DOI:10.20040/j.cnki.1000－7709.2026.20250059

基于 DD-ACMD-PSA-TCN-GRELM 耦合模型的日径流预测

寿玮玮[1],刘月馨[2],顾晨晖[1],王雪峰[2],王 顺[1],葛宜达[3],张 楚[3]

(1. 中国电建集团华东勘测设计研究院有限公司,浙江 杭州 311122; 2. 杭州华辰电力控制工程有限公司,浙江 杭州 311122; 3. 淮阴工学院自动化学院,江苏 淮安 223003)

摘要:径流预测对于科学管理水资源和优化水力发电调度具有重要意义。针对径流预测的非平稳性和不确定性,提出了一种基于数据驱动的自适应啁啾模态分解(DD-ACMD)、PID搜索算法(PSA)、时间卷积网络(TCN)和广义正则化极限学习机(GRELM)的耦合预测模型,并以乌江流域的乌江渡水文站的日径流量为例,通过对比BP、ELM、GRELM、TCN、TCN-GRELM、DD-ACMD-TCN-GRELM模型的预测性能,验证了所提模型的有效性。结果表明,本文所提方法通过引入深度学习技术和优化算法调参,可提供更加精准和可靠的径流预测结果,其纳什系数可达0.957 5。

关键词:PID搜索算法;时间卷积网络;GRELM;径流预测

中图分类号:TV121^{+}.1; P338 **文献标志码**:A **文章编号**:1000-7709(2026)02-0001-05

Daily Runoff Prediction Based on Coupled the DD-ACMD-PSA-TCN-GRELM Model

SHOU Wei-wei[1], LIU Yue-xin[2], GU Chen-hui[1], WANG Xue-feng[2], WANG Shun[1], GE Yi-da[3], ZHANG Chu[3]

(1. PowerChina Huadong Engineering Corporation Limited, Hangzhou 311122, China; 2. Hangzhou Huachen Power Control Engineering Corporation Limited, Hangzhou 311122, China; 3. Faculty of Automation, Huaiyin Institute of Technology, Huai'an 223003, China)

Abstract: Runoff prediction is important for scientific management of water resources and optimization of hydropower generation scheduling. A coupled prediction model based on data-driven adaptive chirp mode decomposition (DD-ACMD), PID-based search algorithm (PSA), temporal convolutional network (TCN), and generalized regularized extreme learning machine (GRELM) is proposed to address the non-stationarity and uncertainty of runoff prediction. The daily runoff for the Wujiangdu Hydrological Station in the Wujiang River Basin is studied and the effectiveness of the proposed model is verified by comparing the prediction performances of the BP, ELM, GRELM, TCN, TCN-GRELM and DD-ACMD-TCN-GRELM models with a Nash-Sutcliffe efficiency coefficient of up to 0.957 5. The experimental results show that the proposed method can provide more accurate and reliable runoff prediction by introducing deep learning techniques and optimizing the algorithm tuning parameters.

Key words: PID-based search algorithm; temporal convolutional network; GRELM; runoff prediction

收稿日期:2025-01-07,**修回日期**:2025-03-05,**接受日期**:2025-03-10

基金项目:国家自然科学基金青年科学基金项目(62303191);江苏省自然科学基金项目(BK20191052);江苏省高校自然科学基金面上项目(23KJD480001);江苏省双创计划(JSSCBS20201037);江苏省"青蓝工程"(苏教师函[2024]14号);淮阴工学院研究生科研与实践创新计划项目(HGYK202412,HGYK202413)

作者简介:寿玮玮(1982-),男,博士、高级工程师,研究方向为水文水动力模型与水利信息化,E-mail:shou_ww1@hdec.com

通讯作者:张楚(1989-),男,副教授、硕导,研究方向为水电、风电等清洁能源优化运行与控制、人工智能应用,E-mail:zhangchuhust@foxmail.com

