

基于 EMD 分解和改进 GWO-BP 神经网络的 滑坡位移预测

陈显刚, 郑 剑, 马庆福, 张平生, 郭兴隆, 张 亭
(云南磷化集团有限公司, 昆明 650600)

摘 要:考虑到滑坡位移受多因素的影响,结合信号分解与智能算法,提出了一种时序分解—模型构建—模型训练的 EMD-BP-TIGWO 滑坡位移预测方法。首先,利用 EMD 方法将滑坡监测数据分解为多个 IMF 分量及一个残余量,将分解后的分量划分为周期项及趋势项位移;其次,构建 BP-TIGWO 模型,引入 Tent 映射及自适应权重,提高灰狼算法的收敛速度及全局搜索能力,并利用 TIGWO 算法优化 BP 神经网络的权值及阈值;利用 Pearson 相关系数对周期项滑坡位移与降雨量间的时滞期数进行分析,利用优化后的 BP 模型分别对周期及趋势项滑坡位移进行预测;最后,将各分量预测值进行叠加得到滑坡累计位移预测值,并对模型预测准确率进行评价。实验结果表明,EMD-BP-TIGWO 模型在考虑降雨输入特征下,连续 32 d 预测的 RMSE、MAE 及 R^2 分别为 0.64、0.51 及 0.97,模型预测精度明显高于未考虑时滞的 EMD-GWO-BP、EMD-GWO-BP、BP-TIGWO、BP 模型的预测精度,可为预测滑坡的位移提供参考。

关键词:滑坡;模态分解;BP 神经网络;改进灰狼优化算法;时间序列

中图分类号:P642.2

文献标志码:A

文章编号:1671-4172(2024)03-0125-09

Landslide displacement prediction based on EMD decomposition and improved GWO-BP neural network

CHEN Xiangang, ZHENG Jian, MA Qingfu, ZHANG Pingsheng, GUO Xinglong, ZHANG Ting
(Yunnan Phosphate Group Co., Ltd., Kunming 650600, China)

Abstract: Considering that the landslide displacement is influenced by multiple factors, a time series decomposition-model construction-model training method of EMD-BP-TIGWO landslide displacement prediction is proposed by combining signal decomposition and intelligent algorithms. Firstly, the landslide monitoring data are decomposed into multiple IMF components and a residual using the EMD method, and the decomposed components are divided into period term and trend term displacements; secondly, the BPTIGWO model is constructed, the Tent mapping and adaptive weights are introduced to improve the convergence speed and global search capability of the whale algorithm, and the weights and thresholds of BP neural network are optimized using the TIGWO algorithm; subsequently, the optimized BP-TIGWO model is used to predict the landslide displacement using the optimized BP neural network and the TIGWO algorithm. Subsequently, the optimized BP model was used to output the predicted values, and finally, the predicted values of each component were superimposed to obtain the predicted values of landslide cumulative displacement, and the model prediction accuracy was evaluated. The experimental results show that the RMSE, MAE and R^2 of the EMD-BP-TIGWO model are 0.64, 0.51, and 0.97 respectively, under the feature of no rainfall input for 1 d. The prediction accuracy of the model is significantly higher than that of the EMD-GWO-BP, EMD-GWO-BP, BP-TIGWO, and BP models that do not consider the time lag, which can provide a reference for predicting the displacement of the landslide.

Key words: landslide; mode decomposition; BP neural network; improving the gray wolf optimization algorithm; time series

滑坡一旦发生,不仅会对周边地区人员的生命安全造成巨大的危害,还会造成较大的财产损失^[1]。滑坡受自身地质条件与降雨等因素的影响,其位移随时间的变化而变化,通过滑坡监测数据能较为直观地判断滑坡的变形破坏趋势^[2-3]。因此,通过分析滑坡监测数据建立滑坡位移预测模型对减少滑坡灾害发生后造成的财产损失有重要意义。针对滑坡位移预测,常用的方法是将滑坡总位移分解为趋势项与周期项位移,构建不同的模型对各分量进行预测,将预测结果叠加得到累计滑坡位移。

