

一种新的无线传感器网络中异常节点检测定位算法

蒋俊正^{*①②} 杨杰^① 欧阳缮^①

^①(桂林电子科技大学信息与通信学院 桂林 541004)

^②(广西无线宽带通信与信号处理重点实验室 桂林 541004)

摘要: 无线传感器网络中异常节点检测是确保网络数据准确性和可靠性的关键步骤。基于图信号处理理论, 该文提出了一种新的无线传感器网络异常节点检测定位算法。新算法首先对网络建立图信号模型, 然后基于节点域-图频域联合分析的方法, 实现异常节点的检测和定位。具体而言, 第1步是利用高通图滤波器提取网络信号的高频分量。第2步首先将网络划分为多个子图, 然后筛选出子图输出信号的特定频率分量。第3步对筛选出的子图信号进行阈值判断从而定位疑似异常的子图中心节点。最后通过比较各子图的节点集合和疑似异常节点集合, 检测并定位出网络中的异常节点。实验仿真表明, 与已有的无线传感器网络中异常检测方法相比, 新算法不仅有着较高的异常检测概率, 而且异常节点的定位率也较高。

关键词: 无线传感器网络; 异常检测; 图信号处理; 子图; 节点域-图频域联合分析

中图分类号: TP393

文献标识码: A

文章编号: 1009-5896(2018)10-2358-07

DOI: 10.11999/JEIT171207

Novel Method for Outlier Nodes Detection and Localization in Wireless Sensor Networks

JIANG Junzheng^{①②} YANG Jie^① OUYANG Shan^①

^①(School of Information and Communication, Guilin University of Electronic Technology, Guilin 541004, China)

^②(Guangxi Key Laboratory of Wireless Wideband Communication and Signal Processing, Guilin 541004, China)

Abstract: The outlier nodes detection and localization in Wireless Sensor Networks (WSNs) is a crucial step in ensuring the accuracy and reliability of network data acquisition. Based on the theory of graph signal processing, a novel algorithm is presented for outlier detection and localization in WSNs. The new algorithm first builds the graph signal model of the network, then detect the location of the outlier based on the method of vertex-domain and graph frequency-domain joint analysis. Specifically speaking, the first step of algorithm is extracting the high-frequency component of the signal using a high-pass graph filter. In the second step, the network is decomposed into a set of sub-graphs, and then the specific frequency components of the output signal in sub-graphs are filtered out. The third step is to locate the suspected outlier center-nodes of sub-graphs based on the threshold of the filtered sub-graphs signal. Finally, the outlier nodes in the network are detected and located by comparing the set of nodes of each sub-graph with the set of suspected outlier nodes. Experimental results show that compared with the existing outlier detection methods in networks, the proposed method not only has higher probability of outlier detection, but also has a higher positioning rate of outlier nodes.

Key words: Wireless Sensor Networks (WSNs); Outlier detection; Graph signal processing; Sub-graphs; Vertex-domain and graph frequency-domain joint analysis

收稿日期: 2017-12-21; 改回日期: 2018-05-18; 网络出版: 2018-07-30

*通信作者: 蒋俊正 jzjiang@guet.edu.cn

基金项目: 国家自然科学基金(61761011, 61371186), 广西自然科学基金(2017GXNSFAA198173), 桂林电子科技大学研究生教育创新计划(2018YJCX34)

Foundation Items: The National Natural Science Foundation of China (61761011, 61371186), The Natural Science Foundation of Guangxi (2017GXNSFAA198173), The Innovation Project of GUET Graduate Education (2018YJCX34)

1 引言

无线传感器网络(Wireless Sensor Networks, WSNs)是由数量众多的传感器节点构成的多跳网络, 并且不同节点之间可以进行通信^[1]。伴随着无线通信和电子技术的快速发展, 无线传感器网络已经广泛应用于环境监控^[2]、目标追踪^[3]、精细农业生产^[4]等多个重要领域^[5]。然而传感器节点由于其储能有限、监测环境较为复杂、和节点本身容易遭受外界攻击等原因, 容易造成网络中的部分节点出现异常, 从而影响采集数据本身的真实性和稳定性^[6]。为了保证网络收集到高质量的数据, 异常节点检测和定位是无线传感器技术中的重要步骤。

