

# 改进的 PSO-RBF 神经网络在联合制碱中的应用

李永伟<sup>1</sup>, 李钰曼<sup>1</sup>, 王红飞<sup>1</sup>, 李丽铭<sup>2</sup>

(1.河北科技大学电气工程学院,河北石家庄 050018;2.河北科技大学党政办公室,河北石家庄 050018)

**摘要:**联合制碱过程是一类典型的复杂工业过程,具有时变、非线性、不确定性等特征,在线控制模型难以建立。针对联合制碱复杂工业过程控制精度不高、鲁棒性差等问题,提出一种改进的 PSO-RBF 神经网络控制算法。将粒子群优化算法和径向基神经网络相结合,使用改良的粒子群优化算法对 RBF 神经网络的隐含层基函数中心、宽度和输出层的连接权值进行寻优,建立基于改进的 PSO 算法优化后的 RBF 神经网络模型。将改进的 PSO-RBF 神经网络控制模型应用到联合制碱的关键工序碳化过程中,并与先前应用的模糊神经网络控制模型进行比较,经仿真研究验证表明,在联合制碱碳化过程中应用改进的 PSO-RBF 神经网络控制算法,其控制精度和系统鲁棒性得到了有效的提高,为解决一类复杂工业过程的建模与优化控制方法研究提供了有效的技术途径。

**关键词:**自动化技术应用;联合制碱;粒子群优化算法;RBF 神经网络;优化控制

中图分类号:TP183;TQ114

文献标志码:A

## Application of improved PSO-RBF neural network in the synthetic ammonia decarbonization

LI Yongwei<sup>1</sup>, LI Yuman<sup>1</sup>, WANG Hongfei<sup>1</sup>, LI Liming<sup>2</sup>

(1.School of Electrical Engineering, Hebei University of Science and Technology, Shijiazhuang, Hebei 050018, China;2.Department of CP Affairs and Administration, Hebei University of Science and Technology, Shijiazhuang, Hebei 050018, China)

**Abstract:** The synthetic ammonia decarbonization is a typical complex industrial process, which has the characteristics of time variation, nonlinearity and uncertainty, and the on-line control model is difficult to be established. An improved PSO-RBF neural network control algorithm is proposed to solve the problems of low precision and poor robustness in the complex process of the synthetic ammonia decarbonization. The particle swarm optimization algorithm and RBF neural network are combined. The improved particle swarm algorithm is used to optimize the RBF neural network's hidden layer primary function center, width and the output layer's connection value to construct the RBF neural network model optimized by the improved PSO algorithm. The improved PSO-RBF neural network control model is applied to the key carbonization process and compared with the traditional fuzzy neural network. The simulation results show that the improved PSO-RBF neural network control method used in the synthetic ammonia decarbonization process has higher control accuracy and system robustness, which provides an effective

收稿日期:2017-09-30;修回日期:2017-11-06;责任编辑:李 穆

基金项目:河北省自然科学基金(F2014208145)

第一作者简介:李永伟(1958—),男,河北沧县人,教授,主要从事复杂工业过程智能控制、信息融合、故障诊断等方面的研究。

E-mail:0599li@163.com

李永伟,李钰曼,王红飞,等.改进的 PSO-RBF 神经网络在联合制碱中的应用[J].河北科技大学学报,2017,38(6):578-584.

LI Yongwei, LI Yuman, WANG Hongfei, et al. Application of improved PSO-RBF neural network in the synthetic ammonia decarbonization[J]. Journal of Hebei University of Science and Technology, 2017, 38(6): 578-584.

way to solve the modeling and optimization control of a complex industrial process.

