

https://doi.org/10.3799/dqkx.2018.909



基于时间序列分解和多变量混沌模型的 滑坡阶跃式位移预测

黄发明^{1,2}, 殷坤龙^{2*}, 杨背背², 李 喜², 刘 磊², 付小林³, 刘小文¹

1. 南昌大学建筑工程学院, 江西南昌 330000

2. 中国地质大学地质调查研究院, 湖北武汉 430074

3. 中国地质环境监测院, 北京 100081

摘要:三峡库区某些库岸滑坡在强降雨、库水位涨落等诱发因素影响下,其位移时间序列表现出阶跃式变化特征且可能存在混沌特性,但目前常用于滑坡位移预测的混沌模型,均建立在单变量混沌理论的基础之上,且已有的考虑了诱发因素的常规多变量模型,大都采用经验性的方法来选取输入变量;常规多变量模型对滑坡位移序列的非线性特征,及其与诱发因素间的动态响应关系缺乏数学理论上的深入分析.因此,提出一种基于指数平滑法、多变量混沌模型和极限学习机(extreme learning machine, ELM)的滑坡位移组合预测模型.指数平滑多变量混沌 ELM 模型首先对滑坡累积位移序列的混沌特性进行识别;然后用指数平滑法对累积位移进行预测,得到趋势项位移,并用累积位移减去趋势项位移得到剩余的波动项位移;之后对波动项位移及降雨量、库水位变化量这 3 个因子进行多变量相空间重构,并用 ELM 模型对多变量重构后的波动项位移进行预测;最后将预测得到的趋势项和波动项位移值相加,得到最终的累积位移预测值.以三峡库区白水河滑坡 ZG93 监测点的累积位移作为实例进行分析,并将模型与指数平滑多变量混沌粒子群-支持向量机(PSO-SVM)模型、指数平滑单变量混沌 ELM 模型作对比.结果表明滑坡位移序列存在混沌特性,模型能有效预测滑坡位移,其预测效果优于对比模型.且本文模型从混沌理论的角度将波动项位移与降雨量、库水位变化量的动态响应关系进行综合分析,更能反映滑坡位移系统演化的物理本质.

关键词:库岸滑坡;阶跃式位移预测;混沌分析;多变量相空间重构;指数平滑法;极限学习机.

中图分类号: P694

文章编号: 1000-2383(2018)03-0887-12

收稿日期: 2017-10-07

Step-Like Displacement Prediction of Landslide Based on Time Series Decomposition and Multivariate Chaotic Model

Huang Faming^{1,2}, Yin Kunlong^{2*}, Yang Beibei², Li Xi², Liu Lei², Fu Xiaolin³, Liu Xiaowen¹

1. School of Civil Engineering and Architecture, Nanchang University, Nanchang 330000, China

2. Geological Survey Institute, China University of Geosciences, Wuhan 430074, China

3. China Institute of Geo-Environment Monitoring, Beijing 100081, China

Abstract: The GPS monitoring cumulative displacement on reservoir landslides in the Three Gorges Reservoir area shows step-like characteristics and is a probable chaotic time series under the influences of the seasonal rainfall and reservoir water level fluctuation. Traditionally, the uni-variable chaotic model is commonly used to predict the landslide displacement; and all existing multivariable models select the input variables empirically without theoretical exploration of the nonlinear dynamic evolution process of landslide displacement and its inducing factors. A new combined model based on double exponential smoothing (DES), multivariable chaotic model, extreme learning machine (ELM) is proposed in this study. First, the chaos characteristic

基金项目:国家自然科学基金项目(No.41572292);江西省自然科学基金项目(No.20161RAR206126).

作者简介:黄发明(1988-),男,博士,研究方向为滑坡灾害预测预报. ORCID:0000-0002-4428-7133. E-mail: huang1503518@sina.cn

* **通讯作者:**殷坤龙, ORCID:0000-0002-3547-1633. E-mail: yinkunlong@163.com

引用格式:黄发明,殷坤龙,杨背背,等,2018.基于时间序列分解和多变量混沌模型的滑坡阶跃式位移预测.地球科学,43(3):887-898.

of landslide displacement is identified by the combined DES and multivariable chaotic ELM. Second, the DES method is used to predict the cumulative displacement. The predictive results are the trend displacement, and the periodic displacement is obtained by reducing the trend displacement from the cumulative displacement. Third, the multivariate phase space reconstruction method of chaotic theory is used to explore the dynamic relationship between the periodic displacement and its inducing factors, and the ELM model is established to predict the periodic displacement. Finally, the total forecast cumulative displacement is obtained by adding the predictive trend and periodic displacement. The GPS monitoring cumulative displacement on the Baishuihe landslide is used as case study. In addition, the proposed model is compared with the combined DES and multivariable chaotic particle swarm optimized support vector machine model, the combined DES and uni-variable chaotic ELM model. The results show that the prediction accuracy of the proposed model is higher than that of other models. The proposed model explores the nonlinear characteristic of landslide displacement and its dynamic relationship with inducing factors. The model also reflects the physical meaning of the nonlinear evolution of the landslide displacement.

Key words: reservoir landslide; step-like displacement prediction; chaos theory; multivariate phase space reconstruction; exponential smoothing method; extreme learning machine.

三峡库区自 2003 年蓄水以来,在强降雨和周期性库水位涨落等诱发因素作用下,某些库岸滑坡位移表现出加速变化和平稳变化交替进行的、近似单调增长的阶跃式变形特征(吴益平等,2014;Huang *et al.*,2017c).滑坡变形对当地居民生命财产安全造成严重威胁,而位移预测是滑坡稳定性评估和变形破坏预测的重要内容,因此,本文尝试建立一种考虑诱发因素的新型滑坡位移预测模型。

目前,已有一些非线性模型如灰色模型(Gao and Feng,2004)、协同预测模型(许强等,2008),分形理论(樊晓一,2011)、混沌模型(周翠英等,2008)、指数平滑法(卢继强和徐峰,2011)等用于滑坡位移预测,其中混沌模型被广泛用于滑坡位移序列的混沌特性识别及定量预测(Qin *et al.*,2002);然而现有的用于滑坡位移预测的混沌模型大都是未考虑诱发因素的单变量混沌模型(Huang *et al.*,2016;周翠英等,2008),虽然单变量混沌模型认为只需要对滑坡位移系统中位移时间序列这一分量选择合适的延迟时间和嵌入维,即可很好地重构位移序列的相空间并进行预测.但在实际应用中,由于滑坡位移监测数据有限、含有噪声且系统信息具有不完备性,直接将单变量混沌模型用于位移预测效果不佳(赵敏等,2008).因此,目前出现了许多考虑诱发因素的多变量模型,且这些缺乏混沌分析的常规多变量模型的预测效果优于单变量混沌模型(Cai *et al.*,2015;Zhou *et al.*,2015;Huang *et al.*,2016).

常规多变量模型在将月降雨量和月库水位变化量这两个因子用于单调递增的滑坡累积位移预测时,需要先将滑坡累积位移进行时间序列分解.现有研究(张俊等,2015)认为滑坡累积位移是在自身岩土条件和外部诱发因素共同作用下产生和发展的,

因此可将累积位移分解为反映边坡岩土自身条件的确定性的趋势项位移和诱发因素作用下的非线性的波动项位移;通过对累积位移进行时间序列分解,才能引入对滑坡位移具有重要影响的外部诱发因素.目前,已有多种时间序列分解模型如小波分析、经验模态分解(Lian *et al.*,2013)、多项式模型(汤罗圣和殷坤龙,2013)等用于累积位移分解,但这些时间序列分解模型的分解过程都是一次完成,把所有的累积位移序列作为输入变量,同时一次输出所有的子序列;其分解的实质是对已知数据的拟合而不是预测,所以这些分解模型不能用于时间序列预测.指数平滑法(卢继强和徐峰,2011)使用历史数据对待预测数据进一步滚动向前预测,可实现对累积位移的逐步预测,其预测结果反映了滑坡位移的确定性的趋势;通过从累积位移中减去趋势项位移,即可获得受降雨量、库水位变化量影响的波动项位移(熊莎等,2013).

