

考虑位移滞后效应的降雨型滑坡 SSA-DELM 位移预测模型研究

廖兴灵^{1,2}, 简文彬^{1,2,3}, 樊秀峰^{1,2,3}, 章德生^{1,2}

(1. 福州大学 紫金地质与矿业学院 岩土与地质工程系, 福建 福州 350108;

2. 福建省地质灾害重点实验室, 福建 福州 350108;

3. 地质工程福建省高校工程研究中心, 福建 福州 350002)

摘要: 针对东南丘陵山地降雨型滑坡变形发展特征, 现有滑坡预测模型应用存在局限, 结合滑坡变形特点研究基于智能算法的滑坡预测模型。以福建安溪尧山滑坡为例, 选取2019年9月至2022年6月滑坡监测数据进行研究, 采用集对分析、灰关联法、麻雀搜索算法及深度极限学习机对滑坡位移进行预测, 提出了一种考虑滑坡位移滞后时间基于深度学习的滑坡位移预测模型。结果表明: SSA-DELM模型的MAE、MAPE、RMSE相较于已有的BP神经网络、SVM模型均更小, 同时模型结合了滑坡影响因子以及水位-位移滞后特征, 具有明确的物理意义, 位移预测效果较好且精度较高, 可推广应用于类似的滑坡位移预测中。

关键词: 位移预测; 滞后; 集对分析; 麻雀搜索算法; 深度极限学习机

中图分类号: P642.22

文献标识码: A

文章编号: 1672-1144(2023)02-0128-09

Rainfall Induced Landslide Displacement Prediction Model Based on SSA-DELM Considering Hysteresis Effect of Displacement

LIAO Xingling^{1,2}, JIAN Wenbin^{1,2,3}, FAN Xiufeng^{1,2,3}, ZHANG Desheng^{1,2}

(1. Department of Geotechnical and Geological Engineering, Zijin School of Geology and Mining, Fuzhou University, Fuzhou, Fujian 350108, China;

2. Institute Key Laboratory of Geohazard Prevention of Fujian Province, Fuzhou, Fujian 350108, China;

3. Institute of Geotechnical and Engineering Geology of Fujian Province, Fuzhou, Fujian 350002, China)

Abstract: This paper proposes a new landslide displacement prediction model. The model is based on deep learning which considers the hysteresis effect of landslide displacement. There are limitations in the application of existing landslide prediction models, due to the deformation and development characteristics of rainfall-induced landslide in south-eastern China, in which there are plenty of mountains and hills. Therefore, it is of great theoretical and practical significance to study the landslide prediction model for disaster prevention and reduction. The model is based on intelligent algorithm, combining with the characteristics of landslide deformation. Research selected the landslide displacement monitoring data from September 2019 to June 2022, in Mount Yao, Anxi, Fujian Province. The model adopted gray relational analysis, set pair analysis and optimization of deep extreme learning machine based on sparrow search algorithm. Results show that the mean absolute error, the mean absolute percentage error and the root mean square error (RMSE) of the proposed SSA-DELM are all lower than existing BP, SVM model. Moreover, model integrates with influence factors of landslide and hysteresis effect of water level displacement.

Keywords: displacement prediction; hysteresis; set pair analysis; sparrow search algorithm; deep extreme learning machine

我国东南丘陵山地地质环境条件脆弱,台风暴雨、极端降雨频发,诱发了大量的地质灾害。以崩、滑、流为主的地质灾害占据了绝大部分,其中又以滑坡发生频率高、分布范围广、破坏性大最为显著,每年都会带来大量的人员伤亡和经济损失^[1-2]。因此,对滑坡进行预测、预报显得尤为重要。滑坡预测、预报经历了从经验模型到数学统计模型到物理分析方法,再到如今的以机器学习、人工智能^[3-5]相结合的非线性模型,可见,滑坡预测、预报一直是研究领域的热点,且随着技术的进步,仍在蓬勃发展。

