

硅锰合金埋弧熔炼过程中炉渣成分软测量

唐春霞^{1,2}, 江彤³, 阳春华¹, 贺建军¹

(1.中南大学 信息科学与工程学院, 长沙 410083; 2. 长沙民政学院, 长沙 410004;
3. 湖南人文科技学院 生命科学系, 娄底 417000)

摘要: 针对硅锰合金埋弧熔炼过程中炉渣成分检测难的问题, 提出一种基于自适应差分进化 (ADE) 优化的约减最小二乘支持向量机 (RLSSVM) 软测量模型。该模型以硅锰合金熔炼过程的工况参数为实测数据集, 首先通过斯密特正交变换获取高维特征空间核矩阵的基, 然后利用 Direct Kernel PLS 回归计算得到约减最小二乘支持向量机软测量模型, 并以最小化训练样本的均方差为目标函数, 用自适应差分进化算法优化最小二乘支持向量机的核参数和正则化参数, 将此模型应用于 30 MW 硅锰合金埋弧熔炼过程炉渣成分测量。结果表明: ADE-RLSSVM 模型测量值与实际值的最大相对误差为 7.3%, 运行时间为 21 min。

关键词: 埋弧炉; 炉渣成分; 差分进化; 最小二乘支持向量机; 斯密特正交化

中图分类号: TP273

文献标志码: A

Soft sensor modeling for slag composition of silicon-manganese smelting process

TANG Chun-xia^{1,2}, JIANG Tong³, YANG Chun-hua¹, HE Jian-jun¹

(1. School of Information Science and Engineering, Central South University, Changsha 410083, China;
2. Changsha Social Work College, Changsha 410004, China;
3. Department of Life Science, Hunan Institute of Humanities Science and Technology, Loudi 417000)

Abstract: To overcome the difficulty that the slag composition cannot be effectively measured in silicon-manganese smelting process, a soft sensor model based on reduced least squares support vector machine (RLSSVM) was proposed, which was optimized by adaptive differential evolution (ADE) algorithm. Firstly, based on the measured data, the base vectors of kernel matrix can be gotten by Schmidt orthogonalization in the high dimensional feature space. Then, the direct kernel partial least squares regression (PLS) calculation was conducted to obtain the RLSSVM soft sensor model. Taking the minimum standard deviation of the training sample as the objective function, the adaptive differential evolution algorithm was used to optimize the kernel function parameters and regularization parameter of LSSVM. At last, applying this method to estimate the slag composition in a 30 MW submerged arc furnace, the results show that the maximum relative error of ADE-RLSSVM model is 7.3% and the computation time is 21 min.

Key words: submerged arc furnace; slag composition; differential evolution; least squares support vector machine; Schmidt orthogonalization

采用矿热炉法生产硅锰合金时, 炉渣成分是一个重要的工艺参数, 反映了硅锰合金埋弧冶炼过程炉况的好坏, 决定冶炼的温度以及炉渣的碱度、黏度、导

电导热性和金属还原性, 影响各元素在合金与炉渣中的分配, 是调整和控制操作参数的重要依据^[1-2]。受生产条件和检测手段的限制, 很难对炉渣成分进行在线

检测和实时控制。目前,炉渣成分是通过在出铁时取渣样离线化验得到,工艺人员根据化验结果并结合生产经验来调整入炉矿石的品位、组分、焦炭和溶剂的配入量以及供电制度。这一方法不能及时反映生产过程中炉况及产品质量的变化,存在较大的时间滞后,导致炉况不稳、质量指标波动大、电耗高。因此,研究硅锰合金熔炼过程中炉渣成分的软测量方法,对指导配料与供电操作、稳定炉况、提高产品产量、降低电耗和原材料消耗都有着非常重要的意义。