无线传感器网络异常节点是指在传感器网络中, 由于其中的部分节点出现故障, 导致采集的网络数据中存在偏离整体中其他数据的单个或多个数据^[7], 它往往不容易通过直接的数据观察而检测到, 需要通过对采集到的网络数据进行处理, 将异常数据从数据集合中筛选出来, 从而检测和定位网络中的异常节点。由于异常节点检测工作在传感器网络的相关研究中具有重要的意义, 已有学者提出了一些异常节点检测方法。其中基于统计学的方法是较早被提出的^[8], 这种方法检测率较高, 但是需要提前知晓数据集合的先验信息建立统计模型, 而在许多的实际情况中, 数据的统计模型较难建立。此外, 聚类分析的方法也可用于异常节点检测^[9], 该方法的优势在于不需要数据的统计模型, 即可对当前采集的数据进行处理, 但是其中簇的大小及个数较难确定。此外常见的网络异常节点检测方法还有分类方法^[10]和基于最近邻居的方法^[11]。目前学者们提出的异常节点检测方法大多是基于网络中节点信号自身的时间关联性, 然而基于网络拓扑结构的异常检测研究相对较少, 其主要原因是没有一种广泛适用的数学模型将网络信号和网络拓扑结构联系起来。近年来, 随着图信号处理理论的逐步建立, 大规模非规则信号处理成为新兴的研究领域, 该理论将网络的拓扑结构和网络数据通过图信号模型关联在一起, 为基于拓扑结构的网络异常检测工作提供了一种新的研究模型, 如何利用大规模非规则信号处理的方法对传感器网络进行异常检测和定位成为了很多学者研究的热点问题。

2014年, Sandryhaila和Moura在文献^[12]中提出了基于图高通滤波处理的传感器网络异常检测方法。该方法首先将网络信号进行高通滤波得到输出信号, 再根据输出信号的图频率判断传感器网络是否异常, 即网络中是否存在异常节点。该方法操作简便, 异常检测率较高, 但是该方法仅仅基于图频

谱的阈值判断, 并不能定位出异常节点。而本文算法是基于局部子图处理和节点域-图频域联合分析的方法检测网络是否异常并且定位网络中的异常节点, 为之后的修复工作提供帮助。具体而言, 第1步是利用高通图滤波器提取网络信号的高频分量。第2步将网络划分为多个子图, 并且筛选出子图输出信号的特定频率分量。第3步对筛选出的子图信号进行阈值判断从而定位疑似异常的子图中心节点。最后通过对比网络中各子图的节点集合和第3步中定位得到的疑似异常节点集合, 检测并定位出网络中的异常节点。与文献^[12]中设计的算法相比较, 在对同样的数据集合进行实验仿真的情况下, 本文设计的异常检测算法的检测率更高, 同时还可以定位出网络中异常节点。

2 图信号处理相关知识

图信号处理(graph signal processing)是将传统的规则域数字信号处理延伸到非规则域信号处理的一个新兴的研究工具。它的基本框架是将图(graph)中的每一个节点赋予一个信号值, 生成图信号(graph signal), 并且借助拉普拉斯矩阵的性质对图信号进行处理^[13]。目前关于图信号处理的研究主要包括图信号滤波^[14], 图信号采样^[15], 图信号的加窗傅里叶变换^[16]以及图滤波器组的设计^[17]等。

在本文算法中, 首先建立无线传感器网络的图信号模型 $G = (V, E, \mathbf{W})$, $V = \{v_1, v_2, \dots, v_N\}$ 是传感器节点集合。 $E = \{e_{ij}\}$ 是图模型中边的集合, e_{ij} 表示节点*i*和节点*j*之间有边相连接, 在本文算法中, 我们将每个节点与周围地理距离最近的*S*个节点相连接构成边, 使用图拉普拉斯矩阵 $\mathbf{L} = \mathbf{D} - \mathbf{W}$ 来描述图的拓扑结构。 $\mathbf{W} = \{w_{ij}\}$ 是权矩阵, 其中 w_{ij} 如式(1):

$$w_{ij} = \begin{cases} \frac{a_{ij}}{R_{ij}^2}, & i \neq j \\ 0, & i = j \end{cases} \quad (1)$$

式中, R_{ij} 表示节点*i*和节点*j*之间的欧式距离。当节点*i*和节点*j*之间有边连接, 则 $a_{ij} = a_{ji} = 1$, 反之则为0。图模型的度矩阵 $\mathbf{D} = \text{diag}\{d_i\}$, 其中 $d_i = \sum_{j=1}^N w_{ij}$, $i = 1, 2, \dots, N$ 。

图信号集合 $\mathbf{F} = [\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_M]$ 是一个 $N \times M$ 矩阵, 其中列向量 $\mathbf{f}_m \in \mathbf{R}^N$ 表示传感器网络中某一时刻各个节点的信号值, 其中*N*为网络中传感器节点的个数, *M*为网络信号的连续采样时刻数。 \mathbf{F} 中的 \mathbf{f}_M 表示第*M*时刻采集的信号集, 即需要检测是否含有异常节点的图信号集合; $[\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_{M-1}]$ 是历史信号。在本文算法中 $M = 5$ 。

