

铁水硅含量的混沌粒子群支持向量机预报方法

唐贤伦, 庄 陵, 胡向东

(重庆邮电大学 网络化控制与智能仪器仪表教育部重点实验室, 重庆 400065)

摘要: 提出一种基于混沌粒子群优化(CPSO)的支持向量回归机(SVR)参数优化算法, 并使用该算法建立高炉铁水硅含量预测模型(CPSO-SVR), 对某大型钢铁厂高炉铁水硅含量的实际采集数据进行预测, 结果表明基于混沌粒子群优化算法寻优的参数建立的铁水硅含量支持向量回归预测模型具有良好的预测效果. 与最小二乘支持向量回归机(LS-SVR)、使用粒子群优化算法训练的神经网络(PSO-NN)进行比较, CPSO-SVR模型对铁水硅含量进行预测时预测绝对误差小于0.03的样本数占总测试样本数的百分比达到90%以上, 预测效果明显优于PSO-NN, 且比LS-SVR稳定性更强, 可用于高炉铁水硅含量的实际预测, 表明混沌粒子群优化算法是选取SVR参数的有效方法.

关键词: 支持向量机; 粒子群优化; 参数优化; 预测; 铁水硅含量

中图分类号: TP27 **文献标识码:** A

The support vector regression based on the chaos particle swarm optimization algorithm for the prediction of silicon content in hot metal

TANG Xian-lun, ZHUANG Ling, HU Xiang-dong

(Key Laboratory of Network Control & Intelligent Instrument, Ministry of Education, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: An optimal selection approach of support vector regression parameters is proposed based on the chaos particle swarm optimization(CPSO) algorithm; A model based on the support vector regression to predict the silicon content in hot metal is established; and the optimal parameters of which is searched by CPSO. The data of the model are also collected from the No.3 BF in Panzhihua Iron and Steel Group Co. The results show that the proposed prediction model has better prediction results than the neural network trained by particle swarm optimization and least squares support vector regression algorithm; the percentage of samples with absolute prediction error less than 0.03 is higher than 90%, when predicting the silicon content by the proposed model. This indicates that the prediction precision can meet the requirement of practical production and demonstrates that the CPSO is an effective approach for parameter optimization of support-vector regression.

Key words: support vector regression; particle swarm optimization; parameters optimization; prediction; silicon content in hot metal

1 引言(Introduction)

铁水硅含量是高炉冶炼过程中评定高炉炉况稳定性和生铁质量的重要指标, 也是表征高炉热状态及其变化的标志之一^[1], 因此准确地预测铁水硅含量有助于控制高炉热状态, 保证高炉稳定运行.

常用的高炉铁水硅含量预测方法有时间序列分析、概率统计等传统方法和以人工神经网络为代表的基于人工智能理论的方法^[2]. 由于高炉冶炼过程是一个高度复杂的非线性过程, 传统方法难以建立有效的数学模型, 致使预测结果精度不高. 基于神经

网络的预测方法, 取得了一些很成功的应用, 但是在训练过程中存在局部极小问题, 且收敛速度比较慢, 网络隐层节点难以确定等问题, 限制了其应用.

统计学习理论是由Vapnik建立的一种专门研究小样本情况下机器学习规律的理论, 支持向量机是在这一理论上发展而来的一种新的通用学习方法^[3,4]. 支持向量机通过结构风险最小化原理来提高泛化能力. 其算法是一个凸二次优化问题, 保证找到的解是全局最优解, 能较好地解决小样本、非线性、高维数等实际问题, 问题的复杂度不取决于

特征的维数, 目前已被广泛应用于模式识别、数据挖掘、遥感图像分析和网络安全等领域. 近年来, 研究者提出了用于求解回归问题的支持向量回归机(SVR) [5~7], 其可以任意精度逼近非线性函数, 具有全局极小值点, 收敛速度快, 已被应用于电力系统短期负荷预测、地下水位预测等领域[8,9]. 与人工神经网络方法相比, SVR不存在容易陷入局部最优等问题, 提高了泛化能力, 因此有较大的优越性[10].

