

混沌免疫优化 RBF 网络在动态变形预测中的应用*

朱 玉 赵 卿 梅 艳
(江苏师范大学测绘学院,徐州 221116)

摘 要 针对动态变形数据常规预测模型的不足,提出了一种基于混沌免疫优化的 RBF 模型,即利用混沌免疫算法(CIOA)对 RBF 网络的中心向量及连接权值进行优化。CIOA 结合了免疫算法和混沌优化算法各自的空间搜索优势,在免疫进化的过程中引入混沌寻优方法,改善算法的寻优模式,提高算法的收敛速度,避免算法陷入局部最优。结果表明:将混沌免疫优化 RBF 网络应用于动态变形数据预测中,有效地提高了预测的速度和性能。
关键词 混沌免疫优化算法;RBF 网络;动态变形监测;寻优模式;预测
中图分类号:P207 **文献标识码**:A

PREDICTION OF DYNAMIC DEFORMATION BASED ON CHAOTIC IMMUNE OPTIMIZATION ALGORITHM BRF NEURAL NETWORK

Zhu Yu, Zhao Qing and Mei Yan
(School of Geodesy and Geomatics, Jiangsu Normal University, Xuzhou 221116)

Abstract Aiming to the shortcoming of the traditional prediction model, a method for designing the RBF neural network based on chaotic immune optimization algorithm (CIOA) is proposed, which uses CIOA to the RBF network center vector and weights optimization. By applying chaos mutation operator to producing new antibody and applying immune selection operator to realizing the survival of the fittest, CIOA is able to maintain a good diversity. At the same time, CIOA has higher convergence speed and it can effectively avoid falling into local optima. The results show that chaotic immune optimization RBF neural network applied to the prediction of dynamic deformation, effectively improve the predicted speed and performance.
Key words: chaotic immune optimization algorithm(CIOA); RBF neural network model; dynamic deformation monitoring; optimization model; prediction

1 引言

在动态变形监测数据分析及预测中,随着监测手段的不断丰富,变形体动态变形监测数据越来越复杂,数据量也越来越大,且动态变形问题大多都是复杂的非线性问题,多数都具有混沌特征。虽然经典的预报模型用于平稳时间序列的预报逐渐成熟,

但对非平稳混沌时间序列的预报研究尚存在许多问题^[1,2]。目前在变形监测预测中,突变法、小波分析法、信息处理法、专家系统法、神经网络等方法得到了不同程度的应用和发展,但这些方法在实际应用中,预测精度及计算效率并不是太高,还需要进一步改进^[3]。
径向基函数(RBF, Radial Basis Function)网络

* 收稿日期:2012-02-29
基金项目:国家自然科学基金(40774010);江苏师范大学博士学位教师科研项目(10XLR24)
作者简介:朱玉,男,1977年生,讲师,博士研究生,主要研究方向为空间数据处理、空间数据挖掘. E-mail: zhuyuj@139.com

是一种特殊类型的神经网络模型,它不同于其他神经网络模型,具有几个独特的特征。它可以根据具体问题确定相应的网络拓扑结构,具有自学习、自组织、自适应等功能,学习速度快,可以进行大范围的数据融合,可以并行高速地处理数据,在收敛速度、逼近能力、搜索的遍历性和重构的精度等方面均优于其他前向网络^[4]。

在 RBF 网络中,隐层节点数直接影响网络的复杂性和泛化能力。如果隐层节点数不够,RBF 网络可能无法对数据进行充分的学习;如果隐层节点数太多,可能会导致 RBF 网络泛化能力太弱或网络的过学习。此外,隐层和输出层之间的合适的权值确定也非常重要。本文将混沌免疫优化算法(CIOA, Chaotic Immune Optimization Algorithm)引入到 RBF 算法中,提出基于 CIOA 优化的 RBF 算法,对其隐层节点数、隐层中心位置及连接权值等参数进行优化,从而达到提高 RBF 算法精度的目的,将其应用到动态变形监测数据预测中,实验结果证明了其有效性。

