

基于 WPT-IDBO-RELM 和 WPT-IDMO-RELM 模型的日径流预测

李菊¹, 崔东文²

(1. 云南开放大学城市建设学院, 云南 昆明 650500; 2. 云南省文山州水务局 云南 文山 663000)

摘要:为提高日径流时间序列预测精度,改进正则化极限学习机(RELM)的预测性能,对比验证改进蜣螂优化(IDBO)算法和改进侏獾优化(IDMO)算法与其他算法的优化效果,提出了基于小波包变换(WPT)的 WPT-IDBO-RELM 和 WPT-IDMO-RELM 日径流时间序列预测模型。对云南省暮底河水库、马鹿塘电站入库日径流进行预测,结果表明 WPT-IDBO-RELM 和 WPT-IDMO-RELM 模型对暮底河水库日径流预测的平均绝对百分比误差分别为 1.048%、1.015%,对马鹿塘电站日径流预测的平均绝对百分比误差分别为 1.493%、1.478%,优于其他对比模型;IDBO、IDMO 算法对标准测试函数和实例目标函数的寻优效果均优于其他对比算法,且 IDBO、IDMO 算法优化效果越好,RELM 超参数越优,WPT-IDBO-RELM、WPT-IDMO-RELM 模型预测精度越高;WPT 可将日径流序列分解为分量更少、规律性更强的子序列分量,在提高预测精度的同时显著降低模型复杂度和计算规模。

关键词:日径流预测;正则化极限学习机;改进蜣螂优化算法;改进侏獾优化算法;小波包变换

中图分类号:TV124

文献标志码:A

文章编号:1006-7647(2024)06-0048-08

Daily runoff prediction based on WPT-IDBO-RELM and WPT-IDMO-RELM models//LI Ju¹, CUI Dongwen²
(1. College of Urban Construction, Yunnan Open University, Kunming 650500, China; 2. Wenshan Water Bureau of Yunnan Province, Wenshan 663000, China)

Abstract: To improve the accuracy of daily runoff time series prediction and improve the prediction performance of the regularized extreme learning machine (RELM), the optimization performance of the improved dung beetle optimization (IDBO) algorithm and improved dwarf mongoose optimization (IDMO) algorithm was compared and verified, and the WPT-IDBO-RELM and WPT-IDMO-RELM models for daily runoff time series prediction were proposed based on wavelet packet transform (WPT). The daily inflows of the Mudihe Reservoir and Malutang Power Station in Yunnan Province were predicted. The results show that the average absolute percentage errors of the WPT-IDBO-RELM and WPT-IDMO-RELM models in predicting daily runoff for the Mudihe Reservoir are 1.048% and 1.015%, respectively, and 1.493% and 1.478% for Malutang Power Station, which are better than other comparative models. The optimization performance of the IDBO and IDMO algorithms on standard test functions and instance objective functions is better than that of comparative algorithms. The better the optimization performance of the IDBO and IDMO algorithms, the better the hyperparameters of the RELM, and the higher the prediction accuracy of the WPT-IDBO-RELM and WPT-IDMO-RELM models. WPT can decompose the daily runoff series into subseries components that have stronger regularity and are fewer in number, significantly reducing model complexity and computational scale while improving prediction accuracy.

Key words: daily runoff prediction; regularized extreme learning machine; improved dung beetle optimization algorithm; improved dwarf mongoose optimization algorithm; wavelet packet transform

提高水库日径流时间序列预测精度对于区域水资源优化配置、水库优化调度等具有重要意义。日

径流预测模型通常分为物理模型和数据驱动模型两大类,物理模型从水文原理出发,通常涉及径流形成

基金项目:云南省教育厅科学研究基金项目(2023J0797,2024J0756)

作者简介:李菊(1983—),女,高级工程师,硕士,主要从事水文水资源和工程管理研究。E-mail:471248466@qq.com

通信作者:崔东文(1978—),男,正高级工程师,主要从事水资源管理与保护及智能算法在水文水资源领域中的应用研究。

E-mail:cdwgr@163.com

的物理机制,存在原理复杂、水文参数率定困难、资料收集成本高等问题,因此物理模型的预测精度和泛化能力有限。近年来,基于数据分解技术-元启发式算法-预测器的时间序列数据驱动模型因其较强的非线性学习能力和较好的泛化性能,已在日径流时间序列预测研究中得到广泛应用。例如:刀海娅等^[1]构建多极小波包变换-改进熵熊优化算法-混合核极限学习机组合模型对景东、把边站日径流进行了预测,结果表明该模型具有较高的预测精度;陈金红等^[2]构建小波包变换-白鲨优化算法-门限循环控制单元/长短期记忆神经网络/卷积神经网络组合模型对暮底河水库日径流进行了预测,结果表明此三种模型在日径流时间序列预测研究中具有较好的应用前景;吴小涛等^[3]提出集合经验模态分解-变分模态分解-麻雀搜索算法-核极限学习机组合模型对湖北宜昌寸滩水文站汛期日径流进行了预测,结果表明该模型能准确模拟汛期径流的变化趋势;王秀杰等^[4]构建变分模态分解-粒子群优化算法-长短期记忆神经网络组合模型对黄河下游花园口和利津站日径流时间序列进行了多步预测,结果表明该模型能够有效提高日径流多步预测精度。

上述模型中,数据分解技术和元启发式算法对组合模型的预测性能具有重要影响。当前,经验模态分解及其改进分解、固有时间尺度分解、极点对称模态分解、经验小波变换、变分模态分解、时变滤波经验模态分解等数据分解技术已在众多领域时间序列预测研究中得到应用。然而,分解分量多导致模型计算规模大是此类分解技术的最大不足。同样,元启发式算法在混合核极限学习机、门限循环控制单元、长短期记忆神经网络、卷积神经网络、支持向量回归机超参数优化中扮演着重要角色。由于元启发式算法不依赖梯度信息,通过随机搜索的方式就能很好地解决非线性、非凸性、不可微性、不连续性和高维性等优化问题,已在各领域得到广泛应用。依据“没有免费午餐定理”,在逻辑上没有一种元启发式算法能够以最佳方式解决所有优化问题。因此,数量众多的元启发式算法以及改进算法被广泛提出,并成功应用于各类预测器超参数优化。

