

doi:10.11835/j.issn.1000-582X.2018.12.010

# 考虑概率潮流的分布式电源优化配置

张忠伟<sup>1</sup>, 王金玉<sup>1</sup>, 张建波<sup>1</sup>, 杨 洋<sup>2</sup>

(1. 东北石油大学 电气信息工程学院, 黑龙江 大庆 163318;

2. 中国石油集团电能公司 中油电能电力技术服务公司, 黑龙江 大庆 163453)

**摘要:**为了解决电动汽车和分布式电源并网为电力系统带来的较强的随机性、间歇性和相关性的问题,以分布式电源和电动汽车的概率模型为基础,建立了以分布式电源总费用、供电可靠性和有功网损为目标函数的优化配置模型,将概率潮流计算嵌入基于成功历史的自适应参数差分进化算法求解目标函数。采用无迹变换利用输入随机变量的均值和协方差近似描述系统状态变量统计特性,直接方便地处理具有不确定性的随机变量。然后利用径向基神经网络求解功率方程,避免了计算雅可比矩阵和偏导,减少了算法运行时间。最后采用基于成功历史的自适应参数差分进化法并行计算多目标函数。通过 IEEE33 节点配电系统进行仿真,验证了该方法的有效性和高效性,节约了规划成本。

**关键词:**分布式电源;电动汽车;基于成功历史的自适应差分进化;无迹变换;径向基神经网络

**中图分类号:** TM712

**文献标志码:** A

**文章编号:** 1000-582X(2018)12-083-09

## Optimal configuration of distributed generation considering probability power flow

ZHANG Zhongwei<sup>1</sup>, WANG Jinyu<sup>1</sup>, ZHANG Jianbo<sup>1</sup>, YANG Yang<sup>2</sup>

(1. School of Electrical Engineering & Information, Northeast Petroleum University, Daqing 163318, Heilongjiang, P.R.China; 2. Electric Technical Services Company, China Petroleum Electric Energy Co., Ltd, Daqing 163453, Heilongjiang, P.R.China)

**Abstract:** In order to solve the problem caused by paralleling operation of electric vehicles and distributed power grids, which brings strong randomness, intermittent and correlation to power system. Based on the probabilistic model of distributed power supply and electric vehicle, an optimal configuration model taking distributed power supply total cost, power supply reliability and active network loss as the objective function was established, embedding the probabilistic power flow calculation into the adaptive parameter difference based on the success history. The evolutionary algorithm was used to solve the objective function. The unscented transformation was used to describe the statistical properties of the system state variables by using the mean and covariance of the input random variables to directly deal with the random variables with uncertainty. Then RBF neural network was used to solve the power equation, which avoided calculating the Jacobian matrix and partial derivative, reducing the running time of the algorithm. Finally, the multi-objective function was calculated in parallel using the adaptive parameter differential evolution

收稿日期:2018-05-10

基金项目:国家自然科学基金资助项目(51574087)。

Supported by the National Natural Science Foundation of China (51574087).

作者简介:张忠伟(1965—),男,副教授,主要从事电力电子传动、电网规划分析等研究,(E-mail)zhangzw829@126.com。

method based on the success history. The simulation of the IEEE33 node power distribution system verified the effectiveness and efficiency of the method and the method can save planning costs.

**Keywords:** distributed power; electric vehicle; adaptive differential evolution based on success history; unscented transformation; RBF neural network

传统分布式电源(distributed generation, DG)优化配置问题主要围绕风电(wind generation, WG)和光伏(photovoltaic, PV)并网运行。随着电力工业和电力电子技术的发展,电动汽车(plug-in electric vehicle, PEV)作为一种更加经济的手段接入电网。合理配置 DG 和 PEV 可以有效降低系统网损,提高供电可靠性和灵活性<sup>[1]</sup>。然而 DG 和 PEV 也给电力系统带来了较强的随机性和间歇性,同时 DG 出力的相关性也影响节点电压的波动性<sup>[2]</sup>。因此,在配电网优化中必须考虑 DG、PEV 和负荷之间的随机性、间歇性以及相关性,为电网的安全运行奠定基础,满足智能电网的需求。

针对 DG 和 PEV 并网不确定性问题,国内外相关学者进行了相当多的研究。文献[3]考虑多风电场相关性对概率潮流计算的影响,采用 K-means 聚类和 Copula 函数建立场景概率潮流计算方法。文献[4]考虑分布式电源与负荷之间的相关性,采用无迹变换(unscented transformation, UT)将概率潮流转化为确定性最优潮流。文献[5]在文献[4]的基础上结合径向基神经网络(radial basis function, RBF),处理概率潮流中功率方程计算问题。针对 DG 和 PEV 并网优化问题,文献[6]考虑电压控制成本,以年综合成本和清洁能源发电占比为目标函数。文献[7]将环境效益纳入 DG 和 PEV 优化目标函数内,将自适应变异引入量子粒子群算法。文献[8]研究了分布式电源与微电网组合的混合供电方案,采用 NSGA-II 算法求解集成供电系统中 DG 优化配置方案。文献[9]分析了 DG 出力相关性对节点电压的影响,提高了 DG 并网时的接入容量。