SVR在具体应用中存在一个突出问题, 即如何设置影响算法性能的关键参数, 因为参数的优化选择对回归模型的学习精度和推广能力的好坏起着决定性作用. 目前一般都通过交叉验证试算的方法, 或者梯度下降法确定, 不仅效率较低且稳定性不高. 本文提出混沌粒子群优化算法(CPSO)并用于优化支持向量回归算法(SVR)的参数, 在此基础上建立铁水硅含量粒子群支持向量回归预测模型(CPSO-SVR), 结果表明, 该方法具有良好的预测精度和稳定性.

2 支持向量回归机算法(SVR algorithm)

给定数据样本集合 $\{x_i, y_i\}, i = 1, 2, \dots, l$, 其中 $x_i \in \mathbb{R}^d$ 为输入变量, $y_i \in \mathbb{R}$ 为相应的输出值, l 为训练样本个数, 通过非线性映射 φ , 把数据空间中的输入向量 x_i 映射到特征空间, 然后在特征空间中进行线性回归, 构造出决策函数 $f(x) = \langle w, \phi(x) \rangle + b$.

根据统计学习理论, SVR通过极小化目标函数来确定回归函数, 即求下式的最小值:

$$\begin{aligned} \min & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*), \\ \text{s.t.} & \begin{cases} y_i - \langle w, \varphi(x_i) \rangle - b \leq \varepsilon + \xi_i, \\ \langle w, \varphi(x_i) \rangle + b - y_i \leq \varepsilon + \xi_i^*, \\ \xi_i, \xi_i^* \geq 0, \varepsilon \geq 0, i = 1, 2, \dots, l. \end{cases} \end{aligned}$$

其中 $\langle w, \phi(x_i) \rangle$ 表示内积, C 为一常数, C 表示对超出误差 ε 样本的惩罚程度.

由于特征空间的高维且目标函数不可微, 所以不可能直接求解. 而在高维特征空间中, 线性问题中的内积运算可以用核函数来代替, 所以引入核函数 $K(x_i, x_j) = \langle \Phi(x_i), \Phi(x_j) \rangle$, 利用 Wolfe 对偶将上述问题转换为下面的对偶问题:

$$\begin{aligned} \min & \frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j)k(x_i, x_j) - \\ & \sum_{i=1}^l [\alpha_i^*(y_i - \varepsilon) - \alpha_i(y_i + \varepsilon)], \\ \text{s.t.} & \begin{cases} \sum_{i=1}^l \alpha_i - \alpha_i^* = 0, \\ \alpha_i, \alpha_i^* \in [0, C]. \end{cases} \end{aligned}$$

求得最优解 $\bar{\alpha} = (\bar{\alpha}_1, \bar{\alpha}_2, \dots, \bar{\alpha}_l)^T$ 及 $\bar{\alpha}^* = (\bar{\alpha}_1^*,$

$\bar{\alpha}_2^*, \dots, \bar{\alpha}_l^*)^T$ 后, 可得到回归函数:

$$f(x) = \sum_{i=1}^l (\bar{\alpha}_i - \bar{\alpha}_i^*)K(x, x_i) + b^*.$$

3 基于混沌粒子群优化的SVR预测模型 (Prediction model of SVR based on CPSO)

3.1 混沌粒子群优化算法(Chaos PSO, CPSO)

