

DOI: 10.7641/CTA.2014.30491

选矿过程精矿品位自适应在线支持向量预测方法

刘长鑫[†], 丁进良, 姜 波, 柴天佑

(东北大学 流程工业综合自动化国家重点实验室, 辽宁 沈阳 110819)

摘要: 本文提出了一种基于支持向量回归的选矿过程精矿品位自适应在线预测方法, 通过使用新的混合核函数和参数在线更新机制提高了精矿品位的预测精度. 在分析经典核函数特性后, 构造了一种混合核函数以兼顾模型的学习能力与泛化能力, 同时为了提高预测方法对选矿生产动态过程的适应性, 模型依据新工况样本对现有样本集统计特性的影响, 引入了模型参数自适应调整机制, 并采用在线迭代学习机制更新模型, 提高了模型的计算速度. 使用某选矿厂生产实际数据进行实验分析, 结果表明本文方法比现有方法在计算时间和预测精度上都有明显优势, 适合应用于动态变化的选矿生产过程.

关键词: 自适应参数; 在线预测; 混合核函数; 支持向量机; 精矿品位

中图分类号: TP273 **文献标识码:** A

Adaptive online support vector regression prediction model for concentrate grade of the ore-dressing processes

LIU Chang-xin[†], DING Jin-liang, JIANG Bo, CHAI Tian-you

(State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang Liaoning 110819, China)

Abstract: An online prediction approach is proposed for concentrate grade of ore-dressing processes based on support vector regression (SVR). The algorithm combines a new mixture kernel function and an updating technique for adaptive online parameters. In this context, different type of kernel functions is analyzed, and a new mixed kernel is developed to reach a compromise between learning capability and generalization. Furthermore, to improve the adaptability, an adaptive parameter scheme for online updating is introduced to match the changing process conditions, which considers that each new sample can change statistic properties of the training data set. Experiment results demonstrate its higher accuracy and faster computation speed than existing methods, which suggests that it is appropriate to be applied to dynamic ore-dressing production processes.

Key words: adaptive parameters; online prediction; mixture kernel; support vector regression; concentrate grade

1 引言(Introduction)

精矿品位是选矿生产过程的最终关键生产指标之一, 直接影响着企业的总体经济效益. 品位高说明精矿质量好, 价格就高, 提高产量的同时保证精矿品位一直是选矿企业的生产目标. 但是精矿品位的高低与选矿过程各段工序包括竖炉、强磁磨矿、弱磁磨矿、强磁浮选、弱磁浮选等主要工序都密切相关. 为了保证选矿过程最终的精矿品位需要整个生产过程协同控制. 然而由于选矿过程的复杂性使其往往难以及时在线获取, 一般精矿品位都是通过离线抽样化验的方式获得, 伴随较大的滞后性, 生产操作工和工程师很难及时调整操作设置来保证最终精矿品位稳定. 伴随着基础控制系统的全面应用及计算机技术的飞速发展, 大量的生产工况数据都可以迅速采集并进行存储.

通过这些易于直接检测的相关过程数据, 挖掘其与最终精矿品位之间的隐含关系, 从而研究并建立精矿品位的实时在线预测模型, 对指导工程师面对变化的工况条件及时合理调整操作决策, 保持各工序的高效平稳运行, 从而保证最终精矿品位稳定具有重要意义.

选矿过程因其过程复杂, 机理不清, 目前国内外鲜有采用机理建立精矿品位预测模型的文献研究, 大多采用基于数据的建模方法. 文献[1]采用回归分析法通过统计分析方法将大量过程参数和质量数据进行分析、浓缩和提取, 建立主导变量和辅助变量之间的数学模型; 文献[2]利用线性模型加非线性补偿的方法建立了精矿品位预测模型, 并通过概率密度估计选择最优参数; 文献[3]采用加权支持向量机的方法建立了生产指标预测模型, 并通过构造重要性函数的方法确定

收稿日期: 2013-05-16; 收修改稿日期: 2013-10-16.

[†]通信作者. E-mail: cxliu@mail.neu.edu.cn.

基金项目: 国家自然科学基金资助项目(61273031, 61134006); 新世纪人才计划资助项目(NCET-12-0104); 辽宁省优秀人才支持计划资助项目(LJQ2012020); 国家支撑计划“选矿过程全流程先进控制技术”资助项目(2012BAF19G01).

