

DOI:10.19651/j.cnki.emt.2210764

大坝监测数据多维度 LSTM 异常检测与恢复

熊敏¹ 江德军¹ 高志良¹ 何海峰² 罗冲³(1. 国能大渡河流域水电开发有限公司 成都 610041; 2. 成都大汇物联网科技有限公司 成都 610041;
3. 四川大学电气工程学院 成都 610065)

摘要: 大坝安全监测是大坝安全的重要保障,对监测数据进行异常检测与恢复可有效避免对大坝状态的错误估计和判断,具有重要现实意义。近年来基于深度学习方法的大坝监测数据异常检测受到广泛研究,但现存方法存在数据利用不足、信息挖掘不充分等问题。因此,本文提出一种多维度 LSTM 异常检测与恢复方法,该方法用 LSTM 输入多个测点的大坝监测数据对单测点数据进行预测,有效利用了不同测点间的相关信息;最后利用拉依达准则对目标测点进行异常检测。本文利用大渡河瀑布沟水电站真空激光准直监测数据进行案例验证,通过与单维度的 LSTM 异常检测与恢复方法相比较,验证了所提方法能有效地检测数据异常和预测恢复正常数据,是一种有效的大坝监测数据异常检测与恢复方法。

关键词: 大坝监测数据;LSTM;拉依达准则;异常检测;数据恢复

中图分类号: TV698.1 文献标识码: A 国家标准学科分类代码: 570.6020

Dam monitoring data multi-dimensional LSTM anomaly detection and recovery

Xiong Min¹ Jiang Dejun¹ Gao Zhiliang¹ He Haifeng² Luo Chong³(1. CHN Energy Dadu River Hydropower Development Co., Ltd., Chengdu 610041, China;
2. Dahui IOT Technology Co., Ltd., Chengdu 610041, China;
3. College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: Dam monitoring data is an important guarantee of dam safety. Anomaly detection and recovery of dam monitoring data can effectively avoid the wrong estimation and judgment of dam status, which has important practical significance. In recent years, there are extensive studies on anomaly detection of dam monitoring data based on deep learning methods. However, the existing methods have some drawbacks such as insufficient data utilization and insufficient information mining. Therefore, a multi-dimensional LSTM anomaly detection and recovery method is proposed in this paper. The dam monitoring data of multiple monitoring points are fed into LSTM to predict the data of single monitoring point, and the relevant information between different monitoring points is effectively utilized. Finally, anomaly detection is performed on the data of the target detection point using Pauta criterion. In this paper, the laser collimation monitoring data of Fudougou Hydropower Station in Dadu River are used for case verification. By comparing with the single dimension LSTM anomaly detection and recovery algorithm, it is verified that the performance of proposed method is effective both in anomaly detection and data recovery, which is an effective method for dam monitoring data anomaly detection and recovery.

Keywords: dam monitoring data; LSTM; Pauta criterion; anomaly detection; data recovery

0 引言

水利大坝是超大型建筑,具有防洪度汛、农业灌溉、水力发电等综合作用。我国自建国以来,修建了数以万计的大坝,这些水利大坝为我国创造了巨大经济效益^[1]。但水

利大坝在为我们带来多种经济效益的同时,也伴随着对人类社会带来一些安全威胁。一旦水利大坝发生溃坝则会带来灾难性的后果。如上世纪法国马尔帕塞双曲拱坝溃坝造成人员死亡和失踪达 500 余人,财产损失达 300 亿法郎^[2]。

因此对水利大坝实施常态化监测,密切掌握水利大坝

内外部形变、渗流数据,从而在大坝具有安全隐患时及时发现并消缺,对防止溃坝等灾难的发生至关重要^[3]。大坝是超大型建筑,为了密切掌握其各部分形变、渗流等数据,需引入大量监测仪器。据有关统计显示,三峡大坝具有 16 252 支监测仪器,白鹤滩水电站具有约 15 000 支监测仪器,向家坝水电站具有约 5 000 支监测仪器^[4]。

