

张波, 程雪辰, 罗炜, 等. 基于 VAE 和 INGO-ResNet-Informer 的双阶段混凝土坝位移预测模型[J]. 水利水电技术(中英文), 2026, 57(9): 233-244. DOI: 10.13928/j.cnki.wrahe.2026.09.018

ZHANG Bo, CHENG Xuechen, LUO Wei, et al. A two-stage concrete dam displacement prediction model based on VAE and INGO-ResNet-Informer[J]. Water Resources and Hydropower Engineering, 2026, 57(9): 233-244. DOI: 10.13928/j.cnki.wrahe.2026.09.018

基于 VAE 和 INGO-ResNet-Informer 的双阶段 混凝土坝位移预测模型

张 波^{1,2,3}, 程雪辰^{1,2,3}, 罗 炜^{1,2}, 陈 健^{1,2,3}

(1. 长江勘测规划设计研究有限责任公司, 湖北 武汉 430010; 2. 水资源工程与调度全国重点实验室, 湖北 武汉 430072; 3. EPC 管理技术创新中心, 湖北 武汉 430010)

摘 要:【目的】位移是内外环境双重作用下大坝运行态势和结构性态最直观可靠的反映, 建立科学合理的大坝安全监控模型对保障其安全运行具有重要意义。【方法】针对混凝土坝位移监测数据呈现复杂非线性、多样且时变的特征, 为提高大坝性态分析的准确性, 提出一种基于变分自编码器(VAE)、改进北方苍鹰优化算法(INGO)、残差神经网络(ResNet)和 Informer 的双阶段混凝土坝位移预测模型。首先, 通过 VAE 对温度监测数据进行潜在空间建模与非线性特征提取; 然后, 利用改进 ResNet 对多源输入影响因子进行深层表征, 引入 Informer 模型捕捉数据中的长时间依赖信息, 并采用多种策略改进得到的 INGO 算法对模型关键超参数进行自适应调节, 实现对坝体位移的精确建模。【结果】以某混凝土拱坝位移监测数据为例, 将所提模型与传统预测模型进行对比, 结果显示, 所提模型可以准确预测大坝位移变化趋势, 在各测点位移数据测试集上的 RMSE、MAE 和 R^2 均为最优。【结论】所提模型在预测精度、稳定性及残差抑制能力等方面均具有显著优势, 可为混凝土坝安全监测与运行管理提供技术支撑。

关键词: 混凝土坝位移预测; 变分自编码器; 残差神经网络; Informer; 改进北方苍鹰优化算法; 影响因素; 预测模型

DOI: 10.13928/j.cnki.wrahe.2026.09.018

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(2026)09-0233-12



A two-stage concrete dam displacement prediction model based on VAE and INGO-ResNet-Informer

ZHANG Bo^{1,2,3}, CHENG Xuechen^{1,2,3}, LUO Wei^{1,2}, CHEN Jian^{1,2,3}

(1. Changjiang Survey, Planning, Design and Research Co., Ltd., Wuhan 430010, Hubei, China; 2. State Key Laboratory of Water Resources Engineering and Management, Wuhan 430072, Hubei, China; 3. Technology Innovation Center for Engineering, Procurement, and Construction (EPC) management, Wuhan 430010, Hubei, China)

收稿日期: 2025-05-19; 修回日期: 2025-06-27; 录用日期: 2025-07-20; 网络出版日期: 2026-04-20

基金项目: 国家重点研发计划(2022YFC3005504); 长江勘测规划设计研究有限责任公司生产类自主创新科研项目(CX2023S056)

作者简介: 张 波(1979—), 男, 高级工程师, 硕士, 主要从事水利工程 EPC 管理研究。E-mail: zhangbo@cjwsjy.com.cn

通信作者: 陈 健(1990—), 男, 工程师, 博士, 主要从事大坝安全监控及 EPC 管理研究。E-mail: chenjian_cjsj@163.com

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

Abstract: [Objective] Displacement is the most intuitive and reliable reflection of the dam's operating status and structural behavior under the dual effects of internal and external environments. Establishing a scientific and reasonable dam safety monitoring model is of great significance to ensure its safe operation. [Methods] To address the complex nonlinear, diverse, and time-varying characteristics of concrete dam displacement monitoring data, a two-stage concrete dam displacement prediction model based on Variational Autoencoder (VAE), Improved Northern Goshawk Optimization (INGO) algorithm, Residual Neural Network (ResNet) and Informer is proposed to improve the accuracy of dam behaviour analysis. Firstly, VAE is used to perform latent space modeling and nonlinear feature extraction on temperature monitoring data. Then, the improved ResNet is utilized to deeply characterize the multi-source input impact factors, the Informer model is introduced to capture the long-term dependency information in the data, and the INGO algorithm, enhanced with multiple strategies, adaptively tunes the key hyperparameters of the model to achieve precise modeling of dam displacement. [Results] Taking the displacement monitoring data of a concrete arch dam as an example, the proposed model is compared with the traditional prediction model. And the result demonstrate that the proposed model can accurately predict the dam displacement trend, achieving the best $RMSE$, MAE and R^2 values on the displacement data test set of each measuring point. [Conclusion] The proposed model exhibits significant advantages in prediction accuracy, stability and residual suppression ability, providing technical support for the safety monitoring and operation management of concrete dams.