以往文献主要基于传统潮流计算方法求解 DG 和 PEV 的优化配置,忽略了他们之间的不确定性,且传统蒙特卡洛模拟采样复杂,计算负担重。笔者充分考虑 WG、PV、PEV 和负荷之间的随机性、间歇性和相关性,以 DG 总成本、供电可靠性和有功损耗建立目标函数模型,采用 UT 和 RBF 相结合求解概率潮流。UT 比任何非线性函数更能近似其真实概率分布,保障了算法的精度,同时利用 RBF 求解非线性方程组的能力,避免了传统潮流计算所需计算偏导和雅可比矩阵,提高了算法运行的速度。采用基于成功历史的自适应参数差分进化算法(success-history based parameter adaptation for differential evolution, SHADE)对优化模型进行求解。以 IEEE33 节点配电系统为例,计算结果与差分进化-蒙特卡洛(DE-MCS)和量子粒子群-拉丁超立方蒙特卡洛(QPSO-CLMCS)进行对比,验证所提算法的有效性。

## 1 微电网中不确定性分量建模

### 1.1 WG 概率模型

双参数(规模参数  $c$  和形状参数  $k$ )的 Weibull 分布被用来描述风速  $v$  的变化规律,其概率密度函数为:

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

风机输出功率  $P_{WT}$  与风速  $v$  之间的函数关系表示为:

$$P_{WT} = \begin{cases} 0, & v \leq v_{ci}, v \geq v_{co}, \\ P_r \frac{v - v_{ci}}{v_n - v_{ci}}, & v_{ci} \leq v \leq v_n, \\ P_r, & v_n \leq v \leq v_{co}, \end{cases} \quad (2)$$

式中:  $P_r$  为风机的额定功率;  $v_{ci}$ 、 $v_{co}$  和  $v_n$  分别为切入风速、切出风速和额定风速<sup>[10]</sup>, 分别取 4, 25, 15 m/s。

### 1.2 PV 概率模型

太阳辐射  $r$  是影响光伏系统输出功率大小的主要因素。Beta 分布被用来近似描述  $r$  在一定时间段内的分布,其概率密度函数<sup>[5]</sup>表示为:

$$f(r) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \left[\frac{r(t)}{r_{\max}}\right]^{\alpha-1} \left[1 - \frac{r(t)}{r_{\max}}\right]^{\beta-1}, \quad (3)$$

式中: $\alpha$  和  $\beta$  分别为 Beta 分布的 2 个形状参数; $r_{\max}$  为某时段内的最大太阳辐射。光伏发电系统的输出功率  $P_{PV}$  与太阳辐射  $r$  的函数关系可以表示为:

$$P_{PV} = \begin{cases} P_m \frac{r^2}{R_{std} R_c}, 0 \leq r \leq R_c, \\ P_m \frac{r}{R_{std}}, R_c \leq r \leq R_{std}, \\ P_m, r \geq R_{std}, \end{cases} \quad (4)$$

式中: $P_m$  为光伏发电系统额定功率; $R_c$  为确定点的太阳辐射,通常设置为  $150 \text{ W/m}^2$ ; $R_{std}$  为标准测试环境下的太阳辐射,通常设置为  $1000 \text{ W/m}^2$ 。

### 1.3 PEV 概率模型

考虑到 PEV 采用无序充电模式,采用(文献[11]所示模型),采用极大似然估计法求得日行驶里程  $d$  近似服从对数正态分布,其概率密度函数如式(5)所示;根据 NHTS 的统计结果,起始充电时刻  $T$ (即最后一次出行返回时刻)近似服从正态分布,其概率密度函数如式(6)所示。

$$f(d) = \frac{1}{\sqrt{2\pi} d \sigma_d} \exp\left[-\frac{(\ln d - \mu_d)^2}{2\sigma_d^2}\right], \quad (5)$$

$$f(T) = \begin{cases} \frac{1}{\sqrt{2\pi} \sigma_T} \exp\left[-\frac{(T - \mu_T)^2}{2\sigma_T^2}\right], \\ \frac{1}{\sqrt{2\pi} \sigma_T} \exp\left[-\frac{(T + 24 - \mu_T)^2}{2\sigma_T^2}\right]. \end{cases} \quad (6)$$