中国知网 https://www.cnki.net

1 引言

径流量的准确预测对于水资源管理、洪水预警、水力发电和环境保护等至关重要[1]。流域水文过程的复杂性以及极端气象事件的不确定性，使得径流量的准确预测难度较大。近年来，人工智能模型[2]因其在处理复杂非线性关系和集成大量数据等方面的优势，成为径流量预测的主流方法，如徐军杨等[3]利用深度信念极限学习机(DBN-ELM)实现了对渭河上游北道水文站日径流的高精度预测。此外，为了能够更有效地降低径流数据中的非平稳特性，将分解技术与人工智能模型相结合，从而提高径流量预测的准确性，如程家波等[4]使用变分模态分解(VMD)对日径流数据进行分解，并将分量输入残差网络(ResNet)中，得到较为精确的径流预测结果。考虑到人工智能模型存在大量参数，传统手动调参方式不仅耗时还存在较大的主观性，越来越多使用智能算法寻优来解决此问题。因此，本文以乌江流域乌江渡水文站的日径流量为例，提出一种基于数据驱动的自适应啁啾模态分解(DD-ACMD)、PID搜索算法(PSA)、时间卷积网络(TCN)、广义正则化极限学习机(GRELM)的组合预测模型，并将 BP、ELM、GRELM、TCN、TCN-GRELM、DD-ACMD-TCN-GRELM 模型作为对照组，验证了所提 DD-ACMD-PSA-TCN-GRELM 模型的有效性。

2 研究方法

2.1 数据驱动的自适应啁啾模态分解

传统的自适应啁啾模态分解(ACMD)是一种高效的信号分解方法，专为处理非平稳信号设计。然而，ACMD 在处理具有非常接近或重叠频率模态的宽带非平稳信号时可能会遇到困难。为了解决上述问题，开发了一种数据驱动的自适应啁啾模态分解(DD-ACMD)技术[5]，实现对复杂非平稳信号的有效分解。具体过程如下。

(1)对日径流时间序列信号求导来增强高频模式，其导数可以表示为：

$$s'(t)=\sum_{i=1}^{K}\left[a_i'(t)\cos\phi_i(t)-a_i(t)\phi_i'(t)\sin\phi_i(t)\right] \tag{1}$$

式中，$s'(t)$ 为信号 $s(t)$ 的导数；$s(t)$ 为原始日径流时间序列信号；K 为信号中模态的总数；$a_i(t)$ 为第 i 个模态的振幅；$\phi_i(t)$ 为第 i 个模态的相位函数；$\phi_i'(t)$ 为第 i 个模态的瞬时频率；$a_i'(t)$ 为 $a_i(t)$ 的导数；t 为时间变量。

(2)通过对信号的导数进行归一化来估计最高频率模式的初始瞬时频率，具体公式为：

$$f_i(t)=\frac{1}{2\pi}\frac{\mathrm{d}}{\mathrm{d}t}\arccos g_i(t)=\frac{1}{2\pi}\frac{\mathrm{d}\phi_i(t)}{\mathrm{d}t} \tag{2}$$

式中，$f_i(t)$ 为最高频率模式的瞬时频率；$g_i(t)$ 为归一化后的第 i 个模态的调频信号；$\phi_i(t)$ 第 i 个模态的相位函数。

(3)引入时变低通滤波器去除当前信号估计瞬时频率以上的噪声，过程如下。

步骤 1 将调频信号改写为：

$$p(t)=\cos\left[2\pi\int_0^t m(\tau)\mathrm{d}\tau+\theta_0\right] \tag{3}$$

式中，$p(t)$ 为调频信号；$m(\tau)\mathrm{d}\tau$ 为在一个时间间隔 τ 上瞬时频率 $m(\tau)$ 的微小变化量；θ_0 为初始相位。

步骤 2 计算调频信号的解析信号：

$$y(t)=p(t)+\mathrm{j}H[p(t)]=\exp\left\{\mathrm{j}\left[2\pi\int_0^t m(\tau)\mathrm{d}\tau+\theta_0\right]\right\} \tag{4}$$

式中，$y(t)$ 为 $p(t)$ 的解析信号；$p(t)$ 为调频信号；$H[p(t)]$ 为 $p(t)$ 的 Hilbert 变换。

步骤 3 定义解调算子 $\Phi^-(t)$ 和调制算子 $\Phi^+(t)$：

$$\Phi^-(t)=\exp\left\{-\mathrm{j}2\pi\int_0^t m_\mathrm{d}(\tau)\mathrm{d}\tau-m_\mathrm{c}t\right\} \tag{5}$$

$$\Phi^+(t)=\exp\left\{\mathrm{j}2\pi\int_0^t m_\mathrm{d}(\tau)\mathrm{d}\tau-m_\mathrm{c}t\right\} \tag{6}$$

