

DOI:10.3876/j.issn.1000-1980.2026.02.012

基于 QR-KOA-ITransformer-BiLSTM 的混凝土坝变形和变形区间预测模型

赵宇^{1,2}, 郑东健^{1,2}, 冉成^{1,2}, 林英浩^{1,2}

(1. 河海大学水利水电学院; 2. 河海大学水灾害防御全国重点实验室)

摘要: 为提高混凝土坝变形预测模型的精度和泛化能力,充分利用长时间序列数据前后信息的拓扑关系,并考虑各种不确定性影响,融合改进的 Transformer 模型(ITransformer)和双向长短期记忆神经网络(BiLSTM),结合开普勒优化算法(KOA),构建了 KOA-ITransformer-BiLSTM 混凝土坝变形预测模型(KIB 模型);同时为考虑测值误差等各种不确定性的影响,引入分位数回归(QR)方法,建立了 QR-KOA-ITransformer-BiLSTM 混凝土坝变形区间预测模型(QKIB 模型)。实例验证结果表明,KIB 模型明显提高了预测精度与迭代效率,平均绝对误差、平均绝对百分比误差、均方误差、均方根误差指标分别比 LSTM 模型降低了 77.89%、90.37%、93.08%、73.69%,决定系数 R^2 提高了 23.02%;QKIB 模型具有更好的稳定性和预测精度,90%置信水平下综合评价指标由 QR-LSTM、GRU、QR-BiLSTM 的 1.38736、0.78648、0.54342 减小到 0.24195。

关键词: 混凝土坝变形预测;ITransformer;双向长短期记忆网络;开普勒优化算法;变形区间预测模型

Concrete dam deformation and deformation interval prediction model based on QR-KOA-ITransformer-BiLSTM

Zhao Yu^{1,2}, Zheng Dongjian^{1,2}, Ran Cheng^{1,2}, Lin Yinghao^{1,2}

(1. College of Water Conservancy & Hydropower Engineering, Hohai University;

2. State Key Laboratory of Water Disaster Prevention, Hohai University)

Abstract: To enhance the accuracy and generalization capability of concrete dam deformation prediction models, fully utilize the topological relationships of temporal data in long time series, and consider various uncertainties, an improved Transformer (ITransformer) model and bidirectional long short-term memory neural network (BiLSTM) were integrated with the Kepler optimization algorithm (KOA) to construct the KOA-ITransformer-BiLSTM concrete dam deformation prediction model, namely KIB model. Additionally, to address uncertainties such as measurement errors, the quantile regression (QR) method was introduced, establishing the QR-KOA-ITransformer-BiLSTM concrete dam deformation interval prediction model, namely QKIB model. Experimental results demonstrate that the KIB model significantly improves prediction accuracy and iterative efficiency, reducing the mean absolute error, mean absolute percentage error, mean squared error, and root mean squared error by 77.89%, 90.37%, 93.08%, and 73.69%, respectively, compared to the LSTM models, while increasing the coefficient of determination R^2 by 23.02%. The QKIB model exhibits superior stability and accuracy, with the comprehensive evaluation metric at the 90% confidence level decreasing from 1.38736 (QR-LSTM), 0.78648 (GRU), and 0.54342 (QR-BiLSTM) to 0.24195.

Key words: concrete dam deformation prediction; ITransformer; bidirectional long short-term memory network; Kepler optimization algorithm; deformation interval prediction model

大坝安全关系到国计民生。变形是大坝安全状态的综合反映,考虑各种不确定性影响,建立大坝变形区间预测模型对及时掌握大坝安全状态有重要意义。传统的统计模型为均值回归模型,常基于多元线性回归等数学原理构建监测数据和环境量之间的函数关系,但大坝工作状态的复杂性以及环境荷载影响的非线性特征,使得传统统计模型具有明显的缺陷和不足。因此,利用新兴的机器学习算法来预测大坝变形已成为大坝变形预测的研究热点。邵楠等^[1]通过运用极限学习机(ELM)构建了预测大坝水平位移的模型,该模型展