### 1.4 负荷概率模型

负荷具有时变性,可以用正态分布近似表示负荷功率的变化。节点  $i$  负荷的有功功率和无功功率概率密度函数为:

$$f(P_{Li}) = \frac{1}{\sqrt{2\pi} \sigma_i} \exp\left[-\frac{(P_{Li} - P_{Li}^b)^2}{2\sigma_i^2}\right], \quad (7)$$

$$f(Q_{Li}) = P_{Li} Q_{Li}^b / P_{Li}^b, \quad (8)$$

式中: $P_{Li}^b$ 、 $Q_{Li}^b$  分别为基态节点负荷有功功率和无功功率; $\sigma_i$  为节点  $i$  负荷功率的标准差,这里取 5%。

## 2 基于机会约束的多目标优化模型

### 2.1 目标函数

1) DG 设备运行总成本  $C_{DG}$ , 包括设备投资成本  $C_T$ 、运行维护成本  $C_{OM}$  和替换成本  $C_R$ 。

$$C_{DG} = C_T + C_{OM} + C_R = \sum_{i \in NDG} (C_i^T + C_i^{OM} + C_i^R) x_i P_i, \quad (9)$$

式中: $C_i^T$ 、 $C_i^{OM}$ 、 $C_i^R$  分别为电源  $i$  的投资成本、运维成本和替换成本; $x_i$  为电源  $i$  的数量; $P_i$  为电源  $i$  的装机容量<sup>[10]</sup>。

2) 供电可靠性最大。供电可靠性是衡量供电系统电能质量的重要指标,合理配置 DG 可提高电网在孤岛运行时的供电可靠性。本文采用优化期内总缺供电量成本  $C_{EENS}$  衡量 DG 并网后供电系统的可靠性<sup>[7]</sup>。

$$C_{EENS} = C_{ens} \cdot \beta_{EENS}, \quad (10)$$

式中: $C_{ens}$  为单位缺供电量成本,取  $13.65 \text{ \$/ (kw} \cdot \text{h)}$ ; $\beta_{EENS}$  为期望缺供电量指标。

3) 有功损耗最小。有功损耗是衡量配电网经济运行的重要指标,合理配置 DG 和 PEV 可有效减少有功损耗,对提高配电网经济运行能力有重要意义。有功损耗的费用表示为:

$$C_{\text{loss}} = \sum_{t=1}^T C_e P_{\text{loss}} T_{\text{max}}, \quad (11)$$

式中: $C_e$  为单位电价,取  $0.089 \text{ \$/ (kw} \cdot \text{h)}$ ; $P_{\text{loss}}$  为配电网网损; $T_{\text{max}}$  为年最大负荷利用时间(h),取  $8760 \text{ h}$ 。

## 2.2 约束条件

1) 功率平衡方程。

$$\left. \begin{aligned} P_G - P_L &= V_i \sum_{j=1}^N V_j (G_{ij} \cos \delta_{ij} + B_{ij} \sin \delta_{ij}), \\ Q_G - Q_L &= V_i \sum_{j=1}^N V_j (B_{ij} \cos \delta_{ij} - G_{ij} \sin \delta_{ij}), \end{aligned} \right\} \quad (12)$$

式中:  $P_G$ 、 $Q_G$  分别为节点  $i$  处电源输出的有功、无功功率;  $P_L$ 、 $Q_L$  分别为节点  $i$  处的有功、无功负荷。

2) 机会约束与不等约束。

对含 DG 的概率潮流计算时, 还需考虑 DG 接入容量、DG 渗透率、节点电压幅值和馈线传输容量的越限问题。笔者采用机会约束与不等式约束, 对节点电压幅值和线路传输容量采用机会约束限制。

$$\left. \begin{aligned} Pr \{V_{\min} \leq V_i \leq V_{\max}\} &\geq \alpha, \\ Pr \{S_{ij} \leq S_{ij\max}\} &\geq \beta, \end{aligned} \right\} \quad (13)$$

式中:  $Pr\{\cdot\}$  为事件  $\{\cdot\}$  成立的置信水平, 节点电压幅值置信水平  $\alpha$  和馈线传输容量的置信水平  $\beta$  均设为 0.8<sup>[12]</sup>。

对 DG 接入容量, DG 渗透率采用不等式约束限制。

$$\left. \begin{aligned} P_{EN} &= \left( \sum_{i=1}^{N_{DG}} P_{DG_i} \right) / \left( \sum_{i=1}^{N_{BUS}} P_{L_i} \right) \leq P_{EN\max}, \\ S_{DG_i} &\leq S_{DG_i\max}, \end{aligned} \right\} \quad (14)$$