构建月波动项位移和月降雨量、月库水位变化量之间的动态响应关系是选取模型有效输入变量,并对波动项位移进行预测的关键.但常规多变量模型对波动项位移与诱发因素间的动态响应关系研究不够深入,主要依靠经验性分析来选择模型的输入变量.而在单变量混沌模型基础上发展起来的多变量混沌模型(Garcia and Almeida,2005;王新迎和韩敏,2012;Chen and Han,2013)通过计算波动项位移及其诱发因素的延迟时间和嵌入维,能重构出比单变量混沌模型更为准确的位移相空间,为输入变量的选取提供了理论依据.相关研究表明,多变量混沌模型能有效提高混沌时间序列的预测精度(Huang *et al.*,2015;Nakamura *et al.*,2016).因此,本文在分析月波动项位移与月降雨量、月库水位变

化量之间的相关性的基础上,采用多变量混沌模型对波动项位移进行时间序列建模.

选择合适的模型作为已建立的多变量混沌模型的预测器非常重要,目前常用的预测器主要有线性回归(雷绍兰等,2006)、神经网络(周翠英等,2005)和支持向量机(Huang *et al.*,2017a)等.传统神经网络存在局部最优、预测效果不理想等缺点.支持向量机(support vector machine,SVM)能克服传统神经网络存在的缺点,且常用粒子群算法(particle swarm optimization,PSO)来选取 SVM 模型的参数(谭琨等,2015).同时,最新发展起来的极限学习机(extreme learning machine,ELM)模型(Huang *et al.*,2017b,2017d,2006)也克服了传统神经网络的缺点,其在多个领域得到了成功的应用(Li *et al.*,2016).因此,本文将 ELM 模型作为多变量混沌模型的预测器,构建指数平滑多变量混沌 ELM 模型,以三峡库区白水河滑坡 ZG93 GPS 监测点的累积位移为例,并与指数平滑多变量混沌 PSO-SVM 模型和指数平滑单变量混沌 ELM 模型进行对比.

1 指数平滑多变量混沌 ELM 模型原理

1.1 模型流程

流程主要包含 4 步:(1)用最大 Lyapunov 指数法识别滑坡累积位移混沌特性;(2)用指数平滑法将

累积位移分解为趋势项和波动项位移;(3)识别波动项位移混沌特性,并将其与诱发因素进行多变量相空间重构,之后用 ELM 模型预测波动项位移;(4)将趋势项和波动项位移的预测值相加,得到最终累积位移预测值,如图 1 所示.

1.2 累积位移单变量混沌分析

混沌系统的长期演化结果不可预测,但如果通过非线性模型计算出混沌系统的内在确定性法则,则可预测出其短期行为.常规单变量相空间重构理论(Takens,1981)为混沌系统预测提供了一种思路:对于混沌系统,只需通过计算这个系统中的一个分量的延迟时间和嵌入维,来重构出原始系统的确定性法则,即可再用非线性模型对这个确定性法则进行预测.

1.2.1 单变量相空间重构 设累积位移序列 $C_i (i = 1, 2, \dots, N)$, 通过相空间重构将单变量位移序列转化为多变量的位移动力系统:

$$Y_i = \{C_i, C_{i-1}, \dots, C_{i-(m-1)}, \tau\}, \quad (1)$$

式中: $Y_i [i = 1 + (m - 1)\tau, \dots, N - 1]$ 是重构得到的相点, N 是位移序列长度; τ 是延迟时间,指系统平均记忆时间; m 是嵌入维,指描述混沌系统所需的最小状态变量; τ 和 m 的选择是相空间重构成功与否的关键参数.

计算 τ 的方法主要有互信息和相关系数法,但这两种方法更适合于无噪声的长时间序列,对实际

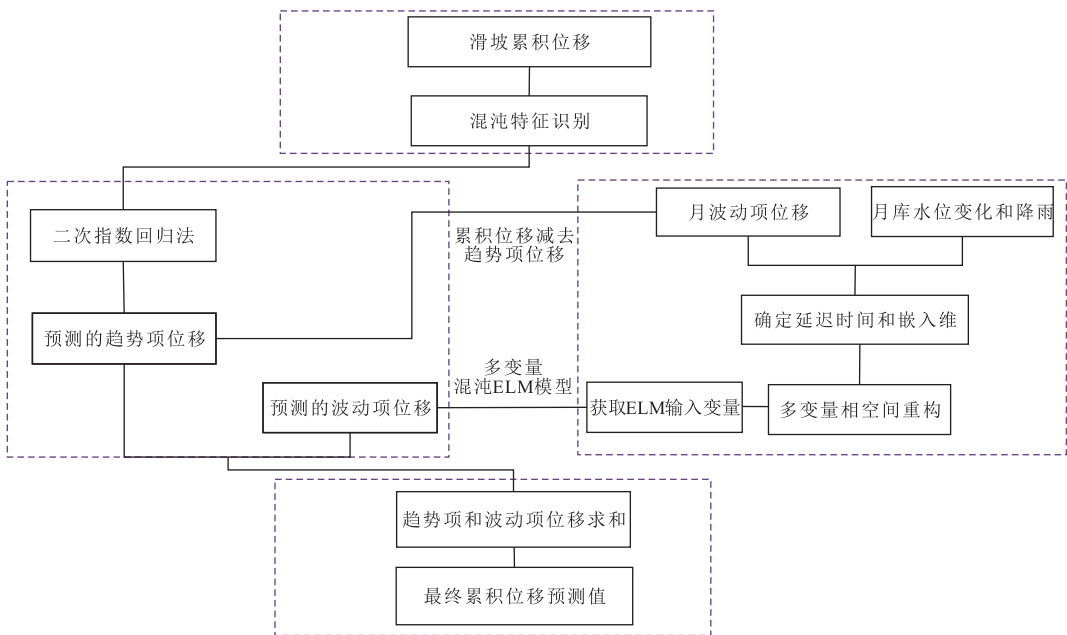


图 1 指数平滑多变量混沌 ELM 模型流程

Fig.1 Flow chat of the coupling DES and multivariable chaotic ELM model

监测获得的较短时间序列并不十分适用,且一个较大的 τ 值会增大非线性模型预测的复杂度,降低预测精度.已有研究(黄发明和田玉刚,2014;黄发明等,2015)表明,对于含有噪声的短时间序列,一个较小的 τ 值就能获得满意的预测结果,所以本文所有变量的 τ 值均设为 1.同时,一个太大或者太小的 m 值均会导致重构的相空间不准确,预测结果不理想.目前常用的嵌入维计算主要是 Cao 法和假近邻点法(false nearest neighbor, FNN) (Hegger and Kantz, 1999),其中 FNN 法因较适用于含噪声的短时间序列而被本文采用.