Keywords: concrete dam displacement prediction; variational autoencoder; residual neural network; Informer; improved northern goshawk optimization algorithm; influencing factor; prediction model

0 引 言

随着我国水利水电建设的快速发展,大批重力坝、拱坝等混凝土坝工程陆续投入运行。我国现有水库大坝中,坝龄超过 45 年的占比超过 87%^[1],这些大坝在运行过程中受水库水位波动、温度季节性变化和筑坝材料性能下降等多种复杂因素的耦合作用,结构性态退化与病害演化趋势日益凸显^[2-3]。一旦坝体发生异常变化,不仅可能导致坝体破坏,还将给下游地区人员的生命财产安全带来严重威胁。因此,开展大坝安全监测研究,针对坝体位移、渗流、裂缝等效应量进行准确建模和预测,对于及时识别潜在风险、制定合理的运行维护与应急预案和保证大坝运行安全具有十分重要的工程意义与社会价值。

坝体位移是反映其结构响应和运行状态的重要指标,构建一个高精度、强泛化能力的预测模型具有重要的工程意义与研究价值^[4]。由于坝体响应行为受到多种复杂因素的耦合作用,传统基于线性回归的预测模型在处理高度非线性、强时序依赖性的监测数据时存在明显局限^[5]。随着人工智能技术的飞速发展,众多学者开始将机器学习方法用于构建大坝安全监控模型,有效弥补了线性回归模型的不足与缺陷^[6-7]。赵昕等^[8]提出了一种基于改进 ECLAT 关联规则算法的坝顶垂直位移预测模型,通过对大坝变形的海量监测数据进行挖掘,筛选出影响坝体位移的主要影响因素,并在考虑温度变化对垂直位移具有滞后影响的基础上对坝体位移进行预测。冯瑜等^[9]提出了一种基

于鲸鱼优化算法 (Whale Optimization Algorithm, WOA) 优化随机森林回归 (Random Forest Regression, RFR) 的混凝土坝变形预测模型,利用 WOA 算法对 RFR 的关键超参数进行寻优,显著提高了预测模型的精度和泛化性能。

近年来,基于深度学习的时序建模方法逐渐成为大坝位移预测研究的热点方向^[10-11]。高睿颖等^[12]采用融合双重注意力机制的门控循环单元 (Gated Recurrent Unit, GRU) 对大坝位移进行预测,显著提高了模型的预测精度。曹梦茜和郑东健^[13]采用 WOA 算法对长短期记忆网络 (Long Short-Term Memory network, LSTM) 的关键超参数进行寻优,实现了较好的准确性和适用性。施彦形等^[14]提出了一种基于卷积神经网络 (Convolutional Neural Network, CNN)、注意力机制与 LSTM 的深度学习预测模型,其准确预测了多个测点的位移,具有较高的预测精度和较强的稳定性。丁勇康等^[15]耦合 KAN (Kolmogorov-Arnold Networks) 机制改进了 LSTM 的全连接层结构,并采用多策略改进的哈里斯鹰优化算法 (Harris Hawk Optimization, HHO) 搜寻模型的最佳参数,进而提出了基于 IHHO-LSTM-KAN 的大坝变形预测模型,实现了大坝全生命周期变形精准预测。

然而,若直接将原始温度实测数据作为位移预测模型的输入,则可能由于温度因子维度高、时序性强和信息冗余等特性,导致模型复杂度过高、训练过程出现过拟合或收敛缓慢等问题^[16-17]。为此,缪新颖等^[18]采用主成分分析 (Principal Component

Analysis, PCA)对环境因子进行去耦和降维,以降低输入因子间的多重共线性;马春辉等^[19]采用核主成分分析(Kernel Principal Component Analysis, KPCA)对输入因子进行降维,提高模型的计算效率。方卫华等^[20]采用本征正交分解(Proper Orthogonal Decomposition, POD)对高维实测数据求取特征正交基,减少了自变量的个数和克服了变量间的多重共线性问题。上述线性降维方法在处理非线性时序数据时,难以充分捕捉温度数据中蕴含的深层非线性结构特征^[21-22]。

针对上述问题,有机结合变分自编码器(Variational AutoEncoder, VAE)、改进北方苍鹰优化算法(Improved Northern Goshawk Optimization algorithm, INGO)、改进残差神经网络(Residual Neural Network, ResNet)和Informer模型,充分挖掘各方法的数据处理优势,提出了基于VAE与INGO-ResNet-Informer的双阶段混凝土坝位移预测模型,即V-INRInformer。首先,利用VAE对温度监测数据进行隐变量学习与特征压缩,有效提取潜在温度特征;然后采用改进ResNet对多源输入因子进行深层表征,借助Informer模型对序列的时间依赖性进行建模,获取最终位移预测结果。为提升所建模型的综合性能,引入INGO算法对模型的关键超参数进行寻优,显著提高了模型的预测精度和泛化能力。通过对某混凝土拱坝监测数据进行分析,验证了所提模型的可行性和有效性。

1 方法与理论

1.1 变分自编码器

变分自编码器(VAE)^[23]是一种基于贝叶斯推断的生成模型,其核心目标是学习输入数据在潜空间中的概率分布表示。在大坝温度监测数据中,VAE能够有效提取其低维隐变量,减少冗余信息,增强特征表达能力,从而为后续的预测建模提供信息密度更大的输入。

