

刘桓辰, 朱静, 郭梦京. 融合特征因子筛选的拱坝变形深度学习预测模型[J]. 水利水电技术(中英文), 2025, 56(3): 123-134. DOI: 10.13928/j.cnki.wrahe.2025.03.010

LIU Huanchen, ZHU Jing, GUO Mengjing. Deep learning prediction model for arch dam deformation by incorporating feature factor screening[J]. Water Resources and Hydropower Engineering, 2025, 56(3): 123-134. DOI: 10.13928/j.cnki.wrahe.2025.03.010

融合特征因子筛选的拱坝变形深度学习预测模型

刘桓辰¹, 朱静¹, 郭梦京²

(1. 陕西省水利电力勘测设计研究院, 陕西 西安 710001; 2. 西安理工大学
水利水电学院, 陕西 西安 710000)

摘要:【目的】变形是库水、温度和材料特性等多因素耦合作用下大坝整体服役性态的直接表征, 建立精确、高效的预测模型对于掌握坝体变形趋势和评估大坝风险具有重要意义。【方法】针对传统预测模型精度低、适应性差和抗噪能力弱等问题, 将哈里斯鹰算法(HHO)、变分模态分解(VMD)、随机森林算法(RF)和长短时记忆神经网络(LSTM)相结合, 提出了一种混凝土拱坝变形深度学习预测模型。首先, 通过引入Tent混沌映射、能量随机性递减策略改进HHO算法, 利用IHHO-VMD方法分解拱坝变形数据序列得到若干不同频率的模态分量(IMF); 其次, 利用RF算法计算变形特征因子的贡献率, 筛选预测模型最优输入因子集合; 最后, 采用LSTM模型对各IMF分量进行学习和预测, 重构各分量预测值得到最终的变形预测值。【结果】仿真信号分解结果表明: 与现有信号分解方法相比, 采用IHHO-VMD方法可以实现信号最优分解。通过某工程实例分析, 所提模型预测4个测点位移时, 平均RMSE、MAE、 R^2 和MAPE为0.3976 mm、0.3275 mm、0.9918和1.5194%。【结论】相较于其他组合模型, 所提模型的4种评价指标结果均为最优, 表明该模型具有预测精度高、泛化能力好和鲁棒性强等优势。

关键词: 混凝土拱坝变形; 哈里斯鹰算法; 变分模态分解; 随机森林算法; 长短时记忆神经网络; 水利工程; 变形

DOI: 10.13928/j.cnki.wrahe.2025.03.010

开放科学(资源服务)标志码(OSID):

中图分类号: TV698.11

文献标志码: A

文章编号: 1000-0860(2025)03-0123-12



Deep learning prediction model for arch dam deformation by incorporating feature factor screening

LIU Huanchen¹, ZHU Jing¹, GUO Mengjing²

(1. Shanxi Province Institute of Water Resources and Electric Power Investigation and Design, Xi'an 710001, Shaanxi, China;

2. Institute of Water Resources and Hydroelectric Engineering, Xi'an University of Technology,

Xi'an 710000, Shaanxi, China)

Abstract: [Objective] Deformation is a direct characterization of the overall serviceability of dams under the coupling of reservoir

收稿日期: 2024-03-31; 修回日期: 2024-04-26; 录用日期: 2024-07-05; 网络出版日期: 2025-03-20

基金项目: 国家自然科学基金项目(41807156); 陕西省教育厅重点实验室科研计划项目(18JS073)

作者简介: 刘桓辰(1985—), 男, 高级工程师, 硕士, 主要从事水工结构安全与设计研究。E-mail: zerolhc@126.com

通信作者: 郭梦京(1986—), 男, 副教授, 硕士研究生导师, 博士, 主要从事水利工程生态环境效应与调控研究。E-mail: guomengjing@xaut.edu.cn

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

water, temperature and material properties, etc. The establishment of an accurate and efficient prediction model is of great significance in grasping the deformation trend of dams and assessing the risk of dams. [Methods] Aiming at the problems of low accuracy, poor adaptability and weak noise immunity of traditional prediction models, a deep learning prediction model for concrete arch dam deformation is proposed by combining the Harris Hawk algorithm (HHO), Variational Modal Decomposition (VMD), Random Forest algorithm (RF), and Long-Short-Term Memory neural network (LSTM). First, the HHO algorithm is improved by introducing Tent chaotic mapping, energy randomness decreasing strategy, and the arch dam deformation data sequence is decomposed to obtain a number of modal components (IMF) with different frequencies using the IHHO-VMD method. Secondly, The RF algorithm is utilized to calculate the contribution of deformed characteristic factor and to screen the optimal set of input factors for the prediction model;. Finally, the LSTM model is used to learn and predict each IMF component, and the final deformation prediction is obtained by reconstructing the predicted values of each component. [Results] The simulated signal decomposition result show that compared with the existing signal decomposition method, the optimal signal decomposition can be realized by using the IHHO-VMD method. Analyzed by a project example, the proposed model predicts the displacement of four measurement points with average *RMSE*, *MAE*, R^2 and *MAPE* of 0.397 6 mm, 0.327 5 mm, 0.991 8 and 1.519 4%. [Conclusion] Compared with other combined models, the result of the four evaluation indexes of the proposed model are optimal, indicating that the model has the advantages of high prediction accuracy, good generalization ability and robustness.

Keywords: concrete arch dam deformation; harris hawks algorithm; variational mode decomposition; random forest algorithm; long-short-term memory neural network; hydraulic engineering; deformation

0 引言

目前我国已建大坝近十万座^[1], 对我国国民经济的稳定和发展具有重要意义。在水压荷载、温度荷载和时效荷载等多种动静循环荷载作用下, 坝体变形呈现复杂非线性、周期性和非稳定性等特点^[2]。传统拱坝变形预测模型结构简单, 具有一定的解释性, 但在处理复杂度高、非线性强的数据序列时, 存在抗噪性能差、拟合效果不佳和泛化能力不足等问题, 无法充分挖掘序列中的有效信息和把控变形与特征因子间的复杂关系^[3]。随着水库大坝自动化监测系统的普遍使用和人工智能的飞速发展, 机器学习、深度学习等技术被广泛应用于预测、分析大坝变形, 取得了显著效果。支持向量机(SVM)、反向传播神经网络(BPNN)、极限学习机(ELM)和循环神经网络(RNN)等方法被广泛用于构建预测模型。XING等^[4]提出了ICSO-SVM混凝土坝变形预测模型, 利用ICSO算法对SVM参数进行寻优, 一定程度上提高了模型的预测精度, 但模型稳定性较差, 难以精确描述变形量与特征因子间的动态关系。程换新等^[5]利用IPSO算法搜寻RNN模型的结点权值参数, 提高了模型对突变序列的刻画能力, 忽略了RNN模型在处理长序列时易出现梯度消失、梯度爆炸等问题。

为避免因RNN模型架构缺陷引发的性能不稳定, 通过引入记忆单元和门控机制, 提出了LSTM模型, 可有效捕捉数据序列中长时间依赖关系和深度挖掘序列特征信息。欧斌等^[6]利用LSTM模型预测混凝土坝变形量, 预测值与实测值吻合度较高。WEI等^[7]提

出了OC-LSTM超高拱坝首次蓄水变形预测模型, 利用LSTM模型处理改进CNN模型提取的特征信息, 相较单一LSTM模型或CNN模型, 预测精度得到了较大提升。施彦彤等^[8]基于卷积神经网络、注意力机制和长短时记忆网络, 构建了大坝监测模型, CNN从监测数据中提取特征, LSTM更好地从时间序列数据中学习, 并在此CNN-LSTM模型的基础上, 耦合深度学习算法Attention机制, 突出特征对输入效果的影响, 在不影响模型精度的前提下提高了计算速度。YANG等^[9]提出了耦合注意力机制的LSTM混凝土坝变形预测模型, 采用LSTM模型把控变形与环境因素间的关系; 利用注意力机制计算特征因子权重, 通过工程实例验证了该模型的有效性和可行性。较现有模型, 上述模型具有预测精度高、鲁棒性强等特点, 但受模型输入特征因子冗余影响和序列中噪声信号干扰, 难以充分挖掘变形量与特征因子间复杂的非线性动态关系, 导致对序列变点、拐点的预测能力较差, 稳定性不足。

