doi:10.16112/j.cnki.53-1223/n.202502120001
引用格式:王光华,王子轩,傅蜀燕,等. 基于 ICEEMDAN-IGWO-DHKELM 的大坝变形多测点预测方法[J]. 昆明理工大学学报(自然科学版),2026,51(5):57-73.
Citation: Wang Guanghua, Wang Zixuan, Fu Shuyan, et al. Multi-point prediction method for dam deformation based on ICEEMDAN-IGWO-DHKELM[J]. Journal of Kunming University of Science and Technology(Natural Science),2026,51(5):57-73.

基于 ICEEMDAN-IGWO-DHKELM 的大坝变形多测点预测方法

王光华[1],王子轩[2,3],傅蜀燕[2,3],张燕明[2,3],欧　斌[2,3*]
(1. 云南省发展和改革委员会,云南 昆明 650053;2. 云南农业大学 水利学院,云南 昆明 650201;
3. 云南省中小型水利工程智慧管养工程研究中心,云南 昆明 650201)

摘要:针对传统单测点方法无法有效表征大坝整体变形趋势的问题,提出了一种融合分形理论的大坝变形多测点预测方法. 首先,基于分形理论揭示大坝变形与环境因素之间的相关性,了解不同测点的变形与环境因素之间的相互作用;然后,利用改进的完全自适应噪声集合经验模态分解(Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise,ICEEMDAN)方法为每个测点提供独立且有效的分解结果;最后,利用改进灰狼优化算法(Improved Grey Wolf Optimizer,IGWO)对深度混合核极限学习机(Deep Hybrid Kernel Extreme Learning Machine,DHKELM)参数进行寻优,进而构建基于 IGWO-DHKELM 的多测点预测模型. 案例分析结果表明,大坝变形时间序列内部演变的波动行为不是随机的,而是呈长程相关性. 同时融合 ICEEMDAN 的 IGWO-DHKELM 多测点模型能够提供大坝整体变形的全面视角,能考虑各测点的空间关系和变形差异,从而更好地捕捉大坝的整体变形趋势,共均方根误差(*RMSE*)等指标显著低于其他对比模型,且决定系数(R^2)接近于 1,表明该模型能有效挖掘大坝监测数据中的内在关系,具有良好的预测精度和泛化能力.

关键词:大坝变形;分形理论;改进的自适应噪声集合经验模态分解;改进灰狼优化算法;深度混合核极限学习机
中图分类号:TV698.11　　**文献标识码**:A　　**文章编号**:1007-855X(2026)05-0057-17

Multi-point prediction method for dam deformation based on ICEEMDAN-IGWO-DHKELM

Wang Guanghua[1], Wang Zixuan[2,3], Fu Shuyan[2,3], Zhang Yanming[2,3], Ou Bin[2,3*]
(1. Yunnan Provincial Development and Reform Commission, Kunming 650053, China; 2. College of Water Conservancy, Yunnan Agricultural University, Kunming 650201, China; 3. Research Center for Smart Management and Maintenance of Small and Medium-sized Water Conservancy Projects in Yunnan Province, Kunming 650201, China)

Abstract: To address the problem that traditional single-point methods cannot effectively characterize the overall deformation trend of dams, a multi-point prediction method for dam deformation integrating fractal theory is proposed. First, based on fractal theory, the correlation between dam deformation and environmental factors is re-

收稿日期:2025-02-12. **基金项目**:国家自然科学基金项目(52369026);云南省自然科学基金项目(202401BD070001-071).
作者简介:王光华(1986-),男,硕士. 主要研究方向:工程项目高效管理. **E-mail**:196843633@qq.com
通信作者:欧斌(1983-),男,博士,副教授. 主要研究方向:水工结构安全监控与病害诊断. **E-mail**:oubin@ynau.edu.cn

vealed, and the interaction between deformation and the environment at different measuring points is clarified. Then, the Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (ICEEMDAN) is used to provide independent and effective decomposition results for each measuring point. Finally, the Improved Grey Wolf Optimization (IGWO) algorithm is employed to optimize the parameters of the Deep Hybrid Kernel Extreme Learning Machine (DHKELM), and then a multi-point prediction model based on IGWO-DHKELM is constructed. The case analysis results show that the fluctuation behavior of the internal evolution of dam deformation time series is not random but exhibits long-range correlation. Meanwhile, the IGWO-DHKELM multi-point model integrating ICEEMDAN can provide a comprehensive perspective of the overall dam deformation, consider the spatial relationship and deformation differences among various measuring points, and thus better capture the overall deformation trend of the dam. Compared with other comparative models, it has significantly lower indicators such as Root Mean Square Error ($RMSE$), and the coefficient of determination (R^2) is close to 1, indicating that the model can effectively mine the intrinsic relationships in dam monitoring data and has good prediction accuracy and generalization ability.

Keywords: dam deformation; fractal theory; ICEEMDAN; IGWO; DHKELM

0 引 言

混凝土坝的变形是大坝结构性态变化的直观表现,是评估大坝结构健康监测(SHM)中的重要指标[1-2]. 变形主要包括由水位和温度变化引起的可逆变形,以及由坝体材料性质随时间变化导致的不可逆变形[3-5]. 此外,监测数据往往受到噪声干扰,表现出不规则和强非线性,传统模型难以揭示变形与各类因素之间的复杂关系. 因此,需构建处理非线性和非平稳特性的数值模型,减小噪声干扰并挖掘监测序列中的规律[6],以更精确地预测大坝位移变化,确保大坝安全并指导决策.

随着大数据技术的发展,大坝变形预测方法主要分为三类:统计模型、基于机器学习的混合模型和时间序列模型. 统计模型通过建立环境因素与变形的数学关系,常见的有静水季节时间(HST)模型[7]及其改进版本(HTT、HSTT 和 HETT 模型)[8-10]. 然而,传统模型预测方式单一,单一智能算法的训练和预测能力不够稳定,限制了预测精度和可靠性. 因此,许多学者转向智能算法与分解工具的结合创新,以提升预测性能. Gu 等[11]研究了统计模型和随机森林回归(RFR)在混凝土坝变形预测中的应用. Zhang 等[12]提出了 DenseNet-LSTM 深度学习模型,结合了 DenseNet 和 LSTM,并通过相关性分析和随机森林(RF)筛选与变形相关的特征. Zhou 等[13]提出了一种结合多尺度自适应核集成的方法来进行大坝变形预测的模型. Cai 等[14]利用自适应噪声的经验模态分解(CEEMDAN)优化长短期记忆(LSTM)神经网络,通过自注意机制捕捉时间特征,有效处理滞后效应和各测点差异问题.

上述研究主要针对大坝变形中的高度非线性和非稳定性进行分析,但大坝变形预测中,测点之间、变形趋势与环境因子之间,以及变形分解后的模态分量间存在一定的多重相关关系. 因此,Hu 等[15]采用 RF、最小二乘支持向量机(LS-SVM)、简单提升回归树(SBRT)、核极限学习机(KELM)和改进的统计模型进行大坝变形预测. Pan 等[16]提出了一种基于卷积神经网络(CNN)的时空变形场行为模型,融合了气候数据、水压和约束条件用于大坝温度场预测. Guo 等[17]采用弹性波计算机断层扫描(EWCT)分析了坝体混凝土的分形特性. 通过将定义的 EWCT 分形维数与坝混凝土的强度和成熟度相结合,建立了坝混凝土质量评价模型. Yang 等[18]通过利用多分形去趋势波动分析(MF-DFA)模型对隧道变形数据进行多分形表征,利用 M-K(Mann-Kendall)分析构建隧道变形预警研究的双准则($\Delta\alpha$ 指标准则和 $\Delta f(\alpha)$ 指标准则),最后,采用粒子群优化长短期记忆(PSO-LSTM)预测模型预测隧道沉降. Ou 等[19]将变分模态分解(VMD)、分形理论和鲸鱼优化算法(WOA)与深度极限学习机(DELM)模型结合,对去噪数据进行定性分析,捕捉变形趋势中的复杂模式. 上述方法仅是对大坝变形趋势进行定性分析,并未分析环境量对变形的影响,同时上述方法均为单一测点预测分析.

综上所述,本文提出了一种基于分形理论的大坝多测点预测方法. 该方法利用多重分形去趋势互相关

分析法(MF – DCCA)对变形与环境量的多重相关性进行分析. 在进行多重相关性分析后,所提方法可以有效识别环境量与大坝变形在特定时间尺度内的相关性,并利用 ICEEMDAN 算法对大坝变形监测数据进行最佳分解处理,将其作为 IGWO – DHKELM 多测点预测模型的输入因子. 同时,基于相关性分析结果对模型进行优化,最终得到更准确的多测点预测结果.

1 坝工原理

混凝土坝任一点的变形可看作一个矢量 $\boldsymbol{\delta}$,按其成因可分为水压分量($\boldsymbol{\delta}_{\mathrm{H}}$)、温度分量($\boldsymbol{\delta}_{\mathrm{T}}$)和时效分量($\boldsymbol{\delta}_{\theta}$),即:

$$\boldsymbol{\delta}=\boldsymbol{\delta}_{\mathrm{H}}+\boldsymbol{\delta}_{\mathrm{T}}+\boldsymbol{\delta}_{\theta} \tag{1}$$

(1)水压分量因子选择

混凝土坝在水压作用下,坝体上任一点产生的变形 $\boldsymbol{\delta}_{\mathrm{H}}$ 由下列三个部分组成:水压作用在坝体上而引起的坝体变形 $\boldsymbol{\delta}_{1\mathrm{H}}$;库水压力作用在坝基面上使坝基变形引起的变形 $\boldsymbol{\delta}_{2\mathrm{H}}$;库水重力作用使坝基面转动引起的变形 $\boldsymbol{\delta}_{3\mathrm{H}}$[20]:

$$\boldsymbol{\delta}_{\mathrm{H}}=\boldsymbol{\delta}_{1\mathrm{H}}+\boldsymbol{\delta}_{2\mathrm{H}}+\boldsymbol{\delta}_{3\mathrm{H}} \tag{2}$$

混凝土坝的水压分量可通过上游水深 h 的多项式表征,即:

$$\boldsymbol{\delta}_{h}=\sum_{i=1}^{n_1}a_i(h^i-h_0^i) \tag{3}$$

式中:n_1 为多项式的最高次数,重力坝通常取为 3,拱坝通常取为 4 或 5;a_i 为水压分量拟合系数;h_0 为初始测量日库水水深.

