

# 基于分类概率综合多场景分析的分布式电源多目标规划

孙惠娟<sup>1</sup>, 刘君<sup>2</sup>, 彭春华<sup>1</sup>

(1. 华东交通大学 电气与自动化工程学院, 江西 南昌 330013;

2. 江西省机电设备招标有限公司, 江西 南昌 330046)

**摘要:**为了在配电网分布式电源规划中更加准确合理地考虑分布式电源出力及负荷需求的不确定性, 基于风电、光伏和负荷的随机性分布特征差异, 提出分类概率综合多场景分析方法以实现更合理的多场景生成, 并融合 K-Means 聚类方法和层次凝聚聚类(HAC)算法形成 H-K 复合聚类场景压缩方法, 实现更高效的场景压缩; 以年均收益率和配电系统电压分布改善率最大化为目标构建多场景分布式电源多目标规划模型, 并采用基于 HAC 种群截断策略的改进非劣排序复合微分进化算法对模型进行求解; 以 IEEE 33 节点配电系统为例进行了分布式电源多目标规划, 仿真结果验证了所提方法的有效性和优越性。

**关键词:**分布式电源规划; 多场景分析; 分类概率; H-K 复合聚类

**中图分类号:** TM 761

**文献标识码:** A

**DOI:** 10.16081/j.issn.1006-6047.2018.12.006

## 0 引言

可持续性在未来电网的基础特征之一, 包括可再生能源等在内的分布式电源 DG (Distributed Generation) 的大量接入和应用是其最为本质的表现<sup>[1]</sup>。但大量 DG 的接入将增加配电网运行的复杂性和不确定性, 因此也会给配电网规划带来重大影响, 即在配电系统中必须合理规划 DG 的安装位置和容量。

传统基于确定性因素分析计算的配电网规划方法过于简单, 对于具有随机性、波动性的 DG 接入的配电网已不再适用。近年来较多文献对配电网不确定性规划问题进行了分析和研究。其中多场景分析是处理难以用数学模型描述的随机性问题的一种有效方法。文献[2]针对 DG 出力和负荷需求的间歇性及不确定性, 根据各自的影响因素将日负荷和 DG 输出分为几种典型场景, 通过拉丁超立方抽样和样本缩减实现了多场景分析处理不确定性问题的求解过程; 文献[3]按照风速变化和太阳光照强度变化分别建立了 3 个风电场景和 3 个光伏场景, 以这 9 种场景组合计算 DG 的输出功率, 解决 DG 出力不确定性问题。但这种列举有限典型场景的分析方法不够全面, 很可能会遗漏最佳方案。文献[4]提出对每个目标函数生成足够多的场景, 并为每个目标函数构造一个集合函数来处理包含不确定性因素的多目标优化问题; 文献[5]针对风电和负荷的功率误差生成规模足够大的场景, 假设二者的输出功率均

服从正态分布, 以正态分布概率密度函数计算各个场景的发生概率。已有的相关研究简单采用正态分布的不分类概率多场景分析方法存在较大的不合理性, 因此会在 DG 规划过程中产生较大的误差。

综上所述, 为了更准确地描述 DG 出力和负荷需求的不确定性, 使 DG 规划更合理, 本文拟基于负荷、风电和光伏的随机性特征差异, 深入分析各自统计特征, 提出新的分类概率综合多场景分析方法, 以便实现更准确的多场景生成。为了避免场景规模过于庞大而造成计算复杂度过高, 本文还将研究更为高效的场景压缩方法。本文首先拟融合层次凝聚聚类 HAC (Hierarchical Aggregation Clustering algorithm) 算法<sup>[6]</sup>和 K-Means 聚类方法<sup>[7]</sup>形成 H-K 复合聚类算法进行场景压缩, 利用 HAC 算法计算速度快的优点完成初步聚类, 同时弥补 K-Means 算法初始信息选取过于随机的缺点, 再使用 K-Means 算法进一步完善聚类过程, 弥补 HAC 算法聚类的粗糙性, 得到最终的典型“规划场景”; 然后以年均收益率和配电系统电压分布改善率最大化为目标构建 DG 多目标规划模型, 并采用基于 HAC 种群截断策略的改进的非劣排序复合微分进化 INSCDE (Improved Non-dominated Sorting Compound Differential Evolution) 算法对模型进行求解和基于最短归一化距离法实现多目标总体最优决策, 从而可得到最优的 DG 多目标规划方案。

## 1 分类概率综合多场景分析方法

### 1.1 分类概率综合多场景生成过程

配电网 DG 多目标规划要考虑的随机变量有风电出力值、光伏出力值和负荷需求值等。由于风电出力值、光伏出力值是分别由随机的风速、光照决定, 且通常为以风速、光照为变量的分段函数, 故其随机分布特性比风速和光照更复杂。为此, 本文不

收稿日期: 2018-05-24; 修回日期: 2018-10-30

基金项目: 国家自然科学基金资助项目(51867008, 51567007); 江西省自然科学基金资助项目(20171BAB206042); 江西省教育厅科技项目(GJJ160525)

