

动态评价粒子群优化及风电场微观选址

万春秋¹, 王峻², 杨耕¹, 张兴³

(1. 清华大学自动化系, 北京 100084; 2. 同济大学控制科学与工程系, 上海 201804; 3. 清华大学航天航空学院, 北京 100084)

摘要: 提出了动态评价方法处理一类约束优化问题. 将目标函数值和约束违反量进行动态归一化处理, 再进行加权求和, 动态评价解的优化性能. 不仅解决了惩罚因子确定困难的问题, 而且增加了优化算法的多样性, 提高了优化算法搜索全局最优解的能力. 将动态评价方法引入粒子群算法, 求解风电场微观选址优化问题. 仿真结果表明, 动态评价方法提高了风电场发电量和风能利用效率. 此外, 该方法可广泛应用于其他优化算法以求解约束优化问题.

关键词: 动态评价; 粒子群优化算法; 风电场微观选址

中图分类号: TP202.7 **文献标识码:** A

Dynamic evaluation based particle swarm optimization and wind farm micrositing

WAN Chun-qiu¹, WANG Jun², YANG Geng¹, ZHANG Xing³

(1. Department of Automation, Tsinghua University, Beijing 100084, China;

2. Department of Control Science and Engineering, Tongji University, Shanghai 201804, China;

3. School of Aerospace, Tsinghua University, Beijing 100084, China)

Abstract: A dynamic fitness evaluation method is proposed to handle constrained optimization problems. The values of the objective and the constraint violation are both dynamically normalized and summed up with corresponding weights to evaluate the fitness values. The proposed method not only overcomes the difficulty in tuning the coefficients of penalty function, but also increases the diversity and global search ability of the optimization algorithm. It is applied to the particle swarm optimization algorithm to solve the optimization problem in micrositing a wind farm. Simulation results demonstrate that the power generated by the wind farm is increased, so is the efficiency of wind energy exploitation. Moreover, the proposed method can be widely applied to other optimization algorithms to solve constrained optimization problems.

Key words: dynamic evaluation; particle swarm optimization algorithm; micrositing of wind farm

1 引言(Introduction)

约束优化问题的求解广泛采用约束处理技术与非约束优化算法相结合的方法. 惩罚函数法是应用较多的约束处理技术, 它通过引入惩罚因子将约束优化问题转化为非约束优化问题^[1], 再采用非约束优化算法进行求解. 惩罚函数法中静态惩罚法应用最普遍, 其惩罚因子在优化过程中为恒值. 为了与本文提出的动态评价方法相区别, 本文将该方法称为静态评价方法. 在静态评价方法中, 惩罚因子的选取本身就是一个复杂的优化问题. 如果惩罚因子过小, 对非可行解的惩罚过轻, 可能会得不到可行解; 相反, 如果惩罚因子过大, 对非可行解的惩罚过重, 可行解的质量较低, 得不到问题的最优解. 为了解决以上问题, 本文提出了一种解的动态评价方法, 在优化过程中动态平衡解的目标函数值和约束违反量, 同时提高优化算法的搜索精度和收敛速度.

风电场微观选址是指根据风电场地形、地貌和风能特征, 合理排布风机安装位置, 提高风电场的经济效益和风能利用效率^[2]. 风电场微观选址优化问题的研究较少, 工程中多采用经验交错方案. 在已有的微观选址优化研究中, 主要集中于“离散”方案^[3~5], 风电场被划分为离散的网格, 风机只能安放在网格的中心. 这种方法虽然简化了问题的求解, 却降低了风机选址的自由度. 为了解决该问题, 万春秋等提出了离散网格与连续优化相结合的方法^[6]. 由于没有进行风机之间最小允许距离的约束, 风机的安全问题不能得到保障. 因此, 对风机之间的距离进行约束是优化微观选址需要解决的一个关键问题.

由以上分析, 风电场的微观选址为复杂的非线性约束优化问题. 该问题约束条件多, 目标函数的导数难以计算, 并且计算量大, 无法采用以梯度为基础的传统优化算法进行求解. 因此, 本文将动态评价方法

引入粒子群优化算法,进行微观选址问题的优化求解,取得了较好的效果.

2 动态评价粒子群优化(Dynamic evaluation based particle swarm optimization)

根据具体优化目标,优化问题可分为最小化优化问题和最大化优化问题.对最小化优化问题取负值,可转化为最大化优化问题.本文主要针对如下的最大化优化问题对提出的方法进行说明.优化问题的目标函数和约束条件为

$$\begin{aligned} \max \mathcal{P}(\mathbf{z}), g_j(\mathbf{z}) \leq 0, j \in \{1, \dots, C\}, \\ \mathbf{z}_{\min} \leq \mathbf{z} \leq \mathbf{z}_{\max}. \end{aligned} \quad (1)$$

式中: $\mathbf{z} = [z_1 \ \dots \ z_n]$ 为维数为 n 的解向量, $\mathcal{P}(\mathbf{z})$ 为解 \mathbf{z} 的目标函数, $g_j(\mathbf{z}) \leq 0$ 为不等式约束, C 为不等式约束的数目. $\mathbf{z}_{\min} = [z_{\min,1} \ \dots \ z_{\min,n}]$ 和 $\mathbf{z}_{\max} = [z_{\max,1} \ \dots \ z_{\max,n}]$ 分别为解向量的下界和上界. 设 S 为满足边界条件的搜索空间, $F \subset S$ 为满足所有约束条件的可行空间.

