

田宇, 崔东文, 毛宗波, 等. 基于数据分解与十种“植物”算法优化的 RELM 地下水位预测[J]. 水利水电技术(中英文), 2025, 56(9): 118-130. DOI: 10.13928/j.cnki.wrahe.2025.09.009

TIAN Yu, CUI Dongwen, MAO Zhongbo, et al. Groundwater level prediction based on data decomposition and ten “plant” algorithm optimization using RELM [J]. Water Resources and Hydropower Engineering, 2025, 56(9): 118-130. DOI: 10.13928/j.cnki.wrahe.2025.09.009

基于数据分解与十种“植物”算法优化的 RELM 地下水位预测

田宇¹, 崔东文², 毛宗波¹, 李锐¹

(1. 云南省水利水电勘测设计院有限公司, 云南 昆明 650021; 2. 云南省文山州水务局, 云南 文山 663000)

摘要:【目的】提高地下水位时间序列预测精度对于科学预判地下水位变化趋势、合理开发和利用地下水资源具有重要意义。为提高地下水位时间序列预测精度, 解决数据分解组合时间序列预测模型计算规模大、复杂程度高等问题【方法】基于小波包分解(WPT)、入侵杂草优化(IWO)算法/花授粉算法(FPA)/树木生长算法(TGA)/向日葵优化(SFO)算法/食肉植物算法(CPA)/蒲公英优化(DO)算法/常春藤算法(IVYA)/青蒿素优化(AO)算法/苔藓生长优化(MGO)算法/莲花效应优化算法(LEA)共十种“植物”算法和正则化极限学习机(RELM), 提出基于WPT分解处理的IWO/FPA/TGA/SFO/CPA/DO/IVYA/AO/MGO/LEA-RELM预测模型, 并通过云南省西城、南庄、临安、文澜、者林寨、植物园6个地下水位时间序列预测实例对各模型进行验证。首先, 利用1层WPT将实例地下水位时间序列分解为趋势项和波动项, 并基于趋势项和波动项训练集构建RELM超参数优化实例目标函数; 其次, 利用十种“植物”算法对实例目标函数进行极值寻优, 获得各算法最优超参数; 最后, 利用最优超参数构建IWO/FPA/TGA/SFO/CPA/DO/IVYA/AO/MGO/LEA-RELM模型对实例地下水位时间序列趋势项和波动项进行预测和重构。【结果】结果显示: IVYA、CPA、FPA寻优性能优于IWO、AO、SFO、DO, 远优于LEA、MGO、TGA; IVYA-RELM、CPA-RELM、FPA-RELM模型预测的平均绝对百分比误差(MAPE)在0.003 0%~0.000 4%之间, 平均绝对误差(MAE)在0.038 9~0.006 3 m之间, 决定系数(DC)在0.997 7~0.999 8之间, 预测精度优于其他对比模型, 具有较好的预测效果。【结论】结果表明: 十种“植物”算法的寻优性能排名与十种组合模型的拟合精度、预测精度排名具有高度的一致性。总体上, 算法寻优能力越强, 组合模型的拟合、预测精度越高, 性能越好; WPT分解分量少、分量规律性强, 是一种简介高效的分解方法。

关键词: 地下水位预测; 小波包分解; 十种“植物”算法; 正则化极限学习机; 实例目标函数; 超参数优化; 影响因素

DOI: 10.13928/j.cnki.wrahe.2025.09.009

开放科学(资源服务)标志码(OSID):

中图分类号: S273.4; TP183; P641.7

文献标志码: A

文章编号: 1000-0860(2025)09-0118-13



与作者互动
请扫描二维码

收稿日期: 2024-12-06; 修回日期: 2025-02-07; 录用日期: 2025-02-12; 网络出版日期: 2025-03-20

基金项目: 国家重点研发计划项目(2021YFC300205-06)

作者简介: 田宇(1988—), 男, 高级工程师, 学士, 主要从事水利水电工程设计等工作。E-mail: 189566990@qq.com

通信作者: 崔东文(1978—), 男, 高级工程师, 学士, 主要从事水资源管理保护及智能算法在水文水资源系统中的应用研究等工作。

E-mail: cdwgr@163.com

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

Groundwater level prediction based on data decomposition and ten “plant” algorithm optimization using RELM

TIAN Yu¹, CUI Dongwen², MAO Zhongbo¹, LI Rui¹

(1. Yunnan Water Resources and Hydropower Survey and Design Institute Co., Ltd., Kunming 650021, Yunnan, China;

2. Yunnan Province Wenshan Water Bureau, Wenshan 663000, Yunnan, China)

Abstract: [Objective] Improving the accuracy of groundwater level time series prediction is of great significance for scientifically predicting the change trends of groundwater levels and ensuring the rational development and utilization of groundwater resources. The aim is to improve the accuracy of groundwater level time series prediction and address the issues of large computational scale and high complexity in data decomposition-based combination time series prediction models. [Methods] A WPT-decomposed IWO/FPA/TGA/SFO/CPA/DO/IVYA/AO/MGO/LEA-RELM prediction model was proposed, combining Regularized Extreme Learning Machine (RELM) with ten “plant” optimization algorithms, including Wavelet Packet Decomposition (WPT), Invasive Weed Optimization (IWO), Flower Pollination Algorithm (FPA), Tree Growth Algorithm (TGA), Sunflower Optimization (SFO), Carnivorous Plant Algorithm (CPA), Dandelion Optimization (DO), Ivy Algorithm (IVYA), Artemisinin Optimization (AO), Moss Growth Optimization (MGO), and Lotus Effect Optimization Algorithm (LEA). This model was validated using groundwater level time series prediction examples from six locations in Yunnan Province, including Xicheng, Nanzhuang, Lin’an, Wenlan, Zhelinzhai, and Botanical Garden. First, the example’s groundwater level time series were decomposed into trend and fluctuation components using one-level WPT. Based on these components, a RELM hyperparameter optimization objective function for the example was established. Then, the ten “plant” algorithms were used to optimize the objective function to determine the best hyperparameters. Finally, the optimal hyperparameters were used to establish IWO/FPA/TGA/SFO/CPA/DO/IVYA/AO/MGO/LEA-RELM models to predict and reconstruct the trend and fluctuation components of the example’s groundwater level time series. [Results] The result showed that IVYA, CPA, and FPA outperformed IWO, AO, SFO, DO in optimization performance, and significantly outperformed LEA, MGO, and TGA. The IVYA-RELM, CPA-RELM, and FPA-RELM models achieved a *MEAn* absolute percentage error (*MAPE*) of 0.003 0% to 0.000 4%, a *MEA* absolute error (*MAE*) of 0.038 9 m to 0.006 3 m, and a coefficient of determination (*DC*) of 0.997 7 to 0.999 8, which outperformed other comparison models and demonstrated excellent prediction performance. [Conclusion] The result indicate that the optimization performance of the ten “plant” algorithms is highly consistent with the fitting and prediction accuracy rankings of the ten combined models. Overall, the stronger the optimization ability of the algorithms, the higher the fitting and prediction accuracy, and the better the performance of the combined models. The WPT decomposition, with fewer components and strong regularity, is a simple and efficient decomposition method.

Keywords: groundwater level prediction; wavelet packet decomposition; ten “plant” algorithms; regularized extreme learning machine; example objective function; hyperparameter optimization; influencing factors

0 引言

地下水位时间序列是反映地下水位变化趋势的重要指标,提高地下水位时间序列预测精度对于科学预判地下水位变化趋势、合理开发和利用地下水资源具有重要意义。当前,地下水位时间序列预测模型分为物理模型和数据驱动模型两类。物理模型是一类基于物理过程和地质特性的模型,虽然可释性好,但受降水、气温、水汽压、土壤渗透率等多种因素的制约,导致模型资料收集困难、计算过程复杂、预测精度低等问题;数据驱动模型是一类基于历史数据和机器学习算法的模型,由于其不依赖于物理过程模拟,而是通过提取历史数据中隐含信息实现预测,具有较好的

预测精度和实用性,如卷积神经网络(CNN)-长短期记忆网络(LSTM)组合模型^[1]、多变量 LSTM 模型^[2]等。近年来,基于“数据分解+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,已在地下水位时间序列预测中得到应用,如郑世龙等^[3]基于奇异谱分析分解(SSA)和 RBF 神经网络预测的 SSA-RBF 地下水位组合预测模型;侯金霄等^[4]基于经验模态分解(EMD)和 LSTM 预测的 EMD-LSTM 地下水位组合预测模型;张建锋等^[5]基于离散小波分解(DWT)和 BP 神经网络预测的 SWT-BP 地下水位组合预测模型;付智勇等^[6]基于互补集合经验模态分解(CEEMD)和随机森林(RF)预测的地下水位组合预测模型;WU 等^[7]基于变分模态分解

