

DOI:10.19651/j.cnki.emt.2416343

基于改进麻雀优化与SVR滑坡位移预测^{*}黄奕朝^{1,2,3} 孙希延^{1,2,3,4} 纪元法^{1,2,3} 卢伟萍⁵

(1. 桂林电子科技大学广西精密导航技术与应用重点实验室 桂林 541004; 2. 桂林电子科技大学信息与通信学院 桂林 541004; 3. 卫星导航定位与位置服务国家地方联合工程研究中心 桂林 541004; 4. 南宁桂电电子科技有限公司 南宁 530031; 5. 广西气象科学研究所 南宁 530022)

摘要: 针对滑坡位移具有高度非线性和复杂性,难以利用传统优化算法结合人工智能方法进行更合理、准确的预测建模的问题,本文提出一种 Lévy 飞行策略的混沌麻雀优化算法(CLSSA)-变分模态分解(VMD)-支持向量回归(SVR)的滑坡位移预测模型。首先利用 CLSSA 优化 VMD 分解参数对滑坡位移时间序列进行分解,其次采用 CLSSA-SVR 模型对 VMD 分解子序列进行预测,最后通过叠加子序列预测数据求出累计位移预测。以白水河滑坡为例,对该模型进行验证,实验结果表明,所提方法在最终累计位移预测结果中 MAE 为 2.24 mm, RMSE 为 3.37 mm, R^2 为 0.995, 相对于麻雀优化算法-变分模态分解-支持向量回归(SSA-VMD-SVR),所改进的优化算法增加了 VMD 的自适应能力,提高滑坡位移各分量预测效率。

关键词: 滑坡位移预测; Lévy 飞行策略; 混沌麻雀优化算法; 变分模态分解; 支持向量机回归
中图分类号: TN306; P642.22 **文献标识码:** A **国家标准学科分类代码:** 620.1030

Landslide displacement prediction based on improved sparrow optimization with SVR

Huang Yichao^{1,2,3} Sun Xiyan^{1,2,3,4} Ji Yuanfa^{1,2,3} Lu Weiping⁵

(1. Guangxi Key Laboratory of Precision Navigation Technology and Application, Guilin University of Electronic Technology, Guilin 541004, China; 2. Information and Communication School, Guilin University of Electronic Technology, Guilin 541004, China; 3. National & Local Joint Engineering Research Center of Satellite Navigation Positioning and Location Service, Guilin 541004, China; 4. GUET-Nanning E-Tech Research Institute Co., Ltd., Nanning 530031, China; 5. Guangxi Institute of Meteorological Sciences, Nanning 530022, China)

Abstract: Aiming at the problem that landslide displacement is highly nonlinear and complex, and it is difficult to use traditional optimization algorithms combined with artificial intelligence methods for more reasonable and accurate predictive modeling, a Lévy flight strategy chaotic sparrow optimization algorithm (CLSSA)-variational modal decomposition (VMD)-support vector regression (SVR) landslide displacement prediction model is proposed. Firstly, CLSSA is used to optimize the VMD decomposition parameters to decompose the landslide displacement time series, secondly, the CLSSA-SVR model is used to predict the VMD decomposition subsequence, and finally, the cumulative displacement prediction is derived by superimposing the subsequence prediction data. The model is validated by taking the Baishui River landslide as an example, and the experimental results show that the proposed method has an MAE of 2.24 mm, an RMSE of 3.37 mm, and an R^2 of 0.995 in the final cumulative displacement prediction, and relative to the sparrow optimization algorithm-variational modal decomposition-support vector regression (SSA-VMD-SVR), the improved optimization algorithm increases the adaptive ability of VMD that improves the efficiency of landslide displacement prediction for each component.

Keywords: landslide displacement prediction; Lévy flight strategy; chaotic sparrow optimization algorithm; variational modal decomposition; support vector machines

0 引言

滑坡的演化过程是一个复杂的非线性过程,是由不同

因素的复杂相互作用引起的,如复杂的地质环境、不同的水文条件以及人为因素影响。仅仅依靠对原始位移进行预测,其模型有效性、准确性难以得到保证^[1]。

收稿日期:2024-07-01

* 基金项目:广西科技厅项目(桂科 AA23062038,桂科 AD22080061)、国家自然科学基金(62161007,62061010)、桂林市科技项目(20210222-1)、教育部重点实验室 2022 年主任基金(CRKL220102)项目资助

传统机器学习模型在滑坡位移时间序列预测中难以应对其复杂的非线性和动态特性,亟需通过引入先进的方法和技术对现有模型进行优化和提升,以实现更精确和可靠的预测。尚敏等^[2]基于时间序列与混合核函数模型,通过反复指数平滑对滑坡位移序列进行分解与预测,但受限其自身优化算法的局限性,未能充分考虑模型在更复杂情境下的适应性和泛化能力。杨进昆等^[3]引入卷积神经网络(convolutional neural networks, CNN)和注意力机制模块提高了滑坡预测精度。Lin 等^[4]采用加权移动平均法(weighted moving average, WMA)将滑坡位移数据分解,鉴于滑坡位移趋势随时间的变化,使用长短期记忆(long short-term memory, LSTM)模型进行预测。封青青等^[5]提出了改进的自适应噪声完备集合经验模态分解(intrinsic computing expressive empirical mode decomposition with adaptive noise, ICEEMDAN)的蜣螂算法优化(dung beetle optimizer, DBO)的长短期记忆网络模型有效解决集合经验模态分解(ensemble empirical mode decomposition, EEMD)的噪声残留问题。但像 LSTM 这类复杂的神经网络模型在实际应用中常面临收敛速度缓慢、对数据样本量要求较高以及参数调优困难等挑战。相比之下,支持向量机回归(support vector regression, SVR)凭借其在小样本、多维度和非线性处理方面的卓越性能,已在滑坡预测与预报领域得到了广泛应用。任帅等^[6]提出了一种结合改进混沌灰狼优化算法(circle tactics grey wolf optimizer, CTGWO)与支持向量机的滑坡位移预测模型有效克服了传统模型的不足,还显著提升了预测的精度和鲁棒性。Wen 等^[7]针对单一优化算法陷入局部最优陷阱、收敛速度缓慢以及易出现停滞现象等问题,提出了粒子群优化算法(particle swarm optimization, PSO)-重力搜索算法(gravitational search algorithm, GSA)-支持向量回归机混合模型。姜宇航等^[8]考虑到变分模态分解(variational mode decomposition, VMD)分解时,对惩罚参数与上升步长的选择没有标准化,只能通过大量实验确定,提出了采用 PSO 对 VMD 进行参数寻优。然而,传统麻雀优化算法以其卓越的寻优能力、高效的求解性能及简洁的结构设计而备受关注。

