

DOI: 10.12096/j.2096-4528.pgt.19102

基于遗传算法优化 BP 神经网络的 SCR 脱硝系统催化剂体积设计

唐诗洁¹, 陆强¹, 曲艳超², 任翠涛², 杨勇平¹

(1. 生物质发电成套设备国家工程实验室(华北电力大学), 北京市 昌平区 102206;
2. 北京华电光大环境股份有限公司, 北京市 昌平区 102206)

Catalyst Volume Design in SCR Denitrification System Based on Genetic Algorithm Optimized BP Neural Network

TANG Shijie¹, LU Qiang¹, QU Yanchao², REN Cuitao², YANG Yongping¹

(1. National Engineering Laboratory for Biomass Power Generation Equipment, North China Electric Power University, Changping District, Beijing 102206, China; 2. Beijing National Power Group Co., Ltd., Changping District, Beijing 102206, China)

摘要: 火电厂 SCR 脱硝系统的设计需要在满足脱硝效率的同时, 尽可能节约成本, 因此需要准确预测 SCR 脱硝所需的催化剂体积。火电厂的烟气条件复杂多变, 烟气温度、烟气流量、出入口 NO_x 浓度等参数都会影响 SCR 催化剂的体积设计, 因此催化剂体积预测是一个多因素耦合的问题。针对这一特点, 使用 BP 神经网络对催化剂体积设计进行了预测, 并针对该模型结构上的缺陷, 进行基于遗传算法优化的神经网络建模研究。结果表明, 遗传算法优化后的 BP 神经网络模型预测精度和数据拟合能力均有提高, 为脱硝系统的催化剂体积设计提供了新思路。

关键词: SCR 催化剂; 催化剂体积预测; BP 神经网络; 遗传算法

ABSTRACT: The design of the SCR denitrification system in coal-fired power plants requires the efficient denitrification efficiency and the low cost. Hence, it is essential to accurately calculate the volume of SCR denitrification catalysts. The flue gas conditions of thermal power plants are complex and changeable. Flue gas temperature, flue gas flow, inlet and outlet NO_x concentrations, and other parameters all affect the volume of the SCR catalyst.

基金项目: 国家重点基础研究发展计划项目(2015CB251501); 北京市科技新星(Z171100001117064); 中央高校基本科研业务专项资金(2018ZD08, 2016YQ05)。

National Basic Research Program of China(2015CB251501); Beijing Nova Program (Z171100001117064); Fundamental Research Funds for the Central Universities (2018ZD08, 2016YQ05).

Therefore, catalyst volume prediction is a multi-factor coupling problem. For this feature, the BP neural network model was used to predict the volume design of the catalyst, and the neural network modeling based on genetic algorithm optimization was investigated for the structural defects of the BP neural network model. The results show that the prediction accuracy of BP neural network model optimized by genetic algorithm is promising, which provides a new way for catalyst volume design of SCR denitrification.

KEY WORDS: SCR catalyst; catalyst volume prediction; BP neural network; genetic algorithm

0 引言

随着电力需求的不断增长, 电力生产带来的环境污染尤其是大气污染问题日益严重, 其中 NO_x 排放已成为一个亟待解决的问题^[1-2]。选择性催化还原法(SCR)是国际上应用最广、最为成熟的火电厂 NO_x 排放控制技术^[3]。其中, SCR 催化剂是脱硝系统的关键与核心, 其成本费用占总投资费用的 20% 以上^[4-5]。因此, 合理的催化剂体积设计方案对电厂的经济安全运行具有重要意义。

SCR 催化剂体积设计与电厂烟气条件密切相关。张帅夫等人^[6]研究了烟气条件对电厂 SCR 催化剂设计的影响, 结果表明, 烟气温度、烟气流量、入口 NO_x 浓度等是决定催化剂体积的主要

