

基于支持向量机回归的铸坯表面目标温度设定

高凤翔¹ 王长松¹ 吴秀永¹ 陈晓² 李珂²

(1 北京科技大学机械电子工程系,北京 100083; 2 安阳钢铁公司,安阳 455004)

摘要 提出了一种多输入多输出支持向量机回归算法,利用冶金技术人员计算的目标温度设定表,设定实时二冷区铸坯表面目标温度。200 mm × 1 534 mm 16Mn 钢板坯连铸试验结果表明,在训练样本相同时,支持向量机训练时间为 3.2 s,预测目标温度误差为 ±1 °C, BP 神经网络训练时间为 23.5 s,预测目标温度误差为 ±2 °C,多输入多输出支持向量机回归算法优于 BP 神经网络算法,能够根据工艺变化情况,实时改变目标温度,为实现连铸动态控制提供了条件,有助于提高铸坯的质量。

关键词 铸坯表面目标温度 二次冷却 支持向量机回归

Setting of Object Surface Temperature of Casting Slab Based on Support Vector Regression

Gao Fengxiang¹, Wang Changsong¹, Wu Xiuyong¹, Chen Xiao² and Li Ke²

(1 Mechanics-Electronic Engineering Dept., University of Science and Technology, Beijing 100083;
2 Anyang Iron and Steel Co Ltd, Anyang 455004)

Abstract A multi-input and multi-output support vector regression algorithm is introduced to predict the real-time object surface temperature of casting slab in secondary cooling zone by using the given object temperature schedule calculated by metallurgical technicians. Test results of casting 200 mm × 1 534 mm slab of steel 16Mn show that with same training specimen number, the training time by support vector regression algorithm is 3.2 s with error of predict object temperature ±1 °C, while the training time by BP (back propagation) neural networks algorithm is 23.5 s with error of predict object temperature ±2 °C, and the multi-input and output support vector regression algorithm is better than BP neural networks algorithm to alter the object surface temperature of slab in real time according to the variety of process, therefore it is available to dynamic-control the casting process and increase the quality of slab.

Material Index Object Surface Temperatures of Slab, Secondary Cooling, Support Vector Regression

实现连铸二冷水动态控制的关键一步,是根据变化的浇铸条件实时确定二冷区铸坯表面目标温度^[1]。实时设定铸坯表面目标温度有助于提高二次冷却动态控制的精确度,获得更佳的铸坯质量。

1 设定铸坯表面目标温度的冶金准则

冶金技术人员在计算铸坯表面目标温度时必须综合考虑钢的高温力学性能、生产工艺限制条件等冶金准则^[2],包括:(1)矫直点表面温度准则;(2)液相穴长度限制准则;(3)拉坯方向铸坯表面温度冷却准则;(4)铸坯表面温度回升准则;(5)结晶器出口坯壳厚度限制准则;(6)二冷区铸坯表面温度限制准则。

2 多变量支持向量机回归算法

支持向量机是新的机器学习算法,以统计学习理论为理论体系,通过寻求结构风险最小化来实现风险的最小化,追求在有限信息的条件下得到最优结果^[3]。铸坯表面目标温度是一个二输入多输出

系统,目前支持向量机回归算法只适用于多输入、单输出的情况^[4]。在处理多输入多输出系统时如果采用构造一系列单变量支持向量机模型的方法,将增加模型与控制的复杂性。为此,通过对支持向量机回归算法进行改进,使支持向量机能够应用于多输入多输出的铸坯表面目标温度设定系统。

对于铸坯表面目标温度设定这样的非线性回归问题,可以通过一非线性映射把数据映射到一个高维特征空间,再在高维特征空间进行线性回归^[5]。设有非线性映射 $\Phi: R^d \rightarrow H$ 将输入空间的数据样本映射到高维特征空间 H 中,在特征空间 H 中构造线性回归曲线。由于在优化过程中只考虑高位空间的点积运算,因此用一个核函数 $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ 就可以实现变换后的非线性回归^[6]。设采样数据样本为 $(x^1, y^1), \dots, (x^l, y^l)$, 其中 $x^l \in R^m, y^l \in R^n, m$ 为输入量个数, n 为输出量个数。映射到高维空间的线性函数设为:

$$f_i(x) = \omega_i \cdot \Phi(x) + b_i \quad i=1, \dots, n \quad (1)$$

式中: $\omega_i \in R^m$, 是法向量; $b_i \in R$, 是阈值。

根据 Vapnik 的结构风险最小化准则, $f_i(\cdot)$ 应使下式

$$\frac{1}{2} \sum_{i=1}^n \|\omega_i\|^2 + C \sum_{i=1}^n \sum_{j=1}^l L_i[f_i(x^j), y_i^j] \quad (2)$$

