

DOI: 10.20040/j.cnki.1000-7709.2023.20222203

基于 EEMD-AEFA-LSTM 的混凝土坝变形预测模型

曹梦茜^{a,b}, 郑东健^{a,b}

(河海大学 a. 水利水电学院; b. 水文水资源与水利工程科学国家重点实验室, 江苏 南京 210098)

摘要: 对混凝土坝变形监测资料进行合理的数据挖掘和准确的预测分析是确保大坝安全长效运行的关键手段, 大坝变形时间序列受到温度、水位等环境量的影响, 具有周期性、非线性等变化特征, 现有的智能算法无法很好地捕捉序列的非线性关系。对此, 提出了基于 EEMD-AEFA-LSTM 模型的混凝土坝变形预测模型, 采用集合经验模态分解 EEMD 有效分解变形时间序列, 通过人工电场算法 AEFA 优化的长短期记忆网络 LSTM 模型对各分解分量进行预测并重构预测结果。选取某混凝土坝 EX16、EX24 测点的变形监测资料开展预测研究。结果表明, 所建 EEMD-AEFA-LSTM 模型的预测精度明显高于 AEFA-LSTM、PSO-LSTM、GA-LSTM 模型, 预测结果的平均绝对误差、均方误差、均方根误差均为最小值, 为混凝土坝变形的精确预测提供了新途径。

关键词: 集合经验模态分解; 人工电场算法; 长短期记忆网络; 混凝土坝; 变形预测

中图分类号: TV698.11

文献标志码: A

文章编号: 1000-7709(2023)09-0089-05

1 引言

混凝土坝变形监测资料作为能够直观反映大坝运行性态的数据, 是衡量大坝是否处于安全运行状态的关键依据^[1, 2]。因此, 建立稳定、高效且准确的混凝土坝变形预测模型, 对及时掌握大坝未来变形趋势, 提供大坝安全控制决策、保障大坝安全长效运行具有重要意义^[3]。随着人工智能的不断发展, 基于智能算法的混凝土坝变形预测模型现已成为当下主要预测方法之一。魏博文等^[4]分别采用神经网络和自回归滑动平均模型预报变形监测数据的多尺度分量, 所建组合模型能够准确捕捉监测信息中的有效成分, 充分表征了序列蕴含的时变特性, 预测精度较传统模型明显提升; 杨晨蕾等^[5]为消除大坝测点数量增多造成的预测效率和精度降低这一负面影响, 引入模糊 C-均值聚类算法对大坝变形测点进行分区, 并采用 XGBoost 算法预测不同分区的测点, 结果表明所建模型在突变点处拟合效果较好。此智能算法虽然一定程度上提高了模型的预测精度, 但由于混凝土坝变形受到温度、水位等众多环境量的影

响^[6, 7], 其时间序列呈现出较为显著的非平稳变化趋势, 导致模型在迭代过程中易出现收敛缓慢、局部最优、总体精度偏低等情况。对此, HUANG N E 等^[8]提出了经验模态分解 EMD; WU Z 等^[9]在其基础上通过引入白噪声消除了 EMD 存在的模态混叠, 提出了集合经验模态分解 EEMD, 目前该算法已广泛应用于水文、地质、环境等领域, 但在混凝土坝变形预测方面的研究较少。因此, 本文引入集合经验模态分解 EEMD 将混凝土坝变形序列分解为多个平稳分量, 采用新型元启发式优化算法——人工电场算法 AEFA 应用于长短期记忆网络 LSTM 模型的参数优化, 构建了基于 EEMD-AEFA-LSTM 的混凝土坝变形预测模型, 以某实际混凝土坝工程的变形监测资料进行预测分析, 验证了改进模型的准确性和可靠性。

2 算法原理

2.1 集合经验模态分解

集合经验模态分解 EEMD 是在经验模态分解 EMD 的基础上引入有限幅度的白噪声, 有效避免了尺度混合带来的分量性质不唯一的缺点,

收稿日期: 2022-10-20, **修回日期:** 2022-11-15

基金项目: 国家自然科学基金项目(52179128)

