

基于多簇回声状态网络的边坡变形预测

华莎¹,袁于思¹,易灿灿²,张磊²

(1. 中铁武汉电气化局集团第一工程有限公司, 湖北 武汉 430074;

2. 武汉科技大学, 湖北 武汉 430081)

摘要: 由于边坡失稳是一个循序渐进的过程,利用时间序列分析的方法来预测边坡未来变形,有利于实现边坡的稳定性评价。相比于传统的时间序列分析方法,多簇回声状态网络(MCESN)采用动态储备池将输入信号转换为高维状态向量,选择一组最优的状态向量来表示与任务相关的输入动态。为了验证模型的有效性,采用差分整合移动平均自回归模型(ARIMA)、回归支持向量机(SVM)、长短期记忆网络(LSTM)和传统的回声状态网络(ESN)以及MCESN对三峡船闸高边坡位移进行建模与分析,通过对比均方根误差(RMSE)和复相关系数,发现MCESN的预测精度和模型泛化能力更好。结果表明,MCESN在边坡变形预测具有良好的应用前景。

关键词: 边坡变形;多聚类;回声状态网络;时间序列预测;位移预测

中图分类号: TU454

文献标识码: A

文章编号: 1672—1144(2022)02—0108—05

Slope Deformation Prediction Based on Multi-cluster Echo State Network

HUA Sha¹, YUAN Yusi¹, YI Cancan², ZHANG Lei²

(1. China Railway Wuhan Electrification Bureau Group Co., Ltd. Wuhan Division, Wuhan, Hubei 430074, China;

2. Wuhan University of Science and Technology, Wuhan, Hubei 430081, China)

Abstract: Because the slope instability is a gradual process, the use of time series analysis method to predict the future deformation of the slope is conducive to the realization of the stability evaluation of the slope. Compared with the traditional time series analysis method, the Multi-Cluster Echo State Network (MCESN) uses a dynamic reservoir to convert the input signal into a high-dimensional state vector, and selects a set of optimal state vectors to represent the input dynamics related to the task. In order to verify the effectiveness of the model, the article uses ARIMA, SVM, LSTM and ESN, as well as MCESN on displacement of High Slope of Three Gorges Ship Lock is modeled and analyzed, and RMSE and the Multi-correlation coefficient are compared. It is found that MCESN has better prediction accuracy and model generalization ability. The results show that MCESN has a good application prospect in slope deformation prediction.

Keywords: slope deformation; multi-clustered; echo state network; time series prediction; displacement prediction

随着国民经济的快速发展,人们的工程活动比如公路、隧道、矿山和桥梁等越来越频繁,规模也在逐渐变大,不可避免的形成了各类边坡,而边坡滑坡失稳、地震和火山已经成为全球三大地质灾害。2020年全国地质灾害通报统计报告显示,在全国范围内总共发生7 840起地质灾害事件,伤亡失踪人数达197人,直接经济损失50.2亿元,其中滑坡灾

害4 810起,占总数的61%。边坡失稳已经对整个社会造成严重的危害,给人民带来了巨大的损失,做好边坡的稳定性评价和分析研究势在必行。因此,准确预测边坡的位移形变以及变化趋势,对预防及减少边坡灾害的发生意义重大。

