

研究论文

竖炉燃烧过程智能故障预报系统

严爱军¹, 王 普¹, 曾 宇²

(¹ 北京工业大学电子信息与控制工程学院, 北京 100124; ² 北京华深科技发展有限公司, 北京 100086)

摘要: 赤铁矿竖炉燃烧过程机理复杂, 运行工况变化频繁, 使得故障易发, 从而导致生产不稳定。将案例推理和软测量技术相结合, 提出一种竖炉燃烧过程的智能故障预报方法。软测量模型对难以在线测量的关键工艺参数进行实时测量, 基于案例检索与重用的故障预报模型根据过程数据及关键工艺参数软测量值的变化对燃烧过程的典型故障进行趋势预报, 采用概率的形式表达诊断结果, 并提供操作指导, 可以有效避免故障的发生。将建立的故障预报系统应用于竖炉燃烧过程的生产实际中, 故障发生率明显降低, 表明了方法的有效性。

关键词: 燃烧过程; 故障预报; 案例推理; 软测量

中图分类号: TP 277

文献标识码: A

文章编号: 0438-1157 (2008) 07-1768-05

Intelligent fault prediction system of combustion process in shaft furnace

YAN Aijun¹, WANG Pu¹, ZENG Yu²

(¹ College of Electronic Information & Control Engineering, Beijing University of Technology, Beijing 100124, China; ² Beijing Huashen Science & Technology Development Co., Ltd., Beijing 100086, China)

Abstract: Due to its synthetic and complex characteristics, the combustion process in the hematite ore-filled shaft furnace is noted for complex mechanism and frequent change of operating conditions, which results in frequent occurrence of faults and unsteady production. In order to reduce the faults ratio during the combustion process, an intelligent faults prediction approach was developed based on the combination of case-based reasoning (CBR) with soft-sensing. The soft-sensing model could estimate the key technical parameters which were difficult to measure online, and provide some information about the faults. Then, the fault prediction model based on case retrieval and reuse was adopted to make a thorough analysis on the combustion process. The model could provide the occurring probability of some typical faults, followed by corresponding operation instructions. The proposed fault prediction system was applied to the practical combustion process in a shaft furnace, and evidently eliminated the fault ratio.

Key words: combustion process; fault prediction; case-based reasoning; soft-sensing

引 言

赤铁矿竖炉焙烧工序主要由给矿、燃烧及高温还原等子过程组成^[1]。其中, 燃烧过程的运行情况对于竖炉焙烧工序的工艺指标有着重要影响, 一

旦发生了故障, 将会严重影响竖炉焙烧整个工序的生产, 使竖炉的工作状态进入严重不稳定甚至停滞状态, 因此故障诊断是能够保证竖炉焙烧稳定控制的前提, 还对控制焙烧的整体过程起到理想的先导作用。

2008-04-14 收到初稿, 2008-04-23 收到修改稿。

联系人及第一作者: 严爱军 (1970—), 男, 博士, 讲师。

基金项目: 北京工业大学博士科研启动基金项目 (52002017200701)。

Received date: 2008-04-14.

Corresponding author: Dr. YAN Aijun. E-mail: yanaijun@bjut.edu.cn

Foundation item: supported by the Scientific Research Foundation for the Doctor of Beijing University of Technology (52002017200701).

近年来,人工智能技术渗透到了故障诊断领域^[2-3],这些智能诊断方法的一个共同点是不依赖于被诊断对象的机理模型,避免了基于解析模型故障诊断方法^[4]的固有缺陷。例如,神经网络以其强有力的学习和并行处理能力为故障诊断提供了全新的理论方法和实现手段^[5];基于知识的方法不依赖于对象的精确数学模型,因而在复杂过程的故障诊断领域得到了广泛重视^[6-7],这些方法均表现出一定的快速性和有效性。但神经网络方法存在着训练样本获取困难的问题,传统专家系统在知识获取、推理能力等方面也存在一定的缺陷,并且竖炉燃烧过程复杂多变,使得神经网络与专家系统方法难以胜任此过程的故障诊断。人工智能领域中的案例推理方法^[8-9]适用于没有很强理论模型和领域知识不完全、难以定义或定义不一致而经验丰富的决策环境与对象中,将案例推理技术应用于故障诊断,丰富了故障诊断方法的研究^[10]。上述提到的故障诊断主要集中在发生故障以后的处理和识别研究层面,而对竖炉燃烧过程控制而言,一般不允许发生故障,故需要对燃烧过程的故障趋势进行预报并提供操作指导,以避免故障的发生,而此问题的研究与应用还少有报道。