了支持向量机加权系数,也取得了较好的预测效果。通过分析以上方法,容易发现其共同特征,即它们得到的模型都属于离线模型,以获得的历史样本数据通过批量训练,得到预测模型用来预测品位等指标。但是随着新工况样本数据的到来并没有立即对模型进行更新并参与下一次预测,因此随着工况条件的变化其预测精度也会发生变化,甚至变得相对较差。而如果每次新工况样本到来时都采用历史数据重新训练整个模型,则当样本量增加时其训练时间呈非线性增长,成为实际应用的瓶颈。

支持向量机是一种有潜力的用于处理数据分类与回归的新技术^[4-5],它采用结构风险最小化原则,相比基于经验风险最小化原则的模型(如神经网络等)更容易获得好的泛化性能,避免局部解,同时解的稀疏性有利于提高算法的运行速度,从而获得了广泛的应用^[6-9]。针对新样本添加到训练集后经典支持向量回归模型需要完全重新训练的问题,文献[10]提出了在线支持向量回归模型,其采用增量学习的方式对每次迭代过程中新增加的样本进行学习并更新模型,在获得与批训练算法得到模型效果相近的情况下,因为有效利用了前一次的迭代运算结果,减少了计算复杂度,实现了小时间成本下新样本的学习,计算效率比传统批训练支持向量回归模型明显提高。在相同条件下支持向量回归模型的性能主要取决于3个训练参数(核参数, C , ε)。目前针对批训练支持向量分类与回归参数选择与优化的研究较多^[12-14],对在线支持向量回归参数选择的研究则相对较少^[15]。文献[12]提出通过遗传算法寻求最佳参数,文献[13]则通过求解一个最小化回归误差函数问题求得最佳参数,文献[14]根据样本本序列的时间连续性,通过设计按时间递增的惩罚参数权重函数,使得距离预测样本时间越久的点权重小,距离预测样本时间越近的点权重重大,取得良好效果。类似的思想应用到在线支持向量回归预测为文献[15]的主要工作。

通过分析现有工作,不难发现,针对批训练支持向量回归预测模型的参数寻优选择往往需要求解另外一个参数优化子模型,从计算工作量和参数更新周期角度而言,显然都不适合直接应用到在线支持向量回归模型。文献[16]根据支持向量机的统计特性提出根据样本点特征直接确定参数的简单方法,在批处理支持向量回归中得到良好应用,其随样本增加而线性增加的计算复杂度比非线性增加的参数优化求解算法优势明显,利于应用到随着新样本到来及时更新模型的在线支持向量回归算法。

本文提出一基于支持向量回归的精矿品位自适应在线预测方法。针对单一核函数难以同时保证良好泛化性和预测精度的问题,本文通过分析现有经典核函

数特性,构造了一个新的混合核函数用于精矿品位预测方法,同时根据新样本数据添加到训练集后数据统计特性的变化,引入了模型参数的自适应更新机制。为了避免模型重复训练导致的冗余计算,文章通过结合支持向量回归在线迭代学习机制,加快了本文算法的计算速度。自适应参数及混合核函数一方面去除了固定参数支持向量机算法需要训练样本和待预测样本有一致特征的假设,同时提高了算法的学习能力与泛化能力。通过某选矿厂生产实际数据实验,结果表明本文方法比现有算法在训练时间和预测精度上都有明显优势,适合应用于动态选矿生产过程。

2 精矿品位自适应在线预测方法 (Adaptive online prediction algorithm for concentrate grade)

2.1 模型输入输出结构 (Input and output of the model structure)

选矿过程由一系列子工序组成,为了实现综合精矿品位的稳定,需要各个子工序协同操作。通过分析各子工序关键工艺指标与精矿品位之间的影响关系,本文选取对精矿品位影响突出的子工序工艺指标共11个作为预测模型的输入,分别为一次溢流回收率 x_{in1} 、弱磁入磨品位 x_{in2} 、弱精品位 x_{in3} 、弱尾品位 x_{in4} 、强磁入磨品位 x_{in5} 、强精品位 x_{in6} 、强尾品位 x_{in7} 、弱磁球磨机台时处理量 x_{in8} 、强磁球磨机台时处理量 x_{in9} 、弱磁粒度 x_{in10} 和强磁粒度 x_{in11} ,模型输出选定为精矿品位 y_{cg} 。因此,品位预测模型可以表示为如下非线性函数:

