

DOI: 10.20040/j.cnki.1000-7709.2023.20220749

基于全卷积神经网络的大坝变形监测数据 粗差识别方法研究

齐智勇¹, 孙辅庭^{2,3}, 毛延翩¹, 周建波², 张春辉¹, 李秋炎¹

(1. 中国长江电力股份有限公司, 湖北 宜昌 443002; 2. 国家能源局大坝安全监察中心, 浙江 杭州 311122;
3. 中国电建集团华东勘测设计研究院有限公司, 浙江 杭州 311122)

摘要: 针对大坝变形监测数据普遍存在粗差的问题, 采用全卷积神经网络(FCN)模型对人工标记数据集进行表征学习的方法实现变形粗差数据识别的人工智能模拟; 在此基础上, 利用 Python 和 Tensorflow 框架构建了用于变形监测数据粗差识别的 FCN 模型并以人工标注数据集进行模型训练; 最后, 以训练得到的最优模型对某重力坝变形监测数据进行粗差识别应用。结果表明, 经训练的 FCN 模型能够较准确地识别大坝变形监测数据中的粗差值, 提高了大坝安全管理效率。

关键词: 监测; 粗差; 全卷积神经网络; 大坝安全; 人工智能

中图分类号: TV697 **文献标志码:** A **文章编号:** 1000-7709(2023)03-0087-04

1 引言

基于大坝安全监测数据开展大坝安全监控是及时发现大坝运行过程中潜在风险的重要手段, 而保证大坝安全监测数据的可靠、准确是开展有效监控的重要前提^[1]。大坝变形是安全监测中的重要项目, 也是评判大坝运行性态是否正常的最重要指标, 理想情况下大坝变形监测数据过程线的宏观形态应为连续光滑的, 但由于受观测者、周边环境条件、仪器工作稳定性等因素的影响, 可能导致少量监测数据与其他数据之间存在显著差异, 这些非结构原因导致的显著差异即为粗差数据。粗差实际上为错误的的数据, 监测数据实时更新过程中准确快速识别这些粗差数据以保证所分析数据的可靠性是大坝安全监控的基础工作。通过人工评判方式进行监测数据粗差识别效果较好, 但在海量实时数据面前这种做法不仅效率低, 且无法满足实时监控的要求。现阶段, 大坝安全监测领域基于计算机算法进行粗差数据识别的常用方法包括逻辑判别法、统计判别法、基于最小二乘的监控模型判别法等^[2]。其中, 逻辑判别法仅对显著超过物理意义或仪器量程的数据进行识

别, 仅能识别一部分比较显著的粗差; 统计评判法以统计学为基础, 以相近工况数据满足正态分布为前提, 其实际应用时存在的最大问题是能否得到足够的满足正态分布的数据; 监控模型法^[3]是最为常用和有效的方法, 即建立效应量的最小二乘监控模型并以残差作为评判依据, 该方法人工干预多且对难以建模的数据无效, 模型的维护代价也较大。此外, 小波理论、奇异值方法、灰色系统理论等数学方法也被用于粗差识别中, 但这些方法在大坝安全领域还未大规模应用^[4,5]。近年来, 随着计算机技术和人工智能的快速发展, 以卷积神经网络为核心的深度学习算法在图像识别领域迅速崛起并已取得良好的应用效果^[6]。在大坝安全监测领域, 王丽蓉等^[7]将图像识别技术引入, 通过图像识别的方法对大坝安全监测数据进行识别, 取得了较好的效果。鉴此, 本文直接利用时序数据向量并基于全卷积神经网络开展大坝变形监测数据粗差识别的探索, 旨在为监测数据粗差识别提供更为高效、准确的方法, 同时也为大坝安全监测数据智能化分析和大坝安全监控奠定基础。

2 基于 FCN 的大坝变形监测数据粗差识别方法

收稿日期: 2022-04-15, **修回日期:** 2022-06-06

基金项目: 国家重点研发计划(2021YFC3090100)

