

基于蚁群径向基函数网络的地下水预测模型

曹邦兴

CAO Bang-xing

广州大学 松田学院,广州 511370

Songtian Institute, Guangzhou University, Guangzhou 511370, China

E-mail: cbx852852@163.com

CAO Bang-xing.Prediction model of underground water level that combined ant colony algorithms with RBF network.
Computer Engineering and Applications, 2010, 46(2):224–226.

Abstract: A prediction model of underground water level that combined ant colony algorithms with radial basis function neural network is proposed. It not only has extensive mapping ability of neural network, but also has the advantages of global convergence and distributed computation of ant system. The experimental result indicates good performance can be obtained by neural network based on ant colony algorithms in prediction of underground water level.

Key words: ant colony algorithms; radial basis function network; underground water level; prediction

摘要:提出了一种基于蚁群算法的径向基函数神经网络,用它来进行地下水位预测,既具有神经网络广泛映射能力,又具有蚁群算法全局寻优、分布式计算等特点。实验表明,蚁群算法与径向基函数神经网络相融合能达到良好的预测效果。

关键词:蚁群算法;径向基函数网络;地下水位;预测

DOI:10.3778/j.issn.1002-8331.2010.02.066 文章编号:1002-8331(2010)02-0224-03 文献标识码:A 中图分类号:TP18

1 引言

地下水动态受一系列自然和人为因素的影响,它是地下水系统受多种输入所激励而产生的综合效应。降雨、用水可视为系统的输入,地下水位可视为系统的输出。由于年内的降雨、蒸发、用水具有一定的规律性,地下水位在年内的变化也有一定的规律;但因年际间的降水、蒸发及总体均衡程度的差异,各年的平均水位、水位变幅也有一定的变异性,这就使得多年地下水位的序列规律性较差,难于识别和预测,因此地下水动态的变化是一个复杂的非线性过程。关于地下水的动态预测,目前有许多方法,但各种方法均存在优缺点^[1]。

人工神经网络是 20 世纪 80 年代兴起的一种处理复杂非线性问题十分有效的手段,具有自组织、自学习、自适应等特点,不仅被广泛应用于模式识别、图像处理、非线性系统辨识和自适应控制等领域,也广泛用于动态预测和优化组合等方面。神经网络模型与传统的统计分析模型相比,具有更好的持久性和适时预报性,能够用于解决同时存在多个自变量和多个因变量的地下水系统预报问题^[2]。

蚁群算法(Ant Colony Algorithm, ACA)是一种模拟蚂蚁群体觅食行为的仿生优化算法,该方法采用了正反馈并行自催化机制,具有较强的鲁棒性、优良的分布式计算机制、易于与其他算法相结合等特点,在复杂优化以及智能搜索方面已经展现其优异的性能和巨大的发展潜力。将蚁群算法和径向基函数网络(Radial Basis Function network, RBF)结合起来,采用蚁群算法

来训练网络权值和阈值,使得蚁群神经网络具有神经网络的广泛映射能力又具有蚁群算法的快速、全局收敛以及启发式学习等特点,在某种程度上避免了单纯使用神经网络的不足。经训练后的神经网络用于地下水动态预测,取得了良好的效果^[3-5]。

2 基本蚁群算法

2.1 蚁群算法原理

20 世纪 90 年代初期,意大利学者 Dorigo Macro 等从生物进化论中受到启发,通过模拟自然界中蚂蚁群体觅食的行为而提出了蚁群优化算法(Ant Colony Optimization, ACO)。蚂蚁属群居昆虫,相互协作的一群蚂蚁很容易找到从蚁穴到食物的最短路径,而单个蚂蚁却不能。根据仿生学家的研究结果,蚂蚁凭借路径寻优的能力能够找到蚁巢与食物之间的最短路径,其原理在于蚂蚁在所经过的路径上留下一种称为信息素的挥发性分泌物,蚂蚁在觅食过程中能够感知这种物质的存在及其强度,并以此来指导自己的运动方向,倾向于朝着这种物质强度高的方向移动。信息素强度越高的路径,选择它的蚂蚁越多,则在该路径上留下的信息素强度更大,而强大的信息素又吸引更多的蚂蚁,从而形成一种正反馈。通过这种正反馈,蚂蚁最终可以发现最佳路径,导致大部分的蚂蚁都会走此路径。蚁群算法就是受这种行为启发,以人工蚂蚁模拟真实蚂蚁行为来求解组合优化问题的方法,它是继模拟退火算法、遗传算法、禁忌搜索算法、人工神经网络算法等启发式搜索算法之后的一种新型的、

