

丁勇康, 远近, 毛延翩, 等. 基于 IHHO-LSTM-KAN 的大坝变形预测模型[J]. 水利水电技术(中英文), 2025, 56(5): 170-182. DOI: 10.13928/j.cnki.wrahe.2025.05.014

DING Yongkang, YUAN Jin, MAO Yanpian, et al. Dam deformation prediction model based on IHHO-LSTM-KAN[J]. Water Resources and Hydropower Engineering, 2025, 56(5): 170-182. DOI: 10.13928/j.cnki.wrahe.2025.05.014

# 基于 IHHO-LSTM-KAN 的大坝变形预测模型

丁勇康<sup>1,2</sup>, 远 近<sup>3</sup>, 毛延翩<sup>3</sup>, 都旭煌<sup>3</sup>, 齐智勇<sup>3</sup>, 苏怀智<sup>1,2,4</sup>

(1. 河海大学 水灾害防御全国重点实验室, 江苏 南京 210098; 2. 河海大学 水利水电学院, 江苏 南京 210098; 3. 中国长江电力股份有限公司, 湖北 武汉 430000; 4. 河海大学 水资源高效利用与工程安全国家工程研究中心, 江苏 南京 210098)

**摘要:**【目的】全生命周期高精度的变形预测是评估大坝服役性态和保障大坝安全运行的关键方法。目前预测模型存在数据特征相关性解析不足、对短时序数据预测精度不高、忽视时序持续增长的特性、模型训练易陷入局部最优等问题。【方法】提出一种大坝变形预测模型, 利用长短期记忆网络(LSTM)捕捉时序长短期依赖关系, 并耦合 KAN 机制改进网络全连接层结构以增强对长短期复杂数据关系的表征能力, 采用多策略改进的哈里斯鹰优化算法(IHHO)探索超参数最优组合, 从而优化模型结构、解决梯度问题、加速训练收敛并提高预测性能。【结果】实例表明, 该模型对长短期时序的预测精度和泛化能力均优于其他深度学习模型, 收敛速度优于其他智能优化算法, KAN 机制对短时序预测的改进效果较为明显。【结论】所建模型具有较好的稳健性与适用性, 可为大坝全生命周期的安全监测提供技术参考。

**关键词:** 大坝变形预测; 短时间序列; 长短期记忆网络; KAN; 改进哈里斯鹰优化算法; 变形; 影响因素

DOI: 10.13928/j.cnki.wrahe.2025.05.014

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)05-0170-13



## Dam deformation prediction model based on IHHO-LSTM-KAN

DING Yongkang<sup>1,2</sup>, YUAN Jin<sup>3</sup>, MAO Yanpian<sup>3</sup>, DU Xuhuang<sup>3</sup>, QI Zhiyong<sup>3</sup>, SU Huaizhi<sup>1,2,4</sup>

(1. The National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, Jiangsu, China; 2. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, Jiangsu, China; 3. China Yangtze Power Co., Ltd., Wuhan 430000, Hubei, China; 4. National Engineering Research Center of Water Resources Efficient Utilization and Engineering Safety, Hohai University, Nanjing 210098, Jiangsu, China)

**Abstract:** [Objective] High-precision deformation prediction during the whole life cycle is a key method to evaluate the service behavior of dams and ensure the safe operation of dams. The current prediction model has problems such as insufficient correlation analysis of data feature, low prediction accuracy of short time series data, neglecting the continuous growth properties

收稿日期: 2024-12-04; 修回日期: 2025-01-22; 录用日期: 2025-02-28; 网络出版日期: 2025-04-18

基金项目: 国家自然科学基金重点项目(52239009); 水资源高效利用与工程安全国家工程研究中心开放研究基金(GJGCZX-JJ-202428)

作者简介: 丁勇康(2001—), 男, 硕士研究生, 主要从事大坝安全监测方面研究。E-mail: dingyongkang3@163.com

通信作者: 苏怀智(1973—), 男, 教授, 博士研究生导师, 博士, 从事涉水工程安全防控与提能延寿研究。E-mail: su\_huaizhi@hhu.edu.cn

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

of the time series, and easy to fall into the local optimum in model training. [Methods] Therefore, a dam dynamic deformation prediction model is proposed, which utilizes the long short-term memory neural network (LSTM) to capture the long-term and short-term dependence of time series, couples the Kolmogorov-Arnold Networks (KAN) mechanism to improve the fully connected layer structure of the network to enhance the ability to characterize the complex data relationship of long and short time series, and adopts multi-strategy improved Harris Hawks optimization algorithm (IHHO) to explore the optimal combination of hyperparameters, so as to optimize the model structure, solve the gradient problem, accelerate the training convergence and improve the prediction performance. [Results] Examples show that the prediction accuracy and generalization ability of the model for short and long time series are better than other deep learning models, and the convergence speed is superior to other intelligent optimization algorithms, and the improvement effect of KAN mechanism on the short time series prediction is more obvious. [Conclusion] The model has good robustness and applicability, which can provide technical reference for the dynamic safety monitoring of the whole life cycle of dams.

**Keywords:** dam deformation prediction; short time series; long short-term memory; KAN; improved Harris Hawks optimization algorithm; deformation; influencing factors

## 0 引言

我国已建成水库大坝 9.4 万余座<sup>[1]</sup>, 其中 80% 建于 20 世纪 50 年代至 70 年代, 随着使用年限渐增必然导致材料劣化和监测仪器故障<sup>[2-3]</sup>。“十四五”以来, 已安排 250 座大中型水库和 14 419 座小型水库除险加固, 并增建 30 620 座水库的安全监测设施<sup>[4]</sup>, 2025—2027 年预计实施 200 余座大中型水库和 4 800 余座小型水库除险加固<sup>[5]</sup>, 从而保障大坝运行安全。变形是反映大坝服役性态最直观的效应量<sup>[6]</sup>, 而随着国家水网新建工程稳步推进和旧坝病坝除险工作逐年增加, 监测数据累积时间较短, 这对基于长时序稳定历史资料的大坝变形预测模型提出重大挑战。因此, 探究长短时序下多重环境因素与变形的关联性, 提高模型预测精度和长短时序适应性对大坝安全运行意义重大<sup>[7-8]</sup>。

传统变形预测模型主要是基于数理统计的回归分析模型<sup>[9-10]</sup>, 此类模型结构简单但存在多重共线性问题且对异常值非常敏感, 因此具有强适应性和可学习性的神经网络开始被广泛应用<sup>[11]</sup>。VAPNIK 等<sup>[12]</sup>提出的支持向量机监督学习模型能有效解决共线性问题, 但其二次规划求解方式在计算高阶矩阵时会耗费大量机器内存。张石等<sup>[13]</sup>采用极限学习机随机生成网络权重从而加快训练速度, 且在非平稳数据上表现良好, 但其浅层神经网络依赖人工特征提取, 对复杂函数表征能力不足<sup>[14]</sup>。继而发展出的深度神经网络能利用多层非线性结构自主发现数据模式并提取数据本质特征, 从而最小化预测误差<sup>[15]</sup>。BUI 等<sup>[16]</sup>将长短期记忆网络 (Long Short-Term Memory, LSTM) 应用于越南和平水电站大坝, 捕捉时序长短期依赖关系,

试验表明 LSTM 相对浅层神经网络模型预测性能更优。雷未等<sup>[17]</sup>利用 BiLSTM 的前后双向传播原则, 充分挖掘时序双向信息的关联性, 但模型参数显著增加, 在小数据集上难以形成有效的参数约束, 从而增加过拟合风险。陈以浩等<sup>[18]</sup>通过整合卷积神经网络和门控循环单元 (Gated Recurrent Unit, GRU) 提高预测精度, GRU 通过简化 LSTM 结构缓解反向传播的梯度问题<sup>[19]</sup>, 但学习能力随之减弱, 这将会影响模型在短时序预测中的泛化能力。ZHOU 等<sup>[20]</sup>、HUANG 等<sup>[21]</sup>将多头注意力网络融入 LSTM, 获取数据时空特征, 优化模型在周期性时序上的性能, 但较依赖训练集质量与数量, 模型结构更为复杂。因此各模型在不同长度时序下的适应性及稳健性仍需改进。