因硅锰合金埋弧冶炼过程是一种液、固、气多相共存的复杂工业过程,具有机理复杂、非线性、时变、强耦合等特点^[3],很难用机理分析或系统辨识等方法建立有效的炉渣成分测量模型。同时,硅锰合金采用连续冶炼、定期出铁的生产方式,炉渣成分取样化验的频率不高,完整的数据样本较少,基于大样本、经验风险最小化的传统统计建模方法难以获得理想的测量效果。支持向量机(Support vector machine, SVM)是以统计学习理论为基础的基于结构风险最小化的机器学习方法,较好地解决了小样本、高维数、非线性、局部最小等问题,具有较强的泛化能力,已成功应用于参数预测和过程建模^[4-5]等领域。但样本数据越多,求解二次规划问题(Quadratic programming, QP)越复杂。最小二乘支持向量机(Least squares support vector machine, LSSVM)^[6]用等式约束代替不等式约束,避免了求解耗时的二次规划问题,加快了求解速度,在实际系统建模中得到广泛应用^[7-8]。但最小二乘支持向量机的解不具有稀疏性,不适合复杂工业过程的在线建模,且模型参数的选取直接影响模型的精度和泛化

性能。为此,本文作者提出一种基于自适应差分进化(Adaptive differential evolution, ADE)优化的约减最小二乘支持向量机(Reduced least squares support vector machine, RLSSVM)软测量方法,该方法首先通过施密特正交化获取高维特征空间核矩阵的基,使最小二乘支持向量机的解具有稀疏性,然后利用直接核最小二乘回归(Direct kernel partial least squares)辨识出最小二乘支持向量机参数,建立硅锰合金冶炼过程炉渣成分的软测量模型,并以最小化训练样本的均方差为目标函数,采用差分进化算法优化正则化参数 C 和核宽度 σ^2 ,实现对炉渣成分的在线分析检测。

1 硅锰合金埋弧冶炼过程分析

1.1 机理分析

硅锰合金埋弧冶炼过程工艺流程如图1所示。锰矿石、硅石、焦炭、白云石等原料按一定比例称量、混合后由加料管投放到矿热炉熔池中。因加料管插入炉内并直接与料面接触,当炉料下沉时,可连续补充生料,所以,整个冶炼过程是连续的。电炉变压器低压侧通过短网与电极相连,电流经短网、集电环、软铜线和铜瓦导入电极,通过升降电极和切换变压器二次电压级数来调节熔炼功率,切换电压等级是在有载的情况下进行。由于电极深埋在炉料中,炉料依靠电极端部的电弧热和炉料本身的电阻热提供还原反应所需要的高温,将锰矿石还原成合金,并产生一氧化碳气体,生成的合金与炉渣定期从出铁口排出,生成的





图1 硅锰合金埋弧冶炼过程工艺流程示意图

Fig.1 Schematic diagram of submerged arc silicon-manganese furnace smelting process

烟气由烟道排出。炉内总化学反应包括:



可见,在生产硅锰合金的同时产生 SiO_2 炉渣。为保证生产顺利进行,必须保持炉内高温,使 SiO_2 炉渣成为流动性良好的液态熔体,以确保反应(3)进行,使 MnO 从液态熔体中很好地游离出来。因锰矿石中的 Al_2O_3 在冶炼中很难还原,几乎全部进入炉渣,所以,当炉渣中 Al_2O_3 含量过高时,造成排渣困难。为使炉渣能够顺利排出,提高锰的回收率,要在炉料中加入白云石或石灰等溶剂以保持炉渣具有适宜的碱度、黏度、导电性和导热性,以提高并均衡炉膛温度,让电极深插扩大坩埚,改善还原的热力学和动力学条件。硅锰合金冶炼工艺要求炉渣成分控制在一定范围内: $w(\text{Mn}) < 8\%$, $w(\text{CaO}) 12\% \sim 15\%$, $w(\text{MgO}) 5\% \sim 10\%$, $w(\text{SiO}_2) 34\% \sim 42\%$, $w(\text{Al}_2\text{O}_3) 13\% \sim 20\%$ 。

1.2 软测量模型输入、输出变量选取

通过分析硅锰合金熔炼机理可知,影响炉渣成分的主要因素包括混合矿中的 CaO 含量(x_1)、 MgO 含量(x_2)、 SiO_2 含量(x_3)、 Al_2O_3 含量(x_4),焦炭的配入量(x_5),硅石中 SiO_2 含量(x_6)、 Al_2O_3 含量(x_7)、 P_2O_5 (x_8)含量,白云石中的 CaCO_3 含量(x_9)、 MgCO_3 含量(x_{10})、 P_2O_5 含量(x_{11})、配比(x_{12})、炉膛温度(x_{13})、电炉变压器的二次电压(x_{14})、一次电流(x_{15})、功率因数(x_{16})、电耗(x_{17})、熔炼时间(x_{18}),这些变量是可测的,将其作为软测量模型的辅助变量。软测量模型的主导变量为炉渣成分,即炉渣中 Mn (y_1)、 CaO (y_2)、 MgO (y_3)、 SiO_2 (y_4)以及 Al_2O_3 (y_5)的含量。

