

基于概率性预测的抽水蓄能电站大坝渗流安全监控模型

李心如^{1,2}, 宋锦焘^{1,2}, 杨杰^{1,2}, 许增光^{1,2}

(1. 西安理工大学水利水电学院, 陕西 西安 710048;

2. 西安理工大学省部共建西北旱区生态水利国家重点实验室, 陕西 西安 710048)

摘要:针对抽水蓄能电站大坝渗流安全监控模型影响因子选择及模型构建不确定性造成模型预测精度不高的问题,将深度学习模型和概率性预测方法进行融合,融合卷积神经网络(CNN)的特征提取能力、双向门控循环单元(BiGRU)的数据挖掘潜力、蜣螂优化算法(DBO)的参数优化优势以及分位数回归(QR)的概率性预测能力,构建了基于DBO、CNN、BiGRU、QR算法的大坝渗流概率性预测模型;同时,为构建适合抽水蓄能电站渗流安全监控模型的最优影响因子集,充分考虑渗流的滞后效应,采用核主成分分析法(KPCA)对模型影响因子进行优选。工程实例验证结果表明,构建的大坝渗流概率性预测模型不仅能给出确定性的坝渗透压力高精度预测结果,还可得出相应的预测区间来反映渗流变化的不确定程度,进而为抽水蓄能电站大坝渗流安全监控提供更全面的评价信息。

关键词:大坝安全监控;抽水蓄能电站;监控模型;渗流预测;深度学习;概率性预测

中图分类号:TV641;TV698.1⁺1 **文献标志码:**A **文章编号:**1006-7647(2025)04-0076-09

Seepage safety monitoring model for pumped storage power station dams based on probabilistic prediction//LI Xinru^{1,2}, SONG Jintao^{1,2}, YANG Jie^{1,2}, XU Zengguang^{1,2} (1. School of Water Resources and Hydro-electric Engineering, Xi'an University of Technology, Xi'an 710048, China; 2. State Key Laboratory of Eco-Hydraulics in Northwest Arid Region of China, Xi'an University of Technology, Xi'an 710048, China)

Abstract: To address the issue of low prediction accuracy caused by uncertainties in the selection of factors and construction of the seepage safety monitoring model for pumped storage power station dams, this study integrated deep learning models with probabilistic prediction methods. By incorporating the feature extraction capability of convolutional neural network (CNN), the data mining potential of bidirectional gated recurrent units (BiGRU), the parameter optimization advantage of the dung beetle optimization (DBO) algorithm, and the probabilistic prediction capability of quartile regression (QR), a probabilistic dam seepage prediction model based on DBO, CNN, BiGRU, and QR was established. At the same time, to construct an optimal factor set suitable for the seepage safety monitoring model for pumped storage power stations, the lag effect of seepage was fully taken into account, and the kernel principal component analysis (KPCA) was adopted to optimize the influencing factors of the model. Engineering case studies demonstrate that the established probabilistic dam seepage prediction model can not only provide high-accuracy deterministic prediction results of dam seepage pressure, but also yield corresponding probabilistic prediction intervals to reflect the uncertainty of seepage changes, which can provide more comprehensive evaluation information for seepage safety monitoring of pumped storage power station dams.

Key words: dam safety monitoring; pumped storage power station; monitoring model; seepage prediction; deep learning; probabilistic prediction

抽水蓄能电站因其技术成熟、可靠、环保等特点,被认为是新型电力系统最理想的大型储能装置^[1-3]。近年来,全球抽水蓄能电站数量持续增长,截至2023年底,全球抽水蓄能电站总装机容量已达

179 GW,其中,中国占28.1%,约50 940 MW,居世界首位^[4]。因此,抽水蓄能电站是目前水利工程领域重点关注的建设及研究方向。

抽水蓄能电站的库水位具有变化速率快、变化

基金项目:国家自然科学基金面上项目(52279140);国家自然科学基金青年基金项目(52109166)

作者简介:李心如(2000—),女,硕士研究生,主要从事大坝安全监控与数值仿真研究。E-mail:2220420158@stu.xaut.edu.cn

通信作者:宋锦焘(1990—),男,副教授,博士,主要从事大坝安全监控与风险分析研究。E-mail:104971@xaut.edu.cn

幅度大的特点,这和常规水利工程运行环境差异较大,利用传统安全监控模型会造成预测精度波动较大等问题。因此,构建精准可靠的抽水蓄能大坝安全监控模型显得尤为重要,而渗流问题是大坝安全的重要内容之一^[5-7]。目前,大坝渗流安全监控模型研究多注重构建环境量与大坝渗流的确定性输入输出关系,较少考虑预测结果的不确定性。而实际抽水蓄能电站工程中,渗流安全监控模型因子输入的主观性、因子关系的不准确性及参数选择的随机性等都会造成模型预测结果的不确定性,并导致预测结果的可靠程度波动较大^[8]。此外,由于大部分抽水蓄能电站处于建设期,具有长期可供分析安全监测资料的抽水蓄能电站数量较少。因此,亟须利用已有的监测数据,构建基于概率性预测的抽水蓄能电站大坝渗流安全监控模型,为大坝渗流安全评价提供技术支撑。

近年来,概率性预测理论作为一种可以描述预测结果可靠程度的方法,已逐渐被引入数据分析领域^[8-11]。概率性预测,也被称为区间预测,采用区间形式表达预测结果,以反映结果的不确定性。相对于确定性预测,这种方法不仅可通过计算区间的上下限来描述时间序列的变化范围,还可利用区间覆盖率和区间平均宽度来量化预测模型的可靠性^[12-13],避免基于可信度不高的预测结果作出错误决策。

