

一种联合时域和空域残差的网络异常检测与节点定位方法

金 明, 丁 蓉

(宁波大学信息科学与工程学院, 浙江宁波 315200)

摘 要: 无线传感器网络中, 有效检测网络异常并定位异常节点是确保数据可靠性的前提. 传统的基于图信号处理的网络异常检测和异常节点定位方法无法兼顾检测性能和定位性能. 为克服此缺点, 提出了一种联合图信号时域和空域残差的网络异常检测与节点定位方法. 首先, 建立一个基于历史数据相关性和节点距离的图信号模型. 接着, 联合图信号高频分量的时域残差和空域残差实现网络异常检测. 然后, 利用图信号时域残差把传感器节点分成两组. 在分组过程中, 通过最大化有序残差分组间的均值差将异常节点划分到同一组. 最后, 判定具有较大残差值分组的传感器节点为异常节点. 基于全球海平面压力和温度数据的仿真结果表明了所提方法的有效性. 针对异常节点海平面压力误差为 4 kPa、温度误差为 5 °C 和 3 °C 的三种情况, 与双通道图滤波方法相比, 所提方法的检测概率提高了至少 20%, 正确定位率提高了至少 15%.

关键词: 无线传感器网络; 图信号; 异常节点; 时域残差; 空域残差; 检测与定位

基金项目: 国家自然科学基金(No.61871246, No.61971249); 浙江省杰出青年科学基金(No.LR21F010001); 宁波市自然科学基金重点项目(No.202003N4013)

中图分类号: TP393

文献标识码: A

文章编号: 0372-2112(2023)05-1172-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20220910

Detection and Localization of Outlier Nodes in Wireless Sensor Networks via Jointing Temporal and Spatial Residuals

JIN Ming, DING Rong

(Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo, Zhejiang 315200, China)

Abstract: In wireless sensor networks (WSNs), detecting the occurrence of abnormal behaviors and localizing the outlier nodes effectively are the premise for ensuring the reliability of collected data. Traditional detection and localization methods based on graph signal processing cannot achieve high performance in detection and localization simultaneously. To overcome this drawback, this work proposed a detection and localization method which jointly taken advantage of both temporal and spatial residuals of graph signals. Firstly, a graph model based on the correlations of historical data and the distances among nodes was established, and temporal and spatial residuals of high-frequency graph components were employed to detect network anomalies. Then, sensor nodes were divided into two groups using temporal residuals of graph signals, and the nodes in the group with larger temporal residuals were identified as outlier nodes. Numerical simulations based on the data sets of sea level pressure and surface temperature are provided to demonstrate the superior performance of the proposed method. Compared with the two-channel graph filtering method, the proposed method improves the performance by at least 20% in detection probability and 15% in outlier positioning rate, for the cases with an abnormal error of sea level pressure of 4 kPa and abnormal errors of temperature of 5 °C and 3 °C.

Key words: wireless sensor network; graph signals; outlier nodes; temporal residuals; spatial residuals; detection and localization

Foundation Item(s): National Natural Science Foundation of China (No.61871246, No.61971249); Zhejiang Provincial Natural Science Funds for Distinguished Young Scholars (No.LR21F010001); Ningbo Key Program of Natural Science Funds (No.202003N4013)

1 引言

无线传感器网络是由传感器节点以自组织和多跳方式构成的无线网络^[1]. 通常传感器节点数量众多且部署于恶劣环境,难以维护所有节点. 如果不能识别异常节点,会降低数据可靠性,导致网络做出错误决策. 因此,网络异常检测及异常节点定位是传感器网络获取可靠数据的关键步骤.

目前,网络异常检测和节点定位主要基于统计学和聚类方法. 基于统计学的方法假设节点采集数据符合特定统计模型,根据测量数据与模型的匹配度检测异常节点,主要包括直方图法^[2]和核函数法^[3]. 这类方法需要先验知识建立统计模型,而实际中,数据统计特性会随时间变化,无法获取准确的先验知识. 基于聚类的方法^[4]对测量数据聚类,判定数据量最少的类为异常节点集合. 另外,支持向量机的方法需要训练数据学习分类模型^[5]. 文献[6]提出了一种改进的局部异常因子离群值检测算法,该方法根据数据分布密度和信息熵得到两个疑似异常数据集合,两个集合的交集判定为异常集合. 上述检测方法具有较高的检测性能,但只考虑数据的时间相关性或空间相关性却忽略了网络拓扑结构,造成定位性能较差.