**Keywords:** automated technology applications; the synthetic ammonia decarbonization; PSO; RBF neural network; optimal control

周光耀院士在侯德榜研究的基础上发明了新型变换气联合制碱工艺,解决了倒塔和连续工作的难题,使联合制碱工业过程能进行连续自动控制<sup>[1]</sup>。在整个制碱过程中,碳化过程是核心工序,它是在碳化塔内完成的,这个过程属典型的复杂工业过程,包含了许多物理化学反应,并同时存在着气、液、固三种状态,在反应的全部过程中,流量、压力大小和各个部位的温度等必须进行全面监测和协调控制<sup>[2-6]</sup>。碳化过程的重要工艺指标是  $\text{NaHCO}_3$  的结晶粒度,为了获得理想的  $\text{NaHCO}_3$  结晶体,首先要避免溶液饱和度过大,必须把其严格控制在一定的范围内。此外,还要控制塔内各个部位的温度,通过大量实际生产经验得知,塔内物料反应的情况可以通过碳化塔的纵向温度分布来估计。多年来,控制界专家学者对联合制碱碳化过程进行了大量的研究,对该生产过程进行了多种控制方法的尝试,如 DCS 控制、模糊控制和模糊神经网络控制等<sup>[7-10]</sup>。这些控制方式都起到了一些效果,但其控制精度、鲁棒性等都不太令人满意。鉴于此,在深入研究联合制碱碳化过程和 RBF 神经网络的基础上,引进粒子群优化(particle swarm optimization, PSO)算法,提出了改进的 PSO-RBF 神经网络控制算法。首先,从机理上研究影响因素,找到输入输出变量,建立 RBF 神经网络模型;而后,针对 RBF 神经网络的模型布局特征,提出一种调整惯性权值和学习因子的改良算法,利用改进的 PSO 算法对 RBF 神经网络参数寻优,对改进的 PSO-RBF 神经网络控制算法进行仿真实验研究,并与模糊神经网络控制算法进行效果比较。

## 1 改进的 PSO-RBF 神经网络模型原理

### 1.1 RBF 神经网络

RBF 神经网络是一种由输入层、隐含层和输出层三层组成的广泛应用的神经网络<sup>[11-12]</sup>。采集到的数据通过输入层进入到神经网络中,经过隐含层的径向基函数进行网络学习,并通过隐含层和输出层之间的连接权值计算后到达输出层<sup>[13-14]</sup>,从而产生响应。RBF 神经网络结构示意图如图 1 所示。

标准高斯函数往往被作为隐含层的函数,以下是第  $j$  个隐含层径向基函数的表达式:

$$\phi_j(x) = \exp\left(-\frac{\|X - c_j\|^2}{2\sigma_j^2}\right), \quad j = 1, 2, \dots, J, \quad (1)$$

此时输出为

$$y_k = \sum_{j=1}^J \omega_{jk} h_j(X), \quad k = 1, 2, \dots, K. \quad (2)$$

式(1)、式(2)中  $X$  代表训练样本,是网络的输入量;每个隐含层函数都有一个中心值  $c_j$  和宽度  $\sigma_j$ 。式(2)代表输出函数,其中  $\omega_{jk}$  是隐含层与输出层之间的连接权值。中心  $c_j$ 、宽度  $\sigma_j$ 、连接权值  $\omega_{jk}$  需通过学习和训练确定,本文拟采用粒子群优化(PSO)算法对这 3 个参数进行寻优,进一步提高神经网络的整体性能。

### 1.2 粒子群优化算法

粒子群优化算法中每一个粒子的位置就代表解空间中的一个解,这些粒子在空间内不停的变换位置进行搜索。每个粒子把自身搜索到的最优位置记录下来,称为个体极值,从个体极值中选取最优值作为全局极值,粒子根据个体极值和全局极值随时更新自身的速度和位置,通过接近全局最优位置的粒子实现目标优化。

假设存在一个维数为  $D$  的搜索空间,粒子数为  $n$ ,下式表示其中第  $i$  个粒子的位置:

