

灰色神经网络在城市用水量预测中的应用

胡 瑜, 于宝堃, 许 国, 张 莹

(天津科技大学 电子信息与自动化学院, 天津 300222)

摘 要: 为解决传统 BP 神经网络在城市用水量预测中易陷入局部极小点等问题, 将 BP 神经网络与灰色理论相结合, 构建了灰色神经网络模型(GNNM), 实现了二者的优势互补, 并利用粒子群优化算法(PSO)对该模型的初始权值和阈值进行优化, 形成了 PSO-GNNM(1, N)算法. 通过与传统 BP 神经网络、灰色理论预测法的预测结果相比较, 该算法具有预测误差小、泛化能力强等优点, 可为城市用水量的预测工作提供技术支持.

关键词: 城市用水量; 灰色神经网络; 粒子群优化算法; PSO-GNNM(1, N)算法

中图分类号: TU991

文献标识码: A

文章编号: 1000-7180(2012)07-0142-04

Application of Gray Neutral Network to Prediction of Urban Water Quantity

HU Yu, YU Bao-kun, XU Guo, ZHANG Ying

(College of Electronic Information and Automation, Tianjin University of Science & Technology, Tianjin 300222, China)

Abstract: In order to overcome traditional BP neural network's problem of trapping to a local optimum in prediction of urban water quantity, the gray neutral network model (GNNM) was created by combining BP neural network with gray theory, which can realize the mutual supplement with advantages of these two methods. The PSO-GNNM (1, N) algorithm was formed by using particle swarm optimization to optimize initialized weights and threshold of GNNM. By comparison with the predicted results of traditional BP neural network and gray theory forecasting method, this algorithm had little prediction error and better generalization performance, which can provide technical support for prediction of urban water quantity.

Key words: Urban Water Quantity; Gray Neutral Network; PSO; PSO-GNNM (1, N) algorithm

1 引言

随着我国经济水平的快速增长和城市化进程的不断加快, 城市用水量急剧增加, 加强城市用水量预测已显得非常紧迫, 准确的预测可以保证管理部门合理调度水资源. 常见的预测方法有: 回归分析预测方法、灰色预测法、人工神经网络预测法等^[1]. 上述方法各有优势与不足, 为了能更精确地预测城市用水量, 我们将灰色预测法和人工神经网络预测法相结合, 建立了一种基于灰色理论和神经网络的组合模型, 并利用粒子群算法对模型的初始权值等参数进行优化, 以提高模型的工作效率.

2 灰色理论与神经网络的融合

灰色理论是一种研究既包含已知信息又包含未知信息的系统理论与方法. 该理论以“小样本”、“离散”, “无规律”的数据为主要研究对象, 将杂乱无章的原始数据序列通过一定的处理方法, 使之变为比较有规律的时间序列. 但是, 基本的灰色预测方法缺乏自学习和自组织能力, 尤其是在对复杂的非线性系统进行预测时, 因非线性系统的数据随机性变化显著, 会产生很大的误差. 而 BP 网络^[4]作为神经网络的一种常见模型, 具有很强的非线性映射、自学习和自组织能力, 可大大弥补灰色模型的这一缺陷. 但

收稿日期: 2011-11-09; **修回日期:** 2011-12-15

基金项目: 国家“十一五”科技支撑计划项目(2006BAJ16B08)

BP网络计算过程复杂、计算量大、易陷入局部极小值,而灰色预测方法可以很好地解决这些问题,使BP网络能够利用较少的数据也可较快地进行预测。可见二者之间存在一定的差异性和互补性,将二者融合,可充分发挥各自的优势。

近年来,国内外学者对灰色理论与神经网络的融合不断地进行着探讨和研究,建立了多种灰色神经网络模型,本文将BP神经网络与灰色理论相结合,采用嵌入型灰色神经网络模型,对城市用水量进行分析,结构如图1所示。




