

DOI:10.11705/j.issn.1672-643X.2020.02.30

基于 ACO - BP 神经网络的土石坝位移监测模型研究

茹秋瑾¹, 何自立², 杨军超³, 李晓琳¹, 谭剑波^{1,2}

(1. 杨凌职业技术学院, 陕西 杨凌 712100; 2. 西北农林科技大学 水利与建筑工程学院, 陕西 杨凌 712100; 3. 陕西省引汉济渭工程建设有限公司, 陕西 西安 710010)

摘要: 建立安全监测网络模型来分析和预测大坝变形位移信息, 对保障大坝安全稳定服役意义重大。针对大坝安全监测 BP 神经网络模型运算复杂、收敛速度慢、易陷于局部最优、不能准确反映和预测大坝运行状况的问题, 引入蚁群算法 (ACO) 全局搜索功能搜寻 BP 神经网络参数最优解, 并通过样本数据训练 BP 网络获得大坝变形位移预测值。工程实例应用表明: ACO - BP 网络模型在参数优化方面较 BP 网络更易于收敛, 误差较小、预测性能良好, 可为大坝变形位移监测和安全预报提供一种新的非线性建模仿真分析方法。

关键词: 神经网络; 蚁群算法; 土石坝; 变形位移监测

中图分类号: TV698.1

文献标识码: A

文章编号: 1672-643X(2020)02-0196-06

Research on earth - rock dam displacement monitoring model based on ACO - BP neural networks

RU Qiuji¹, HE Zili², YANG Junchao³, LI Xiaolin¹, TAN Jianbo^{1,2}

(1. Yangling Vocational and Technical College, Yangling 712100, China; 2. College of Water Resources and Architectural Engineering, Northwest A & F University, Yangling 712100, China; 3. Hangjiang - to - Weihe River Valley Water Diversion Project Construction Co., Ltd., Xi'an 710010, China)

Abstract: Establishing a safety monitoring model to analyze and forecast the deformation and displacement of the dam is of great significance for its safe operation. The monitoring model of BP neural networks has the disadvantages of complicated operation and slow convergence, and it is easy to fall into localized optimization. These drawbacks will lead to inaccurate expression and prediction of the dam operation situation. In order to solve these problems, the ant colony optimization (ACO) algorithm was introduced to BP networks to search for optimal solution of parameters at overall situation, as well as to obtain the dam deformation prediction data through training the sample data by BP neural networks. The engineering case study indicates that the ACO - BP network model is easier to converge in parameter optimization than that of the BP network with less errors and good prediction performance, which can provide a new approach of nonlinear modeling and simulation for dam deformation displacement monitoring and safety prediction.

Key words: neural network; ant colony optimization (ACO) algorithm; earth - rock dam; deformation and displacement monitoring

1 研究背景

安全监测是大坝运行管理的一项重要工作, 通过安全监测数据分析可以及时准确了解大坝运行状况。国内外大坝安全监测主要采用数学模型 (统计模型、确定性模型和混合模型) 来进行模拟分析和

预测预报^[1-2], 如: 神经网络、层次分析、模糊综合评价和熵权等模型预测, 但单一模型很难兼顾模型参数指标的随机性和模糊性, 预测分析数据结果准确性不高、可信性较差^[3]。近年来, 许多学者针对大坝安全预测模型、安全监测评价模型等进行优化改进, 并取得较多研究成果。张柯等^[4]采用 ABC (arti-

收稿日期: 2019-07-07; 修回日期: 2019-11-05

基金项目: 国家科技支撑计划项目 (2012BAD10B02); 2018 年杨凌职业技术学院自然科学基金项目 (A2018012)

