

文章编号:1000-582X(2005)02-0077-04

# 基于广义遗传优化的 RBF 算法在铁水脱硫中的应用\*

周世纪<sup>1</sup>, 彭燕妮<sup>1,2</sup>, 曹长修<sup>1</sup>

(1. 重庆大学自动化学院, 重庆 400030; 2. 重庆工商大学 计算机科学与信息工程学院, 重庆 400033)

**摘要:**铁水脱硫过程是一个非常复杂的多元非线性反应过程,在研究了基本遗传算法和 RBF 算法的基础上,提出了基于广义遗传优化的 RBF 算法。并说明了基于广义遗传优化的 RBF 算法在某钢厂铁水脱硫预报模型中的应用。该算法不仅克服了 RBF 中心个数选择的随机性,而且较好地解决了遗传算法时间复杂度高的缺点。通过对基于广义遗传优化的 RBF 算法与 RBF 算法的仿真比较,进一步阐明了该算法在铁水脱硫预报模型中的有效性和精确性。并且现场实验也表明,该算法能够达到终点命中率在 85% 以上,这说明了该算法的工程实用性。

**关键词:**实数编码;广义遗传算法;RBF 算法;主群;脱硫

**中图分类号:**TP183

**文献标识码:**A

铁水脱硫是一个非常复杂的多元非线性反应过程<sup>[1]</sup>,传统的基于脱硫过程物理化学反应和求解微分方程的建模方法普遍存在建模复杂、预报精度低、不能适应铁水原材料及炉况变化等缺点。为了给某大型钢铁厂优化工艺结构,减少生产成本,降低脱硫预报模型的复杂度,提高脱硫剂量预报精度,这就要求运用一种更智能,精度更高的方法进行建模和预报。RBF 网络具有结构简单,编程简单,速度快的特点,但 RBF 网络应用的难点在于中心个数的选择<sup>[2]</sup>,中心个数的选择对网络的逼近能力和效果有很大影响;而广义遗传算法采用定向演化模式,通过将局部定向寻优与局部最优状态的定向转移结合实现全局最优化的功能,但广义遗传算法训练时间复杂度高,因而提出了把广义遗传算法和传统的 RBF 算法结合起来应用在铁水脱硫预报模型中。根据脱硫前的初始条件和终点命中率要求,并且针对数据集的更新和维护的要求,对脱硫预处理过程建立了基于广义遗传优化的 RBF 算法的数学模型,估算合适的脱硫剂加入量。该算法不仅克服了 RBF 中心个数选择的随机性,并且较好地解决了遗传算法时间复杂度高的缺点。通过现场扩大性试验,输出结果达到终点命中率要求,证明了该算法的有效性,可以指导生产实践。

## 1 脱硫模型介绍

在实际的铁水脱硫过程中,影响铁水脱硫剂量的几个因素主要有铁水重量、铁水含硫量、目标硫的含量、脱硫剂类型,其他影响因素还有脱硫前后铁水成分,铁水罐号等。这些因素之间存在严重的非线性关系,在对厂家提供的大量数据进行了相关性分析后,确定了输入输出,并给出了相关的模型如图 1 所示。




图 1 脱硫模型结构

为了克服以往方法实用性较差的困难,文献[3]采用 RBF 神经网络来构建脱硫非线性模型。但 RBF 网络应用的难点在于中心个数的选择,如果中心个数过少,则不能完成分类任务,如果中心个数过多,则网络规模会很大,会产生过学习,使得输入数据和训练样本之间有很小的畸变,得不到正确的泛化结果,而且运算时间也会大幅度的增加,且网络规模过大也不利于工程应用。针对这些缺点,提出了基于广义遗传优化

\* 收稿日期:2004-08-19

基金项目:2002 年重庆市应用基础研究项目(7369);国家教育部博士点基金项目(98061117)

作者简介:周世纪(1976-),男,重庆大学硕士研究生,主要研究方向:神经网络,智能计算及其在计算机通信方面的应用。

的 RBF 算法的脱硫预报模型。

## 2 基于广义遗传优化的 RBF 算法分析

由于实数编码在遗传算法中有表示自然、搜索范围大、精度高的优点,因而在遗传算法中选用实数编码的方法,RBF 网络采用三层结构,在此基础上建立了基于广义遗传优化的 RBF 算法的脱硫模型。根据以上分析所确定模型的主要输入:铁水重量、铁水含硫量、脱硫后残硫量、脱硫剂种类;其它输入:脱硫前铁水成分、脱硫后铁水成分;输出参数:脱硫剂加入量。为了减少运算复杂度,降低运算时间,综合比较了主要输入和其它输入对脱硫效果和脱硫剂加入量的影响,决定取主要输入作为模型的输入,其它输入用于在数据预处理中,剔除噪声数据,使模型的输入更真实可靠。由于目前 RBF 神经网络存在着结构难以确定的问题,即中心数目和宽度难以确定。本项目的目的是要设计出满足目标误差要求的尽可能小的网络结构,以保证神经网络的泛化能力和推广能力。因而利用广义遗传算法优化 RBF 函数的的隐层神经元个数和宽度。

