

BP 神经网络 IF 钢铝耗的预测模型

张思源¹⁾，包燕平^{1)✉}，张超杰¹⁾，林 路²⁾

1) 北京科技大学钢铁冶金新技术国家重点实验室,北京 100083 2) 钢铁研究总院冶金工艺研究所,北京 100081

✉通信作者, E-mail: baoyp@ustb.edu.cn

摘要 为了解决某钢厂 IF 钢冶炼 RH 精炼过程铝耗偏高问题,通过数理统计和 BP 神经网络相结合的方法建立了铝耗预测模型,并与多元线性回归模型进行比较,该模型具有更高准确度。该模型分析了不同冶炼工艺参数对铝耗的具体影响,并对相应工艺参数进行了优化。结果表明:脱碳结束氧活度或 RH 进站氧活度降低 0.005% 左右,每吨钢铝耗可降低 0.07 ~ 0.08 kg,铝脱氧有效利用系数为 70.31% ~ 80.35%;RH 进站钢液温度增加 35 ~ 40 ℃,铝耗降低 1 kg 左右,铝热反应升温利用系数在 97.4% 左右;吹氧量小于 100 m³ 和大于 100 m³ 时,氧气与铝反应的比例分别为 37.3% 和 74.6% 左右,吹氧量每增加 50 m³,铝耗分别增加 0.1 kg 和 0.2 kg 左右。工艺参数优化后平均铝耗由 1.359 kg 降低到 1.113 kg,降幅达 18.1%。

关键词 IF 钢; 低碳钢; 铝耗; 神经网络; 预测模型

分类号 TF769.4

Prediction model of aluminum consumption with BP neural networks in IF steel production

ZHANG Si-yuan¹⁾ , BAO Yan-ping^{1)✉} , ZHANG Chao-jie¹⁾ , LIN Lu²⁾

1) State Key Laboratory of Advanced Metallurgy , University of Science and Technology Beijing , Beijing 100083 , China

2) Metallurgical Technology Institute , Central Iron and Steel Research Institute , Beijing 100081 , China

✉Corresponding author, E-mail: baoyp@ustb.edu.cn

ABSTRACT To solve the high aluminum consumption problem in interstitial-free steel production in a steel plant, an aluminum consumption prediction model was established by mathematical statistics and BP neural networks. Compared with the multiple linear regression model, this model's result is more accurate. The influence of different smelting processes on aluminum consumption was analyzed, and the process parameters were optimized. The results show that the amount of aluminum consumption per ton of steel decreases 0.07 to 0.08 kg when the oxygen activity before RH or after decarbonization reduces by 0.005%. The effective utilization coefficient of aluminum-deoxidizing is from 70.31% to 80.35%; the aluminum consumption decreases about 0.1 kg when the temperature of steel before RH increases by 35 to 40 ℃. The heating utilization coefficient of aluminum thermal reaction is about 97.4%. When the blowing oxygen quantity is less than 100 m³ and greater than 100 m³, the ratio of oxygen reacting with aluminum is about 37.3% or about 74.6% respectively, and the aluminum consumption increases by 0.1 kg or 0.2 kg, respectively, with the blowing oxygen quantity increasing by 50 m³. After the process parameter optimization, the aluminum consumption decreases from 1.359 to 1.113 kg, which results in a decrease of 18.1%.

KEY WORDS IF steel; low carbon steel; aluminum consumption; neural networks; prediction models

IF 钢由于良好的深冲性能,被广泛应用在汽车和家电行业中,对洁净度要求十分严格,因此需要控制钢

中夹杂物的数量、大小、形态和分布^[1-2]。IF 钢属于铝脱氧镇静钢,生产过程中要加入大量的铝合金进行脱

氧,但过量的 Al_2O_3 脱氧产物会影响钢液洁净度。铝耗的降低一方面能够节约生产成本,更重要的是能够减少 Al_2O_3 的产生,降低大尺寸簇状 Al_2O_3 夹杂形成概率,提高铸坯洁净度^[3-4]。因此通过降低铝耗,达到降低钢厂生产成本和提高钢液洁净度的目的显得尤为重要。

目前国内外学者对铝脱氧镇静钢的研究大部分集中在如何降低已经生成的 Al_2O_3 夹杂对钢材质量的影响或仅对 Al_2O_3 夹杂的危害进行描述^[5-8],很少有学者对冶炼工艺对铝耗的具体影响进行系统的分析。本文通过BP神经网络构建铝耗预测模型,以此来分析不同RH冶炼工艺参数对铝耗的具体影响,从而根据该结果对实际生产予以指导,最终通过降低铝耗达到降低生产成本和提高钢液洁净度的目的。

1 BP 神经网络

BP神经网络是一种多层前馈神经网络,由信息的正向传播和误差的反向调节两个过程组成^[9],如图1所示。其中 x_n 和 y_m 为训练样本输入输出的原始数据, W_{ab} 为输入层神经元和隐含层神经元之间的连接权值, W_{bc} 为隐含层神经元和输出层神经元直接的连接权值。