作者简介: 曹梦茜(1998-), 女, 硕士研究生, 研究方向为水工结构安全监测, E-mail: 690817850@qq.com

通讯作者: 郑东健(1965-), 男, 博士、教授、博导, 研究方向为水工结构安全与健康诊断, E-mail: zhengdj@hhu.edu.cn

能够从非线性和非平稳时序数据中提取信号^[10, 11],具体实现过程如下。

将白噪声序列 $s_i(t)$ 与混凝土坝测点变形序列 $y(t)$ 进行组合,得到新测点变形时间序列 $y_i(t)$:

$$y_i(t) = y(t) + s_i(t) \quad i = 1, 2, \dots, n \quad (1)$$

式中, n 为生成白噪声序列的次数。

根据经验模态分解 EMD 分解新测点变形时间序列 $y_i(t)$, 分解后得到的分量包含本征模态函数 $b_{i,j}(t)$ 和趋势项 $u_i(t)$:

$$y_i(t) = \sum_{j=1}^L b_{i,j}(t) + u_i(t) \quad (2)$$

式中, $b_{i,j}(t)$ 为引入 i 次白噪声后计算出的第 j 个本征模态函数; L 为本征模态函数的个数。

对 n 组本征模态函数 $b_{i,j}(t)$ 和趋势项 $u_i(t)$ 进行平均计算得到最终的分量 $I_j(t)$ 和趋势项 $R(t)$:

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

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

2.2 人工电场算法

人工电场算法 AEFA 通过模拟带电粒子在电场中的运行轨迹,将优化求解过程中的最优解转化为带电粒子的最优位置^[12]。人工电场算法主要考虑了粒子之间的相互引力,电荷量大的粒子吸引电荷量小的粒子向其位置更新移动,具体实现过程如下。

在 m 维寻优空间内, $t+1$ 时刻带电粒子 i 的最优位置 $p_i^m(t+1)$ 为:

$$p_i^m(t+1) = \begin{cases} p_i^m(t) & f(P_i(t)) < f(X_i(t+1)) \\ x_i^m(t+1) & f(X_i(t+1)) \leq f(P_i(t)) \end{cases} \quad (5)$$

式中, p_i^m, x_i^m 均为 m 维寻优空间内带电粒子 i 的位置; $f(P_i), f(X_i)$ 均为目标函数值。

带电粒子之间的库仑力 $F_{ij}^m(t)$ 为:

$$F_{ij}^m(t) = K(t) \frac{Q_i(t)Q_j(t)(p_j^m(t) - X_i^t(t))}{R_{ij}(t) + k} \quad (6)$$

式中, $K(t)$ 为 t 时刻的库仑常数; Q_i, Q_j 分别为带电粒子 i, j 的电荷量; $R_{ij}(t)$ 为两粒子之间的欧氏距离; k 为一个极小的常数。

在 m 维寻优空间内, t 时刻带电粒子 i 的总电力 $F_i^d(t)$ 为:

$$F_i^d(t) = \sum_{j=1, j \neq i}^N rF_{ij}^m(t) \quad (7)$$

式中, r 为 $[0, 1]$ 之间的随机数; N 为带电粒子总数。

在 t 时刻,带电粒子 i 在 m 维寻优空间的电

场强度 $E_i^d(t)$ 为:

$$E_i^d(t) = F_i^d(t)/Q_j(t) \quad (8)$$

t 时刻带电粒子 i 在 m 维寻优空间的加速度 $a_i^d(t)$ 为:

$$a_i^d(t) = Q_i(t)E_i^d(t)/M_i(t) \quad (9)$$

式中, $M_i(t)$ 为 t 时刻带电粒子 i 的质量。

在寻优求解时,根据迭代结果以此更新粒子当前的位置 $X_i^d(t+1)$ 和速度 $V_i^d(t+1)$:

$$V_i^d(t+1) = rV_i^d(t) + a_i^d(t) \quad (10)$$

$$X_i^d(t+1) = X_i^d(t) + V_i^d(t+1) \quad (11)$$

2.3 长短期记忆网络

长短期记忆网络 LSTM 模型改进梯度传递过程,显著消除了反向传播过程中容易出现的梯度消失这一现象,具有较为准确和稳定的长序列预测性能,长短期记忆网络模型主要包含 3 种门结构和记忆细胞,具体计算公式如下。