Project supported by the National Natural Science Foundation of China(51867008, 51567007), Jiangxi Natural Science Foundation (20171BAB206042) and the Science and Technology Project of Jiangxi Provincial Education Department(GJJ160525)

直接以风电和光伏的出力值作为场景随机变量,而是基于春夏秋冬四季风速、光照和负荷的随机特性进行多场景分析。

首先对风速、光照强度及负荷需求的历史数据(若缺乏实际数据,也可结合相关气象数据利用 HOMER 软件生成<sup>[8]</sup>)进行统计分析,得出各随机变量在春夏秋冬四季 24 h 典型数据,假设各时刻的典型数据与实际数据的误差服从其统计特征的概率密度函数,则各“规划场景”中随机变量的表达式如下:

$$\begin{cases} v_{t,s} = v_t^0 + \Delta v_{t,s} \\ E_{t,s} = E_t^0 + \Delta E_{t,s} \\ L_{t,s} = L_t^0 + \Delta L_{t,s} \end{cases} \quad (1)$$

其中,  $v_t^0$ 、 $E_t^0$ 、 $L_t^0$  分别为  $t$  时刻典型的风速值、光照强度值和负荷需求值;  $v_{t,s}$ 、 $E_{t,s}$ 、 $L_{t,s}$  分别为  $s$  场景下  $t$  时刻风速值、光照强度值、负荷需求值;  $\Delta v_{t,s}$ 、 $\Delta E_{t,s}$ 、 $\Delta L_{t,s}$  分别为  $s$  场景下  $t$  时刻风速误差值、光照强度误差值、负荷需求误差值;  $s = 1, 2, \dots, N_s$ ,  $N_s$  为场景总数;  $t = 1, 2, \dots, 24$ 。

以上述模型为依据生成大量场景,以风速多场景生成过程为例,具体执行步骤如下。

**a.** 经统计分析,风速误差  $\Delta v$  可近似认为服从威布尔分布<sup>[9]</sup>,其概率密度函数通常可表示为:

$$f(\Delta v) = \exp\left[-\left(\frac{\Delta v}{o}\right)^k\right] \frac{k}{o} \left(\frac{\Delta v}{o}\right)^{k-1} \quad (2)$$

其中,  $k$  和  $o$  分别为威布尔分布的尺度参数和形状参数,可由各时刻的历史风速及典型风速的误差(数据来自文献[10])的平均值  $\mu$  和标准方差  $\sigma$  得出,计算式分别如式(3)和式(4)所示。

$$k = (\sigma/\mu)^{-1.086} \quad (3)$$

$$o = \frac{\mu}{\Gamma(1+k^{-1})} \quad (4)$$

其中,  $\Gamma(\cdot)$  为伽马函数。以 12:00 风速误差为例,由式(3)、(4)及统计数据求出四季该时刻下各参数值如表 1 所示。

表 1 威布尔分布参数值

季节	$k$	$o$
春季	1.96	9.29
夏季	1.71	7.16
秋季	1.97	10.83
冬季	2.11	12.56

**b.** 以春季 12:00 风速误差服从的概率密度函数为例,离散成如图 1 所示的 7 个区间,横坐标为风速误差,纵坐标  $\alpha_{x,t}$  ( $x = 1, 2, \dots, 7$ ) 为每个区间对应的概率密度,各区间宽度为  $\sigma_{\Delta v}$ ,即每个区间对应的概

率为  $\alpha_{x,t}\sigma_{\Delta v}$ ,各区间对应的概率之和为 1。

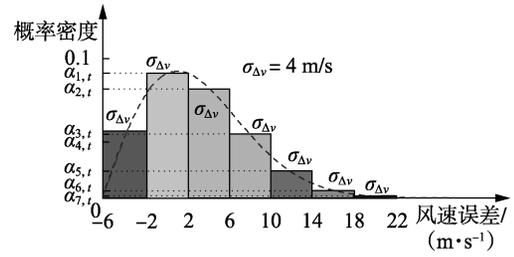


图 1 风速误差的离散化概率密度函数

Fig.1 Discrete probability density function of wind speed error

同理,针对光照强度误差值及负荷需求误差值,经统计分析二者分别近似服从 Beta 分布<sup>[11]</sup>与正态分布<sup>[12]</sup>,其概率密度函数求解步骤与风速误差类似,同样可画出类似图 1 的离散化概率密度函数图,限于篇幅问题,在此不再赘述。光照强度和负荷误差的每个区间对应的概率密度可分别用  $\beta_{y,t}$  和  $\gamma_{z,t}$  表示,各区间宽度分别为  $\sigma_{\Delta E}$  和  $\sigma_{\Delta L}$ 。

**c.** 采用轮盘赌法确定每个场景中各时段下每个随机变量的选中区间,以此来确定  $s$  场景  $t$  时刻风速、光照强度和负荷需求的分类发生概率,得到综合场景如式(5)所示。

$$S = \left\{ \Delta v_{1,t,s}, \dots, \Delta v_{7,t,s}, \Delta E_{1,t,s}, \dots, \Delta E_{7,t,s}, \Delta L_{1,t,s}^D, \dots, \Delta L_{7,t,s}^D \right\} \quad (5)$$

