

文章编号: 2095-2163(2023)08-0080-08

中图分类号: TMT3

文献标志码: A

基于大象优化算法的分布式能源的选址与定容

左超文, 刘敏, 何旺

(贵州大学 电气工程学院, 贵阳 550025)

摘要: 随着“双碳”战略的不断推进, 新能源装机并网数量不断增长, 使得电力系统结构形态发生深刻变化, 实现低碳、绿色、环保发展已经成为全人类的共识。因此, 分布式发电也受到人们的高度重视, 分布式能源(DER)在配电网中的合理配置至关重要, 若是DER接入配电网的位置以及容量选择不合理, 则会造成配电网线路损耗、节点电压越线和运行费用增加等。本文引入了一种新颖的方法来解决DER接入配电网的选址与定容的问题, 该方法通过与逼近理想排序法和改进的大象放牧优化算法相结合。从而得到了一个复杂的现实生活多目标DER规划问题, 并利用本文提出的方法进行求解。目的是确定分布式能源在配电系统当中的最佳地点和容量大小, 以最大限度地提高公用事业和消费者的整体利益。并将所提出的方法在IEEE33节点上进行仿真。基于IEEE33节点算例的仿真结果表明以及对比其它文献所用的方法, 本文所提出的优化方法对于DER接入配电网的选址与定容的问题具有更好的全局收敛效率和寻优能力。

关键词: 分布式能源(DER); 配电系统; 象群优化算法; 自然启发

Siting and capacity setting of distributed energy resources based on elephant optimization algorithm

ZUO Chaowen, LIU Min, HE Wang

(College of Electrical Engineering, Guizhou University, Guiyang 550025, China)

【Abstract】 With the continuous advancement of the “double carbon” strategy, the number of new energy installed and connected to the grid is increasing, which makes the structure of the power system change profoundly. It has become the consensus of all mankind to achieve low-carbon, green and environmental protection development. Therefore, distributed generation is becoming more and more prominent in the world. The rational allocation of distributed energy (DER) in distribution network is very important. If the location and capacity of DER access to distribution network are unreasonable, it will cause distribution network line loss, node voltage crossing and operation cost increase. This paper introduces a new method to solve the problem of location and capacity of DER access to distribution network. This method is combined with the approximate ideal sequence method and the improved elephant grazing optimization algorithm. Thus, a complex multi-objective DER planning problem in real life is obtained and solved by the method proposed in this paper. The aim is to determine the optimal location and capacity of distributed energy in distribution systems to maximize the overall interests of utilities and consumers. The proposed method is simulated on IEEE33 node. Based on the simulation results of the IEEE33 node example and the comparison with the methods used in other literatures, the proposed optimization method has better global convergence efficiency and optimization ability for the location and sizing of DER access distribution network.

【Key words】 distributed energy resources (DERs); distribution systems; elephant optimization algorithm; natural inspiration

0 引言

自然启发优化方法在解决各种现实生活问题中发挥着至关重要的作用, 其中有些问题可能非常困难, 甚至无法使用一般的分析方法解决。截至目前, 相关文献中已经提出了许多基于鸟类、蜜蜂、蚂蚁、蝙蝠、大象、猫、狼等行为的受遗传学、神经系统和群

体智能启发的优化算法^[1]。比如广为熟知的遗传算法^[2]和粒子群算法^[3]等等, 这些算法被广泛应用于解决各种复杂的电力系统优化问题, 并且在搜索全局或接近全局的解决方案方面非常有效。

分布式电源接入配电网, 实现就地消纳, 不仅可以提高新能源的利用率, 而且可以提高电压质量和降低系统网损^[4]。然而, 接入点位置和容量的差异

作者简介: 左超文(1998-), 男, 硕士研究生, 主要研究方向: 需求响应、优化调度; 刘敏(1972-), 女, 教授, 主要研究方向: 电力系统分析、电力系统优化、电力市场等; 何旺(1998-), 男, 硕士研究生, 主要研究方向: 经济调度、优化调度。

