

文章编号: 1001-0920 (2012) 10-0000-00

## 基于改进的 QBC 和 CS-SVM 的故障检测

唐明珠, 阳春华, 桂卫华

(中南大学 信息科学与工程学院, 长沙 410083)

**摘要:** 针对复杂工业过程样本集中的类不平衡、样本标注代价昂贵和样本孤点的问题, 研究基于委员会投票选择 (MQBC) 和代价敏感支持向量机 (CS-SVM) 的故障检测方法. 给出未标注样本信息度的定义, 提出改进的委员会投票选择算法. 主动代价敏感学习通过 MQBC 选择信息度高的未标注样本对其标注并添加到训练集. CS-SVM 将不同类样本的误分类赋予不同的误分类代价, 从而提高 CS-SVM 的故障检测率. 最后, 以铜闪速熔炼过程为例, 实验结果验证了所提出方法的有效性.

**关键词:** 主动学习; 代价敏感支持向量机; 委员会投票选择算法; 故障检测

中图分类号: TP18

文献标志码: A

## Fault detection based on modified QBC and CS-SVM

TANG Ming-zhu, YANG Chun-hua, GUI Wei-hua

(School of Information Science & Engineering, Central South University, Changsha 410083, China. Correspondent: YANG Chun-hua, E-mail: ychh@mail.csu.edu.cn)

**Abstract:** Fault detection based on modified query by committee (MQBC) and cost-sensitive support vector machine (CS-SVM) is proposed to solve three difficulties of fault detection, including class-imbalanced dataset, expensive labeled cost and outlier of sample set. The definition of information is given and the MQBC is proposed. The score of unlabeled sample is evaluated by using information, and the high score of unlabeled sample is selected to be labeled and added to the training set. Different misclassification types of samples are given to different misclassification cost in CS-SVM, so that the fault detection rate is increased. Finally, fault detection for copper flash smelting process is studied to illustrate the effectiveness of the proposed approach.

**Key words:** active learning; cost-sensitive support vector machine; query by committee; fault detection

### 1 引言

现代复杂工业过程时刻产生大量反映过程运行机理和运行状态的数据, 基于成本优化、实际限制和技术商机等因素, 如何利用这些海量数据来提高系统的可靠性成为亟待解决的问题, 基于数据的故障检测方法受到了研究者和企业的极大关注.

传统的基于数据的故障检测大多基于机器学习和数据挖掘方法, 并将故障检测转化为相应的分类问题来解决. 如基于决策树的方法<sup>[1]</sup>、基于代价敏感支持向量机的方法<sup>[2]</sup>、基于单类支持向量机的方法<sup>[3]</sup>和基于代价敏感概率神经网络的方法<sup>[4]</sup>等, 这些方法在一定程度上取得了比较满意的检测率和误报率. 但这些方法都非常依赖于有标注的样本. 然而在

实际的复杂工业过程中, 收集故障类数据并对其进行标注, 是一件代价非常昂贵的工作, 需要领域专家的参与. 而主动学习为解决标注代价昂贵问题提供了途径. 文献 [5] 提出了误差减少选择样本的方法, 即选择使当前分类器对测试集分类误差最小的样本作为候选样本. 该方法的学习精度高, 因为每次选择样本之间, 必须搜索整个样本空间, 所以学习时间长, 复杂度高. [6] 提出了不确定性选择样本方法 (UBS), 选择当前分类器最不能确定其分类的样本作为候选样本, 但该方法有可能选择孤立点. [7-8] 提出了委员会投票选择方法 (QBC), 根据已标注样本训练两个或多个分类器, 组成委员会, 利用这个委员会预测样本进行标注投票, 选择委员之间投票不一致程度最大

收稿日期: 2011-05-04; 修回日期: 2011-09-07.

基金项目: 国家杰出青年科学基金项目 (61025015); 国家自然科学基金项目 (60874069); 国家 863 计划项目 (2009AA04Z137); 中南大学优秀博士学位论文扶植项目.

作者简介: 唐明珠 (1983—), 男, 博士生, 从事数据挖掘、机器学习等研究; 阳春华 (1965—), 女, 教授, 博士生导师, 从事复杂工业过程建模与优化控制等研究.

