

DOI: 10.19783/j.cnki.pspc.221696

含固态变压器新型配电网动态无功多目标优化

孙汝羿, 袁至, 王维庆, 何山

(新疆大学可再生能源发电与并网控制教育部工程研究中心, 新疆 乌鲁木齐 830017)

摘要: 风机和光伏电池等分布式电源(distributed generator, DG)大量接入配电网会导致电压波动和网损增大等问题, 需要对动态无功进行优化。但是由于风光存在的不确定性会影响动态无功优化的效果, 因此提出了一种含固态变压器新型配电网动态无功多目标优化方法。首先, 通过 Weibull 分布和 Beta 分布对风速和光照强度进行曲线拟合, 再采用风机和光伏电池出力公式生成 DG 出力模型。其次, 通过蒙特卡洛仿真抽样法对上述模型进行抽样, 生成上千个 DG 日出力场景, 并采用 k -means 聚类算法将上千个场景聚类成 k 个典型场景, 以缩短随机潮流计算时间。再次, 以 IEEE33 节点系统为基础, 建立含固态变压器有源配电网方案和含有载调压变压器有源配电网方案, 以日内网损和电压波动最小为目标, 采用改进型多目标灰狼算法对两种方案的相关参数进行优化。最后, 以优化后的相关参数进行仿真和对比, 证明了所提方法在降低配电网网损和维持节点电压稳定方面的优越性。

关键词: 固态变压器; 分布式电源; 无功优化; 多目标灰狼算法; 配电网

Multi-objective optimization of dynamic reactive power in a new distribution network with a solid state transformer

SUN Ruyi, YUAN Zhi, WANG Weiqing, HE Shan

(Engineering Research Center Renewable Energy Power Generation and Grid-connected Control,
Ministry of Education, Xinjiang University, Urumqi 830017, China)

Abstract: A large number of distributed generators (DG), such as wind power generators and photovoltaic cells, will be connected to the power distribution network, resulting in voltage fluctuation and active network loss increase. The dynamic reactive power needs to be optimized. However, wind-solar uncertainty will affect the effect of dynamic reactive power optimization. Thus this paper proposes a multi-objective intelligent optimization method for the dynamic reactive power of a distribution network with a solid state transformer (SST) considering wind-solar uncertainty. First, the wind speed and light intensity are fitted by the Weibull and Beta distributions, and then the output formulas of wind power generators and photovoltaic cells are used to generate the DG output model. Second, Monte Carlo simulation sampling is used to sample the above model to generate thousands of daily DG output scenarios, and the k -means clustering algorithm is used to cluster thousands of scenarios into several typical scenarios to shorten the calculation time of random power flow. Third, based on the IEEE33 node system, an active distribution network scheme with the SST and an active distribution network scheme with on-load tap changer transformer are established. To minimize the active power loss and node voltage fluctuation of the distribution network, the relevant parameters of the two schemes are optimized using an improved multi-objective gray wolf optimizer (MOGWO) algorithm. Finally, the optimized parameters are simulated and compared to prove the superiority of the proposed method in reducing network loss and maintaining node voltage stability.

This work is supported by the National Natural Science Foundation of China (No. 52067020).

Key words: SST; DG; reactive power optimization; MOGWO; distribution network

0 引言

分布式电源(distributed generator, DG)以环保和

灵活布局的优势, 近年来得到了不少关注。根据相关机构预测, 2030年 DG 装机容量可达 505 GW, 占同期全国总装机的 17.3%^[1]。总的看来, DG 占比逐年增加。DG 大量接入配电网, 使配电网的结构变得复杂。同时, DG 出力的不确定性和间歇性会导致配电网的潮流分布、稳定性和安全性受到影响^[2]。

基金项目: 国家自然科学基金项目资助(52067020); 新疆维吾尔自治区重点实验室开放课题资助(2022D04081)

然而, 电力系统的传统静态无功优化方法只能得到某一特定场景的优化策略。新型的动态无功优化可以考虑 DG 和负荷的动态变化以及无功设备的动作次数, 与静态无功优化相对比, 更能体现配电网运行状况。因此, 对含 DG 的配电网动态无功优化进行研究的意义尤为突出。

目前, 已有大量关于各种传统无功控制的研究。其中, 最常用的设备类型是有载调压变压器(on-load tap changer, OLTC)和电容器组(capacitor banks, CBs)^[3]。但有载调压变压器的分接头与投切电容器只能分组调节, 调节精度差, 分接头频繁动作会增加系统故障概率。并且在无功优化开环控制的情况下, 有载调压变压器频繁调节, 不仅会加重维护人员的工作强度, 并且可能会因操作设备过多产生操作失误, 不利于系统的安全运行。而固态变压器(solid state transformer, SST)作为一种新型的电力电子器件, 可通过改变其一二二次侧的调制角和调制系数实现有功转移、无功补偿和电压转换等一体化功能, 替代传统变压器和无功补偿器^[4], 其原理图如图 1 所示。

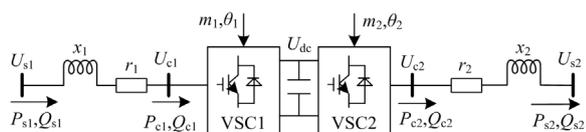


图 1 SST 原理图

Fig. 1 Principle diagram of the SST

目前, SST 的研究主要集中在拓扑结构^[5]和控制策略^[6], 应用于配电网无功优化方面的研究相对较少。其中, 文献[7]首次提出了将 SST 替代 OLTC 对配电网进行无功优化, 仿真结果表明 SST 在降低配电网网损方面优于 OLTC, 但未考虑分布式电源接入对无功优化的影响。文献[8]在文献[7]的基础上引入 DG 接入配电网进行仿真, 进一步验证了 SST 在无功优化方面的优越性。文献[9-10]又在文献[8]的基础上采用了天牛须算法以及细菌觅食算法等智能优化算法, 以进一步减少含 SST 有源配电网的网损。文献[11]通过并联 OLTC 以及 SST 共同进行无功优化。文献[12]通过利用 SST 双向无功的特性来降低径向配电网网损。以上文章虽验证了 SST 在配电网无功优化方面的优越性, 但均未考虑 DG 出力波动对配电网无功优化的影响。为此, 为了更真实地模拟现实中 DG 对配电网的影响, 考虑 DG 出力波动, 对含 SST 的有源配电网进行动态无功优化意义重大。

针对以上不足, 本文提出了含固态变压器新型配电网动态无功多目标优化方法。首先, 获取某地全年风速和光照强度建立概率密度直方图, 对风速和光照强度分别通过 Weibull 分布和 Beta 分布进行曲线拟合得到概率密度函数, 采用风机和光伏电池出力公式生成 DG 出力模型; 其次, 通过蒙特卡洛仿真抽样法对上述模型进行抽样, 生成上千个 DG 日出力场景, 并采用 k -means 聚类算法将上千个场景聚类成 k 个典型场景, 以减少潮流计算时间, 其中 k 值的确定通过手肘法来实现; 再次, 以 IEEE33 节点系统为基础, 建立含固态变压器有源配电网方案和含有载调压变压器有源配电网方案, 以日内网损和电压波动最小为目标, 采用改进型多目标灰狼优化算法(multi-objective grey wolf optimizer, MOGWO)对两种方案相关参数进行优化; 最后, 以优化后得到的固态变压器的调制角和调制系数以及 OLTC 的档位、电容器投切组数等参数对两种方案进行仿真和对比, 验证了所提出方法的可行性以及优越性。

