

基于 GA-QPSO-ELM 的边坡位移组合预测

傅嘉辉¹, 张夫龙¹, 张学超¹, 闫少霞²

(1. 国网新源集团有限公司富春江水力发电厂, 浙江 杭州 311000;

2. 广州南方测绘科技股份有限公司, 广东 广州 510000)

摘要: 为了提高水利工程边坡位移预测精度, 在 QPSO 算法寻优过程中引入遗传算法的交叉和变异操作, 形成 GA-QPSO 算法。采用 GA-QPSO 算法对 ELM 参数进行优化, 建立基于 GA-QPSO-ELM 的边坡位移组合预测模型, 采用实际水利工程的边坡位移监测数据进行仿真分析, 并与其他边坡位移预测方法进行对比。结果表明, GA-QPSO-ELM 组合模型的平均相对误差为 1.186%, 预测精度高于其他方法, 验证了模型的正确性和优越性。

关键词: 边坡位移; 组合预测; 极限学习机; 遗传算法; 量子粒子群算法

中图分类号: TP183 文献标识码: A 文章编号: 1003-7241(2025)01-0053-04

Combined Forecasting of Slope Displacement Based on GA-QPSO-ELM

FU Jia-hui¹, ZHANG Fu-long¹, ZHANG Xue-chao¹, YAN Shao-xia²

(1. Fuchunjiang Hydropower Plant of State Grid Xinyuan Group Co., Ltd., Hangzhou 311000 China;

2. Guangzhou Southern Surveying and Mapping Technology Co., Ltd., Guangzhou 510000 China)

Abstract: In order to improve the accuracy of slope displacement prediction of water conservancy projects, GA-QPSO algorithm is formed by introducing the crossover and mutation operation of genetic algorithm in the optimization process of QPSO algorithm. GA-QPSO algorithm is used to optimize the parameter of ELM, and a combined prediction model of slope displacement based on GA-QPSO-ELM is established. The slope displacement monitoring data of actual water conservancy projects are used for simulation analysis, and compared with other slope displacement prediction methods. The results show that the average relative error of GA-QPSO-ELM combined model is 1.186%, and the prediction accuracy is higher than other methods, which verifies the correctness and superiority of the model.

Keywords: slope displacement; combined forecasting; extreme learning machine; genetic algorithm; quantum particle swarm optimization

0 引言

边坡是通过人工开挖的方式和自然因素的作用下形成的, 受岩土成分、地质特点、气候、水文等多种因素的影响, 边坡会发生一定的位移。边坡位移是表征边坡稳定性的重要参数, 及时掌握边坡位移的变化, 建立准确可靠的边坡位移预测模型对于监测边坡位移变化具有重要的工程意义^[1-2]。

边坡位移常用的预测方法有时间序列法、支持向量机和神经网络等。根据边坡位移数据时间特性, 采用差分自回归移动平滑法建立了基于 ARIMA 的边坡位移预测模型, 利用某边坡位移监测数据验证了模型的正确性和实用性^[3]。采用混沌理论对遗传算法进行改进, 采用改

进遗传算法对最小二乘支持向量机进行优化, 建立了基于改进 GA 优化 LSSVM 的边坡位移预测模型, 并将该模型应用于实际工程, 取得了良好的应用效果^[4]。采用粒子群算法对 BP 神经网络的权值和阈值进行优化, 建立了基于 PSO-BP 的边坡位移预测模型, 仿真结果验证了该模型具有较大的实用价值^[5]。上述方法均采用单一算法建立了边坡位移预测模型, 导致预测结果不够理想, 预测精度更高的边坡位移预测模型有待进一步提高。

本文将 GA 算法和 QPSO 算法的优势相结合, 组成 GA-QPSO 算法, 采用该算法对 ELM 参数进行最优值搜索, 建立基于 GA-QPSO-ELM 的边坡位移组合预测模型, 采用实际水利工程的边坡位移监测数据进行算例分析, 对模型的正确性和实用性进行验证。