$$y_{cg} = f(x_{in1}, x_{in2}, \dots, x_{in11}), \quad (1)$$

式中 f 为非线性映射函数,表示与品位相关的子工序关键工艺指标到精矿品位之间的隐含关系。

将一组输入输出数据 (x_{in}, y_{cg}) 定义为一个样本,则可以得到预测模型需要的训练集

$$T = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\},$$

其中: $x_i \in X \subset \mathbb{R}^n$, $y_i \in Y \subset \mathbb{R}$, l 为训练样本对的个数。选矿精矿品位支持向量预测就是在高维空间 F 内中构造一个线性回归函数 $f(x)$ 使之经过训练之后,对于新工况下子工序指标组成的输入样本 x_c 可以找到对应的精矿品位 y_c 。品位预测模型函数表达如下:

$$f(x) = W^T \Phi(x) + b, \quad (2)$$

其中: W 是 F 中的向量, $\Phi(x)$ 将输入空间 X 映射到高维空间 F , b 为偏移位置。

根据品位预测模型预测值与样本实际值之间的误差容许度要求,定义误差精度 ε 不敏感损失函数

$$L_\varepsilon(y_i, f(x_i)) =$$

$$\begin{cases} |y_i - f(x_i)| - \varepsilon, & |y_i - f(x_i)| \geq \varepsilon, \\ 0, & \text{其他,} \end{cases} \quad (3)$$

则 W 和 b 可通过如下优化模型求解得到:

$$\min \frac{1}{2} W^T W + C \sum_{i=1}^l L_\varepsilon(y_i, f(x_i)), \quad (4)$$

其中: C 为惩罚系数, 表示对误差超出 ε 管道样本的惩罚. 由模型(4)知道, C 值越大, 惩罚越大, 则使得系统的泛化性能下降. 通过引入松弛变量 ξ_i, ξ_i^* , 模型(4)可以转化为凸二次规划问题:

$$\begin{aligned} \min & \frac{1}{2} W^T W + C \sum_{i=1}^l (\xi_i + \xi_i^*), \\ \text{s.t.} & \begin{cases} y_i - W^T \Phi(x_i) - b \leq \varepsilon + \xi_i, \\ W^T \Phi(x_i) + b - y_i \leq \varepsilon + \xi_i^*, \\ \xi_i, \xi_i^* \geq 0, \\ i = 1, \dots, l. \end{cases} \end{aligned} \quad (5)$$

通过引入拉格朗日乘子并转化为对偶问题, 得到对应的库恩-塔克(Karush-Kuhn-Tucker, KKT)条件为

$$\begin{cases} \frac{\partial L_D}{\partial \alpha_i} = \sum_{j=1}^l Q_{ij}(\alpha_j - \alpha_j^*) + \varepsilon - y_i + \xi - \delta_i + u_i = 0, \\ \frac{\partial L_D}{\partial \alpha_i^*} = \sum_{j=1}^l Q_{ij}(\alpha_j - \alpha_j^*) + \varepsilon + y_i - \xi - \delta_i + u_i = 0, \\ \frac{\partial L_D}{\partial b} = \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0. \end{cases} \quad (6)$$

最终得到精矿品位支持向量预测模型式(1)的显式表达

$$f(x) = \sum_{i=1}^l Q_{ij} \theta_i + b, \quad (7)$$

其中: $Q_{ij} = \Phi(x_i)^T \Phi(x_j) = K(x_i, x_j)$ 为核函数, 实现输入空间到高维空间的非线性映射, $\theta_i = \alpha_i - \alpha_i^*$, α_i, α_i^* 为拉格朗日乘子, 满足约束 $\alpha_i \times \alpha_i^* = 0, \alpha_i, \alpha_i^* \geq 0$.

通过历史数据组成样本集的训练可以得到品位预测模型中的核函数 Q_{ij}, θ_i 和 b , 因此模型可以根据待预测工况样本计算对应精矿品位的预测值.

2.2 模型在线更新原理(Online update principle)

为得到选矿品位预测模型(7), 传统支持向量求解方法需要在整个样本集上进行批次训练从而建立回归预测模型, 随着样本集容量逐渐增加, 训练时间将呈非线性增长. 文献[10]提出了一种在线支持向量回归训练方法, 当新工况条件下子工序指标组成的样本 x_c 添加到模型训练集 T 之后, 立刻动态调整该样本

对应的 θ_c , 使得在训练集上预测模型继续满足KKT条件, 达到预测精度要求.