图拉普拉斯矩阵经过特征值分解 $L = U\Lambda U^{-1}$, 得到关于该矩阵的特征值矩阵 $\Lambda = \text{diag}\{\lambda_i\}$ ($\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_N$)和与特征值相对应的特征向量矩阵 $U = [u_1, u_2, \dots, u_N]$ 。在图信号处理理论中, 由特征向量矩阵所定义的图傅里叶变换^[16]是

$$\tilde{F} = U^{-1}F \quad (2)$$

图拉普拉斯矩阵的特征值 λ_n 代表图信号的不同图频率, u_n 是特征值 λ_n 所对应的特征量。其中, 绝对值较大的特征值对应于图信号的高频部分, 绝对值较小的特征值对应于低频部分^[12]。

3 异常节点检测定位算法

在建立好图信号模型之后, 采用节点域-图频域联合分析方法对异常节点进行检测和定位。如图1所示, 算法流程包括预处理、局部处理、阈值判断和匹配筛选。图1中 F 为传感器网络信号的图信号集合。



图1 异常检测流程图

3.1 预处理

首先, 对图信号进行图高通滤波处理。如图2(a)与图2(b)所示, 这是一个简单的传感器网络的图信号模型, 其中每个节点的垂直方向上的竖线长度表示节点的信号值, 而节点之间的连线表示节点之间的某种关联程度。图2(a)与图2(b)的网络拓扑

结构相同, 但是存在异常节点(如图2(b)所示, 其中用圆圈所标记的节点的信号值相比于图2(a)中的相同位置节点的信号值异常增大)。由于网络中相邻的节点的信号值相近, 所以图信号整体呈现出低频信号的特征, 如图2(c)所示。但是网络中异常节点影响了网络图信号模型的信号平滑度, 从而导致图信号的高频分量增大。为了提取出图信号的高频分量, 将图信号 F 通过高通图滤波器 H 滤波之后得到高频图信号 F^{HP} 为

$$H = \frac{L}{2} \quad (3)$$

$$F^{HP} = HF \quad (4)$$

如图2(f)所示, 当含有异常节点的图信号通过高通滤波器之后, 信号的高频部分会出现异常波峰, 反之不含有异常节点的图高频信号则没有出现异常波峰。但是当网络中的传感器节点数较大时, 对描述网络拓扑结构的拉普拉斯矩阵求逆较为困难, 以至于对整体图信号的图傅里叶变换的计算效率较低, 所以对预处理之后的高频图信号采用局部处理的方法。

3.2 局部处理

局部处理包括两个步骤, 首先是建立各个子图的图模型 $G_i = (V_i, E_i, W_i)$ 和各个子图的子图信号 F_i^{HP} , 然后是提取出各子图中特定图频率分量的子图信号分量 \hat{F}_i^{HP} 。

