

基于复合差分进化算法与极限学习机的高炉铁水硅含量预报

蒋朝辉[†], 尹菊萍, 桂卫华, 阳春华

(中南大学 信息科学与工程学院, 湖南 长沙 410083)

摘要: 针对铁水硅含量无法直接在线检测的问题, 本文提出了一种基于优化极限学习机(ELM)的高炉铁水硅含量预报方法. 该方法利用复合差分进化算法(CoDE)的快速定位全局最优解的能力来优化极限学习机的输入权值和隐层节点阈值, 在此基础上建立了基于复合差分进化算法优化极限学习机(CoDE-ELM)的高炉铁水硅含量预报模型. 以某钢铁厂2650 m³的高炉为例, 利用实际采集数据进行模型检验, 结果表明, 当绝对误差小于0.1时, 铁水硅含量的预报命中率为89%, 均方根误差为0.047, 实际目标值序列与预报值序列的相关系数为0.851. 所建模型的预报结果优于支持向量机(SVM)、前馈神经网络(BP-NN)、极限学习机以及差分优化极限学习机(DE-ELM), 对高炉炉温的实际调控具有较好的指导意义.

关键词: 铁水硅含量; 预报模型; 复合差分; 极限学习机

中图分类号: TP273 文献标识码: A

Prediction for blast furnace silicon content in hot metal based on composite differential evolution algorithm and extreme learning machine

JIANG Zhao-hui[†], YIN Ju-ping, GUI Wei-hua, YANG Chun-hua

(School of Information Science and Engineering, Central South University, Changsha Hunan 410083, China)

Abstract: Considering the silicon content of the hot metal cannot be directly detected online, a prediction method for silicon content in hot metal based on the optimized extreme learning machine (ELM) is proposed. The weights of inputs and thresholds of hidden nodes in the extreme learning machine are optimized by a composite differential evolution algorithm (CoDE) because of its ability of quickly locating the global optimum solution. With the optimized results, a prediction method based on the composite differential evolution extreme learning machine (CoDE-ELM) is established. The proposed method is verified by using the actual data on a 2650 m³ blast furnace of a steel plant. The verification results show that when the relative prediction error is confined to 0.1, the hit rate is 89%, the root mean square error of prediction is 0.047, and the correlation coefficient of the sequence of the actual target value and the predicted target value is 0.851. Through experiments, it can be seen that the prediction results of the established model are much better than that of the support vector machine (SVM), feedforward neural network, extreme learning machine (ELM) and differential evolution optimized extreme learning machine (DE-ELM). Moreover, the model provides important guiding significance to the temperature control of the blast furnace.

Key words: silicon content in hot metal; prediction model; composite differential; extreme learning machine

1 引言(Introduction)

高炉铁水硅含量与炉温具有正相关性, 即通过铁水硅含量可以间接地表征炉内温度的变化^[1], 故高炉铁水硅含量是评价高炉炼铁过程炉况、能耗以及生铁质量的关键信息之一. 由于高炉炼铁过程复杂, 无法直接在线实时测量铁水硅含量, 导致对炉温调控不

及时或者盲目. 因此, 实时准确地预测高炉铁水硅含量及其变化趋势, 对维持高炉的稳定顺行、精确调控炉温、提高生铁质量和降低焦比等具有重要意义.

现有铁水硅含量常通过现场取样离线化验、人工目测以及预报模型等方法进行测定、估计和预报. 通过现场取样, 并采用光谱仪等进行离线化验铁水成分,

收稿日期: 2015-08-24; 录用日期: 2016-06-08.

[†]通信作者. E-mail: jzh0903@csu.edu.cn; Tel. +86 15874291486.

本文责任编辑: 李少远.

国家自然科学基金重大项目(61290325), 国家自然科学基金创新研究群体科学基金项目(61321003)资助.

Supported by Major Program of National Natural Science Foundation of China (61290325) and Foundation for Innovative Research Groups of National Natural Science Foundation of China (61321003).