近年来,基于图信号处理技术^[7]的异常检测与定位方法利用传感器网络拓扑结构,提高了检测与定位性能^[8-10]. 文献[8]提出了一种基于高通图滤波器的网络异常检测方法,该方法异常检测率高,但无法定位异常节点. 文献[9]提出了一种基于局部子图匹配的顶点域和图频域联合分析方法(简称子图方法). 该方法能达到100%的异常检测概率,然而虚警概率也超过50%,总体检测性能不佳. 另外,该方法的异常节点定位率不高. 文献[10]提出了一种基于双通道图滤波的异常检测方法,该方法利用图信号时域残差实现异常检测,但是没有利用图信号空域特征,限制了其在异常特征不明显时的检测性能,且该方法只能实现单个异常节点定位.

上述基于统计学和聚类的网络异常检测和节点定位方法忽略了网络拓扑结构,而基于图信号处理的方法无法兼顾检测和定位性能,且当异常节点误差较小时,其性能急剧下降. 鉴于此,本文分别从图信号模型、时域和空域残差、传感器节点分组等方面改进传统的基于图信号处理的方法,提出了一种联合图信号时域和空域残差的异常检测与定位方法.

2 图信号模型

假设传感器网络有 N 个节点将采集数据发送给汇聚节点,汇聚节点根据收集的测量数据判断是否存在异常节点并实现定位. 网络中第 n 个传感器节点在时

刻 t 的测量数据描述为

$$r_t(n) = x_t(n) + \varepsilon_t(n) \quad (1)$$

其中, $x_t(n)$ 表示时刻 t 的待测参数, $\varepsilon_t(n)$ 表示测量误差. 时刻 t 来自 N 个传感器节点的测量数据可以写成

$$\mathbf{r}_t = (r_t(1) \ r_t(2) \ \cdots \ r_t(N))^T \quad (2)$$

其中,上标 $()^T$ 表示转置. 汇聚节点收集从 $t-M+1$ 到 t 时刻(t 表示当前时刻)共 M 个时刻的测量数据,写成矩阵形式

$$\mathbf{R} = \begin{bmatrix} r_{t-M+1}(1) & \cdots & r_{t+1}(1) & r_t(1) \\ r_{t-M+1}(2) & \cdots & r_{t+1}(2) & r_t(2) \\ \vdots & \ddots & \vdots & \vdots \\ r_{t-M+1}(N) & \cdots & r_{t+1}(N) & r_t(N) \end{bmatrix} \quad (3)$$

图1所示为图信号拓扑结构示意图,图中黑点代表传感器节点,节点上的垂直线表示某个时刻的图信号,节点之间的边表示它们具有较强的相关性^[11,12].




图1 图信号拓扑结构示意图

根据节点位置特征,将每个节点与距离最近的 G 个节点相连构成边. 用变量 e_{ij} 的值表示节点 i 和 j 之间是否有边相连, $e_{ij} = 1$ 表示有边相连, $e_{ij} = 0$ 表示没有边相连. 将第 i 和 j 个节点之间的权重记为 w_{ij} , 距离记为 s_{ij} . 传统的图信号模型仅利用节点距离来设置权重. 考虑到实际环境中的洋流、大气运动、遮挡等原因,远距离节点可能比近距离节点具有更高的相关性,提出融合历史数据相关系数和距离的权重,改进后的权重为

$$w_{ij} = \begin{cases} e_{ij} \rho_{ij} \\ s_{ij}^2, & i \neq j \\ 0, & i = j \end{cases} \quad (4)$$

其中, ρ_{ij} 表示节点 i 和 j 历史数据之间的皮尔逊相关系数.

