

基于灰度分析的桥梁健康监测系统传感器异常检测

王宪玉^{1,3}, 李文奇¹, 朱前坤^{1,2}, 杜永峰^{1,2†}

[1. 兰州理工大学 防震减灾研究所, 甘肃 兰州 730050;
2. 西部土木工程防灾减灾教育部工程研究中心(兰州理工大学), 甘肃 兰州 730050;
3. 甘肃省交通规划勘察设计院股份有限公司, 甘肃 兰州 730030]

摘要:为了能够及时检测出传感器的异常状况,设计了一种基于灰色关联度分析的桥梁健康监测系统传感器异常检测模型.首先,分别对多个应变传感器在正常工作和单传感器异常时采集的数据进行灰色关联度分析,得到表征每一列传感器数据与其余列数据在序列几何形状上相似程度的最不相关次数序列.通过对比发现无异常和有异常时最不相关次数的分布呈现明显差异,从而验证了此方法的可行性;然后,设计了一种权重计算策略,将最不相关次数序列转化为归一化的值,并将其作为评价指标,以此来量化每一列传感器数据与其他列数据之间的相关程度;最后,通过分析多组应变数据的评价指标,设置了多阈值预警机制,以实现不同程度的异常情况做出相应的判定.在另一组加速度监测数据上模拟多种异常程度不同的异常状况并进行检测,结果显示整体的异常识别率在90%以上.

关键词:结构健康监测;异常检测;传感器故障;灰色关联度

中图分类号:TU311

文献标志码:A

Sensor Anomaly Detection in Bridge Health Monitoring System Based on Gray Correlation Analysis

WANG Xianyu^{1,3}, LI Wenqi¹, ZHU Qiankun^{1,2}, DU Yongfeng^{1,2†}

[1. Institute of Earthquake Protection and Disaster Mitigation, Lanzhou University of Technology, Lanzhou 730050, China;
2. Engineering Research Center of West Civil Engineering Disaster Prevention and Mitigation(Lanzhou University of Technology), Lanzhou 730050, China;
3. Gansu Province Transportation Planning, Survey & Design Institute Co., Ltd., Lanzhou 730030, China]

Abstract: In order to be able to detect the abnormal condition of sensors in time, a sensor abnormality detection model for bridge health monitoring system based on gray correlation analysis is designed. First, the datas collected from multiple strain sensors in normal operation and single sensor abnormality are analyzed by gray correlation analysis, respectively, and the least correlated count columns that characterize the degree of geometric similarity between each column of sensor data and the rest of the columns of data are obtained. The comparison revealed that

* 收稿日期:2023-08-24

基金项目:国家自然科学基金资助项目(52168041), National Natural Science Foundation of China(52168041); 甘肃省重点研发计划-工业类资助项目(22YF11GA301), Gansu Provincial Key R&D Program-Industrial Funding Project(22YF11GA301); 甘肃省交通运输厅科技项目(2024-13), Gansu Provincial Transportation Department Science and Technology Project(2024-13)

作者简介:王宪玉(1991—),男,黑龙江牡丹江人,兰州理工大学博士研究生

† 通信联系人, E-mail: dooyf@lut.cn

the distribution of the least correlated counts when there was no abnormality and when there was an abnormality showed marked differences, thus verifying the feasibility of this method; then, a weight calculation strategy was designed to transform the least correlated count columns into a normalized value and use it as an evaluation index, which quantified the degree of correlation between each column of sensor datas and the rest of the columns of datas; finally, through the analysis of the evaluation indexes of multiple sets of strain datas, the multi-threshold warning mechanism was set up to realize the corresponding determination of different degrees of sensor anomalies. On another set of acceleration monitoring datas to simulate a variety of degrees of anomalies and detection, the results show an overall anomaly recognition rate of over 90%.

