

文章编号:1001-9081(2014)04-1217-05

doi:10.11772/j.issn.1001-9081.2014.04.1217

基于最小二乘支持向量机和遗传算法的 氧化铝悬浮焙烧能耗估计建模

刘代飞^{1*}, 尹吉¹, 丁凤其²

(1. 长沙理工大学 能源与动力工程学院, 长沙 410114; 2. 中南大学 冶金与环境学院, 长沙 410083)

(*通信作者电子邮箱 dfcanfly@tom.com)

摘要:针对氧化铝悬浮焙烧能耗信息表征和模型应用的实际需求,建立一种最小二乘支持向量机(LS-SVM)能耗估计模型。基于该类模型结合遗传算法(GA)提出一种模型参数优化和工业应用策略。采用灰关联分析确定模型的主输入为主炉温度、烟气含氧量、原料含水量;采用K折交叉验证优化样本数据;采用比较模型预测误差确定核函数为径向基函数(RBF)核。建立输入为能耗参数,输出为模型标志的支持向量机工况模型选择器。能耗估计模型的自学习与动态优化通过样本的更新和聚类实现,模型的选择和投运通过模型选择器依据工况状态实施切换。实验结果表明,建立的焙烧能耗估计模型和模型应用策略,能提高模型的泛化能力、增强模型的工况适应性,是一种有效的焙烧能耗参数估计和分析方法。

关键词:氧化铝;气态悬浮炉焙烧;能耗模型;最小二乘支持向量机;遗传算法

中图分类号: TK39; TP183 文献标志码:A

Energy consumption estimation modeling of aluminum hydroxide gas suspension calcinations based on least squares support vector machine and genetic algorithm

LIU Daifei^{1*}, YIN Ji¹, DING Fengqi²

(1. School of Energy and Power Engineering, Changsha University of Science and Technology, Changsha Hunan 410114, China;

2. School of Metallurgy and Environment, Central South University, Changsha Hunan 410083, China)

Abstract: According to the requirement of energy consumption information representation and model application in aluminum hydroxide gas suspension calcinations process, a kind of energy consumption estimation model was established based on Least Squares Support Vector Machine (LS-SVM) method. By combining the energy consumption model with Genetic Algorithm (GA), a kind of parameters optimization and industry application strategy was presented. Input parameters of energy estimation model were analyzed through grey relational analysis method, and the main factors of input parameters consisted of main furnace temperature, oxygen content of exhaust gas and containing water of aluminum hydroxide. The sampled data of energy consumption parameters were regrouped and optimized through K-fold cross-validation method. By comparing prediction accuracy of energy consumption models with various kernel functions, Radial Basis Function (RBF) kernel function was adopted to express feature information of sampling data. A model switcher whose inputs were energy parameters and output was symbol parameter of energy estimation model was constructed by Support Vector Machines (SVM) method. Self-learning and dynamic optimization processes of energy estimation model were realized by sample data updating and clustering. Model selection and application were realized by using the model switcher according to various calcinations conditions. The experimental results show that the LS-SVM modeling and application strategy can improve the generalization capability and conditions adaptability of energy estimation model. The presented strategy of model application is a feasible method for energy parameter analysis and estimation.

Key words: aluminum hydroxide; gas suspension calcinations; energy consumption model; Least Squares Support Vector Machine (LS-SVM); Genetic Algorithm (GA)

0 引言

在氧化铝工业中,气态悬浮炉作为一种焙烧设备已被广泛应用。开展气态悬浮焙烧过程的参数状态监测和能耗估计

分析,对生产过程的优化调节和管理具有重要意义。通过建立焙烧能耗描述模型,借助模型对焙烧过程能耗状况分析和预测是一种有效的优化操作和管理措施。目前有两种建立能耗估计模型的方法:1)基于机理或经验公式的过程描述,如

收稿日期:2013-09-22;修回日期:2013-11-15。

基金项目:国家自然科学基金资助项目(61304019);湖南省教育厅资助项目(11C0025)。

作者简介:刘代飞(1977-),男,湖南临武人,讲师,博士,主要研究方向:复杂工业过程建模、仿真优化与控制;尹吉(1989-),男,湖南永兴人,硕士研究生,主要研究方向:热工过程自控化;丁凤其(1962-),男,湖南湘乡人,副教授,高级工程师,主要研究方向:铝电解过程控制、氧化铝生产与智能控制。

