

蚁群算法在需水预测模型参数优化中的应用

侯景伟^{1,2*}, 孔云峰², 孙九林³

(1. 宁夏大学 资源环境学院, 银川 750021; 2. 河南大学 环境与规划学院, 河南 开封 475004;

3. 中国科学院 地理科学与自然资源研究所, 北京 100101)

(* 通信作者电子邮箱 houjingwei2005@yahoo.com.cn)

摘要:为了解决投影寻踪(PP)需水预测模型的高维、非正态、非线性参数优化问题,提高需水预测的精度,尝试用基于网格划分的自适应连续域蚁群算法(ACA)在不同拟合和预测时长内对模型参数进行优化组合,并运用该模型进行年需水量预测。基于改进蚁群算法的投影寻踪需水预测模型参数优化进行了实例仿真。对基于改进蚁群算法的预测精度与基于人工免疫算法(AIA)和BP神经网络的模型(BPANN)参数优化结果分别进行了比较,实验结果表明:1)这三种算法的拟合精度相对误差绝对值分别小于2%、10%和10%;2)预测精度相对误差绝对值分别小于6%、11%和12%;3)改进蚁群算法能收敛到全局最优解,收敛速度较快。因此,改进蚁群算法的投影寻踪需水预测结果明显优于人工免疫算法和BP神经网络。该方法可推广到其他类似的高维非线性问题上。

关键词:蚁群算法;需水预测;参数优化;投影寻踪;人工免疫算法;BP神经网络

中图分类号: TP391.9 **文献标志码:** A

Application of ant colony algorithm for parameter optimization of water demand prediction model

HOU Jing-wei^{1,2*}, KONG Yun-feng², SUN Jiu-lin³

(1. School of Resources and Environment, Ningxia University, Yinchuan Ningxia 750021, China;

2. College of Environment and Planning, Henan University, Kaifeng Henan 475004, China;

3. Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, Beijing 100101, China)

Abstract: To improve forecast accuracy of water demand when using Projection Pursuit (PP) model which are high-dimensional, non-normality and nonlinear, an Ant Colony Algorithm (ACA) was used for the parameter optimization of the model. ACA was improved to self-adaptive control pheromone on the grids divided by definitional domains of the model parameters. A case for water demand prediction was emulated according to the improved ACA and PP model. Then prediction accuracy from the improved ACA was compared with the results from Artificial Immune Algorithm (AIA) and BP Artificial Neural Network (BPANN) model, respectively. It is shown that: 1) the absolute relative errors of fitting accuracy are less than 2% from ACA and less than 10% from AIA and BPANN; 2) the absolute relative errors of prediction accuracy are less than 6%, 11% and 12% from ACA, AIA and BPANN, respectively; 3) ACA can converge to global optimal solution with higher convergence rate. Therefore, the improved ACA for optimizing the parameters of PP water demand prediction model is significantly better than the AIA and BPANN. This method can be applied to other similar high-dimensional and nonlinear problems.

Key words: Ant Colony Algorithm (ACA); water demand; parameter optimization; Projection Pursuit (PP); Artificial Immune Algorithm (AIA); BP Artificial Neural Network (BPANN)

0 引言

水资源需求预测是区域产业结构调整、水资源优化配置、供水系统优化调度、水资源规划与管理等的重要参考依据。准确地预测区域水资源需求,对于处理好经济社会发展与水资源供求的矛盾具有重要的理论和现实意义。

传统的需水预测方法包括回归分析法^[1]、指标分析法^[2]、系统动力学法^[3]、灰色系统预测法^[4]等。近年来,人工神经网络^[5-7]、免疫进化算法^[8]等方法被引入到水资源需求预测中。这些方法存在易陷入局部极小点、外插和模型泛化能力弱、收敛速度慢、算法关键参数设置仅凭经验等问题^[9]。

