

# 基于不同输入参数的煤灰熔点预测模型及改进方法

赵晓鹏,徐义巍,李彦军,任海彬

(宁夏京能宁东发电有限责任公司,宁夏 银川 750000)

**摘要:**为提高煤灰熔点预测精度,采用支持向量机算法,分别建立了以8种煤灰主要成分为输入量的8输入参数模型以及以8种灰成分加5种煤灰熔融性参数为输入的13输入参数模型,用于预测煤灰软化温度,并利用误差补偿方法对13输入参数模型进行了改进。结果显示,13输入参数模型相比8输入参数模型可以缩小灰熔点预测误差区间,尤其使负误差减小;相比于改进前,改进后的13输入参数模型使均方差降低了59.5%。

**关键词:**灰熔点;输入参数;分类误差补偿

中图分类号:TQ536.4 文献标识码:A DOI:10.16146/j.cnki.mdlgc.2022.03.013

[引用本文格式]赵晓鹏,徐义巍,李彦军,等.基于不同输入参数的煤灰熔点预测模型及改进方法[J].热能动力工程,2022,37(3):86-91. ZHAO Xiao-peng, XU Yi-wei, LI Yan-jun, et al. Model and improvement method of coal ash melting point prediction based on different input parameters[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(3):86-91.

## Model and Improvement Method of Coal Ash Melting Point Prediction based on Different Input Parameters

ZHAO Xiao-peng, XU Yi-wei, LI Yan-jun, REN Hai-bin

(Ningxia Jingneng Ningdong Electric Power Co., Ltd., Ningxia, China, Post Code:750000)

**Abstract:** In order to improve the prediction accuracy of coal ash melting point, the 8-input parameter model with 8 kinds of main coal ash composition as the input and the 13-input parameter model with 8 kinds of ash composition and 5 kinds of coal ash melting parameters as the input were established respectively, to predict coal ash softening temperature. And the 13-input parameter model was improved by the method of error compensation. The results show that the 13-input parameter model can reduce the error range of ash melting point prediction, compared with the 8-input parameter model, especially to reduce the negative error. The improved 13-input parameter model reduces the mean square error by 59.5%, compared with that before the improvement.

**Key words:** ash melting point, input parameters, classification error compensation

## 引言

煤的灰熔点是影响锅炉结渣的决定性因素。 $\text{SiO}_2$ 、 $\text{Al}_2\text{O}_3$ 、 $\text{Fe}_2\text{O}_3$ 、 $\text{CaO}$ 、 $\text{MgO}$ 、 $\text{K}_2\text{O}$ 、 $\text{Na}_2\text{O}$ 、 $\text{TiO}_2$ 和 $\text{SO}_3$ 等是煤灰的主要组成成分。直接将煤灰化学组分作为输入参数是预测灰熔点的常用方法。李建中等人<sup>[1]</sup>利用支持向量机,将30种煤灰(训练集26

种,测试集4种)中的7种化学组分 $\text{SiO}_2$ 、 $\text{Al}_2\text{O}_3$ 、 $\text{Fe}_2\text{O}_3$ 、 $\text{CaO}$ 、 $\text{MgO}$ 、 $\text{K}_2\text{O} + \text{Na}_2\text{O}$ 和 $\text{TiO}_2$ 作为输入参数预测煤灰软化温度(ST),虽然预测结果的平均相对误差为0.67%,但是样本数较少;刘彦鹏等人<sup>[2]</sup>利用蚁群前馈神经网络模型(ACA-BP),将80种煤灰(训练集60种,测试集20种)的主要化学组分作为输入参数预测灰熔点,平均相对误差为1.55%;Yin等人<sup>[3]</sup>采用带有动量项的反向传播神经网络,