因素。李鑫等人^[7]基于 AVL BOOST 软件建立了 SCR 催化剂模型,对柴油机 SCR 催化剂的尺寸进行仿真和优化设计。目前,行业中尚未确定准确的催化剂体积计算公式,大多情况下仍使用经验公式计算^[8]。但由于影响催化剂体积的参数众多,每增加一个影响参数便会很大程度上提高其公式的复杂性,从而降低计算准确性。

BP 神经网络模型具有良好的非线性自学能力和归纳能力,可以把寻找数值关系的复杂任务交给计算机,尤其适合处理多因素耦合的信息。因此,本文以 SCR 催化剂实际数据和相应烟气参数为基础,建立了 BP 神经网络预测 SCR 催化剂体积模型,并使用遗传算法(genetic algorithm, GA)优化该模型结构上的缺陷,探索预测 SCR 脱硝催化剂体积的更好方法。

1 BP 神经网络预测模型

1.1 BP 神经网络简介

人工神经网络是由大量简单的神经元组成的非线性动力学系统和信息处理系统^[9]。人工神经网络中的神经元以某种方式彼此互联,与生物神经网络相似,具有学习、记忆、归纳和自学能力。在众多的人工神经网络模型中,按照误差逆传播算法训练的 BP 神经网络模型,已被广泛用于数据预测领域^[10-11]。BP 神经网络是一种多层前馈神经网络,通常其拓扑结构由单层的输入层、输出层和隐含层所构成。BP 神经网络的隐含层根据需要可以有一层或多层,而每一层都由若干个神经元组成。图 1 为典型的 BP 网络的结构图,图中 x 代表输入数据, a 、 c 代表阈值, w 、 v 代表

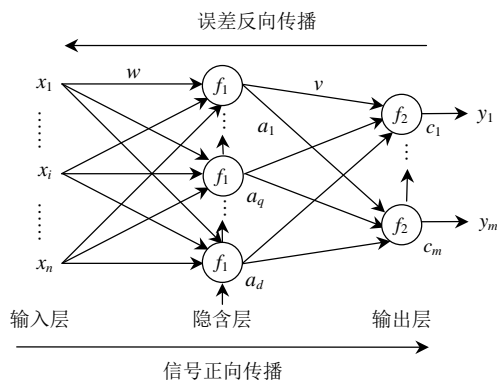


图 1 BP 神经网络结构图

Fig. 1 BP neural network structure diagram

权值, y 表示网络输出结果, f 表示激励函数。

1.2 BP 神经网络原理

BP 神经网络需要通过输入和输出样本对网络进行训练,即通过学习和修正网络的阈值和权值,并不断重复该过程,最终得到符合条件的输入或输出。BP 神经网络算法由信号的正向传播(前向计算过程)和误差的反向传播 2 个阶段组成。具体过程^[12]如下:

1) 信号的正向传播。输入量由输入层经过隐含层逐层计算,并传向网络的输出层。计算中每一层的神经元状态只会影响下一层的神经元状态,网络的权值在信号正向传播过程中固定不变。如果输出层不能得到符合其期望的输出,则转入误差反向传播过程。

2) 误差的反向传播。由前向计算过程得出的网络输出与期望输出之间的差值即为误差。误差信号由网络的输出端开始,沿网络的连接路线返回并计算各权值和阈值对总误差的影响。最后根据误差梯度下降法对权值和阈值进行调整。

这 2 个过程依次反复进行,当网络误差最小或达到设定的要求时,学习过程结束^[13-14]。

2 遗传算法优化 BP 神经网络

虽然 BP 神经网络因具有易于实现任何复杂非线性映射功能的特点而极大地提高了催化剂寿命预测精度,但是 BP 神经网络预测模型有两大缺陷:一是模型训练前 BP 网络连接权重的随机初始赋值,易使其收敛速度变慢且易陷入局部极值点;二是 BP 神经网络结构规模难以确定,尚无统一而完整的理论指导,一般只能根据经验选定,如果网络结构设置不当,就会导致训练发生“过拟合”及学习能力不足现象^[15]。针对以上问题,本文提出了遗传算法优化 BP 神经网络的 SCR 催化剂体积预测方法,以弥补 BP 神经网络缺陷,提高其学习能力及预测精度。

