

基于HPSO的钢坯加热过程炉温优化设定

廖迎新^{1,2,3}, 吴敏¹, 余锦华³, 曹卫华¹

(1. 中南大学 信息科学与工程学院, 湖南 长沙 410083;

2. 中南林业科技大学 电子与信息工程学院, 湖南 长沙 410004; 3. 东京工科大学 仿生学学部, 日本 东京 192-0982)

摘要: 针对一种蓄热推钢式加热炉三个加热区的炉温稳态优化问题, 本文提出了一种混合粒子群优化(HPSO)方法. 首先, 基于钢坯导热偏微分方程和边界条件, 建立钢坯温度预报模型. 然后, 采用HPSO算法确定最佳稳态炉温, 即炉温控制的参考输入. 该方法利用混沌机制产生初始种群, 通过免疫和克隆来提高粒子群优化(PSO)算法的全局搜索能力和搜索精度.

关键词: 加热炉; 稳态优化; 混合粒子群优化; 免疫; 克隆

中图分类号: TP273 **文献标识码:** A

Hybrid particle swarm optimization of temperature settings of billet-reheating process

LIAO Ying-xin^{1,2,3}, WU Min¹, SHE Jin-hua³, CAO Wei-hua¹

(1. School of Information Science and Engineering, Central South University, Changsha Hunan 410083, China;

2. School of Electron and Information Engineering, Central South University of Forestry and Technology,
Changsha Hunan 410004, China;

3. School of Bionics, Tokyo University of Technology, Tokyo 192-0982, Japan)

Abstract: A hybrid particle swarm optimization (HPSO) approach is presented to solve the problem of optimizing the steady-state temperatures of the three zones of a billet reheating furnace. Firstly, a model for predicting billet temperature is constructed based on a heat transfer equation and its boundary conditions. Then, HPSO is used to determine the optimal steady-state temperatures, which are reference inputs for the control of furnace temperature. This approach uses a chaos mechanism to create the initial population, and adopts immunity and cloning to improve the global search capability and search precision of particle swarm optimization.

Key words: reheating furnace; steady-state optimization; hybrid particle swarm optimization; immunity; cloning

1 引言(Introduction)

钢坯加热炉是轧钢生产线的主要设备之一, 用于把钢坯均匀地加热到某一给定温度. 钢坯出炉时应该达到目标温度, 以致轧制时不损坏轧机. 实际生产中主要是通过控制各区炉温, 以控制钢坯的整个加热过程, 使钢坯出炉温度满足工艺要求, 并使燃耗最小. 目前炉温控制主要采用交叉限幅PID控制方式, 控制器的参考输入由操作人员凭经验设置, 很难满足钢坯加热的工艺指标和节能经济指标的要求. 确定最优稳态炉温的问题可描述为: 给定钢坯参数, 确定最优稳态炉温以最小化钢坯出炉的平均温度偏差和温度梯度. 由于影响炉温的因素众多, 采用常规炉温优化方法^[1~3]很难获得满意的优化结果.

炉温稳态优化是一种典型的非线性优化问题. 目前, 各种数字技术, 如直接搜索^[4~6]、混沌优化^[7,8]和进化算法^[9~11]被广泛用于求解非线性优化问题. 其中, 直接搜索法已被应用于优化稳态炉温^[2]. 直接搜索法虽然收敛速度快, 但易陷入局部最优^[12]. 另一方面, 粒子群优化(PSO)通过存储过去信息以及粒子之间的相互作用搜索最优解. 这种方法能快速搜索解空间, 但是存在种群退化现象, 可能产生局部最优. 高鹰等人^[13]将免疫选择机制引入到PSO中, 改善了PSO的全局搜索能力. Leandro等人^[11]将克隆选择原理用于优化, 通过求解30个城市的旅行商问题验证了算法的有效性. 其中受体修正算子保证了种群的多样性, 从而使算法避免了陷入局部最优.