最小。其中, C 是平衡因子, $L_i(\cdot)$ 是损失函数。损失函数 $L_i(\cdot)$ 通常采用 ε 不灵敏区函数, 定义如下:

$$L_i[f_i(x^j), y_i^j] = \begin{cases} 0, & |f_i(x^j) - y_i^j| < \varepsilon_i, \varepsilon_i > 0; \\ |f_i(x^j) - y_i^j| - \varepsilon_i, & \text{其它} \end{cases} \quad (3)$$

则多输入多输出支持向量机回归问题转化为下述优化问题:

$$\begin{aligned} \min J &= \frac{1}{2} \sum_{i=1}^n \|\omega_i\|^2 + C \sum_{i=1}^n \sum_{j=1}^l |f_i(x^j) - y_i^j| \\ \text{s. t.} & \quad |f_i(x^j) - y_i^j| < \varepsilon_i \end{aligned} \quad (4)$$

然而, 在此约束条件下, 由于该优化问题并不一定有解存在, 所以引入松弛变量 ξ_i^j, ξ_i^{j*} , 以保证解的存在性, 则优化问题式(4)可以写为:

$$\begin{aligned} \min J &= \frac{1}{2} \sum_{i=1}^n \|\omega_i\|^2 + C \sum_{i=1}^n \sum_{j=1}^l (\xi_i^j + \xi_i^{j*}) \\ \text{s. t.} & \quad \begin{cases} y_i^j - f_i(x^j) \leq \varepsilon_i + \xi_i^j, \\ f_i(x^j) - y_i^j \leq \varepsilon_i + \xi_i^{j*}, \\ \xi_i^j, \xi_i^{j*} \geq 0 \end{cases} \end{aligned} \quad (5)$$

这是一个凸二次优化问题, 引入 Lagrange 函数:

$$\begin{aligned} L &= \frac{1}{2} \sum_{i=1}^n \|\omega_i\|^2 + C \sum_{i=1}^n \sum_{j=1}^l (\xi_i^j + \xi_i^{j*}) - \\ & \quad \sum_{i=1}^n \sum_{j=1}^l \alpha_i^j [\varepsilon_i + \xi_i^j - y_i^j + f_i(x^j)] - \\ & \quad \sum_{i=1}^n \sum_{j=1}^l \alpha_i^{j*} [\varepsilon_i + \xi_i^{j*} - y_i^j + f_i(x^j)] - \\ & \quad \sum_{i=1}^n \sum_{j=1}^l (\gamma_i \xi_i^j - \gamma_i^* \xi_i^{j*}) \end{aligned} \quad (6)$$

式中: $\alpha_i, \alpha_i^* \geq 0; \gamma_i, \gamma_i^* \geq 0$ 。函数 L 的极值应满足

$$\text{条件:} \begin{cases} \frac{\partial L}{\partial \omega_i} = 0, \\ \frac{\partial L}{\partial b_i} = 0, \\ \frac{\partial L}{\partial \xi_i^j} = 0, \\ \frac{\partial L}{\partial \xi_i^{j*}} = 0 \end{cases} \quad (7)$$

其中 $i=1, \dots, n; j=1, \dots, l$ 。由此得到:

$$\begin{cases} \omega_i = \sum_{j=1}^l (\alpha_i^j - \alpha_i^{j*}) \Phi(x^j), \\ C - \alpha_i^j - \gamma_i^j = 0, \\ C - \alpha_i^{j*} - \gamma_i^{j*} = 0, \\ \sum_{j=1}^l (\alpha_i^j - \alpha_i^{j*}) = 0, \\ i=1, \dots, n; j=1, \dots, l \end{cases} \quad (8)$$

将式(8)代入式(6)中, 得到优化问题的对偶形式:

$$\begin{aligned} \max W(\alpha_i, \alpha_i^*) &= \\ & - \frac{1}{2} \sum_{i=1}^n \sum_{j,k=1}^l (\alpha_i^j - \alpha_i^{j*}) (\alpha_i^k - \alpha_i^{k*}) K(x^j, x^k) + \\ & \quad \sum_{i=1}^n \sum_{j=1}^l (\alpha_i^j - \alpha_i^{j*}) y_i^j - \sum_{i=1}^n \sum_{j=1}^l (\alpha_i^j + \alpha_i^{j*}) \varepsilon_i \\ \text{s. t.} & \quad \sum_{j=1}^l (\alpha_i^j - \alpha_i^{j*}) = 0, 0 < \alpha_i^j, \alpha_i^{j*} < C \end{aligned} \quad (9)$$

$$\text{其中: } K(x^j, x^k) = \Phi^T(x^j) \cdot \Phi(x^k) \quad (10)$$

回归函数 $f_i(x)$ 可直接表示为:

$$f_i(x) = \sum_{j=1}^l (\alpha_i^j - \alpha_i^{j*}) K(x^j, x^k) + b_i \quad i=1, \dots, n \quad (11)$$