VAE主要由编码器和解码器两个子网络组成。编码器网络将输入数据 x 映射成潜空间中服从某一概率分布的隐变量 z 。为增强网络的学习性,通常假设隐变量 z 服从多维高斯分布,其公式为

$$q_{\phi}(z|x) = N[z; \mu(x), \sigma^2(x)] \quad (1)$$

式中, $\mu(x)$ 、 $\sigma^2(x)$ 分别为输入数据 x 的均值和方差; ϕ 为变分参数; $q_{\phi}(z|x)$ 为编码器网络输出的后验概率分布。

解码器网络以隐变量 z 为输入,通过神经网络重构原始输入数据,其条件概率分布表达式为

$$p(x, z) = f(z; \theta) \quad (2)$$

式中, θ 为生成参数; $f(z; \theta)$ 为内含参数 θ 的神经网络。

在训练过程中,VAE通过最大化变分下界(ELBO)对数据进行重构,目标函数为

$$\mathcal{L}_{\text{VAE}}(\theta, \phi; x) = \mathbb{E}_{q_{\phi}(z|x)}[\log p_{\theta}(x|z)] - D_{\text{KL}}[q_{\phi}(z|x) \parallel p(z)] \quad (3)$$

式中, $p_{\theta}(x|z)$ 为解码器网络输出的条件概率分布; $\mathbb{E}_{q_{\phi}(z|x)}[\log p_{\theta}(x|z)]$ 为VAE的重构误差; $D_{\text{KL}}[q_{\phi}(z|x) \parallel p(z)]$ 为VAE的Kullback-Leibler散度; $p(z)$ 为隐变量 z 的先验分布。

通过上述过程,VAE能够对温度监测数据实现有效的特征提取,充分挖掘其潜在的空间结构与变化规律。

1.2 改进残差神经网络

为解决深层神经网络在训练过程中可能出现的退化问题,HE等^[24]提出了残差神经网络(ResNet),通过在局部区域内引入恒等映射实现短路连接,从而使梯度能够在网络中更好地反向传播,有效缓解了梯度消失、梯度爆炸等问题,其基本残差单元如图1所示。




图1 残差模块结构

Fig. 1 The architecture of residual block

残差模块的输出 y 可表示为

$$y = x + F(x) \quad (4)$$

式中, x 为残差模块的输入; $F(x)$ 为卷积操作后输出。

该结构允许网络在深层结构中保留输入特征的原始信息,并在训练过程中通过梯度的直接传播提升网络的稳定性与收敛速度。在反向传播过程中,根据链式法则可得其损失函数的梯度传播过程为

$$\frac{\partial \mathcal{E}}{\partial x} = \frac{\partial \mathcal{E}}{\partial y} \left(\frac{\partial F}{\partial x} + 1 \right) \quad (5)$$

式中, $\mathcal{E}$ 为损失函数。

由于梯度在传播时始终存在一项“1”,可确保网络深层的梯度不会为0,从而有效避免梯度消失问

题。但原始的残差结构中简单的相加操作可能导致部分原始信息丢失,为此,本文采用了一种改进ResNet进行特征提取,即利用通道级的堆叠操作代替原有的加法操作,在保留原始特征的基础上融合卷积特征,可有效捕捉输入特征之间的深层耦合关系,提升模型的特征表达能力,改进残差模块的输出 y 可表示为

$$y = x \oplus F(x) \quad (6)$$

式中, $\oplus$ 为通道堆叠操作。

1.3 Informer 模型

在大坝位移预测过程中,输入特征序列通常具有较强的时序依赖性和周期性。Informer模型^[25]不仅可以降低计算复杂度,还能保留全局注意特性,适用于处理大坝、桥梁等复杂系统中高维、长序列的监测数据,其结构如图2所示。




图2 Informer 模型架构

Fig. 2 The architecture of Informer

Informer模型主要由编码器和解码器两个子网络构成,均基于稀疏自注意力机制展开。不同于传统Transformer模型中的全连接注意力机制,Informer仅选择少量与当前查询项相关性较强的关键位置进行计算,从而将注意力计算的复杂度从 $O(L^2)$ 降低至 $O(L\log L)$,能够显著缩减冗余计算,提高对长序列建模的效率。

Informer模型的编码器网络采用多层堆叠的稀疏多头注意力机制,用于提取输入序列中的关键变化模式;解码器网络则通过屏蔽注意力结构,确保预测仅依赖于过去信息,符合大坝位移因果建模的逻辑。为增强模型对时间特性的感知能力,Informer引入了时间嵌入机制,即时间戳 t 被映射为高维向量 T_t ,该向量与原始输入序列联合输入模型,其表达式为

$$X_{t'} = X_t \oplus T_t \quad (7)$$

式中, $\oplus$ 为特征拼接操作; X_t 为 t 时刻的观测数据。

1.4 改进北方苍鹰优化算法

北方苍鹰优化算法(NGO)^[26]是一种受北方苍鹰捕食行为启发而提出的智能方法。为了增强NGO算法在复杂参数寻优问题中的稳定性与收敛能力,提出了一种改进北方苍鹰优化算法(INGO),通过引入自适应步长机制与精英引导策略,实现了对算法全局搜索能力和局部开发能力的双重优化。

1.4.1 全局搜索阶段

在全局搜索阶段,为增强种群的全局探索能力,同时避免后期震荡,采用随迭代动态变化的自适应步长机制更新个体位置,改进后的位置更新公式为

$$X_i^{new} = X_j + \omega(t) \cdot r_1 \cdot (X_j - r_2 \cdot X_i) \quad (8)$$

$$\omega(t) = \omega_{max} - \frac{t}{T_{max}}(\omega_{max} - \omega_{min}) \quad (9)$$

