

基于 IPSO-BP 模型的大坝多源 监测数据预报与反演^{* 1}

胡纪元^{1,2)} 文鸿雁^{1,2)} 周 吕^{1,2)} 陈冠宇^{2,3)}

(1)广西空间信息与测绘重点实验室,桂林 541004
(2)桂林理工大学测绘地理信息学院,桂林 541004
(3)桂林理工大学广西矿冶与环境科学实验中心,桂林 541004

摘 要 提出一种改进的粒子群算法(IPSO)。该算法在粒子群速度调整中加入了邻域最优粒子影响,并引入惯性权重非线性递减策略和学习因子动态调整方法。将改进的粒子群算法与BP神经网络结合形成IPSO_BP模型,并应用于大坝多源变形监测数据的预报与反演。结果表明,IPSO_BP模型收敛速度更快,有效提高了大坝多源监测数据的预报与反演能力。

关键词 改进的粒子群算法;BP神经网络;IPSO-BP;大坝;预报与反演

中图分类号:P258

文献标识码:A

STUDY ON DAM PREDICTION AND INVERSION WITH MULTI-SOURCE MONITORING DATA BASED ON IPSO-BP MODEL

Hu Jiyuan^{1,2)}, Wen Hongyan^{1,2)}, Zhou Lü^{1,2)} and Chen Guanyu^{2,3)}

(1) Guangxi Key Laboratory for Spatial Information and Geomatics, Guilin 541004
(2) College of Surveying, Mapping and Geoinformation, Guilin University of Technology, Guilin 541004
(3) Guangxi Scientific Experiment Center of Mining, Metallurgy and Environment, Guilin 541004

Abstract In this paper, an improved particle swarm optimization (IPSO) was proposed. In the algorithm, the influence of neighborhood optimal particle was considered, nonlinear inertia weight decreasing strategy and learning factor dynamic adjustment method was introduced. the dam prediction and inversion of multi-source monitoring data was carried using the IPSO_BP model which was formed by the improved IPSO combined with BP neural network. The results show that the convergence speed of IPSO_BP model is faster, the new model can effectively improve the ability of prediction and inversion of dam multi-source monitoring data.

Key words: IPSO; BP neural network; IPSO-BP; dam; prediction and inversion

对观测得到的大坝变形多源监测数据进行准确
预报与反演是保障大坝安全的重要手段^[1]。当前

应用较多的大坝预报与反演方法主要是基于数理分
析的统计模型和神经网络模型^[2]等,这类模型存在

* 收稿日期:2013-12-27

基金项目:国家自然科学基金项目(41071294);广西空间信息与测绘重点实验室项目(桂科能 130511402,1207115-06);广西“八桂学者”岗位专项;广西矿冶与环境科学实验中心项目(KH2012ZD004);广西研究生教育创新计划项目(YCSZ2014151, YCSZ2012083)。

作者简介:胡纪元,男,1988年生,研究生,研究方向为精密工程测量与变形监测技术。E-mail:903895845@qq.com。

通讯作者:文鸿雁,男,1963年生,教授,博士,研究方向为精密工程测量与专题信息系统。E-mail:glitewhy@163.com。

对大坝变形多源监测数据非线性映射能力不强,对初始值依赖较大,易陷入局部最小值等缺点。本文引入标准粒子群算法(PSO),并对其进行改进^[3],通过全局与局部搜索机制和惯性权重非线性递减策略,使算法能很好地反映非线性的搜索过程,并快速跳出局部极值。将改进的粒子群算法(IPSO)与 BP 神经网络结合组成 IPSO-BP 模型,并应用于大坝变形多源监测数据的预报与反演。结果表明,IPSO-BP 模型收敛速度更快,能有效提高大坝多源监测数据的预报与反演能力。

