

Prediction of Yield Based on BP Neural Network and Fitting

Yuqing Han¹, Chunliang Li², Haitao Wang²

¹Department of Finance, School of Economics, North China University of Technology, Tangshan Hebei

²Department of Mathematics and Applied Mathematics, School of Science, North China University of Technology, Tangshan Hebei

Email: 1720778878@qq.com

Received: Nov. 20th, 2019; accepted: Dec. 3rd, 2019; published: Dec. 10th, 2019

Abstract

Deoxidation alloying in the steelmaking process is an important process link in steel smelting. In this paper, a prediction model for the carbon and manganese yield is studied and established, and the simulation optimization test is defined. The control space theorem is defined to judge the model prediction accuracy. Secondly, using BP neural network and fitting methods, the prediction models of alloy element yield in the process of deoxidizing alloying are established respectively, which shortens the learning and training time and improves the prediction accuracy of the model. The predicted values of BP neural network are both 85%. Above, the fitting prediction values are all above 82%. The results show that: 100 production times are randomly selected for simulation optimization. According to the control interval theorem, the fitting prediction accuracy rate is above 84%, and the BP neural network prediction accuracy rate is above 89%, and the BP neural network prediction model is more in line with production requirements.

Keywords

Carbon and Manganese Content, BP Neural Network, Fitting, Simulation Optimization

基于BP神经网络和拟合对收得率的预测

韩雨晴¹, 李纯良², 王海涛²

¹华北理工大学经济学院金融学专业, 河北 唐山

²华北理工大学理学院数学与应用数学专业, 河北 唐山

Email: 1720778878@qq.com

收稿日期: 2019年11月20日; 录用日期: 2019年12月3日; 发布日期: 2019年12月10日

摘要

炼钢过程中的脱氧合金化是钢铁冶炼中的重要工艺环节。本文研究建立了关于碳锰元素收得率预测模型, 仿真优化检验, 定义出控制空间定理来评判模型预测准确率。其次, 使用BP神经网络和拟合两种方法, 分别建立出脱氧合金化过程的合金元素收得率预测模型, 缩短学习训练时间, 提高模型预测精度, 得出BP神经网络预测值均在85%以上, 拟合预测值均在82%以上, 结果表明: 随机选取100炉次的生产数据进行仿真优化, 根据控制区间定理知, 拟合的预测准确率达到84%以上, BP神经网络预测准确率均在89%以上, BP神经网络预测模型更符合生产要求。

关键词

碳锰含量, BP神经网络, 拟合, 仿真优化

Copyright © 2019 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着计算机技术的发展, 国外早已研究出以合金收得率预测及成本优化算法为主体的自动配料模型, 该模型可实现自动脱氧合金化的目的。目前, 国内部分车间引进这一技术并成功应用于生产, 但总体上, 与国际先进国家相比仍有较大差距。

对于不同的钢种在熔炼结束时, 需加入不同量不同种类的合金, 以使其所含合金元素达标, 最终使得成品钢在某些物理性能上达到特定要求。随着钢铁行业中高附加值钢种产量的不断提高, 如何通过过程控制模型, 在线优化控制投入合金种类及数量, 在保证钢水质量的同时最大限度地降低合金钢的生产成本, 是各大钢铁企业提高竞争力所要解决的重要问题。向钢中加入一种或几种与氧亲和力比铁大的元素, 夺取钢中多余的氧的操作为脱氧。脱氧合金化是指在不同钢种熔炼结束后, 向钢中加入不同量、不同种类的合金, 以使其所含合金元素达标, 最终使得成品钢在某些物理性能上符合规程要求的操作。在脱氧合金化过程中, 合金元素损失的途径有: 主要为元素被钢水中的氧化物氧化以及元素残留在钢渣中而没有进入钢水。影响合金氧化程度的因素有很多, 在合金化过程中, 最重要的因素为: 钢液氧活度、渣中不稳定氧化物活度、钢渣碱度、吹氩搅拌强度、钢水温度以及钢水质量。

本文研究建立了关于碳锰元素收得率预测模型, 仿真优化检验, 定义出控制空间定理来评判模型预测准确率, 建立BP神经网络模型和拟合模型去预测碳锰元素的收得率, 得出最佳预测结果。

由于收集了大量历史炼钢数据, 可采用BP神经网络和拟合等预测方法, 对收得率进行预测, 在根据控制区间定理, 对预测出的收得率进行仿真优化检验, 使C, Mn等元素含量达到国家标准[1]。