1 GA-QPSO 算法

1.1 遗传算法

*基金项目: 广东省重点领域研发计划项目 (232023021021900001); 国网新源集团有限公司科技项目资助项目 (SGXYKJ-2022-057)

收稿日期: 2023-11-24

遗传算法(Genetic Algorithm, GA)是一种模拟生物进化过程的寻优方法^[6]。GA的具体过程如下:存在某个种群,该种群采用优胜劣汰的方式进行进化,进化后的子代继承了母本的优良基因,子代仍然采用同样的方式遗传进化,通过若干次进化后,优良基因得以显现出来,即找到全局最优解。遗传算法自上世纪60年代被提出后,受到国内外专家学者的高度关注,应用非常广泛。

遗传算法的基本计算步骤如下:

(1) 编码与种群选择

遗传算法的关键在于如何表示个体和所求问题的解,目前常用的个体表示方法是二进制编码法,这里的个体是指遗传算法中的数据结构。二进制编码实际上就是模仿的生物染色体,所有的生物个体都可以用不同的染色体组合来表示。在GA算法中,定义所有个体均为数字0和1组成的二进制串,且这些二进制串是等长的。

(2) 个体适应度评价

适应度评价是指对种群中的各个个体进行客观评价,它是遗传算法执行选择的基本依据。

个体适应度的评价方法通常采用优化问题的目标函数,即适应函数。适应函数用于评价遗传算法产生的每代个体的优劣。例如,当自变量 $x \in [a, b]$ 时,求函数 $f(x)$ 的最大值,此时函数 $f(x)$ 称为 x 的原始适应度值。

(3) 遗传操作

适应度值较好的个体通过遗传产生下一代的概率更高,遗传操作主要包括选择、交叉和变异。

1) 选择

选择是指根据个体适应度的排序结果,选择种群中适应度较好的个体作为遗传给下一代的双亲。遗传算法中常采用比例选择的方法,具体方法为令 fit_i 为个体 i 的适应度值,则个体 i 能够被选择遗传给下一代的概率为:

$$p_i = \frac{fit_i}{\sum_{i=1}^n fit_i} \quad (1)$$

式中: p_i 为被选择遗传给下一代的概率, n 为种群容量。

若遗传过程中,种群容量 n 始终保持不变,则下一代中出现个体 i 的比例为:

$$n \cdot \left[\frac{fit_i}{\sum_{i=1}^n fit_i} \right] = \frac{fit_i}{\bar{fit}} \quad (2)$$

式中: \bar{fit} 为所有个体适应度的平均值。

选择操作常用策略为轮盘法,在轮盘中,轮盘表示所有个体适应度值的总和,每个个体根据适应度值的大小在轮盘中占据一个扇形区域,然后系统随机产生一个数,该数落入转盘的哪个区域,就选择该区域对应的个体最为父本进行繁殖,显然,适应度值越大的个体被选作父本

的概率越大。

2) 交叉

选择操作完成后,需要对所选择的个体进行基因交流,即交叉操作。交叉操作的具体方法是:预先设定交叉概率 P_c , P_c 的取值范围为 $[0.5, 0.95]$,对于任意一对被选择的父本,它们进行交叉的概率为 p_1 ($p_1 \in [0, 1]$),若 $p_1 \leq P_c$,则进行交叉,否则不进行交叉。

单点交叉是最常见的交叉方法,即对于染色体长度相同的父本,在它们染色体中除去最后一个编码的任意一个编码作为交叉点进行交叉,然后从交叉点开始的编码进行交换,得到新的染色体,形成新个体。

3) 突变

交叉操作得到的子代只能从父本中获得基因,这样出现近亲繁殖的可能性较大,即数学上的局部极值。为了提高子代的适应能力,往往在交叉完成后进行变异操作,以某一概率使子代中的某些基因发生突变,使种群中产生适应性更好的基因。

突变的操作方法是:预先设定突变概率 P_m , P_m 的取值范围为 $[0.001, 0.05]$,对于交叉产生的染色体上任意一位基因发生突变的概率为 p_2 , $p_2 \in [0, 1]$,只有当 $p_2 \leq P_m$,该位基因才能产生突变。如果原基因编码为1,突变后的基因编码变为0,如果原基因编码为0,突变后的基因编码变为1。