### 2.1 样本数据预处理

项目中一共选择 500 组样本数据,其中 2/3 数据用于建模,1/3 组数据用于预测。在进行样本学习以前,首先根据经验把数据进行预处理,即根据生产经验人为的设定样本数据的上下限阈值,剔除掉不符合要求样本记录,之后再采用极差标准化方法作如下处理:

一批样本中每维参数的最大值与最小值之差称为这维参数的极差,即  $R(i) = \max(x_k(i)) - \min(x_k(i))$ ,其中  $1 \leq k \leq n, 1 \leq i \leq m, x_k(i)$  表示第  $k$  个样本的第  $i$  维参数。把样本标准化即把每个  $x_k(i)$  都换为  $x'_k(i) = (x_k(i) - \bar{x}(i))/R(i)$ 。其中  $\bar{x}(i)$  是所有样本第  $i$  维参数的平均值。标准化后,各维参数均处在  $[-1, +1]$  之间。在遗传操作结束后再根据  $\bar{x}(i)$  和  $R(i)$  对数据进行还原。

### 2.2 RBF 神经网络中心和权值的确定

RBF 神经网络中心的选取对网络的非线性映射有着极其重要的作用,目前一般都采用 K 均值聚类<sup>[4]</sup>或最近邻聚类算法<sup>[5]</sup>,这里选用最近邻聚类算法确定此脱硫模型的初始中心和权值,后用广义遗传算法对 RBF 函数的中心和宽度进行优化。最近邻聚类确定中心和权值步骤如下:

1) 选择一个适当的高斯函数宽度  $r$ , 定义一个矢量  $a(h)$  用于存放属于各类的输出矢量之和,定义一个计数器  $b(h)$  用于统计属于各类的样本个数,其中  $h$  为类别数。

2) 从第 1 个输入样本  $x_1$  开始,在  $x_1$  上建立一个聚类中心  $c_1 = x_1$ , 令  $a(1) = x_1, b(1) = 1$ , 这样建立的 RBF 网络只有一个隐单元,中心为  $c_1$ , 输出权矢量为  $w_1 = a(1)/b(1)$ 。

3) 对于第 2 个输入样本  $x_2$ , 求出  $x_2$  到  $c_1$  的距离  $|x_2 - c_1|$ , 如果  $|x_2 - c_1| \leq r$ , 则  $c_1$  为  $x_2$  的最近邻聚类, 且令  $a(1) = x_1 + x_2, b(1) = 2, w_1 = a(1)/b(1)$ ; 如果  $|x_2 - c_1| > r$ , 则将  $x_2$  作为一个新聚类中心, 并令  $c_2 = x_2, a(2) = x_2, b(2) = 1$ 。在第 1 步建立的 RBF 网络中再添加一个隐单元, 该隐单元到输出层的权矢量为  $w_2 = a(2)/b(2)$ 。

4) 把所有样本数据按照上述方法处理完, 就可以得到中心个数  $n$  和权值  $w_i, i = 1, 2, \dots, m$ 。

### 2.3 广义遗传算法优化设计

利用基于实数编码的广义遗传算法<sup>[6-7]</sup>对 RBF 函数的中心个数  $n$  和宽度  $\sigma$  进行优化。即选择  $n$  和  $\sigma$  作为遗传基因。

#### 2.3.1 适度值函数选择

适度函数用来计算种群中个体的适度值, 而适度值是遗传算法中区分个体“好坏”的唯一标准, 也是选择操作的唯一依据。考虑到用 RBF 神经网络建模的目的是使模型的预报精度和泛化能力能达到一个合理的平衡, 因而以训练集和测试集联合误差作为度量个体“好坏”的依据, 误差越小, 说明个体越好, 误差越大, 说明个体越坏。本项目使用如下的函数来评价适度值:

$$fitness = \frac{1}{1 + 0.8 * \frac{1}{0.3N_{i \in \text{测试集}}} + 0.2 * \frac{1}{0.7N_{j \in \text{训练集}}} e_j^2}$$

其中  $N$  为样本总数, 采用普遍的 2/3 样本作为训练集合, 1/3 样本作为内部测试集合来对模型的推广性进行评估, 是误差, 即 RBF 网络实际输出与期望值之差。