在评估模型预测性能时, 大多数学者使用固定长度、多年多周期、数据相对稳定的训练集进行模型训练, 王晓玲等<sup>[22]</sup>和 LIU 等<sup>[23]</sup>分别使用 4 a 和 6 a 数据预测土石坝渗压效应量, LIU 等<sup>[24]</sup>和 LI 等<sup>[25]</sup>分别使用 5 a 和 9 a 数据分解时序噪声并预测变形趋势, 但均未研究模型在长短时序下的预测性能。李明超等<sup>[26]</sup>通过固定训练集改变预测集长度, 固定预测集改变训练集长度验证模型准确性, 但仅得出性能随测试集比例增大而降低的一般规律, 未对短时序预测效果较差的问题提出优化方法。而 KAN (Kolmogorov-Arnold Networks)<sup>[27]</sup>能使网络激活函数实现动态学习并摆脱对线性权重的依赖, 从而增强函数表征能力。经 JIANG 等<sup>[28]</sup>验证, KAN 在时序预测任务中面对对抗性攻击仍有较好的鲁棒性, 因此在数据量较少和数据异常较多的情况下有望发挥重要作用。

超参数配置是影响神经网络预测表现的关键因素, 然而数据量、数据复杂度和网络层数的提高导致

手动调参效率低下, 因此具备自动调参能力的智能优化算法极具优势。王浩然等<sup>[29]</sup>采用改进鲸鱼优化算法对 BP 神经网络的权重和偏置进行寻优, KANCHAN 等<sup>[30]</sup>归纳出基于人类行为、物理现象、生物活动等五类元启发式优化算法, 指出此类灵活性较强且不易陷入局部最优。HEIDARI 等<sup>[31]</sup>提出哈里鹰优化算法 (Harris Hawks optimization algorithm, HHO), 通过模拟哈里鹰飞行突袭的捕食行为进行目标探索, 与其他优化算法相比具有控制参数少、能及时跳出局部最优的优势, 因此该算法能极大加速神经网络超参数寻优的过程。

针对以上问题, 提出基于 IHHO-LSTM-KAN 的大坝变形预测模型。使用 LSTM 识别时序短期和长期特征, 采用 KAN 提升模型表征能力, 从而基于较少的数据量实现高精度预测并提高模型对长短时序预测的适应性; 应用多种策略改进 HHO, 使其在早期快速缩小最优解搜索范围并在后期高效逼近, 提升寻优效率; 利用改进算法寻找超参数最优组合, 避免人工调参的主观局限性, 从而综合提升模型预测精度和对长短时序的适应能力。本文取不同长度的大坝变形监测时序数据, 固定测试集比例, 研究模型在长短时序上的预测性能及 KAN 作用机理, 深入挖掘变形规律, 为大坝全生命周期监控与预警提供技术支持。

## 1 理论方法

### 1.1 大坝变形预测统计模型基本原理

根据大坝变形特性<sup>[32]</sup>, 水压和库水重共同引起坝体顺河向位移和坝基转动, 形成水压分量  $\delta_H$ , 构成水压因子多项式  $\sum_{i=1}^4 a_i H_i$ ; 气温和水温通过影响坝体混凝土温度使拱圈和支墩发生周期性变形, 形成温度分量  $\delta_T$ , 构成谐波组合的温度因子多项式  $\sum_{i=1}^2 (b_{1i} T_{\sin i} + b_{2i} T_{\cos i})$ ; 坝体因材料逐渐劣化和地质构造等原因产生不可逆变形, 形成时效分量  $\delta_\theta$ , 构成时效因子多项式  $\sum_{i=1}^2 c_i \theta_i$ , 因此以水压、温度、时效因子为特征因子构建基于时序分析的大坝变形预测模型<sup>[33]</sup>

$$\begin{cases} H_i = H^i - H_0^i \\ T_{\sin i} = \sin(2\pi it/365) - \sin(2\pi it_0/365) \\ T_{\cos i} = \cos(2\pi it/365) - \cos(2\pi it_0/365) \\ \theta_1 = \theta - \theta_0, \quad \theta_2 = \ln\theta - \ln\theta_0 \\ \theta = t/100, \quad \theta_0 = t_0/100 \end{cases} \quad (1)$$

式中,  $H$ 、 $H_0$  分别为监测日和始测日上游水位;  $t$ 、 $t_0$

分别为监测日、序列首日至始测日累计天数;  $a_i$ 、 $b_{1i}$ 、 $b_{2i}$ 、 $c_i$  为回归系数。

### 1.2 LSTM 变形预测模型

循环神经网络 (Recurrent Neural Network, RNN) 是具有记忆的时间序列预测模型, 为应对长期依赖问题和梯度消失缺陷, LSTM 基于 RNN 引入三门和细胞状态<sup>[34]</sup>, 三门均由具有 sigmoid 激活函数的全连接层处理。遗忘门  $F_t$  的传入包括当前时间步输入  $X_t$  和过去时间步的隐状态  $H_{t-1}$ ,  $X_t$  为特征因子矩阵,  $H_{t-1}$  包含过去预测结果和模型内部状态。 $F_t$  控制过去记忆元  $C_{t-1} \in \mathbb{R}^{n \times h}$ ,  $n$  为批量大小,  $h$  为隐藏单元数, 包括历史水位传递效应、温度累积效应和时效因子长期影响<sup>[35]</sup>。输入门  $I_t$  控制候选记忆元  $\tilde{C}_t \in \mathbb{R}^{d \times h}$ ,  $d$  为特征因子维数, 生成反映因子变化的信息片段。 $F_t$  和  $I_t$  共同控制信息遗忘与传递, 更新记忆单元  $C_t$ , 从而缓解梯度问题, 挖掘时序长短期依赖关系。输出门  $O_t$  决定信息输出, 与  $C_t$  共同作用, 预测出隐状态  $H_t \in \mathbb{R}^{n \times h}$ , 即当前时间步变形预测结果。最后通过反向传播算法更新权重参数, 使网络更好地适应数据。模型数据流演示如图 1 所示, 数学表达式为<sup>[34]</sup>

$$\begin{cases} I_t = \sigma(X_t W_{xi} + H_{t-1} W_{hi} + b_i) \\ F_t = \sigma(X_t W_{xf} + H_{t-1} W_{hf} + b_f) \\ O_t = \sigma(X_t W_{xo} + H_{t-1} W_{ho} + b_o) \\ \tilde{C}_t = \tanh(X_t W_{xc} + H_{t-1} W_{hc} + b_c) \\ C_t = F_t \odot C_{t-1} + I_t \odot \tilde{C}_t \\ H_t = O_t \odot \tanh(C_t) \end{cases} \quad (2)$$

式中,  $W_{xi}$ 、 $W_{xf}$ 、 $W_{xo}$ 、 $W_{xc} \in \mathbb{R}^{d \times h}$  和  $W_{hi}$ 、 $W_{hf}$ 、 $W_{ho}$ 、 $W_{hc} \in \mathbb{R}^{h \times h}$  为权重参数;  $b_i$ 、 $b_f$ 、 $b_o$ 、 $b_c \in \mathbb{R}^{1 \times h}$  为偏置参数;  $\sigma$  和  $\tanh$  为激活函数。

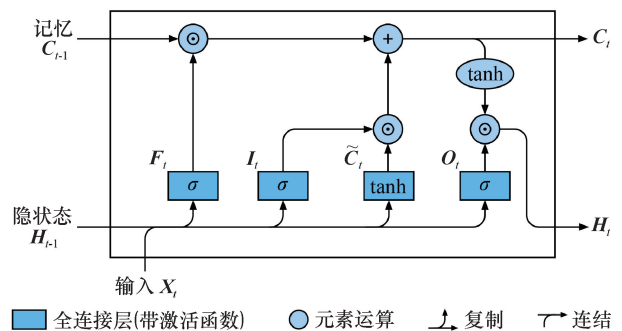


图 1 LSTM 模型逻辑

Fig. 1 LSTM model logic diagram

### 1.3 基于 KAN 的 LSTM 模型改进

LSTM 等神经网络的基础是多层感知机 (Multilayer Perceptron, MLP), 包含输入输出层和多

个隐藏层, 在神经元中使用固定激活函数, 存在无法有效处理高维数据和长短期依赖问题<sup>[36]</sup>。KAN 在网络边缘采用可学习的激活函数, 以参数化为样条的单变量函数替换 MLP 的线性权重<sup>[27]</sup>, 更改 LSTM 中三门使用的 sigmoid 激活函数和记忆元使用的 tanh 激活函数, 更换  $W_{xi}$ 、 $W_{hi}$  等权重参数。由于样条函数对复杂函数有更强大的表征能力, 能更好地拟合复杂非线性关系, 因此 KAN 可使用更少的参数量提高预测性能。KAN 与 MLP 网络结构如图 2 所示。