根据 Kuhn-Tucker 定理有:

$$\begin{cases} \alpha_i^j \alpha_i^{j*} = 0, \\ (C - \alpha_i^j) \xi_i^j = 0, \\ (C - \alpha_i^{j*}) \xi_i^{j*} = 0, \\ i=1, \dots, n; j=1, \dots, l \end{cases} \quad (12)$$

对式(12)分析可知, $\alpha_i^j, \alpha_i^{j*}$ 不能同时为 0, 只有 $\alpha_i^j = C$ 或 $\alpha_i^{j*} = C$ 时, $f_i(x)$ 与 y_i 的误差可能大于 ε_i , 因此有:

$$\begin{cases} \varepsilon_i - y_i^j + f_i(x_j) = 0, 0 < \alpha_i^j < C; \\ \varepsilon_i + y_i^j - f_i(x_j) = 0, 0 < \alpha_i^{j*} < C; \\ i=1, \dots, n; j=1, \dots, l \end{cases} \quad (13)$$

根据式(13)可以求解阈值变量:

$$\begin{cases} b_i = y_i^j - \sum_{k=1}^l (\alpha_i^k - \alpha_i^{k*}) K(x^j, x^k) - \varepsilon_i, \\ 0 < \alpha_i^k < C; \\ b_i = y_i^j - \sum_{k=1}^l (\alpha_i^k - \alpha_i^{k*}) K(x^j, x^k) + \varepsilon_i, \\ 0 < \alpha_i^{k*} < C; \\ i=1, \dots, n; j=1, \dots, l \end{cases} \quad (14)$$

3 试验结果及分析

以钢厂板坯连铸机为对象进行测试。连铸机结晶器长度 0.9 m, 二冷区长度 24.9 m。二冷区共分为 8 段, 长度分别为: 0.5、1.08、1.7、1.9、3.81

3.84、4.66、7.41 m。现场只对二冷区前 7 段水量进行控制,第 8 段水量不进行控制。目标温度控制点设在结晶器出口及二冷区各段出口处,二冷区的上一段出口就是下一段进口。

通过用技术人员提供的铸坯断面尺寸为 200 mm × 1 534 mm 的 16Mn 钢在不同浇铸温度和拉速下的铸坯表面设定温度表的一部分数据对设定铸坯表面目标温度的支持向量机模型进行训练,然后用另一部分数据进行检验。核函数使用径向基函数:

$$K(x, x_i) = \exp\left\{-\frac{|x - x_i|^2}{\sigma^2}\right\} \quad (15)$$

式中: $\sigma = 10$, 支持向量机参数 $\varepsilon = 0.01$, $C = 900$ 。

为了进行对比,在同样条件下运用支持向量机和 BP 神经网络两种算法预测铸坯表面目标温度。两种算法的预测结果误差如表 1、表 2 所示。

表 1 支持向量机预测铸坯表面目标温度误差

Table 1 Errors of predicting object surface temperature of slab by support vector regression algorithm

| 拉速/ (m·min ⁻¹) | 浇铸温 度/℃ | 设定温度点到结晶器上口距离/m | | | | | | | |
|-------------------------------|------------|-----------------|------|------|------|------|------|------|------|
| | | 0.9 | 1.4 | 2.48 | 4.18 | 6.08 | 9.89 | 13.7 | 18.4 |
| 1.4 | 1 549 | -0.3 | -0.3 | 0.2 | 0 | 0.2 | 0.1 | 0.1 | 0 |
| 1.1 | 1 549 | 0.1 | -0.1 | -0.1 | 0 | 0.1 | -0.2 | 0.1 | 0.2 |
| 1.3 | 1 539 | 0.3 | 0.1 | 0.6 | 0.6 | 0.2 | 0.1 | -0.3 | -0.3 |
| 1.0 | 1 539 | -0.5 | 0 | -0.1 | 0 | -0.4 | -0.1 | -0.6 | -0.2 |
| 1.2 | 1 529 | 0.6 | 0.6 | 0.2 | 0.6 | 0.3 | 0.1 | 0 | -0.3 |
| 0.9 | 1 529 | -0.1 | -0.1 | 0.1 | 0.1 | -0.3 | -0.1 | 0.1 | 0.1 |
| 1.1 | 1 519 | -0.6 | -0.6 | -0.6 | -0.4 | -0.4 | -0.6 | -0.2 | -0.4 |
| 0.8 | 1 519 | -0.3 | 0.1 | -0.1 | -0.1 | -0.5 | 0.1 | -0.1 | 0 |