(2)温度分量因子选择

温度分量是由坝体的混凝土和坝基库岸温度变化所产生的. 对于运行期较长的大坝,温度分量可采用周期函数表征,公式为:

$$\boldsymbol{\delta}_{\mathrm{T}}=\sum_{j=1}^{n_2}\left[b_{1j}(\sin\omega jt-\sin\omega jt_0)+b_{2j}(\cos\omega jt-\cos\omega jt_0)\right] \tag{4}$$

式中:b_{1j}和 b_{2j}均为温度分量系数;n_2 为简谐波组数,$n_2=1$ 为年周期,$n_2=2$ 为半年周期;t 为监测起始日至监测当日的累计天数;t_0 为监测起始日至始测日之间的累计天数;ω 为基频;j 为简谐波阶次.

(3)时效分量因子选择

研究表明,时效分量可通过直线和对数因子相结合的方式来表征[21],其表达式为:

$$\boldsymbol{\delta}_{\theta}=c_1(\theta-\theta_0)+c_2(\ln\theta-\ln\theta_0) \tag{5}$$

式中:$\theta=t/100$,$\theta_0=t_0/100$,t 为监测起始日至监测当日的累计天数;t_0 为监测起始日至始测日的累计天数;c_1 和 c_2 均为时效分量拟合系数.

2 算法原理

2.1 多重分形去趋势互相关分析法

大坝变形监测数据通常表现出明显的非平稳性,从而导致大坝变形序列的统计特性(如均值、方差)随时间变化. 例如,受环境因素(如水位变化、温度波动、地质活动等)影响,大坝的变形可能随时间呈现不同的趋势或波动. 传统的线性方法或简单的相关性分析无法有效捕捉这些复杂的非平稳行为. 而 MF – DCCA 算法通过去趋势处理,能够有效消除时间序列中的长期趋势和漂移,使得在不同时间尺度下的交叉相关性得以揭示. 特别是在大坝变形监测中,去趋势操作有助于去除环境因素对大坝变形数据的长期影响,聚焦于变形数据本身的内在动态变化[22]. MF – DCCA 算法如下[23]:

首先,确定两个时间序列$\{x(i)\}$和$\{y(i)\}$,$i=1,2,3,\cdots,N$,其中 N 为时间序列长度. 序列$\{x(i)\}$和$\{y(i)\}$的累计离差序列可表示为:

$$X(i)=\sum_{t=1}^{i}\left[x(t)-\bar{x}\right],Y(i)=\sum_{t=1}^{i}\left[y(t)-\bar{y}\right] \tag{6}$$

其中:$\bar{x}=\frac{1}{N}\sum_{t=1}^{N}x(t)$,$\bar{y}=\frac{1}{N}\sum_{t=1}^{N}y(t)$;$\bar{x}$、$\bar{y}$ 分别为序列$\{x(i)\}$、$\{y(i)\}$的均值.

其次,将累计离差序列$\{x(i)\}$和$\{y(i)\}$划分为长度为 s 的互不相交区间,s 为时间尺度,区间总数 $N_s=[N/s]$.

计算各区间 v 残差的协方差:

$$F^2(s,v)=\frac{1}{s}\sum_{i=1}^{s}|X((v-1)s+i)-\tilde{X}(i)|\cdot|Y((v-1)s+i)-\tilde{Y}(i)| \tag{7}$$

$$F^2(s,v)=\frac{1}{s}\sum_{i=1}^{s}|X(N-(v-N_s)s+i)-\tilde{X}(i)|\cdot|Y(N-(v-N_s)s+i)-\tilde{Y}(i)| \tag{8}$$

式中:$v=1,2,\cdots,N_s$ 为正向划分区间序号,$v=N_s+1,N_s+2,\cdots,2N_s$ 为反向划分区间序号;$\tilde{X}(i)$、$\tilde{Y}(i)$为区间内 $X(i)$、$Y(i)$的拟合趋势项.

最后,对多个分段进行平均,得到 $q(q\neq0)$阶波动函数 $F_q(s)$,计算公式如下:

$$F_q(s)=\left\{\frac{1}{2N_s}\sum_{v=1}^{2N_s}[F^2(s,v)]^{q/2}\right\}^{1/q} \tag{9}$$

当 $q=0$ 时:

$$F_q(s)=\exp\left\{\frac{1}{4N_s}\sum_{v=1}^{2N_s}\ln[F^2(s,v)]\right\} \tag{10}$$

若 $h(q)$随着 q 增大而单调递减,则两个序列之间的互相关性具有典型的多重分形特征. 多重分形的强度可由 $h(q)$的范围计算:

$$\Delta h=\max h(q)-\min h(q) \tag{11}$$

Δh 越大,表明序列多重分形特征越强.

2.2 ICEEMDAN 分解算法

本文所采用的改进的自适应噪声集合经验模态分解(ICEEMDAN)算法,是在经典经验模态分解(EMD)理论体系的基础上,通过集成经验模态分解(EEMD)的噪声注入策略及自适应噪声完备经验模态分解(CEEMDAN)的迭代优化机制,发展形成的新型信号处理方法. 该算法通过改进白噪声添加方式与分量重构准则,显著改善了本征模态函数(IMF)成分间的信号交叠现象,同时有效缓解了传统方法中存在的残留噪声干扰及虚假分量生成问题. 通过向第 i 个 IMF 分量中添加高斯白噪声,改进了分解过程[24-25]. ICEEMDAN 的分解步骤见文献[26].

2.3 改进灰狼优化算法(IGWO)

灰狼优化算法(GWO)[27]是一种基于狼群社会层级结构与协同捕食行为的仿生智能优化方法. 其算法机制模拟了自然界中狼群追踪、合围、猎杀目标的完整行为链,具有结构简洁、参数依赖性低、全局搜索能力强等特点. 在等级架构设计方面,GWO 算法构建了四层社会层级模型:顶层 α 狼对应全局最优解,负责决策群体的空间移动路径;次级 β 狼与三级 δ 狼分别表征次优解集,其中 β 狼具备接替 α 狼的候补决策权,δ 狼承担群体协调功能;底层 ω 狼作为执行层,依据上层指令完成具体的围捕操作. 算法迭代过程中,α、β、δ 三组领导层解通过动态调整空间坐标以优化捕猎路径,ω 群体则根据领导层解的位置信息实施包围策略,最终通过群体智能协作实现全局最优解的逼近. 该算法描述如下:

$$\boldsymbol{D}=|\boldsymbol{C}\boldsymbol{X}_p(t)-X(t)| \tag{12}$$

$$\boldsymbol{X}(t+1)=\boldsymbol{X}_p(t)-\boldsymbol{A}\boldsymbol{D} \tag{13}$$

式中:D 为灰狼个体与猎物之间的距离,t 为迭代次数,$\boldsymbol{X}_p$ 为猎物的位置. 系数向量 $\boldsymbol{A}$ 和 $\boldsymbol{C}$ 按下式计算:

$$\begin{cases}\boldsymbol{A}=2a\boldsymbol{r}_1-a\\ \boldsymbol{C}=2\boldsymbol{r}_2\end{cases} \tag{14}$$

式中:a 为收敛因子,$a=2(1-t/T)$随迭代次数 t 从 2 线性递减到 0,T 为最大迭代次数;$\boldsymbol{r}_1$,$\boldsymbol{r}_2$ 为取值区间[0,1]内的均匀随机数.

传统 GWO 算法采用线性递减的收敛因子 a，容易导致狼群多样性衰减，降低算法性能[28]. 为提高搜索能力，本文提出一种新的收敛因子控制策略，图 1 展示了改进灰狼算法中收敛因子随迭代次数变化曲线[29]. 收敛因子的计算方法如下：

$$a = a_{\min} + (a_{\max} - a_{\min}) \cdot 2^{-10\left(\frac{t}{T}\right)^4} \tag{15}$$

其中：$a_{\min}$为最低收敛因子，$a_{\max}$为最高收敛因子.

为防止在寻优过程中收敛速度过慢，取 $a_{\min}$为 0.007，为使前期搜索速度快，取 $a_{\max}$为 2[30]，该参数选取参考文献[29].

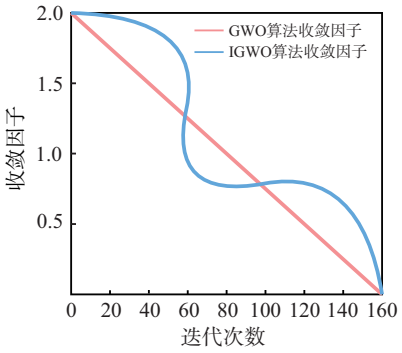

图 1　GWO 算法改进前后收敛因子曲线对比

Fig. 1　Comparison of convergence factor curves before and after GWO algorithm improvement

2.4 深度混合核极限学习机(DHKELM)

极限学习机(ELM)是一种训练单层前馈神经网络(SLFNs)的快速高效算法[31]. 基于 ELM 的核极限学习机(KELM)用于处理非线性特征映射，使用核函数来代替显式的特征转换[13]，核函数原理如图 2 所示. KELM 可用于预测混凝土坝变形位移过程：

$$o(x) = \sum_{i=1}^{N} \beta_i K(x, x_i) \tag{16}$$

其中：o 为预测的大坝变形预测值，β_i 为高维空间中 x_i 所对应的权重系数，$K(\cdot,\cdot)$为核函数.

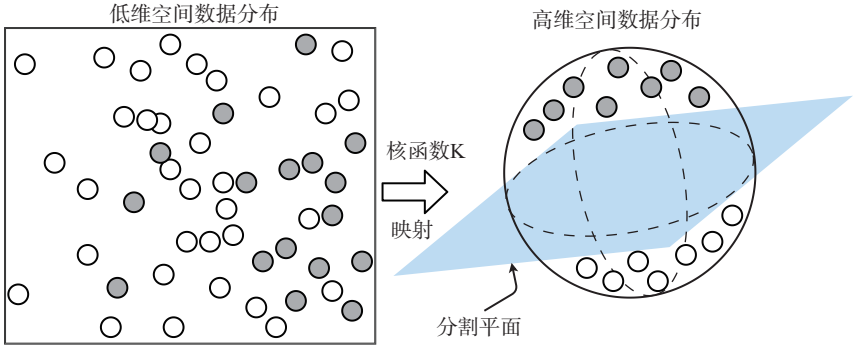

图 2　核函数原理示意图

Fig. 2　Schematic diagram of kernel function principle

权重 β 的求解过程中，涉及正则化最小二乘法问题：

$$\beta = (\boldsymbol{H}^{\mathrm{T}}\boldsymbol{H} + \lambda \boldsymbol{I})^{-1}\boldsymbol{H}^{\mathrm{T}}\boldsymbol{Y} \tag{17}$$

其中：$\boldsymbol{H}^{\mathrm{T}}$ 为核矩阵 $\boldsymbol{H}$ 的转置；λ 为正则化系数，该系数用于防止过拟合；$\boldsymbol{I}$ 为单位矩阵.

