

基于综合学习策略的多目标分解粒子群算法

陈跃刚, 许 奕

(上海大学 悉尼工商学院, 上海 201899)

摘 要: 本文提出了一种基于综合学习策略的多目标分解粒子群算法(D-CLMOPSO), 该算法采用综合学习策略对多目标问题进行求解, 从而避免早熟收敛; 通过分解方法更新主导粒子以增强解的分布; 采用存档机制以存储优化过程中的非支配解, 并采用多项式变异来避免陷入局部最优. 最后将所提出的方法与三种多目标进化算法进行比较, 结果表明所提算法在大多数测试问题上具有良好的性能.

关键词: 多目标; 全面学习; 粒子群优化; 多目标优化分解

中图分类号: TP301.6

文献标识码: A

文章编号: 1000-7180(2018)10-0075-05

Multi-objective Decomposition Particle Swarm Optimization Algorithm Based on Comprehensive Learning Strategy

CHEN Yue-gang, XU Yi

(SILC Business School, Shanghai University, Shanghai 201899, China)

Abstract: In this paper, a multi-objective decomposition particle swarm optimization algorithm (D-CLMOPSO) based on comprehensive learning strategy is proposed, which uses a comprehensive learning strategy to solve multi-objective problems, so as to avoid premature convergence. The dominant particles are updated by decomposition to enhance the solution Distribution; Archiving mechanism to store the non-dominated solution in the optimization process, and using polynomial variation to avoid falling into the local optimum. Finally, the proposed method is compared with the three multi-objective evolutionary algorithms. The results show that the proposed algorithm has good performance on most of the test problems.

Key words: multiple target; comprehensive learning; particle swarm optimization; multi-objective optimization decomposition

1 引言

粒子群优化算法(Particle Swarm Optimization, PSO)^[1-2]是一种群体智能优化算法, 在实际中已经被广泛应用于单目标问题(Single Objective Problems, SOP). 然而, 现实生活和工业中往往需要对多个目标生产进行优化, 这些目标相互影响, 相互制约, 计算复杂度高, 这些问题被称为多目标问题(Multi-Objective Problems, MOPs). 粒子群算法在复杂多目标优化中尚未得到广泛的应用, 其原因是过早收敛, 多样性差. 因此, 提高 PSO 解决 MOPs 的能力是必要的.

综合学习策略是避免陷入早熟收敛的有效策略^[3]. 它没有使用全局最优粒子来引导粒子飞行, 而是随机选择种群中的粒子, 并通过个体最优粒子来引导飞行. 然而, 由于所选择的模板粒子的随机性, 算法收敛缓慢. 在文献[4]中, PCLPSO 改变了 CLPSO 的拓扑结构, 利用并行计算的思想, 将种群分成几个子群体, 分享子种群之间的信息, 具有收敛速度快, 解的质量好, 计算效率高的特点. 在文献[5]中, CLPSO 被成功地用于实际的工程问题, 这表明了它在单目标优化问题中的可行性. 同时, 它也用于多目标优化问题的研究^[6]. 张青富^[7]提出了基于

分解的多目标算法,将多目标问题转化为一系列单目标问题.

本文提出了一种基于综合学习策略的多目标分解粒子群优化算法(D-CLMOPSO).

2 D-CLMOPSO

2.1 综合学习策略

CLPSO 一种 PSO 的改进算法,能够很好地跳出局部最优.文献[3]提出 PSO 的缺陷是很容易因为使用最差而陷入早熟收敛.在传统的粒子群优化算法中,粒子群优化算法利用粒子群优化算法对粒子速度进行更新,对整个群体的进化起着关键作用.如果 gbest 落入局部最优,那么整个种群就很容易陷入局部最优.因此,CLPSO 主要通过学习 pbest 而不是 gbest 来更新粒子速度.粒子速度更新公式如下:

v_i^d(t+1) = \omega v_i^d(t) + c_1 rand(pbest_{fi(d)}^d - x_i^d(t))

式中, f_i = [f_i(1), f_i(2), \dots, f_i(D)] 代表的随机从种群中选择的模板; pbest_{fi(d)}^d 表示被选择粒子的个体最优值. Pc 称为学习概率,决定是否根据模板粒子进行更新.如果一个随机数大于 Pc,相应的维将从它自己的 pbest 中学习,否则会模板粒子的 pbest 中学习.为了处理复杂的 MOP 并获得良好的多样性,当维度从另一个粒子学习时,使用四个随机粒子之间的比赛选择模板粒子.具体的速度更新流程在图 1 中给出.