图1 嵌入型灰色神经网络模型

该模型在神经网络的输入端和输出端分别增加一个灰化层和白化层,灰化层的作用是弱化原始数据的随机性,利用累加生成等方法产生新的数据,作为神经网络的训练样本,而白化层用于将网络的灰色输出数据进行还原^[2]。在嵌入型网络中,利用灰色系统所建立的灰微分方程的解构建BP网络,并将灰微分方程系数映射为网络中的权值与阈值。通过对BP网络的不断训练,可获得权值与阈值的最佳值,从而实现了参数的白化处理,以弥补灰色系统在参数进行白化时的不足。在构造BP网络时,需要充分考虑灰微分方程的结构、参数特征以及灰色系统的已知信息。在对BP网络进行训练时,应将灰色系统中已知数据或经过处理的灰参量作为样本。

3 GNNM(1,N)模型

3.1 GNNM(1,N)模型的建模思想^[3]

在灰色系统中,GM(1,N)模型的灰微分方程:

$$x_1^{(0)}(k) + az_1^{(1)}(k) = \sum_{i=2}^N b_i x_i^{(1)}(k) \quad (1)$$

若将 $x_i^{(1)}(k)$ 的时刻 $k=1,2,\dots,M$ 视为连续的时间变量 t ,则数列 $x_i^{(1)}(k)$ 可视为时间 t 的函数,记为 $x_i^{(1)} = x_i^{(1)}(t)$,进而得到 GM(1,N) 的白化微分方程:

$$\frac{dx_1^{(1)}}{dt} + ax_1^{(1)}(t) = \sum_{i=2}^N b_i x_i^{(1)}(t) \quad (2)$$

该方程为一阶 N 个变量的微分方程。经过计算可得式(2)的时间响应模型:

$$z(t) = \left[x_1^{(1)}(0) - \frac{u}{a} \right] e^{-at} + \frac{u}{a} \quad (3)$$

其中 $u = \sum_{i=2}^N b_i x_i^{(1)}(t)$, 该响应模型把已知的数据视

为连续变化的符合某个函数变化特性的一组特殊数据。上述过程将有限的离散数据拟合出微分方程,以形成数据的一种变化规律,从而预测数据的变化趋势,充分显示出灰色系统只需较少样本的优点。

利用嵌入型灰色神经网络的构建思路,将式(3)的时间响应模型映射到一个BP网络中,然后对这个BP网络进行训练,当网络收敛时,即可从经过训练的BP网络中获得相应的方程系数,从而实现参数的白化操作,以获得式(3)的确切解。但式(3)中的 $f(x) = e^{-x}$ 形式的函数不满足神经网络的构建要求,因而不能将其作为BP网络的激活函数使用。为了将(3)映射到BP网络中必须对其进行变换,变换结果如(4)所示。

$$x_1^{*(1)}(t) = ((x_1^{(1)}(0) - u) - x_1^{(1)}(0)/(1 + e^{-a}) + 2u/(1 + e^{-a})) \cdot (1 + e^{-a}) \quad (4)$$

经过变换后,将式(4)映射到BP网络中,其结构如图2所示。LA~LD分别表示灰色神经网络的四层。其中LB层的激活函数为 $f(x) = 1/(1 + e^{-x})$, 该函数为S型函数,它的中间存在一个高增益区,可解决处理小信号问题,而伸向两边的低增益区适合解决大信号问题,这种特性可确保网络最终能达到稳定状态。其他层的激活函数选取线性函数 $f(x) = x$ 。




图2 灰色BP网络结构图

相应的神经网络权值进行如下赋值:

$$\omega_{11} = a \quad (5)$$

$$\omega_{21} = -x_1^{(1)}(0) \quad (6)$$

$$\omega_{22} = \frac{2b_1}{a}, \omega_{23} = \frac{2b_2}{a}, \dots, \omega_{2n} = \frac{2b_{n-1}}{a} \quad (7)$$

$$\omega_{31} = \omega_{32} = \dots = \omega_{3n} = 1 + e^{-a} \quad (8)$$

LD层中输出节点的阈值为:

$$\theta = (1 - e^{-a})(u - x_1^{(1)}(0)) \quad (9)$$

经过映射,可将灰微分方程映射到神经网络的拓扑结构中,在神经网络的训练过程中,权值不断修正相当于不断提高灰色参数的白化精度。

3.2 GNNM(1,N)模型的学习算法

由于灰色 BP 网络与传统 BP 网络存在不同的特征,因而要对传统 BP 网络的学习算法进行改造,以使其满足灰色 BP 网络的要求,其学习流程如图 3 所示.在对灰色 BP 网络进行训练时需注意两点:(1)由于 $\omega_{21} = -x_1^1(0)$,故在训练过程中,权值 $\omega_{21} = -x_1^1(0)$ 为定值。(2) $\omega_{31}, \dots, \omega_{3n}$ 可直接由输入得到。