1 DG 出力模型

1.1 风电机组出力模型

选择某地风电站全年风速数据样本构建概率密度直方图, 如图 2 所示。

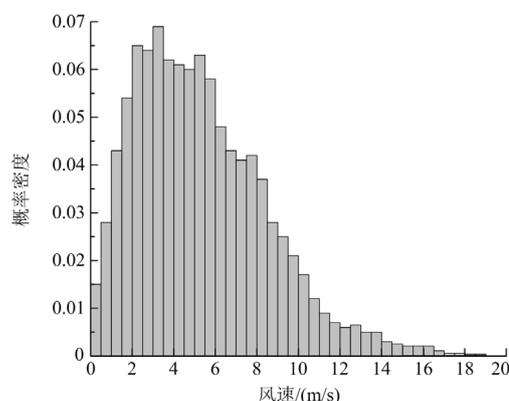


图 2 风速概率密度直方图

Fig. 2 Histogram of wind speed probability density

采用 Weibull 分布^[13]对风速概率密度直方图进行曲线拟合, 得到风速概率密度函数 $W(v)$ 。

$$W(v) = \frac{\rho}{\lambda} \left(\frac{v}{\lambda} \right)^{\rho-1} e^{-\left(\frac{v}{\lambda}\right)^\rho} \quad (1)$$

式中: λ 、 ρ 为根据风速概率密度直方图曲线拟合得到的参数; v 表示风速, 单位为 m/s。

风机有功出力 P_w 与风速 v 的关系满足式(2)。

$$P_w = \begin{cases} 0, & 0 \leq v \leq v_{ci} \text{ 或 } v > v_{co} \\ P_r \frac{v - v_{ci}}{v_r - v_{ci}}, & v_{ci} < v \leq v_r \\ P_r, & v_r < v \leq v_{co} \end{cases} \quad (2)$$

式中： v_r 和 P_r 分别表示风机的额定风速和额定功率； v_{ci} 和 v_{co} 分别表示切入风速和切出风速。

1.2 光伏电池出力模型

选择某地全年 06:00—17:00 光照强度数据样本构建光照强度概率密度直方图，如图 3 所示。

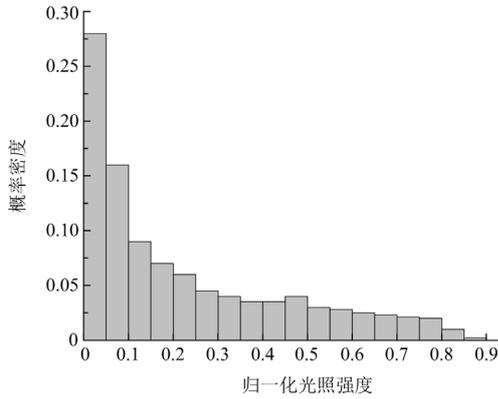


图 3 光照强度概率密度直方图

Fig. 3 Histogram of probability density of illumination intensity

采用 Beta 分布^[14]对概率密度直方图进行曲线拟合，得到概率密度函数 $B\left(\frac{r}{r_{\max}}\right)$ 。

$$B\left(\frac{r}{r_{\max}}\right) = \frac{\Gamma(\lambda + \eta)}{\Gamma(\lambda)\Gamma(\eta)} \left(\frac{r}{r_{\max}}\right)^{\lambda-1} \left(1 - \frac{r}{r_{\max}}\right)^{\eta-1} \quad (3)$$

式中： λ 、 η 为通过光照概率密度直方图进行曲线拟合得到的两个参数； $\Gamma(\cdot)$ 和 r 分别表示 Gamma 函数和光照强度，其中光照强度的单位为 W/m^2 。

光伏发电的有功功率 P_s 与光照强度 r 存在如式(4)所示的关系。

$$P_s = Ar\eta \quad (4)$$

式中， A 和 η 分别表示光伏电池板的面积和电能转换率。

2 基于场景法的随机潮流计算

概率潮流的设想在 1974 年被 Borkowska 首次提出。进入 21 世纪以来，随着新型计算机的不断发展，概率潮流的实现成为了可能。目前概率潮流的计算方法有解析法、近似法以及模拟法^[15-16]。其中蒙特卡洛模拟法进行概率潮流计算的精准度最高，但是该方法需要进行大规模采样，增加了潮流计算

时间。为此，本文采用 k -means 算法将风机、光伏电池的大量数据缩减为 k 个典型场景，在不影响求解精度的前提下缩短潮流计算时间。

2.1 场景生成及随机潮流计算

本文采用蒙特卡洛抽样法分别对建立的风机、光伏电池板出力模型进行抽样，采样次数为 1000 次，每次包含 24 个时刻的有功出力，采样得到的数据采用矩阵 N 表示，大小为 $a \times b$ ，即 1000×24 ，表示 1000 个 DG 日出力场景。考虑到 DG 占比较小，且有功出力总是低于其额定功率，故进行潮流计算时，DG 均假设以 PQ 节点形式接入电网。

2.2 k -means 聚类算法场景缩减

2.1 节所抽样得到的 1000 个 DG 出力场景数目太多，会导致潮流计算时间成本大大增加。为此，考虑通过采用 k -means 聚类算法来解决^[17]。首先从矩阵 N 中任意选取 k 个场景作为聚类中心 M_i ；其次通过计算欧氏距离，将其他数据划分到与聚类中心最近的簇类 $W(j)$ 中；然后重新计算簇类 $W(j)$ 的聚类中心与上次数据进行对比更新；最后，重复上述步骤直至聚类中心不再变化为止。 k -means 聚类流程图如图 4 所示。

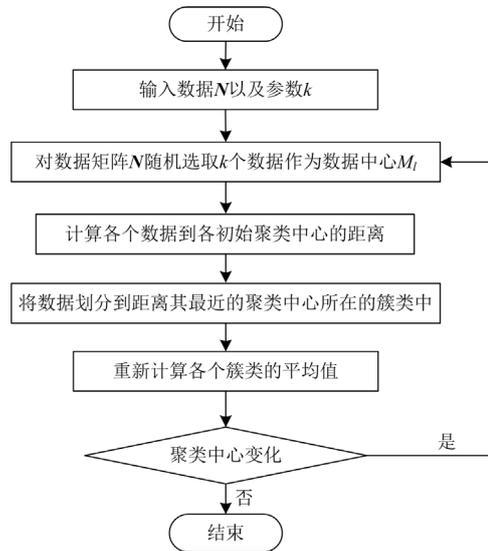


图 4 k -means 聚类流程图

Fig. 4 Flow chart of k -means clustering

2.3 手肘法确定 k 值

k -means 聚类算法 k 值的选择往往是通过经验来确定，这就导致 k 值的选择难免受到主观因素影响，缺乏公正、合理性。为此，本文采用手肘法^[18]实现 k 值的选择。该方法最为重要的指标为误差平方和 e_{SSE} ，如式(5)所示。

$$e_{SSE} = \sum_{j=1}^k \sum_{y \in W(j)} \|y - M(j)\|_2 \quad (5)$$

除此之外, 还有 s_{SH} 和 g_{CH} 系数两个较为重要的评价指标。

$$s_{SH} = \frac{B - A}{\max\{A, B\}} \quad (6)$$

$$g_{CH} = \frac{\left(\frac{\sum_{j=1}^k c_j \|M(j) - z\|_2}{k - 1} \right)}{\left(\frac{\sum_{j=1}^k \sum_{y \in W(j)} \|y - M(j)\|_2}{a - k} \right)} \quad (7)$$

