

热处理炉钢板温度的自适应混沌粒子群算法-最小二乘支持向量机优化预报算法

李 静¹, 王 京¹, 杨 磊², 刘 森³

(1. 北京科技大学 冶金工程研究院, 北京 100083; 2. 舞阳新宽厚钢板责任有限公司轧钢厂, 河南 舞钢 462500;

3. 北京亿玮坤节能科技有限公司, 北京 102205)

摘要: 针对传统传热模型参数调整较复杂和模型精度较低的问题, 构建了一种基于改进粒子群算法优化最小二乘支持向量机(least squares SVM, LSSVM)的钢板温度预报模型. 首先, 对基本粒子群算法进行分析, 提出自适应混沌粒子群算法(adaptive chaos PSO, ACP SO), 并通过性能指标定量评价验证算法的有效性、鲁棒性和寻优效率. 其次, 采用LSSVM建立钢板温度预报模型, 并选用径向基函数作为核函数, 用ACPSO算法优化该模型参数. 最后, 结合现场数据进行仿真研究和工程应用, 结果表明基于该算法建立的钢板温度预报模型具有较高的预报精度, 达到智能调优的目的.

关键词: 热处理炉; 粒子群优化算法; 支持向量机; 混沌

中图分类号: TP273.1 **文献标识码:** A

Optimized prediction algorithm with adaptive chaos particle swarm optimization-least squares support vector machine for steel plate temperature prediction in heat treatment furnace

LI Jing¹, WANG Jing¹, YANG Lei², LIU Sen³

(1. Metallurgical Engineering Institute, University of Science & Technology Beijing, Beijing 100083, China;

2. Rolling Plant of Wuyang New Wide and Heavy Steel Plate Co., Ltd, Wuyang Henan 462500, China;

3. IVYQUEN Energy Saving Technology Ltd, Beijing 102205, China)

Abstract: To deal with the difficulty in parameter adjustment and the low precision of the traditional heat-conduction model, we build a prediction model for the steel plate temperature, based on the least-squares-support-vector machine(LSSVM) which is optimized by the improved particle-swarm algorithm. First, on the basis of the particle-swarm algorithm, we propose an adaptive chaotic particle-swarm algorithm(ACPSO) for which the validity, robustness and the optimization efficiency are quantitatively evaluated based on performance indices; and then, the radial basis functions are selected as the kernel function. Thus, the temperature prediction model of steel plate is built with LSSVM and optimized with ACP SO algorithm. Finally, the model is simulated by using the data acquired from the site and used in practical operation; the result indicates that the prediction model based on ACP SO and LSSVM has higher prediction accuracy than the tradition one, achieving the goal of intelligent optimization.

Key words: heat treating furnace; PSO(particle swarm optimizer algorithm); SVM(support vector machine); chaos

1 引言(Introduction)

热处理炉内的加热过程较复杂, 钢板在炉内温度很难进行实时检测, 目前主要是通过求解炉内钢板的热传导偏微分方程得到钢板的温度分布^[1,2]. 但这种方法需要对钢板的加热过程作许多假设, 预报精度不能很好满足生产需要; 同时加热过程具有典型的分布参数特性及复杂的边界条件, 使得偏微分方程的求解复杂^[2]. 因此本文引入智能算法对热处理炉内钢板进行温度实时预报.

支持向量机方法是建立在统计学习理论的VC维理论和结构风险最小原理基础上, 能较好地解决小样本、非线性、高维数和局部极小点等实际问题, 具有很强的泛化能力^[3]. 其中, 最小二乘支持向量机(least square support vector machine, LSSVM)是标准支持向量机的一种扩展, 简化了计算复杂性, 求解速度相对加快, 在智能控制方面得到广泛应用. 但是, 支持向量机(SVM)的参数选择问题一直没有得到很好解决, 严重限制了SVM的进一步应用^[4].