随着人工智能技术的发展,支持向量机^[14-15]、神经网络^[16-17]和深度学习^[18-19]算法已被广泛应用于大坝渗流研究。赵明哲等^[20]依据分解合成思想,基于 GAMLSS-GLO 及随机森林算法预测了大坝渗流量。Ishfaqe 等^[21]构建了 RS-LSTM 模型,较为准确地预测了大坝渗流量。Zhang 等^[22]考虑输入因子的滞后效应,提出了基于 HGWO-XGBoost 模型的混凝土坝渗流监测模型,模型预测结果符合实际。上述多种智能算法虽然在构建大坝渗流监测模型方面取得了良好结果,但模型预测结果受输入因子数量、模型参数等影响较大。因此,需要针对抽水蓄能电站运行特征,构建渗流最优影响因子库,选择合适的参数优化算法确定深度学习模型的最优参数。

综上所述,为克服现有大坝渗流安全监控模型对抽水蓄能电站适用性不足的问题,实现对抽水蓄能电站大坝渗流数据的高精度确定性预测,并给出不同不确定性程度条件下渗流数据的预测区间,构建了一种基于概率性预测和深度学习融合的抽水蓄能电站大坝渗流监控模型,并通过某长期运行的抽水蓄能电站大坝的渗压计实测数据对模型进行验证。

1 大坝渗流最优影响因子库

1.1 大坝渗流影响因子

大坝渗流监测数据如渗透压力主要受库水位、降雨、温度以及时效因素影响^[23],即大坝渗透压力可以表示为

$$P_i = P_H + P_T + P_R + P_\theta \tag{1}$$

式中: P_i 为坝体某一点的总渗透压力; P_H 为由库水位变化引起的渗透压力分量; P_T 为由温度变化引起的渗透压力分量; P_R 为由降雨变化引起的渗透压力分量; P_θ 为由渗透压力传递和消散引起的时效分量。

抽水蓄能电站运行时,库水位变化速率快,而坝体材料的弱渗透性会造成坝体不同部位水压力的变化滞后于库水位的波动^[23],导致渗透水头需要较长时间才能达到稳定状态。因此,实测渗透水头往往是库水位变动时非稳定渗流的瞬时结果,存在滞后性^[24]。考虑库水位与降雨的滞后效应,渗透压力影响因子各分量的具体表达式为

$$\begin{cases} P_H = \{H_{up0}, H_{up5}, H_{up10}, H_d\} \\ P_T = \left\{T, \sin \frac{2\pi t}{365}, \sin \frac{4\pi t}{365}, \cos \frac{2\pi t}{365}, \cos \frac{4\pi t}{365}\right\} \\ P_R = \{R, \bar{R}_5, \bar{R}_{10}, \bar{R}_{15}, \bar{R}_{30}, \bar{R}_{60}, \bar{R}_{90}\} \\ P_\theta = \{\theta, \ln(1 + \theta)\} \end{cases} \tag{2}$$

式中: H_{up0} 、 H_{up5} 、 H_{up10} 分别为监测日当天、前 5 天、前 10 天的上游平均水位; H_d 为监测日当日下游水位; T 为监测日当日气温; t 为监测日到初始监测日累计监测天数; R 为监测日当日降水量; $\bar{R}_i$ 为监测日前 i 天平均降水量; $\theta = 0.01t$ 。

1.2 最优影响因子库构建

大坝渗流影响因子数量较多,影响因子通常具有高维度、相关性的特性,直接应用于预测模型会影响模型的精度、泛化能力及计算效率^[25]。而核主成分分析法(kernel principal component analysis, KPCA)能有效地提取原始数据集中的非线性特征,降低影响因子之间多重共线性影响^[26]。因此,采用 KPCA 处理大坝渗流影响因子,有利于建立更准确、高效的预测模型^[27]。

根据实际工程监测条件,选择合适的渗流影响因子,通过 KPCA 选取重要影响因子作为主成分及预测模型的输入因子,从而建立最优影响因子库。通常抽水蓄能电站大坝渗流影响因子大于 9 个,输入因子降维后可以有效提升后续深度学习模型的预测精度。

2 基于深度学习的大坝渗流概率性预测模型

2.1 研究方法

深度学习方法因其特征学习能力强、处理大规模非线性数据快速等优势^[28],被广泛应用于大坝安全监控模型。然而,深度学习仍存在信息挖掘不充分、模型参数寻优能力不足的问题,并且基于深度学习的大坝渗透压力预测模型大多为确定性预测模型,未考虑不确定性因素对预测结果的影响。而抽水蓄能电站库水位变化频繁且变幅较大的工作特点,可能会导致模型预测结果的不确定性增加,模型确定性预测结果可靠度降低。

为解决上述问题,进一步提升模型性能,将多个先进的深度学习算法及仿生优化算法进行融合。针对信息挖掘不充分问题,林俊亭等^[29-30]验证了卷积神经网络(convolutional neural network,CNN)和双向门控循环神经网络(bidirectional gated recurrent unit,BiGRU)两个深度学习模型的组合(CNN-BiGRU模型)可以有效提升预测精度,但在大坝安全监控领域未有应用。因此,将CNN和BiGRU结合并应用于大坝安全监控模型是可行的。此外,为克服传统确定性预测模型的局限性,引入分位数回归(quantile regression,QR),以实现大坝渗流的概率性预测^[31-32]。