式中:  $P_{EN}$ 、 $S_{DG_i}$  分别为 DG 渗透率和安装容量。

## 3 多目标优化模型求解

### 3.1 UT(RBF) 求解概率潮流

1) 采用 UT 将概率潮流问题转换为少量样本点的确定性潮流计算。如果输入随机变量  $X$  是具有均值  $u_x$  和协方差  $P_{xx}$  的  $n$  维输入向量, 输出向量  $Y$  可以通过一组非线性变换函数来实现。其中随机变量  $X$  之间的相关性根据各随机变量的标准差  $\delta_i$  以及变量之间的相关系数  $\rho_{ij}$  构造的协方差矩阵  $P_{xx}$  表示。采用对称采样策略参照文献[4],  $N$  个比例对称采样的 Sigma 点为:

$$\left. \begin{aligned} \{\chi_0\} &= u_x, \\ \{\chi_i\} &= u_x + \alpha \sqrt{n/(1-W_0)} A_i, \\ \{\chi_{n+i}\} &= u_x - \alpha \sqrt{n/(1-W_0)} A_i, \end{aligned} \right\} \quad (15)$$

式中:  $\alpha$  为比例缩放系数;  $A_i$  为  $A$  的第  $i$  列元素, 其中  $A$  为对协方差矩阵  $P_{xx}$  进行 Cholesky 分解求得, 相关系数的取值来源于文献[13];  $n$  为输入随机变量维数;  $\{\chi_i\}$  表示第  $i$  个 Sigma 采样点, 为  $n$  维列向量;  $W_0$  为均值处 Sigma 点权值。对所选择的输入随机变量 Sigma 点集中的每个采样点进行非线性变换  $f_U$ , 得到变换后 Sigma 点集。

$$y_i = f_U(\chi_i) \quad i=1, 2, \dots, N, \quad (16)$$

输出随机变量  $Y$  的均值  $\mu_y$  和协方差  $P_{yy}$  采用变换之后的 Sigma 点的加权样本均值和加权协方差来近似。

$$\mu_y = \sum_{i=1}^N W_i^m y_i, \quad (17)$$

$$P_{yy} = \sum_{i=1}^N W_i^c (y_i - \mu_y) (y_i - \mu_y)^T, \quad (18)$$

式中:  $W_i^c$ 、 $W_i^m$  分别为均值权重和协方差权重。

2) RBF 用来解决 DG 和 PEV 在系统中功率方程计算的问题。RBF 具有“任何非线性函数都可以通过具

有零误差的 RBF 神经网络来近似”的优势。功率方程写成非线性方程组的形式:

$$y_i = f(x_i), \quad (19)$$

式中:  $x_i$  代表潮流计算所要求得的节点  $i$  的电压和相角;  $y_i$  表示节点  $i$  的有功功率和无功功率;  $f$  代表功率方程映射。

笔者选择非线性高斯激活函数构成隐含层,采用精确拟合法<sup>[14]</sup>训练 RBF。隐含层的神经元数量等于输入向量的数量,将每个内核的中心设定在特定的输入向量上,忽略了隐含层的优化只需计算输出层的权重因子。因此网络的训练过程所需时间非常短,适用于迭代计算。针对输出层权重因子的优化,采用线性最小二乘回归来计算所得输出权重因子矩阵为:

$$\mathbf{W} = \mathbf{T}\mathbf{A}^T (\mathbf{A}\mathbf{A}^T)^{-1}, \quad (20)$$

式中:  $\mathbf{W}$  为输出层权重因子矩阵;  $\mathbf{T}$  为目标输出向量;  $\mathbf{A}$  为隐含层的输出矩阵。

3)应用 UT(RBF)求解概率潮流问题的主要步骤。

第一步:通过式(13)获得  $N = 2n + 1$  个采样点。

第二步:计算每个 Sigma 采样点的均值权重和协方差权重。

第三步:基于以下步骤将每个采样点馈送到非线性函数式(14)中。

Step1:生成  $\mathbf{X}_i$  的随机向量。向量  $\mathbf{X}_i$  包括配电网中网络参数、DG 和 PEV 中随机变量。

Step2:通过非线性方程组  $f$ , 计算向量  $\mathbf{Y}_i$ 。

Step3:以向量  $\mathbf{Y}_i$  作为输入,  $\mathbf{X}_i$  作为输出,训练 RBF。在已经训练好的网络中,当输入向量  $\mathbf{Y}^*$  时在输出处产生向量  $\mathbf{X}^*$ 。

Step4:在 Step3 中训练好的网络中,输入向量  $\mathbf{Y}^*$  产生向量  $\mathbf{X}_0$ 。

Step5:将  $\mathbf{X}_0$  代入非线性方程组  $f$  求得  $\mathbf{Y}_0$ , 将  $\mathbf{Y}_0$  与  $\mathbf{Y}^*$  进行比较。如果  $\|\mathbf{Y}_0 - \mathbf{Y}^*\|^2$  满足预定的公差,则算法停止,向量  $\mathbf{X}_0$  将被选择为最优解。否则,进行下一步。