网络拓扑结构用图拉普拉斯矩阵 $\mathbf{L} = \mathbf{D} - \mathbf{W}$ 表示, 其中 \mathbf{W} 表示图权重矩阵, 其第 i 行第 j 列的元素为 w_{ij} , 对角矩阵 \mathbf{D} 表示度矩阵, 其第 i 个对角线元素为矩阵 \mathbf{W} 中第 i 行所有元素之和, 表示与节点 i 相连接的边权重之和.

3 网络异常检测与节点定位方法

提出的网络异常检测与定位方法包括检测和定位两部分. 当节点正常工作时, 相邻节点采集到的数据差异较小, 因此, 图信号具有低频特征. 一旦出现异常节点, 该节点与相邻节点的数据存在较大差异, 图频域出

现较大的高频分量. 通过高通图滤波器提取图信号的高频分量, 可以判断是否存在异常节点. 图2所示为基于图1拓扑结构, 高通滤波前后的图信号示意图, 图2(a)和图2(b)为滤波前的图信号, 图2(b)中存在一个异常节点(红色圆圈标记的节点), 图2(c)和图2(d)为滤波后的图信号.

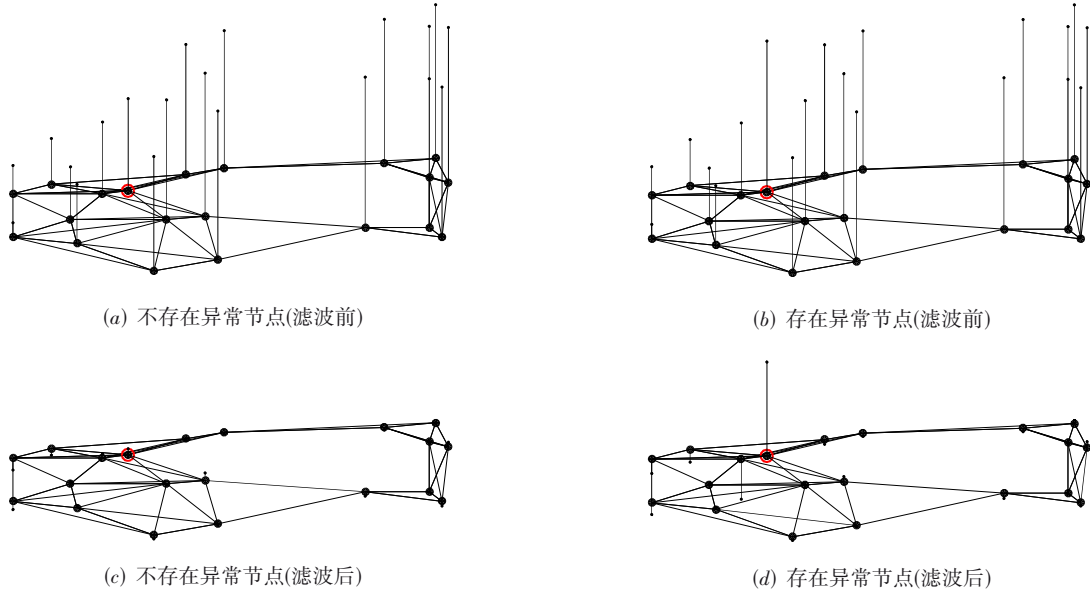


图2 高通滤波前后传感器图信号示意图

3.1 网络异常检测

首先, 采用高通图滤波器对信号进行预处理^[13-15], 获得图信号高频分量. 文献[10]表明, 异常节点的图信号高频分量在时域变化较大, 因此采用了时域残差值进行异常检测. 另外, 如图2(d)所示, 异常节点与邻居节点的图信号高频分量也有明显差异. 这一空域特征也可以用来实现异常检测. 因此, 本文提出一种联合时域和空域残差的异常检测方法.