作者简介: 茹秋瑾 (1986-), 女, 陕西黄陵人, 硕士, 讲师, 研究方向为大坝安全监测与稳定性分析。

通讯作者: 何自立 (1977-), 男, 陕西宝鸡人, 博士, 副教授, 研究方向为水工结构与大坝安全监控。

ficial bee colony) 人工蜂群算法对土石坝变形的 SVM(support vector machine) 支持向量机模型进行优化,使模型拟合度和预测精度得到提高,泛化能力加强。冯学慧^[5] 提出基于熵权法与正态云模型结合的大坝安全监测评价体系,通过隶属度来评价大坝安全等级。何金平等^[6] 在文献中提出基于云模型的大坝安全监测评价方法,来处理大坝安全监测中存在的信息不确定性风险。王娟等^[7] 采用 KICA (kernel independent component analysis) 核独立分量分析原始样本数据的非线性特性,并结合 RVM(relevance vector machine) 关联向量机对大坝缺失监测数据进行插值回归。本文基于翟旭瑞等^[8] 提出的 BP 神经网络模型,采用 ACO (ant colony optimization) 蚁群算法对多层网络隐含单元的连接权值和阈值进行优化,构建 ACO - BP 神经网络模型自动预测分析大坝变形位移,使土石坝安全监测预报更为方便和准确。

2 BP 神经网络模型

2.1 BP 网络结构

BP 神经网络模型一般由输入层、隐含层和输出层 3 部分组成。文中采用 3 层 BP 网络结构,隐含层采用函数 Tansig,输出层采用函数 Purelin,通过网络自动学习耦合输入和输出样本数据间的任意非线性关系^[9-10],BP 神经网络结构如图 1 所示。




图 1 BP 神经网络结构图

2.2 土石坝位移影响因子

土石坝变形^[11] 是大坝监测中的重要监测项目,包括水平位移、竖向位移和纵向位移,其中以竖向位移(沉降量)为最大。竖向位移主要影响因素包括库水压力、温度效应和时效效应,即:

$$\delta = f(\delta_H) + f(\delta_T) + f(\delta_\theta) \quad (1)$$

式中: δ_H 为库水压力分量; δ_T 为温度分量; δ_θ 为时效分量。

大坝竖向位移和各变量间的映射关系为:

$$\delta = F(\delta_H, \delta_T, \delta_\theta) \quad (2)$$

(1) 水压分量 δ_H 。土石坝水压力主要由上游水体压力引起,压力可以分解为水平分量和垂直分量,而垂直位移主要由垂直分量引起,即:

$$\delta_H = \sum_{i=1}^3 a_i (H - H_0)^i \quad (i = 1, 2, 3) \quad (3)$$

式中: H 为观测竖向位移时的坝前水深,即库水位减去坝底高程, m ; H_0 为建模资料系列起始日的水深, m ; a_i 为水压分量的影响系数。

(2) 温度分量 δ_T 。已建大坝坝体内各点的温度主要与气温和水温的变化有关,主要采用气温作为分析因子。同时,考虑坝体内温度变化滞后于气温变化,即:

$$\delta_T = \sum_{i=1}^5 \beta_i \bar{T}_i \quad (i = 1, 2, \dots, 5) \quad (4)$$

式中: \bar{T}_i 为大坝垂直位移监测当日及其前 1 ~ 3 d、前 4 ~ 10 d、前 11 ~ 30 d、前 31 ~ 60 d 所对应的气温平均值, $^{\circ}C$; β_i 为温度分量的影响系数。

(3) 时效分量 δ_θ 。在水压、大坝自重等荷载作用下,时效变量的影响最为显著,即:

$$\delta_\theta = c_1 \theta + c_2 \ln \theta \quad (5)$$

式中: θ 为监测日至建模系列起始日的累计天数除以 100, d ; c_1, c_2 为时效分量的影响系数。

综合水压、温度和时效分量,建立土石坝竖向位移的关联性数学模型,即:

$$\delta = f_H(H - H_0)^i + f_T(\bar{T}_i) + f_\theta(\theta, \ln \theta) \quad (6)$$

选取 BP 网络位移模型的预报因子总集: 水压分量因子 3 个, $\{(H - H_0), (H - H_0)^2, (H - H_0)^3\}$; 温度分量因子 5 个, $\{\bar{T}_0, \bar{T}_{1-3}, \bar{T}_{4-10}, \bar{T}_{11-30}, \bar{T}_{31-60}\}$; 时效分量因子 2 个, $\{\theta, \ln \theta\}$, 共计 10 个预报因子。

3 ACO - BP 神经网络模型

3.1 ACO - BP 神经网络模型

Dorigo 博士于 1991 年利用蚁群活动规律创建蚁群算法,其正反馈、分布式计算和全局寻优等特征使其在数据挖掘、模糊建模、群体智能等领域得到广泛应用^[11-15]。将蚁群算法引入到 BP 神经网络模型对网络连接参数进行优化,即 ACO - BP 神经网络模型。BP 神经网络模型存在易陷入局部极小等不足,针对土石坝竖向位移动态变化的非线性特性,建立基于蚁群算法改进的 3 层反向迭代传播神经网络模型,该模型结构见图 2。

