

DOI: 10.20040/j.cnki.1000-7709.2023.20221887

基于 FCM-WOA-LSTM 的大坝变形预测模型及其应用

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: 随着大坝变形监测资料的持续积累和变形测点数量的不断增多, 预测分析全部变形测点往往需耗费大量的时间, 容易造成反馈不及时的问题。对此, 引入模糊 C-均值聚类算法(FCM), 根据大坝变形规律的相似程度进行分区, 将鲸鱼优化算法(WOA)用于长短期记忆神经网络(LSTM)模型的参数优化, 建立基于 FCM-WOA-LSTM 的大坝变形预测模型, 以某混凝土双曲拱坝的实测变形资料作为样本数据进行预测分析, 并与 LSTM 模型和 SVM 模型的预测结果进行对比。结果表明, FCM-WOA-LSTM 模型预测结果的平均绝对误差 M_{MAE} 、均方误差 M_{MSE} 、均方根误差 R_{RMSE} 均为 3 种模型中最小, 且拟合段的 3 个评价指标值和预测段的 3 个评价指标值均接近, FCM-WOA-LSTM 模型具有更高的预测精度和更好的适用性。

关键词: 大坝变形; 测点分区; 模糊 C-均值聚类; 鲸鱼优化算法; 长短期记忆网络

中图分类号: TV698.1⁺¹

文献标志码: A

文章编号: 1000-7709(2023)05-0071-05

1 引言

变形监测是评判大坝安全性态的重要依据之一, 对大坝变形进行预测分析是保障大坝安全长效运行的必要手段^[1]。目前, 大坝变形预测模型可大致分为统计模型、确定性模型和混合模型三类, 其中, 统计模型因其结构形式简单和计算快捷等优点, 是大坝变形预测分析较常用的模型, 但统计模型难以建立影响因子之间的非线性关系, 无法表征大坝变形的一些复杂特征^[2, 3]。随着计算机技术的不断发展, 机器学习算法逐渐应用于大坝变形分析和预测模型构建中, 如鄢涛等^[4]提出了一种基于 EEMD-ELM 的大坝变形预测方法, 有效平抑了原变形序列的波动特征, 且叠加不同特征尺度变形分量后的预测结果相较于单一模型的预测结果更准确; 苏燕等^[5]构建了联合时间注意力机制和门控循环单元神经网络的大坝动态变形预测模型, 引入随机森林分析各影响因子的重要程度并揭示了大坝变形的作用机制, 克服了神经网络模型在训练过程中产生的信息缺失; 温勇兵等^[6]利用小波包分解技术对变形监测资料进行细化重构, 并建立基于逐步回归和支持向量机的组合预测模型, 工程实例表明, 所建组合模型具有

较强的泛化能力和较高的预测精度。近年来, 相继提出了基于智能仿生的元启发式优化算法, 如灰狼算法(GWO)、人工蜂群算法(ABC)、鲸鱼优化算法(WOA)等, 这类算法全局搜索能力强、计算高效稳定, 已成功应用于各领域的高精度预测分析中^[7-9], 但采用此类方法逐一对大坝所有测点进行建模不利于及时反馈大坝运行性态。为弥补预测效率的不足, 可采用 Kohonen 聚类、DB-SCAN 等算法对大坝变形测点进行合理分区, 但测点之间的分区界定存在模糊性。鉴此, 本文引入模糊 C-均值聚类算法(FCM), 并将鲸鱼优化算法(WOA)和适用于长序列预测的长短期记忆神经网络(LSTM)模型相结合, 提出一种基于 FCM-WOA-LSTM 的大坝变形预测模型, 提高了大坝变形的预测效率和预测精度, 为大坝变形的精准预测分析提供了新的技术手段。

2 基于 FCM-WOA-LSTM 的大坝变形预测模型建立

2.1 算法原理

2.1.1 FCM 聚类算法

采用模糊 C-均值聚类算法(FCM)可有效实

收稿日期: 2022-09-11, 修回日期: 2022-11-18

基金项目: 国家重点研发计划(2018YFC1508603); 国家自然科学基金重点项目(51739003)

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

现大坝变形分区。FCM 聚类算法通过优化目标函数,得到每个变形数据相对于所有类别样本中心的隶属度,继而将变形数据聚类到具有最大隶属值的类中,以实现变形测点的准确聚类^[10]。