1.2 QPSO算法

量子粒子群算法(Quantum Particle Swarm Optimization, QPSO)是基于PSO算法提出的一种改进算法,它认为粒子群在寻优过程中遵循量子力学^[7]。相比PSO算法,QPSO算法的控制参数更少,通常只有一个,这样使得该算法的结构相对简单,且优化效果更好。在QPSO算法中,粒子位置的表达式为:

$$X_{id}(t+1) = p_{id}(t) \pm \frac{L}{2} \ln \left(\frac{1}{u} \right) \quad (3)$$

式中: d 为维数; $X_{id}(t+1)$ 为粒子位置; t 为迭代次数; u 为正态随机数, $u \in [0, 1]$; $p_{id}(t)$ 为个体最好位置; L 为位置参数; $p_{id}(t)$ 和 L 满足下列关系:

$$L(t+1) = 2\beta \left| \bar{m}_b - X(t) \right| \quad (4)$$

$$\bar{m}_b = \frac{1}{M} \sum_{i=1}^M p_{id}(t) \quad (5)$$

$$p_{id}(t) = \varphi \cdot p_{id}(t) \pm (1-\varphi) \cdot p_{gd}(t) \quad (6)$$

$$\beta = m - (m-n) \cdot \frac{t}{t_{\max}} \quad (7)$$

式中: M 为粒子数量; φ 为正态随机数, $\varphi \in [0, 1]$; $p_{gd}(t)$ 为群体最好位置; \bar{m}_b 为平均最优位置; β 为扩张系数; m 、 n 为控制参数。

经过上述变化,可以将(3)变化为:

$$X_{id}(t+1) = p_{id}(t) \pm \beta \cdot |m_b - X(t)| \cdot \ln\left(\frac{1}{u}\right) \quad (8)$$

式中:符号“±”的取值取决于β的范围,当β≤0.5时,取符号为“-”;当β>0.5时,取符号为“+”。

1.3 GA-QPSO算法

QPSO算法虽然具有诸多优势,但相对于复杂函数,QPSO算法在寻优时存在一些不合理的解,使其搜索速度变慢,为了解决这一问题,本文在QPSO算法寻优过程中引入遗传算法的交叉和变异操作,使优良基因尽可能保存下来,并将非优良基因进行变异,提高算法的全局搜索能力。

2 ELM及其优化

2.1 极限学习机

ELM是一种特殊结构的神经网络,其隐含层的数量仅为一层,因此ELM具有更快的学习速度,其学习和训练效果更好。ELM的训练过程实际上是求解非线性方程最小解,其目的是寻找权值的最优值,从而使训练样本预测值与真实值之间的误差最小,其基本原理可参考文献^[8]。

由于ELM的权重参数和偏置量参数可以随意设置,因此在对ELM训练时仅需要确定隐含层权重参数即可。另外ELM结构简单,学习效果只取决于激活函数和隐含层的数目,克服了传统神经网络参数复杂的缺陷,且在计算过程中不易陷入局部极值。因此,在利用ELM进行预测拟合时,为了获得更好的拟合效果,本文采用GA-QPSO算法确定隐含层权重参数最优值。

2.2 GA-QPSO-ELM模型

在构建GA-QPSO-ELM模型时,首先利用QPSO算法对最优权重进行搜索,然后执行GA算法的遗传操作,获取ELM最优参数,最后对边坡位移进行预测,主要步骤为:

- (1) 收集边坡位移数据,并把它初始化和分组;
- (2) 设置QPSO算法参数,包括粒子群个体数、算法迭代次数等;
- (3) 将ELM的权值和阈值作为粒子,并计算初始适应度值;
- (4) 对种群中的粒子进行选择、交叉和突变等操作,并利用式(8)更新粒子位置;
- (5) 对吸引子位置和概率密度函数进行计算,对种群位置进行更新,并选取最优适应度值;
- (6) 判断计算是否终止,若是,停止迭代,输出最优参数,否则跳转到步骤(4);
- (7) 将权值和阈值最优值赋给ELM,对边坡位移进行预测。