基于群体智能的启发式仿生类进化算法^[6]。

2.2 蚁群算法数学模型

以图论中具有代表性的 TSP 问题为例,设有 n 个城市,蚂蚁数量为 m , $d_{ij}(i,j=1,2,\dots,n)$ 表示城市 i 和 j 之间的距离, $\tau_{ij}(t)$ 表示在 t 时刻城市 i 和 j 之间的路径上残留的信息量来模拟实际蚂蚁的信息素浓度^[7]。

初始化时, m 个蚂蚁被放置在不同的城市上,并赋予每条边上的信息量为 $\tau_{ij}(0)$ 。蚂蚁 k 的 $tabu_k$ (禁忌表)的第一个元素赋值为它所在的城市。

用 $p_{ij}^k(t)$ 表示在 t 时刻 k 蚂蚁由城市 i 转移到城市 j 的概率,则

$$p_{ij}^k(t)=\begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}(t)]^\beta}{\sum\limits_{s \in allowed_k} [\tau_{is}(t)]^\alpha [\eta_{is}(t)]^\beta}, & j \in allowed_k \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

其中 $allowed_k$ 表示蚂蚁 k 下一步允许走过的城市的集合,它随蚂蚁 k 的行进过程而动态改变;信息量 $\tau_{ij}(t)$ 随时间的推移而会逐步衰减,用 ρ 表示信息素挥发系数; α, β 分别表示蚂蚁在运动过程中所积累的信息量及启发式因子在蚂蚁选择路径中所起的不同作用; $\eta_{ij}(t)$ 为由城市 i 转移到城市 j 的期望程度,可根据某种启发算法而定。

为了避免残留信息素过多而引起残留信息淹没启发信息,在每只蚂蚁走完一步,或者完成对所有 n 个城市的遍历(也即一次循环)后,对残留信息素进行更新处理。 $t+n$ 时刻在路径 (i, j) 上的信息量按照如下规则进行调整:

$$\tau_{ij}(t+n)=(1-\rho) \cdot \tau_{ij}(t)+\Delta\tau_{ij}(t) \quad (2)$$

其中:

$$\Delta\tau_{ij}(t)=\sum_{k=1}^m \Delta\tau_{ij}^k(t) \quad (3)$$

$\Delta\tau_{ij}^k(t)$ 表示蚂蚁 k 在本次循环中在点 i 和 j 之间留下的信息量,其计算方法根据计算模型而定,在最常用的 ant cycle system 模型中:

$$\Delta\tau_{ij}^k(t)=\begin{cases} Q/L_k, & \text{若蚂蚁 } k \text{ 在本次循环中经过点 } i \text{ 和 } j \\ 0, & \text{其他} \end{cases} \quad (4)$$

其中 Q 为常数, L_k 为蚂蚁 k 在本次循环中所走过的路径长度。

3 蚁群径向基函数网络

3.1 蚁群算法与径向基函数网络的融合策略

假定网络有 m 个参数(包括权值和阈值)。首先,对这些参数进行排序,记为 $p_i(1 \leq i \leq m)$,对于每个 p_i ,将其设置为 N 个随机非零值,形成集合 I_{p_i} 。令蚁群中有 h 只蚂蚁出发寻找食物,每只蚂蚁从集合 I_{p_i} 出发,根据集合中每个元素的信息量和状态转移概率从集合 I_{p_i} 中选择一个元素,当所有集合中完成选择元素后,就到达了食物源,即在所有集合中选择了一组神经网络参数。然后,按照一定的规则调节集合中元素的信息量。这一过程反复进行,当全部蚂蚁收敛到同一路径时,也就意味着找到了网络参数的最优解^[8]。