图 1 速度更新流程图

如果一个粒子连续迭代(称为刷新间隙,一般取

gap = 2) 不能使自身得到有效优化,那么将为该粒子选择新的模板.学习概率的计算公式如下:

Pc_i = 0.05 + 0.45 \frac{(\exp \frac{10(i-1)}{N-1} - 1)}{(\exp(10) - 1)}

随着迭代次数的增加,群体进入局部最优的概率增大,此时学习率逐渐增大,从而避免局部优化.

2.2 粒子选择机制

本文选择分解算法,在目标空间中均匀生成 N 个方向向量,粒子群划分为 N 个子问题,各个粒子在方向向量的指引下逐步更新.

个体最优值更新:粒子的个体最优对整个种群的搜索起着指导作用.为了更新 pbest,通过 Tchebycheff 方法构造聚合函数,使多目标问题标量化,然后计算每个粒子的聚合值,选择最佳粒子并通过二进制锦标赛进行保留.

全局最优值更新:种群的全局最优用于指导粒子的开发,粒子的全局最优利用邻域粒子的信息更新.

2.3 粒子选择机制

外部档案的建立:根据支配的思想,为了更好地利用每一代的信息,使用外部档案集记录每一次粒子群更新后种群的有利信息.档案粒子的选择遵循以下规则:对于每一代的个体最优和全局最优,经过非支配排序后,选择第一非支配前沿粒子作为存档集中的归档粒子.

存档集的维护:随着迭代次数的增加,非支配解也越来越多.为了简化算法,存档集需要保持一定的规模,本文采用保持拥挤距离来进行存档集的维护.在处理复杂的问题时,粒子群往往陷于早熟收敛.为了摆脱早熟收敛,本文采用多项式变异(PM)[8]作用于存档集.

2.4 算法流程

Step1:初始化

(1) 设定算法所需参数,初始化种群速度,位置,计算初始适应度值,初始化个体最优,全局最优,精英集 archive = \emptyset.

(2) 初始化参考点 z^* = (z_1^*, z_2^*, \dots, z_m^*), 其中 z_j^* = \min(f_j(x)), j = 1, 2, \dots, m.

(3) 初始化权重向量,各粒子邻域.

Step2:迭代和更新

(1) 对于每一个粒子,根据图 1 对粒子速度进行更新,根据式(3)更新粒子位置.计算新的适应度值并更新参考点.

(2)更新个体最优值:根据聚合函数的值更新,若满足条件 $g^{te}(x^i|\lambda^j,z)<g^{te}(pbest^i|\lambda^j,z)$,则 $pbest^i=x^i$, $pbestfitness=F(x^i)$.

(3)更新全局最优值:根据邻域信息,通过比较聚合函数值更新全局最优粒子.

(4)将 $pbest$, $gbest$ 合并,作为一个临时种群,找出其中的非支配解,加入精英集.

(5)判断精英集规模:若精英集规模超出预定值,计算各精英解之间的拥挤距离,删除拥挤距离值最小的粒子,若精英集规模依然超出,则继续执行本步,直至规模维持在预定值.

Step3:终止

若达到最大评价次数,则终止算法并输出存档集,否则返回 Step2.

3 实验结果与分析

3.1 测试函数

为了评估所提算法的性能,将其结果与由 dMOPSO^[9],NSGAII^[10]和 MOPSO^[11]获得的结果进行比较.采用 8 个测试函数,ZDT1,ZDT2 和 ZDT3 设置 30 个决策变量,ZDT6 使用 10 个决策变量进行测试.对于 DTLZ2 和 DTLZ4,采用了 12 个变量,DTLZ1 和 DTLZ7 分别用 7 个和 22 个决策变量进行测试.

3.2 参数设置

对于每个测试函数,每个算法独立运行 30 次.算法的参数如下:

学习因子 $c_1, c_2 = 1.5$, 惯性系数 $\omega = \omega_{start} - ((t_{max} - t)/t_{max})(\omega_{start} - \omega_{end})$, $\omega_{start} = 0.9, \omega_{end} = 0.4$, 邻域规模 $T = 20$, 变异概率 $p_m = 0.05$, 多项式变异中的分布指数 $\eta_m = 20$.

ZDT 函数: $m = 2, N = 100, FEAS = 30\ 000$;
DTLZ 函数: $m = 3, N = 210, FEAS = 210\ 000$.

3.3 实验分析

如表 1 所示,DCLMOPSO 在八个测试问题中优于 dMOPSO,NSGAII 和 MOPSO.表 1 显示了四种算法的 IGD 性能指标的平均值和标准差(std),其中加粗值是同一测试函数上的最佳平均值或标准差.此外,该表还记录了每个函数中用其他算法计算 DCLMOPSO 的 T 检验的 p -value(p)值.显著水平 $\alpha = 0.05$,即 p 值大于 0.05 时,表明两种算法在统计学意义上没有显著差异,表中的斜体显示 DCLMOPSO 与对比算法在对应的测试函数上没有显著差异功能. better/similar/worse 表明在所有测试函数中,D-CLMOPSO 优于,相似于和低于比较算法的数目.