本文采用将具有强大学习能力的高斯核函数(RBF)与具备良好泛化能力的多项式核函数(Poly)进行加权组合的方法，从而形成混合核函数[32]. RBF 核通过径向基函数对数据局部特征敏感，能有效捕捉大坝变形中的非线性细节(如局部突变、短期变形趋势)，两者加权后能同时表征大坝变形的复杂多尺度特征. Poly 核通过多项式展开可建模数据的全局特征(如长期趋势、周期性变形)，适合大坝变形的宏观规律. DHKELM 模型示意图如图 3 所示.

在 DELM 中，第 n 层 ELM－AE 的输出 $\boldsymbol{H}(n)$作为下一层的输入[19]：

$$\boldsymbol{H}^{(n+1)} = g(\boldsymbol{W}^{(n)}\boldsymbol{H}^{(n)} + \boldsymbol{b}^{(n)}) \tag{18}$$

其中：$\boldsymbol{W}(n)$和 $\boldsymbol{b}(n)$分别为第 n 层的权重矩阵和偏置向量.

给定最后一层 ELM－AE 的输出特征 $\boldsymbol{H}(p)$，最终的输出函数 $\boldsymbol{Y}$ 可以表示为：

$$\boldsymbol{Y} = \beta^{\mathrm{T}} K_{\mathrm{mixed}}(\boldsymbol{H}^{(p)}, \boldsymbol{X}) \tag{19}$$

其中：$\boldsymbol{Y}$ 为预测的混凝土坝变形位移，$\boldsymbol{X}$ 为影响混凝土坝变形的因素，β 为 HKELM 层的输出权重，K_{mixed}为

混合核函数,P 为特征提取层的数量.

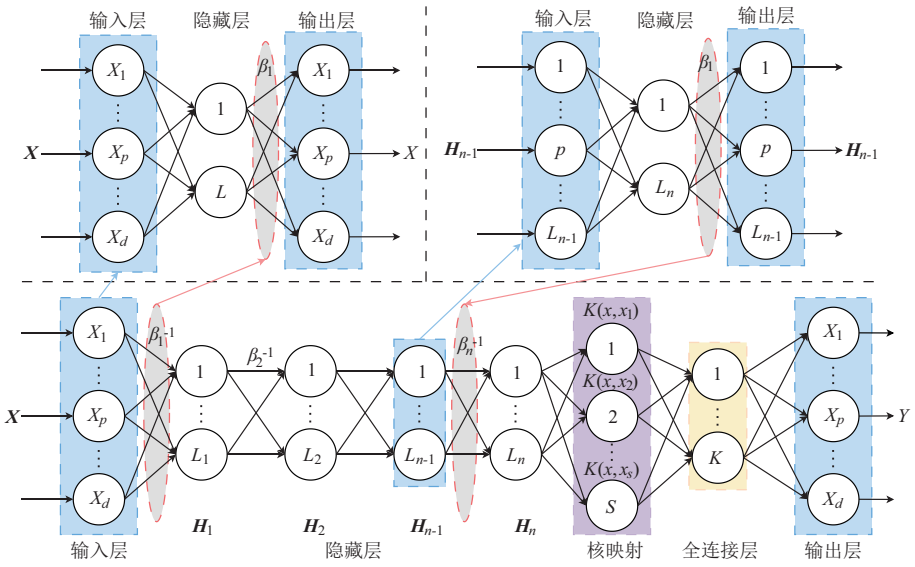

图 3 DHKELM 模型结构示意图

Fig. 3 Schematic diagram of DHKELM model structure

2.5 基于 IGWO 优化的 DHKELM 模型构建流程

DHKELM 由多个 ELM – AE 堆叠并结合 HKELM,流程图如图 3 所示. ELM – AE 的输出权重用于初始化 DHKELM,训练中使用 Sigmoid 激活函数进行特征映射. 因此,本文采用 IGWO 算法优化参数. 优化流程如图 4 所示,具体步骤如下:

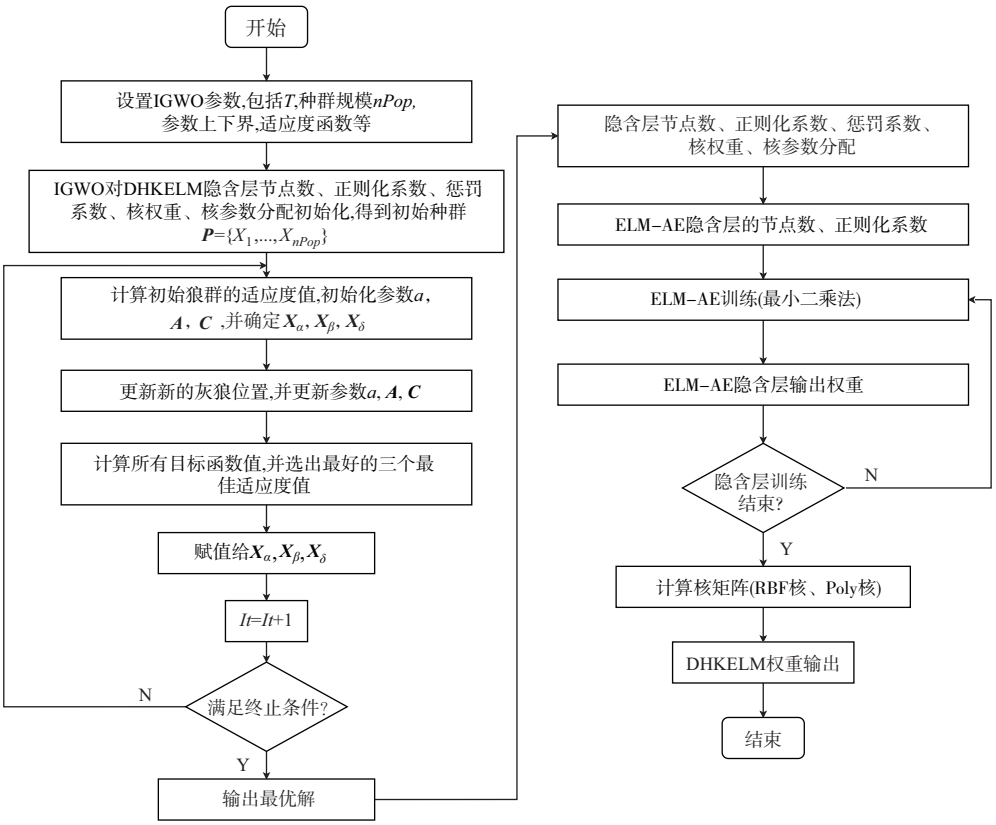

图 4 IGWO – DHKELM 模型构建流程图

Fig. 4 Schematic diagram of the construction process of IGWO – DHKELM model

1）确定改进灰狼优化算法的各项参数，包括最大迭代次数、种群数量、需要优化的参数个数、以及搜索空间的上下限等；

2）根据 IGWO 初始化策略生成种群，并将其赋予 DHKELM 的隐含层节点数、正则化系数和核参数；

3）利用训练数据训练网络，计算均方根误差（*RMSE*），并将其作为适应度函数，以最小化 *RMSE* 为优化目标；

4）选择最小的三个适应度值，依次赋给 X_α、X_β 和 X_δ. 并将最优个体作为首领狼，更新权值因子和其他参数；

5）进入循环，若 *RMSE* 小于阈值或达到最大迭代次数，退出循环，将 X_α 作为最佳 DHKELM 参数；

6）使用 IGWO 优化后的 DHKELM 进行训练，输出 DHKELM 的权重.

3　模型研究框架

本文提出了一种基于分形理论的多测点预测模型，主要包括四部分：大坝变形监测数据预处理、分形理论对变形与环境量进行相关性分析，ICEEMDAN 方法对变形监测数据进行分解重构处理，IGWO 算法对 DHKELM 模型进行参数优化，并进行多测点预测输出. 模型研究框架如图 5 所示.

（1）对大坝变形监测数据进行缺失值处理和异常值识别，并将环境量作为大坝变形预测模型的输入样本，以实际变形值作为目标变量. 预处理后的数据作为后续分形理论相关性分析的基础，确保分形分析中不受到噪声或异常值的影响. 此步骤还将环境量作为预测模型的输入样本，为后续的 ICEEMDAN 分解与 IGWO – DHKELM 模型提供规范化的输入数据.

（2）利用 MF – DCCA 算法深入探究水平位移与环境量的关系，通过计算波动函数、广义相关 Hurst 指数、标度函数及多重分形谱，揭示其复杂联系.

（3）利用 ICEEMDAN 分解方法，通过引入特定噪声，将原始变形监测数据 $X(t)$ 分解为从高频到低频的 IMF 分量和残余函数，有效减轻残余噪声和模态混叠，减少伪分量产生，进而挖掘变形监测数据的深层信息.

（4）利用 IGWO 算法对 DHKELM 模型所有参数进行优化选取，并将具有强大学习能力的高斯核函数（RBF）与具备良好泛化能力的多项式核函数（Poly）进行加权组合，从而形成混合核函数，构建多输入多输出的 IGWO – DHKELM 模型，最终利用 IGWO – DHKELM 模型进行变形预测输出.