1 标准 PSO 算法及其改进

1.1 标准 PSO 算法

设第 i 个粒子在 D 维搜索空间中的速度为:

$$v_i = (v_{i1}, v_{i2}, \dots, v_{id}, \dots, v_{iD})$$

其在 D 维搜索空间个体历史中最优位置为:

$$x_i = (x_{i1}, x_{i2}, \dots, x_{id}, \dots, x_{iD})$$

粒子通过动态追踪个体极值与全局极值实时更新粒子速度和位置的公式为:

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (p_{Best_{id}}^k - x_{id}^k) + c_2 r_2 (g_{Best_{id}}^k - x_{id}^k) \quad (1)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (2)$$

式中, ω 为惯性权重; c_1 与 c_2 为学习因子; r_1 与 r_2 为 $[0, 1]$ 之间的随机数; k 为当前迭代次数。 ω 通常采用线性递减策略, $c_1 = c_2 = 2$, 为防止盲目搜索, 粒子位置和速度限制在一定的区间内。

1.2 改进的粒子群算法

鉴于大坝变形多源监测数据的高度复杂且非线性化特性, 引入惯性权重非线性递减优化策略^[4]。非线性调整策略可表示为:

$$\omega = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \exp\left(1 - \frac{k_{\max}}{k}\right) \quad (3)$$

标准粒子群算法主要是对自身历史最优位置和全局最优位置进行追踪, 而忽略粒子邻域范围内最优粒子的影响。因此, 在粒子速度调整公式中加入邻域最优粒子的影响 (l_{Best}), 同时对其学习因子进行动态调整, 进而促使算法快速收敛, 避免陷入局部极小值。改进算法为^[5-6]:

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (p_{Best_{id}}^k - x_{id}^k) + c_2 r_2 (g_{Best_{id}}^k - x_{id}^k) + c_3 r_3 (l_{Best} - x_{id}^k) \quad (4)$$

$$c_2 = c_3 = 2 \times \left(1 - \frac{k}{k_{\max}}\right) \quad (5)$$

2 改进的粒子群算法优化 BP 神经网络

对 3 层 BP 网络的权值和阈值进行优化。设神经网络输入层、隐含层、输出层神经元数分别为 I 、 H 、 O 。输入层与隐含层连接权值为 w_{IH} , 隐含层与输

出层连接权值为 w_{OH} , 隐含层阈值 θ_H , 输出层阈值 θ_O 。将权值和阈值作为搜索空间中的粒子, 利用改进的粒子群算法对其进行搜索^[7-8], 即构成 IPSO-BP 模型。IPSO-BP 模型基本步骤为:

1) 确定问题维度 D 、目标函数 $f(\cdot)$ 、粒子种群规模、邻域维数、惯性权重与学习因子初值, 网络预设精度 ε 。

$$D = I * H + H * H + H * O + O, f(\cdot) = \frac{1}{S} \sum_{i=1}^S d_o^S - y_o^S \quad (6)$$

