

WSNs 中基于期望网络覆盖和分簇压缩感知的数据收集方案

刘洲洲^{1,2†}, 李士宁²

(1. 西安航空学院 电子工程学院, 西安 710077; 2. 西北工业大学 计算机学院, 西安 710072)

摘要: 为提高无线传感器网络数据收集精确度、降低网络能耗和改善数据包丢失情况下数据收集算法的鲁棒性, 提出一种基于期望网络覆盖和分簇压缩感知的数据收集方案. 首先设计期望网络覆盖优化算法, 给出节点调度策略, 实现对“特殊”区域重点观测和降低节点能耗的目的; 然后通过分析网络分簇与节点部署之间的关系, 设计弱相关性观测矩阵, 降低数据包丢失对数据收集的影响; 最后引入群居蜘蛛优化算法以提高汇聚节点处 CS 数据重构精度. 仿真结果表明, 与其他数据收集算法相比, 所提出方案数据重构误差降低了约 23.5%, 生存期提高了约 20.5%.

关键词: 无线传感器网络; 数据收集; 网络覆盖; 压缩感知; 网络分簇; 群居蜘蛛优化算法

中图分类号: TP393

文献标志码: A

Data collection scheme based on expected network coverage and cluster compressive sensing for WSNs

LIU Zhou-zhou^{1,2†}, LI Shi-ning²

(1. School of Electronic Engineering, Xi'an Aeronautical University, Xi'an 710077, China; 2. School of Computer Science, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: In order to improve the wireless sensor network (WSN) data collection accuracy, reduce the energy consumption of the network and improve the robustness of data collection algorithm under packet loss condition, a data collection scheme based on expected network coverage and cluster compressive sensing is proposed. The data collection scheme is divided into two steps as expected network coverage optimization and cluster CS (compressive sensing) data collection. Firstly, the expected network coverage optimization algorithm is designed, and the node scheduling strategy is given through the quantitative analysis of the node coverage redundancy and the expected value of network coverage in the key observation area, which helps to achieve the purpose of the “special” area observation and reduce energy consumption. Then, by analyzing the relationship between networks clustering and node deployment, the adaptive dynamic network clustering results are provided. On this basis, the weak correlation observation matrix is designed, which can reduce the influence of the packet loss on CS data collection. Finally, the social spider optimization algorithm is introduced to improve the reconstruction accuracy of the CS. The simulation results show that compared with other data collection algorithms, the data reconstruction error is reduced by about 23.5% and the life cycle of network is increased about 20.5%.

Keywords: wireless sensor networks; data collection; network coverage; compressive sensing; network clustering; social spider optimization algorithm

0 引 言

随着无线网络通信技术的快速发展, 无线传感器网络 (WSNs) 已广泛应用于环境监测、追踪定位、智能楼宇、工业控制等领域^[1-2], 并成为国内外广泛关注的热点^[3-4]. 由于受节点计算能力和自身能量的限制以及外部环境因素的影响, 网络负载不均衡、原始数

据冗余度高^[5]、不可靠链路数据包丢失等现象是当前 WSNs 数据收集亟需解决的问题^[6].

网络覆盖作为 WSNs 应用的重要环节, 合理有效的网络覆盖策略不仅直接影响了 WSNs 数据收集与处理结果的优劣, 而且能够最大限度地延长网络生命周期^[7]. 近年来, 压缩感知 (CS) 技术^[8] 作为一种全

收稿日期: 2017-01-19; 修回日期: 2017-05-05.

基金项目: 国家自然科学基金项目 (61401499); 陕西省自然科学基金面上项目 (2017JM6096); 西安市科技计划项目 (2017076CG/RC039(XAHK001)).

责任编辑: 苏为洲.

作者简介: 刘洲洲 (1981—), 男, 副教授, 从事无线传感器网络的研究; 李士宁 (1967—), 男, 教授, 从事移动计算与传感网等研究.

†通讯作者. E-mail: nazi2005@126.com

新的信号获取和处理方式,为WSNs数据收集提供了全新的研究思路.研究表明^[9-11],基于CS的数据收集方法能够充分利用网络空间特性、降低网络能耗,并且数据压缩过程相对简单,有效克服了能量洞^[5]等问题.为此,学者们围绕如何提高WSNs数据收集可靠性进行了系列研究:李鹏等^[12]提出了一种基于压缩感知和树分解路由优化的数据收集方案,该方案分为节点数据稀疏处理和数据收集路径优化两个步骤,有效保证了数据收集具有较高的精度,但是随着网络规模的增大,路径优化计算呈现爆炸式增长;文献^[13]提出了一种基于压缩感知和Pegasis路由协议的数据收集算法,通过在链路中压缩数据以实现延长网络生存周期的目的,但是该算法鲁棒性较差而且网络能耗并不一定能够达到最小期望值;文献^[14]提出了一种基于稀疏投影矩阵数据采集算法,利用最小化开销稀疏投影矩阵完成对节点数据采样,并采用Hungarian算法实现收据数据的准确重构,但是没有充分考虑数据包丢失对数据采集结果的影响,仅适用于无数据包丢失应用场景.上述研究重点分析了节点数据稀疏采样过程,而节点与Sink通信则主要采用多跳路由方式实现,但是随着网络规模的不断扩大,合理的网络分簇更有利于改善数据传输管理效益.Wu等^[15]提出了一种基于LEACH分簇和压缩感知的数据收集算法,通过簇内节点数据压缩矩阵构造和网络分簇,实现了较高效率的网络数据收集,但是该算法没有充分考虑簇内节点数据相关性,而且簇首随机选取的方式容易导致节点能耗过快.周伟等^[16]提出了一种基于CS的机载分簇数据采集算法,充分考虑了硬件资源受限情况下的数据收集技术,为WSNs实际工程应用提供了有效借鉴.

在实际应用领域,往往需要对感知范围内某些重点区域进行监控,并且数据收集重构实时性和高精度给数据收集方法提出了更高的要求.为此,本文提出了一种基于期望网络覆盖和分簇压缩感知的WSNs数据收集方案,通过分析节点覆盖冗余度、重点观测区域网络覆盖期望值以及网络分簇与节点部署之间的关系,给出网络最佳分簇结果,并在此基础上设计基于弱相关性观测矩阵的分簇压缩感知数据收集算法.最后通过仿真实验验证了所提出方案的有效性.

