

DOI: 10.7667/PSPC171808

考虑电动汽车不确定性因素的配电网分布式电源优化布置

王满商^{1,2}, 李正明¹, 汪洋¹

(1. 江苏大学电气信息工程学院, 江苏 镇江 212013; 2. 国网镇江供电公司, 江苏 镇江 212001)

摘要: 分布式电源和电动汽车的规模化接入对配电网经济运行和电能质量产生了较大影响。分布式电源和电动汽车的功率具有不确定性。为实现分布式电源的合理配置, 提出了一种考虑电动汽车不确定性因素的分布式电源优化布置方法。首先, 以网络损耗最小、电压偏移最小和系统稳定性高为优化目标, 利用机会约束规划方法建立分布式电源优化配置模型。然后, 采用支持向量机算法和多目标粒子群算法对上述模型进行求解, 得到其 Pareto 解集。以 IEEE 37 节点配电网为例对所提模型进行验证, 结果表明该模型可以有效得到合理的配置方案。

关键词: 分布式电源; 电动汽车; 不确定性; 多目标规划; 支持向量机; 多目标粒子群

Distribution network distributed power supply configuration considering the uncertainties of electric vehicle

WANG Manshang^{1,2}, LI Zhengming¹, WANG Yang¹

(1. School of Electrical Information and Engineering, Jiangsu University, Zhenjiang 212013, China;
2. State Grid Zhenjiang Power Supply Company, Zhenjiang 212001, China)

Abstract: The large-scale access of distributed generation and electric vehicles has a great impact on the economic operation and power quality of distribution network. Distributed power and electric vehicle power have uncertainties. In order to realize the rational distribution of distributed power, this paper presents a distributed power optimization layout method considering the uncertainties of electric vehicles. First of all, the optimal model of distributed generation is established by using the opportunistic constrained programming method with the least network loss, the minimum voltage offset and the high stability of the system. The SVM algorithm and the multi-objective particle swarm optimization algorithm are used to solve the above model, Pareto solution set is obtained. Finally, the model proposed in this paper is validated by IEEE37 node distribution network. The results show that the model can effectively get a reasonable configuration scheme.

This work is supported by National Nature Science Foundation of China (No. 51477070).

Key words: distributed power supply; electric vehicle; uncertainty; multi-objective programming; support vector machine; multi-objective particle swarm

0 引言

随着新能源技术和电动汽车技术的发展, 越来越多的分布式电源(Distribution Generation, DG)和电动汽车(Plug-in Electric Vehicle, PEV)接入配电网中^[1-2]。DG 为波动性电源, 其出力随环境而变化, 具有一定的随机性。PEV 具备可控负荷和储能单元的双重属性, 其随机充放电行为导致负荷和输出功率具有不确定性^[2]。随着 PEV 数量的增加和 DG 渗透率的增高, 如果在 DG 的选址和定容中不能合理地考虑这些不确定性因素, 有可能给配电网的经济

运行、电压质量甚至安全运行带来风险^[3]。

目前, 国内外对配电网中 DG 的优化配置研究很多, 取得了一定的成果。这些研究多数未考虑 DG、PEV 及负荷的不确定性, 往往采用确定性的规划方法^[4-7]; 在规划目标方面, 多以 DG 成本、网络损耗等为目标, 在考虑多目标时, 往往又简单地将多目标优化问题转化为单目标优化问题^[5,8-9]; 在求解方法上, 主要包括传统优化方法和启发式优化方法^[4-9]。文献[5]在多目标优化中考虑了电压偏移, 文献[9]在多目标优化中考虑了环境效益, 丰富了优化模型。文献[8-9]考虑了 DG 和 PEV 的不确定性, 文献[8]采用蒙特卡洛模拟嵌入遗传算法进行优化模型的求解, 文献[9]采用蒙特卡洛模拟嵌入改进粒子