的样本作为候选样本,但该方法也有可能选择孤立点.为此,如何在类不平衡问题(即样本集中故障类样本少正常类样本多)和标注代价昂贵(已标注样本少未标注样本多,标注样本代价昂贵)的情况下训练出高检测率和低误分类代价的故障检测模型,成为当今复杂工业故障检测研究难点和研究热点.

针对复杂工业过程样本集中的类不平衡问题、标注代价昂贵问题和孤立点问题,提出基于改进的委员会选择算法(MQBC)和代价敏感支持向量机(CS-SVM)的故障检测方法.通过对铜闪速炉熔炼过程进行实验研究,研究结果验证了所提出方法的有效性.

## 2 代价敏感支持向量机

文献[2]提出了代价敏感支持向量机,类别不同的样本被误分时被赋予不同的误分类代价,假设已知类不平衡样本集为 $\{(\mathbf{x}_i, y_i)\}_{i=1}^n$ .其中: $\mathbf{x}_i \in R^d$ ,  $y_i \in Y = \{+1, -1\}$ ,  $I_+ = \{i : y_i = +1\}$ ,  $I_- = \{i : y_i = -1\}$ .该样本集能被超平面分类,代价敏感支持向量机优化问题的原问题为

$$\begin{aligned} \min_{w, b, \xi} & \frac{1}{2} \|w\|^2 + C_1 \sum_{i \in I_+} \xi_i + C_2 \sum_{i \in I_-} \xi_i. \\ \text{s.t. } & y_i((k(w, \mathbf{x}_i) + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, n; \\ & \xi_i \geq 0, \quad i = 1, 2, \dots, n; \\ & C_i \geq 0, \quad i = 1, 2. \end{aligned} \quad (1)$$

其中: $C_1, C_2$ 为误分类代价参数; $k(w, \mathbf{x}_i)$ 为核函数; $\{\xi_i\}_{i=1}^n$ 为误差.

代价敏感支持向量机原问题(1)的对偶问题为

$$\begin{aligned} \min_{\alpha} & \frac{1}{2} \sum_{i, j} \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j) - \sum_{i=1}^n \alpha_i. \\ \text{s.t. } & 0 \leq \alpha_i \leq C_1, \quad i \in I_+; \\ & 0 \leq \alpha_i \leq C_2, \quad i \in I_-; \\ & \sum_{i=1}^n \alpha_i y_i = 0. \end{aligned} \quad (2)$$

其中: $\{\alpha_i\}_{i=1}^n$ 为Lagrange乘子; $C_1, C_2$ 为误分类代价参数; $k(\mathbf{x}_i, \mathbf{x}_j)$ 为核函数.文献[2]指出,在没有先验知识的情况下,选择高斯核函数时CS-SVM分类性能优于其他核函数,而高斯核宽度值 $\sigma$ 通过网格搜索法获得.

## 3 改进的委员会投票选择算法

委员会投票选择方法<sup>[7]</sup>根据已标注样本训练两个或多个分类器,组成委员会,利用这个委员会预测样本进行标注投票,选择委员之间投票不一致程度最大的样本作为候选样本.

当分类引擎选择下一个未标注样本时,需要知道样本的真实标注,但样本的真实标注只有将未标

注样本提交领域专家以后才能获得.因此,只能通过估计得出未标注的真实标注.

MQBC通过委员会来估计未标注样本的真实标注,委员会通过多个代价敏感支持向量机组合成一个分类器,采用投票的方法决定未标注样本的标注.委员会成员数越大,委员会的分类正确率趋近于1<sup>[9]</sup>,也就是说分类预测结果趋近于真实标注.

当委员会估计真实标注后,MQBC在每次选择样本时选择信息度大的未标注样本,未标注样本的信息度为委员会的预测标注与当前分类器的预测标注不一致程度和未标注样本与标注样本集的均值之间的马氏距离倒数之和.