2 约简最小二乘支持向量机软测量模型

2.1 最小二乘支持向量机回归原理

对于给定数据集 $S = \{\mathbf{x}_k, \mathbf{y}_k\}_{k=1}^N$, $\mathbf{x}_k \in \mathbf{R}^M$ 为 M 维输入向量, $\mathbf{y}_k \in \mathbf{R}$ 是一维输出向量, $k=1, 2, \dots, N$ 。利用非线性映射 φ 把输入数据样本非线性映射到高维特征空间,将原样本空间的非线性函数估计问题转化成高维特征空间的线性函数估计问题:

$$f(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + b \quad (6)$$

根据结构风险最小化原理,将上述回归问题表示为一个等式约束的优化问题:

$$\begin{aligned} \min_{\mathbf{w}, b, e} J(\mathbf{w}, e) &= \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{C}{2} \sum_{k=1}^N e_k^2 \\ \text{s.t. } \mathbf{y}_k &= \mathbf{w}^T \varphi(\mathbf{x}_k) + b + e_k \quad (k=1, \dots, N) \end{aligned} \quad (7)$$

为求解此优化问题,建立拉格朗日函数,将约束优化问题变为无约束优化问题:

$$\begin{aligned} L(\mathbf{w}, b, e, a) &= \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{C}{2} \sum_{k=1}^N e_k^2 - \\ &\sum_{k=1}^N a_k [\mathbf{w}^T \varphi(\mathbf{x}_k) + b + e_k - \mathbf{y}_k] \end{aligned} \quad (8)$$

式中: a_k ($k=1, \dots, N$) 为 Lagrange 乘子。

由 KKT 条件及 Mercer 条件将优化问题变为

$$\begin{bmatrix} 0 & 1 & \cdots & 1 \\ 1 & k(\mathbf{x}_1, \mathbf{x}_1) + 1/C & \cdots & k(\mathbf{x}_1, \mathbf{x}_N) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & k(\mathbf{x}_N, \mathbf{x}_1) & \cdots & k(\mathbf{x}_N, \mathbf{x}_N) + 1/C \end{bmatrix} \times \begin{bmatrix} b \\ a_1 \\ \vdots \\ a_N \end{bmatrix} = \begin{bmatrix} 0 \\ y_1 \\ \vdots \\ y_N \end{bmatrix} \quad (9)$$

由式(9)求得系数 a_i , b ($i=1, \dots, N$) 代入式(6),得到最小二乘支持向量机的输出为

$$f(\mathbf{x}) = \sum_{k=1}^N a_k k(\mathbf{x}, \mathbf{x}_k) + b \quad (10)$$

其中最小二乘支持向量机核函数选径向基函数。

2.2 最小二乘支持向量机核矩阵约简

对于每一个样本向量 $\mathbf{x}_i$, 在高维特征空间内的映射可表示为 $\varphi(\mathbf{x}_i)$ ($i=1, 2, \dots, N$), 所有样本向量在高维特征空间内的映射将构成一个映射矩阵 $\{\varphi(\mathbf{x}_1), \dots, \varphi(\mathbf{x}_N)\}$ 。如果这一映射矩阵中存在一组基 $\{\varphi(\tilde{\mathbf{x}}_1), \dots, \varphi(\tilde{\mathbf{x}}_M)\}$ ($M \leq N$), 则任意一个映射向量都可以由基中 M 个线性无关的列向量组合而成^[9], 即

$$\begin{bmatrix} \varphi(\mathbf{x}_1) \\ \vdots \\ \varphi(\mathbf{x}_N) \end{bmatrix} = \begin{bmatrix} a_{11} & \cdots & a_{1M} \\ \vdots & \ddots & \vdots \\ a_{N1} & \cdots & a_{NM} \end{bmatrix} \begin{bmatrix} \varphi(\tilde{\mathbf{x}}_1) \\ \vdots \\ \varphi(\tilde{\mathbf{x}}_M) \end{bmatrix} \quad (11)$$