和其它的随机算法比较, 粒子群优化算法(PSO)能够在较短的时间内求得高质量的解而且具有稳定的收敛特性[11,12], 已经得到了广泛的应用. PSO初始化为一群随机粒子(随机解), 在 D 维搜索空间中, 第 i 个粒子在 D 维空间中的位置表示为 $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$, x_i 在 $[a_i, b_i]$ 范围内取值. 第 i 个粒子经历过的最好位置(有最好适应度)记为 $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$, 每个粒子的飞行速度为 $V_i = (v_{i1}, v_{i2}, \dots, v_{iD}), i = 1, 2, \dots, m$. 在整个群体中, 所有粒子经历过的最好位置为 $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$, 每一代粒子根据下面公式更新自己的速度和位置:

$$v_{id} = \omega v_{id} + c_1 r_1 (p_{id} - x_{id}) + c_2 r_2 (p_{gd} - x_{id}), \quad (1)$$

$$x_{id} = x_{id} + v_{id}. \quad (2)$$

其中: ω 为惯性权重; c_1 和 c_2 为学习因子, 通常, $c_1 = c_2 = 2$; r_1 和 r_2 是 $[0, 1]$ 之间的随机数. 更新过程中, 粒子每一维的位置、速度都被限制在允许范围之内.

PSO虽然简单, 但其有易陷入局部极值点, 进化后期收敛速度慢等缺点. 由于混沌运动具有随机性、遍历性、对初始条件的敏感性等特点[13], 为了提高种群的多样性和粒子搜索的遍历性, 本文在粒子群优化算法中引入混沌思想, 改善了粒子群优化算法摆脱局部极值点的能力, 提高了算法的收敛速度和精度.

如下的 Logistic 方程是一个典型的混沌系统:

$$z_{n+1} = \mu z_n (1 - z_n), n = 0, 1, 2, \dots, \quad (3)$$

式中 μ 为控制参量, 取 $\mu = 4$, 设 $0 \leq z_0 \leq 1$, 系统(3)完全处于混沌状态. 由任意初值 $z_0 \in [0, 1]$, 可迭代出一个确定的时间序列 z_1, z_2, z_3, \dots .

本文将混沌融入粒子群优化算法, 其基本思想体现在两个方面:

1) 混沌初始化粒子的位置, 既不改变粒子群优化算法初始化时所具有的随机性本质, 又利用混沌提高了种群的多样性和粒子搜索的遍历性, 在产生大量初始群体的基础上, 从中择优出初始群体.

2) 以当前整个粒子群迄今为止搜索到的最优位置为基础产生混沌序列, 把产生的混沌序列中的最优位置粒子替代当前粒子群中的一个粒子的位置.

引入混沌序列的搜索算法可在迭代中产生局部最优解的许多邻域点,以此帮助惰性粒子逃离局部极小点,并快速搜寻到最优解。

3.2 基于CPSO算法的SVR预测模型(SVR prediction model based on CPSO)

由于SVR模型本身有2个参数 C 和 ε ,而实验使用径向基核函数作为SVR模型的核函数,RBF核的宽度系数 σ 也需要确定.每个粒子由3维参数 (ε, C, σ) 决定其位置和速度,其中,参数的取值范围为: $\varepsilon = [0, 0.8], C = [1, 10^8], \sigma = [0.01, 2]^{[13]}$.适应度函数取为能直接反映SVR回归性能的均方差(MSE).

基于CPSO算法寻优SVR参数向量 (ε, C, σ) 并建立预测模型的步骤如下:

Step 1 初始化设置粒子群的规模、最大允许迭代次数或适应度误差限、惯性权值、学习因子等参数;初始化各粒子的速度.需注意的是:由于同时优化 ε, C, σ 3个参数且它们的值一般不在同一数量级上,在初始化粒子速度时应乘上相应的系数。

Step 2 混沌初始化粒子位置。

1) 随机产生一个3维每个分量数值在0~1之间的向量, $z_1 = (z_{11}, z_{12}, z_{13})$, 根据式(3), 得到 N 个向量 z_1, z_2, \dots, z_N 即为初始群体。

