

文章编号:1001-9081(2009)10-2723-03

改进 PSO 与小波的地基沉降预测应用

董吉文¹, 吴瑞海¹, 段琪庆²

(1. 济南大学 信息科学与工程学院, 济南 250022; 2. 济南大学 土木建筑学院, 济南 250022)

(wrhwww@163.com)

摘要: 将改进的具有双群特性及带变异算子的粒子群优化算法与小波分析结合优化神经网络预测地基沉降量。针对粒子群算法易陷入局部极小值的缺陷, 将粒子总群分成两个子群, 分别对两个子群进行不同的搜索策略以增强算法的全局和局部搜索能力。其中一个子群采用变惯性权重进行局部细搜索; 另一个子群采用大的惯性权重进行全局搜索, 并与小波分析去噪结合, 优化神经网络参数, 对地基累计沉降数据进行预测。实验结果表明这种划分使算法有较强的全局和局部搜索能力, 同时提高了预测精度。

关键词: 小波分析; 粒子群优化; 地基沉降; 预测

中图分类号: TP183 文献标志码: A

Application of improved PSO algorithm and wavelet analysis in foundation settlement prediction

DONG Ji-wen¹, WU Rui-hai¹, DUAN Qi-qing²

(1. School of Information Science and Engineering, University of Jinan, Jinan Shandong 250022, China;

2. School of Civil Engineering and Architecture, University of Jinan, Jinan Shandong 250022, China)

Abstract: The authors used the improved Particle Swarm Optimization (PSO) algorithm that has two subgroups and a mutation operator binding wavelet analysis to optimize neural network parameter to forecast the foundation settlement. Since the basic particle swarm optimization easily falls into the local minimal value, the authors divided the particle swarm into two subgroups. In one subgroup the inertia weight of the particle swarm optimization algorithm decreased when the iterations increased. And in the other subgroup the particle swarm optimization algorithm adopted big inertia weight to do the overall situation search. And the authors used this improved algorithm binding wavelet analysis to optimize the neural network parameter to forecast foundation settlement. The experimental result indicates that this method has strong global and local search ability, and has high forecast precision.

Key words: wavelet analysis; Particle Swarm Optimization (PSO); foundation settlement; prediction

0 引言

小波分析由于它具有提取信号时频域局部信息的特点, 而被广泛应用。在实际地基沉降观测工程中, 由于地理、施工等因素的影响, 原始沉降观测数据不可避免地混入噪声, 对观测数据进行去噪处理是提高预测精度的有效方法^[1-2]。

粒子群优化(Particle Swarm Optimization, PSO)算法^[3-4]是一种基于迭代的寻优算法, 因简单易实现而被广泛应用, 但它易陷入局部极小值区域。为此文献[5]借助文献[6]的思想, 将粒子群划分成两个动态变化的子粒子群 s_1 和 s_2 , 对 s_1 采用随迭代次数递减的惯性权重进行搜索, 对 s_2 采用较大的惯性权重进行全局搜索, 两个子群的大小随迭代的进行动态变化。本文在文献[5]的方法基础上进行了改进, 当算法陷入局部极小值时进行混合变异, 即对 s_1 采用小步长的高斯变异, 对 s_2 采用大步长的柯西变异, 并与小波分析结合预测地基累计沉降量, 与标准 PSO 算法做了对比。实验表明本文的方法具有良好的全局和局部搜索能力, 预测精度高。

1 小波分析理论基础

1.1 小波变换的定义^[1]

小波变换的基本思想是用一族函数去表示或逼近一信号

或函数。这一族函数称为小波函数系, 它是由一基本小波函数通过平移和伸缩构成的。若设基本小波函数为 $\varphi(t)$, 平移和伸缩因子分别为 a 和 b , 则小波变换基底的定义为:

$$\varphi_{a,b}(t) = |a|^{-1/2} \varphi\left(\frac{t-b}{a}\right); a, b \in \mathbf{R}, a \neq 0 \quad (1)$$