式中, X_i^{new} 为第 i 个个体更新后的位置; X_i 为第 i 个个体在第 t 次迭代时的位置; X_j 为种群中任一更优的个体; r_1 、 r_2 为 $[0, 1]$ 内的随机数; $\omega(t)$ 为第 t 次迭代时的权重因子; ω_{max} 、 ω_{min} 分别为自适应步长系数的最大值与最小值; T_{max} 为最大迭代次数。

该机制使NGO算法在搜索初期具备较大跳跃性,后期逐步细化收敛,有助于提升全局最优区域的发现能力。

1.4.2 追捕与逃逸阶段

为加快向最优解的收敛速度,提升局部搜索能力,引入精英引导策略,在每轮迭代结果中选取最优个体位置 X_{elite} 作为引导中心,并结合随机扰动与追踪项对个体位置进行更新,其表达式为

$$X_i^{new} = X_i + r_3 \cdot \left(R \cdot \frac{X_{elite} - X_i}{T_{max}} \right) + r_4 \cdot (X_{rand} - X_i) + \eta \cdot (X_{elite} - X_{rand}) \quad (10)$$

式中, X_{rand} 为当前种群中随机选取的个体; r_3 、 r_4 为 $[0, 1]$ 内的随机数; R 为攻击搜索半径; η 为精英引导系数,通常取 $0.1 \sim 0.3$;其余字母含义同上。

该策略通过融合最优个体和随机扰动的引导信息,提升了搜索路径的多样性,增强了种群对优质区域的聚集能力。

1.5 模型构建流程

综合运用上述方法和理论,构建了基于VAE和INGO-ResNet-Informer的双阶段混凝土坝位移预测模型,模型构建流程图如图3所示,具体实现过程如下。

Step 1: 依据HTT模型^[27]构建输入因子集 $[H^1, H^2, H^3, H^4, T_1, T_2, T_3, \dots, T_n, \theta, \ln\theta]$,其中

H 为上游水位; T 为温度计实测数据; n 为温度计个数; $\theta = t/100$; t 为监测累计天数。

Step 2: 利用 VAE 对温度监测数据进行特征重构, 提取其潜在变量, 进而以较少的隐变量代替原始温度监测数据。

Step 3: 采用改进 ResNet 对构建的输入因子集进行深层特征提取, 充分挖掘输入变量间的非线性关系与局部时序特征。

Step 4: 引入 Informer 模型对混凝土坝位移的时间序列进行建模, 利用其稀疏自注意力机制提升长序列建模效率, 挖掘时序中的全局依赖性。

Step 5: 利用 INGO 算法对 ResNet-Informer 模型的节点数、学习率、Dropout 和批大小 4 个超参数进行寻优, 以提升模型的预测性能和泛化能力。

Step 6: 计算模型预测结果的多项性能评价指标, 并与对照模型的预测结果进行对比分析, 验证所提模型处理混凝土坝位移预测时的精度、泛化性能和稳定性。

2 工程实例

2.1 工程概况

某水电站位于四川省雅砻江下游, 其大坝为混凝土双曲拱坝, 坝高 240 m, 坝顶弧长 774.69 m。坝体内部位移、温度监测仪器的分布如图 4、图 5 所示。




图 4 水平位移监测点布置

Fig. 4 Arrangement of horizontal displacement monitoring points




图 3 模型构建流程

Fig. 3 Flowchart of the proposed model

选取位于 21[#]坝段的测点 PL21-2、IP21-2 从 2014 年 1 月 1 日至 2018 年 12 月 31 日的顺河向水平位移监测数据进行分析, 其中 2014 年 1 月 1 日至 2017 年




图 5 温度传感器布置(高程单位: m)

Figure 5 Arrangement of temperature sensors(Elevation Unit: m)

12 月 31 日的监测数据用作训练集, 序列长度为 1461; 2018 年 1 月 1 日至 2018 年 12 月 31 日的监测数据用作测试集, 序列长度为 365。上游水位和测点位移过程线如图 6 所示。

2.2 温度分量重构

为降低温度数据中冗余信息、强噪声等对预测模型性能的影响, 采用 VAE 对温度监测数据进行特征提取, 并使用其生成的隐变量代替原始温度监测数据用于后续建模。为验证隐变量能够有效表征温度数据的主要特征, 利用 VAE 的隐变量生成能力对测点 T16、T36 和 T49 的温度数据进行特征提取与重构, 并与原始温度数据进行对比, 3 个测点的实测温度与重构温度过程线如图 7 所示。由图 7 可知, VAE 重构得到的温度数据整体上较好地保持了实测温度的变化趋势, 同时对实测温度中的短时剧烈波动进行了有效平滑。考虑到此类短期温度波动对大坝位

移预测效果的影响, 若直接将包含剧烈波动的原始实测数据用于建模, 可能会引入不必要的噪声, 降低模型的预测精度。因此, 使用 VAE 提取的隐变量作为温度输入特征, 有助于提高模型的稳健性与预测效果。