正则化极限学习机 (RELM) 是 Deng 等^[5]在极限学习机中引入结构风险最小化理论以及正则化项而提出,具有训练速度快、泛化能力好等优点。但随机给定的 RELM 超参数(输入层权值和隐含层偏值)制约了 RELM 性能,导致其预测精度低、泛化性能差。目前一些新型元启发式算法已在 RELM 超参数寻优中得到应用,如改进足球战术算法^[6]、菲克定律优化算法^[7]、改进蛇群优化算法^[8]、珍鲹优

化算法^[9]、泥环算法^[9]、天牛群优化算法^[10]等。为提高日径流时间序列预测精度和减小模型计算规模,改进 RELM 预测性能,分析 RELM 超参数优化对组合模型预测性能的影响,本文提出基于小波包变换(WPT)的 WPT-IDBO-RELM 和 WPT-IDMO-RELM 日径流时间序列预测模型,对比验证改进蜣螂优化(IDBO)算法、改进侏獠优化(IDMO)算法与蜣螂优化(DBO)算法、侏獠优化(DMO)算法、灰狼优化(GWO)算法、变色龙群(CSA)算法、鲸鱼优化(WOA)算法、樽海鞘群体(SSA)算法、哈里斯鹰优化(HHO)算法、蛇群优化(SO)算法的寻优性能,并构建了基于上述不同算法的 15 个模型进行对比分析,同时通过云南省两个入库日径流预测实例对各模型进行验证。

1 研究方法

1.1 WPT

WPT 对日径流原始序列进行分解的公式及重构算法分别为

$$\begin{cases} d_l^{j,2n} = \sum_k h_{k-2l} d_k^{j-1,n} \\ \bar{d}_l^{j,2n+1} = \sum_k g_{k-2l} \bar{d}_k^{j-1,n} \end{cases} \quad (1)$$

$$\bar{d}_l^{j,n} = \sum_k (\bar{h}_{l-2k} d_k^{j+1,2n} + \bar{g}_{l-2k} \bar{d}_k^{j+1,2n+1}) \quad (2)$$

式中: $d_l^{j,2n}$ 、 $\bar{d}_l^{j,2n+1}$ 为频带系数; $\bar{d}_l^{j,n}$ 为重构频带系数; $\bar{h}_{l-2k}$ 、 $\bar{g}_{l-2k}$ 分别为重构低通、高通滤波器组参数; h_{k-2l} 、 g_{k-2l} 分别为低通、高通滤波器组参数; j 为尺度参数; l 、 k 为平移参数; n 为频率参数;其他参数含义见文献[11-13]。

1.2 IDBO 算法

蜣螂优化(DBO)算法是一种模拟蜣螂滚球、舞蹈、繁殖、觅食、偷窃行为的新元启发式算法,虽然 DBO 算法寻优性能良好^[14],但对于复杂优化问题依然存在陷入局部极值和搜索停滞等风险。为提高 DBO 算法寻优能力,本文对 DBO 算法进行改进,提出了 IDBO 算法,主要通过以下 3 种策略提升 IDBO 算法的寻优能力:

a. Chebyshev 混沌映射策略。Chebyshev 混沌映射具有良好的伪随机特性,可使种群资源在搜索空间中的分配更加均衡,提高蜣螂种群多样性。本文采用 Chebyshev 混沌映射生成混沌变量,数学描述如下:

$$x_{n+1} = \cos(K \arccos x_n) \quad (3)$$

式中: x_n 为 $[-1, 1]$ 范围内的变量; x_{n+1} 为经 Chebyshev 映射后的变量; K 为阶次,本文取 4。

b. 黄金正弦策略。通过在蜣螂滚球行为位置

更新过程中引入黄金分割系数来提升算法的局部搜索能力,数学描述如下:

$$x_{i,t+1} = x_{i,t} | \sin R_1 | + R_2 \sin R_1 | x_1 x_{i,t} - x_2 X_w | \quad (4)$$

其中 $x_1 = -\pi + 2\pi(1 - \tau)$ $x_2 = -\pi + 2\pi\tau$
式中: $x_{i,t+1}$ 、 $x_{i,t}$ 分别为第 i 个蛭螂第 $t+1$ 、第 t 次迭代位置; R_1 为下次迭代个体移动距离的随机数, $R_1 \in [0, 2\pi]$; R_2 为决定下次移动方向的随机数, $R_2 \in [0, \pi]$; x_1 、 x_2 为黄金正弦系数; τ 为黄金分割系数; X_w 为全局最差位置; t 为当前迭代次数; i 为蛭螂序号。

c. 动态权重系数策略。由于最佳食物来源具有最优适应度值,而 DBO 算法通过随机生成蛭螂位置的策略降低了算法的全局探索能力。本文将基于迭代次数的动态权重系数引入蛭螂位置更新算子,以平衡算法的全局探索与局部开发能力,数学描述如下:

$$x_{i,t+1} = k_1 X_b + k_2 g(|x_{i,t} - X^*| + |x_{i,t} - X_b|)/2 \quad (5)$$

其中 $k_1 = 1 - t^3/T^3$ $k_2 = t^3/T^3$
式中: k_1 、 k_2 为动态权重系数; T 为最大迭代次数; X_b 为蛭螂全局最佳位置; g 为遵循正态分布的随机变量; X^* 为当前蛭螂最佳位置。