Key words: structural health monitoring; anomaly detection; sensor fault; grey relation analysis

桥梁作为重要的交通设施,对社会发展和经济增长有着决定性的作用,然而多数桥梁所处的环境自然条件恶劣,常面临洪水、强风、地震和滑坡等多种自然灾害的威胁^[1].为保障桥梁长期稳定运行,利用健康监测系统来对桥梁关键部位的结构参数进行监测,及早发现潜在问题并采取相应的维修和加固措施的方法被广泛使用^[2].通过这种方法来掌握桥梁的实时运行状况的关键在于确保监测系统能够稳定地采集到有效数据^[3].然而在实际应用中,传感器易受高温、潮湿及腐蚀等环境因素的影响而发生故障或老化,导致监测系统采集到与桥梁真实输出不符的无效数据,从而无法准确了解桥梁的实际状况或者对桥梁运行状况做出误判^[4-5].因此,及时检测发现传感器的异常至关重要.

目前的传感器异常检测方法可以分为基于解析模型的方法和基于数据驱动的方法^[6].基于解析模型的方法是通过建立数学模型或有限元模型来估计系统输出,然后将其与传感器实测数据进行对比以获取异常信息^[7-10].在解析模型合理的前提下,上述方法的检测准确率较高,但对于桥梁等复杂的工程结构,获取满足要求的解析模型往往比较困难,模型的不确定性会导致异常检测的效果不佳.基于数据驱动的方法不需要建立复杂的解析模型,而是直接对传感器采集的数据进行分析处理以获取异常信息.Tang等^[11]提出了一种基于卷积神经网络的异常检测方法.该方法通过将原始时间序列数据转换为双通道图像输入卷积神经网络,实现异常模式的视觉特征学习.文中使用桥梁监测数据验证了该方法具有较高的检测效率和准确率.然而该方法需

要大量人工标注的训练样本,但在实际应用中常面临缺少异常数据样本的难题,这限制了该方法的实用性.除神经网络之外,统计模型在故障检测中也有广泛应用.Sharifi等^[12]提出了一种基于混合概率主成分分析的非线性传感器故障诊断方法.该方法将测量空间分割为几个局部线性区域,每个区域对应一个概率PCA模型.通过贝叶斯分析残差,实现了在系统整个工作区间内对传感器故障的检测与隔离.Ait-Izem等^[13]考虑到传感器测量值的不确定性,采用区间数据表示传感器测量值,捕获了测量中的不确定性,使得故障检测更可靠.上述两种方法都对传统的主成分(Principal Component Analysis, PCA)进行了扩展,实现了故障的检测与隔离,但是作为典型的数据驱动方法,其存在训练数据敏感性和环境适应性差等问题,需要与其他方法结合起来发挥更好的效果.而且,上述方法的计算量较大,在面对桥梁健康监测系统中的海量数据时,适应性较差.

在外部因素的作用下,桥梁各种结构参数的变化呈现差异,但因为桥梁结构系统是一个统一的整体,所以这些参数的变化又存在一定的关联性,如环境关联性、位置关联性、时间关联性和类别关联性^[14].此外,在设计结构健康监测系统时,为了增强系统的稳定性,通常会在健康监测系统中引入冗余传感器^[15],这些冗余传感器所采集的数据通常呈现明显的相关性.为充分利用这些冗余信息,本文提出了一种基于灰色关联度分析的桥梁健康监测系统传感器异常检测方法.首先计算序列之间的灰色关联度,并从中提取指标将相关程度量化;然后设定阈值将相关程度较差的传感器判定异常;最后在监测数

据上模拟四种常见的传感器异常数据特征并进行检测,从而验证了本文方法的有效性.

1 基于灰色关联度分析的传感器异常检测模型

1.1 灰色关联度分析

灰色关联度分析(Grey Relation Analysis, GRA)^[16]是一种多因素统计分析的方法,基本思想是通过数学方法来度量不同序列在曲线几何形状上的相似程度来判断其联系是否紧密.

