第 23 卷第 6 期
2006 年 12 月

控 制 理 论 与 应 用
Control Theory & Applications

Vol. 23 No. 6
Dec. 2006

文章编号: 1000−8152(2006)06−0934−07

一种并行协同粒子群优化的支持向量机预测模型

王华秋[1,2], 廖晓峰[1]

(1. 重庆大学 计算机学院, 重庆 400044; 2. 重庆工学院 计算机科学与工程学院, 重庆 400050)

摘要: 转炉提钒过程是一个非常复杂的多元非线性反应过程, 从统计学和反应机理等角度出发, 难以建立终点控制静态模型. 针对这样的问题, 提出了并行协同粒子群优化的支持向量机预测模型, 不仅克服了支持向量机偏差ε和折中参数C选择的随机性, 而且较好地解决了大数据集的快速并行计算, 缩短了计算时间, 从而有利于连续生产操作. 试验表明, 用该模型预测转炉提钒的冷却剂加入量和吹氧时间, 结果的误差减小, 满足了终点命中率在90%以上的指标, 具有工程实用性.

关键词: 并行协同粒子群; 支持向量机; 参数优化; 转炉提钒; 预测模型

中图分类号: TP183　　**文献标识码**: A

Prediction model of support vector machine based on parallel cooperative particle swarm optimization

WANG Hua-qiu[1,2], LIAO Xiao-feng[1]

(1. College of Computer Science, Chongqing University, Chongqing 400044, China;
2. College of Computer Science and Engineering, Chongqing Institute of Technology, Chongqing 400050, China)

Abstract: Converter re-vanadium is a very complex diverse and nonlinear reaction. From the point of view of statistics and reaction mechanism, it is difficult to build an endpoint control static model. Considering this problem, we presented a prediction model using support vector machine (SVM) based on parallel cooperative particle swarm. This model not only perfectly solves the problem of random selection of SVM regression parameter such as ε and C, but also provides rapid calculation for the problem with large data sets and reduces the computing time. Accordingly the model is beneficial to continuous production. The model was used to predict the quantity of refrigerant and time consumption of oxygen in converter re-vanadium, the results of experiments showed that the errors were reduced and the endpoint hitting ratio reached the target for over ninety percent.

Key words: parallel cooperative particle swarm; support vector machine; parameters optimization; converter re-vanadium; prediction model

1 引言(Introduction)

某大型钢铁厂为了优化工艺结构, 降低提钒工序成本, 保证钒渣和半钢质量, 满足当前提钒快节奏生产, 对转炉提钒冷却制度进行了优化, 但是现有的操作工艺几乎完全依赖统计分析结果, 而转炉提钒过程是一个非常复杂的多元非线性反应过程[1], 有很多影响提钒效果的因素, 仅仅依靠数据统计结果难以提高半钢质量; 而从转炉提钒机理出发建立的优化模型, 具有很大的局限性, 很难适应产品种类、原材料来源的变化, 移植和维护都很困难. 转炉提钒处于炼钢过程中的中间环节, 除去铁水的转运时间, 正常操作时间一般不超过10分钟, 因此需要一种快速高效的智能计算方法, 根据提钒前的初始条件以及半钢质量的要求, 估算合适的冷却剂加入量和吹氧时间, 达到终点状态要求.

粒子群优化算法(particle swarm optimization, PSO)已广泛应用于函数优化、神经网络训练、模式分类、模糊系统控制等领域[2~4]. 粒子群在追逐最优粒子过程中, 随着它接近最优粒子, 其速度也越小, 因此粒子群表现出强烈的“趋同性”, 容易陷入局部极小点. 一些PSO算法的改进算法因此提出, 如Shi等提出惯性权重的改进调整[5]和模糊自适应PSO[6]算法, 吕振肃等提出的自适应变异PSO算法[7], Yasuda等提出自适应粒子群算法[8].

收稿日期: 2005−01−20; 收修改稿日期: 2006−01−04.
基金项目: 国家自然科学基金资助项(60271019); 重庆市教委基础研究项目(KJ060614); 重庆市科委攻关项目(20020828).

支持向量机(support vector machine, SVM)可以基于有限样本训练就能获得良好的泛化能力, 并且是一个通用的学习机, 广泛用于模式识别、回归估计等越来越多的领域. 基于大规模数据的SVM比较成熟的训练算法如T. Joachims的SVM-light[9], J. Platt的SMO[10].