群算法进行优化模型的求解,提高了收敛性,但这些基于蒙特卡洛嵌入启发式算法的模型计算规模较大,且直接将多目标转化为单目标进行考虑。

本文在对 DG 选址和定容建模中,以网络损耗最小、电压偏移最小、系统稳定性高为优化目标;对 DG 和 PEV 的概率特性进行建模,并利用机会约束对其不确定性进行处理;采用支持向量机(Support Vector Machine, SVM)与随机模拟结合的方法对配置方案的指标进行计算,并结合多目标粒子群算法求解其 Pareto 解集。仿真结果验证了本文所提方法的有效性和优越性。

1 不确定性因素建模

1.1 DG 输出功率的不确定性

本文考虑两种最为常见的 DG:光伏发电(Photovoltaic, PV)和风力发电(Wind Turbine Generator, WT),并分别对其功率的不确定性进行数学描述。

光伏出力的最大影响因素为太阳辐照强度,为简化模型,一般情况下可以只考虑光伏出力 P_s 与太阳辐照强度 s 的关系^[10],如式(1)所示。

$$P_s = \begin{cases} P_{s-r} \cdot \frac{s}{s_r} & 0 \leq s < s_r \\ P_{s-r} & s \geq s_r \end{cases} \quad (1)$$

式中: P_{s-r} 为光伏发电的额定出力; s_r 为额定太阳辐照强度,即光伏额定出力所需的最小太阳辐照强度。太阳辐照强度在一定时间段内服从 Weibull 分布,其概率密度函数如式(2)所示^[10]。

$$f(s) = \frac{k_s}{c_s} \left(\frac{s}{c_s}\right)^{k_s-1} \exp\left[-\left(\frac{s}{c_s}\right)^{k_s}\right] \quad (2)$$

式中: k_s 为分布曲线的形状指数; c_s 为规模指数。可根据当地的太阳辐照强度历史数据确定。

风电机组的出力主要与风速相关,一般可以认为风速 v 的随机分布服从 Weibull 分布,其概率密度函数与式(2)的形式相同,其分布曲线形状指数和规模指数可根据当地的风速历史数据确定。风电机组出力 P_w 与风速 v 的关系如式(3)所示^[11]。

$$P_w = \begin{cases} 0 & 0 \leq v \leq v_{ci} \text{ 或 } v_{co} \leq v \\ P_{w-r} \cdot \frac{v - v_{ci}}{v_r - v_{ci}} & v_{ci} < v \leq v_r \\ P_{w-r} & v_r < v \leq v_{co} \end{cases} \quad (3)$$

式中: P_{w-r} 为风电机组的额定出力; v_{ci} 和 v_{co} 分别为切入风速和切出风速; v_r 为额定风速,即额定风电机组出力所需的最小风速。

1.2 PEV 充电和放电功率的不确定性

PEV 的充电和放电行为具有较大的不确定性,

本文以家庭电动车为研究对象。根据已有研究,假定所有电动汽车参与 V2G,且充放电行为是无序的,则 PEV 的充电功率主要受电池特性、充电模式和车主出行习惯的影响^[12-13]。

根据市场主要电动车型的数据,设定电动车主要参数如下:电池容量 30 kWh,平均能耗为 0.15 kWh/km,车载电池的可用荷电状态为 10%~90%,充电功率因数为 0.95,正常充电功率为 4.0 kW,平均行驶速度为 25 km/h。本文假定以 1 d 为周期,私家车上班时间为 09:00 到 17:00,无序模式下 PEV 每个时刻的放电概率均相同。根据美国交通部 NHTS 调查结果,PEV 的充电时刻 t 和日行驶距离 x 均符合正态分布,其概率密度函数分别如式(4)和式(5)所示^[14]。

$$f(t) = \begin{cases} \frac{1}{\sqrt{2\pi}\sigma_s} \exp\left[-\frac{(t - \mu_s)^2}{2\sigma_s^2}\right], & (\mu_s - 12) < t \leq 24 \\ \frac{1}{\sqrt{2\pi}\sigma_s} \exp\left[-\frac{(t + 24 - \mu_s)^2}{2\sigma_s^2}\right], & 0 < t \leq (\mu_s - 12) \end{cases} \quad (4)$$