1.3 IDMO 算法

侏獭优化 (DMO) 算法是 Agushaka 等^[15] 于 2022 年受侏獭生存行为启发而提出的一种新型元启发式算法。该算法将侏獭种群划分为 α 雌性组、侦察组和保姆组,并通过模拟 3 个组的社会行为求解待优化问题。在实际应用中,DMO 算法存在勘探和开发能力弱、种群多样性差等不足。本文参考文献[16]提出了 IDMO 算法,其主要通过引入新算子,改进侦察组种群多样性,以及提升保姆组与其他侏獭互动频次来提升 α 雌性组、侦察组和保姆组的搜索能力。IDMO 算法数学描述如下:

a. 初始化。IDMO 算法利用下式初始化侏獭位置:

$$X_{i,j} = L_b + r(U_b - L_b) \quad (i = 1, 2, \dots, N) \quad (6)$$

式中: $X_{i,j}$ 为侏獭初始化位置; U_b 、 L_b 分别为优化位置的上、下限; r 为 $[0, 1]$ 范围内的随机数; N 为种群大小。

b. α 雌性组位置更新。IDMO 算法通过引入新算子对 α 雌性组活动进行控制,从而达到提升其探索和开发性能的目的, α 雌性组侏獭侦察组位置更新为

$$X_{i+1} = X_\alpha + \frac{p_1}{2} \omega r^2 (X_i - X_k) \quad (7)$$

其中

$$\omega = e^{-4(u/T)^2}$$

式中: X_{i+1} 为侏獭新位置; X_α 为具有最佳适应度值的雌性侏獭位置; p_1 为雌性侏獭发声系数,本文取 1.5; ω 为 α 雌性组活动控制系数; X_i 为当前雌性侏獭位置; X_k 为随机选择的侏獭位置。

c. 侦察组位置更新。IDMO 算法模拟了侦察组在觅食活动后寻找下一个睡眠丘的行为,并将具有最佳适应度值的侦察员位置选定为睡眠丘。侦察组侏獭位置更新为

$$X_{i+1} = X_\alpha + \frac{p_1}{2} \omega r^2 (X_k - X_h)/2 \quad (8)$$

式中 X_h 为随机选择的侏獭位置。

d. 保姆组位置更新。DMO 算法中,保姆位置通过重新初始化来设定,显然大大制约了算法的搜索性能。IDMO 算法通过修改保姆组交换标准,提升了保姆组与其他侏獭的互动,进而改进了算法的寻优性能。保姆组侏獭位置更新为

$$X_{i+1} = \left[X_j + r \left(X_\alpha - \frac{X_k + X_h}{2} \right) b_r \right] \quad (9)$$

式中: X_j 为随机选择的侏獭位置; b_r 为出生率。

1.4 RELM

RELM 是在极限学习机 (ELM) 中引入结构风险和正则化系数改进而来,目的是改善 ELM 过拟合问题^[17-18],其目标函数描述为

$$\min E = \min_{\beta} (C \|\beta\|^2 + \varepsilon^2) \quad (10)$$

$$\text{s. t. } \sum_{v=1}^m \lambda_v f(W_v X_m + b_i) - y_m = \varepsilon_m \quad (11)$$

式中: E 为风险总和; C 为正则化系数; β 为隐含层输出权值; ε 为经验风险误差; λ_v 为隐含层与输出层连接权值; $f(\cdot)$ 为隐含层激活函数; W_v 为输入层权值; X_m 为给定的输入数据; b_i 为隐含层偏值; y_m 为样本输出; ε_m 为误差总和; m 为输入数据数量。

2 预测步骤

步骤 1 数据分解。在实际应用中, WPT 分解层数是制约模型性能的关键,其分解效果一般随着 WPT 分解层数的增加而提升,但过度分解会破坏原始序列的完整性和时变特征,反而降低模型性能。为减小模型计算规模,利用 WPT 对暮底河水库和马鹿塘电站入库日径流数据进行 1 层分解(小波基函数选择 demy 函数;采样频率设置为 10^5),见图 1。

步骤 2 模型输入和输出。利用改进虚假邻近点法确定图 1 中高频和低频分量的输入步长 a , 计算结果见表 1。

依据表 1,利用超前 a 日的日径流数据预测未来 1 d 日径流,则模型的输入、输出可分别表述为




图1 暮底河水库和马鹿塘电站入库日径流 WPT 分解

表1 输入步长 a 的计算结果

实例	分解分量	步长
暮底河水库	高频分量	30
	低频分量	16
	原始序列	9
马鹿塘电站	高频分量	9
	低频分量	12
	原始序列	13

$$\boldsymbol{Q}_{in} = \begin{bmatrix} Q_1 & \cdots & Q_a \\ \vdots & & \vdots \\ Q_{M-a} & \cdots & Q_M \end{bmatrix} \quad (12)$$

$$\boldsymbol{Q}_{out} = \begin{bmatrix} Q_{a+1} \\ \vdots \\ Q_{M+1} \end{bmatrix} \quad (13)$$

式中: $\boldsymbol{Q}_{in}$ 为输入向量; $\boldsymbol{Q}_{out}$ 为输出向量; M 为样本数量。

步骤3 构建目标函数。基于训练集拟合值与实际值构建均方误差 f 作为 IDBO、IDMO、DBO、DMO 算法优化 RELM 超参数的目标函数 (GWO、CSA、WOA、SSA、HHO、SO 算法优化过程可参考实现)。

$$\begin{cases} \min f = \frac{1}{c} \sum_{i=1}^c (\hat{Q}_i - Q_i)^2 \\ \text{s. t. } w \in [w_{\min}, w_{\max}], b \in [b_{\min}, b_{\max}] \end{cases} \quad (14)$$

式中: $\hat{Q}_i$ 为训练集实测值; Q_i 为训练集拟合值; c 为训练集样本数; w 、 b 为 RELM 超参数; $w_{\max}$ 、 $w_{\min}$ 分别为 w 的最大值和最小值; $b_{\max}$ 、 $b_{\min}$ 分别为 b 的最大值和最小值。

步骤4 参数设置。设置 IDBO、IDMO、DBO、DMO 算法中种群规模均为 50, 最大迭代次数均为 200, 其他参数采用算法默认值。初始化蜣螂、侏獠位置。设置 RELM 网络结构为 3 层, 隐含层节点数大小为输入步长, 激活函数选用 sigmoid, 超参数搜索范围为 $[-1, 1]$ 。

步骤5 IDBO、IDMO、DBO、DMO 算法超参数寻优。①评估蜣螂或侏獠搜索个体目标函数值, 确定蜣螂全局最佳位置 X_b 或侏獠全局最佳位置 X_{best} ;

②基于 IDBO、IDMO、DBO、DMO 算法位置更新算子更新蜣螂或侏獠位置; ③评估位置更新后蜣螂或侏獠搜索个体目标函数值, 比较并保存 X_b 或 X_{best} ; ④重复以上过程直至满足终止条件, 输出 X_b 或 X_{best} 。

步骤6 模型构建。利用 X_b 或 X_{best} 建立 WPT-IDBO-RELM、WPT-IDMO-RELM、WPT-DBO-RELM、WPT-DMO-RELM 模型对低频、高频分量进行预测和重构。