随着数据挖掘与机器学习的快速发展,许多学者将智能算法运用于滑坡位移预测中,如杨勇等^[4]结合随机权重法及惯性权重因子对 PSO 算法进行优化,并利用优化后的 PSO 算法及 ELM 建立 IP-PSO-ELM 边坡稳定性预测模型;马增等^[5]针对边坡位移增量的随机波动性,结合叠加马尔科夫链方法建立了边坡位移预测模型;孙晓云等^[6]利用 VMD 方法将边坡监测数据分解为一系列子序列,并建立 BSA-KELM 边坡位移预测模型,取得了较好的预测效果。BP 神经网络具有结构简单、参数设置少等优点,已广泛运用于多领域,但 BP 神经网络的初始权重和偏置是随机产生的,易使模型出现收敛速度慢、陷入局部最小值等问题。许多学者运用粒子群算法^[7]、遗传算法^[8]、灰狼算法^[9]等算法来为模型设置适当的参数值以提高模型的预测精度。灰狼算法(GWO)易出现收敛精度低、陷入局部最优值等问题^[10],因此本文引用改进后的灰狼优化算法对 BP 神经网络的权值及阈值进行优化。基于此,本文尝试建立 EMD-BP-TIGWO 滑坡位移预测模型。首先,基于 EMD 从滑坡位移监测数据中提取出趋势项和周期项位移;其次,引入 Tent 映射及自适应权重的灰狼优化算法对 BP 网络模型进行优化,对 BP 网络模型的权值及阈值进行取值,考虑到降雨对周期项位移的影响,将降雨因素作为输入特征,利用优化后的 BP 模型分别对趋势项及周期项位移进行预测;最后,将两者预测结果叠加便为滑坡累计位移预测结果,并通过 RMSE、MAE 及 R^2 对模型的预测精度进行评价。

1 BP 神经网络方法

1.1 EMD 法

可利用 EMD 方法将滑坡位移分解为周期项及趋势项,如式(1)。趋势项可反映滑坡在内部因素条件影响下位移的变化,呈现近似单调增函数;周期项

可反映滑坡受外部因素影响时位移随时间的变化,通常呈现近似周期性变化^[11]。

$$Y(t) = p(t) + q(t) \quad (1)$$

式中, $Y(t)$ 为累计位移, $p(t)$ 为趋势项位移, $q(t)$ 为周期项位移。

经验模态分解(EMD)是一种自适应信号分解方法,能够将滑坡位移信号分解成一系列固有模态函数(IMFs)及一个残差分量(res)^[12]。其分解过程如下:

1)找出滑坡位移信号 $x(t)$ 的所有极值点,利用三次样条曲线分别连接极大值点与极小值点,形成上下包络线,并计算其均值 n_1 :

$$n_1 = \frac{x_{\min}(t) + x_{\max}(t)}{2} \quad (2)$$

2)原始信号减去均值,得到新信号 $h(t)$:

$$h(t) = x(t) - n_1 \quad (3)$$

3)判断 $h(t)$ 的极值点与零点的个数是否相等(或相差 1 个)及上下包络线是否关于时间轴对称,若不满足,则重复以上步骤,直至 $h(t)$ 满足条件;反之, $h(t)$ 可视为 IMF_1 ,可得到 IMF_1 :

$$IMF_1 = X(t) - h(t) \quad (4)$$

4)重复以上步骤,当不能再提取满足 $y_k = y_{k,\max} + x_k(y_{k,\max} - y_{k,\min})$ 分量时,则停止分解,原始信号可表示为:

$$x_t = \sum_{i=1}^n IMF_i + res \quad (5)$$

其中, res 为残余量。

1.2 BP 神经网络

BP 神经网络由输入层、隐含层及输出层组成。各层之间存在连接权重和偏置,其工作原理为:对输出数据与期望输出数据给定一个误差值,输入层输入数据,经过隐含层、输出层输出数据,若输出数据与给定预期值间的差值大于给定的误差值,输出层产生误差信号,沿最初的连接通道反向传播,通过误差信号的反馈来调整各神经元的连接权值和偏置,使输出值不断接近期望值,直至误差达到最小,则输出数据^[13-14]。

根据输入输出数据确定神经网络的隐函层节点数 h ,通常按照式(6)确定隐含层节点个数。各连接层间常用的激活函数为 Sigmoid 函数,如式(7)。

$$h = \sqrt{m+n} + b \quad (6)$$

式中: b 为 1~10 之间的常数。

$$y = \frac{1}{1 + e^{-x}} \quad (7)$$

1.3 灰狼算法(Grey Wolf Optimizer, GWO)

GWO 是由 MIRJALILI 通过观察自然界中灰狼种群捕食的行为和狼群等级制度而提出的。狼群一共分为 4 个等级。第一等级称为 α 狼, 负责对狼群的捕食对象以及栖息地等选择做决策; 第二等级称为 β 狼, 负责协助 α 狼管理狼群, 做出捕食行动安排; 第三等级称为 ω 狼, 负责狩猎和侦查猎物工作, 其中, α 狼、 β 狼及 ω 狼均为领导者, 且数量均为一只; 第四等级为 g 狼, 有多只, 需要服从且遵守 α 狼、 β 狼及 ω 狼的命令, 灰狼种群只有严格遵守前三条命令, 捕食任务才能顺利完成, 灰狼所处等级越高, 则证明捕食的概率越大^[15-16]。灰狼捕食的过程如下:

1) 搜索猎物。在 D 维搜索空间内, 假设 n 只灰狼构成灰狼种群 X , 种群中第 X 只狼的位置为 $X = (X_1, X_2, \dots, X_n)$, 狼群发现猎物时, 对其进行包围, 其数学模型可表示为:

$$A = |C \cdot X_k(t) - X(t)| \quad (8)$$

$$X(t+1) = X_k(t) - B \cdot A \quad (9)$$

$$B = 2a(r_1 - 1) \quad (10)$$

$$C = 2r_2 \quad (11)$$

$$a = 2 - 2 \cdot \frac{t}{t_{\max}} \quad (12)$$

式中, A 为个体与猎物间的距离; t 为当前迭代次数; $X_k(t)$ 为经过 t 次迭代后猎物的位置; $X(t)$ 为灰狼个体经过 t 次迭代后的位置; B 为收敛因子; C 为摆动因子; r_1 、 r_2 为 $[0, 1]$ 间的随机数; a 为距离控制参数, 从 2 线性递减至 0。

2) 狩猎猎物。确定捕食位置后, α 狼对狼群进行指挥, β 狼及 ω 狼负责辅助工作, ω 狼进行狩猎行动。在此行动中, α 狼、 β 狼及 ω 狼负责指挥 g 狼, 逐渐对猎物逼近, 狼群的数学模型可表示为:

$$A_\alpha = |C_1 \cdot X_\alpha(t) - X(t)| \quad (13)$$

$$A_\beta = |C_1 \cdot X_\beta(t) - X(t)| \quad (14)$$

$$A_\omega = |C_1 \cdot X_\omega(t) - X(t)| \quad (15)$$

$$X_1(t+1) = X_\alpha(t) - B_1 A_\alpha \quad (16)$$

$$X_2(t+1) = X_\beta(t) - B_2 A_\beta \quad (17)$$

$$X_3(t+1) = X_\omega(t) - B_2 A_\omega \quad (18)$$

$$X(t+1) = \frac{X_1(t+1) + X_2(t+1) + X_3(t+1)}{3} \quad (19)$$

式中, B_1 、 B_2 及 B_3 分别为 α 、 β 及 ω 的系数向量; $X_\alpha(t)$ 、 $X_\beta(t)$ 及 $X_\omega(t)$ 分别表示 α 、 β 及 ω 与猎物间的距离; $X_1(t+1)$ 、 $X_2(t+1)$ 及 $X_3(t+1)$ 分别为灰狼个体经过 $(t+1)$ 次迭代后的空间位置;

$X(t+1)$ 为狼在 α 、 β 及 ω 狼指挥下经过 $(t+1)$ 次迭代后的空间位置。

3) 捕食猎物。灰狼捕食猎物时的具体方位主要由 $|A|$ 决定。 $|A| \geq 1$ 时, 则当前位置并不是最佳捕猎位置, 灰狼离开猎物, 进行全局搜索, 寻找全局最优解; $|A| < 1$ 时, 灰狼所处位置是捕猎的合适位置, 灰狼种群进行局部搜索, 开展捕食行动。

GWO 具有原理简单、需调参数少、结构简单等优点, 但在求解复杂问题时易出现收敛精度低、陷入局部最优值等问题。因此, 本文引入 Tent 映射与惯性权重方法来增强灰狼种群的全局搜索能力并提高该算法的收敛能力。

1.4 改进灰狼算法

1.4.1 Tent 映射

GWO 初始种群的位置对于灰狼种群找到最佳捕食位置有着较大的影响。混沌现象指在某个确定的系统中, 存在着一些不可重复的、不可预测的、随机的变量, 具有非周期性、有界性和遍历性等特点, 能更高效地对搜索空间进行全面搜索^[17]。Tent 映射具有较好的遍历性及收敛速度, 因此引入 Tent 混沌映射对最初灰狼种群位置进行优化, 增强灰狼种群的全局搜索能力。其表达式为:

$$x_{k+1} = \begin{cases} 2x_k, & 0 \leq x \leq \frac{1}{2} \\ 2(1-x_k), & \frac{1}{2} < x \leq 1 \end{cases} \quad (20)$$

