

应用于负荷经济分配的改进差分进化算法

赵 昕¹, 李 剑²

(1 三峡大学 信息技术中心, 湖北 宜昌 443002; 2 湖北第二师范学院 计算机科学与工程系, 湖北 武汉 430060)

摘 要: 为了求解电力系统负荷经济分配问题, 提出一种改进差分进化算法. 该算法考虑机组的爬坡约束、出力限制区约束等非光滑费用函数曲线等非线性特性, 采用词典排序法处理系统约束来保证算法结果严格满足约束条件, 保证了系统的稳定性和安全性. 在差分进化算法的交叉算子计算中引入微粒群算法中的个体最优和全局最优的概念, 并采用遗传微粒群算法的多点交叉机制, 将两者以一定的比率引入试验向量增强算法的局部搜索能力. 此算法被应用于一个 6 台机组的算例, 与遗传算法、微粒群算法和标准差分进化算法相比较, 改进的差分进化算法的结果质量更好并且更稳定, 是求解负荷经济分配问题的一种有效方法.

关键词: 差分进化; 负荷经济分配; 电力系统; 微粒群算法

中图分类号: TP311

文献标识码: A

文章编号: 1000-7180(2010)02-0159-04

A Modified Differential Evolution for Economic Dispatching

ZHAO Xin¹, LI Jian²

(1 Information Technology Center, China Three Gorges University, Yichang 443002, China;

2 Department of Computer Science and Engineering, Hubei University of Education, Wuhan 430060, China)

Abstract: To solve the economic dispatch problems in power systems, a modified differential evolution algorithm was introduced. In the proposed algorithm the non-linear characteristics, such as ramp constraints of the generating units, output restricted zone and non-smooth cost functions are considered. To handle the constraints, the lexicographic order method was employed to ensure the stability and the security of the system by providing feasible solutions. In the algorithm, the concepts of the individual best (pbest) and the global best (gbest) were introduced to DE, which were derived from the particle swarm optimization (PSO). Moreover, based on the crossover mechanism from the genetic particle swarm optimization, pbest and gbest were used to generate the trail vector with user defined ratios to enhance the local search performance. The simulation results for a practical system with 6 units have shown the effectiveness and the stability of the proposed approach for economic dispatch problems, which are better than those of the genetic algorithm, PSO, and traditional differential evolution.

Key words: differential evolution; economic dispatch; power system; particle swarm optimization

1 引言

负荷经济分配(Economic Dispatch, ED)问题是机组组合问题的一个子优化问题. ED 问题指的是, 在满足各种约束条件下, 分配运行机组间的负荷, 并且使得电力系统总运行费用最小或发电公司的利润最大. 而 ED 问题中存在大量的不连续、不可微、非线性和离散的约束条件, 而这些约束条件将问题的

可行解限制在很小的区域内. 随着电力市场改革的推进, 电力系统的运营机构一方面希望系统运行于能获得最大收益的状态, 另一方面又需要保证系统的稳定性和安全性, 因此如何同时兼顾收益与安全两个目标成为亟待解决的问题. 求解 ED 问题的标准方法有 λ 迭代法, 梯度法和等微增率法等, 这些方法假设机组的增量负荷特性是单调上升和分段线性的, 这限制了其在求解非线性特性的机组中的应用.

因此,基于智能计算的全局优化技术,例如:遗传算法(Genetic Algorithm)和微粒群算法(Particle Swarm Optimization, PSO)等在近年来被用于求解 ED 问题并取得一定成果^[1-3].

差分进化(Differential Evolution, DE)是一种相对较新的基于群体智能(Swarm Intelligent, SI)的随机搜索进化算法,它具有收敛速度快、鲁棒性好、实现简单和参数少等优点,然而有时 DE 算法也会面临陷入早熟或者收敛速度下降等问题^[4].文中基于标准 PSO 算法^[5]和遗传微粒群算法(Genetic Particle Swarm Optimization, GPSO)^[6]对 DE 进行了改进,得到遗传微粒群差分进化算法(Genetic Particle Swarm Differential Evolution, GPSDE).其中将 PSO 算法中个体的“历史记忆”以及个体之间的“协作”引入 DE 算法,以增强种群进化的稳定性,加速收敛.而将 GPSO 算法中的多点交叉算子引入 DE 算法,增强种群的多样性.通过对于拥有 6 个机组的一个实际系统的仿真计算,结果证实本文算法优于标准微粒群算法和标准的差分进化算法.