图3 灰色BP网络学习流程

4 粒子群算法优化 GNNM(1,N)模型

为了加快 GNNM(1,N)网络收敛速度,提高其稳定性,解决其易陷入局部极小值的问题,本文引入粒子群算法对 GNNM(1,N)网络的初始权值和阈值进行优化,从而改进该网络的学习效率和性能。

4.1 粒子群算法

粒子群算法 (Particle Swarm Optimization, PSO) 是一种基于群体搜索的全局寻优算法。该算法通过群体中粒子间的合作与竞争产生的群体智能来指导优化搜索^[4]。使用该算法时,需在可解空间中初始化一群粒子,每个粒子均代表优化问题的一个潜在最优解,使用位置、速度和适应度值来衡量粒子特征,适应度值使用适应度函数来获得,其值的好坏代表粒子的优劣^[5]。粒子在解空间中不断运动,并通过跟踪个体极值和群体极值来更新个体位置和速度,式(10)和(11)分别为个体位置和速度的计算公式^[6]。粒子每更新一次位置,就计算一次适应度值,并通过比较新粒子的适应度值和个体极值、群体极值的适应度值来更新个体极值和群体极值。

$$v_{id}(t+1) = \omega v_{id}(t) + c_1 r_1 (p_{id}(t) - x_{id}(t)) + c_2 r_2 (p_{gd}(t) - x_{id}(t)) \quad (10)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (11)$$

式中, $x_{id}(t)$ 、 $v_{id}(t)$ 分别表示第 i 个粒子在第 d 维中的当前速度和位置。 ω 为惯性权值因子,它控制着粒子以往速度对当前速度的影响。 c_1 和 c_2 为学习因子, r_1 和 r_2 是介于 $[0, 1]$ 之间的随机数。 $p_{id}(t)$ 代

表个体位置的当前最佳值, $p_{gd}(t)$ 代表种群位置的当前最佳值。公式(10)由三部分共同组成,分别是粒子原有的速度、认知部分和社会部分,这三部分共同作用,使粒子有能力到达最好位置^[7]。

4.2 GNNM(1,N)网络的 PSO 优化算法

利用 PSO 算法优化 GNNM(1,N)网络时,先将 GNNM(1,N)网络的连接权值和阈值编码成实数向量以表示粒子群中粒子所处的位置,即粒子的维数由网络的权值和阈值个数所决定,由于 $\omega_{21} = -x_1^1(0)$ 为定值,因此粒子的维数是 $2N+1$ 。而后随机生成向量群体,并将迭代中新产生的个体向量还原为权值和阈值,以此作为 GNNM(1,N)网络的参数进行训练。将训练过程中产生的均方根误差作为 PSO 算法的适应度函数,由于 GNNM(1,N)网络的输出神经元个数为 1,因此,本文所采用的适应度函数:

$$f(k) = \sqrt{\frac{1}{M} \sum_{j=1}^M (y_j - y_j^*)^2} \quad (12)$$

其中: y_j 为数据集的实际值, y_j^* 为数据集的预测值, M 为测试样本的数量, k 表示粒子的序号。

此时,训练转化为寻找一组使均方根误差最小的优化问题。若系统迭代次数达到上限值或均方根误差小于系统给定值,则训练过程停止,否则训练继续,直到迭代次数达到上限值,此时获得的权值和阈值已逼近最佳值。最后,利用 GNNM(1,N)网络对获得的网络参数做进一步优化,以获得最优的网络参数。PSO-GNNM(1,N)算法的具体流程如图 4 所示。




图4 PSO-GNNM(1,N)算法流程图

5 应用实例

5.1 样本的选取

本文以城市生活用水量作为分析和预测对象。在影响城市生活用水量的诸多因素中,城市人口规模、居民生活水平和城市发展水平具有易量化为数

据变量的特点,可作为反映城市生活用水量的指标.另外,水价的浮动也会导致生活用水量的变化,成为影响城市生活用水量的重要因素之一.根据以上分析,本文将城市生活年用水量作为灰色神经网络的输出量,而网络的输入量选择用水人口数(代表城市人口规模)、人均居住面积、人均可支配收入(代表城市居民生活水平)、全市生产总值(GDP)(代表城市发展水平)和城市平均生活水价(居民用水价格与非居民用水价格的综合值).