气态悬浮焙烧过程的计算流体动力学(Computational Fluid Dynamic, CFD)建模和数值模拟^[1];2)基于数据驱动模型的描述。通过对过程参数信息的在线采集,获得大量蕴含过程信息的数据样本,基于样本数据集建立过程描述模型。描述氧化铝焙烧的数据驱动模型主要有两类应用:传统统计学的线性回归模型和人工神经网络模型^[2-3]。传统统计学线性回归方法操作简单,建立的模型适合描述参数间表层的关联特性。在处理复杂焙烧过程参数关系或动态信息方面,该类模型存在缺陷。人工神经网络方法适合复杂过程的建模,特别是在具备大数据样本条件时,建立的过程模型能够描述求解问题的非线性。但该类模型存在训练耗时长,容易因“过学习”或“欠拟学习”等现象导致模型参数为自身空间中的局部最优值,并最终影响到模型的泛化能力^[4-5]。基于数据驱动的建模需要具备一定数量的样本数据,而氧化铝工业的连续焙烧生产为此提供了实施条件。对焙烧能耗估计的建模而言,仍有许多问题未得到很好的解决,非常突出的有:如何深入挖掘样本数据中蕴含的信息,如何增强焙烧能耗估计模型的泛化能力,如何实现理论模型在工业生产实践中的有效应用。

支持向量机(Support Vector Machine, SVM)是 Vapnik 等^[6-7]以统计学习理论为基础发展起来的机器学习算法。相对于人工神经网络的学习过程采用经验风险最小化原则,支持向量机采用综合考虑了经验风险和置信风险的结构风险最小化原则,能有效地抑制过学习和欠学习现象,并具有良好的泛化能力。标准 SVM 采用序列最小优化(Sequential Minimal Optimization, SMO)算法求解,在处理大样本时,模型求解时间过长^[8]。最小二乘支持向量机(Least Squares Support Vector Machine, LS-SVM)作为标准 SVM 的一种改进在处理大样本方面有优势^[9-10]。本文采用 LS-SVM 对氧化铝悬浮焙烧过程的能耗参数信息进行分析,建立一种 LS-SVM 能耗估计模型,并结合遗传算法(Genetic Algorithm, GA)开展模型参数的优化。针对焙烧操作的特点,本文在建模过程中开展了焙烧参数信息的优化提取和建模优化。根据焙烧生产和管理的要求,提出一种模型自学习和选择投运的策略。这些举措的实施进一步增强了模型的泛化能力和工况适应性,为过程参数的状态监测和能耗分析提供了一种新方案。

1 建模方法

1.1 最小二乘支持向量机

对研究对象的特征参数 \mathbf{x} 和 \mathbf{y} ,已知样本集 $\{\mathbf{x}_k, y_k\}$, \mathbf{x}_k 是 n 维输入向量, y_k 是一维输出标量。基于该样本集,求解非线性函数关系 $\mathbf{y} = f(\mathbf{x})$ 。SVM 通过映射函数 $\varphi(\mathbf{x})$ 将 \mathbf{x} 由低维空间向高维空间进行转化,并使得要求解的参数关系呈线性化描述:

$$f(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + b \quad (1)$$

在已知样本数据集的基础上,结合权向量 \mathbf{w} 的特定优化目标函数,可求出相应的 $f(\mathbf{x})$ 。不同的优化目标函数形成了不同的 SVM 模型。最小二乘支持向量机采用如下优化函数:

$$\min_{\mathbf{w}, b, e} J(\mathbf{w}, e) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \gamma \frac{1}{2} \sum_{k=1}^N e_k^2$$

$$\text{s. t. } y_k = \mathbf{w}^T \varphi(\mathbf{x}_k) + b + e_k; k = 1, 2, \dots, N \quad (2)$$

对该约束优化问题,构造拉格朗日函数:

$$L(\mathbf{w}, b, e; \alpha) = J(\mathbf{w}, e) - \sum_{k=1}^N \alpha_k \{ \mathbf{w}^T \varphi(\mathbf{x}_k) + b + e_k - y_k \} \quad (3)$$

其中 α_k 是拉格朗日乘子。将 L 对 4 个变量分别求导:

