Journal of Computer Applications
计算机应用,2020,40(3):783 - 787
ISSN 1001-9081
CODEN JYIIDU
2020-03-10
http://www.joca.cn

文章编号:1001-9081(2020)03-0783-05
DOI:10.11772/j.issn.1001-9081.2019071224

基于图信号处理的无线传感器网络异常节点检测算法

卢光跃[1,2],周　亮[1,2*],吕少卿[1,2],施　聪[1,2],苏可可[1,2]
(1. 西安邮电大学 通信与信息工程学院,西安 710121; 2. 陕西省信息通信网络及安全重点实验室(西安邮电大学),西安 710121)
(*通信作者电子邮箱zl2018zd@163.com)

摘　要:针对无线传感器网络(WSN)中传感器自身安全性低、检测区域恶劣及资源受限造成节点采集数据异常的问题,提出一种基于图信号处理的WSN异常节点检测算法。首先,依据传感器位置特征建立K-近邻(KNN)图信号模型;然后,基于图信号在低通滤波前后的平滑度之比构建统计检验量;最后,通过统计检验量与判决门限实现异常节点存在性的判断。通过在公开的气温数据集与PM2.5数据集上的仿真验证,实验结果表明,与基于图频域异常检测算法相比,在单个节点异常情况相同条件下,所提算法检测率提升7个百分点;在多个节点异常情况相同条件下,其检测率均达到98%,并且在网络节点异常偏离值较小时仍具有较高的检测率。

关键词:无线传感器网络;图信号处理;异常节点检测;图低通滤波器;平滑度
中图分类号:TP393.02　　**文献标志码**:A

Outlier node detection algorithm in wireless sensor networks based on graph signal processing

LU Guangyue[1,2], ZHOU Liang[1,2*], LYU Shaoqing[1,2], SHI Cong[1,2], SU Keke[1,2]
(1. *School of Communications and Information Engineering*, *Xi'an University of Posts and Telecommunications*, *Xi'an Shaanxi* 710121, *China*;
2. *Shaanxi Key Laboratory of Information Communication Network and Security*
(*Xi'an University of Posts and Telecommunications*), *Xi'an Shaanxi* 710121, *China*)

Abstract: Since the low security of sensors, poor detection area and resource limitation in Wireless Sensor Network (WSN) cause outlier data collected by nodes, an algorithm of the outlier node detection in WSN based on graph signal processing was proposed. Firstly, according to the sensor position features, a K-Nearest Neighbors (KNN) graph signal model was established. Secondly, the statistical test quantity was built based on the smoothness ratio of the graph signal before and after low-pass filtering. Finally, the judgement of the existence of outlier nodes was realized through the statistical test quantity and decision threshold. Experiments on the public temperature dataset and PM2.5 dataset demonstrate that compared with algorithm of outlier node detection based on graph frequency domain, the proposed algorithm has the detection rate increased by 7% under the condition of single outlier node and has the detection rate of 98% under the condition of multiple outlier nodes, and keep high detection rate under the condition of outlier node with small deviation value.

Key words: Wireless Sensor Network (WSN); graph signal processing; outlier node detection; graph low-pass filter; smoothness

0　引言

无线传感器网络是由大量静态或动态的传感器节点以自组织和多跳方式构成的一种分布式传感网络[1]。随着无线通信和微电子技术的不断创新,具有体积小、低成本和低功耗的传感器节点被广泛应用到医疗实时监测[2]、生态环境监测[3]、军事战场监视[4]等许多重要领域[5]。由于传感器节点自身安全性低、资源受限、常处于恶劣的环境中且无人看护,使得节点极易受到来自外界和自身因素的影响而导致节点出现异常。如果异常信息未被检测而加以分析,将会给决策带来严重后果。同时,由于大规模非规则网络结构的出现,使得对具有非规则网络拓扑结构的无线传感器网络异常检测成为研究的热点。

