

基于自适应粒子群优化算法的机组组合

常文平¹, 于海², 华大鹏³

(1. 河南机电高等专科学校电气工程系, 河南 新乡 453002; 2. 河南电力公司新乡供电公司, 河南 新乡 453002;
3. 河南电力公司南阳供电公司, 河南 南阳 453002)

摘要: 机组组合是一个大规模、非线性混合整数优化问题, 求解比较困难, 为了提高粒子群算法的全局和局部搜索能力, 提出一种惯性权值自适应调整的粒子群算法。该算法按照适应度的大小将粒子群分成两个子群, 然后根据适应度的进化速度和进化停滞系数动态调整惯性权值。通过对典型函数的测试以及10台机组24小时的优化调度, 计算结果表明该方法收敛精度较高。

关键词: 粒子群算法; 惯性权值; 自适应; 机组组合

A solution to particle swarm optimization algorithm with adaptive inertia weight for unit commitment

CHANG Wen-ping¹, YU Hai², HUA Da-peng³

(1. Henan Mechanical and Electrical Engineering College, Xinxiang 453002, China; 2. Xinxiang Power Supply Company, Xinxiang 453002, China; 3. Nanyang Power Supply Company, Nanyang 453000, China)

Abstract: Unit commitment is a large-scale and mixed-integer non-linear programming problem. An adaptive inertia weight of particle swarm optimization algorithm (AWPSO) is presented to increase the global and local search. The population is divided into two sub-populations according to the value of fitness, and the inertia weight is formulated as a function of evolution speed and stagnate state. The algorithm is tested with well-known benchmark functions and the simulation results with systems of up to 10 units and 24-h scheduling horizon are presented. The experiments show that the convergence accuracy is increased.

Key words: particle swarm optimization; inertia weight; adaptability; unit commitment

中图分类号: TM744 文献标识码: A 文章编号: 1674-3415(2009)15-0015-04

0 引言

机组组合是在满足一定约束条件下, 通过优化以达到总运行费用最小的目标^[1]。机组组合属于大规模非线性、高维、混合整数的约束优化问题, 许多学者经过研究提出大量了解决机组组合问题的方法, 这些方法主要包括优先表法、动态规划法、分枝定界法、拉格朗日松弛法、内点优化法、Tabu搜索法、专家系统、人工神经网络算法、蚁群算法、遗传算法等^[2]。其中, 最简单和最快速的方法是优先表法, 但是一般找不到最优解; 动态规划法是一种广泛使用的机组组合方法, 但是, 随着机组数量和调度时间的增加, 容易出现“维数灾”问题; 拉格朗日松弛法用于机组组合最有潜力的一种方法, 但是由于对偶间隙的存在, 制约了其使用的范围; 遗传算法由于其可以得到全局最优解、实现简单及对目标函数没有特殊要求等特点而受到重视,

但是遗传算法计算量大, 效率低。

粒子群算法PSO (particle swarm Optimization Algorithm)是由Kennedy和Eberhart等于1995年开发出的基于群体智能的新型演化计算方法, 其思想最初来源于对鸟群觅食过程的模拟, 并最终发展成为一种有效的优化工具^[3]。同遗传算法和蚁群算法等智能算法相比, PSO算法简单、容易实现, 因此被广泛应用于非线性、多峰值等问题的优化。同时, 和遗传算法类似, 粒子群算法也存在早熟收敛现象, 针对这些问题, 国内外学者进行了大量研究工作, 并提出了很多改进算法, Shi等引入惯性权重来更好地控制对解空间的开发^[4], 后来, Berhart和Shi又提出惯性权值线性递减算法^[5], 使粒子群算法的搜索能力明显改善, 该方法在众多领域得到了应用^[6,7]。

在可调整参数中, 惯性权值是粒子群算法最重要的参数, 较大的权值有利于提高算法的全局搜索

能力,而较小的权值会增强算法的局部搜索能力。为了能在全局搜索和局部搜索之间取得更好的平衡,本文提出一种惯性权值自适应调整的粒子群算法,惯性权值随着粒子的状态变化而自动调整,计算结果表明该方法具有较好的性能。