综上所述,针对传统麻雀优化算法在优化能力方面存在不足,且 VMD 分解算法参数调整复杂,影响位移序列的有效分解等问题。本文提出一种引入 Lévy 飞行机制的改进 Circle 麻雀搜索优化算法-变分模态分解-支持向量回归(CLSSA-VMD-SVR)的滑坡位移预测模型。首先利用 CLSSA 优化 VMD 分解参数对滑坡位移时间序列进行分解,提高数据分解精度;其次分析和处理库水位、历史降雨、历史滑坡变化等影响因子,将影响位移的因子序列与滑坡位移分解序列进行灰色关联度分析,选择相关性高的数据作为各子序列预测的输入变量;采用 CLSSA-SVR 模型对各个子序列进行预测,以三峡库区重点监测滑坡-白河水

滑坡为列,将均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)和决定系数(r-squared, R^2)作为评判标准,对模型进行性能评价,并引用八字门数据对模型进行适用性检验,验证了该模型在滑坡位移预测中的有效性和适用性。

1 理论与方法

1.1 变分模态分解算法

变分模态分解是一种自适应模态变分处理方法,通过将分离信号数据分解为一系列具有有限带宽的本征模态函数(intrinsic mode function, IMF),迭代搜寻变分模态的最优解^[9]。

$$u_k(t) = A_k(t) \cos(\phi_k(t)) \quad (1)$$

其中, $A_k(t)$ 为函数幅值; $\phi_k(t)$ 为函数相位; $u_k(t)$ 为本特征模态函数。

计算表达式为:

$$\left\{ \begin{array}{l} \min_{\{\omega_k, \delta(t)\}} \sum_k \left\| \partial(t) \left[(\delta(t) + \frac{j}{\pi t}) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ s \times t \times \sum_k u_k = f(t) \end{array} \right. \quad (2)$$

其中, $\{u_k\}$ 为分解得到的 k 个分量, $\{\omega_k\}$ 为分解的各分量的实际中心频率, $\delta(t)$ 为狄拉克函数, $s \times t$ 表示约束, $f(t)$ 表示要分解的原始时间序列。

引入惩罚因子 a 和拉格朗日乘子 λ 对函数进行求解,如下:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & a \sum_k \left\| \partial(t) \left[(\delta(t) + \frac{j}{\pi t}) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \| f(t) - \sum_k u_k(t) \|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (3)$$

1.2 支持向量机回归模型

SVR 模型以结构风险最小化为基础,解决高维、少样本的非线性问题。与其他模型相比,SVR 模型收敛效率更快,并更为有效地处理多元函数估计问题。SVR 模型原理如下:SVR 回归模型的决策函数表达式为:

$$f(x) = \mathbf{W}^T \varphi(x) + b \quad (4)$$

其中, \mathbf{W}^T 为超平面系数向量; $\varphi(x)$ 为非线性映射函数; b 为偏置量。求解系数和偏置项最小化表示为:

$$D(f) = \frac{1}{2} \|\mathbf{W}\|^2 + \frac{C}{n} \sum_{j=1}^n R_\epsilon[y_j, f(x_j)] \quad (5)$$

其中, $D(f)$ 为最优的线性回归平面; $\|\mathbf{W}\|^2$ 为模型复杂度; C 为惩罚因子; R_ϵ 为 ϵ 控制误差函数。优化问题可简化为:

$$\left\{ \begin{array}{l} \min Q(\mathbf{W}, \xi) = \frac{1}{2} \|\mathbf{W}\|^2 + C \sum_{j=1}^n \xi_j + \xi_j^* \\ \mathbf{W}^T \varphi(x_j) + b - y_j \leq \epsilon + \xi_j \\ y_j - \mathbf{W}^T \varphi(x_j) - b \leq \epsilon + \xi_j^* \\ \xi_j \geq 0, \xi_j^* \geq 0 (j = 1, 2, \dots, n) \end{array} \right. \quad (6)$$

其中, ξ_j, ξ_j^* 为松弛因子。

采用拉格朗日方程和对偶理论将式(6)转换为:

$$\begin{cases} L(W, a, b, \epsilon, y) = \min \frac{1}{2} \sum_{r,j=1}^n (a_r - a_r^*) H_{r,j} \times \\ a_r - a_r^* + \epsilon \sum_{r,j=1}^n (a_r - a_r^*) + \sum_{r=1}^n y_r (a_r - a_r^*) \\ \sum_{r=1}^n (a_r - a_r^*) = 0, (0 \leq a_r, a_r^* \leq C) \\ H_{r,j} = K(x_r, x_j) = \boldsymbol{\varphi}(x_r)^\top \boldsymbol{\varphi}(x_j), (r = 1, 2, \dots, n) \end{cases} \quad (7)$$

其中, $K(x_r, x_j)$ 为 SVR 模型核函数, a_r, a_r^* 为拉格朗日乘子。

求解最优解可表示为:

$$f(x) = \sum_{j=1}^n (a_r - a_r^*) K(x_j, x) + b \quad (8)$$

不同核函数对模型的精度具有至关重要的影响。本文采用高斯核函数以提升模型的鲁棒性与泛化能力。

1.3 改进混沌麻雀优化算法

1) 基本麻雀搜索算法

麻雀搜索算法(sparrow search algorithm, SSA)其灵感源自自然界中麻雀的觅食行为以及对捕食者的逃避策略^[10]。在该算法中,将麻雀种群分为发现者和参与者两类,适应度较好的麻雀中的一部分作为生产者,其余的作为跟随者^[11]。此外,还在种群中随机选择了一些麻雀作为侦察者以增加预警机制。

(1)假设 n 表示麻雀种群大小, d 表示求解变量的维数,则整个麻雀种群 \mathbf{X} 可以表示为:

$$\mathbf{X} = \begin{bmatrix} x_{1,1}, x_{1,2}, \dots, x_{1,d} \\ x_{2,1}, x_{2,2}, \dots, x_{2,d} \\ \vdots \\ \vdots \\ x_{n,1}, x_{n,2}, \dots, x_{n,d} \end{bmatrix} \quad (9)$$

