

DOI: 10.7652/xjtuxb201702007

采用压缩感知和 GM(1,1)的无线传感器网络异常检测方法

刘洲洲^{1,2}, 李士宁²

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

摘要: 针对当前无线传感器网络(WSNs)异常检测算法的检测准确率较低同时影响网络能耗均衡的问题,提出了一种基于改进压缩感知(CS)重构算法和智能优化 GM(1,1)的 WSNs 异常检测方法。首先,通过建立双层异质 WSNs 异常检测模型,并采用压缩感知技术对上层观测节点收集到的下层检测节点温度测量数据进行处理,同时结合温度数据稀疏度未知特点,构造有效的稀疏矩阵和测量矩阵,并重新定义测量矩阵正交变换预处理策略,使得 CS 观测字典满足约束等距(RIP)条件;其次,重新定义了离散蜘蛛编码方式,蜘蛛种群不断协同进化,以获得稀疏结果中非零元素的位置信息,利用最小二乘法得到非零元素的幅度信息,实现了对未知数量检测节点数据的精确重构。在此基础上可以由蜘蛛种群迭代进化得到优化后 GM(1,1)的参数序列,通过检测参数序列的相关阈值来判定节点是否发生异常。实验仿真结果表明,与 OMP-IGM 等异常检测方法相比,该方法的异常检测准确率提高了约 7%~33%,网络能耗降低了约 18%~43%。

关键词: 无线传感器网络;异常事件检测;压缩感知;群居蜘蛛优化;信号重构算法

中图分类号: TP393 **文献标志码:** A **文章编号:** 0253-987X(2017)02-0040-07

An Anomaly Detection Method for Wireless Sensor Networks Based on Compressed Sensing and GM (1,1)

LIU Zhouzhou^{1,2}, LI Shining²

(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: A new anomaly detection scheme for wireless sensor networks (WSNs) based on an improved reconstruction method of compressed sensing (CS) and the intelligent optimizing GM (1, 1) is proposed to improve the accuracy of existing anomaly detection algorithms and to reduce the network energy consumption. A double WSNs heterogeneous anomaly detection model is established, and the CS technology is used to process the upper observation nodes data collected from lower detection nodes. An effective sparse matrix and a measurement matrix are constructed by combining the anomaly detection model characteristics, then an orthogonal transformation pretreatment strategy is redefined for the measurement matrix such that the observation dictionary of CS satisfies the restricted isometry property (RIP). Since the data sparsity for CS is unknown, a new CS reconstruction algorithm based on discrete social spider optimization algorithm is proposed to realize the accurate reconstruction of the detection node data, and an

收稿日期: 2016-06-28。 作者简介: 刘洲洲(1981—),男,博士,副教授。 基金项目: 国家自然科学基金资助项目(61401499);陕西省教育厅科研计划项目资助(16JK1395)。

网络出版时间: 2016-11-24 网络出版地址: <http://www.cnki.net/kcms/detail/61.1069.T.20161124.1853.002.html>

improved GM (1, 1) intelligent optimization scheme for anomaly detection is designed to achieve a reliable prediction of abnormal nodes in the network. The parameters of GM (1, 1) are optimized through the iteration of the spider population, and abnormalities of nodes are determined by detecting the relevant thresholds of the parameter sequences. Experimental simulation results and comparisons with other anomaly detection algorithms show that the accuracy of the proposed scheme increases by about 7% to 33%, and the network energy consumption reduces by about 18% to 43%.

Keywords: wireless sensor networks; anomaly event detection; compressed sensing; social spider optimization algorithm; signal reconstruction method

异常事件检测作为无线传感器网络(WSNs)的重要应用之一,能够及时准确检测到森林火灾、危险化学品泄漏等紧急事件,因此在城市消防、大规模环境监测、跟踪定位等领域有着广泛应用^[1]。然而,由于受到 WSNs 能量、带宽以及网络节点部件等不可靠性的影响^[2],节点会处于非正常工作状态,导致产生错误数据,进而影响了 WSNs 异常检测的准确性,此外,为降低 WSNs 能耗,通常采用少部分节点工作的方式来延长网络寿命。因此,如何利用较少的工作节点实现稳定可靠的异常事件检测已成为 WSNs 热点的研究领域^[3]。