3.2 基于蚁群算法的径向基函数网络优化训练

基于以上分析的融合策略,蚁群算法训练径向基函数网络的主要步骤如下^[9-11]:

(1) 初始化。初始化所有集合 $I_{p_i}(1 \leq i \leq m)$ 中的每个元素

$j(1 \leq j \leq N)$ 的信息素 $\tau_j(I_{p_i})$,所有路径的信息素置为 0,将时间 t 和循环次数 N_c 均置为 0,设置最大循环次数 N_{cmax} ,所有蚂蚁置于蚁穴。

(2) 启动蚂蚁。所有蚂蚁相对独立地从蚁穴出发开始搜索。

(3) 选择路径。对于集合 I_{p_i} 根据以下概率随机选择其第 j 个元素:

$$\text{Prob}(\tau_j^k(I_{p_i}))=\frac{\tau_j^k(I_{p_i})}{\sum_{g=1}^N \tau_g(I_{p_i})} \quad (5)$$

依次在所有集合中选择 1 个元素,同时该路径信息素增加。

(4) 信息素的挥发。当所有的蚂蚁在每步中完成选择后,从所有集合的每一个元素的信息量中减去 E , E 表示信息素的挥发。

(5) 返回蚁穴。在从食物源返回蚁穴其间,根据式(6)调节相当于每个所选择元素 p_i 的信息素 $\tau_j(I_{p_i})$,经历了 m 个时间单位后,信息素浓度为:

$$\tau_j(I_{p_i})(t+m)=\rho\tau_j(I_{p_i})(t)+\Delta\tau_j(I_{p_i}) \quad (6)$$

其中 $\rho(0 \leq \rho \leq 1)$ 表示信息素的持久性。

$$\Delta\tau_j(I_{p_i})=\sum_{k=1}^h \Delta\tau_j^k(I_{p_i}) \quad (7)$$

$\Delta\tau_j(I_{p_i})$ 表示在该次循环中第 k 只蚂蚁在集合 I_{p_i} 的第 j 个元素上留下的信息素,可用下式来计算:

$$\Delta\tau_j^k(I_{p_i})=\begin{cases} Qe^k, & \text{若蚂蚁 } k \text{ 在该次循环中选择了 } I_{p_i} \text{ 的第 } j \text{ 个元素} \\ 0, & \text{其他} \end{cases} \quad (8)$$

其中 Q 是常数,用于调节信息素的挥发速度; e^k 是以蚂蚁选择的元素作为神经网络的权值时各训练样本的最大输出误差,定义如下:

$$e^k=\min_{n=1}^s |Q_n-Q_q| \quad (9)$$

其中 s 是样本数量, Q_n 和 Q_q 是神经网络的实际输出和期望输出。因此误差越小,相对应的信息数增加就越多。

当所有蚂蚁都收敛到同一条路径或循环次数 $N_c >$ 最大循环次数 N_{cmax} ,即发现最优解,算法结束,网络训练完成;否则跳转到步骤(2)重新执行。

4 应用实例及分析

4.1 地下水位数据的引入与预处理

原始数据引自滦河某观测站 24 个月的地下水位实测序列值及 5 个影响因子实测序列值。河道流量、气温、饱和差、降水量、蒸发量都是影响地下水位的重要因子(表 1)。