1.2.2 混沌特性识别 混沌定量识别主要通过计算混沌系统奇异吸引子的特征参数来实现,刻画奇异吸引子的参数主要包括描述邻近轨道发散率的最大 Lyapunov 指数(杨永国和陈玉华,2009)、描述吸引子维数的关联维(Pijn *et al.*, 1991)和反映时间序列信息产生频率的 Kolmogorov 熵(Rosenstein *et al.*, 1993).本文将最大 Lyapunov 指数用于滑坡累积位移和波动项位移的混沌识别,如果位移序列存在混沌特性,那么计算出的最大 Lyapunov 指数将大于 0;否则表明滑坡位移中不存在混沌特性.常用于最大 Lyapunov 指数计算的方法主要有 Wolf 法和小数据量法等(Wapenaar, 2004).小数据量法对短时间序列的最大 Lyapunov 指数计算效果较好,其计算步骤如下:

(1)对某序列 $\{x(i), i=1, 2, \dots, N\}$ 快速傅里叶变换,计算其延迟时间 τ 和平均周期 p ;

(2)用 FNN 法计算其嵌入维 m 并重构其相空间 $X(t) =$

$\{x(t), x(t-\tau), \dots, x(t-(m-1)\tau)\}$, 式中: $t=1+(m-1)\tau, \dots, M; M=N-1$;

(3)找出相点 $X(t)$ 的最近邻点 $X(\hat{t})$ 并限制短暂分离:

$$d_t(0) = \min_{\hat{t}} \|X(t) - X(\hat{t})\|, |t - \hat{t}| > p, \quad (2)$$

式中: $\hat{t}=1+(m-1)\tau, \dots, M$, 且 $t \neq \hat{t}$;

(4)对每个相点 $X(t)$, 计算该领域点对的 ρ 个离散时间步后的距离 $d_t(\rho)$:

$$d_t(\rho) = \|X(t+\rho) - X(\hat{t}+\rho)\|, \quad (3)$$

式中: $\rho=1+(m-1)\tau, \dots, \min(M-t, M-\hat{t})$;

(5)对每个 ρ 求出所有 t 的 $\ln d_t(\rho)$ 平均值 $x(\rho)$:

$$x(\rho) = \frac{1}{q\Delta t} \sum_{\rho=1}^q \ln_t(\rho), \quad (4)$$

式中: q 为非零 $d_t(\rho)$ 的数目,可采用最小二乘法做出回归直线,该直线的斜率就是最大 Lyapunov 指数值.

1.3 指数平滑法

指数平滑法(卢继强和徐峰,2011)是将预测值看作之前观测值的加权和,对越靠近当前预测值的数据给予的权重就越大.一次指数平滑适用于预测在一定范围内波动的时间序列,如式(5)所示;二次指数平滑是对一次指数平滑的再平滑,适用于具有趋势性的时间序列,如式(6)所示.本文用二次指数平滑法预测滑坡累积位移,预测结果为趋势项位移.

$$T_{i-1} = \alpha C_{i-2} + (1-\alpha)T_{i-2}, \quad (5)$$

$$T_i = \alpha C_{i-1} + (1-\alpha)C_{i-2} + (1-\alpha)^2 T_{i-2}, \quad (6)$$

上式中: C_{i-2} 和 C_{i-1} 分别是第 $i-2, i-1$ 月份的累积位移; T_{i-2}, T_{i-1} 和 T_i 分别表示第 $i-2, i-1, i$ 月份的趋势项位移; $\alpha \in (0, 1)$ 为平滑指数,本文平滑指数均设为 0.8.

1.4 多变量相空间重构

在对累积位移进行时间序列分解的基础上,探讨诱发因素对波动项位移的作用关系,只有当诱发因素对波动项位移具有显著影响时,才可对加入诱发因素的波动项位移系统进行多变量相空间重构;否则只能对波动项位移序列进行单变量相空间重构.波动项位移单变量相空间重构如下所示:

$$V_i = [P_{1,i}, P_{1,i-\tau_1}, \dots, P_{1,i-(m_1-1)\tau_1}], \quad (7)$$

式中: $V_i [i=1+(m_1-1)\tau_1, \dots, N-1]$ 为重构得到的相点; $P_{1,i}$ 为波动项位移; τ_1 和 m_1 分别是波动项位移的延迟时间和嵌入维.设加入诱发因素的波动项位移系统为 $\{P_{1,i}, P_{2,i}, P_{\lambda,i}, \dots, P_{M,i}\}_{i=1}^N (\lambda=1, 2, \dots, M)$, 其多变量相空间重构(雷绍半等,2006)为:

$$V_i^* = \left\{ \begin{array}{l} P_{1,i}, P_{1,i-\tau_1}, P_{1,i-2\tau_1}, \dots, P_{1,i-(m_1-1)\tau_1} \\ P_{2,i}, P_{2,i-\tau_2}, P_{2,i-2\tau_2}, \dots, P_{2,i-(m_2-1)\tau_2} \\ P_{\lambda,i}, P_{\lambda,i-\tau_\lambda}, P_{\lambda,i-2\tau_\lambda}, \dots, P_{\lambda,i-(m_\lambda-1)\tau_\lambda} \\ \dots \\ P_{M,i}, P_{M,i-\tau_M}, P_{M,i-2\tau_M}, \dots, P_{M,i-(m_M-1)\tau_M} \end{array} \right\}, \quad (8)$$

式中: $i = j_0, j_0 + 1, \dots, N; j_0 = \text{Max}_{1 \leq \lambda \leq M} \{(m_\lambda - 1)\tau_\lambda + 1\}$, τ_λ, m_λ 表示各个变量的延迟时间和嵌入维.当 $m = \sum_{\lambda=1}^M m_\lambda$ 或 m_λ 足够大时,对于位移变量存在一个确定性的函数 $f: V_i^* \rightarrow P_{1,i+1}$:

$$P_{1,i+1} = f(V_i^*) . \tag{9}$$

若已知 $f(V_i^*)$ 的确定性函数形式,便可对 $P_{1,i+1}$ 进行预测.多变量相空间重构成功与否的关键也在于延迟时间和嵌入维的选择,本文选取各个变量的延迟时间为 1,同时也用 FNN 法分别计算波动项位移、月降雨量和月库水位变化的嵌入维.

1.5 极限学习机

ELM 模型(Huang *et al.*, 2006)是 2006 年提出的一种新的前馈神经网络,该方法随机产生输入层与隐含层的连接权值及隐含层神经元的阈值,在训练过程中只需设置隐含层神经元的个数,便可获得唯一最优解.ELM 的训练和预测过程需先将原始数据归一化至 $[0, 1]$,且 ELM 预测结果需进行反归一化处理以得到真实的预测值.设有任意 N 个不同样本 (x_i, t_i) ,其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n, t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$,则具有 M 个隐含层神经元和激励函数 $g(x)$ 的标准单隐层前馈神经网络可表示为:

$$\sum_{i=1}^M \beta_i g(W_i X_j + b_i) = O_j, j = 1, \dots, N, \tag{10}$$

式中: $W_i = [W_{i1}, W_{i2}, \dots, W_{in}]^T$ 为输入层节点与第 i 个隐含层节点间的连接权值; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 为隐含层第 i 节点和输出层节点间的连接权值; b_i 为隐含层第 i 个神经元的阈值; $W_i X_j$ 为 W_i 与 X_j 的内积; $O_j = [O_{j1}, O_{j2}, \dots, O_{jm}]^T$ 为网络输出值.具有 M 个隐含层神经元和激励函数 $g(x)$ 的标准单隐层前馈神经网络可以零误差逼近训练样本,即: $\sum_{i=1}^M \|o_j - t_j\| = 0$,因此存在 β_i, w_i, b_i 使得:

$$\sum_{i=1}^M \beta_i g(w_i x_i + b_i) = y_j, j = 1, \dots, N, \tag{11}$$

式(11)可表示为:

$$H\beta = Y, \tag{12}$$

$$H(w_1, \dots, w_M, b_1, \dots, b_M, x_1, \dots, x_M) =$$

$$\begin{bmatrix} g(w_1 x_1 + b_1) & \dots & g(w_M x_1 + b_M) \\ \vdots & \dots & \vdots \\ g(w_1 x_N + b_1) & \dots & g(w_M x_N + b_M) \end{bmatrix}_{N \times M} . \tag{13}$$

H 为神经网络输出矩阵, H 的列是第 i 个隐层神经元对输入样本 x_1, x_2, \dots, x_N 的输出向量.由于固定了随机选定的输入权值和隐层阈值,网络训练等于求解式(14)的最小二乘解 $\hat{\beta}$:

$$\min_{\beta} \|H\beta - Y\|, \tag{14}$$

理论证明,上述线性系统最小二乘解的最小值是:

$$\hat{\beta} = H^+ Y, \tag{15}$$

其中: H^+ 为隐含层输出矩阵 H 的 Moore-Penrose

广义逆.