本文针对竖炉燃烧过程机理复杂以及故障频发导致生产不稳定的问题,在分析燃烧过程故障机理的基础上,发挥案例推理技术的优势,提出了竖炉燃烧过程智能故障预报方法,讨论了其结构原理及算法实现。将建立的智能故障预报系统应用于竖炉燃烧过程,表明提出方法的有效性。

1 燃烧过程故障描述

赤铁矿竖炉的主要功能是通过煤气的燃烧产生炽热的炉气,使给矿过程输送来的赤铁矿石温度升高,在高温下使弱磁性赤铁矿发生化学反应还原成强磁性矿物,然后通过冷却搬出过程将焙烧矿冷却并按一定的搬出制度将其排出炉外。图1虚线框内所示的是燃烧过程。加热煤气和加热空气混合燃烧后产生热量,使燃烧室温度处于工艺要求的范围内 $[(1100 \pm 50)^\circ\text{C}]$ 。

竖炉燃烧过程中,有4种最常见也是对稳定生产影响最大的故障,分别是上火 y_1 、冒火 y_2 、放炮 y_3 和炼炉 y_4 (见图1),通过对焙烧过程的机理分析,采用主元分析法(principal component analysis, PCA)^[11]和粗糙集理论的属性约简方

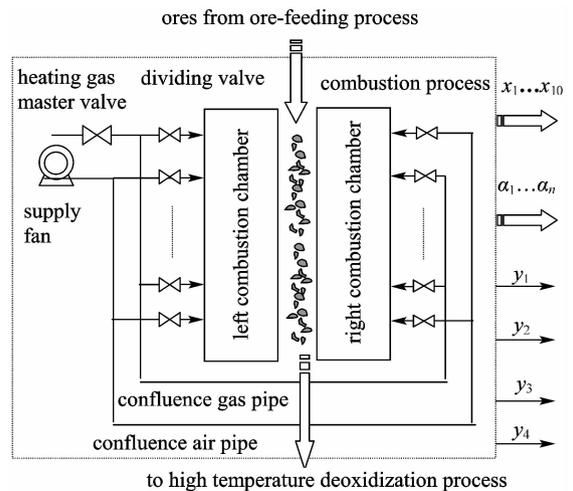


图1 竖炉燃烧过程

Fig. 1 Combustion process in shaft furnace

$x_1 \cdots x_{10}$ —process variables; $a_1 \cdots a_n$ —design parameters;
 y_1 —backfire: fire enters gas pipes; y_2 —flames reach out of top of furnace;
 y_3 —iron ores inside furnace explode;
 y_4 —iron ores melted and stick to firebricks in furnace

法^[12],确定直接影响以上4种故障的过程变量(或关键工艺参数)是

$$(y_1, y_2, \cdots, y_4) = f(x_1, x_2, \cdots, x_{10}; a_1, a_2, \cdots, a_n) \quad (1)$$

其中, $x_1 \sim x_{10}$ 分别表示加热煤气流量、加热空气流量、加热煤气热值、加热煤气压力、炉膛负压、燃烧室温度、还原煤气流量、搬出时间、还原带温度和磁选管回收率(magnetic tube recovery rate, MTRR)过程参量; $a_1 \sim a_n$ 表示竖炉的众多设计参数,这些参数均是时间的函数。式(1)是一个结构参数未知的非线性方程,具有综合复杂性,表现在:竖炉的设计参数大都偏离设计值,机理模型建立很困难;每种故障由参数变化不合理所致,而且每个参数的变化也有可能诱发多种故障,存在着强耦合关系;对故障种类及征兆有着重要影响的关键工艺参数如还原带温度 x_9 、磁选管回收率 x_{10} 不易在线连续测量。这些复杂因素的存在给基于解析模型的故障预报带来了不利影响。同时,领域知识的不完整、样本数据的难以获取给智能方法的应用也提出了挑战。