定义训练样本 x_i 的边界函数为

$$h(x_i) = \sum_{j=1}^l Q_{ij} \theta_j + b - y_i, \quad (8)$$

并根据KKT条件可将整个训练样本集划分为3个子集合, 支持向量集合 S 、保留向量集合 R 和错误向量集合 E :

$$\begin{aligned} S &= \{i | (\theta_i \in [0, C] \cap h(x_i) = -\varepsilon) \cup (\theta_i \in [-C, 0] \cap h(x_i) = \varepsilon)\}, \\ R &= \{i | \theta_i = 0 \cap |h(x_i)| \leq \varepsilon\}, \\ E &= \{i | (\theta_i = -C \cap h(x_i) \geq \varepsilon) \cup (\theta_i = C \cap h(x_i) \leq -\varepsilon)\}. \end{aligned}$$

根据预测模型式(7)和边界函数式(8)知, 当新训练样本添加到训练集后, 只需要动态调整训练样本对应的 $\Delta b, \Delta \theta$ 和 Δh 即可实现支持向量回归的在线增量求解, 标准在线支持向量回归算法的更新公式^[10]如下:

$$\begin{bmatrix} \Delta b \\ \Delta \theta_{s_1} \\ \vdots \\ \Delta \theta_{s_{l_s}} \end{bmatrix} = \beta \Delta \theta_c, \quad \begin{bmatrix} \Delta h(x_{n_1}) \\ \Delta h(x_{n_2}) \\ \vdots \\ \Delta h(x_{n_{l_n}}) \end{bmatrix} = \gamma \Delta \theta_c, \quad (9)$$

其中:

$$\beta = \begin{bmatrix} 0 & 1 & \cdots & 1 \\ 1 & Q_{s_1 s_1} & \cdots & Q_{s_1 s_{l_s}} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & Q_{s_{l_s} s_1} & \cdots & Q_{s_{l_s} s_{l_s}} \end{bmatrix}^{-1} \begin{bmatrix} 1 \\ Q_{s_1 c} \\ \vdots \\ Q_{s_{l_s} c} \end{bmatrix}, \quad (10)$$

$$\gamma = \begin{bmatrix} \Delta Q_{n_1 c} \\ \Delta Q_{n_2 c} \\ \vdots \\ \Delta Q_{n_{l_n} c} \end{bmatrix} + \begin{bmatrix} 1 & Q_{n_1 s_1} & \cdots & 1 \\ 1 & Q_{n_2 s_1} & \cdots & Q_{s_1 s_{l_s}} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & Q_{n_{l_n} s_1} & \cdots & Q_{s_{l_n} s_{l_s}} \end{bmatrix}, \quad (11)$$

$$S_r = \{s_1, s_2, \dots, s_{l_s}\},$$

$$N_r = E \cup R = \{n_1, n_2, \dots, n_{l_n}\}.$$

2.3 混合核函数分析与设计(Analysis and design of the mixture kernel function)

精矿品位预测模型(1)通过支持向量回归预测求解得到的具体模型如式(7)所示, 其中 $Q_{ij} = K(x_i, x_j)$ 为核函数, 是实现将各工序关键指标组成的输入空间 X 中的非线性预测问题转化为特征空间 F 中的内积运算的关键.

现有支持向量模型使用的经典核函数往往各自具有不同的特性, 如以式(12)为代表的核函数有良好的局部特性, 如图1中示意了当前输入附近点在不同宽度参数 p 下得到的核函数值, 可以发现相距输入点较

远的点核函数值接近为零,即只有相邻样本数据才对核函数值产生较大影响,其学习能力强。

$$K_{\text{RBF}}(x_i, x) = \exp\left(-\frac{\|x - x_i\|^2}{2p^2}\right). \quad (12)$$

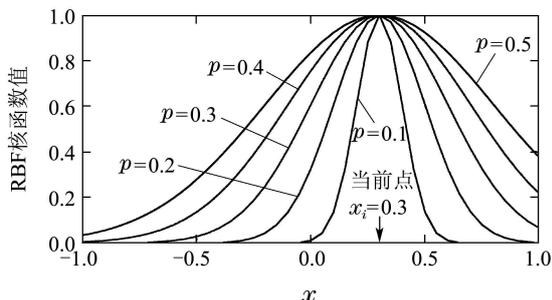


图1 经典局部核(RBF)示意图

Fig. 1 Example of a classic local kernel (RBF)