作者简介: 齐智勇(1985-), 男, 硕士、高级工程师, 研究方向为大坝安全监测、诊断分析, E-mail: qi_zhiyong@ctg.com.cn

2.1 粗差识别方案

变形监测数据的粗差模式可能各种各样,难以通过数据函数或规则去准确描述和穷举,因此可通过深度学习方法对工程师的识别成果进行表征学习,并通过计算机对粗差数据进行智能识别。大坝安全监测数据为效应量的时间序列,其数据格式为(时间,测值),且在时间轴上具有连续性;相对而言,图像数据是以三通道表达的数据序列,其数据格式为(R,G,B),且在空间上具有连续性。根据安全监测数据和图像数据的相似性和差异性,可借鉴图像识别的思路,将用于图像识别的二维卷积神经网络简化至一维形式,并采用卷积神经网络直接对时序数据进行处理,可避免将时序数据转化为图像继而再进行图像识别的繁琐过程。

监测数据粗差识别的目的一方面是判断数据序列中是否存在粗差(分类问题),另一方面还要定位粗差在时序数据中的位置(定位问题),分类卷积神经网络不足以完成以上两个任务。在图像分割领域, LONG J 等^[8]提出了通过全卷积神经网络(FCN)进行图像语义分割,该方法是训练端到端的全卷积神经网络(全卷积神经网络区别于分类卷积神经网络用全连接层得到固定长度的特征向量,而是用反卷积层对最后一个卷积层的特征图进行上采样而使得其恢复到原样本同样尺寸,从而实现了端到端的像素级分类),可实现对每个像素点的分类,监测数据粗差识别任务与该方法描述的任务非常类似,因此借鉴该方法用于监测数据粗差识别。

基于 FCN 开展大坝安全监测数据粗差识别的总体方案见图 1。其具体方案流程如下。

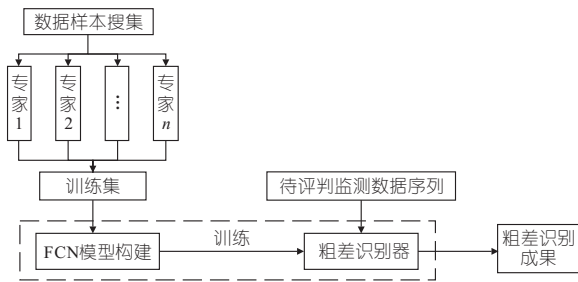


图 1 监测数据粗差识别方案

Fig. 1 Scheme of gross error detection

步骤 1 基于实际监测资料搜集含(不含)粗差数据的变形监测数据序列样本,并分发给大坝安全监测领域的工程技术人员进行人工粗差数据识别;以专家标记类型计数最大的结果作为最终的标记成果,并依据专家标记成果为每个数据分配标签值,制作训练数据集。

步骤 2 构建 FCN 模型,并利用训练数据集

进行模型训练,得到监测数据粗差识别器。

步骤 3 对任意待识别监测数据,输入粗差识别器,得到每个测值识别结果。

2.2 粗差识别 FCN 模型

用于图像分割的 FCN 模型是基于二维卷积构建的,其基本过程是通过若干层卷积运算提取不同尺度的图像特征,最后通过反卷积运算将特征图还原至与原图像相同的尺寸,并通过 softmax 运算对图像中每个位置的像素点进行分类^[8]。为提高模型预测精度,采用跳跃结构,即将不同阶段产生的特征图在反卷积运算过程中进行融合,从而充分利用不同尺度特征图的信息,构建用于监测数据粗差识别的一维 FCN 模型,其与图像识别模型最大的不同是在时间序列数据上采用一维卷积运算进行特征提取和还原,本文搭建的 FCN 模型结构见图 2。