随着机器学习的快速发展,近年来很多学者对边坡的稳定性进行深入研究,并提出了大量的算法

应用于边坡工程中。人工神经网络(ANN)和支持向量机(SVM)是最流行的方法,能够很好的解决非线性问题。余晓露等^[1]构建了基于 BP 神经网络的边坡对点模型,可以反映边坡的实际状况。孙平定等^[2]利用遗传算法对样本数据预处理,采用 BP 神经网络对边坡的稳定性进行准确的判别。晏红波等^[3]采用集合经验模态分解(EEMD)提取大坝变形数据的特征,并建立遗传 BP 神经网络进行预测,并得到了高效可靠的预测值。龚斌等^[4]采用改进粒子群算法对 BP 神经网络进行优化并用于边坡变形预测,验证了其有效性。贾家银等^[5]利用改进 PSO 对 BP 神经网络参数优化,并采用 PCA 选取影响因子,对隧道围岩变形进行预测,验证了其优越性。由于 BP 神经网络在训练过程中存在着过拟合、达到局部最小值、收敛速度慢等问题,许多学者采用了支持向量机和随机森林等对边坡稳定性进行深入研究。李建新等^[6]基于模糊 C 均值聚类和支持向量机对边坡安全系数进行估算,得到可靠性强的安全系数。黄俊等^[7]提出基于网格搜索和粒子群优化的 SVM 模型(GS-PSO-SVM),能有效地对边坡稳定性状态进行预测。史笑凡等^[8]分别将 SVM 和 BP 神经网络对边坡的稳定预测,结果表明 SVM 的性能要高于 BP 神经网络。王健伟等^[9]提出网格搜索法优化 SVM 的参数,得到了准确的边坡安全系数。Liu 等^[10]人利用长短时记忆神经网络(LSTM)、随机森林(RF)和门控递归单元(GRU)对三个不同的三峡库区边坡变化做出了预报,并自适应选取高精度的预测模型。但是,SVM 算法本身也存在问题,比如 SVM 的核函数必须满足条件苛刻,且对于多分类问题,SVM 处理难度大。由于边坡的地形复杂,影响边坡的形变应变因素众多,边坡变形中的数据具有典型的非平稳和非线性特征,因此当前对于边坡稳定性研究还有待深入。

回声状态网络(ESN)^[11]是一种新型的递归神经网络,最开始是由 Jaeger 提出的,与传统的 RNN 不同,ESN 通常包含大量的内部神经元(通常 RNN 包含 5~30 个内部神经元),只有输出权值用线性回归方法训练,克服了局部最优和梯度消失等问题。据堇等^[12]针对传统 ESN 参数难以确定和局部最优的问题,提出改进乌鸦计算(ICSA)对 ESN 参数进行优化,并在短期风电输出功率预测中证明了此方法的可行性和可靠性。张各各等^[13]针对传统 ESN 的过拟合问题采用粒子群优化算法(PSO)确定平滑消边绝对偏离-回声状态网络模型(SCAD-ESN)的超

参数,仿真数据结果表明 SCAD-ESN 能有效地降低训练误差,克服过拟合问题。但是 ESN 的应用需要平衡网络结构和网络性能之间的权衡。如果网络结构太小,网络可能呈现有限的信息处理能力,而对于复杂的问题,ESN 不能达到令人满意的精度。另一方面,如果网络结构过大,网络在测试过程中可能表现出较差的泛化性能。因此,ESN 在实践中选择最优的网络结构往往存在困难。本文采用多簇回声状态网络(MCESN)^[14]对边坡的稳定性进行研究,MCESN 与 ESN 类似,不同之处在于储备池,MCESN 的多聚类拓扑结构比传统 ESN 的随机结构更具优势,能够得到更高的预测精度。

综上所述,针对目前边坡变形预测的不足与局限性,本文提出了 MCESN 用于变形预测,通过复相关系数和均方根误差(RMSE)两个指标评价 MCESN 模型的可行性和有效性。工程实测数据表明,MCESN 模型预测样本的平均相对误差为 0.251 8,预测精度远高于整合移动平均自回归模型(ARIMA)、支持向量机(SVM)、长短期记忆网络(LSTM)和传统的回声状态网络(ESN)的预测精度,边坡形变预测的精度得到大幅度提升。

1 理论描述

1.1 ESN 的基本理论

回声状态网络包括具有 K 个输入神经元的输入层、具有 N 个神经元的储备池和具有 L 个输出神经元的输出层。ESN 与其他神经网络不同之处在于其包括一个动态的储备池,具有许多随机稀疏连接的神经元以及一个简单的训练过程,其中只有输出权重是自适应的,ESN 的结构图见图 1。




图 1 回声状态网络结构图

储备池状态按式(1)更新:

$$x(n+1) = f(W^{\text{in}}u(n+1) + W^{\text{res}}x(n) + W^{\text{back}}y(n)) \quad (1)$$

其中: $u(n+1)$ 为时刻 $n+1$ 的输入; $x(n)$ 为时刻 n

的储备池神经元状态; $y(n)$ 表示时刻 n 的输出; f 是储备池神经元的激活函数; W^{in} 为的输入权重矩阵; W^{res} 为储备池权重矩阵; W^{back} 为反馈权重矩阵

