37(19): 85-87.
- [10] 姜占华,孙丹丹,王爱民. IPTV 频道切换中一种基于优先路径能力的组播树算法[J]. 计算机科学, 2011, 10(1): 112-115.

[11] 谈广云,许华虎,高珏. P2P 流媒体直播系统的组播树构建及设计[J]. 上海大学学报(自然科学版),2010,11(1):211-216.

[12] 李泽军,曾利军,刘卉. 无线传感器网络数据环区域查询处理算法[J]. 传感技术学报,2012,25(8):1132-1137.



刘卉(1980-),女,湖南衡阳人,讲师,硕士研究生,主要研究方向为无线传感器网络、智能信息处理,liuhixueyan@yahoo.com.cn;



李泽军(1972-),男,湖南常宁人,副教授,硕士研究生,主要研究方向为无线传感器网络、数据挖掘,lzjfox@163.com。