2 混沌免疫优化算法

人工免疫算法(AIA, Artificial Immune Algorithm)是借鉴生命科学中的免疫概念和理论发展起来的一种新兴算法^[5]。它能够有效地利用待求解问题中的一些有用信息抑制优化过程中产生的“退化”现象。一方面,它能够充分利用进化过程中每一代的最佳个体,另一方面,它又具有在确定性变化基础上随机搜索的特性。因此,它能从一定程度上减少随机影响因素及克服未成熟收敛。但是免疫算法在小区间内搜索到满意解的效率不能令人满意^[6]。

混沌是指发生在确定性系统中的一种貌似随机的不规则运动,但实际上混沌中还是蕴藏着一定的规律,即混沌运动具有伪随机性、遍历性、规律性等特点,使混沌搜索能在一定范围内按照自身规律不重复地遍历每一个状态。混沌优化算法首先改变优化变量为混沌变量,并通过改变混沌变量准则检查每个点在整个解空间的变化,接受更好的点为目前最佳的解决方案。然后,它以当前最佳方案为核心,通过扰动去寻找满足要求的最优解。

所以本文结合人工免疫算法和免疫优化各自在数据空间中的优势,提出一种混沌免疫优化算法 CIOA,算法的基本思想是:在免疫进化的过程中引入混沌寻优方法,改善算法的寻优模式,提高算法的收敛速度,避免算法陷入局部最优。

CIOA 的流程如图 1 所示。

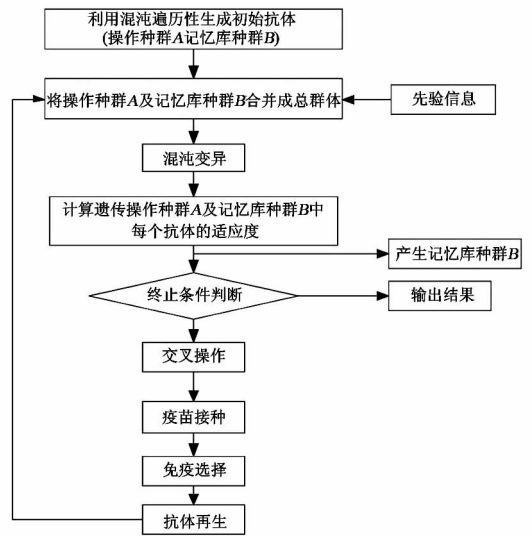


图 1 混沌免疫优化算法流程图

Fig. 1 Flow chart of chaotic immune optimization algorithm

2.1 初始抗体群的产生

利用混沌序列产生初始抗体的步骤如下:

1) Logistic 映射具有计算量小、使用方便的特点,采用

$$\beta_i^{u+1} = \mu_i \beta_i^u (1 - \beta_i^u) \quad (1)$$

Logistic 映射产生混沌序列,生成的混沌序列具有随机遍历的特征,再将生成的混沌序列从 $[0, 1]$ 混沌空间映射到系统状态空间,使生成的混沌序列可以均匀的分布在状态空间。式中, $i = 1, 2, \dots, k$ 表示混沌变量的序号; $u = 0, 1, 2, \dots, N$ 表示种群序号; $i = 1, 2, \dots, k$; β_i 为混沌变量且 $0 \leq \beta_i \leq 1$; μ_i 表示吸引子。

取 $u = 0, \mu_i = 4$, 给式(1)赋 k 个具有微小差异的初值,得到 k 个混沌变量 $\beta_i^{(1)} (i = 1, 2, \dots, k)$, 依次取 $u = 1, 2, \dots, N$ 可得到 N 个初始解群。

2) 按

$$x_i^0 = a_i + \beta_i^{u+1} (b_i - a_i) \quad (2)$$

将 Logistic 映射产生的始抗体群序列从混沌空间映射到原问题的解空间,得到 CIOA 算法所需要的初始抗体群 $A = (x_1^0, x_2^0, \dots, x_k^0)^T$ 。式中, b_i, a_i 为 x_i 的取值上、下限。