2.1 动态评价方法(Dynamic fitness evaluation method)

静态评价方法中解 \mathbf{z} 的适应度函数为

$$\mathcal{F}(\mathbf{z}) = \mathcal{P}(\mathbf{z}) - \gamma\varphi(\mathbf{z}), \quad (2)$$

式中: γ 为惩罚因子,在优化过程中为恒值; $\varphi(\mathbf{z})$ 为解 \mathbf{z} 的约束违反量. 约束违反量 $\varphi(\mathbf{z})$ 为 0, 表示解 \mathbf{z} 满足所有约束条件,该解可行; 约束违反量 $\varphi(\mathbf{z})$ 越大,表示解 \mathbf{z} 离可行区域越远. 在优化过程的不同阶段,目标函数与约束违反量的重要性不同,静态方法只能选择一个折中的惩罚因子,优化解质量较低. 而且,解 \mathbf{z} 的适应度值只取决于 $\mathcal{P}(\mathbf{z})$, $\varphi(\mathbf{z})$ 和 γ , 不能根据当前代所有解的综合信息进行动态变化,不利于解的全局搜索,使得其优化精度相对较低. 另外,目标函数值和约束违反量具有不同的量级,惩罚因子需要根据具体问题的特性通过大量试验确定. 对于复杂优化问题,计算工作量将会很大.

为了解决以上问题,本文提出了一种动态评价方法,先将比较所有解的目标函数值和约束违反量分别进行归一化处理,然后将两项指标进行加权求和,动态平衡目标函数与可行性之间的关系,以获得问题的最优可行解.

解的目标函数值和约束违反量分别代表优化目标和可行性,这两项指标在优化问题中的量级可能相差较大. 如果在适应度函数中直接代入这两项指标,会使优化的搜索方向偏向于量级大的一项,得不到问题的最优解. 为了在同一函数内精确地反映这两项信息,首先需要对它们在各自的范围内进行归一化处理. 令当前进行比较的解种群为 $Z_C = [\mathbf{z}_1 \ \dots \ \mathbf{z}_{NC}]$, NC 为解数目,其中最小目

标函数值和最大目标函数值分别为:

$$\mathcal{P}_{\min} = \min\{\mathcal{P}(\mathbf{z}_i) : \mathbf{z}_i \in Z_{NC}\}, \quad (3)$$

$$\mathcal{P}_{\max} = \max\{\mathcal{P}(\mathbf{z}_i) : \mathbf{z}_i \in Z_{NC}\}, \quad (4)$$

最小约束违反量和最大约束违反量分别为:

$$\varphi_{\min} = \min\{\varphi(\mathbf{z}_i) : \mathbf{z}_i \in Z_{NC}\}, \quad (5)$$

$$\varphi_{\max} = \max\{\varphi(\mathbf{z}_i) : \mathbf{z}_i \in Z_{NC}\}. \quad (6)$$

本文主要研究最大化优化问题,目标函数值和约束违反量经过归一化处理后应该具有最大化的特性,因此本文采用如下的归一化形式:

$$\mathcal{P}'(\mathbf{z}) = \frac{\mathcal{P}(\mathbf{z}) - \mathcal{P}_{\min}}{\mathcal{P}_{\max} - \mathcal{P}_{\min}}, \quad (7)$$

$$\varphi'(\mathbf{z}) = \frac{\varphi_{\max} - \varphi(\mathbf{z})}{\varphi_{\max} - \varphi_{\min}}. \quad (8)$$

式中: $\mathcal{P}'(\mathbf{z})$ 为归一化处理后解 \mathbf{z} 的目标函数值, $\varphi'(\mathbf{z})$ 为约束违反量,它们的取值范围都在 $[0,1]$ 之间. 解 \mathbf{z} 的目标函数值越高, $\mathcal{P}'(\mathbf{z})$ 越大; 相反,解 \mathbf{z} 的约束违反量越小, $\varphi'(\mathbf{z})$ 越大,表示解 \mathbf{z} 距离可行域越近,可行性越好.

对 $\mathcal{P}'(\mathbf{z})$ 和 $\varphi'(\mathbf{z})$ 加权求和,得到解 \mathbf{z} 的适应度值

$$\mathcal{F}(\mathbf{z}) = w\mathcal{P}'(\mathbf{z}) + (1-w)\varphi'(\mathbf{z}), \quad (9)$$

式中: w 和 $1-w$ 分别为 $\mathcal{P}'(\mathbf{z})$ 和 $\varphi'(\mathbf{z})$ 的权重. $\mathcal{F}(\mathbf{z})$ 的取值范围为 $[0,1]$, 表示解 \mathbf{z} 的优化性能,其值越高,优化性能越好.

在公式(9)中,当 w 较大时,目标函数值在适应度函数中占的比重较大; 相反,当 w 较小时,可行性在适应度函数中占的比重较大. 本文在优化过程中对 w 采取如下指数减小的方式:

$$w = w_{\min} + (w_{\max} - w_{\min}) \exp(-\alpha \frac{t}{T_{\max}}), \quad (10)$$

式中: w_{\min} 和 w_{\max} 分别为权重 w 的最小值和最大值, $t \in \{1, \dots, T_{\max}\}$ 为当前迭代次数, T_{\max} 为最大迭代次数, α 为下降参数,决定权重 w 在优化过程中下降的速度. 对于 w 为 1 的极端情况,对解的评价只包含目标函数值,可行性没有被考虑,属于目标函数优化问题,虽然目标函数值得到优化,但是可行性得不到保证. 对于 w 为 0 的极端情况,对解的评价只包含可行性,目标函数值没有被考虑,属于约束满足问题,虽然优化求解可以获得可行解,但是目标函数值差,达不到优化的目标. 为了达到目标函数与可行性的双重优化,本文令 w_{\min} 和 w_{\max} 分别为 0.1 和 0.9.