其中,  $\Delta v_{x,t,s}$ 、 $\Delta E_{y,t,s}$ 、 $\Delta L_{z,t,s}^D$  分别为  $s$  场景下  $t$  时刻风速、光照强度和负荷功率的误差区间;  $D = 1, 2, 3$  表示负荷类型。

**d.** 按下式计算每个综合场景发生的概率。

$$\omega(s) = \prod_{t=1}^{24} \left[ \sum_{x=1}^7 (\Delta v_{x,t,s} \alpha_{x,t} \sigma_{\Delta v}) \sum_{y=1}^7 (\Delta E_{y,t,s} \beta_{y,t} \sigma_{\Delta E}) \times \prod_{D=1}^3 \sum_{z=1}^7 (\Delta L_{z,t,s}^D \gamma_{z,t} \sigma_{\Delta L}) \right] \quad (6)$$

其中,  $\omega$  为  $s$  场景的发生概率;  $\alpha_{x,t}\sigma_{\Delta v}$ 、 $\beta_{y,t}\sigma_{\Delta E}$ 、 $\gamma_{z,t}\sigma_{\Delta L}$  分别为  $s$  场景下  $t$  时刻风速误差区间、光照强度误差区间、负荷需求功率误差区间的发生概率。

**e.** 按下式将每个场景的发生概率标准化。

$$p_r(s) = \omega(s) / \sum_{s=1}^{N_s} \omega(s) \quad (7)$$

## 1.2 基于 H-K 复合聚类算法的场景缩减

在经过分类概率综合多场景生成过程之后,由于数据规模过于庞大,会增加后续计算的复杂度,因此,还需对生成的场景压缩得到典型“规划场景”。

假设场景生成阶段共产生  $N_s$  个“规划场景”,经过 HAC 算法聚类后获得的场景数为  $T_s$ ,期望获得的最终典型“规划场景”的数量为  $M_s$ 。运用 H-K 复合聚类算法进行场景缩减的具体步骤如下。

a. 初始时,将每一个场景当作一个初始类,共有  $N_s$  类,利用 HAC 算法计算两两之间的距离。

b. 找到距离最接近的 2 个类合并成一个新的类,此时类的总数为  $N_s-1$ 。

c. 重新计算新生成的这个类与所有旧类之间的距离。

d. 重复步骤 b 和 c,直到此时总类数为  $T_s$ 。

e. 将经 HAC 算法聚类得到的  $T_s$  个类作为 K-Means 算法的输入,随机选取其中  $M_s$  个场景作为簇的中心,设第  $l$  个簇心场景为  $T_l^{\text{Center}}$ ,则簇心场景集合为  $A_{\text{Center}} = \{T_l^{\text{Center}}\} (l=1,2,\dots,M_s)$ 。

f. 在  $T_s$  个类中去除上述簇心场景集合可以得到此时的剩余场景集合为  $A_{\text{Member}} = \{T_j^{\text{Member}}\} (j=1,2,\dots,T_s-M_s)$ ,其中  $T_j^{\text{Member}}$  为第  $j$  个剩余场景。计算第  $l$  个簇心场景与第  $j$  个剩余场景间的距离  $d_{l,j}$  为:

$$d_{l,j} = \|T_l^{\text{Center}} - T_j^{\text{Member}}\|_2 \quad (8)$$

g. 对于每个剩余场景  $T_j^{\text{Member}}$ ,通过计算和排序找到一个距离它最近的簇心场景,由此将它与最近簇心进行聚类形成一个簇。所有剩余场景聚类操作结束后可得到聚类集合  $A_{\text{Sort}} = \{S_l\} (l=1,2,\dots,M_s)$ ,其中  $S_l$  表示内部场景相似度较高的一个簇。

h. 典型“规划场景”簇心的选取方法:假设某簇  $S_l$  中有  $L_s$  个场景,分别计算其中的每个场景与其他各场景的距离之和,如式(9)所示。

$$d_q = \sum_{\substack{k'=1 \\ k' \neq q}}^{L_s} \|T_q - T_{k'}\|_2 \quad q=1,2,\dots,L_s \quad (9)$$

选取  $d_m = \min(d_1, d_2, \dots, d_{L_s})$  的对应场景  $T_m$  作为本簇的新簇心。同理确定所有簇的簇心场景集合。

i. 重复步骤 f—h,直到聚类结果及获得的典型“规划场景”不再变化,场景缩减全部过程执行完毕。获得的每个簇心典型“规划场景”的概率值等于该场景集合中所有场景的概率之和。

## 2 DG 规划的数学模型

### 2.1 DG 出力场景计算

风电机组出力与风速大小密切相关<sup>[13]</sup>,假设风力发电机的额定输出功率为  $P_R$ ,额定风速为  $v_R$ ,切入风速为  $v_{\text{in}}$ ,切出风速为  $v_{\text{out}}$ ,加入多场景后输出功率表达式如下:

$$P_{\text{WGL},s,t} = \begin{cases} 0 & \Delta v_{l,s} + v_t^0 < v_{\text{in}} \\ P_R \frac{(\Delta v_{l,s} + v_t^0)^2 - v_{\text{in}}^2}{v_R^2 - v_{\text{in}}^2} & v_{\text{in}} \leq \Delta v_{l,s} + v_t^0 \leq v_R \\ P_R & v_R \leq \Delta v_{l,s} + v_t^0 \leq v_{\text{out}} \\ 0 & \Delta v_{l,s} + v_t^0 > v_{\text{out}} \end{cases} \quad (10)$$