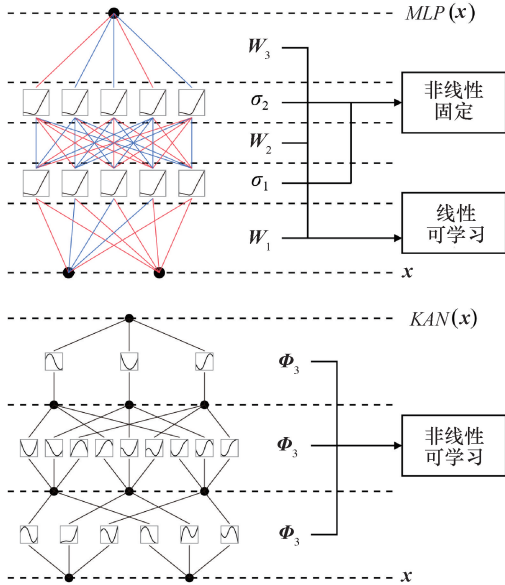


图 2 MLP 和 KAN 网络架构对比

Fig. 2 Comparison diagram of MLP and KAN network architecture

KAN 理论基础是任何多变量连续函数  $f: [0, 1]^n \rightarrow \mathbb{R}$  都可表示为有限个单变量连续函数组合<sup>[37]</sup>

$$f(x) = f(x_1, \dots, x_n) = \sum_{q=0}^{2n} \Phi_q \left[ \sum_{p=1}^n \phi_{q,p}(x_p) \right] \quad (3)$$

式中,  $\phi_{q,p}$  表示  $[0, 1] \rightarrow \mathbb{R}$ ;  $\Phi_q$  表示  $\mathbb{R} \rightarrow \mathbb{R}$ ;  $p$  为输入变量索引;  $q$  为函数层索引;  $n$  为向量维度。

KAN 层是一个一维函数矩阵  $\Phi$

$$\Phi = [\phi_{q,p}], \quad p = 1, 2, \dots, n_{in}, \quad q = 1, 2, \dots, n_{out} \quad (4)$$

通过多次堆叠, 根据第  $l$  个 KAN 层的函数矩阵  $\Phi_l$ , 寻找层输入输出之间的转移矩阵

$$x_{l+1} = \underbrace{\begin{pmatrix} \phi_{l,1,1}(\cdot) & \phi_{l,1,2}(\cdot) & \cdots & \phi_{l,1,n_l}(\cdot) \\ \phi_{l,2,1}(\cdot) & \phi_{l,2,2}(\cdot) & \cdots & \phi_{l,2,n_l}(\cdot) \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{l,n_{l+1},1}(\cdot) & \phi_{l,n_{l+1},2}(\cdot) & \cdots & \phi_{l,n_{l+1},n_l}(\cdot) \end{pmatrix}}_{\Phi_l} x_l \quad (5)$$

式中,  $\phi_{l,i,j}$  为各边上的激活函数, 即非线性变换;  $i$  标记当前层节点;  $j$  标记下一层节点。

网络中残差激活函数  $\phi_x$  是基础函数  $b(x)$  和样条函数  $spline(x)$  之和, 样条函数参数化为 B 样条的线性组合

$$\begin{cases} \phi_x = w [b(x) + spline(x)] \\ b(x) = silu(x) = x / (1 + e^{-x}) \\ spline(x) = \sum_i c_i B_i(x) \end{cases} \quad (6)$$

式中,  $c_i$  为优化系数;  $B_i(x)$  为 B 样条基函数;  $w$  为激活函数大小控制因子。

进而将多层函数级联关系写为矩阵形式表示 KAN 的输出

$$KAN(x) = (\Phi_{L-1} \circ \Phi_{L-2} \circ \cdots \circ \Phi_1 \circ \Phi_0)x \quad (7)$$

### 1.4 IHHO 优化 LSTM 模型超参数

HHO 算法根据哈里斯鹰在捕食猎物过程中的合作行为以及突然袭击的狩猎风格, 将寻优分为探索-过渡-开发三个阶段<sup>[31]</sup>, 哈里斯鹰的位置为候选解, 迭代的最佳候选解为猎物, 即 LSTM 模型最优超参数组合, 根据猎物动态逃逸能量  $E$  和猎物逃脱概率  $r$  调整狩猎策略, 从而快速围捕猎物, 捕食策略如图 3 所示。

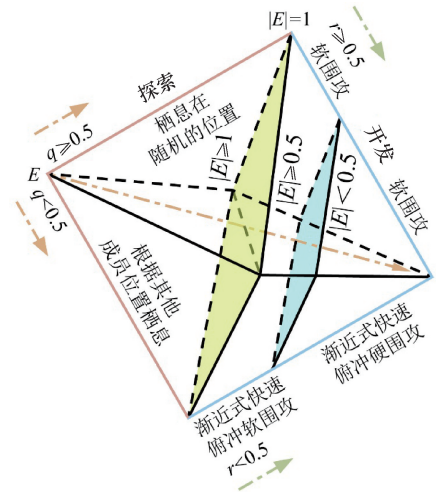


图 3 哈里斯鹰捕食策略

Fig. 3 Harris hawks predation strategy diagram

然而 HHO 存在收敛速度慢、全局探索和局部开发平衡性较差等问题, 因此提出混合策略改进的哈里斯鹰优化算法 (Improved HHO, IHHO), 改进策略如下<sup>[38]</sup>。

(1) 采用 Tent 混沌映射方法增加初始种群多样性, 使初始超参数具有较好遍历均匀性

$$\begin{cases} y_{i+1} = \begin{cases} 2y_i + \text{rand}(0, 1)/N, & 0 \leq y_i < 0.5 \\ 2(1 - y_i) + \text{rand}(0, 1)/N, & 0.5 < y_i \leq 1 \end{cases} \\ x_{i+1} = y_{i+1}(ub - lb) + lb \end{cases} \quad (8)$$

式中,  $\text{rand}(0, 1)$  为  $[0, 1]$  内的随机数;  $N$  为 Tent 序列内粒子个数;  $x_{i+1}$  为映射后的哈里斯鹰个体。

(2) 采用小孔成像反向学习方法, 增加种群精英个体的数量, 从而扩大搜索区域

$$x'_j = (a_j + b_j)/2 + (a_j + b_j)/2n - x_j/n \quad (9)$$

式中,  $x_j, x'_j$  分别为当前哈里斯鹰最优解和小孔成像后的反向最优解;  $a_j, b_j$  分别为第  $j$  维解的上下限;  $n$  为小孔成像调节因子。

(3) 采用动态自适应权重提高能量递减策略的非线性表达, 平衡探索和开发行为, 提高寻优效率

$$\begin{cases} E = 2E_0\omega(1 - t/T) \\ \omega = \delta \left[ \omega_{\text{initial}} - (\omega_{\text{initial}} - \omega_{\text{final}}) \times \frac{(e^{t/T} - 1)}{(e - 1)} \right] \end{cases} \quad (10)$$

式中,  $\omega_{\text{initial}}$  为权重初值;  $\omega_{\text{final}}$  为权重终值;  $\delta$  为  $[0, 1]$  内的随机数。

(4) 采用拉普拉斯交叉算子策略扰动最优适应度的两个个体, 对比择优进入下轮迭代, 避免陷入局部最优

$$\begin{cases} f(x) = e^{-|x-a|/b}/2b \\ U_{1i} = x_{1i} + \beta |x_{1i} - x_{2i}| \\ U_{2i} = x_{2i} + \beta |x_{1i} - x_{2i}| \end{cases} \quad (11)$$

式中,  $U_{1i}, U_{2i}$  为扰动后子代个体的位置;  $a \in R$  为位置参数;  $b$  为尺度参数;  $x_{1i}, x_{2i}$  为解空间中适应度最高的两个个体的位置;  $\beta$  为分布随机数。