式中，$m_\mathrm{d}(\tau)$ 为解调频率；m_c 为载波频率。

步骤 4 将解析信号乘以解调算子得到解调信号：

$$y_\mathrm{d}(t)=y(t)\Phi^-(t) \tag{7}$$

式中，$y_\mathrm{d}(t)$ 为解调后的信号。

步骤 5 通过低通滤波去除高于载波频率的噪声，然后乘以调制算子得到新的解析信号：

$$\hat{y}(t)=\hat{y}_\mathrm{d}(t)\Phi^+(t) \tag{8}$$

式中，$\hat{y}(t)$ 为经过调制后的信号；$\hat{y}_\mathrm{d}(t)$ 为经过低通滤波后的解调信号。

(4)在每次模式提取后，使用时变低通滤波器去除模态以上的噪声，以减少对后续模态提取的影响，通过递归框架从高频到低频依次提取信号模态；每次提取一个模态后，更新剩余信号并重复上述过程，直到满足停止条件。

2.2 时间卷积网络

时间卷积网络(TCN)[6]是一种高效的深度学习模型，特别擅长捕捉时间序列数据中的长距

中国知网 https://www.cnki.net

离依赖关系,通过使用扩张卷积和残差连接,其能够在保持较小计算成本的同时,实现对复杂序列模式的深入理解。因此,TCN 能对时间序列数据进行特征提取,利用扩张卷积技术捕捉时间序列数据中的长期依赖性,同时通过残差连接增强模型的学习能力,使得 TCN 能够从复杂的序列中提取出丰富且具有区分性的特征。其扩张因果卷积的结构见图 1。

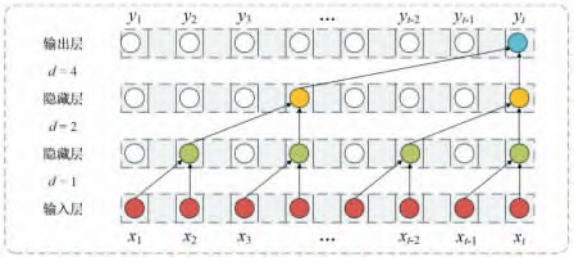


图 1　TCN 的扩张因果卷积的结构

Fig. 1　Structure of dilated causal convolution of TCN

2.3　广义正则化极限学习机

由于径流数据具有高度的非线性和动态性,传统的正则化极限学习机(RELM)难以准确捕捉复杂特征,从而影响模型的泛化能力。因此,提出了一种改进的模型——广义正则化极限学习机(GRELM)[7]。该模型通过结合不同的范数来促进输出权重的稀疏性,不仅提高了泛化能力,还能减少不必要的神经元,从而降低模型复杂度。其建模步骤如下。

步骤 1　初始化。随机生成隐藏节点的参数 a_i、v_i,初始化输出权重矩阵 $\boldsymbol{B}$ 和辅助变量 $\boldsymbol{Z}$。

步骤 2　构建目标函数。计算公式为:

$$\min_{\boldsymbol{B},\boldsymbol{Z}} \frac{1}{2} \| \boldsymbol{HB}-\boldsymbol{T} \|_F^2 + \lambda_1 \| \boldsymbol{B} \|_{2,1} + \lambda_2 \| \boldsymbol{B} \|_F^2 \tag{9}$$

式中,$\boldsymbol{H}$ 为隐藏层输出矩阵;$\boldsymbol{T}$ 为目标输出;λ_1、λ_2 均为正则化参数。

步骤 3　交替方向乘子法(ADMM)的迭代过程。通过最小化增强拉格朗日函数来更新 $\boldsymbol{B}$:

$$\boldsymbol{B}^{k+1}=(\boldsymbol{H}^{\mathrm{T}}\boldsymbol{H}+\eta\boldsymbol{I})^{-1}[\boldsymbol{H}^{\mathrm{T}}\boldsymbol{T}+\rho(\boldsymbol{Z}^k-\boldsymbol{U}^k)] \tag{10}$$