在两目标问题上,D-CLMOPSO 在 Pareto 前沿产生更好的近似解. dMOPSO 在 ZDT1 和 ZDT6 获得更好的结果,但 DCLMOPSO 得到的值之间的差异并不显著.在三目标问题上,D-CLMOPSO 也获得了较好的分布.但是在 DTLZ1 上,D-CLMOPSO 的性能略逊于 NSGAII.在 DTLZ4 上,DCLMOPSO 的性能较差.综合全部测试结果,DCLMOPSO 在大多数测试函数中优于 dMOPSO,在每个问题上明显优于 MOPSO.图 2 显示了 D-CLMOPSO, dMOPSO, MOPSO 和 NSGAII 算法在一些采用的测试问题中得到的最终 Pareto 近似前沿.这些图显示了每个算法找到的最终的最优解集.不难发现,D-CLMOPSO 得到的解集在 Pareto 前沿收敛性及分布都较好,这些结果表明 D-CLMOPSO 具有处理复杂 MOP 的潜力.




图 2 部分测试函数的前沿图

表 1 各对比算法的 IGD 值

函数		D-CLMOPSO	dMOPSO	NSGAII	MOPSO
ZDT ₁	mean	4.369E-03	3.899E-03	4.898E-03	1.817E-02
	std	5.200E-04	3.839E-05	2.043E-04	3.243E-03
	<i>p</i> -value		4.43E-05	3.26E-06	1.98E-19
ZDT ₂	mean	4.150E-03	6.442E-02	4.852E-03	1.923E-02
	std	2.246E-04	1.849E-01	2.074E-04	3.412E-03
	<i>p</i> -value		8.470E-02	5.442E-14	1.348E-20
ZDT ₃	mean	4.957E-03	1.064E-02	7.213E-03	2.425E-02
	std	3.373E-04	7.098E-04	7.634E-03	5.872E-03
	<i>p</i> -value		4.022E-26	1.145E-01	6.641E-17
ZDT ₆	mean	2.415E-03	1.878E-03	2.660E-03	1.059E-02
	std	1.594E-04	4.683E-05	2.251E-04	1.966E-02
	<i>p</i> -value		1.365E-17	9.317E-05	3.095E-02
DTLZ ₁	mean	4.191E-02	3.210E+00	1.902E-02	8.220E+00
	std	1.349E-02	1.180E+01	6.011E-04	2.307E+00
	<i>p</i> -value		8.706E-08	4.646E-10	3.802E-18
DTLZ ₂	mean	4.308E-02	4.715E-02	5.244E-02	7.442E-02
	std	1.362E-03	1.489E-03	2.373E-03	3.010E-03
	<i>p</i> -value		5.836E-09	7.165E-17	1.009E-29
DTLZ ₄	mean	1.468E-01	1.175E-01	5.337E-02	1.852E-01
	std	1.354E-01	7.627E-02	1.727E-03	3.196E-02
	<i>p</i> -value		3.596E-01	8.234E-04	1.792E-01
DTLZ ₇	mean	4.934E-02	1.265E-01	6.890E-02	5.312E-02
	std	2.866E-03	6.728E-03	5.101E-02	1.862E-03
	<i>p</i> -value		2.795E-30	6.887E-02	5.165E-01
better/similar/worse			4/2/2	4/2/2	6/2/0

4 结束语

本文提出了一种基于综合学习策略的分解多目标粒子群优化算法. 在所采用的多数测试问题中, 所提出的算法在性能测量 (IGD) 方面优于 dMOPSO, NAGAI 和 MOPSO. 分解方法的使用极大地有利于 D-CLMOPSO 最小化过程中解集的多样性. 此外, 综合学习策略的使用在很大程度上平衡了 PSO 的搜索和开发能力. 外部档案的变异使得种群迅速跳出局部最优. 因此, 该算法是一种分布性和稳定性较好的多目标优化算法.

然而, 但在处理复杂的多模态问题时, D-CLMOPSO 可能收敛不到完整的 Pareto 前沿. 因此, 在之后的工作中研究如何加快算法的收敛速度, 在复杂的多模态函数中找到分布性更好的前沿是很有必要的.

参考文献:

[1] Eiben A E, Smith J. From evolutionary computation to the evolution of things [J]. Nature, 2015, 521 (7553): 476-482.

[2] Eberhart R C, Kennedy J. A new optimizer using particle swarm theory[C]//Proceedings of the sixth international symposium on micro machine and human science, Nagoya, 1995: 39-43.