异常值也被称为离群值,是指节点自身故障、节点之间通信受阻及外界环境攻击等原因造成采集数据显著偏离正常模式下传感器采集的值。目前,对于异常节点的检测方法有许多种类型。基于统计学的方法[6]需要相应的先验知识建立统计概率分布模型,在该模型的基础上对数据的分布进行映射,通过它们和统计模型的拟合程度进行判决。如果准确获得统计模型,该算法则可以有效检测异常值;然而,在很多应用场景中,很难获得传感器分布的先验参数。基于分类的异常检测算法[7]主要通过数据距离寻找数据之间的相似度,并根据相似度对节点数据进行分类寻找异常节点,其优势在于并不需要统计模型。此外还有基于K均值的检测算法[8]和基于局

收稿日期:2019-07-15;**修回日期**:2019-09-17;**录用日期**:2019-09-18。　　**基金项目**:陕西省教育厅科研计划项目(17JK0703)。
作者简介:卢光跃(1971—),男,河南南阳人,教授,博士,主要研究方向:信号与信息处理、频谱感知、大数据分析; 周亮(1994—),男,陕西西安人,硕士研究生,主要研究方向:大数据分析、图信号处理; 吕少卿(1987—),男,山西五寨人,讲师,博士,主要研究方向:社交网络、大数据分析; 施聪(1994—),男,陕西西安人,硕士研究生,主要研究方向:深度学习、频谱感知; 苏可可(1996—),女,陕西渭南人,硕士研究生,主要研究方向:大数据分析、图信号处理。

部异常因子(Local Outlier Factor, LOF)的检测算法[9],这些异常检测算法在某些方面具有很高的检测率,但是其大多数只是从数据的时间相关性或空间相关性考虑。而目前随着网络技术的快速发展,人们已经步入大数据与智能物联时代,不同网络下的数据处理急剧增加,比如信息网络[10]、社交网络[11]、大脑神经网络等不同类型网络。面对这些具有非规则拓扑结构网状的高维度数据异常检测算法相对较少,因为不仅要考虑数据本身问题,还要考虑数据自身存在的拓扑结构。国外学者 Shuman 等[12]和 Sandryhaila 等[13]提出了图信号处理(Graph Signal Processing, GSP)的概念,其思想是通过数据的拓扑结构建立网络加权图,再将信号值映射到网络加权图的各个顶点上形成图信号。因此,图信号能够很好地体现网络数据与网络拓扑结构之间的关系,为解决非规则拓扑结构网络的高维度数据提供了一种天然的数学模型。目前图信号处理主要应用于网络缺失值重构[14]、网络异常检测[15]、拓扑图学习[16]以及图小波变换[17]等领域。

文献[18]中提出使用图频域异常检测算法对无线传感器网络异常节点进行检测,其核心思想是异常节点导致图信号在图频域的高频分量增大。因此根据图频域傅里叶系数与阈值可直接判断是否存在异常节点,该方法便于实现且异常检测率达到89%。但该方法只单一从图频域进行判断,在传感器异常节点偏离值较小时则会导致检测率降低。针对以上问题,本文提出了一种新的无线传感器网络异常节点检测算法,首先建立图信号模型,设计图低通滤波器,然后基于低通滤波前后的图信号平滑度之比构建统计检验量,从而实现对异常节点的存在性进行最终检测。该算法不仅在相同条件下具有更高的检测率,当网络中异常节点偏离值较小时,仍能达到较高的检测率。

1 相关理论

1.1 图信号模型

图信号处理是基于对图或网络上的信号进行分析所衍生的一种新兴的数学工具。与传统的数字信号不同,图信号是将信号值映射在图的各个节点上,每一个节点表示该信号产生的位置。

在构建图信号模型时,根据每个传感器节点的位置特征,计算相邻节点间的欧氏距离,通过K-近邻来建立图信号模型。图1所示的是一个简单的图信号拓扑。图信号中每个节点表示一个传感器,节点上的竖线表示传感器采集的信号值,图模型中节点之间有边连接表示节点之间相关联,反之则无关联。

