

# 考虑需求响应的水火电优化调度改进型花朵授粉算法

沈艳军<sup>1†</sup>, 杨鑫<sup>1</sup>, 刘允刚<sup>2</sup>

(1. 三峡大学 电气与新能源学院, 湖北 宜昌 443002; 2. 山东大学 控制科学与工程学院, 济南 250061)

**摘要:** 针对花朵授粉算法(FPA)寻优能力的不足, 提出3种策略对其进行改进. 双向学习策略能够加强FPA的局部搜索能力; 仿嗅觉搜索策略不仅能增加种群的多样性, 还能提升算法的全局寻优能力; 动态转换概率策略能够有效地平衡全局搜索与局部搜索之间的切换. 基于上述策略, 提出一种具有更强搜索能力的改进型花朵授粉算法(IFPA), 并在此基础上提出一种新的水火电优化调度模型. 该模型在考虑火电站煤耗成本最小和供电公司利润最大的同时, 还考虑采用一定的补偿策略使得消费者降低电能的需求. 最后, 利用IFPA解决考虑需求响应的水火电优化调度. 仿真结果表明, 改进的算法具有收敛速度快、精度高等优点, 考虑了需求响应的水火电优化调度模型可降低消费者对电能的需求, 进而降低火电站的煤耗成本.

**关键词:** 改进型花朵授粉算法; 双向学习策略; 仿嗅觉搜索策略; 动态转换概率策略; 水火电优化调度; 需求响应

中图分类号: TP273

文献标志码: A

## An improved flower pollination algorithm for hydrothermal scheduling incorporating demand response

SHEN Yan-jun<sup>1†</sup>, YANG Xin<sup>1</sup>, LIU Yun-gang<sup>2</sup>

(1. College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China; 2. School of Control Science and Engineering, Shandong University, Ji'nan 250061, China)

**Abstract:** In order to enhance the searching ability of the flower pollination algorithm (FPA), this paper presents an improved flower pollination algorithm (IFPA) with three strategies, i.e., a double-direction learning strategy to advance the local searching ability, an imitative osphresis search strategy to strengthen the diversity of population and global searching ability, and a dynamic switching probability strategy to balance the switch between global and local searching. On this basis, a hydrothermal scheduling model with demand respond is proposed, which minimizes the fuel cost, maximizes the benefit of power supply company and reduces the electricity demand by providing an appropriate compensation to customers. Finally, the presented model is solved by using the IFPA. The simulation results show that the IFPA has outstanding performance, such as fast convergence speed and high accuracy, and the proposed model incorporating demand response can reduce the demand for electrical supply of customers and fuel cost of thermal power plants.

**Keywords:** IFPA; double-direction learning strategy; imitative osphresis search strategy; dynamic switching probability strategy; hydrothermal scheduling; demand respond

## 0 引言

受自然现象或生物群体行为的启发, 众多学者陆续提出了多种智能算法, 如粒子群算法(PSO)<sup>[1]</sup>、遗传算法(GA)<sup>[2]</sup>、蚁群算法(ACO)<sup>[3]</sup>、人工蜂群算法(ABC)<sup>[4]</sup>、果蝇优化算法(FOA)<sup>[5]</sup>等. 随着智能算法在信号处理、图像处理、生产调度、模式识别等领域的应用日趋广泛, 众多学者对智能算法的关注度也越来越高, 对其研究也更加深入.

花朵授粉算法(Flower pollination algorithm, FPA)是由Yang<sup>[6]</sup>通过对植物花粉的传播进行研究而提出的一种新型智能算法. 由于该算法具有结构新颖、实现简单、参数少等特点, 近年来受到了广泛的关注, 不少学者对算法进行了改进研究. 文献[7-8]利用FPA结合蝙蝠算法(BA)和克隆选择操作来得到更好的解. Zhou等<sup>[9]</sup>将精英反向学习策略与FPA的全局寻优相结合, 自适应贪婪策略与FPA的局部寻优相结合

收稿日期: 2018-03-26; 修回日期: 2018-07-02.

基金项目: 国家自然科学基金项目(61374028).

责任编辑: 侯忠生.

<sup>†</sup>通讯作者. E-mail: shenyj@ctgu.edu.cn.

以提高FPA的搜索能力. Draa<sup>[10]</sup>将反向学习策略与FPA相结合来提高FPA的寻优能力. 此外,还有许多学者研究了FPA的应用,如太阳能光伏参数设计<sup>[11]</sup>、经济负荷调度和经济排放调度<sup>[12]</sup>、特征选择<sup>[13]</sup>等.

水火电调度作为电力系统优化调度中的一个重要问题,一直受到人们的关注,而且越来越多的学者用智能算法对该模型进行求解. 混沌差分进化算法<sup>[14]</sup>、基于小群体的粒子群算法<sup>[15]</sup>和引入变异和迁徙操作的粒子群算法<sup>[16]</sup>处理以火电站煤耗最小为目标的水火电调度问题;侯贸军等<sup>[17]</sup>用微分进化算法求解以发电侧短期购电费用最低为目标的水火电优化调度问题;郭壮志等<sup>[18]</sup>用改进电磁学算法计算以火电站煤耗最小、网损最小和水电站在调度周期末蓄水量最大为目标的水火电优化调度问题;Feng等<sup>[19]</sup>和覃晖等<sup>[20]</sup>以火电厂的煤耗成本和环境排放成本最小化为目标,分别用多目标并行差分进化算法和文化差分进化算法对短期水火电调度问题进行了研究.

现阶段,大多数水火电调度模型只考虑供给侧,很少考虑需求侧. 鉴于此,本文建立一个基于需求响应的水火电调度模型,以火电厂煤耗最小化和供电公司的利益最大化为目标,同时又让消费者参与到电能调配的过程,即通过一定的补偿策略在合理的范围内使得消费者降低对电能的需求. 在此基础上,利用改进后的花粉算法(IFPA)对模型进行求解,并通过算例验证算法和模型的可行性和有效性.

## 1 改进花朵授粉算法(IFPA)

### 1.1 花朵授粉算法(FPA)

Yang等<sup>[21]</sup>受到自然界植物授粉方式的启发提出了花朵授粉算法,并对花粉粒子的行为制定如下规则.