粒子群优化算法(particle swarm optimization, PSO)是由美国的Kenney和Eberhart于1995年提出的,是一类基于群体智能的随机优化算法^[5],具有参数少、流程简单和易于实现的优点. 已经被证明是一种较好的全局优化方法. 但基本粒子群却又易于陷入局部最优^[6],导致搜索成功率不高.

本文结合热处理炉工艺特点,构造了一种基于LSSVM建立钢板预报模型,提出了一种新的改进粒子群算法——自适应混沌粒子群优化算法(adaptive chaos PSO, ACP SO)来优化LSSVM参数. 仿真和工程应用表明,该模型大大提高了钢板温度预报的准确度.

2 自适应混沌粒子群算法(Adaptive chaos PSO)

粒子群优化算法^[5,6]是一种基于迭代的空搜索算法,其速度和位置更新方程如下式:

$$v_{id}^{k+1} = v_{id}^k + c_1 \text{rand}_1^k (pb_{id}^k - x_{id}^k) + c_2 \text{rand}_2^k (gb_d^k - x_{id}^k), \quad (1)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1}, \quad (2)$$

其中: v_{id}^k 为粒子 i 在第 k 次迭代中第 d 维的速度; c_1 , c_2 为加速系数,分别调节向全局最好粒子和个体最好粒子方向飞行的最大步长; rand_1 , rand_2 为 $[0, 1]$ 之间的随机数; x_{id}^k 为粒子 i 在第 k 次迭代中第 d 维的当前位置; pb_{id} 为粒子 i 在第 d 维的个体极值点的位置; gb_d 为整个种群在第 d 维的全局极值点的位置.

式(1)是速度更新公式,式(2)是粒子位置更新公式. 通过式(1)和式(2),粒子 i 决定下一步的运动位置.

鉴于基本粒子群算法在迭代过程中易于陷入局部最优、早熟收敛^[7],利用混沌的“随机性”、“遍历性”及“规律性”等特点^[8],每个粒子在各迭代过程中完成速度和位置更新后,对当前粒子个体产生混沌扰动,以使解跳出局部极值. 本文分别采用混沌扰动机制、自反向机制和末位重置等措施来增强算法的种群多样性.

2.1 ACP SO算法核心(Keys of ACP SO)

1) 粒子混沌扰动机制.

首先,随机产生一个与变量维数相同的 d 维向量: $z_0 = (z_{01}, z_{02}, \dots, z_{0d})$,且分量取值在 $[0, 1]$ 之间;其次,根据混沌系统最典型的Logistic映射^[8]生成 $z_1 = (z_{11}, z_{12}, \dots, z_{1d})$,其中: $z_{1j} = f(z_{0j}, u) = uz_{0j}(1 - z_{0j})$, u 为Logistic控制参数. 产生扰动量 $\Delta x_j = (\Delta x_1, \Delta x_2, \dots, \Delta x_d)$,其中 $\Delta x_j = -\beta + 2\beta z_{1j}$,即将 z_1 的各个分量载波到混沌扰动范围 $[-\beta, \beta]$ 内,并令 $z_0 = z_1$. 最后,再随机选取某一维,用 Δx_j 对粒子原始位置扰动,完成对粒子的自适应调节.

2) 粒子自反向和末位重置机制.

若粒子 i 的决策变量超过其定义域范围,则将此决策变量设定在定义域边界上,令 $v_{id} = -v_{id}$ 重新设置粒子速度,让粒子以相反的方向在下一代中搜索定义域空间.

在粒子群的迭代过程中,引入异常粒子或者随机重置部分粒子速度. 以适应值衡量个体的位置优劣,定义适应值最差的个体为末位个体,本文选择末位粒子重置. 重置粒子时机可选择每次迭代,也可选择经过几次迭代后而适应值没有更新的时刻.

2.2 ACP SO算法步骤(Steps of ACP SO)

- 1) 在决策变量空间内初始化粒子群的大小、速度、位置及个体历史最优位置;
- 2) 计算每个粒子的适应值,更新粒子的全局最优位置 gb ;
- 3) 根据PSO速度和位置更新公式,如式(1)和式(2),更新粒子群中的各个粒子;
- 4) 采用ACP SO算法核心机制对粒子位置、速度更新;
- 5) 更新粒子的个体历史最优位置 pb ;
- 6) 若满足终止条件,则停止;否则,转入2).