用粒子群优化求解支持向量机的算法诸如: U Paquet和AP Engelbrechet采用线性(约束)粒子群算法求解支持向量[11], 其创新之处在于: 1) 对于凸二次优化问题, 提出了基于线性约束的粒子群优化算法, 利用其快速寻优能力代替分解算法的数值迭代计算; 2) 针对分解算法的要求, 对于粒子群初始化时采用了约束方程(文献[11]中的式(13))对粒子群进行线性约束; 3) 在利用线性约束的粒子群算法求解工作集α_β时, 将其转换为求解对偶问题目标函数(文献[11]中的式(3))下降速度最快的方向d, 这些d的非零向量分量的下标即组成工作集α_β, 当然在求解过程中同样要考虑约束条件(文献[11]中的式(4)(5)). 文献[11]提出的算法考虑了粒子群算法的线性约束, 但没有考虑粒子群寻优过程中参数的变化对收敛的影响, 也没有采用并行寻优的方法, 而且是用来求解支持向量的工作集α_β, 而不是用来优化SVM的一些重要参数以提高SVM的计算性能.

支持向量机的参数优化算法很多. 例如: Olivier Chapelle和Vladimir Vapnik研究了SVM算法依赖的几个参数, C是其中之一, 它是控制边缘最大和误差最小的折衷系数, 另外几个参数出现在非线性映射到特征空间的过程中, 通称为核参数. 他们用最速梯度下降法微调上述几个参数, 直到达到他们所定义的几种结构化风险最小[12]. 王志明等则在此基础上采用交叉校验和梯度下降优化SVM的学习参数, 改善系统辨识性能, 采用了均方误差、平均绝对增幅误差和线性相关系数作为性能评价指标[13]. 文献[12,13]之间的区别在于性能评价指标不同. 朱家元等提出了最小二乘支持向量机折衷系数和核参数优化方法—-多层动态自适应优化算法[14], 采用学习样本进行学习, 输出学习误差, 其学习误差测度采用期望输出和辨识输出的平均绝对增幅误差为性能指标, 取最小误差对应的节点值为最优参数对, 如果学习的精度没有达到所需要的要求, 则以最优参数对为中心, 以其值的一定倍数向扩展网格宽度, 构建新二维网络平面, 选取数值相近的参数值进一步学习, 从而获得更高精度的学习结果. Frauke Friedrichs和Christian Igel提出了用串行的进化策略(ES)去决定核空间的参数和控制参数正则化, 通过进化计算编码后的核参数, 个体的适应度函数等于在个体所在的搜索空间的目标函数值[15].

以上可以看出支持向量机的参数优化算法基本上都是对折衷参数和核参数进行优化, 确实提高了SVM的计算精度, 却很少同时涉及选择一个有效的偏差系数ε以及折衷参数C, 只有同时调整二者, 才能取得良好的效果[16]. 而且, 上述算法没有考虑优化计算的额外开销可能增加系统的负担, 造成计算速度下降, 如果是在线系统辨识时算法的实用性会受到影响.

本文提出协同粒子群算法, 要求粒子群之间相互协同, 避免陷入局部极值. 协同粒子群算法用于优化SVM的偏差ε以及折衷参数C, 考虑到粒子群适应值的每次求解都要经历支持向量机的二次优化过程, 因此只有利用粒子群的并行计算才能完成大规模数据的快速预测, 粒子群的追踪过程在各个相对独立的并行进程内完成, 能保证各个种群的多样性和快速性.

本文将并行协同粒子群优化的支持向量机用于建立转炉提钒预测模型, 通过现场扩大性试验, 输出结果达到终点命中率要求, 证明了算法的有效性, 可以指导生产实践.

2 协同粒子群算法(Cooperative PSO algorithm)

粒子通过跟踪两个“极值”来更新自己, 算法结构简单, 运行速度快. 但是, 基本粒子群优化算法在解空间内搜索时, 有时会出现粒子在最优解附近“振荡”的现象, 而且这个最优解可能就是局部最优. 文献[8]通过严格的数学推导, 得出如下结论. 粒子群的速度按如下公式计算:

$$\begin{cases} v_i^{k+1} = w_i \cdot v_i^k + 2(1-k_{2i}) \cdot \phi \cdot \mathrm{rand}(\cdot) \cdot (p_i\mathrm{Best}_i - \\ \qquad x_i^k) + 2k_{2i} \cdot \phi \cdot \mathrm{rand}(\cdot) \cdot (g\mathrm{Best} - p_i\mathrm{Best}_i), \\ x_i^{k+1} = x_i^k + v_i^{k+1}. \end{cases} \tag{1}$$

其中$\phi = w_i + 1 - 2\sqrt{w_i} + 4k_{1i}\sqrt{w_i}k_{2i}$.

参数对群体收敛性的影响是: 如果$0 \leqslant w_i < 1$, 群体的收敛性随着w_i变小而加强; 如果$0 < k_{1i} < 1$, 收敛性随着k_{1i}变大而发散; 如果$0 < k_{2i} < 1, k_{2i} \to 0$时群体将收敛于局部最优, $k_{2i} \to 1$时群体将收敛于全局最优. 但是文献[8]并没有给出这几个参数的选择方法. 为此本文将根据各个参数的作用不同设计了w_i, k_{1i}, k_{2i}: w_i度量靠近局部最优解的程度, k_{2i}度量靠近全局最优解的程度, k_{1i}的影响程度较低, 因此度量迭代次数的增加对它的影响.