步骤7 模型评估。选取平均绝对百分比误差、平均绝对误差和决定系数作为模型评估指标。

3 实例验证

3.1 数据来源

暮底河水库位于云南省文山州文山市县城西北部, 属红河流域泸江水系, 是一座以供水和防洪为主, 兼顾下游发电的中型水库。马鹿塘电站位于盘龙河干流下游, 是一座以发电为主、兼顾防洪的水电站工程。本文数据来源于暮底河水库 2018 年 1 月 1 日至 2020 年 12 月 31 日、马鹿塘电站 2019 年 1 月 1 日至 2021 年 12 月 31 日入库流量日尺度数据, 均有 1096 组数据, 其日径流时序数据如图 1 所示。本文选取暮底河水库、马鹿塘电站入库日径流时序数据的 80% (2018 年 1 月 1 日至 2020 年 5 月 26 日、2019 年 1 月 1 日至 2021 年 5 月 25 日数据) 作为训练集, 剩余 20% (暮底河水库 2020 年 5 月 27 日至 2020 年 12 月 31 日、马鹿塘电站 2021 年 5 月 26 日至 2021 年 12 月 31 日数据) 作为预测集。

3.2 算法实例验证

3.2.1 标准函数仿真

RELM 超参数优化维度等于输入层神经元数乘以隐藏层神经元数再加上隐藏层神经元数, 优化维度在 90~930 之间。为验证 IDBO、IDMO 算法优化性能, 选取 6 个标准测试函数^[20]在 500 维条件下进行试验, 并选取 DBO、DMO、GWO、CSA、WOA、SSA、HHO、SO 算法进行对比仿真测试, 利用 30 次仿真均值进行评估。表 2 为标准测试函数仿真结果 (表中 F1~F3 为单模态测试函数, F4~F6 为多模态测

表 2 标准测试函数仿真结果

函数 代号	函数名称	IDBO	IDMO	DBO	DMO	GWO	CSA	WOA	SSA	HHO	SO
F1	Sphere Function	5.91×10^{-102}	8.91×10^{-102}	2.27×10^{-37}	7.97×10^5	1.04×10^1	5.22×10^4	5.96×10^{-30}	4.12×10^4	5.00×10^{-45}	1.24×10^{-22}
F2	Schwefel's Problem 2.22	0	8.09×10^{-53}	1.42×10^{-22}	5.12×10^{123}	1.74	2.84×10^2	3.58×10^{-20}	2.72×10^2	2.52×10^{-22}	3.30×10^{-9}
F3	Schwefel's Problem 2.21	8.56×10^{-96}	4.09×10^{-96}	1.88×10^5	4.23×10^6	1.94×10^5	5.00×10^5	9.71×10^6	3.48×10^5	3.99×10^{-23}	9.87×10^{-10}
F4	Generalized Griewank's Function	0	0	0	7.18×10^3	9.83×10^{-1}	8.38×10^2	0	3.67×10^2	0	0
F5	Generalized Rastrigin's Function	0	0	0	4.82×10^3	3.37×10^2	2.06×10^3	6.06×10^{-14}	1.91×10^3	0	1.35×10^2
F6	Ackley's Function	4.44×10^{-16}	4.44×10^{-16}	5.63×10^{-16}	2.10×10^1	4.54×10^{-1}	2.00×10^1	1.17×10^{-14}	1.27×10^1	4.44×10^{-16}	1.36×10^{-10}

试函数)。

a. 对于单峰函数, IDBO、IDMO 算法寻优精度较其余 8 种算法至少提高 31 个数量级, 具有更强的极值寻优能力; 对于多峰函数, IDBO、IDMO、HHO 算法 30 次寻优均获得理论最优值 0, 具有更好的全局搜索性能和更强的跳出局部极值能力。可见, IDBO、IDMO 算法对于单峰或多峰函数均具有更强的寻优能力。

b. 从多峰函数寻优效果来看, IDBO、IDMO 算法在 70 次迭代之前便能寻优到全局最优解, 相较 DBO、HHO、WOA、SO 算法具有更好的收敛性能。

c. 与 DBO 算法相比, 引入 Chebyshev 混沌映射、黄金正弦和动态权重系数等策略的 IDBO 算法获得了更好的寻优性能和更强的鲁棒性; 与 DMO 算法相比, 通过引入新算子、改进侦察组种群多样性、提升保姆组与其他休谟互动频次等策略, IDMO 算法寻优精度得到了大幅提升, 具有更好的寻优性能和更强的平衡能力。

d. 综合比较得出 10 种算法的寻优精度由优至劣依次为 IDBO、IDMO、HHO、DBO、WOA、SO、GWO、CSA、SSA、DMO。

3.2.2 适应度函数优化

为验证 IDBO、IDMO 算法实际优化性能, 基于式(14)和暮底河水库、马鹿塘电站低频分量和高频分量训练集构建 4 个实例目标函数, 利用 10 种算法分别对各目标函数进行 30 次寻优, 并利用 30 次目标函数寻优均值 $\bar{f}_{\min}$ 和 30 次平均绝对百分比误差、平均绝对误差、决定系数均值进行评估, 结果见表 3。

a. IDBO、IDMO 算法对 4 个实例目标函数的优化结果 $\bar{f}_{\min}$ 均优于其余 8 种算法, 表现出较好的寻优性能。10 种算法优化性能由优至劣依次为

IDMO、IDBO、SO/HHO、DBO、GWO、SSA、CSA、WOA、DMO。

b. 从 30 次运行均值来看, 基于 IDBO、IDMO 算法优化获得的平均绝对百分比误差、平均绝对误差、决定系数均值明显优于其余 8 种算法, 表明 IDBO、IDMO 算法优化效果越好, RELM 超参数越优, 由此建立的 WPT-IDBO-RELM、WPT-IDMO-RELM 模型预测精度越高; 同时表明, 基于上述若干策略改进的 IDBO、IDMO 算法能获得更佳的 RELM 超参数寻优效果, 相对而言, IDMO 算法的改进效果更佳, 寻优性能提升更明显。

c. IDBO、IDMO 算法收敛速度明显优于其他算法, 具有搜索效率高、速度快, 更接近最优解等特点; WOA、DMO 算法在实例目标函数寻优过程中陷入局部极值且搜索停滞, 表现最差。其中, WOA 算法虽然在标准函数仿真上表现尚佳, 但在实例适应度函数寻优过程中表现较差; DMO 算法在标准函数仿真和实例适应度函数寻优过程中均表现最差。