2.3 ACP SO算法验证(Algorithm authentication of ACP SO)

为评估改进算法的优化性能,通过两个评价指标分别从效率和收敛性能方面定量分析:平均截止代数和平均优化性能. 采用4个基准测试函数^[9]: f_1 为De Jong函数, f_2 为LevyNo.5函数, f_3 为10维函数, f_4 为Schwefel函数. 其中 f_3 和 f_4 为高维函数,这几个函数都具有多个极小值,常规算法求解困难等特点,并与基本粒子群算法(PSO)进行比较.

由于PSO算法和ACP SO算法都属于随机搜索算法,因此各算法在每次迭代独立运行20次,群体规模 NP 为60,最大迭代次数 G 为200. 各算法的测试结果见表1和表2,其中平均最优解为停机条件只设最大迭代次数而不附加计算精度约束的平均种群最优解,用于验证算法的有效性. 平均截止代数及寻优成功率则为在最大迭代次数和计算精度共同约束($\epsilon = 0.001$)下的收敛情况,用于验证算法的寻优效率和鲁棒性.

从表1和表2可以看出,在低维函数 f_1 , f_2 上PSO与ACP SO的最优解和寻优成功率大体相同,但是整体上ACP SO优化效率要高于PSO. 在高维函数 f_3 , f_4 上,虽然ACP SO算法性能明显劣于其在低维函数上的表现,但是却远远好于PSO. 同时根据收敛性证明可知当 NP 或 G 越大,ACP SO算法将以概率1收敛于全局最优. 下面设 NP 为150,最大迭代次数 G 取500,再采用两种算法对函数 f_4 进行测试研究.

表 1 基准测试函数的仿真结果(1)

Table 1 Simulation results of benchmark test functions(1)

函数	理论最优	平均最优解	
		PSO	ACPSO
f_1	-3905.93	-3905.93	-3905.93
f_2	-176.1375	-172.1768	-176.1375
f_3	-78.33236	-68.2373	-76.9187
f_4	0	14.803	0.0017

表 2 基准测试函数的仿真结果(2)

Table 2 Simulation results of benchmark test functions(2)

函数	平均截止代数		寻优成功率	
	PSO	ACPSO	PSO	ACPSO
f_1	29	7	18/20	20/20
f_2	41	10	11/20	20/20
f_3	200	102	0/20	13/20
f_4	200	200	0/20	7/20

由表3可知, 在对函数 f_4 寻优上, 随着种群个数以及迭代次数的增加, ACPSO算法寻优达到了19/20的寻优成功率。

表 3 测试函数 f_4 的仿真结果

Table 3 Simulation results of benchmark test functions f_4

算法名称	平均最优解	平均截止代数	寻优成功率
PSO	11.714	495	3/20
ACPSO	0.0013	284	19/20

下面以 f_2 和 f_4 为例, 具体研究ACPSO算法的寻优过程。图1为ACPSO算法和PSO算法对目标函数 f_2 和 f_4 寻优的平均优化性能曲线(图中黑色粗实线为全局最优值), G 分别取200和500。

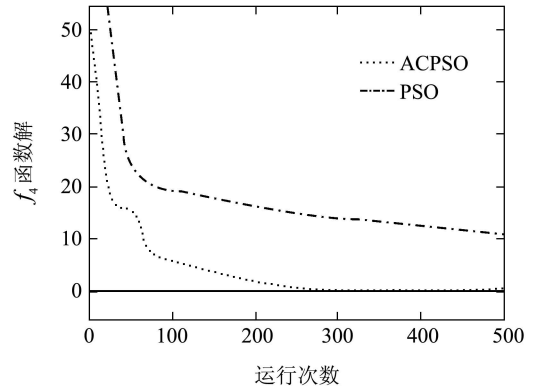



图 1 各算法对函数 f_4 平均优化性能曲线

Fig. 1 Mean performance curve of function f_4

从图1比较结果可以看出, ACPSO算法对于目标函数的优化性能和收敛速度相对PSO算法来说都有较大提高. 因此只要参数设置合理, ACPSO算法必然能以更大的概率收敛于全局最优解。

