

文章编号: 1003-207(2006)06-0113-06

改进粒子群优化算法在电源规划中的应用

李翔, 牛东晓, 杨尚东

(华北电力大学工商管理学院, 北京 102206)

摘要: 电源规划是一类复杂、非线性组合优化问题。传统的方法随着规划期的延长, 考虑因素的增多, 难以有效的进行优化, 在实际应用中作用有限。首先, 对电源规划优化问题进行了建模。然后, 对于粒子群(PSO)的迭代策略进行改进, 在此基础上, 运用遗传粒子群(GPHA)混合优化算法进行了优化尝试。考虑到电源规划中相关参数众多, 在优化过程中引入了虚拟变量对电源规划中的问题进行了简化描述; GPHA 算法的适应度评价函数设计中, 运用了罚函数的思想, 以提高算法优化的效果。最后本文使用某省实际负荷预测和系统负荷实际数据, 进行了电源规划方案优化, 得到了优化后的电源规划方案, 并与普通的遗传算法、粒子群算法以及传统的动态规划算法得到的结果进行了比较。比较的结果显示出了本文提出的算法在优化结果和速度方面具有明显效果。

关键词: 遗传算法; 粒子群算法; 电源规划; 罚函数; 虚拟变量

中图分类号: F713.50 文献标识码: A

1 引言

文献[1]对于影响电源规划问题的相关因素进行了分析, 认为电源规划问题是受复杂条件约束, 多非线性因素影响, 不确定性强的组合优化问题。厂网分离后, 对于发电侧的发电商而言, 如何在满足电力系统安全、环保等约束条件的前提下, 以风险-收益最优为目标, 确定何时何地建设多少台何种型号的机组, 是十分紧迫同时又极具挑战性的工作^[2]。

电源规划的优化问题一直是电力系统规划研究的热点问题^[3]。目前用于研究电源规划问题主要有两大类方法, 一类是传统的优化方法, 如线性规划、动态规划等; 另一类是基于计算机人工智能优化的方法, 如遗传算法、粒子群算法优化算法、免疫算法等。

文献[4-5]中分别应用了线性规划、动态规划等方法, 这些优化方法的在实际中取得了一定的效果, 尤其是在其考虑约束条件和影响因素小的情况下, 能够寻求到全局最优解。同时, 文献[4-5]通过将线性规划方法和动态规划等传统优化方法求解中长期电源规划后指出, 对于中长期电源规划问题, 由于其不确定性较强, 容易产生维数灾。

随着经济的发展, 人们对环保等要求的增加, 以及新型发电机组的研发, 电源规划优化中需要考虑的因素越来越多, 文献[6]中提出在我国电源规划应该考虑环境成本的因素。随着中长期电源规划问题, 受到越来越多的政策、环境的约束, 对这个问题的求解传统方法也显得更为困难。

随着计算机计算能力的提升和人工智能研究的进展, 越来越多的研究者开始采用基于人工智能的方法来解决电源规划问题。文献[7-8]分别将遗传算法(GA)和改进编码方式的遗传算法用于电源规划问题, 利用遗传算法的进化机制求解电源规划问题, 在一定程度上克服了传统优化算法的维数灾问题, 但是却存在着早熟、容易陷入局部极值的问题。文献[9-10]运用粒子群优化算法的全局寻优策略来求解电源规划问题, 从研究的结论来看, 一定程度上解决了局部极值的问题, 但是存在方法求解的稳定性较差。

有鉴于此, 本文提出一种改进的遗传粒子群混合算法(GPHA), 力图在优化效率和全局优化两个方面获得平衡。对于 PSO 的迭代策略进行了改进, 提出了对关键性参数进行动态赋值的策略; 对于问题本身的编码, 结合了虚拟变量的方法, 将问题简化, 从而从整体上进一步提高了优化算法运算的速度; 为了减少运行过程中非可行解出现的概率, 提高算法求解的稳定性, 本文运用 GA 算法对 PSO 的重要参数进行了预处理, 提高了优化的效果。选取实