在实际应用中,首先需要确保待分析序列之间具有一定的关联性,然后从待分析序列中选出一个序列作为基准(称为参考序列),其余序列(称为比较序列)则与参考序列进行比较.也就是在已知参考序列与多个比较序列之间具有关联性的前提下,通过计算灰色关联度将每个比较序列与参考序列之间的关联程度量化,序列之间几何形状越相似,得到的量化结果越大.最后将结果进行排序,就可以知道哪个比较序列与参考序列的关联程度更高.灰色关联度分析的计算流程如下:

1)确定待分析的序列,并从中选出参考序列和比较序列.

2)标准化.为消除因各序列幅值不同产生的影响,使用零均值转换来进行标准化,设 $x_i = \{x_1^i, x_2^i, \dots, x_n^i\}$ 为一待分析序列, μ 和 σ 分别是该序列的均值和标准差,可根据下式将原序列转化成均值为0,标准差为1的正态分布序列:

$$x'_i = \frac{x_k^i - \mu}{\sigma}, k = 1, 2, \dots, n \quad (1)$$

式中: x_k^i 表示第 i 个待分析序列中的第 k 个值.

3)计算灰色关联系数.对于参考序列和任一比较序列,可根据式(2)求得与比较序列中每个序列点对应的参考序列的灰色关联系数:

$$\zeta_i(k) = \frac{\min_i \min_k |x_k - x_k^i| + \rho \max_i \max_k |x_k - x_k^i|}{|x_k - x_k^i| + \rho \max_i \max_k |x_k - x_k^i|} \quad (2)$$

式中: x_k 为参考序列中的第 k 个值; x_k^i 为第 i 个比较序列中的第 k 个值; ρ 为分辨系数,取值范围为(0,1),一般取0.5.

4)计算关联度.计算得到的灰色关联系数是一

个与分析序列等长的序列,由于其所包含的信息过于分散,所以通过求均值的方式将其表征为一个值,便于比较与排序,称之为灰色关联度.灰色关联度越大表示序列之间的相关程度越高.

1.2 传感器异常类型及数据特征

从数据的角度来看,传感器异常状况可以分为恒值异常、固定偏差、趋势异常、精度下降、恒增益、完全卡死和缺失这几类^[17-18].其中完全卡死和缺失这两类异常状况属于硬故障,分别表现为监测数据持续恒值和缺失.因为这两类异常可以通过简单的时间序列检测方法进行识别,所以后续分析不考虑.

假设传感器在正常工作时采集到的数据为: $x(t) = [x_1, x_2, \dots, x_n]$, $n(t)$ 是均值为零的正态分布序列,即: $n(t) \sim N(0, \sigma^2)$,则上述其余5种异常状况的数据特征可以表示为:

- 1)恒值异常: $x'(t) = a + n(t)$, a 为恒值.
- 2)固定偏差: $x'(t) = x(t) + a$, a 为恒值.
- 3)趋势异常: $x'(t) = x(t) + a + bt$, a, b 为恒值.
- 4)精度下降: $x'(t) = x(t) + n(t)$.
- 5)恒增益: $x'(t) = x(t) \times a$, a 为恒值.

1.3 异常检测模型

根据结构参数的关联性与灰色关联度分析的基本原理,提出了一种基于灰色关联度分析的桥梁健康监测传感器异常的检测方法.检测流程如图1所示,具体步骤如下:

1)选取待分析序列.根据位置关联性、时间关联性和类别关联性选取待分析序列.




图1 异常检测模型流程图

Fig.1 Flowchart of anomaly detection model

2)数据预处理.在进行标准化之前,使用 3σ 准则和小波降噪来去除原始数据中的离群点和噪声信息,将原始数据标准化.

3)计算灰色关联度.首先通过数据窗口将待分析序列划分为多组子序列,每个窗口内的子序列作为一组进行计算.然后关于参考序列的选取,这里并不固定某一列作为参考序列,而是遍历选取其中每一列作为参考序列,相应的比较序列则为参考序列之外的所有序列.最后,将每次计算得到的灰色关联系数序列求均值得到灰色关联度.