滑坡位移作为反映滑坡变形最直观的特征,能很好表征滑坡变形趋势,一直是众多学者研究的焦点。因而,对滑坡位移进行预测不失为对滑坡进行预报的好方法。伍法权等^[6]从动力学角度对滑坡位移进行预测;尹顺德等^[7]利用 GA-NN 模型对降雨条件下的滑坡位移演化发展做出了精确的预测,以 BP、GM、Verhulst、Pearl、混沌理论等为代表的位移预测模型得到了迅猛发展。近年来,随着计算机的发展、大数据时代的到来,技术的发展进步为地质灾害防治领域注入了新的活力。越来越多学者利用机器学习、人工智能等相关理论对滑坡位移进行预测。Zhu Xing 等^[3]提出了一种由最小二乘支持向量机(LSSVM)和双指数平滑(DES)组成的混合模型,并将其应用于多因素诱发滑坡的一步超前位移计算。采用小波去噪和 H-P 滤波法将原始位移序列分解为三个分量:周期项、趋势项和随机项,采用 LSSVM 和 DES 模型分别对周期项和趋势项位移进行预测;李麟玮等^[8]提出基于变分模态分解与 GWO-MIC-SVR 模型,采用 VMD 和时序分析法将滑坡累积位移分解为趋势项位移、周期项位移和随机项位移,对各位移分量分别选取影响因子,最终实现滑坡位移预测;杨帆等^[9]提出了基于时间序列的人工蜂群算法(ABC)与支持向量回归机(SVR)相结合的滑坡位移预测方法,利用时间序列加法模型和移动平均法,将位移分解为趋势项和周期项,趋势项位移预测采用多项式最小二乘法拟合,周期项位移采用 ABC-SVR 模型;Li Changdong 等^[10]提出了一种新的 GA-CEEMD-RF 算法模型去预测香溪河流域阶跃型滑坡位移,该算法可用于解决使用单位移预测模型确定诱发因素组合的困难和预测结果的弱稳定,利用八字门滑坡多场监测数据验证了模型的准确性。

近些年滑坡位移预测主要集中于三峡库区,且方法主要体现在采用时间序列、小波分解、模态分解

等手段先对位移序列进行分解,而后采用机器学习相关算法对分解后的趋势项、周期项、随机项分别进行预测,继而得出总的预测位移。但仍存在以下一些问题:(1)在对位移影响因子进行分析时,多采用定性分析,降低了模型的准确度;(2)对位移先分解再进行预测,易导致信息泄露,且过程过于繁琐;(3)以福建为代表的我国东南丘陵山地,台风暴雨频发,降雨型滑坡变形特征具有区域典型性,现有的滑坡预测模型的应用存在局限性。福建省安溪西坪尧山滑坡具有降雨型滑坡特征,且深度学习较机器学习,具有更佳的特征提取能力,在此地进行基于深度学习的滑坡预测相关研究具有重要意义。

本文以福建安溪西坪尧山滑坡为例,基于研究区滑坡地质环境条件及变形特征,应用集对分析理论大致定量确定滑坡变形滞后时间,与灰色关联理论相结合,确定滑坡位移的影响因子,而后采用基于深度学习、麻雀搜索算法优化的极限学习机实现对滑坡位移的预测。

1 研究区滑坡监测数据分析

1.1 滑坡工程地质概况

滑坡点位于福建泉州安溪县西坪镇尧山村所在山体,总体上呈 NS 向展布,方位角约 NE10°,与区内发育 NE10°∠70°~80°断层相一致,整体坡度约 20°~30°,后缘高程约 475 m,前缘高程 360 m,前后缘高差 115 m,平面上呈“长条带状”,后缘较窄,往前缘逐渐变宽,后缘横向宽约 80 m,前缘约 200 m,纵向长 350 m,面积约 $5.2 \times 10^4 \text{ m}^2$,崩坡积体厚度 1.6 m~8.0 m,平均厚度约 7 m。岩土体自上而下可分为:素填土、崩坡积碎石土、残积黏性土、全风化凝灰岩、砂土状强风化凝灰岩、碎块状强风化凝灰岩以及中风化凝灰岩,滑面位于表层崩坡积碎石土与残积土层交界面,埋藏深度约为 6 m~12 m,崩坡积碎石土的重度为 18 kN/m^3 ,黏聚力 14.5 kPa,内摩擦角 27.8°,残积黏性土重度为 17.7 kN/m^3 ,黏聚力 17.0 kPa,内摩擦角 26.2°。

1.2 滑坡监测数据分析

在安溪西坪尧山村滑坡点,共建立两个测站,每个监测站布置有水分计、渗压计、测斜仪、孔隙水压力计、裂缝计,雨量计只在测站一进行布置(见图 1)。自动监测从 2019 年 7 月 25 日开始使用,远程监测自动化系统从 2019 年 8 月 10 日正式启用,为避免监测初期数据的不稳定,选取测站一从 2019 年 9 月 1 日起的监测数据进行分析。

从 2019 年 9 月 1 日至 2022 年 6 月 1 日的滑坡深部位移、降雨量、水位监测数据如图 2 所示。由图 2 可知,每一次水位的涨落起伏,位移也呈现相应变化,具体体现为:水位上升时,位移陡增,例如 2020 年 2 月到 2020 年 10 月,水位高程从 434 m 上升至 437 m,位移从 20 mm 增长至 50 mm,2021 年 6 月到 2021 年 10 月,水位高程从 438 m 上升至 440 m,位移从 50 mm 增长至 120 mm,而当水位下降时,位移平稳变化,呈直线型,例如 2020 年 9 月到 2021 年 6 月,水位从 438 m 下降至 434 m,位移保持在 50 mm 左右,2021 年 9 月到 2022 年 3 月,水位高程从 440 mm 下降至 435 mm,位移保持在 120 mm 左右。每年冬春季节,该地滑坡点位移随着降雨的零星变化整体显现平稳态势,而春夏季节,位移随着降雨的增大呈现波动增长。可见,此地滑坡位移与降雨、水位呈现很好的相关关系,具有明显的季节性。