以多项式核(13)为代表的核函数则具有良好的全局特性,如图2中示意了当前输入附近点在不同多项式阶数 q 下得到的核函数值,可以发现在不同多项式阶数下,当前输入域内所有的点都有非零的核函数值,而且相距输入点较远的样本数据对核函数值产生较大影响,其泛化性能突出。

$$K_{\text{Poly}}(x_i, x) = [x \cdot x_i + 1]^q. \quad (13)$$

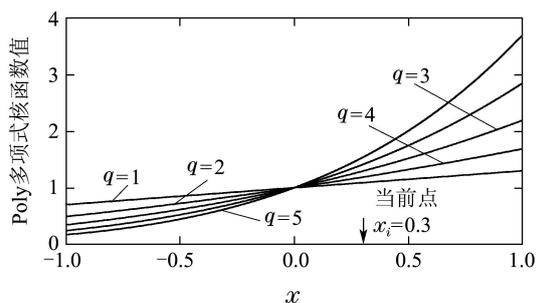


图2 经典全局核(Poly)示意图

Fig. 2 Example of a classic global kernel (Poly)

通过构造混合核函数可以有效的结合两者的优点^[18]. 本文使用上述经典核函数通过线性组合构造混合核函数,仍然满足容许核条件

$$K(x_i, x) = \rho K_{\text{RBF}} + (1 - \rho) K_{\text{Poly}}. \quad (14)$$

通过调整权重系数 ρ 可以平衡混合核函数的局部特性与全局特性. 在混合核函数中,图3示意了不同权重 ρ 下混合核的全局和局部特性,其中RBF核参数 p 和多项式阶数 q 分别取值0.1和1. 由图3可见,当 $\rho=0.1$ 时,局部RBF径向基核起主要作用,随着 ρ 值增加,混合核的全局特性也逐渐增加,在 $\rho=0.5$ 附近不仅具有一定的局部特性,而且兼顾全局特性,而当 $\rho=0.9$ 时,全局多项式核起主要作用. 通过此分析,对于混合权重 ρ 默认取值0.5可以同时兼顾学习能力与泛化能力。

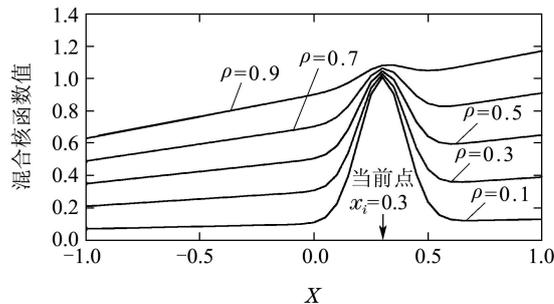


图3 混合核函数不同权重示意图

Fig. 3 Mixed kernel (RBF + Poly)

2.4 参数自适应更新(Adaptive update parameters)

由预测模型显示表达式(7)和增量计算式(9)知,参数 C, ϵ 是另外两个影响支持向量预测模型性能的关键参数. ϵ 代表预测精度, C 代表超出误差样本的惩罚程度. 现有的选择最佳参数的算法大多需要求解另一个参数优化子模型^[12-14,16],从计算量和参数更新周期角度而言,不适合应用到在线支持向量回归预测问题中. 文献[16]提出基于样本统计特性分析的通过样本直接确定支持向量回归模型参数,用于批量训练模型效果良好,其计算量明显比建立一个参数优化子模型来求解最优参数低,并且随着样本增加计算量为线性增加,适合精矿品位预测模型的在线迭代更新. 但对输入样本噪声估计原文并没有提出具体方案,本文使用品位均方差代替噪声估计计算更加清晰直观. 这样当新工况样本添加到训练集后,使用新训练集的统计特性动态更新模型参数,公式如下:

$$C = \max(|\bar{y} + 3\sigma_y|, |\bar{y} - 3\sigma_y|), \quad (15a)$$

$$\text{其中: } \sigma_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2, \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i,$$

$$\epsilon = 3\sigma_y \sqrt{\frac{\ln n}{n}}. \quad (15b)$$

2.5 算法流程(Algorithm pseudo-code)