图1为下降参数 α 取不同值时权重 w 随迭代次数 t 的变化曲线比较. 当 α 为 5 时,权重 w 随迭代次数 t 下降较慢,不利于可行解的搜索. 当 α 分别为 20 和 30 时,权重 w 随迭代次数 t 下降较快,不利于可行性稍差而目标函数值较高解的搜索. 当 α 为 10 时,权重 w

在 t 为1000时基本下降到 w_{\min} . 这样, 则通过式(10), 在优化过程的初期, w 值较大, 目标函数值在适应度函数中占的比重较大, 可以增强对可行性稍差而目标函数值较高解的搜索, 有利于优化求解的全局搜索; 在优化过程的后期, w 值较小, 可行性在适应度函数中占的比重较大, 可以增强对目标函数值较高可行解的搜索, 有利于优化搜索的收敛. 因此, 本文在优化仿真中取下降参数 α 为10.




图1 权重变化曲线比较

Fig. 1 Comparison of weight variation curves

假设 $\mathcal{P}(\mathbf{z}_1)$ (或 $\mathcal{P}(\mathbf{z}_2)$)和 $\varphi(\mathbf{z}_1)$ (或 $\varphi(\mathbf{z}_2)$)分别为解 \mathbf{z}_1 (或 \mathbf{z}_2)的目标函数值和约束违反量, 采用上述的动态评价方法具有如下性质:

性质1 $\forall \mathbf{z}_1, \mathbf{z}_2 \in F$, 如果 $\mathcal{P}(\mathbf{z}_1) > \mathcal{P}(\mathbf{z}_2)$, 则有 $\mathcal{F}(\mathbf{z}_1) > \mathcal{F}(\mathbf{z}_2)$. 即两个可行解进行比较, 目标函数值高者更优.

性质2 $\forall \mathbf{z}_1, \mathbf{z}_2 \in S - F$, 且 $\varphi(\mathbf{z}_1) = \varphi(\mathbf{z}_2) > 0$, 如果 $\mathcal{P}(\mathbf{z}_1) > \mathcal{P}(\mathbf{z}_2)$, 则有 $\mathcal{F}(\mathbf{z}_1) > \mathcal{F}(\mathbf{z}_2)$. 即两个约束违反量相同的非可行解进行比较, 目标函数值高者优于目标函数值低者.

性质3 $\forall \mathbf{z}_1, \mathbf{z}_2 \in S - F$, 如果 $\varphi(\mathbf{z}_1) > \varphi(\mathbf{z}_2) > 0$ 和 $\mathcal{P}(\mathbf{z}_1) > \mathcal{P}(\mathbf{z}_2)$, 可能有 $\mathcal{F}(\mathbf{z}_1) > \mathcal{F}(\mathbf{z}_2)$. 即两个约束违反量不同的非可行解进行比较, 约束违反量和目标函数值高的非可行解可能会优于约束违反量和目标函数值低的非可行解.

性质4 $\forall \mathbf{z}_1 \in F$ 和 $\forall \mathbf{z}_2 \in S - F$, 即 $\varphi(\mathbf{z}_1) = 0$, $\varphi(\mathbf{z}_2) > 0$, 可能会存在 $\mathcal{P}(\mathbf{z}_1) < \mathcal{P}(\mathbf{z}_2)$, 使得 $\mathcal{F}(\mathbf{z}_1) < \mathcal{F}(\mathbf{z}_2)$. 即可行解与非可行解进行比较, 目标函数值高的非可行解可能会优于目标函数值低的可行解.

因此, 动态评价方法的性质1和性质2可以使优化算法逐渐获得目标函数值更高的可行解; 性质3和性质4可以利用目标函数值高而可行性稍低的非可行解的信息, 扩大搜索区域, 提高优化算法获取全局最优解的概率.

在基于动态评价方法的优化过程中, 需要根据比较所有解的目标函数值和约束违反量动态确定 \mathcal{P}_{\min} , \mathcal{P}_{\max} , φ_{\min} 和 φ_{\max} , 相当于在适应度函数

中“嵌入”了一个自适应变化的隐性惩罚因子, 个体解的适应度值根据每一代比较所有解的综合信息进行自适应变化. 在优化过程的前期, 个体解在解空间分布分散, 解之间的目标函数值和约束违反量都相差较多, 个体解的适应度值变化较大, 使得个体解在解比较中的优化性能也变化较大, 扩大了优化搜索的方向和搜索范围, 使得优化算法更容易跳出局部极值, 增加了优化算法获取全局极值的概率. 在优化过程的后期, 个体解分布集中, 解之间的目标函数值和约束违反量都相差较少, 个体解的适应度值变化较小, 使得个体解在解比较中的优化性能也变化较小, 减小了解的搜索范围, 增加了算法的收敛速度. 此外, 通过采用指数变化的 w 取值, 不需要对具体问题进行大量的试验获得合适的惩罚因子, 大大减小了优化工作的计算量.