将160种煤灰(训练集80种,测试集80种)中的7种化学组分作为输入参数建立模型,预测煤灰软化温度,平均相对误差为4.93%。

根据煤灰化学组分对灰熔点的影响,将化学组分进行简单计算得到反映灰熔融性的参数并用于判断灰熔点,是另一种灰熔点预测的常用方法。如煤灰中酸性氧化物 A ( $\text{SiO}_2 + \text{Al}_2\text{O}_3 + \text{TiO}_2$ ) 越多煤灰的灰熔点越高,碱性氧化物 B ( $\text{Fe}_2\text{O}_3 + \text{CaO} + \text{MgO} + \text{K}_2\text{O} + \text{Na}_2\text{O}$ ) 越多灰熔点越低<sup>[4]</sup>, 碱酸比 B/A 则可以反映结渣倾向。Shi 等人<sup>[5]</sup>对比了21种评价参数,发现 B/A 与结渣具有很强的相关性,可以作为判断结渣的首选指标。此外  $\text{SiO}_2$  和  $\text{Al}_2\text{O}_3$  虽然同为主要的酸性氧化物,但灰熔点会随着  $\text{SiO}_2$  的增多,先降低后升高<sup>[6]</sup>。同时,考虑酸性氧化物 A 和硅铝比  $\text{SiO}_2/\text{Al}_2\text{O}_3$  可以增加预测的准确性。与此类似,  $\text{Fe}_2\text{O}_3$ 、 $\text{CaO}$  是主要的碱性氧化物,但富含  $\text{CaO}$  的煤灰比富含  $\text{Fe}_2\text{O}_3$  的灰熔点要高<sup>[7]</sup>, 不同范围内铁钙比  $\text{Fe}_2\text{O}_3/\text{CaO}$  的变化对煤灰熔融行为的影响也存在差异<sup>[8]</sup>。考虑 B 和  $\text{Fe}_2\text{O}_3/\text{CaO}$  可以增加预测的准确性,Liang 等人<sup>[9]</sup>分别将28种煤灰(训练集22种,测试集6种)的 A、B 和 B/A 作为输入参数,利用线性回归分析,预测煤灰变形温度(DT),相对误差均约4.25%。李永兴等人<sup>[10]</sup>分析90种煤灰数据后,将 B/A、 $\text{SiO}_2/\text{Al}_2\text{O}_3$  和  $\text{Fe}_2\text{O}_3/\text{CaO}$  作为输入参数,提出了计算煤灰结渣特性综合指数 R 的关系式,结渣程度的预测准确率达90%。陈裕辉<sup>[11]</sup>利用支持向量机将58种煤灰(训练集46种,测试集12种)中的9种化学组分、 $\text{SiO}_2/\text{Al}_2\text{O}_3$ 、B/A 和沾污指数作为输入参数,预测煤灰变形温度,平均相对误差为1.69%。

训练样本的选取对预测结果有较大影响,增加样本数量可以改善训练集代表性不足的问题<sup>[12]</sup>。虽然已有研究对各自使用的煤种得出了较好的预测结果,但很少注重样本的数量和适用范围及不同输入参数对模型造成的影响。受制于煤灰熔融机制的复杂性,尽管已经考虑了各种化学组分的质量分数以及反映熔融性的间接参数,模型的预测值依然会与实验值之间有一定误差。以往研究大多比较不同预测方法的预测效果<sup>[13-16]</sup>,少有对模型进一步改进。

误差补偿方法可以改善原预测模型的准确性。如康会宾<sup>[17]</sup>在滑坡变形的预测中采用误差补偿方法,将预测值的相对误差由1.58%降低至1.49%;

杨华庆等人<sup>[18]</sup>针对立体视觉系统误差较大的问题,采取误差补偿方法,提高了视觉传感器的标定精度。

为此,本文构建了把煤灰化学组分和多个反映煤灰熔融性的参数(间接参数)共同作为输入的灰熔点预测 SVM 模型,以258种涵盖多样化原煤的煤灰数据为样本,比较了输入参数中有、无间接参数对模型预测精度的影响,并提出一种分类误差补偿方法,对精度较高的模型进一步改进。