基金项目: 国家自然科学基金项目(52179182)

作者简介: 赵宇(2001—),男,硕士研究生,主要从事水工结构安全监控研究。E-mail:1309293365@qq.com

通信作者: 郑东健(1965—),男,教授,博士,主要从事水工结构安全监控研究。E-mail:zhengdj@hhu.edu.cn

现出卓越的预报准确性和稳定性;李明^[2]证实了优化后的 BP 神经网络模型在大坝安全监测方面具有杰出的非线性拟合能力,能够准确反映出变形的动态特征。与常用的极限学习机、BP 神经网络等机器学习算法相比,深度学习算法能进一步挖掘变形数据在时间维度上的关联性,提高模型的预测精度。徐卫亚等^[3]结合粒子群优化(PSO)算法和最小二乘支持向量机(LSSVM)算法,得到了更好的模型性能。由于大坝变形位移的时间序列长,且具有显著的波动周期性特征,而长短期记忆神经网络(LSTM)具有独特的记忆机制与稳定的梯度性能,适合于精准预测大坝的变形情况^[4],如欧斌等^[5]证明了基于 LSTM 架构的预测模型能有效揭示大坝位移与相关影响因素间的复杂非线性关联。由于大坝变形数据前后信息存在一定的联系和拓扑关系,而传统单向 LSTM 模型在处理时序信息时,仅能从前向后单一流向地捕捉特征,而双向长短期记忆神经网络(BiLSTM)通过引入反向传播层,实现了对数据前后双向的深度学习,这不仅增强了模型对时间序列数据的理解,还使其能更有效地挖掘空间数据的深层信息,所以预测精度相较于 LSTM 有显著提升,更适于处理具有周期性和复杂结构的数据集。

近几年来,Transformer 模型应用成为一种新的趋势,并展现出卓越的效能。Transformer 模型利用自注意力机制,提高了模型的可解析性,尤其擅长捕捉序列中的长程依赖关系^[6-7]。因此将大坝监测数据的环境特征独立嵌入 Transformer 模型,利用自注意力机制分析环境特征与变形之间的深度关系,有望大幅提升预测的准确性,能显著提升模型性能^[8],但 Transformer 模型在多变量时间序列的处理上无法充分考虑变量之间的差异。ITransformer(Inverted Transformer)模型将不同的变量分开考虑,通过注意力机制自然地挖掘多变量关联,对大坝变形这类变量数较多且相互关联的多维时序数据有更好的适应性^[9]。由于 ITransformer 模型和 BiLSTM 模型的参数对预测准确性影响显著,而开普勒优化算法(Kepler optimization algorithm,KOA)具有全局寻优、适应性强和快速收敛的优势^[10],因此本文构建了基于 KOA 的 ITransformer 和 BiLSTM 组合(KOA-ITransformer-BiLSTM)混凝土坝变形预测模型(KIB 模型),从而集成 KOA、ITransformer 和 BiLSTM 的优势,提高模型的预测精度和泛化能力。

大坝变形预测的自变量和因变量存在的测值误差等不确定性影响可通过建立区间模型来量化,因分位数回归(quantile regression,QR)无须对变形的误差分布进行假设,可以描述变形的全局特征,不受测值离群点影响,有较好的稳健性^[11],因此本文采用 QR 来量化预测过程中的不确定性影响,在 KIB 模型的基础上,结合 QR 模型,构建了 QR-KOA-ITransformer-BiLSTM 混凝土坝变形区间预测模型(QKIB),并采用某拱坝工程实测数据验证了模型的可靠性。

1 算法原理

1.1 ITransformer 模型

ITransformer 模型在 Transformer 模型基础上,专门在时间序列预测设计方面进行了创新性的改造。ITransformer 的核心思想是通过重新设计 Transformer 架构,将注意力机制和前馈网络的职责进行了倒置,这种倒置的结构允许模型更有效地处理时间序列数据的多元相关性,以更好地捕捉多变量之间的联系。不同于以往 Transformer 预测模型使用的较为复杂的编码器-解码器结构,ITransformer 仅包含编码器,包括特征嵌入层、可堆叠的 Transformer 模块和投影层。