2 ED 问题描述

2.1 ED 问题的目标函数

电力系统中的 ED 问题是一个非线性优化问题,其主要目标是在满足负荷需求和各种约束条件下,最小化运行总费用或者最大化收益.文中目标函数取为最小化电力系统总运行费用^[1-3].

$$\min F = \sum_{i=1}^m F_i(P_i) = \sum_{i=1}^m a_i + b_i P_i + c_i P_i^2$$

其中, F 为电力系统总运行费用; P_i 为机组 i 的出力; $F_i(P_i)$ 为机组 i 的费用特性函数,通常可用二次曲线表示.

2.2 ED 问题的约束条件

(1) 功率平衡约束

$$\sum_{i=1}^m P_i = P_D + P_L, \quad i = 1, \dots, m$$

$$P_L = \sum_{i=1}^m \sum_{j=1}^m P_i B_{ij} P_j + \sum_{i=1}^m B_{0i} P_i + B_{00}$$

其中, m 是机组总数; P_D 是系统负荷需求; P_L 是损失电量,可以由 B 系数法求解.

(2) 机组运行约束

$$P_i^{\min} \leq P_i \leq P_i^{\max}, \quad i = 1, 2, \dots, m$$

其中, $P_i^{\min}$ 和 $P_i^{\max}$ 分别是机组出力最小和最大值.

(3) 爬坡约束

在任意两个连续的运行时间段内改变机组 i 的

出力必须满足如下约束条件:

$$\max(P_i^{\max}, P_i^0 - DR_i) \leq P_i \leq \min(P_i^{\max}, P_i^0 + UR_i)$$

其中, P_{i0} 为机组 i 在前一时段的出力; DR_i 和 UR_i 分别为机组 i 爬坡限制的下限值和上限值.

(4) 机组出力限制区约束

$$P_i^{\min} \leq P_i \leq P_{i,l}^l$$

$$P_{i,j-1}^u \leq P_i \leq P_{i,j}^l, \quad j = 2, 3, \dots, n_i$$

$$P_{i,n}^u \leq P_i \leq P_i^{\max}$$

其中, j 是禁止区域的编号; $P_{i,l}^l$ 和 $P_{i,n}^u$ 分别是第 i 个机组的第 j 个禁止区域的下限和上限.

综上所述, ED 问题的目标函数为非线性;同时包含非线性等式和不等式约束的约束优化问题,同时变量的取值不连续和不可微.

3 改进的差分进化算法

3.1 标准差分进化算法

差分进化算法最初主要用于解决连续函数优化问题^[4],首先在 D 维空间内随机产生 N_p 个初始个体 X_{i0} , $i \in [1, \dots, N_p]$;而优化操作则由其特有的变异、交叉和选择算子来完成.在第 t 次迭代中 $t \in [0, \dots, T]$,种群中的个体 i 所代表的向量 X_{it} 被称为目标向量.变异算子通过式(1)为每一个目标向量生成一个变异向量 V_i .

$$V_i = X_{r1}^t + F(X_{r2}^t - X_{r3}^t) \quad (1)$$

其中, r_1, r_2, r_3 是从当前种群中(不包括 i)随机选取的三个不同的个体. F 是一个由用户指定的数值的参数,被称为步长(Step Size).它的典型取值范围为 $[0, 2]$ 之间.由此可见变异向量是在 r_1 的基础上加上来自于 r_2 和 r_3 这两个向量差值的一定倍率的扰动构成的.

交叉算子用于计算得到试验向量 u_i ,试验向量由每个个体的目标向量和变异向量两者由类似于遗传算法中的多点交叉的方式得到,详见式(2).

$$u_{i,d} = \begin{cases} v_{i,d}, & \text{if } (\text{rand}_{i,d} \leq CR) \text{ or } (d = I_{\text{rand}}) \\ x_{i,d}^t, & \text{if } (\text{rand}_{i,d} > CR) \text{ and } (d \neq I_{\text{rand}}) \end{cases} \quad (2)$$

其中, $\text{rand}_{i,d}$ 是均匀分部在 $[0, 1]$ 之内的随机数; I_{rand} 是在 $[1, 2, \dots, D]$ 中随机选取的一个数,它用来保证试验向量至少包含变异向量中一个分量. CR 被称作交叉率,用于控制试验向量中来自于目标向量和变异向量中分量的比率.