2.1.1 卷积神经网络

CNN是一种由多个处理层叠加而成的深度神经网络,包括输入层、卷积层、池化层和全连接层^[33]。CNN具有在不改变原始数据信息的前提下,自主抓取数据特征的能力,在大坝监测数据处理领域得到广泛应用^[33-36],具有较强的鲁棒性。具体来说,CNN通过多个卷积池化层交替连接,获取数据的局部特征。然后,将这些处理后的信息输入到BiGRU网络进行大坝渗透压力预测。CNN结构描述见文献^[33]。

2.1.2 双向门控循环神经网络

大坝监测数据是一个复杂的非线性、非平稳的时间序列数据^[37],仅依靠CNN难以充分挖掘出数据中的内在关联性。而BiGRU架构每一层之间都有前馈连接,因此可以将CNN与BiGRU集成在一个模型,从而更高效地提取数据的时序特征^[38-40]。BiGRU是门控循环单元(gated recurrent unit,GRU)的改进,是一种双向循环神经网络模型,通过引入双向循环模块成功揭示了时序数据内部的关联性,有效地弥补了传统机器学习模型在处理时序数据方面的不足^[41-43]。由于拥有更简化的结构,BiGRU的计算速度更快,这些显著优点使其在处理大坝监测数

据时更具优势。

2.1.3 蜣螂优化算法

由于CNN-BiGRU模型的超参数对其学习性能具有重要影响,为提高超参数寻优效率,避免手动调参引起的随机性和计算量大等问题,需要引入优化算法进行参数寻优。蜣螂优化(dung beetle optimization,DBO)算法是2023年提出的一种新型元启发式算法^[44-45],该算法兼顾了全局探索和局部开发,相比较传统优化算法,具有收敛速度快和求解精度高的特点,已经被一些学者成功应用于参数优化领域^[46-47]。因此,本文引入DBO算法对CNN-BiGRU的超参数进行调优。

2.1.4 分位数回归概率性预测理论

将KPCA、DBO、CNN、BiGRU进行集成(KPCA-DBO-CNN-BiGRU模型)后,可以对抽水蓄能电站大坝渗透压力进行确定性预测。然而,在实际抽水蓄能工程中,渗透压力监测数据往往存在着规律动态变化的特性,同时建立预测模型时,库水位的频繁变化,人为确定输入样本的主观性及选取模型参数的随机性,都会导致预测结果不确定性增加。故将QR集成到KPCA-DBO-CNN-BiGRU组合模型中,通过预设不同分位数,实现对大坝渗透压力的概率性预测,从而为大坝安全评价提供可靠的分析基础。

2.2 模型评价指标

基于上述不同方法的计算原理,将KPCA、DBO、CNN、BiGRU、QR进行组合,提出KPCA-DBO-CNN-BiGRU-QR大坝渗流概率性预测模型(以下简称“KPCA-DBO-CNN-BiGRU-QR模型”)。该模型能在预测大坝某点渗流监测量具体数值的同时给出预测区间以定量化表征预测结果的不确定性。为了评价该模型的预测精度,分别从确定性预测评价指标和概率性预测评价指标两个方面进行研究。

采用均方误差(MSE)、平均绝对误差(MAE)、决定系数(R^2)作为确定性预测的评价指标,MSE和MAE越小, R^2 越接近1,证明模型预测精度越高^[31]。

采用区间覆盖率 I_{PICP} 、区间平均宽度 I_{PINAW} 以及区间综合评价指标 I_{WC} 作为概率性预测评价指标。 I_{PICP} 表示预测区间覆盖实际值的概率,其值越大,表明构造区间的可靠性越高; I_{PINAW} 表示预测区间的不确定性程度,其值越小,表明区间不确定程度越低,模型的精度越好,在 I_{PICP} 值相同时, I_{PINAW} 越小,表明预测结果越好; I_{WC} 表示对预测结果的全面综合评价,其值越小,表明预测结果越好^[31]。

2.3 研究框架

KPCA-DBO-CNN-BiGRU-QR模型的抽水蓄能电站大坝渗流概率性预测主要包括4个部分:

a. 构建大坝渗流影响因子库。大坝渗流监测量受库水位、降雨、温度、时效等多种因素的影响,需要构建较为完整的大坝渗流影响因子库。

b. 构建大坝渗流最优影响因子库。由于渗流影响因子间存在一定的非线性相关性,采用 KPCA 降低大坝渗流影响因子原始数据集维度,进一步简化模型数据,形成大坝渗流最优因子库。

c. 基于 DBO、CNN、BiGRU、QR 算法的概率性预测模型构建与训练。首先构建 CNN-BiGRU 模型,并利用 DBO 对其进行超参数调优,最后,引入 QR,通过预设不同分位数,在得到确定性的预测结果的同时,得出相应的预测区间来反映结果的不确定程度。

d. 工程实例验证。结合工程实例,对某抽水蓄能电站大坝渗压计监测数据进行建模分析,构建大坝渗透压力最优因子库,验证 KPCA-DBO-CNN-BiGRU-QR 模型的适用性。

模型流程如图 1 所示。




图 1 KPCA-DBO-CNN-BiGRU-QR 模型流程

3 工程实例验证

3.1 工程概况

选用江苏省溧阳市境内某抽水蓄能电站,该电站属一等大(1)型工程。上水库由 1 座主坝和 2 座副坝围筑而成,且均为混凝土面板堆石坝。电站上下水库全景如图 2 所示。



