

基于 EEMD-LSTM-ARIMA 的土石坝渗压预测模型研究

岑威钧, 王肖鑫, 蒋明欢
(河海大学 水利水电学院, 江苏 南京 210098)

摘要: 渗压监测是土石坝渗流安全评价的重要内容之一。由于渗压受到诸多外界因素的影响,测点的渗压值时间序列往往存在非平稳性、局部突变等特点,为此基于“分解-重构-组合”的思想构建了土石坝渗压预测的 EEMD-LSTM-ARIMA 模型。首先采用集合经验模态分解 (EEMD) 对时间序列特征进行提取,根据长短期记忆神经网络 (LSTM) 对提取出的特征分量进行预测,同时结合差分自回归移动平均方法 (ARIMA) 进行残差修正,组合 LSTM 和 ARIMA 的预测结果,重构得到改进预测模型。以某深厚覆盖层上的土石坝工程为例,选取主河床坝体防渗墙后 2 个典型测点的实测渗压值序列为研究对象进行应用验证。结果表明:相较于单一的 LSTM 模型和 ARIMA 模型,改进模型的平均绝对误差 MAE、均方误差 MSE、均方根误差 RMSE 均为 3 种模型中的最小值,预测精度明显优于另外 2 种模型,该模型为土石坝渗压的精确预测分析提供了新途径。

关键词: 土石坝; 渗压预测; 集合经验模态分解; 长短期记忆神经网络; 差分自回归移动平均

中图分类号:TV641

文献标识码: A

文章编号: 1672-643X(2023)02-0180-06

Seepage pore water pressure prediction model of earth – rock dams based on EEMD-LSTM-ARIMA

CEN Weijun, WANG Xiaoxin, JIANG Minghuan

(College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China)

Abstract: Seepage monitoring is one of the important contents of seepage safety evaluation of earth – rock dams. The seepage pore water pressure is affected by multiple external factors, so the time series of seepage pore water pressure at measuring points is often characterized by nonstationarity and local abrupt changes. Regarding to this, the EEMD-LSTM-ARIMA model for seepage pore water pressure prediction of earth – rock dams is constructed according to the concept of decomposition – reconstruction – combination. Firstly, the time series features are decomposed by the ensemble empirical mode decomposition (EEMD), and the extracted feature components are predicted by the long short-term memory (LSTM) neural network. At the same time, the residual error is corrected by the autoregressive integrated moving average (ARIMA), and the improved prediction model is reconstructed by combining the prediction results of LSTM and ARIMA. Taking an earth – rock dam on a deep overburden as an example, the measured seepage pore water pressure series of two typical measuring points behind the cutoff wall of the main riverbed dam are selected as the research objects for application verification. The results show that, compared with the single LSTM model and ARIMA model, the mean absolute error, the mean square error and the root mean square error of the proposed prediction model are the smallest, and the prediction accuracy of the proposed model is obviously superior to the other two models. Therefore, the proposed model can provide a new approach for accurate prediction and analysis of seepage pore water pressure of earth – rock dams.

Key words: earth – rock dam; pore water pressure prediction; ensemble empirical mode decomposition (EEMD); long short-term memory (LSTM) neural network; autoregressive integrated moving average (ARIMA)

收稿日期:2022-07-22; 修回日期:2022-09-14

基金项目:国家自然科学基金项目(51979089、51679073)

作者简介:岑威钧(1977—),男,浙江慈溪人,博士,教授,博士生导师,研究方向为土石坝抗震与工程渗流安全。

1 研究背景

渗压监测是评判土石坝渗流安全性态的必要手段之一^[1]。渗压值受到库水位、降雨、气温等外界因素的影响,导致其时间序列呈现出非线性、多突变等特点^[2-3]。因此,探究并建立准确有效的土石坝渗压预测模型具有重要的现实意义。