4)统计最不相关次数.任意窗口内各传感器的最不相关次数计算流程如图2所示.待分析序列数为 n ,窗口数为 m 时,每一组窗口数据进行 n 次灰色关联度分析,每次分析都可得到 $n-1$ 个表征各比较序列与参考序列相关程度的灰色关联度,其中必然有一个最小值,这个最小的灰色关联度所代表的序列即为此次分析中的最不相关序列.记录每次分析中的最不相关序列,在遍历结束之后统计每个序列在 n 次分析中为最不相关序列的次数,即为最不相关次数.

5)确定异常判定标准.分析第4步得到的最不相关次数,从中提取出用于最终评价传感器是否异常的指标,并确定异常判定的阈值.

6)传感器异常判定.若某个传感器对应的评价指标大于阈值,则输出该传感器发生异常.




图2 最不相关次数计算流程图

Fig.2 Flowchart for calculating the least correlated counts

2 传感器异常检测模型验证

西固黄河大桥是兰州绕城高速公路重点工程,是主桥长为 $(67+110+360+110+67)$ m=714 m的斜拉桥,

纵梁采用工字钢-混凝土结合梁,主塔采用菱形钢筋混凝土结构,南北主塔高分别为151 m和147 m,是西北地区在黄河上建造的跨度最大、塔身最高的斜拉桥,也是甘肃省首座高速公路斜拉桥.大桥的建成对于贯彻落实国家西部大开发战略部署具有重大意义.为应对自然灾害的挑战,大桥设计并安装了健康监测系统,对应变、索力、挠度及桥面温湿度等进行监测.

桥梁全貌见图3,主梁上的应变和加速度传感器布置见图4,其中应变监测采用光纤光栅应变传感器,加速度监测采用941b型拾振器.



图3 西固黄河大桥

Fig.3 Xigu Yellow River bridge

2.1 选取评价指标

从大桥第1跨和第5跨跨中截面里各选取前4个应变传感器从2023年5月22日17:00—18:00的监测数据,应变数据如图5所示.这段时间中单列传感器数据有67 219个数据点,经过预处理之后使用大小1 000、步长为500的滑动窗口将这1小时内的应变数据划分为133组窗口数据.计算各传感器在每个窗口中的最不相关次数,统计每个窗口中各传感器的最不相关次数在每个值上的分布情况,得到最不相关次数分布直方图,直方图见图6.可以看到各传感器的最不相关次数集中在最小值“0”次处,达到最大值“7”次的很少,而在其他次数上的分布较均匀且次数越小分布越多.

异常传感器监测数据与正常传感器监测数据的时程曲线在几何形状上具有明显差异,在灰色关联度分析中则表现为异常数据的灰色关联度最低,即异常序列的最不相关次数会更多.在传感器RSG-1-4上依次模拟各类异常数据,并统计各传感器的最不相关次数分布情况.由于固定偏差和恒增益这两种异常在应变数据上的表现形式非常相似,所以文中




图 4 主梁传感器布置图

Fig.4 Main beam sensor arrangement diagram




图 5 1 和 5 跨应变数据

Fig.5 1 and 5-span strain datas




图 6 最不相关次数分布直方图

Fig.6 Histogram of distribution of least correlated counts

仅取前者进行模拟. 根据文献[19–20]的建议, 异常数据的参数设置见表 1, 其中 σ 为监测数据的标准差, 异常数据见图 7, 4 种异常状况下各传感器的最不相关次数分布情况见图 8.

133 个窗口中, RSG-1-4 在恒值异常、固定偏差及趋势异常时的最不相关次数达到最大值 7 的个数在 120 左右, 精度下降时的最不相关次数主要集中在 7 次和 6 次, 其他序列的最不相关次数基本都集中在 1 次和 2 次, 这与图 6 中无传感器异常时的分布情

表 1 传感器异常参数		
Tab.1 Sensor abnormal parameters		
异常类型	异常序号范围	异常参数
恒值异常	20 000~67 219	$a=148; n(t) \sim N(0, 0.01^2)$
固定偏差	20 000~57 219	$a=1.6\sigma$
趋势异常	20 000~67 219	$a+bt=-2.4\sigma$
精度下降	2 000~67 219	$n(t) \sim N(0, 0.3\sigma^2)$

况相比呈现明显差异.

