

基于灰色 Elman 神经网络转炉吹氧量的预测

张子阳 孙彦广

(中国钢研科技集团有限公司冶金自动化研究设计院 北京 100071)

摘要 钢铁企业转炉动态吹炼的过程复杂,其冶炼过程中存在的非线性问题导致消耗的氧气量难以准确估量造成能源浪费。传统方法不能准确预测,一些简单的神经网络预测的精度较低。为了提高预测效果,提出采用灰色 Elman 神经网络来建立转炉吹氧量预测模型。通过优化权值和阈值,解决普通的神经网络局部最优和过拟合等问题。结合转炉炼钢用氧的特点对实际生产数据进行仿真计算,预测用氧量的平均误差为 334 m^3 ,远小于 BP 神经网络预测用氧量的平均误差 976 m^3 。结果显示所建立的预测模型可有效快捷地确定转炉吹氧量,验证方法是有效的,具有更高的预测精度。

关键词 转炉用氧量 灰色 Elman 神经网络 预测 高精度

中图分类号 TP319 文献标识码 A DOI:10.3969/j.issn.1000-386x.2018.11.016

PREDICTION OF OXYGEN AMOUNT IN CONVERTER BASED ON GREY ELMAN NEURAL NETWORK

Zhang Ziyang Sun Yanguang

(Automation Research and Design Institute of Metallurgical Industry, China Iron & Steel Research Institute Group, Beijing 100071, China)

Abstract The process of dynamic blowing of converters is complex in iron and steel companies. The non-linear problems in the smelting process make it difficult to accurately estimate the amount of oxygen consumed, which causes energy waste. Traditional methods cannot accurately predict, and some simple neural network predictions have lower accuracy. In order to improve the prediction accuracy, we proposed a prediction model of oxygen amount in converter based on gray Elman neural network. The problems such as local optimality and overfitting of ordinary neural networks were solved by optimizing the weights and enthalpy values. Combined with the characteristics of oxygen in converter steelmaking, the simulation was carried out with actual production data. The average error of predicted oxygen consumption was 334 m^3 , which was much less than that of oxygen consumption predicted by BP neural network which was 976 m^3 . The results show that the established prediction model can efficiently and quickly determine the oxygen amount in converter. The method is verified to be effective and has higher prediction accuracy.

Keywords Oxygen amount in the converter Grey Elman neural network Prediction High precision

0 引言

转炉炼钢用氧过程是冶炼过程中重要的环节,直接影响着最终钢水的质量。氧气顶吹转炉炼钢是从转炉顶部吹入一定压力的氧气,与转炉内的铁水发生反应,铁水中的碳、硅、磷、硫等元素在高温的情况下剧烈

反应,实现降碳和脱除磷、硫等铁水中的杂质元素。其优点是生产效率高、节约能源和冶炼周期短等。转炉炼钢技术不断提高,20 世纪 50 年代转炉钢仅占世界钢产量的 1%,到 20 世纪 90 年代转炉钢所占比例为 59.3%,如今已经达到了 90% 以上^[1]。由于转炉炼钢冶炼生产环境复杂、转炉内反应变化快、影响吹氧量的因素较多,因此,转炉炼钢用氧量的有效预测为提高氧

气的利用率、增加冶炼的稳定性提供了重要的指导。

转炉用氧量预测的关键是建立合适的模型,选择合适供氧方式有助于增加氧气系统的稳定性^[2]。许多学者在这领域进行了多方面的研究,通过支持向量机、BP 神经网络和极限学习机等方法进行预测建模。例如:文献[3]通过支持量机的参数寻优提高转炉炼钢用氧量模型的预测精度;文献[4]针对钢铁企业氧气系统建立最小二乘支持向量机预测模型和调度模型;文献[5]运用 BP 神经网络算法建立多影响因素的钢铁企业氧气用量预测模型;文献[6]采用极限学习机来建立耗氧量预测模型的方法获得了较好的精度。上述方法对转炉吹氧量预测都取得了一定的效果,其中部分研究采取单一建模,由于模型自身的局限性、对原始数据的反映角度以及提取的目标不同,造成预测精度较低。预测模型中与实际炼钢机理深度结合不够,缺少对转炉运行方式的阶段性考虑导致模型预测误差较大,在预测的效果上仍有很大的提升空间。