(VMD)和极限学习机(ELM)预测的地下水水位组合预测模型。

上述SSA-RBF、EMD-LSTM、DWT-BP、CEEMD-RF、VMD-ELM地下水水位时间序列预测模型虽然具有一定的预测精度,但存在两方面的问题和不足:(1)SSA、EMD、DWT、CEEMD、VMD方法分解分量多,导致模型复杂程度高、计算规模大;(2)RBF、LSTM、RF、BP、ELM预测器超参数的合理选取对组合模型性能影响较大,合理确定预测器超参数是提高模型预测精度的关键。为提高地下水水位时间序列预测精度,解决上述“数据分解+预测器”组合模型面临的问题和不足,本文基于小波包分解(Wavelet Packet Transform, WPT)方法、入侵杂草优化(Invasive Weed Optimization, IWO)算法/花授粉算法(Flower Pollination Algorithm, FPA)树木生长算法(Tree Growth Algorithm, TGA)/向日葵优化(Sunflower Optimization, SFO)算法/食肉植物算法(Carnivorous Plant Algorithm, CPA)/蒲公英优化(Dandelion Optimization, DO)算法/常春藤算法(Ivy Algorithm, IVYA)/青蒿素优化(Artemisinin Optimization, AO)算法/苔藓生长优化(Moss Growth Optimization, MGO)算法/莲花效应优化算法(Lotus Effect Optimization Algorithm, LEA)共十种“植物”算法和正则化极限学习机(Regularized Extreme Learning Machine, RELM),提出WPT趋势项和波动项分解的IWO/FPA/TGA/SFO/CPA/DO/IVYA/AO/MGO/LEA-RELM地下水水位时间序列预测模型,并通过云南省西城、南庄、临安、文澜、者林寨、植物园6站2019—2023年逐周地下水水位时间序列预测实例对各模型进行验证。

1 材料与方法

1.1 数据来源

西城、南庄、临安、文澜、者林寨、植物园6站逐周地下水水位时序数据来源于云南省红河州国家地下

水监测工程,监测序列为2019年1月至2023年12月,共261周。西城、南庄、临安、文澜、者林寨、植物园6站周最高地下水水位和6站周最低地下水水位差分别为4.09 m、4.77 m、11.40 m、2.88 m、2.66 m、3.02 m,地下水水位起伏波动激烈。从地下水类型来看,孔隙水埋藏浅,直接受降雨、地表水以及部分基岩水补给,近补近排,排泄量不大,矿化度和总硬度相对较低,多为软水,水化学类型主要为 $\text{HCO}_3\text{-Ca}$ 型;裂隙水埋藏相对较深,补给区不易划分,出水量相对稳定,水循环交替强烈,受人类活动影响相对较小,水化学类型多为 $\text{HCO}_3\text{-Ca}$ 型。地下水水位站基本信息如表1所列,地下水水位站相对变化曲线如图1所示,地下水水位站点分布如图2所示。




图1 地下水水位相对变化曲线

Fig. 1 Relative variation curves of groundwater levels

1.2 小波包变换(WPT)

WPT对西城、南庄、临安、文澜、者林寨、植物园6站地下水水位时序数据分解公式^[8-9]为

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

重构公式为

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

式中, $d_l^{j, 2n}$ 、 $d_l^{j, 2n+1}$ 为频带系数; j 为尺度参数; l 、 k

表1 地下水水位站基本信息

Table 1 Basic information of groundwater level stations

站名	水文地质单元	经纬度/(°)		成井深度/m	地貌类型	地下水类型	含水层类型	含水层岩性	水位变化影响因素
		东经	北纬						
西城	西南岩溶区,南盘江中下游流域盆地碳酸盐岩岩溶水、松散岩孔隙水小区,代号I3-3。	103.240 651 6	23.708 353 6	69.01	高原盆地	孔隙水	承压水	圆砾	大气降水和地下水开采是地下水水位变化主要影响因素。大气降水对地下水水位变化具有明显影响,并呈周期性动态变化和季节性规律;地下水开采也对地下水水位变化存在剧烈影响,主要表现在生活用水及农田灌溉等
南庄		102.901 029 2	23.721 726 5	98.00	高原盆地	孔隙水	承压水	圆砾	
临安		102.888 664 3	23.625 205 1	128.70	高原盆地	裂隙水	承压水	灰岩	
文澜		103.382 619 7	23.361 965 0	63.10	高原盆地	裂隙水	潜水	泥岩	
者林寨		103.430 380 8	24.432 109 3	60.55	高原盆地	孔隙水	潜水	细中砂、圆砾	
植物园		103.254 652 2	23.665 318 3	161.00	高原盆地	孔隙水	潜水	灰岩、白云质灰岩	

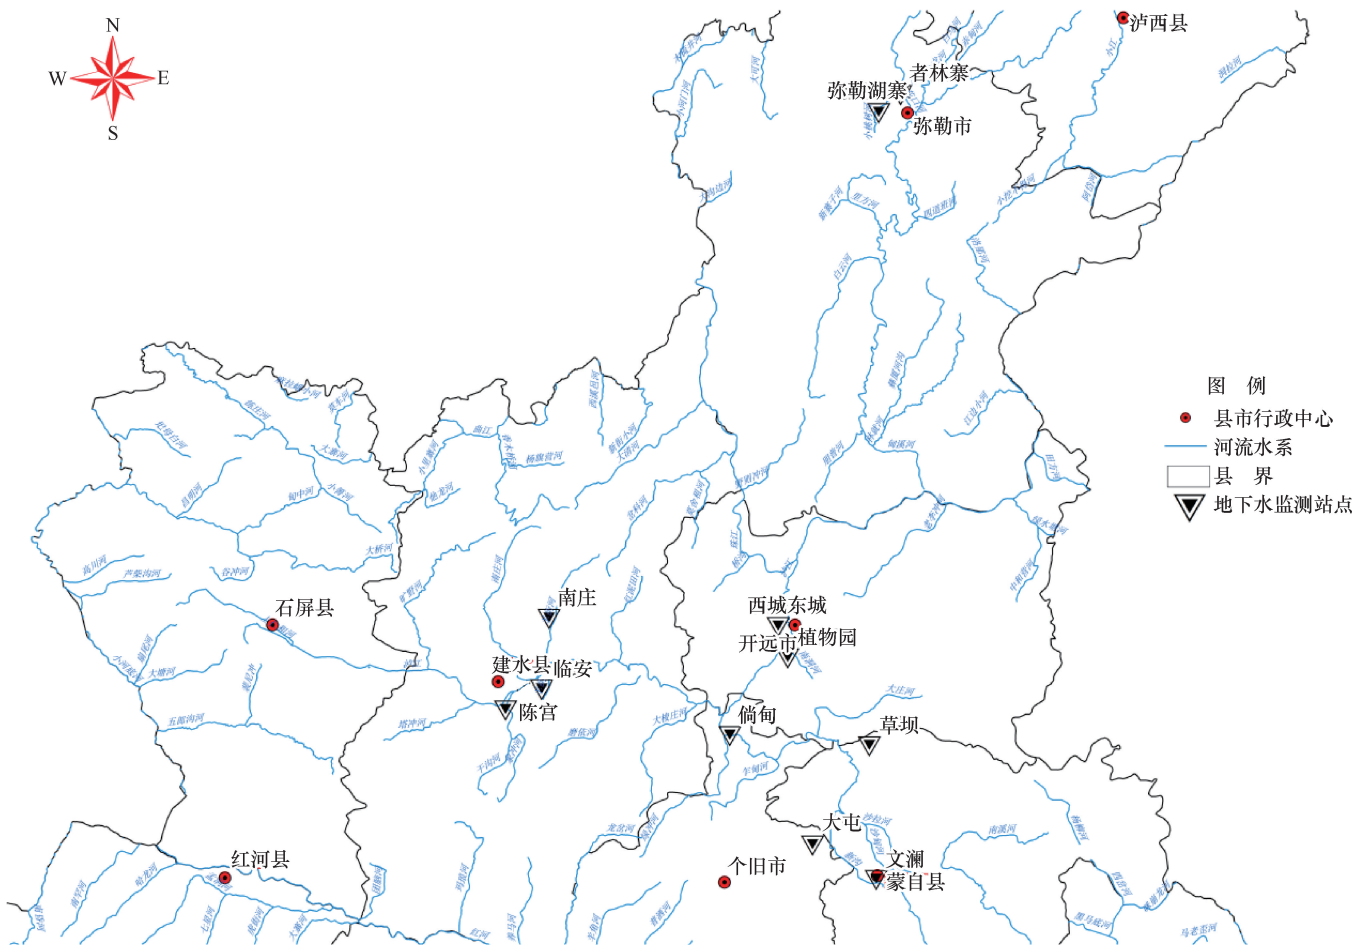


图2 地下水位站点分布

Fig. 2 Distribution of groundwater level stations

为平移参数; n 为频率参数; h_{k-2l} 、 g_{k-2l} 为低通、高通滤波器组; \bar{d}_i^n 为重构频带系数; \bar{h}_{l-2k} 、 \bar{g}_{l-2k} 为重构低通、高通滤波器组。

