

文章编号: 1001-0920(2005)12-1379-05

改进粒子群算法及其对热连轧机负荷分配优化的研究

王建辉^{a,b}, 徐 林^{a,b}, 闫勇亮^b, 顾树生^{a,b}

(东北大学 a 教育部暨辽宁省流程工业综合自动化重点实验室, b. 信息科学与工程学院, 沈阳 110004)

摘 要: 提出一种基于适应度方差的权重梯度方向变异的改进粒子群优化算法(IPSO), 通过判断适应度方差, 按照权重梯度方向进行变异操作, 解决了 PSO 算法的早熟收敛和易于陷入局部极值的问题. 应用 IPSO 算法对精轧机组负荷分配进行优化, 根据负荷分配优化策略, 给出综合板形板厚的最小方差目标函数, 在实现各机架负荷分配优化的同时, 提高板形质量. 仿真结果表明, 该算法计算精度高, 收敛速度快, 为精轧机组轧制规程的智能优化设计提供了一种新的有效方法.

关键词: 粒子群算法; 权重梯度方向; 变异; 热连轧机; 负荷分配优化

中图分类号: TP18; TG333.7

文献标识码: A

Improved PSO and Its Application to Load Distribution Optimization of Hot Strip Mills

XU L in^{a,b}, WANG J ian-hui^{a,b}, YAN Yong-liang^b, GU Shu-sheng^{a,b}

(a Key Lab of Process Industry Automation of Ministry of Education, b School of Information Science and Engineering, Northeastern University, Shenyang 110004, China Correspondent: XU L in, E-mail: xulinkn@263.net)

Abstract: An improved particle swarm optimization (IPSO) algorithm with the mutation in weighted gradient direction based on the evaluation of the fitness variance is presented, which can avoid the shorts of easily getting in local extremum and easy in premature convergence. The IPSO is used to optimize the scheduling of the finishing of hot strip mills. Based on the strategy of load distribution optimization, the minimum variance object function of shape and gauge control is proposed in the condition of making sure of good shape. It realizes the load distribution optimization. The results of emulation show that IPSO is more precise in calculating and more fast in convergence than others, and provides a new valid method for the intelligent optimum design of scheduling hot strip mills.

Key words: Particle swarm optimization algorithm; Weight gradient direction; Mutation; Hot strip mills; Load distribution optimization

1 引 言

热连轧精轧机组的轧制规程设定计算是决定产品质量和生产稳定性的重要因素, 而负荷分配是整个设定计算的核心环节, 负荷分配的合理与否不仅直接决定轧制过程应力状态特性, 而且对板形有着很大的影响, 同时对整个生产流程有着重要的影响. 因此, 在进行各机架设定计算时, 寻找一个最优

的压下负荷分配方案, 对有效利用设备能力, 保证产品质量起着很重要的作用.

热连轧精轧机组的负荷分配优化实质是确定一组机架出口厚度, 使整个机组工作状态达到最优^[1]. 传统的负荷分配优化方法多为建立在单目标约束条件基础上的寻优策略, 目前也有基于多目标的智能负荷优化设定, 如遗传算法等^[2], 但由于算法本身存

收稿日期: 2005-04-11; 修回日期: 2005-06-09

基金项目: 国家自然科学基金项目(60274024, 60474040).

作者简介: 王建辉(1957—), 女, 辽宁鞍山人, 教授, 博士, 从事智能控制理论及应用、网络环境下的先进控制技术等研究; 顾树生(1939—), 男, 黑龙江绥化人, 教授, 博士生导师, 从事智能控制理论及应用、网络环境下的先进控制技术等研究

在易于陷入局部极值和计算复杂度高不足,因此在实际应用中受到限制.