其中　　$\eta=(\lambda_2+\rho)/C$

式中,η 为等效正则化参数;$\boldsymbol{I}$ 为单位矩阵;ρ 为惩罚参数;$\boldsymbol{U}^k$ 为拉格朗日乘子。

通过软阈值操作更新 $\boldsymbol{Z}$:

$$\boldsymbol{Z}^{k+1}=S_{\lambda_1/\rho}(\boldsymbol{B}^{k+1}+\boldsymbol{U}^k) \tag{11}$$

式中,$S_{\lambda_1/\rho}$ 为块软阈值操作。

更新拉格朗日乘子:

$$\boldsymbol{U}^{k+1}=\boldsymbol{U}^k+\boldsymbol{B}^{k+1}-\boldsymbol{Z}^{k+1} \tag{12}$$

步骤 4　输出权重。最终的输出权重矩阵 $\boldsymbol{B}$ 即为模型的预测参数。

2.4　PID 搜索算法

PID 搜索算法(PSA)的灵感来源于 PID 控制算法,这是一种在过程控制领域广泛使用的算法[8]。算法的基本原理如下。

(1)初始化。假设决策变量的数量为 d,变量的上下限分别为 u、l。PSA 算法的控制参数包括最大迭代次数 T 和种群大小 n。初始种群可以通过以下公式生成:

$$x_{ij}=(u_j-l_j)r_1+l_j$$
$$i=1,2,\cdots,n;j=1,2,\cdots,d \tag{13}$$

式中,x_{ij} 为第 i 个个体的第 j 维;u_j、l_j 分别为第 j 个变量的上下限;r_1 为 0～1 之间的随机数。

(2)增量 PID 控制:①计算系统偏差。对于最小化问题,迭代次数 t 时种群中的最佳个体 $x^*(t)$ 是对应于历史最小值的个体。种群在迭代次数 t 时的偏差 $e_k(t)$ 定义为:

$$e_k(t)=x^*(t-1)-x(t-1) \tag{14}$$

为了便于计算和迭代更新,将前 1 次迭代的种群偏差表示为 $e_{k-1}(t)$,前 2 次迭代的种群偏差表示为 $e_{k-2}(t)$。$e_{k-1}(t)$ 可以表示为:

$$e_{k-1}(t)=e_k(t-1)+x^*(t)-x^*(t-1) \tag{15}$$

②PID 调节。迭代次数 t 时 PID 调节的输出值 $\Delta u(t)$ 定义为:

$$\Delta u(t)=K_p\boldsymbol{r}_2[e_k(t)-e_{k-1}(t)]+K_i\boldsymbol{r}_3e_k(t)+K_d\boldsymbol{r}_4[e_k(t)-2e_{k-1}(t)+e_{k-2}(t)] \tag{16}$$

式中,$\boldsymbol{r}_2$、$\boldsymbol{r}_3$、$\boldsymbol{r}_4$ 分别为 0～1 之间的随机数向量;K_p、K_i、K_d 分别为比例、积分、微分的调整系数。

(3)零输出。为了防止算法陷入局部最优,PSA 算法引入了一个称为零输出的条件因子。零输出的定义如下:

$$o(t)=[\cos(1-t/T)+\lambda(t)\boldsymbol{r}_5L]e_k(t) \tag{17}$$

其中　　$\lambda=[\ln(T-t+2)/\ln T]^2$

式中,$\boldsymbol{r}_5$ 为 0～1 之间的随机数向量;L 为 Levy 飞行函数;λ 为调整系数。

(4)种群更新。所有个体的更新均与 $\Delta u(t)$、$o(t)$ 相关。种群更新公式定义为:

$$x(t+1)=x(t)+\boldsymbol{\eta}\Delta u(t)+(1-\eta)o(t) \tag{18}$$

其中　　$\boldsymbol{\eta}=\boldsymbol{r}_6\cos(t/T)$

式中,$\boldsymbol{\eta}$ 为一个 0～1 之间的随机数矩阵;$\boldsymbol{r}_6$ 为 0～1 之间的随机数矩阵。

2.5　DD-ACMD-PSA-TCN-GRELM 模型的构建

DD-ACMD-PSA-TCN-GRELM 模型结构见

中国知网　https://www.cnki.net

图 2。步骤如下。

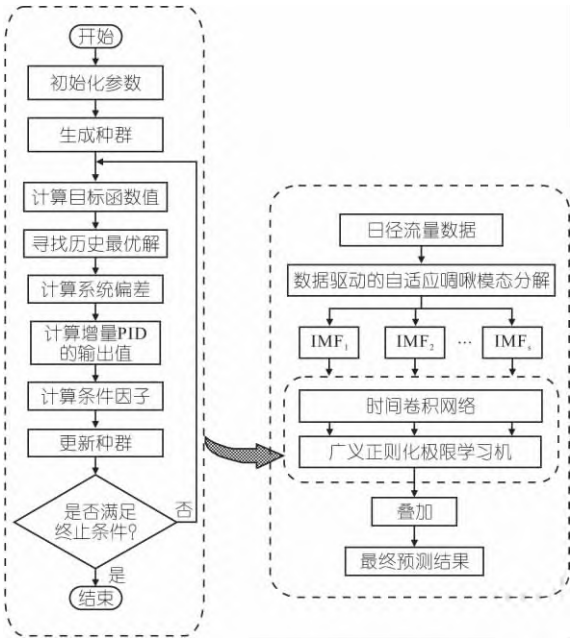


图 2 DD-ACMD-PSA-TCN-GRELM 模型的结构

Fig. 2 Structural framework of DD-ACMD-PSA-TCN-GRELM model

步骤 1 使用 DD-ACMD 对原始日径流数据进行分解，得到多个分量。

步骤 2 对每个分量构造输入矩阵，并划分为训练集和测试集。

步骤 3 利用训练集构建 TCN-GRELM 组合模型，即将训练集数据送入 TCN 中挖掘日径流量数据之间的潜在关联，利用 GRELM 模型的非线性拟合能力，快速学习并适应新数据。

步骤 4 使用 PSA 算法优化 TCN-GRELM 模型的丢弃率、残差块的个数和隐藏层神经元数等重要参数，以提升 TCN-GRELM 模型的预测性能。

步骤 5 利用测试集得到每个分量的预测结果并相加，得到最终日径流量的预测值。

3 实例应用

3.1 概况

乌江流域位于中国西南部，发源于贵州省威宁县，流域内年均降水量在 1 000～1 500 mm 之间，降水主要集中在夏季，冬季则相对干燥。乌江流域的水资源受季节性降水影响，夏季水量较大，冬季则相对较少。乌江渡水文站位于贵州省遵义县境内的乌江干流上，是乌江渡水电站的重要依据站。该水文站监测的水文数据包括多年平均流量 502 m^3/s，设计洪水流量为 19 200 m^3/s。乌江流域水系图及乌江渡水文站点示意图见图 3。

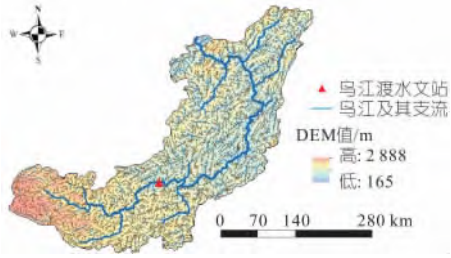


图 3 乌江流域水系图及乌江渡水文站点的示意图

Fig. 3 Map of water system of Wujiang River Basin and schematic diagram of hydrological stations in Wujiangdu

3.2 数据预处理

收集了 2000 年 5 月 1 日～2020 年 4 月 29 日乌江流域乌江渡水文站的径流量，采样频率为 1 次/d，共计 7 304 个数据点。通过 DD-ACMD 方法对采集的原始径流量数据进行分解，可以有效地降低原始信号的非平稳特性，分解结果见图 4。