式中, d_o^S 为输出层第 O 个节点的期望输出, y_o^S 为网络的计算输出。

2) 初始化粒子速度和位置, 计算每个个体的适应度值, 据此获得 p_{Best} 、 g_{Best} 、 l_{Best} 。

3) 通过改进的粒子群算法公式更新粒子的速度和位置, 并计算新粒子的适应度。

4) 根据步骤 3) 计算出的适应度对 p_{Best} 、 g_{Best} 、 l_{Best} 进行更新。

5) 由 ε 和 k_{\max} 判断优化算法是否结束。若满足其中任何一个条件, 算法结束, 输出最优个体的一组权值阈值; 不满足, 则转到步骤 3)。

改进粒子群优化 BP 神经网络模型 (IPSO-BP) 的计算流程如图 1。

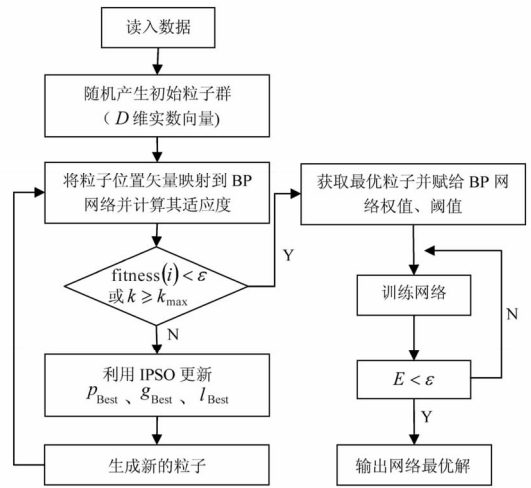


图 1 IPSO-BP 模型流程

Fig. 1 Flow chart of IPSO-BP model

3 多源监测数据预报与反演

对于混凝土大坝, 其位移量主要取决于水压 (H_1, H_2^t, H_3^t)、温度 ($T_0, \sin(2p_it/365), \cos(2p_it/365), \sin(4p_it/365), \cos(4p_it/365)$) 以及时效 ($\theta, \ln\theta$) 等因素, 其中 $\theta = 0.01t$ (t 为起始观测至本次观测的累计天数)。本文对丰满大坝一坝段 1985-01-04 ~ 1988-05-04 共 190 期多源监测数据进行预报与反演。

1) 结合 BP 神经网络,应用平均影响值 (MIV)^[9]对输入模式中的 H_1 、 H_1^2 、 H_1^3 、 T_0 、 $\sin(2p_it/365)$ 、 $\cos(2p_it/365)$ 、 $\sin(rp_it/365)$ 、 $\cos(4p_it/365)$ 、 θ 、 $\ln\theta$ 共 10 个因子进行筛选。MIV 计算过程:对第 $n(n=1,2,\cdots,10)$ 个因子在原始监测值基础上分别增加、减小 10%,其他 9 个因子监测值保持不变,构成两个新的训练样本 P_1 、 P_2 。利用已建好的 BP 网络分别对 P_1 、 P_2 进行仿真,求两仿真结果的差值。对差值求平均,得出第 n 个因子对大坝变形量的贡献值^[10],即 MIV_{-n} 。每个因子的贡献值如表 1。

表 1 大坝影响因子的 MIV 值

Tab.1 The MIV values of dam impact factors

影响因子 n	MIV _{-n}
H_1	0.149 1
H_1^2	-0.066 5
H_1^3	0.054 5
T_0	-0.131 4
$\sin(2p_it/365)$	-0.133 7
$\cos(2p_it/365)$	-0.043 8
$\sin(4p_it/365)$	-0.128 5
$\cos(4p_it/365)$	0.041 7
θ	-0.119 3
$\ln\theta$	-0.135 5

对这 10 个影响因子按照 MIV 大小进行排序, 去掉 MIV 值的绝对值小于 10% 的影响因子, 最后确定神经网络输入模式为: H_1 、 $\ln\theta$ 、 $\sin(2p_it/365)$ 、 T_0 、 $\sin(4p_it/365)$ 、 θ 。可知, 输入层节点数为 6 个。

2)对步骤1)确定的影响因子进行归一化处理:

$$x' = 2 \times \frac{x - x_{\max}}{x_{\max} - x_{\min}} - 1 \quad (7)$$

式中, x' 是归一化后的样本数据, x 是原始样本数据, x_{\max} 和 x_{\min} 是样本中各输入对应的最大和最小值。

3)综合考虑输入节点数,根据经验公式反复试凑,确定网络的隐含层节点数为13。构建 $6 \times 13 \times 1$ 的神经网络模型,可确定问题维度 $D = 105$,种群规模30,最大迭代次数3 000。