针对异常事件检测问题,学者们开展了一系列深入研究,文献[4]利用压缩感知技术,在构建自回归模型的基础上,提出了一种有效识别外部异常和内部异常数据检测方法,但是该方法需要监测数据稀疏度等先验信息;肖政宏等设计了一种基于分布式机器学习的异常检测方法^[5],通过采用贝叶斯分类算法,实现了异常事件精确判定;李洪成等将遗传算法与 k -均值算法相结合,提出了基于分布式计算框架的改进 k -均值异常检测方法^[6],仿真结果证明了该方法的有效性,但是该方法受初始中心选择影响较大。由于 WSNs 部署环境恶劣、节点能量有限,目前的异常事件检测方法还难以有效应用于实际环境。

压缩感知(compressed sensing, CS)是一种全新的信号获取与处理方式,一经提出就表现出了强大的生命力。信号重构算法作为压缩感知理论关键技术之一,主要分为组合优化类、凸优化类和贪婪迭代类 3 类重构算法,其研究重点主要集中在如何通过低维观测数据实现高维数据的精确重构。压缩感知理论的提出为 WSNs 异常事件检测研究提供了全新的思路。为了实现稀疏度未知数据的准确分析检测,并且有效降低 WSNs 网络能耗,本文提出了一种联合改进压缩感知重构算法和智能优化 GM

(1,1)的 WSNs 异常检测方法:首先采用基于离散群居蜘蛛优化算法的压缩感知重构算法(discrete social spider optimization reconstruction algorithm,DSSORA),实现了对稀疏度未知信号的精确重构;然后利用压缩感知技术进行数据收集,同时引入测量矩阵正交变换预处理策略,使得观测字典满足约束等距条件(restricted isometry property, RIP)^[7];在此基础上,构建改进 GM(1,1)智能优化异常检测模型,将群居蜘蛛优化算法(social spider optimization,SSO)与 GM(1,1)相结合,最终实现对网络节点异常的可靠预测。

1 问题描述

双层异质 WSNs 异常检测系统模型中的上层网络由 L 个观测传感器节点 $M_i (i=1, 2, \dots, L)$ 组成,主要用于监测底层网络工作状态。低层网络(设定为方形监控区域,并被划分为 N 个网格)由 N 个检测传感器节点 $D_j (j=1, 2, \dots, N)$ 组成,是异常事件检测主体网络。某时刻,低层网络中有 $K (K \ll N, K \text{ 未知})$ 个节点处于工作状态,这些节点将测量数据信号发送给观测节点,经过观测节点数据处理后,传送给监控中心,从而完成对整个网络的状态监控,异常检测模型如图 1 所示。




图 1 WSNs 异常检测系统模型

假定 K 个工作检测节点信号线性叠加,不存在相互之间信号干扰,则第 i 个观测节点 M_i 接收到第

j 个检测节点 D_j 的信号为

$$P_{i,j} = \frac{P_j G_{i,j}}{d_{ij}^\alpha} \quad (1)$$

式中: $G_{i,j}$ 、 d_{ij}^α 分别是 D_j 与 M_i 之间的瑞丽衰减^[8]和信号传播距离, α 为信号衰减指数。因此, M 个观测节点与 N 个检测节点的传输矩阵为

$$\mathbf{G}_{M \times N} = \begin{bmatrix} P_1 G_{1,1}/d_{11}^\alpha & P_2 G_{1,2}/d_{12}^\alpha & \cdots & P_N G_{1,N}/d_{1N}^\alpha \\ P_1 G_{2,1}/d_{21}^\alpha & P_2 G_{2,2}/d_{22}^\alpha & \cdots & P_N G_{2,N}/d_{2N}^\alpha \\ \vdots & \vdots & & \vdots \\ P_1 G_{M,1}/d_{M1}^\alpha & P_2 G_{M,2}/d_{M2}^\alpha & \cdots & P_N G_{M,N}/d_{MN}^\alpha \end{bmatrix} \quad (2)$$

将所有检测节点信号值用向量 $\mathbf{s}_{N \times 1} = [s_1, \dots, s_j, \dots, s_N]^T$ 表示, 当节点 D_j 处于非工作状态时, 其信号值 $s_j = 0$, 由于工作节点数量 $K \ll N$, 因此 $\mathbf{s}_{N \times 1}$ 为稀疏度为 K 的 $N \times 1$ 维向量。此时, 可以采用压缩感知理论实现对 $\mathbf{s}_{N \times 1}$ 的精确重构, 从而得到工作检测节点相关信息。