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

式中: $0 < x \leq 200$; $\mu_s = 17.6$; $\sigma_s = 3.4$; $\mu_d = 3.2$; $\sigma_d = 0.88$ 。

根据本文假设,放电概率密度函数如式(6)所示。

$$f(t) = \begin{cases} \frac{1}{8}, & t \in [9, 17] \\ 0, & t \in [0, 9) \cup (17, 24] \end{cases} \quad (6)$$

2 多目标 DG 优化布置模型

本文以最为经典的两种 DG 作为研究对象,对 PV 和 WT 在配网中的接入位置和接入容量进行优化。目前,国内 DG 项目中,上网电价高于当地脱硫燃煤机组标杆上网电价的部分,通过向用户征收附加电价的方式解决,因此,从配电公司的角度可不必考虑 DG 的固定投资及运行维护费用^[14]。本文建立考虑经济性和稳定性的优化模型,目标函数为:网络损耗最小、电压偏移最小、系统电压稳定性最高。

2.1 目标函数

2.1.1 配电网网络损耗

配电网网络损耗是 DG 配置方案经济性的重要指标之一。DG 接入配网后,一般情况下会减小支路潮流,进而减小网络损耗,但当 DG 配置不当时,可能会使支路潮流反向流动,使网络损耗增加。优化模型的第一个目标函数为网络损耗最小化,如式(7)所示。

$$\min f_1 = P_{\text{loss}} = \sum_{k=1}^N G_{k(i,j)} [V_i^2 + V_j^2 - 2V_i V_j \cos(\theta_i - \theta_j)] \quad (7)$$

式中: N 为网络支路总数; G_k 为节点 i 和 j 之间的支路 k 对应的电导; V 和 θ 分别为节点电压的幅值和相位。

2.1.2 配电网网络节点电压偏移

节点电压水平是配电系统电压质量的重要指标之一, 也是评价系统电源规划合理性的重要指标之一。一般情况下, DG 的接入能够对节点电压起到支撑作用, 降低节点电压偏移。文献[15]给出了较为合理的节点电压偏移指标, 计算各节点相对于额定电压的差值, 并考虑了节点重要等级。第二个目标函数如式(8)所示。

$$\min f_2 = I_V = \sum_{i=1}^{N_N-1} w_i \left(\frac{V_i - V_0}{V_0} \right) \quad (8)$$

式中: N_N 为节点总数; V_i 和 V_0 分别代表第 i 个节点和额定电压幅值; w_i 为第 i 个节点的权重因子, w_i 满足式(9)。

$$\sum_{i=1}^{N_N-1} w_i = 1 \quad (9)$$

2.1.3 配电网电压稳定性

不合理的 DG 配置有可能影响到配电网的电压水平的稳定, 使配电网承受负荷增长的能力受到限制, 甚至影响到配电网的稳定性^[16]。通常采用电压稳定指标(Voltage Stability Index, VSI)来表征系统的电压稳定性, 根据文献[17], 对于网络中支路 k , VSI 如式(10)所示。

$$VSI_k = 4[(X_{ij}P_j - R_{ij}Q_j)^2 + (X_{ij}Q_j + R_{ij}P_j)V_i^2]/V_i^4 \quad (10)$$

式中: R_{ij} 、 X_{ij} 分别为支路 k 的电阻和电抗; P_j 、 Q_j 分别为支路 k 的接收端点 j 的有功功率和无功功率。

VSI 越小, 系统的电压稳定性越高, 整个配电系统的电压稳定指标为各支路 VSI 的最大值。本文优化模型的第三个目标函数如式(11)所示。

$$\min f_3 = \text{VSI} = \max\{\text{VSI}_1, \text{VSI}_2, \dots, \text{VSI}_N\} \quad (11)$$