**规则1** 异花传粉过程看作是全局传粉过程,传粉者的运动轨迹遵循Levy分布.

**规则2** 自花传粉的过程认为是局部传粉过程.

**规则3** 花的繁衍率与两朵关联花的相似度成比例.

**规则4** 全局授粉与局部授粉之间的切换受转换概率 $p \in (0, 1)$ 控制.

根据上述4条准则,用相应的数学公式对其进行描述. 首先,在全局传粉过程中花粉粒子被传粉者(蜜蜂、昆虫等)携带进行长距离的运动,通过下式对全局传粉进行描述:

$$x_i^{t+1} = x_i^t + \gamma L(\lambda)(g_* - x_i^t). \quad (1)$$

其中: $x_i^t, x_i^{t+1}$ 为花粉粒子 $i$ 第 $t$ 代和 $t+1$ 代的状态; $g_*$

是全局最优解; $\gamma$ 为步长缩放因子,用来控制步长的大小; $L(\lambda)$ 为遵循Levy分布的步长函数,有

$$L(\lambda) \sim \frac{\lambda \Gamma(\lambda) \sin(\pi\lambda/2)}{\pi} \frac{1}{s^{1+\lambda}}, \quad s \gg s_0 > 0, \quad (2)$$

$\lambda = 3/2, \Gamma(\lambda)$ 为标准伽马函数, $s$ 满足

$$s = \frac{U}{|V|^{1/\lambda}}, \quad U \sim N(0, \delta^2), \quad V \sim N(0, 1), \quad (3)$$

$\delta^2$ 满足

$$\delta^2 = \left\{ \frac{\Gamma(1+\lambda)}{\lambda \Gamma[(1+\lambda)/2]} \cdot \frac{\sin(\pi\lambda/2)}{2^{(\lambda-1)/2}} \right\}^{1/\lambda}. \quad (4)$$

通过准则2和准则3可以得到FPA局部搜索的公式为

$$x_i^{t+1} = x_i^t + \epsilon(x_j^t - x_k^t). \quad (5)$$

其中: $x_j^t$ 和 $x_k^t$ 代表同株植物不同花朵产生的花粉,这里相当于第 $t$ 代个体中随机选取的两个不同的个体; $\epsilon$ 为属于 $(0, 1)$ 的随机数. 算法流程的伪代码可参阅文献[21].

标准FPA在处理低维问题时能取得较好的效果,但对于维度高、较为复杂的问题,FPA就很难取得令人满意的结果. 所以,本文提出双向学习策略、仿嗅觉搜索策略和动态转换概率策略对FPA进行改进.

### 1.2 双向学习策略

标准FPA通过式(5)进行局部搜索时,具有很大的随机性,在处理复杂问题时,往往达不到令人满意的准度和精度,故本文提出双向学习策略,针对标准FPA局部搜索能力弱的缺点对FPA进行改进,引入了双向学习因子 $S$ ,有

$$x_i^{t+1} = x_i^t + \epsilon(x_j^t - x_k^t) + S, \quad (6)$$

$$S = \omega\alpha(x_{\text{best}}^t - x_i^t) + (1-\omega)\beta(x_{\text{best}}^m - x_i^t). \quad (7)$$

其中: $x_{\text{best}}^t$ 为第 $t$ 代的最优个体, $x_{\text{best}}^m$ 为第 $m$ 代的最优个体,且 $t \neq m$ ; $\omega$ 为决定 $x_{\text{best}}^t$ 和 $x_{\text{best}}^m$ 所占比重的权重因子; $\alpha, \beta$ 为两个属于 $(0, 1)$ 的随机数.

**注1** 学习因子 $S$ 的引进可以使粒子向第 $t$ 代和第 $m$ 代的最优个体同时靠近,这样不仅能为粒子的搜索提供一个方向,还能在一定程度上避免种群的过度集中,提高了整个群体的寻优效率. 另外,相比式(5),有 $S$ 加入的式(6)使种群多样性也得到提升,更有利于群体准确地找到最优解.

### 1.3 仿嗅觉搜索策略

随着局部搜索能力的加强,为避免种群陷入局部最优,全局搜索能力也应该得到相应的提升. 首先,将全局搜索的迭代公式(1)改进为下式,以进一步提升种群的多样性:

$$x_i^{t+1} = x_i^t + \gamma L(\lambda)(x_r^t - x_i^t). \quad (8)$$

其中  $x_r$  为种群中随机选出的个体,且  $r \neq i$ . 与式(1)相比,式(8)使得个体在进行全局寻优时能向着不同的方向随机搜索,并不仅仅是向  $x_{\text{best}}^t$  靠近,这样即可增加种群的多样性,更有效地进行全局搜索.

然后,受果蝇优化算法<sup>[5]</sup>的启发,将果蝇算法中嗅觉搜索机制改进后融入到FPA中,进行更进一步的全局搜索.在式(8)得到  $x_i^{t+1}$  后,以  $s$ (由下式得到)为步长,在  $x_i^{t+1}$  的邻域内随机产生  $n$  个个体,保留这些个体和  $x_i^{t+1}$  之中的最优个体,作为新的  $x_i^{t+1}$ :

$$s = \delta \left[ \left( 1 - \frac{t}{G_{\max}} \right) \frac{\text{Ub} - \text{Lb}}{4} + \frac{\text{Ub} - \text{Lb}}{4} \right]. \quad (9)$$

其中:  $\delta$  为属于  $(-1,1)$  的随机数,  $t$  为当前迭代次数,  $G_{\max}$  为最大迭代次数,  $\text{Ub}$  为解的取值上限,  $\text{Lb}$  为解的取值下限.

**注2** 仿嗅觉搜索中的策略(8)与(1)相比,用  $x_r^t$  代替  $g_*$ ,这样产生的  $n$  个个体总是分散在较大的搜索空间中,从而增大了全局搜索过程的随机性和多样性.

#### 1.4 动态转换概率策略

FPA中,转换概率  $p \in (0,1)$  控制着全局搜索与局部搜索之间的切换, Yang<sup>[6]</sup>指出当  $p = 0.8$  时算法的寻优效果最佳, Draa<sup>[10]</sup>通过实验提出  $p = 0.2$  时得到的解最优.但随着研究的不断深入,人们发现相比固定的  $p$  值,动态  $p$  值能使得FPA更好地寻找到最优解. Zhou等<sup>[9]</sup>提出了一种动态的转换概率

$$p = 0.6 - 0.1(\text{Max\_iter} - t) / \text{Max\_iter}, \quad p \in (0.6, 0.5).$$

Salgotra等<sup>[22]</sup>同样提出了一种相似的动态转换概率  $p = p - \frac{\text{maxiter} - t}{\text{maxiter}} \times 0.1$ ,且  $p$  的初值为0.8. 本文提出一种新的动态转换概率

$$p = p_{\max} - \exp \left( -10 \times \frac{G_{\max} - t}{G_{\max}} \right) (p_{\max} - p_{\min}). \quad (10)$$

其中:  $p_{\max}$  为转换概率的最大值,取0.8;  $p_{\min}$  为转换概率的最小值,取0.2;  $G_{\max}$  为迭代的最大次数;  $t$  为当前迭代次数.