3 最小二乘支持向量机(LSSVM)

最小二乘支持向量机是基于支持向量机方法中的一种^[10]. LSSVM用最小二乘线性系统代替传统的支持向量, 即采用二次规划方法解决模式识别问题, 它通过构造损失函数将原支持向量机中算法的二次寻优变为求解线性方程, 因此能够有效地降低计算的复杂性. 它用以下式函数对未知函数进行估计^[11]:

$$y_i = w^T \phi(x_i) + b, \quad (3)$$

其中: $x \in \mathbb{R}^n, y \in \mathbb{R}$, 非线性函数 $\phi(\cdot) : \mathbb{R}^n \rightarrow \mathbb{R}$ 将输入空间映射为高维特征空间. 给定训练集为

$$(x_i, y_i); x_i \in \mathbb{R}^n; y_i \in \mathbb{R}, i = 1, 2, \dots, l, \quad (4)$$

其中: x_i 为输入, y_i 为输出. 则函数估计问题可以描述为求解下述优化问题:

$$\min_{w,b,e} j(w, b, e) = \frac{1}{2} \|w\|^2 + \gamma \sum_{i=1}^l e_i^2, \quad (5)$$

$$i = 1, 2, \dots, l.$$

约束条件

$$y_i = w \times \varphi(x_i) + b + e_i, i = 1, 2, \dots, l, \quad (6)$$

其中: $\varphi(x)$ 是核空间映射函数; w 是权向量; b 是偏差量; 误差变量 $e_i \in \mathbb{R}$; γ 为惩罚因子.

式(5)的Lagrange函数为

$$L(w, b, e; \alpha) = J(w, b, e) - \sum_{i=1}^l \alpha_i \{w^T \varphi(x_i) + b + e_i - y_i\}, \quad (7)$$

其中 α_i 是Lagrange函数乘子.

Lagrange函数的最优条件为

$$\begin{cases} \frac{\partial L}{\partial w_i} = 0 \Rightarrow w_i = \sum_{i=1}^l \alpha_i y_i \varphi(x_i), \\ \frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^l \alpha_i y_i = 0, \\ \frac{\partial L}{\partial e_i} = 0 \Rightarrow \alpha_i = \gamma e_i, \\ \frac{\partial L}{\partial \alpha_i} = 0 \Rightarrow y_i (w^T \varphi(x_i) + b) - 1 + e_i = 0. \end{cases} \quad (8)$$

可以通过求解线性方程组而不是二次规划来得到支持向量, 根据上述Lagrange最优性条件的求解, 可以得到原优化问题(5)的最优解, 最优性条件可以以矩阵的形式统一表示为

$$\begin{bmatrix} I & 0 & 0 & -Z^T \\ 0 & 0 & 0 & -Y^T \\ 0 & 0 & \gamma I & -I \\ Z & Y & I & 0 \end{bmatrix} \begin{bmatrix} w \\ b \\ e \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \bar{1} \end{bmatrix}, \quad (9)$$

其中:

$$Z = [\varphi(x_1)^T y_1; \dots; \varphi(x_l)^T y_l], Y = [y_1; \dots; y_l], \\ e = [e_1; \dots; e_l], \bar{1} = [1; \dots; 1], \alpha = [\alpha_1; \dots; \alpha_l].$$

从式(9)中消去 w, e 得

$$\begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 & I^T \\ I & \Omega + \gamma^T I \end{bmatrix}^{-1} = \begin{bmatrix} 0 \\ \gamma \end{bmatrix}, \quad (10)$$

其中: $y = (y_1, y_2, \dots, y_n)^T$, $I = (1, 1, \dots, 1)^T$, $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)^T$, Ω 是一个方阵, 其第 k 列 l 行的元素是 $\Omega_{kl} = \varphi(x_k)^T \varphi(x_l) = K(x_k, x_l)$; $K(\cdot, \cdot)$ 是核函数. 由式(7)可求解 w , 可得到训练集的测量模型

$$y(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + b. \quad (11)$$

从上述推导可知, 将求解优化问题转换为求解线性方程时, 等式约束起了重要作用. 优化问题线性化求解可以很大程度降低了算法的复杂度. 以径向基函数(RBF)核为例, LSSVM算法需要确定的参数要少于标准SVM算法.