粒子群算法^[3]是基于群体智能的全局随机优化算法,起源于对鸟类捕食行为的模拟,与遗传算法类似,是一种基于迭代的优化工具.但与遗传算法相比,粒子群算法的优势在于其算法简单、易于实现,且需要调整的参数少.由于传统的粒子群优化算法存在早熟收敛、易于陷入局部极值的不足,因此本文提出一种基于适应度方差的权重梯度方向变异的改进粒子群优化算法,充分利用梯度信息中所包含目标函数的一些重要信息,通过判断适应度方差最小,进行变异操作,进一步修正速度更新,从而有效地避免了粒子群优化算法中早熟收敛问题,并将改进粒子群优化算法应用于热连轧精轧机组负荷分配优化问题.仿真结果表明,该算法结构简单、计算精度高、收敛速度快,为热连轧精轧机组轧制规程的智能优化设计提供了有效的方法.

2 基于权重梯度方向变异的改进粒子群算法

2.1 基本粒子群(BPSO)算法

BPSO算法在每一次迭代中,粒子通过跟踪两个“极值”来进行自我调整.第一个就是粒子本身所经历过的最优解,称为个体极值 p_i ;另一个极值是整个种群目前找到的最优解,称为全局极值 p_g .

对于在 D 维空间中的一个优化问题,BPSO算法利用下列公式计算 t 代的第 d 维($d = 1, 2, \dots, D$)的速度和位置^[4]:

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

$$x_{id}^t = x_{id}^{t-1} + v_{id}^t. \quad (2)$$

式中: v_{id}^t 为第 i ($i = 1, 2, \dots, m$)个粒子在 t 代的第 d 维空间的速度; x_{id}^t 为第 i 个粒子在 t 代的第 d 维空间的位置; w 为惯性权重,起调整粒子运动快慢的作用; c_1 和 c_2 为加速度常数,其取值决定向 p_i 和 p_g 移动的速度的变化,取值越大,粒子移向 p_i 和 p_g 的加速度就越大,一般取2; $r_1()$ 和 $r_2()$ 为 $[0, 1]$ 范围内变化的随机数.

2.2 基于权重梯度方向变异的改进粒子群优化算法(IPSO)

在BPSO算法中,由于整个搜索过程依赖于全体历史最优点和个体历史最优点的经验,在后期搜索时可能会因大的惯性而导致局部搜索能力较弱,影响搜索精度.另一方面,搜索过程中粒子群的趋同性,使算法易于陷入局部极值.

考虑到粒子总是向适应度函数值高的方向群

游^[5],因此对群体中所有粒子按照适应值的高低进行排序,在粒子速度更新中,选取适应值高的前 n ($1 < n < m$)个粒子的信息,使粒子的移动更具针对性和效率,同时考虑到最大速度的约束,粒子的速度更新可由下式确定:

$$v_{id}^t = w v_{id}^{t-1} + c_1 r() (p_{id} - x_{id}^{t-1}) + \frac{1}{n} \sum_{i=1}^n c_2 R_i() (p_{gdi} - x_{id}^{t-1}),$$

$$v_{id}^t = \begin{cases} v_{max}, & v_{id}^t > v_{max}; \\ -v_{max}, & v_{id}^t < -v_{max}. \end{cases} \quad (3)$$

式中: p_{gdi} 为整个种群中所有粒子根据其个体极值 p_{id} 所对应的按适应值大小排序后选取的前 n 个粒子在解空间中的位置; $R_i()$ 为 $[0, 1]$ 范围内变化的随机数.

由式(3)可知,粒子的运动速度不仅与其历史飞行经验和其他邻近粒子的飞行经验有关,而且受最大飞行速度的限制.

大量实验表明,粒子群算法无论是早熟还是达到全局最优解,粒子群中的粒子都会聚集在搜索空间内的某一特定位置,因此可通过判断适应度方差最小来判断^[6].