混凝土拱坝上布设的监测仪器和信号传输线路受仪器性能、环境等因素的叠加影响, 采集到的数据序列中夹杂噪声信号, 如果直接使用深度学习模型对其进行拟合、预测, 容易降低信息挖掘的效率和质量, 削弱模型对序列局部特征的刻画能力。针对上述问题, 部分学者利用VMD将变形数据序列分解成若干IMF分量, 剔除残余分量, 对各IMF分量分别构建预测模型, 从而实现模型性能的提升。周兰庭等^[10]提出了基于SSA-LSTM-GF的混凝土坝变形预测方法,

利用 SSA 将变形实测数据序列分解多个 IMF 分量, 分别用 LSTM 模型和 GF 算法对周期分量和趋势分量进行预测, 最后重构分量预测值, 与其他组合模型相比, 具有更高的预测精度。BAI 等^[11]利用 DA-RNN 模型对 VMD 分解得到的特征序列进行学习, 增加了学习过程中重要时间步长的权重, 提高了模型的准确性。曹恩华等^[12]采用 VMD 分解变形数据序列, 筛选模型输入特征因子后, 采用 ELM 对各 IMF 分量进行预测, 重构得到最终预测结果, 预测效果对比分析表明, VMD 分解效果优于 EMD, 模型预测精度高于 BP、HST-ELM 等模型。上述方法采用人工取值的 VMD 进行序列分解, 减少了噪声信号的干扰, 但忽略了 VMD 参数取值对序列分解效果的影响, 取值不当, 可能导致模态混叠严重、相近信息难以分离。

在实际应用中, VMD 参数常依据经验选取, 分解效果存在较大不确定性。为此, 部分学者采用智能算法搜寻最佳参数组合, 以提升 VMD 分解效果。张建中等^[13]使用 GWO 算法搜寻 VMD 最佳参数组合, 实现了对变形数据序列的最优分解, 解决了人工选择 VMD 参数导致分解效果差、性能不稳定等问题。李冰^[14]使用 WOA-VMD 方法分解原始数据序列, 通过与基础 VMD 分解得到的分量时频谱图对比, 验证了 WOA 算法对 VMD 参数组合进行寻优的有效性和可行性。将智能算法与 VMD 进行有机结合, 分解参数取值具有较好的合理性, 但受制于智能算法种群多样性、迭代更新方式和搜索能力转换等因素, 算法寻优时可能陷入局部最优, 导致寻优结果不理想, VMD 性能下降。

混凝土拱坝变形数据序列经 VMD 分解成多个 IMF 分量, 进行拟合和预测时, 相关性低的高维变形特征因子会导致模型性能下降, 因此需要筛选和优化特征因子。漆一宁等^[15]利用 mRMR 算法和增量搜索对 VMD 分解出的各 IMF 分量进行特征因子筛选, 降低了模型输入因子冗余度, 有效避免了模型出现过拟合。CAO 等^[16]提出了一种融合极限梯度提升和 Spearman 的特征选择方法, 在挖掘序列内在规律基础上对特征因子进行约减, 提高了后续模型的稳定性。ZHANG 等^[17]依据 RF 算法对计算得到的特征因子贡献率进行排序, 通过分析不同特征因子数量下评价指标结果波动情况来确定最佳因子集合, 有效降低了因子多重共线性对模型精度的影响。

为减少序列中噪声信号对信息挖掘的干扰, 提高智能算法对 VMD 参数的寻优精度和降低特征因子冗余度对模型性能的影响, 采用 LSTM 模型提取 IMF 分

量与变形特征因子间的长时间依赖信息, 通过与 IH-HO-VMD 和 RF 特征因子选择方法进行有机结合, 提出了融合特征因子筛选的混凝土拱坝变形深度学习预测模型, 即 IHV-RLSTM 模型 (IH-HO-VMD-RF-LSTM)。首先, 利用 Tent 混沌映射、能量随机性递减策略改进得到的 IH-HO 算法搜寻 VMD 参数最佳组合, VMD 在最佳参数组合下将拱坝变形数据序列分解成若干 IMF 分量, 利用 RF 算法从常规变形特征因子中筛选与分量相关性强的因子, 降低因子间的冗余性和多重共线性; 然后采用 LSTM 模型对各分量进行训练、验证和预测, 重构得到最终的拱坝变形预测值。工程实例分析验证了所提模型的有效性和可行性。

1 方法与理论

1.1 基于改进哈里斯鹰算法优化的变分模态分解

1.1.1 哈里斯鹰算法

2019 年, HEIDARI 等^[18]受北美洲哈里斯鹰群独特捕食行为的启发, 提出了哈里斯鹰算法 (HHO), 具有参数少、寻优精度高和全局搜索能力强等优点。该算法包括全局搜索和局部开发两个阶段, 根据猎物的逃逸能量来进行搜索模式的转换, 逃逸能量的计算公式为

$$E = 2E_0 \left(1 - \frac{t}{T}\right) \quad (1)$$

式中, E 为猎物的当前逃逸能量, 当 $|E| \geq 1$ 时, 算法开展全局搜索; 当 $|E| < 1$ 时, 算法进行局部开发; T 为最大迭代次数; t 为当前迭代次数; E_0 为猎物的初始逃逸能量。

1.1.1.1 全局搜索

当 $|E| \geq 1$ 时, 哈里斯鹰在搜索空间中随机搜索猎物, 并更新个体位置, 更新公式为

$$X(t+1) = \begin{cases} X_{rand}(t) - r_1 |X_{rand}(t) - 2r_2 X(t)| & q \geq 0.5 \\ (X_r(t) - X_m(t)) - r_3 lb + r_4 (ub - lb) & q < 0.5 \end{cases} \quad (2)$$

式中, $X(t+1)$ 、 $X(t)$ 分别为第 $t+1$ 、 t 次迭代时哈里斯鹰的位置; $X_{rand}(t)$ 为随机选择的鹰的位置; $X_r(t)$ 为猎物位置; r_1 、 r_2 、 r_3 、 r_4 和 q 为随机数; lb 、 ub 为搜索空间的上下限; $X_m(t)$ 为第 t 次迭代时哈里斯鹰群的平均位置。

1.1.1.2 局部开发

当 $|E| < 1$ 时, 哈里斯鹰会根据猎物逃逸能量绝对值 $|E|$ 和 $(0, 1)$ 间的随机数 β 选择合适的围攻策

略, 包含 4 种策略。

(1) 软围攻。当 $\beta \geq 0.5$, $|E| \geq 0.5$ 时, 猎物逃逸能量充沛, 哈里斯鹰实施软围攻策略, 个体位置更新公式为

$$X(t+1) = \Delta X(t) - E |JX_r(t) - X(t)| \quad (3)$$

式中, r_s 为 $(0, 1)$ 间的随机数; J 为猎物的跳跃强度, 取值范围为 $(0, 2)$; $\Delta X(t)$ 为第 t 次迭代时猎物与哈里斯鹰间的距离。

(2) 硬围攻。当 $\beta \geq 0.5$, $|E| < 0.5$ 时, 猎物逃逸能量不足, 哈里斯鹰实施硬围攻策略, 个体位置更新公式为

$$X(t+1) = X_r(t) - E \cdot |\Delta X(t)| \quad (4)$$

(3) 快速俯冲式软围攻。当 $\beta < 0.5$, $|E| \geq 0.5$ 时, 哈里斯鹰实施快速俯冲式软围攻策略 Y, Z , 个体位置更新公式为

$$X(t+1) = \begin{cases} Y(t): X_r(t) - E |JX_r(t) - X(t)| \\ F(Y(t)) < F(X(t)) \\ Z(t): Y(t) + S \cdot LF(D) \\ F(Z(t)) < F(X(t)) \end{cases} \quad (5)$$