4 ACPSO优化LSSVM的钢温预报模型 (Temperature prediction model based on LSSVM optimized by ACPSO)

4.1 LSSVM建立预报模型(Establish the prediction model with LSSVM)

最小二乘支持向量机将非线性的样本数据映射为高维控制的线性输出, 如式(11)所示. 这里核函数采用径向基函数

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right), \quad (12)$$

其中: $\|x - x_i\|^2 = \sqrt{\sum_{i=1}^n (x^k - x_i^k)^2}$, σ^2 为RBF核函数参数.

本文在某种钢种和厚度一定的情况下, 根据工艺参数对产品性能的影响关系, 把钢板的长度、宽度、厚度、辊道的速度、钢板所处上部、下部炉膛的温度和钢板上时刻的温度这7个量作为输入, 钢板在本时刻的温度为输出, 用LSSVM建立预报模型. 模型通过对样本集的学习, 求解式(12)的方程.

4.2 LSSVM参数选择(Selection of LSSVM parameter)

LSSVM的性能取决于算法参数的选取^[12], 具体模型由其参数唯一确定. 本文采用RBF核, LSSVM只需确定核函数参数 σ^2 和惩罚因子 γ , 而不再需要确定不敏感损失系数, 简化了模型结构.

核函数参数 σ^2 的大小反映了向量之间的相关程度, 决定了在该空间所构造的线性分类面的最大VC维, 从而影响样本数据在此空间中分布的复杂程度.

惩罚因子 γ 的大小影响模型的复杂性和稳定性, 反映了在确定的数据子空间中训练错误率和模型复杂度之间的关系.

目前对于这两个参数的选取大多采用经验和试凑的方法. 本文采用ACPSO算法优化LSSVM参数, 找到算法在学习对象上性能最优的参数组合.

4.3 ACPSO优化步骤(Optimized steps of ACPSO)

本文选取平均绝对误差作为适应度函数, 以衡量算法优劣性. 每一个粒子代表LSSVM的一组参数, 粒子所对应的适应度是该组参数下算法的性能. 则适应度函数形式如下所示:

$$f = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y_i^*}{y_i} \right|, \quad (13)$$

其中: f 为适应度函数, y_i 为实际值, y_i^* 为预报值, n 为训练样本个数.

在搜索过程中, 若预测误差达到某一给定值或者到达最大迭代次数, 则算法终止. 具体步骤如下:

1) ACPSO初始化算法参数. 按照ACPSO步骤初始化粒子群的大小、速度、位置及个体历史最优位置;

2) 用训练样本集训练LSSVM模型, 用式(13)的适应度函数计算每一个粒子的适应度值, 根据粒子的适应度值更新个体最优位置 pb 和全局最优位置 gb ;

3) 根据PSO速度和位置方程更新粒子群中的各个粒子, 采用自调节机制对粒子位置和速度更新;

4) 若满足终止条件或最优解在一定迭代次数内停滞不再变化, 则停止; 否则, 转入2).

5) 用获得的最优参数重新训练LSSVM, 建立LSSVM模型. 用测试样本集进行推广能力测试.

4.4 钢板温度精度要求(Precision of plate temperature)

热处理炉分入炉区、中间区和出炉区, 在保证炉

温控制精度的前提下, 工艺上对不同的区段有不同的温度误差要求^[13]:

入炉区要求温度模型误差范围在 $\pm 30\text{ }^\circ\text{C}$ 之内; 中间区要求温度模型误差范围在 $\pm 20\text{ }^\circ\text{C}$ 之内; 出炉区要求温度模型误差范围在 $\pm 10\text{ }^\circ\text{C}$ 之内.