本文在以往的研究基础上提出灰色神经网络的模型。该组合模型全局搜索能力较强,同时对网络进行优化,并且加入了适当的算子,增强了搜索局部最优解和全局最优解的能力,并将该模型应用于炼钢用氧系统对其预测性能进行验证。

1 转炉炼钢用氧的过程

转炉炼钢用氧过程中,根据不同的炉型用不同型号的氧枪吹入氧气,依据供氧制度在熔池中氧气与碳、硅、磷、硫等元素反应,达到钢水要求的程度,同时释放热量使溶液的温度升高。转炉炼钢过程中所需原料分为主原料和辅原料,其中主原料为废钢和铁水,辅原料为氧气、石灰、铁矿石、白云石等^[7,9]。在钢水吹炼之前,需要对特定铁水的总用氧量进行估算,当吹炼用氧量为估算值的 85% 左右时,通过氧枪副枪检测熔池碳含量、熔池温度与特定钢水标注比较,决定补吹氧气量和补加冷却剂量,最终得到符合要求的钢水^[10-11]。

转炉炼钢的操作过程主要由装料、吹炼、测温、取样、出钢、除渣等构成。冶炼过程中元素反应复杂^[12],氧气转炉炼钢的吹炼过程分为三期:

(1) 吹炼前期:在前期铁水中硅、锰元素含量较高,熔池中的硅、锰元素被快速氧化,小部分碳元素同时氧化,正常情况下吹碳速度与时间成正比。即:

$$r_c = -\frac{d\omega[C]_{\%}}{dt} = k_1 t \quad (1)$$

式中: t 为吹炼时间,单位为 min; k_1 为吹炼系数,与铁水中的硅含量、铁水温度和吹炼条件等因素有关。

(2) 吹炼中期:在中期阶段熔池中硅、锰元素含量较少,随着熔池中温度和 FeO 含量升高,碳的反应不断加剧,脱碳速度主要取决于供氧强度。吹碳中期脱碳反应速度表示为:

$$r_c = -\frac{d\omega[C]_{\%}}{dt} = k_2 I_{O_2} \quad (2)$$

式中: k_2 为吹炼系数,与枪位等因素有关; I_{O_2} 为供氧强度,单位为 $m^3(t \cdot \min)^{-1}$ 。

(3) 吹炼末期:此期间由于碳的含量降低,脱碳速度随之下降,吹炼后期的脱碳速度可以表示为:

$$r_c = -\frac{d\omega[C]_{\%}}{dt} = k_3 \omega[C]_{\%} \quad (3)$$

式中: k_3 为吹炼系数,与枪位等因素有关。

2 预测模型

转炉炼钢通过氧气吹炼降低铁水中部分元素的质量分数,静态模型是计算用氧量的基础。静态模型主要有机理模型、统计模型和增量模型等,其模型需要考虑的因素较多、存在较大的误差,实际分析困难。在冶炼过程中仅通过机理模型进行吹氧量的预测不够精确,调整模型参数不及时使得误差变化大,预测的效率低。而智能模型更准确解决炼钢过程中的非线性问题,可以通过数学方程描述,精度较高。通过适当的模型来预测转炉炼钢吹炼过程的吹氧量,指导炼钢生产,提高氧气的利用率。