通常,将一个无向图定义为$G = (\boldsymbol{V}, \boldsymbol{E})$,$\boldsymbol{V} = \{v_1, v_2, \cdots, v_N\}$代表$N$个节点的集合,$\boldsymbol{E}$是所有相连节点边的集合。而图的网络拓扑结构则用图拉普拉斯矩阵$\boldsymbol{L} = \boldsymbol{D} - \boldsymbol{W}$表示,$\boldsymbol{D} = \mathrm{diag}\{d_i\}$表示图的度矩阵,$d_i$是与节点$i$相连的所有边的数目;$\boldsymbol{W} \in \mathbf{R}^{N \times N}$表示图的加权矩阵,$\boldsymbol{W} = \{w_{ij}\}$,$w_{ij}$表示节点$i$与节点$j$之间的关联程度,可定义为:

$$w_{ij} = \begin{cases} a_{ij} / K_{ij}^2, & i \neq j \\ 0, & i = j \end{cases} \tag{1}$$

其中:$a_{ij} = 1$表示节点i与节点j相连接,反之$a_{ij} = 0$;K_{ij}为节点i到节点j的欧氏距离:

$$K_{ij} = \sqrt{(X_i - X_j)^2 + (Y_i - Y_j)^2} \tag{2}$$

1.2 图信号的傅里叶变换

在经典的数字信号处理(Digital Signal Processing, DSP)中,函数$f(t)$的傅里叶变换如式(3)所示:

$$F(\omega) = \int_R f(t)\,\mathrm{e}^{-\mathrm{j}\omega t}\,\mathrm{d}t \tag{3}$$

从经典的傅里叶分析,可以得出$\mathrm{e}^{-\mathrm{j}\omega t}$实质上代表一维拉普拉斯矩阵的特征函数[12],即:

$$-\Delta(\mathrm{e}^{\mathrm{j}\omega t}) = -\frac{\partial^2}{\partial t^2}\mathrm{e}^{\mathrm{j}\omega t} = \omega^2 \mathrm{e}^{\mathrm{j}\omega t} \tag{4}$$

在图信号处理中,可以使用图拉普拉斯矩阵的特征值与特征向量定义图傅里叶变换。首先将图拉普拉斯矩阵进行特征值分解$\boldsymbol{L} = \boldsymbol{U}\boldsymbol{\Lambda}\boldsymbol{U}^{\mathrm{T}}$,得到图拉普拉斯矩阵的特征向量矩阵$\boldsymbol{U} = [\boldsymbol{u}_1, \boldsymbol{u}_2, \cdots, \boldsymbol{u}_N]$和特征值矩阵$\boldsymbol{\Lambda} = \mathrm{diag}\{\lambda_i\}$ $(i = 1, 2, \cdots, N)$,其中$0 = \lambda_1 \leqslant \lambda_2 \leqslant \cdots \leqslant \lambda_N$。

因此图信号的傅里叶变换和逆变换定义为:

$$\boldsymbol{F} = \boldsymbol{U}^{\mathrm{T}}\boldsymbol{f} \tag{5}$$

$$\boldsymbol{f} = \boldsymbol{U}\boldsymbol{F} \tag{6}$$

图拉普拉斯矩阵的特征值λ_i表示图信号的频率,$\boldsymbol{u}_i$表示图频率相对应的图信号分量。从式(4)可以看出,ω越大,频率越大;图信号的频率λ_i也类似,即λ_i越大,图信号频率也越大。

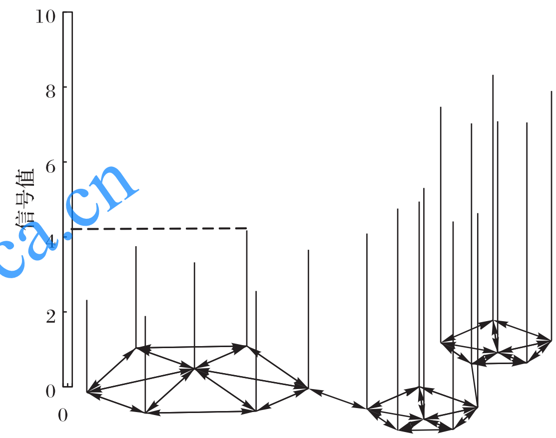

图1 图信号网络拓扑

Fig. 1 Network topology of graph signals

1.3 图信号平滑度

在图信号处理中,图信号的平滑度可定义为:

$$S(f) = \sum_{(i,j) \in \varepsilon} w_{ij}[f(j) - f(i)]^2 \tag{7}$$

其中ε表示与节点i相连的所有边的集合。

从式(7)中可以看出,图信号平滑度表示节点图信号的相近程度。平滑度越大,说明相邻节点的图信号有较大差异;而平滑度越小,说明相邻节点的图信号越相似。

当所有节点都正常工作时,节点上的图信号不仅在时间上平稳变化,在空间上相邻节点之间的图信号也随着时间平稳变化,因此图信号的平滑度小;而当存在异常节点时,图信号的平滑度将不可避免地增大。

2 异常节点检测方法

2.1 图频域

在无线传感器网络正常工作时,相邻传感器节点间的相似性也是平稳变化的,该相似性是指正常工作时相邻传感器采集数据之间差值的绝对值,所以图信号在频域具有低频特征。如果采集的数据有异常值存在,则会在频域出现高频分量。如图2所示,分别绘制传感器在无异常节点和有多个(如1、3、5个)异常节点时的频谱图。可以明显看出,在无异常值时图信号的频域只含有低频特征;而当有异常节点存在,可以

看出其频域不仅含有高频分量,而且随着异常节点个数的增加高频分量也更加丰富。

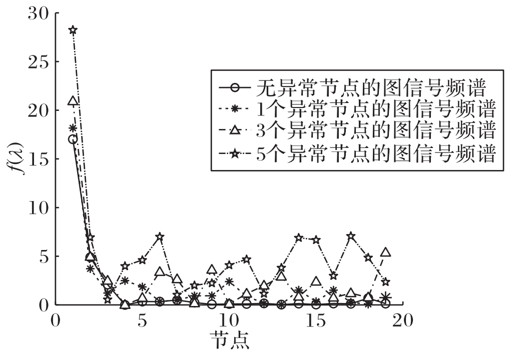

图 2　有/无异常节点的图信号频谱对比

Fig. 2　Frequency spectrum comparison of graph signals with and without outlier nodes

2.2　图低通滤波器

图低通滤波器的设计如式(8)所示:

$$g(\lambda_i)=\begin{cases}1, & \lambda_i<\lambda_{cut}\\ 0, & \lambda_i\geqslant\lambda_{cut}\end{cases} \tag{8}$$

其中 λ_{cut} 为图滤波器截止频率。

在本文中选择图拉普拉斯矩阵特征值的中位数作为图滤波器截止频率。

2.3　平滑程度准则

首先对图信号进行低通滤波,得到低通滤波后的图信号为:

$$\boldsymbol{f}^{LP}=\boldsymbol{U}g(\boldsymbol{\lambda})\boldsymbol{U}^{T}\boldsymbol{f} \tag{9}$$

计算低通滤波后图信号的平滑度,即:

$$S^{LP}(f)=\sum_{(i,j)\in\varepsilon}w_{ij}[f^{LP}(j)-f^{LP}(i)]^2 \tag{10}$$

图 3 表示低通滤波前后有、无异常节点图信号的对比。无异常节点时,相邻节点间的信号值相近,图信号具有低频特征,频率分量都在低频部分,因此无异常节点时图信号在低通滤波前后基本一致。当存在异常节点时,图信号的平滑度变化,出现较多的高频分量,此时异常节点存在时的图信号通过低通滤波后,其异常的高频部分被抑制,因此异常节点存在时图信号低通滤波前后将有较大的变化,这意味着其平滑度会有较大的变化。