Step6:如果上一步产生的  $\mathbf{Y}_0$  比其他  $\mathbf{Y}_i$  更接近  $\mathbf{Y}^*$ , 则  $(\mathbf{Y}_i, \mathbf{X}_i)$  中的一个将被替换为  $(\mathbf{Y}_0, \mathbf{X}_0)$ , 然后转到 Step3。如果约束条件不满足,则用约束条件中的最大值或最小值替换当前参数,并且算法转到步骤 Step4。

第四步:按式(15)、式(16)分别计算输出变量  $Y$  的均值和协方差。

### 3.2 基于成功历史的自适应差分进化算法 (SHADE)

标准的差分进化算法有 4 个基本步骤:初始化、变异、交叉和选择,SHADE 使用了被个体成功使用控制参数的历史存储器  $M$  来指导变异和交叉中控制参数值的选择<sup>[15]</sup>。每一代成功产生比父代个体好的试验向量的交叉率  $CR$  和放缩因子  $F$  记为  $S_{CR}$ 、 $S_F$ , 他们的平均值存储在历史存储器  $M_{CR}$ 、 $M_F$  中。如表 1 所示,SHADE 保留  $H$  条参数,以便在搜索过程中引导控制参数实现自适应,按照式(21)、式(22)更新历史存储器  $M$ 。即使某些子代的  $S_{CR}$ 、 $S_F$  含有一组较差的值,存储在前一代存储器中的参数也不会受到影响。因此,基于成功历史参数的自适应策略提高了算法的鲁棒性,能够加快算法的收敛速度。

表 1 控制参数历史存储器  $M$

Table 1 History memory  $M$  of the control parameter

控制参数	1	2	...	$H-1$	$H$
$M_{CR}$	$M_{CR,1}$	$M_{CR,2}$	...	$M_{CR,H-1}$	$M_{CR,H}$
$M_F$	$M_{F,1}$	$M_{F,2}$	...	$M_{F,H-1}$	$M_{F,H}$

$$M_{CR,t+1} = \begin{cases} M_{WA}(S_{CR}) & S_{CR} \neq \emptyset, \\ M_{CR,t} & \text{其他}, \end{cases} \quad (21)$$

$$M_{F,t+1} = \begin{cases} M_{WL}(S_F) & S_F \neq \emptyset, \\ M_{F,t} & \text{其他,} \end{cases} \quad (22)$$

式中  $M_{WA}(S_{CR})$  和  $M_{WL}(S_F)$  分别表示  $S_{CR}$  的权重均值和  $S_F$  的权重 Lehmer 均值。初始化索引  $k=1$ , 每当有一对新的  $S_{CR}$  和  $S_F$  插入到存储器时, 索引  $k=k+1$ 。当在  $t$  代所有个体都不能产生比父代更好的试验向量时, 存储器不更新。

在每一代中, 每个个体进行交叉和变异操作之前, 控制参数 CR 和 F 首先从  $[1, H]$  随机选择, 然后应用公式(21)、式(22)求得其控制参数 CR、F。

$$CR_i = \text{rand}n_i(M_{CR}, 0.1), \quad (23)$$

$$F_i = \text{rand}c_i(M_F, 0.1), \quad (24)$$

式中:  $\text{rand}c_i(M_F, 0.1)$  表示生成一个服从以  $M_F$  为位置参数, 以 0.1 为尺度参数的 Cauchy 分布的值;  $\text{rand}n_i(M_{CR}, 0.1)$  表示生成一个服从均值为  $M_{CR}$ , 标准差为 0.1 的正态分布的值。如果 CR、F 生成的值超出范围  $[0, 1]$ , 按照 JADE 的参数自适应调整方式<sup>[16]</sup>。

### 3.3 UT(RBF)与 SHADE 算法求解步骤

1) 初始化算法。设定种群规模  $Np$ 、最大进化代数  $T_{\max}$ 、决策变量维数  $d$  以及配电网基本参数和 UT(RBF)算法基本参数。

2) 对目标向量  $\mathbf{X}_i^t$  进行交叉和变异操作。采用“current-to-pbest/1”变异策略, 生成变异向量  $\mathbf{V}_i^t$ ; 采用二项式交叉, 每当 0 和 1 之间随机生成的数字小于或等于交叉率 CR 时, 变异向量  $\mathbf{V}_i^t$  和目标向量  $\mathbf{X}_i^t$  交叉, 生成试验向量  $\mathbf{U}_i^t$ 。