1 问题描述

构建如图1所示WSNs数据采集模型,以双重正方形监控区域为研究对象, $N \times N$ 方形监控区域分为重点监控区域I和非重点监控区域II,并将监控区域

均分为 $N \times N$ 个方格.在监控区域内部署 Q 个传感器节点 $V = \{SN_i\}$ ($i = 1, 2, \dots, Q$)和1个Sink节点,传感器节点采用文献^[12]的能耗模型,且初始能量异构.设定传感器节点与Sink位置信息已知,用 f_i 表示节点 SN_i 采集到的信息,则传感器采集信息向量 $\mathbf{X}_{Q \times 1} = (f_1, f_2, \dots, f_Q)^T$.对于监控区域内 K 个事件源,用向量 $\mathbf{G}_{N^2 \times 1} = (g_1, \dots, g_j, \dots, g_{N^2 \times 1})^T$ 表示(g_j 表示第 j 个方格内事件源信号强度, $g_j = 0$ 表示该区域内无事件源),有

$$\mathbf{X}_{Q \times 1} = \Psi_{Q \times N^2} \mathbf{G}_{N^2 \times 1} = \begin{bmatrix} \psi_{11} & \cdots & \psi_{1N^2} \\ \vdots & \ddots & \vdots \\ \psi_{N1} & \cdots & \psi_{NN^2} \end{bmatrix} \begin{bmatrix} g_1 \\ \vdots \\ g_{N^2} \end{bmatrix}, \quad (1)$$

其中 $\Psi_{Q \times N^2}$ 为传播矩阵.由于Sink节点通常只接收处理部分传感器节点信息,选取观测矩阵 $\Phi_{W \times N}$ 对 $\mathbf{X}_{N \times 1}$ 融合处理,即

$$\mathbf{y} = \Phi_{W \times Q} \mathbf{X}_{Q \times 1} = \Phi_{W \times Q} \Psi_{Q \times N^2} \mathbf{G}_{N^2 \times 1}. \quad (2)$$

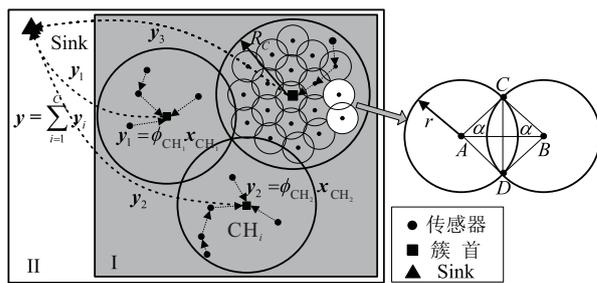


图1 WSNs数据采集模型

当WSNs按照一定规则划分为 C 个簇时,簇首节点 CH_k ($k = 1, 2, \dots, C$)采用观测矩阵 $\Phi_{M \times Q_k}$ 对簇内 Q_k 个节点数据 $\mathbf{X}_{Q_k \times 1} = (f_1^k, f_1^k, \dots, f_{Q_k}^k)^T$ 进行融合,得到测量值 $\mathbf{y}_{M \times 1}$,即

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_M \end{bmatrix} = \Phi_{M \times Q_k} \mathbf{X}_{Q_k \times 1} = \begin{bmatrix} \phi_{11} & \cdots & \phi_{1Q_k} \\ \vdots & \ddots & \vdots \\ \phi_{M1} & \cdots & \phi_{MQ_k} \end{bmatrix} \begin{bmatrix} f_1^k \\ \vdots \\ f_{Q_k}^k \end{bmatrix} = \begin{bmatrix} \phi_{11} & \cdots & \phi_{1Q_k} \\ \vdots & \ddots & \vdots \\ \phi_{M1} & \cdots & \phi_{MQ_k} \end{bmatrix} \begin{bmatrix} \psi_{11} & \cdots & \psi_{1N^2} \\ \vdots & \ddots & \vdots \\ \psi_{Q_k 1} & \cdots & \psi_{Q_k N^2} \end{bmatrix} \begin{bmatrix} g_1 \\ \vdots \\ g_{N^2} \end{bmatrix} = \Phi_{M \times Q_k} \Psi_{Q_k \times N^2} \mathbf{G}_{N^2 \times 1}. \quad (3)$$

由于事件源数量 $K \ll N^2$, $\mathbf{G}_{N^2 \times 1}$ 为稀疏向量,

$\Psi_{Q_k \times N^2}$ 为稀疏基, 此时式(3)符合压缩感知(CS)模型. 当合理选取测量矩阵 $\Phi_{M \times Q_k}$ 时, 可以通过 $y_{M \times 1}$ 得到稀疏向量 $G_{N^2 \times 1}$, 进而得到数据采集信息 $X_{Q \times 1} = (f_1, f_2, \dots, f_Q)^T$.

采用分簇式压缩感知数据收集不仅降低了 Sink 节点数据获取数据量, 而且合理的观测矩阵设计能够保证数据重构结果具有较高的精度.

2 期望网络覆盖优化

2.1 相关定义

对网络覆盖进行优化的目的是在保证网络覆盖率要求的前提下, 使用最少的传感器节点实现对监测区域的有效覆盖, 从而达到降低网络通信数据量和延长网络生存周期的目的. 针对双重正方形监控区域, 设计期望网络覆盖优化算法, 定量分析节点覆盖冗余度和重点观测区域网络覆盖期望值, 实现对“特殊”区域重点观测.

定义1(网络覆盖率) 所有传感器节点覆盖面积与监控区域面积的比值定义为网络覆盖率 $P(S)$, 有

$$P(S) = \left(\sum_{i=1}^Q s_i \right) / A(S), \quad (4)$$

其中 s_i 为节点 SN_i 覆盖面积.

推论1 对于双重正方形监控区域, 重点监控区域内节点数期望值 $E(X) = QP(I)$, 其中 $P(I)$ 为重点监控区域网络覆盖率.

