

文章编号: 1001-0920(2009)11-1713-06

一种多目标粒子群改进算法的研究

徐 鸣¹, 沈 希², 马龙华¹, 黄跃进², 胡 娟³, 顾江萍², 金华强², 钱积新¹

(1. 浙江大学 信息科学与工程学院, 杭州 310027; 2. 浙江工业大学
机械工程学院, 杭州 310014; 3. 加西贝拉压缩机有限公司, 嘉兴 314000)

摘 要: 针对多目标粒子群优化过程中的粒子飞行偏向性和多样性损失问题, 提出一种基于最大最小适应函数的改进算法. 该算法在最大最小适应函数的计算中引入了函数相对值算法和 ϵ -支配的概念, 并提出了变 ϵ -支配的策略, 改进了最大最小适应函数的计算方法, 解决了粒子飞行过程中的偏向性和多样性损失问题, 加快了算法的收敛速度. 将该改进算法应用于直流变频压缩机启动时峰值电流和启动转速的优化问题, 应用结果表明该算法收敛速度快且效果良好.

关键词: 多目标优化; 粒子群算法; 最大最小适应函数; 变 ϵ -支配

中图分类号: TP301 **文献标识码:** A

Research on modified multi-objective particle swarm optimization

XU Ming¹, SHEN Xi², MA Long-hua¹, HUANG Yue-jin², HU Juan³, GU Jiang-ping², JIN Hua-qiang², QIAN Ji-xin¹

(1. College of Information Science and Engineering, Zhejiang University, Hangzhou 310027, China; 2. College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014, China; 3. Jiaxipera Compressor Company Limited, Jiaxing 314000, China. Correspondent: SHEN Xi, E-mail: sx@zjut.edu.cn)

Abstract: According to multi-objective optimization problem, a modified multi-objective particle swarm optimization algorithm is proposed based on maximin fitness function. Maximum-minimum relative algorithm is introduced to the computation of maximin fitness function value, which solves the skewed popularity of the particles in the flight process. Besides, the conception of ϵ -dominance is imported to the computation of maximin fitness function value. A modified computation method and an alterable ϵ -dominance strategy are proposed, which effectively improved the convergence speed of the algorithm and the diversity of the particles. The modified multi-objective particle swarm optimization algorithm is applied to starting performance optimization of direct current (DC) inverter compressor. The results show that the convergent speed of the algorithm is fast and the result is valid.

Key words: Multi-objective optimization; Particle swarm optimization algorithm; Maximin fitness function; Alterable ϵ -dominance

1 引 言

在工程优化、智能控制和人工智能等领域, 会遇到大量的多目标优化问题. 因此, 将进化算法应用于多目标优化的研究越来越广泛, 现已成为不同学科领域设计与决策工作的有效工具.

多目标优化问题一般很少存在唯一的全局最优解, 大多存在一个非劣解集(Pareto 解集). 实际应用中, 多目标优化问题往往是如何寻求 Pareto 解集中

的一个或多个满意解. 传统的多目标算法往往将多目标优化问题转换成单目标问题后, 利用成熟的单目标优化算法求解, 其缺点在于一次优化求解只能求出一个解. 而理想的进化多目标策略越来越趋向于能通过一次并行计算求解出足够多的解分布在 Pareto 前沿上, 以供决策者下一步决策. 粒子群优化算法(PSO)作为一种新颖的进化计算策略, 近些年已越来越广泛地应用于多目标优化问题的求解, 并

收稿日期: 2008-12-01; 修回日期: 2009-04-22.

基金项目: 国家自然科学基金项目(60474064); 浙江省杰出青年基金项目(R106768); 浙江省重大科技专项基金项目(2006C11002).

作者简介: 徐鸣(1981—), 男, 浙江金华人, 博士生, 从事多目标优化、鲁棒优化的研究; 沈希(1966—), 男, 浙江湖州人, 教授, 博士, 从事机电一体化技术、制冷系统测量与控制等研究.

涌现出许多基于 PSO 的多目标优化算法^[1-4].