要使 ESN 正常工作, ESN 应具备回声状态属性, W^{res} 的谱半径应小于 1。为保证回声状态属性, 最后的 W^{res} 将通常按式(2) 缩放:

$$W^{res} = \alpha(W^{res} / |\lambda_{\max}|) \quad (2)$$

α 是缩放参数, 其值介于 0 和 1 之间, $|\lambda_{\max}|$ 是 W^{res} 的谱半径, 需满足必要条件。

ESN 的输出可以表示如下:

$$y(n) = f^{out}(W^{out}x(n)) \quad (3)$$

其中: f^{out} 表示神经元的激活函数; W^{out} 是大小为 $L \times (N + K)$ 的输出权重矩阵。

如上所述, ESN 的训练方式是只需要调整输出权重。在训练过程中, 将储备池神经元的状态收集到一个状态矩阵 M 中, 见式(4):

$$M = \begin{bmatrix} X^T(t) \\ X^T(t+1) \\ M \\ X^T(t+k-1) \end{bmatrix} \quad (4)$$

然后, 将相应的输出向量收集到目标矩阵 T 中, 见式(5):

$$T = \begin{bmatrix} y(t) \\ y(t+1) \\ M \\ y(t+k-1) \end{bmatrix} \quad (5)$$

其中 t 对应于初始瞬态过程的长度。为了减少初始储层状态的影响, k 被认为是训练样本的数量。 f^{out} 是恒等函数, 使用伪逆算法计算输出权重矩阵 W^{out} , 见式(6):

$$W^{out} = M^+ T \quad (6)$$

其中 M^+ 是状态矩阵 M 的广义逆矩阵, 将式(6) 修改如下:

$$W^{out} = (M^T M)^{-1} M^T T \quad (7)$$

1.2 多簇回声状态网络(MCESN)

与传统的 ESN 一样, 多簇回声状态网络(MCESN)由输入层、储备池和输出层组成。与图 1 的 ESN 的随机连接储层拓扑不同, MCESN 具有一个多集群拓扑结构的储层^[15], 如图 2 所示。

假设 MCESN 有 K 个输入单元、 N 个内部单元和 L 个输出神经元。MCESN 的储备池内部结构根据 Kaisers 聚类算法^[16]生成多聚类结构。储备池中的所有神经元被分为两种不同类型的神经元, 即先驱神经元和正常神经元。具有相互联系的先驱神经




图 2 MCESN 网络结构图

元是决定簇数的关键神经元, 正常神经元在簇内具有连接性。根据神经元之间的空间距离和相关的时

间窗概率模型, 在时间步 t 上建立两个神经元 u 和 v 之间的连接, 其概率计算如下:

$$P_{\text{conn}} = P_{\text{dist}}[d(u, v)] * P_{\text{time}}^{u(u)}(t) * P_{\text{time}}^{v(v)}(t) \quad (8)$$

$$P_{\text{dist}}[d(u, v)] = \beta e^{-\alpha d(u, v)} \quad (9)$$

其中 $d(u, v)$ 是节点 u 和 v 之间的欧几里得距离; α 和 β 是形成连接概率的比例系数。时间窗相关概率计算如下:

$$P_{\text{time}}^{u(u)}(t) = P(t; i, \varphi(u_i, \omega)) = \frac{1}{16} (t^{2\lambda} (t^\lambda - 1)^2)^{1/\varphi(u_i, \omega)} \quad (10)$$

其中 $t = j/N$, ($j = 1, 2, \dots, N$); $u_i = i/n + 1$, ($i = 1, 2, \dots, n$), 其中 n 是先锋节点的数目, N 是储藏神经元的数目; ω 表示时间窗口积分值; $\lambda = -(\log(2))/\log(u_i)$ 以及 $\varphi(u_i, \omega)$ 是一个数值确定的比例因子, 用于计算所需的 ω 值。

MCESN 的储备池处理通过以下步骤实现:

(1) 储备池由少量(即 n 个)先驱神经元生成, 神经元双向全对全连接。

(2) 添加一个随机神经元并归类到最近的簇中, 这是由最近的先锋神经元的评估决定的, 这个神经元有概率连接属于同一个集群的每个节点。该节点还根据式(8) 连接到其他节点。任何未能建立连接的新节点将被忽略。重复步骤(2), 直到现有节点的数量达到定义的储备池。

(3) 每个节点自连接概率 P_s 与自身连接。

(4) 对生成的网络节点进行映射, 得到一个多集群的储备池。矩阵 W^{res} 反映节点之间的连接强度。储备池连接矩阵 W^{res} 计算如下:

$$W^{res} = \begin{pmatrix} W_{1,1} & L & W_{1,i} \\ M & O & M \\ W_{i,1} & L & W_{i,i} \end{pmatrix} \quad (11)$$