2.2 粒子群优化(Particle swarm optimization)

粒子群算法是受鱼群、鸟群等的捕食行为启发而提出的一种基于种群的全局随机优化算法^[7]. 该算法不需要计算优化问题的导数, 代码简单, 需要调整的参数少, 收敛速度快, 尤其适用于求解复杂的实值优化问题^[8,9].

粒子群算法优化的机制为: 在搜索空间中随机产生具有位置和速度的初始种群, 种群中粒子的位置 \mathbf{z} 代表问题的解, 速度 \mathbf{v} 代表对位置 \mathbf{z} 的修正, 整个种群的位置表示为 $\mathbf{Z} = [\mathbf{z}_1^T \ \mathbf{z}_2^T \ \cdots \ \mathbf{z}_{NP}^T]^T$, 速度表示为 $\mathbf{V} = [\mathbf{v}_1^T \ \mathbf{v}_2^T \ \cdots \ \mathbf{v}_{NP}^T]^T$, NP 为粒子的数量. 从初始种群出发, 通过随机向粒子自身经历的最好位置 \mathbf{z}^p 和种群经历的最好位置 \mathbf{z}^g 靠近, 调整种群中粒子的速度 \mathbf{V} 和位置 \mathbf{Z} , 逐渐寻求问题的最优解.

粒子群算法的发展经历了3种主要形式^[7~11], 其中收缩因子形式收敛速度快, 优化过程不受最大允许速度的限制. 令粒子运动的最大允许速度为

$$\mathbf{v}_{\max} = [v_{\max,1} \ \cdots \ v_{\max,n}],$$

则粒子运动的速度和位置更新方程为:

$$v_{i,k}(t+1) = K(v_{i,k}(t) + c_1 r_1 (z_{i,k}^p(t) - z_{i,k}(t)) + c_2 r_2 (z_k^g(t) - z_{i,k}(t))), \quad (11)$$

$$v_{i,k}(t+1) = \begin{cases} -v_{\max,k}, & v_{i,k}(t+1) < -v_{\max,k}, \\ v_{\max,k}, & v_{i,k}(t+1) > v_{\max,k}, \\ v_{i,k}(t+1), & \text{其他}, \end{cases} \quad (12)$$

$$z_{i,k}(t+1) = z_{i,k}(t) + v_{i,k}(t+1), \quad (13)$$

$$z_{i,k}(t+1) = \begin{cases} z_{\min,k}, & z_{i,k}(t+1) < z_{\min,k}, \\ z_{\max,k}, & z_{i,k}(t+1) > z_{\max,k}, \\ z_{i,k}(t+1), & \text{其他}. \end{cases} \quad (14)$$

式中: $i \in \{1, \dots, NP\}$ 为种群中粒子的索引, $k \in \{1, \dots, n\}$ 为粒子维数的索引, c_1 和 c_2 为正数, 分别表示认知和社会参数, r_1 和 r_2 为 $[0,1]$ 之间均匀分布的随机数,

$$K = \frac{2}{|2 - c - \sqrt{c^2 - 4c}|}, \quad c = c_1 + c_2 > 4$$

为收缩因子. 收缩因子的作用是在优化过程中减小速度的影响, 缩小整个种群的搜索范围.

粒子运动的初始位置和速度在相应的搜索空间中随机产生:

$$\begin{cases} z_{i,k}(0) = z_{\min,k} + r_3(z_{\max,k} - z_{\min,k}), \\ v_{i,k}(0) = -v_{\max,k} + 2r_4v_{\max,k}, \end{cases} \quad (15)$$

式中 r_3 和 r_4 为 $[0,1]$ 之间均匀分布的随机数.

2.3 算法流程(Flows of the algorithm)

虽然粒子群算法运算简单, 收敛速度快, 但该算法易过早地陷入局部极值, 在约束优化问题的求解中其“早熟”问题更加严重. 本文将提出的动态评价方法引入粒子群算法, 在搜索过程中动态评价粒子的优化性能, 增加优化算法的多样性, 使算法具有更好的全局搜索能力和更快的收敛速度.

动态评价粒子群算法流程为:

Step 1 设置算法参数, 包括种群规模 NP 、位置下界 \mathbf{z}_{\min} 和上界 \mathbf{z}_{\max} 、最大速度 \mathbf{v}_{\max} 、最大优化代数 T_{\max} 、下降参数 α . 令迭代次数 $t = 0$.

Step 2 种群初始化.

1) 利用公式(15)产生初始种群每个元素的位置和速度, 获得初始种群的位置 $Z(t)$ 和速度 $V(t)$.

2) 计算初始种群每个个体的目标函数值和约束违反量.

3) 令当前比较解种群为 $Z_C = Z(t)$, 利用公式(3)~(10)计算初始种群每个个体的适应度值. 令初始的粒子自身经历最好位置为 $Z^p(t) = Z(t)$, 且对 $\forall i \in \{1, \dots, NP\}$, 有

$$\mathcal{P}_i^p(t) = \mathcal{P}(\mathbf{z}_i(t)), \quad \varphi_i^p(t) = \varphi(\mathbf{z}_i(t)).$$

4) 令初始的种群经历最好位置及其目标函数值和约束违反量分别为

$$\begin{cases} \mathbf{z}^g(t) = \arg \max_{\mathbf{z}_i(t) \in Z(t)} \{\mathcal{F}(\mathbf{z}_i(t))\}, \\ \mathcal{P}^g(t) = \mathcal{P}(\mathbf{z}^g(t)), \quad \varphi^g(t) = \varphi(\mathbf{z}^g(t)). \end{cases}$$

Step 3 种群迭代.