2 多目标优化问题

通常,一个多目标优化问题可描述为

$$\begin{aligned} \min(\max) f(\mathbf{x}) = & \\ & (f_1(\mathbf{x}), \dots, f_n(\mathbf{x}), \dots, f_N(\mathbf{x})). \quad (1a) \\ \text{s. t. } g_j(\mathbf{x}) \leq & 0, j = 1, 2, \dots, \alpha; \\ h_k(\mathbf{x}) = & 0, k = 1, 2, \dots, \beta; \\ x_{d\min} \leq x_d \leq & x_{d\max}, d = 1, 2, \dots, D. \quad (1b) \end{aligned}$$

式中: \mathbf{x} 为 D 维向量, N 为优化目标总数, $f_n(\mathbf{x})$ 为第 n 个目标函数, $g_j(\mathbf{x})$ 为第 j 个不等式约束, $h_k(\mathbf{x})$ 为第 k 个等式约束, α 和 β 为不等式约束、等式约束的总数, $x_{d\min}$ 和 $x_{d\max}$ 为每维向量搜索上下限.

传统多目标优化的研究方法很多,如分量加权法和法、理想点法、主要目标法和评价函数法等. 这些方法都是基于单目标进行求解的方法. 近几年,研究人员将进化算法引入多目标优化问题,其中比较典型的有:Coello 等^[1] 提出在非劣最优基础上应用“容器”记录已经找到的非支配向量,并指导其他粒子飞行;Pulido 等^[2] 将聚类技术引入 PSO 多目标优化算法,将微粒群分为若干子群,对每个聚集的子群分别优化并相互交流信息,从而达到整个群体的最优化;Mostaghim 等^[3] 提出了 ϵ -支配的概念,其算法加速了收敛速度,并提高了非劣解的均匀度;Balling^[4] 提出了最大最小(maximin)适应函数策略,在不需要附加的类聚和小生境等技术的情况下,就可以使非劣解达到均匀分布的目的;Li^[5] 则在 Balling^[4] 的基础上提出一种基于 maximin 适应函数策略的多目标粒子群算法. 所有这些算法都要完成两个主要任务:一是引导种群向 Pareto 前沿移动;二是保持总群在 Pareto 前沿上的多样性.

3 粒子群优化算法

PSO 算法是 1995 年 Kennedy 等^[6,7] 提出的一种演化计算技术,来源于一个简化社会模型的仿真过程. 其理论基础主要包括 3 个基本因素:粒子的评价、与近邻的比较和对领先近邻的模拟^[8,9]. 作为一种高效并行优化算法,PSO 算法可用于解决大量非线性、不可微和多峰值的复杂优化命题,而且算法程序简洁,需要调整的参数相对较少.

PSO 算法中每个粒子都是解空间的一个解,每个粒子根据自己的飞行经历和同伴的飞行经历来调整自己的飞行线路. 其中: $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{iD})^T$ 表示第 i 个粒子的当前位置; $\mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{iD})^T$ 表示第 i 个粒子曾经到过的最佳位置,用下标 g 表示这群粒子中位置最优的个体,即 \mathbf{p}_g ; $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{iD})^T$ 表示第 i 个粒子的速度,每个粒子都通过速度更新和位置更新的方式产生新一代个体,整个种

群不断地迭代,从而达到寻优的目的. 这里速度更新和位置更新公式如下:

$$\begin{aligned} v_{id}(t+1) = & \\ & \omega \cdot v_{id}(t) + c_1 \cdot r_1 \cdot (p_{id}(t) - X_{id}(t)) + \\ & c_2 \cdot r_2 \cdot (p_{gd}(t) - x_{id}(t)), \quad (2) \end{aligned}$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1). \quad (3)$$

其中: $i = 1, 2, \dots, M$, M 为种群数量;参数 c_1 和 c_2 分别称为认知(Cognitive)和社会(Social)参数; ω 为惯性权重; r_1 和 r_2 分别取两个相互独立并在 $[0, 1]$ 之间的随机数,并服从均匀分布.