## 1 预测模型及改进方法

### 1.1 输入参数及所用数据

煤灰化学组分中,除了  $\text{SiO}_2$ 、 $\text{Al}_2\text{O}_3$ 、 $\text{Fe}_2\text{O}_3$ 、 $\text{CaO}$ 、 $\text{MgO}$ 、 $\text{K}_2\text{O} + \text{Na}_2\text{O}$  和  $\text{TiO}_2$  7种对灰熔点影响较大的氧化物外,将煤灰中  $\text{SO}_3$  质量分数划入输入参数后预测结果的最大相对误差和平均相对误差均减小<sup>[11]</sup>。故本次研究也将  $\text{SO}_3$  质量分数考虑在内。间接参数则采用文献中常见的间接参数 A、B、B/A、 $\text{SiO}_2/\text{Al}_2\text{O}_3$  和  $\text{Fe}_2\text{O}_3/\text{CaO}$ 。

分别构建了两类不同参数模型用于对比:8输入参数模型和13输入参数模型。8输入参数模型将8种煤灰化学组分( $\text{SiO}_2$ 、 $\text{Al}_2\text{O}_3$ 、 $\text{Fe}_2\text{O}_3$ 、 $\text{CaO}$ 、 $\text{MgO}$ 、 $\text{K}_2\text{O} + \text{Na}_2\text{O}$ 、 $\text{TiO}_2$ 、 $\text{SO}_3$ )作为输入参数;13输入参数模型在8参数模型基础上加入 A、B、B/A、 $\text{SiO}_2/\text{Al}_2\text{O}_3$ 、 $\text{Fe}_2\text{O}_3/\text{CaO}$ ,共13种参数作为输入参数。

采用的258种煤灰数据来源于中国科学院中国典型煤种热转化特性数据库、西安热工院煤灰数据库以及自建数据库。其中179种煤灰的  $\text{ST} < 1500\text{ }^\circ\text{C}$ ,79种煤灰的  $\text{ST} \geq 1500\text{ }^\circ\text{C}$ 。煤灰样本的主要化学组分质量分数范围、间接参数范围及灰熔点分布如表1~表3所示。

表1 煤灰样本主要化学组分范围

Tab.1 Main chemical composition ranges of coal ash sample

组分	质量分数/%
$\text{SiO}_2$	7.55 ~ 80.91
$\text{Al}_2\text{O}_3$	4.95 ~ 64.99
$\text{Fe}_2\text{O}_3$	0.91 ~ 30.11
$\text{CaO}$	0.15 ~ 62.69
$\text{MgO}$	0.03 ~ 13.3
$\text{K}_2\text{O} + \text{Na}_2\text{O}$	0.05 ~ 14.29
$\text{TiO}_2$	0.01 ~ 7.63
$\text{SO}_3$	0.08 ~ 23.92

表 2 煤灰样本间接参数范围

Tab.2 Indirect parameter ranges of coal ash sample

间接参数	范围
A	15.07% ~96.89%
B	2.04% ~71.49%
B/A	0.02 ~4.74
SiO <sub>2</sub> /Al <sub>2</sub> O <sub>3</sub>	0.2 ~12.85
Fe <sub>2</sub> O <sub>3</sub> /CaO	0.14 ~27.53

表 3 煤灰样本 ST 分布

Tab.3 Distribution table of ST of coal ash sample

样本个数	ST 范围/℃
11	1 000 ~1 100
45	1 100 ~1 200
60	1 200 ~1 300
38	1 300 ~1 400
25	1 400 ~1 500
79	1 500 以上

### 1.2 预测模型

利用 LIBSVM 软件包<sup>[19]</sup>,采用 Gauss 径向基核函数,通过支持向量机进行建模和预测<sup>[20-25]</sup>。惩罚因子  $C$  和核函数参数  $g$  的选择对模型极为重要。 $C$  越大,模型越不能容忍出现误差,容易过拟合, $C$  越小则模型容易欠拟合;增大参数  $g$  可能使训练准确率提高,但会造成对未知样本的预测效果变差。为得到最佳模型,以均方误差 (MSE) 最低为评价标准,利用 K - CV (K 折交叉验证) 方法,通过网格法在  $0 \leq C \leq 2^8, 2^{-5} \leq g \leq 2^5$  的范围内寻找最佳  $C, g$  值,兼顾了模型的学习性和预测性。