2 基于离散群居蜘蛛优化的压缩感知重构算法

2.1 压缩感知理论

压缩感知理论认为当某个信号能够通过稀疏矩阵进行稀疏表示时, 可以用一个与稀疏矩阵不相关的测量矩阵将该信号转化到低维信号空间, 并通过一定的重构方法实现原始信号精确重构。对于 N 维信号 $\mathbf{x}_{N \times 1}$, 可以用正交矩阵 $\Psi_{N \times N} = \{\psi_1, \dots, \psi_N\}$ 进行表示, 即

$$\mathbf{x}_{N \times 1} = \Psi_{N \times N} \mathbf{s}_{N \times 1} \quad (3)$$

式中: $\mathbf{s}_{N \times 1}$ 为 $N \times 1$ 维向量。当 $\mathbf{s}_{N \times 1}$ 仅有 K ($K \ll N$) 个非零系数时, 则 $\mathbf{s}_{N \times 1}$ 在 $\Psi_{N \times N}$ 是稀疏的, 稀疏度为 K 。通过非相关测量矩阵 $\Phi_{M \times N}$ 将 $\mathbf{x}_{N \times 1}$ 投影到低维测量向量 $\mathbf{y}_{M \times 1}$ 上, 得到 M 个测量数据, 即

$$\mathbf{y}_{M \times 1} = \Phi_{M \times N} \mathbf{x}_{N \times 1} = \mathbf{A}_{M \times N} \mathbf{s}_{N \times 1} = \mathbf{A} \mathbf{s} \quad (4)$$

式中: $\mathbf{A}_{M \times N} = \Phi_{M \times N} \Psi_{N \times N}$ 。当 $M \ll N$ 时, 式(4)为欠定方程组, 但如果 $\mathbf{s}_{N \times 1}$ 足够稀疏, 而且 $\mathbf{A}_{M \times N}$ 满足 RIP 条件时, 可以通过求解最小 l_0 范数稀疏重构出 $\mathbf{s}_{N \times 1}$, 即

$$\min \|\mathbf{s}\|_{l_0} \quad \text{s.t.} \quad \mathbf{y} = \mathbf{A} \mathbf{s} = \Phi \Psi \mathbf{s} \quad (5)$$

2.2 DSSORA 算法实现

研究表明, 求解最小 l_0 范数问题属于 NP-hard 问题, 因此, 本文将群居蜘蛛优化算法 (SSO)^[9] 应用到稀疏重构算法中 (SSO 基本理论参考文献[9], 这里不再赘述), 为了使得 SSO 应用于离散优化问题, 对离散蜘蛛优化算法 (discrete social spider optimi-

zation, DSSO) 进行研究, 重新定义离散蜘蛛编码方式, 设计离散蜘蛛迭代进化策略。通过蜘蛛种群不断协同进化, 以获得稀疏结果中非零元素的位置信息, 最后利用最小二乘法得到非零元素的幅度信息, 从而实现了稀疏数据重构。

定义 1 离散蜘蛛编码 对于蜘蛛个体编码 $F_i = (F_{i1}, F_{i2}, \dots, F_{iN})$ (以雌性蜘蛛为例), 定义编码位 F_{ij} ($j=1, 2, \dots, N$) 随机取值 0 或 1, 且取值为 1 的编码位数为 K 。

目前, 群居蜘蛛优化算法主要应用于连续优化问题。当采用定义 1 蜘蛛编码方式时, 如果仍沿用传统的蜘蛛更新策略会产生大量不符合要求的解, 严重降低了算法收敛效率, 因此需要重新设计蜘蛛更新策略。

定义 2 蜘蛛编码位变换算子 对于蜘蛛个体 $F_i = (F_{i1}, \dots, F_{im}, \dots, F_{in}, \dots, F_{iN})$, 编码位 F_{im} 变换算子 $T_{im}: F_{im} \leftrightarrow F_{in}$ 定义为随机选取编码位 F_{in} 与 F_{im} 交换编码位置 ($m, n \in \{1, 2, \dots, N\} \wedge m \neq n$)。

