

基于 LS-SVM 稀疏化算法的飞灰含碳量软测量方法

张大海¹, 楼锐¹, 刘宇穗¹, 王晓雄¹, 张世荣²

(1. 中国能源建设集团广东省电力设计研究院有限公司, 广州 510663; 2. 武汉大学 动力与机械学院, 武汉 430072)

摘要: [目的]为了解决经典迭代剪切稀疏化算法在飞灰含碳量软测量模型应用中计算量过大问题, 提出了一种基于样本分布特征的 LS-SVM 稀疏化算法。[方法]算法在计算样本特征空间距离基础上, 融合密度和离散度构建全局代表性指标, 并按此指标对原始样本集进行排序和剪切, 完成稀疏化。为验证算法性能将提出的算法应用到某 1 000 MW 火电机组飞灰含碳量软测量模型, 训练样本集取自机组现场试验数据。[结果]结果表明: 本算法能在适当牺牲误差性能的情况下大大消减样本容量, 显著降低飞灰含碳量 LS-SVM 软测量模型训练及在线预测计算量。[结论]所提 LS-SVM 稀疏化算法在保证误差值降低 0.01% 的情况下, 将样本空间从 90 个缩小到 30 个, 既减小了计算规模, 又保证了计算精度。所提算法可在 PLC 等计算性能受限的工业控制器中实现飞灰含碳量在线软测量功能, 并可推广至发电厂其他参数软测量系统。

关键词: 飞灰含碳; 稀疏化; 全局代表性指标; 软测量

中图分类号: TM611; TP274.2

文献标志码: A

文章编号: 2095-8676(2019)04-0069-06

A Soft Measurement Method for Carbon Content of Fly Ash Based on Sparseness Approach for LS-SVM

ZHANG Dahai¹, LOU Rui¹, LIU Yusui¹, WANG Xiaoxiong¹, ZHANG Shirong²

(1. China Energy Engineering Group Guangdong Electric Power Design Institute Co., Ltd., Guangzhou 510663, China;

2. School of Power and Mechanical Engineering, Wuhan University, Wuhan 430072, China)

Abstract: [Introduction] The paper aims to establish a sparseness approach based sample distribution for LS-SVM models to solve the problem of excessive computation in the application of classical iterative shearing sparseness algorithm for the soft measurement model of the carbon content in flying ash. [Method] On the basis of calculating the feature space distance between the samples, global representative indicator is constructed by mixing together the density and dispersion. The original samples were sorted and pruned and the sparseness was realized according to the indicator. The LS-SVM soft measurement model of the carbon content in fly ash was applied to a 1 000 MW coal-fired power plant, the original training sample set was taken from the field operation data of the unit. [Result] The results show that the proposed algorithm can greatly reduce the capacity of the training set with tiny loss of the error performance and it can reduce the training and online prediction calculation work during the LS-SVM soft measurement model of the carbon content in fly ash. [Conclusion] The LS-SVM sparse algorithm proposed in this paper reduces the sample space from 90 to 30, which not only reduces the calculation scale, but also guarantees the calculation accuracy, while guaranteeing that the error is reduced by 0.01%. The algorithm can realize on-line soft measurement of carbon content in fly ash in industrial controllers with limited computing performance such as PLC, and can be extended to other parameters soft measurement systems in power plants.

Key words: carbon content of fly ash; sparseness; global representative indicator; soft measurement

国家能源政策的逐步推进, 对传统火力发电行

业提出了更高的要求, 发电企业需要不断提高发电效率和改进环保排放指标。对设备进行升级和运行过程优化是提升效率、降低排放指标的主要途径; 运行过程优化需要机组更多的参数种类及更全面的参数数量。火力发电流程复杂运行方式多变, 一些

对运行优化尤为重要的热工参数(如燃料发热量、煤粉颗粒粗细、烟气含氧量、飞灰含碳量等),目前尚无成熟的传感设备实现直接测量。另一方面,机组控制系统及管理系统存储了海量运行参数,这使得基于数据的热工参数软测量成为可能^[1~2]。近年来,主元分析法、偏最小二乘法、神经网络(ANN)法、支持向量机(Support vector machine, SVM)以及模糊理论等在发电厂软测量中都有研究。其中,支持向量机尤其获得了关注^[3~6]。Vapnik等人提出的支持向量机方法^[7],广泛应用于模式识别和函数估计。支持向量机算法需要求解受不等式约束的二次型规划问题,建模过程复杂。Suykens提出的最小二乘支持向量机算法(Least square support vector machine, LS-SVM)^[8]可以大大减少建模计算量。LS-SVM建模时只需求解线性方程组,运算速度更快,适合工业设备现场应用。