2 故障预报系统

2.1 系统结构与功能

本文提出基于案例推理的方法实现故障的预测。图2给出了将过程参量软测量技术与案例推理相集成的智能故障预报系统的结构原理。主要功能

是：来自分布式控制系统（distributed computer control systems, DCS）的参量 $x_5 \sim x_8$ 和 $x_{11} \sim x_{13}$ 作为软测量模型的辅助变量，用于对还原带温度和磁选管回收率进行实时估计与测量^[13-14]，得到 x_9 和 x_{10} ，然后其他参量 $x_1 \sim x_8$ 一起组成当前的燃烧工况描述，采用案例推理的方法，对存储在历史案例库中以往故障的判断案例进行检索与重用，得到以概率形式表示的 4 种典型故障的趋势预报 $y_1 \sim y_4$ ，并将结果存储在历史案例库中，供下一次的故障趋势预报之用。

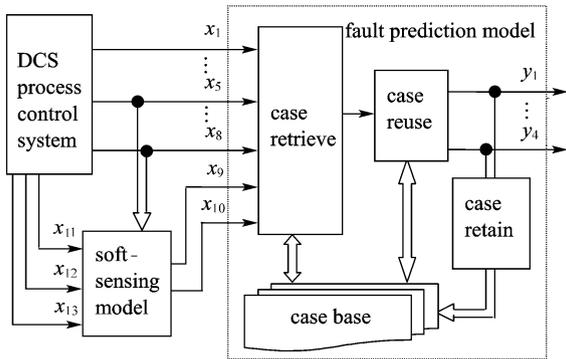


图 2 智能故障预报系统的结构

Fig. 2 Structure of intelligent fault prediction system

x_{11} —ore sort; x_{12} —roasting degree; x_{13} —ore granularity

2.2 算法实现

还原带温度和磁选管回收率的软测量模型采用 RBF 神经网络实现，算法如下所列，各符号的意义及其他更为详细的阐述见文献 [13-14]。

$$\omega_i(n+1) = \omega_i(n) - \eta_j \sum_{j=1}^N e_j(n) G(\|x_j - t_i(n)\|) \quad (2)$$

$$t_i(n+1) = t_i(n) -$$

$$\eta_j \omega_i(n) \sum_{j=1}^N e_j(n) G'(\|x_j - t_i(n)\|) \Sigma_i^{-1}(n) [x_j - t_i(n)] \quad (3)$$

$$\Sigma_i^{-1}(n+1) = \Sigma_i^{-1}(n) -$$

$$\eta_j \omega_i(n) \sum_{j=1}^N e_j(n) G'(\|x_j - t_i(n)\|) [x_j - t_i(n)]^T \quad (4)$$

$$\begin{cases} E = \frac{1}{2} \sum_{j=1}^N e_j^2 \\ e_j = d_j - \sum_{i=1}^m \omega_j G(\|x_j - t_i\|) \end{cases} \quad (5)$$

按给出的算法及统计过程控制（statistical process control, SPC）^[15] 机制得到还原带温度和磁选管回收率的软测量值 x_9 和 x_{10} 。

通过上述处理与计算，可以得到所需要的完整

过程参量 $x_1 \sim x_{10}$ ，当前的燃烧工况输入描述就由这些参量值表示。最后采用案例推理的方法实现分析与处理过程，具体方法如下。

图 2 中的历史案例库由竖炉燃烧过程以往发生故障时的经验案例组成，其中的每条案例记录 $C_k (k=1, 2, \dots, q)$ 包括燃烧工况描述 X_k 和相应的解 Y_k ，可表示为

$$C_k = (X_k; Y_k), k = 1, 2, \dots, q \quad (6)$$

其中， q 是案例总数； $X_k = (x_{1,k}, x_{2,k}, \dots, x_{10,k})$ ； $Y_k = (y_{1,k}, y_{2,k}, \dots, y_{4,k})$ ，故障种类的解 $y_{1,k} \sim y_{4,k}$ 的取值范围均是 $[0, 1]$ ，表示 4 种故障各自发生的概率。