[3] Liang J J, Qin A K, Suganthan P N, et al. Comprehensive learning particle swarm optimizer for global optimization [J]. IEEE Transactions on Evolutionary Computation, 2006, 10(3): 281-295.

[4] Gulcu S, Kodaz H. A novel parallel multi-swarm algorithm [J]. Engineering Applications Of Artificial Intelligence, 2015(45): 33-45.

[5] Salman A, Omran M G H, Clerc M, et al. Improving the performance of comprehensive learning particle swarm optimizer [J]. Journal of Intelligent & Fuzzy

Systems, 2016, 30(2):735-746.

[6] Huang V L, Suganthan P N, Liang J J, Comprehensive learning particle swarm optimizer[J]. International Journal of Intelligent Systems, 2006, 21(2): 209-226.

[7] Zhang Q, Li H. MOEA/D: A multiobjective evolutionary algorithm[J]. IEEE Transactions on evolutionary computation, 2007, 11(6): 712-731.

[8] Chen J, Lin Q, Ji Z, A hybrid immune multi objective optimization algorithm[J]. European Journal of Operational Research, 2010, 204(2): 294-302.

[9] Martlnez S Z, Coello C C A, A multi-objective particle swarm optimizer based on decomposition[C]//Proceedings of the 13th annual conference on Genetic and evolutionary computation. Dublin, Ireland, ACM, 2011: 69-76.

[10] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multi objective genetic algorithm: NSGA-II[J]. IEEE Transactions on evolutionary computation, 2002, 6(2): 182-197.

[11] Coello C A C, Pulido G T, Lechuga M S. Handling multiple objectives with particle swarm optimization [J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3): 256-279.

作者简介:

陈跃刚 男, (1977-), 博士(后), 副教授, 硕士生导师. 研究方向为决策优化、城市经济.

许 奕(通讯作者) 男, (1993-), 硕士研究生. 研究方向为多目标进化算法及应用. E-mail: xuyi0100@126.com.

(上接第 74 页)

通过实测验证,设计的射频功率放大器性能见表 1. 在 100~200 MHz 可稳定输出 37.4 dBm 以上功率值,增益达到 17.4 dB 以上,效率 57% 以上. 实验表明栅极 R-C 并联电路可有效改善射频功率放大器的稳定性,符合设计预期.

表 1 射频功率放大器实测性能

参数	138 MHz	157 MHz	172 MHz
输出功率/dBm	37.4	37.5	38.4
增益/dB	17.4	17.5	18.4
漏极效率/%	57.7	61.0	68.3

6 结束语

本文研究了射频功率放大器的稳定性判定理论,并通过仿真和实例对其判据进行了验证;同时研究了栅极 R-C 并联电路作为稳定电路的阻抗特性,通过控制变量法分别研究了不同电阻值与不同电容值对稳定电路作用的影响,并引入了 R-C 并联电路的转折频率 f_0 用来分析 R-C 稳定电路的特性. 通过研究可知:转折频率 f_0 决定了 R-C 电路的阻抗特性,从而影响着此类稳定电路的稳定效果,对射频功率放大器稳定性电路的设计具有指导意义.

研究中忽略了加入 R-C 并联电路后对匹配电路的影响,实际应用中需要将此方面纳入考虑中.

参考文献:

[1] 吕剑锋,孙虹. 射频功率放大器的稳定性分析[J]. 国外电子测量技术, 2005, 24(7): 11-14.

[2] Reinhold Ludwig, Gene bogdanov. RF circuit design: theory and applications[M]. 2 nd ed. Beijing: Publishing House of Electronics Industry, 2013.

[3] 王帅. RF-LDMOS 器件研究和功率放大器设计[D]. 北京:中国科学院微电子研究所, 2013.

[4] 马立宪. LDMOS 微波宽带功率放大器设计[D]. 安徽:安徽大学, 2011.

[5] Glenn Collinson, Marty Jones. A novel technique for measuring small signal S-parameters of an RF/microwave transistor, power amplifying stage for use in power amplifier stability analysis[J]. International Microwave Symposium Digest, 1993(3): 1255-1258.

[6] 徐兴福. ADS2011 射频电路设计与仿真实例[M]. 北京:电子工业出版社, 2014.

作者简介:

韩 月 男, (1991-), 硕士研究生. 研究方向为 LDMOS 射频功率放大器设计. E-mail: hanyue@ine.ac.cn.

丛密芳 男, (1984-), 助理研究员. 研究方向为 LDMOS 射频功率放大器设计.

李 科 男, (1977-), 高级工程师. 研究方向为 LDMOS 射频功率放大器设计.

杜 寰 男, (1963-), 研究员. 研究方向为存储器驱动电路、平板显示驱动电路、功率器件等.