1.6 模型预测精度评估

对于不同模型的波动项位移预测值,采用均方根误差(RMSE)和拟合系数(R^2)两个指标来评定模型预测精度:

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N_0} (P_{1,i} - \hat{P}_{1,i})^2}{\hat{N}}}, \tag{16}$$

$$R^2 = 1 - \frac{N_0 \sum (P_{1,i} - \hat{P}_{1,i})^2}{N_0 \sum P_{1,i}^2 - \sum \hat{P}_{1,i}^2}, \tag{17}$$

式中: $P_{1,i}$ 和 $\hat{P}_{1,i}$ 分别表示原始波动项位移值和反归一化之后获得的波动项位移预测值; \hat{N} 表示用于模型测试的波动项位移数量.

2 指数平滑多变量混沌 PSO-SVM 模型

指数平滑多变量混沌 PSO-SVM 模型建立在滑坡位移混沌识别和多变量相空间重构的基础之上,用 PSO-SVM 替代指数平滑多变量混沌 ELM 模型中的 ELM 对重构后的波动项位移进行预测.因此,其输入输出变量与指数平滑多变量混沌 ELM 模型一致. SVM 模型是在统计学习理论和结构风险最小化原则基础上发展起来的,它在解决小样本及非线性问题中表现出许多优势.本文 SVM 采用径向基函数作为核函数,其预测性能与误差惩罚因子 c 、不敏感损失系数 ϵ 和核函数参数 ϕ 密切相关,本文运用 PSO 算法搜索 SVM 3 个参数的最佳组合(谭琨等, 2015).

(1)确定 PSO 算法的参数:每个粒子的维数为 3,种群大小为 100,迭代次数为 100,在一定范围内随机确定每个粒子的初始位置向量; SVM 预测值的均方根误差作为 PSO 算法的适应度函数;

(2)进行迭代计算,通过比较各个粒子的个体最优值和全局最优值来更新粒子位置向量;

(3)达到最大迭代次数时,迭代结束,此时获得的位置向量即是所求的 SVM 模型的最佳参数组合.

3 白水河滑坡实例分析

3.1 滑坡工程地质概况

白水河滑坡位于三峡库区秭归县长江南岸,呈阶梯状向长江展布.该滑坡前缘高程约 70 m,后缘高程约 390 m,南北纵长约 780 m,东西宽约 700 m,滑体平均厚度约 30 m,总体积约为 $1\ 260 \times 10^4 \text{ m}^3$.坡体主要

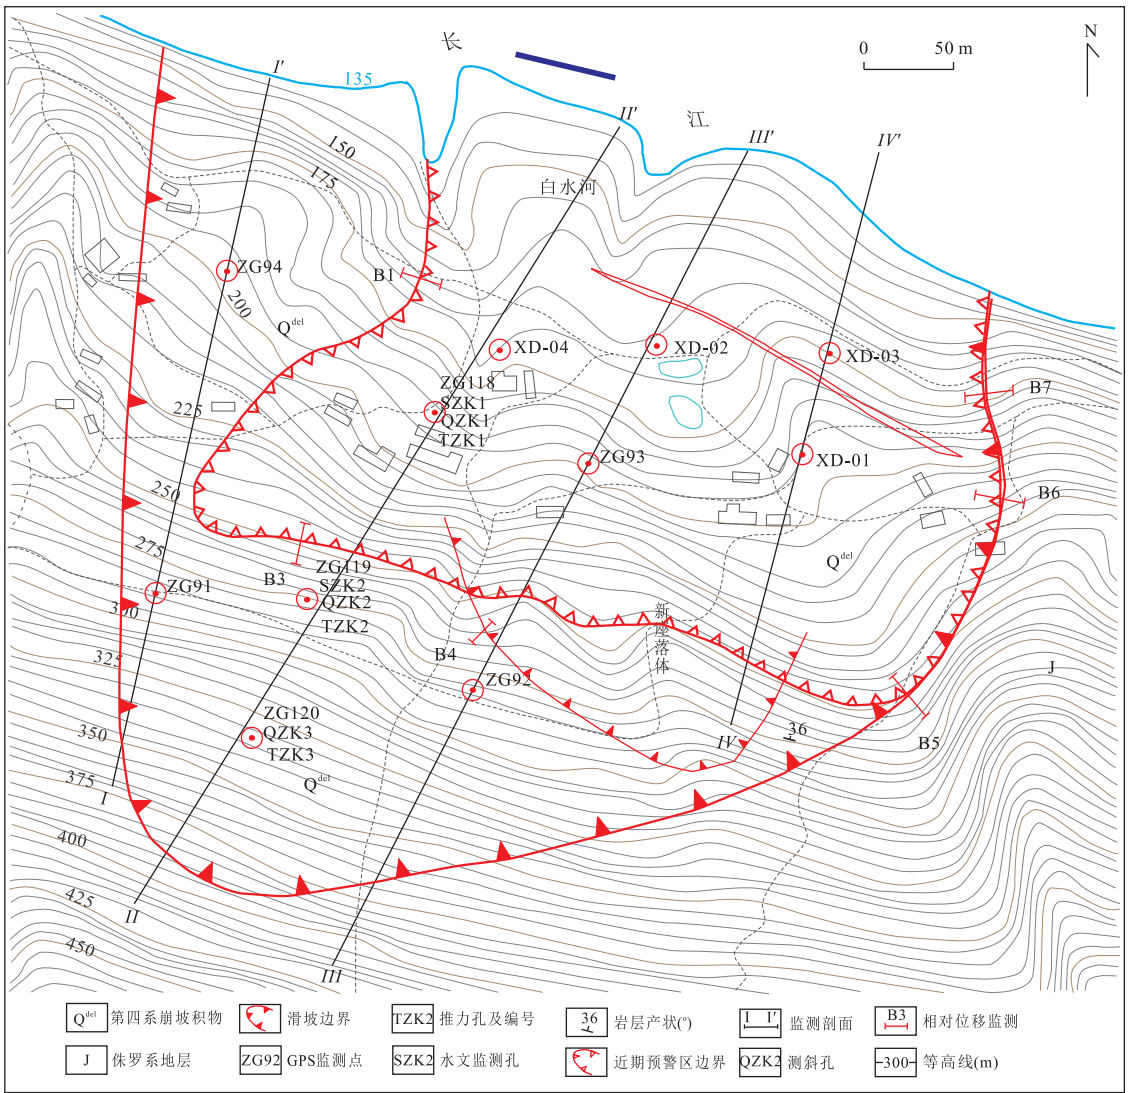


图 2 白水河滑坡平面图和监测点布置图

Fig.2 Topographical map of the Baishuihe landslide, with location of monitoring points




图 3 GPS 监测点累积位移值

Fig.3 GPS monitoring cumulative displacement values

由第四系残坡积土、堆积土组成,地层岩性为侏罗纪中厚层状砂岩夹薄层状泥岩,岩层产状 $15^{\circ} \angle 36^{\circ}$ 。

自 2003 年 6 月起,采用 GPS、雨量计等对滑坡的地表累积位移、降雨量进行监测,滑坡平面和监测点布置如图 2 所示.从 2003 年 6 月至 2009 年 8 月的滑坡累积位移监测值如图 3 所示,从图 3 可知,滑坡累积位移序列呈现出阶跃式的非线性变化特征.本文以 ZG93 点的 GPS 监测位移值作为实例分析,将 2003 年 11 月至 2007 年 12 月的 50 个值用于模型训练,从 2008 年 1 月至 2009 年 8 月的剩余的 20 个值用于模型测试.