Wang等人^[14]在此基础上将PSO与克隆选择融合, 进一步提高了算法的收敛性. 但是, 这些方法没有兼顾PSO的全局优化和精确搜索能力的改善. 混沌是一种无序然而又具有确定性的行为, 是在许多非线性系统中出现的普遍现象. 如果用混沌机制产生初始种群, 粒子的多样性能得到保证. 此外, 免疫系统的基于密度的选择机制可防止种群退化^[15], 克隆有助于精练解^[10]. 因此, 将混沌、免疫和克隆机制与PSO融合, 是求解炉温稳态优化设定问题的一种非常有前途的方法.

本文提出了一种混合粒子群优化(HPSO)方法, 以确定一个蓄热推钢式加热炉的最优稳态炉温, 克服了PSO所存在的局部最优等缺陷. 首先, 基于热传导偏微分方程和边界条件, 建立钢坯温度预报模型; 然后, 综合考虑钢坯加热过程的工艺和经济要求建立炉温优化目标函数, 采用HPSO搜索3个区的最优稳态炉温. 实际运行结果证实了模型的有效性并显示HPSO优于人工操作和直接搜索法.

2 炉温控制系统结构(Configuration of furnace temperature control system)

本文采用图1所示的加热炉控制系统结构, 在此结构中, T_m^* 为钢坯平均温度的理想值. g, h, T_D 和 v_r 分别表示钢坯种类、钢坯厚度、钢坯装炉温度和轧机轧制速率. T_m 为钢坯平均温度预报值, T_a, T_s 和 T_c 分别为钢坯出炉时的平均、表面和中心预报温度, q 为煤气流量向量. 图中炉温控制器采用自适应模糊神经网络控制方式调节3个区的温度向量 T_f (通过热电偶测得), 使钢坯出炉平均温度跟踪目标值.




图1 炉温控制系统的结构

Fig. 1 Configuration for furnace temperature control system

通过稳态优化模块中的查询表和插值运算, 由参数 g, h, T_D 和 v_r 可获得初始炉温设定. 之后, 该初始值被用来构造初始种群的粒子, 采用HPSO产生最优炉温设定向量 T_r . 另一方面, 在加热过程中存在着不可测干扰(如炉压、炉体绝缘条件及炉膛气氛的变化等), 可能导致钢坯出炉温度产生较大的变化. 为了抑制这些影响, 通过一个PID补偿器来生成一个补偿向量 ΔT_r , 以期获得较好的优化效果. T_r 和 ΔT_r 组成了炉温控制系统的参考输入 $T_r^*(= T_r + \Delta T_r)$, 炉温控制器对其进行跟踪. PID补偿器根据钢坯平均温

度与理想曲线的区域偏差, 对各区炉温设定值进行修正, 调节机制的详细说明参见参考文献[2]. PID补偿器中的积分环节用于消除系统控制的稳态误差, 保证控制精度. 此外, 由于加热炉的滞后时间为其时间常数的0.5%以下, 因此本文不考虑其影响.

3 钢坯温度预报模型(Model for predicting billet temperature)

钢坯入炉后依次通过预热、加热和均热区. 在此过程中钢坯受到炉膛气氛和炉墙的辐射传热, 并通过传导传热损失一部分热能给水冷滑轨. 为了简单地描述这种复杂钢坯加热过程, 本文作下列假设: 1) 炉温只是时间和炉长坐标的函数; 2) 忽略钢坯与水冷滑轨之间的传热; 3) 在每一个区内钢坯表面的热交换系数均为常数.

钢坯中的主要传热机制是热传导. 加热炉内紧密排列的矩形钢坯可看作一个平壁, 其边缘的传热可忽略不计, 炉宽方向的热流基本相同, 而炉长方向的传热也可忽略不计, 导热仅沿厚度方向进行. 沿厚度方向 x 钢坯可分成均匀的几层, 钢坯温度分布 $T(x, t)$ 和平均温度 $T_m(t)$ 可由下列方程组得到^[2]

$$\begin{cases} \frac{\partial T(x, t)}{\partial t} = \frac{1}{c\rho} \frac{\partial}{\partial x} \left[\lambda \frac{\partial T(x, t)}{\partial x} \right], \\ \lambda \frac{\partial T(x, t)}{\partial x} = \begin{cases} -Q(y, t), & x = 0, \\ 0, & x = h, \end{cases} \\ Q(y, t) = \sigma \Phi(y) [\hat{T}_f^4(y, t) - T^4(0, t)], \\ \frac{\partial}{\partial t} T_m(t) = \frac{Q(y, t)}{h c \rho}, \\ 0 \leq t \leq t_r, 0 \leq x \leq h. \end{cases} \quad (1)$$