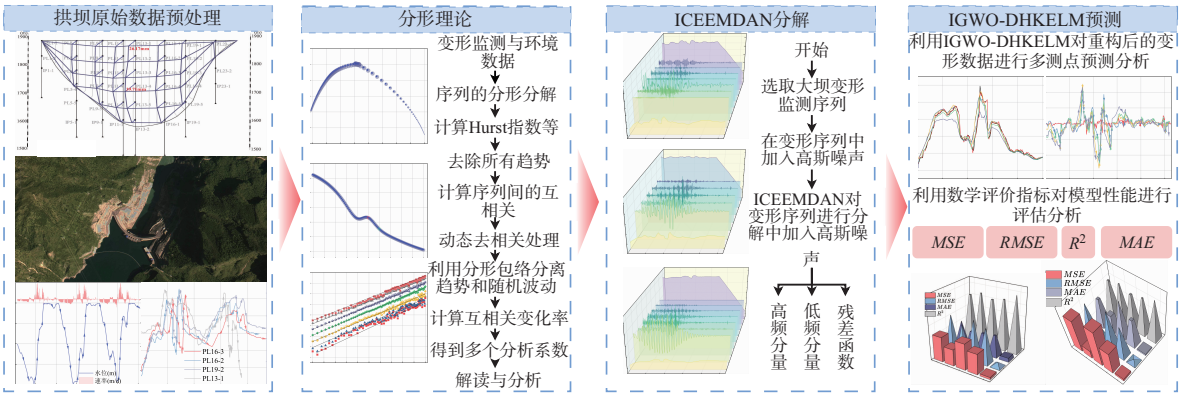

图 5　模型研究框架

Fig. 5　Model research framework

4　案例分析

某拱坝水电站位于四川雅砻江，电站总装机容量 360 万 kW（6 台 ×60 万 kW），枯水年枯期平均出力 108.6 万 kW，多年平均年发电量 166.2 亿 kW · h. 水库正常蓄水位 1 880 m，死水位 1 800 m，总库容 77.6 亿 m^3，调节库容 49.1 亿 m^3，属年调节水库. 枢纽建筑由挡水、泄水及消能、引水发电等永久性建筑物组

成,其中混凝土双曲拱坝坝高 305 m. 研究对象为该双曲拱坝 PL16 -3、PL16 -2、PL19 -2 和 PL13 -1 测点在 2014 年 1 月 1 日—2016 年 12 月 31 日期间的变形监测数据.

4.1 水平位移与环境量间的多重相关性分析

本文利用 MF - DCCA 算法探究水平位移与环境量的关系,结果如图 6 所示. 其中,图 6(a) ~ 6(c)结果显示:变形对大幅度水位和气温变化不敏感,而对小幅度波动较敏感,呈现左截尾、右长尾. 图 6(a) ~ 6(c)对应的变形与环境量的宽度 Δα 分别为 0.403、0.584 和 3.752;Δα 越大,说明时间序列的波动越剧烈、不均匀,表明变形与环境量具有复杂的多重分形特征.

图 6(d) ~6(f)展示了不同 q 阶下变形与环境量的广义 Hurst 指数 H_q. H_q 随 q 增大而递减,并呈现非线性特征,变化幅度随 $|q|$ 增大而减小,表明 H_q 值在 q 极值时收敛. 当 $q=2$ 时,H_q 分别对应为 2.176、1.531 和 1.805,均大于 0.5,表明变形与环境量存在长期幂律互相关,呈长程相关性.

图 6(g) ~6(h)显示,不同 q 阶下 $\lg(s)$ 与 $\lg F_q(s)$ 呈良好线性关系,表明变形与水位和气温在不同尺度上具有幂律持续性特征. 图 6(i)显示,曲线初始折线后变直线,可能原因为小尺度下变形和时效的非简单幂律行为,存在时序模式变化或异常波动. 随时间尺度增加,局部结构稳定,曲线趋向幂律行为.

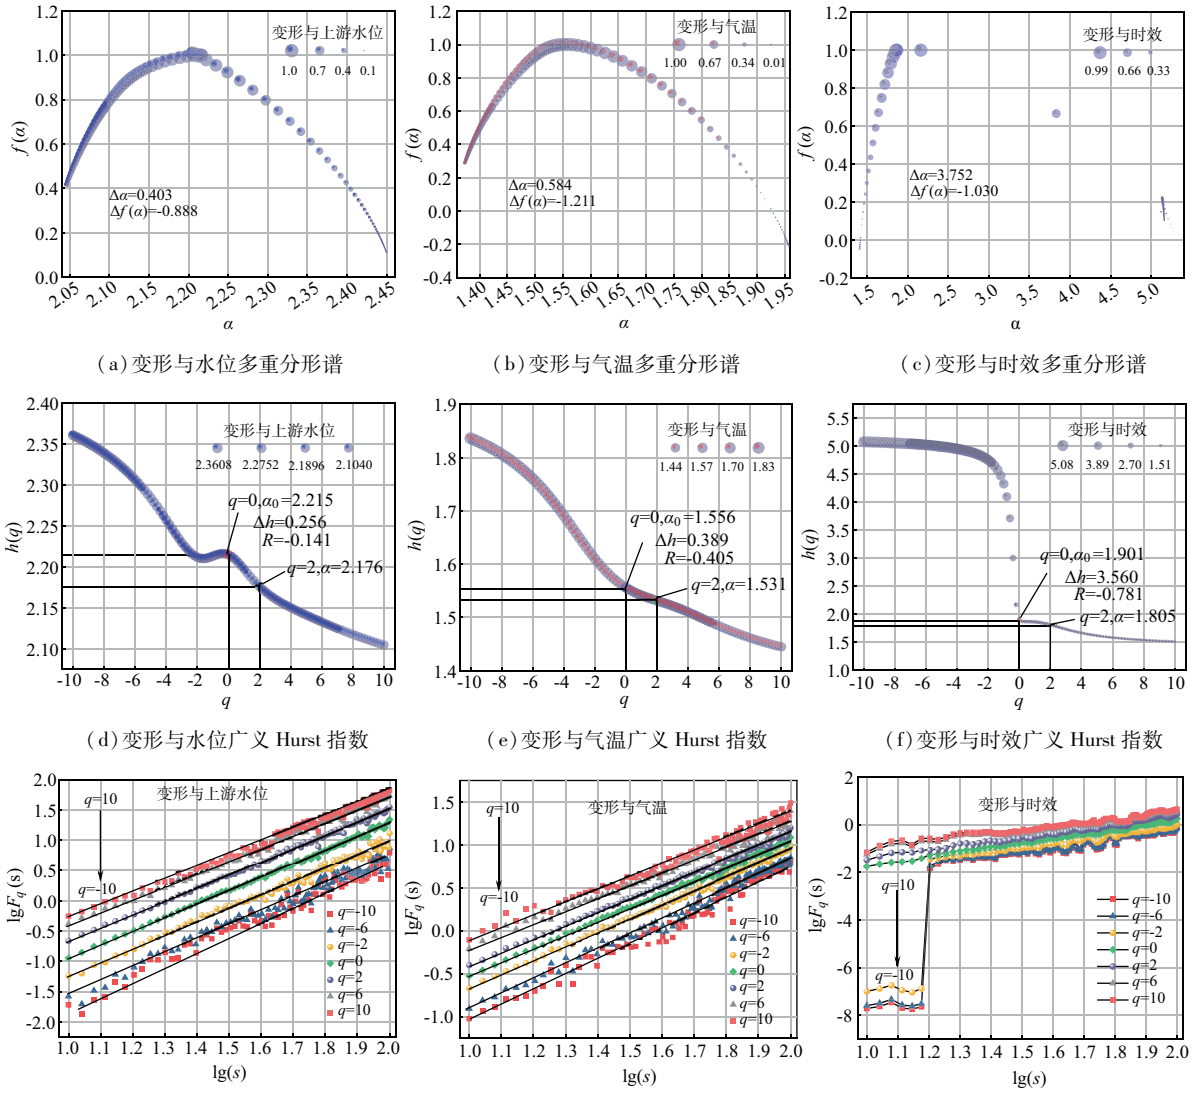

(a)变形与水位多重分形谱 (b)变形与气温多重分形谱 (c)变形与时效多重分形谱

(d)变形与水位广义 Hurst 指数 (e)变形与气温广义 Hurst 指数 (f)变形与时效广义 Hurst 指数

(g)变形与水位波动函数 (h)变形与气温波动函数 (i)变形与时效波动函数

图 6 变形与环境量之间的多重分形谱结果

Fig. 6 Multifractal spectrum results between deformation and environmental variables

4.2 ICEEMDAN 分解结果分析

利用 4.1 节分形理论从宏观层面刻画变形与环境量的整体复杂度，本节利用 ICEEMDAN 从微观层面解构数据的多尺度成分. 采用 ICEEMDAN 方法将原始序列（大坝变形原始数据）分解为不同频率的 IMF 分量和趋势项，通过选择性重构 IMFs 去除噪声，获得更平滑的变形数据，从而提高后续分析和预测模型的准确性. 分解结果如图 7 所示. 图 7 显示，两个测点经过 ICEEMDAN 分解后的模态分量具有显著相似性. PL19 – 2 测点的 IMF2 和 IMF3 波动频率较高，通常由噪声或短期环境因素引起. IMF4 至 IMF6 反映了与季节性变化、气候变动和水位周期性变化相关的中期趋势. IMF1 和 IMF7 ~ IMF8 为低频分量，趋势项则体现了大坝的总体变形趋势，反映长期累积效应和基础变形特征.

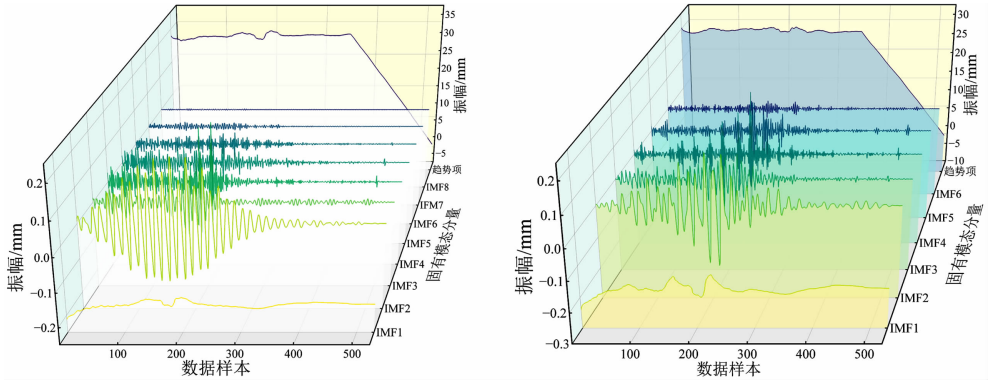

图 7　ICEEMDAN 方法分解结果

Fig. 7　ICEEMDAN method decomposition results

4.3 IGWO 算法优化适应度函数及待优化决策变量

利用 IGWO 算法对 DHKELM 模型的关键参数进行寻优求解. 如表 1 所示，DHKELM 模型包含 6 个需要优化的决策变量. 图 8 展示了 IGWO 算法在参数寻优过程中的适应度变化曲线.