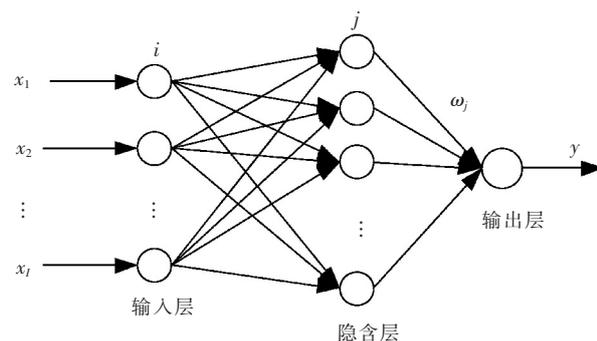


图 1 RBF 神经网络结构示意图

Fig.1 Structure of RBF neural network

$$x_i = (x_{i1}, x_{i2}, \dots, x_{iD}),$$

第  $i$  个粒子的速度表示为

$$v_i = (v_{i1}, v_{i2}, \dots, v_{iD}),$$

这个粒子自身经历过的最好位置为个体极值:

$$p_i = (p_{i1}, p_{i2}, \dots, p_{iD}),$$

从所有粒子的个体极值中选择适应度值最小的作为全局极值:

$$p_g = (p_{g1}, p_{g2}, \dots, p_{gD}),$$

在找到这 2 个极值后,粒子根据式(3)、式(4)更新速度和位置:

$$v_{id}^{t+1} = \omega v_{id}^t + c_1 r_1 (p_{id}^t - x_{id}^t) + c_2 r_2 (p_{gd}^t - x_{id}^t), \quad (3)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1}, \quad (4)$$

式中:  $i=1, 2, \dots, n$ ;  $d=1, 2, \dots, D$ ;  $\omega$  为惯性权重;  $c_1$  和  $c_2$  为学习因子;  $v_{id}$  是粒子  $i$  迭代到  $t$  时的第  $d$  维速度,  $v_{id} \in [-v_{\max}, v_{\max}]$ ;  $r_1, r_2$  是介于  $[0, 1]$  之间的随机数。

### 1.3 改进的 PSO 算法

标准 PSO 算法在寻优时有很多优点,但也存在不足,如标准算法易过早陷入局部最优值而非真正的全局最优值,影响全局最优解的搜索<sup>[15]</sup>。为了改善标准 PSO 算法的这个缺点,在研究了惯性权重和学习因子的基础上提出了改进的 PSO 算法。若惯性权重的值较大,则可以提高粒子的全局搜索能力;否则,粒子的全局搜索能力下降,局部探索能力获得加强。因此,为了平衡全局和局部搜索之间的关系,提出改进理念:开始时全局搜索能力强,等找到最优值的大致范围后,再提高局部搜索能力,使粒子群快速搜索到全局最优解<sup>[16-17]</sup>。根据以上理念,引入一种按照指数下降的惯性权重调整策略,如式(5)所示:

$$\omega(t) = \omega_{\text{end}} + (\omega_{\text{start}} - \omega_{\text{end}}) e^{(-\frac{8t}{T})}. \quad (5)$$

取  $\omega_{\text{start}}=0.9$ ,  $\omega_{\text{end}}=0.4$  和  $T=1000$ , 惯性权重随迭代次数的变化曲线图如图 2 所示。

由图 2 可以看到: 惯性权重在迭代初期变化较快,在迭代后期变化减慢,并且在算法搜索末期还能保持较大的惯性权重。

学习因子在粒子的寻优过程中可以调节个体认知和群体认知所占的比重<sup>[18]</sup>。个体极值的速度由学习因子  $c_1$  调节,群体的全局极值的速度由学习因子  $c_2$  调节。因此,为了提高搜索精度,对学习因子进行不断调整:影响个体极值速度的学习因子  $c_1$  逐渐变小,相反影响全局极值速度的学习因子  $c_2$  逐渐变大。这样调整能够保证粒子在寻优初期进行大范围搜索,后期完成精细搜索。具体设置如下:

$$c_1(t) = (c_{1f} - c_{1i}) \times \frac{(T-t)}{T} + c_{1i}; \quad (6)$$

$$c_2(t) = (c_{2f} - c_{2i}) \times \frac{t}{T} + c_{2i}. \quad (7)$$

式中:  $c_{1i}, c_{2i}$  为初值;  $c_{1f}, c_{2f}$  为终值;  $t$  为目前的迭代次数;  $T$  为最大迭代次数。假如初值设为 0.5, 终值设为 2.5, 最大迭代次数  $T$  设为 1000, 则随着迭代次数的增加,学习因子  $c_1$  从 2.5 减小到 0.5, 学习因子  $c_2$  从 0.5 增大到 2.5。