证明 设重点监控区域 I 节点数为 k , 则非重点监测区域节点数为 $Q - k$, 因此变量 X 满足 $(Q, P(I))$ 二项分布 ($P(I)$ 为重点监控区域网络覆盖率), 即

$$P\{X = k\} = \binom{Q}{k} P^k(I) [1 - P(I)]^{Q-k}. \quad (5)$$

则有

$$\begin{aligned} E(X) &= \sum_{k=1}^Q k P\{X = k\} = \\ &= \sum_{k=1}^Q k \binom{Q}{k} P^k(I) [1 - P(I)]^{Q-k} = \\ &= \sum_{k=1}^Q \frac{kQ!}{k!(Q-k)!} P^k(I) [1 - P(I)]^{Q-k} = \\ &= \sum_{k=1}^Q \frac{QP(I)(Q-1)!}{(k-1)![(Q-1)-(k-1)]!} \times \\ &= P^{k-1}(I) [1 - P(I)]^{(Q-1)-(k-1)} = \\ &= QP(I) \sum_{k=1}^Q \frac{(Q-1)!}{(k-1)![(Q-1)-(k-1)]!} \times \end{aligned}$$

$$\begin{aligned} &P^{k-1}(I) [1 - P(I)]^{(Q-1)-(k-1)} = \\ &QP(I) [P(I) + 1 - P(I)]^{Q-1} = QP(I). \quad (6) \end{aligned}$$

推论1得证. \square

定义2(节点感知领域集) 对于传感器节点 SN_i ($i = 1, 2, \dots, Q$), 其感知领域集 Z_i 定义为

$$Z_i = \{SN_j\}, 0 < \|SN_k - SN_i\| \leq 2r, \quad (7)$$

其中 r 为节点感知半径.

定义3(节点覆盖冗余度) 对于传感器节点 SN_i ($i = 1, 2, \dots, Q$), 其感知领域集 Z_i 内节点覆盖自身感知面积的比重定义为节点覆盖冗余度 Θ_i , 有

$$\Theta_i = \left(\sum_{SN_k \in Z_i} s_i \cap s_k \right) / s_i, \quad (8)$$

其中 $s_i \cap s_k$ 为节点 SN_k 与 SN_i 的重叠面积.

推论2 对于给定节点 SN_i ($SN_i \in V$), 其节点覆盖冗余度 Θ_i 满足

$$\begin{aligned} \Theta_i &= \\ &= 1 - \prod_{j=1}^{SN_j \in Z_i} \left(1 + \frac{\|SN_j - SN_i\| \sqrt{4r^2 - \|SN_j - SN_i\|^2}}{2\pi r^2} - \right. \\ &\quad \left. \frac{2 \arccos \frac{\|SN_j - SN_i\|}{2r}}{\pi} \right). \quad (9) \end{aligned}$$

证明 对于 SN_i , 选取感知领域集 Z_i 内节点 SN_j , 两个节点感知区域存在重叠部分(如图1所示), 分别用 A, B 表示节点位置, 则 $AB = \|SN_k - SN_i\|$. 在 $\triangle ABC$ 中, 有

$$\angle CAB = \angle CBA = \alpha = \arccos \frac{AB}{2r}. \quad (10)$$

令两个节点感知区域重叠部分面积为 $s_{i,j}$, 则有

$$\begin{aligned} s_{i,j} &= 2\alpha r^2 - AB \cdot r \cdot \sin \alpha = \\ &= 2r^2 \arccos \frac{AB}{2r} - AB \cdot r \cdot \frac{\sqrt{r^2 - \left(\frac{AB}{2}\right)^2}}{r} = \\ &= 2r^2 \arccos \frac{AB}{2r} - \frac{AB \sqrt{4r^2 - AB^2}}{2}. \quad (11) \end{aligned}$$

显然, SN_i 感知区域内任意点被 SN_j 覆盖的概率为

$$P_j = \frac{s_{i,j}}{\pi r^2} = \frac{2 \arccos \frac{AB}{2r}}{\pi} - \frac{AB \sqrt{4r^2 - AB^2}}{2\pi r^2}. \quad (12)$$

因此, SN_i 感知区域内某点被 Z_i 内节点覆盖的概率为

$$\begin{aligned} P_i &= 1 - \bar{P}_i = 1 - \prod_{j=1}^{SN_j \in Z_i} (1 - P_j) = \\ &= 1 - \prod_{j=1}^{SN_j \in Z_i} \left(1 - \frac{2 \arccos \frac{AB}{2r}}{\pi} + \frac{AB \sqrt{4r^2 - AB^2}}{2\pi r^2} \right). \quad (13) \end{aligned}$$

根据定义2,由式(13)可以得出节点 SN_i 节点覆盖冗余度 Θ_i 满足

$$\Theta_i = 1 - \prod_{j=1}^{SN_j \in Z_i} \left(1 + \frac{\|SN_j - SN_i\| \sqrt{4r^2 - \|SN_j - SN_i\|^2}}{2\pi r^2} - \frac{2 \arccos \frac{\|SN_j - SN_i\|}{2r}}{\pi} \right). \quad (14)$$

推论2得证. \square

对于节点 SN_i ,如果其节点覆盖冗余度 $\Theta_i \geq P_{\min}(S)$ ($P_{\min}(S)$ 为最低网络覆盖要求),则表明该节点感知区域几乎被其 Z_i 内其他节点覆盖,因此可以将该节点状态切换至休眠状态.

2.2 期望网络覆盖优化实现

为了尽可能延长网络的生命周期,往往在监控区域内部署大量节点,如果所有节点都处于工作状态,则会产生大量冗余数据,导致数据通信通道阻塞.为此,根据重点监控区域节点期望值和节点覆盖冗余度设计节点调度策略,使得节点在工作状态和休眠状态进行切换,既保证了网络有效覆盖,又减少了工作节点数量,并且尽量优先安排剩余能量低的节点进入休眠状态,从而很大程度地延长了网络生存周期.

算法1 WSNs节点调度算法.

输入: Q 、 $P_{\min}(S)$ 、 $P_{\min}(I)$ 、节点相关物理特征信息//节点冗余度判定

1. For $i = 1 : Q$
2. 根据式(9)计算 SN_i 节点覆盖冗余度 Θ_i
3. If $\Theta_i \geq P_{\min}(S)$
4. 令 SN_i 为休眠状态,更新所有节点感知领域集
5. End for//重点监控区域节点状态判定
6. 计算当前网络节点总数 Q'' 和重点监控内节点集合规模 $|V^1|$
7. If $|V^1| < Q'' P_{\min}(I)$
8. 随机从重点监控内选取 $Q'' P_{\min}(I) - |V^1|$ 个休眠节点,并令其处于工作状态
9. Else
10. 对重点监控内节点集合按照节点剩余能量从小到大排列并得到 $V^1 = \{SN_1^1, SN_2^1, \dots, SN_{|V^1|}^1\}$,令 $t = |V^1|$
- While($t > Q'' P_{\min}(I)$) do
- {
11. For $k = 1 : |V^1|$
12. 计算关闭节点 SN_k^1 后重点监控覆盖率 $P(I)$,若 $P(I) \geq P_{\min}(I)$,则令 SN_k^1 处于休眠状态

13. $t - 1 \rightarrow t$

//非重点监控区域节点状态判定

14. 依次对剩余节点进行状态判定,若关闭节点网络覆盖率满足要求,则令该节点处于休眠状态.