2.1 灰色神经网络模型

灰色模型(GM)是对影响因素较多的系统进行分析预测有效的手段。通过对原始的数据序列累加计算,把计算后数据序列中的规律性予以展现,根据数据处理推断现实规律,利用曲线拟合得到新的时间序列。设时间数据序列为:

$$x^{(0)} = (x_1^{(0)}, x_2^{(0)}, \dots, x_n^{(0)})$$

根据灰色预测法的定义,首先对 $x^{(0)}$ 进行累加,其结果仍为时间序列,记为 $x^{(1)}$:

$$x^{(1)} = (x_t^1 | t = 1, 2, \dots, n)$$

$x^{(1)}$ 可以用白化方程表示为:

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = b_1 y_2 + b_2 y_3 + \dots + b_{n-1} y_n \quad (4)$$

式中: $a \in (-2, 2)$ 为发展系数, y_1, y_2, \dots, y_n 为灰色预测模型输入参数,该模型为 GM(1,1) 模型。令 $u = b_1 y_2 + b_2 y_3 + \dots + b_{n-1} y_n$, 通过 a 和 u 即可求出 $x^{(1)}$ 。

式(4)的时间响应表达式为:

$$z(t) = \left[y_1(0) - \frac{b_1}{a} y_2(t) - \frac{b_2}{a} y_3(t) - \dots - \frac{b_{n-1}}{a} y_n(t) \right] e^{-at} +$$

$$\frac{b_1}{a}y_2(t) + \frac{b_2}{a}y_3(t) + \dots + \frac{b_{n-1}}{a}y_n(t)$$

$$\text{令 } c = \frac{b_1}{a}y_2(t) + \frac{b_2}{a}y_3(t) + \dots + \frac{b_{n-1}}{a}y_n(t)$$

标准化为:

$$z(t) = \left[(y_1(0) - c) - (y_1(0) - 2c) \frac{1}{e^{-at} + 1} \right] (e^{-at} + 1) \quad (5)$$

BP 神经网络在预测方面应用广泛^[14-15],采用 Elman 神经网络,其具有映射动态特征的功能与灰色预测模型时变特征对应。如图 1 所示,Elman 神经网络包括输入层、隐含层、输出层和承接层。每层神经元通过权值和阈值连接,层内或层间通过连接层进行反馈联结,承接层记忆隐含层前一时刻的输出,可以作为一个延时算子,承接层的存在使 Elman 神经网络具有动态特性。




图 1 Elman 神经网络结构图

数学模型可以表示为:

$$\begin{cases} y(k) = g(w^3x(k)) \\ x(k) = f(w^1x_c(k)) + w^2(u(k-1)) \\ x_c(k) = x(k-1) \end{cases} \quad (6)$$

式中: $g(\cdot)$ 为线性函数; $f(\cdot)$ 为神经网络的阈值函数,表示为 $f(\cdot) = \frac{1}{1 + e^{-x}}$ 。

映射后的灰色 Elman 神经网络模型由多个不同的影响因素作为输入,输出为目标预测量。通过灰色模型的确定性信息对神经网络进行修正,根据模型输入输出的模拟值与实际值的绝对误差进行训练,从而改进神经网络预测模型。

2.2 灰色神经网络模型预测算法

当转炉炼钢受到多因素的影响时,吹氧量的数据会产生一定波动,通过 GM 模型降低干扰因素的影响,样本的数据逐渐递增。Elman 神经网络通过自联方式处理历史数据,在动态建模的过程中,运用反馈网络,使得处理动态信息的效率有效提升。将 GM 模型与 Elman 神经网络相结合,对转炉吹氧量数据样本进行预测,减少随机干扰的影响。根据灰色理论在处理不确定性问题的优势,结合神经网络进行预测,综合二者