第1步, 将网络中的每一个节点和它的相邻节

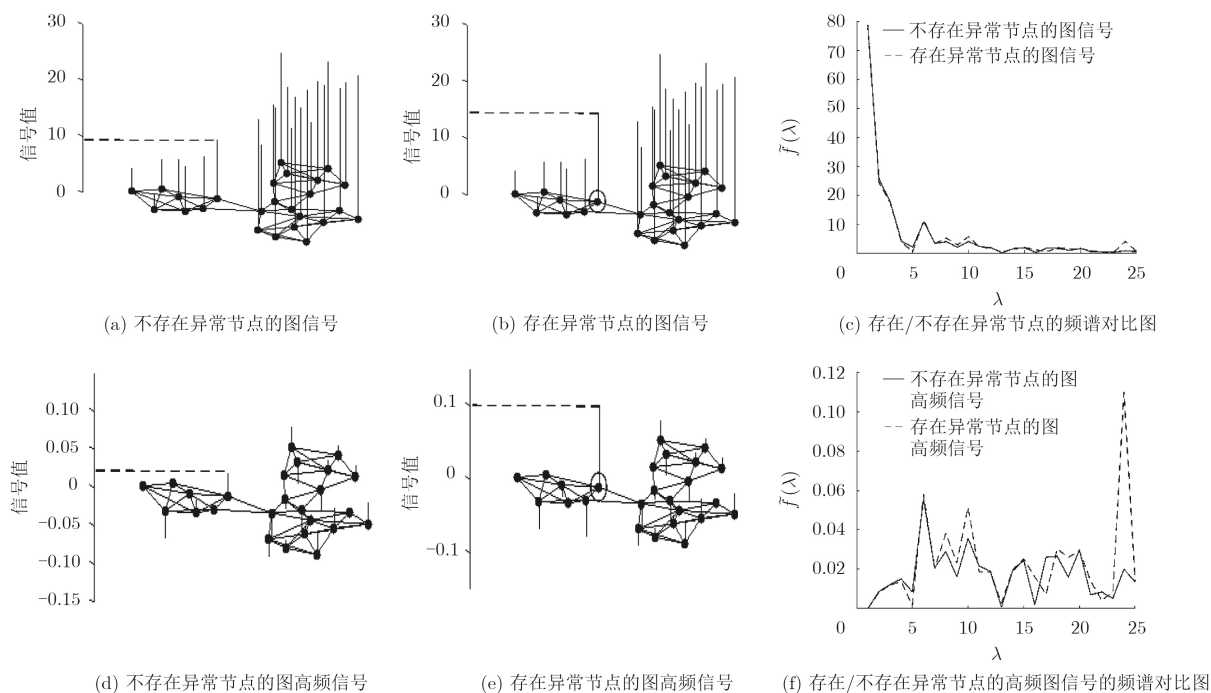


图2 预处理前后信号在节点域-图频域的对比图

点共同构成子图 $G_i = (V_i, E_i, \mathbf{W}_i)$ ($i = 1, 2, \dots, N$), 其中 V_i 和 E_i 分别表示第 i 个子图模型中的节点集合和边的集合。我们将第 i 个子图的中心节点记为 v_i 。第 i 个子图模型 G_i 的权矩阵 $\mathbf{W}_i = \{w_{ij}\}$ ($v_j \in V_i$), 子图 G_i 的度矩阵 \mathbf{D}_i 和拉普拉斯矩阵 \mathbf{L}_i 分别为

$$\mathbf{D}_i = \text{diag} \left(\sum_{n=1}^{N_i} w_i(m, n) \right) \quad (5)$$

$$\mathbf{L}_i = \mathbf{D}_i - \mathbf{W}_i \quad (6)$$

各子图的子图信号 $\mathbf{F}_i^{\text{HP}} = [\mathbf{f}_{i,1}^{\text{HP}}, \mathbf{f}_{i,2}^{\text{HP}}, \dots, \mathbf{f}_{i,M}^{\text{HP}}]$ 是一个 $N_i \times M$ 的矩阵, 其中 N_i 是第 i 个子图中的节点个数, 即 $N_i = |V_i|$, $f_{i,m}^{\text{HP}}(n) = f_m^{\text{HP}}(n)$ ($v_n \in V_i$)。将 \mathbf{L}_i 进行特征值分解之后, 得到关于 \mathbf{L}_i 的特征值矩阵和特征向量矩阵分别是 $\mathbf{\Lambda}_i = \text{diag}\{\lambda_{i,k}\}$ ($k = 1, 2, \dots, N_i$) 和 $\mathbf{U}_i = [\mathbf{u}_{i,1}, \mathbf{u}_{i,2}, \dots, \mathbf{u}_{i,N_i}]$ 。在子图处理中, 同样采用图信号处理中节点域-图频域联合分析方法, 通过子图傅里叶变换^[16]计算出子图信号的图频谱矩阵 $\tilde{\mathbf{F}}_i^{\text{HP}} = [\tilde{\mathbf{f}}_{i,1}^{\text{HP}}, \tilde{\mathbf{f}}_{i,2}^{\text{HP}}, \dots, \tilde{\mathbf{f}}_{i,M}^{\text{HP}}]$ 如式(7)和式(8):

$$\mathbf{L}_i = \mathbf{U}_i \mathbf{\Lambda}_i \mathbf{U}_i^{-1} \quad (7)$$

$$\tilde{\mathbf{F}}_i^{\text{HP}} = \mathbf{U}_i^{-1} \mathbf{F}_i^{\text{HP}} \quad (8)$$