在算法运行初期, 因粒子之间的差异较大, 局部极值p_iBest和个体x_i之差一般比较大, 惯性因子w_i接近于1,同理全部极值gBest和局部极值p_iBest之差一般比较大, k_{2i}接近于0, k_{1i}的值设计得较大.

粒子在位置更新与速度更新的过程中, 如果发现新位置优于个体极值, 则将个体极值设置为新位置; 同样, 如果新位置优于全局极值, 则将全局极值设置为新位置gBest. 粒子群在式(1)的作用下向gBest靠拢, 其间将不断更新个体极值. 对于粒子群中的任意粒子, 其最终收敛位置将是整个粒子群找到的全局极值, k_{1i}随着迭代次数n的增加以指数下降.

当算法接近收敛时, 局部极值和全局极值的差距逐渐减小并趋向于0, 惯性因子w_i自动调整逐渐接近0, k_{2i}逐渐接近1. 根据以上分析, 设计如下参数:

$$\begin{cases} w_1 = 1 - \exp(-\dfrac{\|p_i\text{Best} - x_i\|^2}{2}), \\ k_{1i} = k_0 \exp(-\dfrac{i}{\tau_0}), \\ k_{1i} = \exp(-\dfrac{\|p_i\text{Best} - g\text{Best}\|^2}{2}). \end{cases} \tag{2}$$

3 并行协同粒子群优化的支持向量机(SVM based on parallel cooperative PSO)

支持向量机采用经验风险极小化方法解决非线性回归问题, 其核心就是求解支持向量的值, 因此支持向量机的偏差ε以及折中参数C对于损失函数和支持向量个数至关重要. 通常这些参数是凭经验来决定取何值, 如果选择不当, 就会使得输入数据和训练样本之间有很小的畸变, 得不到正确的结果.

针对这个问题, 利用协同粒子群优化算法具有全局快速寻优的特点, 弥补偏差ε以及折中参数C的随机性, 以确定最佳值. 由于群体每次寻优过程都要经历耗时的二次优化计算, 从而计算效率不高, 为此本文将上述协同粒子群算法并行化, 粒子群的追踪过程是在各个相对独立的并行进程内完成的, 根据粒子群不同的运动方式得到不同的参数w_i, k_{1i}, k_{2i}, 这样既提高了加速比又在各个进程保证了种群的多样性, 不易陷入局部极小.

因此支持向量机预测模型的主要步骤是: 选择适当ε和C, 求解最优化问题, 用其解构造决策函数.

1) 初始化粒子群参数w_i, k_{1i}, k_{2i}. 初始化粒子群: 由于采用并行计算, 故每个进程都分配一群粒子, 第j次优化粒子群的结构是: $X_j = (x_{1j}, \cdots, x_{pj})^{\mathrm{T}}$, 其中$p$是进程数, j是优化次数; $X_{ij} = (x_{ij1}, \cdots, x_{ijk})^{\mathrm{T}}$, x_{ijk}代表第i进程第j次优化的第k个粒子, 它是二维变量, 分别代表ε和C.

2) 读取训练集$T = \{(x_1, y_1), \cdots, (x_k, y_k)\} \in (X, Y)^k$, 其中$x_i \in X = \mathbb{R}^n, y_i \in Y = \mathbb{R}^n, i = 1, \cdots, k$. 选择适当的核$K(x, x') = \exp(-\|x - x'\|^2/\sigma^2)$, 用核主分量分析法KPCA进行数据预处理: 对于给定的训练样本$\{x_i\}_{i=1}^k$, 计算$k \times k$核矩阵$K = \{K(x_i, x_j)\}$, 其中$K(x_i, x_j) = \varphi^{\mathrm{T}}(x_i)\varphi(x_j)$, 计算特征值$K\alpha = \lambda\alpha$, 其中$\lambda$为$K$的特征值, α为对应的特征向量. 归一化计算的特征值$\alpha_k^{\mathrm{T}}\alpha_k = \dfrac{1}{\lambda_k}$, $k = 1, 2, \cdots, p$, 其中λ_p是矩阵K最小的非零特征值. 为了抽取测试点的主分量, 计算投影

$$\alpha_k = q_k^{\mathrm{T}}\varphi(x) = \sum_{i=1}^{k} \alpha_{k,j} K(x_j, x),\ k = 1, 2, \cdots, p.$$

其中$\alpha_{k,j}$是特征向量α_k的第j个元素.