根据斯密特正交化理论,对特征空间映射矩阵中的列向量 $\varphi(\mathbf{x}_a)$ 的正交化可表示为^[10]

$$\varphi_{t+1}(\mathbf{x}_a) = \varphi_t(\mathbf{x}_a) - [\varphi_{t+1}(\mathbf{x}_a)' \mathbf{v}_t] \mathbf{v}_t \quad (12)$$

式中: $\mathbf{v}_t = \frac{\varphi_t(\mathbf{x}_i)}{\sqrt{\varphi_t(\mathbf{x}_i)' \varphi_t(\mathbf{x}_i)}}$, $\varphi(\mathbf{x}_i)$ ($1 \leq i \leq N$) 为所挑选出的向量。

对于核矩阵, 其 Gram 形式为

$$\mathbf{G}(a, b) = \varphi(\mathbf{x}_a)^T \varphi(\mathbf{x}_b) = \mathbf{K}(\mathbf{x}_a, \mathbf{x}_b) \quad (13)$$

由式(12)、(13)可知:

$$\begin{aligned} \mathbf{G}_{t+1}(a, b) &= \varphi_{t+1}(\mathbf{x}_a)^T \varphi_{t+1}(\mathbf{x}_b) \\ \mathbf{G}_{t+1}(a, b) &= \varphi_{t+1}(\mathbf{x}_a)^T \varphi_{t+1}(\mathbf{x}_b) \\ &= \mathbf{G}_t(a, b) - \frac{\mathbf{G}_t(a, \mathbf{x}_i) \mathbf{G}_t(b, \mathbf{x}_i)}{\mathbf{G}_t(\mathbf{x}_i, \mathbf{x}_i)} \end{aligned} \quad (14)$$

在构造核矩阵的简约形式时, 采用贪婪算法逐一从核矩阵各列向量中选出模大的向量 $\mathbf{G}(i, i)$, 向量个数最多为核矩阵的秩, 然后对核矩阵剩余部分进行正交化, 得到核矩阵的基。

2.3 DK-PLS 最小二乘支持向量机参数辨识

为提高计算稳定性, 利用 Direct Kernel PLS 辨识出约简最小二乘支持向量机的参数, 算法描述如下^[11]:

Step 1: 令 $\mathbf{K}^0 = \varphi(\mathbf{x})^T \varphi(\mathbf{x})$ 为特征空间的 Gram 矩阵, 即 $K_{ij} = K(\mathbf{x}_i, \mathbf{x}_j)$, 对输出 $\mathbf{Y}^1 = \mathbf{y}$ 进行归一化处理, 使其均值为 0、标准差为 1, 并设 M 为设定的主元数;

Step 2: 对 $\mathbf{K}^0$ 进行对中对处理

$$\mathbf{K}^1 = \left(\mathbf{I} - \frac{1}{N} \mathbf{I}_N \mathbf{I}_N^T \right) \mathbf{K}^0 \left(\mathbf{I} - \frac{1}{N} \mathbf{I}_N \mathbf{I}_N^T \right) \quad (15)$$

Step 3: for $i=1:M$

$$\mathbf{t}^i = \mathbf{K}^i (\mathbf{K}^i)^T \mathbf{y}^i;$$

$$\mathbf{t}^i = \mathbf{t}^i / \|\mathbf{t}^i\|;$$

$$\mathbf{K}^{i+1} = \mathbf{K}^i - \mathbf{t}^i (\mathbf{t}^i)^T \mathbf{K}^i;$$

$$\mathbf{y}^{i+1} = \mathbf{y}^i - \mathbf{t}^i (\mathbf{t}^i)^T \mathbf{y}^i;$$

$$\mathbf{y}^{i+1} = \mathbf{y}^{i+1} / \|\mathbf{y}^{i+1}\|;$$

end

Step 4: 由 M 个主元计算回归系数向量

$$\boldsymbol{\alpha} = \mathbf{K}^1 \mathbf{Y} (\mathbf{T}^T \mathbf{K}^1 (\mathbf{K}^1)^T \mathbf{Y})^{-1} \mathbf{T}^T \mathbf{y} \quad (16)$$

式中: $\mathbf{Y} = [\cdots \mathbf{y}^i \cdots]_{N \times M}$, $\mathbf{T} = [\cdots \mathbf{t}^i \cdots]_{N \times M}$, $\mathbf{I}$ 表示单位阵, 而 $\mathbf{I}_N$ 为全 1 向量; $\boldsymbol{\alpha} = [(\cdots \mathbf{a}_j \cdots)]_{1 \times N}^T$ 。