第2步是在各子图中提取出特定图频谱分量的子图信号分量 $\hat{\mathbf{F}}_i^{\text{HP}}$ 。首先, 找出第 i 个子图中的特定图频率 $k_{i,\max}$, 如式(9)所示, $k_{i,\max}$ 是第 i 个子图中当前时刻的频率分量与历史时刻的频率分量的差值最大的图频率。然后通过特定图频率分量 $k_{i,\max}$ 上进行图逆傅里叶变换^[16](即式(10)和式(11)所示), 提取出子图信号 \mathbf{F}_i^{HP} 在特定图频率上的子图信号分量 $\hat{\mathbf{F}}_i$ 。

$$k_{i,\max} = \arg \max \sum_{m=1}^{M-1} \left| \tilde{\mathbf{f}}_{i,M}^{\text{HP}}(k) - \tilde{\mathbf{f}}_{i,m}^{\text{HP}}(k) \right| \quad (9)$$

$$\hat{\mathbf{U}}_i = [\hat{\mathbf{u}}_{i,1}, \hat{\mathbf{u}}_{i,2}, \dots, \hat{\mathbf{u}}_{i,N_i}],$$

$$\hat{\mathbf{u}}_{i,k} = \begin{cases} \mathbf{0}, & k \neq k_{i,\max} \\ \mathbf{u}_{i,k}, & k = k_{i,\max} \end{cases} \quad (10)$$

$$\hat{\mathbf{F}}_i = \hat{\mathbf{U}}_i \tilde{\mathbf{F}}_i^{\text{HP}} \quad (11)$$

3.3 阈值判断

通过比较各子图信号分量 $\hat{\mathbf{F}}_i = \{\hat{\mathbf{f}}_i(p, q)\}$ ($p = 1, 2, \dots, N_i, q = 1, 2, \dots, M$) 中每个节点的当前信号值与历史时刻信号值的差值和设置的阈值进行比较判断, 筛选出疑似异常子图, 并且将疑似异常子图的中心节点视为疑似异常节点。

阈值判断的第1步是通过式(12)和式(13)计算出的第 i 个子图中节点 p 的最小阈值 $\Theta_{\min,i}(p)$ 和最大阈

值 $\Theta_{\max,i}(p)$ 。

$$\Theta_{\min,i}(p) = Q_{1,i}(p) - \tau[Q_{2,i}(p) - Q_{1,i}(p)] \quad (12)$$

$$\Theta_{\max,i}(p) = Q_{2,i}(p) + \tau[Q_{2,i}(p) - Q_{1,i}(p)] \quad (13)$$

在此步骤中, 最小阈值 $\Theta_{\min,i}(p)$ 和最大阈值 $\Theta_{\max,i}(p)$ 是基于箱型图统计方法^[18]而得出的, 超出最小阈值和最大阈值范围的信号节点为疑似异常节点。 $Q_{1,i}(p)$ 是第 i 个子图信号中节点 p 的信号集合 $\hat{\mathbf{f}}_i(p, \hat{q})$ 的下四分位数^[18], $Q_{2,i}(p)$ 是第 i 个子图信号中节点 p 的图信号 $\hat{\mathbf{f}}_i(p, \hat{q})$ 的上四分位数^[18], 其中 $\hat{q} = 1, 2, \dots, M-1$ 。具体的计算方法是将节点 p 的信号集合从小到大进行排序, 在75%位置的即为上四分位数, 在25%位置的即为下四分位数^[18]。参数 τ 的取值是根据箱型图统计方法得出的, 一般情况下 $\tau = 1.5$ 筛选出的异常值为温和异常值^[18], $\tau = 3$ 筛选出的异常值为极端异常值^[18]。在本文算法仿真实验中, 采用的参数 τ 的取值大于1.5。

第2步进行判断筛选, 当第 i 个子图中存在任意节点 p 的当前信号小于该节点的最小阈值 $\Theta_{\min,i}(p)$ 或者大于该节点的最大阈值 $\Theta_{\max,i}(p)$ 时, 则认为子图 G_i 为疑似异常子图, 进而筛选出子图 G_i 的中心节点 v_i , 将满足判断筛选条件的子图的中心节点集合记为疑似异常节点集合 V_A 。

3.4 匹配筛选

通过将上一个步骤中所得到的集合 V_A 与各子图的节点集合 V_i 进行匹配筛选。若 $V_i \not\subset V_A$, 则说明 V_i 的中心节点 v_i 不是异常节点。反之, 若 $V_i \subset V_A$, 则说明 V_i 的中心节点 v_i 是异常节点。如式(14)所示, 通过匹配筛选之后, 得到集合 V' 。

$$V' = \{v_i | V_i \subset V_A\} \quad (14)$$

当集合 V' 为空集时, 说明检测时刻网络中不存在异常节点, 反之, 则说明检测的网络存在异常节点, 并且集合 V' 中的节点即为算法定位出网络中异常节点集合。

为了读者更好地理解匹配筛选的具体过程, 接下来通过一个例子来进行具体的说明。假设建立一个环状图模型如图3所示, 并且在上一步(即3.3节阈值判断)中计算出的集合 $V_A = \{v_1, v_2, v_4, v_5\}$ 。如表1所示, 通过集合 V_i ($i = 1, 2, \dots, 6$) 与集合 V_A 进行匹配筛选, 定位出网络中的异常节点集合 $V' = \{v_2\}$ 。