基于图 8 的优化过程分析，当种群规模设置为 30 时，算法在第 18 代收敛至最优解. 综合考虑计算效率与优化效果，最终确定 IGWO 的优化参数为：种群规模为 30，最大迭代次数为 500. 经过优化计算，得到 DHKELM 模型最优参数分别为：$\sigma = 1.9$、$d = 2$、$c = 0.4$、$w_{\mathrm{RBF}} = 0.6$、$w_{\mathrm{Poly}} = 0.4$、$\lambda = 3 \times 10^{-3}$、$N_{\mathrm{h}} = 200$（*PL*19 – 2 测点）、$N_{\mathrm{h}} = 110$（PL16 – 3 测点）. 参数优化结果可从以下方面进行解释：

（1）RBF 核带宽：根据 4.2 节 ICEEMDAN 分解结果，高频 IMF 分量（PL19 – 2 的 IMF2 – 3，PL16 – 3 的 IMF2 – 3）主要反映噪声和短期扰动特征，因此采用较小的 RBF 核宽度（$\sigma = 1.9$）以捕捉局部细节. 同时，结合 4.1 节水位序列分形分析结果（$\Delta\alpha = 0.403$，复杂度较低），最终确定最优 σ 值.

（2）多项式核阶数：低频 IMF 分量和趋势项呈现明显的长期变化规律，因此多项式核采用二阶（$d = 2$）以有效拟合周期性环境因素的影响.

（3）混合核权重：为使模型既可以捕捉局部细节又可以捕捉全局特征，最终得到 $w_{\mathrm{RBF}} = 0.6$，$w_{\mathrm{Poly}} = 0.4$.

（4）正则化参数：由于在多测点预测时，测点空间相关性较高，导致最终正则化系数 $\lambda = 3 \times 10^{-3}$，以约束参数冗余.

（5）深度结构参数：隐含层节点数的确定依据各测点 ICEEMDAN 分解结果（PL19 – 2：8 个 IMF + 1 个趋势项；PL16 – 3：6 个 IMF + 1 个趋势项），最终分别设置为 200 个和 110 个节点.

表 1　DHKELM 模型决策变量

Tab. 1　Decision variables of DHKELM model

变量类别	变量名称	范围	作用
核函数参数	RBF 核带宽	$\sigma \in [0.1, 10]$	控制高斯核的局部响应范围，影响模型对数据分布的敏感度.
	多项式核阶数	$d \in [1, 3]$	决定多项式核的非线性复杂度.
	多项式核系数	$c \in [0, 1]$	调整多项式核的常数项，影响核函数的偏移量.

续表 1

变量类别	变量名称	范围	作用
混合核权重	RBF 核权重	$w_{\mathrm{RBF}} \in [0.3, 0.7]$	需满足权重和为 1.
	Poly 核权重	$w_{\mathrm{Poly}} = 1 - w_{\mathrm{RBF}}$	$w_{\mathrm{Poly}} = 1 - w_{\mathrm{RBF}}$(无需单独优化).
正则化参数	正则化系数	$\lambda \in [10^{-5}, 10^{2}]$	控制模型复杂度的权衡,防止过拟合.
深度结构参数	隐藏层节点数	$N_h \in [2n, 10n]$	决定隐层随机特征映射的维度,影响模型容量和计算效率.
	隐藏层激活函数:Sigmoid	固定选取	非优化参数.

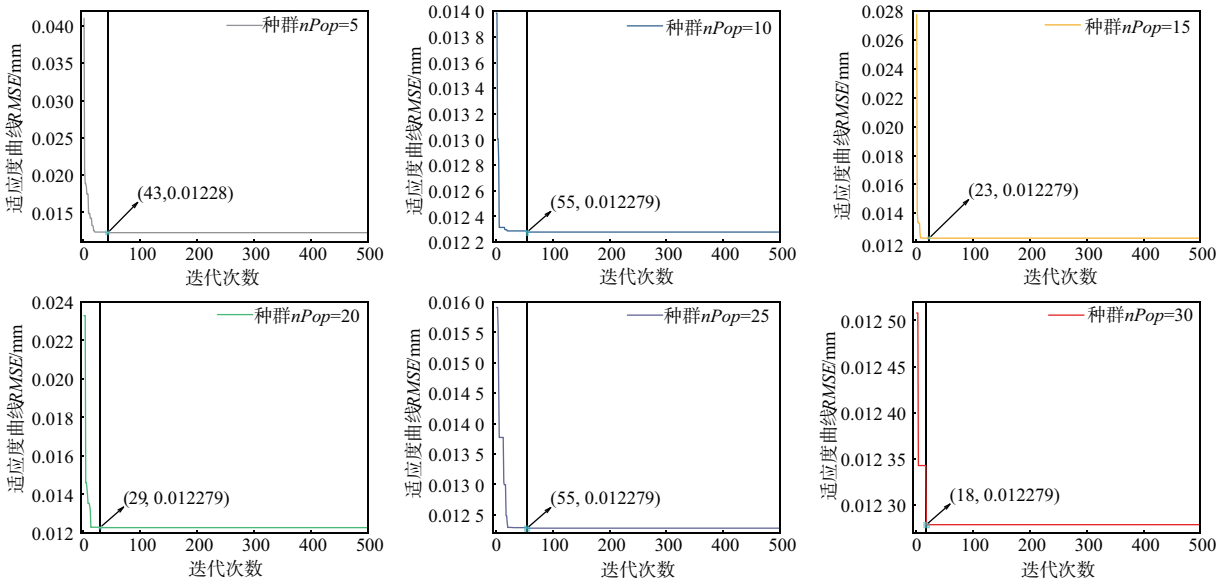

图 8 IGWO 优化参数适应度曲线

Fig. 8 IGWO optimization parameter fitness curve

4.4 DHKELM 模型核函数对比及 DELM 层数对比分析

在 ICEEMDAN 分解的基础上,本节对于 DHKELM 模型的核函数选取和 DELM 层数分析进行了对比验证,以选取适用于大坝变形多测点的最佳 DHKELM 模型参数.

(1)不同核函数对比分析

为全面评估本文所选取的 RBF – Poly 混合核函数的优势,选取其他不同组合的混合核函数(RBF – Lin、RBF – wav、Poly – Lin 等)以及单一核函数作为对比. 同时,为考察 RBF – Poly 混合核函数在不同数据分布下的泛化能力,选取了两类典型拱坝的监测数据,并设置不同的训练集与测试集比例进行验证. 各核函数的拟合效果对比结果如图 9 所示.

由图 9(a)和 9(b)可知,RBF – Poly 混合核函数在各项评价指标上均显著优于其他核函数组合. 相较于 RBF – Lin 组合,RBF – Poly 通过 Poly 的全局高阶特性与 RBF 的局部非线性表征能力,能够更好地处理大坝变形中由水位 – 温度耦合作用产生的复杂非线性关系. 而 Lin 核由于仅能实现线性映射,难以有效捕捉这种强非线性特征. 与 RBF – wav 组合相比,RBF – Poly 展现出明显的工程应用优势:一方面,多项式核的阶数 d 可调节模型对全局非线性关系的表征复杂度;另一方面,其计算复杂度显著低于需要多尺度分解的 wav,更适用于多测点协同预测. 这一特性使得 RBF – wav 组合更适用于信号处理领域而非工程变形分析领域.

此外,RBF – Poly 较 Poly – Lin 组合具有三方面优势:1)RBF 核能有效捕捉变形序列的局部突变特征;2)IGWO 可同步优化 RBF 的 σ 参数和 Poly 的 d 参数,降低调参难度;3)避免了 Poly 核单独优化时易陷入局部最优的问题. 综合评价指标显示,RBF – Poly 在所有测试场景下均保持最优性能,验证了其在大坝多测点变形预测中的适用性和优越性.