4 多目标粒子群优化改进算法


4.1 maximin 适应函数的改进

maximin 是由 Balling 提出,并应用于多目标优化问题. 根据定义,第 i 个粒子(向量) \mathbf{x}_i 的 maximin 适应值可表示为^[5]


$$f_{\text{maximin}}(\mathbf{x}_i) = \max_{j \neq i} \{ \min_k \{ f_k(\mathbf{x}_i) - f_k(\mathbf{x}_j) \} \}. \quad (4)$$

其中: $i, j = 1, 2, \dots, M; k = 1, 2, \dots, N$. 显然,所有 f_{maximin} 值小于零的粒子都是非劣解^[5]. 这个独特的性质使得 maximin 适应函数成为一个求解多目标优化问题的有效工具. maximin 适应函数值具有“奖励”分散的非劣解,“惩罚”聚集的非劣解的特性^[10]. 非劣解的适应函数值越小,该非劣解相对于其他非劣解越孤立. 根据这一特性,如果应用轮盘法为每一个粒子在非劣解集选取 p_g ,则非劣解的适应函数值越小,该非劣解选作 p_g 的概率越高.

上述 maximin 适应函数建立过程存在一个问题:如果多个目标函数值在同一个数量级下,则计算




(a) 目标函数具有同一数量级




(b) 目标函数差一个数量级

图 1 目标函数在不同数量级下的粒子适应函数值对比


得到的适应函数值没有偏向性或不明显. 如图 1(a) 所示, $A(0,1), B(0.5, 0.5)$ 和 $C(1,0)$ 点的 maximin 适应函数值分别为 $-0.5, -0.5$ 和 -0.5 . 但如果多个目标函数值处于不同数量级下, 如图 1(b) 所示, 这里 f_1 比 f_2 少了一个数量级, 计算得到非劣解集的 A, B 和 C 点的适应度值分别为 $-0.05, -0.5$ 和 -0.5 . 如果按照轮盘法在其中选择 p_g , 则粒子群将会以更大的概率向 B 和 C 方向飞行, 也就是向数量级小的目标飞行.




(a) 算法调整前 ZDT_1 结果



(b) 算法调整后 ZDT_3 结果



(c) 算法调整前 ZDT_1 结果



(d) 算法调整后 ZDT_3 结果

图 2 算法调整前后仿真结果对比

本文以 Zitzler^[11] 提出的测试函数 ZDT1 和 ZDT3 为原型, 对 f_1 降了 2 个数量级, 记为 ZDT_1 和 ZDT_3, 仿真结果如图 2(a) 和图 2(b) 所示.

从图 2(a) 和图 2(b) 可以看出, 该算法可以搜索到 Pareto 前沿, 但粒子在 f_1 端排列紧密, 在 f_2 端排列松散, 粒子不是均匀分布, 容易造成前沿粒子多样性的破坏, 有时甚至无法找到 Pareto 前沿. 为了在一定程度上解决以上问题, 将某些多目标经典算法(如功效系数法、最大最小选择法)中每迭代一步都进行规范化操作的思想引入 maximin 算法. 相对于对所有粒子进行规范化处理, 仅对非劣解集中粒子进行处理将大大提高算法的效率. 因此, 对非劣解集中每个微粒的所有目标适应函数 $f_k(x_i)$ 进行调整, 调整方法如下:

$$f_k(x_i) = \frac{f_k(x_i) - \min_k(f_k(x_i))}{\max_k(f_k(x_i)) - \min_k(f_k(x_i))}. \quad (5)$$

将粒子目标函数值 $f_k(x_i)$ 代入式(4), 可以计算得到 x_i 的最新 maximin 适应值. 按此方法计算图 1(b) 所示 A, B 和 C 点, 其 maximin 适应值又恢复为 $-0.5, -0.5, -0.5$. 因此, 对于 ZDT_1 和 ZDT_3 引入该算法后, 可以有效解决粒子因目标函数值差异所导致的偏向性问题. 仿真结果如图 2(c) 和图 2(d) 所示, 显然粒子的排列比图 2(a) 和图 2(b) 均匀很多.