式中, S 为维度为 D 的随机向量; LF 为 Levy 飞行函数。

(4) 快速俯冲式硬围攻。当 $\beta < 0.5$, $|E| < 0.5$ 时, 哈里斯鹰实施快速俯冲式软围攻策略 Y, Z , 个体位置更新公式为

$$X(t+1) = \begin{cases} Y(t): X_r(t) - E |JX_r(t) - X_m(t)| \\ F(Y(t)) < F(X(t)) \\ Z(t): Y(t) + S \cdot LF(t) \\ F(Z(t)) < F(X(t)) \end{cases} \quad (6)$$

1.1.2 变分模态分解

VMD 是一种基于维纳滤波、希尔伯特变换、变分原理和交替方向乘子法等理论的非递归信号分解方法, 能有效避免端点效应、模态混叠等问题, 可以高效地处理复杂的高维非线性数据序列, 将数据序列 $f(t)$ 分解为多个模态分量^[19-20], 分解流程如下。

(1) 构建约束变分模型

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \otimes u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_k u_k = f \end{cases} \quad (7)$$

式中, $\{u_k\}$ 为分解得到的 IMF 分量; $\delta(t)$ 为 Dirichlet

函数; \otimes 为卷积运算符; $\{\omega_k\}$ 为中心频率。

(2) 求解上式得到

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (8)$$

式中, α 为二次惩罚因子; λ 为 Lagrange 算子。

(3) 使用 ADMM 计算 $\{u_k\}$

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i^{n+1}(\omega) + \frac{\hat{\lambda}_k^{n+1}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (9)$$

式中, \hat{u}_k^{n+1} 为当前数据信号的维纳滤波; $\hat{u}_k^n(\omega)$ 、 $\hat{f}(\omega)$ 分别为 $u_k(\omega)$ 、 $f(\omega)$ 的 Fourier 变换。

(4) 更新中心频率 $\{\omega_k\}$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |u_k^n(\omega)| d\omega}{\int_0^\infty |u_k^n(\omega)| d\omega} \quad (10)$$

(5) 更新 λ

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau [\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)] \quad (11)$$

式中, $\hat{u}_k^{n+1}(\omega)$ 、 ω_k^{n+1} 分别为维纳滤波与频率中心; τ 为保真系数。

1.1.3 改进哈里斯鹰算法

(1) Tent 混沌映射。Tent 混沌映射为分段线性映射, 凭借其出色的随机特性和操作便捷性而得到广泛应用^[21-22]。因此, 采用该映射方式初始化种群位置, 以保证解在空间中分布的均匀性。Tent 混沌映射公式为

$$y_{k+1} = \begin{cases} y_k/0.7 & y_k < 0.7 \\ (10/3)(1 - y_k) & y_k \geq 0.7 \end{cases} \quad (12)$$

式中, y_k 、 y_{k+1} 分别为粒子在第 k 、 $k+1$ 次迭代后的位置; k 为迭代次数。

(2) 能量随机性递减策略。在传统 HHO 算法中 E 为线性递减, 不符合实际情况下猎物能量的变化趋势。因此, 将余弦函数引入到逃逸能量 E 的计算公式中, 使 E 发生随机周期性变化^[23], 改进后的计算公式为

$$E = 2E_0 \left(1 - \frac{t}{T}\right) \cdot \cos \left[\left(2k + \frac{1}{2}\right) \pi \frac{t}{T} \right] \quad (13)$$

式中, t 、 T 分别为当前迭代次数、最大迭代次数; $k = 0, 1, \dots$ 为猎物逃逸能量 E 的递减周期数。在能量周期性递减调控机制中, 通过调整周期数 k 来调控猎物逃逸能量 E 的周期性下降^[24]。 k 越大, HHO 算法

偏向于局部开发, 反之注重全局搜索。

1.1.4 IHHO-VMD 分解方法

对于 VMD 参数, 当 K 过小时, 分解出的信号会叠加大量噪声, 即信号欠分解; 当 K 过大时, 会导致信号过度分解并出现模态分量混叠现象^[25]。 α 则决定 IMF 分量的带宽, 取值不当会导致 IMF 分量的中心频率混叠, 使得 VMD 无法分解出有效的频率信号^[26]。因此, 利用 IHHO 算法自适应搜寻 $[K, \alpha]$ 的最优组合, 选择包络熵作为适应度函数^[27], 改善 VMD 对拱坝变形数据序列的分解效果。

利用 IHHO 算法搜寻 VMD 的最佳参数组合 $[K, \alpha]$ 的具体步骤如下。(1) 设置 IHHO 算法参数, 包括种群数量、最大迭代次数、Tent 混沌参数、 K 和 α 的取值范围等; (2) 将拱坝变形数据序列进行 VMD 分解, 计算每只 Harris 鹰的适应度值; (3) 依据 IHHO 算法迭代优化机制, 更新 Harris 鹰个体位置, 不断更新最小适应度值; (4) 返回第二步继续寻优, 达到最大迭代次数时, 算法停止, 输出最小适应度值和最佳参数组合; (5) VMD 在最佳参数组合下对拱坝变形数据序列进行分解。

1.1.5 IHHO-VMD 方法分解效果分析

为验证 IHHO-VMD 分解方法的有效性和可行性, 构造了仿真信号 $y(t)$, 采样频率为 1 024 Hz, 采样时间为 1 s, 仿真信号公式为

$$\begin{cases} y(t) = y_1(t) + y_2(t) + y_3(t) + y_4(t) \\ y_1(t) = \cos(10\pi t) \\ y_2(t) = 1.2\sin(40\pi t) \\ y_3(t) = 1.5\sin(160\pi t + \pi/3) \\ y_4(t) = \text{noisy} \end{cases} \quad (14)$$