这些监测仪器每天都会产生数以万计的数据,监测数据会受到环境干扰、设备老化等多种内外因素影响产生异常值。有时会误触发大坝险情警报,造成应急资源浪费,有时会影响大坝监测模型分析,对大坝状态造成错误估计,影响大坝安全。依靠人工处理异常值显然工作量巨大而且容易受到主观意识影响。因此近年来,有众多学者对大坝监测数据异常检测方法展开研究。

现有的针对大坝监测数据的异常监测方法可归纳为过程线法、统计检验法、时空判别法、数学模型法与近年来快速兴起的人工智能方法^[5]。过程线法主要通过相关方法绘制相关参数过程线通过人工或模式识别算法识别异常,如 Zheng 等^[6]提出一种自适应过程线异常检测方法,该方法将输入的大坝监测数据经过高斯模糊、二值化处理,再经过布谷鸟搜索算法完成异常监测。该方法最后经过案例研究,验证了其有效性。Shao 等^[7]也做了类似的研究工作,达到了较好的验证效果。过程线法在数据简单时能够到达较好效果,但随着数据增多,人工识别异常工作较为繁琐,引入模式识别方法后其准确度也待提高。

统计检验法主要用统计理论发掘数据中的异常,如李富强^[1]利用高阶统计量分析方法对大坝安全监测数据进行分析研究,成功从监测数据中提取到了反映大坝形变的特征量。还有如李子阳等^[8]利用了均值漂移模型、T 检验法、Cook 距离检验法对大坝监测数据进行了有效验证。统计检验法在面对已知分布规律的数据时能较好实施,但面对分布规律复杂未知的数据时,较难达到优异效果。

时空判别法主要利用相关理论对监测数据进行变换,找出数据局部特征如变化率异常的点,或全局特征如超出阈值的点。相关研究如 Liu 等^[9]利用小波变换与 Lipschitz 指数构建了一种大坝监测数据异常检测方法,经过实际数据验证,该方法能够准确检测到异常点。崔伟杰等^[10]利用小波变换模极大值和阈值方法实现异常值检测与去除,并利用小波软阈值去噪对监测数据噪声进行去除。可见时空判别法主要利用一些经典信号处理方法,在信号时频域进行异常识别判断。但经典的信号处理方法数据能力有限,在面对复杂数据时其性能有待进一步提升。

数学模型法主要应用坝工理论和数学方法对水工建筑进行建模,通过监测环境量进行异常检测,相关研究如 Zhang 等^[11]基于最小二乘回归、在线鲁棒性识别和早期预警、日变化率等方法针对数据不同异常类型集成融合提出一种数据类型自匹配在线异常检测方法,该方法经过大渡河实际监测数据验证,其实际运行速度得到有效提高,误检

率也降低至 2%。Xu 等^[12]基于单点时间序列模拟、远程重测时空分析和环境响应突变识别方法,提出一种针对大坝监测数据的三级在线异常检测方法,也在在上述大渡河监测数据上做了类似验证达到了良好效果。数学模型方法需要对大坝或者相关对象进行数学建模,其方法实施难度较大,周期较长,成本较高。

基于人工智能的异常检测方法近年来研究较多,其主要从监测数据中学习并发现异常,如郑霞忠等^[13]从大坝监测数据时间序列相关性的角度,利用密度聚类等方法实现了异常检测,并利用粒子群最小二乘支持向量机实现了异常数据恢复。赵新华等^[14]利用孤立森林算法对去除趋势项后的监测数据进行异常检测,并利用拉依达准则进行异常值清洗。Yang 等^[15]针对大坝监测数据将非均匀膨胀理论与局部异常因子结合,提出了一种对局部异常敏感和高适应性的改善局部异常因子异常检测方法。叶斌^[5]利用长短期记忆递归神经网络(long short term memory, LSTM)对单个大坝监测数据进行了预测并实现异常检测。上述方法都在相关数据集上得到了验证并取得了优异效果。