由于灰熔点实验数据中将  $ST \geq 1\ 500\ ^\circ\text{C}$  的结果记录为  $1\ 500\ ^\circ\text{C}$ 。因此,对于一个煤灰样本,需要两个模型用于预测:判断是否满足  $ST \geq 1\ 500\ ^\circ\text{C}$ ,若是,则  $ST$  记为  $1\ 500\ ^\circ\text{C}$ ;若否,则根据输入参数预测具体灰熔点。

为评价模型的预测效果,随机取 80% 的样本作为训练集,20% 作为测试集,如表 4 所示。由训练集样本得到最佳模型,再用该模型对测试集进行预测,比较预测结果。各模型的输入参数均进行了归一化处理。

表 4 训练集和测试集样本数

Tab.4 Sample numbers in training set and test set

ST	训练集样本数	预测集样本数
$< 1\ 500\ ^\circ\text{C}$	144	35
$\geq 1\ 500\ ^\circ\text{C}$	64	15

### 1.3 改进方法

提出一种分类误差补偿方法对两类输入参数中结果较好的原预测模型做进一步修正,流程如图 1 所示。建立原预测模型后,首先根据绝对误差  $\Delta$  对训练集预测结果进行标记分类(预测结果偏低、偏高或正常),再以分类结果为输出,以原模型输入参数为输入建立“判断模型”,判断测试集样本所属类别,根据类别通过补偿值  $\delta$  进行补偿,得到更准确的预测值。

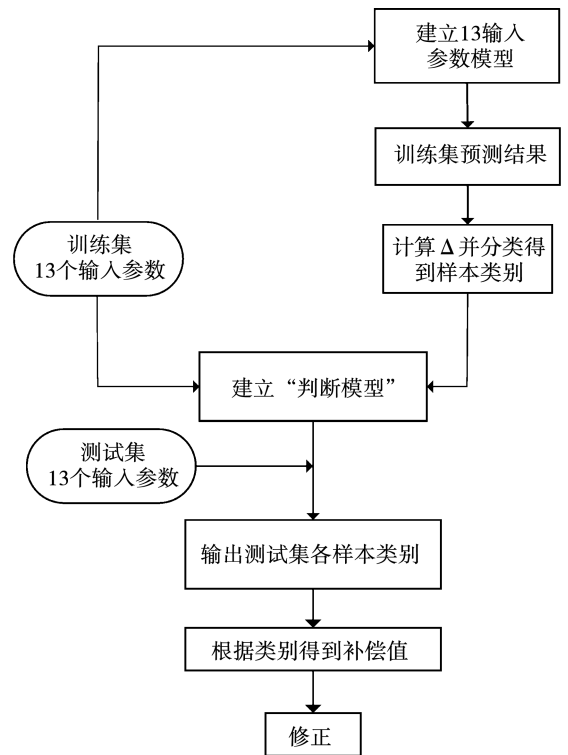


图 1 模型改进流程图

Fig.1 Improved model flow chart

绝对误差  $\Delta$  分类标准:  $\Delta < -30\ ^\circ\text{C}$  为 A 类(预测结果偏低);  $-30\ ^\circ\text{C} \leq \Delta \leq 30\ ^\circ\text{C}$  为 B 类(预测结果良好);  $\Delta > 30\ ^\circ\text{C}$  为 C 类(预测结果偏高)。“判断模型”同样利用支持向量机建立,输入参数和模型构建方法同原预测模型,仅输出参数变为所属类

别。为使修正后更多的绝对误差落在  $\pm 30\text{ }^\circ\text{C}$  以内,对于 A、C 类  $\delta$  分别取  $+60$  和  $-60$ 。修正式为  $ST(\text{修正值}) = ST(\text{预测值}) + \delta$ 。