作者在电站锅炉飞灰含碳量在线软测量系统研制时,为了确保软测量装置的运行可靠,采用PLC作为计算平台。PLC作为常用的工业控制器,其控制能力强大,但存储空间和计算资源相对有限,LS-SVM更加适合飞灰含碳量的在线测量环境。与SVM相比,LS-SVM的所有样本都是模型的支持向量,失去稀疏性,这是LS-SVM固有的缺点。随着训练样本集数据量的增加,LS-SVM的弱点将越来越突出地表现出来,为了提高模型计算速度。需要对模型进行稀疏化处理。Suykens提出了一种迭代LS-SVM稀疏算法^[9],通过对样本支持值进行排序处理,并按照一定规则通过剔除样本的方法实现稀疏化。文献[10]通过剔除具有最小引入误差的样本来实现稀疏化。文献[11~13]将上述方法应用到了实际工程和后续研究中。文献[14~15]将LS-SVM稀疏化作为最优问题进行研究,以剪切率为优化变量,采用PSO来解优化问题。文献调研表明,迭代算法依然是LS-SVM稀疏化算法的主要研究方向。每一次迭代都需要先训练LS-SVM模型,再按预设的指标进行样本剪切。每次LS-SVM模型训练都要根据当前支持向量集求解线性系统,若数据量较大,稀疏化算法的计算复杂性会非常高。文献[16]提出了一种非迭代LS-SVM稀疏化算法,以数据特征空间全局代表性为样本剪切指标。文献[17]将LS-SVM软测量算法应用于PLC系统实现了飞灰含碳的在线软测量。本文从锅炉飞灰含碳量在线软测

量的实际应用环境出发,应用LS-SVM算法来减轻PLC的计算量,并基于样本分布特征对LS-SVM软测量模型进行稀疏化,以某1000MW机组的实际运行数据为例验证了此稀疏化算法的有效性。

1 飞灰含碳量 LS-SVM 软测量模型

1.1 输入参数

飞灰含碳量是影响锅炉燃烧效率的关键因素,也是锅炉燃烧优化调整的主要参考参数。锅炉燃烧过程复杂,无法直接建立飞灰含碳量测量的数学模型,通过燃烧过程运行数据建立飞灰含碳量软测量模型,是实现飞灰含碳量在线软测量的有效手段。

本文以广东某电站1000MW机组为研究对象,通过现场调研及运行参数的相关性分析,软测量模型选取了发电机功率、末级过热器温度平均值、高温再热蒸汽平均温度、炉膛压力、二次风门平均开度、热二次风箱与炉膛差压、一次风压、煤机瞬时给煤量、尾部烟道出口含氧量、空预器出口烟气温度等25个SIS系统中已有的参数作为二次变量;并采用飞灰含碳量化验值用作对比。目前对飞灰含碳量软测量的研究大都以锅炉当前运行参数 $x(t)$ 为模型输入预测对应时刻输出。锅炉燃烧过程是一个典型的动态过程,即飞灰含碳量 $y(t)$ 不仅与对应时刻的输入 $x(t)$ 有关,还与输入向量 $x(t)$ 及飞灰含碳量 $y(t)$ 的历史值有关。为此,本文考虑飞灰含碳量的动态规律,引入阶数和延迟系数重构输入向量。输入向量重构实质上是一种向量扩维过程,阶数高意味着向量维数大,将导致后续计算量激增。为了适应本项目采用的PLC计算平台,将输入向量的阶数设定为1,按照式(1)重构模型的输入变量:

$$\begin{aligned}x(t) = & [x_1(t-d_1), x_2(t-d_2), \dots, x_{25}(t-d_{25}), \\& x_1(t-\Delta t-d_1), x_2(t-\Delta t-d_2), \dots, \\& x_{25}(t-\Delta t-d_{25})]\end{aligned}\quad (1)$$

式中: $d_i(i=1, \dots, 25)$ 为各运行参数的延迟时间,s; Δt 为采样时间,s。炉内各参数对飞灰的影响迅速,延迟时间应设置较小;而炉外参数(例如,煤机瞬时给煤量)则需要设置较大的延迟时间。