综合分析可知,人工智能方法近年来受到广泛研究,具有较好泛化能力,能够处理大量复杂数据,拟合未知数据分布,不需要过多复杂的系统对象知识,在训练数据量足够时能够达到较好性能^[16-17],是未来大坝监测数据异常检测的重要发展趋势。但上述人工智能方法研究内容都是针对单个监测参数的前后变化趋势或者单个数据的整体数据空间特征进行分析得到的异常检测方法,没有综合利用其他监测参数数值的有效信息。为此本文提出一种针对大坝监测数据的多维度 LSTM 异常检测与恢复方法。该方法可对大坝监测数据多维度分析,利用时间序列的时空特征对特定数据进行预测与异常检测。

1 LSTM 理论介绍

在常规的神经网络中,信息是单向传递的。当前的输出只与当前的输入有关。但是在某些场合,当前的输出不仅和当前输入有关,而且还和过去一段时间的数据相关,如文本预测就需要结合上文信息。因此,递归神经网络(recurrent neural network, RNN)自 1982 年被提出,RNN 因为具有反馈输入,可以有效利用时间序列前后信息关联性。但 RNN 在面对长时间序列预测时存在梯度爆炸与消失问题^[18]。因此在 1997 年 Hochreiter 等^[19]提出了 LSTM,后来被 Graves 改进推广^[20],LSTM 中的关键结构包括遗忘门、输入门和输出门。LSTM 可以有效遗忘噪声,保存重要信息,输出关键信息,具有长时间关联性学习能力;可以很好解决梯度消失与爆炸问题^[21]。LSTM 可以用于实现分类、预测等任务。

LSTM 模型如图 1,其中 x_t 表示时间序列的一个节点信息, h_t 表示输出的节点信息。

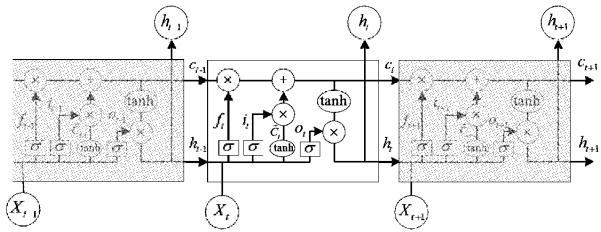


图 1 LSTM 模型

遗忘门的作用是将上一个节点的输出值 h_{t-1} 以及当前节点信息 x_t 作为当前遗忘门的输入, 在 Sigmoid 函数的映射下, 选择输出信息。激励为 1 表示完全保留信息, 而激励为 0 时则表示完全舍弃。最终获得的信息表示为 f_t 。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

输入门的作用是决定将信息如何放在细胞状态中, 即对输入进行选择。它主要是由 i_t 和 \tilde{C}_t 两个部分组成。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (4)$$

输出门决定了最后要输出什么样的值, 对细胞状态进行选择输出 h_t 。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

LSTM 十分擅长处理时间序列形式的数据, 有效利用时间序列信息的前后关联性, 提高预测能力。通过深度 LSTM 模型, 可以构建更为有效的复杂映射函数。

2 数据与方法

2.1 实验数据

本文中, 利用大渡河流域瀑布沟大坝真空激光准直系统监测数据作为实验验证数据。真空激光准直系统布置在大坝基础廊道, 是横向贯穿整个大坝的高精度测量装置。如图 2 所示, 监测系统主要由激光发射端与接收端以及中间的真空管道和测点箱组成。测量时, 发射端发射激光, 通过对光斑的相关特征进行测量解算后, 即可得到对应测点箱的横截面两方向位移。测点箱中的波带板逐个升降, 即可完成每个测点箱的位移测量。

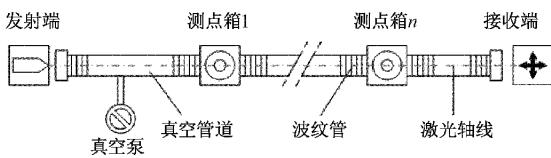


图 2 激光准直系统

如图 3 所示, 本文搜集了大渡河流域瀑布沟大坝廊道激光 9 个测点箱的纵向位移参数, 其时间范围从 2012 年 11 月 22 日 ~ 2022 年 4 月 11 日共计 3 241 个测点数据。其中