## 2 结果与分析

### 2.1 不同输入参数模型结果

模型预测结果优劣以均方误差 (MSE) 和平均绝对百分比误差 (MAPE) 作为评价标准。同时,为了更贴合实际需要,统计了绝对误差  $\Delta$  (灰熔点  $ST$  的预测值 - 实验值) 在  $\pm 30$ 、 $\pm 50$  和  $\pm 80\text{ }^\circ\text{C}$  以内的百分比,如表 5 所示。

表 5 不同输入参数模型结果对比

Tab. 5 Comparison of model results with different input parameters

模型	MSE	MAPE/%	误差 $\pm 30\text{ }^\circ\text{C}$	误差 $\pm 50\text{ }^\circ\text{C}$	误差 $\pm 80\text{ }^\circ\text{C}$
			以内占比/%	以内占比/%	以内占比/%
8 输入参数	6 377.00	4.10	54	62	64
13 输入参数	5 345.95	3.63	56	60	74

由结果可知,相比于 8 输入参数模型,13 输入参数模型 MSE 减小了 16.2%,MAPE 由 4.10% 降至 3.63%。虽然绝对误差在  $\pm 30\text{ }^\circ\text{C}$  和  $\pm 50\text{ }^\circ\text{C}$  以内的比例与 8 输入参数模型相近,但在  $\pm 80\text{ }^\circ\text{C}$  以内的比例由 64% 增加至 74%。为更好地分析两模型的预测结果,对比了测试集样本的绝对误差及相对误差分布,如图 2 ~ 图 3 所示。




图 2 不同输入参数模型绝对误差分布

Fig. 2 Absolute error distributions of models with different input parameters




图 3 不同输入参数模型相对误差分布

Fig. 3 Relative error distributions of models with different input parameters

由图 2 和图 3 可知,两模型预测结果主要区别在绝对误差小于  $-50\text{ }^\circ\text{C}$  的区域。间接参数的加入可以缩小误差区间,尤其可以使负误差减小。为直观表示误差大小,此后以绝对误差作为评价参数。虽然 13 输入参数模型比 8 输入参数模型预测结果更好,但是从工程实际的角度看, $ST$  预测误差,尤其是误差区间 ( $-112.13 \sim 105.46\text{ }^\circ\text{C}$ ) 仍较大,具有进一步改进的空间。

### 2.2 改进模型结果

选择 13 输入参数模型进一步改进。改进模型预测误差分布如图 4 所示。




图 4 模型改进前后绝对误差分布

Fig. 4 Absolute error distributions of models before and after the improvement

改进模型的误差分布更靠近绝对误差为零的区域,在整个误差区间内都提高了预测的准确率。3 种模型的对比如表 6 和图 5 所示。相比于 8 输入

参数模型和13输入参数模型,经过分类误差补偿后的改进模型MSE分别减小了66.07%和59.53%;MAPE分别下降了2.18%和1.71%;绝对误差在 $\pm 30\text{ }^{\circ}\text{C}$ 以内的比例分别由54%、56%增加至76%。

表6 改进模型结果

Tab.6 Results of the improved model

MSE	MAPE/%	误差 $\pm 30\text{ }^{\circ}\text{C}$	误差 $\pm 50\text{ }^{\circ}\text{C}$	误差 $\pm 80\text{ }^{\circ}\text{C}$
		以内占比/%	以内占比/%	以内占比/%
2 163.49	1.92	76	82	92




图5 各模型预测结果对比

Fig.5 Comparison of predicting results of each model

### 3 结论

利用支持向量机,对258种煤灰数据分别建立了8输入参数模型、13输入参数模型和改进模型,对3种模型的预测结果进行了分析对比,得出结论:

(1) 13输入参数模型将反应煤灰熔融性的间接参数A、B、B/A、 $\text{SiO}_2/\text{Al}_2\text{O}_3$ 和 $\text{Fe}_2\text{O}_3/\text{CaO}$ 纳为输入参数。相比于8输入参数模型,可以使预测结果的误差区间缩小,尤其对负误差具有较好的修正作用,使误差曲线趋于平缓。

(2) 分类误差补偿方法使预测精度大幅提高,相比于改进前,改进后的模型预测结果MSE降低了59.5%,MAPE降低至1.92%。

### 参考文献:

[1] 李建中,周昊,王春林,等.支持向量机技术在动力配煤中灰熔点预测的应用[J].煤炭学报,2007,32(1):81-84.