假设大坝存在 n 个变形测点,分别为 x_1, x_2, \dots, x_n , FCM 聚类算法的目标函数为:

$$\min J_m(\mathbf{U}, \mathbf{c}) = \sum_{j=1}^c \sum_{i=1}^n u_{ij}^m \|x_i - v_j\|^2 \quad (1)$$

式中, \mathbf{U} 为隶属度矩阵, $\mathbf{U} = [u_{ij}]_{c \times n}$; c 为大坝变形的聚类中心数; u_{ij} 为测点 x_i 与聚类中心 v_j 的隶属度; m 为模糊指数,一般取值区间为 $[1.5, 2.5]$ 。

FCM 聚类算法的具体实现过程如下。

步骤 1 给定具体的模糊指数 m 和变形测点聚类个数 c , 初始化隶属度矩阵 \mathbf{U} , 同时计算各变形测点之间的欧氏距离。

步骤 2 计算聚类中心 v_j :

$$v_j = \frac{\sum_{i=1}^n u_{ij}^m x_i}{\sum_{i=1}^n u_{ij}^m} \quad (2)$$

步骤 3 构建隶属度矩阵 \mathbf{U} 并进行更新计算:

$$u_{ij} = 1 / \left(\sum_{k=1}^c \left(\frac{d_{ij}}{d_{kj}} \right)^{\frac{2}{m-1}} \right) \quad (3)$$

步骤 4 重复步骤 2、3, 直到迭代过程中前、后 2 次隶属度差值小于某设定阈值时结束。

2.1.2 鲸鱼优化算法

鲸鱼优化算法(WOA)是模拟座头鲸捕猎行为的一种新型优化算法,具有良好的全局搜索能力,由包围猎物、泡泡网攻击和随机搜索三部分组成。

(1)包围猎物。座头鲸在包围猎物过程中会选择最优路径,具体计算公式为:

$$D = |CX^*(t) - X(t)| \quad (4)$$

$$X(t+1) = X^*(t) - AD \quad (5)$$

式中, D 为猎物与最优搜索代理之间的距离; $X^*(t)$ 为猎物位置; $X(t)$ 为鲸鱼位置; t 为迭代次数; \mathbf{A} 、 \mathbf{C} 均为系数向量。

(2)泡泡网攻击。采用收缩包围和螺旋更新 2 种方式模拟座头鲸捕猎行为,通过这 2 种方式更新座头鲸位置进而向猎物移动,根据随机产生的概率交替更新最优搜索代理,具体计算公式为:

$$X(t+1) = D' e^{bl} \cos 2\pi l + X^*(t) \quad (6)$$

$$D' = |X^* - X(t)| \quad (7)$$

式中, b 为对数螺旋的形状参数; l 为 $0 \sim 1$ 之间的随机数。

(3)随机搜索。座头鲸之间存在随机搜索方式,搜索阶段可按最近搜索代理更新位置,具体计算公式为:

$$D = |CX_{\text{rand}}(t) - X(t)| \quad (8)$$

$$X(t+1) = X_{\text{rand}}(t) - AD \quad (9)$$

式中, $X_{\text{rand}}(t)$ 为猎物的随机位置。

WOA 算法寻优过程中,生成随机数 $q \in [0, 1]$, 当满足 $q > 0.5$ 时进入泡泡网攻击模式,否则对系数向量 \mathbf{A} 进行判断, $|\mathbf{A}| \geq 1$ 时对目标猎物进行搜索, $|\mathbf{A}| < 1$ 时对目标猎物进行包围,随着 WOA 算法的迭代次数增加,逐渐从猎物搜索状态转变为猎物包围状态。

2.1.3 LSTM 算法

长短期记忆(LSTM)网络是循环神经网络的改进模型,用输入门、输出门、遗忘门三种“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 算法能较准确地预测长时间序列,同时能克服计算中出现的梯度消失和爆炸等问题,图 1 为 LSTM 的内部结构。

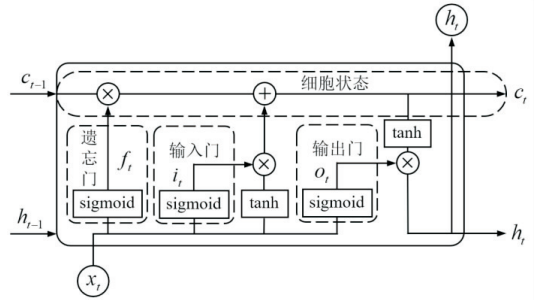


图 1 LSTM 内部结构

Fig. 1 LSTM internal structure

遗忘门 f_t :