利用蚁群算法(ACO)全局寻优能力为 BP 提供 $\sigma(\sigma \geq 1)$ 较优的初始权值组合,来克服 BP 算法对

初值设置较敏感、易陷入局部最优的缺点；再利用BP算法梯度下降的原理进一步“细调”权值，寻找网络真正的全局最优点，来克服由于对定义域进行分割带来的量化误差及单一蚁群算法训练网络耗时过长的不足。样本数据经隐含层学习后，经输出层（output layer）传递函数（Purelin）训练生成大坝位移和3个影响因素之间的关联性数据集。




图2 基于蚁群算法改进的ACO-BP网络模型

3.2 ACO-BP神经网络算法流程

将蚁群算法(ACO)引入到BP神经网络模型对网络连接参数进行优化,其逻辑判断流程见图3。

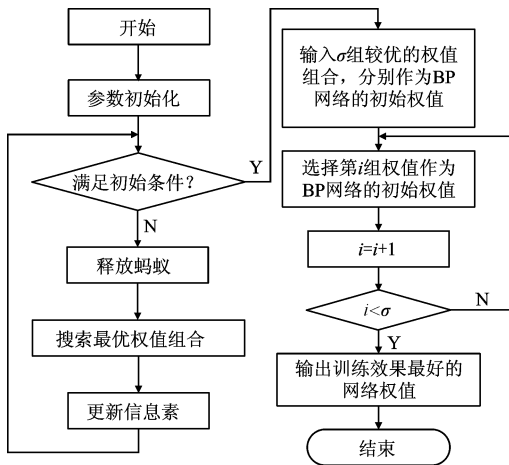


图3 ACO-BP网络模型逻辑判断流程

采用ACO-BP方法训练神经网络的步骤为:ACO-BP神经网络通过初始化、神经网络参数选定、信息素调节等步骤的不断重复,使所有路径收敛为一条路径,通过计算网络输出误差值和实际输出误差值对比,找到局部最优解;计算获得误差满足要求的全局最优解,否则重新寻优。该方法克服了BP

神经网络易陷入局部最优的缺点。

4 算例分析

4.1 工程概况

某大坝为碾压式心墙土石坝,最大坝高105.30 m,坝长297.40 m,水库库容 $5.21 \times 10^8 \text{ m}^3$,校核洪水位708.80 m,正常蓄水位704.00 m。工程以发电为主,兼顾防洪、灌溉、养殖等功能。1983年,主体工程竣工验收。大坝安全定期检查,观测项目主要有渗流、坝体变形、应力应变观测^[16-17]等。运行检查实测坝体浸润线均较低,防渗结构设计整体符合规范要求,施工质量优良。

4.2 大坝位移监测

因在坝体变形中,以竖向位移(沉降量)为最大^[18],所以本文主要对坝体垂直方向位移监测数据进行分析,优选监测数据较完善、资料代表性较强和综合性较全面的大坝下游坝肩处的D7-2、D8-2、D9-2共3个测点,对其2016年7月12日-2016年11月30日之间的监测数据进行分析预测。大坝垂直方向位移各监测孔布置位置见图4,D7-2、D8-2、D9-2 3个测点的位置及变形参数见表1。采用坝壳位移监测中下游7.8 m处D7-2、D8-2、D9-2 3个变形测点的竖向位移及相应水位、温度和时效等数据资料作为学习样本训练ACO-BP神经网络模型。

4.3 BP网络模型构建

(1)输入、输出量的确定。根据土石坝位移监测内容及特点,选择包含输入层、隐含层和输出层的3层神经网络结构^[19-20]。测点布置选取温度分量因子5个,水压分量因子3个和时效分量因子2个,共10个预报因子,即神经网络模型输入层节点数为10;输出量为大坝竖向位移。

(2)隐含层节点数的确定。运用MATLAB软件,训练次数为50 000,在 $[k-2, k+2]$ 区间找出最佳隐含层节点数,对每个节点数分别测试5次后,算出平均次数。其中,测点D7-2不同神经元个数实测数据的网络预测误差见图5,训练次数见表2。