收稿日期: 2022-08-23

哈尔滨工业大学主办 ◆ 学术研究与应用

对配电网的影响不同。如果位置和容量不合适,可能会导致系统中某处电压越线,网损和维护费用增加,所以研究 DER 接入配电网的接入位置和容量大小十分有必要^[5]。然而,最初的配电网络并不是为了适应分布式能源的高渗透率而设计的,分布式电源的接入也会对配电网产生明显的影响,并且不同的位置和容量产生的影响也不相同^[6]。为了减轻 DER 配置的适得其反的影响,配电系统中 DER 数量并不是越多越好,而是应该有一个最佳的容纳数量和最佳地点^[7]。因为只有最佳 DER 调节 (ODERA) 才可以提供巨大的技术经济和社会效益,例如最小化功率、电压偏差、DER 容量、以及温室气体排放,同时提高电压稳定性、瞬态稳定性和可靠性^[8]。分布式系统中 DER 的最佳适应是一个混合整数、非线性和非凸优化问题,通常由 DER 的数量、位置、大小和类型组成。

考虑到上述 DER 选址与定容的多个目标,ODERA 问题也因此成为一个多目标优化问题,其中有 2 个或多个优化目标。考虑到被优化的目标之间有可能相互冲突,因此需要一个精确的多目标公式。通过分配权重或将其与惩罚函数相乘,可以将多目标问题转化为单目标问题,其中常用的技术包括加权和^[9]、目标规划^[10]、基于 ε 约束的方法。但是这些技术存在一定的局限性,例如加权和方法的最优解取决于所选的权重,在目标规划中必须指定预先指定的目标,并且在 ε 约束方法中需要指定主目标和从目标。然而,上述方法的一些局限性可以通过模糊化、最大-最小方法和基于模糊的目标规划来克服^[11],这些方法将所有目标置于相同的规模和单位,但可能没有提供均匀分布的帕累托前沿的内在机制。采用正态边界交算法,得到均匀分布的 Pareto 前沿^[12]。但是,该方法在一开始独立确定个体的最佳值,忽略了其他目标的影响。因此,当不同单元和尺度的所有目标都同等重要时,一种强大的多准则决策 (MCDM) 制定方法^[13]有助于为多目标 DER 选址与定容问题提供一个折衷解决方案。

本文介绍了一种新的自然启发方法象群优化算法 (EHO),用于解决实际工程问题。这种方法的灵感来自大象的放牧行为。针对实际的多目标优化问题,对原有的算法进行了改进。此外,将 MCDM 方法与所提出的 EHO 相结合,以此在多目标实际问题中遇到的各种解决方案中选择最折衷的方案。提出了一个新的现实生活中的混合整数、非线性和非凸优化、多目标 ODERA 问题,以确定 DER 在配电系

统当中的最佳地点和规模大小,从而最大限度地提高公用事业和消费者的整体利益。最后,将此方法在 IEEE33 节点系统上进行有效仿真。将获得的结果与相关文献进行比较。比较结果表明,本文所提出的优化方法对于 DER 的容纳问题具有更好的全局收敛效率和寻优能力。

1 多目标问题数学模型

在本节中,多目标 ODERA 问题由多个不同的 DER 技术组成,旨在优化多个同样重要的目标^[14]。但是在实际中,需求是变化的,在不同需求下确定的 ODERA 可能并不是最优的;因此,提出的 DER 规划问题是针对系统指定的额定负载需求而制定的。下面将对所考虑的目标函数、约束条件和 TOPSIS (优劣解距离法) 方法进行解释。

1.1 目标函数

在实际中,配电公司必须从多方面考虑来保证自己的利益,同时也应该让用户有良好的用电体验。因此,在配电系统中,下面 3 个重要的目标应该是 ODERA 在配电系统当中需要考虑的。分别是功率损失最小化、节点电压偏差最小化和电压稳定指数 (VSI) 的最大化^[15-21]。