3) 构造并求解最优化问题

$$\min_{\alpha^{(*)} \in \mathbb{R}^{2k}} \frac{1}{2} \sum_{i,j=1}^{k} (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) K(x_i, x_j) + \varepsilon \sum_{i=1}^{k} (\alpha_i^* + \alpha_i) - \sum_{i,j=1}^{k} y_i(\alpha_i^* - \alpha_i)$$

$$\text{s.t.} \sum_{i=1}^{k} (\alpha_i^* - \alpha_i) = 0,\ 0 \leqslant \alpha_i^*,\ \alpha_i \leqslant \frac{C}{k},\ i = 1, \cdots, k,$$

得最优解$\bar{\alpha} = (\bar{\alpha}_1, \bar{\alpha}_1^*, \cdots, \bar{\alpha}_k, \bar{\alpha}_k^*)^{\mathrm{T}}$. 其中$K(x, x_i) = \varphi^{\mathrm{T}}(x_i)\varphi(x)$.

4) 构造决策函数

$$f(x) = \sum_{i=1}^{k} (\bar{\alpha}_1^* - \bar{\alpha}_1) K(x_i, x) + \bar{b} = w^{\mathrm{T}} x + \bar{b}.$$

其中: $w = \sum_{i=1}^{N} (\alpha_1 - \alpha_1')\varphi(x_i)$, $\bar{b}$按下列方式计算: 选择位于开区间$(0, \dfrac{C}{k})$中的$\bar{\alpha}_i$或$\bar{\alpha}_i^*$, 若选到的是$\bar{\alpha}_i$, 则$\bar{b} = y_i - \sum_{i=1}^{k} (\bar{\alpha}_1^* - \bar{\alpha}_1)(x_i \cdot x_j) + \varepsilon$; 若选到的是$\bar{\alpha}_i^*$, 则$\bar{b} = y_i - \sum_{i=1}^{k} (\bar{\alpha}_1^* - \bar{\alpha}_1)(x_i \cdot x_j) - \varepsilon$.

5) 结合文献[12]提出的关于SVM参数调整的径向边缘约束准则, 定义粒子群的适应度函数为

$$\text{fitness} = (R^2 + 1/C)(\|w\|^2 + 2C \sum_{i=1}^{k} \xi_i).$$

其中: ξ_i是松弛变量, 用于度量一个数据点对模式可分的理想条件的偏离程度, $\xi_i = 1 - y_i(\sum_{j=1}^{k} \bar{\alpha}_j^* y_j K(x_j, x_i) + \bar{b})$, R是包含所有$\varphi(x_i)$的最小球面, 计算R是一个二次优化问题, 故用最小球面的半径代替, $R^2 = \max_{1 \leqslant i \leqslant k}(K(x_i, x_j))$. 最小化适应度函数就可评价并行协同粒子群参数优化是否收敛, 若适应度超过允许值, 则继续循环计算; 否则退出.

6) 各个进程的局部粒子群优选如下:

$$p_{ij}\text{Best} = (\max\{f_{ij1}, f_{ij2}, \cdots, f_{ij40}\})^{-1},$$

并汇集到主进程, 然后主进程全局粒子群优选如下:

$$g_j\text{Best} = \left(\max \begin{bmatrix} f_{1j1} & f_{1j2} & \cdots & f_{1j40} \\ & & \vdots & \\ f_{ij1} & f_{ij2} & \cdots & f_{ij40} \end{bmatrix}\right)^{-1},$$

其中$(\cdot)^{-1}$表示由适应值反向找到对应的中心数, 主进程最后判断训练次数是否达到最大值或适应值达到要求, 并决定是否进入下一步.

7) 接收本次循环得全局最优解g_jBest, 利用式(1)更新粒子速度和位置.

8) 利用式(2)修正参数w_i, k_{1i}, k_{2i}, 返回到本进程的第3步.

由上述分析设计得到优化算法流程如图1所示.