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{w} = \sum_{k=1}^N \alpha_k \varphi(\mathbf{x}_k) \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{k=1}^N \alpha_k = 0 \\ \frac{\partial L}{\partial e_k} = 0 \rightarrow \alpha_k = \gamma e_k, k = 1, 2, \dots, N \\ \frac{\partial L}{\partial \alpha_k} = 0 \rightarrow \mathbf{w}^T \varphi(\mathbf{x}_k) + b + e_k - y_k = 0, k = 1, 2, \dots, N \end{cases} \quad (4)$$

将式(4)代入式(2),消去 \mathbf{w} 和 e ,整理得 α 和 b 线性方程:

$$\begin{bmatrix} 0 & 1^T \\ 1 & \mathbf{Q} + \frac{\mathbf{I}}{\gamma} \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (5)$$

其中: $\mathbf{y} = [y_1; \dots; y_N]^T$, $1^T = [1; \dots; 1]$; $\alpha = [\alpha_1; \dots; \alpha_N]^T$ 。

采用核函数变换:

$$\Omega_{kl} = \varphi(\mathbf{x}_k)^T \varphi(\mathbf{x}_l) = K(\mathbf{x}_k, \mathbf{x}_l); k = 1, 2, \dots, N \quad (6)$$

由式(5)求得 α 和 b ,则函数估计模型变为:

$$f(\mathbf{x}) = \sum_{k=1}^N \alpha_k K(\mathbf{x}, \mathbf{x}_k) + b \quad (7)$$

核函数的基本作用就是通过接受两个低维空间里的向量,计算出变换后在高维空间里的向量内积值。满足 Mercer 条件的函数都可作为核函数。常用核函数有线性核、多项式核、径向基核、感知器核、样条核函数等。核函数本身也会带一定的参数,如径向基核:

$$K(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{2\delta^2}\right) \quad (8)$$

其中参数 δ 是核函数参数。由此可见,此时 LS-SVM 的建模还需要给定一组模型参数 $\{\gamma, \delta_1, \delta_2, \dots, \delta_i\}$, 其中: γ 为目标函数式(2)的参数, δ_i 为核函数的参数。基于已知样本数据集 $\{\mathbf{x}_k, y_k\}_{k=1}^N$ 和模型参数集 $\{\gamma, \delta_1, \delta_2, \dots, \delta_i\}$ 即可实现 LS-SVM 的非线性函数关系的估计。

1.2 遗传算法优化 LS-SVM 参数

模型参数的优化是必不可少的重要环节。基于某给定的模型训练数据集、验证数据集和核函数,必须实现参数组 $\{\gamma, \delta_1, \delta_2, \dots, \delta_i\}$ 的寻优。本文采用遗传算法开展参数的优化。遗传算法是一种模仿生物进化过程的智能搜索算法,通过计算机程序实现繁殖、变异、杂交、选择和竞争等过程,可以在复杂、多峰、非线性的空间中实现全局搜索^[11-13]。

对 $\{\gamma, \delta_1, \delta_2, \dots, \delta_i\}$ 进行实数编码,选择适应函数:

$$F = \left\{ \frac{1}{N} \sum [y_k - f(\mathbf{x})]^2 \right\}^{-\frac{1}{2}} \quad (9)$$

其中: y_k 为验证数据集的输出实际值, $f(\mathbf{x})$ 为 LS-SVM 的预报值。设群体由 n 个个体组成,第 i 个个体的适应度为 F_i ,群体进化代数为 g ,则遗传迭代计算过程如下。

1) $g = 0$,随机产生 n 个个体,构成初始群体。

2) 计算每个个体的适应度 F_i 。

3) 按下列步骤产生新的群体,直到新群体的个体总数为 n :

① 以概率 $F_i / \sum F_i, F_j / \sum F_j$ 从群体中选择两个个体 G_{α}, G_{β} ;

② 以概率 P_c 对 G_{α}, G_{β} 进行基因交叉操作,获得新个体

G_{α}, G_{β} ;