近年来,随着人工智能和机器学习的不断发展,机器学习算法逐渐应用于土石坝渗压预测模型的构建中。王晓玲等^[4]将特征注意力机制引入蚁狮算法优化的长短期记忆网络,提出了一种土石坝渗压预测耦合模型,并研究了影响渗压效应量的影响因子。刘永涛等^[5]根据集合经验模态分解(ensemble empirical mode decomposition, EEMD)对土石坝渗压监测值进行分解,采用相关向量机(relevance vector machine, RVM)对分解后的各分量预测后叠加,结果表明所建组合模型能够对突变点进行有效预测,提高了模型的泛化能力。陈守开等^[6]考虑了渗压时序数据的动态变化特征,建立了基于动态记忆功能的循环神经网络渗压预测模型,结果表明所建模型整体上能够较好预测渗压的变化趋势,相较于静态模型误差减小了 26.8%,具有较高的可靠度和预测性能。秦继辉等^[7]将能够筛选显著相关因素的逐步回归分析(stepwise regression analysis, SRA)和小波神经网络(wavelet neural network, WNN)相结合,构建了基于 SRA - WNN 的土石坝渗压预测模型,改进模型预测结果的均方根误差(RMSE)和平均绝对误差(MAE)均小于单一逐步回归和小波神经网络模型。

研究发现,不管是传统的回归预测,还是应用越来越广的机器学习预测,单一模型往往具有一定的局限性,机器学习算法对数据噪声的敏感性较强,很难达到理想的预测精度^[8-9]。本文基于“分解-重构-组合”的思想,引入了能够将非平稳序列分解为多个平稳分量的集合经验模态分解(EEMD),采用非线性拟合能力较强的长短期记忆神经网络(long short-term memory, LSTM)进行预测分析,同时根据差分自回归移动平均方法(autoregressive integrated moving average, ARIMA)进行残差修正,并应用于某土工膜防渗土石坝的渗压预测分析,验证了改进模型的可靠性。

2 基于 EEMD-LSTM-ARIMA 的组合预测模型

2.1 EEMD 算法

集合经验模态分解(EEMD)广泛应用于从非线性

性序列中提取信号^[10-12]。该算法通过对信号引入有限幅度的白噪声,有效解决了信号混频现象,具体实现过程如下。

将生成的白噪声序列 $n_i(t)$ 与时间序列 $x(t)$ 组合,得到新时间序列 $x_i(t)$:

$$x_i(t) = x(t) + n_i(t) \quad (i = 1, 2, \dots, m) \quad (1)$$

式中: m 为生成白噪声序列的次数。

采用经验模态分解(empirical mode decomposition, EMD)对新时间序列 $x_i(t)$ 分解,分量包含本征模态函数 $C_{i,j}(t)$ 和趋势项 $r_i(t)$:

$$x_i(t) = \sum_{j=1}^L C_{i,j}(t) + r_i(t) \quad (2)$$

式中: $C_{i,j}(t)$ 为添加 i 次白噪声后计算出的第 j 个本征模态函数; L 为本征模态函数的数量。

将 m 组本征模态函数 $C_{i,j}(t)$ 和趋势项 $r_i(t)$ 取平均计算得到分量 $I_j(t)$ 和趋势项 $R(t)$:

$$I_j(t) = \frac{1}{m} \sum_{i=1}^m C_{i,j}(t) \quad (3)$$

$$R(t) = \frac{1}{m} \sum_{i=1}^m r_i(t) \quad (4)$$

式中: $I_j(t)$ 为最终计算出的分量; $R(t)$ 为最终趋势项。

2.2 LSTM 模型

长短期记忆(LSTM)网络是循环神经网络的改进模型^[13],用输入门、输出门、遗忘门 3 种“门”和细胞状态组成的结构来代替传统神经网络中的隐藏层, LSTM 算法能够较为准确地预测长时间序列,同时还可以克服计算过程中出现的梯度消失和爆炸等问题^[14-16]。

遗忘门 f_t :

$$f_t = \sigma(w_f[h_{t-1}, x_t] + b_f) \quad (5)$$

式中: σ 为 sigmoid 函数; w_f 为遗忘门的权值; h_{t-1} 为上一时刻的单元输出; x_t 为 t 时刻的输入; b_f 为遗忘门的偏移值。

输入门 i_t :

$$i_t = \sigma(w_i[h_{t-1}, x_t] + b_i) \quad (6)$$

$$c'_t = \tanh(w_c[h_{t-1}, x_t] + b_c) \quad (7)$$

$$c_t = f_t c_{t-1} + i_t c'_t \quad (8)$$

式中: w_i 、 w_c 分别为输出门和细胞状态的权值; b_i 、 b_c 分别为输入门和细胞状态的偏移值; c'_t 为前一时刻细胞状态; c_t 为当前时刻细胞状态。