4.2 ϵ -支配策略的引入和改进

ϵ -支配由 Teich^[3] 提出, 其定义如下: 如果一个决策向量 $x_j \in \Omega$, ϵ -支配另一个决策向量 $x_i \in \Omega$, 则必须满足如下 2 个条件:

$$\begin{cases} \frac{f_k(x_j)}{1+\epsilon} \leq f_k(x_i), \quad \forall k = 1, 2, \dots, N; \\ \frac{f_k(x_j)}{1+\epsilon} < f_k(x_i), \quad \text{至少一个 } k = 1, 2, \dots, N. \end{cases} \quad (6)$$

将 ϵ -支配的概念引入 maximin 适应函数值的计算, 则式(4) 根据其定义可更改为

$$f_{\text{maximin}}(x_i) = \max_{j \neq i} \{ \min_k \{ f_k(x_i) - f_k(x_j) / (1 + \epsilon) \} \}. \quad (7)$$

ϵ -支配概念的引入, 增加了粒子的支配区域, 有利于算法剔除距离比较近的非劣解, 提高粒子排列的均匀性. 事实上, 粒子的适应值只与相邻的非劣粒子有关. 设有 3 个非劣解 A, B 和 C , 如图 3 所示. 如果以 $B(1,1)$ 作为参照点(如图 3(a) 所示), 则 A 或 C 分布在灰色区域内, B 点的适应值将变为正, 从而剔除; 如果以 $A(0,1)$ 和 $C(1,0)$ 作为参照点(如图 3(b) 所示), 则 B 分布在灰色区域内, B 点的适应值将变为正, 从而剔除. 可以看出, 引入 ϵ -支配以后, 图

中无论以 B 点为参照还是以 A 和 C 为参照, B 点都从非劣解变为了劣解, 这样不仅可以增加粒子分布的均匀性和多样性, 而且加快了整个种群向 Pareto 前沿的收敛速度.




图 3 不同参照点下的 ϵ 支配区域对比

ϵ 的选取, 其目的就是为了使非劣解达到均匀分布, 因此 ϵ 的选取非常重要. 本文以 ZDT1 和 ZDT3 为例, 通过选取不同的 ϵ 值分别进行 30 次仿真试验, 其结果如表 1 和表 2 所示. 其中: EA 为外部

集大小; SP, Δ' 和 MDG 分别为间距指数、分布指数和最小距离指数^[12]. 从表中可以看出, 随着 ϵ 取值的成倍降低, SP, Δ' 和 MDG 值也基本成倍降低, 这说明随着 ϵ 的降低, 粒子的分布率越来越好, 但同时也会导致 EA 成倍增加. 由于算法的时间复杂度为 $O(ea^2)$ (ea 为外部集中实际非劣解个数), 算法因 ϵ 取值的降低所消耗的时间将会以指数形式快速增长. 折中期间, 建议控制外部集大小 $EA = 100$.

另外, 从表 1 和表 2 还可看出, 对于不同问题, ϵ 的取值对外部集的影响很大, 通过多次试验确定初始的 ϵ 大概为 $\epsilon_{set} = 10/EA$, 目的是为了确在算法运行的初期有一定数量的非劣解 (10% ~ 20% 的 EA) 来保证整个种群向一个均匀的方向飞行. 如果不能满足, 则可以降低 ϵ_{set} , 甚至可以取负值. 在算法运行的中后期, 为了保证外部集能够被非劣解占满, 可根据目前外部集中非劣解个数动态调整 ϵ 的取值. 其作用是: 在算法进行的初期, 较大的 ϵ 值有利于全局搜索, 并加快粒子的收敛速度, 降低算法在时间上的消耗; 在算法的后期, 较小的 ϵ 值有利于局部搜索, 保证 Pareto 前沿所有非劣解的均匀程度.

4.3 算法流程

算法的主要流程如下:

Step1: 初始化. 给定粒子种群数 M , 随机产生 M 个粒子, 并存放在 DomList 中. 设每个粒子的个体最优位置即为初始位置, 并初始化初始速度为 0, 初始化 ϵ_{set} .