结果准确、可靠,但化验结果存在较大检测滞后,导致对炉况的判断不及时,不利于指导现场实时调控;人工目测方法则完全依赖人工经验,主观性强,存在较大误差,调控不准确;基于预报模型的高炉铁水硅含量预报主要有3种思路:①根据高炉炼铁时内部所发生的一系列复杂反应以及传递现象建立铁水硅含量的预报模型^[2],这些模型从理论出发,揭示了高炉内部现象,反映了高炉冶炼机理,但由于冶炼时化学反应复杂,环境恶劣,致使机理模型存在预报结果准确性低、计算耗时以及实时性能差等缺点;②融合机理分析与数据的经验模型^[3].通过分析冶炼过程数据与专家知识,利用提取的规则进行推理,进而实现炉温的预报控制.经验模型简单、可理解性强,在炉况诊断和炉温预报方面意义较大.然而基于规则的定性判断和高炉冶炼过程复杂,使得该模型很难应用于实际的炉温预报;③利用炼铁过程中丰富的在线和离线检测数据(如铁矿石成份、下料速度、焦比、风温、风压、铁水硅含量、硫含量、炉渣成份与碱度等参数),采用数据驱动的思想建立高炉铁水硅含量的预报模型,如自回归模型^[4]、神经网络模型^[5]、贝叶斯模型^[6]、支持向量机模型^[7-8]、偏最小二乘模型^[9]、非线性动力学理论模型^[10]、距离保持极限学习机(distance pertec-tion extreme learning machine, DP-ELM)模型^[11]等.这些模型对高炉铁水硅含量的预报有一定效果,但是仍存在局限性.如自回归预测模型的命中率偏低,不能适应于冶炼复杂的高炉炉温预报系统;神经网络和贝叶斯模型性能较为不稳定,难以与高炉冶炼的机理模型相融合;DP-ELM只需设置网络的隐层节点个数,在算法执行过程中随机选取网络的输入权值以及隐层节点阈值,并且产生唯一的最优解,泛化性能较好,但该模型需设定较多的隐层节点个数来确保其性能,增加了模型的冗余节点,导致过拟合现象.

高炉内部检测设备齐全,可检测生产数据量较大,所获取数据中隐含了丰富的硅含量变化信息,为研究硅含量的实时快速准确预报提供了数据支撑.极限学习机^[12-13](extreme learning machine, ELM)在工程建模以及回归预报中表现出简单快速等优势,使得该模型与铁水硅含量预报有良好的结合点.然而由于该模型随机选取输入权值和隐层节点阈值,因此,很难准确预报波动频繁的硅含量变化.复合差分进化算法^[14-15](composite differential evolution algorithm, CoDE)通过简单组合多个试验向量产生策略和多组控制参数,可以快速定位全局最优值,很好地弥补了极限学习机在铁水硅含量预报中的不足.因此,本文提出了一种复合差分进化算法优化极限学习机(CoDE-ELM)的铁水硅含量预报模型.首先对现场的数据进行整理与合理分类.因现场数据在反映铁水硅含量的

变化信息时呈现出差异性、层次性等特性;其次,利用复合差分进化算法获取ELM的最优输入权值和隐层节点阈值,这不仅解决了因非最佳参数导致模型预报精度下降的问题,而且避免了因增加隐层节点造成的模型复杂度;最后,将所建模型用于铁水硅含量的预报.实例分析表明,本文所建模型相比较于BP-NN, SVM, DP-ELM以及DE-ELM模型,具有结构简单、预报精度高以及稳定性强等优点,可为高炉操作人员合理调控高炉炉温提供有效的指导.

2 数据预处理(Data preprocessing)

本文数据来源于某钢铁厂2650 m³高炉,选取了从2015年1月1号到2015年2月14号的数据进行分析处理.在采样过程中,因外部环境变化、高温高压、高炉休风以及减风等非正常生产的影响,采样数据存在异常值.本文通过3 σ 准则对异常值做相关处理.计算 σ 值:

$$\sigma = \sqrt{\frac{\sum_{i=1}^N V_i^2}{(N-1)}}, \quad (1)$$

式中 $V_i = x_i - \frac{1}{N} \sum_{i=1}^N x_i$ 为变量 x_i 的残差.若残差 $|V_i| > 3\sigma$,则该数据为异常数据,对应的该样本为异常样本,予以剔除.重复使用该方法对所有数据进行异常值剔除,直至没有异常数据为止.