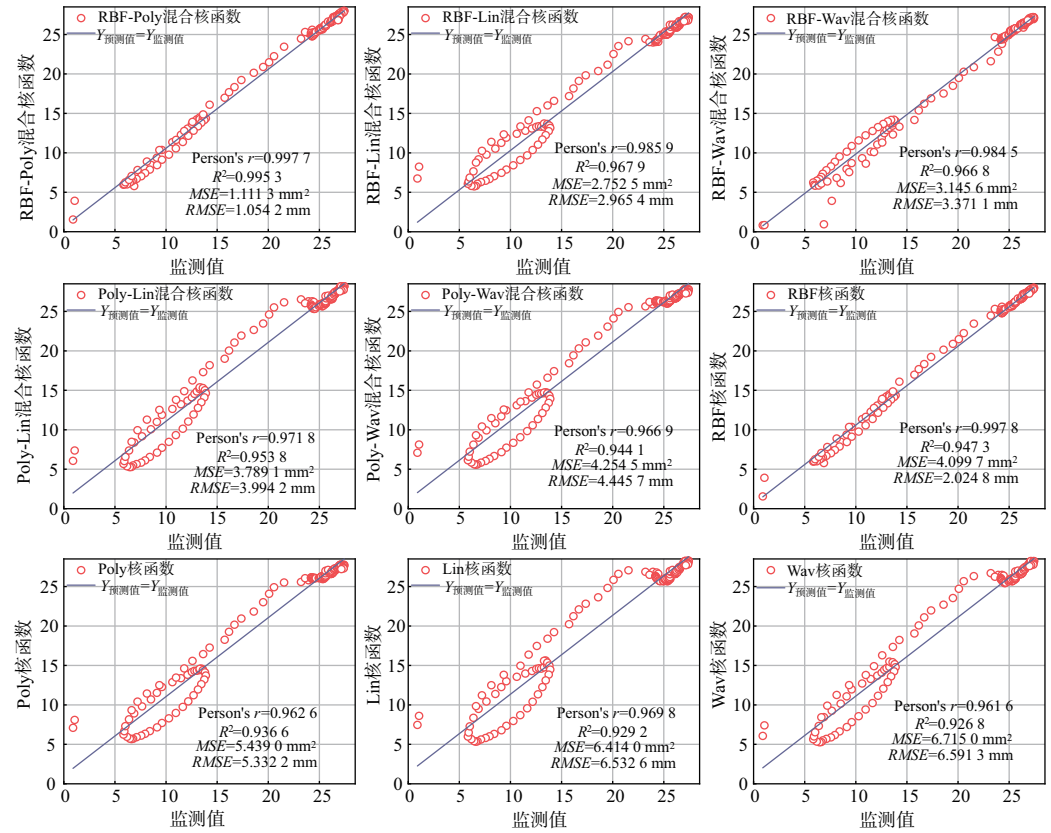

（a）拱坝一（训练集∶测试集 =7∶3）

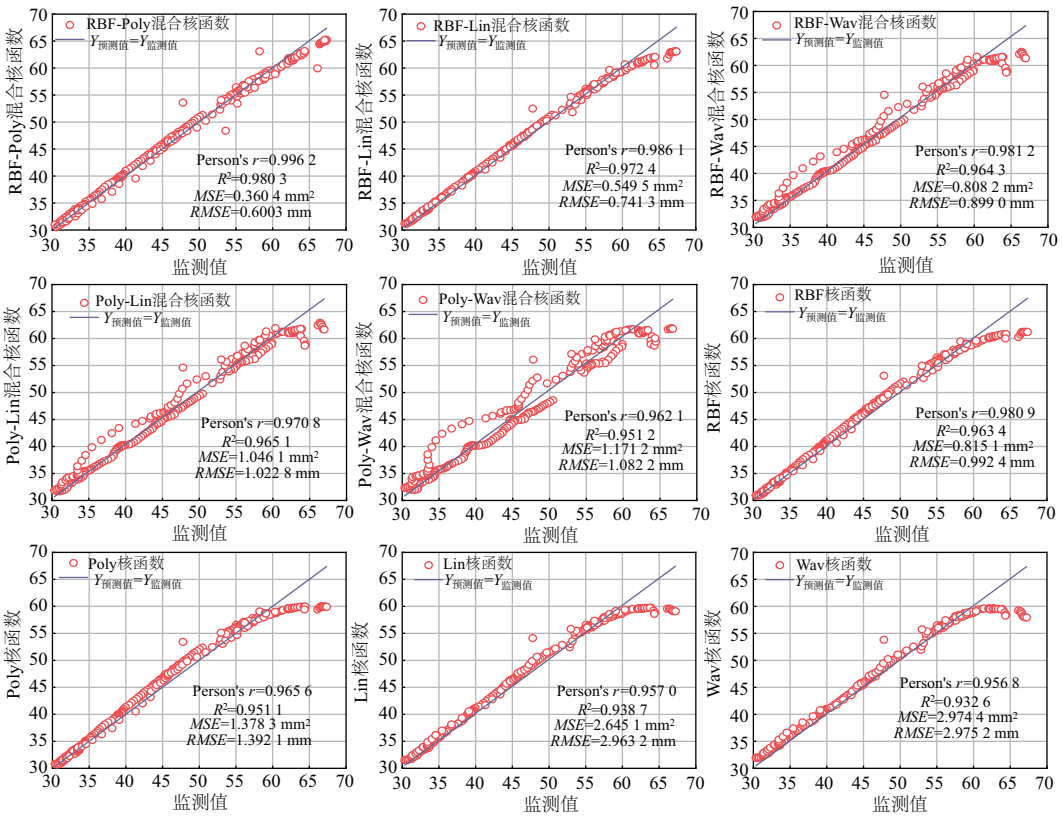

（b）拱坝二（训练集∶测试集 =5∶5）

图 9　不同核函数预测对比曲线

Fig. 9　Comparison curves of different kernel function prediction

(2)不同 DELM 层数对比分析

在大坝多测点变形预测建模过程中,DELM 网络深度会影响模型的特征提取能力和预测性能. 为分析不同网络深度对预测结果的影响,采用与前文一致的实验设置,对两类拱坝监测数据进行对比,结果见表2. 随着 DELM 层数由 1 层增加至 3 ~5 层,两类数据集的总体预测性能均明显改善,表明适当增加网络深度有助于增强模型对非线性变形特征的表征能力. 不同评价指标的最优结果并不完全对应同一网络深度:在拱坝一的预测结果中,3 层结构的 *MSE* 和 *RMSE* 较低,而 5 层结构的 *MAE* 和 R^2 略优;在拱坝二的预测结果中,5 层结构在 *MSE*、*RMSE* 和 R^2 上略优于 4 层结构,但 4 层结构的 *MAE* 更低. 综合预测性能、网络复杂度和后续计算需求,本文选取 4 层 DELM 作为后续模型结构,以兼顾预测精度与模型复杂度.

表 2 不同 DELM 层预测性能分析

Tab. 2 Prediction performance analysis of different DELM layers

拱坝	DELM 层数	评价指标			
		MSE/mm^2	*RMSE*/mm	*MAE*/mm	R^2
拱坝一(训练集:测试集 =7:3)	1	1.499 3	1.224 5	0.972 8	0.920 8
	2	0.941 8	0.970 5	0.8105	0.941 9
	3	0.431 2	0.656 7	0.573 4	0.971 8
	4	0.527 1	0.726 0	0.508 8	0.980 2
	5	0.591 7	0.769 2	0.503 0	0.989 0
拱坝二(训练集:测试集 =5:5)	1	4.934 7	2.221 4	1.362 9	0.910 4
	2	4.134 1	2.033 2	1.492 7	0.936 9
	3	2.927 6	1.711 0	1.222 5	0.966 5
	4	2.404 3	1.550 6	1.046 9	0.980 7
	5	2.312 8	1.520 8	1.236 2	0.981 5

4.5 模型预测性能分析

(1)与传统预测模型对比分析

本文采用多尺度分析方法构建了混凝土坝变形预测模型体系. 首先,基于分形理论(4.1 节)对变形与环境变量的宏观关联特性进行解析;其次,应用 ICEEMDAN 方法(4.2 节)实现变形监测数据的多尺度分解;最后,采用 IGWO 对 DHKELM 的关键参数进行优化(4.3 节)及 DHKELM 模型核函数及层数对比分析(4.4 节),从而建立了 ICEEMDAN – IGWO – DHKELM 大坝变形多测点预测模型.

为验证所提模型的优越性,实验设计了四组对比模型:1)IGWO – DHKELM 模型;2)IGWO – KELM 模型;3)GWO – KELM 模型;4)DHKELM 模型. 所有模型均设置相同种群数及迭代次数以保证优化充分性. 选用 PL16 – 3、PL16 – 2、PL19 – 2 和 PL13 – 1 四个典型测点的监测数据作为样本,其中 2014 年 1 月 1 日至 2016 年 8 月 11 日的数据用于模型训练,剩余数据用于预测性能测试. 图 10 展示了 PL16 – 3 和 PL16 – 2 测点的对比实验结果,包括各模型的拟合曲线、预测结果及残差分布.

图 10 中展示了 4 种监测模型的预测结果对比. 结果表明,基于 ICEEMDN 和 IGWO – DHKELM 算法的模型预测结果最接近实测位移,且 ICEEMDAN 分解重构处理显著提高了模型精度,有助于更清晰地理解变形成分和模式. 与 GWO – KELM 模型相比,IGWO – KELM 模型在参数优化上具有更快的训练速度和更高效率,且有效减少了过拟合风险. 此外,DHKELM 模型优于 IGWO – KELM 和 GWO – KELM 模型,证明其在大坝变形预测中具有更强的性能,通过 IGWO 优化参数后,能够进一步提升预测精度和效率.

图 11 的残差分布图显示,本文模型的残差均匀分布在零值附近,表明模型充分解释了数据的变异性,残差仅包含随机扰动,无系统误差. 相比之下,DHKELM、GWO – KELM 和 IGWO – KELM 模型的残差分布呈现一定模式化趋势,表明这些模型未能充分捕捉数据的潜在非线性关系,且残差表现出系统性增减变化,可能受异方差性影响,预测不确定性随拟合值变化.

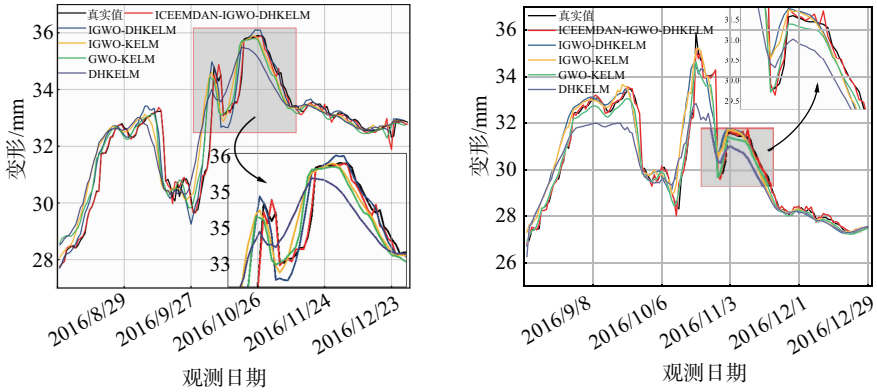

(a) PL16 – 3 测点　　(b) PL16 – 2 测点

图 10　水平位移预测过程线

Fig. 10　Horizontal displacement prediction process line

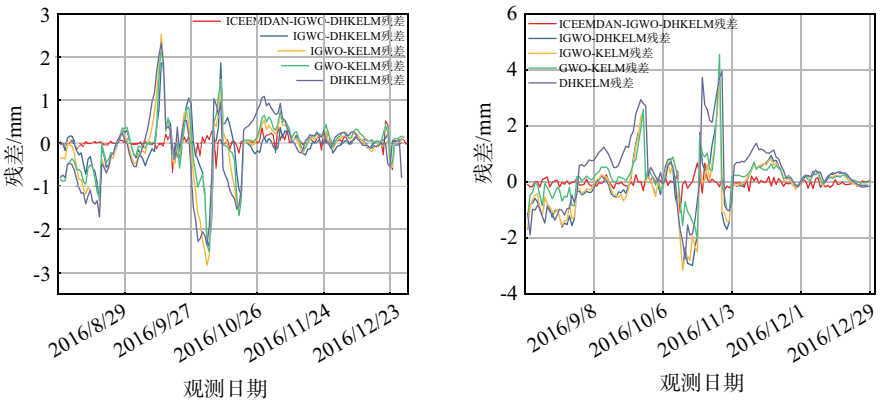

(a) PL16 – 3 残差　　(b) PL16 – 2 残差

图 11　水平位移残差过程线

Fig. 11　Horizontal displacement residual process line

图 12 的雷达图显示,本文提出的模型在 3 个评价指标上显著优于其他模型,特别是在 R^2 上,均接近 0. 99,表明该模型在大坝变形预测中的敏感性和效率更高,能更准确地预测和分析大坝的未来服役状态.