定义 3 离散蜘蛛进化算子 对于蜘蛛个体 $F_i = (F_{i1}, F_{i2}, \dots, F_{iN})$ 和 $F_j = (F_{j1}, F_{j2}, \dots, F_{jN})$, 定义 F_i 到 F_j 的进化算子为 $\Theta_i: F_i \rightarrow F_j$, 即

$$\Theta_i: F_i \rightarrow F_j = F_i + \{T_{i1}, T_{i2}, \dots, T_{iN}\} \quad (6)$$

式中: $\{T_{i1}, T_{i2}, \dots, T_{iN}\}$ 表示编码位变换算子组合。显然, 不同蜘蛛个体之间可以通过一系列编码变换算子实现相互转化, 即 $1 \leq l \leq N-1$ 。当定义蜘蛛进化算子后, 蜘蛛个体迭代更新方式可以描述为 (以雌性蜘蛛为例)

$$\Theta_i: F_i \rightarrow F_i^{\text{new}} = \begin{cases} F_i + \alpha \otimes \langle \Theta_i: F_i \rightarrow S_c \rangle + \beta \otimes \langle \Theta_i: F_i \rightarrow S_b \rangle, & r_m \leq PF \\ F_i - \alpha \otimes \langle \Theta_i: F_i \rightarrow S_c \rangle - \beta \otimes \langle \Theta_i: F_i \rightarrow S_b \rangle, & \text{其他} \end{cases} \quad (7)$$

式中: S_c 、 S_b 分别为距离 F_i 最近且权重高的个体和雌性子群中权重最高的个体; $\alpha \otimes \langle \Theta_i: F_i \rightarrow S_c \rangle$ 表示随机选取 $\Theta_i: F_i \rightarrow F_j$ 中 α 个编码位变换算子进行编码位变换。采用式(7)更新策略实质就是合理调换蜘蛛内部编码位, 在向种群优秀个体学习的同时, 增加变异性, 从而提高了种群样本多样性, 也保证算法最终能够收敛于最优解。

定义 5 目标函数 对于蜘蛛个体, 目标函数的定义为

$$\min J(\mathbf{s}) = \|\mathbf{y} - \Phi \Psi \mathbf{s}\|_2, \mathbf{s} \in \mathbf{R}^N \quad (8)$$

式中: $\mathbf{s}$ 表示稀疏重构信号, 即蜘蛛个体编码方式。

在复杂度计算方面, DSSO 种群初始化计算复

杂度为 $O(F)$ (F 为种群规模), 蜘蛛编码进化更新计算复杂度为 $O(\alpha F \log N) + O(\beta F \log N)$, 蜘蛛种群最优解更新计算复杂度为 $O(F \log F)$, 故每次迭代算法计算复杂度为 $C = O(F) + O(\alpha F \log N) + O(\beta F \log N) + O(F \log F)$, 所以 DSSO 计算复杂度为

$$\mathbf{x}_{N \times 1} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{bmatrix} = \begin{bmatrix} s_1 P_1 G_{1,1}/d_{11}^a + s_2 P_2 G_{1,2}/d_{12}^a + \cdots + s_N P_N G_{1,N}/d_{1N}^a \\ s_1 P_1 G_{2,1}/d_{21}^a + s_2 P_2 G_{2,2}/d_{22}^a + \cdots + s_N P_N G_{2,N}/d_{2N}^a \\ \vdots \\ s_1 P_1 G_{N,1}/d_{N1}^a + s_2 P_2 G_{N,2}/d_{N2}^a + \cdots + s_N P_N G_{N,N}/d_{NN}^a \end{bmatrix} = \begin{bmatrix} P_1 G_{1,1}/d_{11}^a & P_2 G_{1,2}/d_{12}^a & \cdots & P_N G_{1,N}/d_{1N}^a \\ P_1 G_{2,1}/d_{21}^a & P_2 G_{2,2}/d_{22}^a & \cdots & P_N G_{2,N}/d_{2N}^a \\ \vdots & \vdots & & \vdots \\ P_1 G_{N,1}/d_{N1}^a & P_2 G_{N,2}/d_{N2}^a & \cdots & P_N G_{N,N}/d_{NN}^a \end{bmatrix} \begin{bmatrix} s_1 \\ s_2 \\ \vdots \\ s_N \end{bmatrix} = \Psi \mathbf{s} \quad (9)$$

根据压缩感知理论, 原则上只需要 M 个观测传感器节点测量值 $\mathbf{y}_{M \times 1} = [y_1, y_2, \cdots, y_M]^T$ 就能够实现稀疏信号重构, 即