输出:网络覆盖优化结果.

3 分簇压缩感知

3.1 网络分簇

以WSNs运行时间轮数为基本单位,在每轮开始时对稠密部署WSNs网络进行基于期望网络覆盖优化,此时工作节点部署趋于均匀.对于某个运行时段具有 Q_w 个工作节点的网络,采用如图1所示的网络分簇模型,将网络划分为 C 个具有相同簇半径的 R_C 簇,其中 $R_C = \eta R$ (R 为节点通信半径, η 为簇内最大通信跳数). C 计算为

$$Q_C = \lambda \pi R_C^2 = \pi \lambda \eta^2 R^2, \quad (15)$$

$$C = \frac{Q_w}{Q_C} = \frac{Q_w}{\pi \lambda \eta^2 R^2}. \quad (16)$$

其中: Q_C 为簇内节点数, λ 为网络节点密度.由式(15)和(16)可见,网络分簇个数 C 变大,簇内通信次数增加;反之, C 变小,簇间通信次数增加.因此,合理确定分簇规模能够均衡簇内和簇间通信,降低网络通信能耗.

推论3 当簇内最大通信跳数 η 满足下式时:

$$\eta = \left(\frac{6\pi\lambda\mu_1\mu_2 R^2 + 9\mu_1^2}{(2\pi\lambda\mu_2 R^2)^2} + \sqrt{\frac{1}{1728}} \right)^{\frac{1}{3}} + \left(\frac{6\pi\lambda\mu_1\mu_2 R^2 - 9\mu_1^2}{(2\pi\lambda\mu_2 R^2)^2} + \sqrt{\frac{1}{1728}} \right)^{\frac{1}{3}}, \quad (17)$$

网络簇内和簇间通信效益最大.

证明 网络簇内和簇间通信效益最大数学描述为

$$\max f = \mu_1 C + \mu_2 C = \mu_1 \frac{Q_w}{\pi \lambda \eta^2 R^2} + \mu_2 C. \quad (18)$$

其中: C 为簇内通信跳数总数, μ_1 、 μ_2 为权重因子.簇内节点至少需要 β 跳完成与簇首通信的节点数 Q_β 为

$$Q_\beta = \lambda \pi (\beta R)^2 = \pi \lambda \beta^2 R^2. \quad (19)$$

同理,至少需要 $\beta - 1$ 跳的节点数为 $Q_{\beta-1} = \pi \lambda (\beta - 1)^2 R^2$,恰好需要 β 跳的节点数 Q'_β 为

$$Q'_\beta = Q_\beta - Q_{\beta-1} = \pi \lambda \beta^2 R^2 - \pi \lambda (\beta - 1)^2 R^2 = \pi \lambda (2\beta - 1) R^2. \quad (20)$$

簇内节点通信跳数为

$$C_C = \sum_{\beta=1}^{\eta} \beta Q'_\beta = \sum_{\beta=1}^{\eta} \pi (2\beta - 1) \beta \lambda R^2. \quad (21)$$

所有分簇簇内节点通信跳数为

$$\begin{aligned}
C &= CC_C = \\
&= \frac{Q_w}{\pi\lambda\eta^2 R^2} \left[\sum_{\beta=1}^{\eta} \pi(2\beta-1)\beta\lambda R^2 \right] = \\
&= \frac{Q_w}{\eta^2} \left[\sum_{\beta=1}^{\eta} (2\beta-1)\beta \right] = \\
&= \frac{Q_w}{\eta^2} \left[\frac{2\eta(\eta+1)(2\eta+1) - 3\eta(\eta+1)}{6} \right] = \\
&= Q_w \left(\frac{2\eta}{3} - \frac{1}{6\eta} + \frac{1}{2} \right). \quad (22)
\end{aligned}$$

此时式(18)转化为

$$\max \mu_1 \frac{Q_w}{\pi\lambda\eta^2 R^2} + \mu_2 Q_w \left(\frac{2\eta}{3} - \frac{1}{6\eta} + \frac{1}{2} \right). \quad (23)$$

式(23)为 η 变量函数,求偏导数有

$$\frac{2\mu_2}{3}\eta^3 + \frac{\mu_2}{6}\eta^2 - \frac{2\mu_1}{\gamma\pi R^2} = 0. \quad (24)$$

式(24)为特殊一元三次方程,求解该方程得到唯一解,即

$$\begin{aligned}
\eta &= \left(\frac{6\pi\lambda\mu_1\mu_2 R^2 + 9\mu_1^2}{(2\pi\lambda\mu_2 R^2)^2} + \sqrt{\frac{1}{1728}} \right)^{\frac{1}{3}} + \\
&\quad \left(\frac{6\pi\lambda\mu_1\mu_2 R^2 - 9\mu_1^2}{(2\pi\lambda\mu_2 R^2)^2} + \sqrt{\frac{1}{1728}} \right)^{\frac{1}{3}}. \quad (25)
\end{aligned}$$

推论3得证. \square

由推论3可见,分簇大小随网络节点密度变化而变化,其本质是动态自适应调整过程,即随着网络运行时间的推移,工作节点数量逐渐降低,此时分簇半径逐渐变大,更有利于降低网络节点能耗.

算法2 网络分簇.

输入:工作节点数 Q_w , μ_1 、 μ_2 和节点物理特征信息.

1. 根据工作节点部署情况,计算节点密度
2. 根据式(17)确定最佳 η ,根据式(16)得到网络分簇个数//簇首选取与节点划分
3. 根据分簇个数将网络均分为 C 个区域
4. For $i = 1 : C$
5. 对于第 i 个区域,选取距离区域中心1跳范围内剩余能量最大的节点为簇首 CH_i
6. CH_i 选取 R_C 范围内的节点组成分簇 C_i
7. End for//个别工作节点划分
8. 若网络存在距离任何簇首都大于 R_C 的节点,则将其划分到距离最近的分簇内.

输出:网络分簇结果.