表1 大坝下游坝肩D7-2、D8-2、D9-2 3个测点的位置及变形参数

测点	仪器埋设桩号		初始观测值		备注
	纵向(Y向)/m	横向(X向)/m	标点高程/m	沉降位移基准值/mm	
D7-2		0+117.00	709.1114	上4.07	沉降位移上抬为负,下沉为正
D8-2	下0+007.80	0+144.00	709.0923	上0.89	
D9-2		0+184.00	708.9576	上6.05	

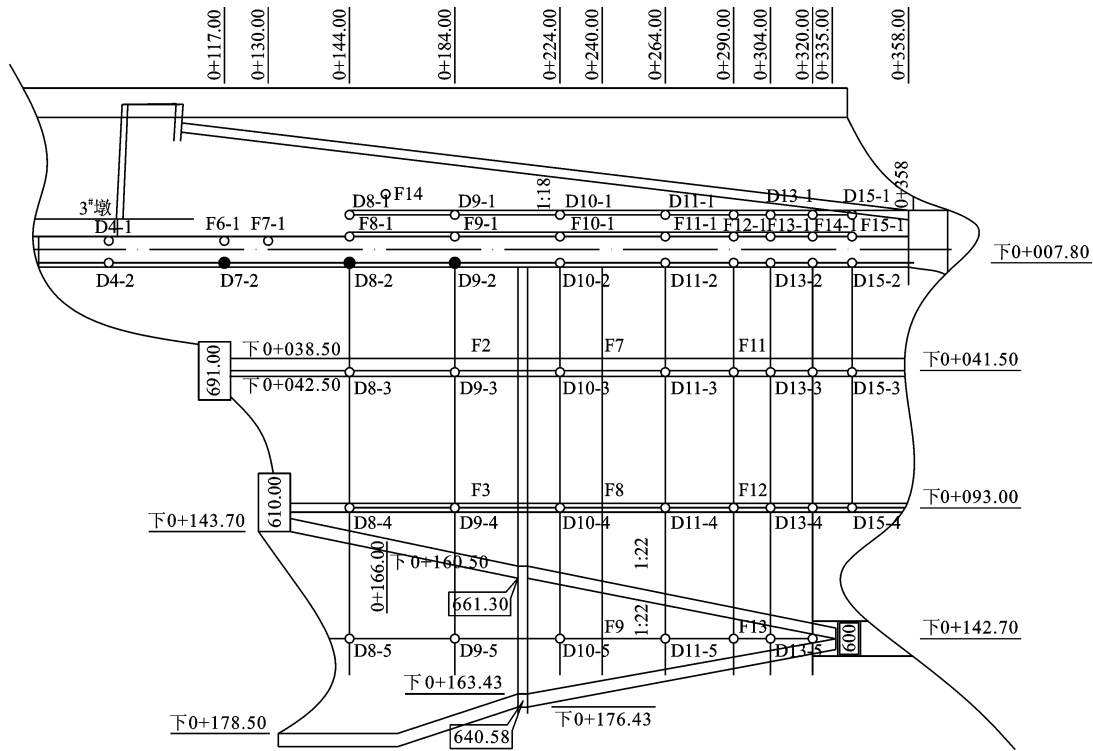


图 4 土石坝变形位移监测测点布置图(单位:m)




图 5 D7 - 2 测点不同隐含层节点数竖向位移预测误差对比

表 2 不同隐含层节点数的训练次数

隐含层节点数	19	20	21	22	23
平均训练次数	23035	23763	18369	22062	26548

从图 5 和表 2 不同神经元个数预测误差对比分析可知:选取隐含层节点数为 21,其在 5 个节点组合中平均训练次数最少,为 18 369,网络预测误差也相对较小,训练次数较少,收敛速度较快。

4.4 ACO - BP 网络模型参数

ACO - BP 网络进行蚁群优化编码定义为矩阵 Matrix_wb,通过自动寻优获得与连接权值和阈值矩阵维数相等的信息素矩阵 Matrix_phe,对应每只蚂蚁选的权值矩阵为 Matrix_w;权值位置矩阵为 Matrix_place。3 层 BP 神经网络主要结构参数为:输入