$$f_t = \sigma(\omega_f [h_{t-1}, x_t] + b_f) \quad (10)$$

式中, σ 为 sigmoid 函数; ω_f 为遗忘门的权重值; 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 :

$$i_t = \sigma(\omega_i [h_{t-1}, x_t] + b_i) \quad (11)$$

$$c'_t = \tanh(\omega_c [h_{t-1}, x_t] + b_c) \quad (12)$$

$$c_t = f_t c_{t-1} + i_t c'_t \quad (13)$$

式中, ω_i 、 ω_c 分别为输出门、细胞状态的权重值; b_i 、 b_c 分别为输入门、细胞状态的偏移值; c'_{t-1} 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 :

$$o_t = \sigma(\omega_o [h_{t-1}, x_t] + b_o) \quad (14)$$

$$h_t = o_t \tanh(c_t) \quad (15)$$

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

2.2 基于 FCM-WOA-LSTM 的大坝变形预测建模流程

基于 FCM-WOA-LSTM 的大坝变形预测建模流程见图 2。

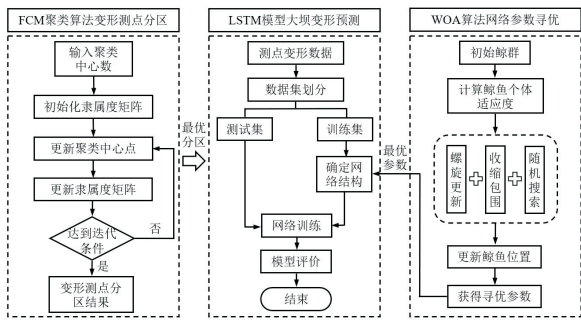


图 2 基于 FCM-WOA-LSTM 的大坝变形预测建模流程

Fig. 2 FCM-WOA-LSTM dam deformation prediction modeling process

混合监控模型预测的具体流程如下。

步骤 1 采用 FCM 聚类算法对坝体变形测点进行有效分区,基于 FCM 的大坝分区结果,选取不同分区的典型测点。

步骤 2 将测点变形时间序列按一定的比例划分训练集和测试集。

步骤 3 将训练集输入 WOA 算法对 LSTM 模型的超参数进行寻优,确定 LSTM 模型的具体结构后,将训练集的变形数据代入模型进行预测。

步骤 4 根据实测坝体变形数据和模型的最终预测结果计算平均绝对误差 M_{MAE} 、均方误差 M_{MSE} 、均方根误差 R_{RMSE} 这 3 个预测评价指标,以此验证 FCM-WOA-LSTM 模型的预测效果。

3 应用

3.1 工程概况

某混凝土双曲拱坝坝高坝顶高程 1 885 m,坝基高程 1 580 m,2012 年 11 月 30 日开始蓄水,2013 年 6 月完成坝体建设。水库正常蓄水位 1 880 m,设计库容 $77.65 \times 10^8 \text{ m}^3$ 。在 # 1、# 5、# 9、# 11、# 13、# 16、# 19、# 23 坝段共布置了 34 个正倒垂监测点,选取测点 2017 年 1 月 1 日~2018 年 12 月 31 日的变形监测资料作为样本数据,测点的具体分布情况见表 1。

表 1 测点分布情况

Tab. 1 Distribution of measurement points

高程 /m	# 1 坝段	# 5 坝段	# 9 坝段	# 11 坝段	# 13 坝段	# 16 坝段	# 19 坝段	# 23 坝段
1 885	PL1-1	PL5-1	PL9-1	PL11-1	PL13-1	PL16-1	PL19-1	PL23-1
1 829		PL5-2	PL9-2	PL11-2	PL13-2	PL16-2	PL19-2	
1 778		PL5-3	PL9-3	PL11-3	PL13-3	PL16-3	PL19-3	
1 730		PL5-4	PL9-4	PL11-4	PL13-4	PL16-4	PL19-4	
1 664			PL9-5	PL11-5	PL13-5	PL16-5	PL19-5	
1 601				IP11-1	IP13-2	IP16-1		

3.2 基于 FCM 聚类算法的测点分区结果

为提高大坝变形预测效率,首先采用 FCM 聚类算法对变形测点进行分区,算法中的聚类中

心数 c 采用轮廓系数法确定,某变形测点 y_i 的轮廓系数 S_i 为:

$$S_i = [a(y_i) - p(y_i)] / \max\{p(y_i), a(y_i)\} \quad (16)$$

式中, $a(y_i)$ 为变形测点 y_i 与本聚类集内其他变形测点的平均距离; $p(y_i)$ 为变形测点 y_i 与最邻近聚类集内所有变形测点的平均距离。