**注3** 与文献[9, 22]相比,本文提出的动态转换概率有宽广的取值范围( $p \in (0.6, 0.5)$ <sup>[9]</sup>,  $p \in (0.8, 0.7)$ <sup>[22]</sup>, 本文  $p \in (0.8, 0.2)$ ). 由于  $p$  值随着迭代次数的增加而减小,在寻优搜索前期,大多数粒子进行的是全局搜索过程,以期接近最优解,在寻优后期大多粒子进行的是局部搜索,在小范围进行精密的搜索,力争能寻到精确的最优解.

基于3个策略:双向学习策略、仿嗅觉搜索策略和动态概率转换策略,改进的花粉算法(IFPA)流程如下所示:

目标函数  $f(x), x = (x_1, x_2, \dots, x_d)$

初始化种群数量  $N$  和最大迭代次数  $G_{\max}$

初始化转换概率的最大最小值  $p_{\max}$  和  $p_{\min}$

找到当前最优解  $g_*$

while  $t < G_{\max}$

通过式(10)更新转换概率

保存当前的最优解

for  $i = 1 : N$

if  $\text{rand} < p$

通过式(8)和仿嗅觉搜索策略进行全局搜索  
else

通过式(6)进行局部搜索

end if

更新新一代的解  $x_i^{t+1}$

如果  $x_i^{t+1}$  优于  $x_i^t$ ,则保留  $x_i^{t+1}$

end for

更新当前最优解  $g_*$

end while

输出最优解

#### 1.5 IFPA的性能分析

为了验证本文提出的3种策略改进算法的有效性和可行性,以一个测试函数为例具体分析,有

$$f_{\text{test}} = -20 \exp \left( -0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2} \right) - \exp \left( \frac{1}{D} \sum_{i=1}^D \cos(2\pi x_i) \right) + 20 + e.$$

维度设为2,定义域为  $(-32, 32)$ . 设定FPA和IFPA种群大小均为20,IFPA嗅觉搜索策略中  $n$  设置为10,终止条件为与理论最优值误差小于  $10^{-3}$  或迭代次数达到100次.

仿真结果显示,FPA在迭代84次后得到了满足精度要求的最优解而终止,但是在寻优的过程中多次陷入局部最优,且经过多次迭代才能跳出.而IFPA在运行15次后就满足要求终止,并且在陷入局部最优后能在几次迭代之内便跳出.本文改进的IFPA不仅在收敛速度上有了很大程度的提高,在跳出局部最优的能力上也有所提升.

为了进一步观察3种策略对算法的影响,将两种算法的初始种群分布和迭代次数  $t = 15$  的种群分布情况展示在图1和图2中.图1是FPA和IFPA随机产生的初始群体的分布情况,图2是经过15次迭代后两种算法的种群分布.图2中,菱形点的分布是分散的,覆盖范围大,这正是仿嗅觉搜索策略所要达到的目的.由图1和图2可见,IFPA的种群个体能很快地

向搜寻到的最优解集中,与此同时,为防止该点为局部最优从而导导致群体陷入局部最优之中,仿嗅觉搜索策略产生的个体(菱形点)在搜索空间不断进行全局搜索,一旦找到最优解就将其保存并替换种群中的个体.在迭代后期,IFPA种群在较小的范围内进行精确寻找,双向学习策略的局部搜索能力即可体现出来.图2中,IFPA的种群个体明显更加集中更加精确地搜索,同时全局搜索的菱形点仍是分散在较大的范围来确保种群陷入局部最优能及时跳出.

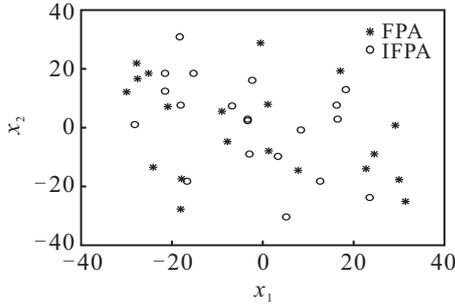


图1 初始群体分布

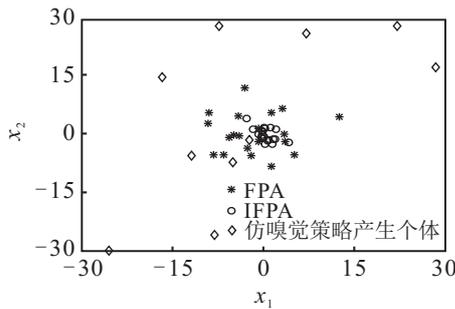


图2 15次迭代后群体分布

综上所述,本文改进的算法IFPA无论是全局搜索还是局部搜索能力相比于FPA都有很大的提升,仿嗅觉搜索策略提升全局搜索能力,以确保种群能及时跳出局部最优,双向学习策略增强算法的局部搜索能力,使得找到更精确的解,动态转换概率策略平衡全局和局部搜索,三者相辅相成,有效地提升了算法的寻优能力.

## 2 模型分析

### 2.1 水火电调度的目标函数

水火电优化调度的主要目的是在满足电力需求的前提下火电站的煤耗成本最小,以此为目标函数的数学模型<sup>[14]</sup>表示为

$$\min f_1 = \sum_{i=1}^{N_s} \sum_{t=1}^T G_i(\text{Ps}_{i,t}) = \sum_{i=1}^{N_s} \sum_{t=1}^T \{\alpha_i + \beta_i \text{Ps}_{i,t} + \gamma_i \text{Ps}_{i,t}^2\}. \quad (11)$$

其中: $f_1$ 为火电厂煤耗成本总和, $N_s$ 为火电站的个数, $T$ 为调度时段, $\text{Ps}_{i,t}$ 为第*i*个火电厂在第*t*时段的

发电量, $G_i(\text{Ps}_{i,t})$ 为火电站*i*在*t*时段发电的煤耗成本, $\alpha_i$ 、 $\beta_i$ 、 $\gamma_i$ 为第*i*个火电站的煤耗系数.