2.2 混沌变异策略

CIOA 算法中利用混沌机制对变异算子进行了改进,用混沌映射来实现混沌变异操作。

将抗体 v 映射到 $[0, 1]$ 空间,并作为混沌初值 β_i^0 代入式(1),再进行 k 次迭代,得到迭代 k 次后的混沌向量 β_i^k ,并按

$$\beta_i^{k'} = (1 - c_v \alpha) \hat{\beta}_i + \alpha \beta_i^k \quad (3)$$

计算变异后的混沌向量 $\beta_i^{k'}$,最后再将 $\beta_i^{k'}$ 映射到解

空间,完成混沌变异过程,得到变异后的抗体 v' 。式(3)中, $0 < \alpha < 1$ 为调节系数,随着迭代次数自适应变化; β_i 为当前最优值; c_v 为抗体浓度(抗体浓度为群体中具有最大适应度或近似最大适应度的抗体数与抗体总数的比率)。

由式(3)可知:由于混沌的初值敏感性, β_i^0 的微小不同可能导致 β_i^k 的极大差异,从而达到增加变异范围、优化变异效果的目的。同时,如果抗体浓度越大,其搜索范围也就越大,在进化后期,群体结构将趋于一致,变异会起到主导作用,变异范围增大,易跳出局部最优。

2.3 免疫记忆

免疫记忆参考操作主要是依据抗体的适应度实现,抗体的适应度即抗体和抗原之间的亲和力。首先按

$$f(v_i) = \frac{1}{k} \sqrt{\sum_{i=1}^k (ag_i - v_i)^2}$$

(4)

计算抗体的适应度,按照适应度大小对抗体排序,取适应度大的 p 个抗体作为记忆细胞放入记忆细胞库,记忆细胞规模 p 的取值可动态变化,如果 $p = 1$,记忆细胞即为待求问题的最优解。通过免疫记忆操作,可以充分利用个体优势对群体进化施加影响,加快算法的收敛速度。

2.4 疫苗接种

免疫进化过程中,较优个体和全局最优解之间的距离一般要小于群体中其他个体和全局最优解之间的距离,同时与较优个体之间距离较小的个体也可能具有较高的适应度。因此可对记忆细胞按

$$v' = v_m + \sigma N(0, 1)$$

(5)

进行免疫接种。通过疫苗接种操作,可以使得与最优抗体类似的个体大量繁殖,从而在进化过程中加大对最优个体附近解空间的投点密度,进而提高算法的搜索效率和进化速度。式(5)中, v' 为接种的个体, v_m 为记忆细胞, $N(0, 1)$ 为产生的服从标准正态分布的随机数, σ 为可调参数。

2.5 免疫选择

为了提高算法的效率,采用

$$E(v_i) = \frac{f(v_i)}{C(v_i)}$$

(6)

计算抗体被选择进入下一代的期望值,目的是通过期望值控制抗体的浓度和多样性,这样适应度高的抗体会被选择来再生,而浓度高的抗体将被抑制。式(6)中, $f(v_i)$ 为抗体的适应度, $C(v_i)$ 为抗体的浓度。

如果抗体的期望值过低,即抗体的适应度小于父代的适应度,说明抗体出现了退化现象,因此只能

选择父代抗体进入下一代而不是该抗体。
经过免疫选择后,再对式(1)的初值作微小变化,产生新的混沌序列补足个体数目。由于混沌序列的初值敏感性,可有效地避免数据冗余。

3 基于 CIOA 优化的 REF 网络

3.1 RBF 网络

RBF 网络的基本思想是用 RBF 作为隐单元的“基”构成隐含层空间,将输入矢量直接映射到隐空间,当 RBF 的中心点确定后,这种映射关系即可确定。另外隐含层空间到输出空间的映射是线性的,即网络的输出是隐单元输出的线性加权和。RBF 网络由输入到输出的映射是非线性的,网络输出对可调参数是线性的,网络的权可利用线性方程组直接求出,这样可加快网络的学习速度并可避免学习陷入局部极小问题。