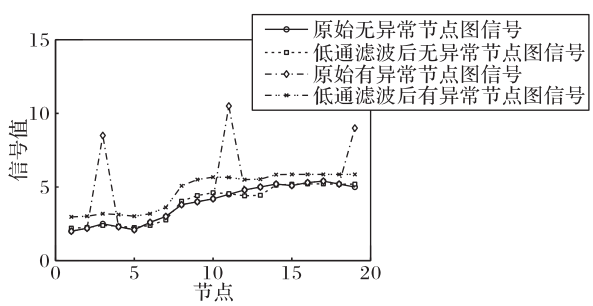

图 3　低通滤波前后有、无异常节点的图信号对比

Fig. 3　Comparison of graph signals with and without outlier nodes before and after low-pass filtering

基于以上分析,设计如式(11)所示的平滑程度判决准则 η:

$$\eta=\frac{S(f)}{S^{LP}(f)}=\begin{cases}H_0, & \eta<\gamma\\ H_1, & \eta\geqslant\gamma\end{cases} \tag{11}$$

其中:H_0 表示不存在异常节点,H_1 表示存在异常节点,γ 表示判决门限。

2.4　确定判决门限

图 4 表示有、无异常节点的 η 的样本统计直方图,从图中箭头所指的局部放大部分可以看出 η 在有无异常节点时的分布情况。

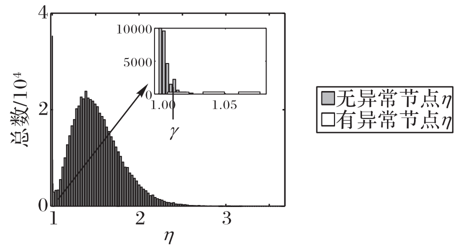

图 4　有、无异常节点的样本统计直方图

Fig. 4　Sample statistical histogram with and without outlier nodes

结合有、无异常节点的 η 的样本统计,根据样本统计变量,选取有异常节点的最小值和无异常节点的最大值作为判决门限的取值区间,通过遍历判决门限区间上的每一个值计算相对应的准确率,将准确率最大时所对应的判决门限设为最佳判决门限。

3　实验仿真与分析

本文的所有数据处理及仿真均采用 Matlab-2017b 软件进行。在美国主要城市日平均气温数据集(ftp://ftp.ncdc.noaa.gov/pub/data/gsod)[19] 和加利福尼亚日平均 PM2.5 数据集(https://www.epa.gov/outdoor-air-quality-data)[20] 上分别进行仿真,并与文献[18]中基于图频域分析的方法进行受试者工作特征(Receiver Operating Characteristic, ROC)曲线对比。在 ROC 曲线中,检测率作为 Y 轴,虚警率作为 X 轴,ROC 曲线上的每一个点表示相对应的判决门限。在虚警率相同的情况下检测率越高,表明对应算法的性能越好,此时虚警率与检测率相交的点即为该数据集下的最佳判决门限。

3.1　气温数据集

本文首先选取的是美国主要城市气温数据集,该数据集来源于美国国家气象局官方网站公开的美国主要城市 2003 年日平均气温数据集。在实验仿真中,随机选择该数据集下 150 个主要城市 365 天日平均气温数据。数据集范围从 −19.9~99.9°F。首先根据传感器位置特征将节点与最近邻的 6 个节点相连接建立 6 近邻图信号模型。如图 5 所示,图上的每个竖线代表每个传感器采集的信号值。

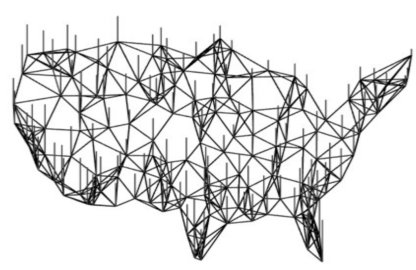

图 5　美国主要城市 2003 年日平均气温网络拓扑

Fig. 5　Network topology of daily average temperature of USA major cities in 2003

本文分别对2种不同场景下的异常情况进行实验仿真。首先考虑单个节点异常，与文献[18]中模拟故障节点类似，每一次随机选择某一天单个传感器节点气温值偏离20°F作为异常节点，为了体现所提算法在异常偏离值较小时具有更好的检测性能，同时仿真了气温偏离10°F和15°F时的异常情况。第二种考虑多个节点异常，每次随机选择某一天多个(2%、3%、5%个)传感器节点作为异常节点，同时偏离10°F。两种情况下均进行50 000次仿真实验。