图 2 电站上下水库全景

选用上水库主坝 0+405.200 处监测点 Pc5 与 Pc8 的渗透水头监测数据建立预测模型,图 3 为 Pc5

与 Pc8 测点的渗压计位置布置图。该电站于 2016 年 11 月开始正常运行,故以 2016 年 11 月 22 日至 2018 年 1 月 4 日监测数据作为训练集,以 2018 年 1 月 5 日至 2018 年 4 月 16 日监测数据作为测试集。图 4 为 Pc5 与 Pc8 测点在该时间段中渗透水头实测值变化情况。




图 3 Pc5 与 Pc8 测点渗压计分布(单位:m)




图 4 Pc5 与 Pc8 测点实测渗透水头过程线

3.2 最优影响因子库

由于实际工程资料中缺少下游水位监测值,大坝的原始渗透压力影响因子最终确定如下:水压分量取 H_{up0} 、 H_{up5} 、 H_{up10} ,温度分量取 T 、 $\sin \frac{2\pi t}{365}$ 、 $\sin \frac{4\pi t}{365}$ 、 $\cos \frac{2\pi t}{365}$ 、 $\cos \frac{4\pi t}{365}$,降雨分量取 R 、 $\bar{R}_5$ 、 $\bar{R}_{10}$ 、 $\bar{R}_{15}$ 、 $\bar{R}_{30}$ 、 $\bar{R}_{60}$ 、 $\bar{R}_{90}$,时效分量取 θ 、 $\ln(1+\theta)$ 。本文选取的渗流统计回归模型为

$$\begin{aligned}
 P_i = & P_H + P_T + P_R + P_\theta = \omega_0 + \\
 & \omega_1 \left(\sum_{i=1}^2 a_i H_{up0}^i + \sum_{i=5}^{m_1} b_i H_{upi} \right) + \\
 & \sum_{i=1}^2 \left(\omega_{2i} \sin \frac{2\pi it}{365} + \omega_{3i} \cos \frac{2\pi it}{365} \right) + \\
 & \omega_4 \left(cR + \sum_{i=5}^{m_2} d_i \bar{R}_i \right) + \omega_5 \theta + \omega_6 \ln(1+\theta) \quad (3)
 \end{aligned}$$

式中: ω_0 为回归常量; m_1 、 m_2 为滞后天数; ω_1 、 a_i 、 b_i 、 ω_{2i} 、 ω_{3i} 、 ω_4 、 c 、 d_i 、 ω_5 、 ω_6 均为回归系数。

对原始渗透压力影响因子数据集进行归一化处理后,通过 KPCA 进行高维特征空间分析。根据安全性和可靠性原则,选用累积贡献率为 99% 的主成分作为预测模型的输入因子,测试多项式核、高斯

核、线性核对降维效果的影响,并绘制累积贡献率曲线(图 5)。




图 5 Pc5 与 Pc8 测点 KPCA 算法贡献率曲线

在满足累积贡献率 99% 的条件下,Pc5、Pc8 两个测点渗透压力影响因子采用高斯核 KPCA 算法或多项式核 KPCA 算法需要前 6 个主成分表征原始数据,而线性核 KPCA 算法需要前 10 个主成分表征原始数据,且高斯核 KPCA 算法前 6 个主成分保留的信息量大于多项式核 KPCA 算法,说明高斯核 KPCA 算法的降维效果最好。因此,Pc5 与 Pc8 测点均采用高斯核 KPCA 算法提取出的前 6 个主成分作为模型的输入变量,这为后续提高模型的精度与计算效率提供了因子选取基础。

3.3 模型参数确定

在特征筛选的基础上,采用 DBO 算法优化 CNN-BiGRU 模型超参数。参考文献[47],初步设置 DBO 参数如下:搜寻维度为 4,初始种群数为 30,最大迭代次数为 50,滚球蜣螂、繁育蜣螂、觅食蜣螂和偷窃蜣螂数量分别为 6、6、7 和 11。CNN-BiGRU 模型的超参数寻优范围及结果见表 1。

表 1 超参数寻优结果

测点	优化参数	寻优范围	寻优结果
Pc5	隐藏层 1 神经元数	[20,60]	60
	隐藏层 2 神经元数	[20,30]	30
	学习率	[0.001,1]	0.001
	训练次数	[10,100]	20
Pc8	隐藏层 1 神经元数	[20,60]	60
	隐藏层 2 神经元数	[20,30]	30
	学习率	[0.001,1]	0.003
	训练次数	[10,100]	30

3.4 确定性预测及结果对比分析

为证明 KPCA-DBO-CNN-BiGRU-QR 预测模型

的学习和泛化能力,采用集成不同算法的模型 (DBO-CNN-BiGRU-QR 模型、CNN-BiGRU-QR 模型)、统计回归模型等作为对比模型。基于同一测试数据进行预测,随后使用 MSE、MAE、 R^2 对预测效果进行评价。设置分位数为 0.5,可以获得确定性预测结果。图 6 为统计回归模型、CNN-BiGRU-QR、DBO-CNN-BiGRU-QR、KPCA-DBO-CNN-BiGRU-QR 模型测试数据的预测值与大坝渗透水头实测值的对比。由图 6 可知,相比其他 3 种模型,KPCA-DBO-CNN-BiGRU-QR 模型的预测精度和预测稳定性有明显提高,可以有效预测坝体的渗透水头变化过程。