特征嵌入层对每个变量历史观测序列独立地进行特征映射,以获得不同的特征表示。它将每个变量的整个时间序列独立地嵌入为一个 Token,而不是像传统 Transformer 那样将同一时间下的多个变量组合成一个 Token。这种架构允许 ITransformer 通过自注意力机制更加高效地捕捉变量间的联系,从而有效挖掘时序信息。

Transformer 模块中的多头注意力层能够对不同变量间的相关性进行建模,既能增加神经网络可训练参数,提高数据挖掘能力,又能够提取序列内部多对特征之间的互信息,在处理时序数据上有较为出色的性能表现。同时前向传播层为全连接层,通过提取历史观测和未来预测数据中共享的时间特征,将特征外推为预测结果,用于丰富网络特征^[12-13]。

1.2 BiLSTM

LSTM 是一种循环神经网络,其特有的门控机制使网络能根据需要在不同的时间点上存储或清除信息^[14-15]。这种架构使 LSTM 能够学习复杂的时间动态,有效管理序列中的长距离依赖关系,克服了传统循环神经网络模型(RNN)在长序列处理上的局限性。坝顶水平位移序列包含了大量样本,为了适应实际工程应

用需求,所拟合的特征应为一个长序列,传统的预测网络无法很好适用于该长度序列,而 BiLSTM 由两层独立的 LSTM 构成,综合了正向时间序列和反向时间序列的长短期记忆单元,能够在处理序列数据时考虑前后信息,解决了 LSTM 模型无法充分利用未来数据信息的问题,不仅提高了数据处理效率,也使预测结果的精度有一定的提升^[16-17]。

1.3 KOA

KOA 是一种基于开普勒行星运动规律的新型优化算法,该算法的原理是将太阳和在椭圆轨道上围绕它旋转的行星表示为搜索空间,由于行星在不同的时间与太阳处于不同的相对位置,可通过不断调整运行轨道逼近最优位置,因此搜索空间被更有效地探索和利用,能有效解决传统进化算法中存在的容易陷入局部最优、收敛速度慢、缺乏种群多样性等连续优化问题。对于本文中 ITransformer-BiLSTM 这种具有众多超参数的组合模型来说,KOA 算法能以更少的尝试次数和更高的精度找到接近全局最优的超参数组合。

1.4 分位数区间模型

1978 年,Koenker 和 Bassett 首次提出了 QR 模型,相较于传统模型,QR 模型对最小二乘回归进行了优化,旨在研究自变量和因变量条件分位数之间的关系,并且能够获取因变量的条件概率分布。将 KIB 模型中的平均绝对误差(MAE)损失变成分位数损失函数,构建 QKIB 模型,从而获取各分位点的回归预测与预测置信区间^[18]。针对变形区间概率预测,本文采用预测区间覆盖率(prediction interval coverage probability, PICP)、预测区间归一化平均宽度(prediction interval normalized average width, PINAW)、综合评价指标(comprehensive weighting criterion, CWC)、平均预测区间中心偏差(mean prediction interval center deviation, MPICD)和区间平均分位数(average interval score, AIS)等性能评价指标进行评价。

2 模型构建

ITransformer 模型此前主要用于自然语言识别领域,要将其运用到大坝变形预测中,需对 ITransformer 框架进行一定的改动。ITransformer 模型在结构设计上适应了多序列输入和多序列输出的任务,其预测层模块会选择对应数量的序列进行输出,而其他特征将被抛弃,这在单序列负荷预测的任务中会丢失特征,无法充分利用网络提取的多维特征。大坝变形预测时间序列数据具有多变量输入单变量输出的特点,因此本文所构建模型的输出模块在原预测层模块的基础上,以跳跃连接的方式加入并行的 BiLSTM 层,将多维特征映射为单维特征,有效利用了预测层模块丢弃的特征信息,从而提高了 ITransformer 架构的局部特征捕捉能力^[19-20]。改进的 ITransformer 结构如图 1 所示,表达式如下:

$$M_o(F) = M_p(F) + M_b(F) = f_n + M_b(F) \tag{1}$$

式中: F 为特征矩阵; f_n 为特征矩阵 F 的第 n 个序列特征; $M_o(F)$ 、 $M_p(F)$ 、 $M_b(F)$ 分别为输出模块、预测层模块和 BiLSTM 模块的处理函数。