LI Jian-zhong,ZHOU Hao,WANG Chun-lin,et al. Employing support vector machine to predict the ash fusion temperature of coal blends[J]. Journal of China Coal Society,2007,32(1):81-84.

[2] 刘彦鹏,仲玉芳,钱积新,等.蚁群前馈神经网络在煤灰熔点预测中的应用[J].热力发电,2007,36(8):23-26.

LIU Yan-peng,ZHONG Yu-fang,QIAN Ji-xin,et al. Application of ant colony algorithm and BP neural network in prediction of coal ash fusion point[J]. Thermal Power Generation,2007,36(8):23-26.

[3] YIN C,LUO Z,NI M,et al. Predicting coal ash fusion temperature with a back-propagation neural network model[J]. Fuel,1998,77(15):1777-1782.

[4] 陈文敏,姜宁.煤灰成分和煤灰熔融性的关系[J].洁净煤技术,1996,2(2):34-37.

CHEN Wen-min,JIANG Ning. The relationship between coal ash composition and coal ash fusibility[J]. Clean Coal Technology,1996,2(2):34-37.

[5] SHI W,BAI J,KONG L,et al. An overview of the coal ash transition process from solid to slag[J]. Fuel,2021,287:119537.

[6] 孙琴月,朱学栋,唐黎华,等.煤灰熔融温度多项式模型的偏回归函数分析[J].华东理工大学学报:自然科学版,2005,31(1):18-21.

SUN Qin-yue,ZHU Xue-dong,TANG Li-hua,et al. Analysis of coal ash fusion temperature using polynomial partial regression functions[J]. Journal of East China University of Science and Technology,2005,31(1):18-21.

[7] 刘新兵,陈芜.煤灰熔融性的研究[J].煤化工,1995(2):48-52,47.

LIU Xin-bing,CHEN Chong. Study on the fusion of coal ash[J]. Coal Chemical Industry,1995(2):48-52,47.

[8] SHI W,KONG L,BAI J,et al. Effect of  $\text{CaO}/\text{Fe}_2\text{O}_3$  on fusion behaviors of coal ash at high temperatures[J]. Fuel Processing Technology,2018,181:18-24.

[9] LIANG Wang,WANG Guang-wei,NING Xiao-jun,et al. Application of BP neural network to the prediction of coal ash melting characteristic temperature[J]. Fuel,2020,260:116324.

[10] 李永兴,陈春元.动力用煤结渣特性综合判别指数的研究[J].热力发电,1994(3):36-39.

LI Yong-xing,CHEN Chun-yuan. Research on comprehensive discriminant index of slagging characteristics of power coal[J]. Thermal Power Generation,1994(3):36-39.

[11] 陈裕辉.基于支持向量机煤灰熔融特性及低温受热面积灰监测[D].北京:华北电力大学(北京),2019.

CHEN Yu-hui. Ash fusion characteristics and fouling monitoring of low temperature heating surface based on support vector machine[D]. Beijing: North China Electric Power University (Bei