$S_i \in [0, 1]$, 其值越大说明聚类效果越好。

为确定达到最佳聚类效果,假定聚类中心数 c 的变化范围为 $[2, 10]$, 分别计算不同聚类中心数下的轮廓系数,具体计算结果见图 3。




图 3 基于 FCM 聚类算法的测点分区结果

Fig. 3 Measurement point partitioning results based on FCM clustering algorithm

由图 3 可知,聚类中心数 $c = 4$ 时,轮廓系数最大,其值为 0.50,此时同聚类集内的变形测点密集度较高,不同聚类集之间的离散度最高,因此最佳聚类中心数为 4。

聚类中心数为 4 时的测点分区结果见图 4。

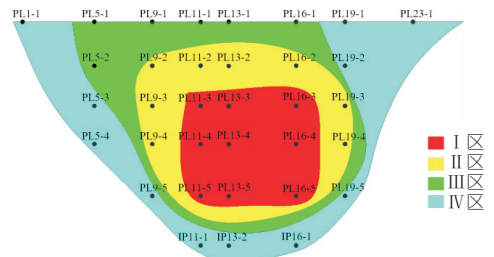


图 4 基于 FCM 聚类算法的测点分区结果

Fig. 4 Measurement point partitioning results based on FCM clustering algorithm

3.3 基于 WOA-LSTM 的大坝变形预测

为了验证不同分区测点均适用于本文所建模型,选取 I 区内的 PL13-4 测点和 V 区内的 PL11-1 测点进行计算分析,将 2017 年 1 月 1 日~2018 年 6 月 30 日的变形监测资料作为训练集,样本数量为 546 个,将 2017 年 7 月 1 日~2017 年 12 月 31 日的变形监测资料作为预测集,样本数量为 184 个。

设置鲸鱼优化算法 WOA 的最大迭代次数 $max_{iter} = 200$, 鲸鱼种群数量为 10, 隐含层神经元个数 m 的寻优区间为 $[1, 30]$, 学习率 l_r 的寻优区间为 $[0.000 1, 0.01]$, 采用 WOA 算法寻找 LSTM 模型中最优的神经元个数 m 和学习率 l_r ,

目标函数设置为训练集的均方误差 M_{MSE} 。WOA-LSTM 中 LSTM 模型采用输入层、单隐藏层、输出层三层架构,输入变量根据拱坝变形统计模型确定,包括水压因子 $H - H_0$ 、 $H^2 - H_0^2$ 、 $H^3 - H_0^3$ 、 $H^4 - H_0^4$, 温度因子 $\sin \frac{2\pi t}{365}$ 、 $\cos \frac{2\pi t}{365}$ 、 $\sin \frac{4\pi t}{365}$ 、 $\cos \frac{4\pi t}{365}$ 及时效因子 $\theta - \theta_0$ 、 $\ln \theta - \ln \theta_0$, 其中 H 、 H_0 分别为计算时段各天、第 1 d 对应的上游水位; t 为监测日至起测日的累计天数; θ 为监测日至起测日的累计天数除以 100; θ_0 为建模起始日至起测日的累计天数除以 100。模型最终的优化结果见图 5。由图 5 可看出,该模型在迭代第 41 次已收敛到最优解,目标函数值为 0.295 mm^2 , 对应的 LSTM 模型超参数分别为 $m = 30$ 、 $l_r = 0.15$ 。




图 5 改进模型优化效果曲线

Fig. 5 Improved model optimization performance curve

为了验证 WOA-LSTM 大坝变形预测模型的准确性和稳定性,采用单一的长短期记忆神经网络 LSTM 模型和支持向量机 SVM 模型进行预测,同时采用平均绝对误差 M_{MAE} 、均方误差 M_{MSE} 、均方根误差 R_{RMSE} 分析 3 种模型的预测精度。

利用 Matlab 建立 FCM-WOA-LSTM 模型、LSTM 模型、SVM 模型,分别计算得到 PL11-1、PL13-4 测点的大坝变形预测结果,图 6 为 PL11-1、PL13-4 测点 3 种模型的预测结果对比。由图 6 可知,FCM-WOA-LSTM 模型、LSTM 模型、SVM 模型预测变形值的变化规律大体上与实测变形一致,PL11-1、PL13-4 测点 FCM-WOA-LSTM 模型预测变形序列与实测变形序列的吻合程度明显高于另 2 种模型,3 种模型整个时间序列的残差均存在一定程度的波动性,PL13-4 测点的 LSTM 模型和 SVM 模型预测结果的残差在某些时刻出现突增,总体上 FCM-WOA-LSTM 模型整个时间序列预测结果的残差小于 LSTM 模型和 SVM 模型。

