

DOI: 10.7667/PSPC161237

基于最优场景生成算法的主动配电网无功优化

吴丽珍^{1,2}, 蒋力波¹, 郝晓弘¹

(1. 兰州理工大学电气工程与信息工程学院, 甘肃 兰州 730050;
2. 北京交通大学国家能源主动配电网技术研发中心, 北京 100044)

摘要: 针对间歇性分布式电源输出功率的不确定性和随机性, 提出采用 Wasserstein 距离指标和 K-means 聚类场景削减技术生成最优场景, 将随机优化问题转换为确定性优化问题。建立了风—光—荷多场景树模型, 并以有功网损最小、电压偏差最小作为目标函数, 考虑储能荷电状态约束影响, 建立含间歇性分布式电源的主动配电网无功优化数学模型, 并采用人工蜂群算法对模型进行求解。仿真分析得出基于 Wasserstein 距离指标和 K-means 聚类场景削减技术生成的最优场景能较精确地体现分布式电源有功出力的随机特性。最后, 以 IEEE-33 节点配电系统为例进行仿真分析, 验证了所提方法的有效性和可行性。

关键词: 主动配电网; 场景分析; Wasserstein 距离; K-means 聚类; 人工蜂群算法

Reactive power optimization of active distribution network based on optimal scenario generation algorithm

WU Lizhen^{1,2}, JIANG Libo¹, HAO Xiaohong¹

(1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;
2. National Active Distribution Network Technology Research Center, Beijing Jiaotong University, Beijing 100044, China)

Abstract: Considering the uncertainty and stochasticity of intermittent distributed generations (DGs), a scenario method using Wasserstein distance metric and K-means cluster scenes reduction technique to generate optimal scene is proposed in this paper. So the stochastic optimization problem is transformed into a deterministic optimization problem. The multi-scenario tree models of wind-photovoltaic-load are established. A multi-objective reactive power optimization mathematical model of active distribution network containing intermittent DGS is built, which includes objectives that are the total active power losses and the voltage deviations of the bus, and considering energy storage states of charge characteristic constraints. Also, the artificial bee colony algorithm is used to solve the optimization problems. Simulation results show that the optimal scenes based on the Wasserstein distance indicators and K-means cluster technology reflect the random feature of distributed generation active power output more accurately. Finally, the simulation analysis of IEEE-33 bus distribution test system is carried out to verify the effectiveness and feasibility of the proposed method.

This work is supported by National Natural Science Foundation of China (No. 51467009).

Key words: active distribution network; scenario analysis; Wasserstein distance; K-means cluster; artificial bee colony algorithm (ABC)

0 引言

主动配电网(Active Distribution Networks, ADN)是目前智能配电网的一种发展模式, 能利用先进的自动化、通信和电力电子等新技术实现对接入配

网的分布式电源和其他设备进行主动管理^[1]。但是, 间歇性分布式电源(如风电和光伏)和具有与配电网管理系统互动的主动需求负荷并入 ADN 后, 由于其输出功率的间歇性或随机性, 将会影响到 ADN 管理系统的无功电压协调控制、潮流优化和故障时的网络重构等, 导致配电网的电能质量变差以及继电保护失效等问题^[2]。通过无功优化可以改善配电网节点电压和潮流分布, 提高负荷端的电压质量,

基金项目: 国家自然科学基金项目(51467009); 兰州市科技计划项目(2016-3-67)

减少网络损耗。

传统的无功优化模型没有考虑输出功率的随机性, 不完全适用于含分布式电源的 ADN 中。文献[3]采用风光预测输出功率, 处理配电网的潮流计算, 其优化结果严重依赖于历史数据, 且误差较大。文献[4]采用场景法模拟风电机组出力的随机性, 研究风电机组接入配电系统的无功优化; 但所提方法场景划分较少, 不能较为准确地描述原分布的随机性。文献[5]提出将分布式电源出力和负荷的随机波动同时考虑, 建立配电网无功优化模型, 并结合传统解析法的基于全概率公式的计算方法处理模型所涉及的随机潮流问题; 该方法较好地处理了无功优化模型中的不确定性问题, 对含有分布式电源的 ADN 无功优化具有一定的参考意义。以上文献仅考虑了分布式电源对无功优化的影响, 而未考虑储能对无功优化的影响。

对连续非线性随机问题的求解, 通常是离散化, 即采用离散概率分布表示连续分布随机变量并求解。获取离散概率的方法通常有拉丁超立方^[6]和蒙特卡洛^[7]等抽样方法, 通过大量抽样再经聚类得到少量场景数和对应场景概率, 场景的质量严重依赖于场景的抽样数目, 且计算量大, 周期长。文献[8]通过 Wasserstein 距离指标得到的最优场景与原场景分布较为贴近, 波动趋势也近似一致, 但抽样数目较多, 不易于计算。文献[9]采用同步回代缩减技术形成经典场景, 在大规模场景下用此方法效率较低; 用 K-means 聚类法对场景进行缩减, 该方法简单易行, 速度快, 效率高, 且能保证缩减后场景的多样性。因此, 本文采用 Wasserstein 距离指标和 K-means 聚类场景缩减法。