### 1.5 大坝变形预测模型构建

根据前述理论, 构建基于 IHHO-LSTM-KAN 的大坝变形预测模型, 建模流程如图 4 所示, 主要步骤如下。

(1) 数据预处理。选定坝体目标测点, 确定大坝变形特征因子, 对顺河向水平位移、环境温度、上游水位和时效序列进行预处理, 将时序数据  $x_i$  归一化为标准训练格式, 以消除各因子量纲差别

$$M_i = (x_i - x_{\min}) / (x_{\max} - x_{\min}) \quad (12)$$

式中,  $M_i$  为归一化数据;  $x_{\min}, x_{\max}$  分别为数据集的最小值和最大值。

(2) 时序分割。按时间长度切分监测数据, 以相同比例划分为训练集和测试集, 从而分析模型在不同长度时序下的性能表现。

(3) 模型参数优化。设置 IHHO 优化算法的最大迭代次数和种群数, 确定 LSTM 模型和 KAN 网络的超参数寻优范围, 定义适应度函数, 按照优化策略迭代更新网络参数。

(4) 模型训练及评估。将最优超参数输入训练集数据进行模型训练, 对比真实值与测试集预测结果, 结合多重评价指标进行模型评估和机制分析, 选取  $MAPE, RMSE, R^2$  和  $MAE$  作为评价指标<sup>[39]</sup>

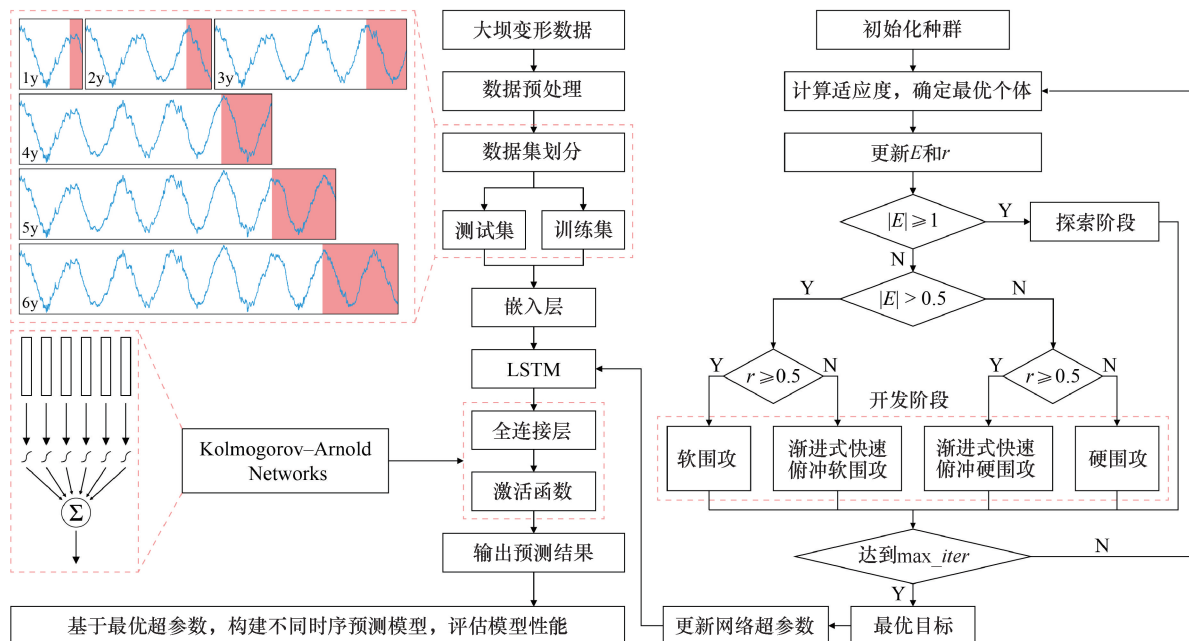


图 4 IHHO-LSTM-KAN 大坝变形预测模型

Fig. 4 IHHO-LSTM-KAN dam deformation prediction model

$$\begin{cases} MAPE = \frac{1}{n} \sum_{i=1}^n |(\hat{y}_i - y_i/y_i)| \\ RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \\ R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2} \\ MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \end{cases} \quad (13)$$

式中,  $n$  为时序数据长度;  $y_i$  为第  $i$  个数据实测值;  $\hat{y}_i$  为第  $i$  个数据预测值;  $\bar{y}$  为实测数据均值。

## 2 工程实例分析

某水库是一座具有防洪、灌溉、发电、养殖等综合功能的年调节大(2)型工程, 总库容 3.47 亿  $m^3$ , 拦河坝为混凝土双支墩肋墩坝。大坝水平位移监测采用垂线法, 设有 11 条正垂线和 2 条倒垂线, 均采用 RZ-50 型电容式垂线坐标仪实现自动监测。

### 2.1 数据集划分

大坝监测数据通常在初期含有较大局部波动且仅含有限的年度周期信息<sup>[40-41]</sup>, 之后数据趋于稳定, 周期特征明显, 具有明显长期趋势, 据此本文利用 3 a 以下的短时序和 3 a 以上的长时序检验模型的预测性能和长短时序适应性。选取 PL6-1 测点 2006 年 12 月 27 日至 2014 年 6 月 26 日的水平位移监测序列, 共 2739 组。为分析模型在不同时序下的性能表现, 分别自起始日抽取 1~6 a 的监测数据作为训练集, 以 8:2 的比例向后抽取测试集, 共 6 组时序数据, 分别命名为 1y、2y、3y、4y、5y 和 6y, 数据切分如图 5 所示。

### 2.2 预测模型对比

为验证 LSTM 模型对长短时序预测的性能优势,

并分析 KAN 机制作效果, 选择 BiLSTM、GRU、TCN 和 Transformer 作为对照模型。BiLSTM 和 GRU 均为 LSTM 的改进模型, 前者采用复杂化策略, 其双向传播原则能有效挖掘信息的前后关联性, 但增加了模型复杂度; 后者采用简化策略, 将 LSTM 输入门和遗忘门合并为更新门, 但模型记忆能力受限<sup>[42]</sup>。TCN 作为 CNN 变体, 使用因果卷积与扩张卷积扩大网络感受野<sup>[43]</sup>, Transformer 采用自注意力机制并行处理所有位置的信息<sup>[44]</sup>, 两者在近年已被广泛应用于序列到序列任务。因此选取上述四种模型作为对照组, 进一步研究各模型对于不同长度时序预测任务的适应性。选取 1y 和 3y 序列作为输入, 窗口大小取 10, 正则化参数 dropout 取 0.2, 其余模型参数均采用默认值。1y 时序预测结果如图 6 和图 7 所示, 3y 时序预测结果如图 8 和图 9 所示。

#### 2.2.1 LSTM 优越性分析

由图 6 和图 8 可知, LSTM 预测性能最优, 其  $RMSE$  指标与 BiLSTM、GRU、TCN 和 Transformer 相比, 在 1y 时序中降低了 0.045 98、0.061 27、0.224 74、0.393 99, 在 3y 时序中降低了 0.012 33、0.017 12、0.090 92、0.516 44。由结果可得, LSTM 明显优于 GRU、TCN 和 Transformer, 但与 BiLSTM 综合表现相当, 两者在不同时序中预测指标并无绝对大小差异, 文献[45]对比两模型在 12 组数据集中的预测表现, 综合分析 6 种评估指标, 发现两者表现近似且 LSTM 略优, 这是由于 BiLSTM 虽然具备双向 LSTM 层, 但由于结构复杂度提升, 模型参数量增加, 导致训练过程更容易过拟合, 影响整体性能。

#### 2.2.2 KAN 优越性分析

由图 6 和图 8 可知, KAN 对 LSTM 预测性能的改进效果最为显著。以 1y 时序为例, 引入 KAN 后各模型评估指标  $MAPE$  和  $RMSE$  有不同程度优化, LSTM




图 5 PL6-1 测点水平位移监测序列

Fig. 5 Horizontal displacement monitoring sequence of PL6-1 measuring point




图 6 1y 时序不同模型统计指标比较

Fig. 6 Comparison of statistical indicators of different models in 1y time series