其中: t_r 为钢坯的加热时间, c, ρ 和 λ 分别为钢坯的比热容、密度和传热系数. $Q(y, t)$ 和 $\Phi(y)$ 分别为钢坯上表面的热流密度和热吸收系数. 斯蒂芬-玻尔兹曼常数 $\sigma = 5.67 \times 10^{-8} \text{ W}/(\text{m}^2 \cdot \text{K}^4)$. 式中温度的单位为 K . 根据实际经验和工艺分析, 炉温 $\hat{T}_f$ 可近似描述为炉长方向位移 y (钢坯到炉子入口的距离)的二次函数^[1]. 首先根据钢坯所在位置的炉温和钢坯上表面温度计算出钢坯上表面的热流密度, 然后计算钢坯表面温度, 之后计算出钢坯内部各层温度和平均温度. 根据以上方程, 钢坯温度分布显然与钢坯的传热系数和初始温度有关, 并受炉温和边界条件控制. 在线计算是基于式(1)的离散递推公式, 完成1步温度预测所需时间不足0.01 s.

4 炉温稳态优化(Optimization of steady-state furnace temperatures)

最优稳态炉温的确定是加热过程中温度控制的基础, 受到工艺和经济的约束: 加热过程中钢坯出炉

时的断面温差及其平均温度与目标值的误差和能耗必须最小. 因此, 优化目标函数选为

$$J(T_r) = \left\{ \frac{1}{2} k_1 [T_a^* - T_a(T_r)]^2 + \frac{1}{2} k_2 [T_s(T_r) - T_c(T_r)]^2 + \frac{1}{2} k_3 \int_0^{t_r} \|q(T_r, t)\| dt \right\}. \quad (2)$$

优化问题就是寻找一个最优稳态炉温设定向量 $T_r = [T_{r1} \ T_{r2} \ T_{r3}]^T$, 使得

$$\min J(T_r) \quad (3)$$

$$\text{s.t. } T_{rli} \leq T_{ri} \leq T_{rhi}, \quad i = 1, 2, 3. \quad (4)$$

其中: T_a^* 为钢坯出炉平均温度的目标值. $i = 1, 2, 3$ 表示预热、加热和均热区. T_{rli} 和 T_{rhi} 分别为各区温度所允许的下限和上限. k_1, k_2 和 k_3 ($k_1, k_2 \gg k_3$) 为加权系数.

为了减小加热过程中因表面熔化而产生的铁锈及脱碳, 钢坯表面的温度不得过高. 炉温不能超过耐火材料所容许的上限. 而且, 钢坯的温度梯度必须保持在一定范围内. 考虑到各区之间的强耦合影响, 炉长方向的炉温梯度也必须维持在一定范围内.

5 粒子群优化(Particle swarm optimization)

受群居行为的启发, 1995年Kennedy和Eberhart提出了PSO算法^[16]. 这是一种并行进化计算方法, 可用于求解多模态结构的非线性优化问题. PSO的初始种群由随机候选解组成, 这些候选解被定义为粒子. 每个粒子具有两个属性: 位置和速度. 根据自身经验和粒子群的社会信息, 调整粒子的速度和方向使得每个粒子“飞向”一个全局最优解. 通过这一搜索过程(即粒子的飞行)来对解空间进行搜索. 在稳态炉温优化中, 设 N_p 为粒子群的种群规模; $p_j(k)$ 为第 j 个粒子迄今所达到的最好解, $j = 1, \dots, N_p$; $p_g(k)$ 为整个种群迄今所达到的最好解. $z_j(k)$ 和 $v_j(k)$ 分别为第 k 次迭代第 j 个粒子的位置和速度, 可用下列运动方程调节:

$$\begin{cases} v_j(k+1) = \gamma(k)v_j(k) + c_1 r_1 [p_j(k) - z_j(k)] + \\ \quad c_2 r_2 [p_g(k) - z_j(k)], \\ z_j(k+1) = z_j(k) + v_j(k+1), \end{cases} \quad (5)$$

