

基于 SVM 的高效煤粉锅炉爆燃保护策略研究

潘 昊^{1,2,3}

(1. 煤科院节能技术有限公司,北京 100013;2. 煤炭资源开采与环境保护国家重点实验室,北京 100013;
3. 国家能源煤炭高效利用与节能减排技术装备重点实验室,北京 100013)

摘要:为了提高高效煤粉锅炉的燃烧稳定性,提出了一种基于支持向量机(SVM)的爆燃保护控制策略。提取锅炉关键参数构建特征向量,采用 SVM 对系统历史数据进行离线训练,应用径向基函数、网格搜索算法生成系统状态分类器,并引入氧含量因子校正训练模型。锅炉运行时,分类器通过在线数据预测系统预爆燃状态并控制 PLC 模块执行保护程序。测试结果表明,氧含量因子取 0.4 时,分类器的最高交叉验证匹配率大于 97%,最高预测准确率大于 95%,失配率小于 10%。保护策略能够有效地识别锅炉预爆燃状态,同时在锅炉正常工作状态下保持低误判率,增加了系统运行的鲁棒性。

关键词:煤粉锅炉;爆燃保护;支持向量机;机器学习

中图分类号:TK16 文献标志码:A 文章编号:1006-6772(2017)04-0123-05

Research on furnace explosion protection strategy of efficient pulverized coal fired boiler based on SVM

Pan Hao^{1,2,3}

(1. China Coal Research Institute Company of Energy Conservation Co., Ltd., Beijing 100013, China;

2. State Key Laboratory of Coal Mining and Environmental Protection, Beijing 100013, China;

3. National Energy Technology and Equipment Laboratory of Coal Utilization and Emission Control, Beijing 100013, China)

Abstract: In order to improve the combustion stability of pulverized coal fired boiler, a furnace explosion protection strategy based on Support Vector Machine (SVM) was proposed in the paper. The state vector was constructed with key parameters of the boiler; afterwards a system state classifier was generated by training off-line history data of boiler with SVM, applying radial basis function and grid search algorithm. Besides, the oxygen content factor was introduced to regulate the training model. During running time of boiler, the classifier predicted pre-furnace state from on-line data then executed protection program through PLC (Programmable Logic Controller) module. Results show that when the oxygen content factor takes value of 0.4, the maximum cross validation matching rate of the classifier is over 97%, the maximum predicting accuracy is over 95%, and mismatching rate is less than 10%. The protection strategy is able to identify the pre-furnace explosion state of boiler effectively as well as keeping low error judging rate under normal working state, and enhance the robustness of the system

Key words: pulverized coal fired boiler; furnace explosion protection; support vector machine; machine learning

0 引 言

高效煤粉工业锅炉系统的出现极大改善了链条锅炉普遍存在的效率低下、污染严重等问题,具有广阔的市场潜力^[1-3]。近年来,煤粉工业锅炉的应用

日趋广泛,已逐渐成为各种工业供热系统的重要组成部分^[4]。煤粉工业锅炉已实现了计算机全程自动化控制,锅炉运行平稳、热效率高。然而,供料、煤粉质量、人工操作等方面的原因仍会引起锅炉燃烧状态的波动,其中大量煤粉在短时间内急剧燃烧的

收稿日期:2017-02-07;责任编辑:孙淑君 DOI:10.13226/j.issn.1006-6772.2017.04.020

基金项目:北京市科技计划重大科技成果转化落地培育资助项目(Z161100004816012)

作者简介:潘 昊(1988—),男,黑龙江哈尔滨人,助理工程师,硕士,从事高效煤粉锅炉自控系统研究设计工作。E-mail:phacolyte@163.com

引用格式:潘昊.基于 SVM 的高效煤粉锅炉爆燃保护策略研究[J].洁净煤技术,2017,23(4):123-127.

Pan Hao. Research on furnace explosion protection strategy of efficient pulverized coal fired boiler based on SVM[J]. Clean Coal Technology, 2017, 23(4): 123-127.