3.2 分簇压缩感知实现

压缩感知(CS)技术的出现为信号采集与数据处理带来了一场深刻变革,其通过对低维空间的非相关性观测实现对高维信号的感知^[7].对于网络内某

分簇,根据数据采集模型,簇首 $CH_i(i = 1, 2, \dots, C)$ 利用测量矩阵 $\Phi_{M \times Q_k}$ 对簇内节点数据 $\mathbf{X}_{Q_k \times 1} = (f_1^k, \dots, f_{Q_k}^k)^T$ 进行投影进而得到 $\mathbf{y}_{M \times 1}$,而 $\mathbf{X}_{Q_k \times 1}$ 在稀疏基 $\Psi_{Q_k \times N^2}$ 上的 $\mathbf{G}_{N^2 \times 1}$ 是 $K(K \ll N^2)$ 度稀疏的,因此有

$$\mathbf{y}_{M \times 1} = \Phi_{M \times Q_k} \Psi_{Q_k \times N^2} \mathbf{G}_{N^2 \times 1} = \mathbf{A}_{M \times N^2} \mathbf{G}_{N^2 \times 1}. \quad (26)$$

根据CS理论,当 $\mathbf{A}_{M \times N^2} = \Phi_{M \times Q_k} \Psi_{Q_k \times N^2}$ 满足RIP(restricted isometry property)条件时,可以通过求解一个优化问题稀疏重构出 $\mathbf{G}_{N^2 \times 1}$,进而得到 $\mathbf{X}_{Q_k \times 1} = (f_1^k, \dots, f_{Q_k}^k)^T$.另外,数据压缩处理在簇首 CH_i 处完成,而数据重构在Sink节点处完成,这样更加符合WSNs物理特性,更有利于网络降低总能耗.由于WSNs节点采集的数据具有一定的相关性和稀疏性,对测量矩阵 $\Phi = (\phi_{ij})_{M \times Q_k}$ (通常 $M \ll Q_k$)作如下设计:

$$\begin{aligned}
\phi_{ij} &= \sqrt{s} \times \begin{cases} 1, & p = \frac{1}{2s} \left(1 - \frac{K}{N^2} \right) \\ 0, & p = 1 - \frac{N^2 - K}{N^2 s} \\ -1, & p = \frac{1}{2s} \left(1 - \frac{K}{N^2} \right) \end{cases} \Rightarrow \\
\Phi &= (\phi_{ij})_{M \times Q_k} = \begin{bmatrix} \phi_{11} & \cdots & \phi_{1Q_k} \\ \vdots & \ddots & \vdots \\ \phi_{M1} & \cdots & \phi_{MQ_k} \end{bmatrix}. \quad (27)
\end{aligned}$$

其中 s 为 $\Phi_{M \times Q_k}$ 的稀疏度,可以证明采用式(27)的测量矩阵 $\Phi_{M \times Q_k}$ 满足RIP条件.从 $\Phi_{M \times Q_k}$ 的定义可以看出, s 越小, $\mathbf{G}_{N^2 \times 1}$ 的稀疏度 K 越高,则 $\Phi_{M \times Q_k}$ 越稠密,表明簇内需要进行更多的数据通信.

弱相关性观测矩阵设计.在实际WSNs网络运行过程中,往往会出现链路数据包丢失现象,如果不对错误链路数据进行处理,则会造成最终数据重构结构误差较大.通过观察WSNs可以发现,节点间具有空间相关性^[5],这种空间相关性可以用节点间距离进行表示:两节点间距离越小,相关性越大;两节点间距离超过 $2R$ 时,相关性为零.因此设计弱相关性矩阵为

$$\begin{aligned}
\mathbf{W}_C &= (w_{ij})_{Q_k \times Q_k} = \\
&= \begin{cases} 1, & i = j; \\ \frac{1}{\|\text{SN}_i - \text{SN}_j\|}, & 0 < \|\text{SN}_k - \text{SN}_i\| \leq 2R; \\ 0, & \text{otherwise.} \end{cases} \quad (28)
\end{aligned}$$

对 \mathbf{W}_C 进行归一化处理,有

$$\mathbf{H}_C = (h_{ij})_{Q_k \times Q_k} = \left(\frac{w_{ij}}{\sum w_{ij}} \right)_{Q_k \times Q_k}. \quad (29)$$

此时,簇内节点数据转化为 $\mathbf{X}_{Q_k \times 1}^{\text{new}}$,有

$$\mathbf{X}_{Q_k \times 1}^{\text{new}} = \mathbf{H}_C \mathbf{X}_{Q_k \times 1}. \quad (30)$$

当节点数据 f_i^k 发生错误时,令 \mathbf{H}_C 第 i 列全部为0,得到新的弱相关性矩阵 \mathbf{H}_C^1 ,此时利用 \mathbf{H}_C^1 修正簇内节点数据,即

$$\mathbf{X}_{Q_k \times 1}^h = \begin{bmatrix} f_{1,\text{new}}^k \\ \vdots \\ f_{i,\text{new}}^k \\ \vdots \\ f_{Q_k,\text{new}}^k \end{bmatrix} = \begin{bmatrix} f_1^k + \cdots + 0 \times f_i^k h_{1i} + \cdots + f_{Q_k}^k h_{1Q_k} \\ \vdots \\ 0 \times f_i^k + f_1^k h_{i1} + \cdots + f_{Q_k}^k h_{iQ_k} \\ \vdots \\ f_{Q_k}^k + \cdots + 0 f_i^k h_{Q_k i} + \cdots + f_{Q_k-1}^k h_{Q_k Q_k-1} \end{bmatrix} = \begin{bmatrix} 1 & \cdots & 0 & \cdots & h_{1Q_k} \\ \vdots & & \vdots & & \vdots \\ h_{i1} & \cdots & 0 & \cdots & h_{iQ_k} \\ \vdots & & \vdots & & \vdots \\ h_{Q_k 1} & \cdots & 0 & \cdots & 1 \end{bmatrix} \begin{bmatrix} f_1^k \\ \vdots \\ f_i^k \\ \vdots \\ f_{Q_k}^k \end{bmatrix} = \mathbf{H}_C^1 \mathbf{X}_{Q_k \times 1}. \quad (31)$$

由式(31)可见,当链路发生错误时,弱相关性矩阵利用其他正确数据对发生错误节点进行估计,消除了错误节点对簇内节点数据向量的影响.此时,CS模型转化为

$$\begin{aligned} \mathbf{y}_{M \times 1} &= \Phi_{M \times Q_k} \mathbf{H}_C^1 \mathbf{X}_{Q_k \times 1} = \\ &\Phi_{M \times Q_k} \mathbf{H}_C^1 \Psi_{Q_k \times N^2} \mathbf{G}_{N^2 \times 1} = \\ &\mathbf{A}_{M \times N^2}'' \mathbf{G}_{N^2 \times 1}. \end{aligned} \quad (32)$$

CS重构. 群居蜘蛛优化(SSO)算法是一种新型群体智能启发计算技术,在连续优化问题中表现出了良好的全局寻优性能^[18](SSO基本原理见相关文献).为了提高CS重构算法精度,本文将离散群居蜘蛛优化算法(DSSO)引入稀疏信号重构过程,以实现稀疏度未知信号的精确重构.