### 1.4 改进的 PSO-RBF 神经网络模型的构建

改进的 PSO-RBF 神经网络的基本思想是将 RBF 神经网络中所有的径向基函数中心、宽度和连接权值看成不断移动的粒子<sup>[19]</sup>,通过改进后的算法对这些粒子的最优值进行搜寻<sup>[20]</sup>。径向基神经网络的误差函数作为适应度函数,计算公式如式(8)所示:

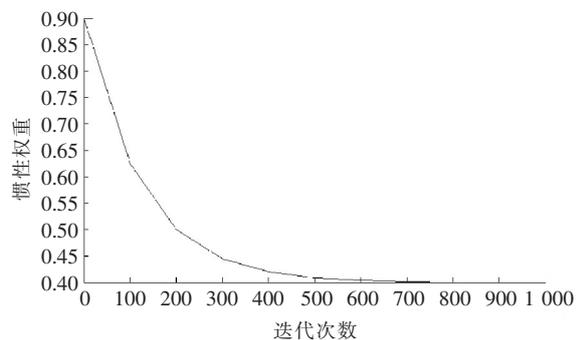


图 2 惯性权重变化曲线图

Fig.2 Diagram of change of inertia weight

$$f = \frac{1}{N} \sum_{n=1}^N (Y_n - \hat{Y}_n)^2, \quad (8)$$

式中: $Y_n$  是第  $n$  个输出值; $\hat{Y}_n$  是第  $n$  个训练样本的实际值; $N$  为样本容量。改进的 PSO-RBF 神经网络的操作流程如下。

步骤 1:将 RBF 神经网络的 3 个参数中心值、宽度和连接权值,顺序组合成 PSO 算法中的粒子向量<sup>[21]</sup>,并初始化种群,包括种群个数和种群迭代次数。

步骤 2:按照式(8)计算粒子的适应度值。

步骤 3:更新粒子的个体极值  $p_i$ 。找到粒子自身搜寻过程中适应度值最小的位置作为个体极值,下一步搜索之前,对比本次适应度值与之前个体极值的适应度值,选择适应度值更小的粒子位置作为新的个体极值。

步骤 4:更新种群的全局极值  $p_g$ 。比较搜寻空间所有粒子个体极值的适应度值,选择适应度值最小的个体极值作为全局极值,下一步搜索前,比较当前全局极值与之前全局极值的适应度值,选择适应度值小的作为新的全局极值。

步骤 5:更新粒子的位置和速度。根据更新公式对粒子的位置和速度进行更新。

步骤 6:判断结束条件,根据设置的结束条件判断是否结束迭代,若满足则进入下一步,否则返回步骤 2,重新进行迭代。

步骤 7:记录找到的全局极值,结束 PSO 算法。

步骤 8:利用全局极值构建 RBF 神经网络,并训练网络。

利用改进的 PSO 算法优化 RBF 神经网络的基本框架图见图 3。

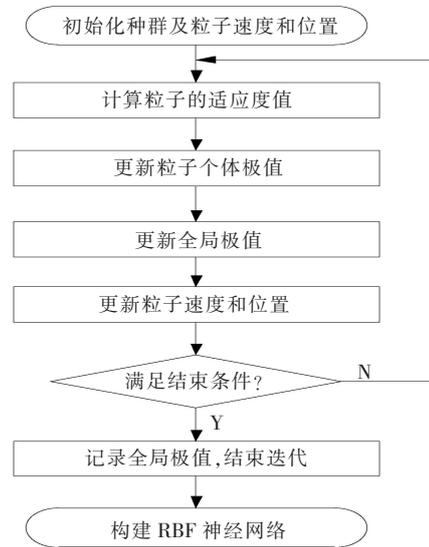


图 3 改进的 PSO-RBF 神经网络基本框架图

Fig.3 Basic frame diagram of improved PSO-RBF

## 2 仿真试验研究

从某联碱厂采集与碳化过程相关的 800 组数据,将这些数据作为样本数据用作 RBF 神经网络的学习和训练,之后再取 50 组数据作为测试样本对神经网络学习的结果进行测试,利用 Matlab 仿真软件进行仿真实验。按照式(9)对数据进行归一化处理,归一化到 $[0,1]$ 区间:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, \quad (9)$$