本文建立了考虑风力发电和光伏发电随机性的场景模型, 以有功网损最小和电压偏差最小作为目标函数, 同时考虑储能特性的影响; 采用 Wasserstein 距离指标和 K-means 聚类场景缩减法, 形成最优场景, 并采用人工蜂群算法(Artificial Bee Colony algorithm, ABC)对模型进行求解。

1 Wasserstein 距离指标

获得经典场景是为了得到趋近于分布式电源的真实功率, 以实现 ADN 的无功优化。

Wasserstein 概率距离^[10]是对两个概率分布距离的一个测度, 记为 $d_{w,r}$ 。

$$d_{w,r}(p_1, p_2) = \int d(x_1, x_2)^r d\pi(x_1, x_2) \quad (1)$$

式中: p_1 和 p_2 为概率密度函数; $\pi(x_1, x_2)$ 为联合概

率密度函数; r 为阶数。因此, 离散概率分布对连续分布近似问题可以转化为 $d_{w,r}$ 最小。

根据场景模拟的思想, 若离散点集合 Φ 的一个概率测度 $\tilde{P} = \sum_{s=1}^S p_s \delta_{z_s}$, 其中 δ_{z_s} 为 z_s ($s=1, 2, \dots, S$) 上的点质量。若要获得最优场景, 则需要求解概率测度函数 \tilde{P} 的最优分位点 z_s 以及 z_s 对应的概率, 使得 Wasserstein 距离 $d_r(p, \tilde{p})$ 最小。

假设一维连续变量 x 的概率密度函数为 $f(x)$, 以 S 个离散分位点的离散分布近似 $f(x)$, 则 Wasserstein 距离指标下的最优分位点 z_s 可由式(2)得到。

$$\int_{-\infty}^{z_s} f^{1/(1+r)}(x) dx = \frac{2s-1}{2S} \int_{-\infty}^{\infty} f^{1/(1+r)}(x) dx \quad (2)$$

对应分位点 z_s 的概率 p_s 按式(3)计算。

$$\begin{cases} p_s = \int_{\frac{z_{s-1}+z_s}{2}}^{\frac{z_s+z_{s+1}}{2}} f(x) dx, s=2, \dots, S-1 \\ p_0 = \int_{z_0}^{\frac{z_0+z_1}{2}} f(x) dx \\ p_S = \int_{\frac{z_{S-1}+z_S}{2}}^{z_{S+1}} f(x) dx \end{cases} \quad (3)$$

式中: $z_0 = -\infty$; $z_S = +\infty$ 。

2 基于 Wasserstein 距离的多场景模型

2.1 风电功率的最优分位点

通常风电功率在区间 $(0, P_n)$ 的概率密度函数描述为^[11]

$$f_w = \frac{khv_{in}}{P_n c} \left[\frac{(1+(hP)/P_n)v_{in}}{c} \right]^{k-1} \exp \left\{ - \left[\frac{(1+(hP)/P_n)v_{in}}{c} \right]^k \right\} \quad (4)$$

此外:

$$p(P=0) = p(v < v_{in}) + p(v \geq v_o) = 1 - \exp[-(v_{in}/c)^k] + \exp[-(v_o/c)^k] \quad (5)$$

$$p(P=P_n) = p(v_r \leq v < v_o) = \exp[-(v_r/c)^k] - \exp[-(v_o/c)^k] \quad (6)$$

式中: P 为风力发电的输出功率; v_{in} 、 v_r 和 v_o 分别为切入风速、额定风速和切出风速; $h = (v_r/v_{in}) - 1$; P_n 为风电机组的额定功率; $c > 0$ 、 $k > 0$ 分别为概率分布的尺度参数和形状系数。

将概率密度函数式(4)代入式(2), 且不完全伽马函数为 $\Gamma(x, m)\Gamma(m) = \int_0^m x^{m-1} e^{-x} dx$, 则可得到离散分位点公式, 如式(7)。

$$c_3 \Gamma(t) [\Gamma(c_1 + c_2 z_s, t) - \Gamma(c_1, t)] = \frac{2s-1}{2S} c_3 \Gamma(t) [\Gamma(c_1 + c_2, t) - \Gamma(c_1, t)] \quad (7)$$

式中: $t = (k+r)/[(1+r)k]$ 且一般取 $r=2$, $c_1 = v_{in}/c$, $c_2 = (v_{in}/c)/(h/p_n)$, $c_3 = (kc_2)^{-r/(1+r)}(1+r)^t$ 。

2.2 光伏功率的最优分位点

光伏发电输出功率 P_V 的连续概率密度函数为

$$f(P_V) = \frac{1}{P_{V,\max} B(\alpha, \beta)} \left(\frac{P_V}{P_{V,\max}}\right)^{\alpha-1} \left(1 - \frac{P_V}{P_{V,\max}}\right)^{\beta-1} \quad (8)$$