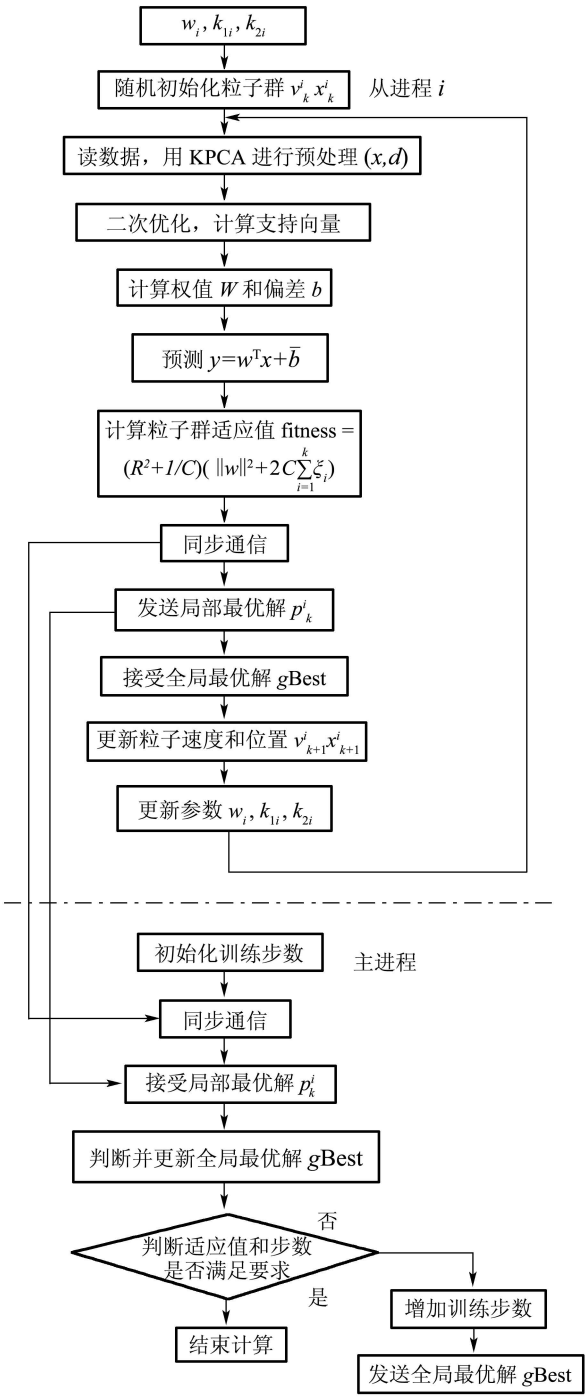

图 1 优化算法程序流程

Fig. 1 Flow chart for optimized algorithm program

4 计算复杂度分析(Computing complexity analysis)

为了分析算法的计算复杂度和收敛性, 本文通过分析并行算法每一步找到并行进程所需的计算时间, 由于MPI的发送和接收就是文件的读写, 因此文件I/O读写时间被考虑在内.

设: n为粒子群数, d为粒子群维度, P为节点数, T_{FW}为发送文件时间, T_{FR}为读取文件时间, T_{A}为算法计算操作时间, 主进程的计算时间忽略不计, δ为算法循环数, T_{s}为阻塞同步通信时间.

基于Master-Slaver结构的并行协同粒子群SVM算法计算时间可以被描述如下: 主进程所用时间为$(P-1)[T_{\mathrm{FR}}+T_{\mathrm{FW}}+T_{\mathrm{S}}]$, 从进程所用时间为$2T_{\mathrm{FR}}+T_{\mathrm{FW}}+TS+ndT_{\mathrm{A}}/P$, 则总时间为$(ndT_{\mathrm{A}}/P+PT_{\mathrm{FW}}+(P+1)T_{\mathrm{FR}}+PT_{\mathrm{S}})\delta$.

只要合理将训练和测试数据集分配到各个进程, 使得每个进程的负载大致平衡, 阻塞同步时间T_S就小, 就可以减小同步通信量和读写时间, 这时, $ndT_{\mathrm{A}}/P \gg PT_{\mathrm{FW}}+(P+1)T_{\mathrm{FR}}$, 总时间近似于$ndT_{\mathrm{A}}/P$, 只有串行计算的$1/P$.

5 并行计算实验(Parallel computing experiments)

5.1 建立实验环境(Building up experimental environment)

用1～7台联想奔月2000 1G作为Slaver, 1台DELL Server作为Master, 整个网络用以太网交换机连接, 计算机间除了用网络联接外, 其他全部独立. 编程语言采用Visual C＋＋6.0. 消息传递库为标准MPI, 版本为mpich2. SVM算法采用LibSVM-26程序, 结合并行协同粒子群优化算法, 形成并行优化SVM算法. 然后设计主从模式的MPI程序, 算法采用先局部后全局的思想, 其计算过程特征可以描述如下:

第1步 数据划分. Master主进程采用随机抽样的方法向Slaver从进程广播数据, 为每个Slaver从进程划分数据;

第2步 任意从进程i第j次在本地数据上各自独立地利用协同粒子群算法优化计算SVM算法得到p_{ij}Best即局部最佳中心数.

第3步 从进程用MPI_Send或者MPI_Bcast与主进程交换计算所得的局部最优解p_{ij}Best, 使得主进程都拥有每个从进程的p_{ij}Best.

第4步 Master主进程将收集的来自Slaver从进程的p_{ij}Best, 并检查是否达到最优适应值, 若达到则得到全局最优解g_jBest, 停止搜索, 若否, 则继续直到达到最优适应值.