### 2.2 约束条件

#### 1) 系统负载平衡约束

$$\sum_{i=1}^{N_s} \text{Ps}_{i,t} + \sum_{j=1}^{N_h} \text{Ph}_{j,t} = P_D^t, \quad t = 1, 2, \dots, T. \quad (12)$$

其中

$$\begin{aligned} \text{Ph}_{i,t} = & C_{1i}(V_i^t)^2 + C_{2i}(Q_i^t)^2 + C_{3i}V_i^t Q_i^t + \\ & C_{4i}V_i^t + C_{5i}Q_i^t + C_{6i}, \\ & i = 1, 2, \dots, N_h, \quad t = 1, 2, \dots, T. \end{aligned} \quad (13)$$

#### 2) 火电站功率约束

$$\begin{aligned} \text{Ps}_i^{\min} \leq \text{Ps}_i^t \leq \text{Ps}_i^{\max}, \\ i = 1, 2, \dots, N_s, \quad t = 1, 2, \dots, T. \end{aligned} \quad (14)$$

#### 3) 水电站功率约束

$$\begin{aligned} \text{Ph}_i^{\min} \leq \text{Ph}_i^t \leq \text{Ph}_i^{\max}, \\ i = 1, 2, \dots, N_h, \quad t = 1, 2, \dots, T. \end{aligned} \quad (15)$$

#### 4) 水电站排量约束

$$\begin{aligned} Q_i^{\min} \leq Q_i^t \leq Q_i^{\max}, \\ i = 1, 2, \dots, N_h, \quad t = 1, 2, \dots, T. \end{aligned} \quad (16)$$

#### 5) 水库储水约束

$$\begin{aligned} V_i^{\min} \leq V_i^t \leq V_i^{\max}, \\ i = 1, 2, \dots, N_h, \quad t = 1, 2, \dots, T. \end{aligned} \quad (17)$$

#### 6) 水库始末水量约束

$$V_i^0 = V_i^B, \quad V_i^T = V_i^E, \quad i = 1, 2, \dots, N_h. \quad (18)$$

#### 7) 动态水量平衡约束

$$\begin{aligned} V_i^t = \\ V_i^{t-1} + I_i^t - Q_i^t - S_i^t + \sum_{j=1}^{N_u} [Q_j^{t-\tau_{j,i}} + S_j^{t-\tau_{j,i}}], \\ i = 1, 2, \dots, N_h, \quad t = 1, 2, \dots, T. \end{aligned} \quad (19)$$

其中: $N_h$ 为水电站的个数, $\text{Ph}_{i,t}$ 为水电站*i*在*t*时段的发电量, $P_D^t$ 为*t*时段的负荷需求量, $C_{1i}$ 、 $C_{2i}$ 、 $C_{3i}$ 、 $C_{4i}$ 、 $C_{5i}$ 、 $C_{6i}$ 为水电站*i*的发电系数, $Q_i^t$ 为水电站*i*在*t*时段的排水量, $V_i^t$ 为水电站*i*在*t*时段的水库容量, $\text{Ps}_i^{\max}$ 和 $\text{Ps}_i^{\min}$ 分别为火电站*i*在*t*时段发电量的上下限, $\text{Ph}_i^{\max}$ 和 $\text{Ph}_i^{\min}$ 分别为水电站*i*在*t*时段的发电量的上下限, $Q_i^{\max}$ 和 $Q_i^{\min}$ 分别为水电站*i*在*t*时段的排水量上下限, $V_i^{\max}$ 和 $V_i^{\min}$ 分别为水电站*i*在*t*时段的库容上下限, $V_i^B$ 、 $V_i^E$ 分别为水电站*i*在调度时

段  $T$  始末的库容量,  $I_i^t$  为水电站  $i$  在  $t$  时段的水来水,  $S_i^t$  为水电站  $i$  在  $t$  时段的弃水量,  $N_u$  为水电站  $i$  的上游水电站数量,  $\tau_{j,i}$  为水电站  $i$  与上游电站  $j$  之间的水流时滞.

### 2.3 需求响应模型

需求响应是消费者参与到电能调配过程中的一种措施, 目的在于采用一定的补偿策略使得消费者在合理范围内减少对电能的需要. 受文献[23]的启发, 本文提出一种需求响应模型, 定义  $H_{j,t}(q, \theta)$  为消费者  $j$  在  $t$  时段减少使用  $q$  MW 电量所承担的损失,  $y_{j,t}$  为供电公司对消费者减少使用  $q$  MW 电量的行为作出的补偿, 则该消费者所获得的利润为

$$B_{1,j,t}(\theta, q, y) = y_{j,t} - H_{j,t}(q, \theta), \quad (20)$$

其中  $\theta \in [0, 1]$  为消费因子,  $\theta$  越大表示消费者参与该激励政策的积极性越高.  $H_{j,t}(q, \theta)$  定义如下:

$$H_{j,t}(q, \theta) = K_1 q_{j,t}^2 + K_2 q_{j,t} - K_2 q_{j,t} \theta_j, \quad (21)$$

其中  $K_1$ 、 $K_2$  为消费者的损失系数. 同样地, 供电公司所获得的利润可以表示为

$$B_{2,j,t} = \lambda_t q_{j,t} - y_{j,t}. \quad (22)$$

其中:  $\lambda_t$  为供电公司在  $t$  时段每减少 1 MW 供电量而减少的成本,  $q_{j,t}$  为用户  $j$  在  $t$  时段减少使用的电量.

将供电公司利益最大作为目标函数, 有

$$\max f_2 = \sum_{t=1}^T \sum_{j=1}^J [\lambda_t q_{j,t} - y_{j,t}]. \quad (23)$$

$$\text{s.t. } y_{j,t} - H_{j,t}(q, \theta) > 0,$$

$$j = 1, 2, \dots, J, t = 1, 2, \dots, T; \quad (24)$$

$$\sum_{t=1}^T \sum_{j=1}^J y_{j,t} \leq \text{UB}; \quad (25)$$

$$\sum_{t=1}^T q_{j,t} \leq \text{CM}_j. \quad (26)$$

其中: UB 为供电公司的预算补偿上限,  $\text{CM}_j$  为用户  $j$  在调度时间段  $T$  内减少用电量的上限,  $q$  和  $y$  为两个变量. 约束条件(24) 表明每个时间段用户所得的利益都要大于零, 这样才具有合理性.