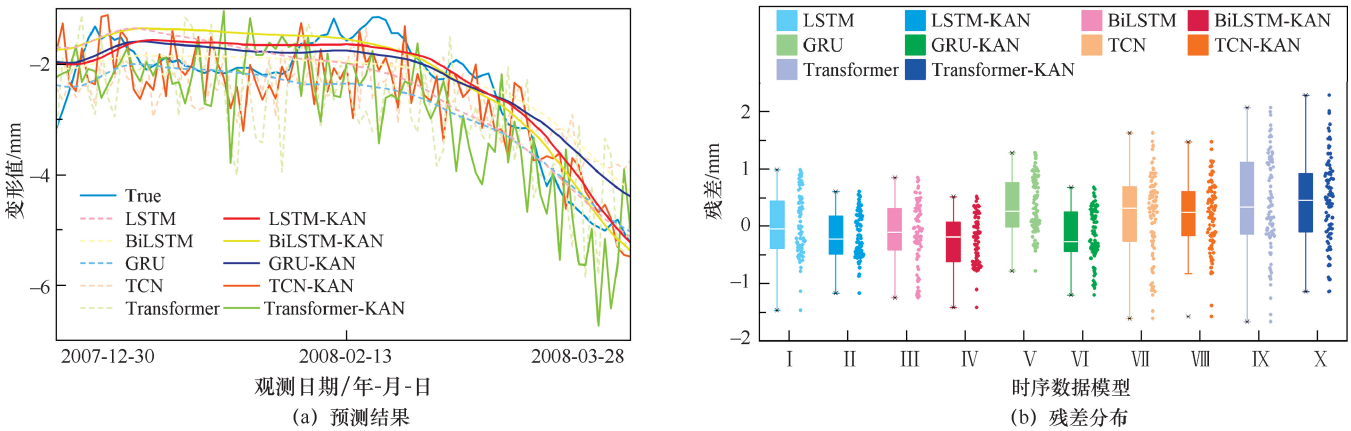


图 7 1y 时序不同模型预测效果比较

Fig. 7 Comparison of prediction effects of different models in 1y time series




图 8 3y 时序不同模型统计指标比较

Fig. 8 Comparison of statistical indicators of different models in 3y time series

优化了 30.56% 和 22.10%，BiLSTM 优化了 10.91% 和 18.63%，GRU 优化了 30.45% 和 13.25%，TCN 优化了 18.10% 和 19.01%，Transformer 优化了 7.15% 和 5.65%。这是由于 KAN 将模型中 sigmoid 激活函数替换为样条函数，可使用更少的函数表征数据模式，因此有效减少了模型参数数量，降低过拟合风险，并显著增强模型处理复杂非线性关系的能力。文献[46]采用自回归集成移动平均法 (ARIMA) 优化 LSTM 与 BiLSTM，发现在不同预测步长下 ARIMA-LSTM 表现

更优，且在 1~3 短步长下差异更为显著，该试验同样说明 LSTM 在结构优化上具有更大的改进空间。对比发现，LSTM-KAN 相对其他 KAN 改进模型，其 RMSE 指标在 1y 时序中降低了 0.05585、0.10019、0.19846、0.45914，在 3y 时序中降低了 0.03723、0.05980、0.04500、0.28121，由图 7 和图 9 可知，LSTM-KAN 在不同时序下残差均最小且更集中于 0 附近，结果表明其预测性能最优，对长短时序预测的适应性最强。

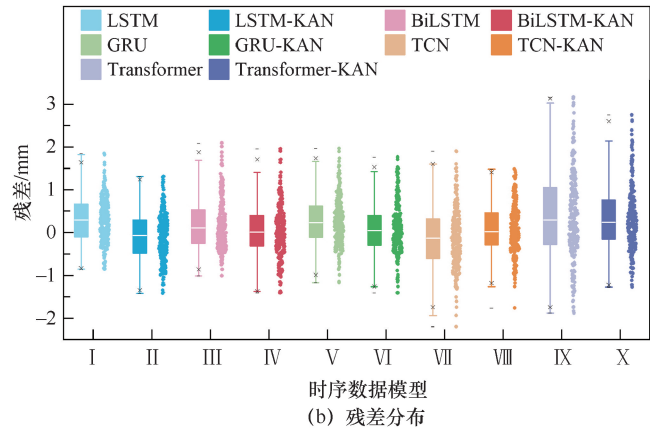
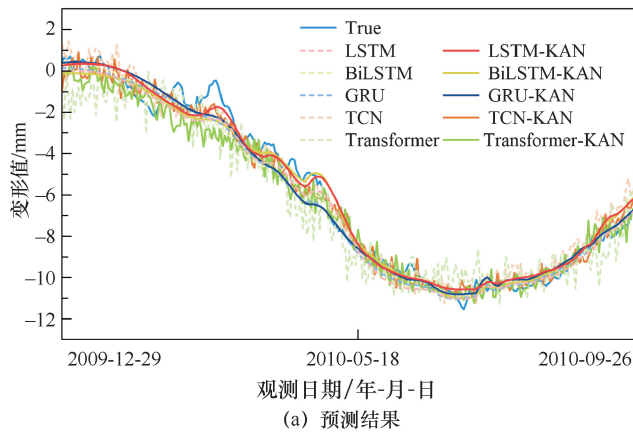


图9 3y 时序不同模型预测效果比较

Fig. 9 Comparison of prediction effects of different models in 3y time series

综上所述, 五种基础模型中 LSTM 预测性能最优; KAN 机制对各模型均有一定增益效果, 对 LSTM 改进效果最好; LSTM-KAN 预测性能在不同长度时序中均表现最好。然而根据试验结果, LSTM-KAN 训练集预测指标均明显优于测试集指标, 说明预测曲线出现过拟合现象, 这是由于模型的超参数选择未能达到最优<sup>[47]</sup>, 存在较大的探索空间, 因此本文采用智能优化算法进行超参数组合寻优, 提高模型在测试集上的泛化能力。

### 2.3 优化算法对比

IHHO 是基于生物的元启发式优化算法, 为验证其高效性, 与其他同类算法进行对比, 包括基于物理的多元宇宙优化算法 MVO<sup>[48]</sup>; 基于群体的粒子群优化算法 PSO<sup>[49]</sup>; 基于生物的蜣螂优化算法 DBO<sup>[50]</sup>、鲸鱼优化算法 WOA<sup>[51]</sup>和麻雀优化算法 SSA<sup>[52]</sup>。数据集选取 3y 序列, 对 LSTM-KAN 模型的超参数组合寻优。LSTM 模型的关键超参数包括学习率、批大小、隐藏层单元数和循环训练次数等<sup>[47]</sup>, 其中学习率控制模型每次迭代中更新权重的速度, 直接影响收敛速度。寻优算法参数  $pop$  均设为 20, 最大迭代次数  $max\_iter$  均设为 100, 以适应度值为优化指标, 算法动态搜索过程如图 10 所示。为快速准确获取最优超参数组合, 根据经验设置搜索空间, 超参数寻优范围及结果如表 1 所列。

由图 10 可得, IHHO 算法动态搜索过程明显优于其他方法, 适应度值在第 20 次迭代下降到 0.005 14 并趋于稳定, 在第 53 次后又又有小幅度下降, 最终稳定在 0.005 02。SSA、PSO 和 WOA 算法适应度值在前期迭代阶段迅速下降, DBO 和 MVO 则缓慢下降并在迭代中期达到稳定, 相对 IHHO 寻优精度偏低, 且易陷入局部最优<sup>[53]</sup>, 无法探查整个搜索空间。

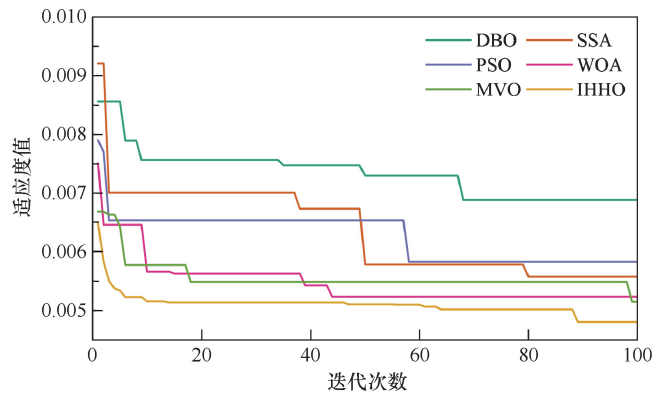


图10 适应度变化曲线

Fig. 10 Variation curve of fitness

表 1 3y 时序 LSTM-KAN 模型超参数寻优结果  
Table 1 LSTM-KAN model hyperparameter optimization results in 3y time series

超参数	优化范围	IHHO 寻优值
<i>learning rate</i>	[0, 0.05]	0.000 981 68
<i>batch_size</i>	[10, 200]	118
<i>hidden_dim</i>	[24, 384]	256
<i>num_epochs</i>	[10, 100]	42

由上述分析可知, IHHO 算法结合多种优化策略, 在早期迭代中可快速寻找潜在的最优解区域, 具有较强的全局搜索能力和快速收敛特性。

### 2.4 时序应用分析

为验证本文提出的预测模型的性能优越性和长短时序适应性, 并分析 KAN 对于长短时序的作用机理, 分别使用 1y、2y、3y、4y、5y、6y 时序作为输入, 采用 IHHO 优化算法进行网络超参数寻优, 对比长短时序下模型改进前后的预测效果, 预测结果如图 11 和图 12 所示。