在建模时,将影响铁水硅含量的变量作为模型输入,铁水硅含量作为模型输出.铁水中硅含量的变化与固体原料(包含铁矿石、烧结矿和焦炭)、待加热的气态物质(包含空气和一些辅助燃料)以及下部的风量、风温等参数的变化有密切的关系,表1列出了18个待选变量.过多的输入变量会增加模型复杂度,而过少的输入变量又会降低模型精度.因此,建模时有必要删除待选变量中与铁水硅含量相关性不强的变量.本文计算了所有待选变量与铁水硅含量之间的皮尔逊相关系数,结果如表1所示.值得说明的是,虽然透气性指数与硅含量的相关性系数不高,但在实际高炉调控中,它是现场操作者判断铁水硅含量变化的重要依据之一.因此,在建模时也将其作为模型输入.综上,选取上一炉铁水硅含量、喷煤量、热风温度、富氧流量、实际风速、鼓风动能、热风压力、以及透气性指数共8个变量作为模型的输入,其统计值如表2所示,输出变量的时间序列如图1所示,时间序列长度为800,铁水硅含量大多在[0.3, 0.5]的范围内波动.最后,考虑到选取的各输入变量数量级相差较大,对模型的收敛速度和复杂度会有影响,因此,在建模前需要对各变量进行归一化处理,通过数值变换来消除变量间的量纲影响.由表1也可以得出变量之间的差异性表现:与硅含量同步增减的变量,称为正相关变量,与硅含量异步增减的变量,称为负相关变量.通过如下方法分别进行归一化:

$$\tilde{x}_i = \begin{cases} \frac{x_i - \min x_i}{\max x_i - \min x_i}, & \text{正相关,} \\ \frac{\max x_i - x_i}{\max x_i - \min x_i}, & \text{负相关.} \end{cases} \quad (2)$$

表 1 输入变量与硅含量相关性系数

Table 1 Correlation coefficient between the input variables and silicon content

变量名	与Si含量的相关性系数	变量名	与Si含量的相关性系数
Ti	0.9	鼓风动能	-0.285
S	-0.38	炉腹煤气量	-0.285
Si(n-1)	0.53	冷风流量	0.099
喷煤量	-0.42	标准风速	-0.083
热风温度	-0.308	富氧压力	0.055
富氧流量	0.21	阻力系数	0.03
实际风速	-0.33	富氧率	0.181
热风压力	-0.38	透气性指数	-0.231
冷风压力	0.14	全压差	0.328

表 2 模型输入变量

Table 2 The input variables of model

输入变量	单位	均值	方差
上一炉铁水硅含量	wt%	0.43	0.007
喷煤量	t	21.12	0.60
热风温度	°C	1213.6	29.6
富氧流量	m ³ /min	612.05	1.02E06
实际风速	m/s	271.61	20.45
鼓风动能	J/s	129.96	30.53
热风压力	kPa	27.81	0.30
透气性指数	m ³ /min · kPa	17.27	0.35




图 1 高炉铁水硅含量时间序列图

Fig. 1 Time series of blast furnace silicon content in hot metal

3 极限学习机(Extreme learning machine)

传统神经网络中隐层参数的计算是利用梯度下降法, 是一种寻找局部最优的过程, 即使找到局部最优, 也未必能够满足要求而结束, 因此必须多次选择初始点重新开始计算, 在最坏情况下需要全部遍历搜

索空间才能找到最优解, 因此学习速度很慢、泛化性能差. Huang等提出ELM模型, 是一种基于最小二乘原理的单隐层前馈神经网络模型, 不同点在于隐层参数随机产生, 不用根据测试输出反向调节, 输出权值通过求解线性方程组的最小二乘解获得, 具有学习速度快、精度高、泛化性能好等特点. ELM的具体算法描述如下^[16]:

N 个样本 (x_j, t_j) , $x_j = [x_{j1}, x_{j2}, \dots, x_{jn}]^T \in \mathbb{R}^n$ 代表 n 维输入样本, $t_j = [t_{j1}, t_{j2}, \dots, t_{jm}]^T \in \mathbb{R}^m$ 代表 m 维输出样本(本文 $m = 1$), 具有 K 个隐含层节点数的ELM模型可以表示为

$$f_K(x_j) = \sum_{i=1}^K \beta_i g(\alpha_i \cdot x_j + b_i), \quad j = 0, 1, \dots, n, \quad (3)$$