图6显示在单个节点异常情况下偏离值不同时本文所提算法与图频域算法的ROC曲线对比。从图中可以看出，单个节点异常偏离值越大，即数据集的方差越大时，其检测效率越高；反之，当异常偏离值较小，即数据集的方差较小时，其检测率较低。而且从图中明显看出在虚警率相同条件下，所提算法在单个节点异常偏离值为10°F时的检测率高于图频域算法在异常偏离值为20°F时的检测率。结果表明在虚警率相同时所提算法优于图频域算法，且当异常偏离值较小时所提算法相比图频域算法具有更高的检测性能。

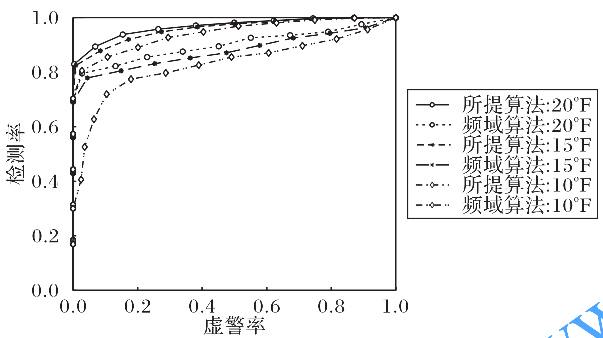

图6　气温数据不同偏离值下的ROC曲线对比

Fig. 6　Comparison of ROC curves with different temperature data deviations

图7所示为多个(2%、3%、5%个)节点异常情况下本文所提算法与图频域算法的ROC曲线对比。从图中可看出随着异常节点数增多，两种算法的检测性能同时增大；但从图中虚线所指的局部放大图中可看出，在相同仿真条件下，所提算法检测率均高于图频域算法的检测率。

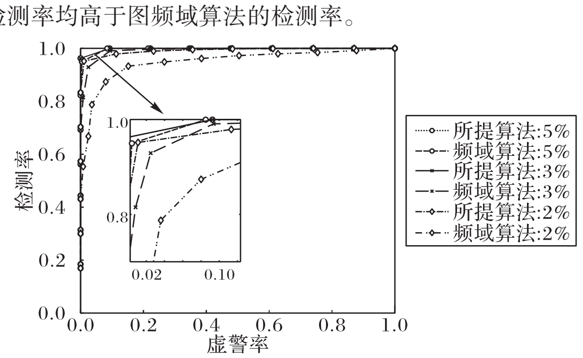

图7　气温数据多节点异常下的ROC曲线对比

Fig. 7　Comparison of ROC curves of temperature data under multiple outlier nodes

3.2　PM2.5数据集

第2个仿真实验数据采用美国环境保护局官方网站公开的加利福尼亚州监测站点2015年日平均PM2.5数据集。在实验仿真中，随机选取了该数据集下的60个站点200天的日平均PM2.5数据，数据集范围从−2.03 μg/m³到164.851 μg/m³，如图8所示。

同样对两种不同场景下的异常情况进行实验仿真，由于PM2.5数据与气温数据的度量值不一样，因此在第一种仿真实验中，将某一天的单个节点数据值偏离15 μg/m³作为异常节点，同时为了体现本文所提算法在异常偏离值较小时具有更好的检测性能，仿真了单个节点数据值偏离10 μg/m³和5 μg/m³时的异常情况。第二种实验每次随机选择某一天多个(2%、3%、5%个)传感器节点作为异常节点，同时偏离10 μg/m³。两种情况均进行10 000次仿真实验。