投影寻踪^[10] (Projection Pursuit, PP)需水预测模型能更好地处理非正态、非线性、高维数等技术难点。为了解决PP需水预测模型的参数优化问题,目前常用的方法有多重平滑回归法^[11]、非参岭函数法^[12]、免疫进化算法^[8]等。这些方法往往优化过程比较繁杂,实现难度较大,结果易失真,并且算法的改进比较麻烦。近年来,迅速发展的蚁群算法(Ant Colony Algorithm, ACA)是模拟蚂蚁群体觅食行为的一种仿生优化算法^[13-14],具有鲁棒性强、分布式计算优良、正反馈并行自催化、易与其他算法结合等优点,在智能搜索和复杂优化方面具有巨大的发展潜力^[15-16]。因此,本文利用蚁群算法和投影寻踪需水预测模型来进行水资源需求预测。本文首先对

收稿日期: 2012-04-01; **修回日期:** 2012-05-28。 **基金项目:** 国家自然科学基金资助项目(40771146); 高等学校博士学科点专项科研基金资助项目(20070475001); 省部共建河南大学科研项目(SBGJ090605); 广西空间信息与测绘重点实验室(桂林理工大学)研究基金资助项目。

作者简介: 侯景伟(1973-),男,河南镇平人,博士,主要研究方向:GIS的开发与应用、最优化控制; 孔云峰(1967-),男,河南新安人,教授,博士生导师,主要研究方向:GIS分析与设计、空间优化、空间综合社会科学; 孙九林(1937-),男,江苏盐城人,工程院院士,博士生导师,主要研究方向:遥感与地理信息系统应用、虚拟地理环境、信息化农业、区域开发规划。

PP 需水预测模型及其驱动因素进行了分析,构建了参数优化的目标函数;其次对蚁群算法进行了设计和改进,并开发了基于蚁群算法的水资源需求预测软件;最后以河南省镇平县的需水预测为例,进行了水资源需求预测,并与其他智能算法的仿真结果进行了比较,以验证 ACA 在需水预测模型参数优化中的有效性和可行性。

1 PP 需水预测模型

1.1 需水预测驱动因素分析

水资源需求预测涉及经济、社会、生态、人口、技术等诸多方面,是一个多层次、多因素的复杂系统,具有一定的模糊性和不确定性。需水预测驱动因素的选择原则是依据研究区及其资料的实际情况,选择对区域年需水量相关性较强的影响因子。高相关性的影响因子包含的有效信息较多,使所构建的预测模型能更好地描述水资源需求的时空特征。一般来说,与年需水量相关性较强的影响因素包括 GDP、农业总产值、工业总产值、农业用水系数、城镇供水利用系数、水重复利用率、农村人口、城镇人口、大牲畜数量、小牲畜数量、居民人均可支配收入等。

1.2 基于投影寻踪的需水预测模型

由 Friedman 提出的投影寻踪是一种用来分析处理高维非正态的多元数据统计方法。PP 是把高维数据按一定方向投影到低维子空间上,利用投影指标函数分析原始数据结构特征,搜索投影指标函数达到最优时的投影值。PP 需水预测模型能有效防止维数灾难问题,在解决函数逼近、数据分类、时间序列预测等高维非正态和非线性问题上具有一定的优势。PP 需水预测模型如下:

$$D = \sum_{i=1}^m \alpha_i F_i \left(\sum_{j=1}^n \beta_{ij} x_j \right) \quad (1)$$

其中: D 为年需水量; m 为岭函数的个数; α_i 为第 i 个岭函数的权重; $F_i(\cdot)$ 为第 i 个岭函数; x_j 为第 j 个需水预测驱动因素, $j = 1, 2, \dots, n$; n 为自变量的个数,即所选取的需水预测驱动因素的个数; β_{ij} 为第 i 个岭函数在第 j 维向量的权重。

式(1)可以简化为矩阵形式:

$$D = [\alpha_1, \alpha_2, \dots, \alpha_m] \begin{bmatrix} \beta_{11} & \beta_{12} & \dots & \beta_{1n} \\ \beta_{21} & \beta_{22} & \dots & \beta_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \beta_{m1} & \beta_{m2} & \dots & \beta_{mn} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (2)$$