### 2.4 考虑需求响应的水火电优化调度

需求响应的应用不仅能够一定程度上达到削峰填谷的效果, 还能减少消费者对负荷的需求. 因此, 本文将提出的需求响应模型与水火电调度模型相结合, 调度的总目标函数可以表示为

$$\min F = \omega' \sum_{i=1}^{N_s} \sum_{t=1}^T G_i(\text{Ps}_{i,t}) +$$

$$(1 - \omega') \sum_{t=1}^T \sum_{j=1}^J [y_{j,t} - \lambda_t q_{j,t}], \quad (27)$$

其中  $\omega'$  为权重系数. 约束条件(12) 改写为

$$\sum_{i=1}^{N_s} \text{Ps}_{i,t} + \sum_{j=1}^{N_h} \text{Ph}_{i,t} = P_D^t - P_{DR}^t. \quad (28)$$

$P_{DR}^t$  是  $t$  时段由用户通过参与需求响应减少的用电量, 计算式为

$$P_{DR}^t = \sum_{j=1}^J q_j^t, t = 1, 2, \dots, T. \quad (29)$$

其余约束条件不变, 这样目标函数  $F$  和一系列约束条件(12)~(19)、(24)~(26) 便构成了考虑需求响应的水火电调度模型, 有

$$\min F = \omega' f_1 + (1 - \omega')(-f_2); \quad (30)$$

$$\text{s.t. } \sum_{i=1}^{N_s} \text{Ps}_{i,t} + \sum_{j=1}^{N_h} \text{Ph}_{i,t} = P_D^t - P_{DR}^t, \quad (31)$$

$$\text{Ps}_i^{\min} \leq \text{Ps}_i^t \leq \text{Ps}_i^{\max}, \quad (32)$$

$$\text{Ph}_i^{\min} \leq \text{Ph}_i^t \leq \text{Ph}_i^{\max}, \quad (33)$$

$$Q_i^{\min} \leq Q_i^t \leq Q_i^{\max}, \quad (34)$$

$$V_i^{\min} \leq V_i^t \leq V_i^{\max}, \quad (35)$$

$$V_i^0 = V_i^B, V_i^T = V_i^E, \quad (36)$$

$$V_i^t = V_i^{t-1} + I_i^t - Q_i^t - S_i^t + \sum_{j=1}^{N_u} [Q_j^{t-\tau_{j,i}} + S_j^{t-\tau_{j,i}}], \quad (37)$$

$$y_{j,t} - H_{j,t}(q, \theta) > 0, \quad (38)$$

$$\sum_{t=1}^T \sum_{j=1}^J y_{j,t} \leq \text{UB}, \quad (39)$$

$$\sum_{t=1}^T q_{j,t} \leq \text{CM}_j. \quad (40)$$

其中: 式(30) 是以火电站煤耗成本  $f_1$  最小和供电公司利润  $f_2$  最大为两个子目标的目标函数, 式(31) 为系统负载平衡约束, 式(32) 为火电站功率约束, 式(33) 为水电站功率约束, 式(34) 为水电站排量约束, 式(35) 为水库储水约束, 式(36) 为水库始末位置约束, 式(37) 为动态水量平衡约束, 式(38) 为用户所得利益约束, 式(39) 为补偿金额约束, 式(40) 为用户减少用电量约束.

**注4** 需要特别指出的是, 由于两个目标函数分别为火电站煤耗成本最小和供电公司利润最大, 两者不能直接取和, 故本文中式(30) 是将  $f_2$  取负值后与  $f_1$  加权取和.

**注5** 现有的水火电调度模型仅考虑发电侧, 如文献[24] 考虑了水电站的随机自然来水量, 文献[25]

考虑了负荷的不确定性,文献[26]考虑了水电系统的波动量.与这些模型相比,本文提出的模型首次将需求响应引入水火电优化调度模型中,使消费者也能参与到电能调配的过程中,且在一定的激励措施下,降低消费者对电能的需求,从而降低发电侧的负担.

### 3 算例分析

为了验证模型和算法的可行性,本文选取同一流域内的4个水电站、1个火电站以及3个消费者的算例进行检验,调度的时间为一天(24h).图3展示了4个水电站水资源的流动网络.由图3可见,水电站1和水电站2为一级水电站,水流经两者处理后汇入水电站3,水电站4接受来自水电站3的排水. $I_1, I_2, I_3, I_4$ 分别为各水电站的自然来水, $Q_1, Q_2, Q_3, Q_4$ 分别为各水电站的排水量.

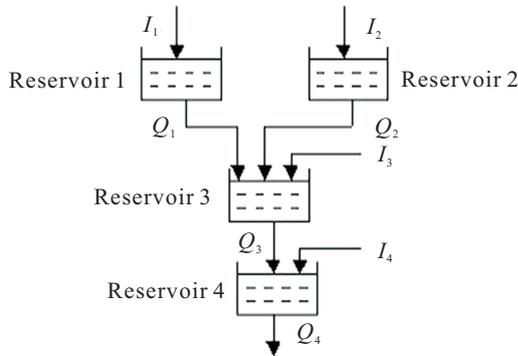


图3 水资源流动网络

算例具体数据由表1~表4给出.表1是4个水电站的发电系数;表2是4个水电站的库容上下限和单位时间排水量上下限;表3是3个消费者的成本系数、消费因子以及每个消费者每天最多减少的用电量;表4是每个调度时段的负荷需求值和供电公司每减少1MW供电节约的成本值 $\lambda_t$ .此外,火电站发电系数 $\alpha, \beta, \gamma$ 分别取值为1000.0、10.0和0.5.4个水电站的自然来水分别为 $[10, 8, 1, 0] \cdot 10^3 \text{m}^3/\text{h}$ .水流时滞 $\tau_{1,3} = 1 \text{h}, \tau_{2,3} = 2 \text{h}, \tau_{3,4} = 2 \text{h}$ .供电公司补偿预算的上限 $UB = 50\,000 \$$ .

表1 水电站发电系数

水电站 $i$	$C_{1i}$	$C_{2i}$	$C_{3i}$	$C_{4i}$	$C_{5i}$	$C_{6i}$
1	-0.001	-0.1	0.01	0.40	4.0	-30
2	-0.001	-0.1	0.01	0.38	3.5	-30
3	-0.001	-0.1	0.01	0.30	3.0	-30
4	-0.001	-0.1	0.01	0.38	3.8	-30

基于以上数据,利用本文提出的改进花粉算法(IFPA)对算例进行计算,采用Matlab R2012a进行编程,初始种群数量为80,迭代次数为2000.目标函数中权重 $\omega'$ 分别取0.25、0.50、0.75、1.0,独立运行20次得到运行结果的均值如表5所示.