结合本文构造的混合核函数与模型参数自适应在线更新算法特性,应用支持向量回归在线更新原理^[10-11],得到精矿品位自适应在线支持向量回归预测算法的计算伪代码如下. 假定最新工况下各关键工序指标组成的样本输入为 $x_c = \{x_{c1}, x_{c2}, \dots, x_{c11}\}$,对应实际精矿品位 y_c 添加到预测模型训练集时,则精矿品位预测算法的在线更新过程执行如下步骤:

- 1) 添加新样本 (x_c, y_c) 到预测算法训练集.
- 2) 设置新样本权重 $\theta_c = 0$.
- 3) 预测品位及计算偏差 $f(x_c), h(x_c)$.
- 4) IF $|h(x_c)| < \epsilon$.
添加样本 x_c 到保留向量集合 R ,直接退出.
- 5) 更新品位预测模型参数,式(15a)和(15b).
- 6) 计算现有样本偏差 $h(x_i), i = 1, \dots, l$.

7) WHILE 新样本 x_c 未加入到任何训练集.

7.1) 更新品位模型信息 β, γ , 式(10)和(11).

7.2) 计算新样本 x_c 在对集合移动距离 $\Delta\theta_c \min(L_{c1}, L_{c2}, L_S, L_E, L_R)$, 见文献[10].

7.3) 定义样本移动标志位 $\text{Flag}(L_{c1} = 1, L_{c2} = 2, L_S = 3, L_E = 4, L_R = 5)$.

7.4) 假定找到样本 x_l 对新样本 θ_c 影响最直接.

7.5) 更新模型 θ_c, b 和 $\theta_i \in S_r, h(x_j) \in N_r$, 式(9).

7.6) SWITCH Flag:

Flag = 1: 添加新工况 x_c 到集合 S ; 更新模型信息 R 矩阵; 退出.

Flag = 2: 添加新工况 x_c 到错误向量集合 E ; 退出.

Flag = 3: 如果 $\theta_l = 0$, 移动样本 x_l 到保留向量集合 $S \rightarrow R$, 在模型信息 R 矩阵中移除样本 x_l ; 否则移动样本 x_l 到错误向量集合 $S \rightarrow E$, 在模型信息 R 矩阵中移除 x_l .

Flag = 4: 移动样本 x_l 到支持向量集合 $E \rightarrow S$; 添加样本 x_l 到模型信息 R 矩阵中.

Flag = 5: 移动样本 x_l 到支持向量集合 $R \rightarrow S$; 添加样本 x_l 到模型信息 R 矩阵中.

3 实验验证(Experimental verification)

3.1 性能指标(Performance criteria)

评价回归预测模型性能好坏的指标选择均方误差MSE(16a), 平均绝对误差MAE(16b), 它们用来度量实际值与预测值之间的偏差, 其值越小, 预测值越接近实际值, 表示预测精度高. 最小误差(MinE)和最大误差(MaxE)反应误差波动范围.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (16a)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (16b)$$

3.2 精矿品位预测结果分析(Concentrate grade prediction result analysis)

本文选取某选矿厂生产实际数据为该厂12月份到次年7月份生产数据用来预测精矿品位, 经过采样筛选合格样本170组, 其中训练样本120组, 测试样本50组. 两组数据先进行归一化, 以避免某个属性量纲影响, 之后在进行离线批量和在线增量训练测试模型的预测能力和泛化能力, 并分别对比了文献[17]离线批量训练预测方法(RBF核)、文献[10]标准在线支持向量回归方法(RBF核)和本文提出方法的实验结果. 其中固定参数根据交叉验证获取, 分别为核参数 $p = 0.001, C = 45, \varepsilon = 0.25$, 本文算法参数为根据训练样本统计特性使用式(15a)和(15b)进行自适应更新, 混合核参数为常值 $p = 0.001, q = 1, \rho = 0.5$ 兼顾学

习能力与泛化性能. 各方法预测精矿品位的结果如表1和图4-6所示.