1.1.1 功率损失最小化

在垂直一体化电力系统中,配电系统在电力输送过程中会出现功率损失,这毫无疑问会影响配电公司的总收入。所以对于配电公司来说,功率损失最小化是一个主要目标,即以最小的损失输送电力。其公式可以表示如下:

$$\min f_1 = \sum_{i=1}^N \sum_{j=1}^N \alpha_{ij} (P_i P_j + Q_i Q_j) + \beta_{ij} (Q_j P_j - P_i Q_i) \quad (1)$$

其中, $\alpha_{ij} = r_{ij} \cos(\delta_i - \delta_j) / V_i V_j$, $\beta_{ij} = r_{ij} \sin(\delta_i - \delta_j) / V_i V_j$; N 表示系统中节点数; P_i 和 Q_i 分别表示每个节点的有功功率和无功功率注入; r_{ij} 表示 i 个节点和节点 j 之间的分支电阻; V_i 和 δ_i 表示第 i 个节点电压的幅值和相角。

1.1.2 节点电压偏差最小化

随着人们生活水平的不断提高,现代电力消费者对电源电压的质量要求也越来越高,都希望可以有一个好的用电体验。节点电压偏差是衡量系统节点上电压质量的指标^[15]。因此,节点电压调节是电网公司的一项基本职责,在整个系统中提供经过调节的节点电压曲线。在提出的最优 DER 集成模型中,节点电压调节被视为目标函数之一,其公式表示

如下:

$$\min f_2 = \sum_{j=1}^N (V_j - 1)^2 \quad (2)$$

1.1.3 电压稳定指数 (VSI) 的最大化

节点电压偏差的最小化并不是定义配电系统安全水平的充分保证。因此, VSI 也被作为目标函数之一, 以最大化系统的电压稳定裕度 (VSM)。VSI 是系统安全的一个衡量标准, 定义了一个节点在各种重载条件下将其电压曲线维持在可接受范围内的能力^[16]。电网公司的目标是使所有分支的 VSI 值接近于统一, 以保证电力网络的安全运行。连接节点 i 和 j 的分支的 VSI 可以表示为:

$$VSI_{ij} = V_j^4 - 4(P_i r_{ij} + Q_i r_{ij}) V_j^4 - 4(P_i x_{ij} - Q_i r_{ij})^2 \quad (3)$$

其中, x_{ij} 表示连接节点 i 和节点 j 支路的阻抗。为了改善整个系统的 VSM, 需要使在所有系统支路中具有最小 VSI 值的支路的 VSI 最大化。因此, 提议的 VSM 最大化的目标函数可以表示为:

$$\max f_3 = \min \langle VSI_{ij} \rangle \quad \forall ij \quad (4)$$

1.2 约束条件

上述的公式(1)、(2)和(4)中提出的目标函数有以下约束条件:

$$P_i = V_i \sum_{j=1}^N V_j Y_{ij} \cos(\theta_{ij} + \delta_i - \delta_j) \quad \forall i \quad (5)$$

$$Q_i = -V_i \sum_{j=1}^N V_j Y_{ij} \sin(\theta_{ij} + \delta_i - \delta_j) \quad \forall i \quad (6)$$

$$S_{DER_i} \leq S_{DER}^{max} \quad \forall i$$

$$V_{min} \leq V_i \leq V_{max} \quad \forall i \quad (7)$$

$$\sum_{i=1}^N \sigma_i S_{DER_i} \leq S_{peak} \quad (8)$$

式(5)~式(8)约束分别表示节点功率平衡、单个 DER 的最大容量、节点电压极限、DER 的渗透率。

1.3 使用 TOPSIS 方法的多目标优化模型

多目标问题可以表示为:

$$\text{optimize} = [f_1(x), f_2(x), f_3(x), \dots, f_{n_2}(x)] \quad (9)$$

服从 $x \in C$, 其中 $f_j(x) : R_n \rightarrow R$ 是第 j 个目标函数, $j = 1, 2, \dots, n_2$, $n_2 > 1$, C 为可行搜索空间。