2.3 模型参数设置

由于水位、温度和时间等输入变量在数值尺度上存在较大差异, 因此对各类变量进行归一化处理, 公式为

$$x' = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (11)$$

式中, x 为原始数据; $x_{\max}$ 、 $x_{\min}$ 分别为最大值和最小值; x' 为归一化数据。

为验证 INGO 算法的可行性和高效性, 将其与粒子群优化算法 (Particle Swarm Optimization, PSO)、灰狼优化算法 (Grey Wolf Optimizer, GWO) 和常规 NGO 算法进行对比, 算法种群规模均设为 100, 最大




图6 水位和测点位移过程线

Fig. 6 Curves of water level and displacement of measurement points




图7 实测温度和重构温度过程线

Fig. 7 Curves of actual temperature and reconstructed temperature

迭代次数均设为 50, 选用训练集与测试集的均方误差 (MSE) 的平均值作为适应度函数, 对 ResNet-Informer 模型的节点数、学习率、Dropout 和批大小 4 个参数进行寻优。测点 PL21-2 的寻优过程线如图 8 所示。由图 8 可知, INGO 算法寻优速度最快, 在第 19 次迭代时达到最小适应度值, 且最终适应度值比其他优化算法更小, 说明其对模型参数的寻优过程显著优于其他算法, 具有较好的适应性。ResNet-Informer 模型参数优化范围及寻优结果如表 1 所列。

2.4 模型预测效果

2.4.1 预测过程线分析

为验证本文所提模型的可行性和准确性, 将其与 VAE-ELM (V-ELM)、VAE-LSTM (V-LSTM)、VAE-CNN-LSTM (V-CLSTM)、VAE-Informer (V-Informer) 和




图8 适应度变化过程线

Fig. 8 Variation curve of fitness

表1 参数寻优区间及结果

Table 1 Hyperparameter optimization range and results

优化参数	优化范围	PL21-2	IP21-2
ResNet 节点数	[16, 128]	128	16
学习率	[0.000 1, 1]	0.001	0.005
Dropout	[0, 1]	0.20	0.15
批大小	[0, 128]	32	32

INGO-ResNet-Informer (INRInformer) 共 5 种对照模型进行对比分析, 前 4 种对照模型的超参数通过网格寻优算法确定。

基于 2.3 节寻优获得的模型最优参数, 分别构建了测点 PL21-2、IP21-2 的最佳位移预测模型, 得到了两个测点的位移过程线。同时, 利用 5 种对照模型分别对测点 PL21-2、IP21-2 的位移进行训练和预测, 预测结果如图 9 所示, 模型预测残差分布如图 10 所





图 9 位移预测结果对比

Fig. 9 Comparison of displacement prediction results





图 10 测试集残差分布

Fig. 10 Residual distribution of test set

示。由图 9 可知,所有模型在整体上均能较好地跟踪实测位移过程线的变化趋势,在一定程度上捕捉了数据中的主要特征模式,证实了所提模型和对照模型的有效性,但各模型预测性能存在较大差异。具体来看,V-ELM 模型预测两个测点的位移时,所得预测位移过程线明显偏离实测位移过程线,且部分过程线波动较大,表现出较差的预测能力;相比之下,其他基于深度学习方法的模型预测结果较好,尤其是 V-INRInformer 模型的预测位移过程线与实测位移过程线吻合度较高,证明其具有较强的复杂趋势学习能力和良好的泛化性能。由图 10 可知,V-INRInformer 模型对两个测点位移的预测残差分布范围均较小,中值与零均最接近,并且箱体均最短,表明其预测值与实

测值的差异较小,具备较高的预测精度和较强的稳定性。

2.4.2 评价指标统计分析

为进一步定量评估所提模型的综合性能,选用均方根误差(RMSE)、平均绝对误差(MAE)和决定系数(R^2)度量其预测值与实测值间的差异,其公式为

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (12)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2}$$

(14)

式中, $\hat{y}_i$ 、 y_i 分别为样本的预测值和实测值; $\bar{y}$ 为样本的平均值; n 为样本长度。

各模型的预测性能评价指标计算结果如表 2 所列,评价指标雷达图如图 11 所示。由表 2 可知, V-INRInformer 模型的评价指标结果均为最佳,即 $RMSE$ 和 MAE 最小, R^2 最大,定量说明所提模型的预测值和实测值接近,其预测准确性、稳定性和泛化性较好。

3 结果讨论

3.1 预测结果讨论

以各模型对测点 PL21-2 的位移预测结果进行分析, V-ELM 模型的预测精度最低, R^2 仅为 0.970,表明其无法准确捕捉大坝变形与影响因子间复杂非线性映射关系,这主要是由于 ELM 的浅层结构和静态建模特性导致其在预测过程中存在低阶非线性拟合不足、长期依赖性忽略等局限^[28];基于深度学习方法 V-LSTM、V-CLSTM 模型的预测精度较高,主要得益于 LSTM 的门控循环结构和层次化特征学习可以较