4 实验仿真结果及分析

本文分别在4种不同的异常情况下进行实验仿真, 首先是单个传感器节点受到干扰, 信号值偏离正常值, 将原本的真实信号值增大; 其次是单个节点由于异常无法工作, 当前时刻的信号值为零;




图3 环状图模型

表1 环状图模型的匹配筛选表

V_i (V_i 的中心节点为 v_i)	匹配筛选	筛选结果
$V_1 = \{v_1, v_2, v_3\}$	$V_1 \not\subset V_A$	v_1 不是异常节点
$V_2 = \{v_1, v_2, v_4\}$	$V_2 \subset V_A$	v_2 是异常节点
$V_3 = \{v_1, v_3, v_5\}$	$V_3 \not\subset V_A$	v_3 不是异常节点
$V_4 = \{v_2, v_4, v_6\}$	$V_4 \not\subset V_A$	v_4 不是异常节点
$V_5 = \{v_3, v_5, v_6\}$	$V_5 \not\subset V_A$	v_5 不是异常节点
$V_6 = \{v_4, v_5, v_6\}$	$V_6 \not\subset V_A$	v_6 不是异常节点

在第3种和第4种情况中，将随机选取某一时刻的5个传感器节点，同时增大选取节点的信号值或将选取节点的信号值均设置零。本文中所有的仿真都是在相同的实验环境下运行的。

在每一次的实验中，首先将温度网络的某一天的传感器网络信号和之前4天的历史信号共同构成的图信号经过高通滤波得到高频图信号。之后，根据3.2节步骤进行局部子图划分，在每个子图中提取特定频率的子图局部信号。然后，根据3.3节步骤通过阈值判断出疑似异常节点。最后，通过3.4节步骤匹配筛选确定网络中的异常节点。在每一组仿真实验的第3步阈值判断中，根据 τ 值的不同，设置不同的最小阈值和最大阈值(式(12)和式(13))。当检测出的节点集合非空集，则认为此次检测异常节点成功，同时若检测出的异常节点集合中包含真实的异常节点，则此次实验定位异常节点成功。

本文算法的检测性能指标包括检测率和定位率。DR表示检测率，它表示检测成功的总次数与实验总次数之比；OPR是异常节点的定位率，即检测出的异常节点集合包含真实异常节点的实验次数与实验总次数之比。具体而言， $OPR(OS \leq K)$ 表示检测出的异常节点集合包括真实的异常节点，且其节点个数不多于 K 。对于不同的仿真情况，实验中 K 分别取5和10。

4.1 美国主要城市温度网络数据

实验仿真的数据集合为2003年全年美国主要城市的日平均温度^[12]。网络中共有150个传感器节

点，所采集的数据是美国150个主要城市的日平均温度，该温度网络信号的最小值为 -17.8°F ，最大值为 104.3°F ，平均值为 43.25°F 。将每个传感器节点与地理距离最近的6个节点连接，建立图信号模型，如图4所示，其中每个节点的垂直方向上的竖线长度表示节点的信号强度。在第1组和第2组中，每一次实验将其中一天的某一个传感器温度增加 20°F 或设置为 0°F 。当参数 τ 取值不同时，测试的次数均为54150次，仿真结果如表2和表3所示。在第3种和第4种情况中，分别随机设置异常时刻，并且将5个传感器温度均增加 20°F 或设置为 0°F 。当参数 τ 取不同值时，均测试50000次，仿真结果分别如表4和表5所示。

当网络中出现单个异常节点时，检测率均在90%以上，异常节点的定位率也保证在85%以上。表4和表5中列出了5个节点异常的情况，检测率均




图4 美国主要城市2003年某日平均气温网络图

表2 美国主要城市温度网络中单个节点信号值异常增大情况的检测指标(%)

τ	DR	OPR	OPR ($OS \leq 5$)
2	98.5	94.2	64.2
3	95.4	89.7	69.3
4	90.6	84.5	69.0

表3 美国主要城市温度网络中单个节点信号值异常置零情况的检测指标(%)

τ	DR	OPR	OPR ($OS \leq 5$)
2	99.7	98.3	67.0
3	99.2	97.7	76.4
4	98.4	96.9	80.4

表4 美国主要城市温度网络中5个节点信号值异常增大情况的检测指标(%)

τ	DR	OPR	OPR ($OS \leq 10$)
2	100.0	72.5	26.1
3	100.0	58.3	24.6
4	99.9	46.5	20.6

表 5 美国主要城市温度网络中5个节点信号值异常
置零情况的检测指标(%)