3.3 预测结果与分析

构建 WPT-IDBO-RELM 等 13 种模型对实例低频、高频分量进行 30 次训练、预测和加和重构, 并与 IDBO-RELM、IDMO-RELM、DBO-RELM、DMO-RELM 模型的预测结果作比较, 30 次均值结果见表 4, 预测相对误差见图 2。依据表 4、图 2 可以得出以下结论:

a. 模型 1 和模型 2 对暮底河水库、马鹿塘电站入库日径流预测的平均绝对百分比误差、平均绝对误差、决定系数均值略优于模型 10、模型 3 和模型 9, 优于模型 5、模型 6、模型 8、模型 7、模型 11、模型 12 和模型 4, 远优于其他对比模型, 具有更高的预测精度。

b. 在相同分解与相同预测器情形下, 以平均绝对百分比误差为例, 模型 1 和模型 2 对暮底河水库

表 3 10 种算法优化结果及对比

实例	算法	低频分量							高频分量						
		$\bar{f}_{\min}$	平均绝对百分比误差/%		平均绝对误差/(m ³ /s)		决定系数均值		$\bar{f}_{\min}$	平均绝对百分比误差/%		平均绝对误差/(m ³ /s)		决定系数均值	
			训练	预测	训练	预测	训练	预测		训练	预测	训练	预测	训练	预测
暮底 水库	IDBO	2.09×10 ⁻³	1.164	1.049	0.039	0.049	0.9997	0.9996	1.60×10 ⁻³	22.298	31.050	0.019	0.018	0.9989	0.9988
	IDMO	1.89×10 ⁻³	1.036	0.984	0.034	0.044	0.9998	0.9997	1.53×10 ⁻³	22.569	26.078	0.017	0.017	0.9991	0.9989
	DBO	2.51×10 ⁻³	1.972	2.025	0.070	0.099	0.9980	0.9969	1.83×10 ⁻³	35.559	77.273	0.036	0.042	0.9910	0.9831
	DMO	1.34×10 ⁻²	6.052	6.015	0.220	0.312	0.9865	0.9813	1.37×10 ⁻²	112.563	346.502	0.131	0.166	0.9244	0.8660
	GWO	5.36×10 ⁻³	2.174	2.223	0.078	0.111	0.9984	0.9975	5.32×10 ⁻³	48.785	92.145	0.047	0.061	0.9910	0.9828
	CSA	6.72×10 ⁻³	2.952	3.068	0.107	0.152	0.9969	0.9955	6.51×10 ⁻³	53.392	127.919	0.055	0.070	0.9874	0.9764
	WOA	7.20×10 ⁻³	5.146	4.857	0.181	0.250	0.9901	0.9865	8.97×10 ⁻³	72.000	191.221	0.082	0.098	0.9638	0.9427
	SSA	5.73×10 ⁻³	2.559	2.621	0.093	0.131	0.9976	0.9966	4.23×10 ⁻³	49.735	117.700	0.049	0.062	0.9903	0.9828
	HHO	2.49×10 ⁻³	1.242	1.145	0.042	0.054	0.9995	0.9995	1.76×10 ⁻³	23.888	54.174	0.022	0.022	0.9983	0.9980
	SO	2.31×10 ⁻³	1.210	1.140	0.041	0.051	0.9996	0.9995	1.77×10 ⁻³	23.280	42.541	0.019	0.019	0.9987	0.9985
马鹿 塘电 站	IDBO	3.98×10 ⁻³	1.433	1.196	0.586	0.862	0.9993	0.9992	7.93×10 ⁻³	55.539	46.573	0.579	0.691	0.9880	0.9869
	IDMO	3.94×10 ⁻³	1.428	1.190	0.582	0.937	0.9994	0.9991	7.92×10 ⁻³	55.133	46.568	0.577	0.691	0.9882	0.9869
	DBO	6.73×10 ⁻³	2.215	2.231	0.955	1.762	0.9978	0.9957	9.82×10 ⁻³	76.968	49.330	0.692	0.852	0.9811	0.9774
	DMO	1.31×10 ⁻²	3.966	4.327	1.797	3.662	0.9930	0.9836	1.46×10 ⁻²	137.023	62.178	1.034	1.275	0.9600	0.9518
	GWO	4.74×10 ⁻³	1.549	1.558	0.664	1.238	0.9991	0.9981	8.86×10 ⁻³	55.473	46.797	0.573	0.701	0.9884	0.9865
	CSA	6.10×10 ⁻³	1.878	1.983	0.832	1.570	0.9984	0.9970	8.59×10 ⁻³	58.504	47.345	0.615	0.741	0.9860	0.9846
	WOA	1.09×10 ⁻²	3.346	3.430	1.499	2.758	0.9948	0.9909	1.19×10 ⁻²	109.415	55.167	0.848	1.041	0.9723	0.9670
	SSA	6.36×10 ⁻³	1.939	2.065	0.864	1.634	0.9983	0.9967	8.13×10 ⁻³	56.782	47.168	0.590	0.714	0.9875	0.9859
	HHO	3.99×10 ⁻³	1.450	1.280	0.610	0.950	0.9992	0.9990	7.98×10 ⁻³	55.528	46.532	0.578	0.693	0.9880	0.9868
	SO	4.68×10 ⁻³	1.573	1.391	0.666	1.008	0.9990	0.9989	7.97×10 ⁻³	55.693	46.681	0.578	0.695	0.9881	0.9868