设当前的燃烧工况描述是 $X = \{x_i\} (i=1, \dots, 10)$ ，它与每一条案例记录 C_k 的相似度定义如下

$$\text{sim}(X, C_k) = \sum_{i=1}^{10} \epsilon_i (1 - \frac{|x_i - x_{i,k}|}{\max(x_i, x_{i,k})}) \quad (7)$$

其中， ϵ_i 是权值系数，满足

$$\sum_{i=1}^{10} \epsilon_i = 1 \quad (8)$$

设相似度的阈值是 sim_v ，经过图 2 中的案例检索，设检索出的匹配案例个数为 l ，这些匹配案例的相似度是 θ_k

$$\begin{cases} \theta_k = \text{sim}(X, C_k), k = 1, 2, \dots, l \\ \text{s. t } \text{sim}(X, C_k) \geq \text{sim}_v \end{cases} \quad (9)$$

经过图 2 中的案例重用，对当前炉内燃烧状况的判断结果 $Y = (y_1, y_2, \dots, y_4)$ 可表示为

$$y_i = \left(\sum_{k=1}^l \theta_k y_{i,k} \right) / \sum_{k=1}^l \theta_k \quad (10)$$

其中， $y_{i,k}$ 是历史案例库中相应于匹配案例的解。将此次案例推理的结果保存到案例库中，用于下一次的故障判断与趋势预报。

综上，对炉内燃烧状况诊断与趋势预报的实现方法是按式 (2) ~ 式 (5) 确定的算法对还原带温度和磁选管回收率进行实时测量，再综合 DCS 过程控制系统提供的其他参量，按式 (6) ~ 式 (10) 所表示的案例推理算法得到炉内燃烧状况的诊断结果，并提供操作指导。

3 工业应用

竖炉燃烧过程中，导致故障频发影响生产稳定性的最根本原因是没有实用可靠的故障预报系统，完全是依赖于操作员的经验知识来判断炉内燃烧状况并采取相应的操作，不仅劳动强度很大，更不利于安全生产，制约了竖炉焙烧工序的产品质量与产

量的提高。

采用本文提出的方法，结合某选矿厂竖炉焙烧工序的实际，研发了基于 ControlLogix5000 计算机控制系统的故障预报系统，如图 3 所示。其中同故障预报相关的主要检测值，如流量计 FT1 检出的加热空气流量 f_1 、由流量计 FT2 检出的加热煤气流量 f_2 、由流量计 FT3 检出的还原煤气流量 f_3 、由热值仪 HT 检出的煤气热值 h 、由压力计 PT1 检出的加热煤气压力 p_1 、由压力计 PT2 检出的炉内负压 p_2 、由定时器 tT 测出的搬出时间 t 、由热电偶 TT 检出的燃烧室温度 T 等，由 DCS 过程控制系统进行数据处理后，燃烧过程故障预报系统接收 DCS 控制系统中的相关信息，并向 DCS 控制系统提供故障的判定结果与相关提示信息。

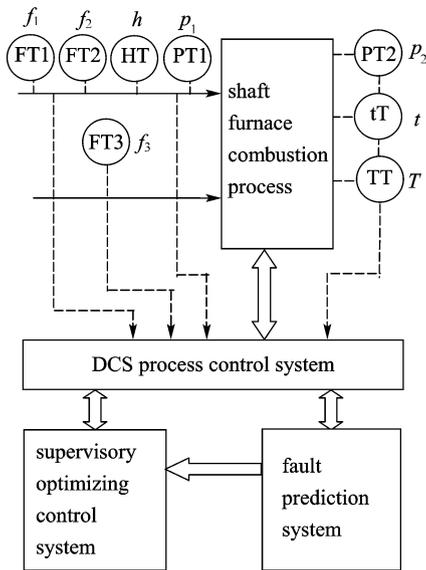


图 3 故障预报系统的应用

Fig. 3 Application of fault prediction system

FT—flowmeter; HT—calorimeter; TT—thermocouple;
PT—manometer; tT—calculagraph; f_1 —flow
of heating air; f_2 —flow of heating gas; f_3 —flow of
reducing gas; p_1 —pressure of heating gas;
 p_2 —negative press; h —heat value of heating gas;
 t —move out time; T —combustion temperature