的模型的特点,得到预测值进行训练学习。通过修正网络进行拟合提高转炉炼钢预测精度的目的。灰色 Elman 神经网络算法流程如图 2 所示。

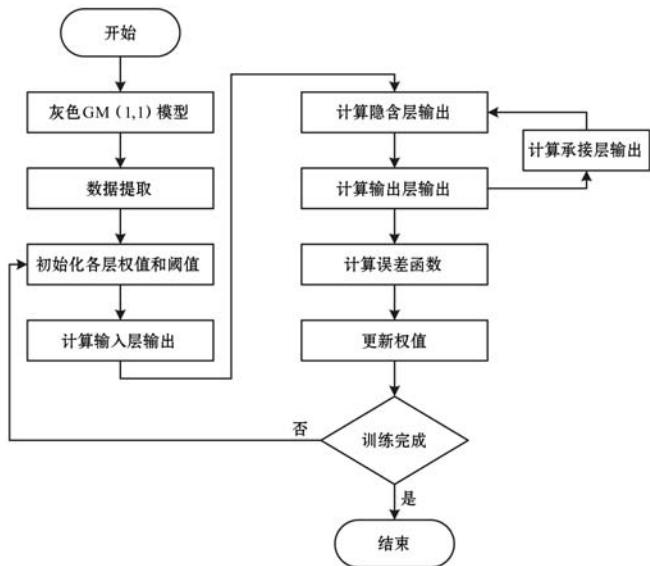


图 2 灰色 Elman 神经网络算法流程图

灰色 Elman 神经网络预测算法具体步骤如下:

- (1) 首先将数据归一化,并进行累加计算,确定发展系数 a 和灰色作用量 u 。
- (2) 确定各层的权值和阈值, Q 个隐含层神经元对应的阈值为:

$$b_1 = [b_{11}, b_{12}, \dots, b_{1Q}]'$$

式中: $b_{11} = b_{12} = \dots = b_{1Q} = \frac{0.8326}{spread}$, $spread$ 为径向基函数的扩展速度。

- (3) 计算输入层、输出层和隐含层输出,同时承接层对隐层单元的输出值进行记忆,反馈给隐层单元。
- (4) 计算误差函数和权值更新,神经元对应的的权值和阈值更新方式如下:

$$\begin{aligned} IW_k^{1,1} &= IW_k^{1,1} + \alpha(p - IW_k^{1,1}) \\ b_1 &= e^{1 - \log[(1 - \beta)e^{1 - \log(b)} + \beta \times a^1]} \end{aligned}$$

式中: $IW_k^{1,1}$ 为初始连接权值, $IW_k^{1,1}$ 是 $IW^{1,1}$ 的第 k 行; b_1 为初始阈值; α 为权值的学习速率; β 为阈值的学习速率; a^1 作为输出可以表示为 $a^1 = [a_1^1, a_2^1, \dots, a_i^1], i = 1, 2, \dots, n$ 。

- (5) 训练结束判断,若训练不满足条件则返回步骤 2,当神经元间权值确定后训练结束。

3 模型应用与分析

3.1 模型的输入输出数据选择

某钢铁联合有限公司采用“一罐到底”作业方式,根据其转炉流程特点、操作经验和相关性分析确定输

入变量为九个影响因素。由于采取搅拌脱硫的方式,S元素对氧气使用量的影响较小,没有将其作为输入影响因素,具体输入变量如表 1 所示。输入因素之间相互影响,同时数据维数较多,输入变量对吹氧量预测模型的准确性有直接影响。由于部分检测设备的稳定性差和一些非线性因素的影响,使得在现场实际采集的数据存在一定的数据丢失、归零和偏差等现象,不满足转炉吹氧量预测的要求,造成模型的泛化能力弱、预测准确性低的情况,需要对数据进行预处理以提高预测精度。本文删除转炉部分丢失、归零和偏差等数据然后进行预测分析。

表 1 模型的输入

输入	因素 1	因素 2	因素 3	因素 4	因素 5	因素 6	因素 7	因素 8	因素 9
名称	铁水量	废钢量	铁水温度	初始 C%	硅含量	锰含量	磷含量	终点 C%	出钢温度