2.2 DG 优化布置模型的约束条件

2.2.1 机会约束

在系统正常运行中, 可以容许个别线路出现短时的过负荷现象。这是因为线路的极限值一般由其热容量决定, 短时的过负载并不会使线路达到其热稳定极限。但过负荷情况应该较大程度地被限制, 另外考虑到电源功率和负荷的不确定性, 该约束适合用软约束的形式表示^[8], 本文采用如式(12)所示的条件约束表示。

$$\Pr\{S_{ij} \leq S_{ij\max}\} \geq \beta \quad (12)$$

式中: S 为馈线传输容量; $\Pr\{\cdot\}$ 表示事件 $\{\cdot\}$ 成立的概率; β 为馈线传输容量不越限的置信水平。

2.2.2 等式约束

模型的等式约束即为配电网的潮流方程约束, 如式(13)所示。

$$\begin{cases} P_i = V_i \sum_{j=1}^N V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ Q_i = V_i \sum_{j=1}^N V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (13)$$

式中: P_i 、 Q_i 分别为节点 i 的有功和无功注入; V_i 、 V_j 分别为节点 i 和节点 j 的电压幅值; G_{ij} 、 B_{ij} 分别为节点 i 、 j 之间的互电导和互电纳; θ_{ij} 为节点 i 、 j 的相位差。

2.2.3 不等式约束

模型的不等式约束包括节点电压的约束、DG 有功和无功出力的上下限约束、DG 最大准入容量的约束, 如式(14)所示。

$$\begin{cases} V_{i\min} \leq V_i \leq V_{i\max} & i = 1, \dots, N_N - 1 \\ P_{\text{DG},i\min} \leq P_{\text{DG},i} \leq P_{\text{DG},i\max} & i = 1, \dots, N_{\text{DG}} \\ Q_{\text{DG},i\min} \leq Q_{\text{DG},i} \leq Q_{\text{DG},i\max} & i = 1, \dots, N_{\text{DG}} \\ \sum_{i=1}^{N_{\text{DG}}} S_{\text{DG}i} \leq S_{\text{DG}\max} & i = 1, \dots, N_{\text{DG}} \end{cases} \quad (14)$$

式中: N_N 为节点总数; N_{DG} 为 DG 总数。

3 求解策略

3.1 SVM 拟合配电网潮流

考虑到 DG 和 PEV 的不确定性, 当给定某个配置方案时, 需要对该方案进行随机潮流计算, 以确定该方案的优劣^[9]。在模型的求解过程中, 需要进行多次潮流计算。为降低计算规模, 本文采用 SVM 对潮流计算中的控制变量和状态变量进行非线性拟合, 以训练好的 SVM 代替后续求解过程中的每一次潮流计算。

SVM 是一种典型的机器学习算法, 其拟合公式如式(15)^[18]。

$$y(x) = \sum_{k=1}^N (\alpha_k - \alpha_k^*) K(x_i, x) + b \quad (15)$$

式中: y 、 x 分别为输出向量、输入向量, 对应于潮流计算中的控制变量和状态变量; x_i 为训练样本中的输入向量; $K(x_i, x)$ 为核函数, 一般采用高斯核函数; b 为偏置向量, $(\alpha_k - \alpha_k^*)$ 为输出权重, 二者均是训练过程中要确定的量。

本文采用随机抽样产生 DG 和 PEV 的功率样

本, 然后代入潮流方程进行计算(采用前推回代法), 得到各节点的电压幅值和相角(潮流状态变量), 以该样本对 SVM 进行训练。当 SVM 达到设定的训练精度后, 即可用来模拟潮流计算。

3.2 机会约束条件的检验

本文基于蒙特卡洛模拟的思路对机会约束条件进行检验。基于随机变量的概率分布函数, 对太阳辐照强度、风速、PEV 的充电时刻、行驶距离、放电时刻进行 N_s 次独立抽样并计算对应的功率值, 然后代入 SVM 中模拟随机潮流计算, 并计算每一次潮流计算结果是否满足馈线容量约束。假设 N_s 次独立抽样中, 有 N_F 次满足馈线容量约束, 最后判断 N_F/N_s 是否大于馈线传输容量不越限的置信水平 β : 如果大于 β , 则可认为其满足机会约束条件; 反之, 则认为不满足。