其中,  $P_{\text{WGL},s,t}$  为第  $l$  个风电机组在  $s$  场景下  $t$  时刻的出力;  $l=1,2,\dots,N_{\text{WG}}, N_{\text{WG}}$  为安装风电机组的总数;  $s=1,2,\dots,M_s; t=1,2,\dots,24$ 。

光伏电源有功出力与光照强度以及安装容量密切相关<sup>[14]</sup>,假设光伏电源的额定输出功率为  $S_R$ ,额定光照强度  $E_R$ ,系统各个位置处的光照强度相同,加入多场景后输出功率表达式如下:

$$P_{\text{PVI},s,t} = \begin{cases} S_R \frac{E_t^0 + \Delta E_{l,s}}{E_R} & E_t^0 + \Delta E_{l,s} \leq E_R \\ S_R & E_t^0 + \Delta E_{l,s} > E_R \end{cases} \quad (11)$$

其中,  $P_{\text{PVI},s,t}$  为第  $l$  个光伏电源在  $s$  场景下  $t$  时刻的出力;  $l=1,2,\dots,N_{\text{PV}}, N_{\text{PV}}$  为安装光伏电源的总数;  $s=1,2,\dots,M_s; t=1,2,\dots,24$ 。

将不同场景下的风速误差值和光照误差值分别代入式(10)和(11),即可分别求得各场景下的风电和光伏功率。

### 2.2 目标函数

为满足电网运行的经济性和供电可靠性要求,以最大化 DG 年均收益率和系统电压分布改善率作为目标函数。

(1) DG 年均收益率。

DG 的年均收益率在数值上等于 DG 的年均收入与年均投资成本的比值,如式(12)所示。

$$\max J_{\text{IC}} = \frac{I_Y}{C_Y} \quad (12)$$

其中,  $I_Y$  为年均收益;  $C_Y$  为年均投资成本。

a. 年均投资成本:

$$C_Y = C_i \frac{r_0(1+r_0)^n}{(1+r_0)^n - 1} + C_{\text{om}} + C_{\text{be}} + C_{\text{pl}} \quad (13)$$

其中,  $C_i$  为 DG 的初期投资费用;  $r_0$  为折现率;  $n$  为使用年限;  $C_{\text{om}}$  为 DG 的年运行维护费用;  $C_{\text{be}}$  为年购电成本;  $C_{\text{pl}}$  为年直接停电损失费用。

b. 年均收益:

$$I_Y = I_{\text{sn}} + I_{\text{ps}} + I_{\text{su}} \quad (14)$$

其中,  $I_{\text{sn}}$  为 DG 年上网卖电量收入;  $I_{\text{ps}}$  为年电价补贴收入;  $I_{\text{su}}$  为用户年售电收入。

(2) 系统电压分布改善率。

在配电网系统中选择合适的 DG 容量及接入位置可以明显改善系统电压分布。定义电压分布改善率指标为:

$$J_{\text{VP}} = \frac{I_{\text{VPw}} - I_{\text{VPwo}}}{I_{\text{VPwo}}} \quad (15)$$

其中,  $I_{\text{VPw}}$  为含 DG 时系统年电压指标;  $I_{\text{VPwo}}$  为不含 DG 时系统年电压指标。

多场景电压指标计算公式为:

$$J_{VP} = \sum_{m=1}^{N_m} \left[ D_m \sum_{s=1}^{N_s} \left( p_r(s) \sum_{l=1}^N V_l L_l k_l \right) \right] \quad (16)$$

其中,  $N_m$  为季节数, 取 4;  $D_m$  为第  $m$  个季节的相应天数;  $N$  为系统节点数;  $V_l$  为节点  $l$  的电压幅值;  $L_l$  为节点  $l$  的负荷值;  $k_l$  为节点  $l$  负荷的权重因子。

相关约束条件可以参考文献[15], 本文不再赘述。

### 3 模型求解

#### 3.1 INSCDE 算法

非劣排序复合微分进化 NSCDE (Non-dominated Sorting Compound Differential Evolution) 算法是当下比较新的求解多目标优化问题的智能优化算法, 在全局优化方面很有优势, 它可以在保证算法收敛速度的同时, 提升种群在进化过程中的多样性, 具有较好的全局搜索性能<sup>[15]</sup>。

为了进一步地保持种群多样性, 克服算法搜索不均的问题, 本文在 NSCDE 算法中对其非支配排序策略加以改进并引入基于 HAC 算法的种群截断策略, 提出 INSCDE 算法, 使其更好地运用在 DG 多目标规划问题中。