5.2 评价并行算法性能(Evaluating the performance of parallel algorithm)

本文采用的并行加速比计算式为$S = \dfrac{P}{1+(T_{\rm FR}+T_{\rm FW})/T_{\rm A}}$, 并行效率为$E = \dfrac{S}{P}$, 将结点数由2增加到8, 运行并行协同粒子群SVM算法, 并记录其性能, 分析结果如表1所示

随着节点的增多, 计算时间缩短, 通信时间增加, 但总的执行时间降低, 因此并行算法加速比在增加, 算法具备一定的可伸缩性, 但是效率下降, 说明并行机群之间的读写时间占总执行时间的比例在增加, 还可以在数据通信的方式上做改进, 比如在任务分配时可以考虑各个节点计算机的CPU资源, 内存资源, 当前进程数, 响应时间等信息作为负荷均衡的依据, 合理分配负荷, 提高计算效率.

表 1 并行算法性能分析

Table 1 Parallel algorithm performance analysis

	P=2	P=4	P=6	P=8
通信时间/s	2.74	5.84	8.39	11.76
计算时间/s	64.15	43.02	31.23	24.56
总时间/s	66.83	48.93	39.61	36.36
加速比	1.91	3.52	4.72	5.41
效率	0.95	0.88	0.78	0.67

6 转提钒预测模型(Prediction model for converter re-vanadium)

考虑到影响转炉提钒的几个因素之间存在严重的非线性关系, 为了克服以往方法实用性较差的困难, 采用并行智能计算方法来构建提钒非线性模型. 由于影响转炉提钒的因素较多, 因此需要对转炉提钒过程的一些变化不大且易于实现的因素进行量化和固化, 忽略一些影响因素较小的因素. 由于铁水中的Si,Mn,Ti,P等元素含量少, 提钒过程中主要耗氧元素是C和V, 因此确定模型的输入为：TSC (铁水碳), TSSI (铁水硅), TSV (铁水钒), TSWD (铁水温度), HJTSZL (铁水重量), BGWD (半钢温度), BGV (半钢钒), BGC (半钢碳);目标输出为: SJ_CYSJ (吹氧时间)和SJ_LQJ (冷却剂量).

首先要建立训练和测试数据集, 考虑到冷却剂的种类对提钒效果的影响, 选择某大型钢铁公司的时间在2003年1月到2003年6月的数据建立模型训练需要的数据集, 这期间使用的是复合球团冷却剂, 选择这期间铁水温度T在1207°C～1314°C、铁水碳C在3.8%～4.9%、铁水钒V在0.222%～0.366%、铁水硅Si在0.06%～0.28%的数据, 为了获得高加速比, 最终获得8300多条样本, 用其中的8260多条作训练集, 其余30条作测试集, 数据被分配到8结点上, 用Z-Score标准化方法将它们转化为无量纲0和1之间的数据.

实验是基于两种模型方法的比较: 并行优化SVM和标准SVM. 为便于比较, 30组数据分别采用并行优化SVM和标准SVM算法计算, 之后每个时刻比较分析值与模型输出值之差. 两种算法的输出和实际值对比如图2, 3所示(其中虚线为预测输出, 实线为实际值).

图2,3显示了并行优化SVM模型预测结果最大相对误差低于标准SVM模型10%～20%, 其相对误差平均在10%以内, 即命中率在90%以上. 标准SVM对于“干净”的训练数据预测性能较好, 但是对于不经常出现的数据处理起来却很差. 而并行优化SVM模型由于得到了适合样本数据的参数, 因此对于全部范围的数据几乎都能良好地逼近.