KIB 模型预测流程如图 2 所示。构建好 KIB 模型后,在 KIB 模型基础上,将损失函数 MAE 替换为分位数损失函数,进而构建 QKIB 模型用于混凝土坝变形区间预测,其具体的训练与预测流程同 KIB 模型。

3 工程实例验证

3.1 工程概况

某重力拱坝共分 30 个坝段,布置有正垂线测点 6 个,倒垂线测点 10 个,正垂线布置在 8 号、18 号、26 号 3 个代表性坝段。坝区岩层除原生的单斜层状构造外,较大的断层有 F_{11} 、 F_{31} 、 F_{32} 、 F_{35} 等,微细裂隙发育,地质条件复杂,倒垂线主要监测坝基和 F_{11} 、 F_{32} 大断层及两坝肩岩体变形。监测系统更新改造时,新增倒垂线测点 6 个、正垂线测点 1 个^[21]。选取 18 号坝段坝顶水平位移监测数据集来建立变形预测模型。监测时间为 1973 年 1 月至 2007 年 7 月,对监测数据进行预处理后总共得到 3854 组的数据。取 1973 年 1 月 30 日到 2006 年 6 月 5 日共 3469 组数据为训练集,2006 年 6 月 6 日到 2007 年 7 月 10 日共 385 组数据为测试集。

3.2 数据预处理

在混凝土坝的运行过程中,水平位移受到静水水压、温度变化和时间效应的显著影响。为了模拟这些影响,采用的模型参数包括水压因子 H 、 H^2 、 H^3 、 H^4 ,温度因子 $\sin \frac{2\pi it}{365}$ 、 $\cos \frac{2\pi it}{365}$ 、 $\sin \frac{2\pi it}{365} \cos \frac{2\pi it}{365}$,时效因子




图 1 改进的 ITransformer 结构
Fig. 1 Improved ITransformer structure




图 2 KIB 模型预测流程
Fig. 2 Prediction process of KIB model

$\ln\theta$, 其中 H 为监测日上下游水位差, t 为从开始测量到当前日期的天数, θ 为 $0.01t$ 。

3.3 KIB 模型参数寻优

KIB 模型的参数设置为:最大训练次数设定为 70 次, Batch size 取默认值 50, 学习率设定为 0.001, 注意力机制头(head)、注意力机制键(key)、神经元个数、位置编码向量数以及 dropout 丢弃率通过参数寻优来确定。采用麻雀搜索(SSA)、PSO 和 KOA 共 3 种算法分别对模型参数进行优化, 以验证 KOA 算法的优越性, 训练结果如图 3 所示。由图 3 可以看出, KOA 算法训练集的均方根误差曲线和损失函数曲线效果最好, 可

证明所选参数的合理性。KOA 算法在经历 29 轮迭代后,训练集的均方根误差和损失函数均稳定在较低数值,这证明了参数配置的适宜性以及模型训练的高效性。从运行速度上看,SSA 和 PSO 两种寻优算法的用时分别为 298.65 s 和 256.31 s,而 KOA 仅需 80.37 s,可以看出,KOA 算法能解决一般优化算法中收敛速度慢、缺乏种族多样性的缺点,能更有效地探索和利用搜索空间,降低时间复杂度,表明 KOA 算法适应本文构建的混凝土坝变形监测模型。超参数寻优结果为:注意力机制头为 28,注意力机制键为 16,神经元个数为 21,位置编码向量数为 4,丢弃率为 0.09。