式中: A 为某一簇类全部样本点到其中一个样本点的平均距离; B 为某个样本点与其本身所在簇以外簇全部样本点的平均距离的最小值; z 为数据集的中心。

表 1 为通过手肘法对风光数据样本确定场景数目时的评价指标, 图 5 为将风机、光伏电池的大量数据缩减为 k 个典型场景时与 e_{SSE} 之间的关系。

表 1 场景数目为 3, 4, 5 时的评价指标

Table 1 Evaluation indicators when the number of scenarios is 3, 4 and 5

场景类型	场景数目	e_{SSE}	s_{SH}	g_{CH}
风	3	1 234 891	0.068	71.479
	4	1 217 549	0.053	58.936
	5	1 197 423	0.051	53.631
光	3	649 427	0.073	79.508
	4	634 821	0.065	65.302
	5	623 419	0.067	61.092

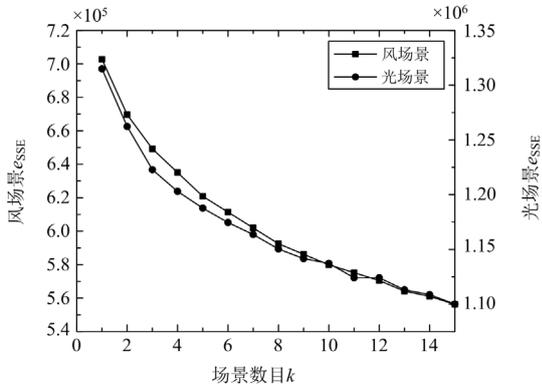


图 5 场景数目与 e_{SSE} 的关系

Fig. 5 Number of scenarios versus e_{SSE}

从图 5 中可以看出, 随着风光场景数目 k 值的不断增大, e_{SSE} 不断减小, 但依旧处于一个较高的水平, k 值太大也违背减少潮流计算时间的初衷。从表 1 可以看出, 随着场景数 k 的增加, s_{SH} 系数和 g_{CH} 指标是不断减小的。其中, s_{SH} 系数越接近 1 表明聚类效果越好, g_{CH} 指标越大表明簇自身越紧密。综合评价得到聚类场景数目 $k = 3$ 时聚类效果为最佳的。

本文将 1000 个时间序列场景聚类为 3 个场景后, 风电、光伏 DG 有功出力分别如图 6 和图 7 所示。

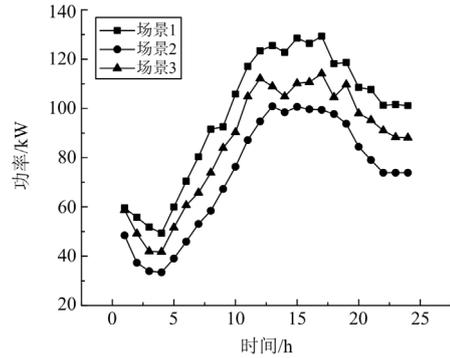


图 6 风电 DG 出力

Fig. 6 Output of wind power DG

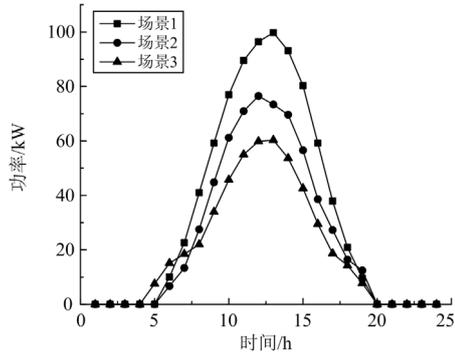


图 7 光伏 DG 出力

Fig. 7 Output of photovoltaic DG

3 多目标有源配电网优化模型

3.1 目标函数

无功优化最基本的目的是尽可能大地降低网损以及保证电压波动在允许范围之内, 尽可能保持电压稳定; 因此, 本文无功优化的目标函数为: 有功网损 F_{loss} 和电压偏移量 $F_{\Delta u}$ 。

$$F_{loss} = \min f_{loss} = \sum_{t=1}^T \sum_{i,j \in N_L} G_{ij} [(u_i^t)^2 + (u_j^t)^2 - 2u_i^t u_j^t \cos(\theta_{ij}^t)] \quad (8)$$

$$F_{\Delta u} = \min f_{\Delta u} = \sum_{t=1}^T \sum_{i=1}^{N_{bus}} \left(\frac{u_i^t - u_i^{spec}}{u_{i,max}^t - u_{i,min}^t} \right)^2 \cdot u_{i,max}^t \quad (9)$$

式中: F_{loss} 和 $F_{\Delta u}$ 分别表示 T 个时刻的总网损以及总电压偏移量的最小值; f_{loss} 和 $f_{\Delta u}$ 分别表示 T 个时刻的总网损以及总电压偏移量; 配电网所有的支路构成的集合用 N_L 表示; u_i^t 和 u_i^{spec} 分别表示 t 时刻 i 节点电压和电压期望, 电压期望通常设为 1.0 p.u.; $u_{i,\text{max}}^t$ 和 $u_{i,\text{min}}^t$ 分别表示节点电压的最大值和最小值; 配电网每条支路的电导用 G_{ij} 表示, 相角差用 θ_{ij} 表示; 下标 i, j 表示支路集合 N_L 中的每条支路的节点编号; 配电网的节点总数用 N_{bus} 表示。

3.2 约束条件

1) 系统潮流方程

$$\begin{cases} P_i = u_i \sum_{j=1}^{N_{\text{bus}}} u_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ Q_i = u_i \sum_{j=1}^{N_{\text{bus}}} u_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (10)$$

式中: P_i 和 Q_i 分别表示 i 节点的发电机与负荷有功、无功的差; B_{ij} 为支路电纳。

2) 配电网不等式约束

$$\begin{cases} u_{i,\text{min}} \leq u_i \leq u_{i,\text{max}} \\ 0 \leq P_{i,\text{DG}} \leq P_{i,\text{DG},\text{max}} \\ Q_{i,\text{DG},\text{min}} \leq Q_{i,\text{DG}} \leq Q_{i,\text{DG},\text{max}} \\ C_{k,\text{min}} < C_k < C_{k,\text{max}} \\ T_{i,\text{min}} < T_i < T_{i,\text{max}} \end{cases} \quad (11)$$

式中: $P_{i,\text{DG}}$ 与 $Q_{i,\text{DG}}$ 分别表示 i 节点接入的分布式电源有功功率以及无功功率; C_k 和 T_i 分别表示电容器的组数和 OLTC 分接头的档位。