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_M \end{bmatrix} = \begin{bmatrix} \Phi_{1,1} x_1 + \cdots + \Phi_{N,1} x_N \\ \Phi_{1,2} x_1 + \cdots + \Phi_{N,2} x_N \\ \vdots \\ \Phi_{1,M} x_1 + \cdots + \Phi_{N,M} x_N \end{bmatrix} = \begin{bmatrix} \Phi_{1,1} & \Phi_{1,2} & \cdots & \Phi_{1,N} \\ \Phi_{2,1} & \Phi_{2,2} & \cdots & \Phi_{2,N} \\ \vdots & \vdots & & \vdots \\ \Phi_{M,1} & \Phi_{M,2} & \cdots & \Phi_{M,N} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{bmatrix} = \Phi \mathbf{x} \quad (10)$$

式中: $\Phi_{i,j} = 1$ 表示网格 i 上存在传感器 j , 否则 $\Phi_{i,j} = 0$; Φ 为测量矩阵。

根据式(9)和(10)构造稀疏矩阵 Ψ 与测量矩阵 Φ , 使得 $\mathbf{y}_{M \times 1} = \Phi \mathbf{x} = \Phi \Psi \mathbf{s} = \mathbf{A} \mathbf{s}$ 。当观测传感器节点 $M = O(c(K+1) \ln(N/K))$ 时, $\mathbf{A}$ 以较大概率满足 RIP 条件。

2.4 测量矩阵正交变换预处理策略

为尽可能使用较少观测传感器节点实现异常事件监测, 本文采用测量矩阵正交变换预处理策略, 其工作特点是在式(4)中引入线性变换算子 $\mathbf{T}$, 即

$$\left. \begin{aligned} \mathbf{y}' &= \mathbf{T} \mathbf{y} = \mathbf{T}(\mathbf{A} \mathbf{s} + \boldsymbol{\varepsilon}) \\ \mathbf{T} &= \mathbf{Q} \mathbf{A}^*, \mathbf{Q} = \text{orth}(\mathbf{A}^T)^T \end{aligned} \right\} \quad (11)$$

式中: $\mathbf{y}'$ 为测量值; $\boldsymbol{\varepsilon}$ 为 $M \times 1$ 高斯白噪声; $\mathbf{A}^*$ 为矩阵 $\mathbf{A}$ 的逆变换算子; $\text{orth}(\cdot)$ 表示矩阵列正交变换。此时, 测量值 $\mathbf{y}'$ 可以表示为

$$\mathbf{y}' = \mathbf{Q} \mathbf{A}^* (\mathbf{A} \mathbf{s} + \boldsymbol{\varepsilon}) = \mathbf{Q} \mathbf{s}' + \boldsymbol{\varepsilon}' \quad (12)$$

由于 $\mathbf{Q} = \text{orth}(\mathbf{A}^T)^T$ 是正交变换矩阵, 因此能够很好地满足 RIP 条件。

$T_{\max} C$ ($T_{\max}$ 为最大迭代次数)。

2.3 稀疏矩阵与测量矩阵设计

如果在低层网络每个网格中同时部署一个观测传感器节点, 则 N 个观测传感器节点的测量信号 $\mathbf{x}_{N \times 1}$ 为

3 改进 GM(1,1) 智能优化异常检测

3.1 基本 GM(1,1) 模型

GM(1,1) 模型^[10] 是当前应用较为广泛的灰色预测模型之一, 其数据样本空间允许少到 4 个, 因此非常适应于 WSNs 异常检测要求。设 $x^{(0)} = (x^{(0)}(1), x^{(0)}(2), \cdots, x^{(0)}(K))$ 为 K 个数据样本空间, 对 $x^{(0)}$ 进行 AGO 变化得到新序列 $x^{(1)} = (x^{(1)}(1), x^{(1)}(2), \cdots, x^{(1)}(K))$, 即

$$x^{(1)}(1) = x^{(0)}(1); x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i) \quad k \in (1, 2, \cdots, K) \quad (13)$$

对 $x^{(1)}$ 进行 MEAN(紧邻均值)操作, 得到白化背景值 $z^{(1)} = (z^{(1)}(2), z^{(1)}(3), \cdots, z^{(1)}(K))$, 即

$$z^{(1)}(k) = 0.5 x^{(1)}(k) + 0.5 x^{(1)}(k-1) \quad k = 2, 3, \cdots, K \quad (14)$$