式中: $\alpha_i = [\alpha_{i1}, \alpha_{i2}, \dots, \alpha_{in}]$ 是连接输入神经元和第 i 个隐层节点的ELM模型输入权值, b_i 是第 i 个隐层偏差, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 是连接第 i 个隐层节点和输出节点的ELM模型输出权值, $\alpha_i \cdot x_j$ 表示 α_i 和 x_j 的内积, 激励函数 $g(x)$ 选用sigmoid函数, 即

$$g(\alpha_i \cdot x_j + b_i) = \frac{1}{1 + \exp(-(\alpha_i \cdot x_j + b_i))}. \quad (4)$$

图2所示网络的训练目标是使得输出的误差达到最小, 可表示为

$$\sum_{j=1}^n \|f_K(x_j) - t_j\| = 0, \quad j = 0, 1, \dots, n, \quad (5)$$

即存在 β_i, α_i, b_i , 使得

$$\sum_{i=1}^K \beta_i g(\alpha_i \cdot x_j + b_i) = t_j, \quad j = 0, 1, \dots, n. \quad (6)$$

上述 N 个方程可以写为

$$H\beta = T, \quad (7)$$

式中:

$$H = \begin{bmatrix} g(\alpha_1 \cdot x_1 + b_1) & \dots & g(\alpha_K \cdot x_1 + b_K) \\ g(\alpha_1 \cdot x_2 + b_1) & \dots & g(\alpha_K \cdot x_2 + b_K) \\ \vdots & & \vdots \\ g(\alpha_1 \cdot x_n + b_1) & \dots & g(\alpha_K \cdot x_n + b_K) \end{bmatrix}_{n \times K}, \quad (8)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_K^T \end{bmatrix}_{K \times m}, \quad T = \begin{bmatrix} t_1^T \\ t_2^T \\ \vdots \\ t_n^T \end{bmatrix}_{n \times m}, \quad (9)$$

输出权值矩阵 β 是唯一的可调参数, 其最小二乘解为

$$\hat{\beta} = H^\dagger T, \quad (10)$$

式中 H^\dagger 称为隐含层输出矩阵 H 的Moore-Penrose广义逆矩阵. 如果隐层输出矩阵 H 非奇异, 则线性系统的最小二乘估计值可写为 $H^\dagger = (H^T H)^{-1} H^T$ 或 $H^\dagger =$

$H^T(HH^T)^{-1}$.

ELM网络结构如图2所示.




图2 ELM网络结构

Fig. 2 Structure of extreme learning machine network

4 极限学习机的优化(The optimization of extreme learning machine)

铁水硅含量作为高炉炉内热状况的重要指示剂, 它的波动可反映炉温的波动, 因此硅含量的准确预报对高炉的调控至关重要. 然而ELM随机选取输入权值和隐层节点阈值, 且输出权值是在确定的输入权值和隐层节点阈值的基础上求得, 因而可能存在因非最佳的输入权值和隐层节点阈值导致的ELM预报精度受影响. 鉴于此, 本文采用CoDE中组合多个试验向量产生策略和多组控制参数的方法产生ELM的输入权值和隐层节点阈值. 将所得最优的输入权值和隐层节点阈值代入ELM. 在CoDE的训练过程中, 将均方根误差(root mean square error, RMSE)作为CoDE的适应度函数, 具体表示如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (f(x_i) - t_i)^2}, \quad (11)$$

式中: $f(x_i)$ 为样本测试值, t_i 为样本实测值. 基于CoDE算法寻找ELM中最优的输入权值和隐层节点阈值(α, b)的具体步骤如下:

Step 1 初始化参数. 参数包括种群规模NP、种群进化代数G、实际样本数据的维数D、变异算子集 $F = [f_1, f_2, f_3]$ 、交叉算子集 $CR = [CR_1, CR_2, CR_3]$ 以及ELM中的隐层节点个数K.

Step 2 随机产生种群. 其中种群的每个向量代表ELM中的输入权值和隐层节点阈值: $(a_i, b_i), i = 1, \dots, K$.

Step 3 通过CoDE优化方法计算种群中向量的适应度函数值.

Step 4 针对每个向量, 分别执行以下3步操作:

1) 变异操作.