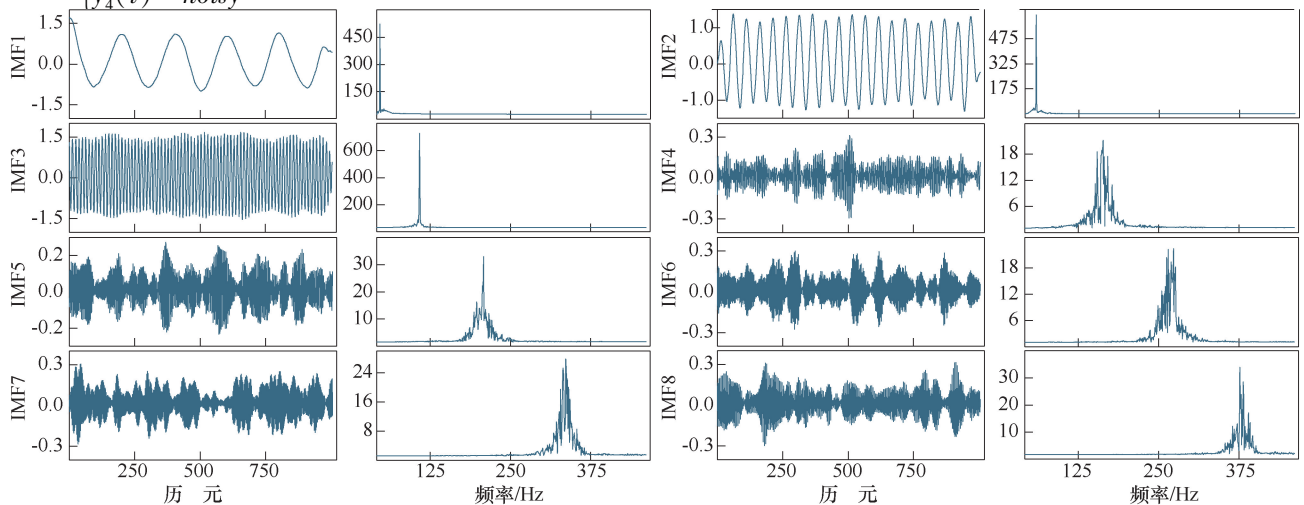


图 2 IHHO-VMD 分解结果的时域和频域

Fig. 2 Domain and frequency domain of IHHO-VMD decomposition results

式中, $noisy$ 为信噪比 10 dB 的高斯白噪声。

利用 IHHO-VMD、HHO-VMD、WOA-VMD 和 GWO-VMD 对仿真信号进行分解, 算法种群数量为 50, 最大迭代次数为 30, 分解层数 K 和惩罚因子 α 的取值范围分别为 $[3, 10]$ 、 $[1\ 000, 8\ 000]$, 算法的适应度函数为包络熵, 终止条件为达到最大迭代次数。寻优得到的最佳参数组合 $[8, 5\ 168]$, 最佳适应度值为 2.856 38, 4 种算法迭代寻优过程线如图 1 所示, IHHO-VMD 分解结果如图 2 所示。由图 1 可知, IHHO 算法寻优速度最快, 在第 4 次迭代时搜寻到了最佳参数组合, 且适应度值最小, 说明其对 VMD 最佳参数组合的寻优过程优于其他算法, 具有较好的适应性。由图 2 可知, IHHO-VMD 可以准确对信号进行分解, 有效抑制了频率混叠现象, 说明所提降噪方法具有较好的分解效果和可行性。

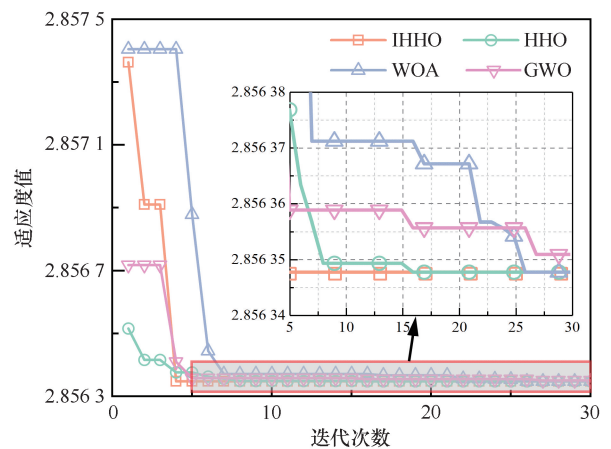


图 1 算法迭代寻优过程线

Fig. 1 Algorithm iterative optimization process line

1.2 随机森林算法

RF 算法是基于统计学理论提出的一种集成了多个决策树的方法^[28], 具有原理简单、泛化能力强和计算量小等优点, 通过平均不纯度下降值计算特征权重系数和判断特征重要性^[29-30]。变量 X_j 在 RF 算法中的 Gini 重要性计算公式为

$$VIM_j^{(Gini)} = \frac{1}{n} \sum_{i=1}^n VIM_{ij}^{(Gini)} \quad (15)$$

式中, n 为 RF 算法中分类树的数量; $VIM_{ij}^{(Gini)}$ 为变量 X_j 在第 i 棵树中的重要性。

1.3 长短时记忆神经网络

LSTM 模型采用三种不同的“门”结构和细胞状态代替隐藏层, 可以有选择的保留或遗弃部分信息, 降低了冗长的历史信息对学习质量的影响, 解决了数据序列长距离时间依赖问题, 在处理长时间序列问题上效果显著^[31-32]。遗忘门 f_t 计算公式为

$$f_t = \sigma(\omega_f[h_{t-1}, x_t] + b_f) \quad (16)$$

式中, σ 为激活函数; ω_f 为权重; h_{t-1} 为前一单元的输出; x_t 为 t 时刻的输入; b_f 为偏移。

输入门 i_t 计算公式为

$$i_t = \sigma(\omega_i[h_{t-1}, x_t] + b_i) \quad (17)$$

$$c'_t = \tanh(\omega_c[h_{t-1}, x_t] + b_c) \quad (18)$$

$$c_t = f_t c_{t-1} + i_t c'_t \quad (19)$$

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 、 c_t 分别为前一时刻和当前时刻的细胞状态。

输出门 o_t 计算公式为

$$o_t = \sigma(\omega_o[h_{t-1}, x_t] + b_o) \quad (20)$$

$$h_t = o_t \tanh(c_t) \quad (21)$$

式中, ω_o 为权重; b_o 为偏移; h_t 为 t 时刻单元输出。

2 模型构建

结合以上方法与理论, 提出了 IHV-RLSTM 模型, 实现流程如图 3 所示, 具体步骤如下: (1) 初始化 IHHO 参数并确定适应度函数; (2) 利用 Tent 混沌映射初始化种群位置, 通过种群位置不断更新迭代, 得到 VMD 最佳参数组合; (3) 利用最优参数组合下的 VMD 对大坝变形数据序列进行分解, 并划分训练集、验证集和测试集; (4) 利用 RF 算法筛选出与 IMF 分量相关性强的特征因子, 将预处理后的训练集和验证集及对应特征因子集合分别输入到 LSTM 模型中进行训练、验证; (5) 选择最优 LSTM 模型对 IMF 分量测

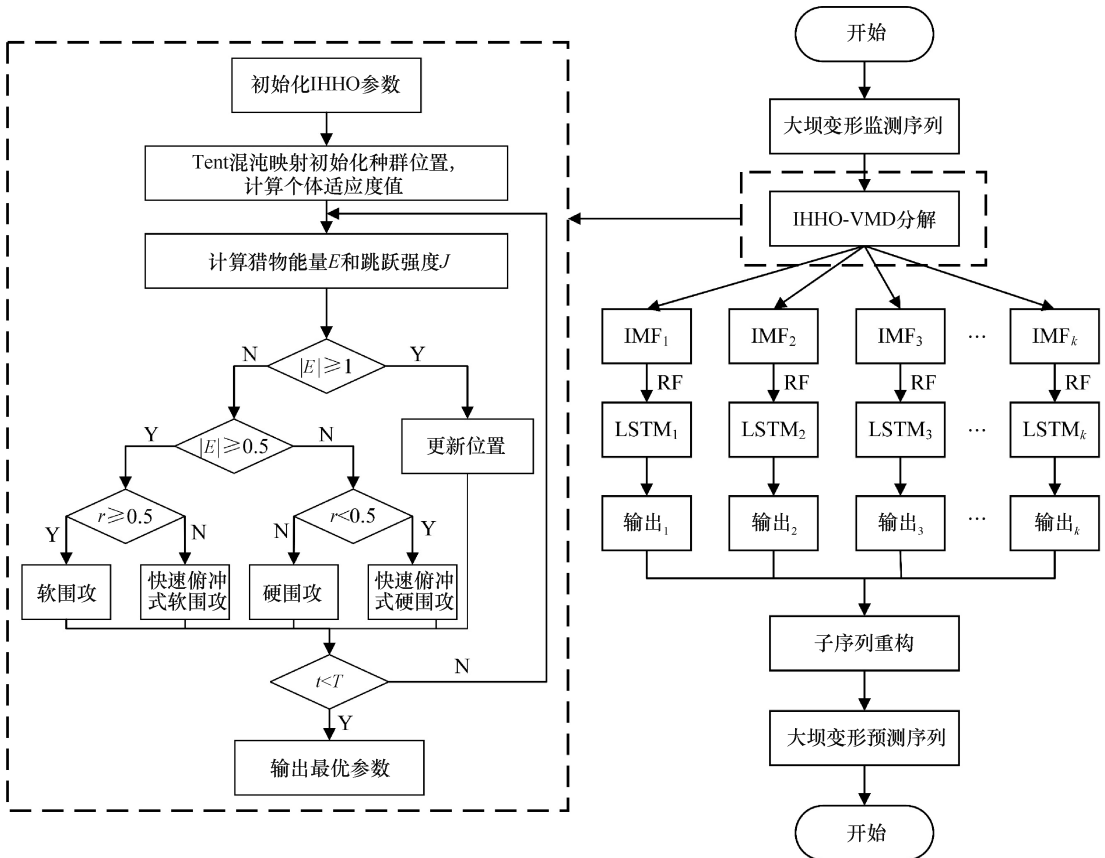


图 3 IHV-RLSTM 模型流程

Fig. 3 IHV-RLSTM model flowchart

试集进行预测, 重构各分量预测结果得到最终变形预测值; (6) 计算实测值和预测值间的平均绝对误差 (MAE)、平均绝对百分比误差 (MAPE)、均方根误差 (RMSE) 和相关系数 (R^2), 评价模型综合性能。