令矩阵 \mathbf{H} 为图样条滤波器^[15], 通过最小化通带失真和阻带能量, 得到多项式系数 \mathbf{h} , 利用多项式逼近构建滤波器为

$$\mathbf{H} = \sum_{k=0}^K h_k \mathbf{L}^k \quad (5)$$

其中, K 表示滤波器阶数. 令 \mathbf{H}' 表示高通图滤波器的输出, 则 \mathbf{H}' 为

$$\begin{aligned} \mathbf{H}' &= \mathbf{H}\mathbf{R} \\ &= \mathbf{H}(\mathbf{r}_{t-M+1}, \dots, \mathbf{r}_{t-1}, \mathbf{r}_t) \\ &= (\mathbf{h}'_{t-M+1}, \dots, \mathbf{h}'_{t-1}, \mathbf{h}'_t) \end{aligned} \quad (6)$$

其中, \mathbf{h}'_t 表示传感器网络中高通滤波后第 t 时刻各节点的信号值, \mathbf{h}'_{t-M+1} 表示传感器网络中第 $t-M+1$ 时刻各节点的信号值. 图信号高频分量最大时域残差和平均

时域残差分别为

$$\theta_t = \left\| \mathbf{h}'_t - \frac{1}{M-1} \sum_{m=1}^{M-1} \mathbf{h}'_{t-m} \right\|_{\infty} \quad (7)$$

和

$$\bar{\theta} = \frac{2}{(M-1)(M-2)} \sum_{a,b=1,\dots,M-1} \left\| \mathbf{h}'_{t-a} - \mathbf{h}'_{t-b} \right\|_{\infty} \quad (8)$$

其中, $\|\cdot\|_{\infty}$ 表示无穷范数. 如果在当前时间 t 有异常节点, 那么最大时域残差将大于平均时域残差. 因此, 可以比较最大残差与平均残差实现异常节点检测. 另外, 空域残差为

$$\theta_s = (\mathbf{h}'_t)^T \mathbf{L} \mathbf{h}'_t \quad (9)$$

最后, 若 $\theta_t / \bar{\theta} > \gamma$ 或 $\theta_s > \lambda$ (γ 和 λ 分别表示时域残差和空域残差的判决门限), 则判定网络存在异常节点.

3.2 异常节点定位

对于异常网络, 采用变化点检测来定位异常节点^[16]. 均值能够反映数据集中趋势, 通过最大化组间均值差将有序的残差值划分为两组, 其中两组数据的分割点即为测量数据变化点. 首先, 计算残差:

$$\mathbf{z} = \mathbf{h}'_t - \frac{1}{M-1} \sum_{m=1}^{M-1} \mathbf{h}'_{t-m} \quad (10)$$

接着, 将 \mathbf{z} 中元素绝对值降序排序, 第 i 个值记为 z_i . 选

取任意 $n(1 \leq n \leq N-1)$, 计算两组残差的均值分别为

$$\hat{\mu}_1 = \frac{1}{n} \sum_{i=1}^n \tilde{z}_i \quad (11)$$

和

$$\hat{\mu}_2 = \frac{1}{N-n} \sum_{i=n+1}^N \tilde{z}_i \quad (12)$$

然后, 计算组间均值差异:

$$J(n) = \frac{n(N-n)}{N} (\hat{\mu}_1 - \hat{\mu}_2)^2 \quad (13)$$

通过最大化组间均值差异, 进行变化点搜索:

$$\bar{n} = \arg \max_n J(n) \quad (14)$$

最后, 判定具有较大残差值的分组为异常节点集合.

4 数值仿真

仿真采用全球海平面压力数据集^[17]和部分海平面温度数据集^[18], 高通图滤波器选择 $n=2$ 图样条滤波器, 设置 $G=5$ 和 $M=3$. 性能指标包括检测性能和定位性能, 其中, OPR (Outlier Positioning Rate) 表示异常节点定位率. 令 K 为真实异常节点个数, OPR (Outlier Sensor, $OS < K+L$) 表示检测出所有异常节点, 且误判为异常节点数量小于 L 的概率. 与文献^[10]相同, 时域残差判决门限设置为 1.5. 另外, 空域残差判决门限为 0.000 7.