燃烧过程的故障预报系统在应用实践中的一个典型处理过程是确定式 (8) 所定义的各权值分别为： $\epsilon_1 = 0.09$, $\epsilon_2 = 0.03$, $\epsilon_3 = 0.04$, $\epsilon_4 = 0.05$, $\epsilon_5 = 0.15$, $\epsilon_6 = 0.15$, $\epsilon_7 = 0.09$, $\epsilon_8 = 0.10$, $\epsilon_9 = 0.15$, $\epsilon_{10} = 0.15$ 。过程参量 $x_1 \sim x_{10}$ 的值分别为：加热煤气流量 $x_1 = 3941 \text{ m}^3 \cdot \text{h}^{-1}$ 、加热空气流量

$x_2 = 4137 \text{ m}^3 \cdot \text{h}^{-1}$ 、加热煤气热值 $x_3 = 4005 \text{ kJ} \cdot \text{m}^{-3}$ 、加热煤气压力 $x_4 = 2.91 \text{ kPa}$ 、炉膛负压 $x_5 = -2.35 \text{ kPa}$ 、燃烧室温度 $x_6 = 1179^\circ\text{C}$ 、还原煤气流量 $x_7 = 2126 \text{ m}^3 \cdot \text{h}^{-1}$ 、搬出时间 $x_8 = 5 \text{ min}$ 、还原带温度 $x_9 = 587^\circ\text{C}$ 、磁选管回收率 $x_{10} = 79.21\%$ 。通过计算得出预报结果：上火 $y_1 = 0.53$ 、冒火 $y_2 = 0.03$ 、放炮 $y_3 = 0.21$ 和炼炉 $y_4 = 0.73$ 。并通过操作指导画面提示操作员：当前燃烧温度较高，炉膛负压过低，发生故障的可能性由大至小依次是炼炉、上火、放炮和冒火，建议减少加热煤气供应量以降低温度，稍加快搬出时间。通过这样的处理过程后，就有可能将故障消灭在萌芽状态。

故障预报系统投入使用前后，燃烧过程的故障发生率（即发生故障的时间与生产运行时间之比）见图 4 和图 5。从图中可以看出，投入使用后虽然有漏报，但故障发生率已明显降低，最大限度地保证了生产的安全和连续性。实践证明，故障预报系统的预报准确率达到了 95% 以上，并且使得竖炉焙烧工序的各项指标得到了显著提高，取得了明显的效益。

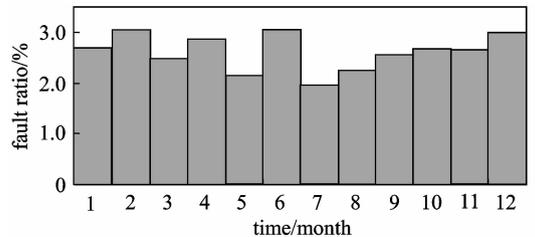


图 4 未投入预报系统时的故障发生率统计

Fig. 4 Fault ratio without fault prediction system

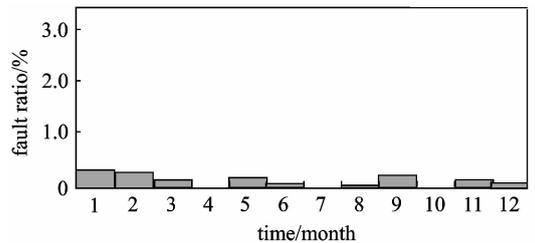


图 5 投入预报系统后的故障发生率统计

Fig. 5 Fault ratio with fault prediction system

4 结 论

本文将过程参量的软测量与案例推理技术相结合实现了竖炉燃烧过程的智能故障预报系统，对不易测量或测量滞后的关键工艺参数的实时软测量为故障的推理判断提供了特征参数，案例推理技术的