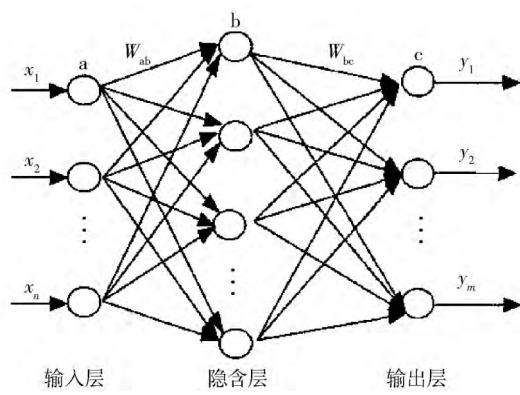


图1 三层BP神经网络结构图

Fig. 1 Structure diagram of a three-layer BP neural network

BP神经网络包含3层^[10]:输入层、隐含层和输出层。隐含层可以为一层也可以为多层(本模型隐含层为1层),每一层神经元互相连接,通过向后反馈的学习机制,不断修正神经网络中神经元权值,直至输出正确结果。

BP神经网络可以进行自主训练,在训练过程中通过不断的计算修正,实现输入变量和输出结果之间准确的映射作用。数学理论证明三层的神经网络可以以任意精度逼近任何非线性连续函数^[11-12]。IF钢冶炼过程中,影响铝耗的工艺参数较为复杂,BP神经网络恰好可以准确地探求出不同工艺因素对铝耗的影响,以此来指导生产。

2 模型建立及应用

2.1 输入变量确定

正确的输入变量是保证模型中铝耗与冶炼工艺参数准确映射关系的前提,可能影响铝耗的冶炼工艺参数为进站到开始处理时间、抽真空到深真空时间、最小真空度、RH进站钢液温度、吹氧量、RH进站氧活度和脱碳结束氧活度。本文所用数据以某钢厂2016年3—5月份的冶炼工艺数据为基础,筛选掉异常炉次,对845炉有效冶炼工艺数据进行处理。

考虑到各冶炼工艺参数之间可能存在一定的关联性,首先通过主成分分析,对可能影响铝耗的工艺参数进行降维处理,计算结果如表1所示。

表1 方差及主成分贡献率

Table 1 Eigenvalue and principle component contribution rate

成分	特征向量		
	特征值	方差贡献率/%	方差累计贡献率/%
1	2.018	28.823	28.823
2	1.230	17.567	46.390
3	1.037	14.818	61.208
4	0.913	14.183	75.391
5	0.778	11.116	86.507
6	0.677	9.668	96.175
7	0.268	3.825	100.000

从表1发现,特征值大于1的主成分有3项,累计方差贡献率为61.208%,小于主成分方差占总方差75%~85%的要求^[13],因此不能够通过主成分分析进行降维处理。通过SPSS软件对冶炼工艺参数与铝耗的关系进行相关性分析,明确铝耗与主要工艺参数的显著性水平,如表2所示。

表2 不同冶炼工艺与铝耗的显著性结果

Table 2 Significant results between different smelting processes and aluminum consumption

工艺参数	进站到开始处理时间	抽真空到深真空时间	最小真空度	RH进站钢液温度	吹氧量	RH进站氧活度	脱碳结束氧活度
显著性	0.061	0.135	0.232	0	0	0	0