其中: γ 是惯性因子; c_1 和 c_2 为认知和社会系数, 反映了一个粒子指向一个最好位置的程度. 通过引入两个随机因子 r_1 和 r_2 使粒子群具备随机探索能力.

粒子的位置 $z_j(k)$ 由3个区的温度组成; 向量 $v_j(k)$ 表示搜索最优温度向量的速度和方向. 在飞行过程中, 第 j 个粒子被吸引到最好位置, 由它自己的前一个最好解 $p_j(k)$ 和整个种群的全局最好解 $p_g(k)$ 决定. 吸引强度由两个乘积项决定: $c_1 r_1$ 和 $c_2 r_2$. 不失一般性, 设 $c_1 = c_2$. r_1 和 r_2 是在 $(0, 1)$

范围内服从均匀分布的随机数. 一个适当的 $\gamma(k)$ 可防止过于频繁地改变粒子的飞行方向. 在优化过程中选择 $\gamma(k)$ 随迭代次数线性递减. 在本研究中, 这些参数选为: $N_p \in [20, 50]$; $c_1, c_2 \in [1.6, 2.4]$. 第 j 个粒子的适应度为其目标函数式(2)的值加0.1的导数.

尽管PSO能快速产生一个最优解, 但这种方法存在着种群退化、低精度和局部最优问题. 本文通过HPSO方法来解决这些问题.

6 混合粒子群优化(Hybrid particle swarm optimization)

本研究提出一种HPSO方法以克服PSO的缺陷. 根据一个查询表和插值运算获得一个初始稳态炉温向量, 进一步编码形成一个初始粒子. 该方法通过一种Logistic映射(参见文献[7])产生一个初始种群, 保证粒子群的多样性. 利用克隆提高搜索精度, 并引入基于密度的免疫选择机制来防止PSO的种群退化.

自适应免疫系统识别的分子被称之为抗原. 当一个抗原侵入到动物体内时, 该动物对此反应在骨髓中产生一个细胞群(称为B细胞)并产生抗体. 一个抗体是一个分子, 最初附着在B细胞表面并识别抗原. 每个B细胞分泌出针对某一抗原的单一类型的抗体. 抗原刺激B细胞增生扩散并成熟为最终的抗体分泌细胞(称为浆细胞)以及长寿命的B记忆细胞. 当第二次遇到抗原激励时, B记忆细胞分化出能够产生高适应度抗体的浆细胞. 这一细胞分化过程产生了克隆^[11]. 将克隆算子作用于全局最好解可提高PSO的搜索精度, 其中 $p_g(k)$ 被作为B记忆细胞, 抗体则为 $p_g(k)$ 的克隆粒子.

克隆在 $p_g(k)$ 的邻域内产生新粒子, 该邻域被定义为

$$SN(p_g(k)) = \{z : \|z - p_g(k)\| \leq R, \quad z \in \Omega, \quad R > 0\}. \quad (6)$$

其中: Ω 为候选解空间, $\|\cdot\|$ 为欧几里德范数, R 为扩展半径. 由于 R 的取值过大会降低优化算法的收敛速度, 过小则会降低搜索精度, 因此, 选择一个适当的 R 值非常重要. 本研究中, R 在 $[0.05, 0.1]$ 范围内取值.