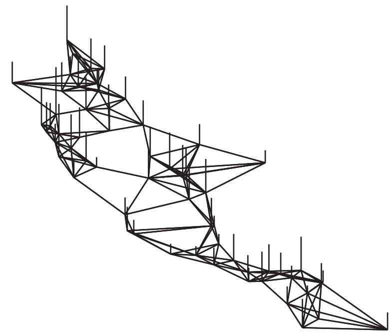

图8　加利福尼亚2015年日平均PM2.5网络拓扑

Fig. 8　Network topology of daily average PM2.5 of California in 2015

图9显示PM2.5数据集在单个节点异常情况下偏离值不同时本文所提算法与图频域算法的ROC曲线对比。与气温数据集在单个节点异常情况下的仿真结果一样，数据集的方差越大，其检测率也越大。同样，在异常偏离值为5 μg/m³时其检测性能仍然高于频域算法在异常偏离程度为15 μg/m³时的检测性能。

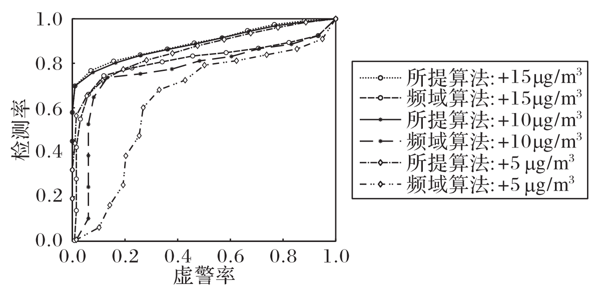

图9　PM2.5数据不同偏离值下的ROC曲线对比

Fig. 9　Comparison of ROC curves with different PM2.5 data deviations

图10是PM2.5数据集在多个(2%、3%、5%个)节点异常情况下本文所提算法与图频域算法的ROC曲线对比图。从图中可以看出，异常节点数越多，两种算法的检测性能越好，但当虚警率相同时所提算法在相同仿真条件下仍然具有较高的检测性能。

对以上两种具有不同特征集的数据上分别进行实验仿真，结果表明在虚警率相同的情况下所提算法具有更好的检测性能。此外，可以看出在PM2.5数据集上的检测性能略低于气温数据集，这是因为气温数据日变化幅度较大，导致数据集方差较大，使得整体的平滑度较低，而PM2.5数据集日变化幅度较小，其方差较小，导致整体的平滑度较大，因此PM2.5数据集的检测性能较低。但相比现有的图频域算法，

本文所提算法仍具有较高的检测性能。

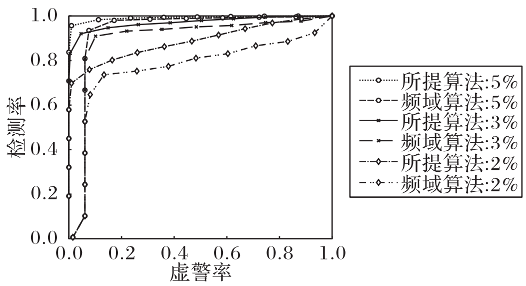

图 10　PM2.5 数据多节点异常下的 ROC 曲线对比

Fig. 10　Comparison of ROC curves of PM2.5 data under multiple outlier nodes

4　结语

本文提出了一种基于图信号处理的无线传感器网络异常节点检测算法。利用传感器节点的顶点域平滑性与图频域低频特性联合分析方法计算低通滤波前后图信号的平滑度,建立平滑程度判决准则,实现对异常节点的存在性判断。在不同的数据集上分别进行实验仿真,结果表明,在虚警率相同时所提算法在相同仿真条件下均具有较高的检测率,同时,在单个节点异常偏离值较小时仍具有较好的检测性能。

参考文献 (References)

[1]　SHUKLA D S, PANDEY A C, KULHARI A. Outlier detection: a survey on techniques of WSNs involving event and error based outliers[C]// Proceedings of the 2014 International Conference on Innovative Applications of Computational Intelligence on Power, Energy and Controls with Their Impact on Humanity. Piscataway: IEEE, 2014: 113-116.