与在 GA 和 PSO 等进化算法中只有具有更优适

应值的个体被保留不同,在DE算法的选择算子为了保持种群的多样性,只要试验向量的适应值不劣于原目标向量即可替换原目标向量。

$$X_i^{t+1} = \begin{cases} u_i, & \text{if } (f(u_i) \leq f(X_i^t)) \\ X_i^t, & \text{otherwise} \end{cases} \quad (3)$$

3.2 改进的差分进化算法

3.2.1 约束条件处理

在ED问题中存在需要满足的约束条件,因此在选择算子判断试验向量和目标向量优劣的时候需要综合考虑向量的目标函数值以及其对于约束条件的满足情况。在进化计算中有多种处理约束条件的方法,例如,罚函数法、随机排序法、多目标函数法以及协同进化法等。文中采用词典排序法,它可以被描述为,给定两个解:(1)如果一个解可行,另一个不可行,则可行解更优;(2)如果两个解都不可行,则对约束条件违背较小的解更优;(3)如果两个都是可行解,则目标函数值更优的获胜。词典排序法具有无需参数且实现简单的优点;同时由于它对约束条件的违背具有极强的惩罚,因此可以保证只要算法搜索到可行解,那么算法最终解将一定严格满足所有约束条件,因此非常适合电力系统对于约束条件满足,即系统稳定性和安全性的严格要求。然而词典排序法对非可行解的惩罚很强,相对于其他方式搜索性能有所降低,因此有必要对DE算法进行改进以增强其全局和局部搜索能力,提高搜索效率。

3.2.2 遗传微粒差分进化算法

DE算法中的变异向量来自于从种群中随机选取的3个母体计算得到,其中没有基于适应值的比较和选择操作,因此具有很强的全局搜索能力,但是同时也牺牲了其局部搜索能力。为了增强其局部搜索能力,有学者通过引入基于适应值比较的方式选择适应值高的个体来生成变异向量。而由式(2)可见,在DE算法中试验向量的分量分别来自于目标向量和变异向量。因此通过对目标向量的改进同样可以增强局部搜索能力,途径则是提高目标向量优质基因的含量。

文中将微粒群算法(Particle Swarm Optimization, PSO)中特有的“历史记忆”和“种群协作”的机制引入DE算法。PSO是一种模拟社会行为的随机全局搜索算法,其种群由大量的微粒构成,每个微粒即为优化问题的一个潜在解,其更新公式见(4):

$$\begin{aligned} V_i^t &= \omega V_i^{t-1} + c_1 r_1 (pb_i^{t-1} - X_i^{t-1}) + c_2 r_2 (gb^{t-1} - X_i^{t-1}) \\ X_i^t &= X_i^{t-1} + V_i^t \end{aligned} \quad (4)$$

其中, pb_i^{t-1} 是微粒 i 搜索到的已知最优解也称个体最优, gb^{t-1} 是种群搜索到的已知最优解也称全局最优; c_1 和 c_2 是学习因子; r_1 和 r_2 是在区间 $[0,1]$ 上平均分部的随机数; ω 是惯性权重。PSO中每次迭代中微粒通过跟踪个体最优和全局最优这两个“极值”来更新自己。这是因为个体最优和全局最优相对与普通微粒具有更优的适应值以及更多优质基因^[5]。

RAND = rand;

for $d = 1:D$

if RAND < ω_1 then $X_{i,d}^t = X_{i,d}^{t-1}$

else if RAND < ω_2 then $X_{i,d}^t = pb_{i,d}^{t-1}$

else $X_{i,d}^t = gb_d^{t-1}$

end

(5)

文中将个体最优和全局最优引入DE算法中的目标向量以实现类似于PSO算法中的更新机制,通过个体最优和全局最优引导加强局部搜索能力。DE算法中试验变量是通过类似于GA中的多点交叉算子实现的,因此PSO中的交叉机制并不适合,需要进行改进。遗传微粒群算法(GPSO)是一种融入遗传算法交叉和变异操作的新型PSO算法^[6]。对于微粒 i ,其交叉更新算子见式(5)。其中 d 是向量的索引; D 是向量的维数; rand 是 $[0,1]$ 区间上平均分部的随机数; $0 \leq \omega_1 < \omega_2 \leq 1$ 。因此,微粒的新位置由其原位置、个体最优和全局最优三者通过多点交叉得到,而 ω_1 和 ω_2 则设置三者在新位置中比率,这类类似于标准PSO中个体最优和全局最优引导机制。