##### 3.1.1 改进的排序策略

假设种群规模为  $N_p$ , 首先使用 NSCDE 算法中的非占优排序策略计算种群中每个个体的序值, 然后对该个体的序值加上相应支配其个体的数量, 步骤如下:

$$m(X_l) = R(X_l) + n(X_l) \quad (17)$$

其中,  $X_l$  为第  $l$  个个体;  $R(X_l)$  为  $X_l$  的非支配排序序值;  $n(X_l)$  为支配  $X_l$  的个体数量。最后, 对于种群内  $N_p$  个个体按照升序排列  $m(X_l)$ , 并将  $m(X_l)$  对应的序值作为对个体  $X_l$  进行多目标非支配排序操作的最终序值依据。

为说明改进排序策略的优越性, 以一个双目标函数优化问题为例, 假设在快速非支配排序后, 个体  $a \sim e$  为第一序值, 个体  $A \sim C$  为第二序值, 同时假设个体  $A$  被个体  $a, b$  和  $c$  支配, 个体  $B$  被个体  $c$  和  $d$  支配, 个体  $C$  被个体  $e$  支配, 如图 2 所示, 其中  $f_1(X)$  和  $f_2(X)$  为个体  $X$  所对应的 2 个优化目标值。若使用 NSCDE 算法的排序策略, 个体  $A \sim C$  拥有相同的序值, 然而, 它们各自相邻的支配方案数量是不同的。为了说明  $A, B$  和  $C$  分别响应的密度信息不同, 以 3 个等半径的圆来覆盖其相邻个体。如图 2 所示, 个体  $A$  比个体  $B$  更拥挤, 而个体  $B$  比个体  $C$  更拥挤。通过改进的排序策略, 可以得出个体  $A, B$  和  $C$  的序值分别为 4, 3 和 2。因此, 个体  $C$  的密度更小拥有更低的序值, 这意味着它在选择阶段更具有优越性。所以, 改进的排序策略可以更好地保持种群多样性。

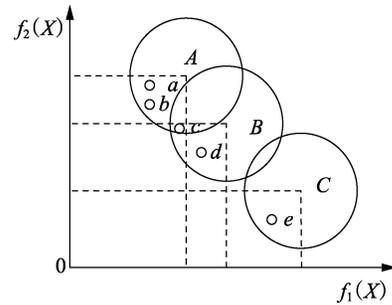


图 2 个体分布图

Fig.2 Schematic diagram of individual distribution

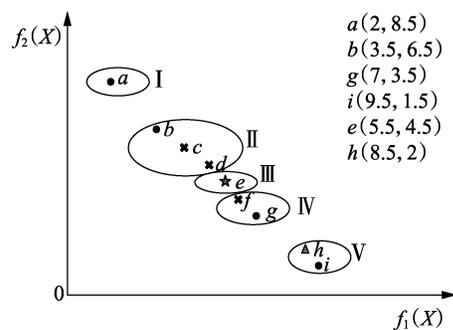
##### 3.1.2 基于 HAC 算法的种群截断策略

本文提出一种基于 HAC 算法的聚集方法处理在排序之后拥有同一序值的个体, 首先计算解与解之间的空间距离, 以此来描述个体间的相似性, 并将其相似度较高的个体聚成合适数量的簇, 然后将每个簇中拥有最大拥挤距离的个体保留下来至下一代种群中, 从而克服搜索不均的问题。

以一个双目标函数优化问题为例, 如图 3 所示, 假设要从拥有相同序值的个体  $a \sim i$  候选者中选择 5 个个体进入下一代种群中, 具体步骤如下:

a. 运用 HAC 算法将所有个体分成 5 簇(I—V);

b. 计算每个个体与同序值其他所有个体之间的距离, 用来表示个体间的拥挤度, 并在每个簇中选取一个拥挤距离最大的个体进入下一代。



- 2 种策略均选出的解
- ★ 基于 HAC 算法策略选出的解
- ▲ 传统策略选出的解
- \* 淘汰解

图 3 2 种截断策略的选取结果

Fig.3 Selecting results of two truncation strategies

传统的截断策略只进行步骤 b, 不执行将所有个体聚成相似度较高的几个簇这一步骤, 而是直接对所有候选个体进行拥挤度计算, 选出拥挤度较大的个体。因此, 由基于 HAC 算法策略选出的下一代个体为  $a, b, g, i$  和  $e$ , 由传统策略选出的下一代个体为  $a, b, g, i$  和  $h$ 。对比 2 组结果可知, 基于 HAC 算法的截断操作选择了个体  $e$  而不是个体  $h$  进入下一代种群。

为了证明本文提出的截断策略能克服搜索不均的问题, 通过计算相邻个体距离的方差来测量个体

分布的均匀度,由基于 HAC 算法的截断策略计算的方差为 0.352 8,而传统策略计算的方差为 2.158 0,由此可见本文所提出的改进截断策略可以提升解的均匀分布性能。

### 3.2 DG 多目标规划流程

经过 INSCDE 算法优化后可得到一系列 Pareto 最优解,针对这一系列最优解,本文采用基于最短归一化距离的多目标决策方法<sup>[15]</sup>提取出最优折中解,得到最优的规划方案。