对核矩阵进行对中对处理后回归时将不出现偏置量参数, 式(10)改写为

$$f(\mathbf{x}) = \sum_{j=1}^N \mathbf{a}_j \hat{\mathbf{K}}(\mathbf{x}, \mathbf{x}_j) \quad (17)$$

式中: 核矩阵 $\hat{\mathbf{K}}$ 表示为

$$\hat{\mathbf{K}} = \left(\mathbf{K}^{\text{test}} - \frac{1}{N} \mathbf{I}_N \mathbf{I}_N^T \mathbf{K}^{\text{train}} \right) \left(\mathbf{I} - \frac{1}{N} \mathbf{I}_N \mathbf{I}_N^T \right) \quad (18)$$

3 自适应差分进化优化最小二乘支持向量机参数

核函数参数 σ^2 和正规化参数 C 直接影响最小二乘支持向量机软测量模型的精度和泛化性能, 常用的参数选择方法如交叉验证不仅耗时, 而且难以寻找到最优值。其他参数优化算法如遗传算法、粒子群算法^[12-13]等虽然缩短了计算时间, 降低了对初值选取的依赖度, 但计算的复杂性仍然很大。差分进化算法^[14]是一种基于种群智能理论的全局优化算法, 具有结构紧凑、参数少、使用灵活、收敛速度快、鲁棒性强等特点, 该方法通过对当前种群进行变异和交叉操作产生一个新种群, 然后利用基于贪婪思想的选择操作对这两个种群进行一对一的选择, 从而产生新一代种群。具体而言, 对初始种群 $\mathbf{X}^0 = [\mathbf{x}_1^0, \mathbf{x}_2^0, \cdots, \mathbf{x}_{N_p}^0]$, 个体 $\mathbf{x}_i^0 = [\mathbf{x}_{i1}^0, \mathbf{x}_{i2}^0, \cdots, \mathbf{x}_{iD}^0]$ 表征问题的一个解 (N_p 为种群规模, D 为解的维数, i 为个体在种群中的序列号)。首先利用式(19)对第 k 代的每个个体进行差分变异操作, 得到新的个体 $\mathbf{V}_i^{k+1}$, 即

$$\mathbf{V}_i^{k+1} = \mathbf{x}_{r1}^k + F(\mathbf{x}_{r2}^k - \mathbf{x}_{r3}^k) \quad (19)$$

式中: $\mathbf{x}_{r1}^k$ 、 $\mathbf{x}_{r2}^k$ 、 $\mathbf{x}_{r3}^k$ 是从第 k 代种群中随机选取的 3 个互异个体; $\mathbf{x}_{r1}^k$ 为父代基向量; $\mathbf{x}_{r2}^k - \mathbf{x}_{r3}^k$ 为父代差分向量, $F \in [0, 2]$ 是变异算子。然后, 利用式(20)对变异个体 $\mathbf{V}_i^{k+1}$ 实施交叉操作生成试验个体:

$$\mathbf{U}_i^{k+1} = (\mathbf{U}_1^{k+1}, \mathbf{U}_2^{k+1}, \cdots, \mathbf{U}_{N_p}^{k+1})$$

$$\mathbf{U}_{ij}^{k+1} = \begin{cases} \mathbf{V}_{ij}^{k+1}, & \text{if } (\text{rand}(j) \leq CR) \text{ or } j = \text{rnbr}(i) \\ \mathbf{X}_{ij}^k, & \text{if } (\text{rand}(j) > CR) \text{ or } j \neq \text{rnbr}(i) \end{cases}$$

$$i = 1, 2, \cdots, N_p; j = 1, 2, \cdots, D \quad (20)$$

式中: $\text{rand}(j)$ 为 $[0, 1]$ 之间均匀分布的随机数; $\text{rnbr}(i)$ 为 $(1, 2, \cdots, D)$ 之间的随机整数, 以确保 $\mathbf{U}_i^{k+1}$ 至少从 $\mathbf{V}_i^{k+1}$ 中获得一个参数; 交叉算子 $CR \in [0, 1]$ 。最后, 按贪婪准则将试验个体 $\mathbf{V}_i^{k+1}$ 与当前种群中的目标向量 $\mathbf{x}_i^k$ 进行比较, 以决定试验个体是否成为下一代中的成员。