图 6 不同预测模型确定性预测结果对比

表 2 分别为不同预测模型的预测精度比较。由表 2 可知,统计回归模型的预测结果精度不高,建模效果一般;未使用优化算法和因子优选方法的 CNN-BiGRU-QR 模型具有较大的预测误差;当引入优化算法并直接对原始数据进行计算时, DBO-CNN-BiGRU-QR 模型的预测效果显著优于 CNN-BiGRU-QR 模型,预测误差大幅降低;采用 KPCA 对输入数

表 2 不同预测模型确定性评价指标对比

测点	预测模型	MSE/m ²	MAE/m	R ²
Pc5	CNN-BiGRU-QR	0.005	0.058	0.896
	DBO-CNN-BiGRU-QR	0.003	0.042	0.940
	KPCA-DBO-CNN-BiGRU-QR	0.002	0.033	0.965
	统计回归模型	0.004	0.052	0.908
Pc8	CNN-BiGRU-QR	0.012	0.094	0.890
	DBO-CNN-BiGRU-QR	0.006	0.061	0.948
	KPCA-DBO-CNN-BiGRU-QR	0.004	0.050	0.967
	统计回归模型	0.016	0.116	0.854

据进行非线性主元提取并采用 DBO 算法进行超参数调优后,构建的 KPCA-DBO-CNN-BiGRU-QR 模型预测精度有进一步的提升,这验证了 KPCA 在对原始数据进行非线性提取方面的显著效果。综合考虑,KPCA-DBO-CNN-BiGRU-QR 模型展现出良好的预测精度。

3.5 概率性预测及结果对比分析

抽水蓄能电站运行时库水位变动频率高、变化幅度大,这极大地增加了模型预测结果的不确定性,对预测结果的可信度产生影响。分别选取分位数 0.975 与 0.025 的计算结果作为上下限,从而获得 95%置信水平下的预测区间。将 Pc5、Pc8 两测点处数据代入 KPCA-DBO-CNN-BiGRU-QR 模型,得到区间预测结果(图 7)。由图 7 可知,KPCA-DBO-CNN-BiGRU-QR 模型计算得到的渗透压力预测结果与实际变化趋势基本一致,预测区间能够有效地包络实际渗透水头曲线,展现了高精度的概率性预测能力。

表 3 给出了不同预测模型在 Pc5、Pc8 两测点处的概率性预测误差统计结果。由表 3 可知,Pc5、Pc8 两测点数据采用 KPCA-DBO-CNN-BiGRU-QR 模型计算的区间综合评价指标 I_{WC} 分别为 0.379、0.757,均低于其余 2 种模型,表明 KPCA-DBO-CNN-BiGRU-QR 模型概率性预测结果最好,更适用于构建抽水蓄能电站大坝渗透压力的概率性预测模型。

此外,预测区间能动态表征大坝渗流监测值的可能变化范围,可以作为大坝渗流安全的量化参考依据,对拟定合理监控指标有重要的参考意义。

表 3 不同预测模型概率性评价指标对比

测点	预测模型	I_{PICP}	I_{PINAW}	I_{WC}
Pc5	CNN-BiGRU-QR	1.000	0.739	0.739
	DBO-CNN-BiGRU-QR	1.000	0.636	0.636
	KPCA-DBO-CNN-BiGRU-QR	1.000	0.379	0.379
Pc8	CNN-BiGRU-QR	0.980	1.473	1.502
	DBO-CNN-BiGRU-QR	0.970	1.133	1.168
	KPCA-DBO-CNN-BiGRU-QR	0.980	0.742	0.757

4 结 语

为克服传统大坝渗流安全监控模型对抽水蓄能电站大坝适用性不足、模型预测结果不确定性程度高等问题,将深度学习模型和概率性预测方法进行融合,利用 KPCA 实现影响因子集结构的优化,利用 DBO 优化 CNN-BiGRU 模型超参数,并引入 QR,构建了 KPCA-DBO-CNN-BiGRU-QR 大坝渗透压力概率性预测模型,实现了更精确可靠的大坝渗透压力预测。工程实例分析表明,模型在获得确定性预测结果的同时,获得了 95%置信水平下的预测区间,可用于表征预测过程中不确定性因素对预测结果的影响,更符合抽水蓄能大坝渗流实际规律,为大坝渗流安全监控提供更加全面合理的信息。




图 7 不同预测模型不同测点的区间预测结果

参考文献:

[1] 任艳,崔正辉. 全球能源转型背景下中外抽水蓄能发展分析研究[J]. 水力发电, 2023, 49 (10): 92-96. (REN Yan, CUI Zhenghui. Analysis of pumped-storage development in China and other countries under the background of global energy transition[J]. Water Power, 2023, 49 (10): 92-96. (in Chinese))

[2] 茅昌平,杨张阳,李广凯,等. 抽水蓄能电站库区水化学特征影响因素及其示踪作用[J]. 河海大学学报(自然科学版), 2023, 51 (1): 34-42. (MAO Changping, YANG Zhangyang, LI Guangkai, et al. Influencing factors of hydrochemical characteristics in reservoir area of pumped storage power station and their tracing function [J]. Journal of Hohai University (Natural Sciences), 2023, 51 (1): 34-42. (in Chinese))

[3] 王妍月. 利益相关者视角的抽水蓄能电站定价机制[J]. 水利经济, 2023, 41 (2): 52-57. (WANG Yanyue. Research on pricing mechanism of pumped storage power station from stakeholder perspective [J]. Journal of Economics of Water Resources, 2023, 41 (2): 52-57. (in Chinese))