3) SST 控制变量约束和功率约束

$$\begin{cases} 0 < m_1, m_2 \leq 1 \\ -45^\circ < \theta_1, \theta_2 < 45^\circ \\ \sqrt{P_{ci}^2 + Q_{ci}^2} \leq S_c \end{cases} \quad (12)$$

式中: P_{ci} 、 Q_{ci} 分别表示 VSC 两侧输入、输出的有功和无功功率; S_c 表示视在功率; m_1 、 m_2 表示 SST 的调制系数; θ_1 、 θ_2 表示 SST 的调制角。

3.3 多目标优化算法

3.3.1 灰狼优化算法

灰狼优化(grey wolf optimizer, GWO)算法是由澳大利亚学者首次提出的智能优化算法^[19]。该算法通过模拟狼群狩猎而得来, 具有简单易实现、需求参数少等优点。算法的基本思路为狼群朝向狼王 α 以及狼王左右护法 β 、 γ 移动, 移动以后重新确定

α 、 β 和 γ 。其中 α 、 β 和 γ 为目前已知解的最优解、优解和次优解。狼群个体 ω 朝 α 、 β 和 γ 的引导方程 D_p 为

$$D_p = CX_p^t - X_{\text{position}}^t \quad (13)$$

$$X_{\text{position}}^{t+1} = \frac{1}{3} \sum_{p=\alpha,\beta,\gamma} (X_p^t - AD_p) \quad (14)$$

$$\begin{cases} A = 2\alpha r_1 - \alpha \\ C = 2r_2 \\ \alpha = 2 - 2t/t_{\text{max}} \end{cases} \quad (15)$$

式中: X_p^t 为根据头狼 α 、 β 和 γ 位置而得出的引导位置; X_{position}^t 为第 t 次迭代中个体狼的位置; 最大迭代次数为 t_{max} ; r_1 、 r_2 为随机数, 取值为 0~1; A 、 C 以及 α 分别为系数向量以及收敛因子。

3.3.2 MOGWO 算法

Mirjalili 等人对 GWO 算法进行了部分改进, 有了可适用于多目标问题的 MOGWO 智能优化算法^[19]。具体改进如下所述。

1) 引入外部存档 Archive 机制

MOGWO 算法在迭代求解的过程中, 为了记录非支配解引入外部存档 Archive。在不断迭代的过程中, 外部存档 Archive 存储的非支配解通过对比不断更新, 更新所遵循的原则如下: 算法迭代产生的新的个体不能支配外部存档 Archive 中的任意个体, 则该个体不能并入外部存档; 若迭代产生的新个体至少可支配外部存档 Archive 中的一个个体, 则新个体可以并入外部存档中。其中, 若外部存档 Archive 个体数目达到最大值, 则淘汰拥挤度距离最小的个体, 个体拥挤度距离 $D(i)$ 计算如式(16)所示。

$$D(i) = \sum_{j=1}^n \frac{f_i(j+1) - f_i(j-1)}{f_{i,\text{max}} - f_{i,\text{min}}} \quad (16)$$

式中: n 表示目标函数的个数; $f_i(j+1)$ 和 $f_i(j-1)$ 分别表示与个体 j 相邻的两个个体的第 i 个目标函数值; $f_{i,\text{max}}$ 为外部存档中所有粒子第 i 个目标函数的最大值; $f_{i,\text{min}}$ 为其中的最小值。

2) 头狼选择方式

MOGWO 算法在 Archive 种群选择头狼利用轮盘赌的方式确定。其中, Archive 种群任意一个被选为头狼的概率为 P_i 。

$$P_i = \left(\frac{1}{N_i} \right)^c \quad (17)$$

式中: c 为轮盘赌系数, 按实际需要设定, 且满足 $c > 1$; N_i 为 Archive 种群数量, 它与 P_i 成反比。

3.3.3 MOGWO 算法的改进

1) 增加动态搜索因子

为了避免 MOGWO 算法陷入局部最优, 引入动态搜索因子 q , 通过每次迭代不断修改 q 的值来改变狼群移动的步长, 从而加快该算法的收敛速度, 避免陷入局部最优。动态搜索因子 q 为

$$q = q_{\text{end}} + \frac{(q_{\text{start}} - q_{\text{end}})(d_{\text{max}} - d)}{d_{\text{min}}} \quad (18)$$

式中: q_{start} 为初始搜索因子; q_{end} 为终止搜索因子; d_{max} 为 MOGWO 算法求解的最大迭代次数。

引入动态搜索因子后的 X_{position}^d 为

$$X_{\text{position}}^d = \frac{1}{3} \sum_{p=\alpha, \beta, \lambda} (X_p^d - AD_p)q \quad (19)$$

2) 非支配解的选择

为了能从非支配集中选取最佳解, 目前最为常用的是采用权重分析法, 但每部分评判指标的权重往往是人为定夺, 难免受到个人主观影响, 公正、客观性得不到保证。为此, 本文采用熵权法^[20]来确定每部分评判指标所占的权重。具体步骤如下。

(1) 标准化

标准矩阵 Y : Y 的任意一个数 Y_{ij} 可用式(20)来表示。

$$Y_{ij} = \frac{x_{ij} - \min(x_i)}{\max(X_i) - \min(X_i)} \quad (20)$$

式中: 优化方案为 n 个, 评判指标为 k 个的决策矩阵用 $X = [X_1, X_2, \dots, X_k]$ 表示, 其中每个优化方案第 i 个评判指标用 $X_i = [X_{i1}, X_{i2}, \dots, X_{in}]^T$ 表示, x_{ij} 为决策矩阵 X 中第 i 行 j 列的值。

(2) 信息熵

由信息熵的定义得到数据的信息熵 E_j , 可由式(21)表示。

$$\begin{cases} E_j = -\ln(n)^{-1} \sum_{i=1}^n p_{ij} \ln p_{ij} \\ p_{ij} = \frac{Y_{ij}}{\sum_{i=1}^n Y_{ij}} \end{cases} \quad (21)$$

(3) 确定权重

每个评判指标所占的权重用 W_i 表示。

$$W_i = \frac{1 - E_i}{k - \sum E_i} \quad (22)$$

3.3.4 改进型 MOGWO 算法验证

为了验证改进型 MOGWO 算法的优越性, 本文将改进型 MOGWO 算法、MOGWO 算法与改进多

目标粒子群算法^[21](multi-objective particle swarm optimization, MOPSO)进行对比, 采用常用的多目标基准测试函数 ZDT1、UF2 和 UF4 进行验证。其中 ZDT1 函数测试次数和迭代次数分别设置为 200 和 100; UF 系列函数测试次数和迭代次数分别设置为 20 和 1000; 选用评价指标为世代距离(generational distance, GD)和逆世代距离(inverted generational distance, IGD); 测试所用计算机配置为: CPU 为 i5-6200U, 主频为 2.4 GHz, 12 G RAM, 显卡为 GeForce 940MX, 操作系统为 Windows10 64 位操作系统, 仿真平台为 Matlab2020(a)。经仿真测试得到了 GD 指标评价结果和 IGD 指标评价结果, 详细数据分别如表 2 和表 3 所示。