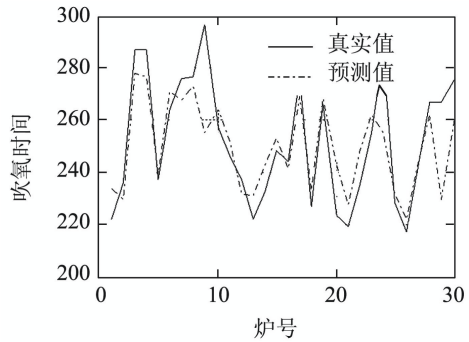

(a) 吹氧时间预测

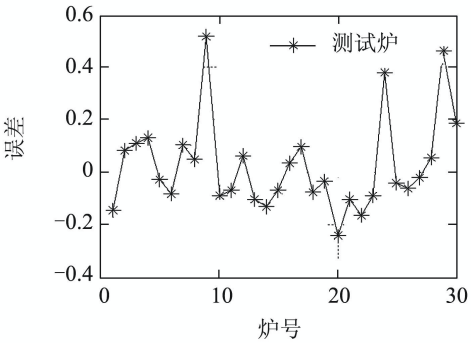

(b) 相对误差

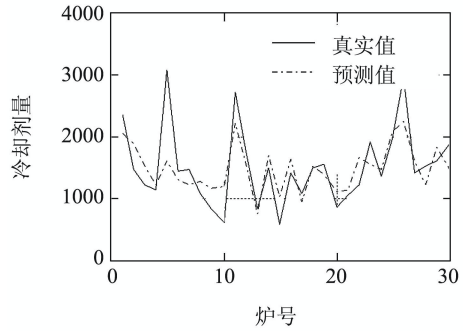

(c) 冷却剂量预测

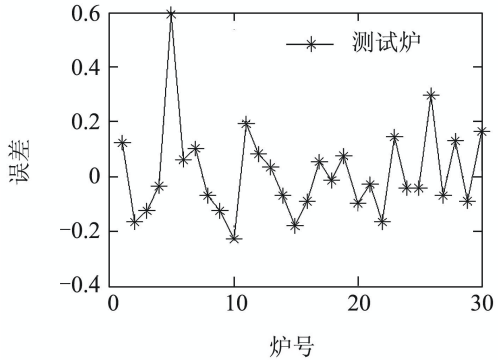

(d) 相对误差

图 2 标准SVM模型预测输出及误差

Fig. 2 Outputs and errors of standard SVM

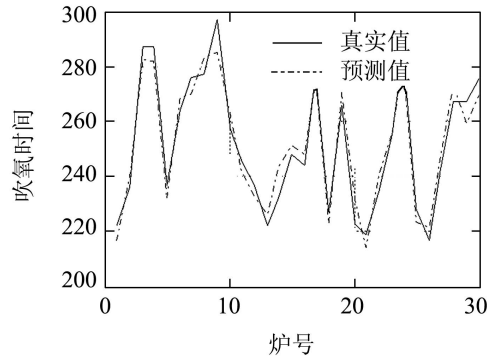

(a) 吹氧时间预测

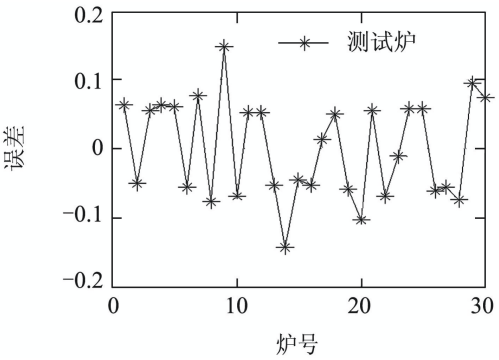

(b) 相对误差

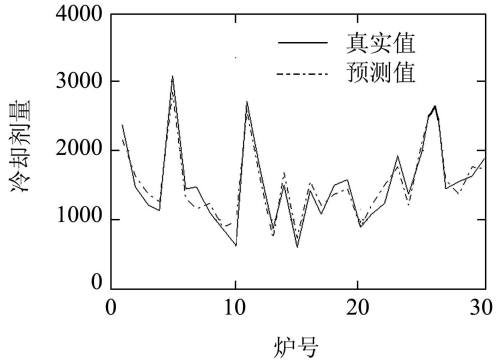

(c) 冷却剂量预测

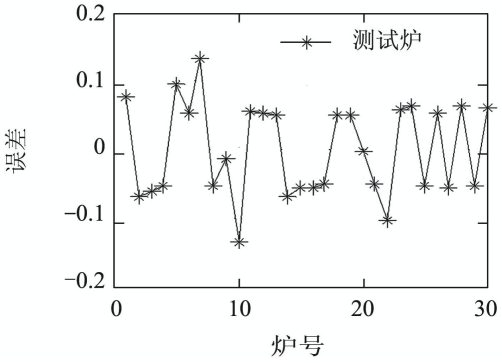

(d) 相对误差

图 3 并行优化SVM模型预测输出及误差

Fig. 3 Outputs and errors of parallel optimized SVM

除了预测精度外, 还比较了算法计算所需的时间和SVM参数, 比较结果如表2所示.

表 2 计算结果比较

Table 2 Comparision with computing results

		吹氧时间	冷却剂量
标准SVM	计算时间/ s	7.8	10.6
	平均误差/ %	15.8	12.6
	ε	0.01	0.01
	C	10	10
并行优化SVM	计算时间/ s	8.2	11.3
	平均误差/ %	6.25	9.07
	ε	0.0062	0.0075
	C	12.42	18.19

虽然SVM参数的优化增加了算法的计算时间, 但是这种粒子群优化SVM算法的并行执行方式有效地避免了预测计算的时间增加过大, 使得循环执行的优化操作在机群中并行进行, 仅仅增加了不到1 s的计算时间, 相反明显提高了预测的精度, 特别是吹氧时间, 提高了约7%.

从上述测试结果及其分析中可以得出, 并行优化SVM算法执行的预测性能高于标准SVM. 预测结果满足要求, 符合转炉提钒实际生产对于实时性和准确性的要求.

7 结论(Conclusion)

针对粒子群算法可能出现的停滞现象, 以及支持向量机参数优化对于大数据集计算时求取速度较慢的缺点, 本文提出了一种并行协同粒子群SVM参数优化算法, 引入了协同机制和并行计算方法. 理论和实践证明, 并行协同粒子群优化的支持向量机模型可以对提钒过程进行及时识别和预测, 对钢铁提钒处理生产过程具有指导作用. 应当指出, 在粒子群参数选择、并行任务分解这几个方面的处理还有不完善之处, 还需要有的改进, 以得到算法全局最优解的概率和并行机群的负载平衡能力.