1) 利用公式(11)~(14)更新种群中每个元素的速度和位置, 获得新种群的位置 $Z(t+1)$ 和速度 $V(t+1)$.

2) 计算种群 $Z(t+1)$ 中每个个体解的目标函数值和约束违反量.

3) 令当前比较解种群为

$$Z_C = [Z(t+1)^T \quad Z^p(t)^T \quad \mathbf{z}^g(t)^T]^T,$$

利用公式(3)~(10)计算种群 $Z(t+1)$ 、粒子自身经历最好位置 $Z^p(t)$ 和种群经历最好位置 $\mathbf{z}^g(t)$ 的适应度值.

4) $\forall \mathbf{z}_i(t+1) \in Z(t+1)$, 如果

$$\mathcal{F}(\mathbf{z}_i(t+1)) > \mathcal{F}(\mathbf{z}_i^p(t)),$$

则有

$$\begin{cases} \mathbf{z}_i^p(t+1) = \mathbf{z}_i(t+1), \\ \mathcal{P}_i^p(t+1) = \mathcal{P}(\mathbf{z}_i(t+1)), \\ \varphi_i^p(t+1) = \varphi(\mathbf{z}_i(t+1)), \end{cases}$$

否则

$$\begin{cases} \mathbf{z}_i^p(t+1) = \mathbf{z}_i^p(t), \\ \mathcal{P}_i^p(t+1) = \mathcal{P}_i^p(t), \\ \varphi_i^p(t+1) = \varphi_i^p(t). \end{cases}$$

如果 $\mathcal{F}(\mathbf{z}_i(t+1)) > \mathcal{F}(\mathbf{z}^g(t))$, 则有

$$\begin{cases} \mathbf{z}^g(t+1) = \mathbf{z}_i(t+1), \\ \mathcal{P}^g(t+1) = \mathcal{P}(\mathbf{z}_i(t+1)), \\ \varphi^g(t+1) = \varphi(\mathbf{z}_i(t+1)). \end{cases}$$

5) 若种群经历最好解在上述迭代更新中没有被改进, 则有

$$\begin{cases} \mathbf{z}^g(t+1) = \mathbf{z}^g(t), \\ \mathcal{P}^g(t+1) = \mathcal{P}^g(t), \\ \varphi^g(t+1) = \varphi^g(t). \end{cases}$$

否则, 直接转到 Step 4.

Step 4 收敛条件判断. 如果 $t+1 = T_{\max}$, 停止迭代, 输出优化结果; 否则, $t = t+1$, 转到 Step 3.

本文中目标函数值与约束违反量的计算方法具体见第3节优化模型部分.

3 风电场微观选址问题描述(Description of wind farm micrositing problem)

本文风电场微观选址的目标是在风机数目已知的条件下, 确定各台风机的具体位置, 达到风电场发电功率最大化. 采用的模型主要包括风向及风速模型、尾流模型、功率计算模型、目标函数和约束条件模型.

风向的变化采用风向玫瑰图. 风向玫瑰图由多个扇形组成, 代表风电场的主要风向, 每一扇形的长度代表该风向在全年占的比例, 并满足以下关系:

$$\sum_{p=1}^M \rho_p = 1, \quad (16)$$

式中: M 为风向的数目, ρ_p 为风向 p 的年度比例.

风速的年度分布采用威布尔分布, 其概率密度函

数为^[12]

$$f(u) = \frac{\kappa}{\nu} \left(\frac{u}{\nu}\right)^{\kappa-1} \exp\left(-\left(\frac{u}{\nu}\right)^\kappa\right), \quad (17)$$

式中: u 为风速, κ 为形状参数, ν 为尺度参数.

尾流采用线性模型表示. 根据动量平衡定理和贝兹(Betz)极限理论, 处于风机下游距离为 d 处的尾流风速为^[13,14]

$$\tilde{u}_0(d) = u_0 \left(1 - \left(1 - \sqrt{1 - C_T}\right) \left(\frac{D}{D + 2\beta d}\right)^2\right), \quad (18)$$

式中: u_0 为入口风速, C_T 为风机推力因子, D 为风机转子直径, β 为尾流衰减常数.

根据动能平衡定理, 风机 a 的入流风速为^[13,14]

$$u_a = u_0 \left(1 - \sqrt{\sum_{\substack{b=1 \\ b \neq a}}^N (l_{b,a} \left(1 - \frac{\tilde{u}_b(d_{b,a})}{u_0}\right))^2}\right), \quad (19)$$

式中: N 为风机数目, $\tilde{u}_b(d_{b,a})$ 为风机 b 在风机 a 位置处的尾流风速,

$$d_{b,a} = y'_b - y'_a,$$

y'_a (或 y'_b)为坐标变换后风机 a (或 b)在来风方向上的坐标, $l_{b,a}$ 为风机 b 在风机 a 位置处的风速损失比例.