3.3 多目标粒子群算法

本文采用文献[19]提出的基于拥挤距离的多目标粒子群算法求解多目标 DG 优化配置问题。以各优化配置方案作为粒子的位置, 算法步骤如下。

1) 初始化。给定种群规模 M , 最大迭代步数 T_{\max} , 随机产生每个粒子的位置 p_i , 置每个粒子的速度 v_i 为 0。计算每个粒子的初始适应度矢量(即本文的 3 个目标函数), 筛选非劣解放入外部文档 A, 并将每个个体作为个体局部最优解。

2) 进行迭代寻优。每次从文档 A 的前 10% 随机挑选一个粒子作为当前全局最优位置 G , 按式(16)更新每个粒子的速度和位置。

$$\begin{cases} v_i = \omega v_{i-1} + c_1 r_1 (p_{ib} - p_i) + c_2 r_2 (G - p_i) \\ p_i = p_{i-1} + v_i \end{cases} \quad (16)$$

式中: ω 为惯性权重因子; c_1 、 c_2 为学习因子; r_1 、 r_2 为 $[0, 1]$ 的随机数; p_{ib} 为粒子 i 的局部最优值。更新过程中检查粒子位置是否越界, 若越界的话, 则将其位置更改为边界值并将粒子的飞行方向置为反向, 即 $-v_i$ 。

若迭代步数 $t \leq MP_m$, P_m 为变异率, 对粒子 p_i 执行高斯变异操作。计算每个粒子的适应度矢量, 将非劣解插入外部文档并删除文档中的劣解。当外部文档达到最大容量时, 计算非劣解的拥挤距离并排序, 从拥挤度较大的 10% 中随机选择一个粒子, 用新的非劣解将其替换。根据 Pareto 支配关系更新 p_{ib} , 进行下一次迭代。

3) 优化结果: 当达到最大迭代次数, 外部文档中的粒子即为该问题的 Pareto 最优解。

3.4 求解步骤

本文求解 DG 优化配置模型步骤如下。

1) 随机抽样产生 DG 和 PEV 的功率样本(假设各待选节点均接入 DG)进行潮流计算, 以潮流结果训练 SVM。

2) 初始化粒子, 即 DG 配置方案。

3) 采用蒙特卡洛方法和 SVM 进行随机潮流计算, 随机生成新的粒子替换不满足约束条件的粒子, 直至所有粒子满足约束条件。以随机潮流结果的期望值作为各优化目标。

4) 进行粒子更新, 当更新后的粒子不满足机会约束时, 采用步骤 3) 给出的替换方法, 当更新后的粒子不满足不等式约束时, 采用 3.3 节中的更改方法。

5) 至迭代结束, 输出 Pareto 解集, 并进行潮流计算验证。

4 算例分析

4.1 模型设置

本文以图 1 所示的 IEEE37 节点配电网为例^[20]对本文所提模型进行测试。系统电压等级 35 kV, 0 号节点为系统平衡节点, 系统基准容量为 15 MV, 系统总有功负荷为 12.285 MW, 总无功负荷为 6.005 Mvar, DG 最大渗透率为 40%。假设该系统共有 1000 辆 PEV, 均匀分布于各配变台区。DG 安装节点集合为 $\{1, 2, \dots, 35\}$ (节点 36 为变压器支路连接的末端节点, 不考虑接入 DG, 且各节点最多安装一种 DG)。线路容量的机会条件约束置信水平 β 设置为 0.85, 各节点电压偏移权重相同。假设光照强度分别服从 $k_s=1.4$ 、 $c_s=1.5$ 的 Weibull 分布, PV 的功率因数为 1.0; 风速服从 $k_w=2.1$ 、 $c_w=7.5$ 的 Weibull 分布, $v_r=15$ m/s, $v_{ci}=4$ m/s, $v_{co}=25$ m/s, WT 的功率因数为 0.9。