从参数集合里面随机选择一组F, CR参数, 分别通过DE/rand/1、DE/rand/2和DE/current to rand/1算子产生3个变异向量:

$$v_{i1}(g+1) = x_{r_1}(g) + F * (x_{r_2}(g) - x_{r_3}(g)),$$

$$i \neq r_1 \neq r_2 \neq r_3, \quad (12)$$

$$v_{i2}(g+1) = x_{r_1}(g) + F * (x_{r_2}(g) - x_{r_3}(g)) +$$

$$F(x_{r_4}(g) - x_{r_5}(g)),$$

$$r_1 \neq r_2 \neq r_3 \neq r_4 \neq r_5, \quad (13)$$

$$v_{i3}(g+1) = x_i(g) + \text{rand} * (x_{r_1}(g) - x_i(g)) +$$

$$F(x_{r_2}(g) - x_{r_3}(g)),$$

$$r_1 \neq r_2 \neq r_3. \quad (14)$$

上述3个公式中, x_{r_i} 表示基向量, g 表示迭代数, F 表示变异算子, $r_1, r_2, r_3, r_4, r_5 \in \{1, 2, \dots, NP\}$ 互不相同, $v_{i,j}(g+1)$ 为变异向量. DE/rand/1策略的变异过程是从种群的第 g 代中获得3个向量, 对其中的两个向量进行减运算, 通过变异算子作用后, 与剩下的向量进行加运算. DE/rand/2将两个变异算子用在两组不同的向量相减中, 所得结果加在第5个向量上产生变异向量. DE/current to rand/1也是利用两个变异算子的缩放产生变异向量.

2) 交叉操作.

交叉操作是对目标向量与变异向量进行的交叉, 具体的交叉操作如下所示:

$$u_{j,i,k}(g+1) = \begin{cases} v_{j,i,k}(g+1), & \text{rand}(0, 1) \leq CR, \\ & \text{或 } j = j_{\text{rand}}, k = 1, 2, \\ x_{j,i}(g), & \text{其他,} \end{cases} \quad (15)$$

式中: CR 表示交叉算子, k 为试验向量的个数, 其中 $v_{i3}(g+1)$ 不参与交叉操作, 直接进入下一步骤. 通过条件 $j = j_{\text{rand}}$ 保证通过交叉算子计算后得到的新向量中存在变异的向量. 交叉操作获得如下向量: $u_{i,\text{best}} = \text{bestSelect}(u_{i1}, u_{i2}, u_{i3})$. bestSelect 是一个基于适应值的选择函数, 从一组向量中选择适应值最好的向量.

3) 选择操作.

通过式(11)对交叉操作产生的新向量 $u_{j,\text{best}}$ 与基向量 $x_i(g)$ 进行选择, 并选取适应度函数值小的向量进入下一代, 选择操作公式如下:

$$x_i(g+1) = \begin{cases} u_{i,\text{best}}(g+1), & f(u_{i,\text{best}}(g+1)) \leq f(x_i(g)), \\ x_i(g), & \text{其他.} \end{cases} \quad (16)$$

Step 5 判断CoDE优化算法是否满足运行的终止条件, 一般为达到预设的迭代次数或者算法的精度, 若是满足, 转Step 6, 否则 $g = g + 1$, 转Step 4.

Step 6 获得最优输出, 即ELM模型的输入权值和隐层节点阈值.

Step 7 将最优输出代入式(10), 计算模型输出权值 β .

Step 8 根据式(3), 计算CoDE-ELM的逼近函数, 建立优化模型.

CoDE-ELM流程图如图3所示.

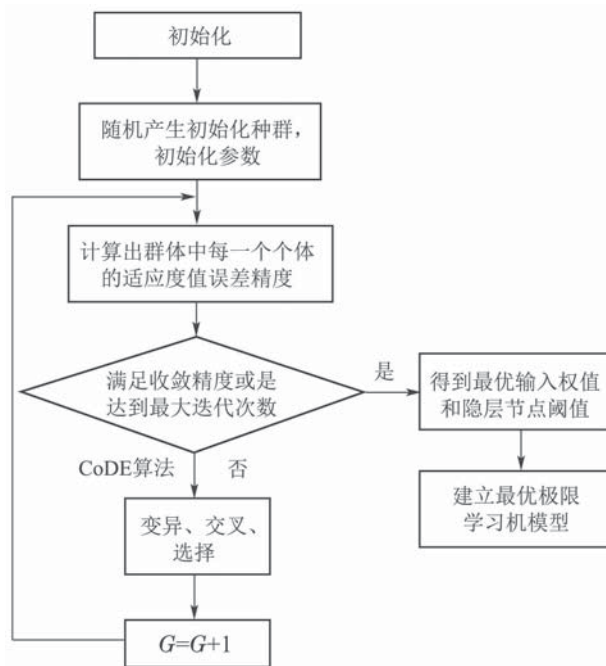


图 3 CoDE-ELM流程图

Fig. 3 Flow chart of the CoDE-ELM

5 铁水硅含量的预报结果与分析(Prediction results and analysis of silicon content in hot metal)