1.2 飞灰含碳量 LS-SVM 预测模型

支持向量机回归采用如下形式对未知函数进行预估:

$$y_t(x) = \omega^T \varphi(x) + b \quad (2)$$

式中: $\varphi(\cdot)$ 为非线性函数, 将输入空间映射到高维特征空间; 输入向量为 x , 预测输出为 y_t , 待求参数为向量 ω 和偏置 b , 采用误差平方代替松弛变量, 将 SVM 优化问题转化为如下 LS-SVM 回归优化问题:

$$\min T(\omega, e) = \frac{1}{2} \omega^T \omega + \gamma \frac{1}{2} \sum_i^N e_k^2$$

s. t.

$$y_k = \omega^T \varphi(x_k) + b + e_k \quad (3)$$

式中: 误差变量为 $e = [e_1, \dots, e_N]$, 惩罚系数为 γ 。定义拉格朗日函数:

$$L(\omega, b, e, \alpha) = T(\omega, e) - \sum_{k=1}^N \alpha_k \{\omega^T \varphi(x_k) + b + e_k - y_k\} \quad (4)$$

式中: $\alpha = [\alpha_1, \dots, \alpha_N]$ 为拉格朗日乘子。对(4)式计算对 ω , b , e , α 的偏导:

$$\left. \begin{array}{l} \frac{dL}{d\omega} = 0 \rightarrow \omega = \sum_{k=1}^N \alpha_k \varphi(x_k) \\ \frac{dL}{db} = 0 \rightarrow \sum_{k=1}^N \alpha_k = 0 \\ \frac{dL}{de_k} = 0 \rightarrow \alpha_k = \gamma e_k \\ \frac{dL}{d\alpha_k} = 0 \rightarrow \omega^T \varphi(x_k) + b + e_k - y_k = 0 \end{array} \right\} \quad (5)$$

消除式中 ω 和 e_k , 可得线性系统:

$$\begin{bmatrix} 0 & E^T \\ E & \Omega + \gamma^{-1} I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (6)$$

式中: $y = [y_1, \dots, y_N]^T$, $E = [1, \dots, 1]_{1 \times N}^T$, I 为单位矩阵。

$$\Omega: \Omega_{kd} = \varphi(x_k)^T \varphi(x_d) = K(x_k, x_d) \quad (7)$$

式中: $k, d = 1, \dots, N$; $K(x_k, x_d)$ 为核函数, 通过核函数将原输入空间 R^N 映射到高维再生核特征空间 Z , 并将求解非线性问题转换为求解线性问题。令 $U = (\Omega + \gamma^{-1} I)^{-1}$, 根据式(7)可得:

$$b = \frac{E^T U y}{E^T U E} \quad (8)$$

$$\alpha = U \left[y - \frac{E E^T U y}{E^T U E} \right] \quad (9)$$

得到 LS-SVM 的预测模型:

$$y_t(x) = \sum_{k=1}^N \alpha_k K(x, x_k) + b \quad (10)$$

式中: α_k 为相应样本的支持值。

在锅炉飞灰含碳量 LS-SVM 模型中, 样本 x_k 为采用式(1)重构的锅炉运行参数向量, y_k 为飞灰化验值。LS-SVM 模型训练时, 取训练样本集按照(8)–(9)计算获得 α 和 b 。实时预测时, 用实时运行参数按式(10)即可获得飞灰含碳量预测值。另外, 式(5)表明 $\alpha_k = \gamma e_k$, 而 $e_k \neq 0$, 故 $\alpha_k \neq 0$; 即所有训练样本成为支持向量, LS-SVM 失去了稀疏性。随着训练样本的增加, 模型维数相应提高, 算法计算量会急剧增加, 影响算法的应用效果, 因此需对 LS-SVM 模型稀疏化处理。

2 基于样本分布特征稀疏化算法

2.1 全局代表性指标

LS-SVM 稀疏化是从原始训练数据集中选择若干数据点, 并通过计算使得基于选择数据点的决策超平面具有类似于未稀疏化 LS-SVM 的泛化能力。不同的稀疏化算法具有不同的样本选择指标, 在传统 LS-SVM 稀疏化算法中一般以支持值的绝对值 $|\alpha_i|$ 为选择指标, 文献[16]则按照样本的全局代表性进行选择。