式中: $P_{V,\max}$ 为最大光伏功率; $B(\alpha, \beta)$ 为 Beta 函数; α 、 β 为 Beta 分布的形状参数。

将式(8)代入式(2)得到光伏发电功率的离散分位点, 即

$$\int_0^z t^{\mu-1} (1-t)^{\theta-1} dt = \frac{2s-1}{2S} \int_0^1 t^{\mu-1} (1-t)^{\theta-1} dt \quad (9)$$

式中: $t = \frac{P_V}{P_{V,\max}} \in (0, 1)$; $\mu = \frac{\alpha+r}{1+r} > 0$; $\theta = \frac{\beta+r}{1+r} > 0$ 。

2.3 负荷模型

把负荷预测结果作为一个随机变量来处理, 采用类似于模拟风电场的处理方式, 用离散分布表示连续随机变量分布。根据 IEEE-RTS 系统每小时的负荷曲线和聚类分析将负荷划分为 n_d 个不同的运行状态, 对应的概率为 p_d^a 。

2.4 风—光—荷多场景模拟

风电、光伏和负荷的所有场景集合 δ_{SC} 可表示为^[12]

$$\begin{cases} \delta_{SC} = \delta_D \delta_W \delta_{PV} \\ \sum_{s \in \delta_{SC}} p_d p_w p_{pv} = 1 \end{cases} \quad (10)$$

式中: δ_D 、 δ_W 和 δ_{PV} 分别为负荷、风电和光伏离散概率的分布集合; p_d 、 p_w 和 p_{pv} 分别为负荷、风电和光伏在不确定情况下的概率。系统在场景 s 下的概率为

$$p_s = p_d p_w p_{pv} \quad (11)$$

3 基于场景概率的多目标无功优化模型

3.1 目标函数

以有功网损最小和负荷节点电压偏差最小作为目标函数, 建立考虑间歇性分布式电源的 ADN 无功优化模型。

(1) 有功网损最小

$$\min P_{\text{loss}} = \min \sum_{s=1}^{n_s} p_s \sum_{i,j \in N_l} G_{ij} (U_{js}^2 + U_{is}^2 - 2U_{is} U_{js} \cos \theta_{ijs}) \quad (12)$$

式中: 下标中含“ s ”的变量均表示场景 s 下的值; P_{loss} 为系统有功网损; G_{ij} 、 θ_{ijs} 分别为节点 i 、 j 之间的电导和电压相位差; U_{is} 、 U_{js} 分别为节点 i 、 j 的电压幅值; N_l 为网络输电线路集合; n_s 为场景数。

(2) 电压偏差最小

$$\min \Delta U = \min \sum_{s=1}^{n_s} p_s \sum_{i=1}^{N_L} \left| \frac{U_{is} - U_{is}^*}{U_{i\max} - U_{i\min}} \right| \quad (13)$$

式中: U_{is}^* 为节点 i 的额定电压; $U_{i\max}$ 、 $U_{i\min}$ 为节点 i 的最大、最小允许电压; N_L 为系统负荷总节点数。

3.2 优化约束条件

各个节点功率的等式约束为

$$\begin{cases} P_{PVis} + P_{batis} + P_{Wis} - P_{Lis} = U_{is} \sum_{j=1}^n U_{js} (G_{ij} \cos \theta_{ijs} + B_{ij} \sin \theta_{ijs}) \\ Q_{PVis} + Q_{batis} + Q_{Wis} - Q_{Lis} = U_{is} \sum_{j=1}^n U_{js} (G_{ij} \sin \theta_{ijs} - B_{ij} \cos \theta_{ijs}) \end{cases} \quad (14)$$

式中: P_{is} 、 Q_{is} 为节点注入的有功功率和无功功率; B_{ij} 为节点 i 、 j 之间的电纳; n 为主动配电网的节点数。

主动配电网无功电容器、线路变压器分接头和节点电压约束为

$$\begin{cases} Q_{C,\min} \leq Q_{Cis} \leq Q_{C,\max} \\ T_{i\min} \leq T_{is} \leq T_{i\max} \\ U_{i\min} \leq U_{is} \leq U_{i\max} \end{cases} \quad (15)$$

式中: $Q_{C,\max}$ 、 $Q_{C,\min}$ 分别为无功电容器投切容量上、下限; $T_{i\max}$ 、 $T_{i\min}$ 分别为线路变压器分接头变比上、下限; $U_{i\max}$ 、 $U_{i\min}$ 分别为节点电压上、下限。

磷酸铁锂储能电池充放电过程中荷电状态 (States of Charge, SOC) 的约束为

$$\begin{cases} SOC_{\min} \leq SOC_s(t) \leq SOC_{\max}, \forall t \\ P_{\max C}(t) = \min \left\{ P_{\max C}, \frac{E_{\text{bat}} [SOC_{\max} - SOC_s(t-1)]}{\Delta t \eta_c} \right\} \\ P_{\max D}(t) = \min \left\{ P_{\max D}, \frac{\eta_d E_{\text{bat}} [SOC_s(t-1) - SOC_{\min}]}{\Delta t} \right\} \end{cases} \quad (16)$$