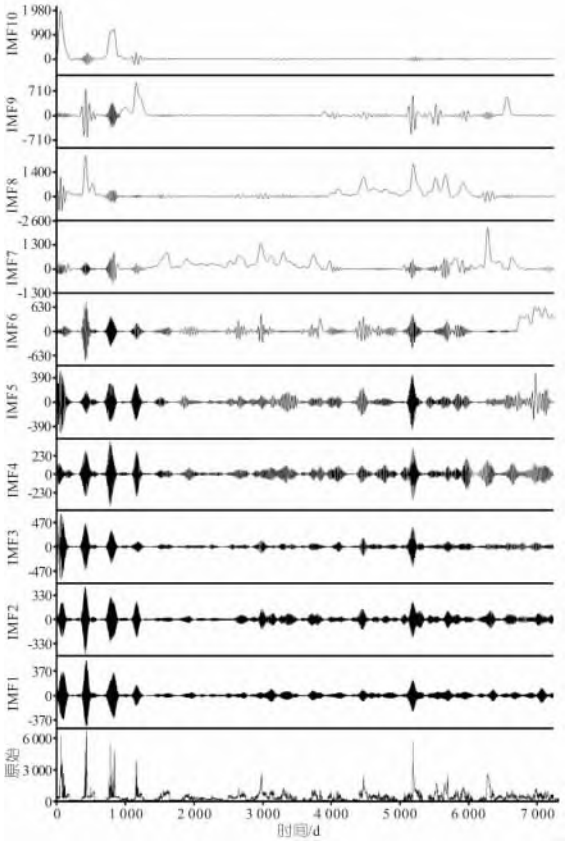


图 4 原始径流量分解示意图

Fig. 4 Schematic diagram of decomposition of original runoff

3.3 参数设置及评价指标

对样本数据集进行划分，前 70%的数据作为训练集，剩下的 30%作为测试集。输入序列长度为 7，预见期为 1 d。设置 DD-ACMD 分解的惩罚参数为 1×10^{-5}，分解的最大模态数为 20。TCN-GRELM 模型的参数设置学习率为 0.01，最大迭代次数为 800，卷积核的个数为 [2, 64]，激活函

中国知网 https://www.cnki.net

数为 sigmoid。设置 PSA 算法的种群大小为 30,迭代次数为 20。采用多种指标,包括均方根误差(R_{RMSE})、平均绝对误差(M_{MAE})、相关系数(R)、对称平均绝对百分比误差(S_{SMAPE})、纳什效率系数(N_{NSE})客观评价所提模型的预测性能。

3.4　结果与分析

在对乌江流域乌江渡水文站的径流量预测研究中,提出了一种新的预测模型——DD-ACMD-PSA-TCN-GRELM,为了验证所提模型的精确性和鲁棒性,将 BP、ELM、GRELM、TCN、TCN-GRELM、DD-ACMD-TCN-GRELM 模型作为对照组。乌江渡水文站点评价指标见表 1。

表 1　乌江渡水文站点评价指标

Tab. 1　Evaluation indicators of Wujiangdu Hydrological Station

模型	阶段	R_{RMSE}	M_{MAE}	R	S_{SMAPE}/%	N_{NSE}
BP	训练	182.337 2	108.443 2	0.932 1	26.041 2	0.846 8
	测试	191.377 1	115.518 8	0.920 2	30.407 9	0.840 7
ELM	训练	176.457 1	102.251 4	0.092 9	25.855 6	0.859 2
	测试	180.814 1	102.641 8	0.926 4	26.445 6	0.857 8
GRELM	训练	172.336 2	102.064 1	0.929 6	26.127 6	0.868 7
	测试	175.465 2	102.279 3	0.929 4	26.342 8	0.863 4
TCN	训练	162.558 4	97.081 0	0.947 4	24.131 2	0.885 4
	测试	171.746 9	102.025 9	0.935 2	26.221 3	0.871 7
TCN-GRELM	训练	151.171 5	91.258 1	0.950 2	22.844 6	0.888 9
	测试	168.254 1	98.545 2	0.937 9	26.013 2	0.876 5
DD-ACMD-TCN-GRELM	训练	94.256 7	62.812 4	0.988 1	19.142 6	0.959 4
	测试	109.567 4	71.812 6	0.972 3	21.221 3	0.948 2
DD-ACMD-PSA-TCN-GRELM	训练	88.594 1	50.624 5	0.989 0	18.054 6	0.969 4
	测试	97.674 4	58.562 8	0.978 2	20.234 3	0.957 5

注:R_{RMSE}、M_{MAE} 单位均为 m^3/s。

由表 1 可看出,各模型在训练阶段的指标更为出色,值得注意的是,DD-ACMD-PSA-TCN-GRELM 模型在测试集上的各项指标均优于对照组中的其他模型。其 R_{RMSE}、M_{MAE} 分别为 97.674 4、58.562 8,低于 BP、ELM、GRELM、TCN、TCN-GRELM、DD-ACMD-TCN-GRELM 模型,这表明 DD-ACMD-PSA-TCN-GRELM 模型在预测精度上具有显著优势,各模型在测试集中的评价指标见图 5。