注:在0.01水平(双侧)上显著相关。

从表2可知,RH进站钢液温度、吹氧量、RH进站氧活度以及脱碳结束氧活度与铝耗的显著性结果均小

于显著性水平0.01,应拒绝 H_0 假设(与铝耗之间的相关性不显著),认为与铝耗之间的相关性显著。

作 845 炉中 RH 进站钢液温度、吹氧量与铝耗关系的散点图, 因吹氧量对钢液氧活度产生较大影响,

RH 进站氧活度和脱碳结束氧活度与铝耗关系的散点图为未吹氧的 338 炉次统计结果如图 2 所示。

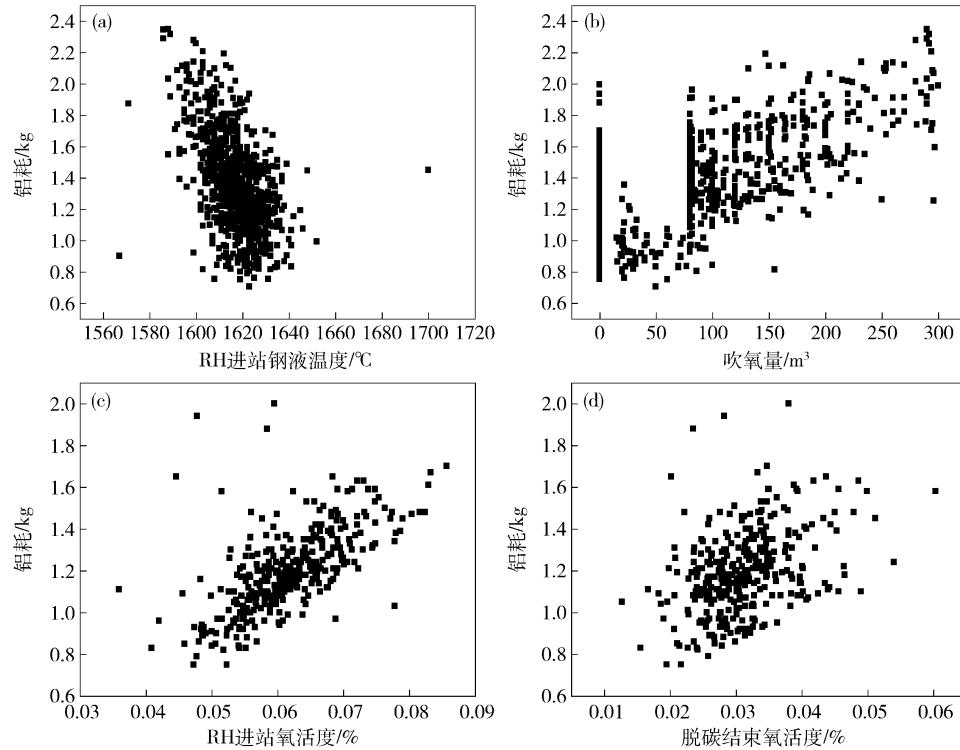


图 2 不同冶炼工艺与铝耗关系。(a) 铝耗与 RH 进站钢液温度的关系; (b) 铝耗与吹氧量的关系; (c) 铝耗与 RH 进站氧活度的关系; (d) 铝耗与脱碳结束氧活度的关系

Fig. 2 Relationship between different smelting processes and aluminum consumption: (a) relationship between aluminum consumption and steel temperature before RH; (b) relationship between aluminum consumption and blowing oxygen quantity; (c) relationship between aluminum consumption and oxygen activities before RH; (d) relationship between aluminum consumption and oxygen activity after decarbonization

由图 2 可知, RH 进站钢液温度、吹氧量、RH 进站氧活度和脱碳结束氧活度与铝耗均有明显的线性关系。铝耗随 RH 进站钢液温度的升高而降低, 随吹氧量、RH 进站氧活度和脱碳结束氧活度的升高而升高。计算各因素与铝耗的相关系数 r 如下式^[14]:

$$r = \frac{n \sum xy - \sum x \sum y}{\sqrt{\left[n \sum x^2 - (\sum x)^2 \right] \left[n \sum y^2 - (\sum y)^2 \right]}}, \quad (1)$$

式中 x 为 RH 进站钢液温度、吹氧量、RH 进站氧活度或脱碳结束氧活度中的影响因素之一, y 为铝耗, n 为样本量。结果如表 3 所示。

由表 3 可知, 吹氧量与铝耗的相关系数最大, 对铝耗影响最强; 脱碳结束氧活度与铝耗的相关系数最小, 对铝耗影响最弱; RH 进站钢液温度和 RH 进站氧活度

表 3 不同冶炼工艺与铝耗的相关系数

Table 3 Correlation coefficients between different smelting processes and aluminum consumption

冶炼工艺参数	RH 进站钢液温度	吹氧量	RH 进站氧活度	脱碳结束氧活度
相关系数	-0.527	0.685	0.533	0.395

与铝耗的相关系数居中, 对铝耗影响处于居中位置, 因此可以确定以上四个冶炼工艺参数作为模型的输入变量。

2.2 模型建立过程

以 2016 年 3—5 月份的 845 炉 RH 冶炼工艺参数为依据, 进行模型的训练和仿真, 随机选择其中 90% 的数据用于训练, 剩余 10% 的数据用于结果的仿真。训练参数如表 4 所示。

表 4 BP 神经网络铝耗预测模型训练参数

Table 4 Training parameters of the aluminum consumption prediction model with BP neural networks

训练参数	隐层个数	隐层神经元个数	学习速率	动量因子	训练精度	输入层传递函数	隐层传递函数	输出层传递函数	训练函数
设定值	1	8	0.001	0.9	0.0001	tansig	tansig	purelin	trainlm

表4 训练参数选取为多次训练以后选取的最优参数 其他未注明参数均采用默认值。应用 matlab GUI

将BP神经网络铝耗预测模型编制成软件进行应用，模型界面和控制过程如图3和图4所示。



图3 BP 神经网络铝耗预测模型界面

Fig.3 Interface of the aluminum consumption prediction model with BP neural networks

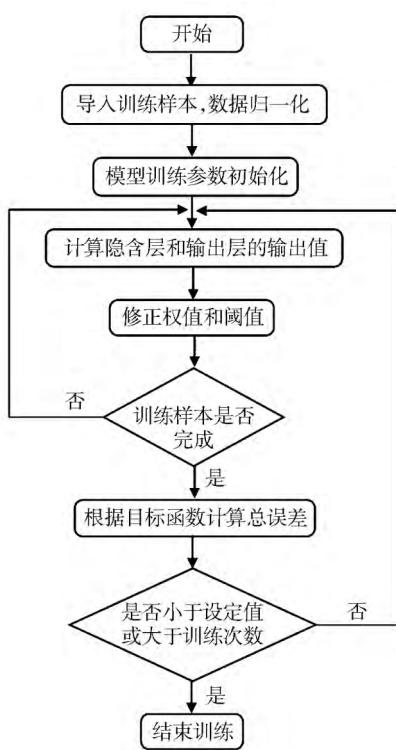


图4 BP 神经网络铝耗预测模型控制过程

Fig.4 Control process of the aluminum consumption prediction model with BP neural networks

2.3 模型结果仿真

模型训练完成以后, 将845炉次的10%用于结果的仿真。仿真结果如表5所示。

由表5可知, BP神经网络铝耗预测模型仿真结果的标准差为0.285, 平均误差为5.34%, 平均正确率为94.66%。相对误差在10%以内的命中率达到了91.8%。绝对误差范围在[-0.1, 0.1]范围内的命中率达到了85.9%, 命中率较高, 具有很高的应用价值。