3.2 累积位移混沌识别

采用最大 Lyapunov 指数识别累积位移混沌特性,选取延迟时间为 1;用 FNN 法计算累积位移的

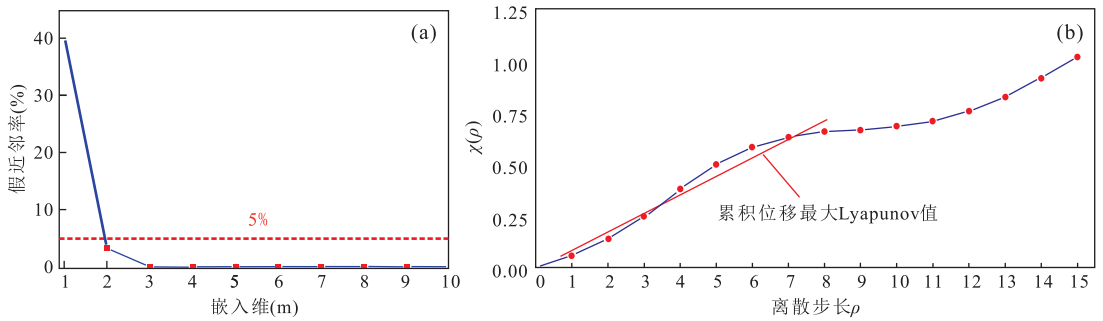


图 4 ZG93 监测点累积位移最佳嵌入维(a)和最大 Lyapunov 指数(b)

Fig.4 The optimal embedding dimension calculation result (a) and largest Lyapunov exponential value (b) of cumulative displacement of ZG93




图 5 二次指数平滑法提取滑坡趋势项和波动项位移

Fig.5 Time series decomposition of cumulative displacement of ZG93 using DES method

嵌入维, 阈值选取为 10, 当累积位移的假近邻率随着嵌入维数的增加首次低于 5% 时, 即认为此时的嵌入维是最佳嵌入维. 从图 4a 可知累积位移最佳嵌入维 $m=2$, 重构其相空间为:

$$Y_i = \{C_i, C_{i-1}\} \quad (18)$$

再用小数据量法计算累积位移最大 Lyapunov 指数如图 4b 所示: 横坐标是离散时间步长 ρ , 纵坐标表示两个近邻点在 ρ 离散时间步长之后的平均离散距离; 红色斜线是对 $\rho=2, 3, \dots, 8$ 这一段曲线的最小二乘拟合, 其斜率即是最大 Lyapunov 指数值. 结果显示累积位移的最大 Lyapunov 指数为 0.063 8, 大于 0, 证明 ZG93 监测点累积位移序列存在混沌特性.

3.3 指数平滑法分解累积位移

二次指数平滑法首先按式(19)将 C_i 赋值给 T_1 , 再按式(20)对累积位移进行预测, 预测值为趋

势项位移; 最后按式(21), 用累积位移减去趋势项位移, 即得到月波动项位移. 累积位移时间序列分解结果如图 5 所示.

$$T_1 = C_1, \quad (19)$$

$$T_i = 0.8C_{i-1} + 0.16C_{i-2} + 0.04T_{i-2}, \quad (20)$$

$$P_{1,i} = C_i - T_i. \quad (21)$$

3.4 波动项位移诱发因素分析

滑坡波动项位移及其诱发因素如图 6 所示, 从图中可知, 白水河滑坡变形与月降雨量密切相关. 波动项位移快速增长期基本都发生在雨季, 在旱季滑坡变形较小. 如 2007 年 5—8 月降雨量较大, 同期最大波动项位移达 630 mm; 而在 2008 年 1—3 月降雨量较小, 此时波动项位移接近 0. 图中也反映出波动项位移与库水位变化量之间具有较大的相关性, 当库水位从低水位上升至较高水位时, 滑坡变形较小; 当库水位从高水位下降至较低水位时, 滑坡开始发生较大变形. 如从 2006 年 11 月—2007 年 9 月库水位为 155 m, 此时滑坡变形较小; 但是在库水位快速下降至 140 m 时, 滑坡波动项位移值达到将近 680 mm.

同时, 图中显示强降雨季节也是库水位较低的时期, 因此降雨量和库水位的综合作用对波动项位移具有较强的叠加效应. 如 2007 年 4 月至 9 月, 滑坡处于雨季, 同时库水位也从 140 m 降低至 135 m, 导致波动项位移快速增大. 上述分析表明波动项位移是在降雨量和库水位变化量两个外部诱发因素共同作用下的一个非线性系统, 同时也解释了某些库岸滑坡位移具阶跃式特征的原因, 即在周期性的强降雨和库水位变化联合作用下, 滑坡变形时急时缓, 交替进行.

3.5 多变量混沌 ELM 模型预测波动项位移

3.5.1 波动项位移混沌识别 设波动项位移延迟时




图 6 滑坡月波动项位移与月降雨量、月平均库水位相关性曲线

Fig.6 The correlation curve of periodic displacement and rainfall, reservoir water level of ZG93 point

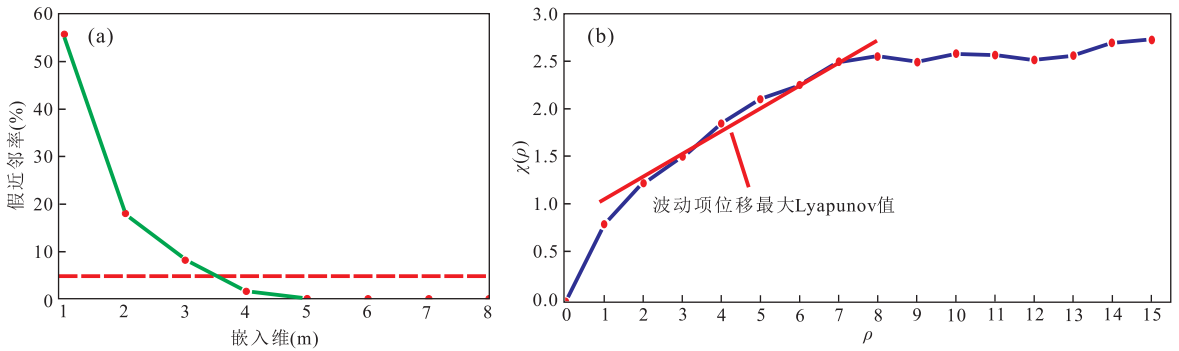


图 7 波动项位移最佳嵌入维(a)和最大 Lyapunov 指数值(b)

Fig.7 The optimal embedding dimension (a) and largest Lyapunov exponential value (b) of periodic displacement

间为 1, FNN 法阈值为 10, 计算其最佳嵌入维为 4, 如图 7a 所示, 并重构波动项位移单变量相空间如式 (22) 所示. 在此基础上采用小数据量法计算得到波动项位移的最大 Lyapunov 指数为 0.173 4, 如图 7b 所示, 表明 ZG93 监测点波动项位移存在混沌特性.

$$V_i = \{P_{1,i}, P_{1,i-1}, P_{1,i-3}\}, \quad (22)$$

式中: $V_i (i=4, 5, \dots, 69)$ 为波动项位移单变量重构的相点.

3.5.2 波动项位移多变量相空间重构 基于波动项位移的混沌识别及其与诱发因素间的较强相关性, 可重构出波动项位移的多变量相空间. 其中各变量延迟时间 $\tau_1 = \tau_2 = \tau_3 = 1$, 波动项位移最佳嵌入维 $m_1 = 4$; 采用 FNN 法, 为了避免引入冗余信息, 设阈值为 50, 计算月降雨量和月库水位变化量的最佳嵌入维如图 8 所示, 结果显示月降雨量最佳嵌入维 $m_2 = 2$, 月库水位变化量最佳嵌入维 $m_3 = 3$. 重构的

多变量相空间如下:

$$V_i^* = \left\{ \begin{matrix} P_{1,i}, P_{1,i-1}, P_{1,i-2}, P_{1,i-3} \\ P_{2,i}, P_{2,i-1} \\ P_{3,i}, P_{3,i-1}, P_{3,i-2} \end{matrix} \right\}, \quad (23)$$

式中: $V_i^* (i=4, 5, \dots, 69)$ 为重构的多变量相点; $P_{2,i}$ 和 $P_{3,i}$ 分别为月降雨量和月库水位变化量.