图 1 滑坡监测点布置图(航拍图)




图 2 滑坡监测曲线图

2 研究方法

针对现有滑坡预测模型存在局限性,本文提出的滑坡位移预测模型集成了灰关联分析法(GRA)、集对分析理论(SPA)、深度极限学习机(DELM)以及麻雀搜索算法(SSA)。运用 GRA 及 SPA 可为滑坡位移定量提取合适的影响因子,SSA 可弥补 DELM 初始输入参数随机性问题。相关理论如下:

2.1 灰色关联度分析法(GRA)

滑坡是个灰色系统,影响滑坡位移因素众多,“灰系统理论”^[11] 中的灰关联分析是据各因素变化曲线几何形状的相似程度,以此来判断因素间关联程度。因而,使用该方法可为滑坡位移选择合适的影 响因子。汪洋等^[12] 利用灰关联理论,得出湖北秭归下土地岭滑坡滑带的 c 、 φ 值对滑坡稳定性影响最为敏感;黄盛锋等^[13] 将灰色关联法运用于强度折减法中,得出边坡稳定系数对 c 、 φ 值改变非常敏感。基本流程如下:

(1) 确定分析序列

(2) 无量纲化处理

为消除原始数据因单位不同而可能造成的干扰与误差,采用区间相对值归一化对数据进行处理,见式(1):

$$X_{ij} = \frac{x_{ij} - \min x_{ij}}{\max x_{ij} - \min x_{ij}} \tag{1}$$

(3) 计算差值序列,并求最大差与最小差

$$\Delta_{ij} = |X_{ij} - Y_{ij}| \tag{2}$$

$$\Delta_{\max} = \max \Delta_{ij} \tag{3}$$

$$\Delta_{\min} = \min \Delta_{ij} \tag{4}$$

(4) 计算关联度系数序列

根据下式计算关联度系数序列 ζ ,其中 $\rho \in (0, 1)$,一般取 0.5;

$$\zeta_{ij} = \frac{\Delta_{\min} + \rho \Delta_{\max}}{\Delta_{ij} + \rho \Delta_{\max}} \tag{5}$$

(5) 计算关联度(关联度是介于[0,1]之间的变化量)

$$\gamma_{ij} = \frac{1}{n} \sum_{i=1}^n \zeta_{ij} \tag{6}$$

2.2 集对分析理论(SPA)

由于自然条件下滑坡土体呈非饱和态,滑坡位移对降雨所带来的水分响应具有滞后特征。集对分析是由我国学者赵克勤^[14] 首先提出用于处理系统确定性与不确定性相互作用的数学理论,将二者视为一个系统,在一定的情景下讨论两集合所具有的特征,进行同、异、反分析并加以定量刻画。运用该理论可确定滑坡位移滞后时间,继而进一步丰富滑坡位移影响因子。其数学表达式如式(7) 所示:

$$\mu = a + bi + cj = \frac{S}{N} + \frac{P}{N}i + \frac{E}{N}j \tag{7}$$

$$a, b, c \in [0, 1] \text{ 且 } a + b + c = 1$$

式中: μ 为联系度或关联度; a 为同一度; b 为差异度; c 为对立度; i 为差异度系数,一般在 $[-1, 1]$ 之间取

值; j 为对立度系数,一般设为 -1 ; S 为集对中同一的特征数; P 为集对中差异的特征数; E 为集对中对立的特征数; N 为集对中所有的特征数。

2.3 深度极限学习机(DELM)

深度极限学习机(DELM)思想是由南洋理工大学 Kasun 等^[15]提出,由多层 ELM-AE 及 ELM 组成。

(1) ELM-AE 为以 ELM 为基础的自动编码器用于对输入数据的特征提取。自动编码器 AE 经过训练可以将输入复制到输出,为无监督式学习,应用 AE 的思想于 ELM 中,让 ELM 的输入数据同理被用于输出,即输出 Y 等于输入 X (式 8)。ELM-AE 的网络结构如图 3 所示。

$$x_j = \sum_{i=1}^L \beta_i G(a_i, b_i, x_j), a_i \in R^n, b_i \in R, \beta_i \in R^n \quad (8)$$

$$j = 1, 2, \dots, N \quad \mathbf{a}^T \mathbf{a} = \mathbf{I}, \mathbf{b}^T \mathbf{b} = 1$$