1 数学模型

机组组合的约束包括功率平衡、备用容量要求、启停时间要求等条件,其目标是在调度期内,使总燃料费用、机组启停费用之和最小。机组组合的数学描述如下^[8]。

1.1 目标函数

$$\text{Minimize } J = \sum_{j=1}^T \sum_{i=1}^N [F_i(P_{ij}) \cdot U_{ij}] + \sum_{j=1}^T \sum_{i=1}^N \left[\sigma_i + \delta_i \left(1 - \exp\left(\frac{-T_{\text{off},ij}}{\tau_i}\right) \right) \right] U_{ij} (1 - U_{ij-1}) \quad (1)$$

式中: P_{ij} 是机组 i 在 j 时段的出力; $F_i(P_{ij})$ 是机组 i 在发电功率为 P_{ij} 时的燃煤费用,并且 $F_i(P_{ij}) = a_i + b_i P_{ij} + c_i P_{ij}^2$, a_i, b_i, c_i 为机组 i 燃煤费用系数; U_{ij} 是机组 i 在 j 时段的运行状态,当 $U_{ij} = 0$ 时,表示机组 i 在 j 时段停机,当 $U_{ij} = 1$ 时,表示机组 i 在 j 时段运行; σ_i, δ_i 表示机组 i 冷/热启动系数; τ_i 是机组 i 的起动机耗量特性参数, $T_{\text{off},ij}$ 表示机组 i 在 j 时段已经停机的时间。

1.2 约束条件

功率平衡约束:

$$\sum_{i=1}^N P_{ij} \times U_{ij} = P_{Dj} \quad j = 1, 2, 3, \dots, T \quad (2)$$

式中: P_{Dj} 为 j 时段系统的负荷功率需求。

旋转备用约束:

$$\sum_{i=1}^N P_{i\text{max}} \times U_{ij} \geq P_{Dj} + P_{Rj} \quad j = 1, 2, 3, \dots, T \quad (3)$$

式中: P_{Rj} 为 j 时段系统的旋转备用功率需求。

机组容量约束:

$$P_{i\text{min}} \leq P_{ij} \leq P_{i\text{max}} \quad j = 1, 2, 3, \dots, T \quad (4)$$

式中: $P_{i\text{max}}$ 为机组 i 的功率上限, $P_{i\text{min}}$ 为机组 i 的功率下限。

启停约束:

$$T_{\text{oni}} > MUT_i \quad (5)$$

$$T_{\text{offi}} > MDT_i \quad (6)$$

式中: $T_{\text{oni}}, T_{\text{offi}}$ 为机组 i 的实际连续运行/停机的时间, MUT_i, MDT_i 为机组 i 的允许最小连续运行/停机的时间。

2 改进的粒子群算法

2.1 基本粒子群算法

在基本粒子群算法中,首先在可行解空间中随机初始化 m 个粒子构成初始种群,并为每个粒子随机初始化一个速度,每个粒子都对应优化问题的一个解,并由目标函数为之确定一个对应的适应值,而速度用来决定粒子在解空间中的运动。在算法的每次迭代中,粒子将跟踪自身当前找到的最优解和种群当前找到的最优解,迭代搜索直到最后得到最优解。

设 n 维搜索空间中有 m 个粒子。第 i 个粒子表示为 $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$, 它经历的最好位置(对应最好的适应值)记为 $P_i = (p_{i1}, p_{i2}, \dots, p_{in})$, 简称为 P_{best} 。群所有粒子经历过的最好位置的用 g_{best} 表示。粒子的速度用 $V_i = (v_{i1}, v_{i2}, \dots, v_{in})$ 表示。对每一代,其速度和位置的调整如下式:

$$V(k+1) = \omega V(k) + c_1 \text{rand}() (P_{\text{best}} - X(k)) + c_2 \text{rand}() (g_{\text{best}} - X(k)) \quad (7)$$

$$X(k+1) = X(k) + V(k+1) \quad (8)$$

其中: ω 为惯性权重, c_1, c_2 为学习因子, $\text{rand}()$ 为 $[0, 1]$ 范围内变化的随机函数。

为了改善 PSO 算法的局部搜索能力, Shi 引入了惯性权值 w , 其计算公式为:

$$\omega(k) = \omega_{\text{max}} - k(\omega_{\text{max}} - \omega_{\text{min}}) / k_{\text{max}} \quad (9)$$

式中: k 为进化代数, k_{max} 为设定的最大进化代数。

2.2 惯性权值自适应调整算法

线性权值递减策略简单、直观,且具有较好的寻优性能,但是惯性权值只和进化代数线性相关,不能适应算法中非线性变化的特性。事实上,惯性权值应该随着粒子进化速度的变化而变化。