因此, 可以构建 GM(1,1) 灰微分方程模型, 即

$$x^{(0)}(k) + a z^{(1)}(k) = b \quad (15)$$

式中: a, b 分别为发展系数和灰作用量。GM(1,1) 白化模型为

$$\frac{dx^{(1)}}{dt} + a x^{(1)} = b \quad (16)$$

利用最小二乘法求出参数 (a, b) , 通过求解方程(16)可以得到预测值序列 $\hat{x}^{(0)}$ 。根据 CM(1,1) 灰微分方程模型有

$$\left. \begin{aligned} \hat{x}^{(1)}(k+1) &= [x^{(0)}(1) - b/a] e^{-ak} + b/a \\ \hat{x}^{(0)}(k+1) &= \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k) \end{aligned} \right\} \quad (17)$$

3.2 智能优化 GM(1,1) 算法

对于 $z^{(1)}$ 序列, 其白化背景值是在 $x^{(1)}(k)$ 和 $x^{(1)}(k-1)$ 均值基础上产生的, 然而在实际训练过程中不可能满足这个条件, 因此引入参数序列 $\lambda =$

$(\lambda_2, \lambda_3, \dots, \lambda_K)$ 构造新的白化背景值序列,即

$$z^{(1)}(k) = (1 - \lambda_k)x^{(1)}(k) + \lambda_k x^{(1)}(k-1) \quad k = 2, 3, \dots, K \quad (18)$$

λ 的取值决定了预测结果的准确度,为了得到最优参数 λ ,引入SSO算法,通过蜘蛛种群不断迭代进化,最终得到最优解。

取蜘蛛个体编码为参数序列 $\lambda = (\lambda_2, \lambda_3, \dots, \lambda_K)$,定义SSO优化目标函数为

$$\min J(x^{(0)}, \lambda) = \left[\frac{\sum_{k=1}^K (\hat{x}^{(0)}(k) - x^{(0)}(k))}{K-1} \right]^{1/2} \quad (19)$$

式中: $\hat{x}^{(0)}(k)$ 为 $x^{(0)}(k)$ 的预测值序列。基于SSO算法的参数序列 λ 求解过程实质为SSO算法函数优化问题具体应用(具体实现流程不再赘述),当得到最优 λ 后,设定 t 时刻异常阈值 Γ_t 为

$$\Gamma_t = \omega_1(\mu_x + \omega_2 \sigma_x) + (1 - \omega_1)\Gamma_{t-1} \quad (20)$$

式中: ω_1, ω_2 为调整系数; μ_x, σ_x 分别为序列 x 的均值和方差。对于工作检测传感器节点 D_j ,如果其测量值与预测值满足 $|\hat{x}_t^{(0)}(D_j) - x_t^{(0)}(D_j)| \geq \Gamma_t$,则判定该节点发生异常。从式(20)可以看出,异常阈值 Γ_t 随着时间变化而自适应调整,有利于提高异常检测准确率。图2给出了本文基于改进压缩感知重构算法和智能优化GM(1,1)的WSNs异常检测方法(DSSORA-IGM(1,1))实现框图。




图2 本文的WSNs异常检测方法实现框图

4 仿真实验分析

4.1 实验设置

低层监控区域内按照一定规则部署500个检测传感器节点,选取10天内WSNs温度测量数据进行仿真试验,仿真平台为Matlab2012。检测传感器节点采用与文献[11]相同的能量模型,DSSO相关参数设置参考文献[12]。为进一步分析本文WSNs异常检测方法DSSORA-IGM(1,1)的性能,选取基于OMP重构算法的WSNs异常检测方法OMP-IGM(1,1)、文献[13]提出的WSNs网络时间检测方法以及文献[14]提出的异常检测方法进行对比实验,主要采用误警率 P_f 、漏检率 P_m 和相对误差 E 3个评价指标进行性能评估,计算公式如下

$$\left. \begin{aligned} P_f &= \frac{N - \|x - \hat{x} + 1\|_{l_0}}{N - \|x\|_{l_0}} \\ P_m &= \frac{N - \|x - \hat{x} - 1\|_{l_0}}{\|x\|_{l_0}} \\ E &= \frac{\|x - X\|_2}{\|x\|_2} \end{aligned} \right\} \quad (21)$$