式中: $\mathbf{a}$ 为 a_i 组成的矩阵,表示正交化的隐藏层随机输入的权值矩阵; $\mathbf{b}$ 为 b_i 组成的向量,表示正交化的隐藏层偏置向量。ELM-AE 的输出权值 β 可由式(9)得出:

$$\beta = \begin{cases} \left(\mathbf{H}^T \mathbf{H} + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{H}^T X, n \neq L \\ \mathbf{H}^{-1} X, n = L \end{cases}, \beta^T \beta = \mathbf{I} \quad (9)$$

式中: $\mathbf{H}$ 为隐藏层输出矩阵; C 为正则化系数; $\mathbf{I}$ 为单位矩阵; n 为输入层节点个数; L 为隐藏层节点个数。




图3 ELM-AE 网络结构图

(2) 深度极限学习机(DELM)以 ELM-AE 为基本单元,因其具有较佳的特征表达能力,经逐层训练,可得原始数据的高级特征。以输入样本 X 作为第一个 ELM-AE 的目标输入,目标输出 X_1 近似等于输入 X ,可求得输出权值 β_1 ,而后将 ELM-AE 第一个隐藏层的输出 H_1 作为第二个 ELM-AE 的输入,目标输出 X_2 近似等于 H_1 ,依次逐层训练学习,最后一层采用 ELM 进行训练,输出权值 β 可由式(9)求得(见图 4)。DELM 每一层的输入权重 ω_{i+1} 等于 β_{i+1}^T , H_{i+1} 为最后一个隐藏层的输出, T 为样本标签^[16]。




图4 DELM 训练过程

2.4 麻雀搜索算法(SSA)

麻雀搜索算法由东华大学的薛建凯等^[17]提出的一种新兴的元启发式算法,通过不断更新个体位置,模拟麻雀觅食和反捕食行为,属于基于群体的社会化特征优化的群智能算法。相比传统算法,结构简单、易于实现,且控制参数较少,局部搜索能力较强。运用该优化算法,可在一定程度上弥补深度极限学习机输入参数随机性的问题。基本流程如下:

(1) 种群初始化

假设种群数为 n ,则种群由所有个体组成可表示为 $X = [x_1, x_2, \dots, x_n]^T$,各自对应的适应度函数 $F = [f(x_1), f(x_2), \dots, f(x_n)]^T$ 。

(2) 发现者位置更新

$$x_{i,j}^{t+1} = \begin{cases} x_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \times \text{iter}_{\max}}\right), R_2 < ST \\ x_{i,j}^t + Q \cdot L, R_2 \geq ST \end{cases} \quad (10)$$

式中: t 为当前迭代次数; $x_{i,j}^t$ 为 t 代中第 i 只麻雀在第 j 维的位置; α 为介于 $0 \sim 1$ 之间的量; $\text{iter}_{\max}$ 为最大迭代次数; R_2 为报警值; ST 为安全阈值; Q 为服从正态分布的随机数; L 为 $1 \times \text{dim}$ 全1矩阵, dim 表示维度。

(3) 更随者位置更新

$$x_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{x_{\text{worst}}^t - x_{i,j}^t}{i^2}\right), i > \frac{n}{2} \\ x_p^{t+1} + |x_{i,j}^t - x_p^{t+1}| \cdot \mathbf{A}^+ \cdot L, i \leq \frac{n}{2} \end{cases} \quad (11)$$

式中: x_{worst}^t 为第 t 代适应度最差的个体位置; x_p^{t+1} 为 $t+1$ 代中适应度最佳的个体位置; $\mathbf{A}$ 为 $1 \times \text{dim}$ 的矩阵,每个元素随机预先设置为 1 或 -1 , $\mathbf{A}^+ = \mathbf{A}^T (\mathbf{A} \mathbf{A}^T)^{-1}$ 。

(4) 警戒者位置更新

$$x_{i,j}^{t+1} = \begin{cases} x_{\text{best}}^t + \beta \cdot |x_{i,j}^t - x_{\text{best}}^t|, f_i \neq f_g \\ x_{\text{best}}^t + k \cdot \left(\frac{x_{i,j}^t - x_{\text{best}}^t}{|f_i - f_{\omega}| + \varepsilon} \right) f_i = f_g \end{cases} \quad (12)$$

式中: x_{best}^t 为第 t 代中全局最优位置; β 为控制步长,服从 $N(0,1)$; k 为介于 $-1\sim 1$ 之间的量; ε 为常数; f_i 为当前个体的适应度值; f_g, f_w 为当前全局最优和最差个体的适应度值。

2.5 模型位移预测流程

如图 5 所示,本文对滑坡进行位移预测的基本流程如下:

(1) 数据预处理。首先对数据进行下载,而后整理分析,由于外部条件等不可控因素,监测数据必然存在着诸如缺失、异常等现象,因此,对数据进行预处理显得十分重要。

(2) 采用灰色关联分析(GRA)对位移、降雨、水位、孔压进行相关性分析,而后采用集对分析理论(SPA)大致定量确定滑坡变形滞后时间为 2 d,将 2 d 前水位、2 d 前水位波动速率作为滑坡位移的影响因子,并结合灰关联分析结果,可得最终滑坡位移预

测的影响因子。

(3) 将预处理完的监测数据与滑坡位移影响因子相结合,组成数据集,对其进行划分为训练集和测试集。

(4) 对划分好的数据集,首先对其进行归一化处理,以减小数据大小,提高运算速度,而后采用麻雀搜索算法(SSA)确定深度极限学习机(DELM)的输入权重,与未进行参数寻优的深度极限学习机进行对比训练,通过反归一化后,可得最终位移预测结果。

(5) 为表征模型性能,利用平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方根误差(RMSE)模型评价指标对提出的模型进行评价,同时与已有的滑坡位移预测模型:BP 神经网络、SVM,进行对比验证。




图 5 位移预测流程图

2.6 模型性能评价

本文提出的滑坡预测模型为回归模型,平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方根误差(RMSE)为常用的评价方法,计算公式如下:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_{tp} - y_t| \tag{13}$$

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{(y_{tp} - y_t)}{y_t} \right| \tag{14}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{tp} - y_t)^2} \tag{15}$$

式中: y_{tp} 为 t 时刻样本的预测值; y_t 为 t 时刻样本的实际值; N 为样本总数。MAE、MAPE、RMSE 越小,则

模型预测效果越好。

3 模型应用实例

3.1 数据处理

数据处理的基本流程为:数据获取→数据清理→数据集成→数据变换→数据归纳,本文数据来源于课题组自建的远程监测自动化系统,数据采集频率为每小时一采。通过对数据进行整理,发现位移和孔压数据 2020 年 11 月 1 日至 2020 年 11 月 17 日存在缺失,水位数据 2020 年 11 月 1 日至 2020 年 11 月 19 日以及 2021 年 11 月 22 日至 2021 年 11 月 28 日存在缺失,通过作图发现,位移图像在个别点存在异常,分别是 2020 年 4 月 15 日、4 月 18 日、5

月 2 日、5 月 18 日至 5 月 27 日、6 月 6 日、6 月 16 日、6 月 25 日、10 月 1 日和 10 月 5 日。为获得完整数据,对位移、雨量、水位、孔压存在的缺失值、异常值分别进行填补、剔除,雨量为对每时雨量值求和得到,位移、水位、孔压为每时求平均后得到。最终滑坡位移-降雨-水位的监测数据图如图 2 所示。

3.2 训练集、测试集划分

训练集主要是用来训练模型参数的样本集合,对于训练完成的模型,通过测试集进行评估。划分方法一般分为 3 种^[18],留出法、交叉验证法和自助法,对于小规模数据集,训练集和测试集的比例为 7:3 或是 8:2,若引入验证集,则训练集、验证集、测试集的比例为 6:2:2;对于大规模数据集,三者的比例为 98:1:1。由于考虑对模型进行参数寻优,因而数据集不设验证集,本文训练集与测试集的比例为 8:2。

3.3 位移与影响因子的定量分析

对从 2019 年 9 月 1 日至 2022 年 6 月 1 日共 1005 组位移、降雨、水位、孔压数据进行灰色关联度分析,结果如图 6 所示。




图 6 灰色关联分析热图

位移与降雨、水位、孔压的关联度分别为 0.60、0.70、0.71,从数值上可知,位移与水位、孔压关联程度较降雨更大,而关联度只是作为衡量指标序列相似程度的测度,为介于 0~1 之间的量,值越接近于 1,反映为该子序列对母序列的影响越敏感;反之,越接近 0,影响越不敏感^[12]。另外,从滑坡机理上进行分析,滑坡深部位移相较于浅层位移,表层的降雨,由于自然条件下土层呈现非饱和状态且具有渗透性,滑坡深部位移无法第一时间对降雨进行响应,而水位、孔压为反应滑坡内在、深层次的物理量,降雨带来的降水,除了造成地表径流外,首先会使地下水位高程上升,其次是可使土体内部的孔隙被水所充填,孔隙水体积增加,孔隙水压力增大,根据有效应力原理,孔隙水压力增大,有效应力减小,土体呈

不稳定状态,极易产生位移变形,因而,水位、孔压与滑坡深部位移有很好的相关性。因此,安溪西坪尧山滑坡的深部位移相较于降雨,水位、孔压对其的影响更敏感,且二者的敏感程度近似相等,可将降雨、水位、孔压作为滑坡位移的影响因子,后两者为主要影响因子。