2. 收得率预测评判标准

预测C、Mn两种元素的收得率并且使之预测准确率最大限度地提高[2]。通过阅读文献知, 需定义一个控制区间定理来评判预测准确率, 最后通过仿真实验来检验预测模型的好坏。

规定控制区间定理是指已知某合金元素含量达标范围为 $[a\%, b\%]$, 若预测出该合金元素含量在

$\left[\frac{a\% + b\%}{2} - \frac{b\% - a\%}{4}, \frac{a\% + b\%}{2} + \frac{b\% - a\%}{4} \right]$ 区间内, 则该预测值准确率达到 90% 以上, 若预测值接近于 $\frac{a\% + b\%}{2}$, 则该预测值准确率趋于 100%。

给出具体评判预测准确率方法后, 通过建立 BP 神经网络和拟合两种模型分别预测某种合金元素 i 的收得率, 根据如下公式求出某种合金元素 i 含量; 再利用控制区间定理, 来判定某种合金元素 i 含量是否达到国家标准要求。

$$\text{合金元素 } i \text{ 量} = \frac{\text{目标出钢含量 } i - \text{吹止成分 } i}{\text{元素 } i \text{ 收得率}} \times (\text{钢水净重} - \text{合金总质量})$$

2.1. BP 神经网络的 C、Mn 收得率预测模型建立

BP 神经网络是一种非线性动力系统, 包含输入层、隐含层、输出层三层单元。设输入向量为 $X = (x_1, x_2, \dots, x_n)^T$, 隐含层输出向量为 $Y = (y_1, y_2, \dots, y_m)^T$, 输出层输出向量为 $G = (g_1, g_2, \dots, g_k)^T$, 则有期望输出向量为 $D = (d_1, d_2, \dots, d_l)^T$, 输出层到隐含层之间的权值矩阵用 V 表示, $V = (v_1, v_2, \dots, v_m)$, 其中列向量 v_m 为隐含层第 m 个神经元对应的权向量, 隐含层到输出层之间的权值矩阵用 W 表示, $W = (w_1, w_2, \dots, w_i)$, 其中列向量 w_i 为输出层第 i 个神经元对应的权向量[3]。

$$\begin{cases} G_j = f(\text{net}_j), j = 1, 2, \dots, k, \text{ 输入层} \\ \text{net}_j = \sum_{i=0}^m \omega_{ij} g_i, j = 1, 2, \dots, k, \text{ 隐含层} \\ f(x) = \frac{1}{1 + e^{-x}}, \text{ 转移函数} \\ f'(x) = f(x)[1 - f(x)] \end{cases}$$

其中, 转移函数 $f(x)$ 均为单极性 Sigmoid 函数, $f(x)$ 具有连续性可导性。

网络误差的定义与权值更新[4]。当网络输出与期望输出不等时, 存在输出误差 E , 给出定义如下:

$$E = \frac{1}{2}(D - G)^2 = \frac{1}{2} \sum_{i=1}^k (d_i - g_i)^2 \tag{1}$$

将以上误差定义式展开至隐含层, 有:

$$\begin{aligned} E &= \frac{1}{2} \sum_{i=1}^k [d_i - f(\text{net}_i)]^2 \\ &= \frac{1}{2} \sum_{i=1}^k \left[d_i - f\left(\text{net}_i = \sum_{i=0}^m w_{ij} g_i\right) \right]^2 \end{aligned} \tag{2}$$

进一步展开至输入层, 有:

$$\begin{aligned} E &= \frac{1}{2} \sum_{i=1}^k \left\{ d_i - f\left[\sum_{i=0}^m w_{ij} f(\text{net}_i)\right] \right\}^2 \\ &= \frac{1}{2} \sum_{i=1}^k \left\{ d_i - f\left[\sum_{i=0}^m w_{ij} f\left(\sum_{i=0}^n v_{ij} g_i\right)\right] \right\}^2 \end{aligned} \tag{3}$$

由上式可以得出, 网络误差是各层权值 w_{ij} , v_{im} 的函数, 因此调整权值可改变误差 E 。

显然, 调整权值的原则是使误差不断地减小, 因此应使权值的调整量与误差地梯度下降成正比, 即:

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}}, \quad i = 0, 1, 2, \dots, n; \quad j = 1, 2, \dots, k$$

$$\Delta v_{mi} = -\eta \frac{\partial E}{\partial v_{mi}}, \quad m = 0, 1, 2, \dots, l; \quad i = 1, 2, \dots, n$$
(4)

式中，负号表示梯度下降，常数 $\eta \in (0, 1)$ 表示比例系数，在训练中反映了学习速率[5]。

2.2. BP 神经网络的 C、Mn 收得率预测模型求解

由问题一求出 C、Mn 收得率的数据组，将数据组分成 90% 的训练集，构建出三层网络层[6]；输入向量为 $X = (x_1, x_2, \dots, x_n)^T$ ，隐含层输出向量为 $Y = (y_1, y_2, \dots, y_m)^T$ ，输出层输出向量为 $G = (g_1, g_2, \dots, g_k)^T$ 。

任意 100 炉次中 Mn 收得率的真实值与预测值见图 1：

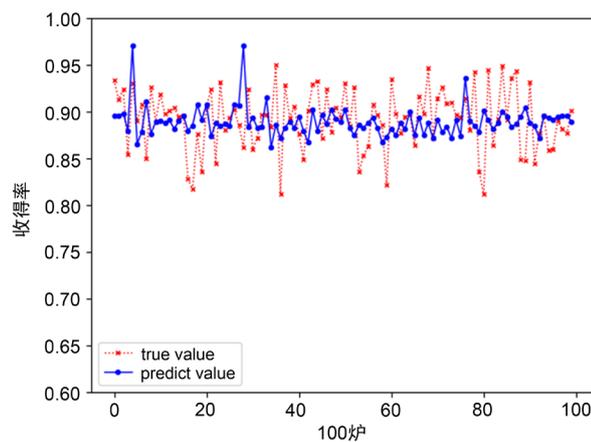


Figure 1. Comparison of real value and predicted value of Mn
图 1. Mn 的真实值与预测值对比图

该模型对 100 炉终点成分 Mn 的预测值均达到 85% 以上，部分预测值超过了 95%，甚至趋于 100%；同时，可得出 Mn 的 100 组误差值，部分误差值趋于零，95% 以上的误差值不超过区间 $[-0.1, 0.1]$ ，但有个别误差点小于 -0.1 ，因此，仍可通过仿真预测进一步优化预测值。

任意 100 炉次中 C 收得率的真实值与预测值见图 2：

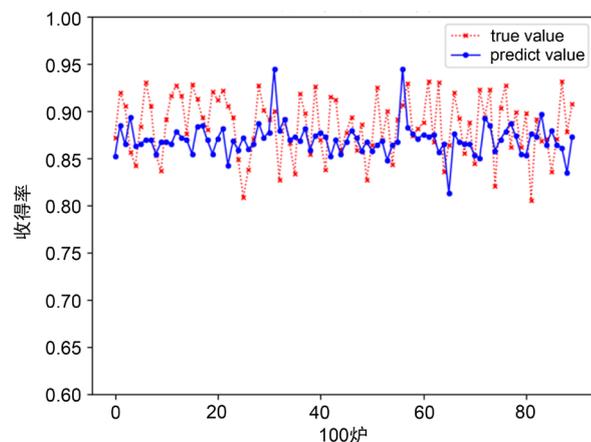


Figure 2. Comparison of real value and predicted value of C
图 2. C 的真实值与预测值对比图

该模型对 100 炉的终点成分 C 的预测值大部分达到 85% 以上, 少数预测值超过了 87%, 另外, 可得出 C 的 100 组误差值, 大部分误差值趋于零, 所有误差值均不超过区间 $[-0.1, 0.1]$ 。

2.3. 拟合的 C、Mn 收得率预测模型求解

从历史收得率中随机抽取 10 组数据进行拟合分析, 见表 1:

Table 1. 10 group year (year) and yield (%)
表 1. 10 组年份(年)与收得率(%)

1678	1640	1651	1656	1661	1668	1693	1651	1672	1647
0.865	0.951	0.945	0.876	0.941	0.917	0.937	0.926	0.930	0.971