设第 t 代第 i 个粒子的适应值为 f_i^t ($i = 1, 2, \dots, m$); f_{avg}^t 为粒子群当前的平均适应值, $f_{avg}^t = \frac{1}{m} \sum_{i=1}^m f_i^t$; σ_t^2 为第 t 代粒子群体适应度方差,则 σ_t^2 可定义为

$$\sigma_t^2 = \sum_{i=1}^m (f_i^t - f_{avg}^t)^2. \quad (4)$$

设归一化后的群体适应度方差为 $\bar{\sigma}$,用来表征粒子的收敛程度,则 $\bar{\sigma}$ 可定义为

$$\bar{\sigma} = \sigma_t^2 / \alpha_{max}^2, \quad (5)$$

其中 α_{max}^2 为从第1代到第 t 代的群体最大适应度方差, α_{max}^2 的取值为

$$\alpha_{max}^2 = \max\{\sigma_j^2, j = 1, 2, \dots, t\}. \quad (6)$$

设粒子群在第 k 代时达到全局极值 p_m ,即

$$\lim_{t \rightarrow +\infty} p_g(k) = p_m, \quad (7)$$

显然如果全局极值为 p_m ,粒子将在位置更新公式的作用下向 p_m 靠拢,其间将不断地更新个体极值 p_i .如果粒子没有搜索到比 p_m 更好的位置,则粒子的个体极值将等于 p_m ,即

$$\lim_k p_i(k) = p_m. \quad (8)$$

式(8)表明,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最优极值,且所有的粒子将聚集到该位置.

设粒子在第 k 代达到全局最优,即 p_m 为全局最

优点, 则此时粒子的适应值为

$$f_i^k = f(p_m), i = 1, 2, \dots, m. \quad (9)$$

粒子的平均适应值为

$$f_{avg}^k = f(p_m), \quad (10)$$

整理可得

$$\overline{\sigma}_k \quad \text{min.} \quad (11)$$

显然当群体适应度方差最小时, 粒子群算法达到全局极值点, 此时还要通过理论全局最优解或期望最优解 f_d 来判断是否为最优解. 如果此时已经得到全局最优解, 则认为算法达到全局收敛; 反之, 则表明算法陷入局部极值.

如果算法陷入局部极值, 则可根据基于权重梯度方向^[7]的变异机制对全局最优值进行变异操作, 改变粒子的方向, 从而使粒子进入其他区域搜索.

梯度信息中包含着目标函数的一些重要信息, 对于函数 $f(x), x = (x_1, x_2, \dots, x_n)$, 其梯度可表示为

$$\nabla f(x) = \left[\frac{\partial f(x)}{\partial x_1}, \frac{\partial f(x)}{\partial x_2}, \dots, \frac{\partial f(x)}{\partial x_n} \right]^T, \quad (12)$$

权重梯度方向定义为

$$D(x) = \nabla f(x) - \sum_{j=1}^n w_j \nabla g_j(x). \quad (13)$$

式中: $g_j(x) \{x \in R^n, j = 1, 2, \dots, n\}$, 为具有 n 个约束条件的非线性规划问题的约束条件; w_i 为梯度方向权重, 定义为

$$w_i = \begin{cases} 0, & g_j(x) = 0, \\ \delta_j, & g_j(x) > 0; \end{cases} \quad (14)$$

$$\delta_j = \frac{1}{g_{\max}(x) - g_j(x) + \delta}; \quad (15)$$

$$g_{\max}(x) = \max\{g_j(x), j = 1, 2, \dots, n\}; \quad (16)$$

其中 δ 为一个很小的整数.

因此, 全局最优值 p_g 沿权重梯度方向的变异便可描述为

$$p_g^t = p_g^{t-1} + \eta D(p_g^{t-1}), \quad (17)$$

其中 η 为服从 Gauss(0, 1) 分布的随机变量.

综上, 根据粒子的适应值对粒子速度更新公式进行了改进, 同时根据粒子适应度方差, 提出了基于权重梯度方向变异的改进粒子群优化算法.

为验证上述算法的有效性, 使用 Griewank 和 Rosenbrock 函数进行测试.

Griewank 函数为

$$f(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1 \quad (18)$$

Rosenbrock 函数为

$$f(x) = \sum_{i=1}^n (100(x_i^2 - x_{i+1})^2 + (1 - x_i)^2). \quad (19)$$

测试时, 维数取 30, 种群规模为 50, 惯性权重 w 从 1.2 变化到 0.4, 最大迭代次数为 3000. IPSO 算法中 $n = 10, \delta = 1$, 各进行 50 次测试取平均值, 实验结果分别见表 1 和表 2.