TOPSIS 方法是常用的综合评价方法, 能充分利用原始数据信息, 精确反映各评价方案之间的差距^[17]。TOPSIS 法可翻译为逼近理想排序法, 国内常将其简称为优劣解距离法, 是一种综合评价方法, 能够充分利用原始数据的信息, 精确反映各个方案

之间的差距^[17]。简单来说, 就是在给出所有的方案之后, 根据已有的数据, 构造出一个所有方案组成的系统中的理想最优解 (PIS) 和最劣解 (NIS), PIS 指的是该理想方案中的各项指标都取到最优值, NIS 则是方案中的各项指标都取到最劣值。其中中心思想为通过计算来评估系统中任何一个方案距离 PIS 和 NIS 的综合距离。如果存在某个方案距离理想 PIS 最近, 距离 NIS 最远, 那么也就认为这个方案为最佳方案。如上文所讨论的, TOPSIS 方法被用来制定和解决配电系统的多目标 ODERA 问题。该方法基于欧几里得几何距离, 通过求出各个方案与 PIS 和 NIS 的综合距离来确定最佳方案。因此, 选择的替代方案应该与 PIS 的欧几里得距离最小, 与 NIS 的距离最大。可以通过下面这个表达式来进行衡量:

$$\frac{\text{某一方案} - \text{最劣解}}{\text{理想最优解} - \text{最劣解}} \quad (10)$$

通过上述表达式可以看出, 若是方案取到理想最优解, 表达式值为 1, 反之取到最劣解则值为 0。

通过这种方式, 可以发现解决方案集中在其各自的最佳解决方案周围, 从而提高了现实生活中的多目标优化问题的解决方案质量。TOPSIS 方法为提出的多目标问题找到折衷的解决方案的基本步骤如下:

步骤 1 准备一个标准化决策矩阵, 将所有维度属性转换为无维度属性。矩阵的元素可以表示为:

$$r_{ij} = \frac{f_{ij}}{\sqrt{\sum_{i=1}^{n_1} f_{ij}^2}} \quad \forall i \in n_1 \quad \text{and} \quad j \in n_2 \quad (11)$$

其中, n_1 和 f_{ij} 分别是备选方案的数量和第 j 个目标的第 i 个备选方案的值。

步骤 2 如果需要, 可以构建一个加权归一化决策矩阵来为目标提供权重。如果所有目标都同等重要, 则可以跳过该步骤。矩阵的元素可以表示为:

$$v_{ij} = \omega_j \times r_{ij} \quad \forall i \in n_1 \quad \text{and} \quad j \in n_2 \quad (12)$$

其中, ω_j 是第 j 个目标的权重, 并且 $\sum_{i=1}^{n_2} \omega_j$ 。

步骤 3 PIS 和 NIS 被确定, 并分别保持每个单独目标的最佳和最差解决方案, 如下所示:

$$PIS = \{v_1^+, v_2^+, v_3^+, \dots, v_{n_2}^+\} \quad (13)$$

$$NIS = \{v_1^-, v_2^-, v_3^-, \dots, v_{n_2}^-\} \quad (14)$$

其中,

$$v_j^+ = \begin{cases} \max \langle v_{ij} \rangle \\ \min \langle v_{ij} \rangle \end{cases} \quad \forall i$$

$$v_j^- = \begin{cases} \max\langle v_{ij} \rangle \\ \min\langle v_{ij} \rangle \end{cases} \quad \forall i$$