综上所述,本文采用的基于 INSCDE 算法求解 DG 规划问题的流程可以分为 5 个步骤,即前期数据收集整理分析、基于分类概率综合多场景生成、基于 H-K 复合聚类算法的场景缩减、建立 DG 规划数学模型、INSCDE 算法求解得出最优规划方案。

## 4 算例分析

### 4.1 参数设置

为验证本文所提模型和算法的有效性,以图 4 所示的 IEEE 33 节点系统为例进行多目标规划 DG 的选址定容,线路参数及相关数据来自文献<sup>[16]</sup>。计划在 4 个节点接入风电和光伏,DG 初期投资费用及运行维护费用等相关数据参考文献<sup>[17]</sup>,在不考虑 DG 出力不确定时,假设风电和光伏的出力均为额定容量的 35%。

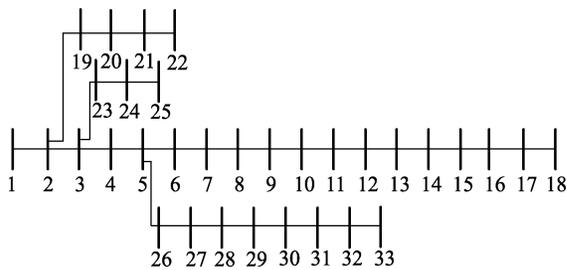


图 4 IEEE 33 节点配电系统

Fig.4 IEEE 33-bus distribution system

### 4.2 结果分析

为说明 H-K 复合聚类场景压缩方法的优越性,本文分别运用 H-K 复合聚类算法和常规 K-Means 聚类算法将生成的 1 000 个场景压缩至 10 个典型场景。由于 H-K 复合聚类算法前期采用了高效的 HAC 算法,不需筛选初始聚类中心而是直接对个体进行距离计算,可以快速完成初步聚类,仅需 20.28 s 可以得到 100 个缩减类,然后以此作为 K-Means 算法的输入进行精细化聚类,仅需 3.57 s 即可得到 10 个典型场景,共耗时 23.85 s;而单纯采用常规 K-Means 聚类算法直接对 1 000 个场景聚类压缩至 10 个典型场景,由于整体聚类效率较低,需耗时 33.24 s,相比 H-K 复合聚类算法总耗时增加了 39.37%。可见,采用 H-K 复合聚类算法可以显著缩短聚类时间。

在应用 H-K 复合聚类算法与 INSCDE 优化算法

的基础上,场景生成阶段考虑分类概率和不考虑分类概率(均服从正态分布)2 种情况,程序运行 1 000 代得到 Pareto 前沿如图 5 所示,由图可以看出二者之间有较为明显的差异。在年均收益率  $J_{IC}$  相同的情况下,考虑分类概率比不考虑分类概率得出的电压改善程度值  $J_{VP}$  会更大,这是由于考虑了风电出力、光伏出力、负荷需求服从不同的概率密度函数,更符合实际应用中不同随机变量的出力状态,增大了风光接入电网时二者本身的互补概率以及 DG 出力与负荷需求之间的匹配概率。

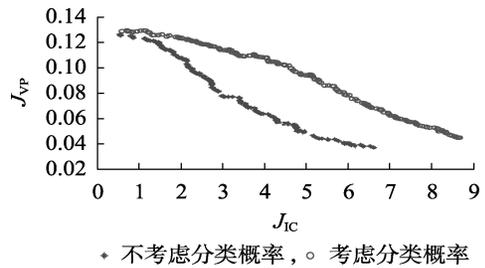


图 5 2 种模式的 Pareto 前沿

Fig.5 Pareto frontiers of two modes

表 2 为运用 INSCDE 算法与 H-K 复合聚类求解不考虑多场景、考虑多场景且不考虑分类概率、考虑多场景及分类概率 3 种模式 DG 规划得出的总体最优折中解。其中,第一种模式不考虑 DG 出力及负荷需求的不确定性,以一组确定数据处理 DG 规划问题,这是不合理的,此时的风电机组和光伏发电在电压改善度上无法体现区别,导致经济效益更高的风电机组成为最佳选择,尽管获得的年均收益率较高,但依旧不合理。在考虑 DG 出力不确定性加入多场景分析后,是否针对随机变量不同采用分类偏差概率模型对规划结果也有较大的影响,从表中可以看出考虑分类概率与不考虑分类概率相比,总体最优解有所改善,其中  $J_{IC}$  的值增加了 51.75%,  $J_{VP}$  的值增加了 24.8%。

表 2 3 种模式的最优折中解

Table 2 Optimal compromise solutions of three modes

模式	DG 类型	安装位置	安装容量/kW	$J_{IC}$	$J_{VP}$
不考虑多场景	WG	16	110	5.935 1	0.002 7
	WG	28	100		
	WG	31	200		
	WG	33	400		
考虑多场景且不考虑分类概率	WG	28	100	3.394 1	0.076 6
	PV	33	600		
	WG	29	600		
考虑多场景及分类概率	PV	17	560	5.150 4	0.095 6
	WG	28	100		
	WG	17	550		
	WG	29	600		
	PV	33	600		

