

# 类进化算法驱动的动态电力经济调度优化

陈 皓, 潘晓英

(西安邮电大学计算机学院, 陕西西安 710121)

**摘 要:** 动态电力经济调度(Dynamic Economic Dispatch, DED)属于一种在时间和空间上相互耦合的多阶段动态决策问题, 一般被转化为一个高维的约束数值优化问题来求解. 本文提出了一种新型全局优化算法--类进化算法(Cluster Evolutionary Algorithm, CEA), 并将其应用于 DED 问题的计算. CEA 通过聚类过程在进化个体间构建一定结构的连接关系, 并利用这种虚拟的簇类化组织来协调和控制群体的优化计算过程, 提高算法对高维问题空间的搜索效率和抗早熟能力. 在仿真实验中 2 个 DED 测试系统被用于对 CEA 的性能进行检验, 其所得最佳计算结果要好于目前已报道的最优解, 而实验统计数据则显示 CEA 是一种求解 DED 问题可行且有效的方法.

**关键词:** 进化算法; 类搜索机制; 动态电力经济调度

**中图分类号:** TP18      **文献标识码:** A      **文章编号:** 0372-2112 (2017)01-0220-05

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2017.01.030

## Cluster Evolutionary Algorithm Driven Dynamic Economic Dispatch Optimization

CHEN Hao, PAN Xiao-ying

(School of Computer Science and Technology, Xi'an University of Post & Telecommunication, Xi'an, Shaanxi 710121, China)

**Abstract:** Dynamic economic dispatch (DED) is a multi-stage decision problem with space and time coupling. In order to get the global optimal solution, a DED problem generally has been transformed into a high-dimensional constrained numerical optimization problem to solve. In this study, a novel global optimization algorithm, cluster evolutionary algorithm (CEA), is proposed to solve DED problem. In CEA, a virtual cluster organization is constructed among individuals so as to dynamically adjust the searching process of simulated evolutionary system while improving the optimization efficiency of population. In simulations, CEA is applied to 2 DED testing systems for verifying its feasibility. Meanwhile, a comparative study is carried out with other existing methods. Results clarify the significance of the proposed algorithm and verify its performance. Considering the quality of the solution obtained, CEA seems to be a promising alternative approach for solving the DED problem.

**Key words:** evolutionary algorithm; cluster searching mechanism; dynamic economic dispatch

### 1 引言

动态经济调度的目标是在发电机组启停计划已经确定的情况下, 依时间顺序计算机组在不同时段的出力数据, 以使系统在满足一系列工作约束的条件下总成本最小. 该问题决策时间的跨度通常为数小时, 其目标函数可表示

$$Cost = \min \sum_{t=1}^{N_t} F_t \quad (1)$$

其中  $Cost$  为总发电成本(\$),  $F_t$  为  $t$  时段断面的机组发

电费用(\$/h),  $N_t$  为时间段的数量. 通常发电机组的能耗特性使用二次函数来近似拟合,  $t$  时段发电机组的能耗函数可表示为

$$\begin{aligned} F_t &= \sum_{i=1}^{N_g} f_i(P_{t,i}) + \sum_{i=1}^{N_g} \varepsilon_{t,i} \\ &= \sum_{i=1}^{N_g} (\alpha_i P_{t,i}^2 + \beta_i P_{t,i} + \gamma_i + \varepsilon_{t,i}) \end{aligned} \quad (2)$$

其中  $N_g$  为系统内发电机总数,  $P_{t,i}$  为  $t$  时段第  $i$  台发电机的有功功率(MW),  $f_i(P_{t,i})$  为第  $i$  台发电机的耗量特性, 其中  $\alpha_i, \beta_i$  及  $\gamma_i$  为其耗量特性常数,  $\varepsilon_{t,i}$  为阀点效应

收稿日期: 2015-06-23; 修回日期: 2015-12-13; 责任编辑: 李勇锋

基金项目: 国家自然科学基金(No. 61203311, No. 61105064); 陕西省教育厅科研计划(No. 2013JK1183, No. 2014JK1667); 厦门市科技计划(No. 3502Z20141164)

引起的第  $i$  台发电机耗量特性变化.