状态称为爆燃,此时炉内呈强正压环境,不仅损害了炉体机械强度和寿命,也破坏了燃烧的稳定性,降低了锅炉热效率。因此,研究爆燃保护控制策略,对于提升煤粉锅炉运行安全系数和使用寿命具有重要意义。对于煤粉锅炉这种非线性系统,系统复杂度较高,许多学者采取智能控制算法对锅炉燃烧状态、尾气排放等方面进行了研究。张克良^[5]采用模糊神经网络对锅炉燃烧进行优化控制;沈利^[6]采用最小二乘-支持向量机(support vector machine, SVM)算法建立电站锅炉排烟温度预测模型;林龔灏^[7]采用SVM进行火焰温度场回归分析;张振星等^[8]利用自适应遗传算法、SVM模型对锅炉NO_x排放进行优化控制;牛玉广^[9]、赵文杰^[10]、尹金和^[11]等阐述了儿种基于改进SVM算法,如加权最小二乘、小波分析等来优化锅炉燃烧效率、NO_x排放及飞灰残炭量的理论模型。对于锅炉爆燃成因及防护,也有学者进行了研究:卢铭庆等^[12]分析了炉膛爆燃数学模型,指出可燃混合物的过剩堆积是形成爆燃的主因;董志明等^[13]分析了炉内温差及温度上升速率对爆燃的影响,并阐述了相应的锅炉温、压超限自动跳闸控制措施;江波等^[14]通过锅炉断料保护及燃油稳燃控制等手段来降低爆燃率。对于爆燃保护的研究工作大多是基于锅炉供料控制、稳燃技术、烟风系统连锁策略等前馈控制手段,然而对于如何识别锅炉异常燃烧,检测炉膛爆燃状态,进而执行连锁保护的反馈控制研究相对较少,结合智能控制算法来解决该类问题同样具有较强的应用价值。

1 煤粉工业锅炉爆燃原因

1.1 可控因素

可控因素主要为现场司炉人员操作失误因素,包括风管余粉吹扫不净、供料量增幅过快、风路设备调节不合适、起停炉时间过短等,此类因素可以通过加强操作人员管理来避免。

1.2 不可控因素

不可控因素主要为供料方面的非人为因素,如供料器不稳定、煤粉质量参差不齐等造成的供料波动。供料不稳时,单位时间内送入炉内的煤粉量与传感器检测得到的数据不符,使操作人员无法正确配风,造成炉内煤粉呈缺氧状态燃烧,大量未充分燃烧的粉渣积聚炉膛,锅炉进入“预爆燃”状态。随着时间推移,当未燃尽煤粉达到一定浓度时,在极短的时间内急剧二次燃烧,发生爆燃事故^[12]。

由于供料不稳造成爆燃的情况较难预测,对锅炉运行危害较大,然而煤粉锅炉属于多参数、非线性、强耦合系统,各参数间很难建立起解析模型,采用经典控制理论较难保证稳定性,因此,需要引入对处理非线性系统具有优势的机器学习方法。本文对SVM算法作简要概述,阐述爆燃保护控制策略,以期降低爆燃率。

2 SVM算法概述

支持向量机(support vector machine, SVM)是一种基于统计学习理论的监督型机器学习算法,广泛应用于模式识别领域^[16]。SVM本质上是一个二元分类模型,利用已知样本集来训练分类器,使其能够对新样本作出最优化预测。

设某系统特征集为 (\mathbf{x}_i, y_i) ,其中 $\mathbf{x} \in R^n$ 为 n 维向量,其分量表示系统各特征参数; $y_i \in \{1, -1\}$ 为系统状态类别,SVM利用 (\mathbf{x}_i, y_i) 在 n 维特征空间构造分类函数 $f(\mathbf{x}) = \omega^T \mathbf{x} + b$,使得 $y_i = 1, -1$ 的样本点位于分类超平面 $\omega^T \mathbf{x} + b = 0$ 两侧,并且最大化几何间隔 $\frac{f(\mathbf{x})}{\|\omega\|}$,其中 $\|\cdot\|$ 为2-范数,进而将问题转化为采取Lagrange对偶及序列最小优化算法解决式(1)所示的凸二次优化问题。所得到的分类超平面处于两异类点集边界超平面 $y(\omega^T \mathbf{x} + b) = 1$ 的中间,而位于 $y(\omega^T \mathbf{x} + b) = 1$ 面上的点即称为支持向量(support vector)^[15-16]。

$$\min \frac{1}{2} \|\omega\|^2$$

$$\text{当 } y_i(\omega^T \mathbf{x}_i + b) \geq 1 \quad (i = 0, 1 \cdots n) \quad (1)$$