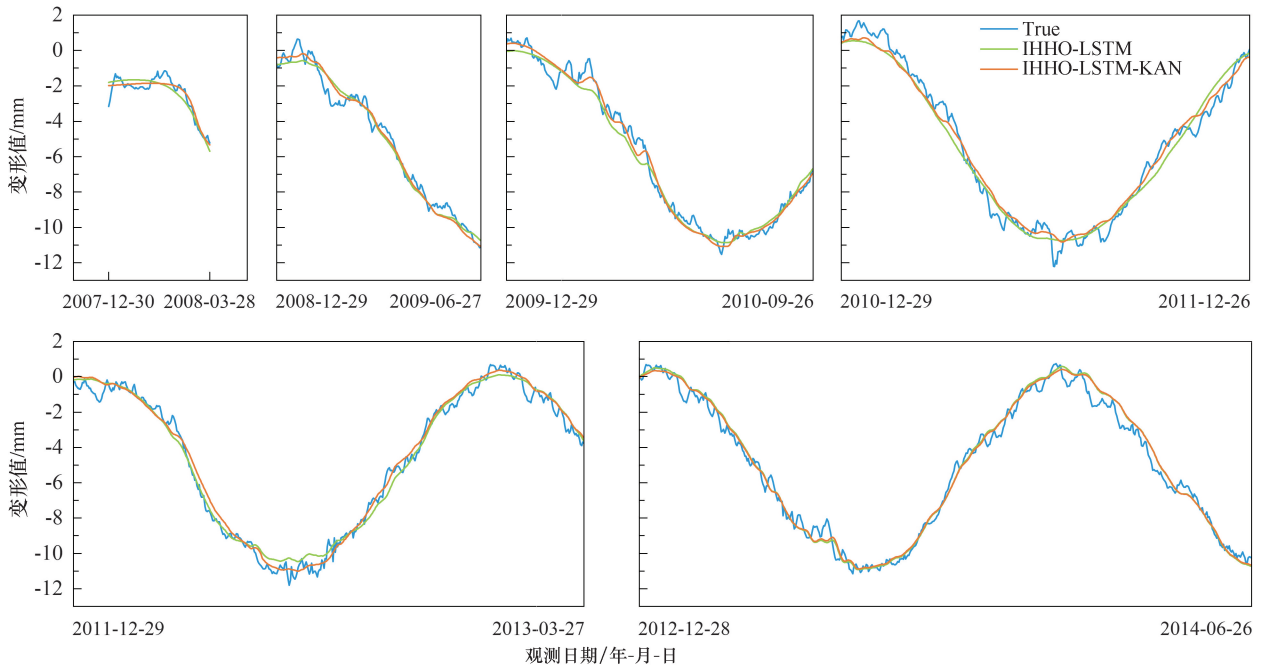


图 11 不同时序数据集模型预测结果

Fig. 11 Model prediction results of different time series




图 12 不同时序数据集模型统计指标

Fig. 12 Model statistical indicators of different time series

### 2.4.1 模型稳健性分析

对比图 12 与图 6、图 8 预测指标, 可知 IHHO 优化算法对不同时序预测均有较好改进效果。LSTM-KAN 在 1y 时序中 MAPE 和 RMSE 指标降低了 0.015 32 和 0.063 92, 在 3y 时序中降低了 0.053 96 和 0.105 73, LSTM 预测指标同样有显著优化, 测试集各项指标均更接近训练集。这表明 IHHO 能有效搜索网络最优超参数<sup>[54]</sup>, 缓解模型训练的过拟合问题, 提高预测性能。

由图 11 和图 12 可知, 本文模型在长短时序预测中均表现出较好性能。在 6 组时序中, LSTM-KAN 的 MAPE 除 2y 时序均低于 0.40, R<sup>2</sup> 除 1y 时序均高于

0.98, 且各项指标相对 LSTM 均有明显优化。研究表明, 时序数据量较少时, 模型难以学习周期信息, 导致拟合程度较低<sup>[55]</sup>, 本文 1y 时序符合该数据特点, 而引入 KAN 后 R<sup>2</sup> 提升 0.059 42, 表明 KAN 补充了 LSTM 在短期训练中缺乏的历史信息, 从而使模型更好地捕捉短时序特征, 提高泛化能力。2y 时序中, KAN 使 MAPE 降低了 0.650 27, 该时序出现多处短期大幅度波动, 超出模型训练学习到的正常范围, 导致误差显著增加<sup>[56]</sup>, 而 KAN 降低了 LSTM 对数据极端值和小数值的敏感性, 显著增强对局部波动的预测能力。5y 和 6y 时序中, 各项指标均有所提升且整体性能优良, 表明 KAN 能进一步提高模型对时序长期依

赖关系的辨识能力, 从而提升长时序预测的准确性。结合前文分析成果, 可得本文模型在长短视频预测中相较基础模型及其他模型均有较好稳健性。

#### 2.4.2 KAN 适应性分析

根据图 11 和图 12 的预测结果, 可知 KAN 对不同时序的优化效果表现出一定趋势, 具体表现如图 13 和图 14 所示。由图 13 可知, 模型引入 KAN 后, 相较于长时序, 短视频预测的残差分布范围显著缩小, 中位数更趋于 0, 超出 1.5 倍四分位距的异常预测值<sup>[57]</sup>显著减少。由图 14 可知, 引入 KAN 后, 模型对于 1y 至 6y 时序预测,  $RMSE$  分别优化了 20.64%、10.41%、22.98%、16.03%、8.59%、2.57%,  $R^2$  分别优化了 7.08%、0.45%、0.85%、0.80%、0.25%、0.08%。表明 KAN 对长短视频预测均有良好改进效果, 且对短视频优化能力更强。这是由于短视频信息量有限且预测集存在多处离群点和突变区域, 因此 KAN 在应对全局极端值和局部扰动方面的能力得以充分应用; 长时序则包含多周期信息,

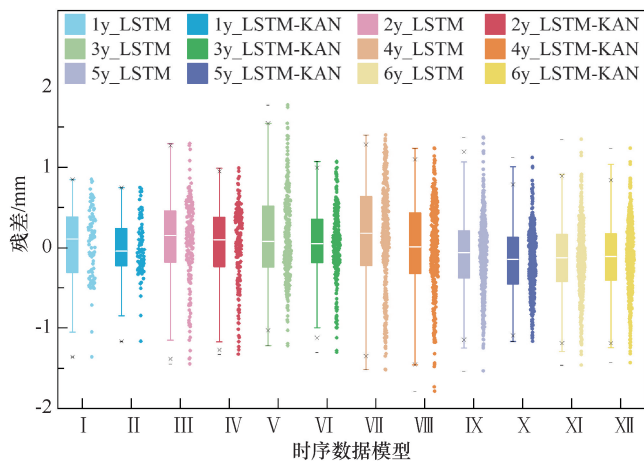


图 13 不同时序数据集模型残差分布

Fig. 13 Model residual distribution in different time series




图 14 不同时序数据集 KAN 机制优化效果

Fig. 14 KAN optimization results in different time series

LSTM 已能捕捉时序中的不同模式, 包括短期波动、季节性变化和长期趋势<sup>[58]</sup>, 因此 KAN 在数据量充足且预测集较为稳定的情况下有一定优化效果但提升程度不显著。

### 3 结论

本文构建了基于 IHHO-LSTM-KAN 的大坝变形预测模型, 使用某混凝土肋墩坝实测水平位移监测数据进行检验, 按时间长度切分为多组长短视频数据, 结合多重指标评估模型性能, 得出以下主要结论。

(1) 对于大坝变形时序预测, LSTM 模型能更好捕捉长短视频复杂数据关系, 相对 TCN、Transformer、BiLSTM 和 GRU 模型具有更高的预测精度。KAN 利用可学习的激活函数增强模型表征能力, 对各模型均有明显优化效果, 在较短时序中对 LSTM 优化程度最高, LSTM-KAN 在长短视频中均表现出最优综合性能。

(2) 采用智能优化算法对预测模型超参数寻优, IHHO 通过多种寻优策略跳出局部最优, 避免了手动调参的经验主观性和难以寻找最优解的问题, 相对 MVO、DBO、PSO、WOA 和 SSA 在迭代速度和优化精度上表现最优, 有效提高模型预测准确性。