发电机组在工作时除需满足基本的运行约束外还需满足电力平衡约束和机组出力爬坡约束:

(1) 电力平衡约束

在  $t$  时段的时间断面上,发电系统满足

$$\sum_{i=1}^{N_g} P_{t,i} = P_{t,L} + P_{t,S} \quad (3)$$

其中  $P_{t,L}$  为  $t$  时段的系统总负荷,  $P_{t,S}$  为  $t$  时段的系统总网损,它可由 B 系数法求得.

(2) 机组出力爬坡约束

$$\max(P_i^{\min}, P_{t-1,i} - DR_i) \leq P_{t,i} \leq \min(P_i^{\max}, P_{t-1,i} + UR_i) \quad (4)$$

其中,  $P_i^{\min}$ 、 $P_i^{\max}$  为发电机  $i$  的出力上、下限,  $P_{t-1,i}$  为发电机  $i$  在  $t-1$  时段的有功功率,  $UR_i$  和  $DR_i$  分别是该发电机在下一时段出力容许的最大上升和下降值.

由于不同时段系统总负荷  $P_{t,L}$  会发生较明显的变化,因此 DED 是一个动态的多阶段优化过程. 该问题可依照时间序列离散为若干个时间段内的静态优化问题,但机组出力爬坡约束使发电系统在不同时段的出力数据间具有耦合性. 这一特点使 DED 的运算结果更符合实际需求,但计算过程也更复杂,传统的计算方法(如梯度投影法以及拉格朗日松弛法等)很难对其进行有效求解. 为实现全局优化,该问题一般被转化为一个高维约束数值优化问题来求解. 由于进化算法(Evolutionary Algorithm, EA)对高维问题空间具有较好的全局搜索能力,同时对目标函数的类型和搜索空间的结构没有任何限制,因此在对高维约束数值优化问题的计算中得到了大量应用. 目前,一些典型的进化优化算法,如进化规划<sup>[1]</sup>、粒子群算法<sup>[2,3]</sup>、差分进化算法<sup>[4]</sup>、和谐搜索算法<sup>[5]</sup>等,被应用于求解 DED 问题并获得了较好的效果. 但是,高维的目标函数以及非线性的约束易使 EA 在实际计算过程中产生过早收敛或收敛缓慢等现象,这严重影响了对该问题的优化效率和求解质量.

本文提出了一种新的全局优化算法--类进化算法(Cluster Evolutionary Algorithm, CEA). CEA 在个体间构建一定结构的簇类组织,并利用类组织对模拟进化系统的运算过程进行控制和协调,以获得更为有效的抗早熟能力以及稳定的搜索优化性能. 本文介绍了 CEA 的基本模型和主要计算机制,并对 2 个 DED 系统进行了仿真实验,最后给出了结论.

## 2 类进化算法

### 2.1 算法模型

类进化算法(CEA)是一种以簇类为计算的核心单元并基于类结构驱动的新型进化搜索模型,其基本计算框架如图 1 所示. 不同于传统的 EA,CEA 不是以静态

的群体为基础完成迭代搜索,而是通过动态结构的类组织来控制个体的生成和选择过程. 在该模型中,类组织是一种依据群体在问题编码空间中的分布特征通过聚类计算形成的个体连接关系. 在搜索运算中,系统将完全由类组织来控制 and 驱动. 其搜索运算过程被区分为类间搜索和类内搜索两个层面的计算. 类间搜索通过不同子类间的协作来完成对问题空间的勘探,而类内搜索则通过同一子类内的信息交互实现多个局部区域内并行的求精. 这种分工机制不仅有利于降低系统中全局性和局部性搜索运算间的耦合性,为更细致地协调二者间的关系提供基础,同时也为有效融合具有不同计算特性的搜索机制提供了环境. 此外,系统将通过类迭代完成群体更替.