1.3 十种“植物”算法

受篇幅限制,本文仅对2024年1月以来基于“植物”启发的新型元启发式算法进行介绍。

1.3.1 入侵杂草优化(IWO)

IWO是MEHRABIAN等^[10]于2006年受农田中杂草扩散和生长启发而提出的一种元启发式算法。该算法通过模拟杂草种子在自然界的扩散、生长、繁殖和竞争性消亡求解待优化问题,目前已在径流预测、优化调度等方面得到应用。原理见参考文献[11]。

1.3.2 花授粉算法(FPA)

FPA是YANG等^[12]于2014年受自然界花朵授粉启发而提出的一种元启发式算法。该算法通过模拟异花授粉、自花授粉过程实现全局和局部搜索求解待优化问题,目前已在径流预测、路径规划、工程优化、

超参数寻优等方面得到广泛应用。原理见参考文献[13]。

1.3.3 树木生长算法(TGA)

TGA是CHERAGHALIPOUR等^[14]于2018年受树木在自然界中对光线和食物的竞争启发而提出的一种元启发式算法。该算法通过模拟树木生长过程求解待优化问题,目前已在最优潮流计算等方面得到应用。原理见参考文献[15]。

1.3.4 向日葵优化算法(SFO)

SFO是GOMES等^[16]于2019年受自然界向日葵运动行为启发而提出的一种元启发式算法。该算法通过模拟向日葵的生长和授粉过程求解待优化问题,目前已在解决最优功率流问题、多目标优化等方面得到应用。原理见参考文献[16]。

1.3.5 食肉植物算法(CPA)

CPA是ONG等^[17]于2020年受食肉植物适应恶劣环境启发而提出的一种元启发式算法。该算法通过模拟食肉植物吸引、诱捕、消化和繁殖策略求解待优

化问题,目前已在轧带钢厚度预测、物流调度、微电网优化、短期风速预测、目标跟踪、关键参数寻优等方面得到广泛应用。原理见参考文献[18]。

1.3.6 蒲公英优化(DO)算法

DO是ZHAO等^[19]于2022年受自然界蒲公英种子依靠风长距离飞行启发而提出一种元启发式算法。该算法通过模拟蒲公英种子上升、下降和着陆三种策略求解待优化问题,目前已在车间调度、关键参数优化等方面得到应用。原理见参考文献[20]。

1.3.7 常春藤算法(IVYA)

IVYA是GHASEMI等^[21]于2024年受自然界常春藤生长现象启发而提出一种元启发式算法。该算法通过模拟常青藤种群有序协调增长和扩散生长策略求解待优化问题。

(1)初始化。设在搜索空间中,种群为 N 的常春藤初始化位置描述为

$$I_i = I_{\min} + \text{rand}(1, D) \odot (I_{\max} - I_{\min}), \quad i = 1, 2, \dots, N_{\text{pop}} \quad (3)$$

式中, I_i 为第 i 枝常春藤位置; I_{\max} 、 I_{\min} 为搜索空间上、下限值; $\text{rand}(1, D)$ 为介于0和1之间均匀分布的 D 维随机向量; N_{pop} 为常春藤数量; D 为问题维度。

(2)协调与有序增长。常春藤是一种随时间生长的匍匐植物。IVYA中,常青藤生长速率 Gv 是由微分方程给出的时间函数,具体为

$$\begin{cases} \frac{dGv(t)}{dt} = \psi \cdot Gv(t) \cdot \varphi(Gv(t)) \\ \Delta Gv_i(t+1) = \text{rand}^2 \odot (N(1, D) \odot \Delta Gv_i(t)) \end{cases} \quad (4)$$

式中, Gv_i 为第 i 枝常春藤生长速率; ψ 为生长速度; φ 为校正因子; $\Delta Gv_i(t+1)$ 、 $\Delta Gv_i(t)$ 分别为 $t+1$ 和 t 时刻常春藤增长率; rand 为区间 $[0, 1]$ 内的随机数; $N(1, D)$ 为维度为 D 的标准正态分布随机数。

(3)获取阳光生长。为了快速生长,常春藤找到附着表面(如墙、岩石或树)来爬向阳光是至关重要的。IVYA中,常春藤 I_i 通常选择最近、适应度函数值较佳的邻居 I_{ii} 作为朝阳光方向攀爬和移动的支撑。常春藤位置更新描述为

$$I_i^{\text{new}} = I_i + |N(1, D)| \odot (I_{ii} - I_i) + N(1, D) \odot \Delta Gv_i \quad (5)$$

$$\Delta Gv_i = \begin{cases} I_i \emptyset (I_{\max} - I_{\min}), & \text{Iter} = 1 \\ \text{rand}^2 \odot (N(1, D) \odot \Delta Gv_i), & \text{Iter} > 1 \end{cases} \quad (6)$$

式中, I_i^{new} 为第 i 枝常春藤更新位置; $|N(1, D)|$ 为

向量 $N(1, D)$ 绝对值; I_{ii} 为邻近 I_i 的常春藤位置; \emptyset 为阿达玛除法(逐元素除法); Iter 为迭代次数;其他参数意义同上。

(4)传播和进化。IVYA中,常春藤 I_i 试图跟随整个种群中最佳常春藤 I_{Best} 位置生长,这相当于在最佳常春藤 I_{Best} 周围寻找更好位置。常春藤位置更新描述为

$$I_i^{\text{new}} = I_{\text{Best}} \odot (\text{rand}(1, D) + N(1, D) \odot \Delta Gv_i) \quad (7)$$

式中, I_{Best} 为迄今为止最佳常春藤位置;其他参数意义同上。

(5)爬升与扩张。为了模拟常春藤生命中的爬升与扩张过程,IVYA定义:当常春藤 I_i 目标函数值 $f(I_i)$ 劣于 $\beta \times f(I_{\text{Best}})$ 时 $[\beta = (2 + \text{rand})/2]$ 时,常春藤开始扩展藤枝和叶子;否则,常春藤开始向上生长和爬升。

1.3.8 青蒿素优化(AO)算法

AO是YUAN等^[22]于2024年受青蒿素治疗疟疾疗效启发而提出一种元启发式算法。该算法通过模拟青蒿素在治疗疟疾过程中全面消除(全局搜索)、局部清除(局部开发)和后期巩固(局部极值逃逸能力)三种策略求解待优化问题,目前已在变形预测等方面得到应用。原理见参考文献[23]。

1.3.9 苔藓生长优化(MGO)算法

MGO是ZHENG等^[24]于2024年受苔藓生长启发而提出的一种元启发式算法。该算法通过模拟苔藓生长过程中确定风向、孢子传播、双重繁殖、隐生机制4种生长策略求解待优化问题。

(1)初始化。与其他算法一样,MGO采用随机初始化苔藓位置,计算公式为

$$M_i = lb + \text{rand}(0, 1) \times (ub - lb) \quad (8)$$

式中, M_i 为苔藓初始化位置; ub 、 lb 为搜索空间上、下限值; $\text{rand}(0, 1)$ 为 $(0, 1)$ 范围内的随机数。

(2)确定风向。MGO风向机制是利用大多数搜索个体与最优个体之间的位置关系来确定种群中所有搜索个体的进化方向。在迭代过程中,风向保持不变,且风向总是从苔藓数量较多的区域吹向最有利生长环境中的单个苔藓。风向机制描述为

$$D_wind = \frac{1}{\text{num}} \sum_{i=1}^{\text{num}} dM_i, \quad dM_i \in \text{dir}X \quad (9)$$

式中, D_wind 为风向,其维度与搜索个体相同; num 为搜索个体数量; $\text{dir}X$ 为搜索个体与最佳搜索个体的距离集合。

(3)孢子传播。在稳定风向条件下,孢子能够传播更远的距离;而在湍流条件下,孢子只能在更短的

距离内传播。MGO 中,大多数孢子在稳定风向条件下传播,小部分在湍流条件下传播。苔藓位置更新描述为

$$M_i^{\text{new}} = \begin{cases} M_i + \text{step1} \cdot D_wind, & r_1 > d_1 \\ M_i + \text{step2} \cdot D_wind, & r_1 \leq d_1 \end{cases} \quad (10)$$

式中, M_i^{new} 为第 i 个苔藓更新位置; 步骤 1 为稳定风向条件下孢子的传播距离; 步骤 2 为湍流条件下孢子的传播距离; r_1 为 $(0, 1)$ 范围内的随机数; d_1 为孢子传播控制常数, 本文取 0.2。