对于特征集线性不可分的情况,SVM将数据映射到高维空间,再进行线性SVM训练,并引入松弛变量处理噪声特征点,整个优化过程转化为式(2),其中 $\varphi(\cdot)$ 为低维向高维空间映射, ξ 为松弛变量,反映算法对离群样本的容忍度。系数 C 为惩罚因子常量,体现分类超平面受离群样本的影响^[15]。

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i$$

$$\text{当 } y_i(\omega^T \varphi(\mathbf{x}_i) + b) \geq 1 - \xi_i$$

$$\xi_i > 0 \quad (i = 0, 1 \cdots n) \quad (2)$$

在优化过程中,式(1)可表示为训练点内积的形式 $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$,对于式(2)SVM引入核函数 $k(\mathbf{x}_i, \mathbf{x}_j) = \langle \varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j) \rangle$ 将映射后高维空间训练中的内积运算转化为原特征空间中的计算,常用的核函数有

线性核、径向基核、多项式核等^[16-17]。

SVM 的训练结果依赖于支持向量,而非支持向量相关性低,相比于神经网络等算法,在统计样本量较少的情况下,具有较好的分类预测效果以及较强的泛化能力^[15]。

3 爆燃保护控制策略

在锅炉在线运行过程中,“预爆燃”状态的识别是整个保护策略的基础,如何合理的对监控数据中的异常状态进行挖掘,将决定控制的鲁棒性。由前文分析,SVM 基于统计理论,对于小样本集、非线性系统的状态识别具有优势,因此本文基于 SVM 讨论保护控制策略。

煤粉工业锅炉测控系统主要由 PLC (programmable logic controller) 模块、现场传感器及上位机构成,本文将爆燃保护策略嵌入锅炉测控系统中,系统分为离线、在线两部分,如图 1 所示。

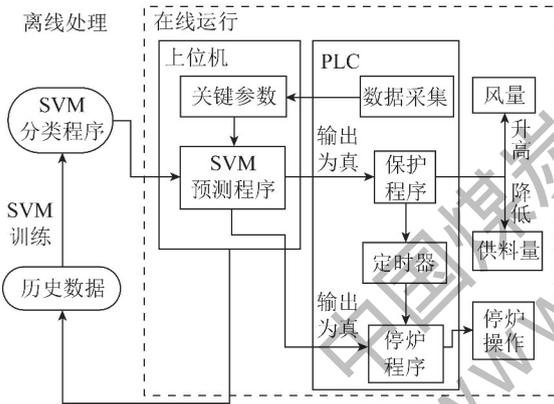


图 1 爆燃保护控制系统

Fig. 1 System diagram of furnace explosion protection system

离线部分主要是对锅炉运行关键参数历史数据进行分析、处理和训练。由经验丰富的司炉人员定期抽取锅炉爆燃状态前后数据,构建训练样本集,通过 SVM 分类程序训练分类模型,进而生成 SVM 预测程序;在线部分主要是执行爆燃保护操作。由 PLC 控制器通过采集传感器数据对锅炉工况进行监测,并记录历史数据;同时将关键参数实时传入 SVM 预测程序,预测输出为真时,即判定出现“预爆燃状态”,控制 PLC 执行保护操作(如降低煤粉供料量及风量);若持续预测输出为真则执行报警及停炉操作。

3.1 训练参数的选取

锅炉运行时与爆燃相关性高的参数主要有火焰强度 F 、炉膛负压 $P1$ 、烟道负压 $P2$ 、供粉量 M 、烟气

氧含量 O , 本文拟将 5 个关键参数作为 SVM 特征向量 x 的各分量,将锅炉运行状态作为系统状态变量 y , 正常运行状态 $y = +1$, 预爆燃状态 $y = -1$ 。SVM 分类器训练结果依赖支持向量,如果训练样本过于集中则会产生过拟合现象^[15],造成错误预测,因此在选取历史数据时,在保证 $y = +1$ 、 $y = -1$ 数据量对等的前提下,样本应尽可能在特征空间呈均匀分布,本文选取的样本覆盖的情况见表 1。