式中: k 为种群个数, 对混沌序列进行逆映射, 便得到灰狼种群个体的位置序列 y_k , 如式(21)。

$$y_k = y_{k, \max} + X_k(y_{k, \max} - y_{k, \min}) \quad (21)$$

式中: $y_{k, \max}$ 及 $y_{k, \min}$ 分别为灰狼种群初始位置序列的最大值与最小值。

1.4.2 惯性权重因子

在灰狼种群狩猎阶段, 若 α 狼、 β 狼及 ω 狼的权重因子较大, 会使得 g 狼全局搜索的范围增大, 在觅食后期, 若 α 狼、 β 狼及 ω 狼的权重因子较小, 则会使局部范围搜索能力变大。惯性权重值较小时, 灰狼的局部搜索能力变强, 反之, 灰狼的全局搜索能力变弱, 因此, 在灰狼局部寻优初期设置较大的权值, 在灰狼全局寻优时设置较小的权值, 以此提高灰狼种群的全局搜索能力^[18]。引入惯性权重因子的公式为:

$$\omega = \omega_{\max} - \left(\frac{t}{T_{\max}}\right) \cdot (\omega_{\max} - \omega_{\min}) \quad (22)$$

其中, $\omega_{\min}$ 和 $\omega_{\max}$ 分别为惯性权重的最小、最大值, $t_{\max}$ 为最大迭代次数, t 为当前迭代次数。

因此, ω 狼在捕食猎物阶段的位置更新公式为:

$$X(t+1) = \omega \cdot \frac{X_1(t+1) + X_2(t+1) + X_3(t+1)}{3} \quad (23)$$

1.5 EMD 与改进 BP 神经网络预测模型

本文基于 EMD-BP-TIGWO 模型的边坡位移预测主要步骤如图 1 所示:




图 1 EMD-BP-TIGWO 模型流程图

Fig. 1 Flow Chart of the EMD-BP-TIGWO model

1) 利用 EMD 将滑坡位移监测数据分解为多个 IMF 和一个 res 残余量, 将分解后的 IMF 分量及残余量分为趋势项位移及周期项位移, 并对数据进行归一化处理, 避免数据量纲的复杂性对模型的预测精度造成影响, 并将其按 8 : 2 的比例划分, 作为 TIGWO-BP 模型的训练集及测试集数据。

2) 确立 BP 网络的输入层 m 、隐含层 h 及输出层 n 节点个数, 随机对初始阈值及权值进行赋值, 选择 Sigmoid 为各连接层间的激活函数, 设置网络学习速率 $\alpha = 0.01$, 最大迭代次数为 1 000, 目标训练误差为 0.000 1。

3) 利用 Tent 映射对灰狼种群初始位置进行映射, 设置惯性权重值 $\omega_{\min}$ 和 $\omega_{\max}$ 的值分别为 0.1 及 1, 设置灰狼种群的初始种群规模及最大迭代次数, 优化参数个数及优化参数上下限, 计算每只灰狼的适应度值, 找出 α 狼、 β 狼及 ω 狼当前最优的适应度

值及其位置, 更新式(22)计算出惯性权重因子 ω 的值, 计算出参数 B 和 C 的值并更新每个等级灰狼个体位置。

4) 判断算法是否达到最大迭代次数, 若达到, 则输出 BP 神经网络权值及阈值, 反之, 返回步骤 3。

5) 将趋势项及周期项各分量数据划分为训练集及测试集, 使用 BP-TIGWO 模型对各分量的训练集进行训练, 将各分量预测结果叠加得到累计滑坡位移预测结果。

2 滑坡位移预测实例分析

2.1 工程概况

某露天矿山采场标高为 1 030~1 390 m, 采场靠帮边坡最大达到了 290 m, 于 2021 年 12 月出现局部滑坡的情况。为监测滑坡的变化情况, 该矿山于 2022 年 1 月初采用智能全站仪对滑坡进行监测, 共布设了 6 个监测点 (PT1—PT6), 以全站仪监测

系统获取的 2022 年 2 月 2 日至 2022 年 11 月 23 日共 295 d 的监测数据及降雨量数据对该边坡的位移进行分析,如图 2 所示。




图 2 滑坡累计位移曲线图

Fig. 2 Accumulative monitoring displacement of landslide

从图 2 可以看出,7 月至 10 月为雨季,降雨量较多,所有监测点累计位移出现增大。其中,监测点 PT5 的累计总位移变化最大,最大累计位移变化量达到了 306 mm,因此本文对监测点 PT5 获取的监测数据做详细分析。

2.2 滑坡位移时间序列的 EMD 分解

运用 MatlabR2021b 软件编程,对 295 d 监测数据进行 EMD 分解,设置白噪声幅值为 0.2,最大迭代次数为 600,对监测数据进行分解,得到 5 个 IMF 和 1 个 *res* 分量,如图 3 所示。从图 3 中可以看出,*res* 变化趋势平缓,呈单调增加趋势,因此可将其作为趋势项位移。*IMF1*—*IMF5* 为频率各不相同的 5 个位移序列分量,将 5 个分量叠加得到滑坡的周期项位移,对原始数据样本进行数据重构,重构后的时间序列滑坡位移如图 4 所示。