- Jing), 2019.
- [12] 林德平. 支持向量机在预测配煤灰熔点中的应用[J]. 电力科学与工程, 2015, 31(8): 66-70.  
LIN De-ping. The Application of support vector machine in predicting ash fusion temperature of blended coals[J]. Electric Power Science and Engineering, 2015, 31(8): 66-70.
- [13] 刘 硕, 周安宁, 杨伏生, 等. 煤灰流动温度的预测研究[J]. 煤炭与化工, 2017, 40(3): 20-24.  
LIU Shuo, ZHOU An-ning, YANG Fu-sheng, et al. Study on prediction of coal ash flow temperature[J]. Coal and Chemical Industry, 2017, 40(3): 20-24.
- [14] 蒋绍坚, 付国富, 黄靛云, 等. 基于 Elman 神经网络的烟煤与生物质混烧灰熔点预测[J]. 中南大学学报(自然科学版), 2016, 47(12): 4240-4247.  
JIANG Shao-jian, FU Guo-fu, HUANG Liang-yun, et al. Forecasting on ash fusion temperatures of bituminous coal and biomass co-firing based on Elman neural network[J]. Journal of Central South University (Science and Technology), 2016, 47(12): 4240-4247.
- [15] 潘文静. 基于支持向量机的电站锅炉煤灰熔点预测[J]. 广东电力, 2015(7): 6-9.  
PAN Wen-jing. Coal ash melting point prediction of power plant boiler based on support vector machine[J]. Guangdong Electric Power, 2015(7): 6-9.
- [16] 操岳峰, 李寒旭, 胡 洋, 等. 煤灰熔点数学模型的研究[J]. 煤炭与化工, 2017, 40(10): 108-111.  
CAO Yue-feng, LI Han-xu, HU Yang, et al. Study on mathematical model of coal ash fusion temperature[J]. Coal and Chemical Industry, 2017, 40(10): 108-111.
- [17] 康会宾. 基于误差补偿智能预测模型的滑坡变形预测研究[J]. 人民长江, 2020, 51(9): 122-128.  
KANG Hui-bin. Research on landslide deformation prediction based on error compensation intelligent prediction model[J]. Yangtze River, 2020, 51(9): 122-128.
- [18] 杨华庆, 张建功, 唐德渝, 等. 机器人立体视觉系统标定误差预测补偿技术[J/OL]. 控制工程, <https://doi.org/10.14107/j.cnki.kzgc.20200014>, 1-6[2021-04-15].  
YANG Hua-qing, ZHANG Jian-gu, TANG De-yu, et al. Predictive error compensation for calibration of robot stereo vision system [J/OL]. Control Engineering of China, <https://doi.org/10.14107/j.cnki.kzgc.20200014>, 1-6[2021-04-15].
- [19] CHANG C, LIN C. LIBSVM: a library for support vector machines [J]. ACM Transactions on Intelligent Systems and Technology (TIST), 2011, 2(3): 1-27.
- [20] 王红娜. 基于支持向量机的混煤灰熔点预测[D]. 保定: 华北电力大学, 2017.  
WANG Hong-na. Prediction of coal ash fusion point based on support vector machine[D]. Baoding: North China Electric Power University, 2017.
- [21] 李清毅, 周 昊, 林阿平, 等. 基于网格搜索和支持向量机的灰熔点预测[J]. 浙江大学学报(工学版), 2011, 45(12): 2181-2187.  
LI Qing-yi, ZHOU Hao, LIN A-ping, et al. Prediction of ash fusion temperature based on grid search and support vector machine [J]. Journal of Zhejiang University (Engineering Science), 2011, 45(12): 2181-2187.
- [22] 朱中翔. 基于支持向量机算法的室内环境毫米波传播特性研究[D]. 南京: 南京邮电大学, 2020.  
ZHU Zhong-xiang. Study on propagation characteristics of indoor millimeter wave based on support vector machine [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020.
- [23] 王 涵. 基于支持向量机的雾霾预测分析[D]. 银川: 宁夏大学, 2020.  
WANG Han. Haze prediction analysis based on support vector machine [D]. Yinchuan: Ningxia University, 2020.
- [24] 单婧婧, 刘海林. 基于支持向量机的海量电力数据智能分类方法[J]. 自动化与仪器仪表, 2021(2): 216-220.  
SHAN Jing-jing, LIU Hai-lin. Intelligent classification method of massive power data based on support vector machine [J]. Automation & Instrumentation, 2021(2): 216-220.
- [25] 胡 超, 杨 妍, 王松涛, 等. 基于 QAPSO-SVM 的航空发动机故障诊断[J]. 热能动力工程, 2020, 35(12): 40-46, 54.  
HU Chao, YANG Yan, WANG Song-tao, et al. Aeroengine fault diagnosis using quantum adaptive PSO-SVM [J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(12): 40-46, 54.

(丛 敏 编辑)