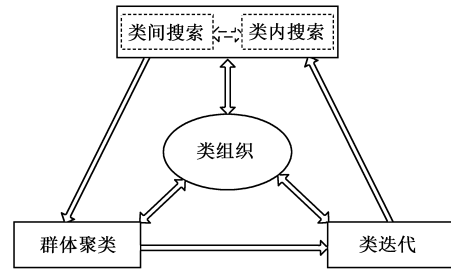


图1 类进化算法模型

首先给出 CEA 在连续空间中的一些基本定义:

**定义 1** 个体  $I$  是一个属于  $D$  维问题空间  $S$  的实数矢量,群体  $Pop$  是规模为  $p$  的个体集合,即  $Pop = \{I_1, I_2, \dots, I_p\}$ ,其中个体  $I_i = (x_1, x_2, \dots, x_D)$  的适应度值为  $fitness_i > 0$ ,且  $I_i$  中每一维变量  $x_j$  的搜索区间为  $x_{low,j} \leq x_j \leq x_{up,j}, j = 1, \dots, D$ .

通常 DED 的计算数据是一个  $N_t \times N_g$  矩阵  $(P_{t,i})$ . 为了便于 CEA 运算,可将  $(P_{t,i})$  转换为一个高维的实数矢量,即  $I = (P_{1,1}, P_{1,2}, \dots, P_{1,N_g}, P_{2,1}, P_{2,2}, \dots, P_{2,N_g}, \dots, P_{N_t,1}, P_{N_t,2}, \dots, P_{N_t,N_g})$ . 则问题维度  $D = N_t \cdot N_g$ ,而问题空间的上界矢量  $\mathbf{x}_{up} = (P_1^{\max}, P_2^{\max}, \dots, P_{N_g}^{\max}, \dots, P_1^{\max}, P_2^{\max}, \dots, P_{N_g}^{\max})$ ,下界矢量  $\mathbf{x}_{low} = (P_1^{\min}, P_2^{\min}, \dots, P_{N_g}^{\min}, \dots, P_1^{\min}, P_2^{\min}, \dots, P_{N_g}^{\min})$ .

**定义 2** 个体  $I_i$  与  $I_j$  间的相似性可通过欧氏距离比  $Dis_{ij}$  来度量

$$Dis_{ij} = Dis(I_i, I_j) = \|I_i - I_j\| / \|\mathbf{x}_{up} - \mathbf{x}_{low}\| \quad (5)$$

其中,  $\mathbf{x}_{up}$  和  $\mathbf{x}_{low}$  为  $S$  的上下界矢量,  $\|x - y\|$  表示  $x$  和  $y$  两个实数矢量的欧几里得范数.

显然,  $Dis_{ij} \in [0, 1]$ ,且  $Dis_{ij}$  愈趋近 0 说明  $I_i$  与  $I_j$  的相似性愈大,反之则相反.

**定义 3** 群体的平均欧氏距离比  $\gamma$  为

$$\gamma = \frac{1}{p-1} \sum_{i=1}^{p-1} \sum_{j=i+1}^p Dis_{ij} / C_p^2 \quad (6)$$

由上述定义可知  $\gamma \in [0, 1]$ ,且  $\gamma$  愈趋近 0 说明群

体的平均差异性越小,反之则相反.故可用其作为群体多样性和收敛性的观察指标.

**定义 4** 类组织  $C$  是一种建立在个体间虚拟的动态连接关系,其中子类  $C_i$  所包含的成员记为  $A_i^e$  并单映射于群体中的一个个体,而中心成员  $A_i^c$  是  $C_i$  中具有最大适应度的成员.其结构可描述如下

$$C = \{C_1, C_2, \dots\}, C_i = \{A_i^1, A_i^2, \dots\}, \\ A_i^j \rightarrow I_k, I_k \in Pop, i, j = 1, 2, \dots, k = 1, 2, \dots, p \quad (7)$$

$$\phi = \{C_i \cap C_j | i \neq j\}, \phi = \{A_i^r \cap A_j^s | i \neq j\}, \\ Pop = \cup C_i, i, j, r, s = 1, 2, \dots \quad (8)$$

$$Dis(A_i^s, A_j^q) > Dis(A_i^s, A_i^r), i \neq j, i, j, r, s, q = 1, 2, \dots \quad (9)$$

$$\forall A_i^r \in C_i, f_{A_i^r} \leq f_{A_i^c}, i, r = 1, 2, \dots \quad (10)$$

## 2.2 计算机制

算法 1 为 CEA 的主要计算步骤.其中  $G$  为总迭代次数,第  $g$  代类搜索将基于类组织  $C^g$  控制完成新个体搜索并生成后代群体  $Pop^{g'}$ ,而群体聚类则完成对第  $g$  代群体  $Pop^g$  及其后代群体  $Pop^{g'}$  的空间分布结构分析并产生新的簇类组织  $C^{g+1}$ ,最后通过类迭代过程筛选个体构建下代群体  $Pop^{g+1}$ .