输出门 o_t :

$$o_t = \sigma(w_o[h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (10)$$

式中: w_o 为输出门的权值; b_o 为输出门的偏移值; h_t

为 t 时刻的单元输出。

2.3 ARIMA 模型

差分自回归移动平均模型 (ARIMA) 是一种广泛应用于各领域的预测模型^[17-19], 主要包含自回归模型和移动平均模型 2 个部分。自回归模型的阶数为 p , 信号差分的阶数为 d , 移动平均模型的阶数为 q , 因此模型通常表示成 $ARIMA(p, d, q)$, 具体的数学表达式为:

$$\Phi(B) \nabla^d x_t = \Theta(B) \varepsilon_t \quad (11)$$

$$\nabla^d = (1 - B)^d \quad (12)$$

$$\Phi(B) = 1 - \sum_{i=1}^p \phi_i B^i \quad (13)$$

$$\Theta(B) = 1 - \sum_{i=1}^q \theta_i B^i \quad (14)$$

式中: $\Phi(B)$ 为 p 阶自回归系数多项式; ∇ 为差分; x_t 为

时间序列; $\Theta(B)$ 为 q 阶移动平均系数多项式; ε_t 为白噪声序列; ϕ 为自回归系数; θ 为移动平均系数。

ARIMA 模型的具体实现过程如下:

(1) 对所研究的时间序列数据进行平稳性验证, 如果不满足要求, 则对其进行 d 阶差分转换成平稳时间序列。

(2) 通过自相关系数图和偏自相关系数图以及贝叶斯信息准则^[20] 确定阶数 p 和 q 。

(3) 采用确定好阶数的 $ARIMA(p, d, q)$ 拟合时间序列, 并根据预测后的数据和原时间序列进行结果统计和预测精度分析。

2.4 EEMD-LSTM-ARIMA 渗压预测模型建模流程

基于 EEMD-LSTM-ARIMA 的渗压预测模型的建模流程如图 1 所示。




图1 EEMD-LSTM-ARIMA 渗压预测模型的建模流程

渗压预测模型建模采用 EEMD 对渗压时间序列进行特征提取, 将分解后得到的各本征模态分量 (intrinsic mode functions, IMF) 分量和剩余分量分别划分训练集和测试集代入 LSTM 模型中进行训练得到 LSTM 模型预测结果 A_1 , 确定具体的 ARIMA 模型后, 对渗压时间序列进行预测, 得到 ARIMA 残差预测结果 A_2 , 将 LSTM 模型和 ARIMA 模型的预测结果重构为 $A = A_1 + A_2$, 最终输出建立的 EEMD-LSTM-ARIMA 模型预测结果, 并根据预测模型的评价指标 (平均绝对误差 MAE、均方误差 MSE、均方根误差 RMSE) 进行模型评价。

3 实例土石坝工程应用

某复合土工膜防渗土石坝, 位于四川省康定县境内的大渡河支流田湾河的上游, 坝顶高程为

2 934.00 m, 最大坝高为 56 m, 坝基覆盖层最大深度为 148 m。该坝布置了较为完善的变形、渗流及相关环境量监测系统, 其中渗流监测采用埋设在不同部位的多个渗压计数据, 采集时间间隔为 1 d。选取大坝主河床处渗压计 P3 和 P4 两个测点 2016 年 6 月 19 日至 2018 年 6 月 9 日的实测数据进行研究, 图 2 为研究期内库水位、P3 和 P4 测点渗压值以及降雨量的历时过程线。

由图 2 可知, 库水位、P3 和 P4 测点渗压值以及降雨量的历时过程线均为非平稳时间序列, P3 和 P4 测点渗压序列与库水位时间序列表现出一定程度的周期性变化, 2 个测点渗压序列与库水位时间序列具有相同的变化特征, 且库水位对渗压的影响具有滞后效应。降雨量时间序列并未表现出显著周期性变化, 其时间序列与测点渗压时间序列并未呈现较强的变化一致性。




图2 实例工程研究期内库水位、P3和P4测点渗压值以及降雨量的历时过程线

为了将渗压非平稳时间序列转换为平稳时间序列,采用EEMD对P3和P4测点渗压值时间序列进行分解,分别得到5个本征模态分量IMF1~IMF5和趋势项,为了检验各IMF分量能否表征原时间序列的不同特征尺度,对其分别进行显著性检验,各IMF分量均通过50%显著性检验,表明各分量对原渗压时间序列的表征程度较好。IMF1分量位于80%~90%的置信区间内,在所有IMF中分量最大,剩余分量IMF2~IMF5