4.1 全球海平面压力

全球海平面压力数据集由 500 个传感器节点从 1948 年到 2010 年采集的季平均海平面压力组成, 共 4 599 个数据. 仿真中, 分别设置 5 个、10 个和 15 个异常节点. 将每个节点与距离最近的 5 个节点连接, 建立图信号模型. 首先根据实测数据说明改进图信号模型的必要性. 以第 10 号传感器节点为例, 与其最近的 5 个节点分别为第 374、459、406、290 和 407 号, 距离分别为 390 km、1 140 km、1 540 km、1 690 km 和 2 420 km, 而对应的相关系数为 0.95、0.88、0.38、0.74 和 0.21. 第 406 号节点比 290 号更靠近 10 号, 但是前者与 10 号的相关系数约为后者的一半. 这是由于海平面压力与纬度相关, 10 号和 290 号节点的纬度分别为北纬 60° 和 62.5° , 而 406 号节点的纬度为北纬 47.5° , 因此, 10 号与 290 号节点比与 406 号节点具有更大的相关系数. 根据式(4)计算可得, 第 290 号与 10 号的权重大于第 406 号与 10 号的权重.

表 1 所示为当异常节点误差为 10 kPa 时, 所提方法、图频域法^[8]、子图方法^[9]和双通道图滤波方法^[10]的检测和定位性能. 从检测性能看, 所提方法、子图方法和双通道图滤波方法都能实现 100% 的检测概率, 而图频域法的检测概率只有 83% 左右. 由于图频域法及双通道图滤波方法无法实现多异常节点定位, 下面比较所提方法和子图方法的定位性能. 从 OPR 性能看, 子图方法的定位率为 90% 左右, 而所提方法能够达到

97% 以上. 另外, 子图方法的虚警概率达到了 58% 以上, 而所提方法的虚警概率仅 1.13%. 从 OPR ($OS < K+5$) 性能看, 所提方法能够实现与 OPR 相近的概率, 这表明所提方法能准确定位异常节点. 然而子图方法的 OPR ($OS < K+5$) 只有 0%. 这表明为了检测出所有异常节点, 该方法会把较多的正常节点误判为异常节点.

表 1 压力测量误差为 10 kPa 时的异常节点检测及定位性能

方法	异常节点个数	检测性能/%		定位性能/%	
		检测概率	虚警概率	OPR	OPR($OS < K+5$)
图频域方法	5	83.09	26.50		
	10	82.60	26.50		
	15	83.02	26.50		
双通道图滤波	5	100	1.13		
	10	100	1.13		
	15	100	1.13		
子图方法	5	100	58.19	94.31	0
	10	100	58.19	89.49	0
	15	100	58.19	85.95	0
所提方法	5	100	1.13	99.05	98.99
	10	100	1.13	98.09	98.06
	15	100	1.13	97.19	97.17

图 3 为不同异常节点个数下的组间均值差异函数 $J(n)$, 该目标函数在真实异常节点数量附近出现峰值, 表明所提方法可以准确地估计异常节点个数. 图 4 所示为在异常节点没有漏判的前提下, 误判为异常节点的数量分布. 可以看出, 子图方法具有较大的误判率. 当真实异常节点数量为 5 时, 子图方法判定为异常节点的数量集中在 24~35 之间. 当真实异常节点数量为 10 和 15 时, 子图方法判定为异常节点的数量分别集中在 52~65 之间和 82~92 之间. 该方法判定为异常节点数量远大于真实异常节点数. 而所提方法具有较高的定位准确度, 其所判定的异常节点数量基本符合真实节点数量.