定义4(目标函数) 定义DSSO优化CS重构算法目标函数为

$$\min f(\mathbf{G}) = \|\mathbf{y} - \Phi_{M \times Q_k} \mathbf{H}_C^1 \Psi_{Q_k \times N^2} \mathbf{G}_{N^2 \times 1}\|_2. \quad (33)$$

定义5(蜘蛛编码方式) 参考事件源信号向量 $\mathbf{G}_{N^2 \times 1} = (g_1, \cdots, g_j, \cdots, g_{N^2 \times 1})^T$,定义DSSO蜘蛛编码方式为

$$F_i(x_j) = x_j \begin{cases} 1, & g_j \neq 0; \\ 0, & g_j = 0; \end{cases} \quad j = 1, 2, \cdots, N^2. \quad (34)$$

其中 F_i 为蜘蛛个体.

定义6(蜘蛛更新策略) 定义DSSO蜘蛛更新策略为

$$\begin{aligned} F_{i,\text{new}} &= \\ &F_i + r_1 \times BS(F_i \rightarrow P_B) + r_2 \times BS(F_i \rightarrow P_g). \end{aligned} \quad (35)$$

其中: P_B 、 P_g 分别为雌性(雄性)子群和蜘蛛种群最优解, $BS(\rightarrow)$ 表示蜘蛛相互转化操作.通过观察不同蜘蛛个体编码,可以发现不同蜘蛛之间可以通过一系列蜘蛛编码位调换操作实现相互转化. $r_1 \times BS(F_i \rightarrow P_B)$ 表示任意选取 r_1 个蜘蛛编码位操作.

算法3 CS重构算法.

输入: 蜘蛛种群相关参数、算法终止条件;

$\Phi_{M \times Q_k}$ 、 $\Psi_{Q_k \times N^2}$ 、 \mathbf{H}_C^1 、 \mathbf{y} .

1. 算法初始化. 根据式(34)和稀疏度 K ,随机生成蜘蛛种群, $t = 0$

2. While (终止条件不满足)

3. {

4. 根据式(35)对雌性(雄性)蜘蛛进行更新

5. 更新雌性(雄性)子群和蜘蛛种群最优解

6. $t + 1 \rightarrow t$

7. }

输出: 事件源信号向量 $\mathbf{G}_{N^2 \times 1} = (g_1, \cdots, g_j, \cdots, g_{N^2 \times 1})^T$ 非零位置.

采用DSSO优化CS重构算法可以得到事件源信号向量非零位置,然后采用最小二乘法得到非零位置幅度信息,最后根据 $\mathbf{X}_{Q_k \times 1} = \mathbf{H}_C^1 \Psi_{Q_k \times N^2} \mathbf{G}_{N^2 \times 1}$ 得到簇内节点数据采集信息,从而完成对WSNs节点数据采集的处理.

4 实验仿真

为了验证基于期望网络覆盖和分簇压缩感知的数据收集方案的有效性,在Matlab仿真平台上进行实验仿真.实验环境设置为:在 $80\text{m} \times 80\text{m}$ 正方形监控区域内稠密部署 $Q = 300$ 个传感器节点,监控区域外部署一个Sink节点,重点监控区域设置为监控中心且边长 30m 的方形区域,监控区域内事件源数量未知,传感器节点有关物理特征参数参考文献[14].数据收集方案相关参数设置为: $P_{\min}(S) = 0.85$ 、 $P_{\min}(I) = 0.9$ 、 $\mu_1 = 0.4$ 、 $\mu_2 = 0.6$ 、 $s = 80/\lg 80$,DSSO参数设置参考文献[18].评价指标采用网络能耗 E 、延时 T_d 、网路生存周期 L_f 和信号重构误差.信号重构误差以信噪比SNR和相对误差RE进行衡量,

即

$$SNR = 10 \lg \frac{\sum_{i=1}^{Q_k} x_i^2}{\sum_{i=1}^{Q_k} (x_i - \tilde{x}_i)^2},$$

$$RE = \frac{\|\mathbf{x} - \tilde{\mathbf{x}}\|_2}{\|\mathbf{x}\|_2}, \quad (36)$$

其中 \mathbf{x} 、 $\tilde{\mathbf{x}}$ 分别为原始数据和重构数据。

4.1 实例仿真分析

采用本文所提出的数据收集方案进行实例仿真,将实验设置为稳定链路数据收集和存在数据包错传数据收集两种场景,实验每过一段时间对数据进行一次采样,并分别对每轮收集方案评价指标进行分析.表1给出了某轮数据采集评价指标结果.

表1 MDSSO-MIP性能指标

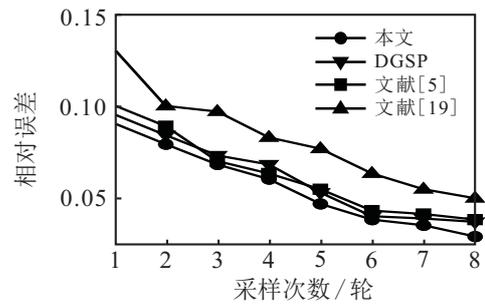
	E/J	T_d/s	$L_f/10^3s$	RE	$P(S)/\%$	$P(I)/\%$
稳定链路	1.3	8.3	2.2	0.09	91	94
不稳定链路	1.8	9.5	1.7	0.13		

由表1可见,采用分簇压缩感知数据收集方案,在稳定网络环境下信号重构误差仅为0.09,即使在不稳定环境下,重构误差也只有0.13,从而表明该方案能够有效完成数据采集,而且具有较高的精度.