根据计算结果统计 3 种模型的最大误差,发现 PL11-1、PL13-4 测点 FCM-WOA-LSTM 模型预测结果的最大误差均为 3 种模型中最小值,以 PL11-1 测点为例,相较于 LSTM 模型和 SVM 模

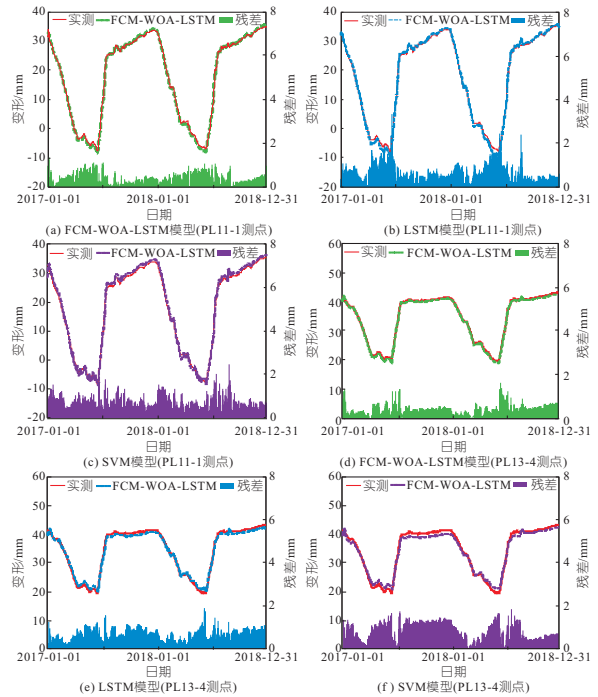


图 6 3 种模型预测结果对比

Fig. 6 Comparison of prediction results of three models

型,改进模型的最大误差分别下降了 1.862、1.850 mm。

计算 PL11-1、PL13-4 测点预测结果的平均绝对误差 M_{MAE} 、均方误差 M_{MSE} 、均方根误差 R_{RMSE} ,发现 FCM-WOA-LSTM 模型拟合段和预测段的平均绝对误差 M_{MAE} 、均方误差 M_{MSE} 、均方根误差 R_{RMSE} 均小于 LSTM 模型和 SVM 模型,进一步验证了 FCM-WOA-LSTM 模型在大坝变形预测方面具有更高的预测精度。以 PL11-1 测点为例,FCM-WOA-LSTM 模型预测段 M_{MAE} 值较另 2 种模型分别降低了 0.158、0.399 mm, M_{MSE} 值分别降低了 0.216、0.587 mm^2 , R_{RMSE} 值分别降低了 0.205、0.452 mm。此外,FCM-WOA-LSTM 模型拟合段的 M_{MAE} 、 M_{MSE} 、 R_{RMSE} 值和预测段的 M_{MAE} 、 M_{MSE} 、 R_{RMSE} 值均对应接近,说明预测结果有较强的稳定性。综上所述,本文提出的 FCM-WOA-LSTM 模型能更准确稳定地预测大坝变形,具有较高的拟合和预测精度。

4 结论

a. FCM 聚类算法实现了大坝变形测点的合理分区,有效解决了多测点长序列数据带来的建模复杂性,同时分区建模提高了预测结果的准确性。

b. PL11-1、PL13-4 测点 FCM-WOA-LSTM 模型预测变形序列与实测变形序列的吻合程度明显高于 LSTM 模型和 SVM 模型,整个时间序列

预测结果的残差近乎均小于 LSTM 模型和 SVM 模型。

c. FCM-WOA-LSTM 模型预测结果的平均绝对误差 M_{MAE} 、均方误差 M_{MSE} 、均方根误差 R_{RMSE} 均为 3 种模型中最小,模型具有较强的泛化能力和较高的预测精度,为大坝变形的精准预测提供了新途径。

参考文献:

- [1] 唐国磊,周惠成,李宁宁,等. 一种考虑径流预报及其不确定性的水库优化调度模型[J]. 水利学报, 2011, 42(6): 641-647,656.
- [2] 张静文,郭家力,刘佳,等. 鄱阳湖流域入湖径流时空变化预测[J]. 南水北调与水利科技, 2016, 14(5): 41-48,70.
- [3] 陈芳,张志强,李扉,等. 基于 EEMD 分解与 BOA 算法优化神经网络的密云水库大阁水文站径流预测[J]. 西北林学院学报, 2021, 36(6): 188-194.
- [4] 鄢涛,陈波,曹恩华,等. 基于 EEMD-ELM 的大坝

变形预测模型[J]. 长江科学院院报, 2020, 37(11): 70-73,80.