LS-SVM 算法引入核函数, 将原始样本空间扩维到高维空间, 实现样本线性可分, 定义两点间的距离为:

$$d(x_1, x_2) = \sqrt{K(x_1, x_1) + K(x_2, x_2) - 2K(x_1, x_2)} \quad (11)$$

在距离基础上定义数据点 x 的密度:

$$\rho(x) = \sum_{j=1}^{N-1} \delta(d(x, x_j)) \quad (12)$$

其中

$$\delta(z) = \begin{cases} 1, z \leq \theta \\ 0, \text{其他} \end{cases} \quad (13)$$

式中: θ 为可调系数。密度 $\rho(x)$ 从几何角度描述了 x 周围数据点的密集程度。 $\rho(x)$ 越大表明在高维空间中点 x 周边汇聚的数据点越多。进一步定义离散度为该点到比该点密度更大的其他点的最小距离:

$$\zeta_i = \min_{\rho(x_i) < \rho(x_j)} d(x_i, x_j), \forall x_j \in X$$

$$x = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a} \quad (14)$$

在以上两个指标中, 密度具有局部性, 离散度具有全局性。将高密度点作为支持向量可以使得超平面的定位更具有精确性; 但若仅考虑密度, 则容易造成

训练样本集中在某个区域，丧失全局性。与之对应，如果选取密度虽然较小但离散度大的点进入训练集，则稀疏化后的决策超平面更接近原始超平面。为此，在进行样本稀疏化时需要同时考虑密度和离散度。综合密度和离散度定义全局代表性指标

$$\tau_i = \rho_i + \zeta_i \quad (15)$$

将 τ 作为样本选择的评估指标具有综合意义。

2.2 稀疏化算法

基于样本空间分布特征的 LS-SVM 稀疏化算法流程如图 1 所示，算法只需一次执行即可获得稀疏化后的训练集，执行过程中未涉及复杂的高维矩阵运算，对平台计算能力的要求低，适合本项目所采用的 PLC 平台。

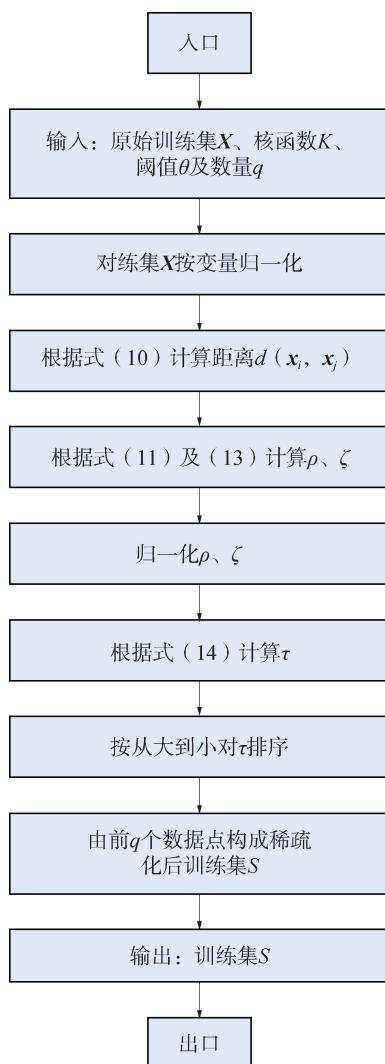


图 1 稀疏化算法流程

Fig. 1 Flow chart of sparse algorithm

3 结果分析

为了验证本文样本空间分布特征的 LS-SVM 稀疏化算法，将其应用到锅炉飞灰含碳量 LS-SVM 软测量系统。该系统采用 PLC 作为软测量模型的运算平台以提高系统的可靠性。以某 1 000 MW 机组的实际运行数据为对象开展算法验证研究。