图 3 3 种算法的迭代变化曲线
Fig. 3 Iterative change curves of three algorithms

3.4 KIB 模型预测效果分析

对同一数据集,分别建立 ITransformer-BiLSTM (IB)、BiLSTM 和 LSTM 模型与 KIB 模型进行对比,测试集的预测结果如图 4 所示。由图 4 可以看出,KIB 模型在预测的精度和稳定性方面展现出了显著的优越性,与同类深度学习模型相比,它能更准确地映射数据趋势,尤其在变形极值点、数据波动点上与实际测量值的匹配度更高。同时,融合了 BiLSTM 的 KIB 模型,其预测精度的提升尤为突出,这表明 BiLSTM 层的加入显著增强了模型处理时间序列数据的能力,具有更强的时间序列特征捕捉能力,从而实现了更精准的预测效果。这是因为 BiLSTM 能够将多维特征映射为单维特征,有效利用了预测层模块丢弃的特征信息,融合了 BiLSTM 的 KIB 模型可以更全面地分析位移数据的特征,从而提高预测的精度和鲁棒性。4 个模型的预测结果见表 1 和图 5。从表 1 可以看出,相较于 IB、BiLSTM、LSTM 模型,KIB 模型的 MAE 分别降低了 48.66%、62.97%、77.89%,平均绝对百分比误差 (MAPE) 分别降低了 66.02%、84.12%、90.37%,均方误差 (MSE) 分别降低了 69.16%、82.14%、93.08%,均方根误差 (RMSE) 分别降低了 44.46%、57.73%、73.69%,决定系数 R^2 分别提高了 3.22%、6.84%、23.02%。从概率密度图可以清晰地看出 KIB 模型的模拟效果明显优于其他模型。综上可得,相较于传统深度学习模型,KIB 模型表现出更好的精度,误差更小,同时稳定性也增强。这表明对于混凝土坝水位波动、温度应力荷载等影响混凝土坝变形的复杂非线性因素,KIB 模型有着更强的捕捉能力与更精准的预测能力,证实了该模型在混凝土坝变形预测领域的显著优越性。




图 4 4 个模型预测曲线
Fig. 4 Prediction curves of four models

表 1 4 个模型预测效果评价指标

Table 1 Prediction performance evaluation indicators for four models

模型	MAE/mm	MAPE/%	MSE/mm ²	RMSE/mm	R ²
KIB	0.186 04	0.162 93	0.057 77	0.240 37	0.986 28
IB	0.362 37	0.479 45	0.187 33	0.432 82	0.955 51
BiLSTM	0.502 63	1.026 33	0.323 45	0.568 72	0.923 18
LSTM	0.841 47	1.692 64	0.834 77	0.913 66	0.801 73

3.5 QKIB 模型变形区间预测结果分析

为证明 QKIB 模型的区间预测优势,将 QKIB 模型与 QR-LSTM、门控循环单元 (GRU) 和 QR-BiLSTM 模




图 5 4 个模型概率密度分布

Fig. 5 Probability density distribution of four models

型的变形区间预测结果进行了比较,结果如图 6 所示,可以明显看出,QKIB 模型具有更加稳定的预测区间宽度,预测区间的覆盖率接近 100%,特别是在位移发生显著波动的时间段预测区间更窄,预测性能明显优于其他模型,表明 QKIB 模型在变形区间概率预测中有更好的稳定性和优势,也反映了其具有卓越的抗噪性能。另 3 个模型在位移上升阶段的预测区间太窄,无法有效覆盖真实值曲线,最终导致概率预测的区间可靠性很低。借助 ITransformer 模型强大的特征提取和学习能力,QKIB 模型的变形区间预测性能在存在不确定性的混凝土坝变形区间预测中有了大幅的提升。