当异常节点测量误差从 10 kPa 下降到 4 kPa 时, 表 2 所示为上述方法的检测和定位性能. 从检测性能看, 子




图 3 海平面压力数据有序残差值的组间均值差异

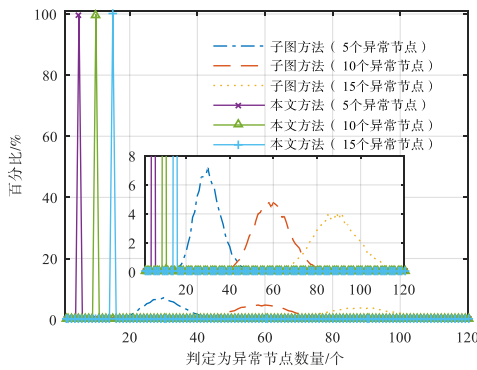


图4 海平面压力的异常节点数量判定概率

图方法虽然能够实现 100% 的检测概率,但虚警概率达到 58.19%。在虚警概率为 1.13% 条件下,所提方法的检测概率达 80% 以上,较双通道图滤波方法提高了至少 20%。从 OPR 性能看,在异常节点数为 5、10、15 个时,子图方法的异常节点定位率从表 1 的 90% 左右分别下降到了 79.03%、64.37% 和 52.28%,而所提方法依旧能够实现 92% 以上的异常节点定位率。从 OPR(OS<K+5) 定位性能看,所提方法也保持着较高的异常节点定位准确度。

表2 压力测量误差为 4 kPa 时的异常节点检测及定位性能

方法	异常节点个数	检测性能/%		定位性能/%	
		检测概率	虚警概率	OPR	OPR(OS<K+5)
图频域方法	5	74.34	26.50		
	10	74.10	26.50		
	15	75.06	26.50		
双通道图滤波	5	59.72	1.13		
	10	73.60	1.13		
	15	79.48	1.13		
子图方法	5	100	58.19	79.03	0
	10	100	58.19	64.37	0
	15	100	58.19	52.28	0
所提方法	5	81.33	1.13	99.04	50.22
	10	98.89	1.13	96.50	75.13
	15	100	1.13	93.97	80.29

4.2 全球部分海平面温度

全球部分海平面温度数据集由 100 个监测站点记录了 1870 年 1 月至 2014 年 5 月期间的 1 733 个时刻的平均海面温度。表 3 所示为温度测量误差为 5 °C 时,所提方法、图频域法、子图方法和双通道图滤波方法的检测和定位性能。从检测性能看,所提方法能够达到接近 100% 的检测概率,子图方法虽然检测概率达到 100%,但是虚警概率将近 90%。双通道图滤波方法与所提方法的虚警概率相同,均为 0.98%,但其检测概率只有 70% 左右。而图频域法的检测性能只有 83% 左右。从 OPR 定位性能看,子图方法具有约 75% 的异常节点定位率,而所提方法能够

实现 85% 以上的异常节点定位率。从 OPR(OS<K+5) 定位性能看,所提方法能够实现 60% 以上的概率,这表明所提方法能准确定位异常节点。然而子图方法的 OPR(OS<K+5) 最高仅有 0.11%。这表明为了检测出所有异常节点,该方法会把较多的正常节点误判为异常节点。

表3 温度测量误差为 5 °C 时的异常节点检测及定位性能

方法	异常节点个数	检测性能/%		定位性能/%	
		检测概率	虚警概率	OPR	OPR(OS<K+5)
图频域方法	5	83.26	34.95		
	10	83.07	34.95		
	15	83.33	34.95		
双通道图滤波	5	67.05	0.98		
	10	72.14	0.98		
	15	75.21	0.98		
子图方法	5	100	89.96	81.31	0.11
	10	100	89.96	73.98	0
	15	100	89.96	72.01	0
所提方法	5	99.94	0.98	94.71	63.26
	10	100	0.98	90.25	70.52
	15	100	0.98	85.32	71.36

图 5 为不同异常节点个数下的组间均值差异函数 $J(n)$,可以看出该目标函数的峰值在真实异常节点数附近,表明所提方法可以准确估计异常节点个数。图 6 所示为误判为异常节点数量的分布。可以看出,子图方法判定异常节点数量明显高于真实异常节点数。当真实异常节点数量为 5 时,子图方法判定为异常节点的数量集中在 18~25 之间。当真实异常节点数量为 10 和 15 时,子图方法判定为异常节点的数量分别集中在 40~50 和 58~66 之间。而所提方法具有较高的定位准确度,其所判定的异常节点数量基本符合真实节点数量。




图5 海平面温度有序残差值的组间均值差异

当异常节点测量误差从 5 °C 下降到 3 °C 时,表 4 所示为所提方法、图频域法、子图方法和双通道图滤波方法的检测和定位性能。从检测性能看,子图方法具




图6 海平面温度的异常节点数量判定概率

有 100% 的检测概率但其虚警概率高达 89%, 在虚警概率为 0.98% 时, 所提方法相比双通道图滤波方法能够实现更高的检测概率, 且更高的异常节点定位性能.