3 模型验证

3.1 工程概况

某混凝土拱坝位于中国四川省境内雅砻江流域, 坝顶高程为 1 885.00 m, 建基面高程为 1 580.00 m, 最大坝高为 305.00 m, 属 300 m 级高坝, 兼顾防洪、发电、灌溉等功能。2012 年水电站开始首次蓄水, 2015 年工程全部完工, 拱坝自动化监测系统投入使用。拱坝正垂线测点布置如图 4 所示, 选取测点 PL5-2、PL9-4、PL13-2 和 PL16-3 从 2016 年 7 月 28 日至 2021 年 3 月 19 日的顺河向位移监测数据进行分析, 按照 7 : 1 : 2 的比例划分成训练集、验证集和测试集。

3.2 拱坝变形影响因素

根据大坝安全监控理论, 采用水压-季节-时效 (HST) 模型构建模型的特征因子集, 即 H^1 、 H^2 、 H^3 、 H^4 、 $\sin 2\pi t$ 、 $\sin 4\pi t$ 、 $\cos 2\pi t$ 、 $\cos 4\pi t$ 、 θ 和 $\ln \theta$, 大坝监测点位移可表示为

$$\delta = \sum_{i=1}^4 [a_{i_i}(H^i - H_0^i)] + \sum_{m=1}^2 \left[\begin{array}{l} b_{1m} \left(\sin \frac{2\pi mt}{365} - \sin \frac{2\pi mt_0}{365} \right) \\ b_{2m} \left(\cos \frac{2\pi mt}{365} - \cos \frac{2\pi mt_0}{365} \right) \end{array} \right] + c_1(\theta - \theta_0) + c_2(\ln \theta - \ln \theta_0) \quad (22)$$

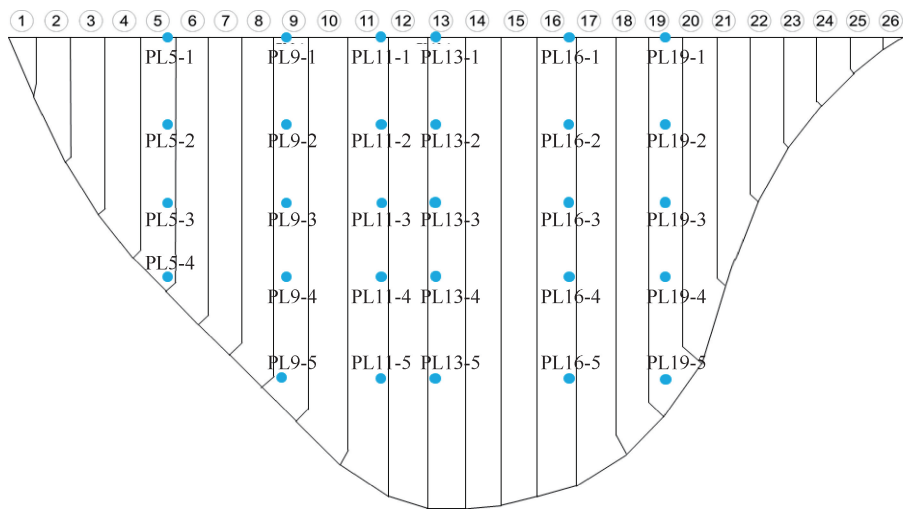


图 4 大坝正垂线测点布置

Fig. 4 Layout of the dam positive pendant measuring points

式中, H 、 H_0 分别为监测日和建模起始日的坝前水深 (m); t 、 t_0 分别为监测日至起测日、建模起始日至起测日的累计天数 (d); θ 、 θ_0 为时效因子, 分别为 $0.01t$ 、 $0.01t_0$ 。

3.3 监测点变形数据序列分解

利用 IHHO-VMD 方法对测点 PL5-2 顺河向位移数据进行分解, IHHO 算法种群数量为 50, 最大迭代次数为 30, 分解层数 K 和惩罚因子 α 的取值范围分别为 $[3, 10]$ 、 $[100, 3\ 000]$, 序列分解寻优曲线如图 5 所示。由图 5 可知, 当迭代至第 6 次时, 包络熵达到最小值 3.001, 得到的最佳参数组合为 $[6, 137.968]$ 。

在 $[K, \alpha]$ 为最佳参数组合, 其余参数为默认值的情况下, 利用 VMD 对测点 PL5-2 顺河向位移数据序列进行分解, 分解结果如图 6 所示。

3.4 IMF 分量特征因子筛选

模型输入特征因子集合的质量对预测模型性能具有重要影响。针对 IHHO-VMD 方法分解测点 PL5-2




图 5 IHHO-VMD 分解寻优曲线

Fig. 5 IHHO-VMD decomposition of optimization curves




图6 测点 PL5-2 位移数据序列分解结果

Fig. 6 Sequence decomposition result of horizontal displacement data of measurement point PL5-2

顺河向位移数据得到的 6 个 IMF 分量含有不同变形信息, 利用前文所述 RF 算法确定各模型的输入特征因子集合, 可有效避免特征因子间的多重共线性问题和维数灾难, 同时保留足够的建模信息。各 IMF 分量的特征因子贡献率如图 7 所示。由图 7 可知, IMF1 分量受时效因子影响较大; IMF2—IMF6 分量主要受温度因子和时效因子影响。




图7 IMF 分量特征因子贡献率

Fig. 7 IMF component characterization factor contribution

确定各分量预测模型输入特征因子集合时, 引入累计贡献率, 依据特征因子贡献率大小进行排序, 选取累积贡献率大于 80% 的特征因子。各 IMF 分量的特征因子筛选结果如表 1 所列。

3.5 模型对比

为验证本文所提模型的可行性和有效性, 将其与 LSTM、VMD-LSTM (V-LSTM)、VMD-RF-LSTM (V-RLSTM)、HHO-VMD-RF-LSTM (HV-RLSTM) 进行对比模型超参数均采用 Adam 算法进行寻优, 学习率为

表 1 IMF 分量特征因子筛选结果

Table 1 IMF component characterization factor screening results

模态分量	模态分量因子
IMF1	$H^2, H^3, H^4, \sin(4\omega t), \cos(2\omega t), \theta, \ln\theta$
IMF2	$H^1, H^2, H^4, \sin(4\omega t), \cos(2\omega t), \theta, \ln\theta$
IMF3	$H^1, H^2, H^4, \sin(2\omega t), \cos(2\omega t), \theta, \ln\theta$
IMF4	$H^4, \sin(2\omega t), \cos(2\omega t), \cos(4\omega t), \theta, \ln\theta$
IMF5	$H^1, H^2, H^3, \cos(2\omega t), \theta, \ln\theta$
IMF6	$H^2, \sin(4\omega t), \cos(2\omega t), \theta, \ln\theta$

0.001, 输入时间步长为 10, 隐藏层数目为 2, 隐藏层节点数为 64, 最大迭代次数为 500。其中, LSTM 和 V-LSTM 模型的输入为 10 个变形特征因子, 其余模型的输入为特征筛选后的因子。

利用训练集和验证集对 5 种模型进行训练、验证, 为降低模型运行次数对预测结果的影响, 每种模型分别运行 10 次, 取验证集 loss 值最小的作为最优模型, 并对测试集进行预测, 预测结果如图 8(a) 所示。由图 8(a) 可知, 5 种模型预测值曲线变化趋势与实测值曲线变化趋势一致, 证实了 5 种模型的有效性。其中, IHV-RLSTM 模型预测值更接近实测值, 说明其具有较高的预测精度。