表 1 Griewank 测试函数对比测试结果

算法	平均迭代次数	理论最优解	平均最优解	搜索成功率/%	成功搜索时间/s	方差
PSO	3 000	0	0.235 4	82.3	35.3	0.029 8
IPSO	1 799	0	0.001 6	96.9	27.7	< 0.001

表 2 Rosenbrock 测试函数对比测试结果

算法	平均迭代次数	理论最优解	平均最优解	搜索成功率/%	成功搜索时间/s	方差
PSO	3 000	1	0.991 3	83.3	28.3	0.025 1
IPSO	1 356	1	0.998 1	97.9	22.5	< 0.001

通过仿真可以看出, 基于权重梯度方向变异的改进粒子群算法比基本粒子群算法精度高, 收敛速度快.

3 基于 IPSO 的精轧机组负荷分配的优化算法

由于按经验公式进行负荷分配的方法虽然合理但并非最优, 因此本文利用 IPSO 算法对各机架的负荷分配进行优化, 根据板形板厚综合控制策略通过引入最小方差目标函数, 在实现各机架负荷分配优化的同时, 提高板形质量.

精轧机组的轧制过程分 3 个阶段^[8]: 第 1 机架考虑带坯厚度波动及咬钢等因素, 使压下量留有一定的空间; 第 2, 3 机架要充分利用设备的能力, 使压下量尽可能大; 从第 4 机架开始, 要综合考虑板形板厚精度和性能指标要求, 轧制力逐渐依次递减. 因此负荷分配的优化策略为: 前几个机架以负荷均衡为目标, 后几个机架则综合考虑板形板厚精度和性能要求.

保证板厚精度就是合理地分配各机架负荷, 使出口的厚度达到期望目标, 厚度目标函数以带钢出口实测厚度与成品目标厚度之间的方差最小为目标; 考虑到精轧机组板形控制以及后续工序的需要, 第 7 机架出口带钢通常带有一定比例的凸度, 凸度目标函数以第 7 机架出口带钢的实测凸度与目标凸度方差最小为目标; 因为保证带钢平直度良好的条件是保证各机架带钢入口和出口的相对凸度趋于一致, 所以根据负荷分配优化策略, 相对凸度目标函数以从第 4 机架开始的入口相对凸度与出口相对凸度的方差最小为目标函数. 因此, 本文使用的综合考虑板形板厚的最小方差目标函数为

$$J = \text{min} \{ (p_1 - \tilde{P}_1)^2 + (p_2 - \tilde{P}_2)^2 + (h_n - \tilde{h}_n)^2 +$$

$$(C_{Rn} - \tilde{C}_{Rn})^2 + \sum_{i=4}^7 \left[\frac{C_{Ri}}{h_i} - \frac{\tilde{C}_{Rn}}{h_n} + \Delta_i \right]^2 \quad (20)$$

式中: P_m 和 \tilde{P}_m 分别为第 m ($m = 1, 2$) 机架的实测轧制力和目标轧制力, h_n 为成品带钢厚度, \tilde{h}_n 为成品目标带钢厚度, C_{Rn} 为出口实测凸度, \tilde{C}_{Rn} 为出口目标凸度, C_{Ri}/h_i 为第 i 机架相对凸度, \tilde{C}_R/h_n 为出口相对凸度, Δ_i 是与容许相对凸度偏差有关的调节量。

利用负荷分配经验公式确定各机架出口厚度的基础值, 即

$$\bar{h}_i = H_0 \exp \left[\frac{K_2 - \sqrt{K_2^2 + 4K_1 E_\Sigma \Psi_i}}{2K_1} \right] \quad (21)$$

式中: \bar{h}_i 为第 i 机架经验出口厚度, H_0 为来料厚度, K_1 和 K_2 为能耗公式系数, E_Σ 为所有机架总能耗, Ψ_i 为累计能耗分配系数。