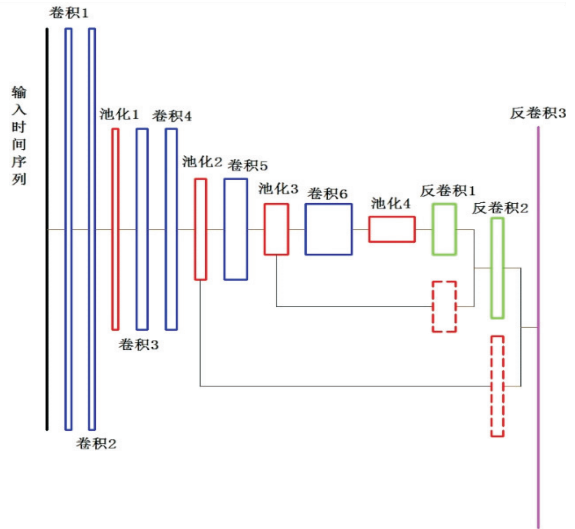


图 2 数据粗差识别 FCN 模型结构

Fig. 2 Architecture of FCN model for gross error detection

模型结构的输入层输入尺寸为 $n \times 2$ 的监测序列向量;卷积 1、2 为卷积运算,操作后均得到 $n \times 16$ 的特征向量;池化 1 为池化运算,操作后得到 $[n/2] \times 16$ 的特征向量;卷积 2、4 为卷积运算,操作后均得到 $[n/2] \times 32$ 的特征向量;池化 2 为池化运算,操作后得到 $[n/4] \times 32$ 的特征向量;卷积 5 为卷积运算,操作后得到 $[n/4] \times 64$ 的特征向量;池化 3 为池化运算,操作后得到 $[n/8] \times 64$ 的特征向量;卷积 6 为卷积运算,操作后得到 $[n/8] \times 128$ 的特征向量;池化 4 为池化运算,操作后得到 $[n/16] \times 128$ 的特征向量;反卷积 1 为反卷积运算,操作后得到 $[n/8] \times 64$ 的特征向量;反卷积 1 得到的特征向量和池化 3 得到的特征向量进行融合并进行反卷积 2 运算,得到 $[n/4] \times 32$ 的特征向量;反卷积 2 得到的特征向量和池化 2 得

到的特征向量进行融合并进行反卷积 3 运算,同时进行 softmax 分类,得到 $n \times m$ 的分类向量,其中 m 为分类的类别数。模型中的卷积运算和池化运算核尺寸均选用 3×3 大小,采用最大池化方法,卷积层后均采用 relu 函数进行激活。

3 模型训练及算例验证

3.1 训练数据准备

首先,搜集大量安全监测数据,包括不同工程类型、部位、监测仪器、监测手段、不同规律等数据;其次,对搜集的数据进行初步整理和可视化呈现,并交由长期工作在大坝安全监测和管理一线的工程技术人员进行人工粗差识别和标记;将数据状态标记为三种状态,其中 0 为正常数据,1 为疑似粗差数据,2 为粗差数据,标记后得到带标签的数据序列;最后,在带标签的数据序列中截取固定长度(本文取 64)测值及标签数据作为训练样本,为提升模型训练速度对样本进行标准化(将以时间戳表示的时间数值以最小值和最大值为上下界等比例缩放至 $[0, 1]$ 区间;将测值以最小值和最大值为上下界等比例缩放至 $[0, 1]$ 区间;标签值不作标准化处理)处理,最终形成训练数据集。

本文研究搜集了在水电站大坝的 300 余条变形长序列过程线(包括重力坝、拱坝、土石坝等多种坝型)作为研究数据。由于部分实测数据中粗差率较小,因此根据工程经验人工模拟了部分粗差数据。此外,本文所采用方法的基本前提是粗差数据占极少数,因此对粗差数据占比超过 5% 的情况进行人工删除部分粗差数据。最终通过标注和样本截取制作得到用于模型训练的数据集,其中样本数量约为 45 000 个。