(2)发现者的位置更新公式如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \times \exp\left(-\frac{i}{\alpha \times itet_{\max}}\right), & R_2 < ST \\ X_{i,j}^t + Q \times \mathbf{L}, & R_2 \geq ST \end{cases} \quad (10)$$

其中, $X_{i,j}^t$ 表示第 i 只麻雀在迭代 t 次时在第 j 维的值, $itet_{\max}$ 是迭代的最大次数, \mathbf{L} 表示 d 维向量,内部每个元素都为 1, α 为区间(0,1]的随机数, $R_2 \in [0,1]$ 表示预警值, $ST \in [0.5,1]$ 表示安全阈值, Q 为服从正态分布的随机数。

(3)参与者位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} Q \times \exp\left(\frac{X_{\text{worst}}(t) - X_{i,j}^t}{i^2}\right), & i > N/2 \\ X_{\text{best}}(t) + |X_{i,j}^t - X_{\text{best}}(t+1)| \times \mathbf{A}^+ \times \mathbf{L}, & \text{其他} \end{cases} \quad (11)$$

其中, $X_{\text{worst}}(t)$ 表示全局最差位置; $X_{\text{best}}(t)$ 表示发现

者占据的最佳位置; N 为种群数量; $\mathbf{A}^+ = \mathbf{A}^\top (\mathbf{A}\mathbf{A}^\top)^{-1}$, \mathbf{A} 表示随机分配为 1 或者 -1 的矩阵。

(4)在觅食时,为了避免捕食者造成伤害,种群中会随机从 10%~20% 的麻雀中挑选侦察者,其侦察者位置更新公式如式所示:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}(t) + \beta \times |X_{i,j}^t - X_{\text{best}}(t)|, & f_i > f_g \\ X_{\text{best}}(t) + K \left(\frac{X_{i,j}^t - X_{\text{worst}}(t)}{|f_i - f_w| + \epsilon} \right), & f_i = f_g \end{cases} \quad (12)$$

其中, $X_{\text{best}}(t)$ 表示当前全局最优位置, β 为步长调节参数,满足标准正态分布, $k \in [-1,1]$ 范围内的随机数。

2)改进的 Circle 混沌初始化策略

SSA 算法使用随机初始化方式生成初始解,但这种方法可能导致初始种群分布不够均匀,从而限制了算法的优化能力。相比之下,混沌映射具有随机性、遍历性和规律性等特点,有助于算法更加动态和全局地搜索空间,从而有效地避免了上述问题^[12]。

混沌是非线性效应产生的一种随机现象,具有无周期性、随机性、均匀性、不可预测性等特点。而 Circle 混沌映射相对于其他混沌映射具有连续性、周期性、映射范围限制、鲁棒性和计算效率等优势。因此本文使用了改进的 Circle 混沌映射,其表达式为:

$$X_{n+1} = b \text{mod} \left(X_n + 0.3 - \left(\frac{0.6}{2\pi} \sin(2\pi X_n) \right), 1 \right) \quad (13)$$

3)改进发现者位置更新公式

在 SSA 算法中,麻雀发现者位置只受上一代发现者位置的影响, $\exp\left(-\frac{i}{\alpha \times itet_{\max}}\right)$ 的值会在不断迭代过程中自适应下降,随着迭代次数的增加,发现者会进入广泛搜索模式。为了提高搜索算法的收敛精度,本文在式(10)基础上将发现者公式更改为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \times \frac{2}{\exp\left(-\frac{4i}{\alpha \times itet_{\max}}\right)^m}, & R_2 < ST \\ X_{i,j}^t + Q \times \mathbf{L}, & R_2 \geq ST \end{cases} \quad (14)$$

麻雀探索者对于全局和局部搜索之间的平衡关系会受到 m 值的选择的影响。本文将 $m \in [1,4]$, 经过实验分析,当 $m = 4$ 的时,平均收敛迭代次数最小,可以使 SSA 算法的探索能力和觅食能力达到较好的平衡。

4)Lévy 飞行策略

为了避免原始 SSA 算法容易陷入局部最优解的问题,引入了 Lévy 飞行策略,用于更新参与者的位置。这一策略的采用有助于增加算法跳出局部最优解的概率,并提高了算法的全局搜索能力^[13]。改进后的公式如下:

$$X_{i,j}^{t+1} = \begin{cases} Q \times \exp\left(\frac{X_{worst}(t) - X_{i,j}^t}{i^2}\right), & i > N/2 \\ X_{best}(t) + X_{best}(t) \otimes Levy(d), & \text{其他} \end{cases} \quad (15)$$

其中, $X_{best}(t)$ 是当前发现者的最佳位置, Lévy 飞行机制如下:

$$Levy(x) = 0.01 \times \frac{r_3 \times \sigma}{|r_4|^{(1/\xi)}} \quad (16)$$

其中, r_3, r_4 均为 $[0, 1]$ 范围内的随机数, ξ 的值可取

1.5, σ 计算方式如下:

$$\sigma = \left(\frac{\Gamma(1 + \xi) \times \sin(\pi\xi/2)}{\Gamma((1 + \xi)/2) \times \xi \times 2^{((\xi-1)/2)}} \right) \quad (17)$$

其中, $\Gamma(x) = (x - 1)!$ 。

1.4 滑坡位移预测流程

CLSSA-VMD-SVR 滑坡预测模型流程如图 1 所示。

- 1) 采用 CLSSA 优化 VMD 的惩罚因子 α 和模态分解数 k , 将滑坡位移序列分解成多个子序列。
- 2) 将各分量数据集以 $(8 : 1 : 1)$ 比例划分为训练集、验证集、测试集, 并引入影响因子。
- 3) 采用 CLSSA 优化 SVR 的 BoxConstraint、KernelScale 和 Epsilon 3 个变量。
- 4) 采用 CLSSA-SVR 模型对各个分量进行预测。
- 5) 将预测值进行累计叠加构成位移预测值。