式中: X 为重构信号; P_f 为误警率; P_m 为漏检率; E 为相对误差。

4.2 实验结果分析

4.2.1 4种检测方法性能比较 在上层网络部署 $M=50$ 个观测传感器节点,分别采用4种检测方法进行实验,实验结果取100次仿真平均值。图3给出了稀疏度 K 未知时采用DSSORA-IGM(1,1)和OMP-IGM(1,1)方法重构信号非零元素的位置信息结果,图4给出了稀疏度 $K=10$ 时4种检测方法的性能对比。




图3 2种检测方法重构信号非零元素的位置信息对比


从图3可以看出,当稀疏度未知的情况下,本文DSSORA-IGM(1,1)方法基本实现了原始信号非零位置精确定位,而OMP-IGM(1,1)方法则无法实现对非零位置的准确定位,不仅存在4处非零位置错误定位,而且增加了一处非零位置,这表明DSSORA-IGM(1,1)方法能够实现对稀疏度未知信号的准确重构。

从图4可以看出,在稀疏度已知的情况下,随着实验次数不断增加,4种检测方法的误警率、漏检率和相对误差明显降低,而能耗则趋于平稳,并且DSSORA-IGM(1,1)方法的各种指标要优于其他3种方法,特别是能耗,远远低于其他3种检测方法。


4.2.2 参数 M 和 K 对检测方法性能影响分析 为进一步分析参数 M 和 K 对检测方法性能影响,分别设置不同 M 和 K ,对比分析DSSORA-IGM(1,1)和OMP-IGM(1,1)方法的检测性能。图5给出了 K 未知、不同 M 时,2种检测方法的性能对比,图6给出了 $M=50$ 、不同 K 时2种检测方法的性能对比。

从图5可以看出,在稀疏度未知的情况下,随着 M 取值不断增加,误警率、漏检率明显下降,特别是对于DSSORA-IGM(1,1)方法,当 $M \geq 100$ 时, P_f


和 P_m 几乎为 0,而 OMP-IGM(1,1)方法的误警率和漏检率仍然较高,都在 50%以上。从图 6 可以看出,随着 K 取值不断增加,误警率、漏检率明显增高,而 DSSORA-IGM(1,1)要优于 OMP-IGM(1,1)




(a) 误警率



(b) 漏检率




(c) 相对误差




(d) 能耗

图 4 4 种检测方法的性能对比



(a) 漏检率 (b) 误警率
图 5 不同 M 取值下 2 种检测方法的性能对比



(a) 误警率 (b) 漏检率
图 6 不同 K 取值下 2 种检测方法的性能对比

方法,但是当 $K \geq 100$ 时,2 种检测方法几乎失效。
仿真实验结果表明,基于离散群居蜘蛛优化算法的压缩感知重构算法能够完成对稀疏度未知信号的精确重构,而测量矩阵正交变换预处理策略的引入,提高了信号重构精度,改进的智能优化 GM(1,1)模型使得 WSNs 检测方法具有较高的检测准确率,而且网络能耗相对较低。

5 结束语

本文提出了一种基于改进压缩感知重构算法和智能优化 GM(1,1)的 WSNs 异常检测方法,该方法无需知道数据稀疏度等先验信息,能够准确实现网络节点异常的可靠预测,对 WSNs 异常检测研究具有一定借鉴意义。后续工作将进一步分析研究该方法的可靠性、可移植性及其在复杂噪声背景下的应用。

参考文献:

[1] 穆天圆, 乔学工, 张敏. 基于 Voronoi 图的蜂群优化算法在 WSN 覆盖中的应用 [J]. 传感技术学报, 2015, 28(10): 1525-1530.
MU Tianyuan, QIAO Xuegong, ZHANG Min. Application of bee colony optimization algorithm based on Voronoi graph in WSN coverage [J]. Journal of Sensing Technology, 2015, 28(10): 1525-1530.
[2] 张波, 刘郁林, 王开, 等. 基于概率稀疏随机矩阵的压缩数据收集方法 [J]. 电子与信息学报, 2014, 36