在选择样本时,MQBC在已标注样本集上训练后得到的版本空间中随机选择多个假设构成委员会,将委员会对未标注样本的预测概率分布作为未标注的真实样本.同时,当前分类器对样本的预测类概率分布作为预测标注的类概率分布,计算真实标注的类概率分布和预测标注的类概率分布之差的绝对值的熵,将其作为选取样本的信息度的一部分.其值越大,表明预测标注和真实标注不一致的程度越大.

$$\begin{aligned} \text{Inconsistent}(\mathbf{x}_i) &= \sum_{c \in Y} [p_D^{\text{com}}(c|\mathbf{x}_i) - p_D^{\text{cur}}(c|\mathbf{x}_i)] \cdot \\ & \lg \frac{1}{|p_D^{\text{com}}(c|\mathbf{x}_i) - p_D^{\text{cur}}(c|\mathbf{x}_i)|}. \end{aligned} \quad (3)$$

其中: $p_D^{\text{com}}(c|\mathbf{x}_i)$ 为与训练集 $D$ 一致的委员会对未标注样本 $\mathbf{x}_i$ 的分类预测为类别 $c$ 的概率, $p_D^{\text{cur}}(c|\mathbf{x}_i)$ 为与训练集 $D$ 一致的当前分类器对样本 $\mathbf{x}_i$ 的分类预测为类别 $c$ 的概率, $Y$ 为样本集类别集合.

标注样本集的均值(或中心向量)定义如下:

$$\mu = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i. \quad (4)$$

为了不采样到孤立点,标注集的中心向量与未标注样本之间的马氏距离如下:

$$r(\mathbf{x}_i) = [(\mathbf{x}_i - \mu)^t \Sigma^{-1} (\mathbf{x}_i - \mu)]^{1/2}. \quad (5)$$

其中: $\mathbf{x}_i$ 为未标注样本; $\mu, \Sigma$ 分别为标注样本集的均值和协方差.

改进的QBC评估未标注样本的信息度标准为

$$\text{Score}(\mathbf{x}_i) = \lambda_1 * \text{Inconsistent}(\mathbf{x}_i) + \lambda_2 * \frac{1}{r(\mathbf{x}_i)}. \quad (6)$$

其中: $\lambda_1, \lambda_2 \in [0, 1]$ ,分别表示委员会成员之间不一致程度的权重和未标注样本与标注样本集均值之间的马氏距离倒数的权重.当 $\lambda_1 = \lambda_2 = 0.5$ 时,表明未标注样本 $\mathbf{x}_i$ 的委员会之间不一致程度与中心向量的马氏距离倒数一样重要;当 $\lambda_1 = 1, \lambda_2 = 0$ 时,只考虑未标注样本的不一致程度,即退化成文献[7]的QBC方法;当 $\lambda_1 = 0, \lambda_2 = 1$ 时,只考虑未标注样本与中心向量马氏距离倒数,也就是选择一个

与标注样本集的中心向量马氏距离最近的未标注样本。一般情况下,既要考虑未标注样本的不一致程度,这是对分类器决策边界起重要作用的样本,也要考虑未标注样本的马氏距离倒数,这是为了减少采样到孤立的点概率,实验中设 $\lambda_1 = \lambda_2 = 0.5$ 。

#### 4 基于MQBC和CS-SVM的故障检测

主动代价敏感学习算法描述如下:算法初始时样本集由一个占少数的标注样本集和占绝大多数的未标注样本集组成;先将标注样本集作为训练集来训练代价敏感支持向量机,以未标注样本的信息度为评估标准;然后从未标注样本集中采样一个或多个样本提交给领域专家进行标注,将标注后的样本添加到已标注样本集中,将更新后的标注样本集作为训练集进行训练,循环执行多次,直到代价敏感支持向量机的平均误分类代价或者最大迭代次数达到预设的值。

基于MQBC和CS-SVM的故障检测方法如下:

输入:标注样本集 $L$ ,未标注样本集 $U$ ,代价矩阵 $C$ ,最大迭代次数 $t_{\max}$ ,平均误分类代价AMC的阈值 $\delta$ ,代价敏感支持向量机代价参数和高斯核函数宽度 $C_1, C_2, \sigma_{\text{CS-SVM}}$ ;

输出:代价敏感支持向量机(CS-SVM)及性能参数。

Step 1: 初始化标注样本集 $L$ ,未标注样本集 $U$ ,代价矩阵 $C$ ,最大迭代次数 $t_{\max}$ ,平均期望代价AMC的阈值 $\delta$ ,代价敏感支持向量机代价参数和高斯核函数宽度 $C_1, C_2$ 和 $\sigma_{\text{CS-SVM}}$ ,迭代次数 $t = 0$ 。