表 1 样本情况

Table 1 Sample information

锅炉状态	样本特征
预爆燃情况 ($y = -1$)	$F < 90\%$, O 低且呈下降趋势, $P1, P2$ 低且波动大, $M > 0$
爆燃后恢复至正常 ($y = +1$)	O 低且呈上升趋势, $F > 70\%$, $M > 0$
锅炉点火至正常运行 ($y = +1$)	$F > 90\%$, O 较高, $P1, P2$ 波动小, $M > 0$
锅炉启炉前、停炉后吹扫、完全停炉 ($y = +1$)	$F = 0, M > 0, P1, P2$ 稳定
锅炉点燃油气 ($y = +1$)	$F > 90\%, M = 0$

3.2 参数特征及误判状态修正

锅炉典型预爆燃状态的火焰强度 F 、氧含量 O 曲线如图 2 所示。由于锅炉供料量不稳或煤粉质量参差不齐,炉膛内煤粉缺氧燃烧,氧含量呈下降趋势,低于一定阈值时,火焰强度下降并出现较大波动。图 2 纵坐标为归一化缩放处理后的火焰强度 F 、氧含量 O 百分比。

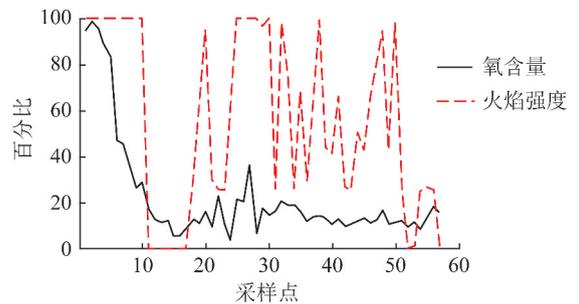


图 2 预爆燃状态的火焰强度、氧含量趋势曲线

Fig. 2 Trend curves of flame intensity, oxygen content in pre-furnace explosion state

由图 2 可以看出,在预爆燃阶段,若司炉人员控制二次风及供料量使得氧含量回升,如图中第 20 ~ 30 个采样时间点,锅炉能够缓慢恢复至正常低负荷燃烧状态。然而 SVM 分类器只能对状态量进行分类,仅采用 5 个状态量作为特征参数将使得分类器无法区分氧含量下降和回升状态,导致预测程序将

保护操作状态误判为预爆燃状态,使得控制逻辑发生震荡,本文定义 η 为氧含量变化因子,将其作为另一特征参数,定义 t 时刻样本的 η 为

$$\begin{aligned} \eta(t) &= T(f(d_1), f(d_2)) \\ d_1 &= O(t - \Delta) - O(t - 2\Delta) \\ d_2 &= O(t) - O(t - \Delta) \end{aligned} \quad (3)$$

式中, Δ 为样本数据的采样周期; $O(t)$ 为 t 时刻氧含量; d_1 、 d_2 均为前向一阶差分,反映距 t 时刻较近时间段内氧含量的变化情况; $f(\alpha)$ 、 $T(\alpha, \beta)$ 均为映射关系。

$$\begin{aligned} f(\alpha) &= \begin{cases} 0 & |\alpha| \leq \Omega \\ \alpha & |\alpha| > \Omega \end{cases} \\ \alpha\beta & \quad \alpha > 0, \beta > 0 \\ T(\alpha, \beta) &= \begin{cases} \alpha + \beta & \alpha = 0, \beta = 0 \\ -|\alpha\beta| & \text{else} \end{cases} \end{aligned} \quad (4)$$

式中, Ω 为阈值常量因子,为氧含量变化提供死区控制, $0 < \Omega < 1.0$,用以滤除氧含量值小范围变动时的 η 的极性波动。根据式(3)、(4), $\eta(t)$ 将系统 t 时刻前氧含量持续上升的情况映射为正值,可以提升分类器对氧含量变化趋势的识别度。

4 训练及预测结果

本文共选取800组锅炉运行历史数据作为样本,其中400组作为训练数据,400组作为预测验证数据,使用libsvm软件包进行SVM训练。训练过程中核函数选取使用频率较高的径向基函数(radial basis function, RBF), $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$ [15,17], RBF核函数对于样本集线性不可分的情况有较大优势,是处理非线性小样本集的常用函数[16]。对于式(2)中的惩罚因子常量 C 以及RBF核函数中的常量 γ ,需要通过寻优的方式获得,libsvm使用网格搜索算法求解预测性能最高时最优化的 (C, γ) [15,17]。