表 1 ZDT1 仿真结果

ϵ	EA	SP	Δ'	MDG
0.1	12.0 ± 1.05	5.21e-2 ± 2.04e-2	4.06e-2 ± 1.67e-2	5.42e-2 ± 2.11e-2
0.05	21.7 ± 1.42	2.49e-2 ± 8.10e-3	1.82e-2 ± 5.60e-3	2.54e-2 ± 8.30e-3
0.02	49.9 ± 2.33	1.08e-2 ± 1.10e-3	8.50e-3 ± 8.04e-4	1.09e-2 ± 1.10e-3
0.01	99.8 ± 3.99	5.20e-3 ± 7.53e-4	4.00e-3 ± 5.22e-4	5.20e-3 ± 7.58e-4
0.005	193.8 ± 10.00	2.8e-3 ± 3.49e-4	2.10e-3 ± 2.40e-4	2.8e-3 ± 3.50e-4
0.002	497.7 ± 7.73	1.2e-3 ± 1.25e-4	8.77e-4 ± 7.17e-5	1.2e-3 ± 1.26e-4
0.001	932.3 ± 9.96	6.64e-4 ± 7.63e-5	4.60e-4 ± 2.57e-5	6.64e-4 ± 7.73e-5

表 2 ZDT3 仿真结果

ϵ	D	SP	Δ'	MDG
0.1	7.0 ± 0.47	1.44e-1 ± 2.90e-2	1.26e-1 ± 2.68e-2	1.42e-1 ± 2.76e-2
0.05	9.7 ± 1.77	1.74e-1 ± 1.61e-2	1.47e-1 ± 2.46e-2	1.80e-1 ± 1.84e-2
0.02	20.7 ± 1.57	8.89e-2 ± 3.31e-2	5.70e-2 ± 1.84e-2	9.03e-2 ± 3.51e-2
0.01	37.6 ± 1.71	3.80e-2 ± 9.40e-3	2.54e-2 ± 9.6e-3	3.84e-2 ± 9.60e-3
0.005	73.2 ± 4.29	2.11e-2 ± 3.10e-3	1.28e-2 ± 1.60e-3	2.12e-2 ± 3.10e-3
0.002	175.7 ± 8.76	9.30e-3 ± 1.10e-3	5.90e-3 ± 5.04e-4	9.3e-3 ± 1.10e-3
0.001	322.7 ± 7.99	4.60e-3 ± 3.42e-4	2.9e-3 ± 1.45e-4	4.60e-3 ± 3.44e-4

Step2: 根据式(5) 计算 DomList 中每个粒子的所有目标函数值, 并根据式(7) 确定每个粒子的适应函数值. 将适应值为负的粒子存放在外部集 nonDomList 中. 重新根据式(7) 计算 nonDomList 中粒子的适应函数值, 以消除劣解的影响^[5].

Step3: 对 DomList 中的每个粒子 i 进行迭代计算. 根据适应值大小, 在 nonDomList 中选取前 20% 的非劣粒子作为 p_g 候选, 通过轮盘赌法在其中选择一个 p_g 作为粒子 i 的全局最优值. 若粒子 i 优于当前的 p_i , 则用其替代当前的 p_i ; 否则 p_i 保持不变. 根据速度更新公式(2) 和位置更新公式(3) 计算出粒子 i 的后代, 并存储在 DomList 中.

Step4: 根据式(8) 调整 ϵ 支配的取值, 迭代次数加 1.

Step5: 如果已经满足停止准则, 例如 nonDomList 中已经达到最大或已经达到最大迭代次数, 则中止计算, 输出 nonDomList; 否则, 转 Step2.

5 直流变频压缩机启动性能的多目标优化

5.1 应用背景

本文研究的直流变频压缩机的驱动机构采用直流无刷电动机(BLDCM), 由 PWM 控制的 BLDCM 外部特性完全可以与直流电动机等效, 且比交流电机体积小、重量轻、效率高, 不存在励磁损耗等问题, 因此, 在高性能应用领域, BLDCM 具有更强的优势.

目前, 国内对直流变频压缩机的本体及其控制器的研究刚刚起步, 大量需求仍依靠进口. 其主要问题在于润滑供油、宽带防振、磨损寿命和可靠起动等. 起动技术直接影响电机的运行效果, 若起动方法选择不当, 则会引起电机无法正常起动, 甚至导致电机失步. 国内外文献普遍采用“三段式”起动技术. 文献[13] 在此基础上, 根据所研究压缩机的特点, 提出一种“新三段式”起动技术, 即二次定位法、脉冲快速加速法, 切换到无刷直流电机运行状态. 其中脉冲快速加速法是一个关键点, 容易造成过流或转速过低而导致启动失败. 这里首先建立脉冲加速过程中电流和电压模型, 并应用多目标粒子群改进算法对启动电流和转速进行优化.