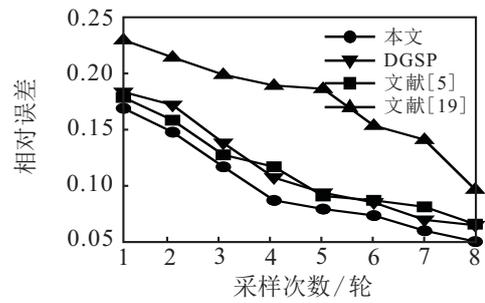
4.2 对比实验

为了进一步分析本文所提出的数据收集方案性能,分别选取文献[14]提出的DGSP方案,文献[5]提出的“不可靠链路下基于压缩感知数据收集方案”以及经典的CDG方案^[19]进行对比分析,其中DGSP和文献[5]提出的方案都是基于压缩感知理论,但是两者并没有采用分簇策略,而是以数据树的形式进行数据传输.分别采用4种方案进行实验,并对对比分析稳定网络环境和不稳定网络环境下评价指标的对比结果.图2~图5给出了不同评价指标对比结果.

由图2可见:随着采样次数的不断增加,4种算法相对误差都逐渐降低,这是因为采样次数较少时,部分节点可能没有被采集到,导致在信号重构过程中相对误差较大.但是,本文方案相对误差要好于其他3种方案,特别是对于不稳定网络,在存在数据包丢失的情况下,本文方案相对误差降低了约23.5%,文献[19]CDG明显高于其他3种方案,原因在于虽然本文方案、DGSP和文献[5]方案都采用了错误数据规避机制,但是DGSP和文献[5]直接将错误数据删除,而本文通过弱相关矩阵对错误数据进行了估计,从而提高了重构精度,并且DSSO的引入使得CS重构结果要好于DGSP采用的传统OMP重构算法.

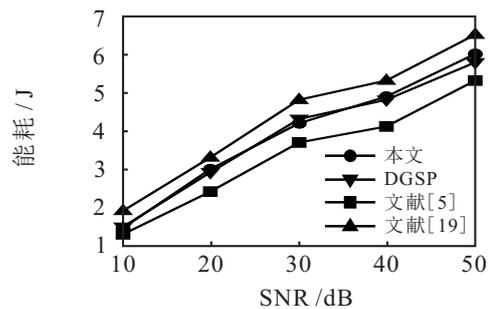


(a) 稳定链路

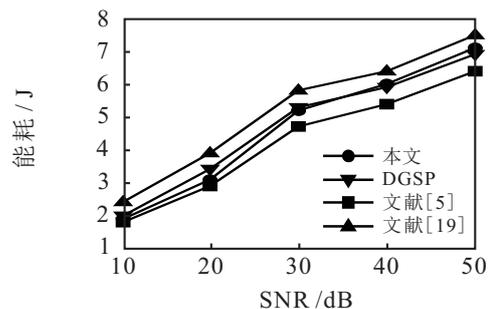


(b) 不稳定链路

图2 4种方案相对误差对比结果



(a) 稳定链路



(b) 不稳定链路

图3 4种方案能耗对比结果

由图3和图4可见:随着SNR的不断增长,4种方案的能耗和延时都在不断增长,这是因为为了得到较高的SNR,4种方案需要增加采样节点数量,从而使得通信次数的网络吞吐量增加,导致网络能耗和延时都在提高.但是,对于同一水平的SNR,本文方案要好于其他3种方案,这是因为本文采用网络分簇结构,有效均衡了簇内节点能耗,并且簇内节点只与簇内节点进行通信,不需要通过其他节点与Sink节点进行通信,使得整个网络负载更加均衡.

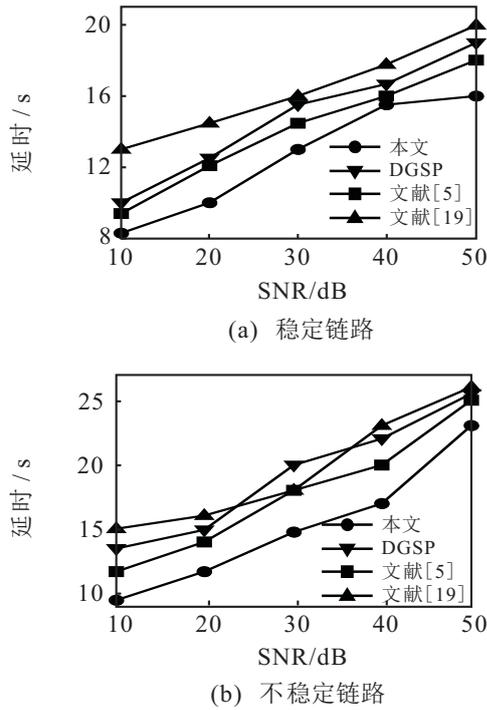


图4 4种方案延时对比结果

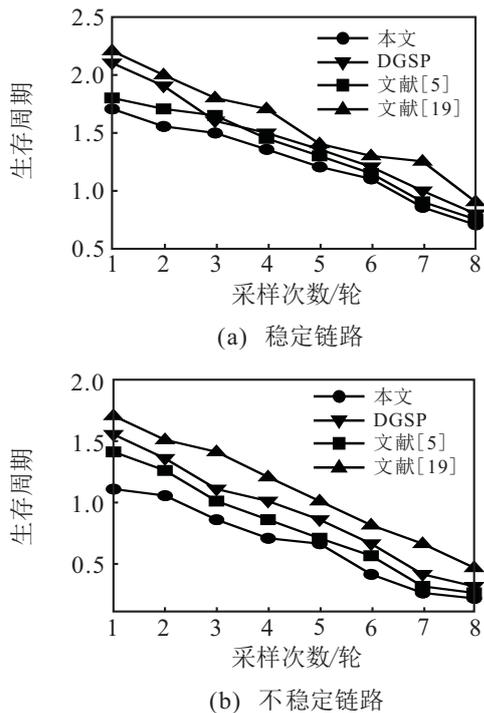


图5 4种方案生存周期对比结果

由图5可见:随着采样次数的增加,网络总能量不断降低,生存周期随之减少,但是随着时间推移,本文方案生存周期要好于其他3种方案,特别是对于不稳定环境,生存周期提高了约20.5%。这是因为基于网络覆盖优化机制的引入,对节点工作状态合理切换,使得网络在保障覆盖要求的前提下,尽可能采用较少的工作节点进行工作,而且在每轮覆盖优化过程中,优先选择能量低的节点进入休眠状态,因此本文方案具有更长的生存周期。