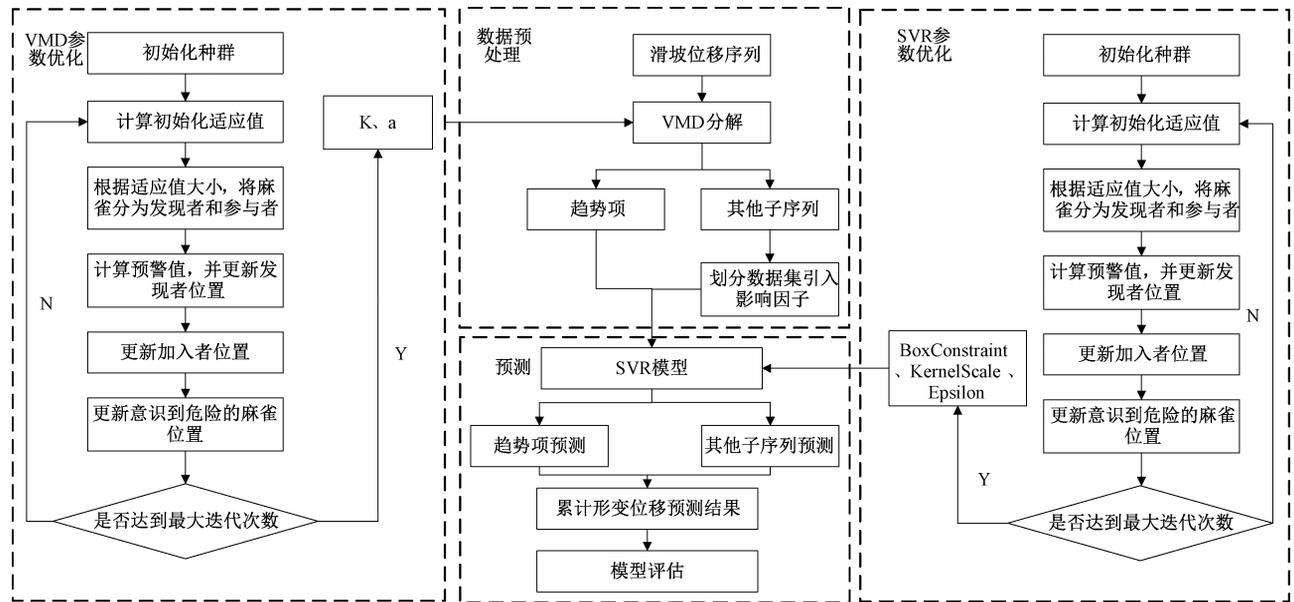


图 1 滑坡位移预测流程图

Fig. 1 Flow chart for landslide displacement prediction

1.5 评估标准

为了合理评估所提出的滑坡位移预测模型的预测性能, 本文使用均方根误差 (RMSE) 来描述预测值的突变情况, 使用平均绝对误差 (MAE) 来度量预测值和实际值之间的误差, 使用决定系数 (R^2) 衡量回归模型的容量, 评价其拟合程度。

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (18)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [\hat{y}_i - y_i]^2} \quad (19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n [\hat{y}_i - y_i]^2}{\sum_{i=1}^n [y_i - \bar{y}]^2} \quad (20)$$

2 研究区域地质概况

白水河滑坡位于三峡大坝上游的长江南岸。滑坡体

处于单斜顺向坡地形, 地形坡度的整体前缘和后缘相对不平坦、中间相对平缓, 阶梯状向长江展布。2005 年以来, 滑坡体后部发生局部拉裂崩塌。目前观察到, 滑坡东侧及其后缘裂缝主要呈横断裂缝, 而西侧则存在大量张性裂缝, 这些裂缝常导致局部浅层破坏。

白水河强烈滑坡变形区域为白水河的堆积体区域, 主要位于前中部, 整体滑坡趋势呈现台阶状特点。受降雨与库水位影响, 白水河滑坡累计形变量会表现为缓倾状态与陡倾状态, 且存在一定滞后效应。白水河滑坡共有 11 个 GPS 点, 其中, Z118 监测点安装在滑坡中段, 并且监测资料完整, 时间最长, 可以较好的提现滑坡演变过程, 适用于实验模型建模。因此本文选取该监测点 2004 年 1 月至 2012 年 12 月滑坡累计位移数据作为试验对象, 数据来源于国家冰川冻土沙漠科学数据中心 (<http://www.ncdc.ac.cn>)。

3 实验分析

3.1 CLSSA 算法性能测试

为了测试 CLSSA 算法的寻优能力,将 CLSSA 算法与 PSO、SSA、GWO 算法同时在 8 个基准函数上进行测试,如表 1 所示。其中, F1~F5 是高纬单峰测试函数,

F6~F8 是高纬多峰测试函数。本次实验中,将对所选基准函数进行独立运行 30 次。所有优化算法的种群规模设定为 30,最大迭代次数为 500^[14]。通过对 30 次实验数据的平均值和标准差进行计算,评估算法的寻优能力和稳定性。实验结果如表 2 所示,迭代效果如图 2 所示。

表 1 8 个基准测试函数
Table 1 Eight benchmark functions

函数名	函数表达式	维数	搜索范围	最优解
Sphere	$F_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
Schwefel 2.22	$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	$[-10, 10]$	0
Schwefel 1.2	$F_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	30	$[-100, 100]$	0
Schwefel 2.21	$F_4(x) = \max_i \{ x_i , 1 \leq i \leq n\}$	30	$[-100, 100]$	0
Quartic	$F_5(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0, 1)$	30	$[-1.28, 1.28]$	0
Rastrigin	$F_6(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$	0
Ackley	$F_7(x) = -20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}\right) - \exp\left(\sqrt{\frac{1}{n}\sum_{i=1}^n 2\pi x_i}\right) + 20 + e$	30	$[-32, 32]$	0
Griewank	$F_8(x) = \frac{1}{4000}\sum_{i=1}^n x_i^2 + \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	$[-600, 600]$	0

表 2 4 种优化算法基准函数测试结果对比

Table 2 Comparison of benchmark function test results of four optimization algorithms