(4) 双重繁殖。MGO 利用下式模拟了苔藓的有性繁殖和营养繁殖, 苔藓通过有性繁殖和营养繁殖产生新的搜索个体, 具体计算公式为

$$\begin{cases} M_i^{\text{new}} = (1 - act) \cdot M_i + act \cdot M_{\text{best}}, & r_2 > d_2 \\ M_{i,j}^{\text{new}} = M_{\text{best},j} + \text{step3} \cdot D_wind_j, & r_4 \leq d_2 \end{cases} \quad (11)$$

式中, $M_{i,j}^{\text{new}}$ 为第 i 个苔藓第 j 维新位置; act 为繁殖控制参数, 取 1 或 0; M_{best} 为当前最佳苔藓位置; $M_{\text{best},j}$ 为当前最佳苔藓第 j 维位置; 步骤 3 为双重繁殖下的传播距离; D_wind_j 为第 j 维风向; r_2 为 $(0, 1)$ 范围内的随机数; d_2 为孢子繁殖控制常数, 本文取 0.5。

(5) 隐生机制。隐生现象是指苔藓在一段时间的不生长或在干旱后能迅速恢复生机的能力。当苔藓失去生存条件时, 它会干燥并进入代谢休眠状态; 一旦条件变得有利, 苔藓就有能力恢复生机。

1.3.10 莲花效应优化算法 (LEA)

LEA 是 DALIRINIA 等^[25]于 2024 年受自然界莲花特性启发而提出的一种元启发式算法。该算法结合了蜻蜓算法中的高效算子, 并通过模拟荷叶超疏水机制和荷花效应求解待优化问题。

(1) 初始化。与其他算法一样, LEA 采用随机初始化搜索个体 (莲花个体) 位置, 具体计算公式为

$$X_i = lb + rand(0, 1) \times (ub - lb) \quad (12)$$

式中, X_i 为莲花个体初始化位置; ub 、 lb 为搜索空间限值; $rand(0, 1)$ 为 $(0, 1)$ 范围内随机数。

(2) 探索阶段。LEA 通过蜻蜓分离、对齐、内聚、对食物来源吸引、干扰敌人五种授粉行为更新莲花个体位置。莲花个体位置更新描述为

$$X_i^{t+1} = X_i^t + w\Delta X_i^{t+1} \quad (13)$$

$$\Delta X_i^{t+1} = (sS_i^t + aA_i^t + cC_i^t + fF_i^t + eE_i^t) + w\Delta X_i^t \quad (14)$$

式中, X_i^{t+1} 为第 i 个莲花个体第 $t+1$ 次迭代位置; X_i^t 为第 i 个莲花个体第 t 次迭代位置; ΔX_i^{t+1} 为莲花个体更新步长; w 为惯性权重; s 为分离系数, S_i^t 为第 i 个

莲花个体第 t 次迭代分离度; a 为对齐系数, A_i^t 为第 i 个莲花个体第 t 次迭代对齐度; c 为内聚系数, C_i^t 为第 i 个莲花个体第 t 次迭代内聚力; f 为食物因子, F_i^t 为第 i 个莲花个体第 t 次迭代食物来源; e 为敌人因子; E_i^t 为第 i 个莲花个体第 t 次迭代敌人位置; ΔX_i^t 为前代莲花个体步长。

(3) 开发阶段。LEA 通过局部授粉 (自花受粉) 模拟开发过程。莲花个体位置更新描述为

$$X_i^{t+1} = X_i^t + R(X_i^t - g^*) \quad (15)$$

式中, g^* 为迄今为止最佳莲花位置; R 为增长区域, 描述为 $R = 2e^{-(4t/T)^2}$; t 、 T 为当前迭代次数和最大迭代次数。

(4) 强化开发阶段。LEA 通过模拟莲花叶子上坑的容量大小来强化开发过程。坑越深, 容量越大, LEA 局部搜索能力越强。莲花个体位置更新描述为

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (16)$$

$$V_i^{t+1} = V_i^t + Rand(X_{\text{deeppit}}^t - X_i^t) \quad (17)$$

式中, V_i^{t+1} 为第 i 个水珠第 $t+1$ 次迭代速度; V_i^t 为第 i 个水珠当前速度; $Rand(\cdot)$ 为随机生成函数; X_{deeppit}^t 为第 t 次迭代最深坑位置。

1.4 正则化极限学习机 (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^[26-27]。其目标函数描述为

$$\min E = \min_{\beta} (C \|\beta^2\| + \|\varepsilon^2\|) \quad (18)$$

$$\text{s. b. } \sum_{v=1}^m \lambda_v f(W_v \cdot X_c + b_i) - y_c = \varepsilon_c \quad (19)$$

式中, E 为风险总和; $C \|\beta^2\|$ 、 $\|\varepsilon^2\|$ 分别为结构风险和经验风险; C 为正则化系数; 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_c 为给定的输入数据; b_i 为隐含层偏值; y_c 为样本输出; ε_c 为误差总和; m 为输入数据数量。

实践中, 输入层权值和隐含层偏差 (超参数) 对 RELM 性能影响较大。当前, 改进蛇群优化算法^[27]、菲克定律优化算法^[28]、改进足球战术算法^[29]、蛻螂优化算法^[30]、珍蚌优化算法^[30]、泥环算法^[30]等新型元启发式算法已在 RELM 超参数寻优中得到应用。

2 预测流程

步骤一: 数据处理。选取西城、南庄、临安、文澜、者林寨、植物园 6 站 2019—2023 年逐周地下水位时间序列实测数据的 70% 样本作为训练集, 剩余 30% 实测数据作为测试集, 对训练集和测试集进行

[0, 1]归一化处理。

步骤二：时间序列分解。利用 1 层 WPT 对西城等地下水水位时间序列进行分解处理，得到趋势项分量 (XY1、NZ1、LA1、WL1、ZLZ1、ZWY1) 和波动项分量 (XY2、NZ2、LA2、WL2、ZLZ2、ZWY2) 共 12 个分解分量。

步骤三：输入和输出。输入维度 m 对模型预测性能影响较大，过小或过的 m 均会导致模型性能下降。本文在延迟时间为 1 的情形下，采用虚假最近邻点法 (FNN) 确定西城、南庄、临安、文澜、者林寨、植物园 6 站地下水水位时序数据的输入维度 m 分别为 19、15、19、25、15、18，即利用前 19、15、19、25、15、18 周地下水水位数据预测西城、南庄、临安、文澜、者林寨、植物园当前地下水水位。模型输入 L_{input} 、输出 L_{output} 表示为

$$L_{input} = \begin{bmatrix} L_1 & L_2 & \cdots & L_m \\ L_2 & L_3 & \cdots & L_{m+1} \\ \vdots & \vdots & \ddots & \vdots \\ L_{K-m} & L_{K-m-1} & \cdots & L_K \end{bmatrix}, L_{output} = \begin{bmatrix} L_{m+1} \\ L_{m+2} \\ \vdots \\ L_{K+1} \end{bmatrix} \quad (20)$$

式中， K 为样本数量； m 为输入维度。

步骤四：构建实例目标函数。基于趋势项分量 (XY1、NZ1、LA1、WL1、ZLZ1、ZWY1) 和波动项分量 (XY2、NZ2、LA2、WL2、ZLZ2、ZWY2) 训练集拟合值与实际值构建均方误差 MSE 作为十种“植物”算法优化 RELM 超参数的目标函数

$$\begin{cases} \min f_{MSE(W, b)} = \frac{1}{c} \sum_{i=1}^c (\hat{L}_i - L_i)^2 \\ \text{s. t } W \in [W_{\min}, W_{\max}], b \in [b_{\min}, b_{\max}] \end{cases} \quad (21)$$

式中， \hat{L}_i 为 L 实测值； L_i 为拟合值； c 为训练集大小； W 、 b 为 RELM 超参数。

步骤五：参数设置。设置十种“植物”算法种群规模为 30，最大迭代次数为 300，其他采用默认值。初始化十种“植物”算法搜索个体空间位置。设置 RELM 隐含层节点数为 m (m 为输入维度)，激活函数选择 sigmoid 函数，超参数搜索空间为 $[-1, 1]$ ，正则化系数 C 为 1×10^{-10} 。

步骤六：超参数寻优。(1) 评估十种“植物”算法搜索个体适应度值，确定最佳搜索个体位置。(2) 基于十种“植物”算法搜索个体更新算子更新新搜索个体位置。(3) 评估搜索个体位置更新后十种“植物”算法的适应度值，确定迄今为止最佳搜索个体位置。(4) 重复直至满足终止条件。输出全局最佳搜

索个体位置，即最佳 RELM 超参数。

步骤七：模型构建。利用最佳 RELM 超参数建立 IWO/FPA/TGA/SFO/CPA/DO/IVYA/AO/MGO/LEA-RELM 模型对各趋势项分量和波动项分量进行预测和重构。