遗忘门 f_t :

$$f_t = \sigma(\omega_f[h_{t-1}, x_t] + b_f) \quad (12)$$

式中, σ 为 sigmoid 函数; ω_f 为遗忘门的权重系数; h_{t-1} 为 $t-1$ 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 :

$$i_t = \sigma(\omega_i[h_{t-1}, x_t] + b_i) \quad (13)$$

$$c'_t = \tanh(\omega_c[h_{t-1}, x_t] + b_c) \quad (14)$$

$$c_t = f_t c_{t-1} + i_t c'_t \quad (15)$$

式中, ω_i, ω_c 分别为输出门和记忆细胞的权重系数; b_i, b_c 分别为输入门和记忆细胞的偏移值; c'_t 为前一时刻记忆细胞; c_t 为当前时刻记忆细胞。

输出门 o_t :

$$o_t = \sigma(\omega_o[h_{t-1}, x_t] + b_o) \quad (16)$$

$$h_t = o_t \tanh(c_t) \quad (17)$$

式中, ω_o 为输出门的权重系数; b_o 为输出门的偏移值; h_t 为 t 时刻单元输出。

3 基于 EEMD-AEFA-LSTM 的混凝土坝变形预测建模流程

基于 EEMD-AEFA-LSTM 的混凝土坝变形预测建模流程见图 1。建模具体流程如下。

步骤 1 采用集合经验模态 EEMD 分解大坝测点变形时间序列,将分解后得到的各分量进行训练集和测试集划分。

步骤 2 确定长短期记忆网络 LSTM 模型中输入层、隐藏层和输出层的具体节点个数,将平均绝对误差 M_{MAE} 作为人工电场算法 AEFA 的寻优函数,对 LSTM 模型中的学习率进行迭代寻优。

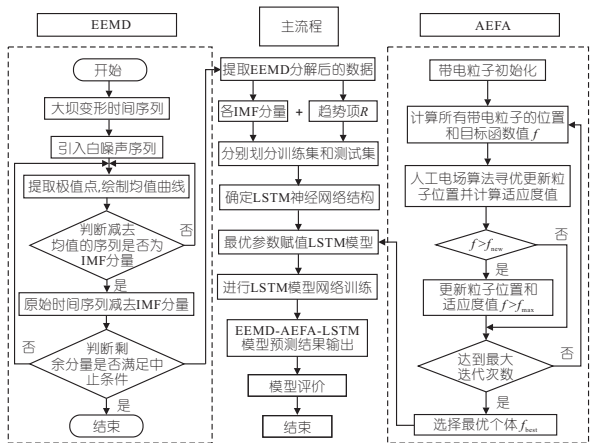


图 1 基于 EEMD-AEFA-LSTM 的混凝土坝变形预测建模流程

Fig. 1 Deformation prediction modeling process of concrete dam based on EEMD-AEFA-LSTM

步骤 3 将各分量的模型预测结果进行叠加

重构,最终得到 EEMD-AEFA-LSTM 模型的预测结果。

步骤 4 采用平均绝对误差 M_{MAE} 、均方误差 M_{MSE} 、均方根误差 R_{RMSE} 这 3 个评价指标评判 EEMD-AEFA-LSTM 模型的预测性能。

4 实例应用

某水电站工程以发电为主,兼有航运、过木等综合效益。水库总库容 $26.0 \times 10^8 \text{ m}^3$,电站装机 7 台,总装机容量 1 400 MW,设计多年平均发电量 $49.5 \times 10^8 \text{ kW} \cdot \text{h}$ 。大坝为混凝土重力坝,坝顶高程 74.00 m,最大坝高 101 m,坝顶全长 783 m。选取 EX16、EX24 测点 2018 年 1 月 1 日至 2021 年 12 月 31 日的变形监测数据进行实例分析,具体的引张线测点布置见图 2。