收稿日期: 2006-06-22; 修订日期: 2006-10-22

作者简介: 李翔(1949-), 男(汉族), 河北保定人, 华北电力大学工商管理学院, 教授, 研究方向: 电力市场理论及应用、电力企业管理。

际数据, 通过与 PSO、GA 等算法独立优化的效果对比, 结果说明了本文提出算法的优越性。

2 电源规划优化问题建模

2.1 对建模中所包含的因素进行定性分析

依据文献[11], 电源规划问题涉及因素主要包括: 投资性因素, 反映规划期内电源规划方案实施的投融资成本; 效益性因素, 指的是反映规划期内方案的投资回收情况, 是对机组运行后上网电价、地方经济促进的综合反映, 满足区域负荷增长需求的程度; 运行成本因素, 是对机组运行后的运行维护成本, 机组运行后燃料易得和充分程度以及燃料成本; 稳定性因素, 是考虑方案实施后对于所在区域整个电力系统运行稳定性的影响; 以及规划期内某时段和时点的机组建设能力约束。

在文献[11]的基础上, 本文考虑将环境成本换算成经济指标记为 $\varepsilon(U_t)$, 将电源规划的不同方案的环境成本记入总成本内进行考虑。

这些因素反映了规划期内电源规划方案实施后经济、技术、社会等方面的综合影响。出于对上述因素量化分析的考虑, 对于不同类型的因素, 选择能够量化处理的重要指标, 在此基础上建立优化目标模型。下表即为本文所选择研究的电源规划优化问题考虑的因素集合。

表1 电源规划优化问题涉及的因素及量化指标表

	投资因素	收益性因素	运行成本因素	稳定性因素	其他因素
指标	新建机组所需投资、不同类型机组所需投资	利率、新建机组规划期内收益、不同类型机组收益	总运行维护成本、运行成本、固定运行成本、储存损耗费用、储存损耗率	规划期内系统失负荷率	环保成本、机组建设能力约束
符号描述	$I(U_t), CI_i$	$d, V(U_t), r_i$	$MC(X_t), MC, FC, OC(X_t), OC$	$L OLP$	$\varepsilon(U_t), U_{ma}$

T 为电源规划期总期限, t 为规划期的年序, N 为规划可选择的机组类型总数, i 为机组类型序号

2.2 目标函数

电源规划问题方案寻优的目的是规划期内在满足环保、安全约束、满足机组建设能力等约束前提下, 以最低的投资和运行成本满足所在区域的电力负荷增长需求, 成本最小化的目标函数可以表达如下:

其中:

$$\min F = \sum_{i=1}^T [I(U_i) + MC(X_t) + OC(X_t) + \varepsilon(U_i) - V(U_i)] \quad (1)$$

$$X_t = X_{t-1} + U_t \quad (t = 1, \dots, T) \quad (2)$$

$$I(U_t) = (1 + d)^{-2t} \sum_{i=1}^N (CI_i \times U_{t,i}) \quad (3)$$

$$V(U_t) = (1 + d)^{T'} \sum_{i=1}^N (CI_i \times \delta_i \times U_{t,i}) \quad (4)$$

$$MC(X_t) = \sum_{i=1}^t ((1 + d)^{1.5t + i + s'} (\sum (X_t \times FC) + MC)) \quad (5)$$

$$OC(X_t) = OC \times \sum_{s=0}^t (1 + d)^{1.5t + i + s'} \quad (6)$$

$$t' = 2(t - 1), \quad \text{and} \quad T' = 2 \times T - t' \quad (7)$$

$$\varepsilon(U_t) = \sum_{j=2}^t P(U_{j-1}) f_j \quad (8)$$

F 为总成本, U_t 为在规划期内的第 t 阶段(考虑到机组的平均建设周期为一年, 所以规划一阶段为 2 年) 新增的机组, X_{t-1} 为 $t-1$ 阶段已有装机容量, X_t 为第 t 阶段已建成机组容量, $I(U_t)$ 为到第 t 阶段新增机组的投资成本, $MC(X_t)$ 为第 t 阶段机组的运行和维护成本, s' 用于表示维护成本在每年的年中进行计算, $OC(X_t)$ 为第 t 阶已有机组和在建机组的储存损耗成本。 T 为电源规划期总期限, t 为规划期的年序, N 为规划可选择的机组类型总数, i 为机组类型序号。 $V(U_t)$ 为新增机组到规划期末总共回收的投资收益, $\varepsilon(U_t)$ 为新建机组到规划期末可能出现的环境成本。 CI_i 为第 i 类机组投产所需投资。上述模型以规划期第一年为基础, 所有的后续成本费用和收益都考虑时间价值, 折现到基期。 $P(U_{j-1})$ 为规划期内到第 t 为止第 $j-1$ 个阶段新增装机在第 j 阶段超过排放许可的超额排放部分, 第 f_j 为第 j 阶段的单位污染排放收费。