3 十种“植物”算法实例验证与应用

3.1 实例目标函数验证

为对比验证十种“植物”算法实际应用及优化效果，基于西城、南庄、临安、文澜、者林寨、植物园 6 站地下水水位趋势项分量 (XY1、NZ1、LA1、WL1、ZLZ1、ZWY1) 和波动项分量 (XY2、NZ2、LA2、WL2、ZLZ2、ZWY2) 构建 XY_{F_1} - ZWY_{F_1} 、 XY_{F_2} - ZWY_{F_2} 共 12 实例目标函数，利用十种“植物”算法 (参数设置同上) 对 12 个实例目标函数进行寻优。寻优曲线如图 3 所示，结果如表 2 所列。

(1) IVYA 对 12 个实例目标函数的寻优结果排名均为 1，寻优效果最好、精度最高，具有最优的全局和极值寻优能力；其次是 CPA、FPA，其对 12 个实例目标函数的寻优结果排名分别为 2、3，具有较优的寻优性能；LEA、MGO、TGA 对 12 个实例目标函数的寻优结果排名分别为 8、9 和 10，寻优效果较差，陷入局部最优；其余 IWO、SFO、DO、AO 对 12 个实例目标函数的寻优效果相对较好，但存在陷入局部极值和早熟收敛等不足。

(2) 十种“植物”算法对 12 个实例目标函数的寻优精度由优至劣依次是：IVYA、CPA、FPA、IWO、AO、SFO、DO、LEA、MGO、TGA。10 种算法中，IVYA 寻优效果最好，TGA 最差。

3.2 实例应用

利用 WPT 将西城等站地下水水位时序数据分解为趋势项和波动项，建立 IWO/FPA/TGA/SFO/CPA/DO/IVYA/AO/MGO/LEA-RELM 模型对各趋势项和波动项进行训练、预测和重构，选取平均绝对百分比误差 $MAPE$ (%)、平均绝对误差 MAE (m)、决定系数 DC 对各模型进行评估，结果如表 3 所列，绝对误差如图 4 所示。

从表 3 和图 3 可以得出：

(1) 模型 7、模型 5、模型 2 对西城、南庄、临安、文澜、者林寨、植物园地下水水位预测的 $MAPE$ 在 0.003 0%~0.000 4% 之间，预测的 MAE 在 0.038 9 m~0.006 3 m 之间，预测的 DC 在 0.997 7~0.999 8 之间，预测精度优于模型 4、模型 1、模型 6、模型 8，远优于模型 10、模型 9 和模型 3，具有更好的

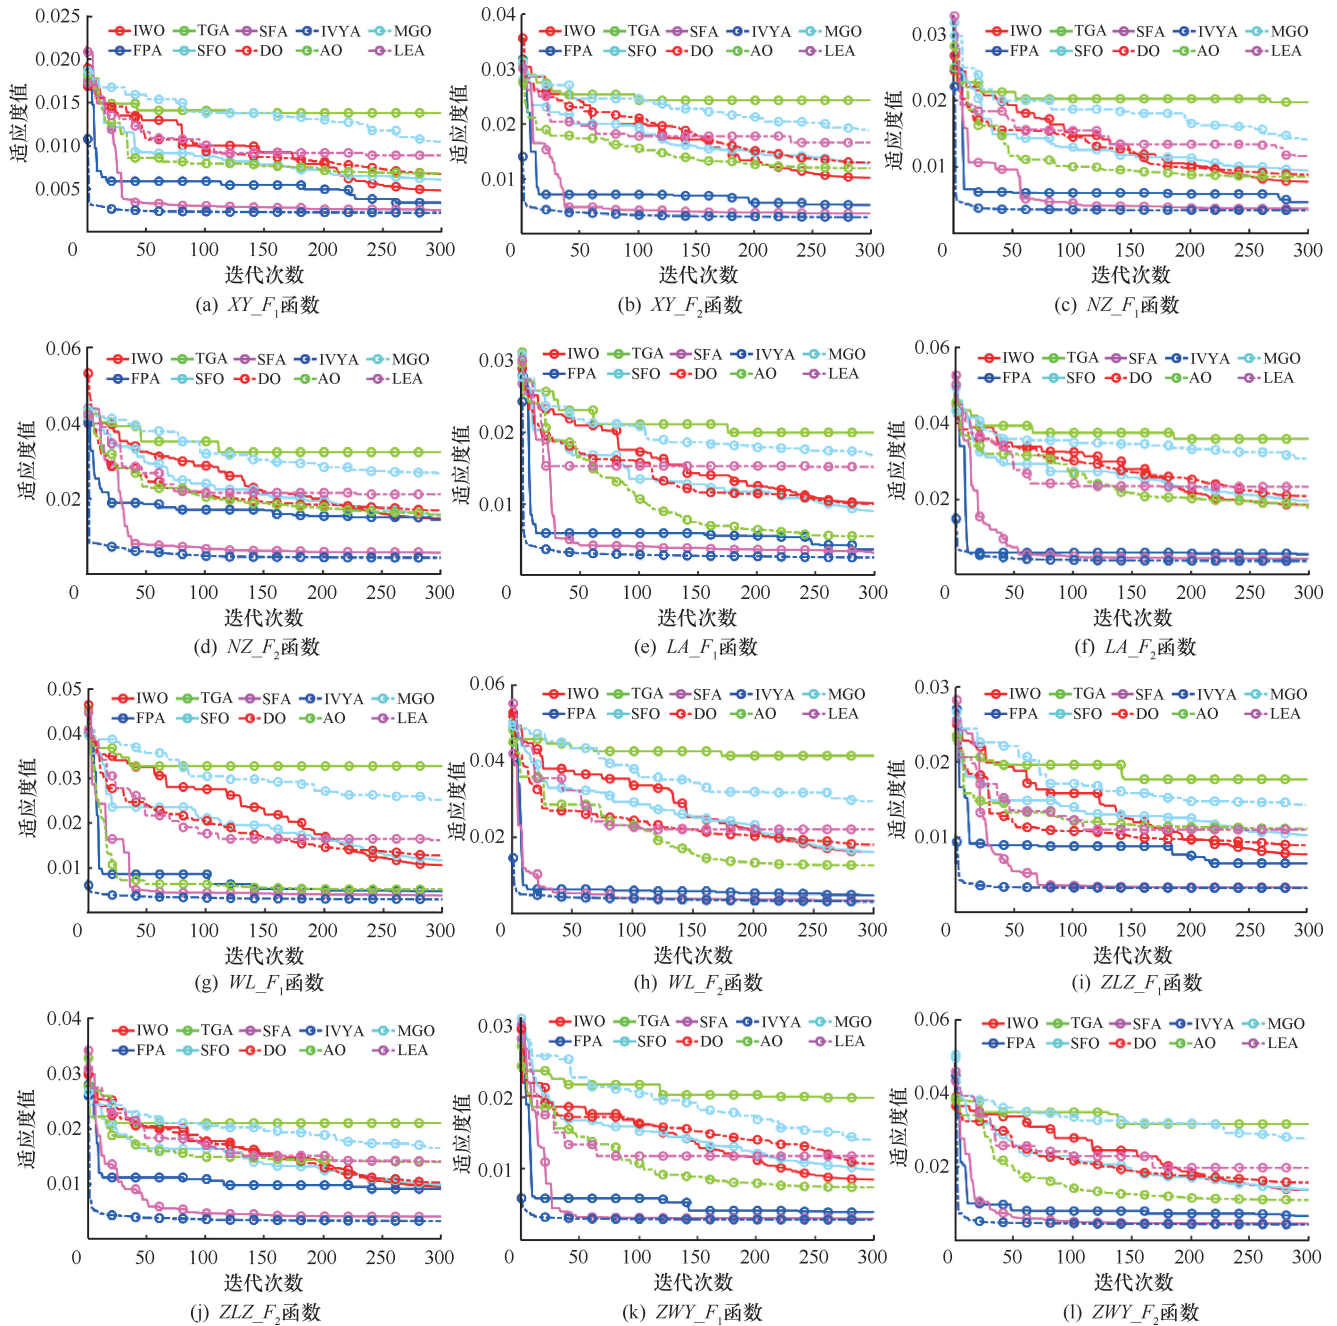


图3 实例目标函数寻优曲线

Fig. 3 Example objective function optimization curves

预测精度和泛化性能。

(2) 十种预测模型对西城、南庄、临安、文澜、者林寨、植物园地下水位训练集拟合精度由高至低依次是模型7、模型5、模型2、模型1、模型8、模型4、模型6、模型10、模型9、模型3；对预测集预测精度由高至低依次是模型7、模型5、模型2、模型8、模型1、模型4、模型6、模型10、模型9、模型3。十种模型的拟合精度与十种“植物”算法的寻优精度排名完全一致，十种模型的预测精度与十种