图 2 引张线测点布置立面图

Fig. 2 Layout elevation of tension line measuring points

为将 EX16、EX24 测点的非平稳变形时间序列平稳化,采用集合经验模态 EEMD 分解 2 个测点的变形时间序列,分别计算得到 5 个 IMF 分量和趋势项 R,其中 IMF1~IMF3 分量频率较高,能够较好反映水压分量引起的大坝变形,剩余的低频分量周期性明显,能够较好反映温度和时效分量引起的大坝变形。计算得到的各分量均通过 60% 显著性检验,说明 EEMD 算法能够有效挖掘大坝影响因子间的非线性关系,分解得到的分量可从多个尺度表征原变形时间序列的物理意义。

确定好 EEMD 分解得到的各 IMF 分量和趋势项 R 后,按照相同比例分别划分训练集和测试集进行计算分析,将该混凝土坝 2018 年 1 月 1 日至 2020 年 12 月 31 日的变形监测数据作为训练集,2021 年 1 月 1 日至 2021 年 12 月 31 日的变形监测数据作为预测集。

划分训练集和测试集后,需确定人工电场算法的计算参数,设置人工电场算法 AEFA 的最大迭代次数为 100 次,粒子种群数量为 5,学习率的搜索寻优范围为 $[0.0001, 0.01]$,采用 AEFA 算法寻找 LSTM 模型中的最优学习率。LSTM 模型采用输入层、单隐藏层、输出层 3 层架构,输入

层和输出层均为测点变形值,隐藏层的节点个数通过试算法选定为 5,确定 LSTM 模型架构为 1-5-1。为验证 EEMD-AEFA-LSTM 变形预测模型的预测性能和稳定性,分别采用 AEFA-LSTM、PSO-LSTM、GA-LSTM 模型进行预测,并采用平均绝对误差 M_{MAE} 、均方误差 M_{MSE} 、均方根误差 R_{RMSE} 对 4 种模型进行结果对比分析。

采用 Matlab 软件建立 EEMD-AEFA-LSTM、AEFA-LSTM、PSO-LSTM、GA-LSTM 模型,分别计算得到 EX16、EX24 测点的大坝变形预测结果,根据 4 种模型的变形预测结果计算各模型的预测残差,图 3 为 EX16 测点 4 种模型的预测性能对比。由图 3 可知,4 种模型预测结果时间序列与实测值时间序列的整体变化情况一致,EEMD-AEFA-LSTM 模型的预测效果明显优于另外 3 种模型的预测效果。4 种模型的预测结果残差随时间的变化存在一定波动性,EEMD-AEFA-LSTM 模型残差随时间变化的波动性最小,GA-LSTM 模型随时间变化的波动性最大。当实测值时间序列变化趋势存在较大转变时,除 EEMD-AEFA-LSTM 模型以外,其余 3 种模型均出现较大的“突变”情况。整体上来说,EEMD-

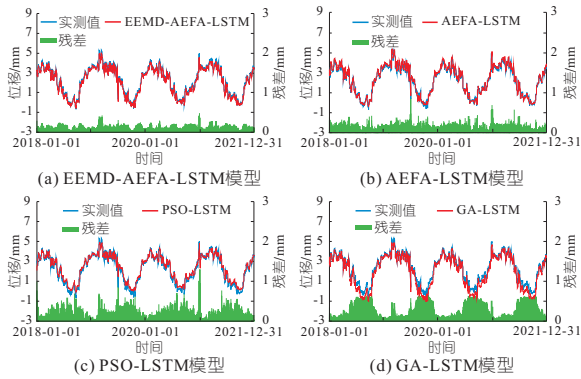


图3 EX16测点4种模型的预测性能对比

Fig. 3 Comparison of prediction performance of four models at EX16 measuring point