2 基于 ACA 的模型参数优化

2.1 参数优化目标函数的建立

在 PP 需水预测模型中,需要优化的参数包括 m 个 α_i 和 $m \times n$ 个 β_{ij} 。首先根据 PP 回归模型构建的极小化准则,选取 α_i 和 β_{ij} 的适当组合,使第 k 个水平年的需水预测误差的平方最小:

$$\min f_k = \left[D_k - \sum_{i=1}^m \alpha_i F_i \left(\sum_{j=1}^n \beta_{ij} x_j \right) \right]^2 \quad (3)$$

其中: $k = 1, 2, \dots, p$; p 为样本数; D_k 为预测水平年的实际用水量,单位为 m^3 。

利用式(3),PP 预测模型的参数优化问题就转化为目标极小化准则条件下的参数矩阵 $\{\alpha_i\}_{1 \times m}$ 和 $\{\beta_{ij}\}_{m \times n}$ 的优化问题。因此,PP 需水预测模型的参数优化问题就是求需水预测误差的平方和均值的最小化问题,其目标函数为:

$$\min f = \frac{1}{p} \sum_{k=1}^p f_k \quad (4)$$

2.2 参数优化的蚁群算法设计

PP 需水预测模型的参数 α_i 和 β_{ij} 的定义域为连续域,因此,本文利用基于网格划分的自适应连续域蚁群算法^[17-18]对参数进行优化。

假设把每个变量分成 N 等份,每个变量有 $N+1$ 个节点, n 个变量共有 $(N+1) \times n$ 个节点。蚂蚁从第 1 个变量移动到第 n 个变量之后所形成的路径集合,就组成了目标函数的一个状态空间解集。该状态空间解集的元素 x_j 为:

$$x_j = x_j^{\text{lower}} + \frac{x_j^{\text{upper}} - x_j^{\text{lower}}}{N} \times l_j \quad (5)$$

其中: x_j^{lower} 和 x_j^{upper} 分别为第 j 个变量定义域的下限值 and 上限值; l_j 为第 j 个变量在 N 等份中所对应第 l 行数, $l \in [0, N]$ 。

蚂蚁 k 在第 j 个变量的第 i 个节点的状态转移概率为:

$$P_{ij}^k = \tau_{ij}^k / \sum_{j=0}^N \tau_{ij}^k \quad (6)$$

$$\tau_{ij}^k = (1 - \rho) \tau_{ij}^k + Q / f \quad (7)$$

其中: τ_{ij}^k 为蚂蚁 k 在第 j 个变量的第 i 个节点的信息量; Q 为一常数; ρ 为信息素挥发系数。

为了防止蚁群算法出现停滞和扩散问题,把每条路径上可能的信息素限制在 $[\tau_{\min}^k, \tau_{\max}^k]$ 。在第 t 次迭代结束后,保留最优的路径,并且只对最优路径上的蚂蚁进行信息素更新。对更新后的信息素阈值进行判断:

$$\tau_{ij}^k(t+1) = \begin{cases} \tau_{\min}^k, & \tau_{ij}^k(t) \leq \tau_{\min}^k \\ \tau_{ij}^k(t), & \tau_{\min}^k < \tau_{ij}^k(t) \leq \tau_{\max}^k \\ \tau_{\max}^k, & \tau_{ij}^k(t) > \tau_{\max}^k \end{cases} \quad (8)$$

为了提高搜索速度,避免优化方案陷入局部最优状态,自适应地控制信息素挥发系数 ρ :

$$\rho(t+1) = \begin{cases} 0.95\rho(t), & 0.95\rho(t) > \rho_{\min} \\ \rho_{\min}, & \text{其他} \end{cases} \quad (9)$$

另外,目标函数的一般算术表达式是一个包含平方运算的复杂多项式。为了有效求解该类复杂的高维非线性问题,在蚁群算法中嵌入了逆波兰表达式算法^[19]。逆波兰表达式能将复杂表达式转换为可以依靠简单的操作得到计算结果。它的优势在于只用两种简单操作,入栈和出栈就可以搞定任何普通表达式的运算。