为实现最优负荷分配值, 先利用式(21) 计算各机架的出口厚度基础值作为负荷分配的基准值, 然后再利用 IP SO 算法对各机架 h_i 在 $[\delta h_i, dh_i]$ 的范围内进行优化, 以确定同时满足式(20) 最小方差目标函数和设备工艺限定条件的最优负荷分配值。

用 IP SO 算法实现热轧负荷分配优化的主要步骤如下:

- 1) 初始化群体, 随机设置各粒子的位置和速度;
- 2) 计算各个粒子的适应值, 并将其从大到小进行排序;
- 3) 对各粒子个体最优及群体最优值进行更新;
- 4) 按式(3) 对粒子速度进行更新;
- 5) 按式(2) 对粒子位置进行更新;
- 6) 更新粒子的个体极值和群体极值;
- 7) 按式(4) 计算群体适应度方差, 判断是否小于一个特定的值或零, 如果满足条件, 判断是否是局部极值, 如果是, 执行 8), 否则执行 9);

8) 按式(17) 执行变异操作;

9) 判断是否达到停止条件, 如果满足, 迭代过程停止, 返回当前最优个体为计算结果, 否则返回 3)。

4 仿真实例

本文分别采用经验分配、基本 PSO 和 IP SO 3 种方法对某钢厂热连轧生产现场实测数据进行了优化计算。

钢种为 Q 235B, 优化算法所需样本数据为: 带宽 $B = 1\ 200$ mm, 来料厚度 $H_0 = 36\ 7$ mm, 成品厚度 $h_n = 5\ 7$ mm, 粗轧机出口温度 $t_{rc} = 1\ 067$, 精轧机出口温度 $t_{fc} = 891$, 目标凸度 $CR_n = 0\ 016$ mm。

仿真中采用种群大小为 $m = 100$, 惯性权重 w 从 1.2 变化到 0.4, 最大代次为 3 000

目标函数中的 Δ_i 为目标函数最优调节量, 可在小于机架容许凸度偏差的情况下选取, 以便调整优化模型。

图 1 为 3 种分配方法的机架轧制力分配情况, 可以看出, IP SO 和 BPSO 方法都保证了 $F_1 \sim F_3$ 轧制力的合理分配。

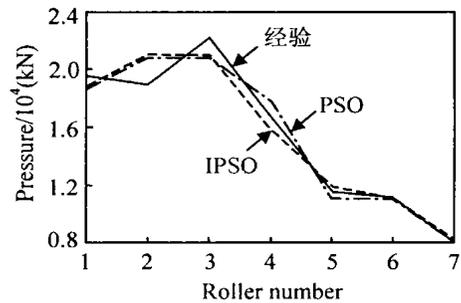


图 1 3 种方法的各机架轧制力分配对比

表 3(轧制力分配情况)、表 4(相对凸度分配) 和表 5(出口厚度分配情况) 则表明, 在保证轧制力合理分配的情况下, IP SO 优化能保证更好的凸度, 且不破坏平直度, 因此使用 IP SO 更为合理。

表 3 各机架轧制力分析结果对比 (kN)

优化	F_1	F_2	F_3	F_4	F_5	F_6	F_7
经验分配	19 470	18 911	22 212	16 695	11 637	11 164	8 051.6
PSO	18 655	207 28	20 727	17 797	11 114	11 061	8 131
IP SO	18 857	20 952	20 952	15 810	11 856	10 999	8 311

表 4 各机架相对凸度分配结果对比 (10^{-3})

优化	$\frac{CR_1}{h}$	$\frac{CR_2}{h}$	$\frac{CR_3}{h}$	$\frac{CR_4}{h}$	$\frac{CR_5}{h}$	$\frac{CR_6}{h}$	$\frac{CR_7}{h}$
经验分配	1.5	1.94	3.32	3.27	2.8	3.02	2.7
PSO	1.36	2.26	3.19	3.07	2.87	3.008	2.758
IP SO	1.33	2.19	3.03	3.55	2.70	3.046	2.697