图 6 4 个模型变形区间预测结果

Fig. 6 Deformation interval prediction results of four models

由表 2 可以看出,在 90%置信度下,QKIB 模型的各评价指标均表现最好,PICP 较 QR-LSTM、GRU、QR-BiLSTM 模型分别提高了 28. 08%、16. 88%、20. 65%,区间覆盖率接近 100%;PINAW 分别降低了 44. 00%、42. 29%、37. 28%,预测区间的平均宽度最小,模型的预测精度最好;CWC 分别降低了 82. 56%、69. 23%、55. 47%,预测区间的狭窄率最低;MPICD 分别降低了 54. 32%、45. 70%、8. 46%,预测区间的中点更靠近真实值,偏移小,预测精度高;AIS 分别降低了 39. 13%、27. 83%、1. 00%。综合来看,QKIB 模型的变形区间概率预测的效果最好。

表 2 90%置信度下 4 个模型变形区间预测结果评价指标

模型	PICP	PINAW	CWC	MPICD	AIS
QKIB	0. 971 43	0. 151 76	0. 241 95	0. 282 11	0. 357 45
QR-LSTM	0. 758 44	0. 271 02	1. 387 36	0. 617 55	0. 587 25
GRU	0. 831 17	0. 262 98	0. 786 48	0. 519 53	0. 495 28
QR-BiLSTM	0. 805 19	0. 241 95	0. 543 42	0. 308 17	0. 361 06

4 结 语

本文鉴于传统模型超参数寻优困难,长时间序列下数据特征关系复杂,集成 KOA 算法、ITransformer 模型和 BiLSTM 等优势,构建了基于 KOA-ITransformer-BiLSTM 的混凝土坝位移预测模型(KIB 模型),提高了混凝土坝变形预测模型精度;在此模型基础上,引入 QR 方法,构建了基于 QR-KOA-ITransformer-BiLSTM 的混凝土坝变形区间预测模型(QKIB 模型),显著提高了变形区间预测精度和全局稳定性。实例分析结果表明,相较于 LSTM 模型,KIB 模型的精度明显提高,模型的 MAE、MAPE、MSE 和 RMSE 指标分别降低了 77.89%、90.37%、93.08%、73.69%, R^2 提高了 23.02%;在满足覆盖率接近 100%的前提下,QKIB 模型在置信水平为 90%时的区间预测指标均表现最好,其中 CWC 由 QR-LSTM、GRU、QR-BiLSTM 的 1.387 36、0.786 48、0.543 42 减小到 0.241 95,具有显著的优越性。本文构建的模型实现了超参数的最优选取,可以捕捉数据更深层次的特征信息,不仅有效提高了混凝土坝位移预测精度,同时具有更好的变形区间概率预测性能。

参考文献:

[1] 邵楠,于中伟. 基于 ELM 的大坝变形分析与预报模型[J]. 城市勘测,2016(4):134-136. (Shao Nan, Yu Zhongwei. Dam deformation analysis and prediction model based on extreme learning machine[J]. Urban Geotechnical Investigation & Surveying, 2016(4):134-136. (in Chinese))

[2] 李明. 基于改进 BP 神经网络的大坝安全监测预报模型[J]. 水利科技与经济,2021,27(3):85-90. (Li Ming. Prediction model for dam safety monitoring based on improved bp neural network[J]. Water Conservancy Science and Technology and Economy,2021,27(3):85-90. (in Chinese))

[3] 徐卫亚,陈世壮,张贵科,等. 基于 PSO-LSSVM-BP 模型的高边坡力学参数反分析及稳定性评价[J]. 河海大学学报(自然科学版),2024,52(5):52-59. (Xu Weiya, Chen Shizhuang, Zhang Guike, et al. Inverse analysis of mechanical parameters of high slope based on PSO-LSSVM-BP model and stability evaluation[J]. Journal of Hohai University(Natural Sciences),2024,52(5):52-59. (in Chinese))

[4] 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. (in Chinese))

[5] 欧斌,吴邦彬,袁杰,等. 基于 LSTM 的混凝土坝变形预测模型[J]. 水利水电科技进展,2022,42(1):21-26. (Ou Bin, Wu Bangbin, Yuan Jie, et al. LSTM-based deformation prediction model of concrete dams[J]. Advances in Science and Technology of Water Resources,2022,42(1):21-26. (in Chinese))

