

A-PDF Split DEMO : Purchase from [www.A-PDF.com](http://www.A-PDF.com) to remove the watermark

# 基于量子微粒群的 BPNN 在 转炉炼钢静态模型中的应用 \*

朱亚萍, 王文龙, 徐生林

(杭州电子科技大学 自动化学院, 浙江 杭州 310018)

**摘要:**针对转炉炼钢静态模型终点命中率较低的问题,首先分析了影响转炉炼钢终点命中率的各种因素,确定了BP神经网络(BPNN)的拓扑结构,并依此建立了转炉炼钢静态模型。然后把量子微粒群算法(QPSO)应用于BP网络的学习中,并比较了QPSO、基本微粒群优化算法(PSO)、梯度下降法的学习性能。最后,基于某炼钢厂的历史数据进行了仿真实验,比较了三种BP网络学习算法下的炼钢终点命中率。研究结果表明,该研究提高了转炉炼钢静态模型的终点C含量和温度预测精度。

**关键词:**BP 神经网络; 转炉炼钢; 量子微粒群优化算法; 基本微粒群优化算法

中图分类号:TP273; TF721

文献标志码:A

文章编号:1001-4551(2011)05-0598-03

## Application of BPNN in static model of converter steelmaking based on quantum-behaved particle swarm optimization

ZHU Ya-ping, WANG Wen-long, XV Sheng-lin

(College of Automation, Hangzhou Dianzi University, Hangzhou 310018, China)

**Abstract:** For the problem of low hit rate of the BOF endpoint based on static model, the factors that affect the hit rate of the BOF endpoint was firstly analyzed, topologies of the BP neural network (BPNN) were determined, the static BOF model was established. Then the quantum particle swarm optimization (QPSO) was used in the study of BP network, and the learning performance of QPSO, the basic particle swarm optimization (PSO), gradient descent was compared. Finally, experiment based on historical data of a steel plant was simulated, the hit rate of the BOF endpoint was compared under three types of BP network learning algorithm. The results indicate that the analysis improves prediction accuracy of the converter end C content and temperature.

**Key words:** BP neural network(BPNN); converter steelmaking; quantum particle swarm optimization(QPSO); particle swarm optimization(PSO)

## 0 引言

转炉炼钢过程是一个相当复杂、高温、多相的物理化学过程,该过程的主要目标是在吹炼终点尽可能达到目标钢水的温度和成分含量。近年来,神经网络在炼钢生产过程中得到广泛的应用<sup>[1-2]</sup>,并取得了一些满意的效果。当前我国存在不少中、小转炉,对这些转炉来说,建立动态模型,需要增设副枪或炉气分析仪等动态设备<sup>[3-5]</sup>,这样会显著增加生产成本。相对而言,将静态模型与人工神经网络技术相结合,开发人工智能静态模型,可以有效地提高终点预测准确率,而成本也

不会显著增加。

本研究提出一种基于量子微粒群优化算法的BP神经网络,用于建立转炉炼钢静态模型。并与基本粒子群优化算法、传统的梯度算法比较,验证所提方法在转炉炼钢预测中的有效性。

## 1 基于 BP 神经网络的转炉炼钢静态模型

利用神经网络可以不需要建立数学模型而对复杂系统进行预测和控制,其中BP神经网络在实际炼钢

应用中最为广泛。BP神经网络是一种多层前向反馈神经网络,隐层节点一般以S型函数作为激活函数:

$$\varphi(x) = 1/(1 - e^{-x}) \quad (1)$$

影响终点钢水温度和钢水碳含量的因素很多,经相关分析,本研究选定模型的输入变量为:铁水量 $X_1$ 、铁水温度 $X_2$ 、铁水C含量 $X_3$ 、铁水Si含量 $X_4$ 、铁水Mn含量 $X_5$ 、铁水P含量 $X_6$ 、铁水S含量 $X_7$ 、废钢量 $X_8$ 、生铁量 $X_9$ 、渣钢量 $X_{10}$ 、石灰加入量 $X_{11}$ 、镁球加入量 $X_{12}$ 、白云石加入量 $X_{13}$ 、铁矿石加入量 $X_{14}$ 、一倒吹氧气量 $X_{15}$ 、一倒供氧时间 $X_{16}$ 、一倒冶炼时间 $X_{17}$ ,共17个变量,即神经网络输入节点数 $I=17$ 。对终点钢水碳含量和终点钢水温度建模,模型输出量为吹炼终点时的钢水碳含量 $Y_1$ 和钢水温度 $Y_2$ ,即神经网络输出节点数 $O=2$ 。隐含层节点数 $M$ 通过多次仿真实验加以确定,即 $M=23$ 。基于具有一个隐层的BP神经网络的转炉炼钢静态模型结构如图1所示。