Step 2: 用标注样本集 $L$ 训练测试分类器代价敏感支持向量机(CS-SVM)(通过10折交叉验证计算平均期望误分类代价和平均故障检测率)。

Step 3: 如果满足终止条件(迭代最大次数 $t_{\max}$ 或平均期望代价AMC小于阈值 $\delta$ ),输出分类器CS-SVM参数及性能参数,算法结束,否则转Step 4。

Step 4: 利用式(4)和(5)分别计算标注样本集的中心向量、未标注样本集中的每个未标注样本与中心向量之间的马氏距离。

Step 5: 依据式(3)计算 $U$ 中的每一个未标注样本 $x_i$ 绝对值的熵。

Step 6: 依据式(6)计算 $U$ 中的每一个未标注样本 $x_i$ 的信息度。

Step 7: 依据信息度对 $U$ 中的每一个样本 $x_i$ 进行排序;

Step 8: 选择信息度 $\text{Score}(x_i)$ 值大的前 $m$ (整

数)个样本作为未标注样本集 $u$ 。

Step 9: 对 $u$ 的每一个样本 $x_i$

提交领域专家标注样本 $x_i, y_i = \text{label}(x_i)$ ;

更新已标注样本集 $L = L \cup \{(x_i, y_i)\}$ ;

Step 10: 更新未标注样本集 $U = U \setminus u$ 。

Step 11: 用已标注样本集 $L$ 训练代价敏感支持向量机(CS-SVM)。

Step 12: 迭代次数增加1,即 $t = t + 1$ ,转Step 3。

其中迭代最大次数 $t_{\max}$ 选取范围为 $[1, |U|/m]$ 。这里: $|U|$ 为样本集中未标注样本数, $m$ 为每次循环时标注未标注样本数。迭代次数 $t_{\max}$ 越大,平均误分类代价越小;平均误分类代价AMC的阈值 $\delta$ 选取依据期望的故障检测率和故障类误分成正常类代价来设定,即

$\delta = (1 - \text{期望故障检测率}) * \text{故障类误分成正常类代价}$ 。

#### 5 工业应用

铜闪速熔炼过程<sup>[10]</sup>将深度脱水(含水小于0.3%)的精矿粉末,在闪速炉喷嘴处与空气或氧气混合,以高速度(60~70 m/s)喷入高温(1450~1550 °C)反应塔内。在2~3 s内完成硫化物的分解、氧化和熔化,形成熔融硫化物和氧化物的混合熔体,并下降到反应塔底部,在沉淀池中汇集并沉淀完成硫与炉渣的澄清分离,最终形成冰铜与炉渣。

深入分析铜闪速熔炼过程机理可知,铜闪速熔炼过程的影响因素主要有18个,如表1所示。本文将闪速熔炼过程的影响因素作为故障检测方法的输入向量,类别作为故障检测方法输出。

表 1 闪速熔炼过程的影响因素

入炉铜精矿总量	烟尘量
入炉铜精矿的铜品位	渣中铁硅比
入炉铜精矿的铁品位	铜铈品位
入炉铜精矿的硫品位	反应塔烟气温度
入炉铜精矿的二氧化硅品位	氧效率
空气量	工业氧浓度
石英熔剂量	烟尘发生率
石英熔剂中的二氧化硅品位	反应塔燃烧风氧浓度
石英熔剂中的铁品位	空气水分率

从某铜闪速熔炼过程生产现场采集的样本集分布如表2所示。表2中的样本集1表示从2010年1~6月某铜冶炼厂铜闪速炉熔炼过程样本集,其中正常类样本数和故障类样本数分别为1987和394;样本集2表示从2010年7~12月某铜冶炼厂闪速炉熔炼过程样本集,其中正常类样本数和故障类样本数分别为4023和504。故障类样本指的是闪速熔炼过程的产品经济成本不符合计划目标,而正常类样本指的是闪速熔炼过程的产品经济成本符合计划目标。

表 2 样本集描述

样本集名	样本数	特征数	正常类样本数	故障类样本数
dataset <sub>1</sub>	2381	18	1987	394
dataset <sub>2</sub>	4527	18	4023	504

为了全面评价基于MQBC和CS-SVM的故障检测方法的性能,将故障检测率和全局的平均误分类代价作为评价标准.故障检测率定义为

$$\text{AvgSensitivity} = \text{tp}/(\text{tp} + \text{fn}), \quad (7)$$

全局的平均误分类代价定义为

$$\text{AvgMisCost} = \frac{\text{fn} * C_{2|1} + \text{fp} * C_{1|2} + \text{tp} * C_{1|1} + \text{tn} * C_{2|2}}{\text{tp} + \text{fn} + \text{tn} + \text{fp}}. \quad (8)$$