为了说明本文所提 INSCDE 算法的优越性,本

文还采用 NSCDE 算法求解了上述基于分类概率综合多场景分析的 DG 多目标规划问题。优化解的分布特征可由差异度  $\Delta$  和最大分布度  $S_{\max}$  来评价,这 2 项评价指标分别用来表征解的分布差异程度和所得 Pareto 前沿的端点间距离<sup>[18]</sup>,计算方法可以参考文献[19-20]。表 3 中展示了分别应用 INSCDE 以及 NSCDE 进行 6 次优化所得结果的  $\Delta$  和  $S_{\max}$  的均值和方差。由表 3 可知,INSCDE 算法具有较小的  $\Delta$  均值和较大的  $S_{\max}$  均值,并且方差更小,说明算法改进后不仅提升了解的均匀分布性和完整性,而且具有更好的收敛稳定性。

表 3 性能指标

Table 3 Performance indexes

算法	$\Delta$		$S_{\max}$	
	平均值	方差	平均值	方差
INSCDE	0.543 7	0.009 2	1.154 6	0.045 1
NSCDE	0.805 6	0.016 4	1.134 9	0.064 5

采用上述 2 种算法得出的 Pareto 前沿如图 6 所示。由图 6 可以看出,正如 3.1 节中的分析,由于 INSCDE 算法采用改进排序策略和基于 HAC 算法的种群截断策略,使得进化过程中能够更好地保持个体多样性和均匀搜索能力,可有效实现深度寻优,因此在解的均匀分布性、Pareto 前沿的准确性和完整性等方面都优于 NSCDE 算法。

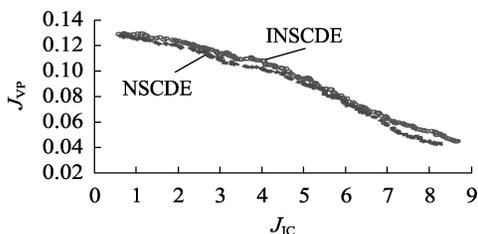


图 6 不同算法的 Pareto 前沿

Fig.6 Pareto frontiers of different algorithms

## 5 结论

本文在考虑 DG 出力及负荷需求不确定性的基础上,针对随机变量类型的不同,提出了运用分类偏差概率模型综合生成足够规模的场景,并利用 H-K 复合聚类方法将其缩减至合适数目的典型场景,以年均收益率以及电压分布改善率为目标函数,采用 INSCDE 算法求解该模型,得到的主要结论如下。

本文基于风电、光伏和负荷的随机性特征差异引入分类概率到规划模型中,能够更准确实际地描述 DG 出力及负荷需求的不确定性,使得求解结果更可靠;提出的 H-K 复合聚类场景压缩方法可实现高效的场景压缩;提出的基于改进排序策略和种群截断策略的 INSCDE 算法,可保证寻优过程中的个体多样性和搜索均匀性,并得到理想的 Pareto 最优前沿。

本文所提模型和算法可以有效解决配电网 DG 规划问题,得到的规划结果有较好的经济性和可靠性,为 DG 规划相关问题的求解提供了新思路。

## 参考文献:

- [1] 范士雄,蒲天骄,刘广一. 主动配电网中分布式发电系统接入技术及其进展[J]. 电工技术学报,2016,31(增刊2):92-101.  
FAN Shixiong,PU Tianjiao,LIU Guangyi. Technologies and its trends of grid integration of distributed generation in active distribution network[J]. Transactions of China Electrotechnical Society,2016,31(Supplyment 2):92-101.
- [2] 张沈习,程浩忠,邢海军,等. 配电网中考虑不确定性的分布式电源规划研究综述[J]. 电力自动化设备,2016,36(8):1-9.  
ZHANG Shenxi,CHENG Haozhong,XING Haijun, et al. Review of DG planning considering uncertainties for distribution network[J]. Electric Power Automation Equipment,2016,36(8):1-9.
- [3] 范博文. 基于场景分析的含分布式电源的配电网无功优化[D]. 济南:山东大学,2016.  
FAN Bowen. Reactive power optimization of distribution network with distributed generation based on scenario analysis[D]. Jinan: Shandong University,2016.
- [4] DEB K,ZHU L,KULKARNI S. Multi-scenario, multi-objective optimization using evolutionary algorithms: Initial results[C]// Evolutionary Computation Conference. Antalya, Turkey:IEEE,2015:187-194.
- [5] AGHAEI J,NIKNAM T,ABARGHOEE R A, et al. Scenario-based dynamic economic emission dispatch considering load and wind power uncertainties[J]. Electrical Power and Energy Systems,2013(47):351-367.
- [6] ZHANG X,XU Z. Hesitant fuzzy agglomerative hierarchical clustering algorithms[J]. International Journal of Systems Science,2015,46(3):562-576.
- [7] YU J,GUO J. An improved agglomerative levels K-means clustering algorithm[C]// International Conference on Management of E-Commerce and E-Government. Shanghai, China:IEEE,2014:221-224.
- [8] 赵长龙. 微网运行经济型及 HOMER 软件应用研究[D]. 成都:西南交通大学,2015.  
ZHAO Changlong. Research on economic operation of microgrid and its application using HOMER software[D]. Chengdu: Southwest Jiaotong University,2015.
- [9] LU Zhigang,SUI Y S,HE Shoulong, et al. Economic unit ramp dispatching for power grid integrated with wind power based on scenario analysis[J]. Advanced Technology of Electrical Engineering & Energy,2016,35(2):38-43.
- [10] CHIRADEJA P, RAMAKUMAR R. An approach to quantify the technical benefits of distributed generation[J]. IEEE Transactions on Energy Conversion,2004,19(4):764-773.
- [11] ZHONG Z,YANG C,CAO W, et al. Short-term photovoltaic power generation forecasting based on multivariable grey theory model with parameter optimization[J]. Mathematical Problems in Engineering,2017(7):1-9.
- [12] 曾鸣,杨雍琦,向红伟,等. 兼容需求侧资源的“源-网-荷-储”协调优化调度模型[J]. 电力自动化设备,2016,36(2):102-111.  
ZENG Ming,YANG Yongqi,XIANG Hongwei, et al. Optimal dispatch model based on coordination between “generation-grid-load-energy storage” and demand-side resource[J]. Electric Power Automation Equipment,2016,36(2):102-111.
- [13] 范松丽,艾芊,贺兴. 基于机会约束规划的虚拟电厂调度风险分析[J]. 中国电机工程学报,2015,35(16):4025-4034.