4) 将 190 期数据分为训练样本 140 期, 验证样本 30 期, 测试样本 20 期。分别用 LM-BP 神经网络模型、标准 PSO 优化 BP 网络模型 (SPSO-BP)、IPSO-BP 模型对丰满大坝变形多源监测数据进行预报与反演, 结果见表 2。表中 fitnesszbest 为粒子群全局最佳适应度值。丰满大坝后 20 期多源变形监测数据预报与反演结果如表 3, 验证样本与测试样本仿真结果如图 2 所示。

5)大坝水平位移精度要求。由表 2 可知,从优化时间上看,SPSO-BP 模型较 LM-BP 网络模型迭代次数少,收敛速度快;IPSO-BP 模型在迭代次数、收

敛速度上又要优于 SPSO-BP 模型。表 3、图 2 中 IPSO-BP 法个别预测值有较大偏差,但从测试样本整体上看,其精度最高,预测样本均方差为 0.507 mm; SPSO-BP 模型次之,均方差 0.546 mm; BP 网络模型精度最低,预测样本均方差为 0.660 mm。3 种方法的测试样本均方根差均小于位移量均方根差的限值,验证了神经网络优化方法在大坝变形预测中的可靠性,其中 IPSO-BP 模型在大坝变形多源监测数据预报与反演方面效果更好。

表 2 3 种网络模型优化结果

Tab.2 Optimization results of the three network models

网络模型	训练 时间 /s	迭代 次数	验证样本 均方差 mm	fitnesszbest
LM_BP	19	3 000	0.504	—
SPSO-BP	0.637	19	0.421	2.104 9
IPSO-BP	0.573	14	0.401	2.096 1

表3 3种网络模型预报与反演结果比较

Tab. 3 Comparison of prediction and inversion results with the three network models

期数	实测值 /mm	LM_BP		SPSO-BP		IPSO-BP	
		预测值 /mm	残差	预测值 /mm	残差	预测值 /mm	残差
171	3.82	3.41	-0.41	3.33	-0.49	3.42	-0.40
172	2.75	3.39	0.64	2.59	-0.16	2.61	-0.14
173	2.32	1.60	-0.72	2.61	0.29	2.64	0.32
174	1.65	2.15	0.50	1.94	0.29	1.85	0.20
175	1.24	2.15	0.91	1.75	0.51	0.93	-0.31
176	0.91	0.75	-0.16	1.24	0.33	1.40	0.49
177	-0.08	0.46	0.54	0.41	0.49	0.29	0.37
178	-0.35	-0.05	0.30	-0.19	0.16	-0.04	0.31
179	-1.02	-0.66	0.36	-0.63	0.39	-0.91	0.11
180	-1.91	-1.42	0.49	-1.47	0.44	-1.54	0.37
181	-2.61	-1.82	0.79	-2.29	0.32	-1.84	0.77
182	-2.88	-2.67	0.21	-3.47	-0.59	-2.37	0.51
183	-3.4	-3.06	0.34	-3.39	0.01	-2.73	0.67
184	-3.56	-2.65	0.91	-3.66	-0.10	-3.48	0.08
185	-3.64	-2.49	1.15	-2.56	1.08	-2.76	0.88
186	-3.15	-2.81	0.34	-3.96	-0.81	-2.91	0.24
187	-3.18	-2.45	0.73	-2.41	0.77	-2.63	0.55
188	-1.4	-2.54	-1.14	-2.36	-0.96	-2.53	-1.13
189	-0.1	-0.16	-0.06	0.29	0.39	0.21	-0.11
190	0.75	-0.19	-0.94	-0.02	-0.77	0.15	-0.60

LM_BP 法测试样本均方根差为 0.660 mm;SPSO-BP 法测试样本均方根差为 0.546 mm;IPSO-BP 法测试样本均方根差为 0.507 mm




图2 3种模型的大坝水平位移预报与反演结果比较
Fig.2 Comparison of dam horizontal displacement prediction and inversion results with three network models