- (6): 1478-1484.
- ZHANG Bo, LIU Yulin, WANG Kai, et al. Compression of probabilistic sparse random based on the matrix data collection method [J]. Journal of Electronics and Information Technology, 2014, 36(6): 1478-1484.
- [3] 肖政宏, 陈志刚, 李庆华. WSN 中基于分布式机器学习的异常检测仿真研究 [J]. 系统仿真学报, 2011, 23(1): 121-127.
- XIAO Zhenghong, CHEN Zhigang, LI Qinghua. WSN based distributed machine learning anomaly detection simulation [J]. Journal of System Simulation, 2011, 23(1): 121-127.
- [4] WANG Jin, TANG Shaojie, YIN Baocai, et al. Distributed compressive sampling for lifetime optimization in dense wireless sensor networks through intelligent compressive sensing [C]//IEEE International Conference on Computer Communications. Piscataway, NJ, USA: IEEE, 2012: 603-611.
- [5] DONOHO D. Compressed sensing [J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [6] 李洪成, 吴晓平, 严博. 面向 MANET 异常检测的分布式遗传 k -means 研究 [J]. 通信学报, 2015, 36(11): 167-173.
- LI Hongcheng, WU Xiaoping, YAN Bo. Distributed genetic k -means for MANET anomaly detection [J]. Journal of Communication, 2015, 36(11): 167-173.
- [7] 吴迪, 王奎民, 赵玉新, 等. 分段正则化正交匹配追踪算法 [J]. 光学精密工程, 2014, 22(5): 1395-1402.
- WU Di, WANG Kuimin, ZHAO Yuxin, et al. Piece-wise regularized orthogonal matching pursuit algorithm [J]. Optics and Precision Engineering, 2014, 22(5): 1395-1402.
- [8] 焦李成, 杨淑媛, 刘芳, 等. 压缩感知回顾与展望 [J]. 电子学报, 2011, 39(7): 1651-1662.
- JIAO Licheng, YANG Shuyuan, LIU Fang, et al. Review and prospect of compressed sensing [J]. Journal of Electronics, 2011, 39(7): 1651-1662.
- [9] CUEVAS E, CIENFUEGOS M, ZALDIVA D, et al. A swarm optimization algorithm inspired in the behavior of the social spider [J]. Expert System with Applications, 2013, 40(16): 6374-6384.
- [10] 江艺羨, 张岐山. 近似非齐次无偏 GM(1, 1)模型的递推解法及应用 [J]. 控制与决策, 2015, 30(12): 2199-2204.
- JIANG Yixian, ZHANG Qishan. Approximate nonhomogeneous unbiased GM (1, 1) recursive solution and application of model [J]. Control and Decision, 2015, 30(12): 2199-2204.
- [11] CHENG C T, TSEC K, LAU F C M. A delay-aware data collection network structure for wireless sensor networks [J]. IEEE Sensors Journal, 2011, 11(3): 699-710.
- [12] 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 Yanjiao, LI Xiaojie, XIAO Jing. The cluster optimization algorithm based on spider dynamic learning strategy [J]. Control and Decision, 2015, 30(9): 1575-1582.
- [13] 赵秀兰, 李克清. 弱稀疏性下的无线传感器网络事件检测算法 [J]. 计算机应用与软件, 2014, 31(3): 104-107.
- ZHAO Xiulan, LI Keqing. An event detection algorithm for wireless sensor networks with weak sparsity [J]. Computer Applications and Software, 2014, 31(3): 104-107.
- [14] 李鹏, 王建新, 曹建农. 无线传感器网络中基于压缩感知和 GM(1, 1)的异常检测方案 [J]. 电子与信息学报, 2015, 37(7): 1586-1590.
- LI Peng, WANG Jianxin, CAO Jiannong. Anomaly detection scheme based on compressed sensing and GM(1, 1) in wireless sensor networks [J]. Journal of Electronics and Information, 2015, 37(7): 1586-1590.

(编辑 刘杨)

(上接第 26 页)

- [12] BIN G, GAO X, YAN Z, et al. An online multi-channel SSVEP-based brain-computer interface using a canonical correlation analysis method [J]. Journal of Neural Engineering, 2009, 6(4): 1771-1779.
- [13] ZHANG Y, PENG X, CHENG K, et al. Multivariate synchronization index for frequency recognition of SSVEP-based brain-computer interface [J]. Journal of Neuroscience Methods, 2014, 221(2): 32-40.
- [14] WU C H, CHANG H C, LEE P L, et al. Frequency recognition in an SSVEP-based brain computer interface using empirical mode decomposition and refined generalized zero-crossing [J]. Journal of Neuroscience Methods, 2011, 196(1): 170-181.

(编辑 武红江)