如前所述，飞灰含碳量 LS-SVM 软测量模型优选了 25 个机组运行参数作为的二次变量；并按式 (1) 进行了扩维以逼近锅炉的动态特征，扩维使得每一个输入向量为 1×50 维。训练样本的输出值取锅炉飞灰含碳量的化验值。由于试验电厂每天只进行一次飞灰采样和分析，故每天只能获得一个化验值。现场试验时从电厂 SIS 系统获得了从 2017 年 1 月 - 2017 年 12 月时段的 140 组有效样本，记为 $\{x_k, y_k\}_{k=1}^{140}$ 。样本中 y_k 为飞灰含碳量化验值，再根据 y_k 的取样时间 t_k 从 SIS 历史数据中分别获得 25 个变量在 $(t_k - d_i)$ 时刻的值 x_i^k ($i = 1, \dots, 25$) 及 $(t_k - \Delta t - d_i)$ 时刻的值 $x_{k-\Delta t}^i$ ($i = 1, \dots, 25$)，然后将 x_i^k 和 $x_{k-\Delta t}^i$ 扩维构成 50 维输入向量 X_k 。最后，将 x_k 与 y_k 结合级获得一个训练样本 $\{x_k, y_k\}$ 。为了对稀疏化算法进行验证，从 140 样本中随机取 90 组样本作为训练 LS-SVM 软测量模型的原始样本集 $\{x_k, y_k\}_{k=1}^{90}$ ，其余 50 组用于模型校验。

本节对稀疏化算法的验证用 Matlab 编程完成，采用 LS-SVMlab 工具箱，核函数选用 RBF，RBF 函数的参数采用试算方式获得， $\gamma = 20$ ， $\sigma^2 = 150$ 。首先，用所有的 90 组原始训练样本对飞灰含碳量 LS-SVM 软测量模型进行训练，结果如图 2 所示。然后，用 50 组校验样本对 LS-SVM 模型进行校验，结果如图 3 所示。

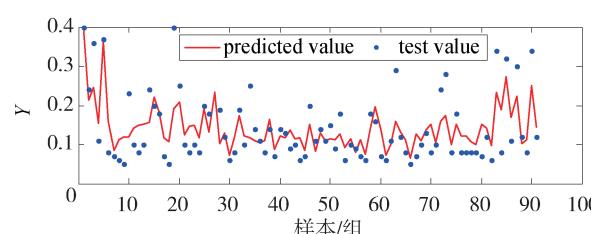


图 2 LS-SVM 软测量模型训练结果(原始样本集)

Fig. 2 Training results of LS-LVM soft measurement model (original sample set)

(original sample set)

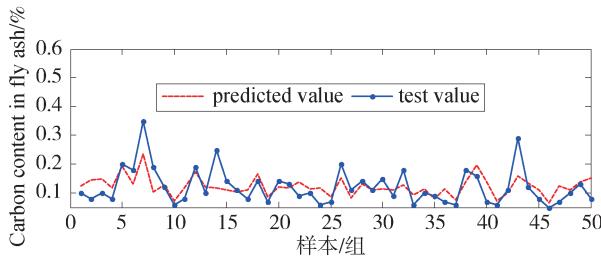


图 3 LS-SVM 软测量模型校验结果(原始样本集)

Fig. 3 Verification results of LS-LVM soft measurement model (original sample set)

采用实际输出样本与 LS-SVM 输出值的均方根误差 RMSE 做为性能评价指标

$$\text{RMSE} = \sqrt{\frac{1}{Z} \sum_{i=1}^z (y'_{t_i} - y'_i)^2} \quad (16)$$

与图 3 对比曲线对应的均方根误差记为 RMSE_{90} , 下标表示训练样本容量。计算结果为 $\text{RMSE}_{90} = 0.056\ 3$ 。

为了验证本文提出的稀疏化方法, 以下将保留样本数量 q 设置为不同的值进行对比研究。先取 $q = 30$, 按照图 1 所示稀疏化流程进行处理。先计算 90 个原始样本在高维空间中的距离, 再计算每个样本的密度和离散度, 将其绘制在二维坐标中, 如图 4 所示。图 4 中 30 个红点所代表的样本点具有更大全局代表性, 将被选留为训练样本; 空心点所代表的样本点具有较小的密度或离散度(或两者都小), 将被剔除出训练样本集。用稀疏化后的 30 组训练样本对飞灰含碳量 LS-SVM 软测量模型进行训练, 结果如图 5 所示。再用 50 组校验样本进行校验, 对比曲线如图 6 所示, 计算得 $\text{RMSE}_{30} = 0.065\ 4$ 。