层神经元数为 10,隐含层神经元数为 21,输出层神经元数为 1,故寻优规模 = $10 \times 21 + 21 \times 1 + 21 + 1 = 253$ ^[10],权值区间的最小值 $W_{\min} = -1$,最大值 $W_{\max} = 1$;最大迭代次数 500,信息启发式因子 $\alpha = 1$,期望值启发式因子 $\beta = 1$ 。ACO - BP 网络模型参数设置见表 3。

表 3 ACO - BP 网络模型参数设置

算法仿真参数	参数值	算法仿真参数	参数值
输入层神经元数	10	问题规模	253
输出层神经元数	1	蚁群规模	50
隐含层神经元数	21	信息挥发度	0.7
隐含层传递函数	Tansig	总信息量	30
输出层传递函数	Purelin	网络参数备选值范围	15 个 $[-1,1]$

对坝体 D7 - 2、D8 - 2、D9 - 2 3 个变形测点,采用 MATLAB 2016 软件按表 3 参数指标编写 ACO - BP 网络模型预测程序,并经样本学习训练后生成对应预测数据,对大坝变形位移进行预测。

4.5 模型预测结果分析

坝体 D7 - 2、D8 - 2、D9 - 2 3 个测点安全监测数据分别采用 BP 网络模型及 ACO - BP 网络模型,针对竖向位移样本进行学习训练和对比分析。限于文章篇幅,仅展示 D7 - 2 测点分析结果,其监测数据经 ACO - BP 模型学习训练后,采用 MATLAB 软

件运算生成的拟合曲线,见图6。D7-2测点实测值与预测值间的数值对比见图7和表4。

从图6、7和表4可知,D7-2测点网络模型输出的预测拟合值与实测值总体变换趋势一致,拟合

效果较好。个别数据点存在拟合精度偏低问题,主要是模型处于不断自学习过程,不影响全局寻优预测。3个测点的安全监测数据采用BP和ACO-BP两种模型处理后,其预测精度对比详见表5。




图6 D7-2测点竖向位移 ACO-BP网络模型拟合曲线




图7 D7-2测点竖向位移不同模型预测值与实测值对比

表4 D7-2测点竖向位移BP和ACO-BP两种模型预测结果与实测数据对比

日期/ (年-月-日)	实测值/ mm	BP 预报 值/mm	BP 预报 差值/mm	BP 相对 误差/%	ACO-BP 预 报值/mm	ACO-BP 预 报差值/mm	ACO-BP 相 对误差/%
2016-11-21	15.910	15.404	-0.506	-3.218	15.726	-0.184	-1.157
2016-11-22	15.740	16.093	0.353	2.232	15.818	0.078	0.496
2016-11-23	15.780	16.310	0.530	3.322	15.955	0.175	1.109
2016-11-24	16.380	16.443	0.063	0.382	16.512	0.132	0.806
2016-11-25	16.950	16.595	-0.355	-2.122	16.733	-0.217	-1.280
2016-11-26	16.880	16.498	-0.382	-2.249	16.986	0.106	0.628
2016-11-27	16.800	16.425	-0.375	-2.216	16.922	0.122	0.726
2016-11-28	16.480	16.962	0.482	2.900	16.618	0.138	0.837
2016-11-29	17.460	17.120	-0.340	-1.942	17.512	0.052	0.298
2016-11-30	17.460	17.145	-0.315	-1.794	17.563	0.103	0.590

表5 3个竖向位移测点的BP和ACO-BP两种模型预测精度对比

模型	测点 D7-2			测点 D8-2			测点 D9-2		
	均方误差/mm	平均绝对误差/mm	平均相对误差/%	均方误差/mm	平均绝对误差/mm	平均相对误差/%	均方误差/mm	平均绝对误差/mm	平均相对误差/%
BP 网络	0.397	0.370	2.237	0.311	0.286	1.668	0.323	0.300	1.521
ACO-BP 网络	0.139	0.131	0.793	0.121	0.108	0.630	0.114	0.104	0.526

由表5可知,参数条件相同的情况下,ACO-BP网络模型预测值的均方误差、平均绝对误差、平均相对误差均小于BP网络模型的相应数值,且ACO-BP模型对样本训练具有更好的逼近能力,更易于收敛。