3) 根据 UT(RBF)算法对目标向量  $\mathbf{X}_i^t$  和试验向量  $\mathbf{U}_i^t$  进行概率潮流计算, 计算目标函数值和适应度。

4) 根据贪婪算法进行选择操作。如果试验向量  $\mathbf{U}_i^t$  的适应度优于目标向量  $\mathbf{X}_i^t$ , 则在下一代中试验向量  $\mathbf{U}_i^t$  取代目标向量  $\mathbf{X}_i^t$ , 并更新存储器  $M_{CR}$ 、 $M_F$  的值; 否则目标向量  $\mathbf{X}_i^t$  被保存, 存储器不更新。

5) 停止标准。判断是否达到最大进化代数  $T_{\max}$ 。如果是, 则停止并输出最优解。如果不是, 转到步骤 2)。

## 4 仿真结果及分析

### 4.1 参数设置

笔者以 IEEE33 节点配电系统为例, 网络结构参数参考文献[17]。该配电系统共有 33 个节点, 节点 1 为发电机节点。DG 和 PEV 通过恒功率因数控制方式并网, 成本参数见表 2, 候选节点综合考虑资源分布和节点电压幅值<sup>[7]</sup>。

表 2 DG 与 PEV 成本参数

Table 2 Cost parameters of the DG and PEV

类型	投资成本/( $\$ \cdot \text{kW}^{-1}$ )	运维成本/( $\$ \cdot \text{kW}^{-1} \cdot \text{h}^{-1}$ )	替换成本/( $\$ \cdot \text{kW}^{-1}$ )
WT	1 800	0.05	0
PT	2 000	0.03	0
PEV	850	0.07	50

WG 概率模型中风速  $v$  服从  $k=2.1$ 、 $c=7.5$  的 Weibull 分布, 功率因数为 0.95, 候选节点为 6, 10, 17, 18; PV 概率模型中太阳辐射  $r$  服从  $\alpha=0.3$ 、 $\beta=1.2$  的 Beta 分布, 功率因数为 1, 候选节点为 6, 9, 18, 28。其中假设该区域的电动汽车有 400 辆, 均匀分布在各配电区, 行驶起始时间  $T$  服从  $\mu_T=17.6$ 、 $\sigma_T=3.8$  的正态分布, 日行驶里程  $d$  服从  $\mu_d=3.2$ 、 $\sigma_d=0.88$  的对数正态分布, 功率因数为 0.9, 候选节点为 6, 28。

## 4.2 优化结果分析

初始化 SHADE 参数设置,群体规模  $N_p$  为 200,最大迭代次数为 500,存储器大小  $H=7$ ,初始化  $CR=F=0.5$ 。SHADE 采用并行计算的方式处理本文多目标优化问题。通过仿真所得优化配置结果如表 3 所示。

表 3 优化配置结果

Table 3 Results of optimal configuration

类型	接入点位置	容量/MW
WT	6	0.121
	17	0.532
PV	9	0.114
	28	0.342
PEV	6	0.456

将 DE-MCS、QPSO-CLMCS 与上述提出的 SHADE-UT(RBF)方法在对 DG 和 PEV 优化配置的问题上进行对比。其中 3 种算法的种群规模均取 200,最大迭代次数为 500,CLMCS 采样次数为 500,且 3 种算法均采用相同的机会约束以及不等式约束。分别计算 3 种方法在规划期内目标函数最优值,通过 Matlab 仿真得到的最优目标函数值如表 4 所示。

表 4 3 种方法最优目标函数值

Table 4 Three methods the optimal objective function value

方法	DG 总费用/ $(\times 10^6 \$)$	缺供电量成本/ $(\times 10^6 \$)$	有功损耗费用/ $(\times 10^5 \$)$
DE-MCS	7.231	1.423	8.029
QPSO-CLMCS	5.562	0.536	6.695
SHADE-UT(RBF)	5.096	0.424	4.856

通过对比表 3 所示 DG 总费用、缺供电量成本以及有功损耗费用,DE-MCS 所求得的目标函数值在 3 种算法中最高,这是因为在 DE 算法求解过程中,进化代数的增加,会使种群的多样性变小,过早的收敛到局部极小点。QPSO-CLMCS 将量子粒子群与拉丁超立方采样蒙特卡洛方法相结合,但是在搜索后期,粒子聚集成群导致搜索空间变得有限。在 3 种优化算法中 SHADE-UT(RBF)目标函数值最低,优化结果最好。总目标函数值对比 DE-MCS 和 QPSO-CLMCS 分别减少了 36.5%、11.2%。并且 3 种方法的计算时间分别为 DE-MCS 14 min、QPSO-CLMCS 10 min 和 SHADE-UT(RBF) 3 min,SHADE-UT(RBF)在 3 种方法中用时最短,这是因为 UT(RBF)对比 CLMCS 避免了蒙特卡洛模拟计算负担重的缺陷,舍弃了传统计算潮流的方法,避免了计算雅可比矩阵。SHADE 采用基于成功历史参数自适应算法,将成功的历史记录存储在寄存器中,加速了算法收敛速度。仿真结果表明,在 DG 和 PEV 优化配置问题上,SHADE-UT(RBF)能更好地保证电网运行的经济性与可靠性。