文中基于PSO和GPSO算法,对DE算法进行改进得到遗传微粒差分进化算法(GPSDE),其中采用一种改进交叉算子(Modified Crossover Operator, MCO)。首先同PSO算法一样,GPSDE中每个个体在每一代中更新并记录每个个体最优以及全局最优;然后两者用于试验向量的交叉。交叉算子如下:

RAND = rand;

for $d = 1:D$

if (rand _{i,d} $\leq$ CR) or ($d == I_{\text{rand}}$) then

$u_{i,d} = v_{i,d}$;

else

if RAND < ω_1 then $X_{i,d}^t = x_{i,d}^{t-1}$

else if RAND < ω_2 then $X_{i,d}^t = pb_{i,d}^{t-1}$

else $X_{i,d}^t = gb_d^{t-1}$

end

end

(6)

由式(6)可见试验向量由变异向量 V_i^t 、原向量

X_i^{t-1} 、个体最优 pb_i^{t-1} 和全局最优 gb^{t-1} 的分量按照一定的比率构成。其中 V_i^t 来自于种群中随机 3 个母体用于提高全局搜索能力;对 X_i^{t-1} 中分量保留的目的是维持个体进化的稳定性和持续性; pb_i^{t-1} 和 gb^{t-1} 具有相对更优质的基因,引入到试验向量能够引导种群加强局部搜索能力。最后,对 4 者的多点交叉方式则能够为最终的试验向量提供充足的多样性,提高算法的全局搜索能力。由于借鉴了 GA、PSO 和 GPSO 算法的机制,因此 GPSDE 算法中参数设置与其也有相似之处。为了能使个体最优和全局最优充分发挥作用,CR 设置为 0.2,即变异向量和目标向量的比率分别为 20% 和 80%。在目标向量中如果全局最优比率过高则所有个体的试验向量将彼此高度相似,会造成类似于 GA 中的过度近亲繁殖现象;如果个体最优比率过高,则个体则主要在其个体最优附近搜索将降低全局搜索能力。文中通过对大量标准约束优化问题算例的测试,总结出有效的典型参数,其中 $\omega_1 = 0.1$, $\omega_2 = 0.6$,即个体原向量、个体最优、全局最优在目标向量中的比率分别为 10%、50%、40%。

4 算例仿真与分析

为了验证文中算法求解 ED 问题的可行性和有效性,此算法被应用于一个拥有 6 台机组的实际电力系统。其系统总负荷为 1263MW,其他参数见下表 1~表 3。利用文中算法、标准 DE 算法、GA 算法及文献[5]中的 PSO 算法,对算例的仿真结果在表 4 中给出。文中算法独立运行 30 次,种群规模为 100,迭代次数为 200, $\omega_1 = 0.1$, $\omega_2 = 0.6$, $F = 0.9$, CR = 0.2。

表 1 系统机组参数

机组	a	b	c	$P_{\max}$	$P_{\min}$
1	240	7.0	0.0070	500	100
2	200	10.0	0.0095	200	50
3	220	8.5	0.0090	300	80
4	200	11.0	0.0090	150	50
5	220	10.5	0.0080	200	50
6	190	12.0	0.0075	120	50

由表 4 可见,在“最小值”项上 DE 算法优于 GA 和 PSO 算法,但是在“平均值”项上它却更差,且在“最大值”项上它劣于两种 PSO 算法。这说明标准 DE 算法具有较强的搜索能力,但是稳定性较差。而 GPSDE 算法在所有三个项目上均优于其他所有算

法,其中 GPSDE 算法的平均值甚至优于 GA 和 PSO 得到的最小值。而相对于 DE 算法,其在搜索结果的质量以及稳定性上都显著更优,这证实了 GPSDE 算法同时综合了 DE 算法的搜索性能以及 PSO 算法的稳定性,并胜过两者。

表 2 爬坡约束和机组出力限制区

机组	P0/MW	DR/MW	UR/MW	出力限制区/MW	P0/MW
1	440	80	120	[210,240][350,380]	440
2	170	50	90	[90,110][140,160]	170
3	200	65	100	[150,170][210,240]	200
4	150	50	90	[80,90][110,120]	150
5	190	50	90	[90,110][140,150]	190
6	110	50	90	[75,85][100,105]	110

表 3 传输损耗系数($B_{00} = 0.0056$)