τ	DR	OPR	OPR (OS \leq 10)
2	100.0	92.5	32.8
3	99.9	89.9	39.9
4	99.9	86.9	42.6

达99.9%，在4种情况下异常节点的定位率也较高。文献[12]对相同的数据集进行实验，将其中某一时刻的单个节点的温度增加相同数值，检测出该时刻异常的概率为89%。

4.2 全球部分海平面温度监测站点数据

实验仿真采用的第2个数据集是全球部分海平面温度监测站点数据集^[19](如图5所示)，共有100个监测站点，1733个时刻的采集数据，数据集的范围从-0.01°C到30.72°C，平均值为19.15°C。同样在4种不同的情况下分别进行检测，但增加的温度值为5°C。




图 5 海平面部分测量站点某时刻的温度传感器网络图

如表6和表7所示，当网络中出现单个异常节点时，网络异常的检测率和网络中异常节点的定位率均较高。而表8和表9中记录的是5个节点出现异常的情况，检测率均达99.9%，而5个异常节点的定位

表 6 海平面部分温度站点网络单节点异常
增大情况的检测指标(%)

τ	DR	OPR	OPR (OS \leq 5)
2	99.9	99.8	78.5
3	99.6	99.4	85.5
4	99.0	98.8	88.6

表 7 海平面部分温度站点网络单节点异常
置零情况的检测指标(%)

τ	DR	OPR	OPR (OS \leq 5)
2	99.8	99.7	81.9
3	99.7	99.5	87.8
4	99.5	99.3	90.6

表 8 海平面部分温度站点网络5个节点异常
增大情况的检测指标(%)

τ	DR	OPR	OPR (OS \leq 10)
2	100.0	98.7	36.7
3	100.0	96.7	41.4
4	99.9	92.9	42.6

表 9 海平面部分温度站点网络5个节点异常
置零情况的检测指标(%)

τ	DR	OPR	OPR (OS \leq 10)
2	100.0	99.6	36.7
3	100.0	99.5	41.8
4	100.0	99.3	44.8

率在两种不同情况下也均达到90%以上。

5 结束语

本文设计了一种新的无线传感器网络异常节点检测定位算法，基于局部子图处理和节点域-图频域联合分析的方法筛选出局部异常子图的中心节点集合，然后通过比较筛选出的中心节点集合与各子图中的节点的匹配度，实现对于网络中异常节点的检测和定位。在4种异常节点存在的不同情况下进行实验仿真，表明本文算法的异常节点检测率和定位率均较高。后续工作将设计在更加复杂情况下的网络异常节点检测和定位算法。

参考文献

- [1] SHUKLA D S, PANDEY A C, and KULHARI A. Outlier detection: A survey on techniques of WSNs involving event and error based outliers[C]. 2014 Innovative Applications of Computational Intelligence on Power, Energy and Controls with their impact on Humanity (CIPECH), Ghaziabad, India, 2014: 113–116. doi: 10.1109/CIPECH.2014.7019101.
- [2] XU Yang and LIU Fugui. Application of wireless sensor network in water quality monitoring[C]. 2017 IEEE International Conference on Computational Science and Engineering (CSE) and International Conference on Embedded and Ubiquitous Computing (EUC), Guangzhou, China, 2017: 368–371. doi: 10.1109/CSE-EUC.2017.254.
- [3] DING Hui. Application of wireless sensor network in target detection and localization[J]. TELKOMNIKA Indonesian Journal of Electrical Engineering, 2013, 11(10): 5734–5740. doi: 10.11591/telkonnika.v11i10.3400.
- [4] ZHU Yingli, SONG Jingjiang, and DONG Fuzhou. Applications of wireless sensor network in the agriculture environment monitoring[J]. Procedia Engineering, 2011, 16(1): 608–614. doi: 10.1016/j.proeng.2011.08.1131.