5 结论

在无线传感器网络的诸多实际应用领域中,对监测数据的收集重构实时性和高精度度提出了更高的要求,为满足应用需求,本文提出了一种基于期望网络覆盖和分簇压缩感知的WSNs数据收集方案.分别对网络覆盖优化、网络分簇、压缩感知数据收集和稀疏信号重构进行了研究,通过仿真的方法,详细分析了在稳定链路和不稳定链路下通过对数据采集网络覆盖优化和网络分簇,验证了通过采用分簇压缩感知完成网络节点上数据处理后的稀疏信号具有较高的重构精度.在稳定网络环境和不稳定网络环境下的仿真实验表明:

1) 本文将离散弱相关矩阵的错误数据估计与群居蜘蛛优化算法引入到稀疏信号重构过程中,以实现稀疏度未知信号的精确重构.该方法具有强大的全局搜索能力,提高了算法的整体性能,特别是对于不稳定网络,重构精度较其他数据收集方案有明显提升。

2) 本文采用网络分簇同时引入网络覆盖优化机制,方案在减少簇成员节点采样数据量次数的同时,只需簇内节点相互通信,不需要其他节点与Sink节点进行通信.相比于传统WSN数据采集方案,该方案大大降低了簇成员节点之间的能量消耗,提高了网络生存周期。

本文提出的数据采集方案为WSNs的实用化提供了有效借鉴.由于篇幅限制,本文没有考虑可移动Sink节点数据收集问题,这是下一步研究的重点。

参考文献(References)

- [1] Mini S, Udgata S, Sabat S. Sensor deployment and scheduling for target coverage problem in wireless sensor networks[J]. IEEE Sensors J, 2014, 14(3): 636-644.
- [2] 侯建军, 朱明强, 刘颖. 一种强背景噪声下的WSN目标定位算法[J]. 北京理工大学学报, 2016, 36(5): 535-540.
- (Hou J J, Zhu M Q, Liu Y. An algorithm for WSN target location under strong background noise [J]. J of Beijing Institute of Technology, 2016, 36(5): 535-540.)
- [3] Zheng H F, Yang F, Tian X H, et al. Data gathering with compressive sensing in wireless sensor networks: A random walk based approach[J]. IEEE Trans on Parallel & Distributed Systems, 2015, 26(1): 35-44.
- [4] Ebrahimi D, Assi C. Network coding-aware compressive data gathering for energy-efficient wireless sensor networks[J]. ACM Trans on Sensor Networks, 2015, 11(4): 1-24.
- [5] 张策, 张霞, 李欧, 等. 不可靠链路下基于压缩感

- 知的WSN数据收集算法[J]. 通信学报, 2016, 37(9): 131-141.
(Zhang C, Zhang X, Li O, et al. WSN data collection algorithm based on compressed sensing under unreliable links[J]. J of Communication, 2016, 37(9): 131-141.)
- [6] Ma J C, Lou W, Li X Y. Contiguous link scheduling for data aggregation in wireless sensor networks[J]. IEEE Trans on Parallel and Distributed Systems, 2014, 25(7): 1691-1701.
- [7] 孙泽宇, 伍卫国, 王换招, 等. 概率模型下的一种优化覆盖算法[J]. 软件学报, 2016, 27(5): 1285-1300.
(Sun Z Y, Wu W G, Wang H Z, et al. An optimal coverage algorithm for probabilistic models[J]. J of Software, 2016, 27(5): 1285-1300.)
- [8] Donoho D. Compressed sensing[J]. IEEE Trans on Information Theory, 2006, 52(4): 1289-1306.
- [9] Xie R T, Jia X H. Minimum transmission data gathering trees for compressive sensing in wireless sensor networks[C]. Proc of the Global Communications Conference. Houston: IEEE Press, 2011: 1-5.
- [10] Wang J, Tang S, Yin B, et al. Data gathering in wireless sensor networks through intelligent compressive sensing[C]. Proc of IEEE Infocom 2012. Piscataway, NJ: IEEE, 2012: 603-611.
- [11] Chou C T, Ignjatovic A, Hu W. Efficient computation of robust average of compressive sensing data in wireless sensor networks in the presence of sensor faults[J]. IEEE Trans on Parallel and Distributed Systems, 2013, 24(8): 1525-1534.
- [12] 李鹏, 王建新, 丁长松. WSN中基于压缩感知的高效能数据收集方案[J]. 自动化学报, 2016, 42(11): 1648-1656.
(Li P, Wang J X, Ding C S. WSN compressed sensing performance data collection scheme[J]. Acta Automation Sinica, 2016, 42(11): 1648-1656.)
- [13] Osamy W, Salim A, Aziz A. Efficient compressive sensing based technique for routing in wireless sensor networks[J]. Infocomp J of Computer Science, 2013, 12(1): 1-9.
- [14] 李鹏, 王建新. 无线传感器网络中基于稀疏投影的数据收集方案[J]. 中南大学学报: 自然科学版, 2016, 47(10): 3445-3453.
(Li P, Wang J X. Data collection scheme based on sparse projection in wireless sensor networks[J]. J of Central South University: Natural Science Edition, 2016, 47(10): 3445-3453.)
- [15] Wu X, Xiong Y, Huang W, et al. An efficient compressive data gathering routing scheme for large scale wireless sensor networks[J]. Computers & Electrical Engineering, 2013, 39(6): 1935-1946.
- [16] 周伟, 景博, 黄以锋, 等. 基于CS的机载分簇型WSN数据采集方法[J]. 通信学报, 2015, 36(5): 1971-1980.
(Zhou W, Jing B, Huang Y F, et al. Clustering of airborne WSN data acquisition method based on CS[J]. J of Communication, 2015, 36(5): 1971-1980.)
- [17] 孙保明, 郭艳, 李宁, 等. 无线传感器网络中基于压缩感知的动态目标定位算法[J]. 电子与信息学报, 2016, 38(8): 1858-1864.
(Sun B M, Guo Y, Li N, et al. Dynamic target localization algorithm based on Compressive Sensing in wireless sensor networks[J]. J of Electronics and Information Technology, 2016, 38(8): 1858-1864.)
- [18] 王艳娇, 李晓杰, 肖婧. 基于动态学习策略的群集蜘蛛优化算法[J]. 控制与决策, 2015, 30(9): 1575-1582.
(Wang Y J, Li X J, Xiao J. The cluster optimization algorithm based on spider dynamic learning strategy[J]. Control and Decision, 2015, 30(9): 1575-1582.)
- [19] Luo C, Wu F, Sun J, et al. Efficient measurement generation and pervasive sparsity for compressive data gathering[J]. IEEE Trans on Wireless Communications, 2010, 9(12): 3728-3738.

(责任编辑: 郑晓蕾)