表 5 各机架出口厚度分配比较 (mm)

优化	h_1	h_2	h_3	h_4	h_5	h_6	h_7
经验分配	25.53	18.57	12.66	9.55	7.84	6.52	5.7
PSO	26.240	17.648	12.418	9.639	7.860	6.581	5.70
IPSO	26.467	18.062	12.948	9.385	7.835	6.539	5.70

图 2 给出了 IPSO 和 BPSO 在优化过程中的收敛情况,可以看出,BPSO 算法初期收敛很快,但在一定代次之后就落后于 IPSO;而 IPSO 在初期收敛速度就与 BPSO 相近,且其机理也保证了较 PSO 充分的全局遍历,同时也提高了收敛精度。

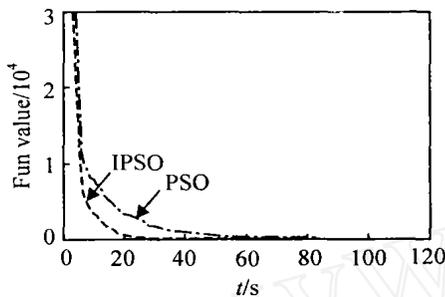


图 2 IPSO 及 PSO 优化的收敛性能

5 结 论

本文通过判断适应度方差,提出了基于权重梯度方向变异的改进粒子群优化算法.该算法收敛速度快,算法精度高,有效地避免了基本粒子群算法存在的早熟收敛和易于陷入局部极值的问题.将该算法应用于精轧机组负荷分配优化问题,根据负荷分配优化策略,给出综合板形板厚的最小方差目标函数,实现了各机架负荷分配的优化,同时,提高了板形质量.仿真结果证明了算法的有效性.

参考文献(References)

- [1] 孙一康. 带钢热连轧的模型与控制[M]. 北京: 冶金工业出版社, 2002.
(Sun Y K. Model and Control of Hot Strip Mill [M]. Beijing: Press of Metallurgy Industry, 2002.)
- [2] 孙晓光, 傅云义, 胡庆祥, 等. 遗传算法对热轧带钢精轧机组负荷分配BP网络参数的优化[J]. 钢铁, 1998, 33(7): 33-36.
(Sun X G, Fu Y Y, Hu G X, et al. BP Networks Optimization of Scheduling on Hot Strip Mill Using Genetic Algorithm [J]. Iron and Steel, 1998, 33(7): 33-36.)
- [3] Kennedy J, Eberhart R. Particle Swarm Optimization [A]. Proc of the 1995 IEEE Int Conf on Neural Networks [C]. Perth, 1995: 1942-1948.
- [4] Shi Y, Eberhart R. A Modified Particle Swarm Optimizer [A]. IEEE Int Conf of Evolutionary Computation [C]. Anchorage, 1998: 69-73.
- [5] Eberhart R, Kennedy J. A New Optimizer Using Particle Swarm Theory [A]. Proc 6th Int Symposium on Micro Machine and Human Science [C]. Nagoya, 1995: 39-43.
- [6] 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.
(L ü Z S, Hou Z R. Particle Swarm Optimization with Adaptive Mutation [J]. Acta Electronica Sinica, 2004, 32(3): 416-420.)
- [7] 唐加福, 汪定伟, 许宝栋, 等. 基于评价函数的遗传算法求解非线性规划问题[J]. 控制与决策, 2000, 15(5): 573-576.
(Tang J F, Wang D W, Xu B D, et al. Evaluation-based Genetic Algorithm for Non-linear Programming Problem [J]. Control and Decision, 2000, 15(5): 573-576.)
- [8] 王焱, 刘景录, 孙一康. 免疫遗传算法对精轧机组负荷分配的优化[J]. 北京科技大学学报, 2002, 24(3): 339-341.
(Wang Y, Liu J L, Sun Y K. Immune Genetic Algorithms (IGA) Based Scheduling Optimization for Finisher [J]. J of University of Science and Technology Beijing, 2002, 24(3): 339-341.)