3.2 模型训练

模型训练采用小批量随机梯度下降法,样本数量为 32,初始学习率为 0.002,学习率随训练迭代次数的增加以指数形式衰减,动量参数设为 0.9,所有样本循环训练一次为 1 个 Epoch。模型训练中,将样本数据分为训练集和验证集,比例为 4 : 1。

图 3 为模型训练结果。由图 3 可看出,训练的前 5 轮模型损失函数迅速下降,训练 5 轮后模型损失函数缓慢下降并趋于稳定,同时训练损失和验证损失差距逐渐增大,表明模型存在一定程度的过拟合现象。从模型精度看,最终的模型验证准确率和召回率约在 91%,综合训练和验证结果可保存第 13 轮训练后的参数作为最终的模型




图 3 模型训练结果

Fig. 3 Result of FCN model training

训练结果。

3.3 粗差识别效果

采用训练得到的最优模型识别监测数据粗差,为进一步提高粗差识别精度,参考训练数据的制备方式,采用“投票法”识别最终的粗差。即先将待识别监测数据截取成固定长度为 m (m 为输入的数据样本长度,此处与模型训练时保持一致,取为 64) 的预测数据;再采用 FCN 模型对截取的数据段进行粗差识别;最后统计原待识别监测数据中每个测值被判为哪种类型的次数最多即标记为该种识别结果。利用该方法对某重力坝变形监测(包括垂线和引张线)数据进行批量粗差识别,图 4 为部分典型测点的识别结果。由图 4 可知,本文提出的 FCN 模型及粗差识别方法对变形监测数据粗差识别可行、有效,尽管 FCN 模型自身训练结果的准确率在 91% 左右,但通过“投票法”的进一步处理能够较好地识别变形监测数据

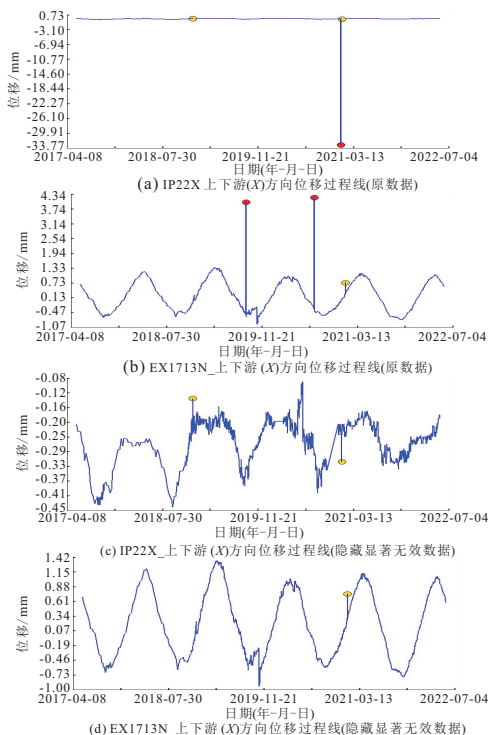


图 4 模型应用结果

Fig. 4 Result of model application

中的粗差和疑似粗差数据。

4 结 论

a. 针对大坝变形监测数据普遍存在粗差的问题,提出采用全卷积神经网络(FCN)对大量人工标记数据样本进行表征学习的方法实现监测数据粗差识别的智能模拟,在此基础上,利用Python和Tensorflow框架构建了变形监测数据粗差识别的FCN网络模型,并以人工标注数据集进行模型训练,模型准确率和召回率达到91%左右。

b. 利用训练好的模型并通过“投票法”开展某大坝变形监测数据粗差识别。结果表明,经训练的FCN模型能较准确地识别变形监测数据中的粗差数据。

参 考 文 献:

[1] 吴中如. 中国大坝的安全和管理[J]. 中国工程科学, 2000, 2(6): 36-39.

[2] 李啸啸,蒋敏,吴震宇,等. 大坝安全监测数据粗差

识别方法的比较与改进[J]. 中国农村水利水电, 2011(3):102-105,112.