5 结论

大坝变形位移监测 ACO-BP网络模型通过引入蚁群算法,全局寻优 BP网络连接权值和阈值来

拟合和预测大坝变形位移发展规律,确保土石坝安全监测预报更为准确可靠。通过工程实例分析,得出以下结论:

(1) ACO-BP网络模型在寻参过程中,采用ACO蚁群算法对多层网络隐含单元的连接权值和阈值进行训练优化,既能发挥蚁群算法的正反馈优势又能实现全局寻优,避免陷入“超前”或“滞后”的局部极小值寻优,加快了BP网络最优解的收敛速率。

(2) ACO-BP网络模型预测值与实测值的相对

误差相对于BP网络模型有了明显减小,在相同参数条件下,ACO-BP模型拟合值的均方误差更小、预测拟合能力更强、可靠性更高,能更好地适用于大坝变形位移的预测预报。可在此基础上构建多维复杂关联因素的安全预警模型,确保大坝安全稳定服役。

参考文献:

- [1] 朱文锋,高超丹,庄克云,等. 基于优化AHP及云模型的大坝安全综合评价[J]. 中国农村水利水电,2019(6): 125-130.
- [2] 潘洁晨. 基于Matlab的土石坝变形分析BP神经网络模型的建立——以哈尔滨西泉眼水库大坝为例[J]. 水资源与水工程学报,2012,23(3):166-169.
- [3] 陈曦,曾亚武,刘伟. 基于模糊层次分析法的农村水库大坝安全二级模糊综合评价[J]. 水利水电技术,2019,50(2):168-176.
- [4] 张柯,杨杰,程琳. 基于ABC-SVM的土石坝变形监测模型[J]. 水资源与水工程学报,2017,28(4):199-204.
- [5] 冯学慧. 基于熵权法与正态云模型的大坝安全综合评价[J]. 水电能源科学,2015,33(11):57-60.
- [6] 何金平,高全,施玉群. 基于云模型的大坝安全多层次综合评价方法[J]. 系统工程理论与实践,2016,36(11):2977-2983.
- [7] 王娟,杨杰,程琳. 基于KICA-RVM的大坝缺失监测数据插值方法[J]. 水资源与水工程学报,2017,28(1): 197-201.
- [8] 翟旭瑞,吕振中,王国松. 基于BP神经网络的大坝安全监测系统评价研究[J]. 水资源与水工程学报,2007(1):60-63.
- [9] SINHA A K, SENGUPTA M. Expert system approach to slope stability[J]. Mining Science and Technology, 1989, 8(1):21-29.
- [10] ROSIPAL R, CLANCY D. Kernel partial least squares for nonlinear regression and discrimination[J]. Neural Network World, 2003,13(3): 291-300.
- [11] 吴中如. 水工建筑物安全监控理论及其应用[M]. 北京:高等教育出版社,2003.
- [12] 杨军超. ACO-BP神经网络在大坝监测数据处理中的应用研究[D]. 西安:西安理工大学,2013.
- [13] 侯立文,蒋馥. 一种基于蚂蚁算法的交通分配方法及其应用[J]. 上海交通大学学报,2001(6):930-933.
- [14] 王笑蓉,吴铁军. Flow shop问题的蚁群优化调度方法[J]. 系统工程理论与实践,2003(5):65-71.
- [15] 李生红,刘泽民,周正. ATM网上基于蚂蚁算法的VC路由选择方法[J]. 通信学报,2000,21(1):22-28.
- [16] 金雁,赵耀. 基于改进蚁群算法的船舶主尺度优化[J]. 华中科技大学学报(自然科学版),2008,36(11): 99-102.
- [17] 雷霆,胡江. 大坝渗流监测的蚁群神经网络模型[J]. 水电能源科学,2008,26(5):57-58+106.
- [18] 陈平志,陈尧隆,杨杰,等. 碧口土石坝外部变形监测分析与安全性态评价[J]. 电网与水力发电进展,2007,23(4):55-59.
- [19] 刘朝利. 神经网络在土石坝位移监测中的应用研究[J]. 黑龙江水利科技,2018,46(11):5-8.
- [20] 解建仓,王玥,雷社平,等. 基于ARIMA模型的大坝安全监测数据分析与预测[J]. 人民黄河,2018,40(10): 131-134.