好的学习位移序列的动态演化规律,其中 V-CLSTM 中的卷积结构具备较强的局部特征提取能力^[29],使得 $RMSE$ 进一步降至 1.955 mm, R^2 提高至 0.988,这与 YANG 等^[30]的研究结论一致。然而, LSTM 模型循环结构对序列依赖性较强^[31], CNN 提取水位、温度和时效因子的特征时,可能导致低层特征在高层次卷积中被稀释或丢失^[32],降低预测模型的综合性能。基于 Transformer 架构的 V-Informer 模型内含 ProbSparse 自注意力机制,能够精确捕捉温度对位移的长期滞后影响,可有效提升模型的时间序列建模能力和全局依赖性学习能力^[33],因此,在本文中其 R^2 高达 0.992。基于此, V-INRInformer 模型通过引入残差连接,不仅缓解了常规卷积网络引发的梯度消失问题,还增强了序列特征提取的深度与稳定性,使得 R^2 达到 0.996,具备更强的特征表达能力。总体来看, V-INRInformer 模型的 $RMSE$ 分别较 V-ELM、V-LSTM、V-CLSTM 和 V-Informer 分别降低了 63.9%、61.3%、43.4%、32.3%,模型预测精度得到较大提升。对于测点 IP21-2, V-INRInformer 模型的 R^2 为 0.990,同样展现出较高的预测精度,证实了 V-INRInformer 模型具备较好的泛化性、稳定性和准确性。

表 2 评价指标结果

Table 2 Comparison results of evaluation indicators

模 型	PL21-2			IP21-2		
	$RMSE/mm$	MAE/mm	R^2	$RMSE/mm$	MAE/mm	R^2
V-ELM	3.072	2.557	0.970	0.140	0.112	0.974
V-LSTM	2.862	2.256	0.974	0.130	0.115	0.977
V-CLSTM	1.955	1.714	0.988	0.129	0.110	0.978
V-Informer	1.635	1.358	0.992	0.107	0.092	0.985
INRInformer	1.618	1.285	0.992	0.096	0.078	0.988
V-INRInformer	1.107	0.883	0.996	0.088	0.073	0.990




图 11 误差指标雷达图

Fig. 11 Radar chart of error index results

通过对比 INRInformer 模型和 V-INRInformer 模型对测点 PL21-2、IP21-2 位移的预测结果可知, VAE 使 INRInformer 模型的 *RMSE* 分别下降了 31.58%、8.33%, *MAE* 分别下降了 31.28%、3.85%, 充分验证了所提模型融合 VAE 的可行性和有效性。实测温度数据常受传感器噪声和周期性波动干扰, 在保持网络结构不变的前提下, 采用 VAE 生成的隐变量代替原始温度数据作为输入, 借助其变分推断过程对温度场中的确定性趋势与随机噪声进行分离^[34], 可以显著降低实测温度数据中噪声的干扰, 提高了模型的稳定性与预测精度, 这与 SHU 等^[35]采用 VAE 进行环境因子特征提取时得到的结论一致。

3.2 分量重要性分析

为评估水压分量、温度分量和时效分量对大坝位移的影响程度, 本文参考文献[36]采用随机森林模型(Random Forests, RF)分析影响因子的重要性, 具体步骤为: 基于影响因子集和位移数据构建 RF 模型, 采用 Gini 指数法计算各影响因子的权重, 将对应分量影响因子的权重相加, 即可得到每个分量占大坝位移的比例。测点 PL21-2、IP21-2 的分量计算结果如表 3 所列。由表 3 可知, 平均水压分量、温度分量和时效分量占比依次为 53.715%、16.915%、29.37%, 水压分量占比最大, 表明水压荷载是影响大坝顺河向水平位移的主要因素, 这与统计模型^[37]的分析结果一致。

表 3 分量占比计算结果

Table 3 Calculation results of component proportion

测 点	水压分量/%	温度分量/%	时效分量/%
PL21-2	57.45	18.69	23.86
IP21-2	49.98	15.14	34.88

4 结 论

本文提出了一种基于 VAE 和 INGO-ResNet-Informer 的双阶段混凝土坝位移预测模型, 通过对某混凝土拱坝实测位移数据进行分析, 验证所提模型具有较高的预测精度、较强的鲁棒性和泛化性能。主要结论如下。

(1)通过 VAE 提取的隐变量能够有效表征温度监测数据的内在特征, 显著降低了原始温度数据中的噪声干扰, 使得模型的 *RMSE*、*MAE* 均出现了不同程度的下降, 充分验证了该方法对提升预测模型性能的有效性; 同时, 改进 ResNet 能够从输入因子中挖掘深层次特征, 捕捉复杂的空间模式与非线性关系, 有

效增强了模型对潜在数据规律的识别能力; Informer 模型内含稀疏自注意机制, 能够有效捕捉大坝位移数据中的长期依赖关系与非线性时间动态特征, 有助于提升模型的预测精度。

(2)引入自适应步长机制与精英引导策略对 NGO 算法进行改进, 提高了算法的迭代速度和寻优精度。同时, 利用 INGO 算法对 ResNet-Informer 模型的超参数进行寻优, 降低了参数设置对模型性能的影响, 有效提高了模型的准确性、稳定性和泛化性能。

(3)相比于对照模型, V-INRInformer 模型在预测精度、泛化性能和鲁棒性等方面均具有良好表现。对测点 PL21-2、IP21-2 的位移数据进行预测时, V-INRInformer 模型的预测值过程线和实测值过程线的吻合度均较高, 说明其可以对大坝变形进行准确分析和预测。

本文所提模型在混凝土坝位移预测中表现出较强的竞争力, 一是为解决大坝位移预测过程中存在的非线性、时变性及多源耦合等关键技术难题提供了创新的解决方案; 二是显著提高了实际混凝土坝位移值和发展趋势的预测精度, 增强了对工程位移监测数据的解译能力, 有助于及时识别坝体异常变形行为、监测数据失真和结构局部病害等潜在问题, 为大坝运行监测、安全预警、巡检管理和调度决策等提供高质量的数据支撑, 对提升大坝运行管理的智能化水平具有重要的工程应用价值和现实意义。本文主要针对单测点位移进行建模, 未考虑测点间的关联性, 未来开展多点变形预测模型的研究。

参考文献(References):

[1] 盛金保, 李宏恩, 盛韬桢. 我国水库溃坝及其生命损失统计分析[J]. 水利水运工程学报, 2023(1): 1-15.
SHENG Jinbao, LI Hong'en, SHENG Taozhen. Statistical analysis of reservoir dam failures and loss of life in China[J]. Hydro-Science and Engineering, 2023(1): 1-15.