(3) 模型在不同时序下均有较好预测效果, 在时序较短、周期信息有限且存在显著局部扰动和极端离群值的情况下, KAN 机制的优化效果尤为突出。在实际应用中, 可对大坝监测初期及位移显著变化期间的变形预测提供重要支持。本文提出的模型对短序列数据预测虽有较大提升, 但最终预测精度仍有所不足, 未来可继续研究模型对全点位全生命周期监测数据的适应性, 设计更为完善的大坝变形预测方案。

#### 参考文献 (References):

- [1] 中华人民共和国水利部. 2023 年全国水利发展统计公报[R]. 北京: 中国水利水电出版社, 2024.  
Ministry of Water Resources of the People's Republic of China. 2023 Statistic Bulletin on China Water Activities [R]. Beijing: China Water & Power Press, 2024.
- [2] 姚可夫, 田始光, 漆一宁, 等. 高海拔区特征环境驱动下混凝土坝服役性能研究进展[J]. 水利学报, 2023, 54(6): 717-728.  
YAO K F, TIAN S G, QI Y N, et al. Performance of concrete dams impacted by characteristic climate in high-altitude area: A review[J]. Journal of Hydraulic Engineering, 2023, 54(6): 717-728.
- [3] 徐小蓉, 金峰, 廖仕信, 等. 堆石混凝土坝信息化施工管理研究[J]. 水利水电技术(中英文), 2023, 54(7): 150-160.

- XU X R, JIN F, LIAO S X, et al. Research of informatization in construction management of rock-filled concrete dam [J]. *Water Resources and Hydropower Engineering*, 2023, 54(7): 150-160.
- [4] 蔡跃波, 向衍, 盛金保, 等. 重大水利工程大坝深水检测及突发事件监测预警与应急处置研究及应用[J]. *岩土工程学报*, 2023, 45(3): 441-458.
- CAI Y B, XIANG Y, SHENG J B, et al. Deep-water detection, monitoring, early warning and treatment of emergencies of major water conservancy projects: A review[J]. *Chinese Journal of Geotechnical Engineering*, 2023, 45(3): 441-458.
- [5] 水利部办公厅. 《全国病险水库除险加固实施方案(2025—2027年)》[Z]. 北京: 水利部办公厅, 2024.
- General Office of Ministry of Water Resources. Implementation Plan for the Reinforcement of Dangerous Reservoirs in China (2025—2027)[Z]. Beijing: General Office of Ministry of Water Resources, 2024.
- [6] 周仁练, 苏怀智, 韩彰, 等. 混凝土坝变形的长期预测模型与应用[J]. *水力发电学报*, 2021, 40(9): 122-131.
- ZHOU Renlian, SU Huaizhi, HAN Zhang, et al. Long-term deformation prediction model of concrete dams and its application[J]. *Journal of Hydroelectric Engineering*, 2021, 40(9): 122-131.
- [7] 冯子强, 李登华, 丁勇. 基于 Blending-Clustering 集成学习的大坝变形预测模型[J]. *水利水电技术(中英文)*, 2024, 55(4): 59-70.
- FENG Z Q, LI D H, DING Y. Dam deformation prediction model based on Blending-Clustering ensemble learning[J]. *Water Resources and Hydropower Engineering*, 2024, 55(4): 59-70.
- [8] 李国英. 为以中国式现代化全面推进强国建设、民族复兴伟业提供有力的水安全保障[J]. *水利发展研究*, 2024, 24(3): 1-3.
- LI Guoying. Improved water security for China's efforts to build itself into a stronger country and rejuvenate the Chinese nation on all fronts by pursuing Chinese modernization[J]. *Water Resources Development Research*, 2024, 24(3): 1-3.
- [9] 卢骏, 戴吾蛟, 章浙涛. 大坝变形变系数回归建模[J]. *武汉大学学报(信息科学版)*, 2015, 40(1): 139-142.
- LU J, DAI W J, ZHANG Z T. Modeling dam deformation using varying coefficient regression[J]. *Geomatics and Information Science of Wuhan University*, 2015, 40(1): 139-142.
- [10] 许昌, 岳东杰, 董育烦, 等. 基于主成分和半参数的大坝变形监测回归模型[J]. *岩土力学*, 2011, 32(12): 3738-3742.
- XU C, YUE D J, DONG Y F, et al. Regression model for dam deformation based on principal component and semi-parametric analysis[J]. *Rock and Soil Mechanics*, 2011, 32(12): 3738-3742.
- [11] ZHANG Y, ZHANG W W, LI Y L, et al. AF-OS-ELM-MVE: A new online sequential extreme learning machine of dam safety monitoring model for structure deformation estimation[J]. *Advanced Engineering Informatics*, 2024, 60: 102345.
- [12] VAPNIK V, VASHIST A. A new learning paradigm: Learning using privileged information[J]. *Neural Networks*, 2009, 22(5/6): 544-557.
- [13] 李明军, 王均星, 王亚洲. 基于改进粒子群优化算法和极限学习机的混凝土坝变形预测[J]. *天津大学学报(自然科学与工程技术版)*, 2019, 52(11): 1136-1144.
- LI M J, WANG J X, WANG Y Z. Deformation prediction of concrete dam based on improved particle swarm optimization algorithm and extreme learning machine [J]. *Journal of Tianjin University (Science and Technology)*, 2019, 52(11): 1136-1144.
- [14] CAI B R, YANG S Q, GAO L X, et al. Hybrid variational autoencoder for time series forecasting[J]. *Knowledge-Based Systems*, 2023, 281: 111079.
- [15] WANG S, WANG J Z, LU H Y, et al. A novel combined model for wind speed prediction-Combination of linear model, shallow neural networks, and deep learning approaches[J]. *Energy*, 2021, 234: 121275.
- [16] BUI K T, TORRES J F, GUTIÉRREZ-AVILÉS D, et al. Deformation forecasting of a hydropower dam by hybridizing a long short-term memory deep learning network with the coronavirus optimization algorithm[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2022, 37(11): 1368-1386.
- [17] 雷未, 王建, 吉同元, 等. 基于深度学习框架的长序列大坝监测缺失数据插补模型[J]. *水利水电科技进展*, 2023, 43(6): 82-88.
- LEI Wei, WANG Jian, JI Tongyuan, et al. Long-series missing data interpolation model for dam monitoring based on deep learning framework [J]. *Advances in Science and Technology of Water Resources*, 2023, 43(6): 82-88.
- [18] 陈以浩, 李明伟, 安小刚, 等. 基于混沌云量子蝙蝠 CNN-GRU 大坝变形智能预报方法研究[J]. *哈尔滨工程大学学报*, 2024, 45(1): 110-118.
- CHEN Y H, LI M W, AN X G, et al. Research on the intelligent prediction method of dam deformation based on chaotic cloud quantum bat CNN-GRU[J]. *Journal of Harbin Engineering University*, 2024, 45(1): 110-118.
- [19] ZHANG C, JIANG D F, GAO Y Y, et al. Interpretable hierarchical error correction GRU model for effective observation selection[J]. *Applied Soft Computing*, 2023, 149: 110982.
- [20] ZHOU Y H, BAO T F, LI G L, et al. Multi-expert attention network for long-term dam displacement prediction [J]. *Advanced Engineering Informatics*, 2023, 57: 102060.
- [21] HUANG B, KANG F, LI J J, et al. Displacement prediction model for high arch dams using long short-term memory based encoder-decoder with dual-stage attention considering measured dam temperature[J]. *Engineering Structures*, 2023, 280: 115686.
- [22] 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.
- WANG X L, LI K, ZHANG Z L, et al. Coupled ALO-LSTM and feature attention mechanism prediction model for seepage pressure of earth-rock dam [J]. *Journal of Hydraulic Engineering*, 2022, 53