3 号测点数据由于整体偏离较大, 因此对其进行剔除, 后续只对除 3 号测点外的其余 8 个测点数据进行分析。

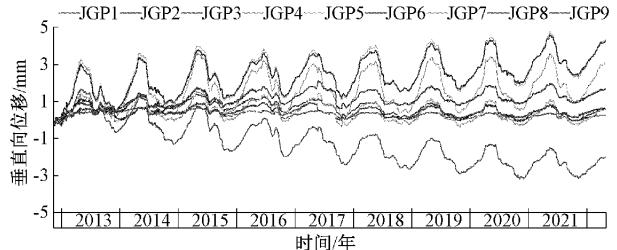


图 3 激光准直系统监测数据

2.2 单维度 LSTM 异常检测与恢复方法

LSTM 针对单维度时间序列, 具有较好的预测能力, 叶斌^[5]将其应用在了大坝渗压水头过程线的异常检测中, 经过与其他方法的对比, 具有良好效果。本节将其引入与后续本文所提方法进行对比, 验证本文所提方法的有效性。

针对激光准直监测数据, 按文献[5]思路搭建单维度 LSTM 预测方法如图 4 所示, 即利用单维度数据中某一时刻的前 30 个时间点对该时刻数据进行预测。利用滑窗重构数据样本输入模型进行训练。进行异常检测时, 对某个时间序列 x_t 进行连续预测, 可得到预测时间序列 \hat{x}_t 。

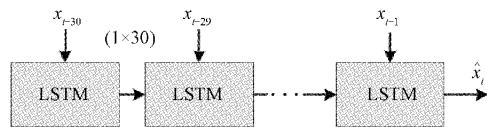


图 4 单维度 LSTM 时间序列预测模型

在经过上述变换之后, 可进行拉依达准则异常检测, 首先得到残差标准差:

$$\sigma = std(\hat{x}_t - x_t) \quad (7)$$

进一步得到异常标签序列:

$$sig(n) = if(|\hat{x}_t - x_t| > 3\sigma) \quad (8)$$

其中, $if(\cdot)$ 为符号函数, 当其中 \cdot 为真时取 1, 否则取 0, 取 1 对应异常。

2.3 多维度 LSTM 异常检测与恢复方法

考虑到大坝准直监测系统是多测点耦合系统, 不管是从其结构进行分析, 还是从数据形式上进行观察, 其数据间都具有相关性。因此若对单维度时间序列进行预测时, 若只考虑单维度时间序列, 其信息利用程度是不足的, 为此本文提出一种多维度 LSTM 异常检测与恢复方法。

利用 LSTM 理论构建如图 5 所示结构 LSTM 预测形式。即在输入多维度时间序列中构建滑窗, 逐步利用滑窗中的数据预测某一维度的下一时刻时间数据。相当于利用某一时刻以前某一时间长度的所有数据, 预测当前时刻数据。滑窗逐步滑动遍历整个时间区间, 即可形成某一时间维度预测后的序列 \hat{x}_t 。在得到 \hat{x}_t 之后, 接着再利用式(7)和(8)完成拉依达异常检测, 得到异常标签序列 $sig(n)$ 。

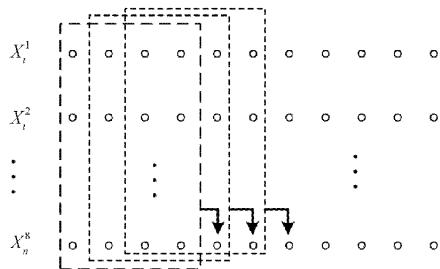


图 5 多维度时间序列 LSTM 预测

为实现如图 5 所示预测目的,利用 LSTM 理论搭建如图 6 所示的多维时间序列 LSTM 预测模型。模型第 1 层每个节点位置都输入 7 维度向量,共 30 个 LSTM 单元,第 1 层对输入数据做初步处理,每个 LSTM 单元都引出数据输出为 50 维度向量。第 2 层 LSTM 作为隐藏层共计 30 个时间单元,对每个时刻数据做进一步处理,综合处理推断得到最后时序的综合输出为 50 个点的特征向量。特征向量进一步输入全连接神经网络,经过处理计算,最后得到单点输出,也即预测输出。将其与预测时间点实际观测值均方差作为损失函数进行优化训练,即可对模型进行训练。