对于任意的函数或信号 $f(t) \in L^2(\mathbf{R})$ ($L^2(\mathbf{R})$ 表示平方可积的实数空间), 其小波变换为该函数与小波函数的内积:

$$W_f(a, b) = \langle f(t), \psi_{a,b}(t) \rangle = |a|^{-1/2} \int_{\mathbf{R}} f(t) \bar{\psi}\left(\frac{t-b}{a}\right) dt \quad (2)$$

其中 $\bar{\psi}(t)$ 是 $\psi(t)$ 的共轭。

由于连续小波变换系数 $W_f(a, b)$ 的信息量是冗余的, 为了减少冗余度, 通常需要将连续小波变换离散化。一种最常用的离散方法就是将尺度按幂级数进行离散化。将式(2)中的 a, b 离散化, 取 $a = a_0^j, b = k b_0 a_0^j$ ($a > 1, b_0 \in \mathbf{R}, j, k \in \mathbf{Z}$), 代入式(1)中得到离散小波的函数为:

$$\varphi_{j,k}(t) = a_0^{-j/2} \varphi\left(\frac{t - k b_0 a_0^j}{a_0^j}\right) = a_0^{-j/2} \varphi(a_0^{-j} t - k b_0) \quad (3)$$

相应的实值函数 $f(t)$ 的小波变换为:

$$Df(j, k) = \langle f(t), \varphi_{j,k}(t) \rangle = a_0^{-j/2} \varphi(a_0^{-j} t - k b_0) \quad (4)$$

当 $a_0 = 2, b_0 = 1$ 时, 式(3)、(4)就变为离散的二进小波及其变换, 此时:

收稿日期: 2009-04-08; 修回日期: 2009-06-03。

作者简介: 董吉文(1964-), 男, 山东莱州人, 教授, 博士, 主要研究方向: 智能计算; 吴瑞海(1983-), 男, 山东平邑人, 硕士研究生, 主要研究方向: 智能计算; 段琪庆(1964-), 男, 山东栖霞人, 副教授, 主要研究方向: 变形监测、地理信息系统。

$$\varphi_{j,k}(t) = 2^{-j/2} \varphi(2^{-j}t - k) \quad (5)$$

$$D_f(j,k) = 2^{-j/2} \int_{\mathbb{R}} f(t) \varphi(2^{-j}t - k) dt \quad (6)$$

由式(5)可见,小波函数 $\varphi(t)$ 的平移和伸缩 $\{2^{-j/2} \varphi(2^{-j}t - k) | j, k \in \mathbb{Z}\}$ 构成 $L^2(\mathbb{R})$ 的一组正交小波基,选择了小波函数就等于选择了一组小波基。根据小波函数的定义,小波函数 $\varphi(t)$ 具有多样性(即不唯一性),因此,在小波变换的实际工程应用中,一个十分重要的问题就是选取最恰当的小波基。目前往往是通过经验(对结果进行对比分析)来选择小波函数。

1.2 多分辨率分析^[1-2]

在多分辨率分析的框架出现之前,许多学者已采用不同的方法构造出了一些正交小波基,如 Harr 小波、Littlewood-Paley 小波、Meyer 小波、Stromberg 小波、Battle-Lemarie 小波等。快速小波变换(Fast Wavelet Transform, FWT)的算法可以快速简捷地进行小波变换和逆小波变换。

设信号 $f(t)$ 的离散采样数据序列为 $f(k), k = 0, 1, 2, \dots, N-1$, 由小波分解法则为:

$$\begin{cases} c_{j,k} = \sum_{n \in \mathbb{Z}} c_{j-1,n} \bar{h}_{n-2k} \\ d_{j,k} = \sum_{n \in \mathbb{Z}} c_{j-1,n} \bar{g}_{n-2k} \end{cases} \quad (7)$$

其中: $c_{0,k} = f(k)$ 为原始数据; $h(n)$ 和 $g(n)$ 为一共轭镜像滤波器的脉冲响应, 分别是低能滤波器 H 和高通滤波器 G 的滤波系数,且 $g(n) = (-1)^{1-n} h(1-n)$; j 为小波分解的层数。其分解与重构过程如图 1 所示。