上述为单风向的风速模型, 在多风向的条件下, 风机的风速需根据风向、入口风速和与其他风机的相对位置关系分别进行计算. 根据公式(18)~(19), 风机 a 在风向 p 的风速可以表示为

$$u_{a,p} = \mathcal{U}(a, p, u_{0,p}, \mathbf{z}), \quad (20)$$

式中: $u_{0,p}$ 为风向 p 的入口风速, $\mathbf{z} = [\mathbf{x} \ \mathbf{y}]$ 为所有风机的坐标向量,

$$\mathbf{x} = [x_1 \ \cdots \ x_a \ \cdots \ x_N],$$

$$\mathbf{y} = [y_1 \ \cdots \ y_a \ \cdots \ y_N],$$

$$a \in \{1, \dots, N\},$$

(x_a, y_a) 为风机 a 在风电场中的坐标.

已知风机的风功率曲线 $P(\cdot)$ 和风能分布, 风电场的年均发电功率为

$$\mathcal{P}(\mathbf{z}) = \sum_{p=1}^M \rho_p \left(\sum_{a=1}^N \int_{u_{in}}^{u_{out}} f_p(u) P(u_{a,p}) du\right), \quad (21)$$

式中: u_{in} 为风机的切入风速, u_{out} 为切出风速, $f_p(u)$ 为风向 p 的风速概率密度函数, $P(u_{a,p})$ 为风机 a 在风向 p 的实际风速为 $u_{a,p}$ 时的发电功率.

本文中, 风电场微观选址的主要目的是减小风机之间的相互干扰, 达到风电场发电量的最大化. 此外, 为了保证风机运行的安全, 风机之间必须满足最小允许距离的要求. 令风机之间的最小允许距离为 d_{min} , 风电场微观选址的目标函数为

$$\max \mathcal{P}(\mathbf{z}), \quad (22)$$

约束条件为

$$\begin{cases} g_j(\mathbf{z}) = (x_a - x_b)^2 + (y_a - y_b)^2 - d_{min}^2 \geq 0, \\ 0 \leq x_a, x_b \leq X_{max}, 0 \leq y_a, y_b \leq Y_{max}, \\ j \in \{1, \dots, C\}, \forall a \neq b, a, b \in \{1, \dots, N\}. \end{cases} \quad (23)$$

式中: $g_j(\mathbf{z})$ 为风机 a 与风机 b 之间的位置约束, $C = N(N - 1)/2$ 为约束的数目, X_{max} 为风电场的长度, Y_{max} 为风电场的宽度, 解空间的下界和上界可分别表示为

$$\mathbf{z}_{min} = [0 \ \cdots \ 0]_{1 \times 2N}$$

和

$$\mathbf{z}_{max} = [[X_{max} \ \cdots \ X_{max}]_{1 \times N} [Y_{max} \ \cdots \ Y_{max}]_{1 \times N}].$$

由此可知, 风电场微观选址为具有大量约束条件的非线性复杂优化问题.

优化求解中约束反量定义为

$$\varphi(\mathbf{z}) = \sqrt{\sum_{j=1}^C |\min\{0, g_j(\mathbf{z})\}|}, \quad (24)$$

表示解 \mathbf{z} 与可行区域之间的距离.

4 仿真结果及分析(Simulation results and analysis)

风电场微观选址常采用交错选址方案. 假设风电场区域为1500 m × 1500 m, 风电场的风能分布参数如表1所示.

表1 风能分布参数

风向/(°)	比例	尺度参数	形状参数
0(北)	0.020	6.4	1.79
30	0.044	7.4	1.81
60	0.056	8.8	1.65
90(东)	0.076	7.0	1.96
120	0.061	7.3	1.83
150	0.053	7.5	1.81
180(南)	0.078	8.0	1.89
210	0.083	8.9	1.85
240	0.123	9.8	1.96
270(西)	0.158	9.9	1.92
300	0.167	9.3	1.93
330	0.079	7.8	1.75

由表1可得风电场平均风速为7.66 m/s, 所以选用额定功率为850 kW的风机^[15]. 该型号风机的风轮直径 D 为50.2 m, 轮毂高度为50 m, 推力因子为常数0.88, 功率曲线如图2所示. 交错微观选址方案如图3所示, 图中“×”表示风机位置. 在该方案中, 32台风机交错排布, 由此减小风机之间的相互影响和风能损失, 风电场的实际年均发电功率为8428.5 kW, 风电场发电效率为84.25%. 该方案虽

然简单易行,但未考虑风能分布和风机型号等对微观选址至关重要的因素,风电场产能还有进一步提高的空间.




图2 风机功率曲线

Fig. 2 Power curve of turbines




图3 经验的选址方案

Fig. 3 Empirical micrositing scheme

根据第3节的分析,风电场微观选址为最大化约束优化问题.本文采用动态评价方法评价风机位置解 \mathbf{z} 的优化性能,将约束优化问题转化为非约束优化问题,并采用粒子群算法对转化之后的优化问题进行求解,简称为动态粒子群算法(DPSO).同时,为了说明动态评价方法的有效性,本文对静态评价方法取不同的惩罚因子值处理约束条件,并采用粒子群算法进行优化问题的求解,简称静态粒子群算法(SPSO).

