Geomatics Science and Technology 测绘科学技术, 2025, 13(2), 84-91 Published Online April 2025 in Hans. <u>https://www.hanspub.org/journal/gst</u> https://doi.org/10.12677/gst.2025.132011

**Hans**汉斯

# 一种滑坡稳定性预测方法研究

# 王 超,毛龙栋,陈金勇,刘 亮

湖北省水文地质工程地质勘察院有限公司,湖北 武汉

收稿日期: 2025年3月7日; 录用日期: 2025年3月31日; 发布日期: 2025年4月8日

# 摘要

滑坡工程的稳定性关乎施工工程的安全健康状况,分析滑坡的变形监测数据,并进行准确的滑坡变形预测,对可能出现的安全隐患做出预判有很重要的意义。本文利用奇异谱分析(SSA, Singular Spectrum Analysis)方法分离出滑坡变形监测数据中的趋势项与周期项;利用神经网络与小波方法对趋势项与周期项进行预测与重构,二者结合得到重构后的预测值。最后通过施工工程中滑坡变形监测数据进行分析,预测结果表明经过奇异谱分析之后的小波 - 神经网络预测模型效果更加稳定,优于单独的小波 - 神经网络模型预测结果。

### 关键词

滑坡,稳定性,奇异谱分析,小波分析,变形预测

# **Research on a Landslide Stability Prediction Method**

#### Chao Wang, Longdong Mao, Jinyong Chen, Liang Liu

Hubei Hydrogeological Engineering Geological Survey Institute Co., Ltd., Wuhan Hubei

Received: Mar. 7<sup>th</sup>, 2025; accepted: Mar. 31<sup>st</sup>, 2025; published: Apr. 8<sup>th</sup>, 2025

# Abstract

The stability of landslide engineering is related to the safety and health status of construction projects. Analyzing the deformation monitoring data of landslides and making accurate predictions of landslide deformation are of great significance for predicting potential safety hazards. This article uses Singular Spectrum Analysis (SSA) to separate trend and period terms from landslide deformation monitoring data; Using neural networks and wavelet methods to predict and reconstruct trend and period terms, and combining the two to obtain the reconstructed predicted values. Finally, through the analysis of landslide deformation monitoring data in construction projects, the prediction results show that the wavelet neural network prediction model after singular spectrum analysis is more stable and superior to the prediction results of the standalone wavelet neural network model.

# **Keywords**

Landslide, Stability, Singular Spectrum Analysis, Wavelet Analysis, Deformation Prediction

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0). http://creativecommons.org/licenses/by/4.0/

C Open Access

# 1. 引言

滑坡一般指的是岩体或者土体,受到河流冲刷、人工生产生活、地下水活动、雨水侵泡等人工与自 然因素的影响,在重力作用下,沿着一定的软弱面或者软弱带,整体或者分散地顺着坡向下滑动的自然 现象。在建筑物、构筑物建造过程中,挖掘土体的堆积、废弃建筑垃圾的不合理堆放都会产生滑坡现象。 该现象的存在会威胁正在施工人员的生命财产安全,并且严重破坏建筑物与构筑物。因此如何科学合理 地预知潜在危险的存在,提前做好预防工作至关重要。关于滑坡体变形监测预测研究工作有过成熟的模 型且均应用在案例中,并且大都基于单模型预测,如较成熟的非等间隔灰色(Grey Model, GM)(1,1)模型, 神经网络模型,小波去噪模型等都取得了良好的预测效果[1]-[4]。变形监测数据受到多种因素影响,单一 模型缺乏整体考虑很难全面地反应误差影响。所以两种及以上单一模型构建组合模型成为近些年热门的 研究方向,不但克服了常见单模型预测中存在的问题,而且在预测效果与精度方面都有提升。如文献[5] 中介绍了灰色模型与多层前馈(Back Propagation, BP)神经网络模型在基坑沉降预测中的应用,利用灰色模 型的预测数据作为神经网络的输入训练样本,试验结果表明了该组合模型优于单模型;文献[6]中阐述了 采矿区沉降预测工作中利用小波函数的去噪能力,优先处理原始观测数据,再利用去噪后的数据建立非 等间隔模型,试验结果表明了该组合模型预测精度优于传统的非等间隔模型预测精度。