函数	PSO		GWO		SSA		CLSSA	
	平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差
F1	2.36	0.90	1.53×10^{-27}	2.86×10^{-27}	3.35×10^{-54}	1.83×10^{-53}	0	0
F2	4.52	1.29	9.66×10^{-17}	6.85×10^{-17}	5.62×10^{-29}	2.24×10^{-28}	0	0
F3	195.11	58.68	1.73×10^{-5}	4.00×10^{-5}	6.34×10^{-25}	2.37×10^{-24}	0	0
F4	2.01	0.26	9.99×10^{-7}	1.55×10^{-6}	2.22×10^{-24}	1.21×10^{-23}	0	0
F5	19.57	16.90	1.96×10^{-3}	1.17×10^{-3}	1.45×10^{-3}	8.39×10^{-4}	6.40×10^{-4}	6.87×10^5
F6	162.36	32.97	2.83	4.90	0	0	0	0
F7	2.55	0.32	9.70×10^{-14}	1.93×10^{-14}	8.88×10^{-16}	8.88×10^{-16}	4.44×10^{-16}	0
F8	0.11	0.04	4.12×10^{-3}	9.25×10^{-3}	0	0	0	0

如表 2 所示结果可知,对于 5 个单峰基准测试函数测试中,CLSSA 各项数据都优于对比算法,尤其在 F1~F4 测试函数上,CLSSA 的各项测试结果均为 0,说明 CLSSA 优方面表现出了较高的优越性。在多峰测试函数中,CLSSA 的收敛平均值与标准差都略高于对比算法。说明 CLSSA 算法在寻优能力、跳出局部最优能力、稳定性上均优于对比算法。从图 2 可以看出,CLSSA 的函数收敛曲线下降很快,说明 CLSSA 具有更高的效率和更快的收敛

速度。

3.2 CLSSA-VMD 滑坡位移分解

传统的 VMD 分解参数大多是依据多次实验以及经验的确定,本文采用 CLSSA 对 VMD 进行参数寻优,在 SSA 算法中设置参数 k 参数范围为 $[2, 5]$,参数 α 范围为 $[0, 1000]$,种群规模 50,优化变量数目 2,最大迭代次数 20,最小包络熵来判断优化参数对数据的适应度。

寻优结果当 α 取 2, k 取 3,最小包络熵 4.259。将最优

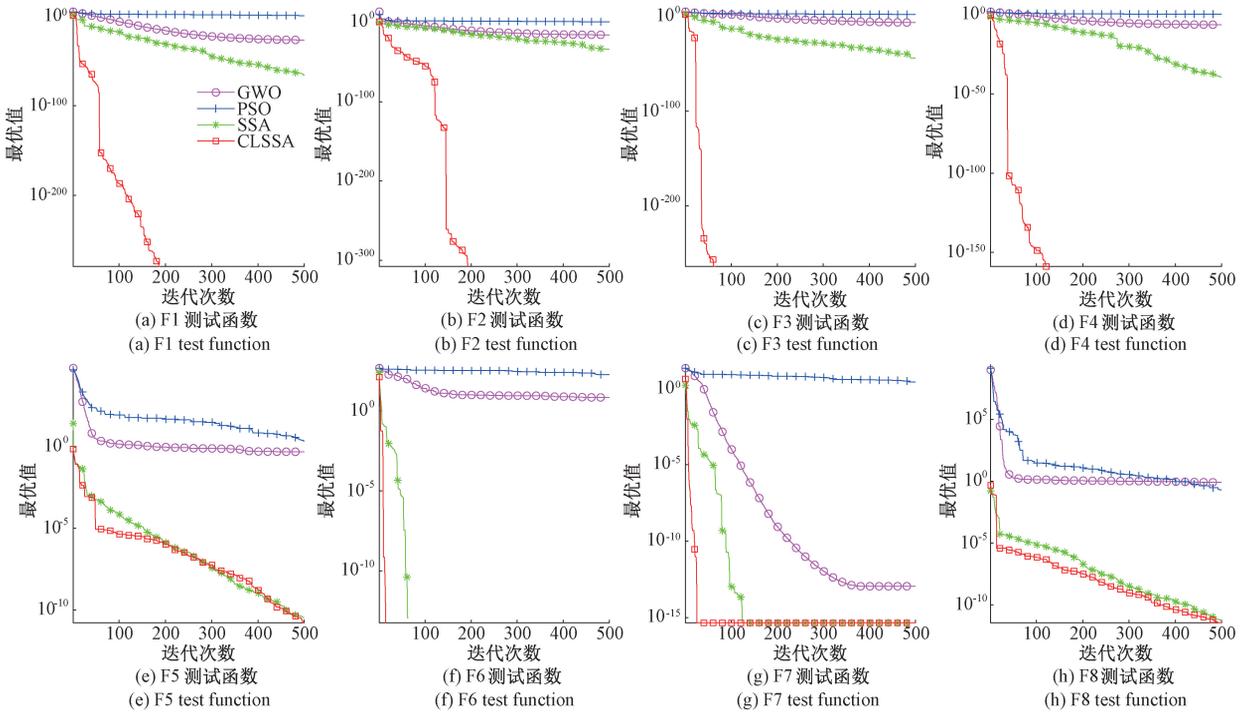


图 2 对比优化算法迭代效果图

Fig. 2 Compare and contrast the effect of optimization algorithm iterations

参数带入 VMD 对滑坡位移分解,分解结果如图 3 所示。由图 3 可知,IMF1 更趋向于滑坡位移变化,IMF2 比 IMF3 波动较小,更具有周期性,所以 IMF1 为趋势项,IMF2 为周期项,IMF3 为随机项。

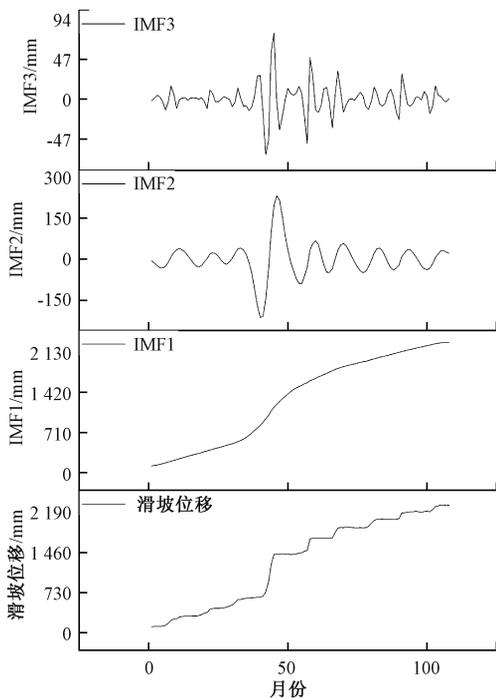


图 3 滑坡位移数据 VMD 分解图

Fig. 3 VMD decomposition of landslide displacement data

3.3 滑坡分量预测

1) 趋势项位移预测

趋势项是滑坡位移当前状态变化的主要反应,本文趋势项预测采用 SVR 单变量预测方法利用 CLSSA 对 SVR 参数寻优,设置参数 BoxConstraint 范围为 $[0.01, 30]$ 、KernelScale 范围为 $[0.01, 5]$ 和 Epsilon 范围为 $[0.01, 1]$ 。其中,BoxConstraint 优化参数为 5.10,KernelScale 优化参数为 1.64,Epsilon 优化参数为 0.216,预测结果如图 4 所示。其中, R^2 为 0.998 8,MAE 值为 0.668 mm, RMSE 值为 0.911 mm。