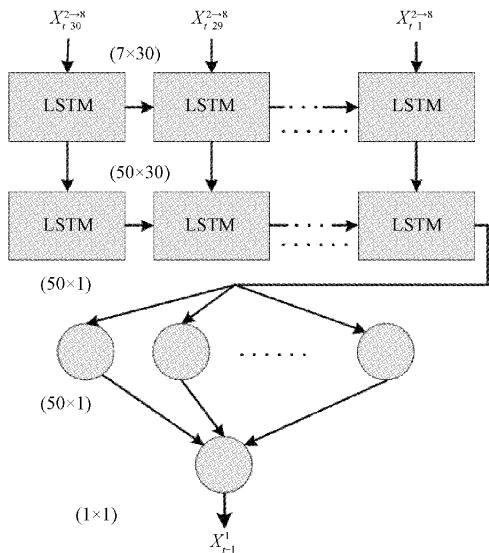


图 6 多维度时间序列 LSTM 预测模型

3 实验对比

本文分别利用单维度 LSTM 异常检测与恢复方法与本文提出的多维度 LSTM 异常检测与恢复方法对图 3 激光准直监测系统测点 1 数据进行异常检测,然后对结果进行对比分析,验证本文所提方法的有效性。

3.1 单维度 LSTM 异常检测与恢复

利用图 4 所示模型,对图 3 中的测点 1 数据进行异常检测。测点 1 数据包含 2012 年 11 月 12 日~2022 年 4 月 11 日共计 3 241 个数据点。利用前 70% 的数据点构建训练样本对模型进行训练。训练样本包含 31 个数据点,即某

个时间点的前 30 个数据和当前数据,当前数据为标签,按此规则设置 30 个时间点长度的滑窗以步长为 1 重构训练数据样本对单维度 LSTM 神经网络进行训练,当单维度 LSTM 预测序列与输入序列的均方误差趋于稳定收敛即认为其达到了较好训练效果并结束训练。在模型训练好后,利用其对后续 30% 的数据点进行预测测试。单维度 LSTM 预测输出结果如图 7 虚线所示。图 7 中的拉依达上界是预测虚线加 3 倍标准差(LSTM 预测值与测点 1 监测值残差的标准差),拉依达下界是预测虚线减 3 倍标准差。图 7 中实线上的圆圈为测点 1 数据中的异常数据标记,该标记是根据专家经验分析确定的。圆圈中的原始数据超过了拉依达上界或下界即可认为是该异常被成功检测。所以从图 7 中可以看出只有左边第一处异常被成功检测,其他几处异常均被漏检。