式中: SOC_{\max} 、 SOC_{\min} 分别为电池 SOC 的上、下限; $P_{\max C}$ 、 $P_{\max D}$ 分别为储能电池额定的最大充、放电功率; η_c 和 η_d 分别为电池充、放电效率; E_{bat} 为电池的额定容量。电池的 SOC 运行范围设置为 0.2~0.95。

3.3 K-means 聚类场景削减

用 $\eta_s (s=1, \dots, N_s)$ 表示缩减前的 N_s 个不同场景, 假设目标场景树为 M_s , 场景削减步骤^[13-14]如下。

(1) 随机选取 M_s 个场景作为簇心, 簇心场景集合为 $C = \{\eta_s^c\} (s=1, \dots, M_s)$ 。

(2) 根据簇心集合, 可确定剩余场景集合为 $G = \{\eta_{s'}^G\} (s'=1, \dots, N_s - M_s)$ 。分别计算剩余场景到簇心场景的场景距离: $D_{s,s'} = \|\eta_s^c - \eta_{s'}^G\|_2$ 。

(3) 根据距离矩阵 $D_{s,s'}$, 将剩余场景归类到距离最近的簇心。此次聚类后的聚类集合为 $\Omega = \{C_i\}, (i=1, \dots, M_s)$, 其中 C_i 表示同类场景集合。

(4) 簇心计算方法。假设某聚类 C_i 中有 L_s 个场景, 计算每个场景与其他场景距离之和: $CT_s = \sum_{s'=1, s' \neq s}^{L_s} \|\eta_s - \eta_{s'}\|_2, s=1, 2, \dots, L_s$ 。选取 $CT_k = \min(CT_s)$ 的场景 η_k 为新的聚类中心。按上述方法重新确定簇心集合。

(5) 重复步骤(2)一步骤(4), 直到簇心和聚类结果不再变化, 场景缩减结束。每个场景的概率值即为该类中所有场景概率之和。

4 基于人工蜂群算法的多目标求解

利用 ABC 算法^[15]求解多目标无功优化的计算流程如图 1 所示, 具体步骤如下。

(1) 输入参数。输入 ADN 原始参数的控制变量, 设定 ABC 算法参数, 算法参数为: 最大迭代次数为 100, 蜜蜂总数 $N=30$, 陷入最优的迭代次数 $N_{limit}=15$ 。

(2) 场景产生。Wasserstein 距离产生最优分位点, 利用 K-means 聚类缩减法将场景缩减到给定值。

(3) 初始化蜂群, 通过式(12)、式(13)计算所有场景的目标函数值, 按式(17)随机生成满足约束条件的 N 个解。

$$x_{ij} = x_j^{\min} + r_{\text{and}}(0, 1) \cdot (x_j^{\max} - x_j^{\min}) \quad (17)$$

式中: $i=1, 2, \dots, N$ 是一个 d 维向量; $j=1, 2, \dots, d$; r_{and} 表示 0 和 1 之间的随机数。

(4) 按式(18)评价食物源的适应度, 通过式(19)更新食物源的全局最优位置。

$$p_i = \frac{F_i}{\sum_{j=1}^N F_j} \quad (18)$$

$$\begin{cases} v = r \cdot (x_{ij} - x_{\text{neighbour}, j}) \\ x_{ij}^{\text{new}} = x_{ij} + v \end{cases} \quad (19)$$

式中: F_i 为第 i 个解对应的适应度函数值; $\text{neighbour} \in \{1, 2, \dots, N\}$ 且 $\text{neighbour} \neq i$; v 为食物源探索方向及步长; r 为 $[-1, 1]$ 上的随机数。