式中: $x_i$  为直接采集的数据; $x_{\min}$  为采集数据的最小值; $x_{\max}$  为采集数据的最大值; $x'_i$  为经过归一化处理后的数据。

为了得到颗粒较大的碳酸氢钠结晶体,使晶核的生成速度与成长速度相适应,通过长期的数据统计和生产经验发现 3 个因素对碳化反应影响较大,分别是:碳化塔中部的温度、塔中上部与塔中部温度差以及塔内液位。在实际操作时,碳化塔中部的温度一般通过调节下段气流量进行控制。因此,塔中部温度、塔中上部与塔中部温度差以及塔内液位为 RBF 神经网络的输入,下段气流量是神经网络的输出,激活函数为高斯函数。隐含层采用 7 个神经元,构成一个由 3 个输入神经元、7 个隐含层神经元、1 个输出神经元组成的 3-7-1 结构的神经网络。

为了更准确地评估模型的性能,采用以下 3 种误差公式作为评价指标,分别是平均绝对误差(mean absolute error, MAE)、平均相对误差(mean relative error, MRE)和均方误差(mean squared error, MSE)。

$$MAE = \frac{1}{N} \sum_{i=1}^N |d_i - y_i|, \quad (10)$$

$$MRE = \frac{1}{N} \sum_{i=1}^N \left| \frac{d_i - y_i}{y_i} \right| \times 100\%, \tag{11}$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (d_i - y_i)^2, \tag{12}$$

式中:  $d_i$  和  $y_i$  分别为网络输出值和实际值。

神经网络的中心值  $c_j$ 、宽度  $\sigma_j$  和连接权值  $\omega_j$  构成每一个粒子的位置向量,  $\mathbf{X}_k = (c_{j1}, \sigma_j, \omega_j), i=1, 2, 3, j=1, 2, 3, 4, 5, 6, 7$ 。维度  $D = 3 \times 7 + 7 + 7 = 35$ 。所以, 种群中的第  $k$  个粒子的位置矢量记为  $\mathbf{X}_k = [x_k^1, \dots, x_k^7, x_k^8, \dots, x_k^{14}, x_k^{15}, \dots, x_k^{21}]^T$ , 其中  $x_k^1$  至  $x_k^7$  分别表示 7 个隐含层的中心值  $c_j (j=1, 2, \dots, 7)$ ,  $x_k^8$  至  $x_k^{14}$  分别表示 7 个隐含层的宽度  $\sigma_j (j=1, 2, \dots, 7)$ ,  $x_k^{15}$  至  $x_k^{21}$  分别表示 7 个对应的输出权值  $\omega_j (j=1, 2, \dots, 7)$ 。与这组位置矢量对应的速度矢量为  $\mathbf{V}_k = [v_k^1, \dots, v_k^7, v_k^8, \dots, v_k^{14}, v_k^{15}, \dots, v_k^{21}]^T$ 。对粒子的位置和速度进行初始化至  $[-1, 1]$ , 设置最大迭代次数  $T$  为 1 000, 利用样本数据对网络进行训练, 以均方误差作为适应度函数, 获得适应度函数最小值与迭代次数的关系曲线。如图 4 所示, 优化后 RBF 神经网络适应度函数最小值较小, 并且收敛速度也较快。