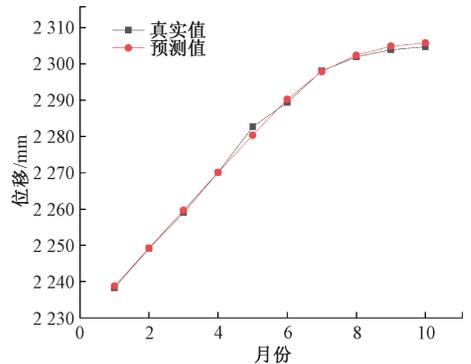


图 4 趋势项预测结果

Fig. 4 Trend term projection results

2) 周期项位移预测

为了提高模型的预测效果,本文对于周期项位移预测采用多输入单输出位移预测方法,考虑到白水河滑坡形变

的外部影响因素,主要包括降雨量和库水位两个面。雨水渗透进岩石裂缝和土壤孔隙,引起滑坡体地下水水位上升,使岩土软化,抗碱强度下降。库水位的周期性升降会导致坡体前缘的黏土发生吸水膨胀和失水收缩,从而影响抗剪强度和稳定性。这些影响是渐进而持续的过程。因此,本文考虑将影响因子划分为库水位、降雨量和滑坡演化状态 3 类。

针对库水位,选择库水位 W_1 , 库水位月间变化量 W_2 , 库水位两月变化量 W_3 作为候选影响因子。针对降雨量,则选择降雨 R_1 , 降雨月间变化 R_2 , 降雨两月间变化 R_3 作为候选影响因子。针对滑坡位移变化,选择前一个月位移变化 L_1 和前两个月位移变化 L_2 作为备选影响因子。为了筛选合适的影响因子作为输入变量,采用灰色关联度分析方法对这 3 类数据变量进行筛选,分辨系数取 0.5,若关联度值大于 0.6 时,则认为数据之间具有相关性,否则不具有相关性。如表 3 所示,除了候选影响因子 W_3 , 其余影响因子对于周期项位于关联度均大于 0.6,说明候选的影响因子大部分对于周期项位移有较紧密关联性。然而,考虑到相同类型的影响因子对周期项位移影响可能包含重复性和冗余性,本文将选择关联度大于 0.7 的影响因子作为输入变量。

表 3 周期项位移与影响因子关联度

Table 3 Periodic term displacement and impact factor correlation

编号	关联度	编号	关联度
W_1	0.68	R_1	0.79
W_2	0.68	R_2	0.79
W_3	0.52	R_3	0.68
L_1	0.89	L_2	0.91

采用 CLSSA-SVR 模型进行预测,根据表中关联度,分别选取前一个月位移变化 L_1 、前两个月位移变化 L_2 、降雨 R_1 和降雨月间变化 R_2 四种数据作为输入变量。根据 CLSSA 搜索优化算法对 SVR 模型进行参数优化,参数范围与趋势项相同,其中,BoxConstraint 优化参数为 4.91, KernelScale 优化参数为 0.91, Epsilon 优化参数为 0.078。其中,周期项预测结果 R^2 为 0.997, RMSE 为 1.33 mm, MAE 为 1.10 mm, 周期项预测效果如图 5 所示。

3) 随机项位移预测

随机项位移预测采用与周期项位移预测相同方法 CLSSA-SVR 模型进行预测,如表 4 所示,本文选取前一个月位移变化 L_1 、前两个月位移变化 L_2 、降雨 R_1 和降雨月间变化 R_2 四种数据作为输入变量。根据 CLSSA 搜索优化算法对 SVR 模型进行参数优化,BoxConstraint 优化参数为 11.92, KernelScale 优化参数为 1.14, Epsilon 优化参数为 0.176。得到的预测结果 R^2 为 0.938, RMSE 为 2.13 mm,

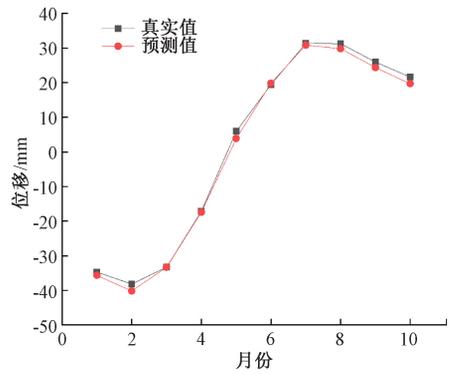


图 5 周期项位移预测结果

Fig. 5 Periodic term displacement prediction results

MAE 为 4.57 mm, 随机项预测效果如图 6 所示。

表 4 随机项位移与影响因子关联度

Table 4 Random term displacement and impact factor correlation

编号	关联度	编号	关联度
W_1	0.69	R_1	0.82
W_2	0.69	R_2	0.81
W_3	0.52	R_3	0.69
L_1	0.93	L_2	0.93

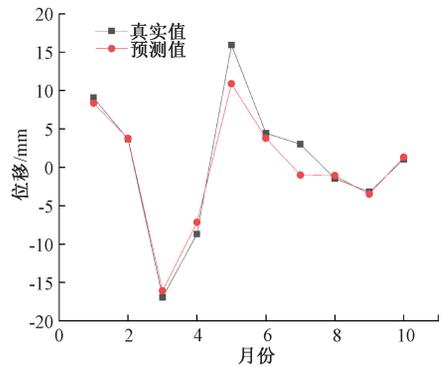


图 6 随机项位移预测结果

Fig. 6 Random term displacement prediction results

3.4 累计位移预测及模型预测对比

如图 7 所示,根据时间序列加法模型,将 VMD 分解的趋势项、周期项、随机项 3 组位移数据进行累加,最终得到 ZG111 的累计位移预测结果。其中, R^2 为 0.995, RMSE 为 3.37 mm, MAE 为 2.24 mm。经过实验分析可以得出,采用 CLSSA-VMD-SVR 模型预测在趋势项和周期项上预测精度有明显的提升,获得了较好的效果。