### 算法 1 CEA

```

 $C^0 = \text{Initializing}(Pop^0);$ 
while( $g < G$ ) {
   $Pop^{g'} = \text{ClusterSearching}(C^g);$ 
   $C^{g+1} = \text{Clustering}(Pop^g, Pop^{g'});$ 
   $Pop^{g+1} = \text{ClusterSelecting}(C^{g+1});$ 
}

```

CEA 的初始化包括群体初始化和类组织初始化两部分.在群体初始化中,系统将在问题空间  $S$  中对群体进行随机分布.在类组织初始化中,初始群体中的每个个体将被置为一个初始子类以及该子类的中心成员并形成规模为  $p$  的初始类组织,子类  $C_i$  的初始搜索规模参数  $\tau_i$  被统一置为 2.

### 2.2.1 类搜索及其调节机制

算法 2 为类搜索的核心步骤.其中  $ch$  为本代类搜索产生的新个体数量,调节参数  $\eta \in (0, 1)$ ,  $UR(0, 1)$  为一均匀分布的随机数.系统将利用子类序号  $i$  依次控制不同子类进行搜索,并通过参数  $\tau_i$  限制子类  $C_i$  搜索的数量.

### 算法 2 类搜索(ClusterSearching)

```

 $i = 1;$ 
 $ch = 0;$ 
while( $ch < p$ ) {
   $t = 0;$ 

```

```

while( $t < \tau_i$ ) { //  $C_i$  的搜索过程
   $C_i = \text{SearchingAmongCluster}(C_i, C);$ 
   $t = t + 2;$ 
  if( $f_{A_i^c} > \bar{f} \&\& UR(0, 1) > \eta$ )
     $\text{SearchingInsideCluster}(C_i);$ 
}
 $ch = ch + t;$ 
 $i = i + 1;$ 
}

```

首先进行的类间搜索(*SearchingAmongCluster*)将在  $C_i$  和其它子类间进行广域勘探,所产生的新个体将加入子类  $C_i$ . 在子类  $C_i$  的类间搜索操作中将首先从  $C$  中随机选择一个子类  $C_j (i \neq j)$ ,接着从  $C_i$  和  $C_j$  中各随机挑选出一个成员  $A_i^r$  与  $A_j^s$ ,最后通过算术交叉和非均匀变异产生两个新个体.

接着,竞争力相对较高的子类(即中心个体适应度值大于群体平均适应度值的子类)有机会通过类内搜索(*SearchingInsideCluster*)提高其所属成员的竞争力,而参数  $\eta$  被用来调节类内搜索的发生概率.利用差分搜索的“DE/best/1/bin”策略可提高这一过程的求精效率.

类搜索中子类进行类内搜索的概率为  $1 - \eta$ ,故  $\eta$  的取值将直接影响系统每代进行的全局及局部搜索的比例.在 CEA 中,参数  $\eta$  将利用一个模拟退火过程来进行调节,公式如下

$$\eta = \left( \exp\left(\frac{-\gamma_g}{T_g}\right) - 1 \right) \xi + 1 \quad (11)$$

其中,  $\gamma_g$  为第  $g$  代群体的平均欧氏距离比,而第  $g$  代群体的退火温度  $T_g = T_0 \cdot \rho^g$ ,  $T_0 = G$ ,  $\rho$  是一个略小于 1 的数,  $\xi \in (0, 1)$ .

另外,类间搜索中变异运算的发生概率  $\beta_m$  将通过一个线性函数来调节.第  $g$  代群体的变异概率为

$$\beta_m = \beta_m^u \cdot (1 - g/G) + \beta_m^l \quad (12)$$

其中  $G$  为总迭代数,  $\beta_m^u, \beta_m^l \in (0, 1)$ . 式(12)使得  $\beta_m$  随着迭代数  $g$  的增大逐渐从  $\beta_m^u + \beta_m^l$  递减到  $\beta_m^l$ .