## 4.3 电压水平分析

为了分析不同算法对系统节点电压的影响,3 种算法优化后的节点电压结果以及不安装 DG 时节点电压水平如图 1 所示。

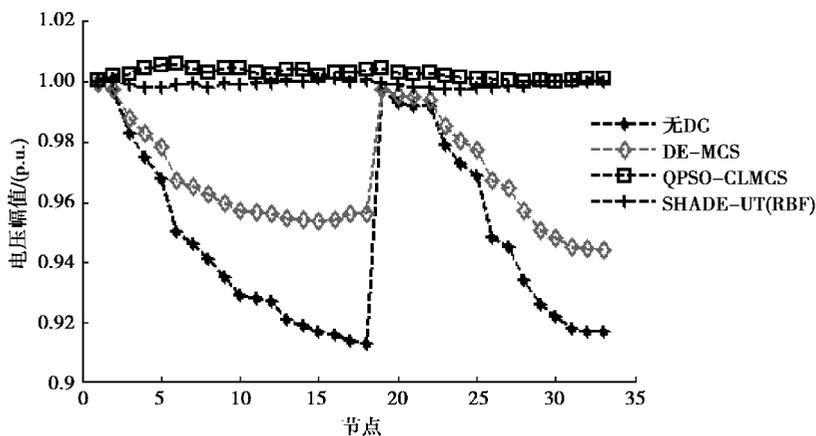


图1 节点电压水平

Fig.1 Node voltage level

未接入 DG 时,节点电压严重超出电压允许上下偏移量  $0.95 \sim 1.05$  p.u.。在接入 DG 后,3 种方法均能使节点电压幅值得到较大改善,但 DE-MCS 由于容易过早收敛,导致仍有少量节点未能达电压允许偏移量。QPSO-CLMCS 和 SHADE-UT(RBF)所求得电压均在允许的偏移量内,但不难看出 SHADE-UT(RBF)的优化效果更好,大部分节点电压幅值在  $1$  p.u.,提高了供电安全性和可靠性。

## 5 结 语

将概率潮流计算引入 SHADE 求得最优规划方案。采用 UT 和 RBF 相结合的方式求解含 DG 和 PEV 的概率潮流,充分考虑 DG 和 PEV 的间歇性、随机性和相关性。采用 SHADE 求解多目标优化问题,以 DG 总费用、供电可靠性和有功损耗为目标函数,更能反映实际需要。SHADE 能够快速收敛到全局最优解,避免了传统差分进化算法容易过早收敛的缺陷。本研究通过仿真验证了所提算法能够在保证计算精度的同时快速收敛,满足实际工程要求,降低了节点电压的波动以及优化成本,同时为大规模 PEV 和 DG 并网提供了可靠的理论依据。

## 参考文献:

- [1] 谢维兵, 刘敏, 周晓霞, 等. 含电压逆变型分布式电源配电网的短路电流计算[J]. 重庆大学学报, 2017, 40(2):70-79.  
XIE Weibing, LIU Min, ZHOU Xiaoxia, et al. Short-circuit current calculation of distributed power distribution network with voltage inverter[J]. Journal of Chongqing University, 2017, 40(2): 70-79.(in Chinese)
- [2] 周隰, 曹立平, 李剑, 等. 改进遗传算法在分布式电源选址定容中的应用[J]. 重庆大学学报, 2014, 37(5):22-28.  
ZHOU Wei, CAO Liping, LI Jian, et al. Application of improved genetic algorithm in distributed power source location and volume [J]. Journal of Chongqing University, 2014, 37(5): 22-28.(in Chinese)
- [3] 熊强, 陈维荣, 张雪霞, 等. 考虑多风电场相关性的场景概率潮流计算[J]. 电网技术, 2015, 39(8):2154-2159.  
XIONG Qiang, CHEN Weirong, ZHANG Xuexia, et al. Calculation of probability power flow in scenarios considering the correlation of wind farms [J]. Power System Technology, 2015, 39(8):2154-2159.(in Chinese)
- [4] 代景龙, 韦化, 鲍海波, 等. 基于无迹变换含分布式电源系统的随机潮流[J]. 电力自动化设备, 2016, 36(3):86-93.  
DAI Jinglong, WEI Hua, BAO Haibo, et al. Stochastic power flow based distributed distributed power system with no trace transform [J]. Electric Power Automation Equipment, 2016, 36(3):86-93.(in Chinese)
- [5] Baghaee H R, Mirsalim M, Gharehpetian G B, et al. Application of RBF neural networks and unscented transformation in probabilistic power-flow of microgrids including correlated wind/PV units and plug-in hybrid electric vehicles [J]. Simulation Modelling Practice & Theory, 2017, 72(C):51-68.
- [6] 刘文霞, 徐慧婷. 考虑电压控制成本的分布式电源优化配置[J]. 电网技术, 2016, 40(10):2998-3005.