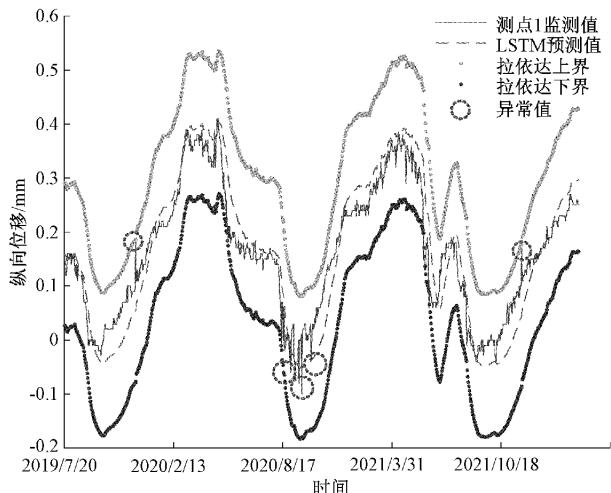


图 7 单维度 LSTM-拉依达异常检测结果

3.2 多维度 LSTM 异常检测与恢复

利用图 6 所示模型对测点 1 数据进行异常检测与恢复。不同于上述单维度 LSTM 方法只利用单维度测点信息进行预测恢复,本节利用图 3 中的 1~2 号和 4~9 号共 8 个测点对测点 1 数据进行预测,然后依据拉依达准则进行异常检测。模型训练使用测点 1~2、测点 4~9 共计 8 个测点的前 70% 的数据点,测试利用后 30% 的数据点。训练时,利用测点 2 和测点 4~9 共计 7 个测点数据作为 LSTM 训练输入,以测点 1 作为训练标签,其训练样本构建形式如图 5 所示,即以 30 个时间点的滑窗对 2 与 4~9 共计 7 个测点进行数据重构,标签为 1 号测点对应时间点的数据。利用重构好的训练样本对 LSTM 进行多轮训练,直到其测点 1 数据与 LSTM 预测输出数据之差的均方误差稳定收敛即认为其达到较好训练效果结束训练。测试时,将上述 8 个测点数据的后 30% 的 2 与 4~9 测点共计 7 个测点输入训练好的多维度 LSTM 神经网络中,输出对于测点 1 的预测数据,预测数据如图 8 虚线所示,拉依达上界与下界计算方法同 3.1 节所述,图中实线上的圆圈标注数据点为专

家经验判断的异常数据点,当其超过拉依达上界或者下界即认为异常被成功检测。从图中可以看出,图中数据头部和尾部的 2 处异常以及中间的 1 处异常被成功检测,只漏检了数据中段的 2 处异常,对比于单维度 LSTM 图 7 结果具有显著优势。

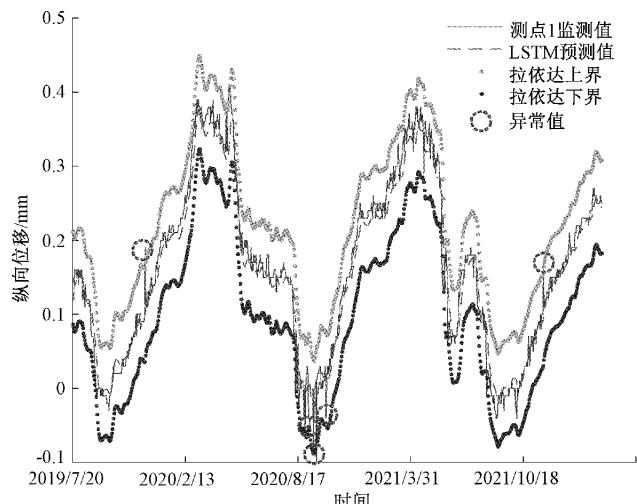


图 8 多维度 LSTM-拉依达异常检测结果

3.3 对比分析

综合对比两种方法的结果图 7 和 8,可以发现本文所提方法对应的结果图 8 所示 LSTM 的预测曲线与测点 1 数据曲线拟合程度较好,而图 7 所示的预测曲线较测点 1 数据具有显著偏差。因此图 7 后续计算出的拉依达边界一方面是其形状较原始数据趋势具有显著偏差,另一方面是其预测值与测点 1 测值残差标准差较大,导致计算出的拉依达边界偏离也较大,因此较难检测出数据中的异常。而本文所提方法因为考虑了测点 1 其余的 7 个相关测点数据,具有较好拟合程度,得到的拉依达边界也较为贴近原始数据,其异常检测效果较好。因此针对大坝激光准直监测数据,本文所提方法是一种有效的异常检测方法。

4 结 论

大坝监测数据反映着其运行状态,但受多种因素影响,其监测数据中难免会存在异常值,影响后续观测分析。现存的大坝监测数据存在信息利用不充分,异常信息挖掘不足问题。因此本文提出了一种考虑时空相关性的多维度 LSTM 异常检测与数据恢复方法。该方法综合利用数据间的相关关系与数据时间上的相关关系,对数据进行异常检测与恢复。以典型的大坝激光准直监测系统的 8 个测点时间序列数据为例,通过本文所提方法与单维度 LSTM 方法对比,不管是预测恢复拟合准确度还是从异常检测准确度,本文所提方法都具有显著优势。多维度 LSTM 异常检测与数据恢复方法效果优异,后续可利用到其他大坝监测数据中进行异常检测与数据恢复,具有良好的应用价值与前景。