2.4 BP 神经网络模型与多元线性回归模型对比

由图2可知, RH进站钢液温度、吹氧量、RH进站氧活度和脱碳结束氧活度与铝耗呈线性关系, 对以上因素和铝耗的关系进行多元线性回归建模, 回归系数如表6所示。

多元线性回归模型为:

$$y = -0.002 \times t + 0.004 \times L_0 + 0.002 \times a[O] + 0.001 \times a'[O] + 2.761. \quad (2)$$

式中: t 为 RH 进站钢液温度; L_0 为吹氧量; $a[O]$ 为 RH 进站氧活度; $a'[O]$ 为脱碳结束氧活度。

由式(2)可知, 吹氧量系数最大, 对铝耗影响最大; 脱碳结束氧活度系数最小, 对铝耗影响最小; RH进站钢液温度和 RH进站氧活度系数绝对值相等, 对铝耗影响几乎相同, 同2.1节所反映的影响规律几乎相同, 验证了各工艺参数对铝耗影响的重要性。

将BP神经网络铝耗预测模型用于结果仿真的85炉工艺参数代入多元线性回归模型中, 对两种模型的预测输出与期望输出进行对比, 如图5所示。

由图5可知, 两种模型的预测输出和期望输出均有较好的吻合度, 变化趋势几乎相同。但大部分炉次中, BP神经网络模型的预测输出与期望输出更接近,

表 5 BP 神经网络铝耗预测模型仿真结果

Table 5 Simulation results of the aluminum consumption prediction model with BP neural networks

炉次	期望输出/kg	预测输出/kg	相对误差/%	炉次	期望输出/kg	预测输出/kg	相对误差/%
1	1.41	1.31	7.00	44	1.10	1.08	1.39
2	1.59	1.67	4.56	45	0.96	0.89	6.91
3	1.21	1.17	3.08	46	1.43	1.49	3.90
4	0.95	0.97	2.11	47	1.04	1.06	1.99
5	1.51	1.44	4.20	48	1.28	1.17	8.56
6	1.48	1.42	3.95	49	1.31	1.10	16.04
7	1.22	1.39	13.53	50	1.06	0.99	7.23
8	1.40	1.37	2.43	51	1.72	1.60	6.73
9	1.40	1.28	8.38	52	1.15	1.04	9.50
10	1.10	1.06	4.03	53	1.35	1.27	5.94
11	1.65	1.58	3.85	54	1.06	1.01	4.49
12	1.33	1.24	7.02	55	0.89	1.07	19.35
13	1.46	1.43	2.09	56	1.63	1.71	5.18
14	1.42	1.35	5.36	57	1.31	1.25	4.77
15	0.92	0.92	0.07	58	1.54	1.39	9.47
16	1.17	1.23	5.03	59	1.73	1.64	5.63
17	1.20	1.12	6.18	60	0.89	0.91	2.73
18	1.63	1.59	2.46	61	1.38	1.41	2.15
19	1.55	1.48	4.29	62	0.91	0.96	5.08
20	1.42	1.50	5.39	63	0.91	0.96	4.88
21	1.45	1.38	4.72	64	0.96	0.98	2.48
22	1.92	1.90	1.07	65	1.98	1.92	3.01
23	1.56	1.60	2.83	66	1.05	1.03	1.89
24	1.69	1.52	10.13	67	1.73	1.59	8.10
25	1.28	1.34	4.48	68	1.30	1.20	7.30
26	0.93	0.90	3.09	69	1.19	1.23	3.00
27	0.70	0.80	12.88	70	1.09	1.00	8.47
28	1.23	1.26	2.33	71	1.16	1.04	10.52
29	1.03	0.97	5.76	72	1.52	1.47	3.51
30	1.52	1.44	5.14	73	1.30	1.22	6.38
31	1.07	1.09	1.89	74	1.32	1.29	2.90
32	1.31	1.21	7.20	75	0.83	0.86	3.36
33	1.27	1.22	4.04	76	1.26	1.19	5.69
34	2.35	2.41	2.79	77	1.38	1.33	3.54
35	1.10	1.17	6.29	78	1.33	1.41	6.08
36	1.08	0.99	8.25	79	1.54	1.51	1.57
37	0.93	0.93	0.64	80	1.15	1.23	7.41
38	1.83	1.89	3.24	81	1.49	1.32	11.01
39	1.49	1.41	5.15	82	1.15	1.22	6.02
40	1.57	1.49	4.92	83	0.97	0.95	2.57
41	1.11	1.09	2.23	84	1.20	1.10	8.03
42	1.66	1.72	3.87	85	1.09	1.04	4.07
43	0.84	0.90	7.17				

表6 多元线性回归系数

Table 6 Coefficients of multiple linear regression

多元线性 回归参数	常量	RH 进站 钢液温度	吹氧量	RH 进站 氧活度	脱碳结束 氧活度
回归系数	2.761	-0.002	0.004	0.002	0.001