其中: $W_{i,i}$ 为第 i 个聚类的权重矩阵($i = (1, \dots, n)$);

$W_{i,j}$ 为第 i 和第 j 个聚类之间的权重矩阵。

储备池神经元的更新方程如下:

$$x(t+1) = f(W^{in}u(t+1) + W^{res}x(t) + W^{back}y(t) + v(t)) \quad (12)$$

其中: f 是储备池神经元的激活函数; $v(t)$ 是噪声。费米函数用作内部神经元函数,输出计算如下:

$$y(t+1) = f^{out}(W^{out}[u(t+1) | x(t+1)]) \quad (13)$$

其中: f^{out} 表示输出神经元的激活函数,采用恒等函数; $[u(t+1) | x(t+1)]$ 表示输入和内部激活向量的串联向量,即输入 $u(t)$ 连接到输出神经元。 W_{out} 是需要通过线性回归方法训练的输出权重矩阵。

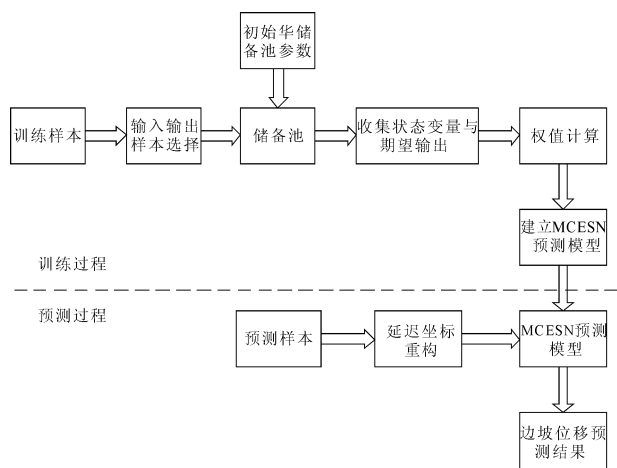


图 3 MCESN 预测边坡位移流程图

2 工程实际数据分析

为了进一步验证本文提出方法的有效性,本文对三峡船闸高边坡 TP/BM29GP02 测点位移进行建模和分析,其变形监测值见表 1^[17],其中利用编号 1—编号 36 的数据用于建模,利用编号 37—编号 43 的数据用于预测。

表 1 三峡船闸高边坡 TP/BM29GP02 测点变形监测值

时序	监测数据 /mm	时序	监测数据 /mm	时序	监测数据 /mm	时序	监测数据 /mm
1	0.00	12	13.31	23	17.08	34	19.16
2	1.21	13	14.37	24	18.58	35	20.20
3	3.29	14	15.28	25	18.17	36	20.90
4	3.65	15	14.89	26	18.18	37	22.25
5	4.60	16	15.37	27	18.63	38	23.17
6	6.29	17	15.34	28	19.16	39	23.89
7	8.09	18	15.19	29	19.60	40	24.73
8	8.12	19	15.01	30	19.67	41	25.75
9	9.18	20	15.40	31	19.00	42	26.22
10	10.65	21	15.80	32	19.30	43	26.50
11	11.60	22	15.95	33	18.87	—	—

本文所用到的高边坡变形监测数据(43 组)见图 4。为了验证所提出的方法的有效性,首先分别用整合移动平均自回归模型(ARIMA)、长短期记忆网络(LSTM)、回归支持向量机(SVM)、和传统的回声状态网络(ESN)对变形数据进行分析。首先用时间序列分析最常见的 ARIMA 和 LSTM 模型,其具体计算结果见图 5(a)和图 5(b),可以发现在训练和预测的过程中,其拟合结果的精度都有待提高。紧接着,利用基于结构风险最小化的支持向量机 SVM 对数据进行分析,利用交叉验证的方法得到其最优的核参数为 4.1,所用的核函数为径向基函数,其分析的结果见图 5(c)。然后采用传统的 ESN 模型对变形数据进行分析,结果见图 5(d),通过比较图 5(a)、图 5(b)、图 5(c)、图 5(d)可以发现,传统 ESN 的鲁棒性和泛化能力比 ARIMA、LSTM 和 SVM 更好。