参考文献(References):

[1] 黄道鑫. 提钒炼钢[M]. 北京: 冶金工业出版社, 2000: 21 – 34.
(HUANG Daoxin. *Converter Re-vanadium and Steel-Making*[M]. Beijing: Metallurgical Industry Press, 2000: 21 – 34.)

[2] ZHANG C, SHAO H, LI Y. Particle swarm optimization for evolving artificial network[C] // *Proc of IEEE Int Conf on System, Man, Cybernetics*. Piscataway: IEEE Service Center, 2000: 2487 – 2490.

[3] MENDES F, CORTEZ P, ROCHA M, et al. Particle swarms for feedforward neural network training[C] // *Proc of Int Joint Conf on Neural Networks*. Honolulu: IEEE Computer Society, 2002: 1895 – 1899.

[4] JUANG Chiafeng. A hybrid of genetic algorithm and particle swarm optimization for recurrent network design[J]. *IEEE Trans on Systems, Man and Cybernetics-Part B: Cybernetics*, 2004, 34(2): 997 – 1006.

[5] SHI Y, EBERHART R. A modified particle swarm optimizer[C]//*Proc IEEE Int Conf on Evolutionary Computation*. Anchorage: IEEE Press, 1998: 69 – 73.

[6] SHI Y, EBERHART R. Fuzzy adaptive particle swarm optimization[C]// *Proc of IEEE Conf on Evolutionary Computation*. Piscataway: IEEE Service Center, 2001: 101 – 106.

[7] 吕振肃, 侯志荣. 自适应变异的粒子群优化算法[J]. 电子学报, 2004, 32(3): 416 – 420.
(LU Zhensu, HOU Zhirong. Particle swarm optimization with adaptive mutation[J]. *Acta Electronica Sinica*, 2004, 32(3): 416 – 420.)

[8] IDE Y K, IWASAKI A N. Adaptive particle swarm optimization[C] // *IEEE Int Conf on Systems, Man and Cybernetics*. Indianapolis: IEEE Press, 2003: 1554 – 1559.

[9] JOACHIMES T. Making large-scale SVM learning practical[M] // *Advances in Kernel Methods-Support Vector Learning*. MA: MIT Press, 1999: 168 – 184.

[10] PLATT J C. Fast training of support vector machines using sequential minimal optimization[M]// *Advances in Kernel Methods-Support Vector Learning*. MA: MIT Press, 1999: 185 – 208.

[11] PAQUET U, ENGELBRECHT A P. Training support vector machines with particle swarms[C]// *Proc of the Int Joint Conf on Neural Networks*. Portland: IEEE World Congress on Computational Intelligence, 2003: 1593 – 1598.

[12] CHAPELLE O, VAPNIK V, BOUSQUET O, et al. Choosing multiple parameters for support vector machines[J]. *Machine Learning*, 2002, 46(1-3): 131 – 159.

[13] 王志明, 蔡莲红, 艾海舟. 基于支持向量机回归的唇动参数预测[J]. 计算机研究与发展, 2003, 40(11): 1561 – 1565.
(WANG Zhiming, CAI Lianhong, AI Haizhou. Mouth movement prediction based on support vector regression[J]. *J of Computer Research and Development*, 2003, 40(11): 1561 – 1565.)

[14] 朱家元, 杨云, 张恒喜, 等. 支持向量机的多层动态自适应参数优化[J]. 控制与决策, 2004, 19(2): 223 – 229.
(ZHU Jiayuan, YANG Yun, ZHANG Hengxi, et al. Multi-layer adaptive parameters optimization approach for support vector machines[J]. *Control and Decision*, 2004, 19(2): 223 – 229.)

[15] FRIEDROCJS F, IGEL C. Evolutionary tuning of multiple SVM parameters[C]// *Proc of the 12th European Symposium on Artificial Neural Networks*. Bruges: European Symposium on Artificial Neural Networks(ESANN), 2004: 519 – 524.

[16] HAYKIN S. *Neual Network-A Comprehensive Foundation*[M]. Second Edition. Beijing : Tsinghua University Press, 1999: 340 – 343.

作者简介:

王华秋 (1975—), 男, 博士, 现在重庆大学计算机学院作博士后研究工作, 研究方向为数据挖掘、并行计算、智能计算, E-mail: wanghuaqiu@cqit.edu.cn;

廖晓峰 (1964—) , 男, 教授, 博士生导师, 中国西南地区“信息与系统”专委会委员和美国IEEE协会会员, 从事信息安全和计算智能研究, E-mail: xfliao@cqu.edu.cn