2.1 遗传算法

遗传算法是一种模拟生物在自然界中的遗传机制和进化过程而形成的自适应全局搜索最优解的算法。遗传算法将优化参数编码成基因组成染色体,然后通过模拟自然界的选择和遗传过程,利

用选择算子、交叉算子、变异算子来变换染色体携带的信息,经过多次重复的操作产生能够代表优化函数所需的染色体^[16]。

2.2 基于遗传算法优化的 BP 神经网络(GABP)

遗传算法主要针对 BP 神经网络的初始阈值和权值进行优化,降低网络限于局部最优解的风险,使网络一开始就在较优的搜索集合内进行,进一步提高了 BP 神经网络的稳定性。遗传算法优化 BP 神经网络的流程主要包括 BP 神经网络连接结构的确定、遗传算法优化 BP 神经网络权值和阈值、BP 神经网络预测 3 个部分^[17],算法流程如图 2 所示。

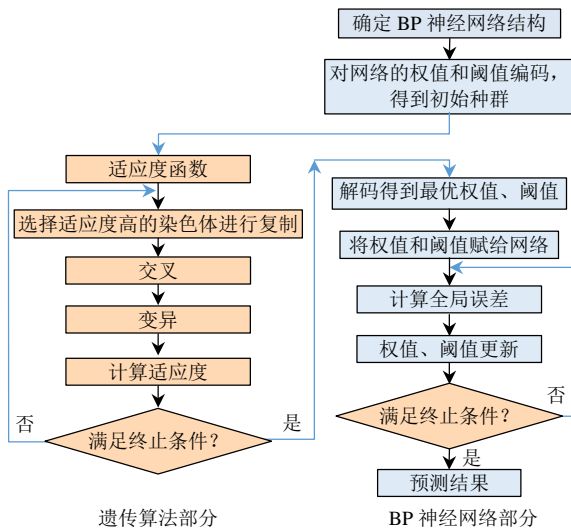


图 2 遗传算法优化 BP 神经网络流程图

Fig. 2 The flow chart of genetic algorithms optimized BP neural network

3 预测模型与结果分析

3.1 BP 神经网络预测模型

3.1.1 BP 神经网络结构设计

1) 输入和输出变量。

电厂 SCR 催化剂是在一个在多因素耦合且复杂的烟气环境中工作,电厂的烟气量、喷氨量、运行时间、运行温度及煤种等都会影响 SCR 催化剂的活性。为了建立简洁、有效的 BP 神经网络模型,需要选出与 SCR 催化剂体积具有明显因果关系的数据作为网络的输入变量。

本文选取 48 份从不同工作环境得到的 SCR 催化剂运行数据作为设计网络所用训练样本和预测样本。原始数据中包括了烟气量、NO_x 进口浓

度、NO_x 出口浓度、温度、灰分浓度、氨逃逸浓度、24 000 h 后的催化剂活性、氨氮比、催化剂比表面积、催化剂脱硝效率和公式修正系数,共 11 个参数。由于脱硝效率与 NO_x 进、出口浓度所反映信息重叠,公式修正系数不会影响催化剂体积量,所以在选择网络输入信息时舍弃这两个变量。因此,最终保留 9 个参数作为神经网络的输入变量并进行归一化处理。网络的输出变量为 SCR 催化剂体积。

为加快程序运行时的收敛速度,确保所有数据信息可以有效影响催化剂体积计算结果,在选定网络输入参数后需要对数据进行统一的归一化处理^[18]。利用 Matlab 软件中的 mapminmax 函数将数据全部归一化到 0~1。计算公式为

$$y = (y_{\max} - y_{\min}) \times (x - x_{\min}) / (x_{\max} - x_{\min}) + y_{\min} \quad (1)$$

式中: y_{\max} 和 y_{\min} 为设定参数,分别设定为 1 和 0; x 为要归一化的数据; x_{\max} 和 x_{\min} 分别为归一化数据中的最大值和最小值。