3.5.3 ELM 和 PSO-SVM 预测波动项位移 在多变量相空间重构的基础上, 对波动项位移进行预测, 多变量相空间 V_i^* 即是 ELM 和 PSO-SVM 模型的输入变量, $P_{1,i+1}$ 是模型的输出变量. 当映射函数 $f: V_i^* \rightarrow P_{1,i+1}$ 被 ELM 或 PSO-SVM 模型确定时, 波动项位移就能被预测:

$$P_{1,i+1} = \text{ELM}(V_i^*), P_{1,i+1} = \text{SVM}(V_i^*). \quad (24)$$

对于多变量混沌 ELM 模型, 本文采用试错法 (Basheer and Hajmeer, 2000) 来选取最佳隐含层神经元个数, 以 ELM 预测结果的均方根误差最小为

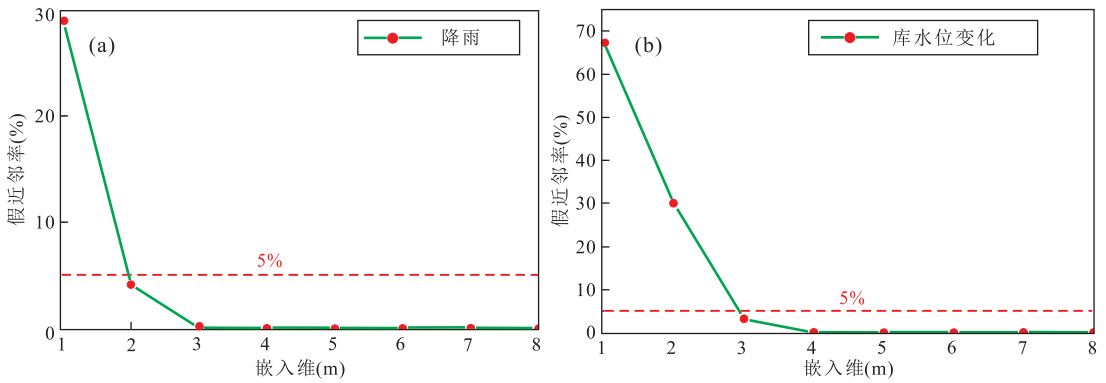


图 8 月降雨量(a)和月库水位变化量(b)的嵌入维

Fig.8 Optimal embedding dimensions of monthly rainfall (a) and monthly water level change (b)

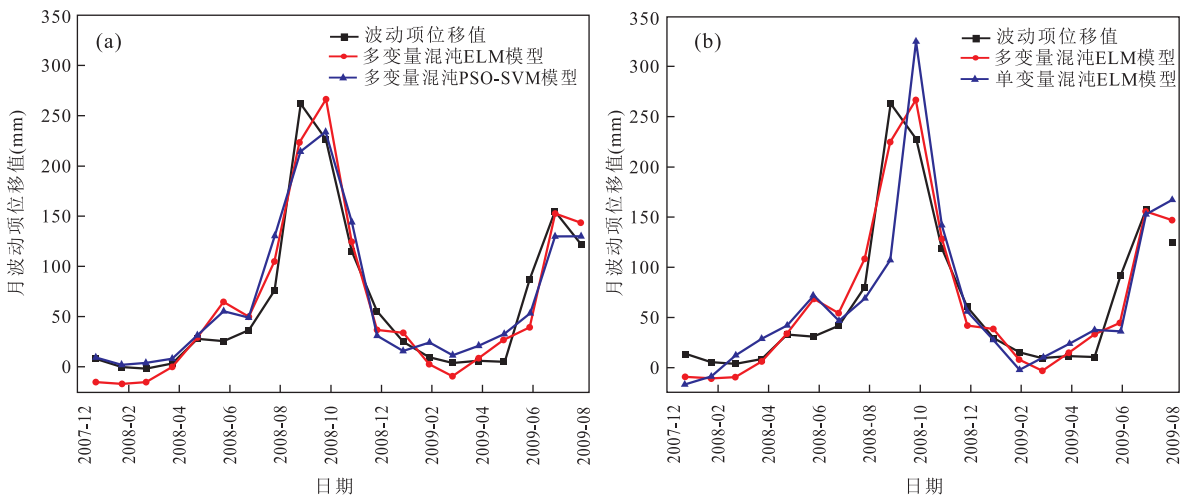


图 9 不同模型的月波动项位移预测值对比

Fig.9 Comparison between predicted and measured periodic displacement by different models

目标,将隐含层神经元个数从 2 增加至 20,结果显示当隐含层神经元个数为 9 时,ELM 预测误差最小.对于多变量混沌 PSO-SVM 模型,得到 SVM 模型的参数为: $c = 3.084$ 、 $\epsilon = 0.002$ 和 $\phi = 0.189$.同时也采用单变量混沌 ELM 模型对波动项位移进行预测,将单变量相空间 V_i 作为 ELM 模型输入变量, $P_{1,i+1}$ 是模型的输出变量,ELM 隐含层神经元数目为 5.

月波动项位移最终预测结果如图 9 和表 1 所示.从中可知,对于波动项位移预测,多变量混沌 ELM 模型预测效果略优于多变量混沌 PSO-SVM 模型,而单变量混沌 ELM 模型预测效果不太理想,尤其是在波动项位移发生突变的情况下预测效果较差.

3.6 累积位移最终预测值

将波动项位移与趋势项位移预测值相加,如式(25)所示,即可得到最终累积位移预测值如图 10 所

表 1 波动项位移预测模型精度对比

Table 1 Prediction performance comparison of periodic displacement by different models

Models	RMSE(mm)	R^2
多变量混沌 ELM	23.71	0.908
单变量混沌 ELM	47.67	0.661
多变量混沌 PSO-SVM	24.86	0.898

示.从图 10 中可知,指数平滑多变量混沌 ELM 和指数平滑多变量混沌 PSO-SVM 模型均能准确地预测出滑坡累积位移的阶跃式变化特征,而指数平滑单变量混沌 ELM 模型预测结果较差且存在滞后效应.

$$\hat{C}_{i+1} = 0.8C_i + 0.16C_{i-1} + 0.04T_{i-1} + f_1(V_i^*), \quad (25)$$

式中: \hat{C}_{i+1} ($i = 4, 5, \dots, 70$) 表示预测得到的累积位移值.

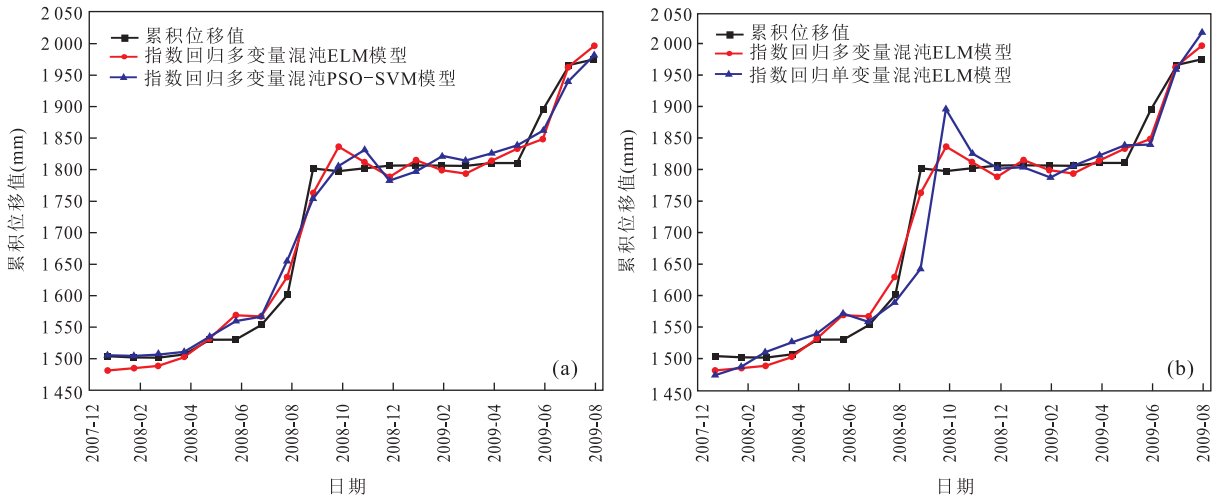


图 10 滑坡最终累积位移预测结果对比

Fig.10 Comparison of predicted and measured cumulative displacement

4 讨论

本文提出指数平滑多变量混沌 ELM 模型并将其用于白水河滑坡 ZG93 监测点的累积位移预测。混沌识别结果显示,滑坡累积位移和波动项位移的最大 Lyapunov 指数分别为 0.063 8 和 0.173 4,说明 ZG93 监测点位移是一个混沌序列,可用混沌模型对其进行预测。