表 4 日径流预测结果对比

模型 编号	模型	暮底水库			马鹿塘电站		
		平均绝对百分比 比误差/%	平均绝对 误差/(m ³ /s)	决定系数 均值	平均绝对百分比 比误差/%	平均绝对 误差/(m ³ /s)	决定系数 均值
1	WPT-IDBO-RELM	1.048	0.047	0.9997	1.493	1.068	0.9990
2	WPT-IDMO-RELM	1.015	0.046	0.9998	1.478	1.051	0.9991
3	WPT-DBO-RELM	1.162	0.056	0.9995	1.570	1.166	0.9987
4	WPT-DMO-RELM	6.994	0.367	0.9781	5.894	4.797	0.9724
5	WPT-GWO-RELM	2.765	0.126	0.9973	1.755	1.420	0.9982
6	WPT-CSA-RELM	2.984	0.150	0.9957	2.500	2.046	0.9963
7	WPT-WOA-RELM	4.346	0.203	0.9928	4.985	3.913	0.9870
8	WPT-SSA-RELM	3.028	0.142	0.9965	2.032	1.623	0.9977
9	WPT-HHO-RELM	1.176	0.054	0.9994	1.512	1.085	0.9989
10	WPT-SO-RELM	1.101	0.051	0.9995	1.514	1.089	0.9988
11	WPT-IDBO-BP	5.432	0.277	0.9813	2.192	1.982	0.9951
12	WPT-IDMO-BP	5.234	0.273	0.9837	2.154	1.838	0.9965
13	WPT-RELM	11.920	0.599	0.9425	10.450	8.060	0.9481
14	IDBO-RELM	15.312	0.923	0.7697	16.857	13.031	0.8224
15	IDMO-RELM	15.279	0.931	0.7672	17.386	13.351	0.8258
16	DBO-RELM	16.054	0.970	0.7589	18.646	14.439	0.8080
17	DMO-RELM	16.399	1.019	0.7193	19.440	15.632	0.7790

日径流预测的平均绝对百分比误差较模型 3~10 分别提高了 9.81%、85.02%、62.10%、64.88%、75.89%、65.39%、10.88%、4.81%，对马鹿塘电站日径流预测的平均绝对百分比误差分别提高了 4.90%、74.67%、14.93%、40.28%、70.05%、26.53%、1.26%、1.39%，表明 IDMO、IDBO 算法对 RELM 超参数的优化效果要优于其他算法。

c. 与 WPT-RELM 模型相比,预测效果最差的模型 4 对暮底水库日径流预测的平均绝对百分比

误差提高了 41.33%,对马鹿塘电站日径流预测的平均绝对百分比误差提高了 43.60%,表明元启发式算法优化 RELM 超参数,能显著改善 RELM 性能,提高日径流预测精度。

d. 与模型 14~17 相比,预测效果最差的模型 4 对暮底水库日径流预测的平均绝对百分比误差提高了 54.22%,对马鹿塘电站日径流预测的平均绝对百分比误差提高了 65.04%,表明 WPT 不但分解分量少,而且能减小日径流预测误差。




图2 预测相对误差

e. 模型1和模型2预测精度明显优于模型11和模型12,表明在相同优化情形下,RELM预测效果优于BP神经网络。

f. 与模型3相比,模型1对暮底河水库、马鹿塘电站两个实例日径流预测的平均绝对百分比误差分别提高了9.81%、4.90%,提升效果并不十分明显,其原因在于DBO算法具有较好的优化性能,从标准测试函数和实例适应度函数仿真中可得到验证;与模型4相比,模型2对暮底河水库、马鹿塘电站两个实例日径流预测的平均绝对百分比误差分别提高了85.49%、74.92%,其原因在于无论是对标准测试函数,还是实例目标函数,DMO算法的仿真寻优效果均表现最差。可见,对于超高维的RELM超参数优化,改进算法寻优性能具有十分重要的意义。

3.4 不同预见期验证

为验证WPT-IDBO-RELM、WPT-IDMO-RELM模型不同预见期的预测能力,利用其对暮底河水库、马鹿塘电站超前2日、超前3日入库日径流进行预测,并利用平均绝对百分比误差、决定系数和合格率(预测相对误差绝对值小于20%视为合格)对模型进行评价,结果见表5。

从表5可以看出,WPT-IDBO-RELM和WPT-IDMO-RELM模型对暮底河水库、马鹿塘电站超前2日入库日径流预测的平均绝对百分比误差、决定系数和合格率分别在5.950%~7.111%、92.5%~93.5%、0.9733~0.9881之间,达到水文甲级预报精度;超前3日入库日径流预测的平均绝对百分比误差、合格率、决定系数分别在15.958%~17.809%、65.0%~72.0%、0.8120~0.8896之间,达到水文乙级预报精度。可见,WPT-IDBO-RELM、

WPT-IDMO-RELM模型对于不同的预见期同样具有较高的预测精度,预测误差随预测期的增加而增大。

3.5 汛期预测验证

汛期日径流变幅较大,为评估模型预测性能,利用WPT-IDBO-RELM、WPT-IDMO-RELM模型对实例汛期(5—10月)入库日径流进行预测(同样选取汛期日径流时序数据的80%作为训练集,剩余20%作为预测集),结果表明WPT-IDBO-RELM、WPT-IDMO-RELM模型对暮底河水库、马鹿塘电站汛期入库日径流预测的平均绝对百分比误差、决定系数分别在0.602%~0.867%、0.9997~0.9998之间,合格率均为100%,达到水文甲级预报精度,具有更高的预测精度。

4 结论

a. 对于6个标准函数和4个实例目标函数,IDBO、IDMO算法仿真及寻优效果均优于其余8种算法,具有更好的极值寻优性能和更强的跳出局部极值能力,表明在DBO算法中引入Chebyshev混沌映射、黄金正弦和动态权重系数策略,能有效改进DBO算法的寻优能力和鲁棒性;在DMO中引入新算子,改进侦察组种群多样性,提升保姆组与其他犹豫互动频次,能有效提高DMO算法的极值寻优能力和鲁棒性能。

b. WPT-IDBO-RELM和WPT-IDMO-RELM模型对暮底河水库、马鹿塘电站日径流的预测效果均优于其他对比模型,具有预测精度高、计算规模小、实用价值高等特点。

c. WPT-IDBO-RELM和WPT-IDMO-RELM模型对实例超前2日、超前3日的日径流预测效果分别达

表5 日径流不同预测期预测结果

预见期	模型	暮底河水库			马鹿塘电站		
		平均绝对百分比误差/%	合格率/%	决定系数	平均绝对百分比误差/%	合格率/%	决定系数
超前2日	WPT-IDBO-RELM	6.090	93.5	0.9874	7.111	92.5	0.9773
	WPT-IDMO-RELM	5.950	93.5	0.9881	7.059	92.5	0.9733
超前3日	WPT-IDBO-RELM	16.498	69.2	0.8804	16.767	66.4	0.8188
	WPT-IDMO-RELM	15.958	72.0	0.8896	17.809	65.0	0.8120