2.3 参数优化 ACA 的实现步骤

步骤 1 利用逆波兰表达式算法将一般算术表达式转换为逆波兰表达式;估计出各变量的定义域: $x_j^{\text{lower}} \leq x_j \leq x_j^{\text{upper}}$ ($j = 1, 2, \dots, n$), n 为需水预测驱动因子的个数;

步骤 2 初始化 τ_{ij}^k 、 τ_{\min}^k 、 τ_{\max}^k 、 Q 、 ρ 、 ρ_{\min} 、最大迭代次数 I_{\max} 、蚂蚁数 N_{ant} 等;

步骤 3 对每个变量进行 N 等分,每个变量有 $N+1$ 个节点,每一等份的长度为:

$$h_j = \frac{x_j^{\text{upper}} - x_j^{\text{lower}}}{N}; j = 1, 2, \dots, n$$

步骤 4 如果 $\max(h_1, h_2, \dots, h_j, \dots, h_n) < \varepsilon$, ε 为设定的最小阈值,那么算法终止,其最优解为:

$$x_j^* = \frac{x_j^{\text{lower}} + x_j^{\text{upper}}}{2}; j = 1, 2, \dots, n$$

否则执行步骤 5;

步骤 5 蚂蚁 k 根据式(6)、(7) 选择下一个节点;

步骤 6 根据式(4) 计算目标函数 f , 根据式(8) 和(9) 更新信息素;

步骤 7 $k = k + 1$, 如果 $k < N_{\text{ant}}$, 那么跳转步骤 5; 否则, 查找 τ_{ij}^k 矩阵中每列最大元素所对应的行集 (l_1, l_2, \dots, l_j) ,

$\cdots, l_n)$, 缩小每个变量 x_j 的取值范围:

$$x_j^{\text{lower}} = x_j^{\text{lower}} + \left(l_j - \frac{1}{2}h_j\right)h_j$$

$$x_j^{\text{upper}} = x_j^{\text{lower}} + \left(l_j + \frac{1}{2}h_j\right)h_j$$

其中 $j = 1, 2, \cdots, n$, 迭代次数加1, 跳转步骤3。

3 实例仿真

本文以河南省镇平县的需水预测为实例, 借助蚁群算法对 PP 需水预测模型进行参数优化。随着镇平县社会经济的快速发展, 水资源需求量在不断地增加, 再加上水环境恶化,

水质性缺水日益严重, 对该县经济社会的可持续发展构成了严峻挑战。因此, 准确预测镇平县的水资源需求量具有更大的现实意义。

根据河南省水资源综合规划和镇平县统计局的相关资料以及镇平县的实际情况, 选取影响镇平县需水量相关性较强的驱动因子, 主要包括: GDP (X_1)、农业总产值(X_2)、工业总产值(X_3)、年末总人口(X_4)、大牲畜数量包括牛、羊、猪(X_5)、农民人均纯收入(X_6)、城镇居民人均可支配收入(X_7)、牧业总产值(X_8) (表1)。选取 1978—2009 年中不连续的 8 年的系列值作为样本数据。

表1 镇平县需水量与各驱动因子的相关性分析

年份	$D/(10^4 \text{ m}^3)$	$X_1/10^4$ 元	$X_2/10^4$ 元	$X_3/10^4$ 元	X_4	X_5	$X_6/$ 元	$X_7/$ 元	$X_8/10^4$ 元
1978	18 210	10 248	6 561	10 568	73.3	199 100	276	430	1 219
1980	19 070	12 142	6 980	10 435	75.5	158 500	286	451	1 501
1985	18 850	32 812	26 304	20 924	82.92	231 600	366	497	4 953
1990	23 860	68 970	38 154	68 065	89.83	270 100	588	862	9 839
1995	28 520	334 844	94 811	535 282	92.38	466 900	1 355	2 346	35 520
2000	33 140	627 907	157 541	1 110 311	93.45	601 000	2 192	3 963	65 357
2005	36 570	1 049 065	191 443	2 302 620	95.81	742 600	3 281	6 951	131 503
2009	41 080	1 368 003	279 170	2 856 618	97.62	320 460	5 396	12 085	92 829
相关系数		0.972 6	0.971 1	0.924 3	0.894	0.8	0.9339	0.9177	0.9227