选取预处理得到的500组样本对上述所建模型进行验证, 其中用前400组样本进行训练, 后100组样本进行测试. 为了进一步验证本论文所建模型的性能, 选取如下模型: SVM, BP-NN, ELM, DP-ELM, DE-ELM以及CoDE-ELM分别对测试样本进行测试. 并对结果进行对比分析.

模型的训练过程对预报系统来说尤为重要. 因此, 先通过对数据的训练, 不断修正参数, 在大量的样本学习后, 模型就能够很好的建立输入输出变量之间的映射关系, 进而对测试集进行预报. 本文用预报值与实测值之间的绝对误差小于0.1来表征预报结果的准确性. 为了更加全面地评价预报模型的性能, 通过以下3种指标对所建立的ELM, CoDE-ELM等预报模型进行比较.

1) 预报命中率(hit rate, HR).

$$HR = \frac{1}{l} \sum_{k=1}^l H_k \times 100\%, \quad (17)$$

式中: l 表示预报样本长度, $H(\cdot)$ 是Heaviside函数, 定义为

$$H_k = \begin{cases} 1, & \|\hat{y}_k - y_k\| < 0.1, \\ 0, & \text{其他,} \end{cases} \quad (18)$$

式中: \hat{y}_k 表示实测值, y_k 为对应的预报值.

2) 预报均方根误差(root mean square error, RMSE)

$$RMSE = \sqrt{\frac{1}{l} \sum_{k=1}^l (y(k) - \hat{y}(k))^2}. \quad (19)$$

3) 实际目标值序列与预报值序列的相关系数(correlation coefficient, CC)

$$CC = \frac{\frac{1}{l} \sum_{k=1}^l (y(k) - \bar{y})(\hat{y}(k) - \bar{\hat{y}})}{\sigma(y)\sigma(\hat{y})}, \quad (20)$$

式中: $\sigma(y)$ 为目标值序列的标准差, $\sigma(\hat{y})$ 为预报值序列的标准差, \bar{y} 为实测值均值, $\bar{\hat{y}}$ 为预报值均值.

图4所示为ELM, DP-ELM, DE-ELM, CoDE-ELM模型中隐层节点 K 和均方根误差RMSE之间的关系曲线. 由图4可得, ELM模型随 K 的变化RMSE表现出较大的波动性, 这是由随机选取输入权值和隐层节点阈值造成的. DP-ELM以及DE-ELM随 K 的变化稳定性有了很大的改善, 但最小的RMSE对应的 K 值较大, 这使得所建模型较为复杂. CoDE-ELM模型中较小的隐层节点就可以保证均方根误差达到最小, 当 K 为9时, RMSE最小, 为0.047. CoDE-ELM模型具有的快速寻优特性以及模型稳定性在高炉铁水硅含量预报中优势显著.

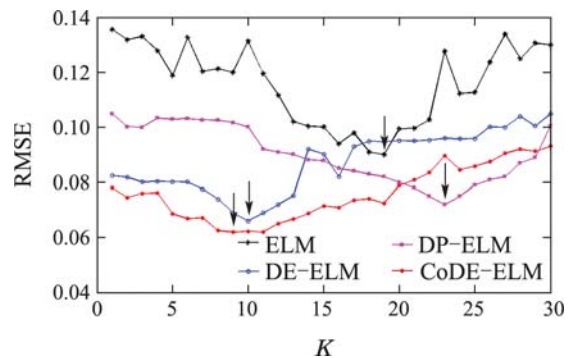


图 4 隐层节点与均方根误差曲线图

Fig. 4 The number of hidden nodes and root mean square error curve

图5给出了不同预报模型对铁水硅含量的预报结果图. 首先, 对于铁水硅含量波动不大的炉次, ELM、CoDE-ELM预报模型的预报效果都较好, 预测值可以很好的跟踪实际值. 而在炉况波动比较大的一些炉次, 比如第4炉、第44炉、第75炉以及第92炉, CoDE-ELM模型的跟踪效果明显优于ELM模型, 预报值也能及时跟踪波动较大的实测值的变化. 其次, 随着炉次的增加, ELM模型的跟踪效果明显减弱, 而CoDE-ELM模型仍能很好的跟踪实测值的变化, 说明在数据规模较大时该模型的学习和泛化性能有一定提高.