“植物”算法的寻优精度排名基本一致，仅模型1、模型8存在差异。由此可以得出：十种“植物”算法的寻优性能越强，其寻优获得的RELM超参数越优，所构建的组合模型拟合精度超高，预测效果越好。

(3) WPT可将地下水位时间序列分解为更具规律、更易建模预测的趋势项和波动项，不但分解分量少(仅2个分量)，而且分解效果好，是一种简洁有效的分解方法。

表2 十种“植物”算法实例目标函数寻优结果

Table 2 Optimization results of objective function for ten “plant” algorithms

函数	算法	寻优结果	排名	函数	算法	寻优结果	排名	函数	算法	寻优结果	排名
XY_F ₁	IWO	0.004 8	4	XY_F ₂	IWO	0.010 3	4	NZ_F ₁	IWO	0.007 8	4
	FPA	0.003 3	3		FPA	0.005 3	3		FPA	0.004 7	3
	TGA	0.013 8	10		TGA	0.024 3	10		TGA	0.019 7	10
	SFO	0.006 1	5		SFO	0.012 8	6		SFO	0.009 5	7
	CPA	0.002 6	2		CPA	0.003 8	2		CPA	0.003 8	2
	DO	0.006 7	6		DO	0.013 0	7		DO	0.008 9	6
	IVYA	0.002 3	1		IVYA	0.003 1	1		IVYA	0.003 5	1
	AO	0.006 8	7		AO	0.012 0	5		AO	0.008 5	5
	MGO	0.010 5	9		MGO	0.018 9	9		MGO	0.014 1	9
	LEA	0.008 9	8		LEA	0.016 6	8		LEA	0.011 6	8
NZ_F ₂	IWO	0.014 8	4	LA_F ₁	IWO	0.010 1	7	LA_F ₂	HTS	0.018 5	5
	FPA	0.014 5	3		FPA	0.003 6	3		CFA	0.005 5	3
	TGA	0.032 3	10		TGA	0.020 0	10		MDWA	0.035 9	10
	SFO	0.015 9	6		SFO	0.009 0	5		TEO	0.019 6	6
	CPA	0.005 8	2		CPA	0.003 2	2		CryStAl	0.004 4	2
	DO	0.016 9	7		DO	0.010 0	6		FLA	0.020 8	7
	IVYA	0.004 5	1		IVYA	0.002 5	1		EVO	0.003 8	1
	AO	0.015 6	5		AO	0.005 5	4		ROA	0.017 8	4
	MGO	0.026 7	9		MGO	0.016 8	9		PSA	0.030 7	9
	LEA	0.021 2	8		LEA	0.015 2	8		AROA	0.023 3	8
WL_F ₁	IWO	0.010 6	5	WL_F ₂	IWO	0.016 1	5	ZLZ_F ₁	IWO	0.007 8	4
	FPA	0.004 7	3		FPA	0.004 8	3		FPA	0.006 6	3
	TGA	0.032 7	10		TGA	0.041 4	10		TGA	0.017 7	10
	SFO	0.011 7	6		SFO	0.016 1	6		SFO	0.010 3	6
	CPA	0.003 9	2		CPA	0.003 4	2		CPA	0.003 4	2
	DO	0.012 8	7		DO	0.018 1	7		DO	0.009 0	5
	IVYA	0.003 0	1		IVYA	0.003 1	1		IVYA	0.003 3	1
	AO	0.005 2	4		AO	0.012 7	4		AO	0.011 1	7
	MGO	0.025 2	9		MGO	0.029 4	9		MGO	0.014 4	9
	LEA	0.016 2	8		LEA	0.022 1	8		LEA	0.011 0	8
ZLZ_F ₂	IWO	0.009 6	4	ZWY_F ₁	IWO	0.008 5	5	ZWY_F ₂	IWO	0.013 7	5
	FPA	0.009 2	3		FPA	0.003 9	3		FPA	0.006 7	3
	TGA	0.021 1	10		TGA	0.019 9	10		TGA	0.031 7	10
	SFO	0.009 9	5		SFO	0.009 9	6		SFO	0.013 8	6
	CPA	0.004 2	2		CPA	0.003 0	2		CPA	0.004 6	2
	DO	0.010 3	6		DO	0.010 7	7		DO	0.015 7	7
	IVYA	0.003 4	1		IVYA	0.002 9	1		IVYA	0.004 3	1
	AO	0.014 0	7		AO	0.007 4	4		AO	0.011 0	4
	MGO	0.016 5	9		MGO	0.014 1	9		MGO	0.027 6	9
	LEA	0.014 2	8		LEA	0.011 8	8		LEA	0.019 8	8

表3 地下水位训练、预测结果

Table 3 Training and prediction results of groundwater levels

站名	模型	序号	训练集				预测集			
			MAPE/%	DC	MAE/m	MEA排名	MAPE/%	DC	MAE/m	MEA排名
西城	IWO-RELM	1	0.0013	0.9997	0.0137	4	0.0031	0.9926	0.0334	5
	FPA-RELM	2	0.0008	0.9999	0.0089	3	0.0009	0.9993	0.0099	3
	TGA-RELM	3	0.0036	0.9978	0.0382	10	0.0047	0.9830	0.0501	9
	SFO-RELM	4	0.0016	0.9996	0.0173	5	0.0029	0.9942	0.0309	4
	CPA-RELM	5	0.0006	0.9999	0.0068	2	0.0008	0.9995	0.0083	2
	DO-RELM	6	0.0018	0.9994	0.0193	7	0.0031	0.9920	0.0336	6
	IVYA-RELM	7	0.0006	0.9999	0.0059	1	0.0006	0.9997	0.0067	1
	AO-RELM	8	0.0017	0.9995	0.0181	6	0.0033	0.9918	0.0354	7
	MGO-RELM	9	0.0027	0.9987	0.0284	9	0.0054	0.9707	0.0579	10
	LEA-RELM	10	0.0022	0.9991	0.0240	8	0.0034	0.9917	0.0361	8
南庄	IWO-RELM	1	0.0016	0.9987	0.0213	4	0.0091	0.9710	0.1225	5
	FPA-RELM	2	0.0009	0.9995	0.0126	3	0.0017	0.9992	0.0231	3
	TGA-RELM	3	0.0037	0.9926	0.0504	10	0.0239	0.6512	0.3214	10
	SFO-RELM	4	0.0019	0.9981	0.0256	7	0.0122	0.9436	0.1640	7
	CPA-RELM	5	0.0007	0.9997	0.0098	2	0.0017	0.9992	0.0229	2
	DO-RELM	6	0.0018	0.9983	0.0239	6	0.0095	0.9640	0.1277	6
	IVYA-RELM	7	0.0007	0.9998	0.0091	1	0.0017	0.9992	0.0227	1
	AO-RELM	8	0.0017	0.9985	0.0226	5	0.0050	0.9923	0.0674	4
	MGO-RELM	9	0.0028	0.9959	0.0372	9	0.0205	0.8451	0.2756	9
	LEA-RELM	10	0.0023	0.9972	0.0312	8	0.0110	0.9543	0.1475	8
临安	IWO-RELM	1	0.0068	0.9985	0.1009	7	0.0135	0.9911	0.1753	7
	FPA-RELM	2	0.0026	0.9998	0.0333	3	0.0030	0.9996	0.0389	3
	TGA-RELM	3	0.0143	0.9939	0.1870	10	0.0155	0.9873	0.2026	9
	SFO-RELM	4	0.0077	0.9982	0.0889	5	0.0100	0.9951	0.1302	5
	CPA-RELM	5	0.0022	0.9999	0.0282	2	0.0026	0.9997	0.0343	2
	DO-RELM	6	0.0070	0.9985	0.0907	6	0.0108	0.9944	0.1405	6
	IVYA-RELM	7	0.0018	0.9999	0.0231	1	0.0020	0.9998	0.0264	1
	AO-RELM	8	0.0041	0.9995	0.0537	4	0.0049	0.9989	0.0642	4
	MGO-RELM	9	0.0115	0.9959	0.1499	9	0.0169	0.9871	0.2198	10
	LEA-RELM	10	0.0102	0.9966	0.1329	8	0.0139	0.9912	0.1816	8
文澜	IWO-RELM	1	0.0020	0.9979	0.0256	5	0.0029	0.9942	0.0370	5
	FPA-RELM	2	0.0008	0.9996	0.0108	3	0.0009	0.9995	0.0112	3
	TGA-RELM	3	0.0057	0.9812	0.0744	10	0.0063	0.9716	0.0823	10
	SFO-RELM	4	0.0021	0.9975	0.0268	7	0.0046	0.9856	0.0591	8
	CPA-RELM	5	0.0007	0.9998	0.0086	2	0.0007	0.9997	0.0091	2
	DO-RELM	6	0.0020	0.9977	0.0257	6	0.0038	0.9897	0.0499	6
	IVYA-RELM	7	0.0005	0.9998	0.0067	1	0.0007	0.9997	0.0087	1
	AO-RELM	8	0.0010	0.9994	0.0135	4	0.0010	0.9994	0.0124	4
	MGO-RELM	9	0.0045	0.9885	0.0581	9	0.0052	0.9789	0.0675	9
	LEA-RELM	10	0.0027	0.9952	0.0353	8	0.0042	0.9866	0.0546	7
者林寨	IWO-RELM	1	0.0010	0.9992	0.0147	4	0.0012	0.9930	0.0177	4
	FPA-RELM	2	0.0009	0.9993	0.0127	3	0.0008	0.9977	0.0108	3
	TGA-RELM	3	0.0024	0.9945	0.0345	10	0.0026	0.9659	0.0364	10
	SFO-RELM	4	0.0013	0.9985	0.0189	6	0.0015	0.9885	0.0213	6
	CPA-RELM	5	0.0005	0.9998	0.0067	2	0.0005	0.9990	0.0068	2
	DO-RELM	6	0.0012	0.9988	0.0164	5	0.0014	0.9912	0.0198	5
	IVYA-RELM	7	0.0005	0.9998	0.0064	1	0.0004	0.9991	0.0063	1
	AO-RELM	8	0.0014	0.9982	0.0200	7	0.0018	0.9852	0.0252	7
	MGO-RELM	9	0.0018	0.9967	0.0260	9	0.0020	0.9817	0.0288	9
	LEA-RELM	10	0.0014	0.9980	0.0195	8	0.0020	0.9809	0.0287	8
植物园	IWO-RELM	1	0.0019	0.9986	0.0202	5	0.0040	0.9846	0.0422	6
	FPA-RELM	2	0.0010	0.9997	0.0103	3	0.0013	0.9986	0.0133	3
	TGA-RELM	3	0.0048	0.9919	0.0506	10	0.0060	0.9663	0.0631	10
	SFO-RELM	4	0.0022	0.9981	0.0237	6	0.0034	0.9890	0.0356	5
	CPA-RELM	5	0.0007	0.9998	0.0075	2	0.0010	0.9992	0.0102	2
	DO-RELM	6	0.0025	0.9977	0.0261	7	0.0048	0.9805	0.0507	7
	IVYA-RELM	7	0.0007	0.9998	0.0071	1	0.0009	0.9992	0.0100	1
	AO-RELM	8	0.0017	0.9989	0.0180	4	0.0023	0.9952	0.0240	4
	MGO-RELM	9	0.0034	0.9957	0.0357	9	0.0061	0.9661	0.0648	9
	LEA-RELM	10	0.0026	0.9972	0.0277	8	0.0058	0.9675	0.0610	8