③ 以概率 P_m 使 G_{α}, G_{β} 中特定基因位产生突变。

4) 若 g 达到预定的群体进化迭代数则停止;否则 $g = g + 1$,并返回2)。

具体的LS-SVM建模和GA优化过程如图1所示。

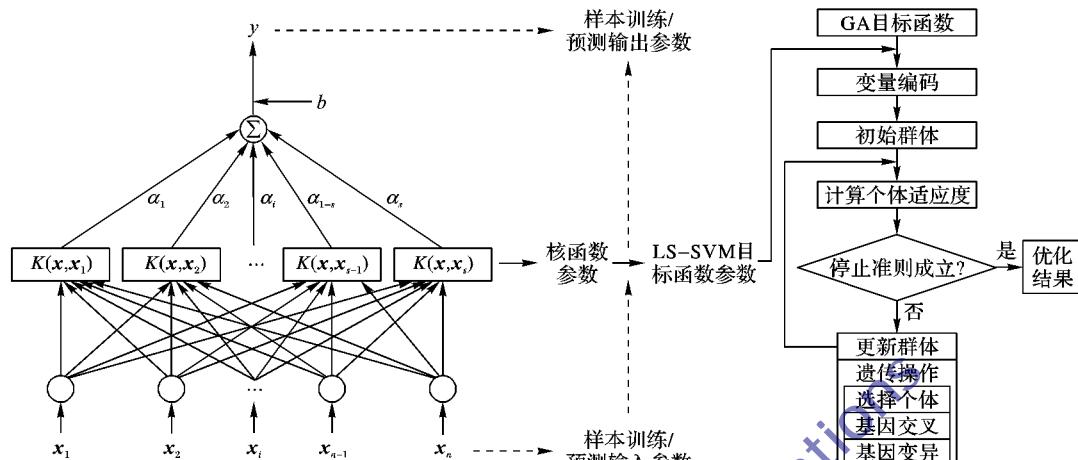


图1 LS-SVM的遗传优化求解过程

2 能耗估计模型的建立和应用

2.1 模型的建立

以氧化铝气态悬浮焙烧过程为研究对象,能耗估计模型的输入 x 具体如下:氢氧化铝的下料量、氢氧化铝的含水量、燃气的流量、燃气的成分、空气的流量、主炉温度、烟气含氧量、漏风量。模型的输入 y 即为单位产量的焙烧能耗。实际生产是一连续过程,焙烧原料的物化特性具有批量性特点,同批次原料的物化特性较为稳定,因此本文采用单位时间内的产量来间接描述能耗。基于样本数据集 $\{x_k, y_k\}_{k=1}^N$ 建立 $y = f(x)$ 函数估计模型,并使其具有良好的泛化能力,还必须解决以下关键问题:

- 1) 对 n 维的 x 如何确定主要影响参数,实现 x 的降维;
- 2) 如何划分模型训练和验证数据样本集;
- 3) 如何选择核函数。

为此本文采用如下策略:

- 1) 采用灰关联分析确定 x 的主因素。

焙烧过程 x 的影响因素众多,对建模而言并非所有的参数都必须考虑,实际上某些参数在定性分析中不是主因,定量标定时变化也不大。因此分析确认此类参数可进一步简化模型结构,突出影响因素的主要矛盾。本文采用灰关联分析确定 x 的主因素,实施模型输入的降维处理。灰关联分析根据各参数几何曲线的相似程度来判断其联系是否密切,曲线的形状越接近,相应序列之间的关联度就越大;反之就越小。相似程度应用关联系数和关联度描述,关联度描述了各个因素对结果的影响程度。关联度越大,影响程度越大^[14]。对某批样本进行数据灰关联分析,采用初值化数据,灰关联矩阵如表1所示,确定 x 的主因素为主炉温度、烟气含氧量、原料含水量。

- 2) 采用交叉验证法规划建模样本。

建模时为了挖掘样本集的有效信息,本文采用交叉验证法确定建模样本。将样本数据集划分为训练集、效验集和测试

集。对训练集和效验集构成的总样本实施 K 折交叉验证法(K -fold Cross-Validation)建模^[15-17]。具体操作为:将总样本平均分成 k 份,轮流选择其中 $k - 1$ 份参与模型训练,剩余的一份进行验证;如此重复 k 次,每个子样本验证一次,平均 k 次的结果,当验证数据误差总和最小时停止训练。