分布在50%~80%置信区间内。

确定具体的LSTM模型后,进行ARIMA模型的参数定阶,对P3和P4测点的渗压时间序列进行平稳性验证,检验结果表明通过1阶差分能够将其转换成平稳时间序列,因而确定了模型中的阶数 $d=1$ 。为了对ARIMA模型中的另外2个参数定阶,计算了序列的自相关系数和偏自相关系数,计算结果如图3所示。




图3 1阶差分时间序列的自相关系数图和偏自相关系数图

由图3可知,滞后阶数等于1时,渗压值1阶差分时间序列的自相关系数和偏自相关系数均处在置信区间外,滞后阶数大于1的自相关系数基本落在置信区间内,自相关系数和偏自相关系数随着滞后阶数的增加始终存在非0取值,不会在某个滞后阶数后恒为0,表现为拖尾。根据图3中自相关系数和偏自相关系数的数值和变化趋势,确定 p 和 q 的值均为1,即得到最终的ARIMA模型为ARIMA(1,1,1)。

确定好LSTM和ARIMA模型后,利用MATLAB软件建立对应模型进行预测,将LSTM预测结果和ARIMA预测结果重构得到最终预测结果。为了验证所建EEMD-LSTM-ARIMA改进模型的可靠度和精度,同时建立单一的LSTM模型和ARIMA模型对渗压值时间序列进行预测,各模型对P3、P4测点渗压值的预测结果与实测值对比及各模型预测结果残差分别如图4和5所示。




图4 3个模型对P3、P4测点渗压值的预测结果与实测值对比




图5 3个模型对P3、P4测点渗压值的预测结果残差

由图4和5可知,3种预测模型的整体波动趋势大体上与实测数据一致,EEMD-LSTM-ARIMA改进模型预测结果的吻合程度明显高于另外2种模型,改进模型整个时间序列预测结果的残差近乎均小于另外2种模型,可见改进模型相较于另外2种模型而言,具有更高的预测精度。

根据渗压值预测结果计算得到P3和P4测点EEMD-LSTM-ARIMA模型、LSTM模型、ARIMA模型预测结果的平均相对误差分别为5.24%、7.30%、11.18%和3.27%、7.38%、10.62%,相较于LSTM和ARIMA模型,改进模型对2个测点渗压值预测结果的平均相对误差分别降低了28.2%、53.1%和55.7%、69.2%。

为了进一步比较3个模型的预测效果,将时间序列分为6段(第1段:2016-06-19至2016-10-16;第2段:2016-10-17至2017-02-13;第3段:2017-02-14至

2017-06-13;第4段:2017-06-14至2017-10-11;第5段:2017-10-12至2018-02-08;第6段:2018-02-09至2018-06-09),统计计算各时间段3个模型对P3、P4测点渗压值预测结果的平均相对误差,如图6所示。

由图6可看出,除第3段时间段(2017-02-14至2017-06-13)之外,其余时间段P3测点EEMD-LSTM-ARIMA模型预测结果的平均相对误差均小于另外2种模型;P4测点EEMD-LSTM-ARIMA模型各时段预测结果的平均相对误差均小于LSTM模型和ARIMA模型。另外,EEMD-LSTM-ARIMA模型各时段平均相对误差变化波动最小,预测效果的稳定性最佳,ARIMA模型各时段平均相对误差变化波动最大,预测效果的稳定性较差。

计算3个模型对P3和P4测点渗压值预测结果的平均绝对误差MAE、均方误差MSE、均方根误差RMSE,该3种预测评价指标的计算结果如图7、8所示。




图6 各时段3个模型对P3、P4测点渗压值预测结果的平均相对误差




图7 3个模型对P3测点渗压值预测结果的3种评价指标计算结果




图8 3个模型对P4测点渗压值预测结果的3种评价指标计算结果

由图7、8可知,相较于LSTM模型和ARIMA模型,EEMD-LSTM-ARIMA模型拟合段和预测段的平均绝对误差 MAE 、均方误差 MSE 、均方根误差 $RMSE$ 均为最小,进一步说明改进模型具有更高的预测性能。此外,改进模型拟合段的 MAE 、 MSE 、 $RMSE$ 值和预测段的 MAE 、 MSE 、 $RMSE$ 值分别接近,表明所建模型预测结果的稳定性高。综上所述,本文所建EEMD-LSTM-ARIMA模型能够更准确地预测土石坝渗压的变化规律,保障了预测结果的精度。