使用避免了建立故障诊断的机理模型,解决了专家系统及神经网络对知识和样本获取困难的问题,采用概率的形式表达诊断的结果更具合理性。该方法在诊断的适用性、准确性、智能性、鲁棒性方面比基于模型和基于知识的诊断模式更具有优越性,充分发挥了长期积累的经验案例的作用。应用于竖炉燃烧的生产实践中,大幅降低了故障发生率,明显提高了生产指标,在过程控制系统的稳定控制和稳定运行中发挥了重要作用,可推广应用于类似工业过程及大型工艺设备的故障诊断。

References

- [1] Yan Aijun (严爱军), Ding Jinliang (丁进良), Chai Tianyou (柴天佑). Integrated automation system for shaft furnace roasting process. *Control Engineering of China* (控制工程), 2006, **13** (2): 120-122
- [2] Awadallah M A, Morcos M M. Application of AI tools in fault diagnosis of electrical machines and drives—an overview. *IEEE Transactions on Energy Conversion*, 2003, **18** (2): 245-251
- [3] Korbicz J, Kowal M. Neuro-fuzzy networks and their application to fault detection of dynamical systems. *Engineering Applications of Artificial Intelligence*, 2007, **20** (5): 609-617
- [4] Simani S. Fault diagnosis of a simulated industrial gas turbine via identification approach. *International Journal of Adaptive Control and Signal Processing*, 2007, **21** (4): 326-353
- [5] Simani S, Fantuzzi C. Fault diagnosis in power plant using neural networks. *Information Sciences*, 2000, **127** (3): 125-136
- [6] Wu M, She J H, Nakano M, Gui W H. Expert control and fault diagnosis of the leaching process in zinc hydrometallurgy plant. *Control Engineering Practice*, 2002, **10** (4): 433-442
- [7] Qian Y, Li X, Jiang Y, Wen Y. An expert system for real-time fault diagnosis of complex chemical processes. *Expert Systems with Applications*, 2003, **24** (4): 425-432
- [8] Waheed A, Adeli H. Case-based reasoning in steel bridge engineering. *Knowledge-Based Systems*, 2005, **18** (1): 37-46
- [9] Zhao Jinsong (赵劲松), Zhao Lihua (赵利华), Cui Lin (崔林), Chen Mingliang (陈明亮), Qiu Tong (邱彤), Chen Bingzhen (陈丙珍). Case-based reasoning framework for automating HAZOP analysis. *Journal of Chemical Industry and Engineering (China)*(化工学报), 2008, **59** (1): 111-117
- [10] Lee S G, Ng Y C. Hybrid case-based reasoning for on-line product fault diagnosis. *International Journal of Advanced Manufacturing Technology*, 2006, **27** (7/8): 833-840
- [11] Lin D T. Facial expression classification using PCA and hierarchical radial basis function network. *Journal of Information Science and Engineering*, 2006, **22** (5): 1033-1046
- [12] Jensen R, Shen Q. Fuzzy-rough attribute reduction with application to web categorization. *Fuzzy Sets and Systems*, 2004, **141** (3): 469-485
- [13] Yan Aijun, Chai Tianyou, Wang Pu. Intelligent hybrid prediction method of reducing zone temperature in shaft furnace//Proceeding of the 2nd IEEE Conference on Industrial Electronics and Applications. Piscataway, United States: Institute of Electrical and Electronics Engineers Computer Society, 2007: 402-406
- [14] Yan Aijun (严爱军), Chai Tianyou (柴天佑). Intelligent hybrid prediction method of magnetic tube recovery rate. *Information and Control* (信息与控制), 2005, **34** (6): 759-764
- [15] Ye N, Parmar D, Borrer C M. A hybrid SPC method with the chi-square distance monitoring procedure for large-scale, complex process data. *Quality and Reliability Engineering International*, 2006, **22** (4): 393-402