常规对滑坡体变形监测数据预测工作主要依据已知变形监测数据建模,对未来某一时刻变形进行预测。然而,由于滑坡体受到外界环境,地质条件,人为活动等多种因素的影响,获取的原始变形观测数据中包含噪声,该噪声的存在直接影响了预测模型的预测效果。基于奇异谱分析方法在频域与时频方面 对时间序列数据分离出不同频率成分,这样会增加提取有用信息的能力,分离出数据中噪声影响。本文综合考虑小波神经网络模型在抗差预测中效果较好,并利用奇异谱分析分离出不同频率信号,结合二者的优势构建了小波-奇异谱预测模型,并以某滑坡体变形监测工程数据为例验证组合模型的鲁棒性。

# 2. 三种模型原理

### 2.1. 奇异谱分析原理

奇异谱分析(Singular Spectrum Analysis, SSA)方法是近年来兴起的一种研究非线性时间序列数据和非 参数时间序列的数据处理方法,该方法基于奇异值分解理论,以该时间序列为基础生成轨迹矩阵,并以 此为基础随后采取求解特征值与特征向量,分离出原始数据中周期项、长期趋势项、噪声项各组成部分, 去除噪声项之后的部分重构时间序列数据完成具体任务。假设一组长度为 *N* 的时间序列数据  $X = \{x_i | i = 1, 2, \dots, N\}$ ,对该序列按照奇异谱分析流程操作为: (1) 轨迹矩阵生成,在原始长度为 N 的时间序列数据中,定义滑动窗口长度为 $L_p$ (一般取 $L_p < \frac{N}{2}$ ), 并令 $K_p = N - L_p + 1$ ;轨迹矩阵以数据列为分割对象,第一列索引为 $1 - L_p$ 之间的信号,第二列为 $2 - L_{p+1}$ , 第三例为 $3 - L_{p+2}$ ,第 $K_p$ 列信号索引列为 $K_p - N$ ,那么生成的轨迹矩阵如公式(1)所示:

$$X = \begin{bmatrix} x_1 & x_2 & x_3 & \cdots & x_{K_p} \\ x_2 & x_3 & x_4 & \cdots & x_{K_{p+1}} \\ x_3 & x_4 & x_5 & \cdots & x_{K_{p+2}} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{L_p} & x_{L_{p+1}} & x_{L_{p+2}} & \cdots & x_N \end{bmatrix}$$
(1)

(2) 奇异值分解。轨迹矩阵的特征值与特征向量计算过程中构建*C* = *XX*<sup>T</sup>, 计算 *C* 的特征值 λ<sub>i</sub> 与特征向量 *U*<sub>i</sub>。在特征值排顺序中,以最大数值作为表现位移观测时间序列数据的最大变化趋势,最小数值表示为噪声项。

设 $d = \min\{L, K\}$ ,定义 $V_i = X^T U_i / \sqrt{\lambda_i}$ ,此时轨迹矩阵的特征值与左、右特征向量就可表示为 $\sqrt{\lambda_i}$ 、 $U_i = V_i$ 。构建初等矩阵:

$$X_i = \sqrt{\lambda_i} U_i V_i^{\mathrm{T}} \tag{3}$$

轨迹矩阵就可表示为:

$$X = X_1 + X_2 + \dots + X_d \tag{4}$$

(3) 序列重构。原序列在 UK上的正交投影系数可以表示为第 k个时间主分量,有:

$$a_i^K = \sum x_{i+j} U_K^j, 0 \le i \le n - L, 0 \le j \le L - 1$$
(5)

式(5)中,  $a_i^K$ 表示序列为 $\{x_i + 1, x_i + 2, \dots, x_i + l\}$ 时,  $U_K$ 反映的时间演变模型所占权重。将通过  $U_K$ 与  $V_K$ 重构的成分记为 $x_i^K$ , 可表示为:

$$x_{i}^{K} = \begin{cases} \frac{1}{L} \sum_{j=1}^{L} a_{i-j}^{K} U_{j}^{K} & L \le i \le K \\ \frac{1}{i} \sum_{j=1}^{L} a_{i-j}^{K} U_{j}^{K} & 1 \le i \le L-1 \\ \frac{1}{n-i+1} \sum_{j=i-n+L}^{L} a_{i-j}^{K} U_{j}^{K} & K+1 \le i \le n \end{cases}$$
(6)

所有重构成分叠加后序列与原序列相同,即:

$$X_i = \sum_{K=1}^{K} x_i^K \tag{7}$$

#### 2.2. 小波神经网络模型结构

滑坡体位移观测信息中包含大量的噪声,导致准确预报位移较困难,利用神经网络的优势进行预测, 不仅提高了预测精度,而且预测的稳定性较好。在神经网络的基础之上,结合小波理论将神经网络模型 中的激励函数替换为小波函数,并将小波理论中的平移因子、尺度因子引入模型中,实现神经网络预测 能力大大提高,克服了神经网络抗差能力弱的缺点,二者结合充分吸取了各自优点构成组合模型。