2) 将 z_i 的各个分量分别载波到 ε, C, σ 参数的取值范围之内。

3) 计算粒子群的适应值,并从 N 个初始群体中选择性能较好的 M 个解作为初始解,随机产生 N 个初始速度。

Step 3 如果粒子适应度优于个体极值 p_i ,将 p_i 置为新位置。

Step 4 粒子适应度优于全局极值 p_g ,将 p_g 置为新位置。

Step 5 根据公式(1)(2)更新粒子的速度和位置。

Step 6 对最优位置进行混沌优化.将 $P_g = (p_{g1}, p_{g2}, p_{g3})$ 映射到Logistic方程(3)的定义域 $[0, 1]$, $z_i = \frac{p_{gi} - a_i}{b_i - a_i}, i = 1, 2, 3$, 然后,用Logistic方程进行迭代产生混沌变量序列 $z_i^{(m)} (m = 1, 2, \dots)$,再把产生的混沌变量序列通过逆映射 $p_{gi}^{(m)} = a_i + (b_i - a_i)z_i^{(m)}$ 返回到原解空间,得:

$$p_g^{(m)} = (p_{g1}^{(m)}, p_{g2}^{(m)}, p_{g3}^{(m)}), m = 1, 2, \dots$$

在原解空间对混沌变量经历的每一个可行解 $p_g^{(m)} (m = 1, 2, \dots)$ 计算其适应值,得到性能最好的可行解 p^* 。

Step 7 用 p^* 取代当前群体中任意一个粒子的位置。

Step 8 若满足停止条件,则停止搜索,全局最优位置即为CPSO-SVR参数向量 (ε, C, σ) ;否则,返回Step 3。

Step 9 基于算法参数 (ε, C, σ) 建立CPSO-SVR铁水硅含量预测模型。

4 硅含量预测实例及结果分析(Example and result analysis)

4.1 数据预处理(Data preparation)

铁水硅含量受很多因素的影响,并且各种因素之间也存在着错综复杂的交互影响,众多影响因素导致高炉炉温变化具有复杂性、非线性、高维数等特点.考虑到实际数据的采集条件及与铁水硅含量之间的相关程度,选取了8个主要因素进行建模:透气性指数、全压差、风压、风量、风温、炉顶煤气温度、喷煤量以及上一炉铁水硅含量[Si]。

由于在高炉上直接采集的数据种类很多,它们的单位和数值各不相同,有的数量级差别较大,需对样本进行规范化处理,考虑到实际数据中铁水硅含量集中在0.1~0.5之间,过于集中,因此输出值也应进行归一化处理.预测模型计算结束后,再做反归一化处理,便得到实际的输出值,即预测值。

4.2 预测结果与分析(Prediction result and analysis)

在炉况基本平稳的情况下,采集高炉大量现场数据进行数据预处理后进行实验.本文以2007年6月1日至6月14日3号高炉铁水硅含量的300个实际数据样本采用CPSO-SVR方法进行训练.为了获得合适的预测模型,本文分别选取多项式核函数、径向基核函数和Sigmoid核函数等常用核函数进行测试,确定使用最适合测试样本集的径向基核函数为SVR模型的核函数,训练后确定最优参数为 $C = 11.9, \varepsilon = 0.7, \sigma^2 = 1.3$.选取前220个数据样本作为训练数据,利用径向基核函数与最优参数以及随机选取的几组参数分别建立铁水硅含量CPSO-SVR预测模型,使用后80个未学习的样本分别进行预测,其预测结果如表1所示.由表1可以看出,利用最优参数建立的预测模型的预测效果最佳.因此,本文利用径向基核函数与参数 $C = 11.9, \varepsilon = 0.7, \sigma^2 = 1.3$ 建立基于CPSO-SVR的铁水硅含量预测模型。

另选取除训练样本数据外的五组数据每组50个样本作为测试数据,分别使用粒子群优化算法训练的神经网络(PSO-NN)、最小二乘支持向量回归机(LS-SVR)以及CPSO-SVR算法进行验证,以预测绝对误差小于0.03的样本数占总测试样本数的百分比作为预测精度进行比较,得到预测结果如表2所