抗体多样性为免疫系统的基本特点之一, 可通过选择机制得到保证. 选择基于抗体密度进行, 也就是与抗原亲和力大并且密度较低的抗体会以较高的概率被选择到下一代. 在进化过程中, 具有高适应度的粒子通常会幸存. 可是, 高适应度粒子的密度过高, 将会丢失适应度低但进化趋势较好的粒子, 这将降低种群的多样性, 因而导致局部最优. 在PSO中引入免疫选择可抑制退化趋势和局部最小, 从而提高算法的全局搜索能力. 本研究中, 优化的目标函数对应

于一个抗原, 包含炉温分布的粒子等价于一个抗体. 粒子的密度和选择概率引用了文献[15]的计算公式. 第 j 个粒子的密度为

$$D(z_j) = 1 / \sum_{n=1}^N |F(z_n) - F(z_j)|, \quad j = 1, 2, \dots, N. \quad (7)$$

其中: $N \geq N_p$; $F(z_j)$ 为第 j 个粒子的适应度. 第 j 个粒子的选择概率为

$$P(z_j) = \frac{1/D(z_j)}{\sum_{l=1}^N 1/D(z_l)}, \quad j = 1, 2, \dots, N. \quad (8)$$

由式(8), 与粒子 j 相似的粒子越多, 粒子 j 被选择进入新父代的机会就越少. 这样给低适应度个体提供了进化的机会.

将混沌机制、克隆和免疫与PSO融合的HPSO算法可用来解决加热炉的稳态炉温优化问题, 其具体步骤如下:

Step 1 确定优化参数. 即确定种群规模 N_p ; 选择 c_1, c_2 和式(6)中 R .

Step 2 构造初始种群. 首先, 通过查询表和插值运算获得一组炉温, 对其编码得到一个粒子; 然后, 利用混沌机制生成其它粒子 z_j , 从而形成一个粒子群. 初始速度 v_j 设为0, 粒子的前一个最优位置设为 $p_j = z_j$, 其中 $j = 1, \dots, N_p$. 并令 $k = 1$.

Step 3 通过评估粒子的适应度确定种群 $A(k)$ 的最好解 p_g . 如果当前种群包含最优个体, 则输出结果并停止运行; 否则, 转下一步.

Step 4 基于以下3种方式产生新粒子:

1) PSO: 按式(5)产生 N_p 个新粒子, 然后基于它们的适应度找出最好位置 $p_j(k)$ 和 $p_g(k)$;

2) 克隆: 在 p_g 的邻域内随机产生 m_1 个粒子(参见式(6));

3) 变异: 在解空间随机产生 m_2 个新粒子.

Step 5 基于密度选择粒子. 按式(8)计算Step 4中生成的 $N = N_p + m_1 + m_2$ 个粒子的选择概率; 然后, 基于粒子的概率从中选择 N_p 个粒子形成一个临时种群 $B(k)$.

Step 6 更新粒子群. 用全局最好位置 $p_g(k)$ 替换 $B(k)$ 中最差适应度粒子, 形成下一代种群 $A(k+1)$. 然后, 令 $k = k + 1$, 并转Step 3.

7 验证与讨论(Verification and discussion)

以上描述的HPSO方法被用来寻找一个蓄热推钢式加热炉的最优稳态炉温. 该加热炉的炉长26.3 m、炉宽6.4 m. 加热炉分为3个区: 预热、加热和均热区. 来自焦炉的高热值煤气和来自高炉的低热值煤气混合形成加热炉的燃料. 钢坯由推钢机推

入加热炉后, 依次通过3个加热区, 然后被送到轧机. 下面给出45#钢的验证结果. 钢坯入炉温度为环境温度(20°C). 钢坯出炉平均温度的目标值取决于钢坯型号, 在1130°C ~ 1250°C范围内. 钢坯出炉时的断面温差及其平均温度与目标值的误差都必须小于30°C.

7.1 钢温预报(Prediction of billet temperature)

加热时间 $t_r = 120$ min. 沿厚度方向钢坯被分为6层. 用式(1)预报钢坯温度和平均温度. 图2显示了测量温度和预报温度. 钢坯中心温度和表面温度的最大预报误差分别为29.8°C和27.8°C. 显然, 两者均小于30°C, 满足工程要求.