图 3 EMD 分解后的滑坡位移序列图

Fig. 3 Landslide displacement diagram of EMD decomposition




图 4 重构后的滑坡位移序列图

Fig. 4 Reconstructed landslide displacement diagram

2.3 基于 BP-TIGWO 模型的滑坡位移预测

2.3.1 BP-TIGWO 网络的建立

设 BP 网络学习速率 $\alpha = 0.01$, 最大迭代次数为 1 000, 目标训练误差为 0.000 1, 设置 GWO 的初

始灰狼种群数量为 40, 最大迭代次数为 90, 需要优化参数 δ 、 φ 两个变量, 分别设置参数上下限为 2、-2; 自适应权重 $\omega_{\min} = 0$, $\omega_{\max} = 1$ 。

为确立模型的 m 、 n 及 h , 分别将 md 位移及 nd 位移作为模型的输入层及输出层节点, 采用滚动预测法来进行预测, 即运用 md 的滑坡位移对 nd 的滑坡位移进行预测。如, $m = 2$ 时, 表示输入变量为 2 d 的位移数据, 为确立模型的输入层及输出层节点数, 取 $m = 29 \sim 31$, $n = 1 \sim 2$, 根据式(6)取 h 初始值为 7, 取 $h = 7 \sim 10$ 将未分解的原始数据代入模型中, 分别计算不同 m 、 n 及 h 取值时 BP 神经网络的均方误差(MSE), 以最小均方差确定最模型的 m 、 n 及 h , 见表 1。

由表 1 可知, 当 m 为 30、 n 为 1、 h 为 9 时, 模型的均方误差为 0.000 110 8, 为所有模型中最小的, 因此确定模型的 m 、 n 、 h 分别为 30、1、9。

表 1 不同输入层、输出层节点数对应的均方误差

Table 1 Mean square error corresponding to different number of nodes in input and output layers

输入层节点	隐含层节点	输出层节点	均方误差	输入层节点	隐含层节点	输出层节点	均方误差
29	7	1	0.000 128 8	29	7	2	0.000 197 5
29	8	1	0.000 120 3	29	8	2	0.000 180 4
29	9	1	0.000 137 2	29	9	2	0.000 185 6
29	10	1	0.000 165 3	29	10	2	0.000 171 9
30	7	1	0.000 116 9	30	7	2	0.000 168 8
30	8	1	0.000 143 1	30	8	2	0.000 121 2
30	9	1	0.000 110 8	30	9	2	0.000 172 1
30	10	1	0.000 120 7	30	10	2	0.000 172 5
31	7	1	0.000 122 2	31	7	2	0.000 255 9
31	8	1	0.000 181 8	31	8	2	0.000 198 3
31	9	1	0.000 134 6	31	9	2	0.000 210 6
31	10	1	0.000 111 4	31	10	2	0.000 136 6

2.3.2 趋势项位移预测

趋势项位移受滑坡自身因素的影响, 能反映滑坡变形的主要趋势。使用 BP-TIGWO 模型对其进行预测, 结果如图 5, 预测精度 R^2 达到了 0.98。

2.3.3 周期项位移预测

周期项位移影响因子的选取是周期位移预测的关键, 研究表明, 降雨量是周期位移的主要影响因素。当雨水经过滑坡体并向其内部渗透时, 滑坡体内的含水量及孔隙水压力逐渐增大, 滑坡体被雨水浸湿, 重量增大, 在重力及雨水浸润的影响下, 滑坡体的抗滑阻力降低, 滑坡体失稳的概率增大; 但降雨量渗透进入岩体的过程并不是实时的, 过程较为缓慢, 具有时间滞后效应。

为了提高周期项位移预测模型的预测精度, 设置不同的时滞期数, 采用 Pearson 相关系数(如式




图 5 趋势项位移预测值与实际值对比

Fig. 5 Comparison of predicted and actual trend term displacements

(24))对不同时滞期数的降雨与周期位移之间的相关性进行计算, 通过比较不同值的大小, 确定最大时

滞期数,并将其作为周期项输入因素。

$$r = \frac{\sqrt{\sum_{i=1}^m (X_i - \bar{X}) \sum_{i=1}^m (Y_i - \bar{Y})}}{\sqrt{\sum_{i=1}^m (X_i - \bar{X})^2 \sum_{i=1}^m (Y_i - \bar{Y})^2}} \quad (24)$$