示. 由预测结果可以看出, CPSO-SVR算法的预测精度比LS-SVR更好, 预测能力明显强于PSO-NN, 也不会陷入局部最优值. 可以看出: 该CPSO-SVR模型具有较强的预测能力, 从而也证明了利用CPSO优化SVR模型参数向量(ϵ, C, σ)的可行性和优越性. 由于用CPSO-SVR算法对高炉铁水硅含量进行预测时, 在预测绝对误差小于0.03范围内的预测精度达到90%以上, 所以CPSO-SVR算法可用于高炉铁水硅含量的实际预测.

表1 不同参数模型预测效果比较

Table 1 Prediction results of model with different parameters

组号	C	ϵ	σ^2	平均相对误差/%
1	11.9	0.7	1.3	5.41
2	8.1	0.5	0.7	7.82
3	10.3	0.4	2.2	9.53
4	1.9	0.2	3.7	10.97

表2 不同算法预测结果比较

Table 2 Comparison of prediction results between three algorithms

组号	预测绝对误差 < 0.03的比例		
	LS-SVR	PSO-NN	CPSO-SVR
1	86%	84%	90%
2	90%	82%	92%
3	88%	84%	90%
4	88%	86%	92%
5	90%	84%	94%

其中使用CPSO-SVR对第2组数据进行硅含量预测的预测值和实测值的比较图见图1, 由图可见, 铁水硅含量的预测值与实测值具有较好的对应关系.

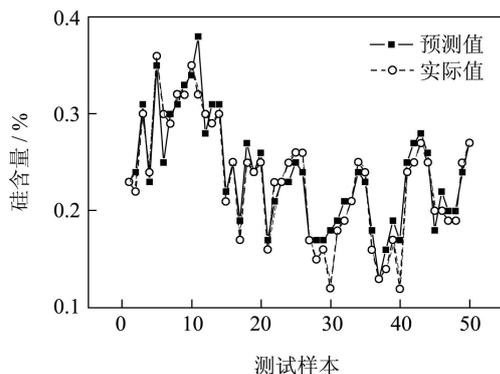


图1 铁水硅含量预测值与实际值

Fig. 1 Prediction values and real values of Silicon Content

为了验证算法的稳定性, 采用PSO-NN、LS-SVR以及CPSO-SVR算法对2007年6月15日至6月30日3号

高炉铁水硅含量的600个实际数据样本进行训练, 利用最优参数建立预测模型, 另选取3组数据每组100个样本作为测试数据分别进行预测, 得到预测结果如表3所示. 结果表明CPSO-SVR算法的预测能力仍然很强, 该算法在不同样本规模和不同时段样本情况下其计算结果稳定. 在数据规模较大的情况下LS-SVR的学习和泛化能力有一定提高, 但是其改善是以耗费更多的时间为代价的, 从这层意义来说CPSO-SVR在训练样本数据较少时具有一定的优势.

表3 数据量较大时预测结果比较

Table 3 Comparison of prediction results for large-scale data

组号	预测绝对误差 < 0.03的比例		
	LS-SVR	PSO-NN	CPSO-SVR
1	91%	87%	93%
2	87%	85%	91%
3	88%	83%	92%

5 结论(Conclusion)

SVR模型的回归精度很大程度取决于其相关参数的选取, 本文使用混沌粒子群优化算法(CPSO)优化SVR的参数并建立铁水硅含量粒子群支持向量回归预测模型(CPSO-SVR), 通过实验得到如下结论:

1) CPSO-SVR铁水硅含量预测模型克服了人工神经网络的主要不足, 算法无需定义网络结构, 不会陷入局部极小值, 非常适用于具有复杂输入输出关系的高炉过程的解析, 并可克服高炉噪声的干扰.

2) 与使用粒子群优化算法训练的神经网络(PSO-NN)、LS-SVR进行比较, CPSO-SVR预测模型对铁水硅含量进行预测的效果明显优于PSO-NN, 比LS-SVR稳定性更强.