为了检验 PSO-GNNM(1,N)算法的预测精度,选用 1999~2007 年天津地区的相关数据作为网络的输入量和输出量对 GNNM(1,N)网络进行训练,并对 2008~2009 年的天津城市生活年用水量进行预测,所使用的样本数据来源于《天津市统计年鉴》和《中国统计年鉴》.在训练之前,需对各个输入量和输出量进行归一化处理,以消除各个因子由于量纲和单位不同而造成的影响.

5.2 PSO-GNNM(1,N)参数的设置

正确选取 PSO 算法的参数,可以加快 PSO 算法的收敛速度,提高 GNNM(1,N)网络的预测精度,使其能够达到最优的预测效果.为了获得最佳的参数值,利用不同的参数组合,分别对 GNNM(1,N)网络进行训练,并比较适应度值,最终取粒子种群数为 10,最大迭代次数为 100,学习因子 c_1 和 c_2 均取值为 2.为了提高 PSO 算法的效率,惯性权值因子 ω 在迭代过程中随着迭代次数的增加而发生变化,其计算公式为:

$$\omega=\omega_{\max}-\frac{\omega_{\max}-\omega_{\min}}{T_{\max}}T$$

(13)

其中, $\omega_{\max}$ 和 $\omega_{\min}$ 分别是 ω 的最大最小值,取值为 0.9 和 0.4. T 和 $T_{\max}$ 分别表示当前迭代步数和最大迭代次数.

由于 PSO 算法中的每一个粒子代表 GNNM

(1,N)网络中的一组权值和阈值,而本文选取五个因素作为城市年用水量的影响因子,故粒子的维数为 11.为了合理地选择粒子群初始速度和位置,首先利用最小二乘法对公式(4)中的参数进行估算,并利用这些估算值计算出 GNNM(1,N)网络的初始权值和阈值,以作为粒子群的初始位置.为了防止粒子超出最优区域,设置粒子在每个维度上的最大值和最小值分别是初始位置值 ± 2 ,同时设置粒子速度的范围是 $[-1,1]$,其初始值为该区域内的一个随机值.

5.3 结果分析

由图 5 中天津市城市生活年实际用水量变化曲线可以看出,近十年来,用水量的变化存在一定的波动,这是由于用水量受众多因素的影响而产生的.利用神经网络可很好地解决这类问题,此外它的变化也符合灰色模型的特点,适于采用 PSO-GNNM(1,N)预测法对其变化规律进行拟合和预测.同时,采用 GM(1,N)预测法和传统 BP 神经网络预测法对年用水量进行拟合与预测,结果见图 5.其中 1999~2007 年的计算值为拟合部分,2008~2009 年的计算值为预测部分.

在表1中列出了三种方法的预测精度,经计算,




图 5 预测模型拟合和预测曲线

表 1 模型计算值及相对误差

年份	年用水量实际值 (万立方米)	传统 BP 神经网络		GM(1,N)		PSO-GNNM(1,N)	
		计算值	相对误差(%)	计算值	相对误差(%)	计算值	相对误差(%)
1999	28025	28057	0.11	28025	0	27997	0.10
2000	25714	25806	0.36	23507	8.58	25770	0.22
2001	32569	32439	0.40	36132	10.94	32565	0.01
2002	29881	29920	0.13	32528	8.86	29856	0.08
2003	29829	29730	0.33	29863	0.11	29990	0.54
2004	28807	28847	0.14	28918	0.38	28826	0.07
2005	28885	28911	0.09	28986	0.35	28865	0.07
2006	27084	27094	0.04	26960	0.46	27098	0.05
2007	29085	29118	0.11	29228	0.49	29101	0.06
2008	30146	30856	2.36	31991	6.12	30384	0.79
2009	29513	29575	0.21	32356	9.63	29468	0.15