#### 2.3.2 交叉算子和变异算子设计

由于采用实数编码方式, 因此设计交叉算子和变异算子。

1) 交叉算子: 采用算术交叉算子, 设  $(n_1, \sigma_1), (n_2, \sigma_2)$  分别为第  $t$  代的 2 个交叉的个体, 则交叉后 2 个个体分别变为

$$\begin{cases} n_1(t+1) = n_1(t) + \tau_1(n_1(t) - n_2(t)) \\ n_2(t+1) = n_2(t) + \tau_2(n_1(t) - n_2(t)) \\ \sigma_1(t+1) = \sigma_1(t) + \tau_3(\sigma_1(t) - \sigma_2(t)) \\ \sigma_2(t+1) = \sigma_2(t) + \tau_4(\sigma_1(t) - \sigma_2(t)) \end{cases}$$

其中,  $\tau_i$  是  $[-1, 1]$  上均匀分布的随机数, 为了减

少待参数的数目,不妨令  $\tau_1 = \tau_2 = \tau_3 = \tau_4$ 。

2) 变异算子:在这里采用高斯变异,设  $(n, \sigma)$  为代变异的个体,其中  $n \in (n_{\min}, n_{\max}), \sigma \in (\sigma_{\min}, \sigma_{\max})$ ; 对于该项目的 RBF 神经网络建模,  $n_{\min} = 20, n_{\max} = 200, \sigma_{\min} = 0.1, \sigma_{\max} = 5$ 。则该个体的变异结果为:

$$n' = \begin{cases} n + \Delta(n_{\max} - n) & \text{随机数} \geq P_{\text{inc}} \\ n - \Delta(n - n_{\min}) & \text{随机数} \leq P_{\text{inc}} \end{cases}$$

$$\sigma = \begin{cases} \sigma + \Delta(\sigma_{\max} - \sigma) & \text{随机数} \geq P_{\text{inc}} \\ \sigma - \Delta(\sigma - \sigma_{\min}) & \text{随机数} \leq P_{\text{inc}} \end{cases}$$

其中,  $P_{\text{inc}}$  是该个体在本次变异中增大的概率,其取值根据变异前后的适应值与变异方向的关系,通过赏罚策略实现自适应调整:定义两个表征不同变异方向的概率,当变异后个体适应值降低,则将相应变异方向的概率减小;反之增大。函数  $\Delta(y)$  为返回区间  $[0, y]$  上的值,可按如下选取:

$$\Delta(y) = \begin{cases} |r|, & |r| \leq y \\ y, & |r| > y \end{cases}$$

其中  $r$  是满足高斯分布的随机数,均值取为 0。

为了更好的促进广义遗传算法中渐进和骤变相结合的进化模式,设计了变异强度自适应变化的方法,即将高斯分布方差按下式求取:

$$\begin{cases} \text{渐进:} & y \cdot \zeta^{t/K} \\ \text{骤变:} & y \cdot (2 - \zeta)^{t/K} \end{cases}$$

其中,  $0 < \zeta < 1$  定义为衰减系数,  $t$  是当前进化代数,  $K$  定义为衰减频率,也就是每隔  $K$  代进行一次强度变化。在渐进阶段中,变异强度逐渐减小,促进局部寻优快速稳定收敛;在骤变阶段中,变异强度逐渐加大,促进局部最优状态定向转移。

因为在广义遗传算法中,交叉操作和变异操作都是作为必然事件,所以略去了交叉概率  $p_c$  和  $p_m$ 。变异概率,从而减少了算法控制参数,提高了算法的自适应性。

### 2.4 广义遗传优化算法程序流程

项目中使用了广义遗传算法对  $n$  和  $\sigma$  这两个参数进行优化。优化算法步骤如下:

1) 对历史数据进行数据预处理,剔除空数据和平滑异常数据,然后对其进行极差标准化,从中随机抽取 500 条数据作为训练样本集:其中作为训练 RBF 神经网络的内部训练数据,剩下作为测试模型泛化能力的内部测试数据,广义遗传算法通过这两组误差作为适应度函数,对网络结构进行优化,即对 RBF 函数中心数目和宽度进行优化,从而选择出最优的网络结构。

2) 选用实数编码方法对中心数目  $n$  和宽度  $\sigma$  进行编码,适应度函数、遗传算子如上所述。

3) 在广义遗传算法中采用“群中群”策略,种群

个体数为 70,主群个体数为 20。当主群中群首连续 5 次不变,由渐进转入骤变状态;如果群首被更换,则算法从骤变状态回到渐进状态。当群首连续 20 次不变时候,认为广义遗传算法已经收敛,程序结束。此时种群的群首即为最优的 RBF 神经网络结构参数。