步骤 4 欧几里得距离 d_i^+ 和 d_i^- 分别根据 *PIS* 和 *NIS* 计算每个备选方案:

$$d_i^+ = \sqrt{\sum_{j=1}^{n_2} (v_{ij} - v_j^+)^2} \quad \text{and} \quad (15)$$

$$d_i^- = \sqrt{\sum_{j=1}^{n_2} (v_{ij} - v_j^-)^2}$$

步骤 5 通过使用步骤 4 计算的欧几里得距离, 计算每个备选方案的相对接近指数 (*RCI*), 如下所示:

$$C_i^+ = \frac{d_i^-}{d_i^+ + d_i^-} \quad (16)$$

具有最高 *RCI* 值的备选方案将被选为最优的解决方案。

2 改进的大象放牧优化算法

EHO 算法是 Wang 等学者^[18] 在 2015 年提出的一种受自然启发的方法。该算法的创作灵感来自于象群的放牧行为。大象研究人员发现, 雌性大象 (FE) 通过大象踩踏地面和低频漫步产生的地震波进行交流, 从而来保护自己的幼崽免受饥饿的捕食者的侵害。这一发现表明, 大象能够通过脚感觉到这些振动, 并将其视为遥远危险的警告信号。EHO 中大象社会行为阐释如图 1 所示。




图 1 EHO 中大象社会行为

Fig. 1 Social behavior of elephants adopted in EHO

在自然界中, 大象是群居动物, 有着复杂的社会结构。大象群一般由几个氏族和幼崽组成, 其中首领通常是年纪最长的母象。在氏族之中的雄象 (ME) 成长至一定年龄之后就会离开氏族, 从而导致氏族更新。并使用低频振动与象群进行接触联

系, 如图 2 所示。每个氏族中的大象数量可以假定相等。母系氏族长, 也就是女首领在大象群中拥有一个最佳的位置, 也就是最优的一个解决方案, 而最差的是由其他雄象们的相对位置决定的。




图 2 提出的 IMOEHO 中使用的个体结构

Fig. 2 Individuals' structure used in the proposed IMOEHO

2.1 大象放牧优化算法 (EHO)

在本文中, 大象的放牧行为的数学建模分为以下步骤:

步骤 1 位置更新。在此步骤中, 每一个大象在不同氏族中的位置 (每个氏族中拥有最佳和最差解决方案的母系族长和 ME 除外) 将更新为:

$$Z_{new,cj,i} = Z_{cj,i} + \alpha(Z_{best,cj,i} - Z_{cj,i}) \times r \quad (17)$$

其中, $Z_{cj,i}$ 和 $Z_{new,cj,i}$ 是第 i 头大象在第 cj 个部落的当前位置和最新位置; α 是设置为 0-1 之间的比例因子; $Z_{best,cj,i}$ 是第 i 头大象在 cj 氏族中的最佳位置; r 是 [0, 1] 之间的随机数。

步骤 2 每个氏族中最合适的大象的位置更

新。最合适的大象、即族长,其位置被更新为:

$$Z_{new,cj,i} = \beta \times Z_{center,cj} \quad (18)$$

$$Z_{center,cj} = \sum_{i=1}^n Z_{cj,i} / n_z$$

其中, i 是大象个体; n_z 是每个部落的大象总数; β 是 $[0, 1]$ 之间的随机数。

步骤3 分离最差的大象个体。现在,最差的大象个体或 ME 将从其家庭群体中分离出来。这是通过将最差解决方案修改为:

$$Z_{worst,cj,i} = Z(Z_{min_{max}} \times rand)_{min} \quad (19)$$

其中, $Z_{worst,cj,i}$ 是第 cj 个氏族中最差的 ME, Z_{max} 和 Z_{min} 分别是部落的最大和最小允许边界限制。

步骤4 收敛。重复步骤 1~3,直至达到收敛条件。

2.2 基本 EHO 的局限性及改进 (变为 IMOEOH)

本小节将讨论基本 EHO 的局限性^[19],并在此基础上提出一些改进建议^[20]:

(1)局限一:在标准 EHO 中,最适合的大象领导该部落的位置仅根据该部落所有大象收到的平均位置或平均信息进行更新,见式(18)。该表达式对于基准测试函数的效果令人满意。但是,当将其应用于现实生活中的问题时,效果可能就没这么好了。这可能是由于在式(18)中,母象族长的位置是通过遵循各个氏族的平均反应来更新的。此外,式(18)中的 β 在 $[0, 1]$ 之间随机选择,可能会进一步影响解的位置。这可能会导致拟合不佳的解决方案,从而会降低氏族的平均水平。作为累积效应,就可能无法达到全局最优解。

对于局限一,研究做出的改进为:为了克服上述限制,建议更新母象在当前最佳位置周围的位置为:

$$Z_{new,cj,i} = Z_{best,cj,i} + \beta \times Z_{center,cj} \quad (20)$$

其中, $Z_{best,cj,i}$ 是目前所有部落的领头象目前获得的最佳位置。这提高了每个氏族的平均值,从而提高了找到全局最佳解决方案的能力。

(2)局限二:根据基本方法中使用的分离算子,雄性或最差的大象长大后必须离开群体。因此,新生成的小象将到达随机选择的位置,以保持每个氏族的大象数量恒定,见式(18)。然而,据观察,大象将其幼崽放在更健壮的雌性附近,以保护幼象们免受饥饿的捕食者的伤害。

对于局限二,研究做出的改进是:为了克服上述限制,建议将新生的小象分配到更强壮的雌性附近的位置。因此,新生的小象将占据靠近各自氏族领袖的位置。修改后的方程表示为:

$$Z_{worst,cj,i} = Z_{fitnesscj} \quad (21)$$

这样

$$Z_{fitnesscj} = \mu \times Z_{local,cj} \quad (22)$$

其中, μ 是 $[0.9-1.1]$ 之间的随机邻近因子, $Z_{local,cj}$ 是第 cj 个部落的大象的局部最佳位置。

3 基于改进和多目标大象放牧优化算法 (IMOEOH)

在本节中,针对 ODERA 在配电系统中的多目标大象放牧优化算法 (IMOEOH) 进行了讨论。为了使用改进的 EHO 解决提出的 ODERA 问题,必须将大象群建模为一些数学方程组,如第 2 节所述。图 2 显示了在所提出的算法中使用的象群结构,该算法由 DER 节点及其相应的容量组成。结构的前半部分包含 DER 位置,后半部分包含 DER 规模,在算法中用作决策变量,类似于大象的位置。这里, M 表示预先指定的 DER 数量,假设安装在给定的配电网中。个体的长度类似于 EHO 中的氏族数量,即 $2M$ 。正如所讨论的,所提出的 DER 适应模型是一个复杂的多目标问题,会产生许多解决方案,因此可能需要强大的 MCDM 方法来从优化方法提供的众多竞争解决方案中选择最折衷的解决方案。因此,这里采用了第 2 节中讨论的 TOPSIS 方法,并与改进的 EHO 有效集成,以帮助其在每一步选择最具竞争力的解决方案。所提出的混合方法的基本步骤如下。

步骤1 随机初始化 n_1 个象种群。

步骤2 计算与图 2 中表示的每个个体对应的 n_2 目标函数的值,并将其排列在式(23)给出的决策矩阵 D 中:

$$D = \begin{bmatrix} f_{11} & f_{12} & f_{13} & \cdots & f_{1n_2} \\ f_{21} & f_{22} & f_{23} & \cdots & f_{2n_2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ f_{n_11} & f_{n_12} & f_{n_13} & \cdots & f_{n_1n_2} \end{bmatrix} \quad (23)$$

步骤3 在决策矩阵 D 上应用式(9)~(15)表示的 TOPSIS 方法,根据计算出的 RCI 值选择一个最折衷的解决方案及其相应的 DER 地点和规模。最好的个体将成为族长或领导者。