定义: 设 g_{fun} 为粒子群最优的适应度值, avgfun 为粒子群平均的适应度值,两者的差值反应进化停滞的程度,则进化停滞系数 $s = \text{abs}(g_{\text{fun}} - \text{avgfun})$ 。

本文根据适应度的值将粒子群分成两个子群,对两个子群分别动态地使用不同的惯性权值,从而达到快速收敛的目的。假设优化目标是寻找极小值,

将适应度小于平均值的粒子分成子群SUB₁, 将剩余的粒子分成另一子群SUB₂, 具体调整惯性权值的公式如下。

对于SUB₁, 不同的粒子采用不同的惯性权值, 计算公式为:

$$\omega(i) = \omega(i) - \left\{ \omega(i) - \omega_{\min} \right\} \frac{|fun(i) - avgfun|}{s} \quad (10)$$

对于SUB₂, 需要加大并采用统一的惯性权值, 计算公式为:

$$\omega = 1.3 - \frac{1}{1 + b_1 \exp(-b_2 \cdot s)} \quad (11)$$

其中: ω_{\min} 为最小惯性权重, 一般取0.4; b_1, b_2 为调整系数, 一般 $b_1 = 1.5$, $b_2 = 0.3$ 。

计算步骤如下:

step1: 初始化粒子群, 包括随机位置和速度;

step2: 评价每个粒子的适应度;

step3: 若算法满足要求, 转step 8, 否则执行step4;

step4: 对每个粒子, 将其适应值与其经历过的最好位置 P_{best} 作比较, 如果较好, 则将其作为当前的最好位置 P_{best} , 将其适应值与全局所经历的最好位置 g_{best} 作比较, 如果较好, 则重新设置 g_{best} , 并计算粒子群的平均适应度 $avgfun$;

step5: 计算进化停滞系数S, 并根据适应度将粒子群分为2个子群;

step6: 根据式(4)、(5)更新粒子的惯性权重, 并进一步更新粒子的速度和位置;

step7: 将迭代步骤次数加1, 转step3;

step8: 输出计算结果, 结束。

3 机组运行状态识别和约束处理

3.1 机组运行状态识别

粒子每一维的取值范围为 $[0, P_{imax}]$, 若某一维取值为 $[P_{imin}, P_{imax}]$, 表示此时段该机组运行, 输出功率等于相应的数值; 若某一维取值为 $[0, P_{imin}]$, 表示此时段该机组停运, 并将输出功率置0。

3.2 约束处理

1) 发电机出力约束处理

当 $P_i > P_{imax}$ 时, 取 $P_i = P_{imax}$; 当 $P_i < P_{imin}$ 时, 取 $P_i = 0$ 。

2) 功率平衡约束处理

如果不满足功率平衡约束, 采用随机调整的方式调整发电机的出力, 具体调整过程如下:

```

if  $\sum_{i=1}^N P_{ij} \times U_{ij} < P_{Dj}$ 
    for  $j=1:T$ 
        for  $i=1:N$ 
             $\Delta P_{ij} = P_{Dj} - \sum_{i=1}^N P_{ij} \times U_{ij}$ 
            if  $P_{imax} - P_i < \Delta P_{ij}$ 
                 $P_i = P_i + rand(P_{imax} - P_i)$ 
             $\Delta P_{ij} = \Delta P_{ij} - rand(P_{imax} - P_i)$ 
            end
            if  $P_{imax} - P_i > \Delta P_{ij}$ 
                 $P_i = P_i + \Delta P_{ij}$ 
            end
        end
    end
if  $\sum_{i=1}^N P_{ij} \times U_{ij} > P_{Dj}$ 
    for  $j=1:T$ 
        for  $i=1:N$ 
             $\Delta P_{ij} = \sum_{i=1}^N P_{ij} \times U_{ij} - P_{Dj}$ 
            if  $P_i - P_{imin} < \Delta P_{ij}$ 
                 $P_i = P_i + rand(P_i - P_{imin})$ 
             $\Delta P_{ij} = \Delta P_{ij} - rand(P_i - P_{imin})$ 
            end
            if  $P_i - P_{imin} > \Delta P_{ij}$ 
                 $P_i = P_i + \Delta P_{ij}$ 
            end
        end
    end