3.4 位移滞后时间确定

为确定滑坡位移滞后时间,引入地下水位波动阈值 $W(\text{m/d})$ 、位移变化阈值 $D(\text{mm/d})$,将水位波动按照在 $\pm W$ 范围内、大于 W 、小于 W 三种标准分为稳定、上升、下降三种状态;同理,将位移变化按照在 $\pm D$ 内、大于 D 、小于 D 三种标准分为稳增、急增、缓增(表 1)确定 W 和 D 是进行相关性分析,继而确定滑坡变形滞后时间的关键^[19-20]。联系度 μ 表征水位和滑坡变形的相关性,其同一度 α 越大,表明两序列所构成的集对在宏观层面上具有越好相关性。由于水位变化对滑坡变形具有滞后效应,设平移步数为 s ,对位移序列进行时间轴平移,考量 t 到 $t+1$ 时刻水位变化情况与 $t+s$ 到 $(t+1)+s$ 区间时刻滑坡位移的相关性,步长为从 0 开始的正整数^[19]。由于位移变形速率、水位升降速率具有较大的离散性,较难通过频率分布直方图找出水位波动阈值、位移变化阈值,而中位数能较好刻画位移速率、水位速率三种状态,使其数量几乎相同,处于同一显著水平,因此 W 取 -0.04 , D 取 0.17 。

同一度越大,表明两序列相关性越好,假定位移变形速率序列平移步长为 2,即每次平移两天,计算该序列与水位升降速率的同一度,通过不断平移计算,当同一度达到最大值时,可得滑坡变形滞后时间^[4]。如图 7 所示,当平移时间为 26 d 时,同一度最大,然而经过验算及结合实际,平移时间为 26 d 时,水位升降速率-位移变形速率和日均水位-日均位移所做出的图形并未表现出很好的一致性(见图 8、图 9)。相反,同一度小范围内的极值,即当平移时间为 2 d 时,却体现出较好的一致性,与实际较为吻合,说明此地滑坡的变形滞后时间约为 2 d,而非最值 26 d。

表 1 滑坡水位变化速率与位移变形速率间的“同-异-反”关系

滑坡位移速率	水位变化速率		
	下降	稳定	上升
缓增	同	异	反
稳增	异	同	异
急增	反	异	同




图 7 滑坡变形滞后时间




图 8 日均水位、日均位移和平移后日均位移曲线




图 9 水位升降速率、位移变形速率与平移后位移变形速率曲线

图 8 为水位与位移、平移后位移的变化曲线,图 9 为水位升降速率与位移变形速率、平移后位移变形速率的变化曲线。2020 年 6 月—9 月及 2021 年 6 月—9 月,即图 9 所示的 I、II 区,水位升降速率与平移后位移变形速率存在较好的一致性,尤其是 2020 年 8 月—9 月和 2021 年 6 月—7 月,从图 8 也可看出,当水位在局部存在连续两次上升时,经过平移后的累积位移上升拐点处与水位上升的波峰处较好的契合,这一点在图 8 中 II 区 2021 年 6 月—7 月

处得到了较好体现。然而在图 9 中的①、②处也发现,相较于平移后的位移变形速率曲线,原位移变形速率曲线与水位升降速率曲线从图中可看出在波动幅度及图像曲线上具有更好的一致性,在图 8 中相应位置(①、②处)从宏观的角度上效果并不明显。这说明此地滑坡变形滞后可能发生于降雨集中且量大的夏季,而对于降雨偏少的冬春季节,例如图 8、图 9 中的①、②处,对应于 2020 年 1 月—4、5 月份及 2022 年 1 月—4、5 月份,位移对水位的变化本就存在着不错的响应,体现出此地滑坡的特殊性。因此,可选 2 d 前水位、2 d 前水位波动速率,而非同一度最值 26 d 前水位、26 d 前水位波动速率作为位移预测的影响因子。

3.5 位移预测及对比分析

每年 5 月—9 月份为此地降雨集中时间,同时也是台风登陆时间,短暂且集中的降雨,极易造成重大地质灾害,滑坡位移变化能很好体现滑坡变形程度,因此,对此时间内的位移进行预测研究具有重要意义。选取 2020 年 5 月 1 日—10 月 1 日期间共计 154 组数据,依训练集与测试集比例,前 124 组为训练集,后 30 组为测试集,同时选取 2021 年 5 月 1 日至 10 月 1 日期间共计 154 组数据,划分比例同上,作为参照和验证。降雨、地下水位、孔压与位移具有密切关系,对位移来说是无可争议的影响因子,依集对理论,上文已得出此地滑坡变形滞后时间约为 2 d,可将 2 d 前水位及水位升降速率、位移变形速率也作为位移的影响因子。最后,通过编写程序,可得位移测试集预测结果如图 10 所示。