本文发现月降雨量和月库水位变化量对白水河滑坡波动项位移具有重要影响,因此可将多变量混沌 ELM 模型用于波动项位移预测,本文波动项位移、月降雨量和月库水位变化量的延迟时间 $\tau_1 = \tau_2 = \tau_3 = 1$,最佳嵌入维分别为 $m_1 = 4, m_2 = 2, m_3 = 3$ 。反映出前四个月的波动项位移、前两个月的月降雨量和前三个月的库水位变化量对滑坡波动项位移影响较大,是滑坡周期性波动的重要诱因,可将这 9 个变量作为多变量混沌 ELM 模型的输入变量对波动项位移值进行预测。由此可见,多变量相空间重构将滑坡波动项位移及其诱发因素的原始系统空间重构出来,从理论上得到了非线性模型的输入变量,改变了常规多变量模型的经验性变量选取方式。

波动项位移预测结果显示:多变量混沌 ELM 模型预测精度优于多变量混沌 PSO-SVM 模型和单变量混沌 ELM 模型,ELM 模型需要选取的参数只有隐含层神经元数目,比 SVM 模型建模更简单快速;同时多变量混沌 ELM 模型克服了单变量混沌 ELM 模型难以预测突变信息和抗噪能力不强的缺点,揭示了滑坡阶跃式变形的根本原因。尽管本文模型预测效果尚可,仍有待改进:(1)滑坡位移及诱

发因素的监测频率均为一个月,难以实时细致的反应滑坡位移演化过程,下一步考虑用更小尺度的数据进行分析;(2)获取的位移序列长度有限,模型得不到充分训练;(3)需考虑地下水位、滑坡加卸载等更多诱发因素对滑坡位移的影响。

5 结论

本文在对库岸滑坡累积位移运用二次指数平滑法进行时间序列分解,以及分析波动项位移诱发因素的基础上,将多变量混沌模型引入波动项位移预测中。实例分析表明白水河滑坡 ZG93 监测点的累积位移和波动项位移序列中存在混沌特性,指数平滑多变量混沌 ELM 模型准确预测出了滑坡累积位移的非线性演化过程,具有明确的物理意义。本文主要贡献在于:将预测滑坡波动项位移的单变量混沌 ELM 模型改进为多变量混沌 ELM 模型,首次运用多变量相空间重构理论构建月降雨量、月库水位变化量和月波动项位移之间的动态响应关系,为非线性模型的输入变量选取提供了理论依据。

致谢:本文感谢中国地质调查局地质灾害防治与地质环境保护支撑计划山地丘陵区地质灾害调查工程三峡库区地质灾害监测预警二级项目(No. 0431203),国家自然科学基金项目(No.41572292),以及江西省自然科学基金项目(No. 20161RAR206126)。

References

Basheer, I. A., Hajmeer, M., 2000. Artificial Neural Net-

- works: Fundamentals, Computing, Design, and Application. *Journal of Microbiological Methods*, 43 (1): 3 — 31. [https://doi.org/10.1016/s0167-7012\(00\)00201-3](https://doi.org/10.1016/s0167-7012(00)00201-3)
- Cai, Z. L., Xu, W. Y., Meng, Y. D., et al., 2015. Prediction of Landslide Displacement Based on GA-LSSVM with Multiple Factors. *Bulletin of Engineering Geology and the Environment*, 75 (2): 637 — 646. <https://doi.org/10.13039/501100001809>
- Chen, D. Y., Han, W. T., 2013. Prediction of Multivariate Chaotic Time Series via Radial Basis Function Neural Network. *Complexity*, 18 (4): 55 — 66. <https://doi.org/10.1002/cplx.21441>
- Fan, X. Y., 2011. Landslide Displacement Multifractal and Its Application to Prediction of Evolvement Trend. *Rock and Soil Mechanics*, 32 (6): 1831 — 1837 (in Chinese with English abstract). <https://doi.org/10.3969/j.issn.1000-7598.2011.06.038>
- Gao, W., Feng, X. T., 2004. Study on Displacement Predication of Landslide Based on Grey System and Evolutionary Neural Network. *Rock and Soil Mechanics*, 25 (4): 514 — 517.
- Garcia, S. P., Almeida, J. S., 2005. Multivariate Phase Space Reconstruction by Nearest Neighbor Embedding with Different Time Delays. *Physical Review E*, 72 (2): 027205. <https://doi.org/10.1103/physreve.72.027205>
- Hegger, R., Kantz, H., 1999. Improved False Nearest Neighbor Method to Detect Determinism in Time Series Data. *Physical Review E*, 60 (4): 4970 — 4973. <https://doi.org/10.1103/physreve.60.4970>
- Huang, F. M., Yin, K. L., Zhang, G. R., et al., 2015. Prediction of Groundwater Level in Landslide Using Multivariable PSO-SVM Model. *Journal of Zhejiang University (Engineering Science)*, 49 (6): 1193 — 1200 (in Chinese with English abstract).
- Huang, F. M., Huang, J. S., Jiang, S. H., et al., 2017a. Landslide Displacement Prediction Based on Multivariate Chaotic Model and Extreme Learning Machine. *Engineering Geology*, 218: 173 — 186. <https://doi.org/10.1016/j.enggeo.2017.01.016>
- Huang, F. M., Huang, J. S., Jiang, S. H., et al., 2017b. Prediction of Groundwater Levels Using Evidence of Chaos and Support Vector Machine. *Journal of Hydroinformatics*, 19 (4): 586 — 606. <https://doi.org/10.2166/hydro.2017.102>
- Huang, F. M., Luo, X. Y., Liu, W. P., 2017c. Stability Analysis of Hydrodynamic Pressure Landslides with Different Permeability Coefficients Affected by Reservoir Water Level Fluctuations and Rainstorms. *Water*, 9 (7): 450. <https://doi.org/10.13039/501100004763>
- Huang, F. M., Yin, K. L., Huang, J. S., et al., 2017d. Landslide Susceptibility Mapping Based on Self-Organizing-Map Network and Extreme Learning Machine. *Engineering Geology*, 223: 11 — 22. <https://doi.org/10.13039/501100001809>
- Huang, F. M., Tian, Y. G., 2014. WA-VOLTERRA Coupling Model Based on Chaos Theory for Monthly Precipitation Forecasting. *Earth Science*, 39 (3): 368 — 374 (in Chinese with English abstract).
- Huang, F. M., Yin, K. L., Zhang, G. R., et al., 2016. Landslide Displacement Prediction Using Discrete Wavelet Transform and Extreme Learning Machine Based on Chaos Theory. *Environmental Earth Sciences*, 75 (20): 1376. <https://doi.org/10.13039/501100004543>
- Huang, G. B., Zhu, Q. Y., Siew, C. K., 2006. Extreme Learning Machine: Theory and Applications. *Neurocomputing*, 70 (1/2/3): 489 — 501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- Lei, S. L., Sun, C. X., Zhou, Q., et al., 2006. The Research of Local Linear Model of Short-Term Electrical Load on Multivariate Time Series. *Proceedings of the CSEE*, 26 (2): 25 — 29 (in Chinese with English abstract).
- Li, A. J., Khoo, S., Lyamin, A. V., et al., 2016. Rock Slope Stability Analyses Using Extreme Learning Neural Network and Terminal Steepest Descent Algorithm. *Automation in Construction*, 65: 42 — 50. <https://doi.org/10.1016/j.autcon.2016.02.004>
- Lian, C., Zeng, Z. G., Yao, W., et al., 2013. Ensemble of Extreme Learning Machine for Landslide Displacement Prediction Based on Time Series Analysis. *Neural Computing and Applications*, 24 (1): 99 — 107. <https://doi.org/10.1007/s00521-013-1446-3>
- Lu, J. Q., Xu, F., 2011. Research on Prediction Model of Landslide Based on Exponential Smoothing Method and Regression Analysis. *Journal of Wuhan University of Technology*, 33 (10): 88 — 91 (in Chinese with English abstract).
- Nakamura, T., Tanizawa, T., Small, M., 2016. Constructing Networks from a Dynamical System Perspective for Multivariate Nonlinear Time Series. *Physical Review E*, 93 (3): 032323. <https://doi.org/10.13039/501100001691>
- Pijn, J. P., van Neerven, J., Noest, A., et al., 1991. Chaos or Noise in EEG Signals; Dependence on State and Brain Site. *Electroencephalography and Clinical Neurophysiology*, 79 (5): 371 — 381. [https://doi.org/10.1016/0013-4694\(91\)90202-f](https://doi.org/10.1016/0013-4694(91)90202-f)
- Qin, S. Q., Jiao, J. J., Wang, S. J., 2002. A Nonlinear Dynamical Model of Landslide Evolution. *Geomorphology*, 43 (1/2): 77 — 85. [https://doi.org/10.1016/s0169-555x\(01\)00122-2](https://doi.org/10.1016/s0169-555x(01)00122-2)
- Rosenstein, M. T., Collins, J. J., De Luca, C. J., 1993. A Practical Method for Calculating Largest Lyapunov Exponents from Small Data Sets. *Physica D: Nonlinear Phenomena*, 65: 29 — 38. [https://doi.org/10.1016/0167-2789\(93\)90328-y](https://doi.org/10.1016/0167-2789(93)90328-y)