RBF 网络的设计关键在于网络学习算法的设计,网络学习算法的关键在于隐层中心点的确定及隐层节点数的确定^[7]。目前在 RBF 网络中隐层中心确定最常用的方法是 k-均值算法,但是 k-均值算法作为一种聚类算法,使用中最大的局限性是需要先根据先验知识确定中心向量个数,且其对初值敏感,因此极大地限制了 RBF 网络的实际应用。为此,本文将前面提出的混沌免疫优化算法 CIOA 引入到 RBF 网络设计中,利用 CIOA 对网络的中心向量进行优化,进而实现权值等参数的优化。

3.2 基于 CIOA 优化的 REF 网络算法

首先利用 CIOA 算法对输入样本点进行处理,根据处理后获得的特征数据确定 RBF 网络的隐层中心和隐层个数,由隐层中心值,再利用最小均方算法求出隐层到输出层的优化权值。基于 CIOA 优化的 REF 网络算法的流程图如图 2 所示。具体步骤如下所示:

1) 初始化

根据输入的训练样本点,采用式(1)产生含有 N 个实数的初始混沌序列,生成的初具有随机遍历的特征。然后将初始混沌序列按式(2)从混沌空间映射到原问题的解空间并进行编码,得到 CIOA 所需要的初始抗体群 C_k ,令 $k = 0$ 。 C_k 中的个体采用两阶式编码结构进行编码。两阶式编码结构由二级基因构成,第一级基因采用二进制编码,用“0”和“1”分别表示 RBF 网络所对应的隐节点径向基函数处于休眠和激活状态;当隐节点径向基函数处于激活状态时,第二级基因进行编码,采用十进制编码,每一位代表一种网络参数。设定初始化的隐层神经元最大个数为 Th_{term} 。

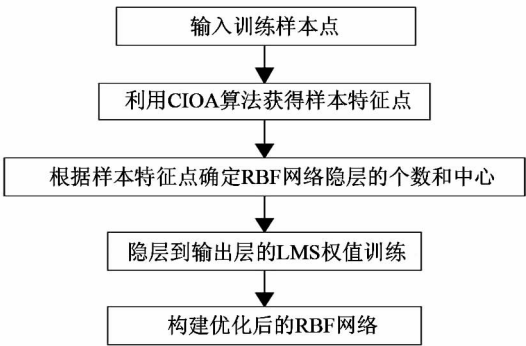


图2 基于 CIOA 优化的 RBF 网络流程

Fig.2 Flow chart of enhanced RBF neural network algorithm based on CIOA

2)利用 CIOA 计算出优化 RBF 网络的隐层个数和中心

3)隐层到输出层权值的训练

隐层到输出层权值的训练采用可变速率的 LMS 算法,通常在 LMS 算法中,学习率参数在计算过程中保持不变,导致收敛速度较慢。所以在网络自适应的训练早期阶段,即迭代次数相对搜寻时间常数较小时,学习率参数近似为一常数,然后,当迭代次数比搜寻时间常数大时,学习率参数自适应改变。此时,可变速率的 LMS 算法以一个传统的随机逼近算法运行,且权值收敛到最优值。

4)优化 RBF 网络的构建、训练及在动态变形监测中的应用。

4 基于 CIOA 优化的 REF 网络模型在动态变形监测中的应用

4.1 变形监测数据分析

变形监测数据来源于山东兖州某矿区(表 1),其中每个观测期间隔约为 5 天。

地表沉陷变形是一个极其复杂的随时间和空间变化的非线性问题,是空间和时间连续的函数。而反映塌陷区地表沉降的实测数据主要是沉降变形数据,该观测数据是单一变量的时间序列。通常认为单变量时间序列仅能提供地表沉降系统演化有限的信息,事实上,单变量时间序列原则上是复杂的地表变形体系中各种要素相互作用的结果,它不但包含着地表变形破坏的综合信息,还蕴藏着参与地表变形破坏整个过程其他变量的痕迹,但最终多种要素综合作用的结果要通过沉降变形监测数据表现出来,对这种动态变形监测数据的分析和预测对矿区的生态重建有着重要的意义。