(5) 输出结果。如果迭代次数满足设定值, 则输出 Parote 最优前沿, 否则返回步骤(3)进入下一次迭代。

(6) 最优解选取。当目标解集生成以后, 决策者需从中选取一个最优食物源作为最终结果。

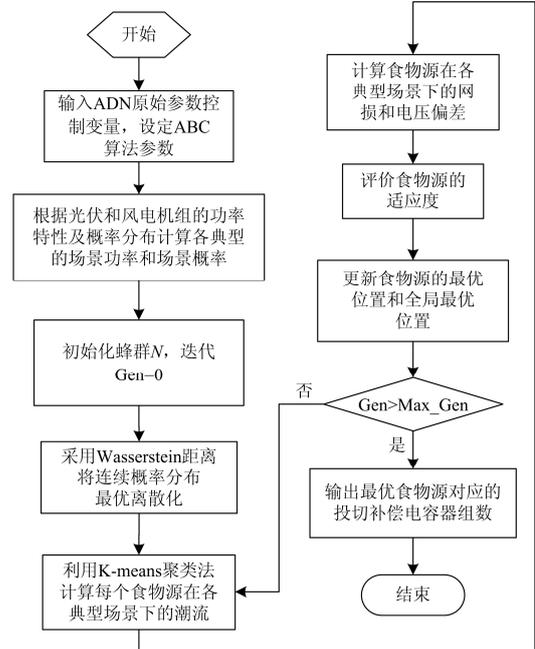


图 1 基于 ABC 算法计算流程

Fig. 1 Flow chart based on ABC algorithm

5 算例分析

本文采用 IEEE-33 节点测试系统进行仿真, 网络图及参数可参见文献[16]。在节点 2、14 和 31 配置可投切无功补偿电容器装置, 2、14 和 31 节点单组电容器容量为 50 kvar, 2 和 14 节点最多可投切电容器 10 组, 31 节点最多可投切电容器 20 组。光伏额定功率为 194.6 kW, 风机额定功率为 200 kW, 储能额定容量为 285 kWh, 充放电效率均为 0.9。风机模型和光伏模型参数如表 1 和表 2 所示。

表 1 风电机组参数

Table 1 Wind parameters

c	$v_{in}/(m/s)$	$v_r/(m/s)$	$v_o/(m/s)$	k
15	5	15	45	2

表 2 光伏电池参数

Table 2 Photovoltaic parameters

最大功率电压/V	最大功率电流/A	η	α	β
26.3	7.61	14%	2.35	3.5

5.1 Wasserstein 距离和 K-means 聚类场景生成法性能分析

用 Wasserstein 距离得到风电场 10 个最优离散

场景, 并与 Kolmogorov 距离和等距离法进行比较, 验证其性能, 场景模拟对比图如图 2 所示。

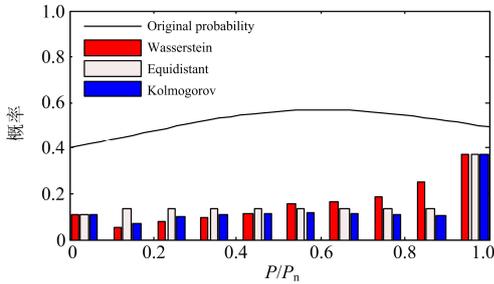


图 2 场景模拟对比图

Fig. 2 Comparison diagram of scene simulation

从图 2 可以看出, 原功率分布在 $[0.2, 0.5]$ 的概率较小, 而在 $[0.6, 0.8]$ 的概率较大。因此, 采用 Wasserstein 距离比 Kolmogorov 距离和等距离法更贴近原功率分布, 其在概率测度空间上与原概率分布距离更小。因此, 只有精确地模拟风电、光伏的出力 and 准确预测其可能发生的场景, 才能控制光伏和风电功率变化, 实现大规模分布式电源并网安全稳定运行。

图 3 为规模 3000 的风电场景集削减到 300 时的收敛情况, 从图中可以看出 K-means 聚类算法收敛速度快且效率高。

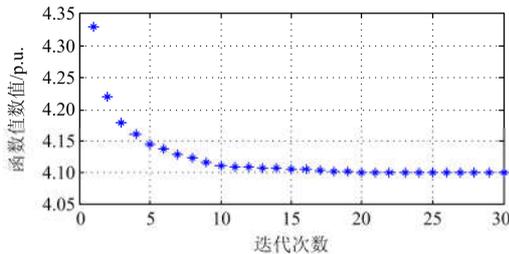


图 3 K-means 聚类算法迭代收敛情况

Fig. 3 K-means cluster algorithm convergence

表 3 为 K-means 聚类法和启发式同步回代削减法的时间对比, 其原始场景为 3000 个。由表 3 可知, 削减后规模增大时, 并行程度提高, 导致平均计算量减小, 计算时间降低, 但 K-means 聚类法的运算耗时和迭代次数都低于启发式同步回代削减法。这个特点可使 K-means 算法用于大规模随机优化问题。

为说明随机场景生成的有效性, 用 Wasserstein 距离和 K-means 聚类削减法得到风电和光伏各 10 个场景的出力曲线, 与典型日出力曲线对比关系见图 4。从图中可以看出, 本文所提出的场景生成算法能很好地模拟风电和光伏出力的波动性, 能较全面地反映在一定区间范围内的随机特性。

表 3 K-means 聚类 and 启发式同步回代削减时间对比

Table 3 Elapsed time comparisons between K-means cluster and simultaneous backward reduction

削减后规模	K-means 聚类法		启发式同步回代削减法	
	迭代次数	用时/s	迭代次数	用时/s
10	76	7.35	158	126.8
50	54	5.23	123	94.2
100	48	2.39	97	75.6
200	32	1.17	62	52.8
500	15	0.56	45	35.3