在优化仿真中,最小允许距离设置为 $d_{\min} = 4D$.风电场的地表粗糙度为 $z_0 = 0.01 \text{ m}$,表示平坦的平原.风机个数与经验方案相同,即32,优化变量的个数为64.根据前期研究结果,粒子群算法的认知参数 c_1 和社会参数 c_2 分别取为2.8和1.3时优化效果最好,粒子数量64兼顾了优化精度与优化时间,故本文采用该取值组合.根据风电场的区域范围,位置下界为 $\mathbf{z}_{\min} = [0 \ \cdots \ 0]_{1 \times 2N}$,上界为 $\mathbf{z}_{\max} = [1500 \ \cdots \ 1500]_{1 \times 2N}$,最大速度取为解空间的动态范围 $\mathbf{v}_{\max} = \mathbf{z}_{\max} - \mathbf{z}_{\min} = [1500 \ \cdots \ 1500]_{1 \times 2N}$,

最大优化代数 T_{\max} 为2000.动态评价方法中下降参数 α 取为10,静态评价方法中惩罚因子 γ 分别取为100,1000和10000.

表2为两种优化算法在给定的参数取值时分别进行10次仿真获得的可行解个数(NF)、可行解中目标函数值的最好值(Best)、平均值(Average)、最差值(Worst)和标准偏差(S.D.).由表2可知,惩罚因子为100时静态粒子群算法获得可行解的个数为0,惩罚因子分别为1000和10000时的静态粒子群算法、动态粒子群算法获得可行解的个数都为10.在统计意义上,动态粒子群算法结果明显好于静态粒子群算法结果.

表2 优化结果比较

Table 2 Comparison of optimal results

	NF	Best	Average	Worst	S.D.
SPSO($\lambda = 100$)	0	—	—	—	—
SPSO($\lambda = 1000$)	10	9329.5	9220.3	9065.1	90.78
SPSO($\lambda = 10000$)	10	9256.5	9207.3	9104.5	95.07
DPSO	10	9401.7	9272.7	9099.3	94.94

惩罚因子分别为1000和10000时的静态粒子群算法、动态粒子群算法最好选址方案的风电场发电效率分别为93.26%,92.53%和93.98%.动态粒子群算法最好选址方案的风电场年均发电功率和发电效率均比经验交错方案提高了11.55%,比惩罚因子为1000时的静态粒子群算法提高了0.77%,比惩罚因子为10000时的静态粒子群算法提高了1.57%.很明显,通过采用本文提出的方法在连续空间优化风机位置,风机的尾流影响和风能损失降低,风资源得到更加有效的利用.

动态粒子群算法最好选址方案的风电场排布如图4所示.由图4可知,风机的位置根据风能分布和风机型号等进行了调整,且风机之间的距离满足最小允许距离的约束.




图4 优化的选址方案

Fig. 4 Optimal micrositing scheme

图5和图6为两种算法最好结果的种群经历最好解的目标函数值和约束违反量的迭代过程. 动态粒子群算法的优化精度和收敛效果明显好于静态粒子群算法. 静态粒子群算法中, 惩罚因子为100时的目标函数优化结果与惩罚因子为10000时接近, 但是其约束违反量大于零, 优化解不可行.




图5 目标函数值优化过程

Fig. 5 Optimization process of objective value




图6 约束违反量优化过程

Fig. 6 Optimization process of constraint violation value

适应度值中目标函数值和约束违反量两项指标的比值反映了它们在每次优化迭代中的重要性. 动态评价方法中比值定义为

$$R_D(t) = \frac{\varphi'(z^g(t))}{P'(z^g(t))}, \quad (25)$$

静态评价方法中比值定义为

$$R_S(t) = \frac{\gamma\varphi(z^g(t))}{P(z^g(t))}, \quad (26)$$

图7为比值在前500代的迭代过程, 图(a)为动态粒子群算法的比值迭代过程, 图(b)和(c)为惩罚因子分别为100, 1000和10000时静态粒子群算法的比值迭代过程.

由图7可知, 在优化过程的前期, 动态评价方法的比值 R_D 在1上下起伏变化, 大于1为可行性较优而目标函数值稍差的情况, 小于1为目标函数值较优而可行性稍差的情况. 由此可知, 解的优化性能变化较大, 算法的多样性大, 有利于解的全局搜索. 在优化

过程的后期, 动态评价方法比值 R_D 收敛于1, 说明最好个体的目标函数值与可行性分别为种群最优, 种群追随最好个体运动, 减小了解的搜索范围, 有利于算法的收敛.




图7 比值迭代过程

Fig. 7 Optimization process of ratio

在静态评价方法中, 当惩罚因子为100时, 对不可行解的惩罚较轻, 算法的多样性大. 但是比值 R_S 不能收敛于0, 优化解不可行. 当惩罚因子分别为1000和10000时, 对非可行解的惩罚较重, 比值 R_S 逐渐收敛于0, 优化解可行. 但是算法的多样性小, 不利于解的全局搜索. 因此, 静态评价方法不能兼顾算法多样性与解的可行性.

图5~7表明, 动态评价方法在优化过程中根据每一代解的综合信息对个体解的优化性能进行动态评价: 在优化的前期增加了算法的多样性, 有利于算法跳出局部极值; 在优化的后期, 主要是进行局部搜索, 收敛速度较快. 此外, 动态评价法利用目标函数值较高的非可行解的信息, 增加了优化算法寻求全局最优解的概率, 进一步提高了算法的多样性和优化精度.

此外, 由于动态评价方法对目标函数值和约束违反量分别进行了归一化处理, 并采用指数变化的权重取值平衡目标函数与可行性之间的关系, 因此不需要选取惩罚参数, 在很大程度上减少了优化工作的计算量. 而在静态评价方法的应用中, 目标函数值和约束违反量具有不同的量级, 最优惩罚因子的选取需要做大量的仿真试验, 对于复杂的优化问题, 将会大大增加试验时间, 增大优化工作的难度.