表1 精矿品位各模型评价指标对比

Table 1 Performance criteria of concentrate grade

指标	MSE	MAE	MinE	MaxE
批训练方法 ^[17]	0.072	0.215	0.011	0.752
标准在线方法 ^[10]	0.057	0.171	0.009	0.798
本文方法	0.021	0.114	0.002	0.324

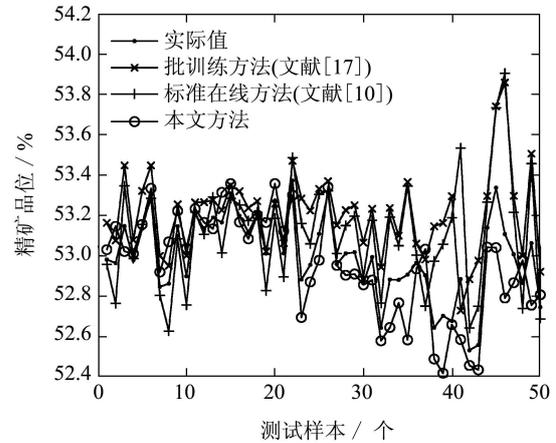


图4 精矿品位实际值与各模型预测值对比

Fig. 4 Real concentrate grade and prediction value obtained by different methods

图5为各算法对应预测误差均值与最大最小误差值盒形图. 由图可见, 本文方法对精矿品位的预测精度有较大提高, 误差范围也更小.

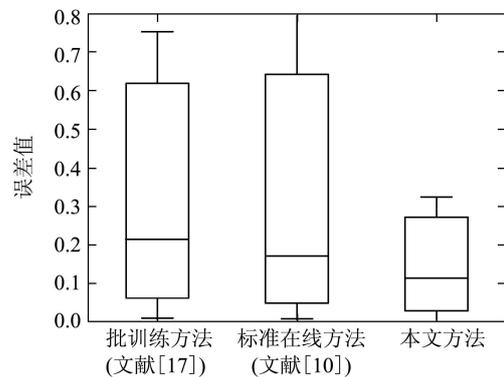


图5 各算法相应的误差盒形图

Fig. 5 Box pot for error by algorithms represented

图6对比了对应3种预测算法的计算时间, 可见批量训练支持向量回归算法因为随着新样本的加入每次都需要对整个训练集进行训练以更新模型, 其计算时间最长且随着样本数量增加时间非线性增长. 标准在线支持向量回归模型和本文模型因为有效利用现有模型信息进行增量训练计算时间明显减少, 且随着样本数量增加时间增加也很缓慢, 该方法有利于在生产实际应用中持续应用.

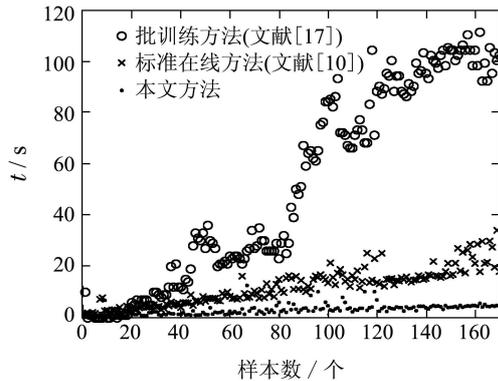


图6 精矿品位模型计算时间对比

Fig. 6 Elapsed time of different methods for concentrate grade prediction

4 结论(Conclusion)

本文提出了一种基于支持向量回归的选矿过程精矿品位的自适应在线预测算法。针对预测模型精度和泛化性难以平衡和动态过程模型适应性有限问题,在分析了核函数特性之后构造了混合核函数,同时给出了一种可行的在线预测模型参数自适应选择方法。某选矿厂生产实际数据的实验证明,本文方法比现有方法在训练时间和预测精度上都有明显优势,适合应用于复杂动态选矿生产过程。

参考文献(References):