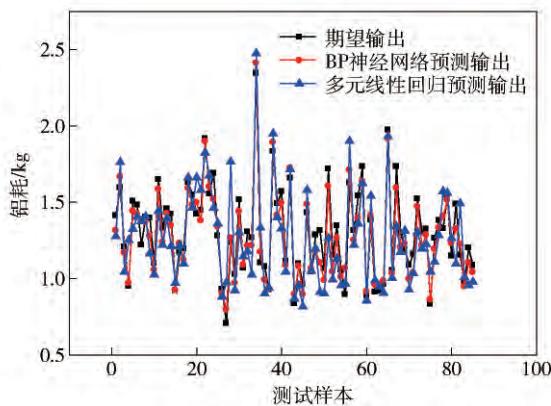


图5 BP 神经网络和多元线性回归预测输出和期望输出对比图
Fig. 5 Comparison of the prediction output of BP neural network and multiple linear regression and desired output

预测精度更高。对两种模型预测结果的相对误差进行对比,如图6所示。

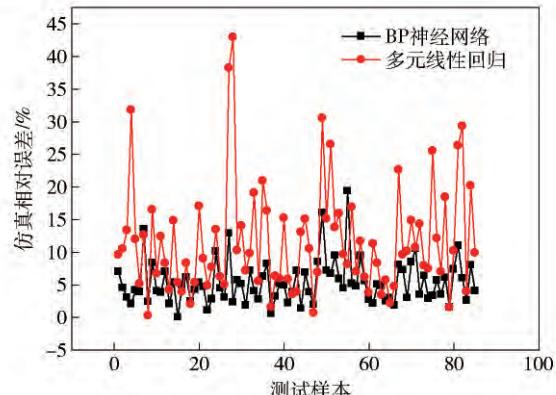


图6 BP 神经网络模型与多元线性回归模型相对误差对比图
Fig. 6 Comparison between the relative errors of the BP neural network and multiple linear regression models

由图6可知,BP 神经网络模型预测结果相对误差大部分在10%以内,少数炉次在10%~20%之间,但均处于20%以内;多元线性回归模型预测结果相对误差仅有半左右在10%以内,其余炉次相对误差较高,波动较大,BP 神经网络模型预测结果明显要好于多元线性回归模型。两种模型部分炉次误差较大,主要是由于生产原料波动以及现场操作问题所致,属于现场操作复杂性的不可抗拒因素。

将BP 神经网络模型和多元线性回归模型预测结果的相关参数进行比较,如表7所示。

表7 多元线性回归模型和BP 神经网络模型预测结果对比

Table 7 Comparison of the prediction results of the BP neural network and multiple linear regression models

模型形式	标准差	平均 误差/%	最大 误差/%	最小 误差/%
多元线性回归模型	0.311	11.56	42.93	0.27
BP 神经网络模型	0.285	5.34	19.35	0.07

由表7可知,BP 神经网络模型预测结果的标准差、平均误差、最大误差以及最小误差均较小,因此BP 神经网络模型更适合应用在IF 钢生产过程铝耗的预测上。

3 结果与讨论

BP 神经网络铝耗预测模型能够较为准确地预测出不同工艺条件下的铝耗情况,在此模型基础上,分析不同冶炼工艺对铝耗的具体影响。

3.1 RH进站氧活度和脱碳结束氧活度对铝耗的影响

将RH 进站钢液温度和吹氧量分别设定在1615 ℃和100 m³,不同RH 进站氧活度条件下,脱碳结束氧活度与铝耗的关系如图7所示。

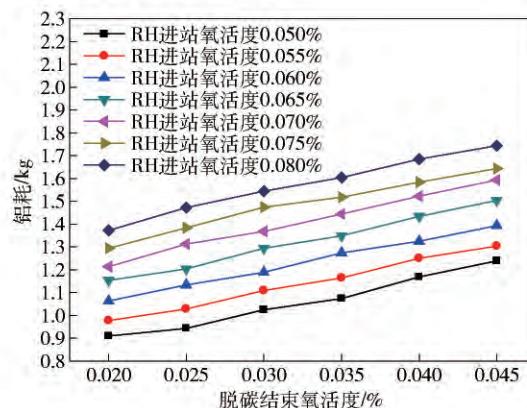
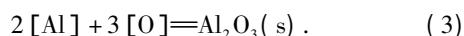


图7 不同RH 进站氧活度条件下铝耗与脱碳结束氧活度的关系
Fig. 7 Relationship between the aluminum consumption and oxygen activity after decarbonization under the conditions of different oxygen activities before RH

由图7可知,RH 进站氧活度相同时,铝耗随着脱碳结束氧活度的上升而上升;脱碳结束氧活度相同时,铝耗随着RH 进站氧活度的上升而上升。当脱碳结束氧活度或者RH 进站氧活度降低0.005%左右时,铝耗降低0.07~0.08 kg。主要是因为随着RH 进站氧活度和脱碳结束氧活度的提高,钢中自由氧含量上升,脱氧用铝耗量增多。

该钢厂生产IF 钢过程所用铝合金为纯铝粒,铝与钢液中氧发生如下反应^[15]:



铝粒进入钢液以后,除了与自由氧发生氧化反应以外,部分直接进入炉渣、炉气或成为钢液中酸溶铝。将铝粒与钢液中自由氧反应的比例定义为铝脱氧有效利用系数,如下式所示:

$$\eta = \frac{W_{Al\text{理论}}}{W_{Al\text{实际}}} \times 100\%. \quad (4)$$

式中, $W_{Al\text{理论}}$ 为理论铝耗量, $W_{Al\text{实际}}$ 为实际铝耗量,单位均为kg。

通过式(3)计算,钢中自由氧含量降低0.005%,理论铝耗量降低0.05625 kg,而实际铝耗量降低0.07~0.08 kg,因此铝脱氧有效利用系数为70.31%~80.36%。