步骤4 用式(17)更新每个氏族中除最差和最好的大象的位置。

步骤5 现在,分别使用式(20)和(21)中表示的建议改进来更新每个氏族中最佳和最差大象的位置。

步骤 6 可以采用修正算法将不可行的个体转换为由 DER 节点和大小组成的可行个体。

具体算法流程如图 3 所示。

术的效果, 构建了不同的测试案例并使用改进的 IMOEOH 算法进行测试, 在本文中, 并不要求 DERs 调节系统的电压, 因此, 都被认为是感性负载, 由于配电网的网络拓扑结构为辐射状, 负荷潮流计算采用前推回代法。所提出的 IMOEOH 使用 Matlab 求解并对研究系统使用的控制参数如下: 群体大小为 50, 氏族个数为 6, 最大迭代次数 $T_{max} = 100$, $\alpha = 0.8, \beta = 0.1$ 。并针对不同的案例研究, 将其他文献使用的不同优化算法和本文提出的 IMOEOH 的仿真结果进行了比较和讨论。




图 3 为 ODERA 提出的 IMOEOH 流程图
Fig. 3 Flowchart of the proposed IMOEOH for ODERA




图 4 IEEE33 节点图
Fig. 4 IEEE33 node figure

在案例研究中, 制定并解决了基准 33 节点径向配送系统的 ODERA 问题, 这是一个基准电压为 12.66 kV 的系统, 基准有功功率和无功功率分别为 3.715 MW 和 2.300 MW。

为了对所提方法和已有的优化技术进行性能比较, 分别在相同的情况下对仿真结果进行了比较分析。

(1) 案例一: 在统一功率因数下容纳 3 台 DERs。在案例一中, 将会选择 3 个 DERs 在配电系统中 3 个不同的节点进行最优的容纳, 包括每个 DERs 所在的节点位置和容量大小。如文献[9]和[18]中一样。通过本文提出的方法获得的仿真结果与不同的现有方法进行比较, 总结见表 1。表 1 中包含了最优 DER 的节点和容量, 以及 3 个目标函数的值和 DER 的渗透率。从表 1 中可以看出, 与现有方法相比, 本文所提出的方法在充分渗透 DER 条件下为多目标 ODERA 问题提供了最折衷的解决方案。表 1 中加粗的部分分别为本文中所提出的方法仿真得出的值, 与文献[9]和[18]相比, 其 3 个目标函数值优异, 从而系统也更加稳定。且文献[9]中的遗传算法、粒子群算法、混合遗传-粒子群算法的 DER 渗透率达不到所要求的标准, 文献[18]中的教学优化算法的 DER 渗透率比本文所提出的方法要高。

(2) 案例二: 在统一功率因数下容纳 4 台 DERs。在案例二中, 假设系统之中有 4 台 DERs 分别安装在系统不同的节点, 如文献[9]和[18]中建议那样, 假设所有的 DERs 都在统一功率因数之下,

4 案例研究

为了验证改进的 IMOEOH 算法对于多目标问题 ODERA 的有效性和实用性, 分别在 IEEE33 节点标准测试系统上实现了改进的 IMOEOH 算法。IEEE33 节点图如图 4 所示。为了研究不同 DER 技

将该算法得到的仿真结果与相同情况下所用的方法进行比较,比较结果见表1。对比表明,当渗透率较低情况下,与遗传算法、粒子群算法、混合遗传-粒子群算法和改进和声搜索算法相比,该方法提供了最折衷的解决方案。

(3)案例三:在滞后功率因数为0.85下容纳3台DERs。在案例一和案例二中,安装的DERs并没

有为系统提供无功支持来考虑优化目标。在案例三中,研究认为系统可以容纳3个运行在滞后功率为0.85下的DERs来为系统提供无功功率支持,与文献[22]中所用的免疫算法相比结果见表1。本文提出的IMOEOH为多目标ODERA问题提供了最折衷的解决方案。可以看出,该方法在改善节点电压分布和稳定性的同时也提高了DER的渗透率。