4 结论

本文建立了基于“分解-重构-组合”思想的EEMD-LSTM-ARIMA预测模型,以某土石坝实测渗压值进行应用验证。主要结论如下:

(1)集合经验模态分解(EEMD)消除了序列的非平稳特征,实现了序列的平稳化,LSTM和ARIMA模型预测结果的组合重构增强了模型的拟合能力和预测精度。

(2)EEMD-LSTM-ARIMA模型预测结果与实测值吻合度明显高于LSTM模型和ARIMA模型,整个时间序列预测结果的残差近乎平均小于另外2种模型。

(3)相较于LSTM和ARIMA模型,实例土石坝P3和P4测点EEMD-LSTM-ARIMA模型渗压预测结果的平均相对误差分别降低了28.2%、53.1%和55.7%、69.2%,且改进模型的平均绝对误差 MAE 、均方误差 MSE 、均方根误差 $RMSE$ 均为最小。

参考文献:

- [1] 顾冲时,苏怀智,刘何稚.大坝服役风险分析与管理研究述评[J].水利学报,2018,49(1):26-35.
- [2] 陶丛丛,陈宏伟,孔松,等.基于原型监测的黏土心墙堆石坝渗流分析[J].长江科学院院报,2017,34(9):70-73+78.
- [3] 徐颖,傅志敏.复合土工膜防渗土石坝渗流安全监控指标拟定[J].水电能源科学,2021,39(1):83-86.
- [4] 王晓玲,李克,张宗亮,等.耦合ALO-LSTM和特征注意力机制的土石坝渗压预测模型[J].水利学报,2022,53(4):403-412.
- [5] 刘永涛,郑东健,孙雪莲,等.基于EEMD-RVM的土石坝渗

流量时间序列预测模型[J].水利水电科技进展,2021,41(3):89-94.

- [6] 陈守开,蒋海峰,史海波,等.基于动-静态模型的渗压值预测与分析[J].人民长江,2021,52(5):174-179.
- [7] 秦继辉,吴云星,谷艳昌.基于逐步回归和小波神经网络的土石坝渗压预测模型研究[J].安全与环境学报,2018,18(5):1670-1674.
- [8] 李俊,苏怀智,周仁练.基于关联规则的土石坝渗流推理预测方法及应用[J].水利水电科技进展,2019,39(5):89-94.
- [9] 黄铭,刘俊.降雨影响下高边坡渗压神经网络监测模型[J].上海交通大学学报,2013,47(10):1548-1551.
- [10] 郭彦,林秀芝,侯素珍,等.基于EMD和BP算法的降水数据插补[J].水资源与水工程学报,2015,26(2):16-21.
- [11] 傅质馨,殷贵,朱俊澎,等.基于EEMD和LSTM的水电机组劣化度预测方法研究[J].太阳能学报,2022,43(2):75-81.
- [12] 范鹏飞,祝福源.基于HS算法优化的EEMD-RNN混凝土坝位移预测模型[J].中国农村水利水电,2021(8):180-185+194.
- [13] 冷天培,马刚,向正林,等.基于时序分解与深度学习的堆石坝变形预测[J].水力发电学报,2021,40(10):147-159.
- [14] 郝玉莹,赵林,孙同,等.基于RF-LSTM的地表水体水质预测[J].水资源与水工程学报,2021,32(6):41-48.
- [15] 杨背背,殷坤龙,杜娟.基于时间序列与长短时记忆网络的滑坡位移动态预测模型[J].岩石力学与工程学报,2018,37(10):2334-2343.
- [16] 王立辉,杨辉斌,王银堂,等.基于GWO-LSTM的丹江口水库入库径流预测[J].水利水运工程学报,2021(6):51-59.
- [17] 黄玥,黄志霖,肖文发,等.三峡水库水位调度对出库水质影响分析与水质预测[J].水资源与水工程学报,2020,31(4):78-85.
- [18] 杨敏,丁剑,王伟.基于ARIMA-SVM模型的快速公交停站时间组合预测方法[J].东南大学学报(自然科学版),2016,46(3):651-656.
- [19] 吴静,李振波,朱玲,等.融合ARIMA模型和GAWNN的溶解氧含量预测方法[J].农业机械学报,2017,48(S1):205-210+204.
- [20] 刘亚新,徐杨.基于机器学习的葛洲坝水电站日均出力预测[J].人民长江,2022,53(4):201-209+220.