其中:  $\text{tp}$ ,  $\text{fn}$  表示使用分类器将原本属于故障类样本分别预测为故障类样本的数和正常类样本的数;  $\text{fp}$ ,  $\text{tn}$  表示使用分类器将原本属于正常类样本分别预测为故障类样本的数和正常类样本的数;  $C_{i|j}$  为将第  $j$  类的样本误分到第  $i$  类的误分类代价,  $i, j \in \{1, 2\}$ . 当正常类样本预测为正常类样本和故障类样本预测为故障类样本时,认为误分类代价为 0, 即  $C_{1|1} = C_{2|2} = 0$ . 当正常类样本预测为故障类样本和故障类样本预测为正常类样本时,分别为  $C_{2|1}, C_{1|2}$ , 对应于代价敏感支持向量机的两个误分类代价参数为  $C_1, C_2$ , 而  $C_1, C_2$  选取为样本集中故障类样本数与正常类样本数之比.

在实验中,为了保证实验的可比性和公平性,主动代价敏感学习的选择算法分别为随机采样(RS)算法、委员会投票选择(QBC)算法、改进的委员会投票选择(MQBC)算法;分类器采用代价敏感支持向量机(CS-SVM).CS-SVM参数为误分类代价参数  $C_1, C_2$  和高斯核函数的宽度  $\sigma_{\text{CS-SVM}}$ . 对于样本集 1 基于改进的 QBC 算法和 CS-SVM 的故障检测方法取  $C_1 = 5, C_2 = 1, \sigma_{\text{CS-SVM}} = 1$ , 期望故障检测率为 99%; 对于样本集 2 基于改进的 QBC 算法和 CS-SVM 的故障检测方法取  $C_1 = 8, C_2 = 1, \sigma_{\text{CS-SVM}} = 2$ , 期望故障检测率为 99%.

为了验证 MQBC 方法对于 CS-SVM 算法的误分类代价的有效性,特别关注 CS-SVM 在达到同等较低的误分类代价的条件下,采用随机采样、QBC 采样、MQBC 采样所需样本的数量的比较结果,如图 1 和图 2 所示.从图 1 中可知,随着主动代价敏感学习中采样样本数的增加,当 CS-SVM 的误分类代价减少到 0.3423 时,随机采样、QBC 采样、MQBC 采样所需样本的数量分别为大于 484, 389 和 254. 这就证明了在 CS-SVM 算法引入 MQBC 后只要标注少量的未标注样本便可获得同样低的误分类代价.从图 2 中可知,CS-SVM 的误分类代价减少至 0.2483 时,随机采样、QBC 采样、MQBC 采样所需样本的

数量分别为大于 561, 561 和 346. 图 1 和图 2 表明,当 CS-SVM 算法引入 MQBC 后只要标注少量的未标注样本便可获得同样低的误分类代价,因此减少了标注样本的规模,也减少了标注代价.同时,随着采样样本数的增加,QBC 的误分类代价时高时低,波动很大,说明 QBC 有可能采样到孤立点,导致代价敏感支持向量机的决策边界有很大的变化,从而导致误分类代价波动大;而 MQBC 随着采样样本数的增加,误分类代价迅速减少,且波动不大,说明 MQBC 采用了信息度作为选择未标注样本的标准,有效地减少了采集到未标注样本集中的孤立点的概率.




图 1 不同采样方法 CS-SVM 在样本集 1 上的平均误分类代价




图 2 不同采样方法 CS-SVM 在样本集 2 上的平均误分类代价

为了验证 MQBC 算法对于 CS-SVM 算法的故障检测率的有效性,特别关注 CS-SVM 在达到同等较高的故障检测率的条件下,采用随机采样、QBC 采样、MQBC 采样所需样本的数量的比较结果,如图 3 和图 4 所示.从图 3 中可知,随着主动代价敏感学习中采样样本数的增加,当 CS-SVM 的故障检测率增加到 0.9099 时,随机采样、QBC 采样、MQBC 采样所需样本的数量分别为 484, 389 和 98.从图 4 中可知,当 CS-SVM 的故障检测率增加到 0.9448 时,随机采样、QBC 采样、MQBC 采样所需样本的数量分别为大于 561, 234 和 80.图 3 和图 4 表明,当 CS-SVM 算法引入 MQBC 后只要标注少量的未标注样本便可获得同样高的故障检测率,因此减少了标注样本的规模,也减少了标注代价.同时,随着采样样本数的增加,QBC 的故障检测率时高时低,波动很大,说明 QBC 有可能采样到孤立点,导致代价敏感支持向量机的决策边界有很大的变化,从而导致误分类