- [5] 苏燕,付家源,林川,等. 基于时间注意力机制的大坝动态变形预测模型[J]. 水力发电学报, 2022, 41(7): 72-84.
- [6] 温勇兵,徐镇凯,魏博文,等. 基于逐步回归和 GDCS-SVM 的大坝变形预测组合模型[J]. 水电能源科学, 2017, 35(5): 92-94,91.
- [7] 蔡国伟,刘旭,张旺,等. 基于改进灰狼优化算法的分布式电源优化配置[J]. 太阳能学报, 2019, 40(1): 134-141.
- [8] 邵光成,章坤,王志宇,等. 基于 IABC-RBF 神经网络的地下水埋深预测模型[J]. 浙江大学学报(工学版), 2019, 53(7): 1323-1330.
- [9] 周有荣,王凯. 改进鲸鱼算法优化混合核支持向量机在径流预测中的应用[J]. 中国农村水利水电, 2020(7): 50-53.
- [10] 范振东,崔伟杰,杨孟,等. 基于模糊 C-均值聚类和支持向量机的大坝安全变形预警模型及应用[J]. 水电能源科学, 2014, 32(12): 71-74.

Dam Deformation Prediction Model and Its Application Based on FCM-WOA-LSTM

CAO Meng-xi^{a,b}, ZHENG Dong-jian^{a,b}

(a. College of Water Conservancy and Hydropower Engineering; b. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China)

Abstract: With the continuous accumulation of dam deformation monitoring data and the continuous increase of deformation measuring points, it often takes a lot of time to predict all deformation measuring points, which is easy to cause the problem of untimely feedback. Therefore, the fuzzy C-means clustering algorithm (FCM) was introduced to partition the dam according to the similarity of deformation laws. The whale optimization algorithm (WOA) was used to optimize the parameters of long short-term memory neural network (LSTM), and a dam deformation prediction model based on FCM-WOA-LSTM was established. The measured deformation data of a concrete double-curvature arch dam was used as sample data for prediction, and the prediction results were compared with those of LSTM model and SVM model. The results show that the average absolute error (M_{MAE}), mean square error (M_{MSE}) and root mean square error (R_{RMSE}) of the prediction results of FCM-WOA-LSTM model are the smallest among the three models, and the three evaluation indexes of the fitting section are close to those of the prediction section, respectively. Compared with the existing models, the FCM-WOA-LSTM model has higher prediction accuracy and better applicability.

Key words: dam deformation; partitions of measuring points; fuzzy C-means clustering; whale optimization algorithm; long short-term memory network

(上接第 66 页)

Experimental Study on Wetting Dynamic Characteristics of Coarse Grained Materials in Earth Rockfill Dam

ZHANG Hong-yang^{1,2}, MA Cong¹, LIU Jian-long, SUN Ya-dong¹,
SONG Zi-yi¹, DING Ze-lin^{1,2}, HAN Peng-ju¹

- (1. College of Water Conservancy, North China University of Water Resources and Electric Power, Zhengzhou 450046, China; 2. Collaborative Innovation Center of Water Resources Efficient Utilization and Protection Engineering of Henan Province, Zhengzhou 450046, China, 3. Management Division of Jiangsu Qinhua River Hydraulic Engineering, Nanjing 210022, China)

Abstract: Conventional and wetting triaxial experiments were carried out on coarse grained materials for dam construction with a large static and dynamic triaxial tester. The dynamic characteristics of coarse grained materials after wetting deformation were studied, and the results were compared with those of conventional triaxial dynamic experiments. The experimental results show that the dynamic characteristics of coarse grained materials are greatly affected by wetting deformation, and the dynamic performance parameters of coarse grained materials are attenuated to a certain extent. The Hardin-drnevich model parameters of the two experiments were compared and analyzed. It was found that wetting deformation had a significant effect on k_2 and λ_{max} , and the numerical values were attenuated, but the effects on n and k_1 were not significant.

Key words: coarse grained materials; wetting deformation; dynamic characteristic; Hardin-Drnevich model; dynamic triaxial experiment