表 2 GD 指标评价结果

Table 2 Evaluation results of GD index

测试函数	算法	均值	最差值	最优值	峰值
UF2	MOPSO	0.113 28	0.160 07	0.067 84	0.092 23
	MOGWO	0.060 42	0.120 45	0.026 43	0.094 02
	改进型 MOGWO	0.002 79	0.005 98	0.001 97	0.004 01
UF4	MOPSO	0.080 36	0.090 41	0.071 50	0.018 91
	MOGWO	0.058 49	0.064 16	0.052 49	0.011 67
	改进型 MOGWO	0.053 74	0.054 39	0.051 30	0.003 09
ZDT1	MOPSO	0.063 97	0.394 81	0.003 94	0.390 87
	MOGWO	0.021 46	0.074 73	0.001 76	0.072 97
	改进型 MOGWO	0.008 03	0.015 09	0.001 33	0.013 76

表 3 IGD 指标评价结果

Table 3 Evaluation results of IGD index

测试函数	算法	均值	最差值	最优值	峰值
UF2	MOPSO	0.097 40	0.124 57	0.083 42	0.041 15
	MOGWO	0.070 42	0.084 59	0.056 43	0.028 16
	改进型 MOGWO	0.029 43	0.043 76	0.014 03	0.029 73
UF4	MOPSO	0.789 40	0.094 09	0.067 82	0.026 27
	MOGWO	0.064 37	0.060 30	0.059 39	0.000 91
	改进型 MOGWO	0.057 06	0.057 14	0.055 39	0.001 75
ZDT1	MOPSO	0.067 42	0.347 95	0.009 43	0.338 52
	MOGWO	0.052 47	0.069 15	0.008 47	0.060 68
	改进型 MOGWO	0.013 01	0.031 48	0.007 35	0.024 13

测试结果表明, 对于 ZDT1 函数来说, 改进型 MOGWO 算法的 GD 和 IGD 指标优化结果明显优于其他算法, 说明改进型 MOGWO 算法跳出局部最优解的能力优于其他算法。对于多模函数 UF2 和 UF4 来说, 改进型 MOGWO 算法的 GD 和 IGD 指标优化结果依旧明显优于其他算法, 验证了改进型 MOGWO 算法跳出局部最优解的能力优于其他算法。同时,

对比改进型 MOGWO 算法与其他算法的峰值,在大多数情况下,改进型 MOGWO 算法的峰值是最小的,说明了改进型 MOGWO 算法稳定性优于其他算法。

4 算例仿真

4.1 参数设置

为了验证含 SST 的有源配电网在降低网损和维持节点电压稳定方面的优越性,本次研究在文献[22]提及的 IEEE33 节点配电系统上,设置了两组方案进行对比,两组方案的配电网模型分别如图 8 和图 9 所示。方案一:含 OLTC 的有源配电网^[23];方案二:含 SST 的有源配电网^[22]。

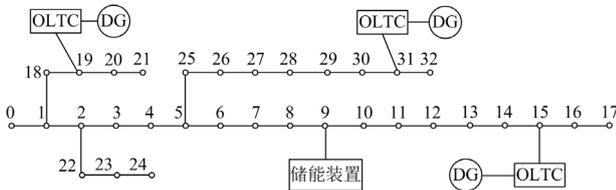


图 8 含 OLTC 的有源配电网
Fig. 8 Active distribution network with OLTC

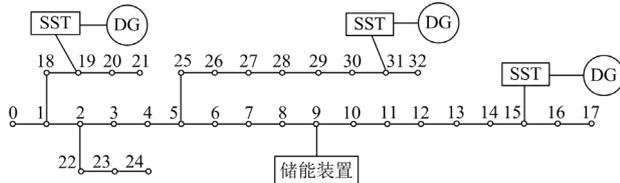


图 9 含 SST 的有源配电网
Fig. 9 Active distribution network with SST

修改后的配电网系统包括:

1) 2 台 150 kW、功率因数为 0.95 的风机(wind turbine, WT) DG, 其中 $v_{ci} = 3 \text{ m/s}$ 、 $v_r = 12 \text{ m/s}$ 、 $v_{co} = 15 \text{ m/s}$; 1 台 150 kW, 功率因数为 0.95 的光伏(photovoltaic, PV) DG, 其中, $A = 3 \text{ m}^2$ 、 $\eta = 22.4\%$; 其中, 方案一的 2 台 WT 分别接入 15、31 节点 OLTC 的二次交流侧, 1 台 PV 则接入 19 节点 OLTC 的二次交流侧。方案二 2 台 WT 通过直流并入的方式接入 15、31 节点 SST 的高压直流母线上, 1 台 PV 则通过直流并入的方式接入 19 节点的 SST 的直流母线上。该方法可减少电力电子器件的使用, 节约投资, 充分发挥 SST 的即插即用的直流端口的作用。

2) 9 节点接入电池储能系统, 最大充放电容量 100 kW;

3) 15、19、31 节点接入 OLTC 或 SST, OLTC 变比为 $0.9 + 8 \times 2.5\%$, SST 的相关参数参考文献[24];

4) 方案一的 OLTC 因自身不能为系统提供无功, 故方案一的 15、19、31 节点接入无功补偿电容, 每个节点无功补偿电容共 $10 \times 50 \text{ kvar}$ 。方案二则不接入。

5) 改进型 MOGWO 算法参数设置: 狼群规模 $M_w = 200$, Archive 种群数 $N_w = 20$; 惩罚因子 $r_k = 0.8$, 递增系数 $k = 1.2$, 轮盘赌系数 $c = 2$, $\theta_{start} = 1.2$, $\theta_{end} = 0.4$, 最大迭代次数 $t_{max} = 100$ 。