表1 以台时产量为参考因素的参数灰关联分析结果

数据	主炉温度	原料含水量	烟气含氧量	漏风率
1	1.0000	1.0000	1.0000	1.0000
2	0.9380	0.5490	0.9110	0.3370
3	0.8940	0.7020	0.8920	0.8920
4	0.8970	0.4940	0.5280	0.5280
5	0.8980	0.4220	0.5310	0.4790
6	0.8540	0.5460	0.8460	0.3470
7	0.8520	0.9150	0.7570	0.3490
8	0.8650	0.5720	0.5470	0.5470
9	0.6430	0.9820	0.8380	0.7560
10	0.7218	0.3333	0.5309	0.7312
关联度	0.8564	0.6515	0.7380	0.5965

- 3) 采用对比建模选择核函数。

LS-SVM建模中核函数的选择非常关键。选择的核函数要尽可能地反映实际求解问题样本数据的分布特性。目前还没有一种针对具体问题构造出合适核函数的有效方法,选择何种核函数也缺乏理论依据^[18]。为此本文采用对比建模来确定核函数,将从某氧化铝厂实际生产数据中获的样本分为训练数据150组,测试数据50组。基于训练数据进行 $K = 15$ 折交叉验证建模获得最佳训练模型,分析模型对测试数据的预报误差比较泛化性能。分别采用线性核、多项式核、径向基核进行建模,比较10次建模后模型预报的均方根误差的平均值。建模结果见表2,其中径向基核模型的预报误差最小,模型对应的预测结果如图2所示,可见采用径向基核的模型具有良好的样本辨识和泛化性能。

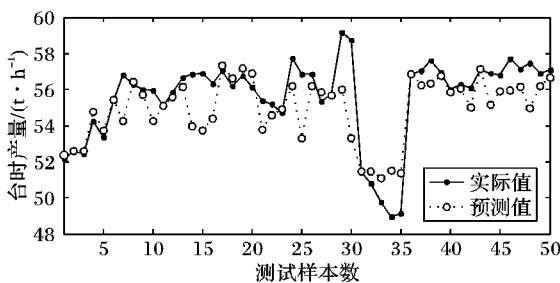


图2 径向基核模型的预测结果

表2 基于特定样本的核函数建模比较

核函数	训练的 均方根误差 (10次平均)	预报的 均方根误差 (10次平均)	对应的最佳 模型参数
线性核 $x_i^T x_j$	1.69	2.02	$\gamma = 0.209$
多项式核 $(x_i^T x_j + t)^d$	1.26	2.56	$\gamma = 0.049, t = 1.48, d = 3$
径向基核 $\exp\left(-\frac{\ x_i - x_j\ ^2}{2\delta^2}\right)$	0.86	1.36	$\gamma = 2.892, \delta^2 = 0.7183$

2.2 模型的应用

焙烧生产为连续、动态、时变过程,当系统运行一段时间后,原料、燃料发生变化,对应的适宜控制参数,以及参数之间的对应关系也将改变。这要求建立的模型应具备一定的自学习能力,以满足模型结构的时效性;模型的投运应该有相关的协调机制,以满足系统多模型的工况适应性。为此,本文建立了如图3所示的模型应用策略。