为了提高实际分类的精度和泛化能力,避免欠学习和过学习状态,libsvm采用交叉验证方法来评估预测性能。本文选取 k 折交叉验证模型:将原始训练样本集均分为 k 个子集,每个子集分别做一次验证集,其余的 $k-1$ 组子集数据作为训练集,经过 k 轮训练得到多个分类模型,将多个模型的平均匹配率作为评价指标[15],评估 (C, γ) 每次搜索结果的预测性能。

表2为氧含量因子中 Ω 阈值常量取不同值,通过网格搜索得到最优 (C, γ) 构建的分类模型的支持

向量个数、最高交叉验证匹配率(评估性能),以及使用该模型对实际预测样本集的预测准确率(实际性能)。

表2 Ω 取不同值时的训练及预测结果

Table 2 Prediction results as a function of Ω values

Ω	支持向量个数	最高交叉验证匹配率/%	预测准确率/%
0.1	34	97.25	66.83
0.2	50	97.25	90.27
0.3	50	97.00	90.27
0.4	61	97.25	96.01
0.5	37	97.50	66.58
0.6	30	97.50	64.59
0.7	33	97.25	67.83
0.8	33	97.50	67.83
0.9	33	97.75	67.83

根据表2, $\Omega = 0.4$ 时预测准确率最高,为96.01%,其最高交叉验证匹配率为97.25%。预测失败样本的失配率如图3所示。网格搜索算法将 C 、 γ 分别在一定范围内取一系列离散值分别代入程序进行训练,以获得预测性能最高时的参数对[15-16]。

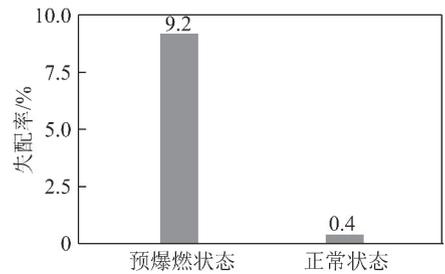


图3 失配率

Fig. 3 Mismatching rate

根据表2, Ω 参数的变化使得氧含量小范围波动时, η 极性发生变化,进而改变支持向量的个数,根据前文所述,支持向量为样本集中位于两异类点集边界超平面上的样本,对于实际分类超平面的选取贡献最大,同时也说明氧含量的变化速率与锅炉预爆燃状态的识别具有强关联性;因此实际锅炉运行时需要经过大量样本多次比对验证后来确定 Ω ,以获取最优训练模型。

根据表2的训练及预测结果,SVM训练最高预测准确率超过95%;根据图3,对于预爆燃状态及锅炉正常状态,预爆燃样本点失配率 $< 10\%$;正常运行样本点失配率 $< 1\%$,分类器对于预爆燃状态监测具

有较好的稳定性,同时也能够保证在锅炉正常状态时的低误判率。

5 结 论

从结果可以看出,仍有部分样本点不能达到预期的预测效果,对于预爆燃状态的预测失配率接近 10%,有待于采取改进的模型进行分类器训练以及参数寻优,今后的工作需从以下几方面进行完善:

1) 增加系统特征参数,综合考虑火焰强度、炉膛负压、供料量等参数的变化速率,扩展特征向量维度以优化分类器训练。

2) 优化训练样本采样规则,使各特征参数在样本空间分布更均匀,增加以及平衡正常和异常状态样本数量,抑制由于样本集中产生的过拟合效应。

3) 将 SVM 预测程序与锅炉燃烧控制系统、炉膛安全监控系统整合,提升爆燃保护系统的冗余度,增强系统的鲁棒性。

参考文献 (References):

[1] 冯现河. 高效煤粉工业锅炉系统在城市供热的应用[J]. 洁净煤技术, 2013, 19(3): 89-92, 101.
Feng Xianhe. Application of efficient coal powder industrial boiler system in urban heat supply[J]. Clean Coal Technology, 2013, 19(3): 89-92, 101.

[2] 宋春燕, 张鑫, 李婷. 高效煤粉锅炉替换层燃锅炉技术改造与能效分析[J]. 洁净煤技术, 2015, 21(3): 98-102, 106.
Song Chunyan, Zhang Xin, Li Ting. Technical and energy analysis of replacement of layer combustion boiler with efficient pulverized coal fired boiler[J]. Clean Coal Technology, 2015, 21(3): 98-102, 106.