[6] 张建辉,滕婕,李秀慧,等. 基于气象特征和改进 Transformer 的光伏功率短期预测[J]. 热能动力工程,2024,39(8):146-154. (Zhang Jianhui, Teng Jie, Li Xiuhui, et al. Short-term prediction of photovoltaic power based on meteorological features and improved Transformer[J]. Journal of Engineering for Thermal Energy and Power,2024,39(8):146-154. (in Chinese))

[7] 牛甲俊,张薇,许达明. 基于 FCM 和 ITransformer-TCN 的短期风电集群功率预测[J]. 东北电力大学学报,2024,44(1):9-16. (Niu Jiajun, Zhang Wei, Xu Daming. Short-term power prediction of wind power cluster based on FCM and ITransformer-TCN [J]. Journal of Northeast Electric Power University,2024,44(1):9-16. (in Chinese))

[8] 刘璐. 基于 BERT 的金融舆情因子构建分析[D]. 武汉:华中农业大学,2022.

[9] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach:Curran Associates Inc. ,2017:6000-6010.

[10] Abdel-Basset M, Mohamed R, Azeem S A A, et al. Kepler optimization algorithm: a new metaheuristic algorithm inspired by Kepler's laws of planetary motion[J]. Knowledge-Based Systems,2023,268:110454.

[11] 王开艳,杜浩东,贾嵘,等. 基于相似日聚类 and 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))

[12] 刘锦翔,张江丰,董山玲,等. 基于条件增强扩散模型的短期负荷概率预测[J]. 电力系统自动化,2024,48(23):197-207. (Liu Jinxiang, Zhang Jiangfeng, Dong Shanling, et al. Short-term load probability forecasting based on conditional enhanced diffusion model[J]. Automation of Electric Power Systems,2024,48(23):197-207. (in Chinese))

[23] Duguay J, Biron P M, Lacey J. Impact of density gradients on the secondary flow structure of a river confluence[J]. Water Resources Research, 2022, 58(10): e2022WR032720.

[24] Lee M, Park Y S, Ko J S, et al. The influence of density difference, discharge ratio and wind on the mixing at large river confluence[J]. Journal of Hydro-Environment Research, 2024, 56: 1-15.

[25] Cheng Zhengyang, Constantinescu G. Stratification effects on flow hydrodynamics and mixing at a confluence with a highly discordant bed and a relatively low velocity ratio[J]. Water Resources Research, 2018, 54(7): 4537-4562.

[26] Shi Lidi, Sun Jian, Lin Binliang, et al. Hydro-thermodynamic processes at a large confluence under reservoir regulation[J]. Water Resources Research, 2022, 58(12): e2022WR033315.

[27] 王彪, 朱建荣, 吕爱琴. 珠江河口磨刀门枯水期盐度统计模型[J]. 水资源保护, 2023, 39(1): 42-48. (Wang Biao, Zhu Jianrong, Lyu Aiqin. Salinity statistical model for Modaomen of Pearl River Estuary during dry season[J]. Water Resources Protection, 2023, 39(1): 42-48. (in Chinese))

[28] Ramón C L, Armengol J, Dolz J, et al. Mixing dynamics at the confluence of two large rivers undergoing weak density variations[J]. Journal of Geophysical Research: Oceans, 2014, 119(4): 2386-2402.

[29] Ramón C L, Prats J, Rueda F. The influence of flow inertia, buoyancy, wind, and flow unsteadiness on mixing at the asymmetrical confluence of two large rivers[J]. Journal of Hydrology, 2016, 539: 11-26.

[30] Hu Lihan, Xu Jin, Han Jianjun, et al. Three-dimensional hydrodynamics and morpho-dynamics at a tidal river junction[J]. Estuaries and Coasts, 2023, 47(2): 376-396.

[31] Horna-Munoz D, Constantinescu G, Rhoads B, et al. Density effects at a concordant bed natural river confluence[J]. Water Resources Research, 2020, 56(4): e2019WR026217.