设曲线拟合函数为:

$$y = a_1 + a_2x + \dots + a_nx^{n-1} \tag{5}$$

若使残差的平方和最小, 在近似值贴近于真实值, 故有:

$$\sum_i^n \delta_i^2 = \min$$

可先选定一组函数 $r_1(x), r_2(x), \dots, r_m(x), m < n$, 特别地, 取

$$\{r_1(x), r_2(x), \dots, r_m(x)\} = \{1, x, x^2, \dots, x^{m-1}\} \tag{6}$$

令

$$\varphi(x) = a_1r_1(x) + a_2r_2(x) + \dots + a_mr_m(x)$$

确定 a_1, a_2, \dots, a_m , 使得

$$J(a_1, a_2, \dots, a_m) = \sum_i^n \delta_i^2 = \sum_i^n [\varphi(x_i) - y_i]^2 = \sum_i^n \left[\sum_{k=1}^m a_k r_k(x_i) - y_i \right]^2 \tag{7}$$

要使 $J(a_1, a_2, \dots, a_m)$ 最小, 即对它求偏导数:

$$\frac{\partial J}{\partial a_k} = 0 \quad (k = 1, \dots, m) \tag{8}$$

矩阵形式为:

$$\begin{pmatrix} (r_1, r_1) & (r_1, r_2) & \dots & (r_1, r_m) \\ (r_2, r_1) & (r_2, r_2) & \dots & (r_2, r_m) \\ \vdots & \vdots & \ddots & \vdots \\ (r_m, r_1) & (r_m, r_2) & \dots & (r_m, r_m) \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_m \end{pmatrix} = \begin{pmatrix} (y, r_1) \\ (y, r_2) \\ \vdots \\ (y, r_m) \end{pmatrix}$$

若记

$$Q = \begin{bmatrix} r_1(x_1) & \dots & r_m(x_1) \\ \vdots & \ddots & \vdots \\ r_1(x_n) & \dots & r_m(x_n) \end{bmatrix}, \quad a = \begin{bmatrix} a_1 \\ \vdots \\ a_m \end{bmatrix}, \quad y = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}$$

此时正则方程组为: $(Q^T Q)a = Q^T y$ 。

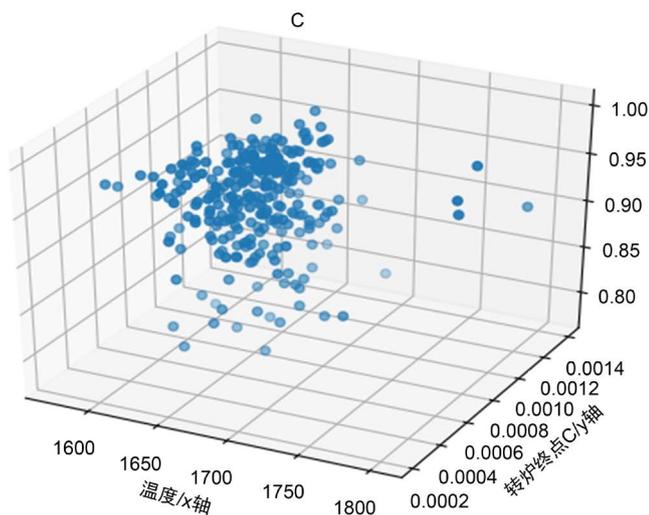


Figure 3. Schematic diagram of the three-dimensional relationship between two impact factors and C yield
图 3. 两影响因子与 C 收得率的三维关系示意图

从而有两影响因子与 C 收得率的三维关系，见图 3，因此可得出预测收得率，取出任意十组 C 的预测值分析，给出如下表格，见表 2：

Table 2. C element fitting predicted value and true value analysis

表 2. C 元素拟合预测值与真实值分析

温度(°C)	1678	1640	1651	1656	1661	1667	1693	1681	1672	1647
预测值(%)	0.829	0.951	0.946	0.876	0.941	0.917	0.937	0.926	0.930	0.971

结论：十组预测数据中碳的收得率最低值为 0.829377，最高值为 0.971045，预测率在 82% 以上，所以拟合的预测效果比 BP 神经网络预测更差[7]。