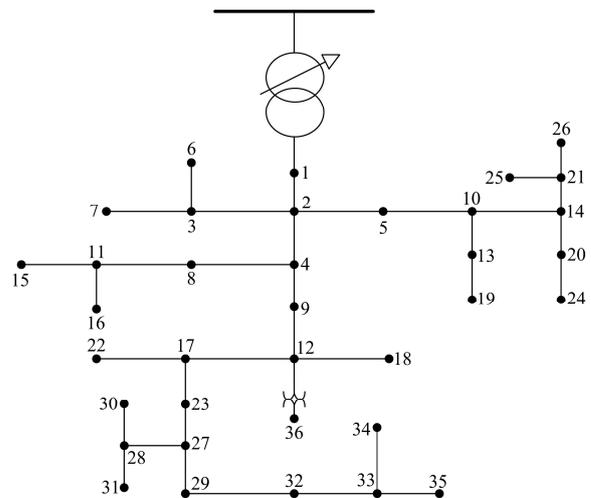


图 1 IEEE37 节点配电网系统

Fig. 1 IEEE 37-node distribution network system

SVM 训练样本的数量为 100, SVM 参数中惩

罚因子取 1, 高斯核参数取 0.1。多目标粒子群算法的参数设置如下: 种群规模 $M=100$, 最大迭代步数 $T_{\max}=200$, 惯性权重因子 $\omega=0.4$, 学习因子 $c_1=c_2=0.5$, 变异率 $P_m=0.5$, 外部文档 A 的容量为 50。

4.2 优化结果及分析

图 2 为采用本文模型和算法得到的 DG 配置 Pareto 解的目标函数空间分布, 即 Pareto 最优前沿。

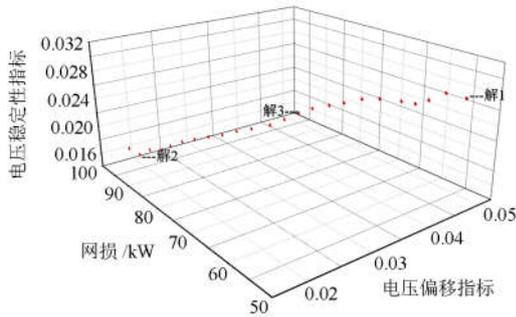


图 2 DG 配置的 Pareto 最优前沿

Fig. 2 Pareto optimal front of DG deployment

图中解 1、解 2、解 3 为具有代表性的几个最优配置方案: 解 1 为网络损耗最小对应的方案, 解 2 为电压稳定性能最优和电压偏移最小对应的方案, 解 3 为各指标均适中的一个典型方案, 各方案对比如表 1 所示。

表 1 各 DG 配置方案对比

Table 1 Comparison of DG deployment schemes

参数	未接入 DG 时	方案 1	方案 2	方案 3
PV 接入点	—	10-18-27-34	10-16-28-32-34	7-14-26-33
PV 容量/ (kW×10)	—	72-60-72-48	60-72-84-48-48	36-72-36-84
WT 接入点	—	14-16-26-31-33	8-14-26-31-35	11-19-31-34
WT 容量/ (kW×10)	—	84-60-60-84	48-72-36-36-36	48-36-84-72
网损/kW	213.9	53.3	92.3	73.4
电压稳定 指标	0.041	0.027	0.018	0.024
电压偏移	0.077	0.049	0.017	0.035

从表 1 可以看出, 大部分的 DG 电源位于网络的末端, 这是由于 DG 接入配网后, 改变了潮流分布, 使沿馈线传输的有功和无功功率减小, 从而提升各节点的电压水平并降低网损。相比于未接入 DG 时, 以上三种方案均较大幅度地降低了网损, 提升了电压水平和系统的电压稳定性。方案 1 较 DG 接入前, 网损降低了 75.08%; 方案 2 较 DG 接入前, 电压稳定指标提升了 56.1%, 电压偏移下降了 77.9%; 方案 3 较 DG 接入前, 网损降低了 65.68%, 电压稳定指标提升了 41.46%, 电压偏移下降了 54.55%。