3) 基于CPSO-SVR模型对铁水硅含量进行预测时预测绝对误差小于0.03的样本数占总测试样本数的百分比达到90%以上, 所以CPSO-SVR算法可用于高炉铁水硅含量的实际预测.

参考文献(References):

- [1] 刘祥官, 刘芳. 高炉炼铁过程优化与智能控制系统[M]. 北京: 冶金工业出版社, 2003.
(LIU Xiangguan, LIU Fang. *BF Ironmaking Process Optimization and Intelligent Control System*[M]. Beijing: China Metallurgical Industry Press, 2003.)
- [2] 张军红, 金永龙, 沈峰满, 等. 应用优化BP神经网络建立铁水硅含量的预测模型[J]. 钢铁研究学报, 2007, 19(11): 60-62.
(ZHANG Junhong, JIN Yonglong, SHEN Fengman, et al. Prediction

- model of silicon content in hot metal using optimized BP network[J]. *Journal of Iron and Steel Research*, 2007, 19(11): 60 – 62.)
- [3] VAPNIK V. *The Nature of Statistical Learning Theory*[M]. New York: Springer-Verlag, 1995.
- [4] VAPNIK V. An overview of statistical learning theory[J]. *IEEE Transaction on Neural Networks*, 1999, 10(5): 988 – 999.
- [5] MUSICANT D R, FEINBERG A. Active set support vector regression[J]. *IEEE Transaction on Neural Networks*, 2004, 15(2): 268 – 275.
- [6] QUAN Y. Successive over-relaxation for support vector regression[J]. *Journal of Software*, 2004, 15(2): 200 – 206.
- [7] SHEVADE S K, KEERTHI S S, BHATTACHARYYA C. Improvements to SMO algorithm for regression[J]. *IEEE Transaction on Neural Networks*, 2000, 11(5): 1188 – 1183.
- [8] VAN GESTEL, SUYKENS T, J A K, et al. Financial time series prediction using least squares support vector machines within the evidence framework[J]. *IEEE Transaction on Neural Networks*, 2001, 12(4): 809 – 821.
- [9] SCHOLKOPF B, SMOLA A J, WILIMSON R, et al. New support vector algorithms[J]. *Neural Computation*, 2000, 12(5): 1207 – 1245.
- [10] 邓乃扬, 田英杰. 数据挖掘中的新方法—支持向量机[M]. 北京: 科学出版社, 2004: 18 – 32.
- (DENG Naiyang, TIAN Yingjie. *New Method of Data Mining-support Vector Machine*[M]. Beijing: Science Press, 2004: 18 – 32.)
- [11] KENNEDY J, EBERHART R C. Particle swarm optimization proc[C] // *IEEE International Conference on Neural Networks*. Piscataway: IEEE, 1995: 1942 – 1948.
- [12] EBERHART R C, SHI Y. Comparing inertia weights and constriction factors in particle swarm optimization[C] // *Proceedings of the Congress on Evolutionary Computing*. Piscataway: IEEE, 2000: 84 – 89.
- [13] 费春国, 韩正之. 一种改进的混沌优化算法[J]. *控制理论与应用*, 2006, 23(3): 471 – 474.
- (FEI Chunguo, HAN Zhengzhi. An improved chaotic optimization algorithm[J]. *Control Theory & Applications*, 2006, 23(3): 471 – 474.)

作者简介:

唐贤伦 (1977—), 男, 副教授, 博士, 目前研究方向为支持向量机、群体智能, E-mail: tangxlun@hotmail.com;

庄陵 (1978—), 女, 讲师, 博士研究生, 目前研究方向为智能控制、智能信息处理, E-mail: zhuangling2000@hotmail.com;

胡向东 (1971—), 男, 教授, 博士, 目前研究方向为智能系统、优化理论等, E-mail: hxd@cqupt.edu.cn.