5 结论(Conclusions)

约束优化问题的求解中, 静态评价方法依赖于具体问题的复杂程度, 惩罚因子的选用困难. 本文提出了一种动态评价方法处理约束, 并将该方法引入粒子群优化算法, 应用于风电场微观选址优化问题的

求解。仿真结果表明,该方法可以获得比经验方法和静态评价方法更好的结果,不仅满足了风机之间最小允许距离的要求,而且使风电场的发电量和发电效率进一步提高,风能得到更加有效的利用。

动态评价方法解决了静态评价方法的应用中惩罚因子选用困难的问题,对于具体的优化问题不需要进行惩罚参数的选取,大大减少了优化工作的难度。此外,动态评价方法可以方便地应用于其他优化算法,具有较好的通用性。

参考文献(References):

- [1] COELLO COELLO C A. Theoretical and numerical constraint-handling techniques used with evolutionary algorithms: a survey of the state of the art[J]. *Computer Methods in Applied Mechanics and Engineering*, 2002, 191(11/12): 1245 – 1287.
- [2] 宫靖远, 贺德馨, 孙如林, 等. 风电场工程技术手册[M]. 北京: 机械工业出版社, 2004.
(GONG Jingyuan, HE Dexin, SUN Rulin, et al. *Wind Farm Engineering and Technical Manual*[M]. Beijing: Machinery Industry Press, 2004.)
- [3] MOSETTI G, POLONI C, DIVIACCO B. Optimization of wind turbine positioning in large wind farms by means of a genetic algorithm[J]. *Wind Engineering Industrial Aerodynamic*, 1994, 51(1): 105 – 116.
- [4] GRADY S A, HUSSAINI M Y, ABDULLAH M M. Placement of wind turbines using genetic algorithms[J]. *Renewable Energy*, 2005, 30(2): 259 – 270.
- [5] WAN C Q, WANG J, YANG G, et al. Optimal micro-siting of wind turbines by genetic algorithms based on improved wind and turbine models[C] // *The 48th IEEE Conference on Decision and Control Held Jointly with 2009 28th Chinese Control Conference*. Piscataway: Institute of Electrical and Electronics Engineers Inc, 2009: 5092 – 5096.
- [6] WAN C Q, WANG J, YANG G, et al. Optimal siting of wind turbines using real-coded genetic algorithms[C] // *Proceedings of European Wind Energy Association Conference and Exhibition*. Marseille, France, 2009. <http://www.ewec2009proceedings.info/proceedings/index.php>.
- [7] KENNEDY J, EBERHART R C. Particle swarm optimization[C] // *Proceedings of the 1995 IEEE International Conference on Neural Networks – Part 4(of 6)*. Piscataway: IEEE, 1995, 4: 1942 – 1948.
- [8] EBERHART R C, SHI Y. Particle swarm optimization: developments, applications and resources[C] // *Proceedings of the IEEE Conference on Evolutionary Computation*. Piscataway: IEEE, 2001, 1: 81 – 86.
- [9] SCHUTTE J F, GROENWOLD A A. A study of global optimization using particle swarms[J]. *Global Optimization*, 2005, 31(1): 93 – 108.
- [10] SHI Y, EBERHART R C. A modified particle swarm optimizer[C] // *Proceedings of the IEEE Conference on Evolutionary Computation*. Piscataway: IEEE, 1998: 69 – 73.
- [11] EBERHART R C, SHI Y. Comparing inertia weights and constriction factors in particle swarm optimization[C] // *Proceedings of the IEEE Conference on Evolutionary Computation*. Piscataway: IEEE, 2000, 1: 84 – 88.
- [12] BURTON T, SHARPE D, JENKINS N, et al. *Wind Energy Handbook*[M]. England: John Wiley & Sons Ltd, 2001: 14 – 19.
- [13] JENSEN N O. *A note on wind turbine interaction*[R]. Denmark: Riso National Laboratory, 1983.
- [14] KATIC I, HØJSTRUP J, JENSEN N. A simple model for cluster efficiency[C] // *Proceedings of European Wind Energy Association Conference and Exhibition*. Rome: Bookshop for Scientific Publications, 1986: 407 – 410.
- [15] LAURA C R, ROSS K M. A geographic analysis of wind turbine placement in northern California[J]. *Energy Policy*, 2006, 34(15): 2137 – 2149.

作者简介:

万春秋 (1979—), 女, 博士研究生, 主要研究方向为风力发电场的微观选址优化技术, E-mail: wancq07@mails.tsinghua.edu.cn;

王峻 (1974—), 男, 教授, 博士生导师, 主要研究方向为车辆动力学与控制、可再生能源的高效利用, E-mail: junwang@tongji.edu.cn;

杨耕 (1957—), 男, 教授, 博士生导师, 主要研究方向为运动控制系统、电力电子技术应用、嵌入式计算机控制技术、可再生能源系统的控制技术, E-mail: yanggeng@tsinghua.edu.cn;

张兴 (1961—), 男, 教授, 博士生导师, 主要研究方向为微/纳米尺度流动与传热学、纳米材料热物性、航空航天热功能材料、可再生能源的高效利用, E-mail: x-zhang@tsinghua.edu.cn.