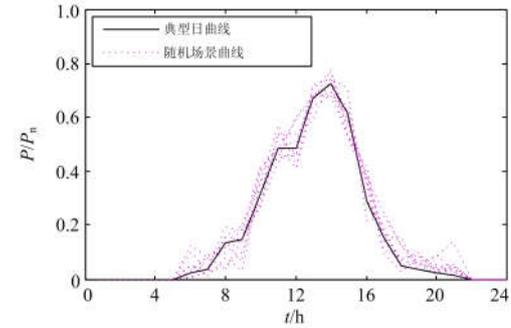
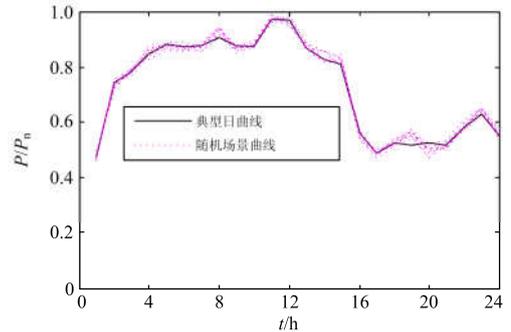


图 4 风电和光伏出力场景

Fig. 4 Scenario of wind and PV power output

5.2 分析计算

采用本文所提出的最优场景生成算法, 以风电、光伏和负荷各 10 个场景为例进行计算, 保证了无功优化的计算速度和精确性。

图 5 给出了考虑多场景和不考虑多场景两种模式的 Parote 前沿。从图中可以看出, 在相同情况下,

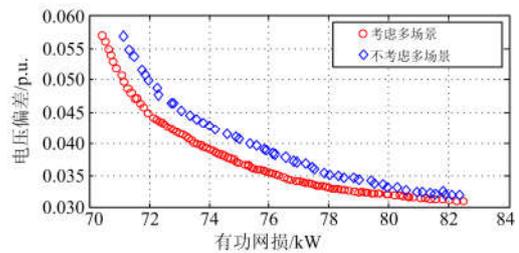


图 5 两种模式下的 Parote 前沿

Fig. 5 Parote solution set for two modes

考虑多场景的 Parote 前沿相比不考虑多场景的 Parote 前沿分布更加均匀,对 ADN 电能质量的提高具有一定的促进作用。表 4 是考虑多场景后各个场景的目标函数值及概率。

表 4 不同场景下的函数值及概率

Table 4 Function value and probability under different scenarios

场景	网损/kW	电压偏差/p.u.	概率
1	76.352	0.0459	0.0044
2	74.221	0.0421	0.0427
3	72.827	0.0416	0.1479
4	72.603	0.0422	0.0090
5	72.443	0.0418	0.2462
6	73.962	0.0415	0.0981
7	73.661	0.0413	0.0855
8	72.894	0.0423	0.2238
9	72.987	0.0419	0.1415
10	79.071	0.0416	0.0009

表 5 和表 6 列出了在多场景下考虑储能和未考虑储能的优化结果,并将 ABC 计算结果与常用算法 GA 和 PSO 的优化结果进行比较分析。图 6 是无功优化的迭代收敛曲线。

表 5 未考虑储能约束的优化结果对比

Table 5 Comparison of the optimization values without considering the energy storage constraints

算法	有功网损/kW	网损减小率/%	电压偏差/p.u.	电压偏差减小率/%
GA	83.112	39.51	0.0479	42.39
PSO	78.847	42.08	0.0494	41.18
ABC	74.164	43.79	0.0438	46.58

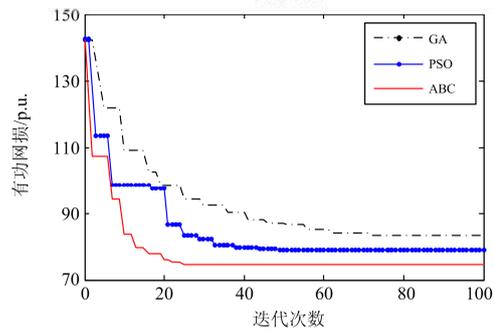
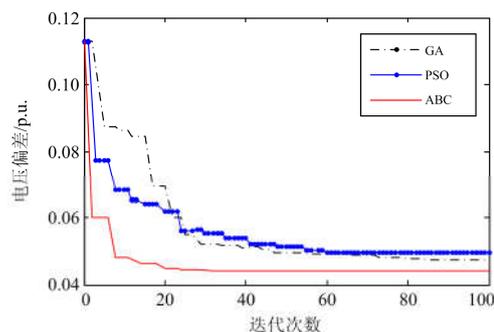
从表 5 可见,未考虑储能约束时通过 ABC 算法优化,有功网损为 74.164 kW,电压偏差为 0.0438 p.u.,网损减小率为 43.79%,电压偏差减小率为 46.58%,此时分别在节点 2、14 和 31 投入 6 组、12 组和 18 组电容器;而从表 6 可见,在考虑储能约束后,有功网损降低至 72.832 kW,电压偏差降低至 0.0416 p.u.,网损减小率升高为 47.23%,电压偏差减小率升高为 50.42%,此时在相同的节点上投切的电容器分别为 3 组、8 组和 11 组。由以上分析可知,考虑储能以后,能有效地减小有功网损、电压偏差和电容器投切量,使得电能质量得到了很大的改善。