序列缺失数据的处理。由于历史原因, 镇平县 1983 年以前的农民人均纯收入和 1984 年以前的城镇居民人均可支配收入缺失。本研究根据灰色系统理论以及序列数据的特点, 利用递进灰拟合模型^[20]对单序列数据集进行预测和插值, 使缺失数据具有较好的光滑性和较高的预测精度(表1)。

岭函数个数的确定。合理地确定岭函数的个数可以减少预测结果的误差, 反映数据本身的结构特征。岭函数通常取 2~5 个(如果岭函数太多, 那么在运算过程中可能会发生“维数灾”), 本研究利用开发的基于蚁群算法的水资源需求预测软件平台(图1), 通过实验法来确定岭函数的个数。

分别取岭函数的个数 $m = 1, 2, 3, 4, 5$, 将每个目标函数 f 分别在软件中运行 5 次, 并求其平均值, 找到平均值最小的目标函数所对应的岭函数个数即为最优个数。经实验, 当 $m = 2$ 时 f 平均值最小, 因此, 本研究取两个岭函数。根据式(3)和(4), 在取两个岭函数的情况下, PP 需水预测模型的求解面临的是一个 18 维(变量)非线性的多项式。

初始化蚁群算法的相关参数。取最大变量个数 20, 迭代次数 130, 蚂蚁数量 40, 分别把每个变量的取值范围分为 10 等份, $\rho = 0.95$, 总信息素为 1.0, 算法退出条件为相邻两次迭代结果 f 值之差为 0.001, 每次迭代结束后, 变量的范围缩小参数为 0.96。

为了分析不同拟合和预测时长的精度差异, 利用该软件和式(2), 按照间隔 1、3、5、7、9 年, 分别计算高维非线性多项式的最优值。经过反复实验发现, 1 年拟合间隔在每次计算的最优解都是 0, 与目标函数的理想最优解 0 相等, 拟合效果最理想; 随着拟合时长的增加, 每次计算的最优解和相对误差有增大的趋势。

图1为基于蚁群算法的一次参数优化结果。图1的上部为计算过程和结果, 本次迭代 123 次后算法结束, 目标函数最优解为 0.363 10; 图1的中部为该次迭代过程的算法收敛情况, 可以看出蚁群算法能收敛于全局最优解, 收敛速度较快;

图1的下部为模型选择与输入以及模型参数大致取值范围的输入等。




图1 基于蚁群算法的需水预测界面和运行结果

模型参数的初始取值范围可凭经验确定, 如果不能凭经验确定, 可利用如图1的软件把每个参数的取值范围设置得足够大, 该算法能够自动找到参数的最优解或次优解。

为了验证拟合间隔内的拟合精度和拟合间隔之后的可行预测时长和预测精度, 下面以 3 年拟合间隔为例。首先, 随机选取连续的 3 年拟合间隔, 如 1978—1980 年, 用蚁群算法分别计算 5 次, 求得 $\min f = 0.89384$, 以及 f 所对应的 18 个参数最优值, 其中 α_i 矩阵为 $[-0.83163 \quad 0.91577]$, β_{ij} 矩阵为:

$$\begin{bmatrix} -0.87609 & -0.5208 & 0.62703 & 0.9865 & -0.51591 & -0.89834 & -0.48636 & -0.72596 \\ 0.21261 & -0.85174 & 0.99519 & 0.99826 & -0.43964 & -0.36433 & -0.78764 & 0.82356 \end{bmatrix}$$