到水文预报甲级、乙级精度,预测误差随预测期的增加而增大。

d. IDBO、IDMO 算法对 RELM 超参数的优化效果略优于 SO、HHO、DBO 算法,优于 GWO、SSA、CSA 算法,远优于 WOA、DMO 算法,其中 IDMO 算法的改进效果更佳,寻优性能提升更明显。总体而言, IDBO、IDMO 算法寻优竞争力越强,寻优效果越好, RELM 超参数越优,所构建的组合模型预测精度越高。

e. WPT 可将日径流原始序列分解为更具规律的低频和低频分量,在较少的分解分量情形下,显著降低模型复杂度和减少计算规模,大幅度提高模型的预测精度。

参考文献:

[1] 刀海娅,程刚,崔东文. 多极小波包变换与改进浣熊算法优化的混合核极限学习机径流预测[J]. 中国农村水利水电,2024(6):1-9. (DAO Haiya, CHENG Gang, CUI Dongwen. Multipole wavelet packet transform and improved raccoon algorithm optimization for mixed kernel extreme learning machine runoff prediction [J]. China Rural Water Resources and Hydropower, 2024(6):1-9. (in Chinese))

[2] 陈金红,崔东文. 基于深度学习神经网络超参数优化的入库径流预测方法研究:以云南省暮底河水库为例[J]. 三峡大学学报(自然科学版),2023,45(4):25-32. (CHEN Jinhong, CUI Dongwen. A study on the prediction method of inflow runoff based on deep learning neural network hyperparameter optimization; taking the Mudihe Reservoir in Yunnan Province as an example [J]. Journal of China Three Gorges University (Natural Science Edition), 2023, 45(4):25-32. (in Chinese))

[3] 吴小涛,袁晓辉,袁艳斌,等. 基于 EEMD-VMD-SSA-KELM 模型的汛期日径流预测[J]. 中国农村水利水电,2023(7):27-34. (WU Xiaotao, YUAN Xiaohui, YUAN Yanbin, et al. Daily runoff prediction during flood season based on EEMD-VMD-SSA-KELM model [J]. China Rural Water Resources and Hydropower, 2023(7):27-34. (in Chinese))

[4] 王秀杰,王玲,滕振敏,等. VMD-PSO-LSTM 模型的日径流多步预测[J]. 水利水电工程学报,2023(4):81-90. (WANG Xiujie, WANG Ling, TENG Zhenmin, et al. Research on multi-step forecast of daily runoff based on VMD-PSO-LSTM model [J]. Hydro-Science and Engineering, 2023(4):81-90. (in Chinese))

[5] DENG W, ZHENG Q, CHEN L. Regularized extreme learning machine[J]. IEEE Symposium on Computational Intelligence & Data Mining, 2009(3):389-395.

[6] 董欣林,崔东文. 基于 WPT-ITTA-RELM/ELM/LSSVM

模型的日径流预测研究[J]. 三峡大学学报(自然科学版),2024,46(4):16-24. (DONG Xinlin, CUI Dongwen. Research on daily runoff prediction based on WPT-ITA-RELM/ELM/LSSVM model [J]. Journal of China Three Gorges University (Natural Science Edition), 2024, 46(4):16-24. (in Chinese))

[7] 高雪梅,崔东文. WPT-FLA-RELM 模型的马鹿塘水电站入库日径流多步预测[J]. 云南水力发电,2023,39(11):56-62. (GAO Xuemei, CUI Dongwen. Multi step prediction of daily inflow of Malutang Hydropower Station using WPT-FLA-RELM model [J]. Yunnan Hydroelectric Power, 2023, 39(11):56-62. (in Chinese))

[8] 王应武,白栩嘉,崔东文. 基于 WPT-ISO-RELM 模型的月径流时间序列预测研究[J]. 水力发电,2024,50(3):12-18. (WANG Yingwu, BAI Xujia, CUI Dongwen. Research on monthly runoff time series prediction based on WPT-ISO-RELM model [J]. Hydroelectric Power, 2024, 50(3):12-18. (in Chinese))

[9] 张代凤,崔东文. 基于 3 种新型群体智能算法优化正则化极限学习机的三峡水库入库日径流预测[J]. 长江科学院院报,2024,41(7):16-24. (ZHANG Daifeng, CUI Dongwen. Prediction of daily inflow runoff of Three Gorges Reservoir using regularized extreme learning machine optimized by three new swarm intelligent algorithms [J]. Journal of Yangtze River Scientific Research Institute, 2024, 41(7):16-24. (in Chinese))

[10] 王振东,刘尧迪,杨书新,等. 基于天牛群优化与改进正则化极限学习机的网络入侵检测[J]. 自动化学报,2022,48(12):3024-3041. (WANG Zhendong, LIU Yaodi, YANG Shuxin, et al. Network intrusion detection based BSO and improved RELM [J]. Acta Automatica Sinica, 2022, 48(12):3024-3041. (in Chinese))

[11] 李新华,崔东文. 基于 WPD-TSO-ELM 模型的月径流时间序列预测[J]. 水力发电,2022,48(9):9-15. (LI Xinhua, CUI Dongwen. Monthly runoff time series prediction based on WPD-TSO-ELM model [J]. Hydroelectric Power, 2022, 48(9):9-15. (in Chinese))

[12] 李新华,崔东文. 基于 WPD-RSA-ELM 模型的水文时间序列多步预测[J]. 水利水电技术(中英文),2022,53(11):69-77. (LI Xinhua, CUI Dongwen. Multi step prediction of hydrological time series based on WPD-RSA-ELM model [J]. Water Resources and Hydropower Technology, 2022, 53(11):69-77. (in Chinese))

[13] 崔东文,袁树堂. 基于 WPD-AHA-ELM 模型的水质时间序列多步预测[J]. 三峡大学学报(自然科学版),2023,45(1):6-13. (CUI Dongwen, YUAN Shutang. Multi step prediction of water quality time series based on WPD-AHA-ELM model [J]. Journal of China Three Gorges University (Natural Science Edition), 2023, 45(1):6-13. (in Chinese))