- (4): 403-412.
- [23] LIU B, CEN W J, ZHENG C H, et al. A combined optimization prediction model for earth-rock dam seepage pressure using multi-machine learning fusion with decomposition data-driven[J]. *Expert Systems with Applications*, 2024, 242: 122798.
- [24] LIU M K, WEN Z P, SU H Z. Deformation prediction based on denoising techniques and ensemble learning algorithms for concrete dams[J]. *Expert Systems with Applications*, 2024, 238: 122022.
- [25] LI M H, REN Q B, LI M C, et al. A separate modeling approach to noisy displacement prediction of concrete dams via improved deep learning with frequency division [J]. *Advanced Engineering Informatics*, 2024, 60: 102367.
- [26] 李明超, 任秋兵, 沈扬. 贝叶斯框架下的大坝变形交互式时变预测模型及其验证[J]. *水利学报*, 2018, 49(11): 1328-1338.
- LI M C, REN Q B, SHEN Y. Prediction model for interactive time series evolution and its verification of dam deformation under Bayesian framework[J]. *Journal of Hydraulic Engineering*, 2018, 49(11): 1328-1338.
- [27] SHUKLA K, TOSCANO J D, WANG Z C, et al. A comprehensive and FAIR comparison between MLP and KAN representations for differential equations and operator networks[J]. *Computer Methods in Applied Mechanics and Engineering*, 2024, 431: 117290.
- [28] JIANG J X, FU T Y, LIU J Q, et al. Incremental energy-based recurrent transformer-KAN for time series deformation simulation of soft tissue [J]. *Expert Systems with Applications*, 2025, 271: 126619.
- [29] 王浩然, 钮新强, 徐利福, 等. 基于奇异谱分析和改进 WOA-BP 的大坝变形预测模型[J]. *水力发电学报*, 2023, 42(11): 136-145.
- WANG Haoran, NIU Xinqiang, XU Lifu, et al. Dam deformation prediction model based on singular spectrum analysis and improved whale optimization algorithm-optimized BP neural network [J]. *Journal of Hydroelectric Engineering*, 2023, 42(11): 136-145.
- [30] RAJWAR K, DEEP K, DAS S. An exhaustive review of the metaheuristic algorithms for search and optimization: Taxonomy, applications, and open challenges [J]. *Artificial Intelligence Review*, 2023, 56(11): 13187-13257.
- [31] HEIDARI A A, MIRJALILI S, FARIS H, et al. Harris Hawks optimization: Algorithm and applications [J]. *Future Generation Computer Systems*, 2019, 97: 849-872.
- [32] 吴中如, 陈波. 大坝变形监控模型发展回眸[J]. *现代测绘*, 2016, 39(5): 1-3.
- WU Z R, CHEN B. A review on development of dam safety monitoring models[J]. *Modern Surveying and Mapping*, 2016, 39(5): 1-3.
- [33] JUAN M T, TAVARES DE CASTRO A, SÁ DA COSTA J. Constructing statistical models for arch dam deformation [J]. *Structural Control and Health Monitoring*, 2014, 21(3): 423-437.
- [34] GREFF K, SRIVASTAVA R K, KOUTNIK J, et al. LSTM: A search space odyssey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(10): 2222-2232.
- [35] 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.
- [36] HUANG S Y, LIU Y P, CUI H Y, et al. MEAformer: An all-MLP transformer with temporal external attention for long-term time series forecasting[J]. *Information Sciences*, 2024, 669: 120605.
- [37] BRAUN J, GRIEBEL M. On a constructive proof of Kolmogorov's superposition theorem[J]. *Constructive Approximation*, 2009, 30(3): 653-675.
- [38] 展广涵, 王雨虹, 刘昊. 混合策略改进的哈里斯鹰优化算法及其应用[J]. *传感技术学报*, 2022, 35(10): 1394-1403.
- ZHAN G H, WANG Y H, LIU H. Improved Harris Hawks optimization algorithm with hybrid strategy and its application [J]. *Chinese Journal of Sensors and Actuators*, 2022, 35(10): 1394-1403.
- [39] 任秋兵, 沈扬, 李明超, 等. 水工建筑物安全监控深度分析模型及其优化研究[J]. *水利学报*, 2021, 52(1): 71-80.
- REN Qiubing, SHEN Yang, LI Mingchao, et al. Safety monitoring model of hydraulic structures and its optimization based on deep learning analysis [J]. *Journal of Hydraulic Engineering*, 2021, 52(1): 71-80.
- [40] 张冲, 王仁坤, 汤雪娟. 溪洛渡特高拱坝蓄水初期工作状态评价[J]. *水利学报*, 2016, 47(1): 85-93.
- ZHANG C, WANG R K, TANG X J. Safety evaluation of Xiluodu ultra-high arch dam during the initial impoundment period [J]. *Journal of Hydraulic Engineering*, 2016, 47(1): 85-93.
- [41] 练继建, 杨阳, 胡少伟, 等. 特大水利水电枢纽调控与安全运行研究进展与前沿[J]. *工程科学与技术*, 2017, 49(1): 27-32.
- LIAN J J, YANG Y, HU S W, et al. Research progresses and frontiers on control and safety operation of super-large hydraulic complex[J]. *Advanced Engineering Sciences*, 2017, 49(1): 27-32.
- [42] LI M H, REN Q B, LI M C, et al. Efficient prediction uncertainty quantification in dam behavior monitoring with attention-based sequence-to-sequence learning[J]. *Applied Soft Computing*, 2024, 167: 112321.
- [43] WU Y R, KANG F, ZHU S S, et al. Data-driven deformation prediction model for super high arch dams based on a hybrid deep learning approach and feature selection[J]. *Engineering Structures*, 2025, 325: 119483.
- [44] TIAN K, YANG J, CHENG L. Deep learning model for the deformation prediction of concrete dams under multistep and multifeature inputs based on an improved autoformer[J]. *Engineering Applications of Artificial Intelligence*, 2024, 137: 109109.

- [45] ZHOU L Y, ZHAO C, LIU N, et al. Improved LSTM-based deep learning model for COVID-19 prediction using optimized approach [J]. *Engineering Applications of Artificial Intelligence*, 2023, 122: 106157.
- [46] SHAO P, WANG H, LONG G Y, et al. A novel multi-step ahead prediction method for landslide displacement based on autoregressive integrated moving average and intelligent algorithm[J]. *Engineering Applications of Artificial Intelligence*, 2024, 137: 109107.
- [47] 吴佳, 陈森朋, 陈修云, 等. 基于强化学习的模型选择和超参数优化[J]. *电子科技大学学报*, 2020, 49(2): 255-261.  
WU J, CHEN S P, CHEN X Y, et al. Reinforcement learning for model selection and hyperparameter optimization [J]. *Journal of University of Electronic Science and Technology of China*, 2020, 49(2): 255-261.
- [48] MIRJALILI S, MIRJALILI S M, HATAMLOU A. Multi-Verse Optimizer: A nature-inspired algorithm for global optimization[J]. *Neural Computing and Applications*, 2016, 27(2): 495-513.
- [49] GAD A G. Particle swarm optimization algorithm and its applications; A systematic review [J]. *Archives of Computational Methods in Engineering*, 2022, 29(5): 2531-2561.
- [50] LI Y H, SUN K X, YAO Q, et al. A dual-optimization wind speed forecasting model based on deep learning and improved dung beetle optimization algorithm[J]. *Energy*, 2024, 286: 129604.
- [51] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. *Advances in Engineering Software*, 2016, 95: 51-67.
- [52] XUE J K, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.
- [53] LIU L, CAO X J, WANG H S, et al. Optimization of model parameters and hyperparameters in deep learning models for spatial interaction prediction[J]. *Expert Systems with Applications*, 2025, 266: 126160.
- [54] ZHAO C, WANG F, JIANG X X, et al. Thermal parameter identification of concrete dams based on hybrid particle swarm optimization using distributed optical fiber monitoring data [J]. *Swarm and Evolutionary Computation*, 2024, 87: 101582.
- [55] JIANG H Y, CHENG F, WU C, et al. A multi-period-sequential-index combination method for short-term prediction of small sample data [J]. *Reliability Engineering & System Safety*, 2024, 242: 109767.
- [56] 陈羨濠, 胡昱, 王亚军, 等. 大坝变形极端梯度提升区间预测模型应用研究[J]. *水力发电学报*, 2024, 43(10): 121-136.  
CHEN Xianhao, HU Yu, WANG Yajun, et al. Dam deformation interval prediction model based on XGBoost [J]. *Journal of Hydroelectric Engineering*, 2024, 43(10): 121-136.
- [57] 贾俊平. 统计学: 基于 R 第 4 版[M]. 北京: 中国人民大学出版社, 2021.  
JIA J P. *Statistics with R 4th ed.* [M]. Beijing: China Renmin University Press, 2021.
- [58] STEFENON S F, SEMAN L O, AQUINO L S, et al. Wavelet-Seq2Seq-LSTM with attention for time series forecasting of level of dams in hydroelectric power plants [J]. *Energy*, 2023, 274: 127350.

(责任编辑 王 璐)