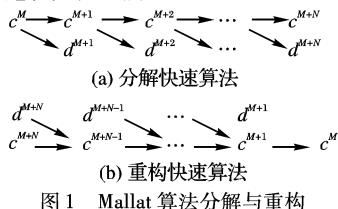


图 1 Mallat 算法分解与重构

相应地有信号的重构算法为:

$$c_{j-1,n} = \sum_{k \in \mathbb{Z}} (c_{j,k} h_{k-2k} + d_{j,k} g_{k-2k}) \quad (8)$$

一般地,小波去噪的基本步骤可归纳为以下三步。

1) 小波分解。

2) 去噪处理。根据具体信号的特点选择阈值,来滤掉一部分高频信息。一般可设阈值为:

$$\lambda = \delta \sqrt{2 \log(n)} \quad (9)$$

其中 n 为对应分解层次的高频系数个数。由于实际噪声系数的标准偏差 δ 未知的,因此,可用小波分解的第 1 层(即最细尺度)上高频系数的绝对标准偏差作为 δ 的估计值。

3) 小波重构。用小波分解的第 J 层的低频系数和经过阈值量化处理后的第 1 层至第 J 层的高频系数重构得到小波去噪后的观测数据。

2 PSO 算法

2.1 基本的 PSO 算法

PSO^[3-4] 中所有的粒子都有一个适应值函数,以判断其当前所在位置的好坏,每个粒子都具有记忆性,记录其到目前所搜寻到的最佳位置。每个粒子还都有个速度,以决定其飞行的速度和方向。

PSO 算法的一般步骤如下所示:

- 1) 初始化粒子群中每个粒子的位置和速度;
- 2) 利用适应值函数评价每个粒子当前位置的适应值;
- 3) 找出每个粒子到目前为止所搜寻到的最优化位置,即局部最优位置;

4) 找出粒子群中所有粒子局部最优位置中的最优位置,即粒子群的全局最优位置;

5) 更新粒子的速度和位置;

设粒子群的每个粒子的维数为 d , 粒子群中的粒子数为 N , 粒子 i 的位置为 $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$, 粒子 i 的速度为 $V_i = (v_{i1}, v_{i2}, \dots, v_{id})$, 粒子 i 的局部最优位置为 $PBest_i = (p_{i1}, p_{i2}, \dots, p_{id})$, 整个粒子群中所有粒子的最优位置为 $GBest = (g_1, g_2, \dots, g_d)$, 则粒子 i 的速度 V_i 和位置 X_i 更新公式为:

$$V_i = W \times V_i + C_1 \times r_1 \times (PBest_i - X_i) + C_2 \times r_2 \times (GBest - X_i) \quad (10)$$

$$X_i = X_i + V_i \quad (11)$$

其中: W 为惯性因子, 非负数, 其作用是调节对解空间的搜索范围; C_1 和 C_2 为学习因子, 控制学习的步长; r_1 和 r_2 是两个 0 到 1 之间的随机数, 目的是增加搜索的随机性。

6) 返回 2) 继续运行, 直到找到一个满意的全局优化位置为止或达到所要求的迭代步数。

2.2 改进的 PSO 算法

PSO 算法简单而又易于实现,但易陷入局部极小值。为解决该问题,文献[5]借助文献[6]的思想,将粒子群划分成两个动态变化的子粒子群 s_1 和 s_2 , 对 s_1 采用随迭代次数递减的惯性权重进行搜索,对 s_2 采用较大的惯性权重进行全局搜索,两个子群的大小随迭代的进行动态变化,且两子群中粒子的重组采用择优的策略,将适应值比较差的粒子放入 s_2 中,适应值比较好的放入 s_1 中。 s_1 和 s_2 子群每次迭代中粒子的数量由式(12)确定:

$$\Delta n = \left[2 \times \frac{N}{3} \times (1 - \frac{t}{T}) \right] \quad (12)$$

$$s1 = \left\lfloor \frac{5}{6} N - \Delta n \right\rfloor \quad (13)$$

$$s2 = N - s1 \quad (14)$$

其中: N 为粒子群的大小, t 是当前的迭代次数, T 是最大迭代次数, $s1$ 和 $s2$ 分别是子群 s_1 和 s_2 的粒子数。

为使种群进入局部极小值区域时能够跳出,引入变异算子,其变异公式是:

$$x_{id} = rand(0,1) \times r \quad (15)$$

其中, r 是变异半径,本文取为 0.8。为了不因变异操作而破坏好的粒子,同时既能改善种群多样性以跳出局部极小值,又能增加搜索精度,因此只对适应性较差的 s_2 子群的粒子进行变异,这样即保留了当前搜索到了较好的粒子,又增加了种群的多样性,有利于提高搜索精度和跳出局部极小值区域。