4.2 预测结果

将已知的动态变形监测 150 个样本数据分成两

组,前 135 个数据作为训练样本,后 15 个数据构成检验样本。在基于 CIOA 优化的 RBF 网络学习算法中,首先利用检验模态分解方法,确定影响塌陷区地表沉陷的主要因素为 6 个:开采深度、开采长度、煤层采厚、煤层倾角、开采宽度和覆岩岩性,然后取 CIOA 优化 RBF 网络有 6 个输入节点,1 个输出节点(动态沉陷预测值),群体规模为 100,记忆库种群大小为 10, $\sigma=0.6$,算法进化最大迭代代数 200。

为了验证算法的性能和效果,同时分别用 RBF 网络和 BP 网络对样本数据进行训练,得到的预测结果如表 2 所示。

表 1 监测点地表沉降监测数据

Tab.1 Monitored surface settlement data at a monitoring station

观测 期数	实测值 (mm)	观测 期数	实测值 (mm)	观测 期数	实测值 (mm)
1	-0.475	76	0.546	136	0.760
2	-2.225	77	-0.465	137	-2.150
3	3.470	78	-0.788	138	-2.960
4	3.010	79	-1.245	139	-3.213
5	-1.185	80	-0.138	140	2.410
6	-0.783	81	0.530	141	1.530
7	1.965	82	-0.556	142	-0.120
8	-1.245	83	-1.925	143	1.330
9	-2.170	84	-0.176	144	-0.530
10	0.617	85	0.470	145	3.270
11	-1.810	86	-1.092	146	-0.450
12	-3.222	87	1.425	147	-3.310
13	-2.880	88	0.876	148	-0.630
14	-0.937	89	-1.116	149	1.550
...	150	1.600

表 2 预测结果比较表

Tab.2 Comparison among the forecasting results

观测 期数	实测值 (mm)	预测结果(mm)					
		BP	误差	RBF	误差	CIOA-RBF	误差
436	0.760	0.952	0.192	0.874	0.114	0.799	0.039
437	-2.150	2.287	-0.137	-2.045	0.105	-2.186	-0.036
438	-2.960	-3.251	-0.291	-3.116	-0.156	-3.073	-0.113
439	-3.213	-3.001	0.212	-3.355	-0.142	-3.202	0.011
440	2.410	2.077	-0.333	2.565	0.155	2.498	0.088
441	1.530	1.719	0.189	1.645	0.115	1.496	-0.034
442	-0.120	0.117	0.237	0.006	0.126	-0.065	0.055
443	1.330	1.207	-0.123	1.238	-0.092	1.284	-0.046
444	-0.530	-0.273	0.257	-0.376	0.154	-0.475	0.055
445	3.270	2.982	-0.288	3.076	-0.194	3.198	-0.072
446	-0.450	-0.573	-0.123	-0.538	-0.088	-0.494	-0.044
447	-3.310	-3.029	0.281	-3.507	-0.197	-3.412	-0.102
448	-0.630	-0.475	0.155	-0.489	0.141	-0.639	-0.009
449	1.550	1.239	-0.311	1.209	-0.341	1.567	0.017
450	1.600	1.097	-0.503	1.247	-0.353	1.478	-0.122
t _{运行} (s)		226.5		178.4		162.6	
训练代数		1000		300		200	

对监测数据进行了多次重复实验,同 BP 网络、RBF 网络比较和分析得出下述结论:1) CIOA – RBF 神经网络精度较高,结果可靠,可用于对动态变形值进行预测;2) CIOA – RBF 网络在提高计算精度的基础上,速度也有所提高,学习效率更快。

5 结语

CIOA 在免疫进化的过程中引入混沌寻优方法,可以改善算法的寻优模式,提高算法的收敛速度,避免算法陷入局部最优。实验表明,基于 CIOA 优化的 RBF 网络具有较快的收敛速度和较高的学习精度,将其应用于动态变形监测预测进一步提高了变形预测的速度和精度。

参 考 文 献

1 张正禄,黄全义,文鸿雁. 工程的变形监测分析与预报 [M]. 北京:测绘出版社,2007. (Zhang Zhenglu, Huang Quanyi and Wen Hongyan. Deformation monitoring analysis and prediction for engineering constructions [M]. Beijing: Surveying and Mapping Press,2007)