为了验证 CLSSA-VMD-SVR 滑坡位移预测模型的优越性,引用主流模型 SSA-VMD-SVR、平滑先验法 (smooth prior approach, SPA)-麻雀搜索算法-支持向量机回归模型 (SPA-SSA-SVR)^[15]、CTGWO-SVR、混合函数的模拟退火

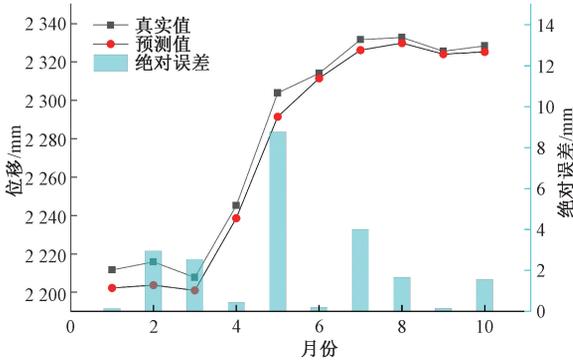


图 7 滑坡累计位移预测结果

Fig. 7 Cumulative landslide displacement prediction results

算法(simulated annealing, SA)-支持向量回归模型(SA-SVR)、ICEEMDAN-DBO-LSTM、CNN-BiLSTM-AM 进行对比实验,不同预测模型累计位移对比如图 8 所示,预测结果如表 5 所示。通过性能指标对比可以看出本文模型在滑坡预测性能上要优于对比模型,其原因在于采用优化算法优化 VMD 分解函数可以更彻底地分解滑坡位移,有效避免模态混叠、过包络、欠包络以及边界效应等问题^[16]。

表 5 不同模型累计位移预测结果

Table 5 Cumulative displacement prediction results of different models

模型类型	RMSE/ mm	MAE/ mm	R ²
CLSSA-VMD-SVR	3.37	2.24	0.995
SSA-VMD-SVR	9.60	8.31	0.965
SPA-SSA-SVR	4.21	2.82	0.993
CTGWO-SVR	4.97	3.67	0.990
SA-SVR	4.78	4.05	0.991
ICEEMDAN-DBO-LSTM	4.85	4.05	0.987
CNN-BiLSTM-AM	6.86	5.79	0.982

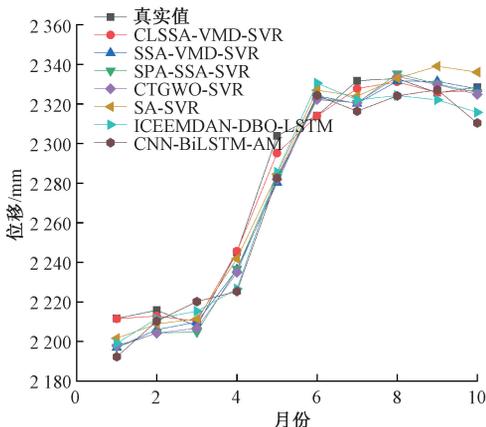


图 8 不同预测模型累计位移对比

Fig. 8 Comparison of cumulative displacements of different prediction models

4 模型适用性验证

为了进一步验证模型在不同监测点的适用性,本文选用与白水河类型相同的八字门滑坡区域的 ZG111 监测点自 2007 年 1 月至 2011 年 12 月的监测数据进行验证分析。ZG111 监测点预测结果如图 9 所示。通过计算 R² 为 0.998, RMSE 为 4.13 mm, MAE 为 3.86 mm,可以看出本模型对不同区域滑坡具有良好的适用性。

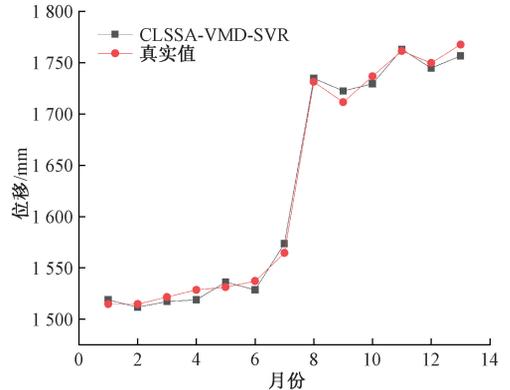


图 9 ZG111 监测点累计位移预测结果

Fig. 9 Cumulative displacement predictions for monitoring point ZG111

5 结 论

本文提出了基于 Lévy 飞行机制的改进混沌麻雀搜索算法解决了传统麻雀搜索算法中种群多样性不足、容易陷入局部最优的问题,并结合 SVR 模型应用在滑坡位移预测领域,提出了 CLSSA-VMD-SVR 模型,有效解决了采用传统单一模型难以对滑坡总体趋势难以预测的问题。在白水河滑坡监测点 Z118 点的实验验证中,研究成果表明:改进的混沌麻雀优化算法在模型参数的全局寻优和跳出局部最优方面表现卓越;基于 CLSSA-VMD 的数据预处理技术实现了滑坡位移信号的深度分解,成功解决了模态混叠、过包络、欠包络及边界效应等问题,显著提升了预测精度。针对滑坡位移数据的非平稳性、周期性和趋势性问题,提出的 CLSSA-VMD-SVR 模型在预测准确性和可靠性上远超传统 SVR 模型,充分展现出广泛的应用前景。但本文对滑坡机理及其多样化影响因子的研究相对有限,后续可以考虑滑坡演变机制和各种因素对滑坡的影响,针对特定地区设定预测模型,进一步提升预测模型的时空适应性及推演能力。

参考文献

[1] 许强,彭大雷,何朝阳,等. 突发型黄土滑坡监测预警理论方法研究——以甘肃黑方台为例[J]. 工程地质学报, 2020, 28(1): 111-121.
XU Q, PENG D L, HE CH Y, et al. Research on the theory and method of monitoring and early warning of