图5 不同建模方法对硅含量预报结果图

Fig. 5 The prediction result of silicon content based on different modeling methods

由图6可知,ELM预报模型的误差大多落在 $[-0.1, 0.1]$ 之间,而本文所建CoDE-ELM预报模型的误差大多在 $[-0.05, 0.05]$ 之间波动,误差图进一步体现了CoDE-ELM模型在硅含量预报中的优势。

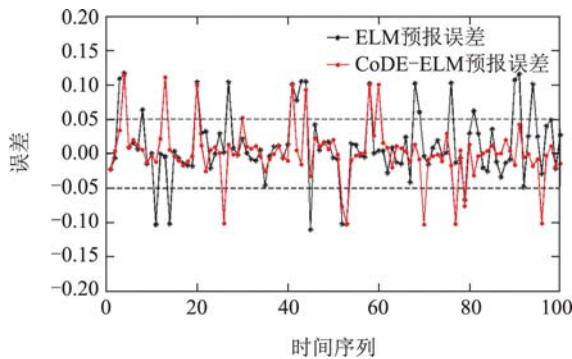


图6 不同建模方法对硅含量预报的误差对比图

Fig. 6 The error comparison of silicon content prediction based on different modeling methods

表3为CoDE-ELM相比于传统预报模型、基于不同优化方法的ELM模型的结果统计图。CoDE-ELM改善了ELM在铁水硅含量预报中存在的不足,即预报值难以及时跟踪波动较大的硅含量值。CoDE-ELM相对于其他预报模型, RMSE最小,命中率最大,实际目标值序列与预报值序列的相关系数也相对较高。

表3 不同建模方法的预报结果对比

Table 3 Comparison of prediction results of different modeling methods

指标	HR	RMSE	CC
SVM	70	0.112	0.685
BP-NN	74	0.125	0.623
ELM	82	0.095	0.813
DP-ELM	82	0.072	0.773
DE-ELM	86	0.066	0.860
CoDE-ELM	89	0.047	0.851

命中率是衡量铁水硅含量预报性能最常用的指标,但它是一个非连续的指标,不能全面地衡量模型预报性能。因此,需综合比较HR, RMSE以及CC来评价模型性能。本文通过CoDE优化预报模型的参数,提高了预报模型的命中率,为高炉操作者调控高炉提供参考依据。

6 结论(Conclusions)

本文提出了一种基于CoDE-ELM的高炉铁水硅含量预报模型。该模型在模型稳定性、预报精度和泛化性能等方面相比于已有预报模型均有一定改进。该模型的预报值能更好地跟踪铁水硅含量的变化规律,尤其对一些炉况波动较大的炉次,跟踪效果也较好,预报结果对高炉炉温的实际调控具有较好的指导意义。

铁水硅含量数值预报固然重要,但是在实际控制高炉运行过程中,相比于具体的硅含量数值,操作者有时更需要参考硅含量趋势变化信息。在这种情形下,仅给出硅含量的预报值是不够的,最好能够同时给出趋势的变化,并且合理地将数值预报与趋势预报结合起来分析炉况变化,这对现场操作有更好的指导意义。因此,下一步的研究将结合更多高炉变量信息,有效地融合数值预报和趋势预报的结果,实现对高炉炉温的控制。

参考文献(References):

- [1] STERNELAND J, ANDERSSON M A T, JONSSON P G. Comparison of iron ore reduction in experimental blast furnace and laboratory scale simulation of blast furnace process [J]. *Ironmaking & Steelmaking*, 2003, 30(4): 313 - 327.
- [2] TAKAHASHI H, KAWAI H, KOBAYASHI M, et al. Two dimensional cold model study on unstable solid descending motion and control in blast furnace operation with low reducing agent rate [J]. *The Iron and Steel Institute of Japan International*, 2005, 45(10): 1386 - 1395.
- [3] GAO C H, GE Q H, JIAN L. Rule extraction from fuzzy-based blast furnace SVM multiclassifier for decision-making [J]. *IEEE Transactions on Fuzzy Systems*, 2014, 22(3): 586 - 596.
- [4] WANG Wenhui. Study for prediction model of silicon content in