在式(11)和(12)的调节下类搜索可在系统计算前期形成由“类间交叉 + 变异”主导的全局性搜索,目标是提高群体对问题空间  $S$  的全局勘探效率;随着  $1 - \eta$  的升高,系统中将形成“类间交叉 + 类内差分 + 变异”的搜索组合,而随着  $\beta_m$  和  $\gamma$  的不断降低且类内搜索频率逐步增加,系统将逐渐向邻域搜索过渡,最终促使群体加速收敛.

### 2.2.2 群体聚类与类选择过程

层次聚类可透过一种层次架构方式反复将数据进行聚合,以形成一个层次序列的聚类问题解.由于这个层次序列的形成过程有利于对类组织的规模进行调

节,寻找类结构的平衡点,故我们借鉴层次聚类的基本思想来设计类组织的构造方法.为了提高计算效率,设置了矩阵  $IDM$  与  $CDM$  来分别存储个体间距  $idm_{ij}$  和类间距  $cdm_{ij}$ . 设  $idm_{ij} \in IDM, cdm_{ij} \in CDM$

$$idm_{ij} = \begin{cases} 0, & \text{if } i \leq j \\ Dis_{ij}, & \text{else } i, j = 1, 2, \dots, 2p \end{cases} \quad (13)$$

$$cdm_{ij} = \begin{cases} 0, & \text{if } i \leq j \\ Dis(C_i, C_j) = \sum_{l \in C_i} \sum_{m \in C_j} idm_{lm} / |C_i| |C_j|, & \text{else } \end{cases}$$

$$i = 1, 2, \dots, j = 1, 2, \dots \quad (14)$$

显然矩阵  $IDM$  与  $CDM$  都是下三角矩阵,且其对角线上的元素都为 0.

### 算法 3 构造类组织

步骤 1 通过式(13)初始化  $IDM$ ,并计算当前群体的平均欧氏距离比  $\gamma$ ,接着将每个个体  $I_i (i = 1, 2, \dots, 2p)$  都置为一个子类  $C_i$ ,并由  $IDM$  初始化  $CDM$ .

步骤 2 从  $CDM$  中找到间距最小的两个子类  $C_r$  和  $C_k$ ,即  $cdm_{rk} = \min(CDM)$ ,若满足  $cdm_{rk} < \gamma$  则执行步骤 3,否则结束聚类计算,输出  $C^{g+1}$ .

步骤 3 合并  $C_r$  与  $C_k$  组成为新子类  $C_{rk}'$ ,接着通过式(14)更新  $CDM$  中  $C_{rk}'$  与其余子类的间距值,并返回步骤 2.

群体聚类完成了对当前群体及其后代个体在问题空间的分布结构分析,之后将基于新的类组织  $C^{g+1}$  挑选个体组成下代群体.首先,按适应度值对不同子类内的个体进行排序;接着,按中心个体的适应度值对  $C^{g+1}$  内的子类进行排序;最后,保留每个子类中成员队列的前一半并将其所映射个体加入下代群体,同时删除其余成员.此外,子类  $C_i (i = 1, 2, \dots, |C^{g+1}|)$  在下代的个体搜索规模限制参数  $\tau_i$  将为

$$\tau_i = [2(|C^{g+1}| - i + 1) / (|C^{g+1}|^2 + |C^{g+1}|)]p \quad (15)$$

## 3 仿真实验

用 VC++ 6.0 实现 CEA,并在 PC (Pentium4 2.4GHz, 2GB memory) 上对 5 机和 10 机两个 DED 测试系统进行优化实验.实验中适应度函数设计如下

$$fitness = \sum_{i=1}^{N_i} [C_{\max} - (\sum_{i=1}^{N_g} (\eta_{pz} F_i(P_{t,i}) + \varepsilon_i) + \eta_{pb} \left| \sum_{i=1}^{N_g} P_{t,i} - P_{t,L} - P_{t,S} \right|^\pi)]$$

其中  $C_{\max}$  为一足够大的常数,  $\eta_{pz} \geq 1$  为禁止运转区域限制系数,若  $P_{t,i}$  违反禁止运转区域约束则该系数将为一大于 1 的常数,反之则等于 1,  $\eta_{pb} \in R$  和  $\pi \in R$  为电力平衡系数.