式中, X 、 Y 为计算相关系数的两个序列; $\bar{X}$ 、 $\bar{Y}$ 为各序列均值; r 为 Pearson 相关系数,其值越大,则证明两序列间相关性越强;当 $\|r\| \geq 0.6$ 时,两序列为高度相关;当 $0.4 \leq \|r\| < 0.6$ 时,两序列呈中度相关; $\|r\| < 0.4$ 时,两序列呈弱相关。分别取时滞期为 0.2, 28~33 d,对其 Pearson 相关系数进行计算,计算结果如表 2 所示。

表 2 降雨-周期位移 Pearson 相关系数

Table 2 Pearson correlation coefficients for rainfall-cycle displacement

滞后时间/d	相关系数	滞后时间/d	相关系数
0	0.004 6	2	0.018 5
28	0.153 2	29	0.157 7
30	0.164 2	31	0.170 1
32	0.174 5	33	0.172 0

从表 2 可以看出,降雨量与周期位移间的 Pearson 系数均小于 0.4,两者之间呈弱相关性,当时滞期数为 32 d 时, r 值为 0.174 5,为所有 r 中最大的,此时,降雨量与周期位移间的变化最相关。

将周期项位移及降雨量数据按 8:2 的比例划分为训练集及测试集,经因果分析得到,当降雨量的时滞为 32 d 时,其与周期位移间的 Pearson 系数达到最大;当 BP 模型的 m 为 30、 h 为 9、 n 为 1 时,模型的 MSE 最小,因此本文选取前 32 d 的降雨量及前 30 d 的周期位移作为输入变量,预测后 1 d 的周期位移;为了验证考虑时滞效应周期位移模型预测的有效性,本文同时建立了未考虑时滞效应的 EMD-TIGWO-BP 模型、EMD-BP 模型、EMD-GWO-BP 模型及 BP 模型对滑坡位移进行预测,对比分析模型周期位移的预测效果,如图 6 所示,各模型预测精度评价指标见表 3。

表 3 周期位移预测模型评估

Table 3 Evaluation of Cyclic Displacement Prediction Models

模型名称	RMSE	MAE	R^2
EMD-BP	2.04	1.55	0.84
EMD-GWO-BP	1.32	1.01	0.88
EMD-TIGWO-BP	1.54	1.20	0.91
EMD-TIGWO-BP(考虑时滞)	0.64	0.51	0.96




图 6 周期项位移预测值与实际值对比

Fig. 6 Comparison of predicted and actual periodic term displacements

由表 3 及图 6 可知,在考虑时滞输入特征情况下,模型的预测精度最好, RMSE、MAE 及 R^2 分别为 0.64、0.51 及 0.96,其评价指标均优于未考虑降雨输入特征的所有模型,可认为考虑降雨输入特征能更好地对周期项及滑坡累计位移进行预测。考虑时滞效应的 EMD-TIGWO-BP 模型预测的精度比未考虑时滞的 EMD-BP、EMD-GWO-BP、EMD-TIGWO-BP 模型的预测精度都高。未考虑时滞的 EMD-GWO-BP 模型较 EMD-BP 模型的均方根误差(RMSE)及平均绝对误差(MAE)值分别提高了 0.72 及 0.54,说明引入 GWO 算法对 BP 算法进行优化可提高 BP 模型的预测精度;未考虑时滞的 EMD-TIGWO-BP 模型较 EMD-GWO-BP 模型的 RMSE 及 MAE 分别提高了 0.22 及 0.19,说明引入 Tent 映射及惯性权重因子对 GWO 算法优化能提高 GWO 算法的全局搜索能力;考虑时滞 EMD-TIGWO-BP 模型的均方根误差值(RMSE)及平均绝对误差(MAE)值分别较未考虑时滞的 EMD-TIGWO-BP 分别提高了 0.9 及 0.69,其模型的 R^2 最大,说明考虑降雨与周期位移间时滞效应能提高模型的预测精度,也说明了考虑时滞影响的重要性。

2.3.4 周期项位移预测

将滑坡趋势项位移及考虑时滞的 EMD-TIGWO-BP 预测的周期项位移进行叠加,得到滑坡累计位移预测值,同时建立了未考虑时滞效应的 GWO-BP 模型、EMD-GWO-BP 模型、BP-TIGWO 模型及 BP 模型与本文方法对比,各模型预测结果见图 7,各模型预测精度评价指标见表 4。




图7 累计位移实际值与不同模型预测值对比

Fig.7 Comparison between the actual values of cumulative displacement and the predicted values by different models

表4 周期位移预测模型评估

Table 4 Evaluation of Cyclic Displacement Prediction Models

模型名称	RMSE	MAE	R^2
GWO-SVM	1.71	1.29	0.82
EMD-GWO-BP	2.27	1.87	0.71
BP-TIGWO	2.47	1.99	0.62
BP	6.61	5.65	0.26
EMD-TIGWO-BP(考虑时滞)	0.64	0.51	0.97