2.3 约束条件

2.3.1 机组建设能力约束

U_t 在第 t 阶段必须满足最大的机组建设能力的约束, 即在 t 阶段内, 机组最大的建设能力存在上限。

$$0 \leq U_t \leq U_{\max,t} \quad (9)$$

其中 $U_{\max,t}$ 为第 t 阶段机组的最大建设数量。

2.3.2 系统备用约束

在选择机组类型时, 必须满足以下备用的约束, 这是电源规划的稳定性要求:

$$(1 + R_{\min}) \times D_t \leq \sum_i^N X_{t,i} \leq (1 + R_{\max}) \times D_t \quad (10)$$

其中 R_{\min} , R_{\max} 为系统的最小和最大备用率, D_t 为第 t 阶段的需求, $X_{t,i}$ 为第 t 阶段第 i 种类型的机组累计的装机容量。

2.3.3 可靠性标准约束

在第 t 阶段内, 在建机组和已建成机组必须满足系统可靠性标准的约束, 即:

$$LOLP(X_t) \leq \vartheta \quad (11)$$

$LOLP(X_t)$ 为第 t 阶段机组总体的失负荷率, ϑ 为以失负荷率标志的系统最低的可靠性标准。

3 遗传粒子群混合算法描述

3.1 PSO 和 GA 算法概述

3.1.1 GA 算法

GA(遗传)算法是一种进化智能算法, 源于对达尔文进化规律的模拟, 通过设计染色体对问题的解进行编码, 通过种群的演化来实现“适者生存”的进化规律, 通过若干代进化达到最优解。通过染色体之间的交叉, 变异来实现优化, 在这一过程中, 适应度高的个体将更有机会保留自己的基因表达。GA 算法在工程优化中得到了广泛的应用, 取得了较好的优化效果, 但同时也存在着容易陷入局部极值等问题^[12]。

3.1.2 PSO 算法

粒子群中, 所有的粒子都有一个由被优化的函数决定的适应值(fitness value), 每个粒子还有一个速度决定他们飞翔的方向和距离^[13]。然后粒子们就追随当前的最优粒子在解空间中搜索 PSO 初始化为一群随机粒子(随机解)。然后通过叠代找到最优解。在每一次叠代中, 粒子通过跟踪两个“极值”来更新自己。第一个就是粒子本身所找到的最优解。这个解叫做个体极值 pbest, 另一个极值是整个种群目前找到的最优解。这个极值是全局极值 gbest。另外也可以不用整个种群而只是用其中一部分最为粒子的邻居, 那么在所有邻居中的极值就是局部极值。在找到这两个最优值时, 粒子会将局部极值和全局极值进行比较, 并根据如下的公式来更新自己的速度和新的位置:

$$X_i(k+1) = X_i(k) + V_i(k+1) \Delta t \quad (12)$$

$$V_i(k+1) = w V_i(k) + c_1 r_1 (P_i - X_i(k)) / \Delta t + c_2 r_2 (P_s - X_i(k)) / \Delta t \quad (13)$$

其中, k 为叠代进化的代数, w 为内部权重, c_1 , c_2 为学习率, r_1 , r_2 为 $[0, 1]$ 区间内一个随机实数, Δt 为每次叠代粒子的步长, V_i 为粒子的速度, $V_i \in (V_{\min}, V_{\max})$, V_{\min} , V_{\max} 为开始 PSO 算法叠代前设定的 $[0, 1]$ 区间内的一个常数。当设定的最大叠代次数或者适应度值达到实现设定的要求时, 算法终止。PSO 算法的稳定性和平均求解速度不如 GA 算法^[14]。

3.2 改进迭代策略的粒子群算法

在粒子群优化过程中, 合理的控制全局搜索和局部搜索的能力对于有效的寻求最优解而言是十分关键的。粒子群的性能的表现取决于其关键参数的选择, 从公式 14 中, 我们可以清楚地看出粒子群在上一个位置时的速度对于粒子群继续迭代的影响, 它提供了让粒子能随机穿过搜索空间的必要动量。内部权重参数 w 决定了粒子在上一个位置的速度对目前位置的粒子的影响, 因而, 局部搜索和全局搜索的平衡取决于控制参数 w 的取值。适当的控制 w 的值, 对于高效、准确地发现全局最优解而言是很重要的。较大的 w 则具有较好的全局搜索能力, 较小的则具有较强的局部搜索能力。