5.2 模型建立

BLDCM 的运动方程可写为

$$T_e - T_L = J \cdot d\omega_m / dt + B\omega_m. \quad (8)$$

其中: ω_m 为转子的机械角速度, T_e 为三相绕组产生的合成电磁转矩, T_L 为电机负载转矩, J 为电机转动惯量, B 为阻尼系数. 反电动势系数和转矩系数分别为

$$K_e = E / \omega_m, \quad (9)$$

$$K_T = T_e / I. \quad (10)$$

其中: I 为矩形波电流有效值, E 为反电动势有效值. 对于某个具体的 BLDCM, 其反电势系数和转矩系数为常数.

为了更清楚地分析 BLDCM 的特性, 并寻求一种有效的控制方法, 得到良好的运行性能, 还需进一步推导 BLDCM 的传递函数. 设电机绕组采用两两导通方式, 则两相通电绕组的电压方程为

$$U = E + I \cdot R + (L - L_M) \cdot dI/dt. \quad (11)$$

式中: R 为两相绕组电阻, L 为两相绕组自感, L_M 为绕组互感. 将式(8) ~ (11) 进行拉氏变换, 得

$$T_e(s) = T_L(s) + J \cdot s \cdot \omega_m(s) + B \cdot \omega_m(s), \quad (12)$$

$$E(s) = K_e \cdot \omega_m(s), \quad (13)$$

$$T_e(s) = K_T \cdot I(s), \quad (14)$$

$$U(s) = E(s) + R \cdot I(s) + (L - L_M) \cdot s \cdot I(s). \quad (15)$$

根据上述状态方程可以画出 BLDCM 的动态结构图, 如图 4 所示.




图 4 BLDCM 动态结构图

这里以输入 $U(s)$ 的脉冲宽度 x_1 , 脉冲占空比 x_2 和脉冲持续时间 x_3 作为输入变量, 未来 5 s 内电流 $I(s)$ 的最大值作为目标函数 f_1 , 未来 5 s 内转速 $\omega_m(s)$ 的最大值取反作为目标函数 f_2 . 对以上建立的多目标优化模型, 应用前述的 PSO 多目标优化算法得到最优加速方案.

5.3 仿真结果与分析

首先给出一组直流变频压缩机设计参数: $R = 6.27 \Omega$, $L = 0.02539 \text{ H}$, $L_M = 0.119175 \text{ H}$, $J = 3.297 \times 10^{-4} \text{ kg} \cdot \text{m}^2$, $B = 3.457 \times 10^{-5} \text{ N} \cdot \text{ms/rad}$, $K_e = 0.5697 \text{ V} \cdot \text{s/rad}$, $K_T = 0.5697 \text{ N} \cdot \text{m/A}$.

算法的参数设置如下: 种群规模设置为 $M = 100$, 外部集规模为 100, 加速度参数 $c_1 = c_2 = 2$, 惯性权重 $\omega = 0.4444$ ^[14], 最大迭代次数为 100 次. 另外, 设置 ϵ 支配的初始值为 0.03. 根据经验设置 $x_{1\max} = 0.02 \text{ s}$, $x_{1\min} = 0.01 \text{ s}$, $x_{2\max} = 7\%$, $x_{2\min} = 3\%$, $x_{3\max} = 0.4 \text{ s}$, $x_{3\min} = 0.2 \text{ s}$. 算法选取具有一定代表意义的两种负载进行仿真. 当负载转矩 T_L 分别为 $0.5 \text{ N} \cdot \text{m}$ (轻载)、 $1 \text{ N} \cdot \text{m}$ (重载) 时, 仿真结果如图 5 所示.




图 5 不同负载下粒子群分布图

从算法的角度看,粒子群经过大约 30 次迭代后基本可以找到 Pareto 前沿,经过多次重复实验,结果较为稳定.从图 5 可以看出,粒子分布均匀,具有很好的多样性,改进的 PSO 多目标算法取得了良好的效果.