- sudden loess landslide—taking Heifangtai in Gansu as an example [J]. *Journal of Engineering Geology*, 2020, 28(1): 111-121.
- [2] 尚敏,熊德兵,张惠强,等. 基于时间序列与混合核函数 SA-SVR 的滑坡位移预测模型研究[J]. *工程地质学报*, 2022, 30(2): 575-588.
SHANG M, XIONG D B, ZHANG H Q, et al. Research on landslide displacement prediction model based on time series and hybrid kernel function SA-SVR [J]. *Journal of Engineering Geology*, 2022, 30(2): 575-588.
- [3] 杨进昆,党建武,杨景玉,等. 基于时序分析及 CNN-BiLSTM-AM 的阶跃型滑坡位移预测[J]. *国外电子测量技术*, 2024, 43(1): 126-134.
YANG J K, DANG J W, YANG J Y, et al. Step-type landslide displacement prediction based on time series analysis and CNN-BiLSTM-AM [J]. *Foreign Electronic Measurement Technology*, 2024, 43(1): 126-134.
- [4] LIN Z AN, SUN X Y, JI Y F. Landslide displacement prediction model using time series analysis method and modified LSTM model [J]. *Electronics*, 2022, 11(10): 1519.
- [5] 封青青,李丽敏,陈飞阳,等. 基于 ICEEMDAN 分解与 SE 重构和 DBO-LSTM 的滑坡位移预测[J]. *电子测量技术*, 2024, 47(7): 80-87.
FENG Q Q, LI L M, CHEN F Y, et al. Landslide displacement prediction based on ICEEMDAN decomposition with SE reconstruction and DBO-LSTM[J]. *Electronic Measurement Technology*, 2024, 47(7): 80-87.
- [6] 任帅,纪元法,孙希延,等. 基于改进灰狼优化与支持向量回归的滑坡位移预测[J]. *计算机应用*, 2024, 44(3): 972-982.
REN SH, JI Y F, SUN X Y, et al. Landslide displacement prediction based on improved gray wolf optimization and support vector regression [J]. *Computer Applications*, 2024, 44(3): 972-982.
- [7] WEN H J, XIAO J F, XIANG X K, et al. Singular spectrum analysis-based hybrid PSO-GSA-SVR model for predicting displacement of step-like landslides: A case of Jiuxianping landslide[J]. *Acta Geotechnica: An International Journal for Geoengineering*, 2024, 19(4): 1835-1852.
- [8] 姜宇航,王伟,邹丽芳,等. 基于粒子群-变分模态分解、非线性自回归神经网络与门控循环单元的滑坡位移动态预测模型研究[J]. *岩土力学*, 2022, 43(S1): 601-612.
JIANG Y H, WANG W, ZOU L F, et al. Research on dynamic prediction model of landslide displacement based on particle swarm-variational modal decomposition, nonlinear autoregressive neural network and gated recurrent unit[J]. *Geotechnics*, 2022, 43(S1): 601-612.
- [9] 王秀杰,王玲,滕振敏,等. VMD-PSO-LSTM 模型的日径流多步预测[J]. *水利水运工程学报*, 2023(4): 81-90.
WANG X J, WANG L, TENG ZH M, et al. Multi-step prediction of daily runoff by VMD-PSO-LSTM model[J]. *Journal of Water Resources and Water Transportation Engineering*, 2023(4): 81-90.
- [10] 杨旭,张涛,李玉梅,等. ISSA 优化 SVM 的电机滚动轴承故障诊断[J]. *电子测量技术*, 2023, 46(15): 186-192.
YANG X, ZHANG T, LI Y M, et al. ISSA optimized SVM for rolling bearing fault diagnosis in electric machines [J]. *Electronic Measurement Technology*, 2023, 46(15): 186-192.
- [11] 陈建东,聂斌,雷银香,等. 多策略增强型麻雀搜索算法[J]. *现代信息科技*, 2023, 7(13): 39-45, 52.
CHEN J D, NIE B, LEI Y X, et al. Multi-strategy enhanced sparrow search algorithm [J]. *Modern Information Technology*, 2023, 7(13): 39-45, 52.
- [12] 柴岩,孙笑笑,任生. 融合多向学习的混沌麻雀搜索算法[J]. *计算机工程与应用*, 2023, 59(6): 81-91.
CHAI Y, SUN X X, REN SH. A chaotic sparrow search algorithm incorporating multidirectional learning[J]. *Computer Engineering and Applications*, 2023, 59(6): 81-91.
- [13] 毛清华,张强,毛承成,等. 混合正弦余弦算法和 Lévy 飞行的麻雀算法[J]. *山西大学学报(自然科学版)*, 2021, 44(6): 1086-1091.
MAO Q H, ZHANG Q, MAO CH CH, et al. Hybrid sine-cosine algorithm and sparrow algorithm for Lévy flight [J]. *Journal of Shanxi University (Natural Science Edition)*, 2021, 44(6): 1086-1091.
- [14] 陈伟,杨盘隆,吴宣够. 改进蚁狮优化算法及其工程应用[J]. *传感技术学报*, 2023, 36(4): 565-574.
CHEN W, YANG P L, WU X G. Improved ant-lion optimization algorithm and its engineering applications[J]. *Journal of Sensing Technology*, 2023, 36(4): 565-574.
- [15] 杨玲,魏静,许子伏. 基于平滑先验法-麻雀搜索算法-支持向量机回归模型的滑坡位移预测——以三峡库区八字门和白水河滑坡为例[J]. *地球科学与环境学报*, 2022, 44(6): 1096-1110.
YANG L, WEI J, XU Z F. Landslide displacement prediction based on smoothing a priori method-sparrow search algorithm-support vector machine regression modeling-taking the Bazimen and Baishui River landslides in Three Gorges Reservoir Area as an example [J]. *Journal of Earth Science and Environment*, 2022, 44(6): 1096-1110.
- [16] GAO Y P, CHEN X, TU R, et al. Prediction of landslide displacement based on the combined VMD-Stacked LSTM-TAR model [J]. *Remote Sensing*, 2022, 14(5): 1164.

作者简介

黄奕朝, 硕士研究生, 主要研究方向为北斗高精度滑坡监测与预测预警。

E-mail: 294220361@qq.com

孙希延(通信作者), 研究员, 博士生导师, 主要研究方向为卫星导航定位及信号处理。

纪元法, 教授, 博士生导师, 主要研究方向为卫星导航与信息处理。

卢伟萍, 硕士, 高级工程师, 主要研究方向为短时强降水预报及降水机理分析。