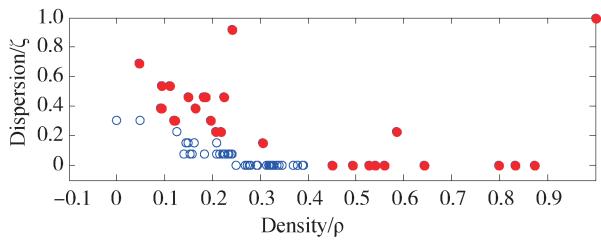


图 4 样本密度和离散度

Fig. 4 Sample density and dispersion

取 $q = 40$ 重复上述过程, LS-SVM 模型的训练结果及校验对比曲线就不再赘述, 计算获得样本容量为 40 时的 $\text{RMSE}_{40} = 0.059\ 4$ 。取 $q = 50$ 进行对比验证, $\text{RMSE}_{50} = 0.062\ 3$ 。将以上 4 种案例结果进

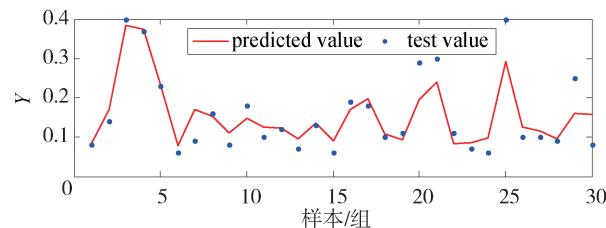


图 5 LS-SVM 软测量模型训练结果(30 组样本)

Fig. 5 Training results of LS-LVM soft measurement model (30 sets of original samples)

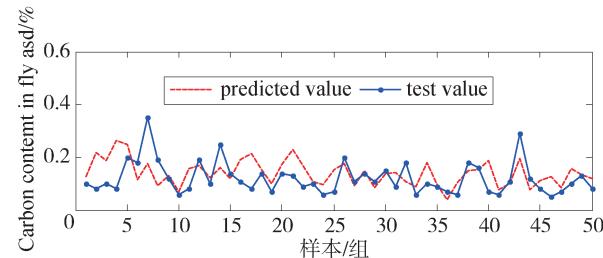


图 6 LS-SVM 软测量模型校验结果(30 组样本)

Fig. 6 Verification results of LS-LVM soft measurement model (30 sets of original samples)

行对比整理, 如表 1 所示。

表 1 模型稀疏化结果对比

Tab. 1 Comparison of model sparse results

训练样本容量/个	样本剪切率/%	RMSE/%
90	0.00	0.056 3
50	44.4	0.062 3
40	55.6	0.059 4
30	66.7	0.065 4

对比 4 个案例可知, 使用原始训练样本集训练飞灰含碳量 LS-SVM 软测量模型后, 校验过程中的误差性能最佳。当采用本文提出的稀疏化算法进行样本裁剪后, 校验误差性能发生了一定程度地劣化, 但在可接受范围内。表 1 还表明, 样本裁剪率与误差性能之间并未表现出单调性特征。总之, 本文提出的 LS-SVM 模型稀疏化算法, 能在适当牺牲误差性能的情况下大大减少训练样本数量, 进而降低 LS-SVM 软测量模型训练及在线预测的计算量。该稀疏化算法适合以工业控制器为计算平台的软测量系统。

4 结论

本文针对采用 PLC 为计算平台的锅炉飞灰含碳

量软测量系统，提出了一种基于高维特征空间样本分布特征的 LS-SVM 稀疏化方法。通过计算样本在高维空间的欧氏距离，并融合密度和离散度建立全局代表性评价指标。样本稀疏化时，按照全局代表性指标排序并裁剪训练样本。此稀疏化算法无需进行大量矩阵计算或迭代计算，一次计算即可获得指定容量的训练样本集，适合本文所采用的 PLC 计算平台。论文还以 1 000 MW 机组的试验数据对稀疏化算法进行了试验，结果表明本文提出的 LS-SVM 算法在保证误差值降低 0.01% 的情况下，将计算样本从 90 个缩小到 30 个，大大减少了 LS-SVM 模型训练和在线预测的计算量。本文提出的 LS-SVM 稀疏化算法适合基于 PLC 的飞灰含碳量 LS-SVM 软测量系统，也可为其他计算能力受限的软测量系统提供参考。基于全局代表性指标进一步优化样本稀疏化算法，如何在保证软测量算法预测精度情况下选择最优的样本数量是今后研究的重点。