4.2 优化策略

由于篇幅的限制, 本文只对其中一个场景进行分析, 改进型 MOGWO 算法流程图如图 10 所示; 方案一和方案二通过改进型 MOGWO 求得的非支配

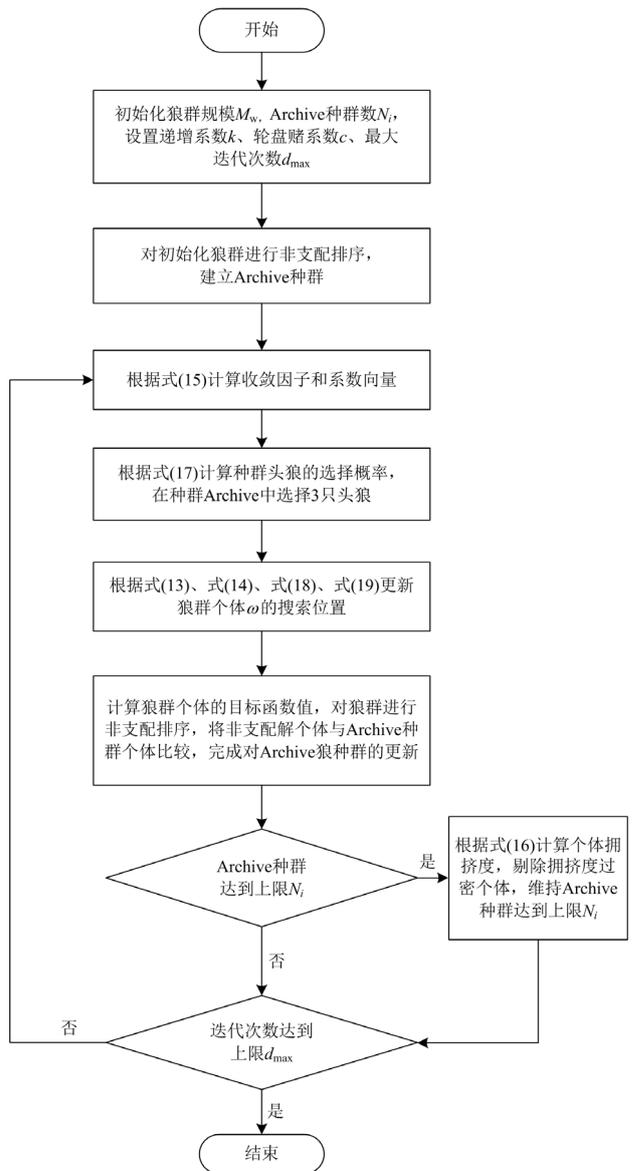


图 10 改进型 MOGWO 算法流程图
Fig. 10 Flowchart of improved MOGWO algorithm

解分别如图 11、图 12 所示；方案一的部分优化策略如图 13、图 14 所示，分别表示接入配电网的 OLTC 的挡位数以及并联电容器的无功补偿量。方案二的优化策略如图 15、图 16 所示，分别表示接入配电网的 SST 一次侧的调制角和调制系数。图 17 为方案一、方案二接入储能的充放电策略。

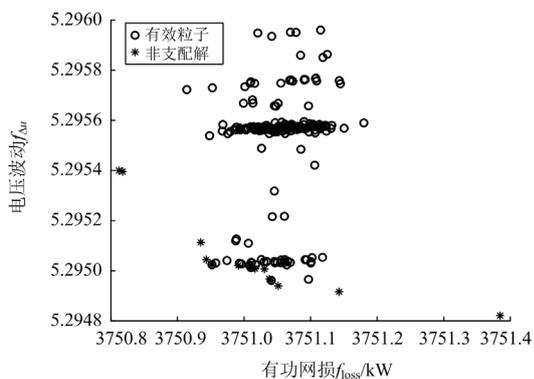


图 11 方案一的非支配解

Fig. 11 Pareto solution set of scheme 1

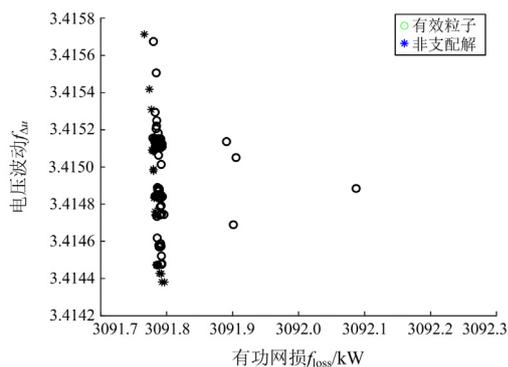


图 12 方案二的非支配解

Fig. 12 Pareto solution set of scheme 2

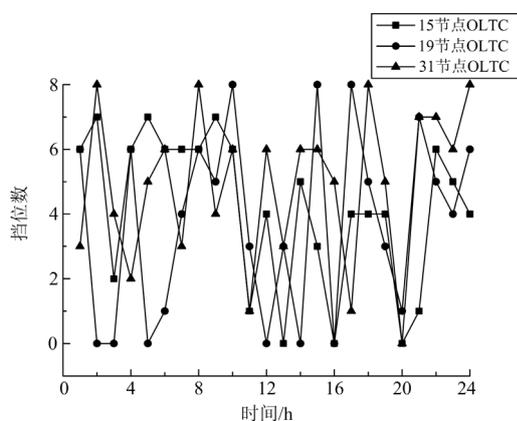


图 13 含 OLTC 的有源配电网 OLTC 挡位图

Fig. 13 OLTC tap diagram of active distribution network with OLTC

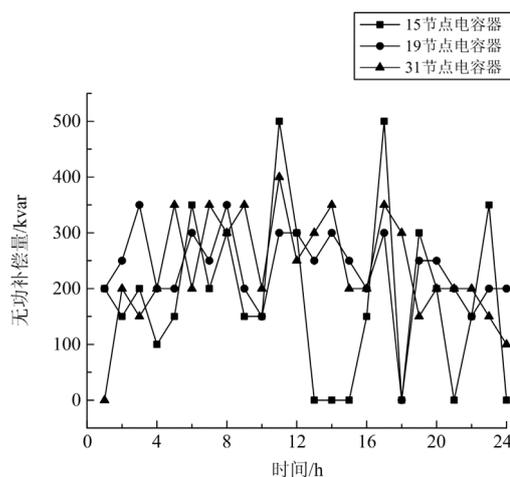


图 14 含 OLTC 的有源配电网电容器无功补偿量

Fig. 14 Number of capacitor banks in active distribution network with OLTC

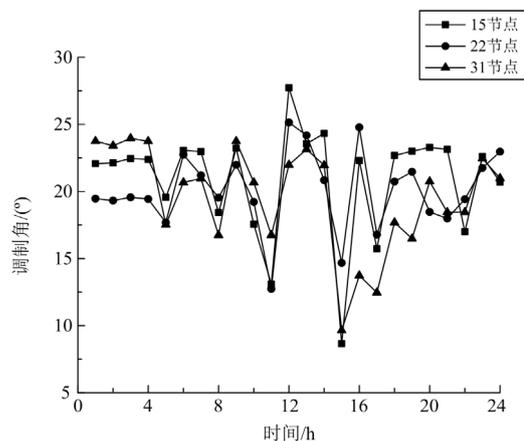


图 15 SST 的调制角

Fig. 15 Modulation angle of SST

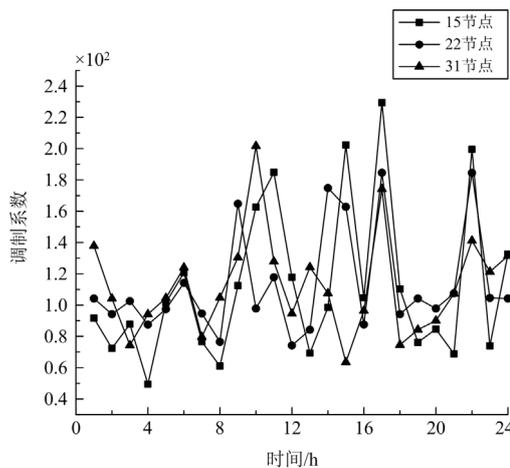


图 16 SST 的调制系数

Fig. 16 Modulation coefficient of SST

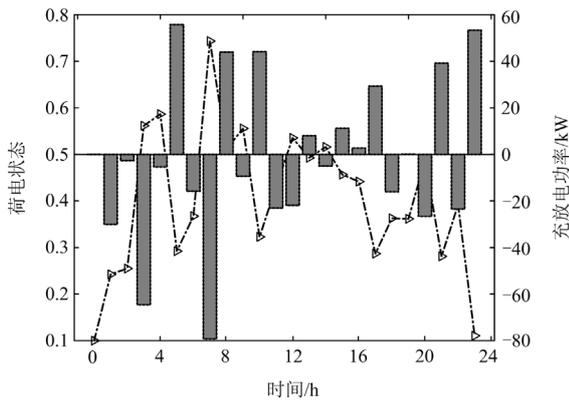


图 17 储能充放电策略

Fig. 17 Charging and discharging strategies for energy storage

4.3 网损对比分析

图 18 为日内网损柱状分析图。从图 18 中可以明显看出，方案二优化后相较于优化前以及方案一优化后的网损都有着明显降低。其中方案二优化后日内网损为 3091.67 kW，相较于优化前网损降低了 1576.19 kW，降比达到 33.77%。相较于方案一优化后日内网损降低了 659.52 kW，降比达到了 17.58%。