从表4及图7可得出以下结论:

1) EMD-TIGWO-BP模型的均方根误差(RMSE)及平均绝对误差(MAE)值分别为0.64、0.51,均为所有对比预测模型中最小的,相关系数(R^2)为0.97,是所有模型中最大的,说明该模型更适用于滑坡位移的预测。

2) EMD-TIGWO-BP模型的RMSE、MAE相比于BP-TIGWO模型分别降低了1.83、1.48, R^2 提高了0.35,预测误差减小,相关系数提高,说明引入EMD对监测数据进行分解的方法更能提高模型的预测精度,验证了对监测数据分解后再进行组合预测方法的可行性。

3) 引用Pearson相关系数对降雨量与周期位移间的时滞期数进行了分析,并建立了考虑降雨时滞效应的EMD-TIGWO-BP模型,其预测精度为所有对比预测模型中效果最好的,说明考虑降雨因素能够有效地提高滑坡位移的预测精度。

3 结论

本文提出了一种基于EMD-TIGWO-BP模型的滑坡位移预测方法。该模型分为5个步骤,首先引用EMD模型将滑坡位移监测数据分解成5个

imf信号及一个res分量;将分解后的信号分量重构为滑坡趋势项及周期项位移;然后,构建BP-TIGWO模型,引入Tent混沌映射及自适应权重因子提高灰狼算法的全局搜索能力及收敛能力,利用改进的灰狼算法对BP神经网络模型的连接权重及偏置项进行赋值;考虑到降雨量对滑坡位移的时滞效应,利用Pearson相关系数确定了降雨量与周期位移的最大时滞期数为32d,利用优化后的BP网络模型分别对趋势项及周期项各分量进行预测;将各分量结果叠加得到滑坡位移累计预测值;最后,对模型的预测精度进行评价。在实验中,本文提出的EMD-BP-TIGWO模型的性能优于其他模型,验证了所建模型的可行性。

参考文献

- [1] 高彩云. 基于新型智能算法ELM的滑坡变形位移预测[J]. 人民长江, 2017, 48(7): 46-49, 69.
GAO Caiyun. Displacement prediction of landslide based on new intelligent algorithm of ELM[J]. Yangtze River, 2017, 48(7): 46-49, 69.
- [2] 黄智杰, 沈佳, 简文彬, 等. 基于XGBoost模型的降雨诱发阶跃型滑坡位移预测[J]. 自然灾害学报, 2023, 32(2): 217-226.
HUANG Zhijie, SHEN Jia, JIAN Wenbin, et al. Displacement prediction of rainfall-induced step-like landslide based on XGBoost model[J]. Journal of Natural Disasters, 2023, 32(2): 217-226.
- [3] 彭鹏, 单治钢, 詹光亮, 等. Bayes融合理论在库区滑坡动态变形监测中的应用研究[J]. 水文地质工程地质, 2012, 39(1): 120-125, 131.
PENG Peng, SHAN Zhigang, ZHAN Guangliang, et al. Application of multi-sensor valuation based on Bayes fusion theory to the dynamic deformation for landslide monitoring[J]. Hydrogeology & Engineering Geology, 2012, 39(1): 120-125, 131.
- [4] 杨勇, 张忠政, 胡军, 等. 基于随机权重法改进PSO-ELM的露天矿边坡稳定性分析[J]. 有色金属工程, 2022, 12(5): 128-134.
YANG Yong, ZHANG Zhongzheng, HU Jun, et al. Slope stability analysis of open-pit mine based on improved PSO-ELM with random weight method[J]. Nonferrous Metals Engineering, 2022, 12(5): 128-134.
- [5] 马增, 刘正宇, 邹平, 等. 基于叠加马尔科夫链的边坡位移预测研究[J]. 有色金属(矿山部分), 2021, 73(4): 40-44.
MA Zeng, LIU Zhengyu, ZOU Ping, et al. Research on slope displacement prediction based on superposition Markov chain[J]. Nonferrous Metals(Mining Section), 2021, 73(4): 40-44.
- [6] 孙晓云, 段锦, 王明明, 等. 基于VMD模型和BSA-KELM模型的高陡边坡位移预测模型研究[J]. 中国矿业, 2022, 31(2): 78-85.
SUN Xiaoyun, DUAN Chuo, WANG Mingming, et al. Study on