为验证所提模型的普适性, 利用 5 种模型对测点 PL9-4、PL13-2 和 PL16-3 顺河向位移数据分别进行训练、验证和预测。各测点预测结果如图 8(b)、(c) 和 (d) 所示。由图可知, 5 种模型对 3 个测点的预测结果过程线变化趋势均与实测值过程线变化趋势一致, 且 IHV-LSTM 模型预测值与实测值吻合度更高, 说明其泛化能力较好。

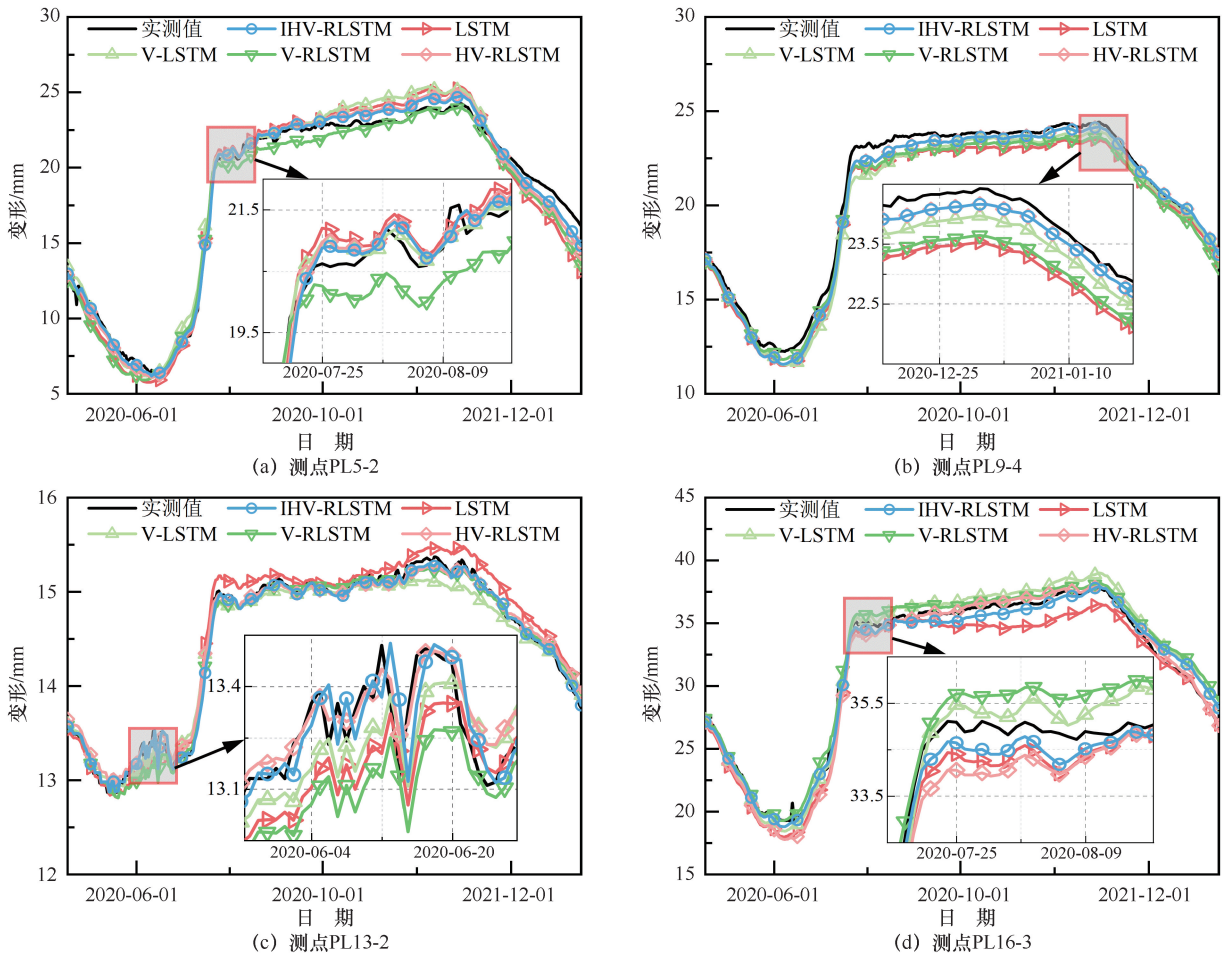


图8 各测点5种模型预测效果对比

Fig. 8 Comparison of the prediction effect of 5 models at each measurement point

为进一步定量评估 IHV-RLSTM 模型的性能, 计算出各模型对 4 个测点位移预测结果的 $RMSE$ 、 MAE 、 R^2 和 $MAPE$, 结果如表 2 所列, 4 类评价指标的雷达图, 如图 9 所示。由表 2 可知, IHV-RLSTM 模型的评价指标计算结果均为最优, 即 $RMSE$ 、 MAE 和 $MAPE$ 最小, R^2 最大, 说明该模型预测值与实测值较接近, 吻合度更高, 模型预测性能更强; 反观, 基本 LSTM 模型的预测效果最差。以测点 PL5-2 为例, 相较于 HV-RLSTM 模型, IHV-RLSTM 模型的 $RMSE$ 、 MAE 和 $MAPE$ 分别降低了 0.146 3 mm、0.124 2 mm 和 0.831%, R^2 提高了 0.004 7, 证实了利用 2 种策略改进 HHO 算法的有效性。对比 V-LSTM、V-RLSTM 模型, 后者 $RMSE$ 、 MAE 和 $MAPE$ 分别降低了 0.151 7 mm、0.131 2 mm 和 0.076 7%, R^2 提高了 0.007 7, 说明筛选模型输入特征因子可以降低因子间的冗余度, 提高模型预测精度。综上, IHV-RLSTM 模型具有较高的预测精度、较强的鲁棒性和较好的泛化能力。

4 结论

本文提出的 IHV-RLSTM 混凝土拱坝变形深度学习预测模型, 利用 IHHO 算法搜寻 VMD 最佳参数组合, 进而实现拱坝变形数据序列的最优分解; 利用 RF 算法通过计算特征因子的贡献率确定模型输入特征因子集合, 降低因子间的冗余度; 利用 LSTM 模型对各 IMF 分量分别进行建模和预测, 重构得到模型预测值。通过仿真信号分解结果对比和某工程 4 个监测点顺河向位移预测分析, 得到以下结论。

(1) 利用 Tent 混沌映射和能量随机性递减策略改进 HHO 算法, 提高了算法的迭代速度和寻优精度, 改善了 VMD 分解效果, 抑制了分解时的模态混叠现象; 同时, 使用 RF 算法筛选 IMF 分量的特征因子, 有利于后续 LSTM 模型捕捉数据序列与环境因素间的高维非线性关系, 增强其对拐点、变点的刻画能力。

表 2 各预测模型评价指标对比结果

Table 2 Comparison results of evaluation indicators of prediction model

测点	模型	RMSE/mm	MAE/mm	R ²	MAPE/%
PL5-2	IHV-RLSTM	0.504 4	0.414 8	0.993 0	2.353 9
	LSTM	1.051 2	0.867 3	0.969 6	5.425 5
	V-LSTM	0.995 9	0.805 4	0.972 7	4.719 4
	V-RLSTM	0.844 2	0.674 2	0.980 4	4.642 7
	HV-RLSTM	0.650 7	0.539 0	0.988 3	3.184 9
PL9-4	IHV-RLSTM	0.446 6	0.375 3	0.988 4	1.894 5
	LSTM	0.776 0	0.7320	0.9648	3.650 8
	V-LSTM	0.731 4	0.595 1	0.968 7	3.066 2
	V-RLSTM	0.644 6	0.610 9	0.975 7	2.947 7
	HV-RLSTM	0.505 6	0.417 4	0.985 1	2.053 1
PL13-2	IHV-RLSTM	0.057 8	0.040 5	0.994 9	0.282 8
	LSTM	0.137 2	0.121 3	0.971 2	0.835 3
	V-LSTM	0.118 3	0.096 6	0.978 6	0.665 4
	V-RLSTM	0.091 1	0.064 6	0.987 3	0.454 8
	HV-RLSTM	0.071 9	0.059 3	0.992 1	0.419 5
PL16-3	IHV-RLSTM	0.581 5	0.479 7	0.990 9	1.546 7
	LSTM	1.098 3	0.936 0	0.967 4	3.071 3
	V-LSTM	0.900 3	0.823 4	0.978 1	2.610 1
	V-RLSTM	0.827 9	0.673 9	0.981 5	2.169 0
	HV-RLSTM	0.701 3	0.519 6	0.983 7	1.994 7