[4] 任伟楠,朱方亮,韩冬,等. 抽水蓄能行业发展现状与展望[J]. 水电与抽水蓄能, 2025, 11 (1): 4-10. (REN Weinan, ZHU Fangliang, HAN Dong, et al. Current status and future development of pumped storage industry[J]. Hydropower and Pumped Storage, 2025, 11 (1): 4-10. (in Chinese))

[5] 马春辉,侯媛媛,杨杰,等. 基于 RUN-XGBoost 算法的土石坝渗流预测模型[J]. 水利水电科技进展, 2024, 44 (2): 72-78. (MA Chunhui, HOU Yuanyuan, YANG Jie, et al. Seepage prediction model of earth-rockfill dams based on RUN-XGBoost algorithm[J]. Advances in Science and Technology of Water Resources, 2024, 44 (2): 72-78. (in Chinese))

[6] 刘永涛,郑东健,孙雪莲,等. 基于 EEMD-RVM 的土石坝渗流量时间序列预测模型[J]. 水利水电科技进展, 2021, 41 (3): 89-94. (LIU Yongtao, ZHENG Dongjian, SUN Xuelian, et al. Time series prediction model of seepage flow of an earth-rock dam based on EEMD-RVM [J]. Advances in Science and Technology of Water Resources, 2021, 41 (3): 89-94. (in Chinese))

[7] 朱瑞恒,岑威钧,薛阳,等. 坝基廊道开裂对心墙坝渗流特性的影响[J]. 河海大学学报(自然科学版), 2024, 52 (4): 22-28. (ZHU Ruiheng, CEN Weijun, XUE Yang, et al. Influence analysis of dam foundation gallery cracks on seepage characteristics of core dam [J]. Journal of Hohai University (Natural Sciences), 2024, 52 (4): 22-28. (in Chinese))

[8] 王晓玲,谢怀宇,王佳俊,等. 基于 Bootstrap 和 ICS-MKELM 算法的大坝变形预测[J]. 水力发电学报, 2020, 39 (3): 106-120. (WANG Xiaoling, XIE Huaiyu, WANG Jiajun, et al. Prediction of dam deformation based on Bootstrap and ICS-MKELM algorithms [J]. Journal of Hydroelectric Engineering, 2020, 39 (3): 106-120. (in Chinese))

[9] 章超波,刘永政,李宏波,等. 基于加权残差聚类的建筑负荷预测区间估计[J]. 浙江大学学报(工学版), 2022, 56 (5): 930-937. (ZHANG Chaobo, LIU Yongzheng, LI Hongbo, et al. Weighted residual clustering-based building load prediction interval estimation [J]. Journal of Zhejiang University (Engineering Science), 2022, 56 (5): 930-937. (in Chinese))

[10] 李晓理,梅建想,王康,等. 基于 Elman 神经网络的 PM_{2.5} 质量浓度区间预测[J]. 北京工业大学学报, 2020, 46 (4): 377-384. (LI Xiaoli, MEI Jianxiang, WANG Kang, et al. PM_{2.5} mass concentration interval prediction based on Elman neural network [J]. Journal of Beijing University of Technology, 2020, 46 (4): 377-384. (in Chinese))

[11] 王晓玲,韩国玺,余佳,等. TBM 掘进速率区间预测 Bootstrap-IHHO-BiLSTM 模型[J]. 水力发电学报, 2023, 42 (12): 159-171. (WANG Xiaoling, HAN Guoxi, YU Jia, et al. Interval prediction Bootstrap-IHHO-BiLSTM model for TBM advance rate [J]. Journal of Hydroelectric Engineering, 2023, 42 (12): 159-171. (in Chinese))

[12] HU Jiaxiang, HU Weihao, CAO Di, et al. Bayesian averaging-enabled transfer learning method for probabilistic wind power forecasting of newly built wind farms [J]. Applied Energy, 2024, 355: 122185.

[13] 李家田,苏怀智,赵海超,等. 基于蒙特卡罗模拟的混凝土坝渗流性态区间综合评价[J]. 水利水电科技进展, 2018, 38 (3): 32-35. (LI Jiatian, SU Huaizhi, ZHAO Haichao, et al. Comprehensive interval assessment of seepage behavior for concrete dams based on Monte Carlo simulation [J]. Advances in Science and Technology of Water Resources, 2018, 38 (3): 32-35. (in Chinese))

[14] 谷艳昌,吴云星,黄海兵,等. 基于遗传算法优化支持向量机的大坝安全性态预测模型[J]. 河海大学学报(自然科学版), 2020, 48 (5): 419-425. (GU Yanchang, WU Yunxing, HUANG Haibing, et al. Prediction model of dam safety behavior based on genetic algorithm optimized support vector machine [J]. Journal of Hohai University (Natural Sciences), 2020, 48 (5): 419-425. (in Chinese))

[15] BELMOKRE A, MIHOUBI M K, SANTILLAN D. Seepage and dam deformation analyses with statistical models: support vector regression machine and random forest [J]. Procedia Structural Integrity, 2019, 17: 698-703.

[16] ZHANG Hongyang, SONG Ziyi, PENG Peng, et al. Research on seepage field of concrete dam foundation based on artificial neural network [J]. Alexandria Engineering Journal, 2021, 60 (1): 1-14.