由图 6 和以上分析可知,本文所采用的 ABC 算法相比 GA 和 PSO 算法迭代次数更少、收敛速度更快、误差更小且优化结果较准确。可见 ABC 算法能够显著减小 ADN 的有功网损和电压偏差。

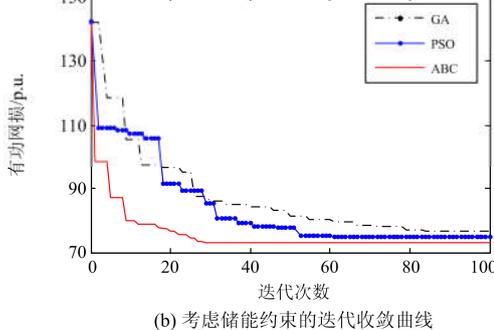
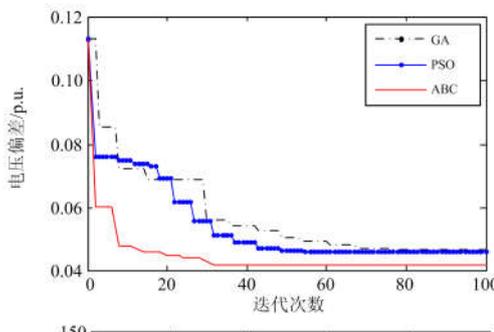
表 6 考虑储能约束的优化结果对比

Table 6 Comparison of optimization values for energy storage constraints

算法	有功网损/kW	网损减小率/%	电压偏差/p.u.	电压偏差减小率/%
GA	76.273	43.62	0.0465	45.06
PSO	74.740	44.56	0.0459	46.18
ABC	72.823	47.23	0.0416	50.42



(a) 未考虑储能的迭代收敛曲线



(b) 考虑储能约束的迭代收敛曲线

图 6 迭代收敛曲线

Fig. 6 Iterative convergence curve

图7为IEEE-33节点测试系统的电压分布情况。可见,考虑储能约束与否,优化后都提高了配电网的节点电压,但考虑储能约束以后,各节点电压均提高至0.97 p.u.以上,再通过电容器的无功补偿,可大幅度提高配电网的电压质量。

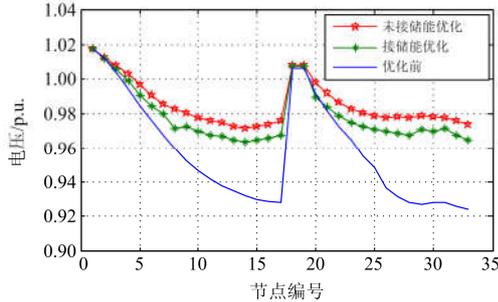


图7 33节点测试系统的电压分布情况

Fig. 7 Voltage distribution of 33-bus test system

6 结论

本文提出一种最优场景生成方法。该方法首先利用 Wasserstein 距离指标将风电、光伏以最优分位点离散化,然后运用 K-means 聚类算法对场景缩减,形成最优场景,有效地提高了随机优化问题转化为确定性优化问题的计算效率和处理问题的规模上限,而且也解决了光伏、风机和负荷功率的波动性。同时,在多场景模式下,算例考虑了储能电池充放电过程中 SOC 约束对 ADN 有功网损和电压偏差的影响。通过 IEEE-33 节点系统的测试,显示出储能能在无功优化中能有效地提高配电网的电压水平并减少网络损耗,以满足用户对电能质量越来越高的要求。