图2 由模型预报的钢坯温度

Fig. 2 Temperature of billet predicted by model

7.2 稳态炉温优化(Optimization of steady-state zone temperatures)

Nelder-Mead(N-M)单纯形法(参见文献[6])被广泛用于求解炉温优化问题. 本节将本文提出的HPSO方法与N-M单纯形法及人工操作法进行比较验证.

HPSO的参数选为: $c_1 = c_2 = 2$, $R = 0.1$, $N_p = 25$, $m_1 = 10$, $m_2 = 2$. N-M单纯形法的扩展和收缩系数分别选为1.2和0.8.

表1 出炉钢坯温度的预测结果

Table 1 Temperature estimation results of a billet at the exit

方法	$ T_a^* - T_a /^\circ\text{C}$	$ T_s - T_c /^\circ\text{C}$
人工操作	7.08	9.35
N-M单纯形	4.81	8.75
HPSO	1.72×10^{-4}	3.49

钢坯出炉的目标平均温度为1160°C. 表1显示了由人工操作、N-M单纯形法和HPSO所获得的加热过程中钢坯出炉时的断面温差及其平均温度与目标值的误差. 对于N-M单纯形法, 其值分别是人工操作时的67.9%和93.6%; 而采用HPSO, 它们只是人工操作时的0.00243%和37.3%. 显然, N-M单纯形法优于人工操作, 而HPSO则远远优于N-M单纯形法. 一个热轧厂的实际运行表明, 与该厂原有的人工操作相

比,引入HPSO稳态炉温优化使燃耗降低了12%.

7.3 HPSO与PSO的收敛特性比较(Comparison of convergence characteristics of HPSO and PSO)

图3显示了钢坯目标平均温度为1160°C时全局最好粒子的进化过程. HPSO和PSO的对应参数均相同,参见7.2部分. 值得注意的是PSO的全局最好粒子的适应度在第4代后不再有明显改善,这是由种群退化导致局部最小所造成的. 而HPSO的全局最好粒子的适应度一直改善到第21代. 由此结果可知,将免疫和克隆与PSO相结合的HPSO克服了PSO的退化问题并提供了较高的搜索精度.




图3 HPSO和PSO的进化曲线

Fig. 3 Evolutionary curves of HPSO and PSO

8 结论(Conclusions)

本文描述了确定一个蓄热推钢式加热炉的最优稳态炉温的HPSO方法. 该方法通过将混沌机制、免疫和克隆与PSO相结合,解决了PSO中存在的种群退化、局部最小等问题. 通过与广泛采用的N-M单纯形法和人工操作相比较,证实了该方法的有效性. 验证结果表明HPSO的全局搜索能力优于N-M单纯形法和人工操作. 实际运行结果表明与人工操作相比该方法不仅节省了燃料,产生了巨大的经济效益,而且通过降低钢坯出炉的平均温度偏差和断面温差提高了产品质量.

参考文献(References):