2 张安兵. 动态变形监测数据混沌特性分析及预测模型研究 [D]. 中国矿业大学,2009. (Zhang Anbing. Study on chaotic characteristic and prediction model of dynamic deformation monitoring data [D]. China University of Mining

and Technology,2009)

3 邓兴升,陈石桥,殷自成. 动态回归模型在变形分析中的应用 [J]. 大地测量与地球动力学,2011, (5):132 – 135. (Deng Xingsheng, Chen Shiqiao and Yin Zicheng. Application of dynamic regression model in deformation analysis [J]. Journal of Geodesy and Geodynamics, 2011, (5):132 – 135)

4 杨行峻,郑君里. 人工神经网络与盲信号处理 [M]. 北京:清华大学出版社,2003. (Yang Xingjun and Zheng Junli. Artificial neural network and blind signal processing [M]. Beijing: Tsinghua University Press,2003)

5 王磊,潘进,焦李成. 免疫算法 [J]. 电子学报,2000,28 (7):74 – 78. (Wang Lei, Pan Jin and Jiao Licheng. Immune algorithm [J]. Acta Electronica Sinica,2000, 28 (7): 74 – 78)

6 Jiao Licheng and Wang Lei. A novel genetic algorithm based ODS immunity [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans,2000,30 (5):552 – 561.

7 刘汉丽,等. 多子群遗传神经网络模型用于路口短时交通流量预测 [J]. 测绘学报,2009,38 (4):363 – 368. (Liu Hanli, et al. Multi-population genetic neural network model for short-term traffic flow prediction at intersections [J]. Acta Geodaetica et Cartographica Sinica, 2009, 38 (4): 363 – 368)

(上接第 52 页)

from GPS data [J]. Terr Atmos Ocean Sci., 2011, 22 (2): 133 – 147.

10 魏木生,陈果良. 加权总体最小二乘问题的解集和性质 [J]. 高校应用数学学报 (A 辑),1994, 9 (3): 304 – 311. (Wei Musheng and Chen Guoliang. Solution sets and property for weighted total least squares problem [J]. Applied Mathematics-A Journal of Chinese Universities, 1994, 9 (3): 304 – 311)

11 刘永辉,魏木生. TLS 和 LS 问题的比较 [J]. 计算数学, 2003, 25 (4):479 – 492. (Liu Yonghui and Wei Musheng. On the comparision of the total least squares and the least squares problems [J]. Mathematica Numerica Sinica, 2003, 25 (4): 479 – 492)

12 崔希璋,等. 广义测量平差 [M]. 武汉:武汉测绘科技大学,2001. (Cui Xizhang, et al. Generalized surveying adjustment [M]. Wuhan: Wuhan Technical University of Surveying and Mapping, 2001)

13 Thompson R C. Principal sub-matrices IX: interlacing ine-

qualities for singular values of sub-matrices [J]. Linear algebraappl., 1972, 5: 1 – 12.

14 Markovsky I and S Van Huffel. Overview of total least squares methods [J]. Signal Processing, 2007, 87:2 283 – 2 302.

15 张洪钺,黄劲东,范文雷. 全最小二乘法及其在参数估计中的应用 [J]. 自动化学报, 1995, 21 (1): 40 – 48. (Zhang Hongyue, Huang Jindong and Fan Wenlei. Total least squares method and its application to parameter estimation [J]. Acta Automatic Sinica, 1995, 21 (1):40 – 48)

16 Branham R L JR. Multivariate orthogonal regression in astronomy [J]. Celestial Mechanics & Dynamical Astronomy, 1995, 61: 239 – 251.

17 Schuermansa M, et al. The use of total least squares data fitting in the shape-from-moments problem [J]. Signal Processing, 2006, 86:1 109 – 1 115.

18 Felus Y A and Burtch R C. On symmetrical three-dimensional datum conversion [J]. GPS Solut., 2009, 13: 65 – 74.