2) 训练和测试样本。

原始样本数据有 48 组,选择 1~45 组作为训练样本,46~48 组作为测试样本。表 1 为部分训练样本数据。

3) 隐含层神经元个数。

相比于增加隐含层数,增加隐含层神经元个数可以快捷有效地提高网络的训练精度。目前,对于隐含层神经元个数的选择还没有明确的规定。隐含层神经元个数 n 一般需要先根据前人设计所得的经验公式确定大致范围后,再通过试验不同隐含层神经元个数时的训练结果,最终选择预测误差最小时的隐含层神经元个数和网络结构。研究总结的经验公式如下:

$$n = \sqrt{m + d} + v \quad (2)$$

式中: m 为输入层神经元个数; d 为输出层神经元个数; v 为常数且 $1 < v < 10$ 。

由于输入数据为 9 个变量,输出数据为催化剂体积 1 个变量,通过式(2)计算后,隐含层神经元个数应为 $4+v$ 个。将式(2)中的训练样本和预测样本数据输入 BP 网络,分别计算不同隐含层神经元个数时预测的平均误差,如图 3 所示。对比发现,当隐含层神经元个数为 4 时,平均误差最

表 1 部分训练样本数据
Tab.1 Part of the training sample data

序号	烟气量/ (Nm ³ /h)	进口 NO _x 浓 度/(mg/Nm ³)	出口 NO _x 浓 度/(mg/Nm ³)	温度/°C	灰分浓度/ (g/Nm ³)	氨逃逸浓度/ (mg/Nm ³)	24 000 h 后活性	氨氮比	催化剂 比表面积	催化剂 体积/m ³
1	270 000	135	100	350	24.6	6.07	28.05	0.27	276	26.27
2	140 000	140	100	350	24.6	6.07	28.05	0.33	276	15.57
3	454 274	140	64	350	16	2.50	32.30	0.56	288	75.23
4	431 651	140	60	350	16	2.50	30.60	0.59	276	80.84
5	197 986	168	60	359	30	7.59	28.05	0.70	316	31.01
6	1 191 600	400	80	365	62	2.50	28.05	0.81	276	388.67
7	847 020	450	88	370	35	2.28	28.90	0.81	276	280.36
8	1 239 689	600	200	385	50	2.28	28.05	0.67	276	412.33
9	1 106 790	650	100	353	65	2.28	28.05	0.85	276	439.07
10	1 100 000	700	150	387	41	1.90	28.05	0.79	316	377.72
11	252 500	400	50	350	36	2.28	28.05	0.89	316	79.68
12	672 775	600	90	348	70	2.28	28.05	0.85	276	260.82
13	735 469	600	90	350	47.9	2.28	28.05	0.85	276	285.12
14	1 170 000	850	90	396	40	2.28	28.05	0.90	282	519.11
15	474 807	400	50	360	25	2.28	28.05	0.88	316	148.87
16	560 000	700	50	360	30	2.28	28.05	0.93	316	220.56
17	350 000	200	80	350	40	2.28	28.05	0.61	294	76.97
18	206 899	300	100	340	45	3.95	28.05	0.68	276	51.40
19	1 300 000	600	100	370	42	2.28	28.05	0.84	276	26.27
20	65 629.4	1 000	100	350	1	2.28	28.05	0.90	276	15.57

小，计算结果更为准确。故 BP 网络的拓扑结构设置为 9-4-1。




图 3 BP 网络不同隐含层神经元个数时预测的平均误差
Fig. 3 BP network prediction errors produced by the different number of hidden layers neurons