表2 水电站库容和排水量

水电站 $i$	$V_i^{\min}/10^3 \text{m}^3$	$V_i^{\max}/10^3 \text{m}^3$	$V_i^B/10^3 \text{m}^3$	$V_i^E/10^3 \text{m}^3$	$Q_i^{\min}/(10^3 \text{m}^3/\text{h})$	$Q_i^{\max}/(10^3 \text{m}^3/\text{h})$
1	80	150	100	120	5	15
2	60	120	80	70	6	15
3	100	240	170	170	10	30
4	70	160	120	120	13	25

表3 消费者成本系数、消费因子和减少用电上限

消费者 $j$	$K_{1j}$	$K_{2j}$	$\theta_j$	$CM_j / \text{MWh}$
1	107.9	132.0	0.00	30
2	137.8	163.0	0.45	35
3	184.7	164.0	0.90	40

表4 各时段的负荷需求和 $\lambda$ 的值

$t$	1	2	3	4	5	6	7	8
负荷/MWh	190	170	170	190	190	210	230	250
$\lambda_t / (\$/\text{MWh})$	157	140	220	376	450	470	504	535
$t$	9	10	11	12	13	14	15	16
负荷/MWh	270	310	350	310	350	350	310	290
$\lambda_t / (\$/\text{MWh})$	670	616	638	682	730	780	850	710
$t$	17	18	19	20	21	22	23	24
负荷/MWh	270	250	230	210	210	210	190	190
$\lambda_t / (\$/\text{MWh})$	680	630	580	420	380	301	253	142

表5 不同 $\omega'$ 下的运行结果

$\omega'$	$F$	$f_1$	$f_2$
0.25	19752.685 1	145388.335 1	22125.904 8
0.50	61073.910 1	144210.757 3	22054.015 4
0.75	103428.705 1	144674.548 5	20308.825 3
1.0	154704.550 8	154704.550 8	0

由表5可见,随着 $\omega'$ 的增加,目标函数值在不断地增加,供电公司利润 $f_2$ 在不断地减小,这是由于 $\omega'$ 变大,子目标 $f_1$ 逐渐占据主导, $f_2$ 的比重减少,对目标函数的影响也变小.当 $\omega' = 0.50$ 时,火电站煤耗成本 $f_1$ 的平均值取得了最小值144210.7573\$.当 $\omega' = 1.0$ 时,不考虑需求侧,目标函数即是火电站的煤耗成本.由表5中数据可知,此时的煤耗成本最大,且比起考虑需求侧时的煤耗有明显的增加,这也验证了本文提出的需求响应模型与水火电模型相结合能有效地减少火电站煤耗的结论.

为进一步说明,将 $\omega' = 0.50$ 的结果进行具体分析.在20次运行结果中,目标函数 $F$ 、火电站的煤耗成本 $f_1$ 、供电公司利润 $f_2$ 的均值分别为

$$61\,073.910\,1 \$, 144\,210.757\,3 \$, 22\,054.015\,4 \$.$$

选取第11次运行结果进行具体说明,目标函数值 $F = 60\,968.926\,8 \$$ ,火电站的煤耗成本

$f_1 = 144\,282.906\,9\ \$$ , 供电公司所得的利润  $f_2 = 22\,345.053\,3\ \$$ . 各电站各时段的发电量如表6所示(单位MWh). 消费者在各时段减少的用电量以及得到的相应的补偿如表7所示. 各个水电站各时段的排水量和库存量分别如图4和图5所示. 考虑需求响应

与不考虑需求响应水电站的煤耗成本与迭代次数的关系如图6所示. 为了验证算法改进的有效性, 利用FPA、EOFPA<sup>[9]</sup>和MGOFPA<sup>[10]</sup>与本文提出的IFPA进行对比, 每种算法种群数量都取80, 独立运行20次, 结果如表8所示.

表6 各电站各时段的发电量

$t$	1	2	3	4	5	6	7	8	9	10	11	12
Ph1	23.966	24.914	26.030	27.127	28.140	34.826	40.960	47.859	51.722	57.301	59.376	54.966
Ph2	16.763	17.318	17.867	18.394	18.991	19.578	20.801	22.447	25.302	30.867	33.783	29.105
Ph3	42.918	39.322	37.463	35.905	33.966	32.288	31.262	30.456	30.633	31.145	32.347	34.154
Ph4	45.632	41.621	44.231	46.189	47.805	49.441	50.798	51.925	53.006	54.165	60.120	58.792
Ps	57.061	43.876	39.624	59.282	56.418	69.536	81.856	92.793	103.900	131.701	159.534	127.238
$t$	13	14	15	16	17	18	19	20	21	22	23	24
Ph1	56.403	54.423	49.902	47.673	44.969	40.103	35.426	30.672	32.149	34.367	30.277	27.814
Ph2	32.440	31.621	28.641	26.187	25.761	23.147	19.856	17.165	19.267	21.353	13.151	13.691
Ph3	36.366	37.978	39.758	41.187	42.085	42.997	42.192	42.235	40.619	38.416	37.665	39.719
Ph4	64.812	66.935	67.308	67.800	68.019	68.738	68.829	69.299	68.759	68.604	66.316	63.617
Ps	155.022	154.342	118.777	102.908	84.6187	69.349	58.975	46.804	45.689	43.982	39.488	41.594

表7 各时段消费者的减少电量及相应补偿

$t$	$q_{1,t}/\text{MWh}$	$y_{1,t}/\ \$$	$q_{2,t}/\text{MWh}$	$y_{2,t}/\ \$$	$q_{3,t}/\text{MWh}$	$y_{3,t}/\ \$$
1	1.292	330.663	1.066	252.141	1.299	333.148
2	0.438	78.576	1.366	379.635	1.142	259.591
3	1.710	541.695	1.702	551.964	1.369	368.971
4	0.633	126.887	0.814	164.588	1.652	531.391
5	1.500	440.791	1.229	318.566	1.947	732.704
6	1.112	280.424	1.318	357.907	1.896	695.091
7	1.390	392.148	1.826	623.139	1.103	243.195
8	1.982	685.784	0.734	140.312	1.798	627.093
9	1.296	352.362	1.749	578.570	2.388	1092.456
10	1.117	282.225	1.915	677.473	1.785	617.816
11	1.306	356.508	2.061	770.252	1.470	423.223
12	1.594	484.789	2.108	801.832	2.039	801.339
13	1.953	669.491	1.510	449.626	1.490	434.789
14	1.325	364.359	1.306	352.435	2.066	822.776
15	1.637	505.329	1.538	464.306	2.436	1136.128
16	1.042	254.955	1.629	512.080	1.570	481.512
17	1.218	320.981	1.365	379.123	1.962	743.441
18	1.344	372.479	2.148	828.691	2.171	906.139
19	0.908	208.881	2.204	867.552	1.606	502.728
20	0.517	97.1430	1.411	401.297	1.894	694.257
21	1.059	260.853	0.933	203.600	1.522	453.227
22	0.779	168.386	0.984	221.923	1.512	447.405
23	1.454	420.244	0.684	125.821	0.962	186.968
24	1.386	390.384	1.388	390.223	0.787	127.428