为验证采用 SVM 进行拟合潮流计算的精确度和时效性, 将本文计算方法与直接采用前推回代法进行每一次潮流运算的方法进行对比, Pareto 最优前沿基本一致, 网络损耗最小及电压稳定性指标、电压偏移指标最优时对应的方案相同。在 Windows10 系统、4 GB RAM、I3-3.1 GHz CPU、Matlab7 平台上进行仿真时, 直接采用前推回代法进行每一次潮流运算的方法耗时 4 823.47 s, 采用本文方法耗时 673.23 s。结果说明了本文方法的有效性和在计算耗时方面的优越性。

5 结论

本文提出了一种配电网 DG 优化配置的模型: 采用机会约束规划方法考虑 DG 和 PEV 的不确定性; 采用 SVM 方法拟合配电网潮流运算; 采用多目标粒子群进行优化方案的求解。算例仿真证明本文方法能够得到合理的 DG 配置方案, 主要结论如下:

1) 采用多目标规划可以兼顾各个规划目标, 通过多目标优化方法得到 Pareto 解集, 有助于规划者从不同的需求出发进行决策。

2) 采用 SVM 对配电网潮流运算进行拟合, 在保证求解有效性的同时, 可以大幅降低计算规模和计算耗时。

3) DG 一般优先配置于配电网的末端, DG 的接入可以降低配电网的网络损耗, 并提升配电系统的电压水平和电压稳定性。

参考文献

- [1] GEORGILAKIS P S, HATZIARGYRIOU N D. Optimal distributed generation placement in power distribution networks: models, methods, and future research[J]. IEEE Transactions on Power Systems, 2013, 28(3): 3420-3428.
- [2] MA Z, CALLAWAY D S, HISKENS I A. Decentralized charging control of large populations of plug-in electric vehicles[J]. IEEE Transactions on Control Systems Technology, 2013, 21(1): 67-78.
- [3] EVANGELOPOULOS V A, GEORGILAKIS P S. Optimal distributed generation placement under uncertainties based on point estimate method embedded genetic algorithm[J]. IET Generation, Transmission & Distribution, 2013, 8(3): 389-400.
- [4] SUN Siyang, YANG Qiang, YAN Wenjun. Optimal temporal-spatial PEV charging scheduling in active power distribution networks[J]. Protection and Control of Modern Power Systems, 2017, 2(2): 379-388. DOI: 10.1186/s41601-017-0065-x.
- [5] EL-ELA A A A, ALLAM S M, SHATLA M M. Maximal optimal benefits of distributed generation using genetic algorithms[J]. Electric Power Systems Research, 2010,