在该组合模型中,时间序列信号正向传播与误差的反向回馈基本是同时工作,文中小波函数以及

Morlet 函数的激励函数,计算公式为:

$$\psi(f(x)) = e^{-f^2(x)} \cos\left(5\frac{f(x) - \beta}{\alpha}\right)$$
(8)

式(8)中  $\alpha$  维尺度因子,  $\beta$  为平移因子, f(x) 为加权和。由此经过输入层与隐含层节点值、权值的乘 积即可得到输出层:

$$y(k) = \sum_{i=1}^{i} w_{ik} h(i), \quad k = 1, 2, \cdots, m$$
 (9)

式(9)中, m 表示输出层节点数, h(i)表示第 i 个隐含层的节点输出, w<sub>ik</sub> 表示隐含层到输出层的权值。 通过梯度修正算法不断改进三层之间的权值与小波激励函数中参数数值,这样使得组合模型中的输出层 输出值不断与期望输出值逼近,使其达到减小预测误差的能力。小波神经网络中参数为达到最优值优化 步骤如下:

(1) 模型中各参数初始化。包括各结构层之间的权值 w<sub>ik</sub>、w<sub>jk</sub>,公式(8)中的尺度因子与平移因子,设置学习效率因子 η 的数值。

(2) 原始时间序列数据分组。将数据分为训练组与测试组,并处理训练组数据将其归一化计算后由输入层输入,并以测试组数据为验证部分,确保网络训练结果优良。

(3) 模型参数训练。由步骤(2)中归一化之后的训练组进入模型结构中,模型的输出值与期望输出二 者差值,若误差符合设定阈值,那么权值与激励函数的参数输出。

(4) 权值与参数修正。步骤(3)中期望输出与模型实际输出二者差值若大于阈值,则需要不断修正模型结构中的权值与小波激励函数中参数,重复以上步骤直至符合要求的权值与参数输出。

(5) 输出最优预测值,由公式(1)~(7)反向操作即可得到最终预测数值。

不同滑坡体变形预测中适用的网络模型三层节点数量的确定,由公式 $n = \sqrt{i+j} + k$ 计算隐含层节点的个数区间范围,式中k为在 1~10 区间内的一常数,i,j分别表示为输入层节点数、输出层节点数。面对不同的被监测物体时,应用于被监测对象的网络中最大学习次数的计算工作,控制训练的最大次数并保证在收敛的情况下,增加隐含层节点的个数;如发生不收敛的情况,并且训练次数未达到最大数值,可考虑减少节点个数以达到最佳三层的节点个数。三层节点个数的调整,其目的方便网络训练中实际输出与期望输出差值符合阈值。

### 2.3. 奇异谱分析 - 小波神经网络模型结构

对于非线性位移观测时间序列数据,小波方法自身具有优良的逼近效果,同时在频域与时域方面都 有良好的局部优化特长。考虑到 BP 神经网络在处理非线性时间序列数据中的优势,二者均可满足非线 性预测能力的要求。所以综合二者的优势弥补了神经网络的缺点,优化组合模型的预测能力,更能贴合 于快速处理收敛非线性函数。

国内外专家学者针对位移观测时间序列数据进行了深入研究,总结出位移观测数据由三部分组成: 趋势项频率部分、周期项频率部分、高斯白噪声频率部分。奇异谱分析方法可将原始位移时间序列数据 分解出此三部分,所以构建了奇异谱分析 - 小波神经网络组合预测模型。位移观测数据时间序列先用奇 异谱分析方法进行预处理,将数据拆分成趋势项与周期项两部分,噪声项部分舍去。

经过处理之后的位移时间序列数据在组合模型中与原始数据序列分别作为输入、输出数据。SSA-小 波神经网络组合模型的实现步骤如下:

(1) 原始数据的平稳性分析。以公式(12)计算时间序列数据的自相关系数,评价平稳性指标。依靠奇

异谱分析方法实现模型重构阶数与嵌入维数的确定工作。

(2) 确定趋势项。异谱分析对时间序列进行分析时,某一重建成分 RC<sup>K</sup> 是否为趋势项可以通过 Kendall 非参数检验进行识别与判定。计算满足 x<sub>ik</sub> < x<sub>ik</sub> 的指标数 K<sub>r</sub>,统计量 τ 为:

$$\tau = \frac{4K_{\tau}}{N(N-1)} - 1 \tag{10}$$

原假设为: RC<sup>K</sup> 是趋势项成分不成立, 那么可以得到 τ 是服从均值为 0、均方差为 S 的正态分布。S 表示为:

$$S = \sqrt{\frac{2(2N+5)}{9N(N-1)}}$$
(11)