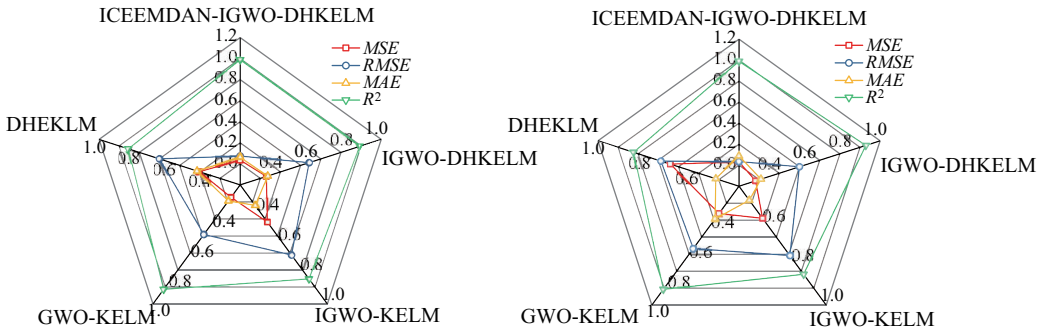

(a) PL16 – 3 测点　　(b) PL16 – 2 测点

图 12　水平位移预测统计指标雷达图

Fig. 12　Radar chart of horizontal displacement prediction statistical index

(2) 多测点变形空间耦合效应分析

为评估多测点变形空间耦合效应对预测精度的影响,采用对比分析方法:将融合测点间空间耦合效应的多输出模型预测结果、忽略空间耦合的单目标算法预测值,分别与实际监测数据进行系统对比验证,其对比结果如图 13 所示.

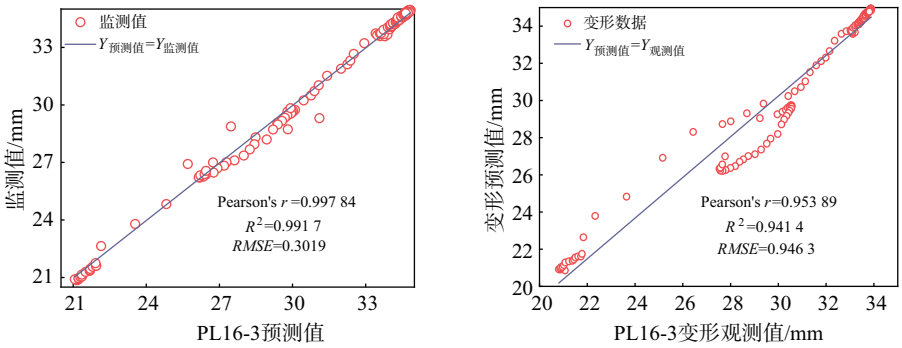

(a)多测点输出 PL16－3 (b)单测点输出 PL16－3

图 13 PL16－3 变形预测拟合散点图

Fig. 13 PL16－3 deformation prediction fitting scatter plot

由图 13 可知,两种预测方法的计算结果均紧密分布在参考对角线附近,这表明预测值与实测数据具有良好的一致性. 然而,通过对比分析发现,相较于忽略空间相互作用的单目标预测方法,融合多测点关联特征的多输出模型展现出更优越的预测性能. 具体表现为:1)预测精度显著提升;2)通过并行处理多个监测点的变形信息,有效避免了单目标算法需要重复训练的缺陷,大幅提高了计算效率. 这种改进使得模型在保证预测准确性的同时,也优化了运算资源的利用效率.

4.6 模型泛化性验证分析

为全面验证模型的优势,以中国东南某碾压混凝土重力坝和西南某土石坝为例进行模型泛化性验证. 该重力坝最大坝高 113.0 m,坝顶高程 179.0 m. 属不完全调节水库,校核洪水位 177.80 m,相应总库容 20.35 亿 m^3. 该土石坝主坝坝长 201 m,坝高 62 m,主坝河床断面布置 5 个渗流监测点. 重力坝环境量及土石坝渗流量变化曲线如图 14 所示. 选取重力坝 PP8 测点和土石坝渗流量进行分析,并选取与上文拱坝相同的预测模型和对比模型进行预测,训练集:验证集:测试集的比例均为 6:1:3. 进而验证了本文模型的预测性能,其预测结果如图 15 所示. 由图 15(a)中渗流量预测结果可知:

1)预测精度方面:ICEEMDAN－IGWO－DHKELM 模型的渗流量预测曲线与监测值变化趋势一致,尤其是在关键时间节点(2018/7/12—2018/9/12 期间),其预测值更贴近实际监测值(9.1～11.7 区间),表明该模型能够精准捕捉渗流量的下降速度;IGWO－DHKELM 模型和 IGWO－KELM 模型在前中期(2018/7/12—2018/9/12 与 2018/9/12—2018/11/22 期间)的预测值略高于监测值,存在轻微高估现象;GWO－KELM 模型在末期(2018/12/22)的预测值偏离监测值更明显,显示其泛化性较弱;DHKELM 模型仅在前期未能有效对渗流量进行预测,但到中期拟合精度逐渐提升,说明本文基于多测点关联特征的多输出模型展现出更优越的预测性能.

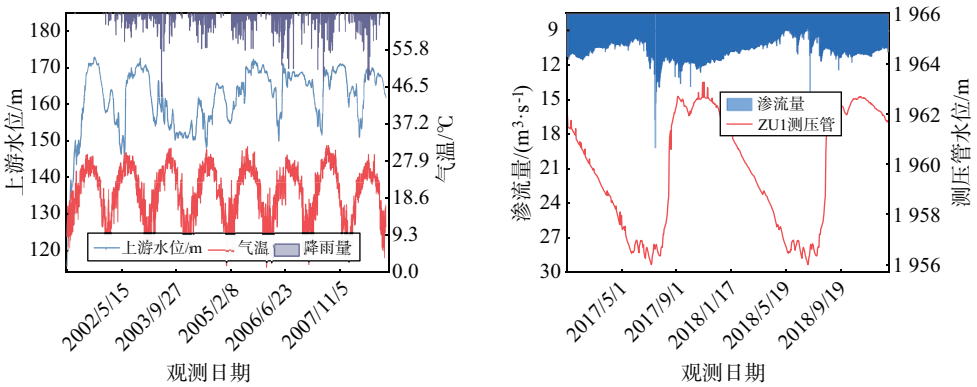

(a)重力坝环境量变化曲线 (b)土石坝渗流量变化曲线

图 14 两种不同坝型的环境量和渗流量变化曲线

Fig. 14 The variation curves of environmental quantity and seepage flow of two different dam types

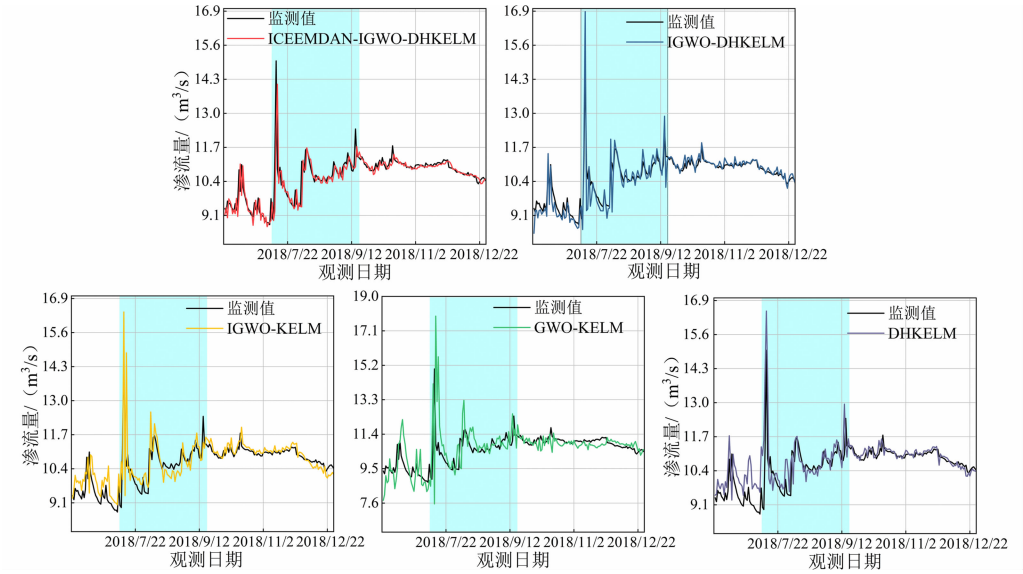

(a)土石坝渗流量预测结果

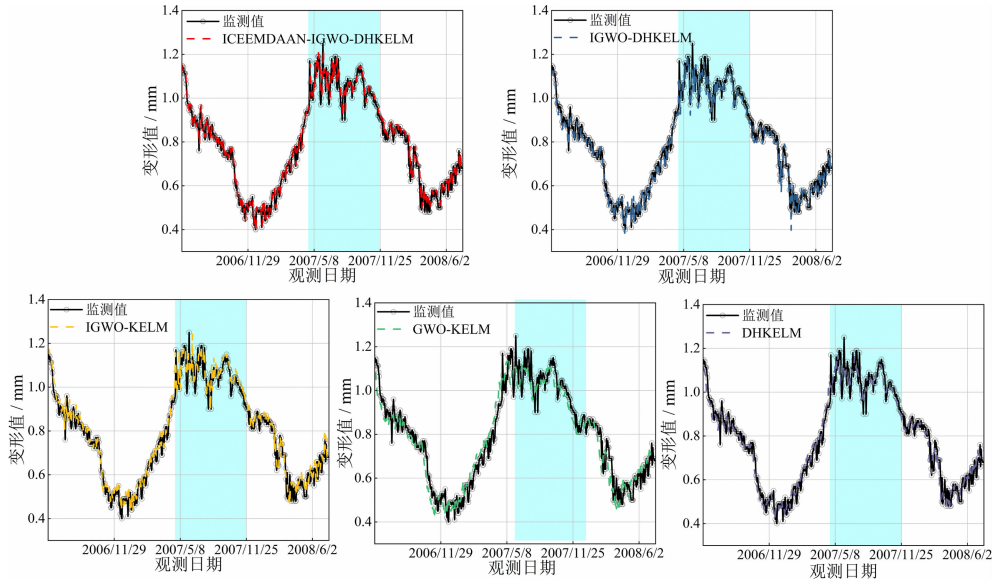

(b)重力坝变形预测结果

图 15　两种不同坝型的预测模型对比

Fig. 15　Comparison of prediction models of two different dam types

2)趋势捕捉能力方面:本文模型通过 ICEEMDAN 分解有效提取了渗流序列的非线性特征,结合 IGWO 优化算法,显著提升了趋势拟合能力. 监测值的持续下降趋势(15 下降至 9. 1)被完整复现,且滞后现象相对于对比模型较小. 而 IGWO – KELM 模型在初期(2018/6/3—2018/7/22)的预测结果整体偏离监测值,未能充分反映渗流量的趋势,表明其对复杂时序模式的适应性不足.