3.2 模型预测分析

根据现场采集的不同钢种的转炉炼钢的历史数据,获得 109 组炼钢信息。将其中 100 组数据进行训练,9 组数据测试样本,通过灰色理论数据累加,将累加后的结果进行 Elman 神经网络训练,在 Elman 神经网络的网络层中的反馈节点存储前一时段的数据,用来计算当前时刻的数值。灰色 Elman 神经网络预测参数设置为:输入层神经元个数为 8 个;中间层传递函数为 tansig;输出层有 1 个神经元,其传出函数为 logsig;训练步数为 1 000,训练函数使用 trainlin,误差为 0.001。吹氧量预测结果如图 3 所示。




图 3 灰色 Elman 神经网络吹氧量预测结果

BP 神经网络预测结果与灰色 Elman 神经网络用氧量预测结果如图 4 所示。通过建立单一 BP 神经网络模型对比分析,灰色 Elman 神经网络模型在性能上

比 BP 神经网络要好,预测效果效果稳定,预测精度高。




图 4 两个模型吹氧量预测结果

BP 神经网络模型与灰色 Elman 神经网络模型用氧量预测误差如图 5 所示。灰色 Elman 神经网络模型预测用氧量误差大部分低于 BP 神经网络预测,灰色 Elman 神经网络用氧量预测的误差范围在 0 ~ 750 m³ 之间,预测用氧量的平均误差 334 m³。而 BP 神经网络预测的用氧量误差范围在 500 ~ 3 000 m³ 之间,用氧量的平均误差 976 m³,不满足实际的氧气要求。BP 神经网络模型预测最大误差是 20.00%,最小误差 0.40%,灰色 Elman 神经网络模型最大误差是 5.36%,最小误差 0.08%,其预测结果拟合精度明显提高。




图 5 两个模型用氧量预测误差

用均方误差 (RMSE) 与平均绝对百分比误差 (MAPE) 来评价模型的精度。两种模型的预测效果对比如表 2 所示。

表 2 两种模型的预测效果对比

模型	RMSE	MAPE
BP 神经网络	2 930	0.069
灰色 Elman 神经网络	323	0.024

从分析结果可以看出,灰色 Elman 神经网络模型均方误差 (RMSE) 与平均绝对百分比误差 (MAPE) 均达到了较好的效果,预测效果好于 BP 神经网络模型。灰色 Elman 神经网络模型预测结果更可靠,预测值曲线趋近实际值曲线,对炼钢生产合理用氧、提高生产效率有着一定的指导作用。

4 结 语

本文建立了灰色 Elman 神经网络用氧量模型,将灰色模型和 Elman 神经网络相结合,对影响转炉用氧量的多个因素分析后进行预测。灰色 Elman 神经网络预测比利用单一预测模型进行预测的精度要高。在进行预测时,使用与用氧量关联度大的因素作为输入层,输入数据尽量精简,才能有效地提高预测精度;利用 Elman 反馈神经网络非线性计算特点,能够较好地拟合预测复杂情况下的非线性预测问题,发挥其反映系统动态特性的能力,减少了单一的 BP 神经网络模型误差稳定性差的缺陷,所得到的预测值与期望值基本一致。模型具有很好的预测精度和稳定性,为钢铁企业制定氧气生产计划,提高氧气利用率以及其他技术气体的合理利用等提供重要的理论依据。