4.5 仿真及应用数据分析(Simulation and discussion of application data)

根据上述过程建立LSSVM模型, 选取粒子群规模为60, γ 取值为[0.01, 400], σ^2 取值为[0.01, 10], 最大迭代次数为400, 权重因子 c_1, c_2 取值为2. LSSVM参数经过ACPSO优化得到最优组合: $\gamma = 156.253, \sigma^2 = 3.9652$.

为了进一步证明ACPSO-LSSVM模型预报能力, 利用某钢厂热处理炉历史数据, 对预报钢板温度的ACPSO-LSSVM模型进行离线学习和测试. 取不同厚度钢板的600组数据作为模型的训练数据, 取同一块钢板的70组数据作为测试数据. 分别用LSSVM和ACPSO-LSSVM在相同精度 $\varepsilon = 0.002$ 情况下进行了对钢板表面平均温度和钢板芯部平均温度训练. 图2和图3为钢板表面和芯部平均温度误差训练结果, 上为LSSVM训练结果, 下为ACPSO-LSSVM训练结果.




图 2 LSSVM和ACPSO-LSSVM钢板表面温度误差曲线
Fig. 2 Plate surface temperature error curve of LSSVM and ACPSO-LSSVM




图 3 LSSVM和ACPSO-LSSVM钢板芯部温度误差曲线
Fig. 3 Plate core average temperature error curve of LSSVM and ACPSO-LSSVM

由图2可知, 直接训练LSSVM需要3413次达到精度要求, ACPSO-LSSVM需要训练2174次, 比直接训练LSSVM快了28.4%. 由图3可知, 直接训练LSSVM需要3985次达到精度要求, ACPSO-LSSVM需要训练3523次, 显然比直接训练LSSVM快了11.6%.

依托某钢厂热处理炉建立钢板表面和芯部温度预报模型, 以芯部温度预报为例, 用ACPSO-LSSVM建立的芯部温度预报曲线如图4所示. 其中: T1为黑匣子试验数据(钢板芯部实际温度), T2为ACPSO-LSSVM预报模型的钢板芯部预报温度. 黑匣子试验是国内外钢铁行业验证预报模型准确度和可信度的常用方法.




图 4 ACPSO-LSSVM钢板芯部平均温度预报曲线
Fig. 4 Plate core average temperature prediction curve of ACPSO-LSSVM

由图4可以看出,用ACPSO-LSSVM建立的钢板钢芯温度在炉内误差最大为10.3℃,出炉区的温度误差在3℃以内,均满足工艺对温度误差的要求.同时也满足工艺对钢板断面温差的要求(小于±5℃).

综上所述,考虑实际炉温控制精度保持在±2℃以内时,从数据分析可以看出,用ACPSO-LSSVM建立的钢板温度预报模型所预报出来的温度:

对于钢板表面平均温度,偏差在5℃之内的预报值达到85.4%,偏差在10℃之内的预报值达到100%;

对于钢板芯部平均温度,偏差在5℃之内的预报值达到83.5%,偏差在10℃之内的预报值达到100%;

热处理炉内钢板刚入炉时,其表面温度总比芯部的温度升高的快,温差逐渐增大,增加到最大时,逐渐减小.到出炉区时,温差基本为0℃,表明出炉区位置时钢板表面和芯部基本不存在温差.

5 结束语(Conclusion)

为解决热处理炉钢板传统传热模型求解复杂程度较低的问题,本文提出了一种基于改进粒子群算法(ACPSO)优化LSSVM模型参数的方法,用于建立钢板温度预报模型.通过平均截止代数和平均优化性能两个评价指标定量分析了ACPSO算法,该算法在效率和收敛性能方面都有优异表现.将所建立的ACPSO-LSSVM温度预报模型应用在某钢厂热处理炉钢板表面和芯部平均温度的预报中,结果验证了该模型具有较高的预报精度和良好的应用前景.