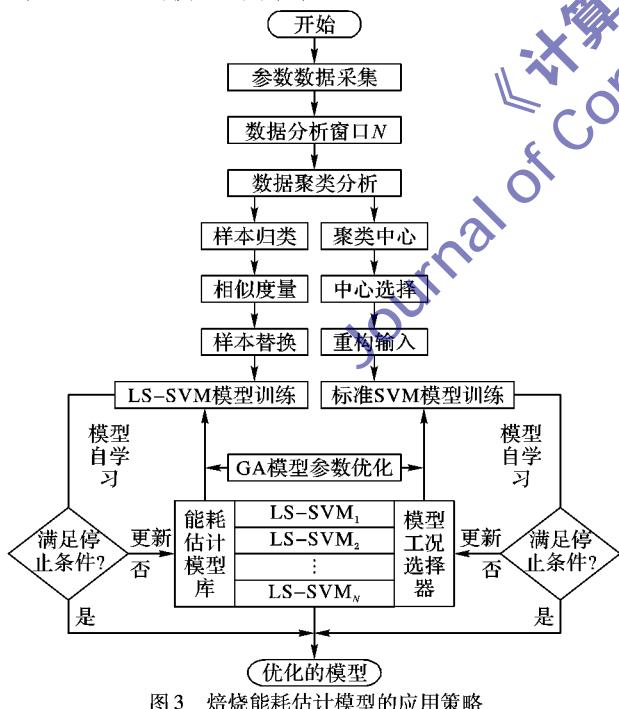


图3 焙烧能耗估计模型的应用策略

1) 模型的自学习与动态优化

确定核函数后,自学习过程有两大主要任务:①提取新息数据,构建新的模型训练样本数据;②优化模型参数 $\{\gamma, \delta_1, \delta_2, \dots, \delta_i\}$ 组。在提取新息时,本文采用固定数据窗,当新数据进入分析窗,达到窗口设定值后,即启动样本的分析。首先对分析窗数据实施聚类,并将分析结果归类到LS-SVM训练样本类集内;然后对旧样本集进行样本更新,样本数据替换采用相似度度量:

$$\cos \theta_{x_i, x_j} = \frac{x_i \cdot x_j}{(\|x_i\| \cdot \|x_j\|)^{1/2}} = \frac{\sum_{a=1}^p x_{ai} x_{aj}}{\sqrt{\sum_{a=1}^p x_{ai}^2} \cdot \sqrt{\sum_{a=1}^p x_{aj}^2}} \quad (10)$$

其中: x_i, x_j 为两个样本; p 为样本中输入变量的个数; $\cos(\theta_{x_i, x_j})$ 越接近1,表明两者越相似。

样本数据更新后,结合遗传算法对LS-SVM模型参数 $\{\gamma, \delta_1, \delta_2, \dots, \delta_i\}$ 开展遗传优化迭代计算。实际生产中大批量氧化铝同批次的焙烧时间多在30 min以上,这个时间间隔可以满足遗传寻优计算。

2) 模型的工况分类与自动切换

在焙烧能耗估计LS-SVM模型时,由于采用的建模样本不同,建立的模型也会不同。在多模型条件下,如何根据工况的变化选择合适的模型投运对实际生产操作的指导更为关键。因受样本数量的制约和焙烧原料批量特性等因素的影响,在采用单一模型全程投运的方式中,LS-SVM模型预测结果往往具有工况区间性,即在特定工况条件下某模型的估计效果好,而当工况改变后此模型应用效果变差。其主要原因是建模用样本不能很好地提供工况全局性的信息,为此,本文采用标准的SVM算法构建模型工况选择器。具体过程如下:分别对焙烧能耗模型输入 x 各分量的原始样本数据进行聚类,并将聚类中心重构成模型工况选择器的输入样本,该选择器的输出是焙烧能耗估计模型的标示量。例如通过建模获得9个焙烧能耗LS-SVM模型,此时可用数字量1~9分别表示9个模型,结合聚类后的输入样本对SVM工况选择器进行训练和验证。最终将该模型作为焙烧能耗估计LS-SVM多个模型实体的选择依据,以此来弥补单一模型提取工况变化信息不充分的缺点。本文在两种工况调整时分别选择固定模型和切换模型作为实际投运方式,系统数据点的采样频率为1 min一次,模型运行结果如图4。其中,采用模型选择器后的变模型方案,无论是离线预测还是实际投运计算,对单位时间产能的估值误差都比定模型的误差要小,可见该方法可强化焙烧能耗LS-SVM模型的估计效果。

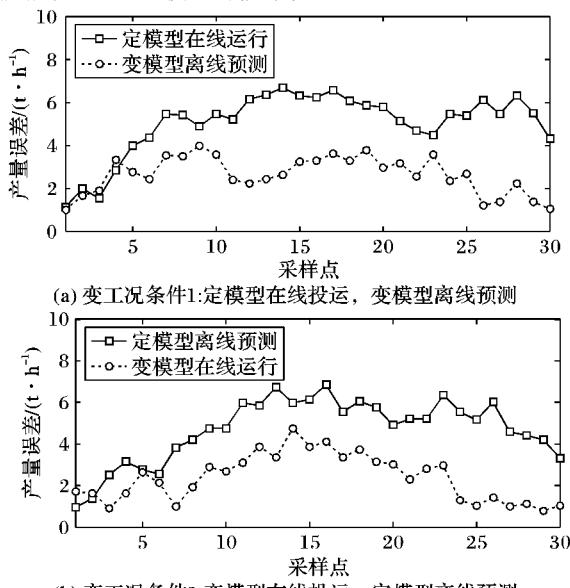


图4 焙烧能耗模型不同投运情况比较

3 结语

针对传统回归模型和人工神经网络模型描述氧化铝气态悬浮焙烧能耗参数关系的不足,本文采用 LS-SVM 方法构建能耗估计模型,结合遗传算法优化模型参数。建模时,采用灰关联分析精简输入参数维度,确定主炉温度、烟气含氧量、原料含水量为主参数;采用交叉验证法规划建模样本,通过对比建模,确定采用径向基核函数。获得的 LS-SVM 模型在训练和预测精度上都能满足建模需求,模型具有良好的泛化能力。