代价有变化;而MQBC随着采样样本的增加,故障检测率呈增加趋势,且波动不大,说明MQBC采用信息度作为未标注样本的选择标注,减少了采集到未标注样本集中孤立点的概率。




图 3 不同采样方法下 CS-SVM 在样本集 1 上的故障检测率




图 4 不同采样方法下 CS-SVM 在样本集 2 上的故障检测率

## 6 结 论

由于样本标注的代价非常昂贵,为了减少样本的标注代价,主动代价敏感学习通过改进的委员会投票选择算法评估样本的信息度,对信息度高的未标注样本提交领域专家标注,有效地减少了标注的样本量,从而减少了样本的标注代价。由于故障类样本预测为正常类样本的代价远高于正常类样本预测为故障类样本的代价,代价敏感支持向量机将故障类样本误分为正常类样本和正常类误分为故障类的误分类代价赋予不同的值,从而提高了故障检测率,并减小了误分类代价。针对QBC采样时有可能采集到孤立点的问题,提出了将信息度作为未标注样本的评价准则,既考虑未标注样本对代价敏感支持向量决策边界的影响,又减小选择未标注样本集中的孤立点的概率。将所提出方法应用于铜闪速熔炼过程,实验结果验证了该方法的有效性。

## 参考文献(References)

[1] Saimurugan M, Ramachandran K I, Sugumaran V, et al. Multi component fault diagnosis of rotational mechanical

system based on decision tree and support vector machine[J]. *Expert Systems with Applications*, 2011, 38(3): 3819-3826.

- [2] Davenport M A. The 2nu-SVM: A cost-sensitive extension of the nu-SVM[R]. Rice University ECE Technical Report, no. TREE 0504, 2005.
- [3] Mahadevan S, Shah S L. Fault detection and diagnosis in process data using one-class support vector machines[J]. *J of Process Control*, 2009, 19: 1627-1639.
- [4] 唐明珠, 阳春华, 桂卫华, 等. 代价敏感概率神经网络及其在故障诊断中的应用[J]. *控制与决策*, 2010, 25(6): 1074-1078.  
(Tang M Z, Yang C H, Gui W H, et al. Cost-sensitive probabilistic neural network and its application in fault diagnosis[J]. *Control and Decision*, 2010, 25(7): 1074-1078.)
- [5] Roy N, McCallum A K. Toward optimal active learning through sampling estimation of error reduction[C]. *Proc of 18th in the Conf Machine Learning*. San Francisco: Morgan Kaufmann, 2001: 441-448.
- [6] Lewis D, Gale W. A sequential algorithm for training text classifiers[C]. *Proc of the ACM SIGIR Conf on Research and Development in Information Retrieval*. London: ACM/Springer, 1994: 3-12.
- [7] Seung H S, Oppor M, Sompolinsky H. Query by Committee[C]. *Proc of 15th Annual ACM Workshop on Computational Learning Theory*. Pittsburgh: Morgan Kaufmann, 1992: 287-294.
- [8] Freund Y, Seung H S, Shamir E, et al. Selective sampling using the query by committee algorithm[J]. *Machine Learning*, 1997, 28(1): 133-168.
- [9] Pham D, Asano S, Bolliger M, et al. The design and imlementation of a first-generation cell processor[C]. *Proc of ISSCC'05*. 2005: 184-185.
- [10] 桂卫华, 阳春华, 李勇刚, 等. 基于数据驱动的铜闪速熔炼过程操作模式优化及应用[J]. *自动化学报*, 2009, 35(6): 717-724.  
(Gui W H, Yang C H, Li Y G, et al. Data-driven operational pattern optimization for copper flash smelting process[J]. *Acta Automatica Sinica*, 2009, 35(6): 717-724.)