为实现对异常序列的识别, 引入了一种权重计算策略. 将各传感器最不相关次数的分布情况转化为可以量化异常序列与正常序列差异的指标. 首先将最不相关次数不小于 $n/2$ 的值视为相关性较差并对其进行映射, 其中 n 为进行异常检测的传感器序列数. 具体的映射规则如下:

- 1) 最不相关次数为最大值 $n-1$ 时, 映射为 1. 表示传感器数据在当前窗口内与其余序列完全不相关.
- 2) 最不相关次数为不小于 $n/2$ 的最小整数时, 映射为 0.1. 表示传感器数据在当前窗口内与其余序列相关性较弱.
- 3) 最不相关次数为 $(n/2, n-1)$ 之间的其他整数时, 根据前两项的取值线性插值获得最不相关次数介于前两项之间的映射值.
- 4) 最不相关次数为其他值时视为相关性较好, 不进行映射.

然后把每个窗口中的映射结果进行累加, 并将累加结果除以其理论最大值“窗口数”, 得到取值范围为 $[0, 1]$ 的归一化的值. 值越大表示对应的传感器数据在当前时间段内与其余列传感器数据越不相关, 该传感器异常的可能性越大.

按照上述方法对 4 种异常状况下各传感器的最




图7 异常数据

Fig.7 Abnormal datas

不相关次数进行计算. 结果如表2所示, 可以看到异常序列对应的值均大于0.8, 其余无异常的序列均接近0, 说明此方法获取的值对于正常序列和异常序列具有明显的区分度, 故选定此值作为评价传感器是否异常的指标.

2.2 确定异常判定阈值

在基于数据驱动的传感器异常检测中, 判定传感器异常依靠对异常数据的特征识别. 当监测数据与真实输出存在不可接受的偏差时, 即可认为偏差是因为传感器异常. 然而, 在数据的异常程度较小时, 难以准确判定异常数据是由传感器异常引起还是环境扰动下结构的真实输出.

继续选用2.1节中的监测数据. 以趋势异常为例, 在RSG-1-4上模拟不同程度的异常, 计算其对应




图8 异常状况下最不相关次数分布直方图

Fig.8 Histogram of the distribution of least correlated counts of anomalies

表2 最不相关次数映射累加结果

Tab.2 Least correlated counts mapping cumulative results

传感器	恒值异常	固定偏差	趋势异常	精度下降
RSG-1-1	0	0.003 0	0	0
RSG-1-2	0	0.000 8	0	0
RSG-1-3	0.008 3	0.021 8	0	0.003 0
RSG-1-4	0.860 2	0.800 8	0.953 4	0.835 3
RSG-5-1	0	0	0	0
RSG-5-2	0	0	0	0.000 8
RSG-5-3	0.007 5	0.010 5	0	0
RSG-5-4	0.007 5	0.006 8	0	0.006 0

的评价指标. 异常范围同表1中的设置相同, 其余异常参数与评价指标见图9.

由图9可以看到评价指标随着最大偏差的增加而不断变大, 最终接近最大值1. 当最大偏差达到




图9 不同异常程度时的评价指标

Fig.9 Evaluation indicators at different levels of abnormality

2.2 σ 时,异常较为明显,其后的评价指标都稳定在0.9以上.在最大偏差达到2.0 σ 之前的异常,对应的评价指标则处于不断上升的阶段,这段中的部分异常数据如图10所示.可以看到,最大偏差达到1.6 σ 之后,数据的趋势已接近水平,与正常状态下的趋势相差较大.而当最大偏差为1.2 σ 时,数据依然保持原有的上升趋势,虽有偏差,但对桥梁状态评估产生的影响有限.