```

4 算例

4.1 数学算例

用下面两个函数作为测试函数, 求它们的最小值并和线性递减惯性权值方法对比。求解时, 设定种群规模为30, 最大迭代次数为200, 粒子群惯性权重最大值为0.9, 最小值为0.4, $c_1=c_2=2$, 共计算20次, 计算结果见表1。

$$f_1(x) = 20 + x_1^2 + x_2^2 - 10[\cos(2\pi x_1) + \cos(2\pi x_2)]$$

$$x_1, x_2 \in [-10, 10]$$

$$f_2(x) = \sum_{i=1}^{10} x_i^2, \quad x_i \in [-10, 10]$$

在计算中, 取粒子群数为30, 迭代次数为500, 计算结果如表1所示。

表1 两种算法计算结果对比

Tab.1 Comparison of solution for two methods

函数	LDWPSO	AWPSO
$f_1(x)$	9.1588×10^{-4}	9.5983×10^{-5}
$f_2(x)$	7.9368×10^{-4}	7.7284×10^{-5}

从表1中可以发现,对于两个函数,AWPSO的收敛精度较LDWPSO高,这表明自适应调整惯性权值的方法较线性递减惯性权值方法更能反应优化的搜索过程。

4.2 工程算例

为了进一步验证改进方法的效果,对10机系统24小时调度时段进行了计算,机组参数和运行参数具体见文献[8]。

表2是改进的自适应粒子群算法AWPSO和SGA(simple genetic algorithm)、PSO计算结果的比较^[8,9],从表中可以发现,用改进的粒子群算法获得的总费用最低。这说明改进粒子群算法的搜索能力得到提高。

表2 3种算法寻优结果对比

Tab.2 Comparison of solution for three methods

费用	方法		
	SGA	PSO	AWPSO
启停费用(\$/d)	5,600	6,194	5,600
燃煤费用(\$/d)	603,423.69	575,256	551,610
总发电费用(\$/d)	609,023.69	581,450	557,210

5 结论

惯性权值对算法的搜索能力有明显的影响,本文按照适应度的大小将粒子群分成两个子群,根据粒子群适应度的变化和粒子进化停滞系数自适应调整两个子群的惯性权值,提高算法的搜索能力。通过两个数学算例和一个10机24小时调度算例计算,证明该方法比线性递减惯性权值方法的收敛精度高,体现了该方法良好的性能。

参考文献

[1] Wood A J, Wollenberg B. Power Generation Operation and Control, 2nd ed [M]. New York: Wiley, 1996.

[2] 陈皓勇,王锡凡. 机组组合问题的优化方法综述[J]. 电力系统自动化, 1999, 23(4): 51-56.
CHEN Hao-yong, WANG Xi-fan. A Survey of Optimization Based Methods for Unit Commitment[J]. Automation of Electric Power Systems, 1999, 23(4): 51-56(in Chinese).

[3] Kennedy J, Eberhart R. Particle Swarm Optimization[A]. in: International Conference on Neural Networks IEEE[C]. Perth, Australia: 1995. 1942-1948.

[4] SHI Yu-hui, Eberhart R. A Modified Particle Swarm Optimizer[A]. in: The IEEE Congress on Evolutionary Computation[C]. Annapolis: 1998. 69-73.

[5] Shi Y, Eberhart R. Empirical Study of Particle Swarm Optimization[A]. in: International Conference on Evolutionary Computation[C]. Washington(USA): 1999. 1945-1950.

[6] Robinson J, Rahmat Samii Y. Particle Swarm Optimization in Electromagnetics[J]. IEEE Trans on Antennas and Propagation, 2004, 52(2): 397-406.

[7] Elegbede C. Structural Reliability Assessment Based on Particle Swarm Optimization[J]. Structural Safety, 2005, 27(10): 171-186.

[8] Gaing Zhe-Lee. Discrete Particle Swarm Optimization Algorithm for Unit Commitment[A]. in: IEEE/PES General Meeting[C]. 2003.

[9] Swarup K S, Amashiro S. Unit Commitment Solution Methodology Using Genetic Algorithm[J]. IEEE Trans Power Syst, 2002, 17: 87-91.

收稿日期: 2008-08-23; 修回日期: 2009-03-09

作者简介:

常文平(1970-),男,博士研究生,副教授,研究方向为电力系统优化调度与智能算法研究; E-mail:wpchang@163.com

于海(1971-),男,硕士,高级工程师,研究方向为电力系统优化调度与安全运行;

华大鹏(1972-),男,学士,高级工程师,研究方向为电力系统优化调度与安全运行。