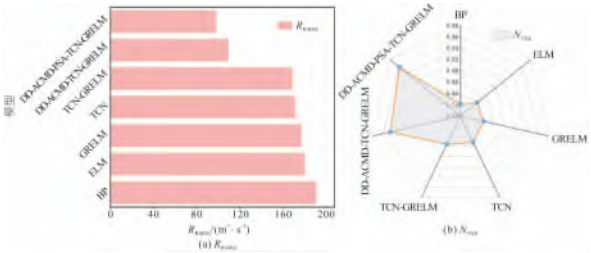


图 5　模型在测试集中的评价指标对比

Fig. 5　Comparison of evaluation metrics of models in test set

模型预测结果对比见图 6。由图 6 可看出,本文所提模型展现出了较为优异的拟合能力。由

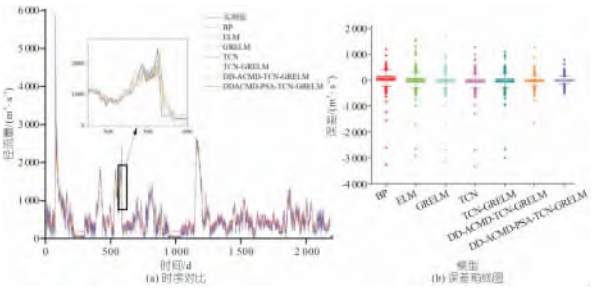


图 6　模型预测结果对比

Fig. 6　Comparison of model prediction results

图 6(a)可看出,在径流量激增时,虽然存在一定偏差,但相较于其他模型,DD-ACMD-PSA-TCN-GRELM 模型能够更准确地捕捉到径流量的非线性关系。由图 6(b)可看出,本文所提模型在径流预测中体现较高的鲁棒性,异常值最少。综上所述,所提 DD-ACMD-PSA-TCN-GRELM 模型在乌江流域乌江渡水文站的径流量预测中表现出色,体现了较高的准确性和稳定性。

4　结论

a. DD-ACMD 通过其自适应性和鲁棒性,为复杂且非平稳的径流数据分析提供了一种有效工具。

b. 所构建的 TCN-GRELM 模型结合了 TCN 和 GRELM 各自的优势,进一步提升了径流量的预测精度。

c. PSA 算法通过更精细的参数调整,提高了模型的泛化能力和稳定性。

参考文献:

[1]　王富强,霍风霖. 中长期水文预报方法研究综述[J]. 人民黄河,2010,32(3):25-28.(WANG F Q, HUO F L. Summary of research on medium and long-term hydrological forecasting methods[J]. Yellow River, 2010, 32(3): 25-28(in Chinese)).

[2]　徐刚,胡婷婷,王琛倪. 基于深度学习的流域洪水预报模型研究[J]. 水文,2023,43(3):82-87,92.(XU G, HU T T, WANG C N. Research on watershed flood forecasting model based on deep learning[J]. Journal of China hydrology, 2023, 43(3): 82-87, 92.(in Chinese))

[3]　徐军杨,张奇伟,蔡鹏,等. 基于深度信念极限学习机与卷积优化算法的洪水预报方法[J]. 水电能源科学,2024,42(8):48-52.(XU J Y, ZHANG Q W, CAI P, et al. Flood prediction method based on deep belief extreme learning machine and convolution optimization algorithm[J]. Water resources and power, 2024, 42(8): 48-52.(in Chinese))

(下转第 21 页)

中国知网　https://www.cnki.net

Study of flood inundation of strong bend river junction in mountainous area[J]. Water resources and power, 2025, 43(2): 15-17, 136.(in Chinese)).

[5] 张文婷, 唐雯雯. 基于水动力学模型的沿海城市洪水实时演进模拟[J]. 吉林大学学报(地球科学版), 2021, 51(1): 212-221.(ZHANG W T, TANG W W. Real-time flood routing simulation of coastal cities based on hydrodynamic model[J]. Journal of Jilin University (earth science edition), 2021, 51(1): 212-221.(in Chinese)).