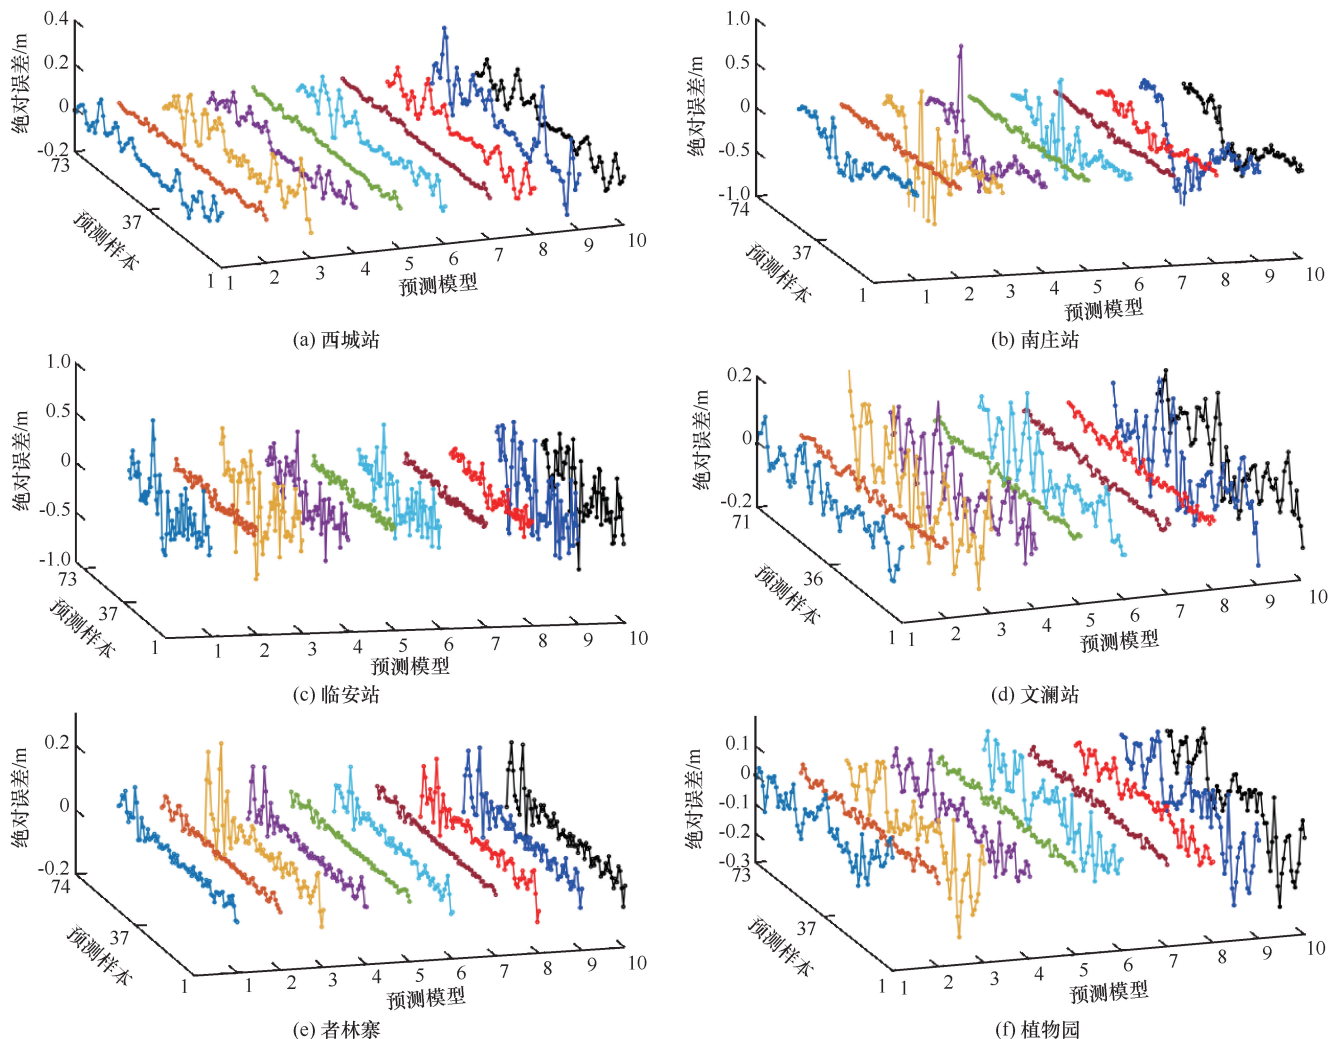


图4 地下水绝对误差

Fig. 4 Absolute errors of groundwater levels

4 结论

基于数据分解的时间序列组合模型最大的不足在于分解分量多、计算规模大、复杂程度高。本文基于WPT方法、十种“植物”算法和RELM,构建IWO/FPA/TGA/SFO/CPA/DO/IVYA/AO/MGO/LEA-RELM地下水水位预测模型,并通过云南省西城、南庄、临安、文澜、者林寨、植物园6站地下水水位时间序列预测实例对各模型进行检验,结果表明如下。

(1)IVYA、CPA、FPA对12个实例目标函数的寻优效果优于IWO、AO、SFO、DO,远优于LEA、MGO、TGA,具有较好的全局和极值寻优性能。10种算法中,IVYA寻优效果最好,TGA最差。

(2)IVYA-RELM、CPA-RELM、FPA-RELM模型对实例地下水水位预测精度优于IWO-RELM、AO-

RELM、SFO-RELM、DO-RELM模型,远优于LEA-RELM、MGO-RELM、TGA-RELM模型,具有更好的预测精度和泛化性能,将其用于地下水水位时间序列预测是可行的。

(3)十种“植物”算法的寻优性能排名与十种组合模型的拟合精度、预测精度排名具有高度的一致性。总体上,算法寻优能力越强,其优化获得的RELM超参数越优,所构建的组合模型拟合、预测精度越高,性能越好。

(4)IVYA-RELM、CPA-RELM、FPA-RELM模型预测精度高、计算规模小,具有较好的实用价值和推广意义。下一步,将基于MATLAB APP Designer平台,尝试将“十种植物”算法(甚至更多)和其他分解技术、预测器等集成、封装成“地下水水位预测软件”,实现具有友好对话界面的地下水水位自动化预测模型。