该厂平均铝耗为1.359 kg,平均RH进站钢液温度、吹氧量以及脱碳结束氧活度分别为1617 °C、83.6 m³和0.034%。由图7可知,脱碳结束氧活度为0.035%时,平均铝耗对应的RH进站氧活度在0.070%左右,因此为了降低铝耗,应将RH进站氧活度保持在0.070%以下,但过低的RH进站氧活度不利于脱碳反应进行,因此建议RH进站氧活度控制在0.050%~0.070%,脱碳结束氧活度小于0.035%。

3.2 RH进站钢液温度和吹氧量对铝耗的影响

将RH进站氧活度和脱碳结束氧活度分别设定在0.065%和0.035%,不同吹氧量条件下,RH进站钢液温度与铝耗的关系如图8所示。

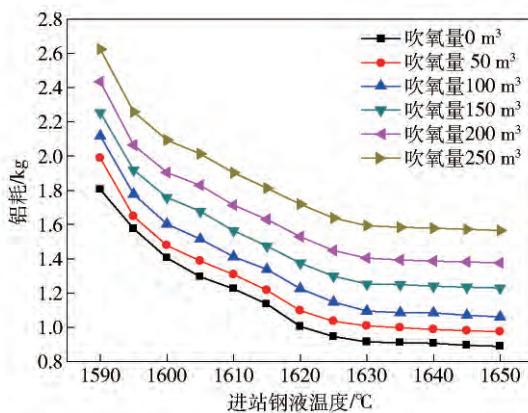


图8 不同吹氧量条件下铝耗和RH进站钢液温度的关系

Fig. 8 Relationship between aluminum consumption and steel temperature before RH under the conditions of different blowing oxygen quantities

由图8可知:当吹氧量一定时,铝耗随RH进站钢液温度的升高而降低;当RH进站钢液温度小于1630 °C时,RH进站钢液温度增加35~40 °C,铝耗降低1 kg左右。当RH进站钢液温度大于1630 °C时,铝耗降低趋势减弱。主要是因为随着RH进站钢液温度的升高,升温用铝耗量降低,当钢液温度达到某一值时,不需要额外加铝升温也能使钢液温度满足下一工序^[16]。因此应当控制RH进站钢液温度在1630 °C以上,但过高的

RH进站钢液温度会增加转炉负担,降低炉衬使用寿命,因此RH进站钢液温度也不宜过高,建议RH进站钢液温度控制在1630~1640 °C之间。

铝粒加入钢液后通过铝的溶解和铝热反应放热来达到提高钢液温度的目的,铝的溶解热对钢液温度的提升作用较小^[17],可忽略不计,因此当吹氧量一定时,钢液温度的提升主要靠铝热反应进行,如式(3)所示,其反应焓 $\Delta H = -1218.8 \text{ kJ} \cdot \text{mol}^{-1}$ 。可得

$$\Delta T = \frac{\Delta H \times \frac{W_{Al} \times 1000}{27} \times \eta}{C_{P\text{steel}} \times W_{\text{steel}} \times 1000} = \frac{51.3 \times W_{Al} \times \eta}{W_{\text{steel}}}. \quad (5)$$

其中 ΔT 为铝热反应导致的升温变化, °C; W_{Al} 为加入铝粒质量, kg; W_{steel} 为钢液质量,t,具体计算按300 t计算; $C_{P\text{steel}}$ 为钢液比热容, $\text{kJ} \cdot \text{kg}^{-1} \cdot ^\circ\text{C}^{-1}$ 。

铝热反应放热除了用于钢液升温以外,可能有一部分热量以辐射、热传导等方式损失到周围空气或设备中。将铝热反应放热量用于钢液升温的比例定义为铝热反应升温利用系数,如下式所示:

$$\eta' = \frac{\Delta T_{\text{实际}}}{\Delta T_{\text{理论}}} \times 100\%. \quad (6)$$

其中 $\Delta T_{\text{实际}}$ 和 $\Delta T_{\text{理论}}$ 分别为1 kg铝耗引起钢液温度理论和实际的变化, °C。

由式(5)可知,铝耗为1 kg时,钢液温度理论上提高36~41 °C,与图8反映出来的温度提高值几乎相同,说明铝热反应放热损失较小。取1 kg铝耗引起钢液温度理论变化和实际变化的中值进行计算,可得铝热反应升温利用系数在97.4%左右。

当RH进站钢液温度相同时,铝耗随吹氧量的升高而升高,主要是因为吹氧量升高,钢中自由氧含量提高,脱氧用铝耗量增多。当吹氧量大于100 m³时,铝耗升高速度加快,其原因如图9所示。

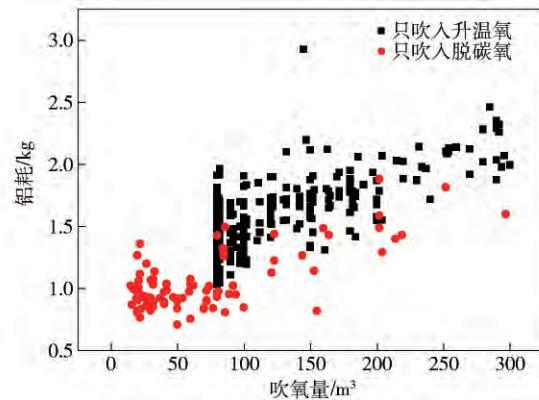


图9 升温氧和脱碳氧对于铝耗的影响对比

Fig. 9 Comparison of the effects of oxygen for decarburization and temperature on aluminum consumption