[3] 吴中如. 水工建筑物安全监控理论及其应用[M]. 北京:高等教育出版社,2003.

[4] 刘千驹,陈代明,陈少勇,等. 小波理论在大坝安全监测数据粗差探测中的应用[J]. 西北水电,2020(增刊1):129-132.

[5] 吴雄伟,程伟平. 基于奇异值分解算法的大坝监测数据回归模型[J]. 水电自动化与大坝监测,2007, 31(3): 53-55.

[6] SCHMIDHUBER JÜRGEN. Deep learning in neural networks: An overview [J]. Neural networks, 2015, 61: 85-117.

[7] 王丽蓉,郑东健. 基于卷积神经网络的大坝安全监测数据异常识别[J]. 长江科学院院报,2021,38(1):72-77.

[8] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, USA:IEEE,2015: 3431-3440.

Research on Gross Error Detecting Method of Monitored Dam Deformation Data Based on Fully Convolutional Networks

QI Zhi-yong¹, SUN Fu-ting^{2,3}, MAO Yan-pian¹, ZHOU Jian-bo², ZHANG Chun-hui¹, LI Qiu-yan¹

(1. China Yangtze Power Co., Ltd., Yichang 443002, China; 2. Large Dam Supervision Center, National Energy Administration of the People's Republic of China, Hangzhou 311122, China; 3. PowerChina Huadong Engineering Co., Ltd., Hangzhou 311122, China)

Abstract: Goss error detecting method of monitored dam deformation data is researched based on the fully convolutional neural networks(FCN). Firstly, the method of representation learning of artificially labeled data sets by FCN model was proposed to simulate engineers' experience. Secondly, the FCN model for gross error detection was built and artificially labeled data sets were used for model training. Finally, the trained FCN model was used for gross error detecting of monitored deformation data of a gravity dam. The results show that the gross error in monitored dam deformation data can be accurately obtained by the proposed method, which can improve efficiency of dam safety management.

Key words: monitoring; gross-error; FCN; dam safety; artificial intelligence

(上接第 26 页)

Influence of Project of Water Diversion from Yangtze River to Taihu Lake on Hydrodynamic Characteristics of Gonghu Bay Under Typical Wind Field in Summer

WANG Wen-kang^{1,2}, XU Shi-kai^{1,2}, ZHAO Jin-xiao^{1,2}, DING Wen-hao^{1,2}, WANG Yong^{1,2}

(1. Nanjing Hydraulic Research Institute, Nanjing 210029, China; 2. Key Laboratory of Taihu Basin Water Management, Ministry of Water Resources, Wuxi 214131, China)

Abstract: Focusing on the influence of the project of water diversion from Yangtze River to Taihu Lake on the hydrodynamic characteristics of Gonghu Bay, the physical model of the wind-driven currents in Taihu Lake was used to analyze the influence on the hydrodynamic characteristics and the vertical flow velocity and planar circulation distribution in Gonghu Bay under the different wind speeds and different diversion flow of Wangyu River in the typical wind field in summer. The results indicate that the variation of Wangyu River diversion flow affects the hydrodynamic characteristics of Gonghu Bay mainly in the near and middle regions, but has little impact on Taihu Lake; The implementation of the water diversion project from Yangtze River to Taihu Lake significantly changes the vertical velocity distribution characteristics on the outlet axis of Wangyu River in the near and middle regions, but has no effect on the vertical velocity distribution characteristics at the junction section; The characteristics of the planar circulation in Gonghu Bay are affected by both wind speed and diversion flow, the changes of wind speed and diversion flow have a significant impact on the area, location and shape of the plane circulation. The research results can provide hydrodynamic theoretical support for evaluating the impact of the water diversion project from Yangtze River to Taihu Lake on the water environment of Gonghu Bay.

Key words: project of water diversion from Yangtze River to Taihu Lake; Gonghu Bay; wind-driven current; hydrodynamics; physical model