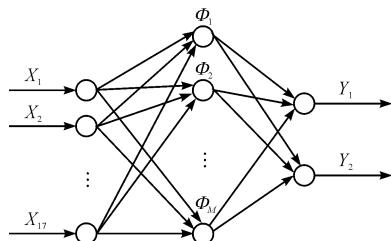


图1 基于BP神经网络的转炉炼钢静态模型结构

## 2 基于量子微粒群优化算法的BP网络学习算法

### 2.1 量子微粒群优化算法

量子微粒群优化算法以量子物理基本理论为基础,它改变了基本微粒群优化算法的进化算法的搜索策略,可以在整个可行解空间中进行搜索,并且进化方程中不需要速度向量,进化方程的形式更简单,参数更少,更容易控制<sup>[6-7]</sup>。

算法方程如下:

$$p_i = \frac{c_1 \times p_{\text{Best}} + c_2 \times g_{\text{Best}}}{c_1 + c_2} \quad (2)$$

$$m_{\text{Best}} = \frac{1}{M} \sum_{i=1}^M p_i \quad (3)$$

$$X(t+1) = p \pm \beta \times |m_{\text{Best}} - X(t)| \times \ln \frac{1}{u} \quad (4)$$

式中: $c_1$ 、 $c_2$ —在(0,1)之间产生的随机数; $m_{\text{Best}}$ —中值最优位置; $\beta$ —收缩扩张系数,调节它的值能控制算法的收敛速度; $X(t)$ —粒子的相关位置信息; $M$ —群体中所含粒子的数目; $u$ —(0,1)之间的随机数。

在迭代过程中,“±”是由(0,1)之间随机产生的随机数 $u$ 的大小决定的,当 $u > 0.5$ 时,取“-”号,其他情况取“+”号。

### 2.2 量子微粒群优化算法作为BP网络学习算法

学习算法通过量子微粒群优化算法获得一组权值,组成BP网络。算法流程如下:

- (1) 确定3层BP网络的输入节点数 $I$ ,输出节点数 $O$ ,隐含层节点数 $M$ ;
- (2) 计算粒子维度 $D = I \cdot M + M \cdot O$ ,确定粒子规模、收缩扩张系数 $\beta$ ,根据具体问题确定最大迭代次数、适应度函数及适应度限制;
- (3) 初始化一组粒子,包括这组粒子的初始位置和初始速度;
- (4) 每一个粒子映射成一组权值,组成BP网络;
- (5) 用训练样本对BP网络进行训练;
- (6) 计算各个粒子的适应度;
- (7) 按照适应度更新 $p_{\text{Best}}$ 和 $g_{\text{Best}}$ ;
- (8) 判别终止条件。迭代已满,或满足适应度限制则终止,输出具有最好适应度的粒子;否则继续;
- (9) 未终止则按式(2,3,4)进化各个粒子的位置和速度,转到(4)迭代。

### 2.3 3种BP网络学习算法的比较

梯度下降法、基本微粒群优化算法、量子微粒群算法都可作为BP网络的学习算法。

基于梯度下降法的BP网络,收敛速度慢,在训练大样本集时易于陷入局部最小点等问题<sup>[8]</sup>。

基本微粒群优化算法不能保证全局收敛,在标准PSO系统中,粒子的收敛以轨道的形式实现,并且又由于粒子的速度总是有限的,在搜索过程中粒子的搜索空间是一个有限的区域,不能覆盖整个可行空间。PSO算法不能保证以概率1收敛到全局最优解<sup>[9-10]</sup>。与PSO相比,量子微粒群优化算法具有简单、调节参数少、易实现的优点,具有良好的收敛性和稳定性。

## 3 模型仿真实验

### 3.1 算法参数确定

BP网络输入节点个数为17,输出节点数为2,隐层节点数按经验取为32;迭代次数选为160次;种群规模选为20。

为保证一定的全局搜索能力和收敛速度, $\beta$ 在0.9~0.5之间取值,随迭代次数线性减小。

### 3.2 数据预处理

数据预处理方法如下:

(1) 剔除异常。本研究采用某炼钢厂 50 t 转炉 2009 年的数据。数据中会存在一些异常值, 异常值可能是由于炼钢过程中的喷溅引起, 也有可能是操作工操作异常所致。需要剔除这些异常值, 否则会引起模型的训练错乱。去除异常数据后, 选取 90 炉数据样本, 其中前 60 炉作为训练样本, 后 30 炉作为测试样本。