图10 不同程度的趋势异常

Fig.10 Varying degrees of trend anomalies

结合前述分析,为降低在异常程度较小时的误判率,本文提出了对传感器异常进行分级判定的机制.以评价指标是否超过0.5作为界限,当评价指标小于0.5时,认为没有异常;当评价指标大于0.5时,认为存在异常,并进一步对异常部分进行分级判定.具体的异常判定阈值如下:

- 1)评价指标在[0,0.5)之间:无异常.
- 2)评价指标在[0.5,0.7)之间:一级异常.
- 3)评价指标在[0.7,0.9)之间:二级异常.
- 4)评价指标在[0.9,1.0]之间:三级异常.

2.3 模型验证

取大桥第3跨上1、3、5、7截面中的8个加速度传感器从2023年8月1日到8月12日共12 d的监测数

据来验证模型的检测性能.原始数据无异常,以1 h为单位将这段数据划分为288组,并在其中96组数据上引入单传感器异常,每24 h的异常分布如图11所示,最终得到每类异常的数量为24,其中精度下降、固定偏差和趋势异常这3类的异常参数均在[1 σ , 3.3 σ]范围内线性分布,恒值异常的参数则在[0,0.1]范围内.将所有数据导入异常检测模型进行检测,检测结果见表3.




图11 24 h内的异常分布

Fig.11 Abnormal distribution over 24 h

表3 检测结果

Tab.3 Detection results

类型	数量	检出	漏检
无异常	192	187	5
恒值异常	24	22	2
固定偏差	24	24	0
趋势异常	24	21	3
精度下降	24	20	4

将异常数据作为正例(positive),正常数据作为负例(negative),可以将检测结果分为以下4类:

- 1)实际为正例且判断为正例的实例数: True Positives (TP);
- 2)实际为负例但判断为正例的实例数: False Positives (FP);
- 3)实际为正例但判断为负例的实例数: False Negatives (FN);
- 4)实际为负例且判断为负例的实例数: True Negatives (TN).

依据上述规则将检测结果进行分类,并计算精确率 P (Precision)、召回率 R (Recall) 和 $F1$ 分数来对模型的性能进行评估.计算结果如下:

$$1) \text{精确率: } P = \frac{TP}{TP + FP} = 0.94;$$

$$2) \text{召回率: } R = \frac{TP}{TP + FN} = 0.91;$$

$$3)F1 \text{ 值: } F1 = \frac{2 \times P \times R}{P + R} = 0.92.$$

整体来看,各项评估指标均在 0.9 以上,模型具有较好的性能.

3 结论

本文利用桥梁健康监测系统中的硬件冗余,设计了基于灰色关联度的异常检测模型.通过计算每个传感器的最不相关次数,并从中提取评价指标的方式来识别异常传感器.结论如下:

1)所提出的传感器异常检测模型原理简单,易于实现,并对计算机硬件要求较低.这使得该模型能够在不同硬件平台上有效运行.且该模型无须选取数据集进行训练,具有良好的适应性,能够有效处理未知情况,为实际应用带来便利.

2)此方法计算迅速,可实现对异常传感器的实时检测.将其与异常诊断方法结合后,可实现对异常传感器的及时定位和异常类型的准确诊断,具有很好的实用价值.

3)该模型目前只对单传感器异常的识别具有较高的准确率,后续将进一步改进算法,便于适应多传感器异常的实际场景.