4) 设定训练参数。

因为样本数据较少，故选择适合中小型网络的 L-M 算法对网络进行训练，即选择 trainlm 函数。其余参数设置如表 2 所示。

表 2 BP 神经网络参数设置

Tab.2 BP neural network parameter setting

参数名称	参数设置
隐含层激励函数	tansig
输出层激励函数	purelin
学习迭代次数	2 000
网络学习精度	0.000 01

3.1.2 BP 神经网络预测结果

根据创建的 BP 网络，对 3 个预测样本进行仿真测试及误差检验。其中，3 个预测样本的输入参数如表 3 所示，BP 网络预测结果如表 4 所示。以相对误差(E_r)、平均相对误差(E_{MRE})、均方根误差(E_{RMSE})、相关系数平方 R^2 作为最终评价指标：

$$E_r = \frac{T - T_{pre}}{T} \times 100\% \quad (3)$$

$$E_{MRE} = \sum_{i=1}^n E_r / n \quad (4)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \times \sum_{i=1}^n \left(\frac{T - T_{pre}}{T} \right)^2} \quad (5)$$

表 3 预测样本输入参数

Tab. 3 Prediction sample input parameters

烟气量/ (Nm ³ /h)	进口 NO _x 浓度/ (mg/Nm ³)	出口 NO _x 浓度/ (mg/Nm ³)	温度/℃	灰分浓度/ (g/Nm ³)	氨逃逸浓度/ (mg/Nm ³)	24 000 h 后活性	氨氮比	催化剂比 表面积
2 099 165	380	57	386	72	2.28	29.16	0.86	284
750 000	350	70	360	40	2.28	34	0.81	276
1 169 150	100	40	385	70	2.28	30.6	0.62	276

表 4 BP 神经网络预测值及误差

Tab. 4 Prediction values and errors of BP neural network

催化剂体积真实值/m ³	BP 神经网络预测值/m ³	预测值相对误差/%	预测值平均相对误差/%	均方根误差/%	相关系数平方 R ²
675.13	705.032 0	4.429 1			
197.96	195.506 7	1.239 3	3.315 5	3.626 5	0.999 8
211	201.973 0	4.278 2			

$$R^2 = \frac{\sum_{i=1}^y T^2}{\sum_{i=1}^y T^2 - \sum_{i=1}^y (T - T_{\text{pre}})^2} \quad (6)$$

式中： T 为催化剂体积的真实值； T_{pre} 为催化剂体积的预测值； y 为预测样本个数。

将训练样本输入到神经网络中，利用表 2 中的网络设置对其进行训练，最终可得， $E_{\text{MRE}}=3.315 5\%$ ， $R_2=0.999 8$ ， $E_{\text{RMSE}}=3.626 5\%$ 。预测效果较好，可以利用该方法对催化剂体积进行预测。

3.2 GABP 神经网络预测模型

3.2.1 遗传算法参数的确定

在使用 GABP 神经网络模型进行预测时，需要确定种群初始化、适应度函数、选择、交叉以及变异算子等参数^[19]。

1) 种群初始化。

GABP 神经网络的训练样本、预测样本与 BP 神经网络一样。前文中 BP 神经网络程序调试的结果中，将隐含层神经元个数设定为 4 个，但在遗传算法优化后有所调整。根据经验公式分别计算不同隐含层神经元个数时预测的平均误差，如图 4 所示。当隐含层神经元个数为 6 时，平均相对误差最小。因此，设置 GABP 网络的拓扑结构为 9-6-1。

2) 适应度函数的选择。

本文选择测试样本的期望值与预测值的均方差加 1 的倒数作为目标函数，此数值越大，均方差越小，网络的预测精度越高。

(1) 选择算子。采用轮盘赌法选择新算子。




图 4 GABP 网络不同隐含层神经元个数时预测的误差
Fig. 4 GABP network prediction mean errors produced by the different number of hidden layers neurons

其基本思想是：各个个体被选中的概率与其适应度大小成正比。

(2) 交叉算子。选择简单的单点交叉方式，交叉概率值设定为 0.9。

(3) 变异算子。选择较小的概率随机产生变异，设置变异概率为 0.1。

遗传算法优化 BP 神经网络的各个参数选择如表 5 所示。

表 5 GABP 神经网络参数设置

Tab. 5 GABP neural network parameter setting

参数名称	参数设置
隐含层激励函数	tansig
输出层激励函数	purelin
学习迭代次数	500
网络学习精度	0.001
进化代数	40
种群规模	10
交叉概率	0.9
变异概率	0.1