- [5] AKYILDIZ I F, SU Weilian, SANKAROSUBRAMANIAM Y, *et al.* A survey on sensor networks[J]. *IEEE Communications Magazine*, 2002, 40(8): 102–114. doi: [10.1109/MCOM.2002.1024422](https://doi.org/10.1109/MCOM.2002.1024422).
- [6] 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. doi: [10.11999/JEIT141219](https://doi.org/10.11999/JEIT141219).
LI Peng, WANG Jianxin, and CAO Jiannong. Abnormal event detection scheme based on compressive sensing and GM(1,1) in wireless sensor networks[J]. *Journal of Electronics & Information Technology*, 2015, 37(7): 1586–1590. doi: [10.11999/JEIT141219](https://doi.org/10.11999/JEIT141219).
- [7] SINGH K and UPADHYAYA S. Outlier detection: Applications and techniques[J]. *International Journal of Computer Science Issues*, 2012, 9(1): 307–323.
- [8] ZHANG Yang, HAMM N A S, MERATNIA N, *et al.* Statistics-based outlier detection for wireless sensor networks[J]. *International Journal of Geographical Information Science*, 2012, 26(8): 1373–1392. doi: [10.1080/13658816.2012.654493](https://doi.org/10.1080/13658816.2012.654493).
- [9] ANDRADE A T C, MONTEZ C, MORAES R, *et al.* Outlier detection using k-means clustering and lightweight methods for Wireless Sensor Networks[C]. The 42nd Annual Conference of the IEEE Industrial Electronics Society (IECON 2016), Florence, Italy, 2016: 4683–4688. doi: [10.1109/IECON.2016.7794093](https://doi.org/10.1109/IECON.2016.7794093).
- [10] AYADI A, GHORBEL O, BENSALAH M S, *et al.* Performance of outlier detection techniques based classification in wireless sensor networks[C]. The 13th IEEE Wireless Communications and Mobile Computing Conference (IWCMC 2017), Valencia, Spain, 2017: 687–692. doi: [10.1109/IWCMC.2017.7986368](https://doi.org/10.1109/IWCMC.2017.7986368).
- [11] ABID A, KACHOURI A, and MAHFOUDDI A. Anomaly detection through outlier and neighborhood data in Wireless Sensor Networks[C]. The 2nd International Conference on Advanced Technologies for Signal and Image Processing, Monastir, Tunisia, 2016: 26–30. doi: [10.1109/ATSIP.2016.7523045](https://doi.org/10.1109/ATSIP.2016.7523045).
- [12] SANDRYHAILA A and MOURA J M F. Discrete signal processing on graphs: Frequency analysis[J]. *IEEE Transactions on Signal Processing*, 2014, 62(12): 3042–3054. doi: [10.1109/TSP.2014.2321121](https://doi.org/10.1109/TSP.2014.2321121).
- [13] SHUMAN D I, NARANG S K, FROSSARD P, *et al.* The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains[J]. *IEEE Signal Processing Magazine*, 2012, 30(3): 83–98. doi: [10.1109/MSP.2012.2235192](https://doi.org/10.1109/MSP.2012.2235192).
- [14] SANDRYHAILA A and MOURA J M F. Discrete signal processing on graphs: Graph filters[C]. 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, Vancouver, Canada, 2013: 6163–6166. doi: [10.1109/ICASSP.2013.6638849](https://doi.org/10.1109/ICASSP.2013.6638849).
- [15] CHEN Siheng, VARMA R, SANDRYHAILA A, *et al.* Discrete signal processing on graphs: Sampling theory[J]. *IEEE Transactions on Signal Processing*, 2015, 63(24): 6510–6523. doi: [10.1109/TSP.2015.2469645](https://doi.org/10.1109/TSP.2015.2469645).
- [16] SHUMAND I, RICAUD B, and VANDERGHEYNST P. A windowed graph Fourier transform[C]. 2012 IEEE Statistical Signal Processing Workshop (SSP 2012), Ann Arbor, USA, 2012: 133–136. doi: [10.1109/SSP.2012.6319640](https://doi.org/10.1109/SSP.2012.6319640).
- [17] HAMMOND D K, VANDERGHEYNST P, and GRIBONVAL R. Wavelets on graphs via spectral graph theory[J]. *Applied & Computational Harmonic Analysis*, 2011, 30(2): 129–150. doi: [10.1016/j.acha.2010.04.005](https://doi.org/10.1016/j.acha.2010.04.005).
- [18] 林丽. 两组独立数据差异性统计检验方法及应用的研究[D]. [硕士学位论文], 上海交通大学, 2007.
LIN Li. Equivalence test method and application study for two independent data groups[D]. [Master dissertation], Shanghai Jiao Tong University, 2007.
- [19] QIU Kai, MAO Xianghui, SHEN Xinyue, *et al.* Time-varying graph signal reconstruction[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2017, 11(6): 870–883. doi: [10.1109/JSTSP.2017.2726969](https://doi.org/10.1109/JSTSP.2017.2726969).
- 蒋俊正: 男, 1983年生, 教授, 博士生导师, 研究方向为图信号处理理论与算法、图滤波器组设计。
- 杨杰: 男, 1991年生, 硕士生, 研究方向为图信号处理理论及应用。
- 欧阳缮: 男, 1960年生, 教授, 博士生导师, 研究方向为自适应信号处理、通信信号处理。