吹氧主要有脱碳和升温两个目的^[18],图9为只吹入升温氧和只吹入脱碳氧时铝耗对比情况,从图中发

现仅吹入脱碳氧时,吹氧量一般较小,大部分在100 m³以下,仅吹入升温氧时,吹氧量一般较大,大部分在100 m³以上。说明当吹氧量大于100 m³时,吹氧量中升温氧量占比将会大幅度提高,使得铝耗大幅度提高,因此建议将吹氧量控制在100 m³以下。

假设吹入氧气为标况下气体,且吹入氧气全部与铝发生反应,则由式(3)可得,所需铝量为

$$W_{\text{铝}} = \frac{\frac{V_{O_2} \times 1000}{22.4} \times 4 \div 3 \times 27 \div 1000}{W_{\text{steel}}} = \frac{1.607 \times V_{O_2}}{W_{\text{steel}}} \quad (7)$$

其中: $W_{\text{铝}}$ 为铝耗量 kg; V_{O_2} 为吹入氧气体积 m³。

由式(7)计算得,吹入50 m³氧气全部与铝反应时,铝耗量为0.268 kg。但实际生产中,吹入氧气很大一部分参与脱碳反应。从图8发现,吹氧量小于100 m³时,吹氧量增加50 m³,铝耗增加0.1 kg左右,此时吹入氧气与铝反应的比例为

$$\eta_1 = \frac{0.1}{0.268} \times 100\% = 37.3\%. \quad (8)$$

吹氧量大于100 m³时,吹氧量增加50 m³,铝耗增加0.2 kg左右,此时吹入氧气与铝反应的比例为

$$\eta_2 = \frac{0.2}{0.268} \times 100\% = 74.6\%. \quad (9)$$

3.3 工艺优化前后对比

对该钢厂工艺优化前的845炉铝耗分布情况进行了统计,平均铝耗为1.359 kg,集中分布在1~1.8 kg之间(如图10所示)。根据以上影响规律,对该钢厂IF钢300 t RH精炼工艺进行优化:RH进站氧活度为0.050%~0.070%,脱碳结束氧活度小于0.035%,RH进站钢液温度为1630~1640 °C,吹氧量小于100 m³。优化后的炉次带入该模型中进行预测,预测结果的平均误差为6.12%,与模型建立过程的仿真结果相当。对优化后的26炉冶炼数据进行统计分析,优化前后的铝耗情况如图10所示。

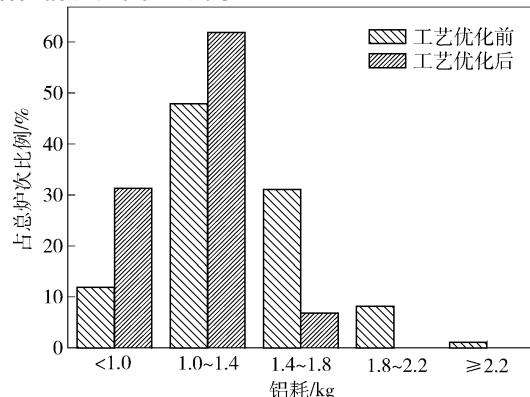


图10 工艺优化前后铝耗情况对比

Fig. 10 Comparison of the aluminum consumption before and after process optimization

由图10可知,工艺参数优化后,所有炉次铝耗均小于1.8 kg,其中小于1.4 kg的炉次占总炉次的百分比大幅度提升,平均铝耗由优化前的1.359 kg降低到1.113 kg,降幅达18.1%,效果显著。

基于BP神经网络的IF钢铝耗预测模型在该钢厂能够达到较好的预测效果,但不同钢厂的实际情况并不相同,对于铝耗的影响因素可能有所不同,其中操作水平、原料条件等都可能对铝耗产生影响。因此,对于不同的钢厂,要结合自己的实际情况,参考本文模型建立的基本过程,建立符合自身情况的铝耗预测模型。

4 结论

(1) 以RH进站钢液温度、吹氧量、RH进站氧活度和脱碳结束氧活度作为BP神经网络模型的输入变量,铝耗作为输出变量,建立了BP神经网络铝耗预测模型,仿真结果平均误差为5.34%,标准差为0.285。与多元线性回归模型进行比较,多元线性回归模型的平均误差为10.52%,标准差为0.308,BP神经网络模型对铝耗的预测精度更高。

(2) 铝耗随吹氧量、RH进站氧活度以及脱碳结束氧活度的升高而升高,随RH进站钢液温度的升高而降低。吹氧量对铝耗的影响最大,脱碳结束氧活度对铝耗的影响最小,RH进站钢液温度和RH进站氧活度对铝耗的影响几乎相同。

(3) 脱碳结束氧活度或RH进站氧活度降低0.005%左右时,铝耗降低0.07~0.08 kg,铝脱氧有效利用系数在70.31%~80.35%;RH进站钢液温度增加35~40 °C时,铝耗降低1 kg左右,铝热反应升温利用系数在97.4%左右;吹氧量小于100 m³和大于100 m³时,氧气与铝反应的比例分别为37.3%和74.6%左右,吹氧量每增加50 m³,铝耗分别增加0.1 kg和0.2 kg左右。