从图 10(a)中可知,以 2020 年 5 月—10 月前 124 组数据作为预测模型训练集,后 30 组数据作为测试集,SSA-DELM 模型位移预测值与实测值最为吻合、DELM 模型次之,BP 模型、SVM 模型与位移实测值偏差较大,作为检验模型优劣的对照组图 10(b),采用与图 10(a)相同的数据集划分和预测模型,结果显示,SSA-DELM 模型输出值与位移实测值仍最为吻合,说明 SSA-DELM 模型相较于已有且较为常用的 BP 模型、SVM 模型对于此地滑坡位移预测显示出较好的预测结果及较优的模型泛化性能。

3.6 模型评价

MAE、MAPE、RMSE 为常用模型评价指标,对上文测试集依不同模型训练出的结果分别采用上述指标进行评价(见表 2)。




图 10 位移预测结果

表 2 模型性能评价

模型		BP	SVM	DELM	SSA-DELM
2020 年 9 月	MAE/mm	3.97	3.33	1.35	0.91
	MAPE/%	7.40	6.12	2.49	1.70
	RMSE/mm	4.30	4.06	1.73	1.27
2021 年 9 月	MAE/mm	2.87	5.90	11.26	2.55
	MAPE/%	2.49	5.09	9.74	2.20
	RMSE/mm	3.78	6.59	11.87	4.05

对 2019 年 9 月—2022 年 6 月滑坡监测数据进行分析,研究区水位、孔压数据对位移数据更为敏感,且位移滞后水位时间为 2 d,采用 SSA-DELM 模型对 2020 年 9 月滑坡位移数据进行预测,模型的 MAE 为 0.91 mm,MAPE 为 1.7%,RMSE 为 1.27 mm,对 2021 年 9 月滑坡位移数据进行对比预测,模型的 MAE 为 2.55 mm,MAPE 为 2.2%,RMSE 为 4.05 mm。

从表 2 模型性能评价结果可看出,神经网络模型总体效果要优于 SVM,深度极限学习机和支持向量机偶然性过大,使用该模型对位移进行预测时,需

使用优化算法进行参数寻优,以减小偶然,增加预测的准确性,采用麻雀搜索算法优化的深度极限学习机模型 (SSA-DELM) 对此处滑坡位移进行预测,其模型评价价值均小于 BP、SVM、DELM 模型,说明此模型具有较好的预测精度,体现出较好的性能。

4 结 论

以福建安溪尧山滑坡为研究背景,结合此地降雨型滑坡变形发展特征及现有滑坡预测模型应用的局限性,研究基于智能算法的滑坡预测模型,得出如下结论:

- (1) 针对滑坡预测过程中影响因子的定性选取,本文采用集对分析理论,对滑坡变形滞后时间进行了定量分析,结合灰关联理论,可为滑坡位移的影响因子选取提供定量表征,提高预测准确度。
- (2) 以深度学习中的自编码器 (AE) 与极限学习机 (ELM) 相结合,构建基于深度学习的极限学习机,在本文位移预测中体现出了较大的随机性,但采用基于麻雀搜索算法 (SSA) 进行参数寻优过后,深度极限学习机 (DELM) 模型的性能得到了极大的提升。
- (3) 针对滑坡位移先分解再预测,易导致信息泄露,且程序过于繁琐,本文对位移数据进行直接预测,与目前已有的 BP、SVM 模型对比,预测结果表明考虑滑坡位移滞后时间基于麻雀搜索算法优化深度极限学习机的滑坡位移预测模型 (SSA-DELM) 具有较高的预测精度和较优的模型泛化性能,且结合了滑坡影响因子以及位移滞后特征,具有明确的物理意义,为滑坡位移预测提供了一种新的方法,具有一定的推广价值。

参考文献:

[1] 林春泽,王宁涛,王清,等. 降雨型滑坡地质灾害预警预报研究进展[J]. 暴雨灾害,2018,37(5):393-400.

[2] 刘传正,陈春利. 中国地质灾害防治成效与问题对策[J]. 工程地质学报,2020,28(2):375-383.

[3] Zhu Xing, Xu Qiang, Tang Minggao, et al. A hybrid machine learning and computing model for forecasting displacement of multifactor-induced landslides [J]. Neural Computing and Applications, 2018,30(12):3825-3835.

[4] Zhang Lei, Shi Bin, Zhu Honghu, et al. PSO-SVM-based deep displacement prediction of Majiagou landslide considering the deformation hysteresis effect. [J]. Landslides, 2021,18(1):179-193.