3 实例分析

以山东省济南市某新建小区一居民楼的连续 20 期沉降观测数据为例进行工程实例分析,预测其累计沉降量,原始的累计沉降观测数据曲线如图 2 所示。

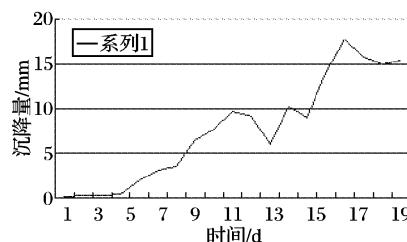


图 2 原始数据序列

3.1 小波去噪分析

地基沉降的监测数据易受环境、施工条件、人为因素等的影响,使得监测值不可避免地混入噪声。为提高预测精度,首

先需要对原始观测数据进行去噪处理。而小波分析是进行数据去噪的理想方法。目前常用的小波基主要有:Little-Paley 小波;Meyer 小波;coif 小波;Haar 小波等。本文经过多种小波的去噪对比,最终选用 Haar 小波进行去噪,利用此法对原始监测数据进行去噪后的曲线如图 3 所示。

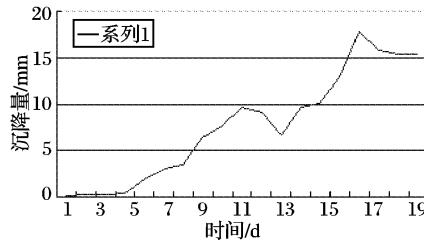


图 3 Haar 小波去噪后曲线

3.2 改进的 PSO 优化神经网络预测分析

利用 Haar 小波去噪后,可以得到比较平滑的去噪后的曲线,然后利用本文的改进方法对数据进行预测分析。经过多次实验分析比较,最终网络的结构输入为 3,隐含层个数为 6,输出为 1。

时间序列预测实际上就是利用包括第 k 时刻值在内的前连续 m 个序列值作为输入,预测第 $k+1$ 时刻的值,因此 20 期连续数据中第 0 时刻值不用可以得到 17 组数据,用前 14 组数据作为训练,用后三组数据作为测试数据,预测最后三组的累计沉降量,并分别用去噪前和去噪后的数据进行实验对比,经多次调试参数和运行测试,发现去噪后比去噪前的预测效果有很大的提高。

为了减小样本值对网络收敛的影响,首先对数据进行归一化处理。本文采用的归一化公式为:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (16)$$

网络的误差采用均方误差平方和:

$$e = \frac{1}{N} \sqrt{\sum_{j=1}^N \sum_{i=1}^O (d_i - y_i)^2} \quad (17)$$

其中: N 为样本的个数, O 为网络输出层神经元的个数, d_i 是期望输出, y_i 是实际输出。

预测步骤如下。

1) 确定参数:种群的大小、粒子位置和速度的范围、最大迭代次数、学习因子 C_1 和 C_2 等。

2) 初始化种群。均匀随机初始化粒子的位置和速度,并计算粒子的局部最优值 $PBest$ 和种群的全局最优值 $GBest$ 。

3) 根据式(12)将种群划分为两个子群,分别对两子群采用不同的惯性权重进行更新,其中 s_1 的惯性权重递减公式为:

$$0.8 - 0.6 \times iter / iter_{\max} \quad (18)$$

其中: $iter$ 为当前迭代次数, $iter_{\max}$ 为最大迭代次数。 s_2 惯性权重为 0.8。

4) 判断种群是否进入局部极小值区域,如果进入则对适应性较差的子群 s_2 进行变异。种群进入局部极小值区域的标志是连续数代全局最优值总变化小于设定阈值,本文设为连续 5 代适应值累计变化小于 0.0009。