以下实验中的相关参数设置如下:在适应度函数

的计算中,当违反禁止操作区域约束时,在 5 机系统实验中  $\eta_{pz} = 1.1$ ,在 10 机系统实验中  $\eta_{pz} = 1.3$ ;在对 5 机和 10 机系统实验中电力平衡系数  $\eta_{pb}$  都为 100,  $\pi$  都为 1. 另外,2 次实验中 CEA 的群体规模都为 60,而总迭代次数  $G$  分别为 400 和 1000. 类搜索中交叉概率  $\beta_c = 0.9$ ,变异概率调节参数  $\beta_m^u = 1/D, \beta_m^l = 1/2D$ . 类内搜索的差分计算中  $F = 0.4, CR = 0.8$ . 构造  $\eta$  的相关参数中  $T_0 = G, \rho = 0.97, \xi = 0.97$ . 以下是 CEA 对 2 个测试系统分别独立进行 50 次计算后得到的实验数据以及与文献中的其它算法实验结果的比较.

5 机系统考虑了机组阀点效应和系统网络损耗,该系统的相关参数见文献[4].此外,系统的调度期长为 24 小时,分为 24 个时段,时段长为 1 小时.该系统目前已报道的最低发电成本是 43048 \$<sup>[6]</sup>,CEA 搜索到的最低成本值为 43042 \$,要略优于此结果.表 1 中比较了近年提出的几种算法的实验统计结果.

表 1 5 机系统实验统计数据对比

Algorithm	Cost			CPU time (minute)
	Max	Min	Mean	
CEA	43125	43042	43061	0.52
MBF-SSO <sup>[6]</sup>	43093	43048	43068	NA
BBPSO <sup>[7]</sup>	44252	43223	43732	1.48
AIS <sup>[8]</sup>	45554	44385	44759	4.00
ICA <sup>[9]</sup>	43209	43117	43144	NA

从搜索运算的规模来看,CEA 相对接近 ICA 和 MBF-SSO,小于 BBPSO 和 AIS.就文献中提供的 CPU 时间来看,CEA 的平均运算时间最短,BBPSO 次之,MBF-SSO 和 ICA 未提供相应数据.从计算结果的整体质量来看,CEA 所得解中最大值略差于 MBF-SSO,但解的均值和最优解都要好于 MBF-SSO 和 ICA,并明显优于 BBPSO 和 AIS.

10 机系统考虑了机组阀点效应和系统网络损耗,该系统的相关参数见文献[10].此系统的调度期长也为 24 小时并分为 24 个时段,每个时段长为 1 小时.该系统目前已报道的最低发电成本是 1040727 \$<sup>[11]</sup>,CEA 搜索到的最低成本值为 1040084 \$,要明显优于此结果.表 2 为几种算法实验统计结果的比较.

表 2 10 机系统实验统计数据对比

Algorithm	Cost			CPU time (minute)
	Max	Min	Mean	
CEA	1040196	1040084	1040115	1.17
CDBCO <sup>[10]</sup>	-	1042900	1044700	1.53
FA <sup>[11]</sup>	1042579	1040727	1041524	0.164
BPSO-DE <sup>[12]</sup>	1056487	1053839	1055217	10.63
AIS <sup>[8]</sup>	1047050	1045715	1048431	23.22

从搜索规模的角度看,FA 的运算量相对最小,CD-BCO 最大,CEA 的运算量接近 AIS,略大于 BPSO - DE.

就文献中提供的平均 CPU 时间来看,FA 用时最少,CEA 要小于 CDBCO,BPSO-DE 和 AIS.从求解质量的角度看,CEA 所得解的均值以及最大值和最小值都要明显好于其它几种算法.