参考文献：

- [1] 罗嘉, 陈世和, 张曦, 等. 电站锅炉典型热工参数软测量研究 [J]. 中国电力, 2016, 49(6): 48-52.
- [2] LUO J, CHEN S H, ZHANG X, et al. Research on soft measurement technology of typical thermal parameters of utility boilers [J]. Electric Power, 2016, 49(6): 48-52.
- [3] 罗嘉, 吴乐. 电站锅炉主要热工过程参数软测量技术研究进展 [J]. 热力发电, 2015, 44(11): 1-9+13.
- [4] LUO J, WU L. Research status of soft measurement technology of typical thermal parameters for utility boilers [J]. Thermal Power Generation, 2015, 44(11): 1-9+13.
- [5] 顾燕萍, 赵文杰, 吴占松. 采用最优 MVs 决策模型的电站锅炉燃烧优化 [J]. 中国电机工程学报, 2012, 32(2): 39-44.
- [6] GU Y P, ZHAO W J, WU Z S. An optimal MVs decision-model for boiler combustion optimization [J]. Proceedings of the Chinese Society of Electrical Engineering, 2012, 32(2): 39-44.
- [7] 周慎学, 沈奇, 夏克晁, 等. 基于在线支持向量机的锅炉燃烧系统动态建模 [J]. 自动化仪表, 2017, 38(10): 30-35.
- [8] ZHOU S X, SHEN Q, XIA K C, et al. Dynamic modeling of boiler combustion system based on online support vector machine [J]. Process Automation Instrumentation, 2017, 38(10): 30-35.
- [9] 张晓宇, 付林, 沈炯, 等. 基于在线支持向量机的锅炉动态建模方法研究 [J]. 中国电机工程学报, 2017, 37(增刊1): 123-128.
- [10] 李佳东, 宋志强, 吴宇. 基于多元线性回归分析的大型电站锅炉飞灰含碳量在线软测量模型的应用研究 [J]. 工业控制计算机, 2016, 29(12): 30-31+34.
- [11] VAPNIK V N. The nature of statistical learning theory [M]. New York: Springer—Verlag, 1995.
- [12] SUYKENS JAK, VANDEWALLE J. Least squares support vector machine classifiers [J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [13] SUYKENS JAK, BRABANTER D J, LUKAS L, et al. Weighted least squares support vector machines: robustness and sparse approximation [J]. Neurocomputing, 2002, 48(1-4): 85-105.
- [14] DE KRUIF B J, DE VRIES T J A. Pruning error minimization in least squares support vector machines [J]. IEEE Transactions on Neural Networks, 2003, 14(3): 696-702.
- [15] 赵永平, 孙健国. 关于稀疏最小二乘支持向量回归机的改进剪枝算法 [J]. 系统工程理论与实践, 2009, 29(6): 166-171.
- [16] 李丽娟. 最小二乘支持向量机建模及预测控制算法研究 [D]. 杭州: 浙江大学, 2008.
- [17] 王定成, 姜斌. 在线稀疏最小二乘支持向量机回归的研究 [J]. 控制与决策, 2007, 22(2): 132-137.
- [18] 陈正, 张小轩, 李慧敏, 等. 基于 PSO 的最小二乘支持向量机稀疏化算法 [J]. 武汉大学学报(工学版), 2016, 49(6): 955-960.
- [19] CHEN Z, ZHANG X X, LI H M, et al. Optimal sparseness approach for least square support vector machine based on PSO [J]. Engineering Journal of Wuhan University, 2016, 49(6): 955-960.
- [20] LUO J, CHEN S, WU L, et al. An optimal sparseness approach for least square support vector machine [C]// 2014 26th Chinese Control and Decision Conference (CCDC), Changsha, China, 2014. Changsha: Northeastern University and IEEE, 2014: 3622-3627.
- [21] 马跃峰, 梁循, 周小平. 一种基于全局代表点的快速最小二乘支持向量机稀疏化算法 [J]. 自动化学报, 2017, 43(1): 132-141.
- [22] 楼锐, 黄冬兰, 刘宇穗, 等. 一种基于 LSSVM 的飞灰含碳量软测量方法及装置 [J]. 南方能源建设, 2017, 4(4): 42-48.

作者简介：



ZHANG D H

张大海(通信作者)

1980-, 男, 山东曹县人, 中国能源建设集团广东省电力设计研究院有限公司工程师, 武汉大学机械设计及理论专业博士, 主要从事发电厂检测仪表与控制系统优化方面的设计与研究工作(e-mail) zhangdahai@mail.gedi.com.cn。