- FAN Songli, AI Qian, HE Xing. Risk analysis on dispatch of virtual power plant based on chance constrained programming [J]. Proceedings of the CSEE, 2015, 35(16):4025-4034.
- [14] 张翔,程浩忠,方陈. 考虑主动管理模式的多目标分布式电源规划[J]. 上海交通大学学报, 2014, 48(9):1231-1238.  
ZHANG Xiang, CHENG Haozhong, FANG Chen. Multi-objective distributed generation planning considering active management [J]. Journal of Shang Hai Jiaotong University, 2014, 48(9):1231-1238.
- [15] 彭春华,于蓉,孙惠娟. 基于 K-均值聚类多场景时序特性分析的分布式电源多目标规划[J]. 电力自动化设备, 2015, 35(10):58-65.  
PENG Chunhua, YU Rong, SUN Huijuan. Multi-objective programming of distributed power supply based on time series characteristic analysis of K-means clustering [J]. Electric Power Automation Equipment, 2015, 35(10):58-65.
- [16] BARAN M E, WU F E. Network reconfiguration in distribution systems for loss reduction and load balancing [J]. IEEE Transactions on Power Delivery, 1989, 4(2):1401-1407.
- [17] 王之阳. 考虑分布式电源接入的配电网规划研究 [D]. 济南:山东大学, 2016.  
WANG Zhiyang. Distribution network planning considering DGs [D]. Jinan: Shandong University, 2016.
- [18] PENG C, SUN H, GUO J, et al. Multi-objective optimal strategy for generating and bidding in the power market [J]. Energy Conversion and Management, 2012, 57(1):13-22.
- [19] DEB K, PRATAP A, AGARWAL S. A fast and elitist multi-objective genetic algorithm: NSGA-II [J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2):182-197.
- [20] ZITZLER E, DEB K, THIELE L. Comparison of multiobjective evolutionary algorithms: empirical results [J]. Evolutionary Computation, 2000, 8(2):173-195.

#### 作者简介:



孙惠娟

孙惠娟(1982—),女,江西南昌人,副教授,硕士,主要研究方向为配电网规划与优化运行(**E-mail**: hjsun@ecjtu.edu.cn);

刘君(1993—),女,江西南昌人,硕士研究生,研究方向为主动配电网规划;

彭春华(1973—),男,江西乐平人,教授,博士研究生导师,博士,主要研究方向为电力系统规划和优化调度(**E-mail**: chinapch@163.com)。

## Multi-objective DG planning based on classified probability integration multi-scenario analysis

SUN Huijuan<sup>1</sup>, LIU Jun<sup>2</sup>, PENG Chunhua<sup>1</sup>

(1. School of Electrical & Automation Engineering, East China Jiaotong University, Nanchang 330013, China;

2. Jiangxi Electromechanical Equipment Tendering Co., Ltd., Nanchang 330046, China)

**Abstract:** In order to consider the uncertainties of DG (Distributed Generation) output and load demand more accurately and reasonably in DG planning of distribution network, based on the difference of random distribution characteristics among wind power, photovoltaic and load, the classified probability integration multi-scenario analysis method is proposed to realize multi-scenario creation more reasonably, and the H-K compound clustering compression method is constructed with the combination of K-Means clustering method and HAC (Hierarchical Aggregation Clustering) algorithm to achieve more efficient scene compression. A multi-scenario and multi-objective DG planning model is built with the objective of maximum average annual profit rate and voltage distribution improvement rate, which is solved by the INSCDE (Improved Non-dominated Sorting Compound Differential Evolution) algorithm based on HAC algorithm population truncation strategy. The IEEE 33-bus distribution system is taken as an example for multi-objective DG planning, and the simulative results verify the effectiveness and superiority of the proposed method.

**Key words:** DG planning; multi-scenario analysis; classified probability; H-K compound clustering