参考文献

- [1] 范士雄, 蒲天骄, 刘广一, 等. 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(2): 92-101.
FAN Shixiong, PU Tianjiao, LIU Guangyi, et al. Technologies and its trends of grid integration of distributed generation in active distribution network[J]. Transactions of China Electrotechnical Society, 2016, 31(2): 92-101.
- [2] 张翔, 程浩忠, 方陈, 等. 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, et al. Multi-objective distributed generation planning considering active management[J]. Journal of Shanghai Jiao Tong University, 2014, 48(9): 1231-1238.
- [3] ZHANG S, TSENG K J, VILATHGAMUWA D M, et al. Design of a robust grid interface system for PMSG-based wind turbine generators[J]. IEEE Transactions on Industrial Electronics, 2011, 58(1): 316-328.
- [4] 陈继明, 祁丽志, 孙名好, 等. 多场景下含风电机组的配电网无功优化的研究[J]. 电力系统保护与控制, 2016, 44(9): 129-134.
CHEN Jiming, QI Lizhi, SUN Mingyu, et al. Reactive power optimization for distribution network with multi-scenario wind power generator[J]. Power System Protection and Control, 2016, 44(9): 129-134.
- [5] 王淳, 高元海. 基于概率统计的含间歇性分布式发电的配电网无功优化[J]. 电网技术, 2014, 38(4): 1032-1037.
WANG Chun, GAO Yuanhai. Probability statistics based reactive power optimization of distribution network containing intermittent distributed generations[J]. Power System Technology, 2014, 38(4): 1032-1037.
- [6] 蒋程, 王硕, 王宝庆, 等. 基于拉丁超立方采样的含风电电力系统的概率可靠性评估[J]. 电工技术学报, 2016, 31(10): 193-206.
JIANG Cheng, WANG Shuo, WANG Baoqing, et al. Probabilistic reliability assessment of power system containing wind power based on Latin Hypercube sampling[J]. Transactions of China Electrotechnical Society, 2016, 31(10): 193-206.
- [7] 何建, 陈光宇, 陶志东, 等. 计及电压稳定指标的含DG配电网无功优化[J]. 陕西电力, 2015, 43(9): 30-35.
HE Jian, CHEN Guangyu, TAO Zhidong, et al. Reactive power optimization in distribution system with system with distributed generators considering voltage stability index[J]. Shaanxi Electric Power, 2015, 43(9): 30-35.
- [8] 黎静华, 韦化, 莫东. 含风电场最优潮流的 Wait-and-See 模型与最优渐近场景分析[J]. 中国电机工程学报, 2012, 32(22): 15-24.
LI Jinghua, WEI Hua, MO Dong. Asymptotically optimal scenario analysis and wait-and-see model for optimal power flow with wind power[J]. Proceedings of the CSEE, 2012, 32(22): 15-24.
- [9] 邹云阳, 杨莉. 基于经典场景集的风光水虚拟电厂协同调度模型[J]. 电网技术, 2015, 39(7): 1855-1859.
ZOU Yunyang, YANG Li. Synergetic dispatch models of a wind/PV/hydro virtual power plant based on representative scenario set[J]. Power System Technology, 2015, 39(7): 1855-1859.
- [10] JACOD J, PROTTER P. Probability essentials[M]. 北京: 清华大学出版社, 2010.
- [11] 胡传胜, 周玲, 程蒙, 等. 含电动汽车和分布式电源的电网动态态重构[J]. 陕西电力, 2015, 43(4): 1-4, 14.

- HU Chuansheng, ZHOU Ling, CHENG Meng, et al. Dynamic optimization of distributed network reconfiguration considering electric vehicle and distributed generation[J]. Shaanxi Electric Power, 2015, 43(4): 1-4, 14.
- [12] 张晓花, 谢俊, 赵晋泉, 等. 考虑风电和电动汽车等不确定性负荷的电力系统节能减排调度[J]. 高电压技术, 2015, 41(7): 2408-2414.
- ZHANG Xiaohua, XIE Jun, ZHAO Jinqun, et al. Energy-saving emission-reduction dispatching of electrical power system considering uncertainty of load with wind power and plug-in hybrid electric vehicles[J]. High Voltage Engineering, 2015, 41(7): 2408-2414.
- [13] 孟建良, 刘德超. 一种基于 Spark 和聚类分析的辨识电力系统不良数据新方法[J]. 电力系统保护与控制, 2016, 44(3): 85-91.
- MENG Jianliang, LIU Dechao. A new method for identifying bad data of power system based on Spark and clustering analysis[J]. Power System Protection and Control, 2016, 44(3): 85-91.
- [14] 徐毅非, 蒋文波, 程雪丽. 基于谱聚类的无功电压分区和主导节点选择[J]. 电力系统保护与控制, 2016, 44(15): 73-78.
- XU Yifei, JIANG Wenbo, CHENG Xueli. Partitioning for reactive voltage based on spectral clustering and pilot nodes selection[J]. Power System Protection and Control, 2016, 44(15): 73-78.
- [15] MARZBAND M, FZARINEJADIAN, SAVAGHEBI M, et al. An optimal energy management system for islanded microgrids based on multiperiod artificial bee colony combined with Markov Chain[J]. IEEE Systems Journal, 2015, 10(1): 1-11.
- [16] AMAN M M, JASMON G B, BAKAR A H A, et al. A new approach for optimum simultaneous multi-DG distributed generation units placement and sizing based on maximization of system load ability using hybrid particle swarm optimization (HPSO) algorithm[J]. Energy, 2014, 66(4): 202-215.

收稿日期: 2016-08-06; 修回日期: 2016-09-27

作者简介:

吴丽珍(1973—), 女, 博士, 副教授, 研究方向为分布式发电与微电网的运行与控制; E-mail: wulzh@lut.cn

蒋力波(1993—), 男, 通信作者, 硕士研究生, 研究方向为分布式发电与微电网优化运行; E-mail: 769326807@qq.com

郝晓弘(1960—), 男, 教授, 博士生导师, 研究方向为电力系统的稳定运行与控制。E-mail: haoxiaohong@lut.cn

(编辑 魏小丽)