[2] 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 Mingchao, REN Qiubing, SHEN Yang. 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.

[3] 徐耀, 王挺, 常清睿. 大坝风险管理技术的发展与趋势探讨[J]. 水利发展研究, 2018, 18(7): 44-48.
XU Y, WANG T, CHANG Q R. Discussion on the development and trends of dam risk management technology[J]. Water Resources Development Research, 2018, 18(7): 44-48.

[4] 李明超, 任秋兵, 孔锐, 等. 多维复杂关联因素下的大坝变形动态建模与预测分析[J]. 水利学报, 2019, 50(6): 687-698.

- LI Mingchao, REN Qiubing, KONG Rui, et al. Dynamic modeling and prediction analysis of dam deformation under multidimensional complex relevance[J]. Journal of Hydraulic Engineering, 2019, 50(6): 687-698.
- [5] LI Mingchao, LI Minghao, REN Qiubing, et al. DRLSTM: A dual-stage deep learning approach driven by raw monitoring data for dam displacement prediction [J]. Advanced Engineering Informatics, 2022, 51: 101510.
- [6] LIU Mingkai, QI Yining, SU Huaizhi. Deformation prediction model for concrete dams considering the effect of solar radiation [J]. Advanced Engineering Informatics, 2025, 65: 103252.
- [7] CHEN Bo, CHEN Weinan, GONG Xueyan, et al. Prediction model for deformation of concrete dams in cold regions considering hysteresis and reduction effects from environment [J]. Chinese Journal of Geotechnical Engineering, 2021, 43(12): 2315-2322.
- [8] 赵昕, 苏怀智, 方正. 基于改进 ECLAT 算法的混凝土坝变形预测模型[J]. 中国农村水利水电, 2025(4): 58-64.
- ZHAO Xin, SU Huaizhi, FANG Zheng. A deformation prediction model for concrete dams based on improved ECLAT method [J]. China Rural Water and Hydropower, 2025, (4): 58-64.
- [9] 冯瑜, 吴云星, 谷汶静, 等. 基于 WOA-RFR 的混凝土坝变形预测监控模型[J]. 人民珠江, 2024, 45(7): 118-124.
- FENG Yu, WU Yunxing, GU Wenjing, et al. Prediction and monitoring model of concrete dam deformation based on WOA-RFR [J]. Pearl River, 2024, 45(7): 118-124.
- [10] ZHU Mingyuan, CHEN Bo, GU Chongshi, et al. Optimized multi-output LSSVR displacement monitoring model for super high arch dams based on dimensionality reduction of measured dam temperature field[J]. Engineering Structures, 2022, 268: 114686.
- [11] LU Taiqi, GU Hao, GU Chongshi, et al. A multi-point dam deformation prediction model based on spatiotemporal graph convolutional network [J]. Engineering Applications of Artificial Intelligence, 2025, 149: 110483.
- [12] 高睿颖, 顾冲时, 王岩博, 等. 基于 DBO-DA-GRU 的大坝变形预测模型[J]. 水电能源科学, 2024, 42(9): 134-138.
- GAO Ruiying, GU Chongshi, WANG Yanbo, et al. Dam deformation prediction model based on DBO-DA-GRU[J]. Water Resources and Power, 2024, 42(9): 134-138.
- [13] 曹梦茜, 郑东健. 基于 FCM-WOA-LSTM 的大坝变形预测模型及其应用[J]. 水电能源科学, 2023, 41(5): 71-75.
- CAO Mengxi, ZHENG Dongjian. Dam deformation prediction model and its application based on FCM-WOA-LSTM[J]. Water Resources and Power, 2023, 41(5): 71-75.
- [14] 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 Technology, 2024, 55(9): 121-132.
- [15] 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.
- DING Yongkang, YUAN Jin, MAO Yanpian, et al. Dam deformation prediction model based on IHHO-LSTM-KAN [J]. Water Resources and Hydropower Technology, 2025, 56(5): 170-182.
- [16] 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.
- LONG Jiang, ZUO Shenglong, XU Lang, et al. Dam deformation prediction model based on impact factors screening and GWo-KELM [J]. China Rural Water and Hydropower, 2024(8): 194-199.
- [17] 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.
- [18] 缪新颖, 单玉鹏, 纪建伟. PCA-GA-LM 模型在水库土石坝渗流预测中的应用[J]. 沈阳农业大学学报, 2021, 52(3): 377-384.
- MIAO Xinying, SHAN Yupeng, JI Jianwei. Application of PCA-GA-LM model for predicting the seepage of reservoir earth-rock dams[J]. Journal of Shenyang Agricultural University, 2021, 52(3): 377-384.
- [19] 马春辉, 杨杰, 程琳, 等. 基于 KPCA-RVM 的土石坝沉降预测模型研究[J]. 西北农林科技大学学报(自然科学版), 2017, 45(1): 211-217.
- MA Chunhui, YANG Jie, CHENG Lin, et al. KPCA-RVM based prediction model for settlement of earth-rockfill dam [J]. Journal of Northwest A & F University (Natural Science Edition), 2017, 45(1): 211-217.
- [20] 方卫华, 王润英, 孙一清. 基于降维分析的大坝安全特征提取方法及其应用研究[J]. 人民珠江, 2019, 40(1): 138-145.
- FANG Weihua, WANG Runying, SUN Yiqing. Dam safety feature extraction method based on dimensionality reduction analysis and its application[J]. Pearl River, 2019, 40(1): 138-145.
- [21] 陈斯煜, 顾冲时, 盛金保, 等. SBL 驱动的可解释性大坝变形区间预测模型[J]. 水力发电学报, 2025, 44(1): 18-29.
- CHEN Siyu, GU Chongshi, SHENG Jinbao, et al. Sparse Bayesian learning-driven interpretable interval prediction model for dam deformation [J]. Journal of Hydroelectric Engineering, 2025, 44(1): 18-29.
- [22] LEI Wei, WANG Jian. Dynamic Stacking ensemble monitoring model of dam displacement based on the feature selection with PCA-RF [J]. Journal of Civil Structural Health Monitoring, 2022, 12(3): 557-578.
- [23] KARATATLI E, CEMGIL A T, KIRBIZ S. Audio source separation using variational autoencoders and weak class supervision [J]. IEEE Signal Processing Letters, 2019, 26(9): 1349-1353.
- [24] YU Honggan, SUN Hao, TAO Jianfeng, et al. A multi-stage data augmentation and AD-ResNet-based method for EPB utilization factor prediction [J]. Automation in Construction, 2023, 147: 104734.
- [25] YANG Jiaqi, LIU Changwei, WANG Jinting, et al. Segmented sequence decomposition-Informer model for deformation of arch dam [J]. Structural Health Monitoring, 2024, 23(5): 3007-3025.
- [26] DEGHANI M, HUBÁLOVSKÝ Š, TROJOVSKÝ P. Northern