(4) 提出RH进站钢液温度控制在1630~1640 °C,吹氧量控制在100 m³以下,RH进站氧活度控制在0.050%~0.070%,脱碳结束氧活度控制在0.035%以下的工艺改进措施。工艺优化后,铝耗从1.359 kg降低到1.113 kg,降幅达18.1%。

参 考 文 献

- [1] Longauerová M, Federová M, Longauer S, et al. Distribution of microalloying elements and impurities in surface zone of CC IF steel. *Ironmaking Steelmaking*, 2009, 36(3): 176
- [2] Yang W, Zhang L F, Wang X H, et al. Characteristics of inclusions in low carbon Al-killed steel during ladle furnace refining and calcium treatment. *ISIJ Int*, 2013, 53(8): 1401
- [3] Yan P, Wang X H, Jiang M, et al. Inclusions in low carbon aluminum killed steel slabs at high casting speed. *Chin J Eng*,

- 2016, 38(3): 342
 (苑鹏, 王新华, 姜敏, 等. 高拉速连铸低碳铝镇静钢铸坯中夹杂物. *工程科学学报*, 2016, 38(3): 342)
- [4] Ma H X, Wang X H, Huang F X, et al. Effect of deoxidation technology on cleanliness of low carbon aluminum killed steel. *Iron Steel*, 2016, 51(1): 19
 (马焕珣, 王新华, 黄福祥, 等. 脱氧工艺对低碳铝镇静钢洁净度的影响. *钢铁*, 2016, 51(1): 19)
- [5] Deng Z Y, Zhu M Y. Evolution mechanism of non-metallic inclusions in Al-killed alloyed steel during secondary refining process. *ISIJ Int*, 2013, 53(3): 450
- [6] Zinngrebe E, Van Hoek C, Visser H, et al. Inclusion population evolution in Ti-alloyed Al-killed steel during secondary steelmaking process. *ISIJ Int*, 2012, 52(1): 52
- [7] Yang S F, Li J S, Wang Z F, et al. Modification of MgO•Al₂O₃ spinel inclusions in Al-killed steel by Ca-treatment. *Int J Miner Metall Mater*, 2011, 18(1): 18
- [8] Li X, Bao Y P, Wang M, et al. Effect of aluminum consumption and oxygen potential at final deoxidation on nozzle clogging of IF steel. *Chin J Eng*, 2015, 37(6): 700
 (李翔, 包燕平, 王敏, 等. 铝耗及终脱氧氧位对 IF 钢水口结瘤的影响. *工程科学学报*, 2015, 37(6): 700)
- [9] Liu T S. *The Research and Application on BP Neural Network Improvement* [Dissertation]. Harbin: Northeast Agricultural University, 2011
 (刘天舒. BP 神经网络的改进研究及应用 [学位论文]. 哈尔滨: 东北农业大学, 2011)
- [10] Guo Z H, Wu J, Lu H Y, et al. A case study on a hybrid wind speed forecasting method using BP neural network. *Knowl Based Syst*, 2011, 24(7): 1048
- [11] Sadeghi B H M. A BP-neural network predictor model for plastic injection molding process. *J Mater Process Technol*, 2000, 103(3): 411
- [12] Zhang L P, Wu K, Zhong Y F, et al. A new sub-pixel mapping algorithm based on a BP neural network with an observation model. *Neurocomputing*, 2008, 71(10): 2046
- [13] Xu Z X, Zhou D Y, Luo Y R. Fuzzy neural network based on principal component. *Comput Eng Appl*, 2006, 42(5): 34
 (徐自祥, 周德云, 罗奕然. 基于主成分的模糊神经网络. *计算机工程与应用*, 2006, 42(5): 34)
- [14] Chaudhury A, Khatirkar R, Viswanathan N N, et al. Low silicon non-grain-oriented electrical steel: linking magnetic properties with metallurgical factors. *J Magn Magn Mater*, 2007, 313(1): 21
- [15] Liu D, Lei H, Wang T L, et al. Thermodynamics of deoxidation equilibrium with Al in liquid iron at 1873 K. *J Mater Metall*, 2015, 14(2): 96
 (刘达, 雷洪, 王天龙, 等. 关于 1873 K 下铁液中铝脱氧平衡热力学的讨论. *材料与冶金学报*, 2015, 14(2): 96)
- [16] Zhai G M, Liu X L. Production practice of IF steel in RH furnace. *Steelmaking*, 2009, 25(5): 5
 (翟高民, 刘相林. RH 处理 IF 钢的操作实践. *炼钢*, 2009, 25(5): 5)
- [17] Li X C, He P, Wang F, et al. Study on temperature drop in RH refining process. *Res Iron Steel*, 2010, 38(5): 13
 (李相臣, 何平, 王峰, 等. RH 精炼过程温降规律的研究. *钢铁研究*, 2010, 38(5): 13)
- [18] Wu Y, Ni H W, Zhang H, et al. Development of liquid temperature prediction model in RH-MFB refining process. *Spec Steel*, 2014, 35(3): 8
 (吴扬, 倪红卫, 张华, 等. RH-MFB 精炼时钢水温度预报模型的开发. *特殊钢*, 2014, 35(3): 8)