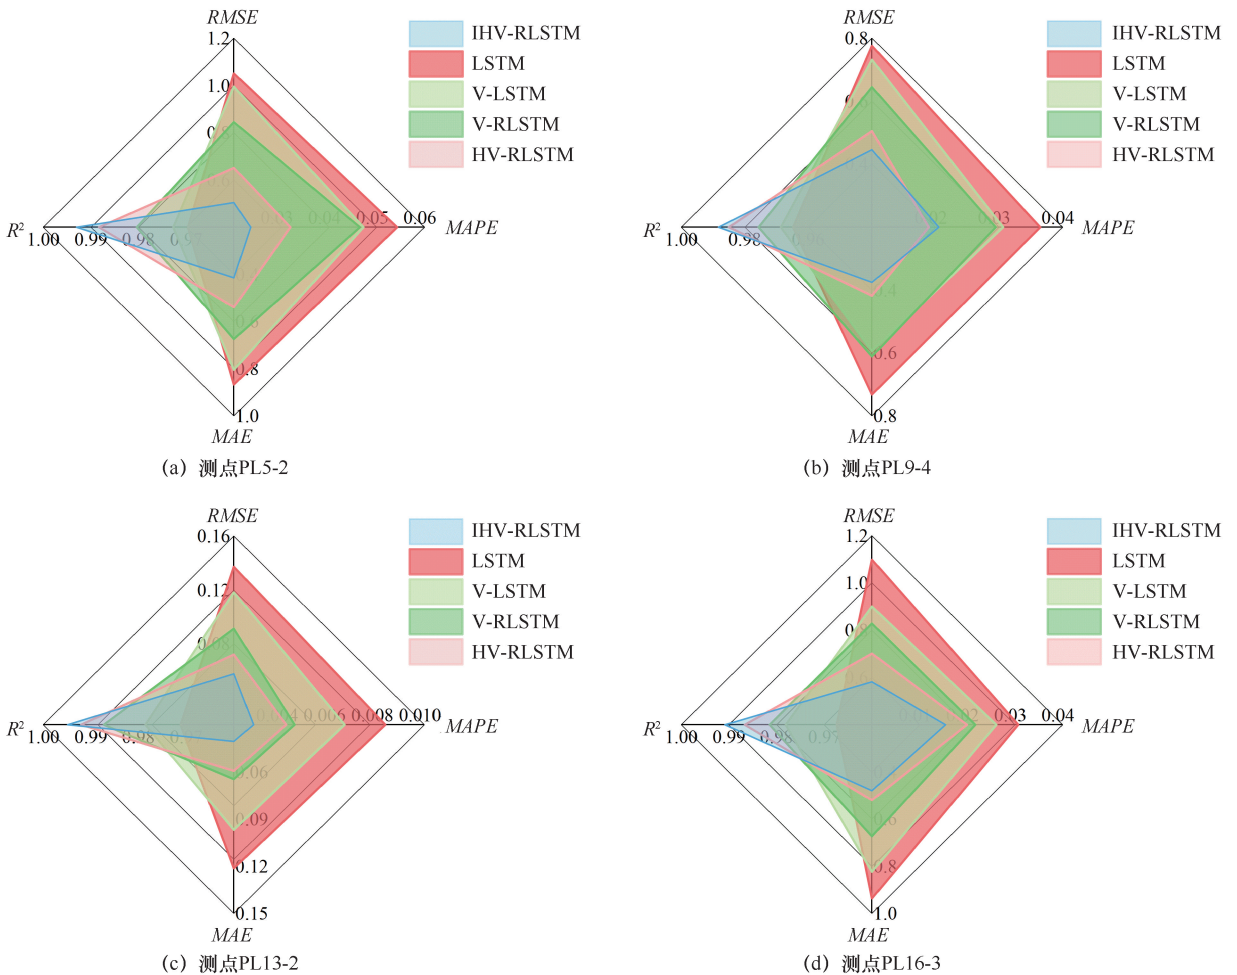


图 9 模型性能评价雷达图

Fig. 9 Radar chart for model performance evaluation

(2)相比于其他预测模型, IHV-RLSTM 在预测精度、泛化能力和适应性等方面均表现较好。对 4 个测点进行预测时, IHV-RLSTM 模型的预测值与实测值的吻合度更高, 说明其具有一定的普适性, 可以及时、有效的分析拱坝变形形态。

本文没有考虑 RF 算法参数取值对特征因子筛选结果的影响, 未来可以利用其他智能算法对其参数进行寻优。此外, 本文聚焦于构建单点位移预测模型, 未来应考虑测点间的关联性, 开展多点位移预测模型的研究。

参考文献 (References):