从应用角度看,计算得到的结果比较符合实际测量数据,具有一定的理论指导意义.但是,以上所涉及的模型为一简单模型,其中作了一些假设,比如绕组电阻恒定、绕组电感恒定、负载转矩恒定等,因此并不是一个精确的模型.要想完全指导实践,还应在模型的建立上更加完善.

根据一般直流变频压缩机的最高启动电流的限制为 2 ~ 3 A,并根据图 5 的仿真结果,总结出以下加速策略:在确定最高限额电流和保证最低加速转速的情况下,根据轻载和重载的不同特性,程序采用 2 次启动方式.首先按轻载启动,在图 5(轻载)中找出合适的点作为启动参数;如果启动失败,则按重载启动,在图 5(重载)中找出合适的点作为启动参数.目的是保证通过 2 次启动压缩机,都能在一个比较宽的负载范围内启动成功.在实际应用过程中,压缩机启动成功率达到 99.99%,取得了很好的效果.

6 结 论

多目标优化问题一直都是工程应用领域的一个难题,在进化算法引入后,多目标优化算法便被广泛地应用于工程实践中.本文针对多目标优化问题,提出了一种基于最大最小适应函数的改进的多目标粒子群优化算法.该算法在最大最小适应函数值的计算中引入了最大最小相对算法,很好地解决了粒子飞行过程中偏向性问题.另外,将 ϵ -支配的概念引入最大最小适应度函数值的计算中,改进了最大最小适应度函数值的计算方法,并相应地提出了一种变 ϵ -支配的策略,有效地提高了算法的收敛速度和粒子的多样性.将该算法应用于直流变频压缩机启动时峰值电流和启动转速的优化问题中,其结果表明该算法收敛速度快且结果可靠,粒子排列均匀,一次性得到了更多满意的解,为提升变频压缩机启动性

能提供了一种有效的优化方法.

参考文献(References)

- [1] Coello C A C, Veldhuizen D A V, Lamont G B. Evolutionary algorithms for solving multi-objective problems [M]. New York: Kluwer Academic Publishers, 2002.
- [2] Pulido G T, Coello C A C. Using clustering techniques to improve the performance of a particle swarm optimizer [C]. Proc of the 2004 Genetic and Evolutionary Computation Conf. Seattle, 2004: 225-237.
- [3] Mostaghim S, Teich J. The role of ϵ -dominance in multi-objective particle swarm optimization method[C]. Proc of the 2003 Congress on Evolutionary Computation. Canberra, 2003, 3: 1764-1771.
- [4] Balling R. The maximin fitness function; Multi-objective city and regional planning[C]. Proc of the 2nd Int Conf on Evolutionary Multi-criterion Optimization. Faro, 2003: 1-15.
- [5] Li X. Better spread and convergence; Particle swarm multi-objective optimization using the maximin fitness function[C]. Proc of the 2004 Genetic and Evolutionary Computation Conf. Seattle, 2004: 117-128.
- [6] Kennedy J, Eberheat R. A new optimizer using particle swarm theory[C]. Proc of the 6th Int Symposium on Micro Machine and Human Science. Nagoya, 1995: 39-43.
- [7] Kennedy J, Eberheat R. Particle swarm optimization [C]. IEEE Int Conf on Neural Networks. Perth, 1995: 1942-1948.
- [8] Clerc M, Kennedy J. The particle swarm explosion, stability, and convergence in a multidimensional complex space[J]. IEEE Trans on Evolutionary Computation, 2002, 6(1): 58-73.
- [9] Kennedy J, Eberheat R, Shi Y. Swarm intelligence [M]. San Francisco: Morgan Kaufmann Publishers, 2001.
- [10] 徐家, 李绍军, 王慧, 等. 基于最大最小适应度函数的多目标粒子群算法[J]. 计算机与数字工程, 2006, 34(8): 31-34.
(Xu J, Li S J, Wang H, et al. A new swarm optimization for multi-objective problem[J]. Computer & Digital Engineering, 2006, 34(8): 31-34.)
- [11] Zitzler E, Deb K, Thiele L. Comparison of multi-objective evolutionary algorithms: Empirical results [C]. Proc of the 2005 Congress on Evolutionary Multi-criterion Optimization. Berlin: Springer-Verlag, 2005: 165-175.

(下转第 1728 页)