- nomena*, 65(1/2): 117—134. [https://doi.org/10.1016/0167-2789\(93\)90009-p](https://doi.org/10.1016/0167-2789(93)90009-p)
- Takens, F., 1981. Detecting Strange Attractors in Turbulence. Springer, Germany.
- Tan, K., Zhang, Q. Q., Cao, Q., et al., 2015. Hyperspectral Retrieval Model of Soil Organic Matter Content Based on Particle Swarm Optimization-Support Vector Machines. *Earth Science*, 40(8): 1339—1345 (in Chinese with English abstract).
- Tang, L. S., Yin, K. L., 2013. A Study of Displacement Prediction of Progressive Landslide Based on the R/S Analysis Method. *Hydrogeology & Engineering Geology*, 40(3): 93—97 (in Chinese with English abstract).
- Wang, X. Y., Han, M., 2012. Multivariate Chaotic Time Series Prediction Based on Extreme Learning Machine. *Acta Physica Sinica*, 61(8): 97—105 (in Chinese with English abstract).
- Wapenaar, K., 2004. Retrieving the Elastodynamic Green's Function of an Arbitrary Inhomogeneous Medium by Cross Correlation. *Physical Review Letters*, 93(25): 254301. <https://doi.org/10.1103/physrevlett.93.254301>
- Wu, Y. P., Zhang, Q. X., Tang, H. M., et al., 2014. Landslide Hazard Warning Based on Effective Rainfall Intensity. *Earth Science*, 39(7): 889—895 (in Chinese with English abstract).
- Xiong, S., He, Y. G., Ji, F., et al., 2013. Application of Exponential Smoothing to Prediction of Deep Displacement in Foundation Pit. *Mining and Metallurgical Engineering*, 33(2): 5—7 (in Chinese with English abstract). <https://doi.org/10.3969/j.issn.0253-6099.2013.02.002>
- Xu, Q., Tang, M. G., Xu, K. X., et al., 2008. Research on Space-Time Evolution Laws and Early Warning-Prediction of Landslides. *Chinese Journal of Rock Mechanics and Engineering*, 27(6): 1104—1112 (in Chinese with English abstract).
- Yang, Y. G., Chen, Y. H., 2009. Chaotic Characteristic and Prediction for Water Inrush in Mine. *Earth Science*, 34(2): 258—262 (in Chinese with English abstract).
- Zhang, J., Yin, K. L., Wang, J. J., et al., 2015. Displacement Prediction of Baishuihe Landslide Based on Time Series and PSO-SVR Model. *Chinese Journal of Rock Mechanics and Engineering*, 34(2): 382—391 (in Chinese with English abstract).
- Zhao, M., Fan, Y. H., Sun, H., 2008. Chaos Local Forecasting of Electric Propulsion Ship Power Load on Multivariate Time Series. *Journal of System Simulation*, 20(11): 2797—2799, 2805 (in Chinese with English abstract).
- Zhou, C. Y., Chen, H., Zhu, F. X., 2008. Multivariable Chaotic Discrimination for Slope Evaluation According to Their Non-linear Displacement-Time Sequence. *Earth Science*, 33(3): 393—398 (in Chinese with English abstract).
- Zhou, C. Y., Yin, K., Huang, F., 2015. Displacement Prediction of Step-Like Landslide Based on the Response of Inducing Factors and Support Vector Machine. *Chinese Journal of Rock Mechanics and Engineering*, 2: 4132—4139.
- Zhou, C. Y., Zhang, L., Huang, X. Y., 2005. Classification of Rocks Surrounding Tunnel Based on Improved BP Network Algorithm. *Earth Science*, 30(4): 480—486 (in Chinese with English abstract).

附中文参考文献

- 樊晓一, 2011. 滑坡位移多重分形特征与滑坡演化预测. 岩土力学, 32(6): 1831—1837.
- 黄发明, 田玉刚, 2014. 混沌序列 WA-VOLTERRA 耦合模型在月降水量预测中的应用. 地球科学, 39(3): 368—374.
- 黄发明, 殷坤龙, 张桂荣, 等, 2015. 多变量 PSO-SVM 模型预测滑坡地下水位. 浙江大学学报(工学版), 49(6): 1193—1200.
- 雷绍兰, 孙才新, 周淑, 等, 2006. 电力短期负荷的多变量时间序列线性回归预测方法研究. 中国电机工程学报, 26(2): 25—29.
- 卢继强, 徐峰, 2011. 基于指数平滑法和回归分析的滑坡预报模型研究. 武汉理工大学学报, 33(10): 88—91.
- 谭琨, 张倩倩, 曹茜, 等, 2015. 基于粒子群优化支持向量机的矿区土壤有机质含量高光谱反演. 地球科学, 40(8): 1339—1345.
- 汤罗圣, 殷坤龙, 2013. 基于 R/S 分析方法的渐进式滑坡位移预测研究. 水文地质工程地质, 40(3): 93—97.
- 王新迎, 韩敏, 2012. 基于极端学习机的多变量混沌时间序列预测. 物理学报, 61(8): 97—105.
- 吴益平, 张秋霞, 唐辉明, 等, 2014. 基于有效降雨强度的滑坡灾害危险性预警. 地球科学, 39(7): 889—895.
- 熊莎, 贺跃光, 姬方, 等, 2013. 指数平滑法在基坑深层位移预测中的应用. 矿业工程, 33(2): 5—7.
- 许强, 汤明高, 徐开祥, 等, 2008. 滑坡时空演化规律及预警预报研究. 岩石力学与工程学报, 27(6): 1104—1112.
- 杨永国, 陈玉华, 2009. 矿井涌水量混沌特征与预测. 地球科学, 34(2): 258—262.
- 张俊, 殷坤龙, 王佳佳, 等, 2015. 基于时间序列与 PSO-SVR 耦合模型的白水河滑坡位移预测研究. 岩石力学与工程学报, 34(2): 382—391.
- 赵敏, Fan, Y. H., 孙辉, 2008. 电力推进船舶电力负荷的多变量混沌局部预测. 系统仿真学报, 20(11): 2797—2799, 2805.
- 周翠英, 陈恒, 朱凤贤, 2008. 边坡演化的非线性时间序列多元混沌判别. 地球科学, 33(3): 393—398.
- 周翠英, 张亮, 黄显艺, 2005. 基于改进 BP 网络算法的隧洞围岩分类. 地球科学, 30(4): 480—486.