分别将 1978—1984 年的 GDP 等 8 个变量值和 18 个最优参数值代入式(2),计算每年的需水量和相对误差(表 2)。由表 2 可知,在 1978—1980 年的拟合阶段,相对误差都几乎为 0,说明用蚁群算法进行水资源需求预测的拟合精度非常高;而在 1981—1984 年的预测阶段,由于都采用 1978—1980 年的最优参数,距离拟合阶段最近的 1981 年的预测精度很高,其相对误差为 4%,距离拟合阶段越远,即预测时长越长,其相对误差越大,预测精度越低。用相同方法随机检验不同拟合间隔,所得结论都是如此。因此,在进行水资源需求预测时,不能用相同的最优参数预测若干年的需水量,而应根据相对误差值对第一个预测年的需水量进行修正后逐年外推,以提高预测精度。

表 2 拟合值与预测值误差分析

年份	实际年需水量	计算年需水量	相对误差/%
1978	18210	18210.14	0.0008
1979	18730	18729.50	-0.0026
1980	19070	19068.91	-0.0057
1981	19620	20410.37	4.0284
1982	19010	21739.87	14.3602
1983	18730	28914.66	54.3762
1984	18540	31396.72	69.3458


为了验证蚁群算法在水资源需求预测中的可行性和有效性,分别用人工免疫算法和二层 BP 神经网络模型对 PP 需水预测模型进行参数优化。1978—2002 年的数据采用 5 年拟合间隔,2003—2009 年的数据采用逐年预测方法。在利用免疫算法对 PP 需水预测模型进行参数优化时,首先在 N 维空间随机生成 n 个初始群体,并计算 n 个个体的适应度,找出初始最优个体,计算初始群体的标准差;通过免疫进化,生成子代群体,并计算子代其适应度,找出最优个体;如果子代最优个体的适应度大于父代的适应度,那么子代最优个体代替父代最优个体;反复迭代,直至满足终止条件,便获得最优个体。BP 神经网络^[21-23]以 1978—2002 年的数据为训练样本,输入数据为它们的实际规模,实际用水量为期望输出值,学习效率为 0.01,最大训练次数为 3000,动量因子为 0.6,终止条件为 0.5。三种算法的实际值、拟合值、预测值和相对误差的比较见图 2。

由图 2(a)可以看出,蚁群算法、人工免疫算法和 BP 神经网络对年需水量的预测结果与实际值基本上吻合,其中蚁群算法所预测结果基本上与实际值重合。从图 2(b)可以进一步分析,在样本数据拟合阶段(1978—2002 年),除了 BP 神经网络在 1995 和 2001 年大于 10% 以外,三种预测方法的相对误差绝对值一般都小于 10%。蚁群算法的平均相对误差绝对值最小,都小于 2%,并且多数在 1% 以下。在样本数据预测阶段(2003—2009 年),三种预测方法的相对误差绝对值都高于拟合阶段。蚁群算法的相对误差绝对值都小于 6%,人工免疫算法和 BP 神经网络的相对误差绝对值分别在 11% 和 12% 以下。因此,无论在拟合阶段,还是在预测阶段,基于蚁群算法的水资源需求拟合精度和预测精度都明显优于人工免疫算法和 BP 神经网络^[24]。


4 结语

投影寻踪需水预测模型体现了需水预测中的高维、非正

态、非线性特点,特别适合系统机制不够清晰或水文地质资料缺乏的地区。



(a) 实际值、拟合值与预测值的比较



(b) 相对误差的比较

图 2 不同预测方法的比较

基于网格划分的自适应连续域蚁群算法为解决 PP 需水预测模型的参数优化问题开辟了新的途径。通过对蚁群算法进行设计和改进,使其能更好地收敛于全局最优解,并具有较强的抗噪声能力,避免早熟收敛现象。实例仿真表明了基于蚁群算法的 PP 需水预测模型的拟合精度非常高,相对误差绝对值都小于 2%,大多在 1% 以下;预测精度在距离拟合阶段越近的年份较高,预测时长越长,预测精度越低。因此建议采用逐年预测,根据预测的相对误差对预测结果进行修正后再进行下一年的预测,以提高预测的精度。为了验证蚁群算法在需水预测模型参数优化中的可行性和有效性,分别用人工免疫算法和 BP 神经网络模型对 PP 需水预测模型进行参数优化和模型求解。结果表明,无论在拟合阶段,还是在预测阶段,基于蚁群算法的拟合精度和预测精度都明显优于人工免疫算法和 BP 神经网络。本研究设计的蚁群算法可以推广到其他高维非线性问题的求解,具有较为广阔的应用前景。