根据生产过程对能耗估计模型投运的要求和模型投运的特点,提出了一种新的模型应用策略;建立了 GA-LS-SVM 模型自学习机制,实现模型的动态优化;建立了工况分类模型 SVM 选择器,指导模型选择和投运。应用表明,该策略能增强模型的适应性,保证了能耗估计 LS-SVM 模型的工业应用,为后续能耗状态的跟踪和管理工作奠定了基础。

参考文献:

- [1] LIU D F, DING F Q, ZHANG H L. Numerical simulation of high temperature air combustion in aluminum hydroxide gas suspension calcinations [J]. Transactions of Nonferrous Metals Society of China, 2009, 19(1): 259 – 266.
- [2] WEI H. Relationship of process parameters and capacity and consumption of Al(OH)_3 gas suspension calciner [J]. Light Metals, 2003(1): 13 – 18. (卫璜. Al(OH)_3 气态悬浮焙烧工艺参数与产能、消耗的关系[J].轻金属, 2003(1): 13 – 18.)
- [3] LI J, LIU D F, DAI X R, et al. Prediction of Al(OH)_3 fluidized roasting temperature based on wavelet neural network [J]. Transactions of Nonferrous Metals Society of China, 2007, 17(5): 1052 – 1056.
- [4] WANG K, YANG J, WANG L, et al. Review on generalization problem of artificial neural network [J]. Application Research of Computers, 2008, 25(12): 3525 – 3530. (王恺, 杨巨峰, 王立, 等.人工神经网络泛化问题研究综述[J].计算机应用研究, 2008, 25(12): 3525 – 3530.)
- [5] ZHAO Y, HU W. Improve the generalization capability of artificial neural network [J]. Journal of Nanjing University of Information Science and Technology: Natural Science Edition, 2011, 3(2): 164 – 167. (赵远东, 胡为尧.人工神经网络泛化性能改进[J].南京信息工程大学学报:自然科学版, 2011, 3(2): 164 – 167.)
- [6] VAPNIK V N, GOLOWIEH S E, SMOLA A. Support vector method for function approximation, regression estimation, and signal processing [C]// Adavanees in Neural Information Processing Systems 1996. Cambridge: MIT Press, 1997: 281 – 287.
- [7] VAPNIK V N. The nature of statistical learning theory [M]. ZHANG X, translated. Beijing: Tsinghua University Press: 2000: 126 – 150. (VAPNIK V N. 统计学习理论本质[M]. 张学工,译.北京:清华大
- [8] SUWANKAWIN S, SANGWONGWANICH S. A speed-sensorless IM drive with decoupling control and stability analysis of speed estimation [J]. IEEE Transactions on Industrial Electronics, 2002, 49(2): 444 – 455.
- [9] SUWANKAWIN S, SANGWONGWANICH S. Design strategy of an adaptive full-order observer for speed-sensorless induction-motor drives-tracking performance and stabilization [J]. IEEE Transactions on Industrial Electronics, 2006, 53(1): 96 – 119.
- [10] ZAKY M S. Stability analysis of speed and stator resistance estimators for sensorless induction motor drives [J]. IEEE Transactions on Industrial Electronics, 2012, 59(2): 858 – 870.
- [11] LUO H. Research on the full-order flux observer and the speed es-
- [12] DING S, QI B, TAN H. An overview on theory and algorithm of support vector machines [J]. Journal of University of Electronic Science and Technology of China, 2011, 40(1): 2 – 10. (邓世飞, 齐丙娟, 谭红艳. 支持向量机理论与算法研究综述[J]. 电子科技大学学报, 2011, 40(1): 2 – 10.)
- [13] SUYKENS J A K, van GESTEL T, de BRABANTER J, et al. Least squares support vector machines [M]. Singapore: World Scientific, 2002: 71 – 111.
- [14] ISMAIL S, SHABRI A, SAMSUDIN R. A hybrid model of Self-organizing Maps (SOM) and Least Square Support Vector Machine (LSSVM) for time-series forecasting [J]. Expert Systems with Applications, 2011, 38(8): 10574 – 10578.
- [15] THI N, LEE G B, WHEELER P, et al. GA-SVM based framework for time series forecasting [C]// ICNC 2009: Proceedings of the 5th International Conference on Natural Computation. Washington, DC: IEEE Computer Society, 2009: 493 – 498.
- [16] TEOH E J, XIANG C. Feature selection and classification via a GA-SVM hybrid [C]// GEM 2008: Proceedings of the 2008 International Conference on Genetic and Evolutionary Methods. Athens, GA: CSREA Press, 2008: 83 – 89.
- [17] LIU H B, JIAO Y B. Application of genetic algorithm-support vector machine (GA-SVM) for damage identification of bridge [J]. International Journal of Computational Intelligence and Applications, 2011, 10(4): 383 – 397.
- [18] LIU S, GUO T, DANG Y. The theory and application of grey system [M]. Beijing: Science and Technology Press, 1999: 49 – 111. (刘思峰, 郭天榜, 党耀国. 灰色系统理论及应用[M]. 北京: 科学技术出版社, 1999: 49 – 111.)
- [19] DING C, WANG L. BP neural network application in turbine fault diagnosis base on the cross-validation [J]. Electric Power Science and Engineering, 2008, 24(3): 31 – 34. (丁常富, 王亮. 基于交叉验证法的 BP 神经网络在汽轮机故障诊断中的应用[J]. 电力科学与工程, 2008, 24(3): 31 – 34.)
- [20] MORENO-TORRES J G, SAEZ J A, HERRERA F. Study on the impact of partition induced dataset shift on k-fold cross-validation [J]. IEEE Transactions on Neural Networks and Learning Systems, 2012, 23(8): 1304 – 1312.
- [21] BAYKAN N A, YILMAZ N. A mineral classification system with multiple artificial neural network using k-fold cross validation [J]. Mathematical and Computational Applications, 2011, 16 (1): 22 – 30.
- [22] FENG G. Parameter optimizing for support vector machines classification [J]. Computer Engineering and Applications, 2011, 47(3): 123 – 124. (奉国和. SVM 分类核函数及参数选择比较[J]. 计算机工程与应用, 2011, 47(3): 123 – 124.)