表 2 BP 神经网络预测铸坯表面目标温度误差

Table 2 Errors of predicting object surface temperature of slab by BP networks algorithm

| 拉速/ (m·min ⁻¹) | 浇铸温 度/℃ | 设定温度点到结晶器上口距离/m | | | | | | | |
|-------------------------------|------------|-----------------|------|------|------|------|------|------|------|
| | | 0.9 | 1.4 | 2.48 | 4.18 | 6.08 | 9.89 | 13.7 | 18.4 |
| 1.4 | 1 549 | -0.8 | -1.5 | 0.6 | 0.5 | 1.0 | -0.5 | 0.9 | 0.3 |
| 1.1 | 1 549 | 1.1 | -0.5 | 0.4 | 1.3 | -0.7 | 0.8 | -1.2 | -0.8 |
| 1.3 | 1 539 | -0.7 | 0.8 | 1.1 | -0.3 | -1.2 | 0.9 | 0.5 | -0.7 |
| 1.0 | 1 539 | 0.4 | -1.0 | 0.3 | -0.9 | 0.7 | -0.4 | 1.3 | 0.3 |
| 1.2 | 1 529 | 0.9 | -0.4 | 0.9 | 0.1 | -1.6 | -0.3 | 0.1 | 0.6 |
| 0.9 | 1 529 | 0.7 | -0.7 | 1.1 | -0.4 | 0.8 | -1.1 | 0.5 | -0.5 |
| 1.1 | 1 519 | -0.6 | 0.2 | -0.7 | 1.4 | -0.9 | 0.3 | 1.2 | -0.8 |
| 0.8 | 1 519 | 0.2 | 0.7 | -0.4 | -1.1 | 0.2 | -0.6 | 0.9 | 0.4 |

在浇铸温度为 1 539 ℃, 拉速发生变化时, 支持向量机预测的一些表面目标温度设定曲线如图 1。图 1 曲线从下往上依次是拉速为 0.8、0.9、1.0、1.1、1.2、1.3、1.4 m/min 的表面目标温度设定曲线。

在相同训练样本情况下, 支持向量机训练时间为 3.2 s, BP 神经网络训练时间为 23.5 s。由表 1 可看出, 支持向量机预测的目标温度误差在 ±1 ℃




图 1 支持向量机预测的铸坯表面目标温度设定曲线

Fig. 1 Setting curves of predicting object surface temperature of slab by support vector regression algorithm

之间, 而 BP 神经网络预测的目标温度误差在 ±2 ℃ 之间。由此可知, 在预测铸坯表面目标温度方面支持向量机优于 BP 神经网络。

4 结论

即使在较少学习样本情况下, 多输入多输出支持向量机也能够得到误差较小的结果。支持向量机能够快速完成复杂多输入多输出系统的模型训练, 较好地克服了 BP 神经网络训练速度慢、容易陷入局部极小点、存在过拟合现象和泛化能力差等缺点。多输入多输出支持向量机回归算法能够根据工艺变化情况, 实时改变目标温度, 使目标温度更加符合实际的连铸生产情况, 有利于提高铸坯的质量。

“十一五”国家科技支撑计划资助项目 (2006BAE03A06)

参考文献

- 1 梁爱生, 曹晓兵. 连铸坯二冷区目标温度曲线的确定. 重型机械, 1999(6): 19
- 2 史震兴. 实用连铸冶金技术. 北京: 冶金工业出版社, 1998
- 3 Vapnik V. Statistical Learning Theory. New York: Wiley, 1998: 354
- 4 Wang Jing, Sun Shuyi. Predictive Control Based on Support Vector Machine Model. Proc 6th WCICA. Dalian; 2006: 1683
- 5 Rojo-Alvarez J, Artinez-Ramon M, Rodo-Umplido M. Support Vector Method for Robust ARMA System Identification. IEEE Trans on Signal Processing, 2004, 52(1): 155
- 6 白鹏, 张喜斌, 张斌. 支持向量机理论与工程应用实例. 西安: 西安电子科技大学出版社, 2008

高凤翔(1974-), 男, 博士研究生, 连铸过程自动化与智能控制。

收稿日期: 2009-05-03