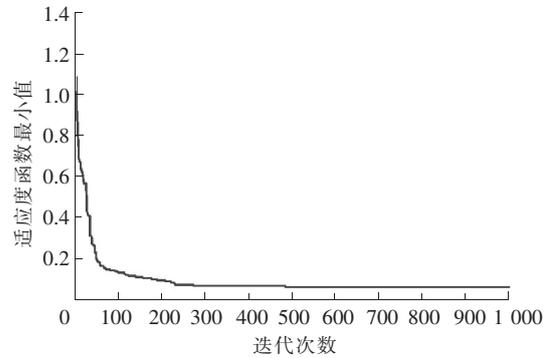


图 4 改进的 PSO-RBF 适应度函数曲线

Fig.4 Fitness function curve of improved PSO-RBF

有学者把模糊神经网络控制算法应用到联合制碱碳化过程中, 并取得了很不错的控制效果<sup>[22]</sup>。为此本文将改进的 PSO-RBF 神经网络控制算法与模糊神经网络控制算法进行对比, 通过仿真实验研究, 验证改进的 PSO-RBF 神经网络控制算法在碳化过程的控制性能优越性。图 5 是用 PSO-RBF 神经网络控制算法和模糊神经网络控制算法对下段气流量建模的仿真结果与实际值的对比图。图 6、图 7 是通过改进的 PSO-RBF 神经网络控制算法和模糊神经网络控制算法得到测试结果的绝对误差对比图和相对误差对比图。

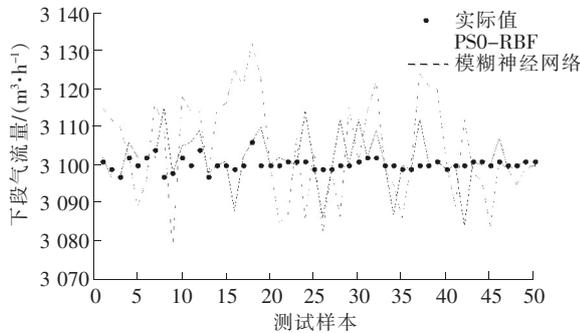


图 5 仿真结果与实际值的对比图

Fig.5 Comparison chart of simulation results and actual value

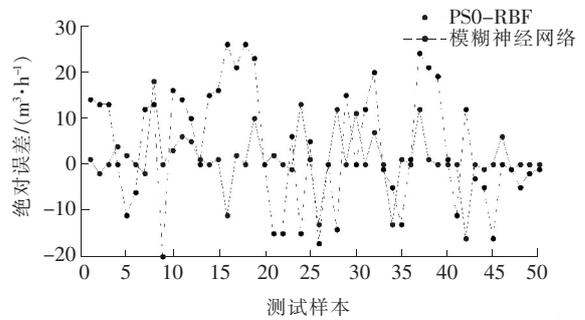


图 6 绝对误差对比图

Fig.6 Absolute error contrast chart

通过式(10)、式(11)和式(12)对仿真数据和实际数据进行计算, 把它们在网络性能进行对比, 其结果如表 1 所示。

表 1 网络性能对比

Tab.1 Network performance comparison

网络	MAE 值	MRE 值	MSE 值
改进 PSO-RBF 神经网络	3.58	0.12%	38.34
模糊神经网络	10.86	0.35%	178.18

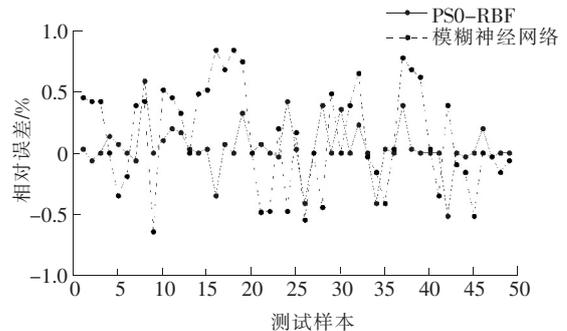


图 7 相对误差对比图

Fig.7 Relative error contrast chart

通过比较这些性能指标可以看出,改进的 PSO-RBF 神经网络算法,MAE 值,MRE 值和 MSE 值均小于模糊神经网络算法的相应值,说明改进的粒子群优化的 RBF 神经网络算法使系统的控制精度和鲁棒性得到有效提高,在联合制碱碳化过程中应用改进的 PSO-RBF 神经网络控制算法是可行和有效的。