(2) 标准化处理。模型各输入变量间的数量级相差较大, 这样会导致模型的学习过程太长, 将输入数据标准化可在一定程度上加快学习过程。本研究中将每一维输入按如下公式归一化到区间 [0, 1] 内:

$$X'_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (9)$$

### 3.3 模型的自适应设计

随着时间的推移, 炉衬的变化, 氧枪的变化, 使模型预测精度逐渐下降, 因而应当在模型进行预测的过程中及时更新模型。BP 神经网络具有在线学习能力, 当结束一炉预测时, 本研究对这一炉的冶炼信息进行一次学习, 及时更新模型参数, 然后再对下一炉次进行预测, 实现模型的自适应。

### 3.4 仿真实验结果及分析

本研究分别用 BP 神经网络的 3 种学习算法, 建立了转炉炼钢静态预测模型, 以进行仿真实验。3 种学习算法下测试样本 30 炉的终点钢水温度预测结果如图 2 所示。

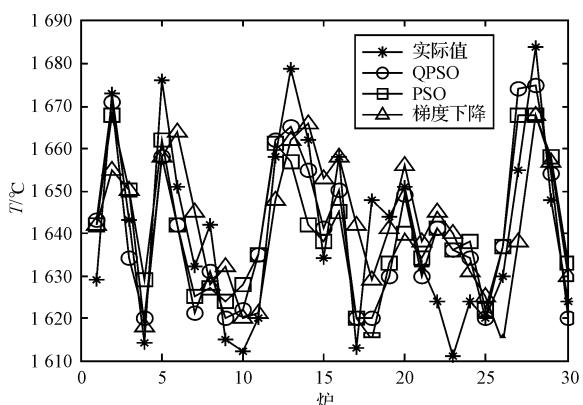


图 2 终点钢水温度预测结果

终点钢水碳含量预报误差在  $\pm 0.02\%$  以内, 终点钢水温度预报误差在  $\pm 15^{\circ}\text{C}$  以内时, 对 5 次有效实验结果取平均, 终点钢水温度和碳含量预报命中率如表 1 所示。

从表 1 中可以看出, 基于量子微粒群优化算法的 BP 神经网络用于转炉炼钢静态预测, 与其他学习算法相比, 具有较高的终点钢水温度命中率和终点钢水碳含量命中率。

表 1 终点钢水碳含量、温度预报命中率

学习算法	碳含量 ( $\pm 0.02\%$ )	温度 ( $\pm 15^{\circ}\text{C}$ )
梯度下降法	68.3%	70%
PSO	73.7%	76.6%
QPSO	77.2%	83.3%

注: 对应于梯度下降法、PSO、QPSO 的双命中率分别为 59.8%、65.0%、70.2%。

## 4 结束语

转炉炼钢静态模型的建立是一个重要课题。本研究将基于量子微粒群优化算法的 BP 神经网络, 用于建立转炉炼钢静态预测模型, 并进行了仿真实验。研究结果表明, 该方法对终点钢水温度、碳含量具有较好的预测精度, 基本满足生产过程的需要。另外, 本研究中并未考虑枪位曲线变化对终点的影响, 将来可就此进一步完善模型。

### 参考文献(References):

- [1] 王登峰, 倪红卫. 人工神经网络在转炉炼钢终点预报中的应用研究[J]. 钢铁研究, 2005, 4(2): 27-31.
- [2] 谢书明, 陈昌, 丁惜瀛. 基于 BP 神经网络的转炉炼钢终点预报[J]. 沈阳工业大学学报, 2007, 29(6): 707-71.
- [3] 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): 868-872.
- [4] 胡志刚, 唐恒国, 张占省. 转炉炉气分析与“投弹”检测相结合在自动化炼钢技术中的应用[J]. 中国冶金, 2010, 20(1): 42-45.
- [5] 刘文, 杨宪礼, 白彦. 转炉采用炉气分析法进行动态控制[J]. 炼钢, 2003, 19(5): 48-51.
- [6] 张兰, 邢志栋. 基于量子微粒群求解混合整数规划[J]. 计算机工程与应用, 2010, 46(9): 49-50.
- [7] 陈伟, 冯斌, 孙俊. 基于 QPSO-RBF NN 的混沌时间序列预测[J]. 计算机应用研究, 2007, 24(5): 68-70.
- [8] SHUN J, MALKI H A. Network Intrusion Detection System Using Neural Networks [C] // Fourth International Conference on Natural Computation (ICNC'08), 2008: 242-246.
- [9] CLERC M. The swarm and queen: towards a deterministic and adaptive particle swarm optimization [C] // Proceeding of Congress of Evolutionary Computation. Piscataway, NJ: IEEE Press, 1999: 1951-1957.
- [10] RICHARDS M, VENTURA D. Choosing a starting configuration for particle swarm optimization [C] // Proceeding of IEEE International Joint Conference on Neural Networks, 2004: 2309-2312.

[编辑: 柴福莉]