由图 15(b)中变形预测结果可知:

1)ICEEMDAN – IGWO – DHKELM 模型的预测曲线与监测值的整体趋势高度一致,尤其是在变形值缓慢变化阶段(2007/5/8—2007/11/25),模型预测值紧贴监测值,未出现明显的滞后或超前现象,在监测值拐点处(2008/5/1 附近),模型能够准确捕捉变形速率的细微变化,验证了其高精度特性. IGWO – DHKELM 模型对于变形趋势可以有效捕捉,但对于图中框选区域以及部分拐点,未能捕捉变形的非线性特征,因此,也体现了 ICEEMDAN 分解方法的有效性. IGWO – KELM 模型和 GWO – KELM 模型在长期预测中,预测曲线逐渐偏离监测值,尤其在末期变形值趋于稳定时,模型仍呈现缓慢下降趋势,表明其对非线性

平稳阶段的适应性较弱.

2)趋势捕捉能力方面:本文模型通过ICEEMDAN分解有效剥离了变形序列的高频噪声与低频趋势分量,结合IGWO算法动态优化DHKELM参数,使得模型能够精准捕捉重力坝变形的渐进式增长特征.在观测周期内,模型完整复现了变形值的非平稳演化过程.IGWO-KELM/GWO-KELM:未引入信号分解步骤,导致模型在初期(2006/11/29—2007/5/8)对短期波动的响应过于敏感,预测曲线呈现不合理震荡.DHKELM模型缺少优化算法支持,参数固定导致模型在长期预测中不断累积误差,末期(2008/6/2)预测值与监测值偏差显著.

由上述分析可知,ICEEMDAN-IGWO-DHKELM模型在重力坝变形预测中展现出更高的精度、更强的趋势适应性及抗噪能力,尤其在长时序、非平稳数据场景下优势显著.对比模型的预测偏差(如IGWO-KELM的末期偏离、DHKELM的局部波动)进一步验证了本文所提多方法融合框架的工程价值,为混凝土坝多测点安全监测提供了可靠的技术支持.

5 结 论

通过以上研究,得出结论如下:

1)利用分形理论对变形与环境量和变形与变形之间进行去趋势互相关性分析,通过工程案例分析可知,变形与环境量、其他测点变形之间存在长期幂律互相关,即某一变量减小可能在未来一定时间尺度内引起另一变量减小,表明两个变量的相关性具有长期持续性.说明大坝变形时间序列内部演变的波动行为不是随机的,而是具有长程相关性的有序过程.

2)在分形理论宏观分析的基础上,利用ICEEMDAN对变形监测数据进行分解处理,可以更全面地理解和分析大坝的变形行为,提高数据分析的精度和可靠性,从而为大坝的安全管理和维护提供有力支持.

3)对传统GWO算法进行优化改进,利用IGWO算法对DHKELM模型进行参数优化,构建最终多测点预测模型,通过对比结果可知,基于ICEEMDAN-IGWO-DHKELM的大坝变形多测点预测模型的预测结果更接近实测位移,可实现大坝安全状态的及时监测和评估.

参考文献:

[1] 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.

[2] Kang F,Wu Y R,Ma J T,et al. Structural identification of super high arch dams using Gaussian process regression with improved salp swarm algorithm[J]. Engineering Structures,2023,286:116150.

[3] Sivasuriyan A,Vijayan D S,Munusami R,et al. Health assessment of dams under various environmental conditions using structural health monitoring techniques: A state-of-art review[J]. Environmental Science and Pollution Research,2022,29(57):86180-86191.

[4] Wang S W,Gu C S,Liu Y,et al. Displacement observation data-based structural health monitoring of concrete dams: A state-of-art review[J]. Structures,2024,68:107072.

[5] Chen X D,Lu Q H,Guo H D,et al. Prediction of arch dam deformation considering the coupling impact of external environmental changes and structural characteristics[J]. Structures,2025,71:108056.

[6] Jia D Y,Yang J,Sheng G L. Dam deformation prediction model based on the multiple decomposition and denoising methods[J]. Measurement,2024,238:115268.

[7] Shan J Z,Zhang X,Liu Y W,et al. Deformation prediction of large-scale civil structures using spatiotemporal clustering and empirical mode decomposition-based long short-term memory network[J]. Automation in Construction,2024,158:105222.

[8] Hu J,Ma F H. Statistical modelling for high arch dam deformation during the initial impoundment period[J]. Structural Control and Health Monitoring,2020,27(12):e2638.

[9] Tatin M,Briffaut M,Dufour F,et al. Thermal displacements of concrete dams: Accounting for water temperature in statistical models[J]. Engineering Structures,2015,91:26-39.

[10] Wang S W,Sui X P,Liu Y,et al. Prediction and interpretation of the deformation behaviour of high arch dams based on a measured temperature field[J]. Journal of Civil Structural Health Monitoring,2023,13(2-3):661-675.

[11] Gu H,Yang M,Gu C S,et al. A factor mining model with optimized random forest for concrete dam deformation monitoring[J]. Water Science and Engineering,2021,14(4):330 – 336.

[12] Zhang Y,Zhong W,Li Y L,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.

[13] Zhou B,Wang Z X,Fu S Y,et al. Dam deformation prediction model based on multi – scale adaptive kernel ensemble[J]. Water,2024,16(13):1766.

[14] Cai S,Gao H X,Zhang J,et al. A self – attention – LSTM method for dam deformation prediction based on CEEMDAN optimization[J]. Applied Soft Computing,2024,159:111615.

[15] Hu J,Ma F H. Comparison of hierarchical clustering based deformation prediction models for high arch dams during the initial operation period[J]. Journal of Civil Structural Health Monitoring,2021,11(4):897 – 914.

[16] Pan J W,Liu W J,Liu C W,et al. Convolutional neural network – based spatiotemporal prediction for deformation behavior of arch dams[J]. Expert Systems with Applications,2023,232:120835.

[17] Guo J J,Xu Y Q,Hu S W,et al. Dam concrete quality evaluation and prediction model based on fractal characteristics of elastic – wave computed tomography[J]. Journal of Materials Research and Technology,2023,27:4224 – 4235.

[18] Yang C T,Huang R D,Liu D W,et al. Analysis and warning prediction of tunnel deformation based on multifractal theory[J]. Fractal and Fractional,2024,8(2):108.

[19] Ou B,Zhang C Y,Xu B,et al. Innovative approach to dam deformation analysis: Integration of VMD,fractal theory,and WOA – DELM[J]. Structural Control and Health Monitoring,2024,2024:1710019.

[20] Jia D Y,Yang J,Ma C H,et al. Research on arch dam deformation prediction method based on interpretability clustering and panel data model[J]. Engineering Structures,2025,329:119794.

[21] 何金平,施玉群,龚静. 混凝土坝时效变形特性研究[J]. 长江科学院院报,2010,27(6):18 – 22.
He J P,Shi Y Q,Gong J. Study on variation laws of time – dependent deformation of concrete dams[J]. Journal of Yangtze River Scientific Research Institute,2010,27(6):18 – 22.

[22] Acikgoz T,Gokten S,Soylu A B. Multifractal detrended cross – correlations between green bonds and commodity markets: An exploration of the complex connections between green finance and commodities from the econophysics perspective[J]. Fractal and Fractional,2024,8(2):117.

[23] Kojić M,Mitić P,Minović J. Gold and sustainable stocks in the US and EU: Nonlinear analysis based on multifractal detrended cross – correlation analysis and granger causality[J]. Fractal and Fractional,2023,7(10):738.

[24] Emeksiz C,Tan M. Wind speed estimation using novelty hybrid adaptive estimation model based on decomposition and deep learning methods (ICEEMDAN – CNN)[J]. Energy,2022,249:123785.

[25] Kang X Y,Li Y L,Zhang Y,et al. PCA – IEM – DARNN: An enhanced dual – stage deep learning prediction model for concrete dam deformation based on feature decomposition[J]. Measurement,2025,242:115664.

[26] Bommidi B S,Teeparthi K,Kosana V. Hybrid wind speed forecasting using ICEEMDAN and transformer model with novel loss function[J]. Energy,2023,265:126383.

[27] 龙江,左生龙,徐朗,等. 基于影响因子筛选和 GWO – KELM 的大坝变形预测模型[J]. 中国农村水利水电,2024(8):194 – 199 + 207.
Long J,Zuo S L,Xu L,et al. Dam deformation prediction model based on impact factors screening and GWO – KELM[J]. China Rural Water and Hydropower,2024(8):194 – 199 + 207.

[28] Chen X D,Sun W H,Liu Y J,et al. Considering integrated information on environmental features and neighborhood deformation: A missing value filling framework for arch dam deformation sequence[J]. Advanced Engineering Informatics,2025,63:102959.

[29] 张文伟. 考虑监测序列时空特征的混凝土坝位移智能预测研究[D]. 西安:西安理工大学,2024.
Zhang W W. Intelligent prediction of concrete dam displacement considering spatio – temporal characteristics of monitoring sequences [D]. Xi'an: Xi'an University of Technology, 2024.

[30] 张新生,聂达文,陈章政. 基于 MIC 特征提取与 ICEEMD – RIME – DHKELM 的建筑业碳排放预测模型[J]. 环境工程,2025,43(4):46 – 58.
Zhang X S,Nie D W,Chen Z Z. Research on a prediction model for carbon emissions of construction industry based on MIC feature extraction and ICEEMD – RIME – DHKELM[J]. Environmental Engineering,2025,43(4):46 – 58.

(编　辑:王丽娟)