对 5 机系统,在总运算量基本接近的情况下,CEA 通过更有效率的搜索计算使得优化结果的整体质量要优于 ICA 和 MBF-SSO.对 10 机系统,CEA 能以增加相对有限的运算量为代价明显提高解的质量,使得其最佳解和解的均值都好于 FA 和 CDBCO.可见,CEA 具有更为可靠的计算效率和稳定性.

#### 4 结论


本文提出了基于类搜索驱动的群体进化优化机制,形成了一种新型的进化搜索算法—CEA,并将其应用于对 DED 问题的求解.在对 2 个 DED 测试系统的仿真实验中 CEA 所获得的最优结果都要好于现有文献中记载的最佳解.实验的统计数据分析显示 CEA 可利用类组织有效融合多种搜索机制,并通过动态调节类间搜索和类内搜索间的协作关系使群体对各种复杂问题空间进行稳定且高效地搜索,这使得它可作为一种有效的 DED 问题求解方法.

#### 参考文献

- [1] Attaviriyapun P, Kita H, Tanaka E, Hasegawa J. A hybrid EP and SQP for dynamic economic dispatch with nonsmooth fuel cost function[J]. IEEE Transactions on Power System, 2002, 17(2): 411–416.
- [2] Victoire T A A, Jeyakumar A E. Deterministically guided PSO for dynamic dispatch considering valve-point effect[J]. Electric Power Systems Research, 2005, 73(3): 313–322.
- [3] Victoire T A A, Jeyakumar A E. Reserve constrained dynamic dispatch of units with valve-point effects[J]. IEEE Transactions on Power System, 2005, 20(3): 1273–1282.
- [4] R Balamurugan, S Subramanian. Differential evolution-based Dynamic economic dispatch of generating units with valve-point effects[J]. Electric Power Components and Systems, 2008, 36(8): 828–843.
- [5] Qun Niu, Hongyun Zhang, Xiaohai Wang, Kang Li, George W Irwin. A hybrid harmony search with arithmetic crossover operation for economic dispatch[J]. Electrical Power and Energy Systems, 2014, 62: 237–257.
- [6] Azizpanah Abarghoee R. A new hybrid bacterial foraging and simplified swarm optimization algorithm for practical optimal dynamic load dispatch[J]. Electrical Power and Energy Systems, 2013, 49: 414–429.

- [7] Zhang Yong, Gong Dunwei, Geng Na, Sun Xiaoyan. Hybrid bare-bones PSO for dynamic economic dispatch with valve-point effects[J]. Applied Soft Computing, 2014, 18: 248–260.
- [8] S Hemamalini, S P Simon. Dynamic economic dispatch using artificial immunosystem for units with valve-point effect[J]. International Journal of Electrical Power and Energy Systems, 2011, 3(4): 868–874.
- [9] Mohammadi Ivatloo B, Rabiee A, Soroudi A, Ehsan M. Imperialist competitive algorithm for solving non-convex dynamic economic power dispatch[J]. Energy, 2012, 44(1): 228–40.
- [10] Lu Peng, Zhou Jianzhong, Zhang Huifeng, Zhang Rui, Wang Chao. Chaotic differential bee colony optimization algorithm for dynamic economic dispatch problem with valve-point effects[J]. Electrical Power and Energy Systems, 2014, 62: 130–143.
- [11] Niknam T, Azizpanah Abarghoee R, Roosta A. Reserve constrained dynamic economic dispatch: a new fast self-adaptive modified firefly algorithm[J]. IEEE Systems Journal, 2012, 6: 635–646.
- [12] Vaisakh K, Praveena P, Rama Mohana Rao S, Meah K. Solving dynamic economic dispatch problem with security constraints using bacterial foraging PSO-DE algorithm[J]. Electrical Power and Energy Systems, 2012, 39: 56–67.

#### 作者简介



陈皓 男,1978 年 5 月生于陕西西安,博士,副教授,硕士研究生导师,CCF 会员,主要研究领域为进化计算,工程优化.  
E-mail: chenhao@xupt.edu.cn



潘晓英 女,1981 年 10 月生于浙江缙云,博士,副教授,硕士研究生导师,CCF 会员,主要研究领域为进化计算,多智能体系统.  
E-mail: panxiaoying@xupt.edu.cn