获得有关地下水位的数据后,在用于训练样本和测试样本之前,需要进行归一化处理。

为检验网络的预测效果,测试集应为训练集以外的样本,所以任意选择第 6~24 组为训练样本,第 1~5 组为测试样本。

4.2 径向基函数网络的构建

径向基函数网络输入层神经元数目取决于地下水位的影响因子数,据题意确定为 5,即分别对应河道流量、气温、饱和差、降水量、蒸发量这 5 个输入向量,输出层神经元数为 1,即对应地下水位埋深。隐层单元激励函数为 matlab 中的高斯径向基函数 radas,加权函数为 dist,输入函数为 netprod,输出层神经元的激励函数为纯线性函数 purelin,加权函数为 dotprod,扩展常数 SPREAD 设为 2.5。径向基函数神经元模型和网络结构如图 1、图 2 所示^[12]。

表 1 地下水位及影响因子实测值

序号	河道流量	气温	饱和差	降水量	蒸发量	水位埋深
1	1.5	-10.0	1.20	1.0	1.2	6.92
2	1.8	-10.0	2.0	1.0	0.8	6.97
3	4.0	-2.0	2.5	6.0	2.4	6.84
4	13.0	10.0	5.0	30.0	4.4	6.50
5	5.0	17.0	9.0	18.0	6.3	5.75
6	9.0	22.0	10.0	113.0	6.6	5.54
7	10.0	23.0	8.0	29.0	5.6	5.63
8	9.0	21.0	6.0	74.0	4.6	5.62
9	7.0	15.0	5.0	21.0	2.3	5.96
10	9.5	8.5	5.0	15.0	3.5	6.30
11	5.5	0	6.2	14.0	2.4	6.80
12	12.0	0.5	4.5	11.0	0.8	6.90
13	0.5	1.0	2.0	1.0	1.0	6.70
14	3.0	-7.0	2.5	2.0	1.3	6.77
15	7.0	0	3.0	4.0	4.1	6.67
16	10.0	10.0	7.0	0	3.2	6.33
17	4.5	18.0	10.0	19.0	6.5	5.82
18	8.0	21.5	11.0	81.0	7.7	5.58
19	57.0	22.0	5.5	186.0	5.5	5.48
20	35.0	19.0	5.0	114.0	4.6	5.38
21	39.0	13.0	5.0	60.0	3.6	5.51
22	23.0	6.0	3.0	35.0	2.6	5.84
23	11.0	1.0	2.0	4.0	1.7	6.32
24	4.5	-7.0	1.0	6.0	1.0	6.56

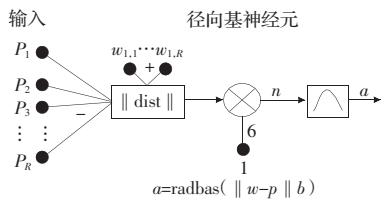


图 1 径向基函数神经元模型图

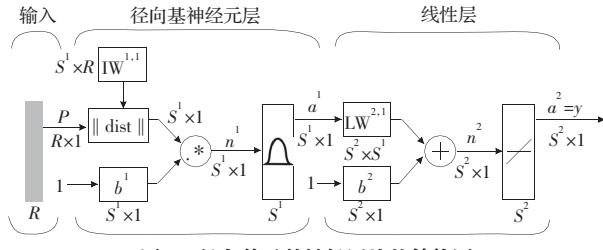


图 2 径向基函数神经网络的结构图

4.3 水位预测

构建好图 2 中的径向基函数神经网络后, 使用表 1 中的第 6~24 组数据为训练样本, 第 1~5 组数据为测试样本, 其水位预测和水位实测结果如下。

第 1~5 组水位预测序列值为:

6.964 2 7.068 1 6.553 2 6.244 7 5.793 8

第 1~5 组水位实测序列值为:

6.92 6.97 6.84 6.50 5.75

地下水位预测的常用方法还有模糊识别法、BP 网络法、RBF 网络法等, 作为与蚁群算法径向基函数网络的对比, 现采用完全相同的训练样本、测试样本、归一化处理, 将 4 种方法的地下水动态预测结果对比如表 2 所示。