[6] 黄国如, 陈文杰, 喻海军. 城市洪涝水文水动力耦合模型构建与评估[J]. 水科学进展, 2021, 32(3): 334-344.(HUANG G R, CHEN W J, YU H J. Construction and evaluation of an integrated hydrological and hydrodynamics urban flood model[J]. Advances in water science, 2021, 32(3): 334-344.(in Chinese)).

[7] BERMÚDEZ M, CEA L, PUERTAS J. A rapid flood inundation model for hazard mapping based on least squares support vector machine regression[J]. Journal of flood risk management, 2019, 12(S1): e12522.

[8] KABIR S, PATIDAR S, XIA X L, et al. A deep convolutional neural network model for rapid prediction of fluvial flood inundation[J]. Journal of hydrology, 2020, 590: 125481.

[9] 张景帅, 胡彩虹. 基于深度学习模型的中小河流洪水模拟[J]. 水电能源科学, 2024, 42(10): 11-15.(ZHANG J S, HU C H. Flood simulation of small and medium-sized rivers based on deep learning model[J]. Water resources and power, 2024, 42(10): 11-15.(in Chinese)).

[10] 顾宇丹. 上海城市人口密集区强降水积水阈值研究[J]. 暴雨灾害, 2016, 35(6): 590-595.(GU Y D. Study on the waterlogging threshold of heavy precipitation in the densely populated areas of Shanghai[J]. Torrential rain and disasters, 2016, 35(6): 590-595.(in Chinese)).

(上接第 5 页)

[4] 程家波, 姬厚灵, 陈中举, 等. 基于 GWO-PE-VMD-ResNet 组合模型的日径流预测[J]. 水电能源科学, 2024, 42(8): 43-47.(CHENG J B, JI H L, CHEN Z J, et al. Daily runoff prediction based on the GWO-PE-VMD-ResNet combined model[J]. Water resources and power, 2024, 42(8): 43-47.(in Chinese))

[5] WANG H B, CHEN S Q, ZHAI W M. Data-driven adaptive chirp mode decomposition with application to machine fault diagnosis under non-stationary conditions[J]. Mechanical systems and signal processing, 2023, 188: 109997.

[6] 张上要, 罗军刚, 石国栋, 等. 基于 VMD-TCN 模型的渭河流域月径流量预测研究[J]. 人民黄河, 2023, 45(10): 25-29.(ZHANG S Y, LUO J G, SHI G D, et al. Monthly runoff prediction in Weihe River Basin based on VMD-TCN model[J]. Yellow River, 2023, 45(10): 25-29.(in Chinese))

[7] INABA F K, TEATINI SALLES E O, PERRON S, et al. DGR-ELM-distributed generalized regularized ELM for classification[J]. Neurocomputing, 2018, 275: 1522-1530.

[8] GAO Y S. PID-based search algorithm: A novel metaheuristic algorithm based on PID algorithm[J]. Expert systems with applications, 2023, 232: 120886.

(上接第 10 页)

[13] SONG M Y, WANG J J, LI R. The importance of weather factors in the resilience of airport flight operations based on Kolmogorov-Arnold networks (KANs)[J]. Applied sciences, 2024, 14(19): 8938.

[14] MAN Y Y, YANG Q L, SHAO J M, et al. Enhanced LSTM model for daily runoff prediction in the upper Huai River Basin, China[J]. Engineering, 2023, 24: 229-238.

[15] 严春华, 张玥, 姜中清, 等. 基于偏自相关分析和残差修正的径流量 GRU 预测模型[J]. 水力发电, 2023, 49(9): 23-28.(YAN C H, ZHANG Y, JIANG Z Q, et al. GRU prediction model of runoff based on partial autocorrelation analysis and residual correction[J]. Water power, 2023, 49(9): 23-28.(in Chinese))

(上接第 32 页)

[3] 叶沛成, 郭帅, 陈传辉, 等. 基于 GIS-Mike Flood 耦合模型的校园内涝模拟研究[J]. 水电能源科学, 2023, 41(8): 85-89.(YE P C, GUO S, CHEN C H, et al. Study of waterlogging simulation of university campus based on GIS-mike flood coupling model[J]. Water resources and power, 2023, 41(8): 85-89.(in Chinese))

[4] CHEN Y, HOU H, LI Y, et al. Urban inundation under different rainstorm scenarios in Lin'an City, China[J]. International journal of environmental research and public health, 2022, 19(12): 7210.

中国知网 https://www.cnki.net