3.2.2 GABP 预测结果

使用遗传算法对 BP 神经网络初始权值阈值进行优化后, 对 3 个预测样本进行仿真测试及误差检验, 预测结果如表 6 所示。

表 6 GABP 神经网络预测值及误差
Tab. 6 Prediction values and errors of GABP neural network

催化剂 体积真 实值/m ³	BP 神经 网络预 测值/m ³	预测值 相对误 差/%	预测值 平均相对 误差/%	均方根 误差/%	相关系 数平方 值 R ²
675.13	685.280 8	1.503 5			
197.96	205.241 1	3.678 1	2.145 3	2.405 7	0.999 7
211.00	208.353 5	1.254 3			

3.3 预测结果汇总

GABP 神经网络与 BP 神经网络的预测结果和误差对比如表 7、8 所示, BP 神经网络、GABP 神经网络预测结果与 SCR 催化剂体积的真实值对比如图 5 所示。

由表 7、8 和图 5 可以看出, 单一的 BP 神经网络模型预测的最大和最小相对误差分别为 4.429 1% 和 1.239 3%; GABP 神经网络模型预测值的最大和最小相对误差分别为 3.678 1% 和 1.254 3%。通过对比可知, 使用遗传算法优化后, 3 个测试样本的预测值比传统的 BP 神经网络模型更接近真实值, 预测平均相对误差从 3.315 5% 减少到 2.145 3%, 均方根误差从 3.626 5% 减少到 2.405 7%。此外, 遗传算法优化后 BP 神经网络的

表 7 BP 神经网络与 GABP 神经网络预测结果对比
Tab. 7 Comparison between BP neural network and GABP neural network prediction results

催化剂体积 真实值/m ³	BP 神经网络		GABP 神经网络	
	预测值/m ³	预测误差/%	预测值/m ³	预测误差/%
675.13	705.032 0	4.429 1	685.280 8	1.503 5
197.96	195.506 7	1.239 3	205.241 1	3.678 1
211.00	201.973 0	4.278 2	208.353 5	1.254 3

表 8 BP 神经网络与 GABP 神经网络预测误差对比
Tab. 8 Error comparison between BP neural network and GABP neural network prediction results

参数	BP 神经网络	GABP 神经网络
R ²	0.999 8	0.999 7
E _{MRE} /%	3.315 5	2.145 3
E _{RMSE} /%	3.626 5	2.405 7

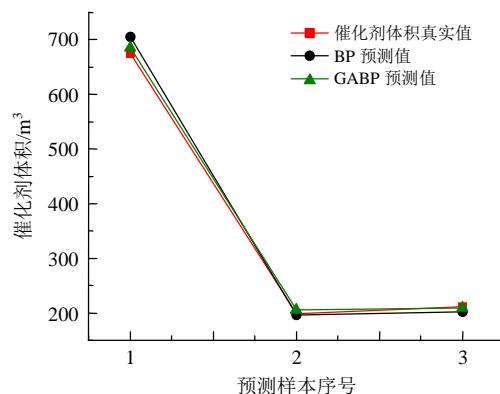


图 5 BP、GABP 神经网络预测结果与真实值的对比
Fig. 5 Comparison of real values with BP network and GABP network predictions

学习迭代次数由优化前的 2000 次降低到 500 次, 大大提高了网络的学习效率。因此, 将 GABP 用于 SCR 脱硝催化剂体积预测是可行的。

4 结论

通过建立 BP 神经网络模型来预测火电厂 SCR 脱硝催化剂使用体积, 并通过遗传算法优化 BP 神经网络的权值和阈值, 克服了 BP 神经网络易陷入局部最优的缺陷。通过实例对比分析发现, 遗传算法优化后预测结果的平均相对误差从 3.315 5% 减少到 2.145 3%, 均方根误差从 3.626 5% 减少到 2.405 7%。基于遗传算法优化后的 BP 神经网络模型结合了两者的优势, 进一步提高了网络的学习效率和收敛速度, 预测结果更精确。