- [1] SHU Xiaosong, BAO Tengfei, LI Yangtao, et al. Dam safety evaluation based on interval-Valued intuitionistic fuzzy sets and evidence theory[J]. *Sensors*, 2020, 20(9): 2648-2676.
- [2] 李旭, 冯晓, 刘宇豪, 等. 基于 SSA-LMD-GM 的大坝变形组合预测模型[J]. *工程勘察*, 2024, 52(1): 45-49.
LI Xu, FENG Xiao, LIU Yuhao, et al. Combined prediction model of dam deformation based on SSA-LMD-GM [J]. *Geotechnical Investigation & Surveying*, 2024, 52(1): 45-49.
- [3] 欧斌, 张才溢, 傅蜀燕, 等. 基于 CNN-BiLSTM 的特高拱坝变形预测模型[J]. *排灌机械工程学报*, 2024, 42(10): 1031-1035.
OU Bin, ZHANG Caiyi, FU Shuyan, et al. CNN-BiLSTM-based deformation prediction model for extra-high arch dams[J]. *Journal of Drainage and Irrigation Machinery Engineering*, 2024, 42(10): 1031-1035.
- [4] XING Yin, CHEN Yang, HUANG Saipeng, et al. Research on dam deformation prediction model based on optimized SVM [J]. *Processes*, 2022, 10(9): 1842-1842.
- [5] 程焕新, 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.
CHENG Huanxin, HUANG Zhen. Short-term electric load forecasting model based on improved PSO optimized RNN [J]. *Electronic Measurement Technology*, 2019, 42(20): 94-98.
- [6] 欧斌, 吴邦彬, 袁杰, 等. 基于 LSTM 的混凝土坝变形预测模型[J]. *水利水电科技进展*, 2022, 42(1): 21-26.
OU Bin, WU Bangbin, YUAN Jie, et al. LSTM-based deformation prediction model of concrete dams [J]. *Advances in Science and Technology of Water Resources*, 2022, 42(1): 21-26.
- [7] WEI Yilun, LI Qingbin, YU Hu, et al. Deformation prediction model based on an improved CNN + LSTM model for the first impoundment of super-high arch dams [J]. *Journal of Civil Structural Health Monitoring*, 2023(13): 431-442.
- [8] 施彦彤, 郑东健, 赵汉, 等. 基于 CNN-Attention-LSTM 的大坝变形预测模型[J]. *水利水电技术(中英文)*, 2024, 55(9): 121-132.
SHI Yantong, ZHENG Dongjian, ZHAO Han, et al. Dam deformation prediction model based on CNN Attention LSTM [J]. *Water Resources and Hydropower Engineering*, 2024, 55(9): 121-132.
- [9] YANG Dashan, GU Chongshi, ZHU Yantao, et al. A concrete dam deformation prediction method based on LSTM with attention mechanism[J]. *IEEE Access*, 2020(8): 185177-185186.
- [10] 周兰庭, 柳志坤, 徐长华. 基于 SSA-LSTM-ARIMA 的混凝土坝变形组合预测模型[J]. *人民黄河*, 2022, 44(1): 124-128.
ZHOU Lanting, LIU Zhikun, XU Changhua. Concrete dam deformation combination prediction based on SSA-LSTM-ARIMA[J]. *Yellow River*, 2022, 44(1): 124-128.
- [11] BAI Dongxin, LU Guangyin, ZHU Ziqiang, et al. Using time series analysis and dual-stage attention-based recurrent neural network to predict landslide displacement [J]. *Environmental Earth Sciences*, 2022, 81(21): 509.1-509.18.
- [12] 曹恩华, 包腾飞, 刘永涛, 等. 基于 VMD 的多尺度变量提取法在混凝土坝变形预测中的应用[J]. *水电能源科学*, 2022, 40(2): 114-118.
CAO Enhua, BAO Tengfei, LIU Yongtao, et al. VMD-based multi-scale variables extraction model for deformation prediction of concrete dam[J]. *International Journal Hydroelectric Energy*, 2022(2): 114-118.
- [13] 张建中, 顾冲时, 袁冬阳, 等. 基于优化 VMD 与 GRU 的混凝土坝变形预测模型[J]. *水利水电科技进展*, 2023, 43(5): 38-44.
ZHANG Jianzhong, GU Chongshi, YUAN Dongyang, et al. Deformation prediction model of concrete dams based on optimized VMD and GRU [J]. *Advances in Science and Technology of Water Resources*, 2023, 43(5): 38-44.
- [14] 李冰. 改进鲸鱼算法优化 GRU 的大坝变形预测研究[D]. 赣州: 江西理工大学, 2022.
LI Bing. Improved Whale Algorithm Optimized GRU for Dam Deformation Prediction Research[D]. Ganzhou: Jiangxi University of Science and Technology, 2022.
- [15] 漆一宁, 苏怀智, 姚可夫, 等. 耦合时序特征分解筛选的大坝变形分析模型[J]. *水力发电学报*, 2023, 42(7): 56-68.
QI Yining, SU Huaizhi, YAO Kefu, et al. Dam deformation analysis model based on characteristic decomposition screening of coupling time series[J]. *Journal of Hydroelectric Engineering*, 2023, 42(7): 56-68.
- [16] CAO Enhua, BAO Tengfei, LI Hui, et al. A hybrid feature selection-multidimensional LSTM framework for deformation prediction of super high arch dams[J]. *KSCE Journal of Civil Engineering*, 2022, 26(11): 4603-4616.
- [17] ZHANG Ye, ZHONG Wen, LI Yanlong, et al. A deep learning prediction model of DenseNet-LSTM for concrete gravity dam deformation based on feature selection [J]. *Engineering Structures*, 2023(295): 116827.
- [18] HEIDARI A A, MIRJALIL I S, FARI S H, et al. Harris hawks optimization; algorithm and applications [J]. *Future Generation Computer Systems*, 2019(97): 849-872.
- [19] 徐先峰, 赵依, 刘壮壮, 等. 用于短期电力负荷预测的日负荷特性分类及特征集重构策略[J]. *电网技术*, 2022, 46(4): 1548-1556.
XU Xianfeng, ZHAO Yi, LIU Zhuangzhuang, et al. Daily load characteristic classification and feature set reconstruction strategy for

- short-term power load forecasting [J]. *Power System Technology*, 2022, 46(4): 1548-1556.
- [20] 朱凌建, 荀子涵, 王裕鑫, 等. 基于 CNN-BiLSTM 的短期电力负荷预测[J]. *电网技术*, 2021, 45(11): 4532-4539.
ZHU Lingjian, XUN Zihan, WANG Yuxin, et al. Short-term power load forecasting based on CNN-BiLSTM [J], *Power System Technology*, 2021, 45(11): 4532-4539.
- [21] LIU Jiandong, ZHONG Ming, LIU Bo, et al. Design of three-dimensional dynamic integer tent map and its image encryption algorithm [J]. *Multimedia Tools and Applications*, 2021 (80): 19219-19236.
- [22] SHADI Y D N, NASER S, SEYED A H Z. New method for fingerprint images encryption using DNA sequence and chaotic tent map[J]. *Optik*, 2020(224): 165661.
- [23] 刘小宁, 魏霞, 谢丽蓉. 混合哈里斯鹰算法求解作业车间调度问题[J]. *计算机应用研究*, 2022, 39(06): 1673-1677.
LIU Xiaoning, WEI Xia, XIE Lirong. Hybrid Harris eagle algorithm for job-Shop scheduling problem [J]. *Application Research of Computers*, 2022, 39(06): 1673-1677.
- [24] 赵世杰, 高雷阜, 于冬梅, 等. 融合能量周期性递减与牛顿局部增强的改进 HHO 算法[J]. *控制与决策*, 2021, 36(3): 629-636.
ZHAO Shijie, GAO Leifu, YU Dongmei, et al. Improved harris hawks optimization coupling energy cycle decline mechanism and Newton local enhancement strategy[J]. *Control and Decision*, 2021, 36(3): 629-636.
- [25] 刘建昌, 权贺, 于霞, 等. 基于参数优化 VMD 和样本熵的滚动轴承故障诊断[J]. *自动化学报*, 2022, 48(3): 808-819.
LIU Jianchang, QUAN He, YU Xia, et al. Rolling bearing fault diagnosis based on parameter optimization VMD and sample entropy [J]. *Acta Automatica Sinica*, 2022, 48(3): 808-819.
- [26] 王博, 南新元. 基于 AO-VMD 和 IAO-SVM 的齿轮箱故障诊断[J]. *机械传动*, 2023, 47(5): 143-149.
WANG Bo, NAN Xinyuan. Fault diagnosis of gearboxes based on AO-VMD and IAO-SVM[J]. *Journal of Mechanical Transmission*, 2023, 47(5): 143-149.
- [27] BANDT C, POMPE B. Permutation entropy: a natural complexity measure for time series[J]. *Physical review letters*, 2002, 88(17): 174102.
- [28] 邓念东, 崔阳阳, 郭有金. 基于频率比-随机森林模型的滑坡易发性评价[J]. *科学技术与工程*, 2020, 20(34): 13990-13996.
DENG Niandong, CUI Yangyang, GUO Youjin. Frequency ratio-random forest-model-based landslide susceptibility assessment [J]. *Science Technology and Engineering*, 2020, 20(34): 13990-13996.
- [29] 马金沙. 基于随机森林变量重要性评分的变量筛选方法及其在肿瘤分型诊断中的应用[D]. 太原: 山西医科大学, 2021.
MA Jinsha. Variable Selection Methods Based on Variable Importance Measurement from Random Forest and Its Application in Diagnosis of Tumor Typing[D]. Taiyuan: Shanxi Medical University, 2021.
- [30] 曹桃云. 基于随机森林的变量重要性研究[J]. *统计与决策*, 2022, 38(4): 60-63.
CAO Taoyun. Study on the importance of variables based on random forest[J]. *Statistics & Decision*, 2022, 38(4): 60-63.
- [31] 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.
YANG Beibei, YIN Kunlong, DU Juan. A model for predicting landslide displacement based on time series and long and short term memory neural network[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2018, 37(10): 2334-2343.
- [32] 宋丽伟. 基于经验模态分解和 LSTM 模型的滑坡位移预测[J]. *人民长江*, 2020, 51(5): 144-148.
SONG Liwei. Landslide displacement prediction based on empirical mode decomposition and long short-term memory neural network model [J]. *Yangtze River*, 2020, 51(5): 144-148.

(责任编辑 王璐)