- [1] 柴天佑, 王中杰, 张莉. 加热炉的炉温优化设定模型[J]. 自动化学报, 2000, 26(4): 537 – 541.
(CHAI Tianyou, WANG Zhongjie, ZHANG Li. Optimal setting model of reheat furnace temperature[J]. *Acta Automatica Sinica*, 2000, 26(4): 537 – 541.)
- [2] 王锡淮, 李柠, 李少远, 等. 步进式加热炉建模和炉温优化设定策略[J]. 上海交通大学学报, 2001, 35(9): 1306 – 1309.
(WANG Xihuai, LI Ning, LI Shaoyuan, et al. Modeling and temperature optimal setpoint strategy for walking beam reheating furnace[J]. *J of Shanghai Jiao Tong University*, 2001, 35(9): 1306 – 1309.)
- [3] 王中杰, 柴天佑, 邵诚. 加热炉多模式动态优化控制策略[J]. 控制与决策, 1999, 14(5): 465 – 468.
(WANG Zhongjie, CHAI Tianyou, SHAO Cheng. Multimode dynamic optimization control strategy for reheating furnaces[J]. *Control and Decision*, 1999, 14(5): 465 – 468.)
- [4] HOOKE R, JEEVES T A. Direct search solution of numerical and statistical problem[J]. *J of the ACM*, 1961, 8(2): 212 – 229.
- [5] JOHN Y, JAMES C L, BOGJU L, et al. A hybrid approach to modeling metabolic systems using a genetic algorithm and simplex method[J]. *IEEE Trans on Systems, Man, and Cybernetics-Part B: Cybernetics*, 1998, 28(2): 173 – 191.
- [6] SWANN W H. A survey of non-linear optimization techniques[J]. *FEBS Letters*, 1969, 2(Suppl): S39 – S55.
- [7] JI M J, TANG H W. Application of chaos in simulated annealing[J]. *Chaos, Solitons and Fractals*, 2004, 21(4): 933 – 941.
- [8] ZHAO L, SHIEH L S, CHEN G R, et al. Simplex sliding mode control for nonlinear uncertain systems via chaos optimization[J]. *Chaos, Solitons and Fractals*, 2005, 23(3): 747 – 755.
- [9] SEO J H, IM C H, HEO C G, et al. Multimodal function optimization based on particle swarm optimization[J]. *IEEE Trans on Magnetics*, 2006, 42(4): 1095 – 1098.
- [10] SHAO X G, CHENG L J, CAI W S. An adaptive immune optimization algorithm for energy minimization problems[J]. *J of Chemical Physics*, 2004, 120(6): 11401 – 11406.
- [11] LEANDRO N D C, FERNANDO J V Z. Learning and optimization using the clonal selection principle[J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(3): 239 – 251.
- [12] MOHAN R A, RAJAN B, ERIC M D, et al. Base station location and channel allocation in a cellular network with emergency coverage requirements[J]. *European J of Operational Research*, 2005, 164(2): 301 – 323.
- [13] 高鹰, 谢胜利. 免疫粒子群优化算法[J]. 计算机工程与应用, 2004, 40(6): 4 – 6.
(GAO Ying, XIE Shengli. Particle swarm optimization algorithms with immunity[J]. *Computer Engineering and Applications*, 2004, 40(6): 4 – 6.)
- [14] WANG Q L, WANG C H, GAO X Z. A hybrid optimization algorithm based on clonal selection principle and particle swarm intelligence[C]//*Proc of IEEE Int Conf on Intelligent Systems Design and Applications*. Los Alamitos: IEEE Computer Society Press, 2006, 2: 975 – 979.
- [15] JIAO L C, WANG L. A novel genetic algorithm based on immunity[J]. *IEEE Trans on Systems, Man, and Cybernetics -Part A: Systems and Humans*, 2000, 30(5): 552 – 561.
- [16] KENNEDY J, EBERHART R C. Particle swarm optimization[C]//*Proc of IEEE Int Conf on Neural Networks*. Perth: IEEE Press, 1995, 4: 1942 – 1948.

作者简介:

廖迎新 (1966—), 女, 中南林业科技大学教授, 于2006年毕业于中南大学, 获工学博士学位, 现在东京工科大学作博士后研究工作, 目前主要研究方向是智能控制和系统优化, E-mail: yxliao0540@gmail.com;

吴敏 (1963—), 男, 1996年至1999年作为客座研究员在日本东京工业大学控制系统工程系进行国际合作研究, 获东京工业大学工学博士学位, 现为中南大学控制理论与控制工程博士点博士生导师, 主要研究兴趣是过程控制、鲁棒控制和智能系统, E-mail: min@csu.edu.cn;

余锦华 (1963—), 男, 于1993年毕业于日本东京工业大学, 获工学博士学位, 现为东京工科大学仿生学学部副教授, 主要研究兴趣是控制理论应用、重复控制、专家控制、网络教学与机器人, E-mail: she@cc.teu.ac.jp;

曹卫华 (1972—), 男, 中南大学副教授, 于2007年获中南大学控制理论与控制工程专业博士学位, 主要研究方向为多智能体系统、机器人技术和生产过程智能控制, E-mail: caowh@mail.csu.edu.cn.