$B_{ij}/(1e-2)$						$B_{0i}/(1e-3)$
0.17	0.12	0.07	-0.01	-0.05	-0.02	-0.3908
0.12	0.14	0.09	0.01	-0.06	-0.01	-0.1297
0.07	0.09	0.31	0.00	-0.10	-0.06	0.7047
-0.01	0.01	0.00	0.24	-0.06	-0.08	0.0591
-0.05	-0.06	-0.10	-0.06	1.29	-0.02	0.2161
-0.02	-0.01	-0.06	-0.08	-0.02	1.50	-0.6635

表 4 仿真计算结果比较

总运行费用/USD			
算法	最小值	平均值	最大值
GA	15459	15469	15524
PSO	15448	15452	15492
DE	15396	15479	15493
GPSDE	15393	15412	15455

5 结束语

文中用改进的 DE 算法成功的求解了电力系统的负荷经济分配问题。此算法在标准 DE 算法的基础上,将 PSO 算法中个体的“历史记忆”以及个体之间的“协作”引入 DE 算法,以增强种群进化的稳定性,加速收敛。而将 GPSO 算法中的多点交叉算子引入 DE 算法,增强种群的多样性。通过对 6 机组实际系统的仿真计算,结果表明本算法能够有效求解非线性和不连续的电力系统负荷经济分配问题,并在解的质量和稳定性上优于遗传算法、微粒群算法以及标准差分进化算法。

参考文献:

- [1] 杨俊杰,周建中,吴玮,等.改进的粒子群优化算法在负荷经济分配中的应用[J].电网技术,2005,29(2):1-4.

(下转第 166 页)




图4 报文平均前传次数与节点通信半径关系图

5 结束语

文中分析了基于拓扑和基于地理位置的路由协议在网络拓扑结构剧烈变化和有障碍物存在时易产生拓扑洞的缺陷,介绍了空间模型的构建及使用,提出了SSR路由协议的设计过程.仿真结果表明在网络连通度适当的条件下,SSR协议有效规避拓扑洞使得路由算法性能可以得到有效改善.但是,影响报文成功传输率的直接因素依然是Ad Hoc网络链路支持,由于SSR协议不能保证GSR上存在有效链路连接,这影响了SSR协议的传输质量.如何提高

SSR协议的传输质量是下一步研究的方向.

参考文献:

- [1] 张国庆,慕德俊,许钟,等.一种高效的按需路由协议安全性改进方法[J].微电子学与计算机,2008,25(5):138-142.
- [2] Perkins C E, Royer E M. Ad-hoc on demand distance vector routing[C]//Proceedings of 2nd IEEE Workshop on Mobile Computing Systems and Applications. New Orleans: IEEE Computer Society, 1999:90-100.
- [3] Karp B, Kung H T. Greedy perimeter stateless routing for wireless networks[C]//Proceedings of ACM-IEEE MobiCom'00. USA: Boston, MA: ACM/IEEE, 2000:243-254.
- [4] Jing Tian, Han L, Rothermel K, et al. Spatially aware packet routing for mobile Ad Hoc inter-vehicle radio networks[C]//Proceedings of the IEE 6th Intl Conf. Shanghai: Intelligent Transportation Systems, IEEE, 2003:12-15.

作者简介:

朱本浩 男,(1974-),硕士,讲师.研究方向为ad hoc网络、路由算法.

姚明海 男,(1963-),博士,教授.研究方向为计算机控制技术、计算机网络等.

(上接第162页)

- [2] 蔡兴国,初壮.用遗传算法解算机组组合的研究[J].电网技术,2003,27(7):36-39.
- [3] 王宜怀.小型水轮发电机组优化运行系统的设计与实现[J].微电子学与计算机,2003,20(8):99-103.
- [4] Storn R, Price K. Differential evolution a simple and efficient heuristic for global optimization over continuous spaces[J]. Journal of Global Optimization, 1997, 11(4):359-431.
- [5] Kennedy J, Eberhart R. Particle swarm optimization[C]//Proceedings of IEEE Conference On Neural Networks.

Perth, Australia, 1995:1942-1948.

- [6] Yin P Y. Genetic particle swarm optimization for polygonal approximation of digital curves[J]. Pattern recognition and image analysis, 2006, 16(2):223-233.

作者简介:

赵昕 男,(1965-),工程师.研究方向为系统集成与优化计算.

李剑 男,博士,讲师.研究方向为智能计算与电力市场.