4.3 消融实验

所提的网络异常检测方法从图信号模型(融合相关系数和距离)和检测手段(联合时域和空域残差)两方面对双通道图滤波方法进行了改进, 而所提的异常节点定位方法是一种新方法. 因此本小节仅对网络异常检测方法中的两个改进点开展消融实验, 以观察它们对网络异常检测性能改善的作用. 表 5 所示为全球

表 4 温度测量误差为 3 °C 时的异常节点检测及定位性能

方法	异常节点个数	检测性能/%		定位性能/%	
		检测概率	虚警概率	OPR	OPR(OS<K+5)
图频域方法	5	78.34	34.95		
	10	78.03	34.95		
	15	78.26	34.95		
双通道图滤波	5	29.31	0.98		
	10	33.64	0.98		
	15	34.86	0.98		
子图方法	5	100	89.96	49.78	0.3
	10	100	89.96	34.94	0
	15	100	89.96	31.27	0
所提方法	5	86.76	0.98	66.19	25.45
	10	99.94	0.98	58.03	29.28
	15	100	0.98	50.27	30.06

海平面压力数据当压力测量误差为 3 kPa 时的异常节点检测概率(虚警概率都为 1.13%). 从表 5 可以看出, 在改进前的图信号模型基础上, 改进的联合时域和空域残差检测方法能够将检测概率提升 30%~40% 左右. 采用改进的图信号模型, 则检测概率能够继续提升 10% 左右. 由此可以发现, 图信号模型和检测手段的同时改进, 能够较大地提升检测概率. 这是因为两个改进点都利用了无线传感器网络的空域信息.

表 5 压力测量误差为 3 kPa 时的异常节点检测概率

异常节点个数	基于距离的图信号模型(改进前)		融合相关系数和距离的图信号模型(改进后)	
	时域残差(改进前)	联合时域和空域残差(改进后)	时域残差(改进前)	联合时域和空域残差(改进后)
15	36.75%	86.16%	36.77%	93.39%
10	29.61%	59.73%	30.4%	69.02%

当压力测量误差增加到 4 kPa 时, 表 6 所示为改进前后的图信号模型和检测方法结合后的异常节点检测概率. 从中可以看出, 改进的联合时域和空域残差方法能够将检测

概率提升 14% 左右, 同时改进模型和检测方法, 则能提升检测概率 21%~25% 左右. 上述结果表明, 为了获得较大的性能提升, 需要同时改进图信号模型和检测手段.

表 6 压力测量误差为 4 kPa 时的异常节点检测概率

异常节点个数	基于距离的图信号模型(改进前)		融合相关系数和距离的图信号模型(改进后)	
	时域残差(改进前)	联合时域和空域残差(改进后)	时域残差(改进前)	联合时域和空域残差(改进后)
10	73.60%	88.32%	74.24%	98.89%
5	59.72%	73.59%	61.60%	81.33%

5 结束语

本文利用改进的图信号模型得到图信号高频分量残差, 用异常节点和正常节点之间的时域和空域残差的变化以及有序时域残差组间差异等特征实现网络异常检测与节点定位. 基于实测数据集的实验结果表明, 改进的图信号模型和联合时域和空域残差的检测方法都能提高网络异常检测性能, 而两者的结合能继续提升检测概率约 10%, 同时获得了较高的定位性能. 另

外, 所提方法在获得较高的检测概率的同时, 能够保持较低的虚警概率.

参考文献

[1] LIANG W, MA C, ZHENG M, et al. Relay node placement in wireless sensor networks: From theory to practice [J]. IEEE Transactions on Mobile Computing, 2021, 20(4): 1602-1613.