取置信度  $\alpha = 0.05$ , 若  $\tau < -1.96S$  或  $\tau > 1.96S$ , 那么认为原假设不成立,此时 RC<sup>K</sup> 即是趋势项成分。

(3)周期项判定。特征值向量中,当任意两个特征值差值接近于零时,那么可将二者对应的重构成分之和表示某个周期成分。

(4) 小波神经网络模型的实现,经过上述步骤区分出趋势项与周期项之后,以公式(7)的得到以轨迹 矩阵为时间序列的预测值,重构得到原始时间序列的预测值。

## 3. 各组合模型精度评定

为比较文中提及的预测模型精度,采用相对误差作为指标。首先计算预测值与实际值的差值  $e(0) = \left\{ e^{(0)}(1), e^{(0)}(2), \dots, e^{(0)}(n) \right\}$ ,其中 $e^{(0)}(k) = x^{(0)}(k) - \hat{x}^{(0)}(k)$ 。相对误差 $q = \{q_1, q_2, \dots, q_n\}$ ,其中  $q_1 = \frac{e^{(0)}(k)}{x^{(0)}(k)}$ 。表1汇总了评价模型预测精度指标。

 Table 1. Model accuracy evaluation criteria

 表 1. 模型精度评定标准

	相对误差 e/%		
一级	1		
二级	5		
三级	10		
四级	20		

# 4. 工程实例分析

近几年,城市建设速度加快,各城市间高速公路连接实现了一小时生活圈。在高速公路建设过程中滑 坡体的产生影响工程施工进度,为此及时掌握滑坡的位移情况关乎工程进度重要因素。本公司受高速公路 建设部门的委托开展某一滑坡位移监测观测工作。该滑坡高差 20.5 m,又逢雨季加速了地质灾害发生的风 险,加剧了该滑坡体的不稳定因素。在滑坡体布设了 10 个监测观测点与 2 个基准点。自 2023 年 5 月 18 日 至 2024 年 6 月 23 日,每间隔 10 天进行观测,总计观测 40 期数据,40 期观测数据如表 2 所示。

测量采用经过检校的测量机器人,以变形观测点 A3 的 40 期变形监测数据为例。为训练组合模型的 网络权值与模型参数,充分利用 40 期的变形观测数据,将其分为训练组与期望组。以 34 期数据为训练 组输入组合模型中训练网络,以后 6 期数据为期望组与模型预测值作差比较,反馈训练模型直至满足要 求。为评价数据的平稳性要求,以公式(12)计算 40 期数据的自相关系数 p:

王超	等
----	---

(12)

观测期数	数值/mm	观测期数	数值/mm	观测期数	数值/mm	观测期数	数值/mm
第1期	1.04	第11期	4.37	第 21 期	6.68	第 31 期	7.93
第2期	1.77	第 12 期	4.57	第 22 期	7.07	第 32 期	7.96
第3期	2.04	第13期	4.92	第 23 期	7.26	第 33 期	8.07
第4期	2.53	第 14 期	5.15	第 24 期	7.41	第 34 期	8.53
第5期	2.66	第15期	5.37	第 25 期	7.55	第 35 期	9.03
第6期	2.93	第16期	5.44	第 26 期	7.58	第 36 期	9.05
第7期	3.18	第 17 期	5.87	第 27 期	7.73	第 37 期	9.09
第8期	3.76	第18期	6.19	第 28 期	7.84	第 38 期	9.12
第9期	3.92	第 19 期	6.33	第 29 期	7.88	第 39 期	9.15
第10期	4.08	第 20 期	6.57	第 30 期	6.68	第 40 期	9.19

Table 2. 40<sup>th</sup> period displacement observation data **麦** 2. 40 期位移观测数据

$$p_{K} = \frac{\sum_{i=1}^{n-K} (X_{i} - u)(x_{i+K} - u)}{S}$$

式(12)中, u 表示序列均值; S 表示序列方差。

由公式(12)解算出滑坡体位移观测数据中每一期的自相关系数,计算结果见图1所示。



图 1. 自相关系数统计结果

根据相关研究可知,当 x<sub>K</sub>~N (0, 1/44)时,那么该位移时间序列数据为平稳状态。在显著水平 α=0.05 时, p<sub>K</sub>(K>1)的置信区间为(-0.118, 0.118)。由图 1 中自相关系数统计结果可计算出 p<sub>k</sub>满足给定的置信区间个数为 9 个,并以此判定 40 期的位移时间序列数据为非平稳状态,可利用奇异谱分析方法分离出不同