对于最小化问题, 则选择目标函数值低的个体作为新种群的个体 $\mathbf{x}_i^{k+1}$, 即

$$\mathbf{x}_i^{k+1} = \begin{cases} \mathbf{V}_{ij}^{k+1}, & \text{if } f(\mathbf{V}_{ij}^{k+1}) \leq f(\mathbf{x}_i^k) \\ \mathbf{x}_i^k, & \text{otherwise} \end{cases} \quad (21)$$

式中: f 为目标函数。

为提高基本 DE 算法的收敛速度, 刘波等^[15]提出了 DE/best/2/bin 变异模式, 其表达式为

$$\mathbf{V}_i^{k+1} = \mathbf{x}_{\text{best}}^k + F(\mathbf{x}_{r1}^k - \mathbf{x}_{r2}^k + \mathbf{x}_{r3}^k - \mathbf{x}_{r4}^k) \quad (22)$$

式中: $\mathbf{x}_{\text{best}}^k$ 为当前最优变异个体。此变异模式的全局搜索能力强、精度高, 但陷入局部最优的可能性加大。由式 (22) 可知, 变异算子 F 越大, $\mathbf{x}_{r1}^k - \mathbf{x}_{r2}^k + \mathbf{x}_{r3}^k - \mathbf{x}_{r4}^k$ 部分对变异个体 $\mathbf{V}_i^{k+1}$ 的贡献越大, 越有利于保持种群的多样性; 反之, $\mathbf{x}_{\text{best}}^k$ 对变异个体 $\mathbf{V}_i^{k+1}$ 的贡献越大, 可避免最优解遭到破坏。同时, 基本 DE 算法中交叉算子 CR 越大, 变异个体 $\mathbf{V}_i^{k+1}$ 对试验个体 $\mathbf{U}_{ij}^{k+1}$ 的贡献越大, 有利于局部搜索和加速收敛速度, 反之, 第 k 代个体 $\mathbf{x}_i^k$ 对试验个体 $\mathbf{U}_{ij}^{k+1}$ 的贡献越大, 有利于保持种群的多样性和全局搜索。本研究在式(22)中引入自适应变异算子 F 和交叉算子 CR:

$$F = F_0 \times 2^{\left(1 - \frac{G_m}{G_m + 1 - G}\right)} \quad (23)$$

$$\text{CR} = \text{CR}_{\min} + \frac{G \times (\text{CR}_{\max} - \text{CR}_{\min})}{G_m} \quad (24)$$

式中: F_0 为初始变异概率; $\text{CR}_{\min}$ 为最小交叉概率; $\text{CR}_{\max}$ 为最大交叉概率; G 为当前进化代数; G_m 为最大进化代数。优化目标函数选为

$$\min \text{MSE} = \min \sum_{i=1}^N \text{MSE}_i = \min \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (25)$$

式中: y_i 和 $\hat{y}_i$ 分别表示第 i 个训练样本的实际值和估计值, N 为样本数。自适应差分进化算法参数设置为 $N_p=30$, $D=2$, $F_0=0.5$, $\text{CR}_{\max}=0.9$, $\text{CR}_{\min}=0.3$ 。

4 工业实例结果分析

为验证软测量模型的有效性, 在工业现场收集了某铁合金厂 30 MW 硅锰合金埋弧冶炼炉大量的工业运行数据。因现场的电压、电流、电耗、炉盖温度等参数每小时记录 1 次, 炉渣成分每炉次化验 1 次, 原料成分每料批记录 1 次, 这些采集参数的数量不等, 在时间上也不完全同步, 本研究建模样本数据取每班的平均值。为避免各变量之间数量级的差异, 消除各因子由于量纲不同而产生的影响, 对数据进行归一化处理。并取 2009 年 4 月至 2009 年 7 月生产 FeMn68Si18 时的生产过程数据共计 300 组作为建模样本数据, 剔除部分记录不全及记录异常的数据后, 保留 258 组数据, 用前 172 组数据作学习样本, 建立软测量模型, 后 86 组作测试样本, 对模型进行实验验证。为不失一般性, 选择炉渣中的 Mn 含量进行在线估计, 经自适应差分进化优化得到 $\sigma^2=0.488$, $C=21.352$ 。验证测试中还将基于 CV-LSSVM 软测量模型的性能与基于 ADE-RLSSVM 软测量模型的性能进行了对比, 结果如图 2 和 3 所示。