AEFA-LSTM模型的预测值时间序列与实测值时间序列的拟合程度最高。

为进一步比较4种模型的预测效果,将测点变形时间序列分为4段(2018-01-01~2018-12-31、2019-01-01~2019-12-31、2020-01-01~2020-12-31、2021-01-01~2021-12-31)并根据预测结果分别统计EX16、EX24测点各年份的平均误差,具体见图4。由图4可知,EX24测点4个时间段的EEMD-AEFA-LSTM模型预测结果的平均误差均小于另外3种模型,除2020年EX16测点AEFA-LSTM模型预测结果的平均误差略小于EEMD-AEFA-LSTM模型预测结果的平均误差外,EX16测点EEMD-AEFA-LSTM模型预测结果的平均误差均小于另外3种模型预测结果的平均误差。4种模型的预测性能排序为EEMD-AEFA-LSTM模型>AEFA-LSTM模型>PSO-LSTM模型>GA-LSTM模型。从整体上来看,EEMD-AEFA-LSTM模型各时段平均误差的数值和变化波动均为最小。根据实测变形数据和4种模型的预测结果求出3个评价指标并进行预测结果对比。




图4 4种模型各时段的预测结果平均误差

Fig. 4 Average error of prediction results of four models in each period

EX16、EX24测点拟合段和预测段的3个预测评价指标计算结果见图5。由图5可知,EEMD-AEFA-LSTM模型预测结果的3个预测评价指标均为4种模型中最小。EX16测点

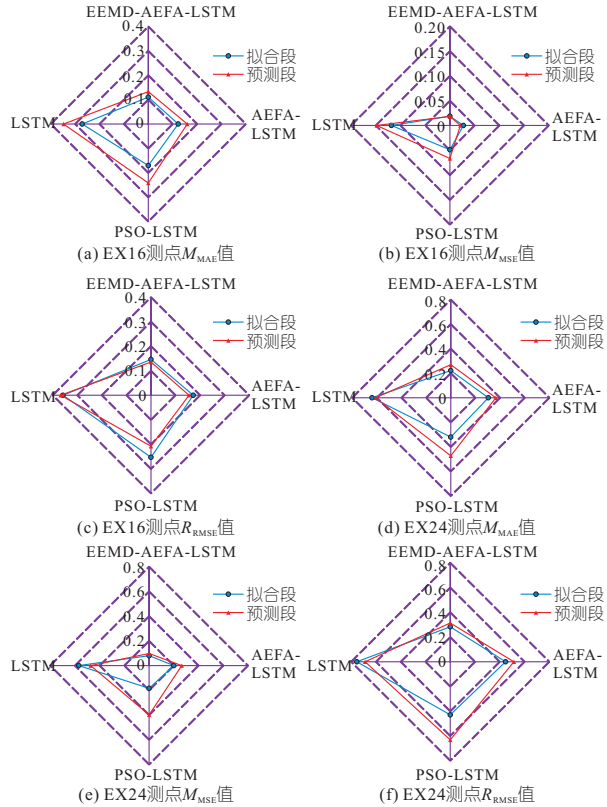


图5 预测评价指标计算结果

Fig. 5 Calculation results of prediction evaluation indicators

EEMD-AEFA-LSTM模型预测段 M_{MAE} 值相较于AEFA-LSTM、PSO-LSTM、GA-LSTM模型分别降低了16.9%、45.2%、61.8%, M_{MSE} 值分别降低了12.8%、72.4%、87.6%, R_{RMSE} 值分别降低了12.6%、34.8%、63.2%。EX24测点EEMD-AEFA-LSTM模型预测段 M_{MAE} 值相较于AEFA-LSTM、PSO-LSTM、GA-LSTM模型分别降低了26.3%、43.0%、55.9%, M_{MSE} 值分别降低了62.6%、75.2%、79.1%, R_{RMSE} 值分别降低了38.8%、50.3%、54.3%。另外EEMD-AEFA-LSTM模型拟合段和预测段的 M_{MAE} 、 M_{MSE} 、 R_{RMSE} 值均分别接近,改进模型的预测稳定性有所提升。进一步佐证了本文所提混凝土坝变形预测模型的强稳健性和广适用性,为混凝土坝变形预测提供了一种新方法。

5 结论

a. 集合经验模态分解EEMD实现了大坝变形时间序列的平稳化,人工电场算法AEFA优化的长短期记忆网络LSTM有效解决了模型在迭代过程中易出现收敛缓慢、总体精度偏低等情况。

b. EX16、EX24测点所建改进模型预测值时间序列与实测值时间序列的拟合程度最高,除EEMD-AEFA-LSTM模型以外,另外3种模型均出现较大的“突变”情况。