[2]　DMITRIEV A S, RYZHOV A I, LAZAREV V A, et al. Experimental ultrawideband wireless sensor network for medical applications [J]. Journal of Communications Technology and Electronics, 2015, 60(9): 1027-1036.

[3]　LUO X, CHANG X. A novel data fusion scheme using grey model and extreme learning machine in wireless sensor networks[J]. International Journal of Control, Automation and Systems, 2015, 13 (3): 539-546.

[4]　KUMAR K A, KRISHNA A V N, CHATRAPATI K S. New secure routing protocol with elliptic curve cryptography for military heterogeneous wireless sensor networks[J]. Journal of Information and Optimization Sciences, 2017, 38(2): 341-365.

[5]　AKYILDIZ I F, SU W, SANKARASUBRAMANIAM Y, et al. A survey on sensor networks[J]. IEEE Communications Magazine, 2002, 40(8): 102-114.

[6]　ZHANG Y, 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.

[7]　GHORBEL O, AYADI A, LOUKIL K, et al. Classification data using outlier detection method in wireless sensor networks[C]// Proceedings of the 13th IEEE Wireless Communications and Mobile Computing Conference. Piscataway: IEEE, 2017: 699-704.

[8]　ABID A, KACHOURI A, MAHFOUDHI A. Anomaly detection through outlier and neighborhood data in wireless sensor networks [C]// Proceedings of the 2nd International Conference on Advanced Technologies for Signal and Image Processing. Piscataway: IEEE, 2016: 26-30.

[9]　SWAIN R R, KHILAR P M. Composite fault diagnosis in wireless sensor networks using neural networks[J]. Wireless Personal Communications, 2017, 95(3): 2507-2548.

[10]　BAI X, WANG Z, ZOU L, et al. Collaborative fusion estimation over wireless sensor networks for monitoring CO_2 concentration in a greenhouse[J]. Information Fusion, 2018, 42: 119-126.

[11]　CAI Z, HE Z, GUAN X, et al. Collective data-sanitization for preventing sensitive information inference attacks in social networks [J]. IEEE Transactions on Dependable and Secure Computing, 2018, 15(4): 577-590.

[12]　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, 2013, 30(3): 83-98.

[13]　SANDRYHAILA A, MOURA J M F. Discrete signal processing on graphs[J]. IEEE Transactions on Signal Processing, 2013, 61 (7): 1644-1656.

[14]　QIU K, MAO X, SHEN X, et al. Time-varying graph signal reconstruction[J]. IEEE Journal of Selected Topics in Signal Processing, 2017, 11(6): 870-883.

[15]　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 Z, YANG J, OUYANG S. Novel method for outlier nodes detection and localization in wireless sensor networks [J]. Journal of Electronics & Information Technology, 2018, 40 (10): 2358-2364.)

[16]　LIU Y, YANG L, YOU K, et al. Graph learning based on spatiotemporal smoothness for time-varying graph signal[J]. IEEE Access, 2019, 7: 62372 -62386.

[17]　ZHENG X, TANG Y, ZHOU J. A framework of adaptive multiscale wavelet decomposition for signals on undirected graphs[J]. IEEE Transactions on Signal Processing, 2019, 67(7): 1696-1711.

[18]　SANDRYHAILA A, MOURA J M F. Discrete signal processing on graphs: frequency analysis[J]. IEEE Transactions on Signal Processing, 2014, 62(12): 3042-3054.

This work is partially supported by the Scientific Research Program of Shaanxi Provincial Education Department (17JK0703).

LU Guangyue, born in 1971, Ph. D., professor. His research interests include signal and information processing, spectrum sensing, big data analysis.

ZHOU Liang, born in 1994, M. S. candidate. His research interests include big data analysis, graph signal processing.

LYU Shaoqing, born in 1987, Ph. D., lecturer. His research interests include social networking, big data analysis.

SHI Cong, born in 1994, M. S. candidate. His research interests include deep learning, spectrum sensing.

SU Keke, born in 1996, M. S. candidate. Her research interests include big data analysis, graph signal processing.