3 算例分析

以西南地区某水利工程的边坡位移监测数据为例进行算例分析,监测数据共40组,具体如表1所示。利用前30组数据进行模型训练,后10组数据进行精度检验。

表1 边坡位移监测数据

样本编号	位移/mm	样本编号	位移/mm
1	10.06	21	16.27
2	10.34	22	16.52
3	10.62	23	16.28
4	10.9	24	16.63
5	11.73	25	17.5
6	12.55	26	18.18
7	13.38	27	18.24
8	13.74	28	18.21
9	13.78	29	17.68
10	14.2	30	18.22
11	14.01	31	18.1
12	13.83	32	18.2
13	15.42	33	18.3
14	15.74	34	18.45
15	15.53	35	18.84
16	16.01	36	18.79
17	16.33	37	18.8
18	16.65	38	18.89
19	15.7	39	18.85
20	16.27	40	18.96

GA-QPSO算法的参数设置如下^[9]:种群规模为20,算法最大迭代次数为100,交叉概率为0.4,变异概率为0.005。

采用GA-QPSO算法对ELM的权值和阈值进行优化,建立基于GA-QPSO-ELM的边坡位移组合预测模型,采用该模型对后10组边坡位移进行预测,预测结果如图1所示。为了对比分析,采用文献[4]和文献[5]的预测结果进行对比,GA-LSSVM模型和PSO-BP模型的预测结果也如图1所示。对比图1中三种模型的预测结果可知,本文所提GA-QPSO-ELM组合预测模型的预测值更接近边坡位移实际值。

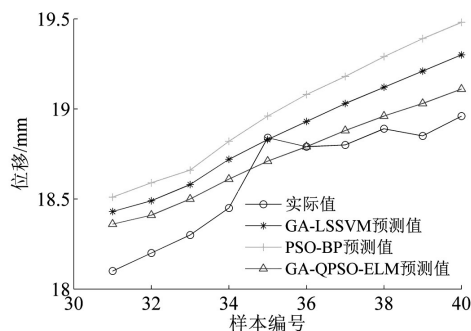


图1 边坡位移预测结果

采用平均相对百分误差对三种模型的预测精度进行评价,其计算公式分别为:

$$\varepsilon_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - y_i^*}{y_i} \right| \times 100\% \quad (9)$$

式中, N 为检验样本的个数; y_i 为第 i 个实际位移量; y_i^* 为第 i 个预测位移量。

表2 三种模型平均相对误差计算结果

模型	GA-LSSVM	PSO-BP	GA-QPSO-ELM
误差/%	1.751	2.434	1.185

三种模型的平均相对百分误差的计算结果如表2所示。由表2可知, GA-LSSVM模型、PSO-BP模型和GA-QPSO-ELM组合模型的平均相对误差分别为1.751%、2.434%和1.186%, 相比GA-LSSVM模型和PSO-BP模型, GA-QPSO-ELM组合模型的平均相对误差降低了32.28%和51.31%, 验证了基于GA-QPSO-ELM的边坡位移组合预测模型的正确性和优越性^[10]。

4 结束语

本文提出了一种基于GA-QPSO-ELM的边坡位移组合预测方法, 利用GA-QPSO算法对ELM进行优化, 建立了GA-QPSO-ELM边坡位移组合预测模型, 利用算例分析对所提方法的有效性进行验证, 并与其他边坡位移预测方法进行对比, 结果表明, 本文所提方法的预测精度更高, 边坡位移预测效果更好。

参考文献:

- [1] 郑海青, 赵越磊, 宗广昌, 等. 融合自注意力机制的Conv-LSTM边坡位移预测方法[J]. 金属矿山, 2022(11): 193-197.
- [2] 李建新, 刘小生, 肖钢, 等. 基于PSR-WSVM模型的边坡位移预测[J]. 大地测量与地球动力学, 2020, 40(6): 577-580.
- [3] 张恒言. 基于时间序列模型的边坡位移预测研究[J]. 黑龙江水利科技, 2022, 50(5): 48-51.
- [4] 杨念江, 樊方涛. 基于混沌遗传算法优化的LS-SVM边坡位移预测[J]. 湖南水利水电, 2020(5): 29-32.
- [5] 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.
- [6] 李启迪, 黄治翰, 汪晗, 等. 基于IGA优化SVM的变压器故障诊断[J]. 黑龙江电力, 2021, 43(4): 342-345, 376.
- [7] 张铭玮, 李正权, 方志豪. 基于量子粒子群优化的CNN-LSTM水质预测模型[J]. 中国计量大学学报, 2022, 33(3): 303-309, 323.
- [8] 陈志豪, 唐次来. 基于极限学习机的成都市水生态足迹分析与预测[J]. 水电能源科学, 2022, 40(12): 98-102.
- [9] 陈奎, 潘磊. 基于GA-QPSO算法的含分布式电源配电网优化重构设计[J]. 实验室研究与探索, 2022, 41(2): 111-115, 120.
- [10] 孙亮, 袁雪枫, 王靖, 等. 基于Kmeans算法的配电房防汛预测模型研究[J]. 自动化技术与应用, 2024, 43(10): 77-80, 90.

作者简介: 傅嘉辉(1989-), 男, 本科, 高级工程师, 研究方向: 电力科技工作。

(上接第23页)

ols step response method for PID control[J]. J Process Control, 2004, 14(6): 635-650.

[6] 冯少辉, 袁海雷. 基于Lambda方法的自衡对象PID整定研究[J]. 石油化工自动化, 2021, 57(4): 31-34.

[7] Newton G C, Gould LA, Kaiser JF. Analytical design of linear feedback controls[M]. USA: John Wiley, 1957.

[8] Dahlin EB. Designing and tuning digital controllers instruments and control systems[J]. Instruments and Control Systems, 1968, 2(6): 77-83.

[9] Kwon M, Chang H J. Extended root-locus technique applied to pole-placement for PI controller design[C]//Ukacc International Conference on Control. IEEE, 2016.

[10] 胡寿松. 自动控制原理[M]. 北京: 科学出版社, 2013: 147-151.

[11] 邵中年, 张志瑞. 基于根轨迹法的随动系统PID控制[J]. 四川兵工学报, 2012, 33(2): 94-96, 110.

[12] 徐建, 杨刚, 胡文霏. 根轨迹法在燃油控制回路PI控制器参数设计中的应用[J]. 航空发动机, 2016, 42(4): 17-20.

[13] 钟庆昌, 谢剑英. 时滞控制及其应用[J]. 控制理论与应用, 2002, 19(4): 500-504.

[14] 李钟慎. PID控制器的解析法整定及其MATLAB实现[J]. 计算技术与自动化, 2003(1): 40-43.

[15] Skogestad S, Grimholt C. The SIMC method for smooth PID controller tuning[J]. Springer London, 2012: 147-175.

[16] Sun L, Li D, Lee K, et al. On tuning and practical implementation of active disturbance rejection controller: a case study from a regenerative heater in a 1 000 MW power plant[J]. Industrial & Engineering Chemistry Research, 2016, 55(23): 6686-6695.

[17] 华山, 陈宝林, 范常浩. 智能先进控制技术在机组调控的研究[J]. 电力科技与环保, 2019, 35(5): 57-60.

[18] 曾喆昭, 刘文珏. 一阶时滞系统的智慧PI控制[J]. 控制理论与应用, 2019, 36(8): 1322-1328.

[19] ZHANG H, ZHAO S, GAO ZQ. An active disturbance rejection control solution for the two-mass-spring benchmark problem[J]. Proceedings of American Control Conference. Boston, MA, USA: IEEE, 2016: 1566-1571.

作者简介: 延寒(1989-), 男, 本科, 工程师, 研究方向: 过程控制及火电厂控制。