参考文献

- [1] 李富强. 大坝安全监测数据分析方法研究[D]. 杭州: 浙江大学, 2012.
- [2] 蔡育杰. 国内外水利工程事故及其原因分析[J]. 建材与装饰, 2017(38): 251-252.
- [3] 叶芳毅, 王喜春. 大坝安全监测信息化管理及应用[J]. 电子测量技术, 2018, 41(9): 75-79.
- [4] 段杭, 任大春, 汤国强, 等. 白鹤滩水电站安全监测管理信息系统的研发与创新[J]. 中国水利, 2019(18): 20-22.
- [5] 叶斌. 基于 LSTM 模型的大坝安全监测数据异常值检测[D]. 武汉: 长江科学院, 2020.
- [6] ZHENG S, SHAO C, GU C, et al. An automatic data process line identification method for dam safety monitoring data outlier detection [J]. Structural Control and Health Monitoring, 2022, 29(7): e2948.
- [7] SHAO C, ZHENG S, Gu C, et al. A novel outlier detection method for monitoring data in dam engineering[J]. Expert Systems with Applications, 2022, 193: 116476.
- [8] 李子阳, 郭丽, 马福恒, 等. 基于统计诊断的大坝监测数据合理性检验[J]. 水利水电科技进展, 2018, 38(5): 71-75.
- [9] LIU J, LIAN J. Outliers detection of dam displacement monitoring data based on wavelet transform [J]. Applied Mechanics and Materials, Trans Tech Publications Ltd, 2011, 71-78: 4590-4595.
- [10] 崔伟杰, 李饶, 张学峰. 基于小波分析的大坝监测数据处理[J]. 四川水力发电, 2016, 35(3): 109-111, 116.
- [11] ZHANG F, LU X, LI Y, et al. A self-matching model for online anomaly recognition of safety monitoring data in dams [J]. Structural Health Monitoring, SAGE Publications, 2022, 22(1): 746-773.
- [12] XU Y, HUANG H, LI Y, et al. A three-stage online anomaly identification model for monitoring data in dams [J]. Structural Health Monitoring, SAGE Publications, 2022, 21(3): 1183-1206.
- [13] 郑霞忠, 陈国梁, 邹韬. 考虑时间序列关联的大坝监测异常数据清洗[J]. 水力发电, 2020, 46(4): 111-114, 125.
- [14] 赵新华, 范振东, 何宁, 等. 基于数据重构与孤立森林法的大坝自动化监测数据异常检测方法[J]. 中国农村水利水电, 2021(9): 174-178.
- [15] YANG J, QU X, HU D, et al. Research on singular value detection method of concrete dam deformation

- monitoring[J]. Measurement, 2021, 179: 109457.
- [16] 谢锦阳, 姜媛媛, 王力. 基于 RA-LSTM 的轴承故障诊断方法[J]. 电子测量与仪器学报, 2022, 36(6): 213-219.
- [17] 王雨虹, 王志中, 付华, 等. 多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究[J]. 仪器仪表学报, 2022, 43(3): 87-97.
- [18] 程换新, 黄震. 基于改进 PSO 优化 RNN 的短期电力负荷预测模型[J]. 电子测量技术, 2019, 42(20): 94-98.
- [19] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [20] GRAVES A. Supervised sequence labelling with recurrent neural networks [M]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, 385.
- [21] 王朝阳, 李丽敏, 温宗周, 等. 基于时间序列和 CNN-LSTM 的滑坡位移动态预测[J]. 国外电子测量技术,

2022, 41(3): 1-8.

作者简介

熊敏,硕士,副高级工程师,主要研究方向为大坝安全监测与监控。

E-mail:350915498@qq.com

江德军,硕士,工程师,主要研究方向为大坝安全监测与监控。

E-mail:497061128@qq.com

高志良,硕士,工程师,主要研究方向为大坝安全监测与监控。

E-mail:294292823@qq.com

何海锋,硕士,工程师,主要研究方向为大坝安全监测与监控工程化实施。

E-mail:50047572@qq.com

罗冲(通信作者),博士生,主要研究方向为装备智能健康评估,装备故障诊断。

E-mail:luochong33@foxmail.com