为进一步评价模型的性能, 对炉渣中其他 4 种成分也进行了估计, 结果如表 1 所示。表中采用最大相对误差($E_{\max}$)、均方根误差(R_M)和相对均方根误差(R_R)作为性能的评价指标。其中:

$$E_{\max} = \max\left(\frac{|y_i - \hat{y}_i|}{y_i}\right) \quad (26)$$

$$R_M = \sqrt{\frac{1}{l} \sum_{i=1}^l (y_i - \hat{y}_i)^2} \quad (27)$$




图2 CV-LSSVM 模型 Mn 含量的估计结果

Fig.2 Estimate results of Mn content of CV-LSSVM model




图 3 ADE-RLSSVM 模型 Mn 含量的估计结果

Fig.3 Estimate results of Mn content of ADE-RLSSVM model

表 1 CV-LSSVM 软测量模型与 ADE-RLSSVM 软测量模型性能的比较

Table 1 Comparison of performances between CV-LSSVM model and ADE-RLSSVM model

Slag composition/%	CV-LSSVM						ADE-RLSSVM					
	σ^2	C	R_M	$E_{\max}/\%$	$R_R/\%$	Run time/min	σ^2	C	R_M	$E_{\max}/\%$	$R_R/\%$	Run time/min
CaO	0.5	20	1.10	12.8	8.5	43	0.632	18.863	0.81	10.7	6.9	21
MgO	0.5	20	0.61	17.9	9.2	43	0.586	22.325	0.43	13.8	6.2	21
SiO ₂	0.5	20	2.15	13.5	5.1	43	0.527	16.566	1.67	11.3	4.7	21
Al ₂ O ₃	0.5	20	1.36	12.6	8.3	43	0.716	20.937	0.86	10.2	7.3	21

$$R_R = \sqrt{\frac{1}{l} \sum_{i=1}^l \left(\frac{y_i - \hat{y}_i}{y_i} \right)^2} \quad (28)$$

式(27)~(28)中: y_i 和 $\hat{y}_i$ 分别表示第 i 个测量样本的实际值和估计值; l 为待估样本数。

由图 2 和 3 可知, 采用 ADE-RLSSVM 估计炉渣中 Mn 的含量时, 最大相对误差为 7.2%, 且 91.8% 的样本的相对误差小于 5%; 而采用 CV-LSSVM 估计炉渣中 Mn 的含量时, 最大相对误差为 17.3%, 误差小于 5% 样本仅为 35.95%。同时, 由表 1 可知, 当采用 ADE-RLSSVM 软测量模型来估计炉渣中 CaO、MgO、SiO₂ 以及 Al₂O₃ 的含量(质量分数)时, 最大相对误差分别为 6.9%、6.2%、4.7% 和 7.3%, 均小于 CV-LSSVM 模型的估计值, 表明模型的预测精度较高。由表 1 还可以看出, ADE-RLSSVM 模型的相对均方根误差均小于 8%, 表明测量结果能较好地跟踪变化趋势; 运行时间为 21 min, 表明建模速度较快。

5 结论

1) ADE-LSSVM 软测量模型的性能优于

CV-LSSVM 软测量模型的, 其对炉渣中 Mn、CaO、MgO、SiO₂ 以及 Al₂O₃ 含量估计的最大相对误差分别为 7.2%、6.9%、6.2%、4.7% 和 7.3%, 均方根误差分别为 1.53、0.81、0.43、1.67、0.86, 相对均方根误差分别为 7.1%、6.9%、6.2%、4.7%、7.3%, 运行时间为 21 min, 满足工业现场对炉渣成分的测量要求。

2) 该方法为硅锰合金高温埋弧冶炼过程反馈控制、炉况改善、熔炼过程操作优化的有效实施、产品质量的提高和生产节能降耗奠定了基础。

REFERENCES

[1] 史江涛, 马跃庆, 蒋仁全. 锰硅冶炼提高 Mn, Si 回收率的研究与实践[J]. 铁合金, 2006, 186(1): 1-4.
SHI Jiang-tao, MA Yue-qing, JIANG Ren-quan. Study on improving Mn and Si recovery for ferromanganese-silicon smelting and its practice [J]. Chinese Journal of Ferro-Alloys, 2006, 188(3): 1-4.