### 3 结 语

为了解决联合制碱复杂工业过程控制精度和鲁棒性问题,在 RBF 神经网络的基础上,引进粒子群优化算法,将粒子群优化算法和 RBF 神经网络相结合,提出了一种改进的 PSO-RBF 神经网络控制算法,利用改进的粒子群优化算法对 RBF 神经网络的隐含层基函数中心、宽度和输出层的权值进行寻优,构建改进的 PSO-RBF 神经网络模型,应用到联合制碱的关键工序碳化过程中,并与先前已应用的模糊神经网络控制模型进行比较,经 Matlab 仿真实验研究,验证了在联合制碱碳化过程中应用改进的 PSO-RBF 神经网络控制算法具有可行性和有效性。这种控制方法克服了由于参数选取不当而导致神经网络收敛性差的缺点,改进了模型的收敛速度和精度,提高了系统的控制精度和鲁棒性,同时为解决一类复杂工业过程的建模与优化控制方法研究提供一条有效的技术途径。由于用改进的 PSO 优化 RBF 神经网络模型,使 RBF 神经网络具有收敛速度快和泛优能力强等特点,在复杂工业过程控制领域广泛应用的同时,可尝试在趋势预测以及故障诊断等领域应用。

### 参考文献/References:

- [1] 叶青. 联合制碱工程在中国[J]. 工程研究-跨学科视野中的工程, 2009, 1(4): 368-379.  
YE Qing. Hou's process for soda manufacture in China [J]. Journal of Engineering Studies, 2009, 1(4): 368-379.
- [2] 任培兵, 田玉珠. 新型变换气制碱技术在联碱行业的应用[J]. 河北化工, 2000, 23(4): 34-35.  
REN Peibing, TIAN Yuzhu. Use of a new type of soda manufacture process with shift conversion gas in integrated soda plants[J]. Hebei Chemical Engineering and Industry, 2000, 23(4): 34-35.
- [3] 魏正全. 变换气制碱外冷碳化塔串塔清洗[J]. 纯碱工业, 2014(3): 25-27.
- [4] 冉海潮, 李永伟, 薛增涛. 联合制碱过程的自动控制系统[J]. 河北科技大学学报, 2003, 24(1): 43-47.  
RAN Haichao, LI Yongwei, XUE Zengtao. The automatic control system for the process of the synthetic ammonia decarbonization[J]. Journal of Hebei University of Science and Technology, 2003, 24(1): 43-47.
- [5] 钟甲. 基于粒子滤波的联合制碱工业工程建模与控制[D]. 石家庄: 河北科技大学, 2011.  
ZHONG Jia. Modeling and Control of Synthetic Ammonia Based on Particle Filter[D]. Shijiazhuang: Hebei University of Science and Technology, 2011.
- [6] 张志海. 先进控制系统在纯碱生产碳化装置的应用[J]. 仪器仪表用户, 2017, 24(2): 39-41.  
ZHANG Zhihai. The application of advanced control system of soda ash production carbonization device [J]. Instrumentation, 2017, 24(2): 39-41.
- [7] 张玉润, 吴明光, 陈瑞峰, 等. 纯碱生产碳化过程的国产 DCS 控制[J]. 化工进展, 1997, 16(5): 49-52.  
ZHANG Yurun, WU Mingguang, CHEN Ruifeng, et al. National distributed control system for carbonification process of soda ash manufacturing[J]. Chemical Industry and Engineering Progress, 1997, 16(5): 49-52.
- [8] 王书海, 冉海潮, 孙丽华, 等. 基于 DCS 的联合制碱过程控制系统[J]. 仪器仪表学报, 2002, 23(3): 354-356.  
WANG Shuhai, RAN Haichao, SUN Lihua, et al. The process control system based on the DCS for the synthetic ammonia decarbonization[J]. Chinese Journal of Science Instrument, 2002, 23(3): 354-356.
- [9] 谭贤成, 张玉润. 模糊控制在联碱碳化过程中的应用研究[J]. 石油化工自动化, 2001, 37(4): 20-22.  
TAN Xiancheng, ZHANG Yurun. Application of fuzzy control in carbonization of Hou's process [J]. Automation in Petro-chemical Industry, 2001, 37(4): 20-22.
- [10] LI Yongwei, LI Wei, YU Guoqing, et al. Applied research in fuzzy neural network predictive control[C]//The 6th IEEE International Conference on Cognitive Informatics. CA:IEEE Computer Society, 2007:408-410.
- [11] 陈金辉, 赵雷振, 杨宗宵, 等. 改进的 BP 神经网络在故障诊断中的应用[J]. 河北科技大学学报, 2011, 32(5): 455-459.  
CHEN Jinhui, ZHAO Leizhen, YANG Zongxiao, et al. Application of improved BP neural network in fault diagnosis[J]. Journal of Hebei University of Science and Technology, 2011, 32(5): 455-459.