参考文献:

- [1] 李铁映,张昕. 预测决策方法[M]. 沈阳: 辽宁科学技术出版社, 1984.
- [2] 韩振强,张新海,崔荃. 黄河远景需水分析——兼论西线南水北调的必要性[J]. 自然资源, 1996(5): 29-35.
- [3] 高彦春,刘昌明. 区域水资源系统仿真预测及优化决策研究——以汉中盆地平坝区为例[J]. 自然资源学报, 1996, 11(1): 23-32.
- [4] 王煜. 灰色系统理论在需水预测中的应用[J]. 系统工程, 1996, 14(1): 60-64.
- [5] 罗利民,方浩,仲跃,等. 小波神经网络算法在区域需水预测中的应用[J]. 计算机工程与应用, 2006, 42(3): 200-201, 214.

(下转第 2959 页)

动信号的时滞系统进行控制,给出了预测控制器的结构和参数优化方法。仿真结果表明,这种方法对不确定时滞系统能够实现在线实时控制,并能较好地改善系统的性能。当时滞为慢时变时,输出也能跟踪输入。当被控对象存在干扰时,利用基于免疫进化计算适应性地调整前馈补偿的增益,在一定程度上可以实现对系统扰动的补偿。通过对钢铁高炉炉温控制实验,表明当系统模型不匹配时,该方法也能达到较好的控制效果,具有一定的实用价值。




图10 被控对象发生变化后响应曲线比较

参考文献:

- [1] 张蒙. 新型 Smith 预估控制器在大延迟系统中的应用[J]. 电力自动化设备, 2011, 31(4): 136-139.
- [2] 雷霞, 李晓光, 尹振红. 基于 Sugeno 推理自调整模糊 Smith-PID 控制器仿真研究[J]. 系统仿真学报, 2008, 20(18): 4952-4955.
- [3] 宋中民, 陈兴林, 段广仁. 基于粗糙集理论与进化计算的时滞系统 Smith 控制[J]. 系统仿真学报, 2006, 18(8): 2247-2250.
- [4] LUO YAN-BIN, GAO YONG-YAN, SUN YOU-XIAN. Robust stability of uncertain Takagi-Sugeno fuzzy systems with time-varying input-delay [J]. Acta Automatica Sinica, 2008, 34(1): 87-92.
- [5] 季春光, 王朋, 李士勇, 等. 基于神经网络的时变大滞后系统的 Smith 预估控制[J]. 哈尔滨工业大学学报, 2003, 35(3): 303-306.
- [6] VIEIRA J, MOTA A. Smith predictor based neural fuzzy controller applied in a water gas heater that presents a large time-delay and load disturbances[C]// CCA'03: Proceedings of 2003 IEEE Conference on Control Applications. [S. l.]: IEEE, 2003: 362-367.
- [7] 张国云, 章兢, 谭建豪. 不确定时滞系统的自适应支持向量机 Smith 预估控制[J]. 湖南大学学报: 自然科学版, 2005, 32(3): 84-89.
- [8] TAKAHASHI K, YAMADA T. Application of an immune feedback mechanism to control systems[J]. JSME International Journal, Series C, 1998, 41(2): 184-191.
- [9] 章家岩, 马中海, 李绍铭. Smith 预估补偿控制策略在转炉煤气回收系统中的应用[J]. 仪器仪表学报, 2011, 32(3): 628-634.
- [10] 陈菊, 刘桂香, 朱学峰. 改进的自适应修正 Smith 算法在大时滞过程控制中的仿真研究[J]. 仪器仪表学报: 增刊, 2008, 29(4): 263-264.
- [11] SASAKI M, KAWAFUKU M, TAKAHASHI K. An immune feedback mechanism based adaptive learning of neural network controller [C]// ICONIP'99: The 6th International Conference on Neural Information Processing. Washington, DC: IEEE Computer Society, 1999: 502-507.
- [12] 丁永生, 任立红. 一种新颖的模糊自调整免疫反馈控制系统[J]. 控制与决策, 2000, 15(4): 443-446.
- [13] 刘宝, 王君红, 丁永生. 一种基于生理调节机制的智能协同借偶控制器[J]. 信息与控制, 2009, 38(5): 539-545.
- [6] JAIN A, VARSHNEY A K, JOSHI U C. Short-term water demand forecast modeling at II T kanpur using artificial neural networks [J]. Water Resources Management, 2001, 15(13): 299-331.
- [7] JAIN A, ORMSBEE L E. Short-term water demand forecast modeling techniques-conventional methods versus AI [J]. Journal American Water Works Association, 2002, 94(7): 64-72.
- [8] 张灵, 陈晓宏, 刘丙军, 等. 免疫进化算法和投影寻踪耦合的水资源需求预测[J]. 自然资源学报, 2009, 24(2): 328-334.
- [9] 何飞, 张国忠, 刘亚. 基于 BP 网络的改进负荷预测方法[J]. 华东电力, 2004, 32(3): 31-33.
- [10] FRIEDMAN J H, STUETZLE W. Projection pursuit regression [J]. Journal of the American Statistical Association, 1981, 76(3): 817-823.
- [11] 邓传玲. SMART 多重平滑回归技术的原理及计算软件[J]. 八一农学院学报, 1988, 11(4): 47-55.
- [12] 郑祖国, 刘大秀. 投影寻踪自回归和多维混合回归模型及其在大河长河段洪水预报中的应用[J]. 水文, 1994(4): 6-10.
- [13] 周波, 钱来, 孟正大, 等. 基于蚁群算法的喷涂机器人路径排序优化[J]. 计算机工程, 2012, 38(1): 192-194, 207.
- [14] COLORNI A, DORIGO M, MANIEZZO V, et al. Distributed optimization by ant colonies [C]// Proceedings of the 1st European Conference on Artificial Life. [S. l.]: IEEE, 1991: 134-142.
- [15] DORIGO M. Optimization, learning and natural algorithms [D]. Italy: Politecnico di Milano, Department of Electronics, 1992.
- [16] DORIGO M, MANIEZZO V, COLORNI A. Ant system: optimization by a colony of cooperating Agents [J]. IEEE Transactions on Systems, Man, and Cybernetics - Part B, 1996, 26(1): 29-41.
- [17] 段海滨, 马冠军, 王道波, 等. 一种求解连续空间优化问题的改进蚁群算法[J]. 系统仿真学报, 2007, 19(5): 494-497.
- [18] 段海滨. 蚁群算法原理及其应用[M]. 北京: 科学出版社, 2005.
- [19] 杨忠. 逆波兰表达式在 VB 中的算法设计与实现[J]. 制造业自动化, 2011, 33(5): 150-151, 154.
- [20] 金义富, 朱庆生, 邢永康. 序列缺失数据的灰插值推理方法[J]. 控制与决策, 2006, 21(2): 236-240.
- [21] 许银山, 吕孙云, 梅亚东, 等. 多维新息向神经网络模型在需水预测中的应用[J]. 水资源保护, 2012, 28(2): 8-11, 16.
- [22] 王丽霞, 任志远, 孔金玲. 基于 BP 模型的延河流域社会经济需水预测[J]. 干旱区资源与环境, 2011, 25(4): 106-110.
- [23] 龙训建, 钱鞠, 梁川. 基于主成分分析的 BP 神经网络及其在需水预测中的应用[J]. 成都理工大学学报: 自然科学版, 2010, 37(2): 206-210.
- [24] 侯景伟. ACA 与 RS、GIS 耦合的水资源空间优化配置[D]. 开封: 河南大学, 2012.

(上接第 2955 页)