(上接第 1216 页)

- [8] SUWANKAWIN S, SANGWONGWANICH S. A speed-sensorless IM drive with decoupling control and stability analysis of speed estimation [J]. IEEE Transactions on Industrial Electronics, 2002, 49(2): 444 – 455.
- [9] SUWANKAWIN S, SANGWONGWANICH S. Design strategy of an adaptive full-order observer for speed-sensorless induction-motor drives-tracking performance and stabilization [J]. IEEE Transactions on Industrial Electronics, 2006, 53(1): 96 – 119.
- [10] ZAKY M S. Stability analysis of speed and stator resistance estimators for sensorless induction motor drives [J]. IEEE Transactions on Industrial Electronics, 2012, 59(2): 858 – 870.
- [11] LUO H. Research on the full-order flux observer and the speed es-

timation method of the induction motor [D]. Wuhan: Huazhong University of Science and Technology, 2009: 63 – 76. (罗慧. 感应电机全阶磁链观测器和转速估算方法研究[D]. 武汉: 华中科技大学, 2009: 63 – 76.)

- [12] YING K, JIANG L, LI H, et al. Vector control fuzzy system based on rotor parameter identification for induction motor [J]. Journal of Computer Applications, 2013, 33(S1): 303 – 306. (应凯, 蒋林, 李洪波, 等. 基于转子参数辨识的感应电机矢量控制模糊系统[J]. 计算机应用, 2013, 33(S1): 303 – 306.)
- [13] HONG N. Matlab simulation of power electronics and electrical drive control system [M]. Beijing: China Machine Press, 2006: 196 – 211. (洪乃刚. 电力电子和电力拖动控制系统的 Matlab 仿真 [M]. 北京: 机械工业出版社, 2006: 196 – 211.)