[2] SINGH V, TATHAVADKAR V, RAO S M, RAJU K S. Predicting the performance of submerged arc furnace with varied raw material combinations using artificial neural network [J]. Journal of Materials Processing Technology, 2007, 183: 111-116.

- [3] HAUKSÐÓTTIR A S, GESTSSON A, VÉSTEINSSON A. Submerged-arc ferrosilicon furnace simulator: Validation for different furnaces and operating ranges[J]. *Control Engineering Practice*, 1998, 6(8): 1035–1042.
- [4] YUAN P, MAO Z Z, WANG F L. Endpoint prediction of EAF based on multiple support vector machines [J]. *Journal of Iron and Steel Research, International*, 2007, 14(2): 20–24.
- [5] 蔡从中, 温玉锋, 朱星键, 裴军芳, 王桂莲, 肖婷婷. 基于工艺参数的7005铝合金力学性能的支持向量回归预测[J]. *中国有色金属学报*, 2010, 20(2): 323–328.
- CAI Cong-zhong, WEN Yu-feng, ZHU Xing-jian, PEI Jun-fang, WANG Gui-lian, XIAO Ting-ting. Quantitative prediction of mechanical properties of 7005 Al alloys from processing parameters via support vector regression [J]. *The Chinese Journal of Nonferrous Metals*, 2010, 20(2): 323–328.
- [6] SUYKENS J A K. Nonlinear model and support vector machines[C]//*IEEE Instrumentation and Measurement Technology Conference*. Budapest: Hungary, 2001: 287–294.
- [7] WANG X F, CHEN J D, LIU C B, PAN F. Hybrid modeling of penicillin fermentation process based on least square support vector machine [J]. *Chemical Engineering Research and Design*, 2010, 88(4): 393–512.
- [8] KUMAR M, KAR I N. Non-linear HVAC computations using least square support vector machines [J]. *Energy Conversion and Management*, 2009, 50: 1411–1418.
- [9] 甘良志, 孙宗海, 孙优贤. 稀疏最小二乘支持向量机[J]. *浙江大学学报: 工学版*, 2007, 47(2): 245–248.
- GAN Liang-zhi, SUN Zong-hai, SUN You-xian. Sparse least squares support vector machine[J]. *Journal of Zhejiang University: Engineering Science*, 2007, 47(2): 245–248.
- [10] HEISTERKAMP D R, PENG J, DAI H K. Adaptive quasiconformal kernel metric for image retrieval [C]//*Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Los Alamitos, CA, USA: IEEE Computer Society, 2001: 388–393.
- [11] BENNETTS K P, EMBRECHTS M J. *Advances in learning theory: Methods models and applications* [M]. Amsterdam: LOS Press, 2003: 227–250.
- [12] 尚万峰, 赵升吨, 申亚东. 遗传优化的最小二乘支持向量机在开关磁阻电机建模中的应用[J]. *中国电机工程学报*, 2009, 29(12): 65–69.
- SHANG Wan-feng, ZHAO Sheng-dun, SHEN Ya-jing. Application of LSSVM optimized by genetic algorithm to modeling of switched reluctance motor [J]. *Proceedings of the CSEE*, 2009, 29(12): 65–69.
- [13] 霍明, 罗滇生, 何井龙. 短期负荷预测中 SVM 参数选取的混沌优化方法[J]. *电力系统及自动化学报*, 2009, 21(5): 124–128.
- HUO Ming, LUO Dian-sheng, HE Jing-long. Chaos optimization method of SVM parameters selection for short-term load forecasting[J]. *Proceedings of the CSU-EPS*, 2009, 21(5): 124–128.
- [14] STORN R, PRICE K. Differential evolution—A simple and efficient heuristic for global optimization over continuous spaces [J]. *Journal of Global Optimization*, 1997, 11(4): 341–359.
- [15] 刘波, 王凌, 金以慧. 差分进化算法研究进展[J]. *控制与决策*, 2007, 22(7): 721–729.
- LIU Bo, WANG Ling, JIN Yi-hui. *Advances in differential evolution*[J]. *Control and Decision*, 2007, 22(7): 721–729.

(编辑 李艳红)