从 4 种方法的预测结果对比可以看出, 蚁群径向基函数网络预测精度比模糊识别法、BP 网络和 RBF 网络明显要高。

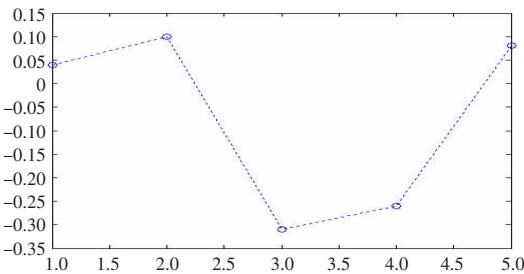


图 3 蚁群算法径向基函数网络预测误差

表 2 4 种方法的地下水动态预测结果对比

样本序号	实测值/m	模糊识别法		BP 网络		RBF 网络		蚁群 RBF 网络	
		预测值/m	相对误差差/(%)	预测值/m	相对误差差/(%)	预测值/m	相对误差差/(%)	预测值/m	相对误差差/(%)
1	6.92	6.70	3.3	6.54	5.5	6.68	3.5	6.96	0.6
2	6.97	6.70	4.2	6.75	3.2	6.81	2.3	7.07	1.4
3	6.84	6.77	1.0	6.55	4.2	6.64	2.9	6.55	4.2
4	6.50	6.30	3.2	5.94	8.3	6.03	7.2	6.24	3.7
5	5.75	5.82	1.2	5.60	2.6	5.91	4.0	5.79	0.7

5 结束语

尝试将蚁群算法与径向基函数网络相融合来进行地下水位预测, 这种方法不仅具有神经网络映射强的优点, 同时, 克服了神经网络容易陷入局部极小的问题。

实测数据表明, 这种方法用于地下水位预测时相对误差小、预测精度高、泛化能力强, 具有使用和推广价值。其不足之处在于网络训练时间较长, 不适合实时控制。

参考文献:

- [1] 杨建强, 罗先香.地下水动态预测的径向基函数法[J].工程勘察, 2001(5):35~37.
- [2] 罗定贵, 郭青, 王学军.基于 RBF 神经网络的地下水动态模拟与预测[J].地球学报, 2003, 24(5):475~478.
- [3] 洪炳熔, 金飞虎, 高庆吉.基于蚁群算法的多层前馈神经网络[J].哈尔滨工业大学学报, 2003, 35(7):823~825.
- [4] Hong B R, Jin F H, Guo Q. Hopfield neural network based on ant system[J]. Journal of Harbin Institute of Technology: New Series, 2004, 11(3):267~269.
- [5] Liu Yan-peng, Wu Ming-guang, Qian Ji-xin. Evolving neural networks using the hybrid of ant colony optimization and BP algorithm[C]//LINCNS 3971: ISNN 2006, 2006:714~722.
- [6] 程世娟, 卢伟, 陈虬.基于蚁群算法的最短路径搜索方法研究[J].科学技术与工程, 2007, 21(7):1671~1819.
- [7] 杨海, 王洪国, 徐卫东.蚁群算法的应用研究与发展[J].科学信息, 2007, 28:13~14.
- [8] 汪征江, 张洪伟, 雷彬.基于蚁群算法的神经网络在企业资信评估中的应用[J].计算机应用, 2007, 27(12):3142~3144.
- [9] 邹政达, 孙雅明, 张智晟.基于蚁群优化算法递归神经网络的短期负荷预测[J].电网技术, 2005, 3(2):59~63.
- [10] 胡利平, 许永威, 高文, 等.蚁群神经网络在鱼病专家系统的应用研究[J].微计算机信息, 2005, 21(7):149~151.
- [11] Xiong Wei-qing, Yan Chen-yang, Wang Liu-yi. Binary ant colony evolutionary algorithm[C]//International Conference on Intelligent Computing, 2005:1341~1350.
- [12] 飞思科技产品研发中心.神经网络理论与 MATLAB7 实现[M].北京:电子工业出版社, 2006.