图 4 高边坡测点变形监测值

最后,利用本文提出的多簇回声状态网络(MCESN)算法对高边坡测点变形监测数据进行分析,其分析结果见图 6,从该图可以发现本文提出的算法在训练和拟合的两个阶段均具有最好的分析精度。为了定量评价不同统计建模方法对高边坡数据稳定性分析的有效性,本文利用 7 个预测样本的均方根误差(RMSE)、复相关系数(RPE)作为指标进行对比,具体结果见表 2,MCESN 的预测精度远高于其他 4 种模型,证明了 MCESN 在边坡位移预测的有效性。

表 2 不同时间序列分析方法的预测精度

指标	ARMA	SVM	LSTM	ESN	MCESN
均方根误差	2.8154	0.8499	0.7598	0.6110	0.2518
复相关系数	0.5174	0.8219	0.6531	0.8882	0.9622




图 5 常用时间序列分析方法预测的结果




图 6 多簇回声状态网络(MCESN)的分析结果

3 结论

针对目前边坡失稳预测精度不高,适应性不强等问题,在传统的 ESN 在时间序列预测上突出贡献的基础上,本文提出了 MCESN 模型应用于边坡变形预测,并将该模型与 ARIMA、SVM、LSTM 和 ESN4 种方法相比,通过工程实测数据表明,其综合性能优

于其他四种模型,预测精度也得到了很大的提升,将 MCESN 运用于边坡稳定性和易发性研究中具有较好的可行性和可靠性,因此,对于地质其他时间序列的问题,在本文提出方法的基础上可以深入探究。

参考文献:

- [1] 余晓露,郑东健. 基于人工神经网络的边坡新多点监控模型[J]. 人民黄河,2020,42(6):117-119,129.
- [2] 孙平定,蔡润,谢成阳,等. 基于遗传优化神经网络的边坡稳定性评价[J]. 现代电子技术,2019,42(5):75-78.
- [3] 晏红波,杨庆,任超,等. 基于 EEMD 的 BP 神经网络边坡预测研究[J]. 水力发电,2017,43(7):37-40.
- [4] 龚斌,唐春安. 大岗山水电站右岸边坡开挖期位移预测的 PBM 模型研究[J]. 水利与建筑工程学报,2019,17(4):130-135.
- [5] 贾家银,刘宇豪,李晓军,等. 基于改进 PSO-BP 神经网络的浅埋隧道围岩变形时序预测研究[J]. 水利与建筑工程学报,2021,19(5):19-22,51.
- [6] 李建新,刘小生,肖海平,等. 基于 FCM-SVM 的矿山边坡安全系数估算[J]. 矿业研究与开发,2019,39(10):76-79.
- [7] 黄俊,刘小生. 基于 GS-PSO-SVM 模型的边坡稳定性预测模型[J]. 中国矿业,2020,29(6):87-91.
- [8] 史笑凡,杨春风,王可意. 基于支持向量机和改进 BP 神经网络的路基边坡稳定性研究[J]. 公路交通科技,2019,36(1):31-37.
- [9] 王健伟,徐玉胜,李俊鑫. 基于网格搜索支持向量机的边坡稳定性系数预测[J]. 铁道建筑,2019,59(5):94-97.
- [10] Liu Z, Guo D, Suzanne L, et al. 边坡位移智能预测算法[J]. 浙江大学学报(英文版)(A 辑:应用物理和工程),2020,21(6):412-429.
- [11] Herbert J, Harald H. Harnessing nonlinearity: predicting chaotic systems and saving energy in wireless communication[J]. Science,2004,304(5667):78-80.
- [12] 琚垚,祁林,刘帅. 基于改进乌鸦算法和 ESN 神经网络的短期风电功率预测[J]. 电力系统保护与控制,2019,47(4):58-64.
- [13] 张各各,徐珍,曾波,等. 基于 SCAD-ESN 的时间序列预测模型[J]. 工程科学与技术,2017,49(6):129-134.
- [14] Xue F, Li Q, Zhou H, et al. Reservoir computing with both neuronal intrinsic plasticity and multi-clustered structure[J]. Cognitive Computation,2017,9(3):400-410.
- [15] Li Q, Wu Z, Xia X. Estimate and characterize PV power at demand-side hybrid system[J]. Applied Energy,2018,218(15):66-77.
- [16] 黎倩. 回声状态网络的神经元模型和拓扑结构优化研究[D]. 重庆:重庆大学,2017:2-5.
- [17] 赵洪波. 边坡变形预测的群体智能模型[J]. 岩石力学与工程学报,2006,25(8):1664.