- molten iron based on wavelet analysis* [D]. Hangzhou: Zhejiang University, 2005.
(王文慧. 基于小波分析理论的高炉炉温预测模型研究 [D]. 杭州: 浙江大学, 2005.)
- [5] CHEN W, WANG B X, HAN H L. Prediction and control for silicon content in pig iron of blast furnace by integrating artificial neural network with genetic algorithm [J]. *Ironmaking & Steelmaking*, 2010, 37(6): 458 – 463.
- [6] GONG Shuhua, LIU Xiangguan. Application of fuzzy Bayesian network to trend prediction of silicon content in molten iron [J]. *Metallurgical industry Automation*, 2005, 29(5): 30 – 32.
(龚淑华, 刘祥官. 模糊贝叶斯网络应用于预测高炉铁水含硅量变化趋势 [J]. 冶金自动化, 2005, 29(5): 30 – 32.)
- [7] GAO C H, JIANG L, LUO S H. Modeling of the thermal state change of blast furnace hearth with support vector machines [J]. *Metallurgical Industry Automation*, 2012, 56(2): 1134 – 1145.
- [8] TANG Xianlun, ZHUANG Ling, HU Xiangdong. The support vector regression based on the chaos particle swarm optimization algorithm for the prediction of silicon content in hot metal [J]. *Control Theory & Applications*, 2009, 26(8): 838 – 842.
(唐贤伦, 庄陵, 胡向东. 铁水硅含量的混沌粒子群支持向量机预报方法 [J]. 控制理论与应用, 2009, 26(8): 838 – 842.)
- [9] BHATTACHARYA T. Prediction of silicon content in blast furnace hot metal using partial least squares (PLS) [J]. *The Iron and Steel Institute of Japan International*, 2005, 45(12): 1943 – 1945.
- [10] MIYANO T, KIMOTO S, SHIBUTA H, et al. Time series analysis and prediction on complex dynamical behavior observed in a blast furnace [J]. *Physica D — Nonlinear Phenomena*, 2000, 135(3): 305 – 330.
- [11] LIU Xueyi. *Research on extreme learning machine and its application to blast furnace ironmaking process* [D]. Hangzhou: Zhejiang University, 2013.
(刘学艺. 极限学习机算法及其在高炉冶炼过程建模中的应用研究 [D]. 杭州: 浙江大学, 2013.)
- [12] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications [J]. *Neurocomputing*, 2006, 70(1): 489 – 501.
- [13] HUANG G B, ZHOU H M, DING X J, et al. Extreme learning machine for regression and multiclass classification [J]. *IEEE Transactions on Systems*, 2012, 42(2): 513 – 529.
- [14] XU Bin. *Research and application of multi-objective optimization algorithms base on differential evolution* [D]. Shanghai: East China University Of Science And Technology, 2013.
(徐斌. 基于差分进化算法的多目标优化方法研究及其应用 [D]. 上海: 华东理工大学, 2013.)
- [15] WANG Y, CAI Z X, ZHANG Q F. Differential evolution with composite trial vector generation strategies and control parameters [J]. *IEEE Transactions on Evolutionary Computation*, 2011, 15(1): 55 – 66.
- [16] YIN Juping, JIANG Zhaohui. Prediction for blast furnace silicon content in hot metal based on data [J]. *Nonferrous Metals Engineering & Research*, 2015, 36(3): 36 – 38.
(尹菊萍, 蒋朝辉. 基于数据的高炉铁水硅含量预测 [J]. 有色冶金设计与研究, 2015, 36(3): 36 – 38.)

作者简介:

蒋朝辉 (1978–), 男, 副教授, 研究生导师, 目前研究方向为复杂工业过程建模与优化控制、广义大系统控制理论与应用, E-mail: jzh0903@csu.edu.cn;

尹菊萍 (1991–), 女, 硕士, 目前研究方向为复杂工业过程建模与优化、信息检测系统研究, E-mail: yin_juping@163.com;

桂卫华 (1950–), 男, 中国工程院院士, 教授, 主要研究方向为复杂工业过程建模与优化控制、工业大系统控制理论与应用, E-mail: gw@csu.edu.cn;

阳春华 (1965–), 女, 教授, 博士生导师, 目前研究方向为复杂工业过程建模与控制、智能自动化控制系统, E-mail: ychh@csu.edu.cn.