- [12] 张成军, 阴妍, 鲍久圣, 等. 多源信息融合故障诊断方法研究进展[J]. 河北科技大学学报, 2014, 35(3): 213-221.  
ZHANG Chengjun, YIN Yan, BAO Jiusheng, et al. Research progress in fault diagnosis methods based on multi-source information fusion[J]. Journal of Hebei University of Science and Technology, 2014, 35(3): 213-221.
- [13] 谢东, 张兴, 曹仁贤. 基于小波变换与神经网络的孤岛检测技术[J]. 中国电机工程学报, 2014, 34(4): 537-544.  
XIE Dong, ZHANG Xing, CAO Renxian. Islanding detection based on wavelet transform and neural network[J]. Proceedings of CSEE, 2014, 34(4): 537-544.
- [14] 李晶, 钟甲, 李永伟. 基于RBF神经网络的复杂系统的建模与优化[J]. 河北省科学院学报, 2010, 27(1): 1-4.  
LI Jing, ZHONG Jia, LI Yongwei. Modeling and optimization of complex systems based on RBF neural network[J]. Journal of the Hebei Academy of Sciences, 2010, 27(1): 1-4.
- [15] MAN C T, LI X X, ZHANG L Y. Radial basis function neural network based on ant colony optimization[J]. The International Conference on Computational Intelligence and Security Workshops, 2007:59-62.
- [16] 皮倩瑛, 叶洪涛. 一种动态调节惯性权重的粒子群算法[J]. 广西科技大学学报, 2016, 27(3): 26-32.  
PI Qianying, YE Hongtao. Particle swarm optimization algorithm for dynamic adjustment of inertia weight[J]. Journal of Guangxi University of Science and Technology, 2016, 27(3): 26-32.
- [17] MELO H, WATADA J. Gaussian-PSO with fuzzy reasoning based on structural learning for training a neural network[J]. Neurocomputing, 2016, 172: 405-412.
- [18] 张水平, 仲伟彪. 改进学习因子和约束因子的混合粒子群算法[J]. 计算机应用研究, 2015, 32(12): 3626-3653.  
ZHANG Shuiping, ZHONG Weibiao. Hybrid particle swarm optimization algorithm of new learning factor and constraint factor [J]. Application Research of Computers, 2015, 32(12): 3626-3653.
- [19] NIU D X, HUA F Y, LI B J, et al. Research on neural network prediction of power transmission and transformation project cost based on GA-RBF and PSO-RBF[J]. Applied Mechanics and Materials, 2014 (644): 2526-2531.
- [20] 卢金娜. 基于优化算法的径向神经网络模型的改进及应用[D]. 太原: 中北大学, 2015.  
LU Jinna. Research on the Improvement of RBF Neural Network Based on Optimization Algorithm and Its Applications[D]. Taiyuan: North University of China, 2015.
- [21] 张志宇, 赵丹国, 侯晓宇. PSO-RBF神经网络在城市需水量预测中的应用[J]. 水电能源科学, 2013, 31(6): 55-57.  
ZHANG Zhiyu, ZHAO Danguo, HOU Xiaoyu. Application of PSO-RBF neural network in urban water demand prediction [J]. Water Resources and Power, 2013, 31(6): 55-57.
- [22] 李景林. 联合制碱过程的自动控制系统研究[J]. 纯碱工业, 2014(6): 27-29.