核并程序的负载平衡. 设计了重叠区域最小误差路径计算多任务模块函数并利用 MATLAB 多核集群任务调度器组件实现了 Image Quilting 纹理合成算法并行化,提高了多核处理器的运行效率,体现了面向多任务构建并行模块方法的可行性和实用性. MATLAB 丰富的库函数以及 Windows 操作系统上的集群相比 OpenMP、MPI 等并行环境对解决同规模串行程序性能瓶颈和并行优化问题效果更佳. 本文对 MATLAB 并行算法做了一些尝试性工作,获得了很好的效果.

参考文献:

- [1] 周伟明. 多核计算与程序设计[M]. 武汉:华中科技大学出版社,2009.
- [2] LIANG L, LU C. Real-time texture synthesis is by patch based sampling[J]. ACM Transaction on Graphics, 2011,20(3):127-150.
- [3] 林定,陈崇成,唐丽玉,等. 基于 Image Quilting 算法的纹理合成[J]. 系统仿真学报,2008(9): 381-385.
- [4] 诸葛振荣,杨敏. Image Quilting 纹理合成算法的实现

与改进[J]. 机电工程,2010,27(2):43-45.

- [5] MathWorks 公司. Parallel computing toolbox user's guide. MATLAB distributed computing server system administrator's guide[EB/OL]. [2009-11-04]. <http://www.mathworks.com/help/toolbox/mdce/index.html//>.
- [6] MathWorks 公司. MathWorks 中国-录制的网上研讨会应用[EB/OL]. [2010-11-04]. http://www.mathworks.cn/company/events/webinars/index.html?s_cid=HP_E_RW.

作者简介:

于梦玲 女,(1985—),硕士研究生. 研究方向为并行计算、多核计算机系统.

郑晓薇 女,(1957—),教授. 研究方向为并行计算、多核计算机系统.

张建强 男,(1981—),硕士研究生,助教. 研究方向为并行计算.

侯立斐 男,(1987—),硕士研究生. 研究方向为模式识别、并行计算.

(上接第 145 页)

PSO-GNNM(1, N) 预测法的平均相对误差为 0.19%, 小于另两种方法的 0.39% 和 4.17%, 满足实际应用的需求. 从图 5 可以看出该方法的拟合和预测精度比其他两种高, 其拟合和预测的年用水量更接近于实际值. 由于神经网络具有较强的非线性运算能力, 其计算结果具备较高的精度, 可反映出用水量随时间变化的趋势, 而 PSO-GNNM(1, N) 预测法吸取了二者的优点, 利用有限的样本数据, 即可对非线性模型进行映射, 提高了预测的精度, 为水资源管理和规划可提供有力的依据.

6 结束语

本文借鉴灰色理论和神经网络提出了 PSO-GNNM(1, N) 预测方法, 该方法充分利用了灰色模型和神经网络模型的优点, 将二者形成了一个有机的整体, 在对天津市城市用水量的预测中取得了较好的效果.

参考文献:

- [1] 刘洪波, 张宏伟, 田林. 人工神经网络法预测时用水量[J]. 中国给水排水, 2002, 18(12): 39-41.
- [2] 李小燕. 灰色神经网络预测模型的优化研究[D]. 武汉: 武汉理工大学, 2009.
- [3] 钟珞, 饶文碧, 邹承明. 人工神经网络及其融合应用技术[M]. 北京: 科学出版社, 2007.
- [4] 李海娜. 基于 PSO-BP 神经网络的铝带坯晶粒度软测量建模及优化[D]. 长沙: 湖南大学, 2009.
- [5] MATLAB 中文论坛. MATLAB 神经网络 30 个案例分析[M]. 北京: 北京航空航天大学出版社, 2010.
- [6] 李娜. 粒子群算法及其应用研究[J]. 农业网络信息, 2010, 25(7): 146-148.
- [7] 董晓慧. 基于粒子群算法的神经网络及其应用的研究[D]. 济南: 济南大学, 2006.

作者简介:

胡瑜 女,(1964—), 工学硕士, 副教授. 研究方向为智能检测技术.