参 考 文 献

- [1] 罗丽军,喻中心. 国内转炉炼钢生产现状及技术应用[J]. 宽厚板,2014,20(1): 39-42.
 - [2] 楼磊. 空分变负荷联产调度问题研究[D]. 杭州: 浙江工业大学,2014.
 - [3] 秦波,吴庆朝,张娟娟,等. 基于 PSO 优化 SVM 的转炉炼钢用氧量预测研究[J]. 测控技术,2014,33(12): 121-124.
 - [4] 吴佩林. 钢铁企业氧气预测与优化调度模型研究[D]. 昆明: 昆明理工大学,2013.
 - [5] 胡云芝,张延平,胡帅. MATLAB 神经网络模型预测钢铁企业氧气用量[C]//冶金循环经济发展论坛论文集. 北京: 首钢技术研究院,2008: 247-248.
 - [6] 赵辉,易晓敏,王红君,等. 转炉炼钢耗氧量预测模型研究[J]. 计算机仿真,2017,34(1): 380-383.
 - [7] 张俊杰. 转炉炼钢过程脱磷和吹氧模型的研究[D]. 大连: 大连理工大学,2009.
 - [8] Han M, Li Y. Hybrid intelligent control of BOF oxygen volume and coolant addition[J]. Neurocomputing, 2014, 123: 415-423.
 - [9] Gesing A J, Das S K. A process model for basic oxygen furnace (BOF) steel converter is in development[J]. Metallurgical and Materials Transactions B, 2017, 48(1): 619-631.
 - [10] 刘畅,张颜颜. 一种转炉炼钢过程中的软测量方法[J]. 控制工程,2016(9): 1312-1318.
 - [11] 吕延春,王新华,朱国森,等. 基于多功能转炉炼钢法的连续循环冶炼过程[J]. 工程科学学报,2016(3): 335-341.
 - [12] Yin Z H, Yu C F, Guo Z H. Sublance of converter steelmaking process calculation model[J]. Smart Factory, 2016(9): 93-96.
 - [13] 卢雅青. 炼钢转炉副枪控制系统的优化[D]. 呼和浩特: 内蒙古大学,2016.
 - [14] 孙晨,李阳,李晓戈,等. 基于布谷鸟算法优化 BP 神经网络模型的股价预测[J]. 计算机应用与软件,2016,33(2): 276-279.
 - [15] 马正华,王腾,杨彦,等. BP 神经网络模型在太湖出入湖河流水质预测中的应用[J], 计算机应用与软件,2013,30(11): 172-175.
- ~~~~~
- (上接第 88 页)
- [21] Christoforaki M, He J, Dimopoulos C, et al. Text vs. space: efficient geo-search query processing[C]//ACM International Conference on Information and Knowledge Management. ACM, 2011: 423-432.
 - [22] Li Z, Lee K C K, Zheng B, et al. IR-tree: an efficient index for geographic document search[J]. IEEE Transactions on Knowledge & Data Engineering, 2011, 23(4): 585-599.
 - [23] 廖浩均,韩冀中,方金云. 空间数据库中全局最近邻查询处理方法[J]. 计算机研究与发展,2011,48(1): 86-93.
 - [24] Xie X, Lin X, Xu J, et al. Reverse keyword-based location search[C]//IEEE, International Conference on Data Engineering. IEEE, 2017: 375-386.
 - [25] Zhang D, Tan K L, Tung A K H. Scalable top-k spatial keyword search[C]//International Conference on Extending Database Technology. ACM, 2013: 359-370.
 - [26] Rochajunior J B, Gkorgkas O, Jonassen S, et al. Efficient processing of top-k spatial keyword queries[M]//Advances in Spatial and Temporal Databases. Springer Berlin Heidelberg, 2013: 205-222.
 - [27] Wu D, Cong G, Jensen C S. A framework for efficient spatial web object retrieval[M]. Springer-Verlag New York, Inc. 2012.
 - [28] Aizawa K, Motomura K, Kimura S, et al. Constant time neighbor finding in quadtrees: An experimental result[C]//International Symposium on Communications, Control and Signal Processing. IEEE, 2008: 505-510.
 - [29] Bao J, Zheng Y, Mokbel M F. Location-based and preference-aware recommendation using sparse geo-social networking data[C]//International Conference on Advances in Geographic Information Systems. ACM, 2012: 199-208.
 - [30] Wei L Y, Zheng Y, Peng W C. Constructing popular routes from uncertain trajectories[C]//ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2012: 195-203.