文献[15]对粒子群 w 的取值做出了重大的改进, 通过设计如下式所示的 w 线性变化函数:

$$W = \begin{cases} w_{\min} + \frac{(w_{\max} - w_{\min})(f - f_{\min})}{f_{\text{avg}} - f_{\min}}, & f \leq f_{\text{avg}} \\ w_{\max}, & f > f_{\text{avg}} \end{cases} \quad (14)$$

式中 w_{\max} 和 w_{\min} 分别表示 w 的最大值和最小值, f 为当前时刻粒子群中当个粒子对应的适应度函数值, f_{\max} 和 f_{\min} 分别为当前时刻粒子群中所有粒子对应的适应度函数值中最大值和最小值。

w 值随着粒子群迭代的进程而改变, 从 0.9 逐步减少为 0.4。在初期, w 值较大, 从而使得粒子群具有更好的全局搜索能力, 后期, 逐渐变为较小的值, 均衡局部搜索的能力, 从而大大改进了粒子群算法最初的迭代策略。为了获得全局搜索和局部寻优能力之间的平衡, 式中将 w 的变化和粒子群中粒子的适应度函数值对应起来。适应度函数值较小的粒子, 即对应较优解的粒子, 速度将减慢, 执行局部寻优任务; 适应度函数较大的粒子, 即对应次优解的粒子, 速度将加快, 执行全局寻优任务。这一改进的迭代策略使得粒子群具有了良好的收敛性和遍历性, 从而提高了粒子群寻求全局最优解的能力。

3.3 GPHA 算法

由于的 GA 算法和 PSO 算法在不同的工程应用中各具优势, GA 算法容易陷入局部极值, 效率较高, 稳定性高, PSO 算法, 容易找到全局最优, 但是稳定性和效率相对较差。因此, 本文综合这两种算法的优势, 用 GA 算法对 PSO 算法的重要参数 w , c_1 、 c_2 进行优化, 形成一种较新的 GPHA 混合算法。算法具体的实现步骤如下:

第一步, 用 GA 算法编码 PSO 算法的初始参数, 粒子群(p_i)的初始位置, 初始速度 V_i 以及 w , c_1 、 c_2 等重要参数, 初始化 GA 种群, 设定好初始的叠代次数 I , i 为叠代序数。其中 w 按照公式 14 在粒子群的迭代过程中进行变更。

第二步, 对粒子群的初始状态译码赋值, 对粒子 X_i , 并按照公式(12)(13)进行位置的叠代, 按照适应度评价函数评价各个粒子所处状态的适应度值。

第三步, 针对第 i 代粒子启动 GA 算法的变异、交叉、选择算子, 将每一次得到的最优粒子 X_i^* 替代 X_i , 重复这一过程, 直到设定的终止条件。

第四步, 重复第二步第三步直到设定的叠代次数达到。

4 遗传粒子群混合优化算法(GPHA)应用于电源规划优化问题

本文为了提高算法优化的效率, 在 GPHA 算法基础上, 引入了虚拟变量来描述电源规划问题的每一个可能方案。

4.1 对于电源规划优化问题进行简化

考虑机组建设能力约束的前提下, 引入虚拟变量 μ , 将每年的机组计划方案表述成单一的虚拟变量, 这样可以避免算法优化的维度过多出现的维数灾问题, 又能减少算法运算过程中内存等硬件系统资源的占用, 提高运算求解的速度。可以按以下步骤得到 μ :

第一步, 列出候选机组每一阶段所有可能的建设规划方案;

第二步, 计算每一种方案的累积新增机组容量;

第三步, 对每一种方案按由低到高的顺序排列, 并进行标注, 对虚拟变量 μ 赋值。

可以通过以下粒子来说明这一简化过程, 建设某一个电源规划问题, 可供选择的机组有两个类型, 分别是 300M W 和 700MW, 每年的最大装机可能为 2 台。如表 2 所示:

表 2 虚拟变量简化描述规划方案

第一种类型	第二种类型	总的新增装机容量(MW)	μ
机组 300M W	机组 700M W		
0	0	0	1
1	0	300	2
2	0	600	3
0	1	700	4
1	1	1000	5
2	1	1300	6
0	2	1400	7
1	2	1700	8
2	2	2000	9