参考文献(References):

- [1] HOLLANDER F, ZUURBIER S P A. Development and performance of on-line computer control in a 3-zone reheating furnace[J]. *Iron and Steel Engineer*, 2002, 79(1): 44 – 52.
- [2] 牛珏, 温治, 王俊升, 等. 大型辊底式连续热处理炉计算机优化控制系统[J]. *钢铁*, 2007, 42(2): 72 – 74.
(NIU Jue, WEN Zhi, WANG Junsheng, et al. Computer control system for optimizing heating of large continuous roller hearth heat treatment furnace[J]. *Iron and Steel*, 2007, 42(2): 72 – 74.)
- [3] 白鹏, 张斌. 支持向量机理论及工程应用实例[M]. 西安: 西安电子科技大学出版社, 2008.
- [4] SUYKENS J A K, DE BRABANTER J, LUKAS L, et al. Weighted least squares support vector machine: robustness and sparse approxi-

mation[J]. *Neurocomputing*, 2002, 48(1): 85 – 105.

- [5] KENNEDY J, EBERHART R C. Particle swarm optimization[C] // *Proceedings of IEEE International Conference on Neural Networks*. Piscataway: IEEE, 1995: 1942 – 1948.
- [6] 杨维, 李歧强. 粒子群优化算法综述[J]. *中国工程科学*, 2004, (6): 87 – 94.
(YANG Wei, LI Qiqiang. Survey on particle swarm optimization algorithm[J]. *Engineering Science*, 2004, (6): 87 – 94.)
- [7] EBERHART R C, SHI Y. Guest editorial special issue on particle swarm optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2004, 8(3): 201 – 203.
- [8] 黄润生, 黄浩. 混沌及其应用[M]. 武汉: 武汉大学出版社, 2005.
(HUANG Runsheng, HUANG Hao. *Chaos and Its Application*[M]. Wuhan: Wuhan University Press, 2005.)
- [9] 赵云涛, 王京, 宋勇, 等. 具有转换函数的均匀差分进化算法及性能分析[J]. *控制理论与应用*, 2009, 26(9): 1014 – 1018.
(ZHAO Yuntao, WANG Jing, SONG Yong, et al. Uniform differential evolution algorithm with transform function and performance analysis[J]. *Control Theory & Applications*, 2009, 26(9): 1014 – 1018.)
- [10] SUYKENS J A K, VANDEWALLE J. Recurrent least squares support vector machines[J]. *Transactions on Circuits and Systems-I*, 2000, 47(7): 1109 – 1114.
- [11] SUYKENS J A K, VANDEWALLE J. Least squares support vector machine classifiers[J]. *Neural Processing Letters*, 1999, 9(3): 293 – 300.
- [12] SUYKENS J A K, VAN GESTEL T, DE BRABANTER J, et al. *Least Squares Support Vector Machine*[M]. Singapore: World Scientific Publishing, 2002.
- [13] 李静, 李小占, 王京, 等. 中厚板热处理线的开发与应用研究[J]. *钢铁*, 2009, 44(2): 83 – 87.
(LI Jing, LI Xiaozhan, WANG Jing, et al. Development and application of heat treatment line in medium plate mill[J]. *Iron and Steel*, 2009, 44(2): 83 – 87.)

作者简介:

李 静 (1973—), 女, 副教授, 博士, 目前研究方向为控制理论与控制工程及应用, E-mail: lijing6332@ustb.edu.cn;

王 京 (1948—), 男, 教授, 博士生导师, 目前研究方向为控制理论与控制工程、智能系统理论与技术, E-mail: wangj@nrcar.ustb.edu.cn;

杨 磊 (1972—), 男, 工程师, 目前研究方向为机电一体化及自动控制应用, E-mail: ylyk@vip.sina.com;

刘 森 (1972—), 男, 学士, 目前研究方向冶金领域节能环保优化及控制系统应用, E-mail: liusen555@163.com.