(下转第 85 页)

Xiaobo, et al. Analysis of main chemical indexes of water of the third drainage ditch in Ningxia in 2019[J]. Wetland Science, 2022, 20(1): 119-124. (in Chinese))

[5] 田林锋, 罗桂林, 姜文娟, 等. 基于多元统计的宁夏典农河水质演替特征探究[J]. 中国环境监测, 2023, 39(1): 128-136. (TIAN Linfeng, LUO Guilin, JIANG Wenjuan, et al. Water quality succession of Diannong River in Ningxia based on multiple statistics [J]. Environmental Monitoring in China, 2023, 39(1): 128-136. (in Chinese))

[6] 张翔, 李榛. 基于主成分分析的北洛河水质时空分布特征及污染源解析[J]. 水土保持通报, 2022, 42(4): 153-160. (ZHANG Xiang, LI Su. Spatial and temporal distribution characteristics of water quality in Beiluo River and pollution sources based on principal component analysis [J]. Bulletin of Soil and Water Conservation, 2022, 42(4): 153-160. (in Chinese))

[7] HUANG Jiacong, ZHANG Yinjun, ARHONDITSIS G B, et al. How successful are the restoration efforts of China's lakes and reservoirs? [J]. Environment International, 2019, 123: 96-103.

[8] 杨盼, 卢路, 王继保, 等. 基于主成分分析的 spearman 秩相关系数法在长江干流水质分析中的应用[J]. 环境工程, 2019, 37(8): 76-80. (YANG Pan, LU Lu, WANG Jibao, et al. Analysis of water quality trend in the main stream of the Yangtze River based on principal component analysis [J]. Environmental Engineering, 2019, 37(8): 76-80. (in Chinese))

[9] MANTEL N. The detection of disease clustering and a generalized regression approach [J]. Cancer Research, 1967, 27(2): 209-220.

[10] 宁忠瑞, 李虹彬. 基于水质标识指数的黄河宁夏段水质评价与分析[J]. 灌溉排水学报, 2020, 39(增刊 1): 56-61. (NING Zhongrui, LI Hongbin. Assessment and analysis of water quality in Ningxia Section of the Yellow River based on comprehensive water quality identification index [J]. Journal of Irrigation and Drainage, 2020, 39(Sup1): 56-61. (in Chinese))

[11] 闫莉, 黄锦辉, 张建军, 等. 宁夏农灌退水对黄河水质的影响研究[J]. 人民黄河, 2007, 29(3): 35-36. (YAN Li, HUANG Jinhui, ZHANG Jianjun, et al. Study on the influence of irrigated water on the water quality of the Yellow River in Ningxia [J]. Yellow River, 2007, 29(3): 35-36. (in Chinese))

[12] 杨丽慧, 王少丽, 阮本清, 等. 基于排水沟的宁夏银北灌区农田退水污染演变研究[J]. 中国生态农业学报, 2015, 23(12): 1580-1587. (YANG Lihui, WANG Shaoli, RUAN Benqing, et al. Evolution of drain-based research of irrigation return flow pollution in Yinbei Irrigation Area [J]. Chinese Journal of Eco-Agriculture, 2015, 23(12): 1580-1587. (in Chinese))

[13] 李仰征, 任金铜, 杨延丽, 等. 岩溶区域水体无机氮分布及影响氮素矿化的生境[J]. 地球与环境, 2019, 47(3): 246-253. (LI Yangzheng, REN Jintong, YANG Yanli, et al. Distribution of inorganic nitrogen and environmental factors of nitrogen mineralization in waters of the karst area [J]. Earth and Environment, 2019, 47(3): 246-253. (in Chinese))

[14] XIONG Qinli, XIAO Yang, LIANG Pinghan, et al. Trends in climate change and human interventions indicate grassland productivity on the Qinghai-Tibetan Plateau from 1980 to 2015 [J]. Ecological Indicators, 2021, 129: 108010.

[15] LI Zongjie, LI Zongxing, FENG Qi, et al. Hydrological effects of multiphase water transformation in Three-River Headwaters Region, China [J]. Journal of Hydrology, 2021, 601: 126662.

[16] 张馨月, 马沛明, 高千红, 等. 三峡大坝上下游水质时空变化特征[J]. 湖泊科学, 2019, 31(3): 633-645. (ZHANG Xinyue, MA Peiming, GAO Qianhong, et al. Spatial-temporal variations of water quality in upstream and downstream of Three Gorges Dam [J]. Journal of Lake Sciences, 2019, 31(3): 633-645. (in Chinese))

(收稿日期: 2023-11-16 编辑: 熊水斌)

(上接第 55 页)

[14] XUE J, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.

[15] AGUSHAKA J O, EZUGWU A E, ABUALIGAH L. Dwarf mongoose optimization algorithm [J]. Computer Methods in Applied Mechanics and Engineering, 2022, 391: 114570.

[16] AGUSHAKA J O, EZUGWU A E, OLAIDE O N, et al. Improved dwarf mongoose optimization for constrained engineering design problems [J]. Journal of Bionic Engineering, 2023, 20(3): 1263-1295.

[17] 吴忠强, 尚梦瑶, 申丹丹, 等. 基于 BSA-RELM 的纯电动汽车锂离子电池 SOC 估计[J]. 计量学报, 2019, 40(4): 693-699. (WU Zhongqiang, SHANG Mengyao, SHEN Dandan, et al. SOC estimation of pure electric vehicle lithium-ion battery based on BSA-RELM [J]. Journal of Metrology, 2019, 40(4): 693-699. (in Chinese))

[18] 杨琼波, 崔东文. WPD-RSO-ESN 和 SSA-RSO-ESN 模型在径流时间序列预测中应用比较[J]. 中国农村水利水电, 2022(2): 61-67. (YANG Qiongbao, CUI Dongwen. Comparison of WPD-RSO-ESN and SSA-RSO-ESN models in predicting runoff time series [J]. China Rural Water Resources and Hydropower, 2022(2): 61-67. (in Chinese))

(收稿日期: 2023-10-11 编辑: 骆超)