参考文献(References):

- [1] 童光泽,李计生,牛最荣,等. 基于CNN-LSTM组合模型在地下水位预测中的应用[J]. 水利规划与设计, 2024(9): 58-62.
TONG G Z, LI J S, NIU Z R, et al. Application of CNN-LSTM combined model in groundwater level prediction[J]. Water Resources Planning and Design, 2024(9): 58-62.
- [2] 田辽西,覃华清. 基于多变量LSTM神经网络的地下水位预测方法研究[J]. 干旱区资源与环境, 2024, 38(9): 138-146.
TIAN L X, QIN H Q. Multivariable LSTM model-based groundwater level prediction [J]. Journal of Arid Land Resources and Environment, 2024, 38(9): 138-146.
- [3] 郑世龙,李虎,王中华,等. 基于SSA-RBF神经网络模型在岩溶地下水位预测中的研究[J]. 城市勘测, 2024(4): 200-204.
ZHENG S L, LI H, WANG Z H, et al. Research on karst groundwater level prediction based on SSA-RBF neural network model [J]. Urban Geotechnical Investigation & Surveying, 2024(4): 200-204.
- [4] 侯金霄,黄林显,胡晓农,等. 基于EMD-LSTM耦合模型的趵突泉岩溶地下水水位预测应用[J]. 水资源与水工程学报, 2023, 34(4): 92-98.
HOU J X, HUANG L X, HU X N, et al. Application of EMD-LSTM coupled model to karst groundwater level prediction in Baotu Spring [J]. Journal of Water Resources and Water Engineering, 2023, 34(4): 92-98.
- [5] 张建锋,刘见宝,崔树军,等. 小波-神经网络混合模型预测地下水水位[J]. 长江科学院院报, 2016, 33(8): 18-21.
ZHANG J F, LIU J B, CUI S J, et al. A wavelet-ANN hybrid model for groundwater level forecasting [J]. Journal of Yangtze River Scientific Research Institute, 2016, 33(8): 18-21.
- [6] 付智勇,陈文强,唐伟雄,等. 基于CEEMD-RF模型的渣土边坡地下水埋深预测[J]. 人民长江, 2020, 51(1): 141-148.
FU Z Y, CHEN W Q, TANG W X, et al. Prediction of groundwater depth in residue slope with CEEMD-RF model based on phase space reconstruction[J]. Yangtze River, 2020, 51(1): 141-148.
- [7] WU M, FENG Q, WEN X H, et al. Deterministic analysis and uncertainty analysis of ensemble forecasting model based on variational mode decomposition for estimation of monthly groundwater level[J]. Water, 2021, 13(2): 139.
- [8] 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 X H, CUI D W. Multi-step prediction of hydrological time series based on WPD-RSA-ELM model [J]. Water Resources and Hydropower Engineering, 2022, 53(11): 69-77.
- [9] 李菊,崔东文. 基于WPT-IDBO-RELM和WPT-IDMO-RELM模型的日径流预测[J]. 水利水电科技进展, 2024, 44(6): 48-55.
LI J, CUI D W. Daily runoff prediction based on WPT-IDBO-RELM and WPT-IDMO-RELM models [J]. Advances in Science and Technology of Water Resources, 2024, 44(6): 48-55.
- [10] MEHRABIAN A R, LUCAS C. A novel numerical optimization algorithm inspired from weed colonization[J]. Ecological Informatics, 2006, 1(4): 355-366.
- [11] 崔东文,郑斌. 几种智能优化算法与支持向量机相融合的月径流预测模型及应用[J]. 人民珠江, 2016, 37(3): 18-25.
CUI D W, ZHENG B. Monthly runoff forecasting model and its application with the integration of several intelligent optimization algorithms and support vector machines[J]. Pearl River, 2016, 37(3): 18-25.
- [12] YANG X S, KARAMANOGLU M, HE X S. Flower pollination algorithm: A novel approach for multiobjective optimization [J]. Engineering Optimization, 2014, 46(9): 1222-1237.
- [13] 崔东文,金波. 花授粉算法-BP神经网络模型及其在月径流预报中的应用[J]. 人民珠江, 2016, 37(4): 36-40.
CUI D W, JIN B. Flower pollination algorithm-BP neural network model and its application in the prediction of monthly runoff [J]. Pearl River, 2016, 37(4): 36-40.
- [14] CHERAGHALIPOUR A, HAJIAGHAEI-KESHTELI M, PAYDAR M M. Tree Growth Algorithm (TGA): A novel approach for solving optimization problems [J]. Engineering Applications of Artificial Intelligence, 2018, 72: 393-414.
- [15] 欧阳晨,卫志农,孙国强. 基于树木生长算法的含UPFC的最优潮流计算[J]. 电力工程技术, 2020, 39(3): 84-91.
OUYANG C, WEI Z N, SUN G Q. Optimal power flow with UPFC based on tree growth algorithm [J]. Electric Power Engineering Technology, 2020, 39(3): 84-91.
- [16] GOMES G F, DA CUNHA S S, ANCELOTTI A C. A sunflower optimization (SFO) algorithm applied to damage identification on laminated composite plates[J]. Engineering with Computers, 2019, 35(2): 619-626.
- [17] ONG K M, ONG P, SIA C K. A carnivorous plant algorithm for solving global optimization problems[J]. Applied Soft Computing, 2021, 98: 106833.
- [18] 丁乐天,曹蔚,吴佳军,等. 基于CPA-FM-MEM磨粒分析的缸套-活塞系统健康状态评估[J]. 润滑与密封, 2024, 49(9): 106-116.
DING L T, CAO W, WU J J, et al. Health status assessment of cylinder liner-piston system based on CPA-FM-MEM wear debris analysis[J]. Lubrication Engineering, 2024, 49(9): 106-116.
- [19] ZHAO S J, ZHANG T R, MA S L, et al. Dandelion Optimizer: A nature-inspired metaheuristic algorithm for engineering applications [J]. Engineering Applications of Artificial Intelligence, 2022, 114: 105075.
- [20] 李伟铭,杨敬辉. 改进蒲公英优化算法的有限缓冲区流水车间调度[J]. 计算机系统应用, 2024, 33(8): 240-249.
LI W M, YANG J H. Limited buffer flow workshop scheduling based on improved dandelion optimization algorithm[J]. Computer Systems and Applications, 2024, 33(8): 240-249.
- [21] GHASEMI M, ZARE M, TROJOVSKY P, et al. Optimization based on the smart behavior of plants with its engineering applications: Ivy algorithm[J]. Knowledge-Based Systems, 2024, 295: 111850.
- [22] YUAN C, ZHAO D, HEIDARI A A, et al. Artemisinin optimization based on malaria therapy: Algorithm and applications to medical image segmentation[J]. Displays, 2024, 84: 102740.
- [23] 王平安. 基于IAO-SVM的软岩隧道变形预测模型[J]. 铁道建筑

技术, 2024(8): 93-96.

WANG P A. Deformation prediction model for soft rock tunnels based on IAO-SVM[J]. *Railway Construction Technology*, 2024(8): 93-96.

[24] ZHENG B L, CHEN Y, WANG C F, et al. The moss growth optimization (MGO): Concepts and performanceOpen Access [J]. *Journal of Computational Design and Engineering*, 2024, 11(5): 184-221.

[25] DALIRINIA E, JALALI M, YAGHOobi M, et al. Lotus effect optimization algorithm (LEA): A lotus nature-inspired algorithm for engineering design optimization[J]. *The Journal of Supercomputing*, 2024, 80(1): 761-799.

[26] 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 Z Q, SHANG M Y, SHEN D D, et al. Estimation of SOC of Li-ion battery in pure electric vehicle by BSA-RELM [J]. *Acta Metrologica Sinica*, 2019, 40(4): 693-699.

[27] 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 Y W, BAI X J, CUI D W. Research on monthly runoff time series prediction based on WPT-ISO-RELM model[J]. *Water Power*,

2024, 50(3): 12-18.

[28] 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 X M, CUI D W. WPT-FLA-RELM model for multi-step prediction of daily inflow runoff of Malutang Hydropower Station[J]. *Yunnan Water Power*, 2023, 39(11): 56-62.

[29] 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 X L, CUI D W. Research on daily runoff prediction based on WPT-ITTA-RELM/ELM/LSSVM model[J]. *Journal of China Three Gorges University (Natural Sciences)*, 2024, 46(4): 16-24.

[30] 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 D F, CUI D W. Prediction of daily inflow runoff of Three Gorges Reservoir using regularized extreme learning machine optimized by three new swarm intelligent algorithms[J]. *Journal of Changjiang River Scientific Research Institute*, 2024, 41(7): 16-24.

(责任编辑 王海锋)