参考文献

- [1] 彭卫兵,沈佳栋,唐翔,等. 近期典型桥梁事故回顾、分析与启示[J]. 中国公路学报,2019,32(12):132-144.
PENG W B, SHEN J D, TANG X, et al. Review, analysis, and insights on recent typical bridge accidents[J]. China Journal of Highway and Transport, 2019, 32(12): 132-144. (in Chinese)
- [2] GHAREHBAGHI V R, FARSANGI E N, NOORI M, et al. A critical review on structural health monitoring: definitions, methods, and perspectives[J]. Archives of Computational Methods in Engineering, 2022, 29(4): 2209-2235.
- [3] SUN L M, SHANG Z Q, XIA Y, et al. Review of bridge structural health monitoring aided by big data and artificial intelligence: from condition assessment to damage detection[J]. Journal of Structural Engineering, 2020, 146(5): 04020073.
- [4] MAO J X, WANG H, SPENCER B F. Toward data anomaly detection for automated structural health monitoring: exploiting generative adversarial nets and autoencoders[J]. Structural Health Monitoring, 2021, 20(4): 1609-1626.
- [5] ERHAN L, NDUBUAKU M, DI MAURO M, et al. Smart anomaly detection in sensor systems: a multi-perspective review [J]. Information Fusion, 2021, 67: 64-79.
- [6] WU H, ZHAO J S. Deep convolutional neural network model based chemical process fault diagnosis [J]. Computers & Chemical Engineering, 2018, 115: 185-197.
- [7] CHO S, CHOI M, GAO Z, et al. Fault detection and diagnosis of a blade pitch system in a floating wind turbine based on Kalman filters and artificial neural networks [J]. Renewable Energy, 2021, 169: 1-13.
- [8] JIN H L, ZUO Z Q, WANG Y J, et al. An integrated model-based and data-driven gap metric method for fault detection and isolation [J]. IEEE Transactions on Cybernetics, 2021, 52(12): 12687-12697.
- [9] GAO Z W, LIU X X. An overview on fault diagnosis, prognosis and resilient control for wind turbine systems[J]. Processes, 2021, 9(2): 300.
- [10] CHO S, GAO Z, MOAN T. Model-based fault detection, fault isolation and fault-tolerant control of a blade pitch system in floating wind turbines [J]. Renewable Energy, 2018, 120: 306-321.
- [11] TANG Z Y, CHEN Z C, BAO Y Q, et al. Convolutional neural network-based data anomaly detection method using multiple information for structural health monitoring [J]. Structural Control and Health Monitoring, 2019, 26(1): e2296.
- [12] SHARIFI R, LANGARI R. Nonlinear sensor fault diagnosis using mixture of probabilistic PCA models[J]. Mechanical Systems and Signal Processing, 2017, 85: 638-650.
- [13] AIT-IZEM T, HARKAT M F, DJEGHABA M, et al. On the application of interval PCA to process monitoring: a robust strategy for sensor FDI with new efficient control statistics [J]. Journal of Process Control, 2018, 63: 29-46.
- [14] YANG D H, YI T H, LI H N, et al. Correlation-based estimation method for cable-stayed bridge girder deflection variability under thermal action [J]. Journal of Performance of Constructed Facilities, 2018, 32(5): 04018070.
- [15] ABDULKAREM M, SAMSUDIN K, ROKHANI F Z, et al. Wireless sensor network for structural health monitoring: a contemporary review of technologies, challenges, and future direction [J]. Structural Health Monitoring, 2020, 19(3): 693-735.
- [16] KONG L J, FANG J, WU Z G, et al. Evaluation of the effect of surface coatings on protection of concrete against sewage-induced degradation based on gray correlation analysis [J]. Journal of Coatings Technology and Research, 2018, 15(6): 1311-1323.
- [17] LI D L, WANG Y, WANG J X, et al. Recent advances in sensor fault diagnosis: a review [J]. Sensors and Actuators A: Physical, 2020, 309: 111990.
- [18] 何富君,刘小磊,卢晓昭,等. 传感器的故障诊断技术研究[J]. 科学技术与工程, 2010, 10(26): 6481-6487.
HE F J, LIU X L, LU X Z, et al. A research on fault detection diagnosis technology for sensor [J]. Science Technology and Engineering, 2010, 10(26): 6481-6487. (in Chinese)
- [19] HUANG H B, YI T H, LI H N. Bayesian combination of weighted principal-component analysis for diagnosing sensor faults in structural monitoring systems [J]. Journal of Engineering Mechanics, 2017, 143(9): 04017088.
- [20] 安星. 基于主元分析的桥梁健康监测传感器故障诊断[D]. 重庆:重庆大学, 2018.
AN X. Sensor fault diagnosis of bridge health monitoring system based on principal component analysis [D]. Chongqing: Chongqing University, 2018. (in Chinese)