[32] Finotello A, Ghinassi M, Carniello L, et al. Three-dimensional flow structures and morphodynamic evolution of microtidal meandering channels[J]. Water Resources Research, 2020, 56(7): e2020WR027822.

[33] Jiang Chenyu, Constantinescu G, Yuan Saiyu, et al. Flow hydrodynamics, density contrast effects and mixing at the confluence between the Yangtze River and the Poyang Lake channel[J]. Environmental Fluid Mechanics, 2022, 23(2): 229-257.

(收稿日期: 2024-12-24 编辑: 熊水斌)



(上接第108页)

[13] 公海涛, 陈志华, 盛斌, 等. 基于孪生网络和 Transformer 的小目标跟踪算法 SiamTrans[J]. 计算机应用, 2023, 43(12): 3733-3739. (GONG Haitao, CHEN Zhihua, SHENG Bin, et al. SiamTrans: tiny object tracking algorithm based on Siamese network and Transformer[J]. Journal of Computer Applications, 2023, 43(12): 3733-3739. (in Chinese))

[14] 张龙威, 刘小生, 刘相杰. 基于 BES-BiLSTM 的混凝土坝变形预测[J]. 水电能源科学, 2023, 41(9): 94-97. (Zhang Longwei, Liu Xiaosheng, Liu Xiangjie. Deformation prediction of concrete dam based on BES-BiLSTM[J]. Water Resources and Power, 2023, 41(9): 94-97. (in Chinese))

[15] 欧斌, 张才溢, 陈德辉, 等. 基于改进 EMD-LSTM 的混凝土坝变形预测模型[J]. 水利水电科技进展, 2024, 44(6): 93-99. (Ou Bin, Zhang Caiyi, Chen Dehui, et al. Deformation prediction model for concrete dams based on improved EMD-LSTM[J]. Advances in Science and Technology of Water Resources, 2024, 44(6): 93-99. (in Chinese))

[16] 王瑞琪. 长短期记忆网络在模型预测控制中的应用[D]. 北京: 北京化工大学, 2020.

[17] 王耀辉, 薛贵军, 赵广昊. 基于改进沙猫群算法优化 CNN-BiLSTM 的热负荷预测[J]. 现代电子技术, 2024, 47(14): 20-29. (Wang Yaohui, Xue Guijun, Zhao Guanghao. Optimised CNN-BiLSTM for heat load prediction based on improved sand cat swarm algorithm[J]. Modern Electronics Technique, 2024, 47(14): 20-29. (in Chinese))

[18] 张栩, 颜伟, 李辉, 等. 基于 QR-BiGRU 神经网络与区间抗差增广状态估计的线路参数区间追踪估计[J]. 电工技术学报, 2024, 39(23): 7406-7417. (Zhang Xu, Yan Wei, Li Hui, et al. Interval estimation and tracking method for transmission line parameters based on QR-BiGRU neural network and interval robust augmented state estimation[J]. Transactions of China Electrotechnical Society, 2024, 39(23): 7406-7417. (in Chinese))

[19] 易海燕. 基于小波分解和卷积神经网络的光伏发电功率预测方法[D]. 深圳: 深圳大学, 2018.

[20] 翁鸣昊, 项兴华, 陈俊涛, 等. 基于 LSTM 与 Transformer 的大坝变形预测研究[J]. 中国农村水利水电, 2024(4): 250-257. (Weng Minghao, Xiang Xinghua, Chen Juntao, et al. Dam deformation prediction research based on LSTM and transformer[J]. China Rural Water and Hydropower, 2024(4): 250-257. (in Chinese))

[21] 秦俊德. 陈村大坝坝基渗压问题的探讨[J]. 大坝与安全, 1991(4): 28-33. (Qin Junde. Discussion on the seepage pressure problem of Chencun Dam foundation[J]. Dam and Safety, 1991(4): 28-33. (in Chinese))

(收稿日期: 2024-11-05 编辑: 熊水斌)