- 钱天任, 邝镇国. 选矿生产指标的评价和预测-回归分析法应用[J]. 有色金属, 1979, (2): 7-11.
(QIAN Tianren, KUANG Zhenguo. The evaluation and prediction of production index in mineral processing-regression analysis [J]. *Non-ferrous Metals*, 1979, (2): 7-11.)
- DING J L, CHAI T Y, WANG H. Offline modeling for product quality prediction of mineral processing using modeling error PDF shaping and entropy minimization [J]. *IEEE Transactions on Neural Networks*, 2011, 22(3): 408-419.
- 马恩杰, 白锐. 基于加权支持向量机的选矿生产指标预测模型[J]. 系统仿真学报, 2008, 20(8): 2220-2223.
(MA Enjie, BAI Rui, CHAI Tianyou. Prediction model for production index of mineral process based on weighted support vector machine [J]. *Journal of System Simulation*, 2008, 20(8): 2220-2223.)
- VAPNIK V N. *The Nature of Statistical Learning Theory* [M]. Berlin: Springer-Verlag, 1995: 181-195.
- SMOLA A, SCHÖLKOPF B. A tutorial on support vector regression [J]. *Statistics and Computing*, 2004, 14(3): 199-222.
- 桂卫华, 宋海鹰, 阳春华. Hammerstein-Wiener模型最小二乘向量机辨识及其应用[J]. 控制理论与应用, 2008, 25(3): 393-397.
(GUI Weihua, SONG Haiying, YANG Chunhua. Hammerstein-Wiener model identified by least-squares-support-vector machine and its application [J]. *Control Theory & Applications*, 2008, 25(3): 393-397.)
- 王新华, 桂卫华, 王雅琳, 等. 混合核函数支持向量机的磨矿粒度预测模型[J]. 计算机工程与应用, 2010, 46(12): 207-209.
(WANG Xinhua, GUI Weihua, WANG Yalin, et al. Prediction modeling for particle size of grinding circuit of mixture kernels SVM [J]. *Computer Engineering and Applications*, 2010, 46(12): 207-209.)
- 张淑宁, 王福利, 何大阔, 等. 在线鲁棒最小二乘支持向量机回归建模[J]. 控制理论与应用, 2011, 28(11): 1601-1606.
(ZHANG Shuning, WANG Fuli, HE Dakuo, et al. Modeling method of online robust least-squares-support-vector regression [J]. *Control Theory & Applications*, 2011, 28(11): 1601-1606.)
- CHEN B J, CHANG M W, LIN C J. Load forecasting using support vector machines: a study on EUNITE competition 2001 [J]. *IEEE Transactions on Power Systems*, 2004, 19(4): 1821-1830.
- MA J S, THEILER J, PERKINS S. Accurate on-line support vector regression [J]. *Neural Computation*, 2003, 15(11): 2683-2703.
- PARRELLA F. Online support vector regression [D]. Savona, Italy: Department of Information Science, University of Genoa, 2007.
- SAINI L M, AGGARWAL S K, KUMAR A. Parameter optimization using genetic algorithm for support vector machine-based price-forecasting model in national electricity market [J]. *Generation, Transmission & Distribution, IET*, 2010, 4(1): 36-49.
- MOSER G, SERIPICO S B. Automatic parameter optimization for support vector regression for land and sea surface temperature estimation from remote sensing data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(3): 909-921.
- CAO L J, TAY F E H. Support vector machine with adaptive parameters in financial time series forecasting [J]. *IEEE Transactions on Neural Networks*, 2003, 14(6): 1506-1516.
- OMITAOMU O A, JEONG M K, BADIRU A B. Online support vector regression with varying parameters for time-dependent data [J]. *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, 2011, 41(1): 191-197.
- CHERKASSKY V, MA Y Q. Practical selection of SVM parameters and noise estimation for SVM regression [J]. *Neural Networks*, 2011, 17(1): 113-126.
- CHANG C C, LIN C J. LIBSVM: a library for support vector machines [J]. *ACM Transactions on Intelligent Systems and Technology*, 2011, 2(3): 27:1-27:27.
- SMITS G F, JORDAAN E M. Improved SVM regression using mixtures of kernels [C] // *Proceedings of the 2002 International Joint Conference on Neural Networks*. Piscataway, NJ: IEEE, 2002, 3: 2785-2790.

作者简介:

刘长鑫 (1983-), 男, 讲师, 博士生, 主要研究方向为基于大数据的复杂工业过程建模、优化结构与方法及其应用研究, E-mail: cxliu@mail.neu.edu.cn;

丁进良 (1976-), 男, 副教授, 主要研究方向为全流程序运行优化控制、复杂工业系统建模等, E-mail: jlding@mail.neu.edu.cn;

姜波 (1988-), 男, 硕士, 主要研究方向为复杂生产全流程优化控制方法与软件开发研究, E-mail: bob.jiang@yeah.net;

柴天佑 (1947-), 男, 中国工程院院士, 教授, IEEE Fellow, IFAC Fellow, 欧亚科学院院士, 目前研究方向为自适应控制、多变量智能解耦控制、流程工业过程综合自动化理论、方法与技术, E-mail: tychai@mail.neu.edu.cn.