[3] 王玉刚. 关于高效环保煤粉工业锅炉技术的推广和应用[J]. 科学与管理, 2015, 35(6): 66-69.
Wang Yugang. A research on popularization and application of high efficiency and environmental protection of coal industry boiler technology[J]. Science and Management, 2015, 35(6): 66-69.

[4] 宋春燕. 高效煤粉锅炉系统技术的工程化应用[J]. 洁净煤技术, 2015, 21(2): 89-92, 96.
Song Chunyan. Industrialization of efficient pulverized coal boiler system technology[J]. Clean Coal Technology, 2015, 21(2): 89-92, 96.

[5] 张克良. 基于模糊神经网络的锅炉燃烧控制方法的研究[D]. 天津: 天津大学, 2004: 14-46.

[6] 沈利. 燃煤电站锅炉的燃烧优化技术及相关算法应用研究[D]. 杭州: 浙江大学, 2011: 19-40.

[7] 林奠灏. 基于支持向量机的炉膛火焰温度场测量研究[D]. 合肥: 合肥工业大学, 2012: 26-55.

[8] 张振星, 孙保民, 信晶. 基于自适应遗传算法的锅炉低 NO_x 燃烧建模及其优化[J]. 热力发电, 2014, 43(9): 60-64, 70.
Zhang Zhenxing, Sun Baomin, Xin Jing. Adaptive genetic algorithm based low NO_x combustion modeling and optimization for boilers[J]. Thermal Power Generation, 2014, 43(9): 60-64, 70.

[9] 牛玉广, 沙超, 孟庆伟, 等. 基于 WLS-SVM-SFS 模型的电站锅炉燃烧优化[J]. 热力发电, 2014, 43(5): 7-12.
Niu Yuguang, Sha Chao, Meng Qingwei, et al. Combustion optimization for utility boilers based on WLS-SVM-SFS Model[J]. Thermal Power Generation, 2014, 43(5): 7-12.

[10] 赵文杰, 吕猛. 基于多 LS-SVM 集成模型的锅炉 NO_x 排放量建模[J]. 电子测量与仪器学报, 2016, 30(10): 1037-1044.
Zhao Wenjie, Lyu Meng. NO_x emission modeling of coal-fired boiler based on multi LS-SVM ensemble model[J]. Journal of Electronic Measurement and Instrument, 2016, 30(10): 1037-1044.

[11] 尹金和, 齐咏生, 李志林, 等. 基于小波 SVM 的电站锅炉飞灰含碳量预测[J]. 能源与节能, 2015(8): 120-123.
Yin Jinhe, Qi Yongsheng, Li Zhilin, et al. Prediction of the unburned carbon of utility boilers based on wavelet SVM[J]. Energy and Energy Conservation, 2015(8): 120-123.

[12] 卢铭庆, 张黎浚. 锅炉炉膛爆燃机理分析及防止[J]. 江西电力, 2004, 28(2): 19-21, 34.
Lu Mingqing, Zhang Lixun. Mechanism analysis and prevention for boiler furnace puff[J]. Jiangxi Electric Power, 2004, 28(2): 19-21, 34.

[13] 董志明, 廖鹏, 袁登友. 300 MW 循环流化床锅炉爆燃原因及控制措施[J]. 锅炉技术, 2008, 39(2): 38-40.
Dong Zhiming, Liao Peng, Yuan Dengyou. Reasons and counter measures of the explosive combustion in a 300 MW CFB boiler[J]. Boiler Technology, 2008, 39(2): 38-40.

[14] 江波, 熊钟. 超超临界 660 MW 机组低负荷运行炉膛爆燃原因分析[J]. 陕西电力, 2016, 44(6): 85-88.
Jiang Bo, Xiong Zhong. Analysis on furnace explosion of 660 MW ultra-supercritical unit under low load[J]. Shaanxi Electric Power, 2016, 44(6): 85-88.

[15] Chang C C, Lin C J. LIBSVM: A library for support vector machines[J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 1-27.

[16] Haridas N, Sowmya V, Soman K P. Gurls vs libsvm: Performance comparison of kernel methods for hyperspectral image classification[J]. Indian Journal of Science and Technology, 2015, 8(24): 1-10.

[17] Gu B, Sheng V S, Tay K Y, et al. Incremental support vector learning for ordinal regression[J]. IEEE Transactions on Neural networks and learning Systems, 2015, 26(7): 1403-1416.