频率项成分。为计算出奇异谱分析中参数的数值,以相关文献的研究成果为依托,原始时间位移观测序 列数据与反归一化之后的序列数据二者的均方根误差最小为原则,解算得到重构阶数(*p* = 15)与嵌入维数 (*M*=16)。以公式(2)~公式(7)得到轨迹矩阵的特征值、特征向量,其中最大特征值表征了数据中趋势项成 分,最小特征值表征了噪声项成分,周期项部分即为其余特征值。

为比较经过奇异谱分析处理之后的模型预测精度,将前 34 期数据作为训练样本,分别输入小波神将 网络模型与 SSA-小波神经网络模型中,得到的预测值与后 6 期实测数据分析比较。预测结果如图 2、图 3 所示,表 3 汇总了两种模型预测差值情况。



图 3. 两种模型预测结果相对误差

 Table 3. Comparison of prediction results between two models/mm

 表 3. 两种模型预测结果对比/mm

预测期数	实际累计 变化量	小波神经网络 模型预测值	小波神经网络 模型预测残差值	SSA-小波神经 网络模型预测值	SSA-小波神经 网络模型预测残差值
35	9.03	9.88	-0.85	9.50	-0.47
36	9.05	9.93	-0.88	9.54	-0.49
37	9.09	10.11	-1.02	8.58	0.51
38	9.12	10.48	-1.36	8.83	0.29
39	9.15	10.54	-1.39	9.54	-0.39
40	9.19	10.61	-1.42	8.67	0.52

图 2 中三条曲线走势表明了引进小波函数的神经网络模型预测精度随着预测时间延长,预测呈发散 状态,预测精度降低;引入奇异谱分析的小波神经网络模型预测效果与原观测值吻合相对较好,说明了 基于奇异谱分析方法处理之后的数据经过小波神经网络预测,预测值与实测值吻合程度优良。图 3 中曲 线关系表明了奇异谱分析的小波神经网络预测结果相对误差数值在 5%之内,由表1判定为二级标准;小 波神经网络模型的预测结果相对误差由 5%逐渐升至 10%,根据表1 可知由二级逐渐降低至四级标准,再 次证明了奇异谱分析方法的引入大大提高了预测精度。表3 汇总了两种比较模型的预测结果与实测值的 差值情况,SSA-小波神经网络模型预测差值小于小波神经网络预测差值,与观测值吻合性更好。综上图 与表格可知,奇异谱分析 - 小波神经网络预测效果优于小波神经网络模型,预测精度高且稳定性强。

#### 5. 结语

奇异谱分析方法将位移观测时间序列进行分解,有效地去除噪声项的干扰。重构之后的数据建立小 波神经网络模型预测非线性数据,得到了优于传统方法的预测效果。本文通过工程项目实例数据为实验, 对比了文中提出的 SSA-小波神将网络模型与小波神经网络模型的预测结果,并在相对误差与绝对差值为 评价指标,得出了奇异谱分析 - 小波神经网络模型预测精度与稳定性都更高的结论,这一组合模型对高 层建筑以及各种地铁、基坑、桥梁等建构筑物的沉降预测都有很好的应用效果。

# 参考文献

- [1] 申靖宇, 刘志忠, 牛晓婷. GM-SVR 模型在高层建筑物沉降监测中的应用研究[J]. 建筑技术·应用, 2021, 18(10): 161-164.
- [2] 周兴. Verhulst 模型在高层建筑物沉降预测中的应用[J]. 城市勘测, 2020(3): 167-169.
- [3] 陈智民, 文选跃. 高层建筑物沉降预测方法及对比分析[J]. 城市勘测, 2021(3): 185-189.
- [4] 冯艳顺, 赵万东, 王红夺, 等. 基于灰色系统理论的高层建筑变形分析应用研究[J]. 测绘与空间地理信息 2021, 5(44): 188-190+195.
- [5] 刘正佳,廖孟光,黄志豪,等. 趋势项优化混合时序模型的建筑物沉降应用[J]. 测绘科学, 2021, 46(4): 43-49.
- [6] 李世友, 王奉伟, 沈云中. 大坝变形时间序列的奇异谱分析[J]. 测绘通报, 2019(9): 64-68.