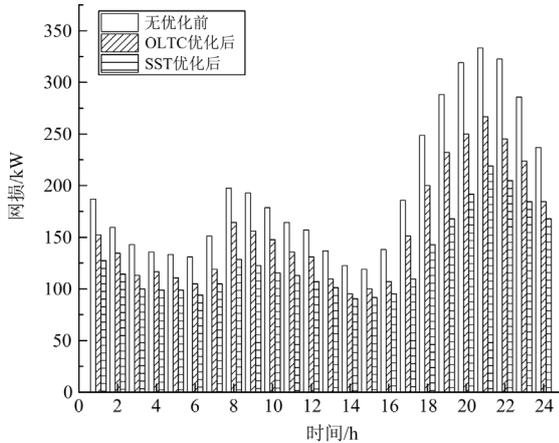


图 18 日内网损柱状图

Fig. 18 Histogram of intranet loss in one day

4.4 电压对比分析

图 19、图 20 分别为方案一、方案二优化后的节点电压图。图 21 是由每个方案优化后的 24×33 个采样点统计而来，24 代表一天的 24 个小时，33 代表配电网的节点数量。其中，节点电压小于 0.95 p.u.或大于 1.05 p.u.表示电压越限，方案一共有 103 个采样点处于该电压范围，方案二共有 38 个采样点处于该电压范围，方案二相较于方案一有明显减少。另外，方案一在电压范围 0.95~1.05 p.u.共有 689 个采样点，采样点电压平均值为 0.968 p.u。方

案二在电压范围 0.95~1.05 p.u.共有 754 个采样点，采样点电压平均值为 0.971 p.u。综上分析，方案二相对方案一显著提升了电压稳定性。

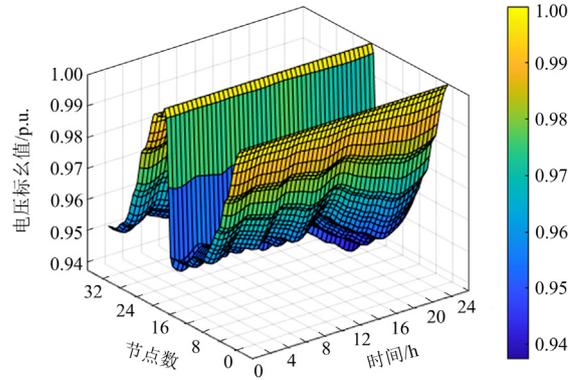


图 19 含 OLTC 的有源配电网节点电压图

Fig. 19 Voltage diagram of active distribution network node with OLTC

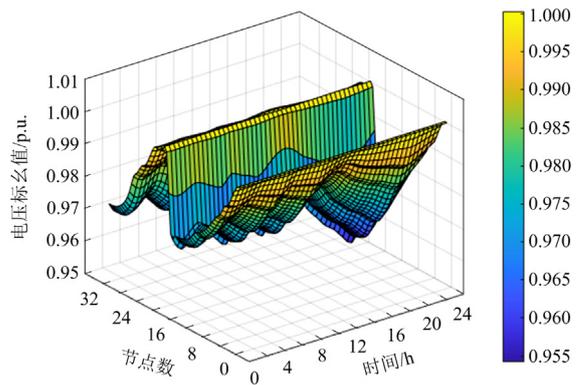


图 20 含 SST 的有源配电网节点电压图

Fig. 20 Voltage diagram of active distribution network node with SST

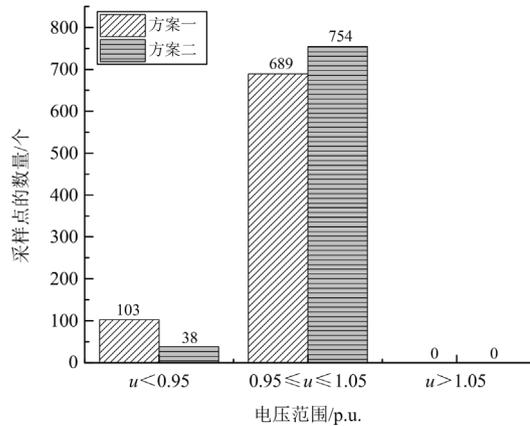


图 21 两种方案优化后的节点电压统计图

Fig. 21 Optimized node voltage statistics of the two schemes

5 结论

本文针对风机和光伏出力存在的不确定性和间歇性导致配电网网损和节点电压偏移增大等问题, 提出了利用固态变压器对新型配电网动态无功多目标优化方法, 得到了如下结论:

1) 在风机、光伏电池出力波动时, 含 SST 的有源配电网无功优化后的网损和电压波动相较于含 OLTC 的有源配电网无功优化后的网损和电压波动有着明显改善, 说明该方法在降低配电网网损和维持节点电压稳定方面的优越性。

2) k -means 聚类算法能减少通过蒙特卡洛抽样方法得到的风机以及光伏电池有功出力的场景, 大大节约了潮流计算所需要的时间成本。

3) 改进型 MOGWO 算法相较于传统 MOGWO 以及 MOPSO 算法有着更好的跳出局部最优解的能力; 同时, 改进型 MOGWO 算法求解的稳定性也明显优于其他算法。

随着电力电子技术的不断发展, 采用电力电子器件代替 OLTC 对配电网进行动态无功优化优势明显。本文研究尚存在一些不足, 未对 SST 的器件损耗和调节代价成本进行分析, 这将是未来的研究重点。