参考文献

- [1] 王雪娇, 郭家秀, 尹华强. 我国火电厂烟气脱硝技术综述[C]//2016 燃煤电厂超低排放形势下 SCR (SNCR)脱硝系统运行管理及氨逃逸与空预器堵塞技术交流研讨会, 杭州, 2016.
- [2] 王学勤, 朱文堃, 徐静静, 等. 楼宇型燃气分布式能源系统 SCR 脱硝应用研究[J]. 发电技术, 2018, 39(6): 580-584.
- [3] 喻小伟, 周瑜, 刘帅, 等. SCR 脱硝催化剂失活原因分析及再生处理[J]. 热力发电, 2014, 43(2): 109-113.
- [4] 霍秋宝, 田亮, 赵亮宇, 等. 火电机组不同脱硝方式下的运行费用分析[J]. 华北电力大学学报(自然科学版), 2012, 39(5): 87-92.
- [5] 王琦, 王树荣, 岑可法, 等. 燃煤电厂 SCR 脱硝技

- 术催化剂的特性及进展[J]. 电站系统工程, 2005, 21(5): 4-6.
- [6] 张帅夫, 张珈毓. 烟气条件对火电厂 SCR 催化剂设计的影响[C]//2012 中国环境科学学会学术年会, 南宁, 2012.
- [7] 李鑫, 宋新刚, 高子朋, 等. 基于 AVL BOOST 的柴油机 SCR 催化剂尺寸优化设计[J]. 中国航海, 2015, 38(3): 18-22.
- [8] 雷本喜, 尹海滨, 蔺海艳. 玻璃熔窑烟气 SCR 脱硝蜂窝状催化剂的选型计算[J]. 江苏建材, 2015(3): 11-13.
- [9] 胡守仁. 神经网络导论[M]. 长沙: 国防科技大学出版社, 1993: 1-10.
- [10] 韩力群. 人工神经网络教程[M]. 北京: 北京邮电大学出版社, 2006: 4-6.
- [11] 朱永利, 尹金良. 人工智能在电力系统中的应用研究与实践综述[J]. 发电技术, 2018, 39(2): 106-111.
- [12] MATLAB 技术联盟, 刘冰, 郭海霞. MATLAB 神经网络超级学习手册[M]. 北京: 人民邮电出版社, 2014: 160-161.
- [13] 于航, 刘阳, 连魏魏, 等. 一种基于神经网络的硅基光伏组件运行温度在线软测量方法[J]. 发电技术, 2018, 39(6): 566-573.
- [14] Xu L, Li Y, Xu N, et al. Soy suce cassification by gographic rgion and frmentation bsd on atificial nural ntwork and gnetic algorithm[J]. Journal of Agricultural & Food Chemistry, 2014, 62(51): 12294.
- [15] Li S, Liu L J, Zhai M. Shortterm traffic flow prediction with the improved particle swarm optimization BP neural network[J]. Systems Engineering Theory and Practice, 2012, 32(9): 2045-2049.
- [16] Holland J H. Adaptation in natural and artificial systems[M]. Cambridge: MIT Press, 1992: 126-137.
- [17] 墨蒙, 赵龙章, 龚媛雯, 等. 基于遗传算法优化的 BP 神经网络研究应用[J]. 现代电子技术, 2018, 41(9): 41-44.
- [18] 柳小桐. BP 神经网络输入层数据归一化研究[J]. 机械工程与自动化, 2010(3): 122-123, 126.
- [19] 陈明. MATLAB 神经网络原理与实例精解[M]. 北京: 清华大学出版社, 2013: 205-207.

收稿日期: 2019-01-25.

作者简介:



唐诗洁

唐诗洁(1993), 女, 硕士研究生, 研究方向为火电厂脱硝综合治理, tangsj1120@126.com;

陆强(1982), 男, 教授, 博士生导师, 主要从事固体燃料高效热利用以及烟气污染物治理方面研究工作, qiangu@ustc.

(责任编辑 辛培裕)