[5] Rajabi A M, Khodaparast M, Mohammadi M. Earthquake-induced landslide prediction using back-propaga-

- tion type artificial neural network: case study in northern Iran [J]. *Natural Hazards*, 2022, 110(1): 679-694.
- [6] 伍法权, 王年生. 一种滑坡位移动力学预报方法探讨[J]. *中国地质灾害与防治学报*, 1996(S1): 38-41, 85.
- [7] 尹顺德, 冯夏庭, 周 辉, 等. 降雨影响下滑坡变形预测的 GA-NN 模型研究[J]. *岩土力学*, 2003(6): 1038-1041.
- [8] 李麟玮, 吴益平, 苗发盛, 等. 基于变分模态分解与 GWO-MIC-SVR 模型的滑坡位移预测研究[J]. *岩石力学与工程学报*, 2018, 37(6): 1395-1406.
- [9] 杨 帆, 许 强, 范宣梅, 等. 基于时间序列与人工蜂群支持向量机的滑坡位移预测研究[J]. *工程地质学报*, 2019, 27(4): 880-889.
- [10] Li Changdong, Criss R E, Fu Zhiyong et al. Evolution characteristics and displacement forecasting model of landslides with stair-step sliding surface along the Xian-gxi River, three Gorges Reservoir region, China [J]. *Engineering Geology*, 2021, 283: 10596.
- [11] 邓聚龙. 灰理论基础[M]. 武汉: 华中科技大学出版社, 2002.
- [12] 汪 洋, 殷坤龙, 安关峰. 滑坡敏感因子的灰色关联分析[J]. *岩土力学*, 2004(1): 91-93.
- [13] 黄盛锋, 陈志波, 郑道哲. 基于灰色关联度法和强度折减法的边坡稳定性影响因素敏感性分析[J]. *中国地质灾害与防治学报*, 2020, 31(3): 35-40.
- [14] Zhao Kegin. Theory and analysis of set pair e a new concept and system analysis method [C]//Conference thesis of system theory and regional planning, 1989: 87-91.
- [15] Kasun L L C, Zhou Hongming, Huang Guangbin, et al. Representational learning with ELMs for big data [J]. *Intelligent Systems, IEEE*, 2013, 28(6): 31-34.
- [16] 颜学龙, 马润平. 基于深度极限学习机的模拟电路故障诊断[J]. *计算机工程与科学*, 2019, 41(11): 1911-1918.
- [17] Xue Jiankai, Shen Bo. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.
- [18] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
- [19] 刘 晓, 唐辉明, 刘 瑜. 基于集对分析的滑坡变形动态建模研究[J]. *岩土力学*, 2009, 30(8): 2371-2378.
- [20] 高晨曦, 刘艺梁, 薛 欣, 等. 三峡库区典型堆积层滑坡变形滞后时间效应研究[J]. *工程地质学报*, 2021, 29(5): 1427-1436.

~~~~~

(上接第 100 页)

- [5] 朱岳明, 徐之青, 贺金仁, 等. 混凝土水管冷却温度场的计算方法[J]. *长江科学院院报*, 2003, 20(2): 19-22.
- [6] 梅甫良, 增德顺. 一期水管冷却效应的数值模拟新方法[J]. *计算力学学报*, 2003(4): 508-510.
- [7] 朱岳明, 张建斌. 碾压混凝土坝高温期连续施工采用冷却水管进行温控的研究[J]. *水利学报*, 2002(11): 55-59.
- [8] Chen Shenghong, Su Peifang, Shahrour I. Composite element algorithm for the thermal analysis of mass concrete: simulation of cooling pipes [J]. *International Journal of Numerical Methods for Heat & Fluid Flow*, 2011, 21(3/4): 434-447.
- [9] 苏培芳, 陈胜宏. 混凝土水管冷却的复合单元算法的初步研究[J]. *武汉理工大学学报*, 2010, 32(24): 48-53.
- [10] 汪卫明, 陈胜宏. 一种新的岩体力学数值计算方法——叠单元法[J]. *岩石力学与工程学报*, 2005, 24(7): 1093-1098.
- [11] Fish J. The s-version of the finite element method [J]. *Computers & Structures*, 1992, 43(3): 539-547.
- [12] 丁建新, 汪卫明, 陈胜宏. 裂缝分析的叠单元法研究[J]. *岩石力学与工程学报*, 2012, 31(5): 1034-1041.
- [13] 汪卫明, 刘友良, 丁建新, 等. 渗流分析中排水孔模拟的叠单元法[J]. *岩土力学*, 2011, 32(S1): 674-679.
- [14] 汪卫明, 刘亚飞, 丁建新. 渗流分析中复杂排水系统模拟的叠单元法[J]. *武汉大学学报(工学版)*, 2012, 45(2): 137-141, 147.
- [15] 石根华. 数值流形方法与非连续变形分析[M]. 北京: 清华大学出版社, 1997.