根据影响 Mn 收得率的两大因子转炉终点温度和转炉终点 C，以温度为 x 轴，转炉终点 C 为 y 轴，收得率为 z 轴，得出三维空间关系图如下，见图 4：

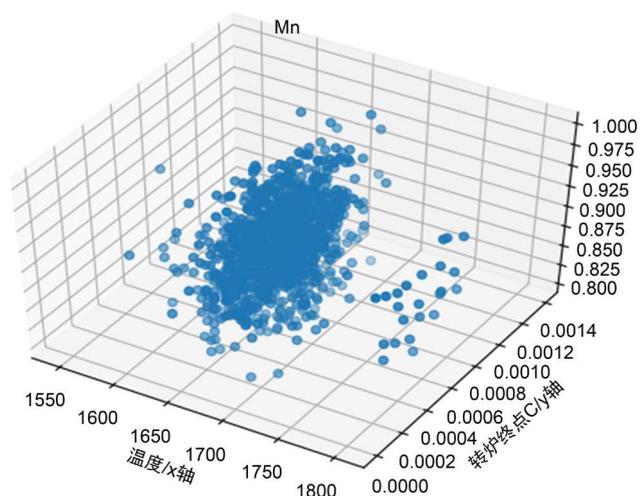


Figure 4. Schematic diagram of a three-dimensional relationship between two factors and Mn yield
图 4. 两因素与 Mn 收得率的三维关系示意图

因此可得出预测收得率，取出任意十组 Mn 收得率分析，给出如下表格，见表 3:

Table 3. Mn element fitting prediction value and true value analysis
表 3. Mn 元素拟合预测值与真实值分析

温度(°C)	1684	1663	1705	1639	1571	1710	1692	1645	1668	1655
预测值(%)	0.937	0.943	0.950	0.894	0.846	0.912	0.920	0.931	0.941	0.951

结论：十组预测数据中锰的收得率最低值为 0.845525，最高值为 0.951274，预测率在 82% 以上，所以拟合的预测效果比 BP 神经网络预测更差。

3. 仿真优化检验

通过分析转炉炼钢生产过程的反应机理，根据附件提供的大量数据，计算出 C 和 Mn 历史收得率并分析出转炉终点温度和转炉终点 C 为 C、Mn 收得率的主要影响因素。采用 10 组 HRB400B 钢号数据进行仿真实验来检验 BP 神经网络模型与拟合模型预测的准确性和可靠性。

以合金元素 i 含量作为预测结果的评价指标，该合金元素 i 含量公式如下：

$$\text{合金元素 } i \text{ 量} = \frac{\text{目标出钢含量 } i - \text{吹出成分 } i}{\text{元素 } i \text{ 收得率}} \times (\text{钢水净重} - \text{合金总质量})$$

目标出钢含量即为钢产品达标目标值，故由目标出钢含量 $i = 0.23$ ，吹出成分 i 为转炉终点 i 。

求出预测值的平均值为 0.21285，见表 4，由定义的控制区间定理得该均值在

$$\left[\frac{a\% + b\%}{2} - \frac{b\% - a\%}{4}, \frac{a\% + b\%}{2} + \frac{b\% - a\%}{4} \right] = [0.205, 0.245] \text{ 区间内，故收得率的预测准确率达到 } 90\% \text{ 以上。}$$

Table 4. Fitting the model to predict the carbon content of the alloy

表 4. 拟合模型预测的合金碳元素含量

第一组	第二组	第三组	第四组	第五组	第六组	第七组	第八组	第九组	第十组
0.2168	0.1906	0.2331	0.1902	0.1965	0.2256	0.1846	0.1964	0.2531	0.2416

求出预测值的平均值为 1.47364，见表 5，由定义的控制区间定理得该均值在

$$\left[\frac{a\% + b\%}{2} - \frac{b\% - a\%}{4}, \frac{a\% + b\%}{2} + \frac{b\% - a\%}{4} \right] = [1.375, 1.525] \text{ 区间内，故收得率的预测准确率达到 } 90\% \text{ 以上。}$$

Table 5. Fitting the model to predict the manganese content of the alloy

表 5. 拟合模型预测的合金锰元素含量

第一组	第二组	第三组	第四组	第五组	第六组	第七组	第八组	第九组	第十组
1.3567	1.4596	1.6012	1.5137	1.451	1.3984	1.486	1.3908	1.5706	1.5084

根据 BP 神经网络模型知，C 和 Mn 的仿真值图如下，见图 5:

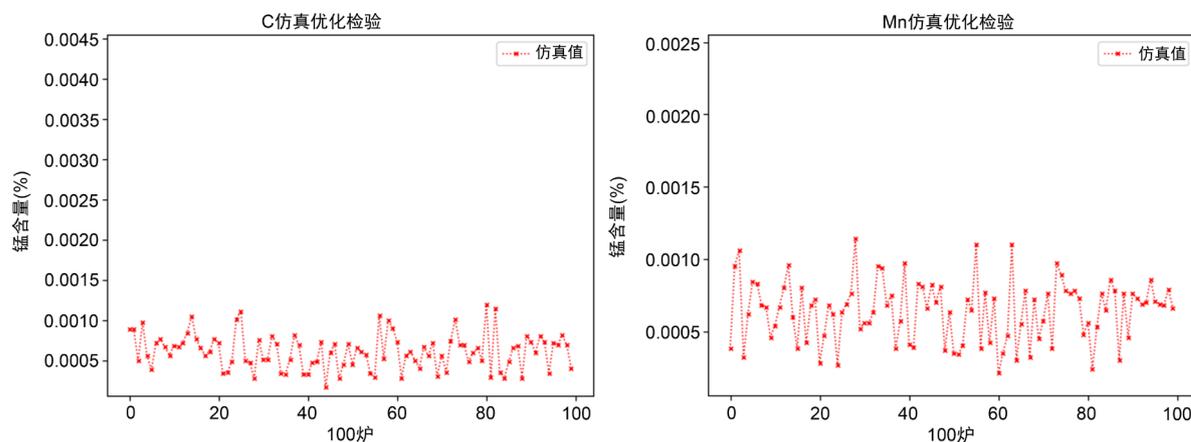


Figure 5. C, Mn simulation test chart

图 5. C、Mn 仿真检验图

结论：根据控制区间定理可知，BP 神经网络对碳和锰的仿真优化误差规定内，预测准确率达到 89% 以上，而且 BP 神经网络预测出的合金元素 i 含量比拟合预测出的合金元素 i 含量更加靠近于 $\frac{a\% + b\%}{2}$ ，因此 BP 神经网络预测出的收得率更加靠近于真实值。

4. 结论

结合大数据思维，利用数据深度处理分析各个变量对合金元素收得率的影响，随机抽取实际生产数据，用 BP 神经网络模型得出的理论预测值误差与拟合模型预测值进行仿真对比分析，确保了 BP 神经网络预测模型的可靠性，再根据建立出脱氧合金化过程的合金元素收得率预测模型，缩短学习训练时间，提高模型预测精度，得出 BP 神经网络预测值均在 85% 以上，拟合预测值均在 82% 以上，结果表明：随机选取 100 炉次的生产数据进行仿真优化，根据控制区间定理知，拟合的预测准确率达到 84% 以上，BP 神经网络预测准确率均在 89% 以上，BP 神经网络预测模型更符合生产要求[8]。

随着钢铁行业中高附加值钢种产量的不断提高，通过历史数据对脱氧合金化环节建立数学模型，以实现在线预测、优化投入合金的种类和数量，在保证钢水质量的前提下，最大程度上降低合金钢的生产成本，是提升各大钢铁企业竞争力和获得长远发展利益的决定性保障。

参考文献

- [1] 徐端, 刘士新. 数据驱动和机理模型混合的炼钢 - 连铸能耗建模研究[J]. 河北冶金, 2018(10): 14-19+40.
- [2] 潘军, 邓南阳, 胡惠华, 赵斌, 薛顺, 王义平. 降低低合金钢 Q345B 合金消耗的工艺优化[J]. 钢铁研究, 2015, 43(2): 56-58.
- [3] Biao, T., et al. (2017) The Research Process on Converter Steelmaking Process by Using Limestone. *IOP Conference Series: Earth and Environmental Science*, **81**, Article ID: 012175.
- [4] 韩敏, 徐俏, 赵耀, 林东, 杨溪林. 基于收得率预测模型的转炉炼钢合金加入量计算[J]. 炼钢, 2010, 26(1): 44-47.
- [5] 王广. 神经网络发展现状综述[J]. 中小企业管理与科技(下旬刊), 2017(2): 165-167.
- [6] 马海志. BP 神经网络的改进研究及应用[D]: [硕士学位论文]. 哈尔滨: 东北农业大学, 2011.
- [7] 包燕平, 张超杰, 王敏. 炼钢过程中合金减量化研究现状及展望[J]. 工程科学学报, 2018, 40(9): 1017-1026.
- [8] 薛正良, 吴丽嘉, 王伟, 左都伟, 罗斌, 彭灿峰, 郝飞翔, 严明. 转炉终点钢水残锰含量及锰收得率的影响因素分析[J]. 炼钢, 2011, 27(6): 40-43.