- LIU Wenxia, XU Huiting. Distributed power supply optimal configuration considering voltage control cost [J]. Power System Technology, 2016, 40(10):2998-3005.(in Chinese)
- [ 7 ] 彭显刚, 林利祥, 刘艺, 等. 计及电动汽车和可再生能源不确定因素的多目标分布式电源优化配置[J]. 电网技术, 2015, 39(8):2188-2194.
- PENG Xiangang, LIN Lixiang, LIU Yi, et al. Optimization of multi-objective distributed generation considering electric vehicles and uncertainties of renewable energy [J]. Power System Technology, 2015, 39(8):2188-2194.(in Chinese)
- [ 8 ] 盛万兴, 叶学顺, 刘科研, 等. 基于 NSGA-II 算法的分布式电源与微电网分组优化配置[J]. 中国电机工程学报, 2015, 35(18):4655-4662.
- SHENG Wanxing, YE Xueshun, LIU Keyan, et al. Optimized allocation of DGs and microgrids based on NSGA-II algorithm [J]. Proceeding of the CSEE, 2015, 35(18):4655-4662.(in Chinese)
- [ 9 ] 周辛南, 柯德平, 孙元章. 基于配电网静态电压质量机会性约束的可再生能源分布式发电容量规划[J]. 电力自动化设备, 2015, 35(9):143-149.
- ZHOU Xinnan, KE Deping, SUN Yuanzhang. Distributed energy generation capacity planning based on chance constraints of static voltage quality in distribution network [J]. Electric Power Automation Equipment, 2015, 35(9):143-149.(in Chinese)
- [10] 吕智林, 谭颖, 李捷, 等. 基于 Markov-ELM 的独立混合微网分布式电源多目标容量优化配置[J]. 中国电机工程学报, 2017(7):1927-1936.
- LV Zhilin, TAN Ying, LI Jie, et al. Multi-objective capacity optimization of independent hybrid micro-grid distributed generation based on Markov-ELM [J]. Proceedings of the CSEE, 2017 (7): 1927-1936.(in Chinese)
- [11] 蔡德福, 钱斌, 陈金富, 等. 含电动汽车充电负荷和风电的电力系统动态概率特性分析[J]. 电网技术, 2013, 37(3): 590-596.
- CAI Defu, QIAN Bin, CHEN Jinfu, et al. Analysis on dynamic probabilistic characteristics of power system with electric vehicle charging load and wind power [J]. Power System Technology, 2013, 37(3):590-596.(in Chinese)
- [12] 彭显刚, 林利祥, 刘艺, 等. 基于纵横交叉-拉丁超立方采样蒙特卡洛模拟法的分布式电源优化配置[J]. 中国电机工程学报, 2015, 35(16):4077-4085.
- PENG Xiangang, LIN Lixiang, LIU Yi, et al. Optimal distributed generator allocation method based on correlation latin hypercube sampling monte carlo simulation embedded crisscross optimization algorithm [J]. Proceedings of the CSEE, 2015, 35(16):4077-4085.(in Chinese)
- [13] Aien M, Rashidinejad M, Firuz-Abad M F. Probabilistic optimal power flow in correlated hybrid wind-PV power systems: A review and a new approach[J]. Renewable and Sustainable Energy Reviews, 2015, 41:1437-1446.
- [14] Zimmerman R D, Murillo-Sanchez C E, Thomas R J. MATPOWER's extensible optimal power flow architecture[C]// Power & Energy Society General Meeting, 2009. PES'09. IEEE. IEEE, 2009:1-7.
- [15] Tanabe R, Fukunaga A. Success-history based parameter adaptation for Differential Evolution [C] // Evolutionary Computation. IEEE, 2013:71-78.
- [16] Zhang J, Sanderson A C. JADE: Adaptive differential evolution with optional external archive[J]. IEEE Transactions on Evolutionary Computation, 2009, 13(5):945-958.
- [17] Demuth H, Beale M. Neural network toolbox-for use with mATLAB[J]. Matlab Users Guide the Math Works, 1995, 21(15):1225-1233.