[17] ZHANG Xuan, CHEN Xudong, LI Junjie. Improving dam

- seepage prediction using back-propagation neural network and genetic algorithm [J]. Mathematical Problems in Engineering, 2020, 2020: 1404295.
- [18] CHEN Xudong, XU Ying, GUO Hongdi, et al. Comprehensive evaluation of dam seepage safety combining deep learning with Dempster-Shafer evidence theory[J]. Measurement, 2024, 226: 114172.
- [19] YANG Xin, XIANG Yan, WANG Yakun, et al. A dam safety state prediction and analysis method based on EMD-SSA-LSTM[J]. Water, 2024, 16(3): 395.
- [20] 赵明哲, 樊牧, 沈立锋, 等. 基于 GAMLSS-GLO 及随机森林算法的土石坝渗流监测模型[J]. 水资源与水工程学报, 2023, 34(5): 198-206. (ZHAO Mingzhe, FAN Mu, SHEN Lifeng, et al. Seepage monitoring model of earth-rock dam based on GAMLSS-GLO and random forest algorithm [J]. Journal of Water Resources & Water Engineering, 2023, 34(5): 198-206. (in Chinese))
- [21] ISHFAQUE M, DAI Qianwei, HAQ N U, et al. Use of recurrent neural network with long short-term memory for seepage prediction at Tarbela Dam, KP, Pakistan [J]. Energies, 2022, 15(9): 3123.
- [22] ZHANG Kang, GU Chongshi, ZHU Yantao, et al. A novel seepage behavior prediction and lag process identification method for concrete dams using HGWO-XGBoost model [J]. IEEE Access, 2021, 9: 23311-23325.
- [23] 刘泽. 基于智能算法的混凝土大坝渗流预测模型研究 [D]. 武汉: 武汉理工大学, 2022.
- [24] 宋锦焄, 袁帅, 段梦强, 等. 基于麻雀搜索算法和滞后效应的土石坝渗流监控模型[J]. 水利水电科技进展, 2022, 42(5): 52-57. (SONG Jintao, YUAN Shuai, DUAN Mengqiang, et al. Seepage pressure monitoring model for earth-rockfill dams based on sparrow search algorithm and hysteresis effect[J]. Advances in Science and Technology of Water Resources, 2022, 42(5): 52-57. (in Chinese))
- [25] 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. (in Chinese))
- [26] 葛盼猛, 陈波, 刘庭赫, 等. 基于 KPCA-ICFSFDP-MOGP 的拱坝多测点变形数据预处理及预测方法[J]. 水利水电科技进展, 2023, 43(4): 92-97. (GE Panmeng, CHEN Bo, LIU Tinghe, et al. Preprocessing and prediction method for multi-point deformation data of arch dams based on KPCA-ICFSFDP-MOGP [J]. Advances in Science and Technology of Water Resources, 2023, 43(4): 92-97. (in Chinese))
- [27] 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. (in Chinese))
- [28] YANG Dashan, GU Chongshi, ZHU Yantao, et al. A concrete dam deformation prediction method based on LSTM with attention mechanism [J]. IEEE Access, 2020, 8: 185177-185186.
- [29] 林俊亭, 王帅, 刘恩东, 等. 基于模糊聚类和 CNN-BIGRU 的轨道电路故障预测[J]. 振动、测试与诊断, 2023, 43(3): 500-507. (LIN Juntong, WANG Shuai, LIU Endong, et al. Fault prediction method of track circuit based on fuzzy clustering and CNN-BIGRU [J]. Journal of Vibration, Measurement & Diagnosis, 2023, 43(3): 500-507. (in Chinese))
- [30] 杨胡萍, 余阳, 汪超, 等. 基于 VMD-CNN-BIGRU 的电力系统短期负荷预测[J]. 中国电力, 2022, 55(10): 71-76. (YANG Huping, YU Yang, WANG Chao, et al. Short-term load forecasting of power system based on VMD-CNN-BIGRU [J]. Electric Power, 2022, 55(10): 71-76. (in Chinese))
- [31] 王开艳, 杜浩东, 贾嵘, 等. 基于相似日聚类和 QR-CNN-BiLSTM 模型的光伏功率短期区间概率预测[J]. 高电压技术, 2022, 48(11): 4372-4384. (WANG Kaiyan, DU Haodong, JIA Rong, et al. Short-term interval probability prediction of photovoltaic power based on similar daily clustering and QR-CNN-BiLSTM model [J]. High Voltage Engineering, 2022, 48(11): 4372-4384. (in Chinese))
- [32] 杨晨昊, 郑东健. 基于分位数回归的升船机变形监控模型构建方法[J]. 水利水电科技进展, 2023, 43(2): 27-32. (YANG Chenhao, ZHENG Dongjian. Construction method for ship lift deformation monitoring model based on quantile regression [J]. Advances in Science and Technology of Water Resources, 2023, 43(2): 27-32. (in Chinese))
- [33] 王世杰, 肖萌, 华国威, 等. 基于 CNN-GRU 的混凝土大坝扬压力预测模型研究[J]. 中国安全生产科学技术, 2023, 19(7): 99-105. (WANG Shijie, XIAO Meng, HUA Guowei, et al. Research on uplift pressure prediction of concrete dam based on CNN-GRU [J]. Journal of Safety Science and Technology, 2023, 19(7): 99-105. (in Chinese))
- [34] LIN Chuan, WENG Kailiang, LIN Youlong, et al. Time series prediction of dam deformation using a hybrid STL-CNN-GRU model based on sparrow search algorithm optimization [J]. Applied Sciences, 2022, 12(23): 11951.
- [35] YANG Jun, QU Jinbin, MI Qiang, et al. A CNN-LSTM model for tailings dam risk prediction [J]. IEEE Access, 2020, 8: 206491-206502.
- [36] HOU Weiya, WEN Yanfeng, DENG Gang, et al. A multi-target prediction model for dam seepage field [J]. Frontiers in Earth Science, 2023, 11: 1156114.