goshawk optimization: A new swarm-based algorithm for solving optimization problems[J]. IEEE Access, 2021, 9: 162059-162080.

[27] 吴中如. 水工建筑物安全监控理论及其应用[M]. 北京: 高等教育出版社, 2003.

WU Zhongru. Safety Monitoring Theory and Its Application of Hydraulic Structures[M]. Beijing: Higher Education Press, 2003.

[28] CAI Zhijian, YU Jia, CHEN Wenlong, et al. Improved extreme learning machine-based dam deformation prediction considering the physical and hysteresis characteristics of the deformation sequence [J]. Journal of Civil Structural Health Monitoring, 2022, 12: 1173-1190.

[29] 洪宇超, 钱建固, 叶源新, 等. 基于时空关联特征的 CNN-LSTM 模型在基坑工程变形预测中的应用[J]. 岩土工程学报, 2021, 43(S2): 108-111.

HONG Yuchao, QIAN Jiangu, YE Yuanxin, et al. Application of CNN-LSTM model based on spatiotemporal correlation characteristics in deformation prediction of excavation engineering [J]. Chinese Journal of Geotechnical Engineering, 2021, 43(S2): 108-111.

[30] YANG Jun, QU Jingbin, MI Qiang, et al. A CNN-LSTM model for tailings dam risk prediction[J]. IEEE Access, 2020, 8: 206491-206502.

[31] YU Yong, SI Xiaosheng, HU Changhua, et al. A review of recurrent neural networks; LSTM cells and network architectures[J]. Neural computation, 2019, 31(7): 1235-1270.

[32] LU Taiqi, GU Chongshi, YUAN Dongyang, et al. Deep learning model for displacement monitoring of super high arch dams based on measured temperature data[J]. Measurement, 2023, 222: 113579.

[33] 何志铎, 熊祖强. 基于 Informer 神经网络的工作面矿压预测研究[J]. 矿业研究与开发, 2024, 44(7): 142-148.

HE Zhihua, XIONG Zuqiang. Research on mine pressure prediction of working face based on Informer neural network [J]. Mining Research and Development, 2024, 44(7): 142-148.

[34] NIU Zijian, YU Ke, WU Xiaofei. LSTM-based VAE-GAN for time-series anomaly detection[J]. Sensors, 2020, 20(13): 1-13.

[35] SHU Xiaosong, BAO Tengfei, LI Yangtao, et al. VAE-TALSTM: A temporal attention and variational autoencoder-based long short-term memory framework for dam displacement prediction[J]. Engineering with Computers, 2022, 38: 3497-3512.

[36] 张潇. 土石坝裂缝发展及灌浆法处理工艺研究[D]. 武汉: 武汉大学, 2023.

ZHANG Xiao. Study on Crack Development and Sand Grouting Treatment Technology of Earth-Rock Dams [D]. Wuhan: Wuhan University, 2023.

[37] 闵四海. 二滩拱坝运行期坝体水平位移分析[J]. 四川水力发电, 2014, 33(4): 94-101.

MIN Sihai. Analysis of horizontal displacement of the dam body during the operational period of the Ertan arch dam [J]. Sichuan Hydro Power, 2014, 33(4): 94-101.

(责任编辑 李侃家)