参考文献

- [1] 侯慧, 王晴, 薛梦雅, 等. 计及源荷不确定性及需求响应的离网型微电网两阶段日前经济调度[J]. 电力系统保护与控制, 2022, 50(13): 73-85.
HOU Hui, WANG Qing, XUE Mengya, et al. Two-stage economic day-ahead dispatch of an islanded microgrid considering uncertainty and demand response[J]. Power System Protection and Control, 2022, 50(13): 73-85.
- [2] 梁恩豪, 孙军伟, 王延峰. 基于自适应樽海鞘算法优化 BP 的风光互补并网发电功率预测[J]. 电力系统保护与控制, 2021, 49(24): 114-120.
LIANG Enhao, SUN Junwei, WANG Yanfeng. Wind and solar complementary grid-connected power generation prediction based on BP optimized by a swarm intelligence algorithm[J]. Power System Protection and Control, 2021, 49(24): 114-120.
- [3] 从帆平, 周建萍, 茅大钧, 等. 基于改进教与学算法的含电能路由器的电力系统无功优化[J]. 电力建设, 2022, 43(6): 110-118.
CONG Fanping, ZHOU Jianping, MAO Dajun, et al. Reactive power optimization of power system with electric energy router applying modified teaching-learning algorithm[J]. Electric Power Construction, 2022, 43(6): 110-118.
- [4] 李子欣, 高范强, 赵聪, 等. 电力电子变压器技术研究综述[J]. 中国电机工程学报, 2018, 38(5): 1274-1289.
LI Zixin, GAO Fanqiang, ZHAO Cong, et al. Research review of power electronic transformer technologies[J]. Proceedings of the CSEE, 2018, 38(5): 1274-1289.
- [5] 苗虹, 周宇鑫, 曾成碧, 等. 一种含高效率输入级及多端口输出级的固态变压器[J]. 电力科学与技术学报, 2018, 33(3): 57-63.
MIAO Hong, ZHOU Yuxin, ZENG Chengbi, et al. Solid state transformer with high efficient input stage and multiport output stage[J]. Journal of Electric Power Science and Technology, 2018, 33(3): 57-63.
- [6] KHAN N H, WANG Y, TIAN D, et al. Optimal siting and sizing of SSSC using modified salp swarm algorithm considering optimal reactive power dispatch problem[J]. IEEE Access, 2021, 9: 49249-49266.
- [7] 崔艳艳. 基于电子电力变压器的配电网无功电压优化控制[D]. 武汉: 华中科技大学, 2006.
- [8] 张祥龙, 周晖, 肖智宏, 等. 电力电子变压器在有源配电网无功优化中的应用[J]. 电力系统保护与控制, 2017, 45(4): 80-85.
ZHANG Xianglong, ZHOU Hui, XIAO Zhihong, et al. Power electronic transformer applied to optimization of reactive power in active distribution system[J]. Power System Protection and Control, 2017, 45(4): 80-85.
- [9] 张晓英, 侯秉臣, 王琨, 等. 基于改进天牛须算法的含固态变压器的配电网无功优化[J]. 高压电器, 2022, 58(11): 221-229.
ZHANG Xiaoying, HOU Bingchen, WANG Kun, et al. Reactive power optimization of distribution network with solid state transformer based on improved beetle antennae search algorithm[J]. High Voltage Apparatus, 2022, 58(11): 221-229.
- [10] 杨文静. 基于蚁群算法考虑 SST 的主动配电网无功优化控制研究[D]. 天津: 天津大学, 2019.
- [11] SHI J, YANG W, XUE F, et al. Reactive power optimization of active distribution network under parallel condition of solid state transformer and on-load tap changer[C] // 2019 22nd International Conference on Electrical Machines and Systems (ICEMS), August 11-14, 2019, Harbin, China.
- [12] IMRAN S, VINOD K, HATEM Z. Loss reduction in radial distribution networks using solid-state transformer[J]. IEEE Transactions on Industry Applications, 2018, 54(5): 5474-5482.
- [13] 崔森, 颜湘武, 李锐博. 提高双馈风电机组动态无功协调控制能力的实验研究[J]. 电力系统保护与控制, 2022, 50(8): 117-129.

CUI Sen, YAN Xiangwu, LI Ruibo. Experimental research on improving the dynamic reactive power coordinated control capability of doubly-fed induction wind turbine[J]. Power System Protection and Control, 2022, 50(8): 117-129.

[14] 黄伟, 刘斯亮, 王武, 等. 长时间尺度下计及光伏不确定性的配电网无功优化调度[J]. 电力系统自动化, 2018, 42(5): 154-162.

HUANG Wei, LIU Siliang, WANG Wu, et al. Optimal reactive power dispatch with long-time scale in distribution network considering uncertainty of photovoltaic[J]. Automation of Electric Power Systems, 2018, 42(5): 154-162.

[15] 刘宇, 高山, 杨胜春, 等. 电力系统概率潮流算法综述[J]. 电力系统自动化, 2014, 38(23): 127-135.

LIU Yu, GAO Shan, YANG Shengchun, et al. Review on algorithms for probabilistic load flow in power system[J]. Automation of Electric Power Systems, 2014, 38(23): 127-135.

[16] 闫桂杭, 班国邦, 余斌, 等. 考虑风光接入的柔性互联配电网概率潮流算法研究[J]. 供用电, 2022, 39(5): 41-47, 60.

YAN Guihang, BAN Guobang, YU Bin, et al. Research on probabilistic power flow algorithm of flexible interconnected distribution network with wind and solar access[J]. Distribution & Utilization, 2022, 39(5): 41-47, 60.

[17] 傅明, 童超, 单松兴, 等. 基于多项式正态变换和拟蒙特卡洛法的概率潮流计算[J]. 江西电力, 2022, 46(7): 1-4, 9.

[18] 王建仁, 马鑫, 段刚龙. 改进的 K-means 聚类 k 值选择算法[J]. 计算机工程与应用, 2019, 55(8): 27-33.

WANG Jianren, MA Xin, DUAN Ganglong. Improved K-means clustering k-value selection algorithm[J]. Computer Engineering and Applications, 2019, 55(8): 27-33.

[19] 何思名, 袁智勇, 雷金勇, 等. 基于改进灰狼算法的 DG 接入配电网反时限过电流保护定值优化[J]. 电力系统保护与控制, 2021, 49(18): 173-181.

HE Siming, YUAN Zhiyong, LEI Jinyong, et al. Optimal setting method of inverse time over-current protection for a distribution network based on the improved grey wolf optimization[J]. Power System Protection and Control, 2021, 49(18): 173-181.

[20] 张艺驰, 姜凤利, 周吉一, 等. 基于多场景含双馈风机的配电网无功优化[J]. 可再生能源, 2018, 36(7): 1027-1032.

ZHANG Yichi, JIANG Fengli, ZHOU Jiyi, et al. Reactive power optimization for distribution network with doubly fed induction generators in multiple scenarios[J]. Renewable Energy Resources, 2018, 36(7): 1027-1032.

[21] 闫群民, 董新洲, 穆佳豪, 等. 基于改进多目标粒子群算法的有源配电网储能优化配置[J]. 电力系统保护与控制, 2022, 50(10): 11-19.

YAN Qunmin, DONG Xinzhou, MU Jiahao, et al. Optimal configuration of energy storage in an active distribution network based on improved multi-objective particle swarm optimization[J]. Power System Protection and Control, 2022, 50(10): 12-19.

[22] 刘畅. 基于改进细菌觅食算法的含固态变压器配网重构综合优化[D]. 北京: 华北电力大学, 2018.

[23] 周立, 王杰, 谢磊, 等. 含分布式电源的配电网多目标无功优化[J]. 重庆邮电大学学报(自然科学版), 2022, 34(5): 818-827.

ZHOU Li, WANG Jie, XIE Lei, et al. Multi-objective reactive power optimization of distribution network with distributed generation[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2022, 34(5): 818-827.

[24] 刘云. 基于电子电力变压器的电力系统稳定性研究[D]. 武汉: 华中科技大学, 2013.

收稿日期: 2022-10-25; 修回日期: 2023-02-08

作者简介:

孙汝羿(1998—), 男, 硕士研究生, 主要从事配电网无功优化方面的研究; E-mail: 2606120349@qq.com

袁至(1984—), 男, 通信作者, 博士研究生, 副教授, 主要从事风力发电及控制、并网技术方面的研究。E-mail: yzisthecure@163.com

(编辑 魏小丽)