如上图所示, $\mu=1$ 即表示该阶段没有新增机组, $\mu=5$, 表示该阶段新增一台 300MW, 一台 700MW, 总共新增 1000MW 装机容量。因为 μ 代表的都是可能组合, 实际上也减少了在实际运算中不用虚拟变量简化前非可行解出现的频率, 从而提高了运算的速度。

4.2 GPHA 算法启动与运行

GA 算法随机为粒子随机的从集合 μ 中选择对应的值, 开始计算相应的单个粒子的和多个粒子的位置。开始变异、交叉、和选择算子, 优化其为粒子群粒子的位置。

计算其局部和全局最佳的适应度值, 利用公式(13)对粒子群中的速度向量进行更新。

在更新粒子速度的基础上, 利用公式(12)进行粒子群中粒子位置的更新。

在更新粒子群的位置之后, 对于每个粒子代表的方案进行适应度值的计算, 本文设计的适应度评价函数依据罚函数原理, 对于非可行解的出现引入惩罚因子, 使得其适应度值表现较可行解相差很多, 这样可以减少在后续的优化进程中非可行解的出现概率, 提高运算的效率。本文对电源规划问题建立模型中的三个约束条件中, 装机容量约束由于引入了虚拟变量, 因而不存在不负荷这一约束的非可行解, 故不用设立惩罚因子。对于备用约束和可靠性标准约束分别设立惩罚因子 l_1 和 l_2 。整体的适应度评价函数可以由下式表示:

$$FC_i = [F_i + l_1 \sum \phi_1 + l_2 \sum \phi_2] \quad (15)$$

其中, FC_i 为第 i 个粒子总的适应度值, F_i 为第 i 个粒子对应的目标函数值, $\sum \phi_1$ 和 $\sum \phi_2$ 分别为第 i 个粒子对于备用约束和可靠性标准约束的违背程度。

重复上述过程, 当达到实现设定的叠代次数时, 算法终止。

5 实例分析

5.1 实例运算环境描述

本文所设计算例,在 Pentium 3.0G 630, 1024M memory 的微机系统上,以 MATLAB7.0.3 为开发工具。

5.2 实验设计描述

本文算例中选取某省 10 年电网规划中负荷预测的数据,负荷预测需求如下表 3 所示。该省区域内总装机容量为 15000MW,规划期分别设定为 10 年。

表 3 某省电网未来十年电网规划中负荷预测数表表格

年份	阶段					
	0	1	2	3	4	5
尖峰负荷 (MW)	11330	13000	14800	16200	17500	18700

在此需求情况下,假设有 5 种备选的不同燃料类型的机组,分别为煤燃料机组、水力发电机组、核能发电机组、风能发电机组、天然气发电机组,其对应的最大建设能力约束分别为:5, 4, 2, 2, 1。参照文献[11],将本算例中系统的最小、最大备用率分别为设定为需求的 10%, 20%。投资成本在年初计算,运行成本在年终计算,收益在年末计算最后换算为基期的现值进行比较。假设机组的闲置成本为 0.05 元/kWh。在此前提下用前面设计的模型和算法进行编程运算。设定最大叠代次数为 1000 次。并且分别用动态规划, GA、PSO 算法同时对本文引用数据进行测算,作为与本文提出算法的对比。

如图 1 所示,可以看出在具体的优化过程中, GPHA 算法在对电源规划方案寻优问题的处理上效率更高,在更短的时间内更容易寻找到全局最优解。




图 1 GPHA 与 PSO 及 GA 算法优化过程示意图

如下表 4 所示,通过比较四种算法的优化过程和结果,可以看出, GPHA 算法较传统的动态规划方法效率提高显著,结合了 GA 和 PSO 算法的优点,从而达到了更好的优化效果。

表 4 GPHA 算法与其他算法优化结果比较示意表

	目标函数值 (亿)	叠代次数 (次)	运算时间 (分)
PSO	319.7	1000	15
GA	323.4	1000	10
GPHA	318.58	1000	8
动态规划	318.57	1	278

6 结论

本文针对电源规划寻优问题尝试使用了新的改进型 GPHA 混合算法,在吸取进化计算(EC)和群体智能(SI)技术等优点的基础上,引入了罚函数和虚拟变量,进一步提高了算法的优化速度。通过算例测算,将改进算法与 PSO、GA 以及动态规划方法优化过程以及结果进行比较,证明该算法在处理电源规划寻优问题时更为快速有效。值得指出的是本文对于电源规划问题中的不确定性因素考虑不够,实例计算与实际电源规划问题存在一定的差距。如何全面有效的描述电源规划中的不确定性因素,提高算法在对于实际电源规划工作的决策支持效果,将是今后需要进一步研究的。