经过上述 3 步,得到的模型结构即是最优的模型结构。

### 3 仿真实验结果及分析

以该钢铁厂数据库中历史数据为基础,选取其中的 500 组数据,400 组作为训练集,随机选取其余 100 组中的 30 组作为测试集,分别使用传统的 RBF 神经网络和基于广义遗传优化的 RBF 算法进行建模。分别使用这两种模型对脱硫过程进行预报,得到结果如图 2 和图 3 所示。




图 2 传统 RBF 脱硫预报模型(预报精度 71.42%)

在图 2 中,可以明显看出,传统的 RBF 算法的中心位置基本上集中在输出 1 000 公斤上下的密集样本区域中,所以在这部分空间中预测效果很好,而在样本分布较少的高输出 ( $\geq 1\ 400$  kg) 和非常稀少低输出 ( $\leq 700$  kg) 的空间中没有相应的中心形成,导致在这些区域预报精度严重降低,甚至出现了错误的预报结果(第 11 个测试样本至第 15 个测试样本)。




图 3 基于广义遗传算法优化的 RBF 脱硫预报模型(预报精度 86.5%)

通过使用广义遗传算法对 RBF 神经网络的中心和宽度进行同时优化,经过 133 代遗传,自适应得到中心数数目 82,宽度 1.677,使用相同的测试数据集得到图 3 所示曲线。对比图 2 和图 3,可以看出基于广义遗传算法优化的 RBF 脱硫预报模型在预报精度上已经大大超过了传统的 RBF 神经网络模型,尤其是在高输出的情况,已经能够很准确的进行预报。实验证明了广义遗传算法对于提高模型的性能具有相当显著的

效果,其稳定的全局优化能力和快速的收敛速度在大型复杂的工业生产建模具有实用性和推广性。

#### 4 结 论

由以上分析及算法流程可以看出,加入广义遗传算法优化的 RBF 模型的训练时间复杂度要高于传统的 RBF 模型训练时间,这是改进算法存在的一个缺憾,但是考虑在钢铁生产中脱硫工艺的相对稳定性,脱硫静态模型在工艺不变的情况下不需经常训练,一旦模型建立,可以使用较长的时间,所以用此混合算法来提高模型预报精度的方法,在实际生产中是可行的。

#### 参考文献:

- [1] 黄道鑫. 提钒炼钢[M]. 北京:冶金工业出版社,2000.
- [2] ZEKERIVA U, CUNEV T G. Analysis of Input-output Clustering for Determining Centers of RBFN[J]. IEEE Trans Neural Networks,2000,16(4):851-857.
- [3] ROBERT J S, JAMSEX J C. Approximation of Nonlinear Systems with Radial Basis Function Neural Networks[J]. IEEE Trans Neural Networks,2001,19(4):1-14.
- [4] 柴天佑,谢书明,杜斌,等. 基于 RBF 神经网络的转炉炼钢终点预报[J]. 中国有色金属学报,1999,9(4):869-892.
- [5] 朱明星,张德龙. RBF 网络基函数中心选取算法的研究[J]. 安徽大学学报(自然科学版),2000,24(1):73-78.
- [6] 徐宗本,聂赞坟,张文修. 父代种群参与竞争遗传算法几乎必然收敛[J]. 应用数学学报,2002,1,25(1):165-175.
- [7] 周明,孙树栋. 遗传算法原理及应用[M]. 北京:国防工业出版社,1999.

## Application of RBF Algorithm Based on Generalized Genetic Optimization in Prediction Model for Molten Iron Desulfuration

ZHOU Shi-ji<sup>1</sup>, PENG Yan-ni<sup>1,2</sup>, CAO Chang-xiu<sup>1</sup>

(1. College of Automation, Chongqing University, Chongqing 400030, China;

(2. Computer Science and Information Engineering College, Chongqing Technology and Business University, Chongqing 400033, China)

**Abstract:** Desulfuration process is a very sophisticate reaction which is not only diverse but also non-line. A RBF algorithm based on generalized genetic optimization is proposed after studying the standard genetic and RBF algorithm. The authors also introduce its application in prediction Model for molten Iron Desulfuration. The algorithm perfectly resolve the problem of random selection of RBF cluster center number. Furthermore, it also reduces the time which GA uses. Comparison between the simulation results of RBF and RBF algorithm Based on GGA optimization further proves the efficiency and precision of its application in Prediction Model for Molten Iron Desulfuration. Finally the result of the test shows that after adopting the algorithm, the end-point hitting ratio can reach eighty-five percent. This indicate the algorithm has the engineering practicability.

**Keywords:** real-coded; generalized genetic algorithm(GGA); RBF algorithm; heading population; desulfurization

(编辑 吕赛英)