- 80(7): 869-877.
- [6] 卢扬, 吴俊勇, 郝亮亮. 基于改进 MOBPSO 算法的含分布式电源的多目标配电网重构[J]. 电力系统保护与控制, 2016, 44(7): 62-68.
LU Yang, WU Junyong, HAO Liangliang. Multiobjective distribution network reconfiguration with distributed generations based on improved MOBPSO algorithm[J]. Power System Protection and Control, 2016, 44(7): 62-68.
- [7] 胡文平, 何立夫, 陈杰军, 等. 考虑大规模电动汽车接入电网的双层优化调度策略[J]. 电力系统保护与控制, 2016, 44(21): 22-28.
HU Wenping, HE Lifu, CHEN Jiejun, et al. A bi-layer optimization based schedule considering large-scale electric vehicles[J]. Power System Protection and Control, 2016, 44(21): 22-28.
- [8] 刘志鹏, 文福拴, 薛禹胜, 等. 计及可入网电动汽车的分布式电源最优选址和定容[J]. 电力系统自动化, 2011, 35(18): 11-16.
LIU Zhipeng, WEN Fushuan, XUE Yusheng, et al. Optimal siting and sizing of distributed generators considering plug-in electric vehicles[J]. Automation of Electric Power Systems, 2011, 35(18): 11-16.
- [9] 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. Multi-objective optimal allocation of distributed generation considering uncertainties of plug-in electric vehicles and renewable energy sources[J]. Power System Technology, 2015, 39(8): 2188-2194.
- [10] MUTOH N, MATUO T, OKADA K, et al. Prediction-data-based maximum-power-point-tracking method for photovoltaic power generation systems[C] // 2002 IEEE Power Electronics Specialists Conference, June 23-27, 2002, Cairns, Qld, Australia: 1489-1494.
- [11] ATWA Y M, EL-SAADANY E F, SEETHAPATHY R, et al. Effect of wind-based DG seasonality and uncertainty on distribution system losses[C] // 2008 40th North American Power Symposium, September 28-30, 2008, Calgary, AB, Canada: 1-6.
- [12] 葛少云, 王龙, 刘洪, 等. 计及电动汽车入网的峰谷电价时段优化模型研究[J]. 电网技术, 2013, 37(8): 2316-2321.
GE Shaoyun, WANG Long, LIU Hong, et al. An optimization model of peak-valley price time-interval considering vehicle-to-grid[J]. Power System Technology, 2013, 37(8): 2316-2321.
- [13] 刘辉, 魏岩岩, 汪旒, 等. 电动汽车入网调频控制策略研究[J]. 电力系统保护与控制, 2015, 43(23): 90-95.
LIU Hui, WEI Yanyan, WANG Ni, et al. V2G control for EVs participating in primary frequency regulation[J]. Power System Protection and Control, 2015, 43(23): 90-95.
- [14] 李亮, 唐巍, 白牧可, 等. 考虑时序特性的多目标分布式电源选址定容规划[J]. 电力系统自动化, 2013, 37(3): 58-63.
LI Liang, TANG Wei, BAI Muke, et al. Multi-objective locating and sizing of distribution generators based on time-sequence characteristics[J]. Automation of Electric Power Systems, 2013, 37(3): 58-63.
- [15] 夏澍, 周明, 李庚银. 分布式电源选址定容的多目标优化算法[J]. 电网技术, 2011, 35(9): 115-121.
XIA Shu, ZHOU Ming, LI Gengyin. Multi-objective optimization algorithm for distributed generation locating and sizing[J]. Power System Technology, 2011, 35(9): 115-121.
- [16] 管志成, 丁晓群, 张木银, 等. 考虑时序特性含电动汽车配电网分布式电源优化配置[J]. 电力系统保护与控制, 2017, 45(18): 24-31.
GUAN Zhicheng, DING Xiaoqun, ZHANG Muyin, et al. Optimal allocation of distributed generation of distributed network containing electric vehicle considering timing characteristics[J]. Power System Protection and Control, 2017, 45(18): 24-31.
- [17] RANJAN R, DAS D. Voltage stability analysis of radial distribution networks[J]. Electric Power Components & Systems, 2001, 23(2): 129-135.
- [18] QI X, LI K, WANG J, et al. Transformer top-oil temperature combination modeling based on thermal circuit and support vector machine[C] // 2016 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC), October 25-28, 2016, Xi'an, China: 1933-1937.
- [19] RAQUEL C R, NAVAL JR P C. An effective use of crowding distance in multiobjective particle swarm optimization[C] // Proceedings of the 7th Annual Conference on Genetic and Evolutionary Computation, ACM, 2005: 257-264.
- [20] IEEE Distribution System Analysis Subcommittee. IEEE radial test feeders[EB/OL]. [2013-08-05]. <http://www.ewh.ieee.org/soc/pes/dsacom/testfeeders/index.html>.

收稿日期: 2017-12-13; 修回日期: 2018-02-27

作者简介:

王满商(1986—), 男, 博士研究生, 研究方向为分布式发电运行控制和微电网电能质量分析与控制;

李正明(1958—), 男, 通信作者, 教授, 博士生导师, 研究方向为微电网电能质量分析与控制, 智能电网与电力系统远程监控等; E-mail: lzming@ujs.edu.cn

汪洋(1978—), 男, 博士, 副教授, 硕士生导师, 研究方向为新能源发电技术, 微电网电能质量分析与控制, 智能电网与电力系统远程监控等。

(编辑 魏小丽)