- [2] SHENG B, LI Q, MAO W, et al. Outlier detection in sensor networks[C]//Proceedings of the 8th ACM International Symposium on Mobile Ad Hoc Networking and Computing. New York: ACM, 2007: 219-228.
- [3] PALPANAS T, PAPADOPOULOS D, KALOGERAKI V, et al. Distributed deviation detection in sensor networks[J]. ACM Sigmod Record, 2003, 32(4): 77-82.
- [4] LIU H, LI J, WU Y, et al. Clustering with outlier removal [J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 33(6): 2369-2379.
- [5] YANG Z, MERATNIA N, HAVINGA P. Distributed online outlier detection in wireless sensor networks using ellipsoidal support vector machine[J]. Ad Hoc Networks, 2013, 11(3): 1062-1074.
- [6] YU S, LI X, ZHAO L, et al. Hyperspectral anomaly detection based on low-rank representation using local outlier factor[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 18(7): 1279-1283.
- [7] RAMAKRISHNA R, SCGLIONE A. Grid-graph signal processing(Grid-GSP): A graph signal processing framework for the power grid[J]. IEEE Transactions on Signal Processing, 2021, 69: 2725-2739.
- [8] SANDRYHAILA A, MOURA J M F. Discrete signal processing on graphs: frequency analysis[J]. IEEE Transactions on Signal Processing, 2014, 62(12): 3042-3054.
- [9] 蒋俊正, 杨杰, 欧阳缮. 一种新的无线传感器网络中异常节点检测定位算法[J]. 电子与信息学报, 2018, 40(10): 2358-2364.
- JIANG J, YANG J, OUYANG S. A new detection and location algorithm for abnormal nodes in wireless sensor networks[J]. Journal of Electronics and Information, 2018, 40(10): 2358-2364. (in Chinese)
- [10] MA M, ZHOU F, JIANG J, et al. Malfunction detection and localization algorithm for wireless sensor network[J]. Circuits Systems and Signal Processing, 2021, 4: 501-509.
- [11] XIAO Z, FANG H, WANG X. Distributed nonlinear polynomial graph filter and its output graph spectrum: filter analysis and design[J]. IEEE Transactions on Signal Processing, 2021, 69: 1725-1739.
- [12] YANG G, YANG L, YANG Z, et al. Efficient node selection strategy for sampling bandlimited signals on graphs [J]. IEEE Transactions on Signal Processing, 2021, 69: 5815-5829.
- [13] DOMINGOS J, MOURA J M F. Graph Fourier transform: A stable approximation[J]. IEEE Transactions on Signal Processing, 2020, 68: 4422-4437.
- [14] JIANG J, CHENG C, SUN Q. Nonsampled graph filter banks: Theory and distributed algorithms[J]. IEEE Transactions Signal Processing, 2017, 67(15): 3938-3953.
- [15] JIANG J, FENG H, TAY D B, et al. Theory and design of joint time-vertex nonsampled filter banks[J]. IEEE Transactions on Signal Processing, 2021, 69(99): 1968-1982.
- [16] CHEN J, GUPTA A K. Parametric Statistical Change Point Analysis with Applications to Genetics, Medicine, and Finance[M]. 2nd ed. New York: Springer, 2011.
- [17] KISTLER R, KALNAY E, COLLINS W, et al. Sea level pressure, 1948-2010[DS/OL]. [2020-12-1]. http://research.jisao.washington.edu/data_sets/reanalysis/.
- [18] NOAA Physical Sciences Laboratory. Sea surface temperature(SST) [DS/OL]. [2020-12-1]. <http://www.esrl.noaa.gov/psd/data/gridded/data.noaa.oisst.v2.html>.

作者简介



金明男, 1981年8月出生于浙江省舟山市. 现为宁波大学教授、博士生导师. 主要研究方向为认知无线电、信号检测与参数估计.
E-mail: jinming@nbu.edu.cn



丁蓉女, 1995年11月出生于安徽省马鞍山市. 现为宁波大学信息科学与工程学院硕士研究生. 主要研究方向为图信号处理及其应用.
E-mail: 2011082093@nbu.edu.cn