- high and steep slope displacement prediction model based on VMD and BSA-KELM[J]. China Mining Magazine, 2022, 31(2):78-85.
- [7] 胡军,董建华,袁永涛.多策略 PSO-BP 算法在尾矿坝监测系统中的应用[J].有色金属(矿山部分),2015,67(3):85-88.
HU Jun, DONG Jianhua, YUAN Yongtao. Multi-strategy PSO-BP algorithm application on the monitoring system of tailings dam[J]. Nonferrous Metals (Mining Section), 2015, 67(3):85-88.
- [8] 张世佳,饶运章,王文涛,等. GA-BP 神经网络模型在稀土矿边坡位移监测中的应用[J]. 有色金属科学与工程,2022,13(1):115-121.
ZHANG Shijia, RAO Yunzhang, WANG Wentao, et al. Application of GA-BP neural network model in the displacement monitoring of rare earth slope[J]. Nonferrous Metals Science and Engineering, 2022, 13(1):115-121.
- [9] 王阳,仪垂杰,赵鹏,等. 基于 CEEMDAN-IGWO-BP 的供热管道泄漏孔径预测[J]. 传感器与微系统,2023,42(1):135-139.
WANG Yang, YI Chuijie, ZHAO Peng, et al. Leakage aperture prediction for heating supply pipeline based on CEEMDAN-IGWO-BP[J]. Transducer and Microsystem Technologies, 2023, 42(1):135-139.
- [10] 张孟健,张浩,陈曦,等. 基于 Cubic 映射的灰狼优化算法及应用[J]. 计算机工程与科学,2021,43(11):2035-2042.
ZHANG Mengjian, ZHANG Hao, CHEN Xi, et al. A grey wolf optimization algorithm based on Cubic mapping and its application [J]. Computer Engineering & Science, 2021, 43(11):2035-2042.
- [11] 廖康,吴益平,李麟玮,等. 基于时间序列与 GWO-ELM 模型的滑坡位移预测[J]. 中南大学学报(自然科学版),2019,50(3):619-626.
LIAO Kang, WU Yiping, LI Linwei, et al. Displacement prediction model of landslide based on time series and GWO-ELM[J]. Journal of Central South University (Science and Technology), 2019, 50(3):619-626.
- [12] 张其虎,张希,孙进辉,等. 基于 EMD-HHT 的地下浅孔爆破振动规律研究[J]. 有色金属(矿山部分),2021,73(3):48-55.
ZHANG Qihu, ZHANG Xi, SUN Jinhui, et al. Research on vibration law of underground shallow hole blasting based on EMD-HHT[J]. Nonferrous Metals (Mining Section), 2021, 73(3):48-55.
- [13] 赵伟,陈培红,曹阳. 基于 ACSOA-BP 神经网络的瓦斯含量预测模型[J]. 煤矿安全,2022,53(1):174-180.
ZHAO Wei, CHEN Peihong, CAO Yang. Prediction model of coal seam gas content based on ACSOA optimized BP neural network[J]. Safety in Coal Mines, 2022, 53(1):174-180.
- [14] 欧阳斌,陈艳红,邓传军. 基于 PSO 优化 BP 神经网络的露天矿边坡位移预测模型[J]. 有色金属(矿山部分),2020,72(5):37-41.
OUYANG Bin, CHEN Yanhong, DENG Chuanjun. Slope displacement prediction model of open pit based on the BP neural network optimized by PSO [J]. Nonferrous Metals (Mining Section), 2020, 72(5):37-41.
- [15] 王述红,魏巍,韩文帅,等. 基于 CGWO 算法的边坡最小安全系数全局寻优方法[J]. 东北大学学报(自然科学版),2022,43(7):1033-1042.
WANG Shuhong, WEI Wei, HAN Wenshuai, et al. Global optimization search method for minimum safety factor of slope based on chaotic grey wolf optimization algorithm[J]. Journal of Northeastern University (Natural Science), 2022, 43(7):1033-1042.
- [16] 张文胜,郝孜奇,朱冀军,等. 基于改进灰狼算法优化 BP 神经网络的短时交通流预测模型[J]. 交通运输系统工程与信息,2020,20(2):196-203.
ZHANG Wensheng, HAO Ziqi, ZHU Jijun, et al. BP neural network model for short-time traffic flow forecasting based on transformed grey wolf optimizer algorithm [J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(2):196-203.
- [17] 滕志军,吕金玲,郭力文,等. 一种基于 Tent 映射的混合灰狼优化的改进算法[J]. 哈尔滨工业大学学报,2018,50(11):40-49.
TENG Zhijun, LYU Jinling, GUO Liwen, et al. An improved hybrid grey wolf optimization algorithm based on Tent mapping[J]. Journal of Harbin Institute of Technology, 2018, 50(11):40-49.
- [18] 傅伟玉. 基于改进灰狼优化算法的金刚石刀具磨损状态识别方法[J]. 工具技术,2021,55(12):103-107.
FU Weiyu. Diamond tool wear state recognition method based on improved gray wolf optimization algorithm [J]. Tool Engineering, 2021, 55(12):103-107.