4 结 语

针对 BP 神经网络权阈值初始化随机性的缺陷,利用 IPSO 算法对 BP 网络进行优化,同时,根据 BP 神经网络平均影响值法 (MIV) 对大坝的众多影响因子进行筛选,选择合适的输入模式,结合 IPSO 算法建立大坝变形 IPSO-BP 模型,并对大坝变形多源监测数据进行预报与反演。结果表明,IPSO-BP 模型在大坝变形多源监测数据预报与反演方面,较 SPSO-BP 模型、BP 网络模型在各方面性能上有较大提高。

参 考 文 献

1 贾金生. 中国大坝建设 60 年[M]. 北京:中国水利出版社,2013. (Jia Jinsheng. Dam construction in China-a sixty-year review[M]. Beijing:China Water Power Press,2013)

2 岳建平,甄宗坤. 基于粒子群算法的 Kriging 插值在区域地面沉降中的应用[J]. 测绘通报,2012(3):59-62. (Yue Jianping,Zhen Zongkun. Application of particle swarm optimization based Kriging interpolation method in regional land subsidence[J]. Bulletin of Surveying and Mapping, 2012(3):59-62)

3 刘殿锋,刘耀林,赵翔. 多目标微观邻域粒子群算法及其在土壤空间优化抽样中的应用[J]. 测绘学报,2013,42(5):722-728. (Liu Dianfeng,Liu Yaolin,Zhao Xiang. Soil spatial sampling design based on a multi-objective micro-

neighborhood particle swarm optimization algorithm[J]. Acta Geodaetica et Cartographica Sinica, 2013, 42(5):722-728)

4 王建. 改进粒子群算法求解 GPS 段基线整周模糊度的研究[J]. 大地测量与地球动力学,2012(4):148-151. (Wang Jian. Research on ambiguity resolution of GPS short baseline by using improved particle swarm optimization[J]. Journal of Geodesy and Geodynamics,2012(4):148-151)

5 张文成. 改进策略的粒子群算法及其实验测试[J]. 计算机工程与设计,2012,33(10):3945-3949. (Zhang Whencheng. Improved particle swarm optimization and experimentation[J]. Computer Engineering and Design,2012,33(10):3945-3949)

6 王建国. 改进粒子群优化神经网络及其在产品质量建模中的应用[J]. 北京科技大学学报,2008,30(10):1188-1193. (Wang Jianguo. Improved particle swarm optimized back propagation neural network and its application to production quality modeling[J]. Journal of University of Science and Technology Beijing,2008,30(10):1188-1193)

7 徐峰,王崇倡,张飞. 粒子群-BP 神经网络模型在大坝变形监测中的应用[J]. 测绘科学,2012,37(4):181-183. (Xu Feng,Wang Chongchang,Zhang Fei. Application of particle swarm optimization-BP neural network in dam displacement prediction[J]. Science of Surveying and Mapping, 2012,37(4):181-183)

8 郑金兴. 粒子群优化人工神经网络在高速铣削力建模中的应用[J]. 计算机集成制造系统,2008,14(9):1710-1716. (Zheng Jinxing. Application of particle-swarm-optimization-trained artificial neural network in high speed milling force modeling[J]. Computer Integrated Manufacturing Systems,2008,14(9):1710-1716)

9 王紫薇,叶奇旺. 基于神经网络 MIV 值分析的肿瘤基因信息提取[J]. 数学实践与认识,2011,41(14):47-58. (Wang Ziwei,Ye Qiwan. Cancer informative gene identification based on MIV method of neural network[J]. Mathematics in Practice and Theory,2011,41(14):47-58)

10 王志军,刘红彩. 遗传神经网络在大坝变形预报因子重要度判定中的应用[J]. 水电自动化与大坝监测,2008,32(5):69-71. (Wang Zhijun,Liu Hongcai. Application of genetic neural network to factor weight determination of dam deformation[J]. Hydropower Automation and Dam Monitoring,2008,32(5):69-71)