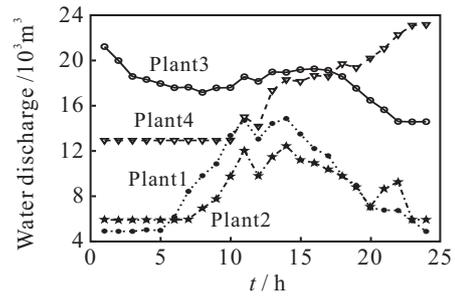


图4 水电站各时段的排水量

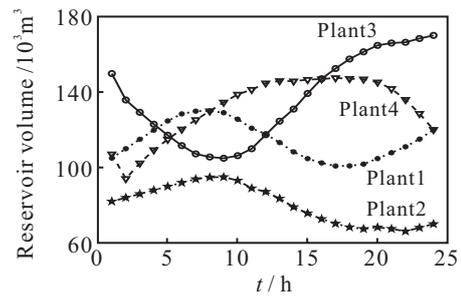


图5 水电站各时段的库存量

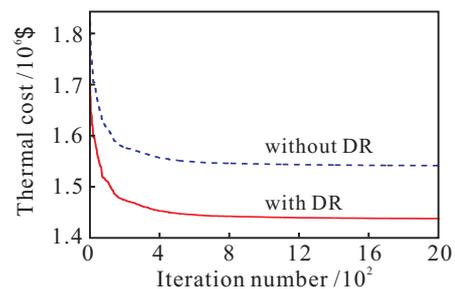


图6 水电站煤耗成本

表8 4种算法对比结果

算法	最优值/\$	最差值/\$	平均值/\$	标准差
FPA	70 684.015 8	75 682.853 2	72 498.167 4	3 116.07
EOFPA	62 715.985 2	63 898.154 3	63 095.768 1	1 049.29
MGOFPA	63 945.154 7	65 415.714 8	64 575.671 9	742.05
IFPA	60 460.595 6	61 686.279 8	61 073.910 1	129.07

由表6、图4和图5可知,4个水电站中,水电站3和4是主要出力水电站,在调度的前10h中,水电站4基本上保持平稳的排水量,其储水量在第1h短暂地下降后,第2h开始逐渐上涨,这是由于来自水电站3的排水和弃水到达水电站有一个水流时滞,而其排水量大于来水量所以储水会出现下降.水电站3的排水量在前10h有缓慢下降的趋势,储水量也逐渐下降,在9h到达最小储水值.水电站1和2先保持一段稳定的排水量,在即将到达用电高峰时开始增大排水量.在10h~16h的用电高峰期间,水电站4作为主要出力排水量快速上升.由表6可知,在用电高峰过去后,水电站4仍然保持较大的产电量,更是在19h开始产电量多于火电站直至24h调度结束.

表7详细地列举了3个消费者在各时段减少的用电量及得到的相应补偿金额,可以发现,各消费者减少的用电量越多,相应得到的补偿金额也越多,且减少的用电量越多,得到的单位补偿金额(补偿金额/减少电量)就越多.例如,消费者1在第2h减少用电0.438 MWh得到补偿金额78.576\$,单位补偿金额为179.397 3\$;在第6h减少用电1.112 MWh得到补偿金额280.424\$,单位补偿金额为252.179 9\$;在第13h减少用电1.953 MWh得到补偿金额669.491\$,单位补偿金额为342.801 3\$.由此可见,这也是需求响应模型中的一种激励措施,即减少的用电量越大得到的单位补偿金便越多,这样就能在一定程度上刺激消费者减少更多的电量.

图6为考虑需求响应火电站的煤耗成本与不考虑需求响应火电站的煤耗成本.可见,不考虑需求响应的火电站煤耗成本达到了 $1.55e+5$  \$,而加入需求响应的煤耗成本减少为 $1.45e+5$  \$,煤耗成本有了很大程度的减少.究其原因,是由于加入需求响应的模型可以鼓励消费者积极参与到电能的调配过程,且在减少电能需求的同时,消费者能获得一定的利益.综上,本文在水火电调度的模型中结合需求响应是切实可行的,也是对火电站减少煤耗成本有较大作用的.

表8为FPA、EOFPA、MGOFPA和IFPA四种算法在处理该算例所得到的最优、最差和平均目标函数值以及20次运算的标准差.由表8可见,标准FPA

得到的结果是4种算法中最差的,不仅各项值都较大,且标准差也远大于其余算法. EOFPA和MGOFPA两者的结果都比标准FPA有显著的提高,但IFPA在处理该算例得到的最优值、最差值、平均值和标准差都是4种算法中最小的,这说明IFPA的寻优能力和稳定性是4种算法中最好的,表明了改进算法的有效性.

## 4 结论

本文提出了一种基于3个策略改进的花朵授粉算法IFPA.双向学习策略加强了FPA的局部搜索能力;仿嗅觉搜索策略提升了FPA在全局搜索时的种群多样性,改善全局搜索的性能,提升种群跳出局部最优解的能力;动态转换概率策略有效地平衡了全局搜索和局部搜索之间的切换.同时提出一种需求响应模型,采用一定的补偿措施使消费者在合理范围内减少电能需求,既让消费者获得一定的利益,也能在一定程度上达到削峰填谷的作用.将所提出的需求响应模型与水火电优化调度模型结合,不仅考虑水电站火电站发电侧,同时考虑消费者需求侧,不但降低了需求负载,也减少了火电站的发电煤耗成本,达到节能减排的效果.利用一个具体算例验证IFPA和考虑需求响应的水火电优化调度模型的有效性和可行性.实验证明,与FPA、EOFPA、MGOFPA相比,IFPA有着更好的搜索能力,能寻找到更稳定更精确的解;考虑需求响应的水火电优化调度模型确实能有效地减少消费者对电能的需求,降低火电站的煤耗成本,减少对环境的污染.

本文以火电站煤耗成本小和供电公司利润最大为目标进行研究,除此之外,在发电侧考虑火电厂的环境排放问题、水电站弃水问题、如何加入风电光电等新能源、需求侧考虑以消费者利润最大为目标等问题都需要进一步研究.