5) 判断是否达到最大迭代次数,如果达到则退出循环,否则转 3)。

用传统的 PSO 与改进的 PSO 算法分别优化 BP 网络的权值,对预测结果进行对比。对于未去噪数据,两种方法的预测误差均在 0.01 左右;而去噪后数据,标准 PSO 算法的预测误差大部分在 0.004 左右,而本文方法大部分预测误差可

以在 0.002 左右,实验结果如表 1,2 所示。实验表明用改进后 PSO 算法对去噪后数据的预测误差比改进前及去噪前的预测误差有明显的提高。

表 1 两种方法对未去噪数据的预测结果

期数	原始沉降/mm	预测值/mm		预测误差/mm	
		标准 PSO	改进后 PSO	标准 PSO	改进后 PSO
18	0.882 452	0.854 956	0.865 589		
19	0.835 771	0.854 754	0.864 011	0.011 944	0.011 308
20	0.855 456	0.842 514	0.847 156		

表 2 两种方法对 Haar 小波去噪后数据的预测结果

期数	原始沉降/mm	预测值/mm		预测误差/mm	
		标准 PSO	改进后 PSO	标准 PSO	改进后 PSO
18	0.882 452	0.887 433	0.877 323		
19	0.855 456	0.845 374	0.855 378	0.004 065	0.001 787
20	0.855 456	0.850 739	0.857 017		

4 结语

粒子群优化算法因简单易实现而被广泛应用,但易出现早熟现象,因此文献[5]提出一种双群特性的粒子群算法。为解决算法后期易陷入局部极小值问题,本文在此基础上进行了进一步改进,只对适应性较差的子群进行变异,保留适应性较好的子群,这样既可以增加粒子的多样性又可以提高算法的搜索精度,将它与标准 PSO 算法分别与小波去噪分析结合预测地基累计沉降里做了对比,实验表明本文的改进方法具有较好的全局和局部搜索能力,预测精度高。

参考文献:

- [1] 黄声享,尹晖,蒋征.变形监测数据处理[M].武汉:武汉大学出版社,2002.
- [2] 彭玉华.小波变换与工程应用[M].北京:科学出版社,1999.
- [3] EBERCHART R C, KENNEDY J. A new optimizer using particle swarm theory[C]// Proceeding of the 6th International Symposium on Micromachine and Human Science. Nagoya: IEEE Press: 2001: 39–43.
- [4] KENNEDY J, EBERCHART R C. Particle swarm optimization[C]// Proceedings of IEEE International Conference on Neural Networks, IV. Piscataway: IEEE Service Center, 1995: 1924–1948.
- [5] 葛洪伟,刘林炬.基于改进粒子群优化算法的矩形 Packing 问题[J].计算机工程,2009, 35(7): 186–188.
- [6] 王向军,向东,蒋涛,等.一种双种群进化规划算法[J].计算机学报,2006, 29(5): 835–840.
- [7] 李莉,李洪奇,谢绍龙,等.基于克隆选择的免疫粒子优化算法[J].计算机科学,2008, 35(10): 253–278.
- [8] 畅建霞,于兴杰,黄强,等.基于多尺度分析与神经网络的需水量预测[J].计算机工程与应用,2008, 44(17): 219–221.
- [9] 罗航,王厚军,龙兵.基于“紧致型”小波神经网络的时间序列预测研究[J].计算机应用研究,2008, 25(8): 2366–2368.
- [10] 陈振伟,郭拯危.小波神经网络预测模型的仿真实现[J].计算机仿真,2008, 25(6): 147–150.
- [11] 刘渊,戴悦,曹建华.基于小波神经网络的流量混沌时间序列预测[J].计算机工程,2008, 34(16): 105–107.
- [12] 董吉文,陈月辉,袁润章,等.基于模糊神经网络的水泥强度预测[J].山东建筑工程学院学报,2005, 20(1): 1–3.
- [13] 王西锋,高岭,张晓李.基于小波技术的网络流量分析和预测[J].计算机应用与软件,2008, 25(8): 70–72.
- [14] 王建国,阳建宏,云海滨,等.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.