参考文献:

- [1] 侯煦光. 电力系统最优规划[M]. 武汉: 华中理工大学出版社, 1991.
- [2] 叶泽. 电力竞争[M]. 中国电力出版社, 北京: 2004.
- [3] Climaco J., C. H., Martins A. G., et al. A multiple objective linear programming model for power generation expansion planning[J]. International Journal of Energy Research, 1995, 19(5): 419- 432.
- [4] Antunes C., Martins A., Gomes, et al. A multiple objective mixed integer linear programming model for power generation expansion planning[J]. Energy, 2004, 29(4): 613- 627.
- [5] Jia N., Yokoyama R., Zhou Y., et al. Optimal generation expansion planning under the deregulated market based on an improved DP approach[C]. Power Plants and Power Systems Control 2000, Proceedings volume from the IFAC Symposium, 2000, 251- 255.
- [6] 韩新阳, 胡兆光, 李敬如. 考虑环保因素的最小费用电源规划研究[J]. 国际电力, 2003, 7(3): 14- 17.
- [7] 吴耀武, 侯云鹤, 熊信良, 等. 基于遗传算法的电力系统电源规划模型[J]. 电网技术, 1999, 23(2): 10- 14.

- [8] Chung T. S., Li Y. Z., Wang Z. Y.. Optimal generation expansion planning via improved genetic algorithm approach[J]. International Journal of Electrical Power and Energy System, 2004, 26(8): 655– 659.
- [9] Kannan S., Slochanal S., Mary Raja, et al. Application of particle swarm optimization technique and its variants to generation expansion planning problem[J]. Electric Power Systems Research, 2004, 70(3): 203– 210.
- [10] Tsukada T., Tamura T., Kitagawa S., et al. Optimal operational planning for cogeneration system using particle swarm optimization[C]. Proceedings of the 2003 IEEE Swarm Intelligence Symposium. SIS' 03 (Cat. No. 03EX706), 2003, 138– 43.
- [11] Sevilgen S. H., Erdem H. H., Cetin B., et al. Effect of economic parameters on power generation expansion planning[J]. Energy Conversion and Management, 2005, 46(11): 1780– 1789.
- [12] 黄席樾, 胡小兵, 何传江, 等. 现代智能算法理论与应用[M]. 北京: 科学出版社, 2004.
- [13] Kennedy J., Eberhart R. C.. Particle swarm optimization. IEEE. Proceedings of The 6th conference on neural networks [C]. NJ Piscataway: IEEE Service center, 1995: 1942– 1948.
- [14] M. Clerc, J. Kennedy. The particle swarm: explosion stability and convergence in a multi– dimensional complex space[J]. Evolutionary Computing, 2002, 6 (1): 58– 73.
- [15] Angeline Peter J.. Using selection to improve particle swarm optimization[C]. IEEE Int Conf Comput Intell, 2003: 84– 86.

Application of the Improved Particle Swarm Optimization Algorithm in the Generation Expansion Planning

LI Xiang, NIU Dong-xiao, YANG Shang-dong

(Business Administration School, North China Electric University, Beijing 102206, China)

Abstract: The generation expansion planning is a complex non– linear and combinatorial optimization problem. With the plan time lengthening and the factors considered increasing, the traditional optimization methods can not make the satisfactory result. And also so, it's applications in the practice are limited. Firstly, the model of the generation expansion was set up. Then, the paper improved the iteration tactic of the particle swarm optimization. It proposed a hybrid algorithm which combined genetic algorithm with particle swarm optimization (GPHA). Considering the various factors concerned, the paper introduced fictitious variables to briefly describe generation expansion planning problem in the optimization process. For the fitness function, the paper used penalty function to enhance the effect. In the end of this paper, it chose actual load forecast and the system load actual data of some province, quoted in the similar question regarding correlation parameter supposition, and compared the algorithm with the ordinary genetic algorithms, particle swarm optimization algorithm and the traditional dynamic programming algorithm. The result proves that the new algorithm has done well in the aspects of optimization and speed.

Key words: genetic algorithm; particle swarm optimization algorithm; generation expansion planning; penalty function; fictitious variable