## 参考文献(References)

- [1] Kennedy J, Eberhart R. Particle swarm optimization[C]. Proc of IEEE Int Conf on Neural Networks. Perth: IEEE, 1995: 1942-1948.
- [2] Holland J H. Adaptation in natural and artificial system[M]. Ann Arbor: University of Michigan Press, 1975: 89-120.
- [3] Dorigo M, Maniezzo V, Colorni A. Ant system: Optimization by a colony of cooperating agents[J]. IEEE Trans on Systems, Man, and Cybernetics-Part B, 1996, 26(1): 29-41.
- [4] Karaboga D, Basturk B. On the performance of artificial bee colony(abc) algorithm[J]. Applied Soft Computing, 2008, 8(1): 687-697.
- [5] Pan W. A new fruit fly optimization algorithm:

- Taking the financial distress model as an example[J]. Knowledge-Based Systems, 2012, 26(2): 69-74.
- [6] Yang X S. Flower pollination algorithm for global optimization[M]. Berlin: Springer Heidelberg, 2012: 242-243.
- [7] Salgotra R, Singh U. A novel bat flower pollination algorithm for synthesis of linear antenna arrays[J]. Neural Computing & Applications, 2018: 30(7): 2269-2282.
- [8] Nabil E. A modified flower pollination algorithm for global optimization[J]. Expert Systems with Applications, 2016, 57(15): 192-203.
- [9] Zhou Y, Wang R, Luo Q. Elite opposition-based flower pollination algorithm[J]. Neurocomputing, 2016, 188(18): 294-310.
- [10] Draa A. On the performances of the flower pollination algorithm-qualitative and quantitative analyses[J]. Applied Soft Computing, 2015, 34(9): 349-371.
- [11] Ram J P, Babu T S, Dragicevic T, et al. A new hybrid bee pollinator flower pollination algorithm for solar pv parameter estimation[J]. Energy Conversion & Management, 2017, 135(5): 463-476.
- [12] Abdelaziz A Y, Ali E S, Elazim S M A. Flower pollination algorithm to solve combined economic and emission dispatch problems[J]. Engineering Science & Technology An International J, 2016, 19(2): 980-990.
- [13] Sayed A E F, Nabil E, Badr A. A binary clonal flower pollination algorithm for feature selection[J]. Pattern Recognition Letters, 2016, 77(9): 21-27.
- [14] Yuan X, Cao B, Yang B, et al. Hydrothermal scheduling using chaotic hybrid differential evolution[J]. Energy Conversion & Management, 2008, 49(12): 3627-3633.
- [15] Zhang J, Wang J, Yue C. Small population-based particle swarm optimization for short-term hydrothermal scheduling[J]. IEEE Trans on Power Systems, 2012, 27(1): 142-152.
- [16] 张景瑞, 龙健, 岳超源, 等. 水火电力系统短期优化调度的一种改进粒子群算法[J]. 控制与决策, 2011, 26(3): 407-412.  
(Zhang J R, Long J, Yue C Y, et al. A modified particle swarm optimizer for short-term hydrothermal scheduling with cascaded reservoirs[J]. Control and Decision, 2011, 26(3): 407-412.)
- [17] 侯贤军, 罗春辉, 隗霖捷, 等. 基于微分进化算法的水火电短期优化调度的研究[J]. 电力系统保护与控制, 2015, 43(9): 54-61.  
(Hou M J, Luo C H, Wei L J, et al. Study on short-term hydrothermal scheduling based on differential evolution[J]. Power System Protection and Control, 2015, 43(9): 54-61.)
- [18] 郭壮志, 吴杰康, 孔繁镍. 基于仿电磁学算法和数据包络分析的水火电力系统多目标优化调度[J]. 中国电机工程学报, 2013, 33(4): 53-61.  
(Guo Z Z, Wu J K, Kong F N. Multi-objective optimization scheduling for hydrothermal power systems based on electromagnetism-like mechanism and data envelopment analysis[J]. Proc of the CSEE, 2013, 33(4): 53-61.)
- [19] Feng Z K, Niu W J, Zhou J Z, et al. Scheduling of short-term hydrothermal energy system by parallel multi-objective differential evolution[J]. Applied Soft Computing, 2017, 61(12): 58-71.
- [20] 覃晖, 周建中. 基于多目标文化差分进化算法的水火电力系统优化调度[J]. 电力系统保护与控制, 2011, 39(22): 90-97.  
(Qin H, Zhou J Z. Optimal hydrothermal scheduling based on multi-objective cultured differential evolution[J]. Power System Protection and Control, 2011, 39(22): 90-97.)
- [21] Yang X S, Karamanoglu M, He X. Multi-objective flower algorithm for optimization[J]. Procedia Computer Science, 2013, 18(1): 861-868.
- [22] Salgotra R, Singh U. Application of mutation operators to flower pollination algorithm[J]. Expert Systems with Applications, 2017, 79(13): 112-129.
- [23] Nwulu N I, Xia X. Optimal dispatch for a microgrid incorporating renewables and demand response[J]. Renewable Energy, 2017, 101(2): 16-28.
- [24] 吴杰康, 唐力, 基于模糊机会约束规划的水火电力系统多目标随机调度模型[J]. 中国电机工程学报, 2011, 31(25): 26-34.  
(Wu J K, Tang L. Multi-objective stochastic scheduling models for hydrothermal plants based on fuzzy chance constrained programming[J]. Proc of the CSEE, 2011, 31(25): 26-34.)
- [25] 邓劼, 鞠立伟, 刘俊勇, 等. 基于模糊CVaR理论的水火电力系统随机调度多目标优化模型[J]. 电网技术, 2016, 40(5): 1447-1454.  
(Deng C, Ju L W, Liu J Y, et al. Stochastic scheduling multi-objective optimization model for hydro-thermal power systems based on fuzzy CVaR theory[J]. Power System Technology, 2016, 40(5): 1447-1454.)
- [26] 仇梦林, 胡志坚, 王小飞, 等. 水火电力系统短期实用化调度模型及求解方法[J]. 电力自动化设备, 2016, 36(12): 115-122.  
(Zhang M L, Hu Z J, Wang X F, et al. Practical short-term dispatch model of hydro-thermal power system and solution[J]. Electric Power Automation Equipment, 2016, 36(12): 115-122.)

### 作者简介

沈艳军(1970—), 男, 教授, 博士, 从事智能算法和非线性系统等研究, E-mail: shenyj@ctgu.edu.cn;

杨鑫(1992—), 男, 硕士生, 从事智能算法和电力系统优化调度的研究, E-mail: 657402087@qq.com;

刘允刚(1970—), 男, 教授, 博士生导师, 从事智能算法、非线性系统的研究, E-mail: lygfr@sdu.edu.cn.

(责任编辑: 郑晓蕾)