- [37] 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. (in Chinese))
- [38] 黄宇,顾智勇,李永玲,等. 基于时间模式注意力机制的CNN-BiGRU短期负荷预测[J]. 华北电力大学学报,2023,50(6):11-20. (HUANG Yu, GU Zhiyong, LI Yongling, et al. Short-term power load forecasting based on temporal pattern attention mechanism of CNN-BiGRU[J]. Journal of North China Electric Power University,2023,50(6):11-20. (in Chinese))
- [39] 任爽,杨凯,商继财,等. 基于CNN-BiGRU-Attention的短期电力负荷预测[J]. 电气工程学报,2024,19(1):344-350. (REN Shuang, YANG Kai, SHANG Jicai, et al. Short-term power load forecasting based on CNN-BiGRU-attention[J]. Journal of Electrical Engineering,2024,19(1):344-350. (in Chinese))
- [40] 杨超,冉启武,罗德虎,等. 基于注意力机制的CNN-BiGRU短期电价预测[J]. 电力系统及其自动化学报,2024,36(3):22-29. (YANG Chao, RAN Qiwu, LUO Dehu, et al. CNN-BiGRU short-term electricity price prediction based on attention mechanism[J]. Proceedings of the CSU-EPSA,2024,36(3):22-29. (in Chinese))
- [41] SONG Jintao, YANG Zhaodi, LI Xinru. Missing data imputation model for dam health monitoring based on mode decomposition and deep learning[J]. Journal of Civil Structural Health Monitoring,2024,14(5):1111-1124.
- [42] 张建中,顾冲时,袁冬阳,等. 基于优化VMD与GRU的混凝土坝变形预测模型[J]. 水利水电科技进展,2023,43(5):38-44. (ZHANG Jianzhong, GU Chongshi, YUAN Dongyang, et al. Deformation prediction model of concrete dams based on optimized VMD and GRU[J]. Advances in Science and Technology of Water Resources,2023,43(5):38-44. (in Chinese))
- [43] 钱杰杰,余军合,战洪飞,等. 基于DL-BiGRU多特征融合的注塑件尺寸预测方法[J]. 浙江大学学报(工学版),2024,58(3):646-654. (QIAN Qingjie, YU Junhe, ZHAN Hongfei, et al. Dimension prediction method of injection molded parts based on multi-feature fusion of DL-BiGRU[J]. Journal of Zhejiang University (Engineering Science),2024,58(3):646-654. (in Chinese))
- [44] XUE Jiankai, SHEN Bo. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing,2023,79(7):7305-7336.
- [45] 潘劲成,李少波,周鹏,等. 改进正弦算法引导的蜣螂优化算法[J]. 计算机工程与应用,2023,59(22):92-110. (PAN Jincheng, LI Shaobo, ZHUO Peng, et al. Dung beetle optimization algorithm guided by improved sine algorithm[J]. Computer Engineering and Applications,2023,59(22):92-110. (in Chinese))
- [46] 刘相杰,刘小生,张龙威. 基于二次模态分解和深度学习的大坝变形预测模型[J]. 水利水电科技进展,2024,44(3):101-106. (LIU Xiangjie, LIU Xiaosheng, ZHANG Longwei. Dam deformation prediction model based on quadratic modal decomposition and deep learning[J]. Advances in Science and Technology of Water Resources,2024,44(3):101-106. (in Chinese))
- [47] 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. (in Chinese))
- (收稿日期:2024-09-13 编辑:俞云利)

(上接第53页)

- [21] 张凌凯,崔子晏. 干湿-冻融循环条件下膨胀土的压缩及渗透特性变化规律[J]. 岩土力学,2023,44(3):728-740. (ZHANG Lingkai, CUI Ziyang. Compression and permeability characteristics of expansive soil under drying-wetting-freezing-thawing cycles[J]. Rock and Soil Mechanics,2023,44(3):728-740. (in Chinese))
- [22] 梁谏杰,张祖莲,黄英,等. 干湿循环作用下加砂对红土抗剪强度及微结构特性的影响[J]. 山地学报,2019,37(6):848-857. (LIANG Jianjie, ZHANG Zulian, HUANG Ying, et al. Effect of sand adding on shear strength and microstructure characteristics of laterite under dry-wet cycling condition[J]. Mountain Research,2019,37(6):848-857. (in Chinese))
- [23] 曾铃,邱健,匡波,等. 干湿循环作用下预崩解炭质泥岩强度特性及其劣化机制[J]. 中南大学学报(自然科学版),2023,54(9):3635-3646. (ZENG Ling, QIU Jian, KUANG Bo, et al. Strength characteristics and deterioration mechanism of pre-disintegrated carbonaceous mudstone in wetting and drying cycles[J]. Journal of Central South University (Science and Technology),2023,54(9):3635-3646. (in Chinese))
- [24] 苏安双,王宇,石北啸,等. 冻融循环条件下粗粒料变形特性试验研究[J]. 河海大学学报(自然科学版),2023,51(6):61-66. (SU Anshuang, WANG Yu, SHI Beixiao, et al. Experimental study on deformation characteristics of coarse aggregates under freeze-thaw cycling conditions[J]. Journal of Hohai University (Natural Sciences),2023,51(6):61-66. (in Chinese))
- (收稿日期:2024-06-27 编辑:熊水斌)