表1 结果对比图

Tab. 1 Comparison table of results

案例	方法	最优节点(容量)	目标函数值			DER 渗透率/%
			f_1 (MW)	f_2	f_3	
	无	无	0.202 7	0.117 1	0.698 8	00.00
案例一	遗传(GA) ^[9]	11(1.500),29(0.423),30(1.071)	0.106 3	0.040 7	0.949 0	50.37
	粒子群(PSO) ^[9]	08(1.177),13(0.982),32(1.830)	0.105 3	0.033 5	0.925 6	50.27
	GA/PSO ^[9]	11(0.925),16(0.863),32(1.200)	0.103 4	0.012 4	0.950 8	50.27
	教学优化(TLBO) ^[18]	09(0.885),18(0.895),32(1.19)	0.104 0	0.029 5	0.9547	56.57
	教学优化(TLBO) ^[18]	12(1.183),28(1.191),30(1.186)	0.124 7	0.001 1	0.950 3	59.90
	改进教学优化(QOTLBO) ^[18]	13(1.083),26(1.188),30(1.20)	0.103 4	0.001 1	0.953 0	58.38
	本文算法(IMOEOH)	33(0.683),04(1.310),9(1.659)	0.036 1	0.001 5	0.958 3	55.10
案例二	遗传(GA) ^[20]	06(0.643),13(0.857),24(0.857),30(0.738)	0.070 1	0.011 5	0.877 6	52.07
	粒子群(PSO) ^[20]	06(0.830),15(0.833),25(0.541),31(0.648)	0.071 3	0.010 9	0.877 6	47.98
	GA/PSO ^[20]	14(0.663),24(1.203),26(0.867),32(0.664)	0.068 2	0.013 0	0.890 3	54.12
	改进和声搜索(IMOHS) ^[21]	06(0.937),14(0.677),24(1.102),31(0.731)	0.067 8	0.011 1	0.889 1	56.31
	本文算法(IMOEOH)	07(0.930),14(0.696),25(0.729),31(0.812)	0.067 1	0.008 3	0.901 2	45.40
案例三	IA(免疫算法) ^[22]	06(1.181),25(0.840),31(0.930)	0.026 1	0.008 6	0.867 8	40.56
	本文算法(IMOEOH)	13(0.929),24(1.181),30(1.473)	0.014 6	0.000 5	0.978 6	51.25

可以看出,与案例一和案例二相比,案例三提供了最不利的解决方案,因为在滞后功率因数为0.85的情况下为系统提供了无功支持,相比于统一功率因数下提高了系统性能,但是与基本情况相比,3种案例下对系统的电压分布都有明显的改善,如图5所示。从图5中也可看出案例一和案例三节点电压分布比较接近,但在案例二中,由于DERs的渗透率比较低,电压调节也略差一点。




图5 不同案例的节点电压分布图

Fig. 5 Node voltage profile of different cases

5 结束语

本文采用TOPSIS方法为配电系统中的DER优化配置建立了一个新的多目标优化框架。介绍了一种新的自然启发算法EHO,并对该算法进行一些改进以克服其局限性。最终将改进后的IMOEOH算法在考虑统一功率因数和滞后功率因数为0.85的情况下,在IEEE33节点上进行有效仿真证明其合理性和有效性。为了证明所提出的IMOEOH算法的优越性,将该方法得到的仿真结果与相关文献中其他方法所得到的结果进行总结比较。结果表明,本文提出的方法具有更好的全局收敛效率和寻优能力,并且对于系统的电压分布具有明显改善。

参考文献

- [1] 杨杰,蒲亦非. 自然启发优化面临的问题与挑战[J]. 现代计算机,2020(16):28-32.
- [2] 吴大立,郑中祥,尹项根,等. 基于Petri网和多种群遗传算法的

- 海洋核动力平台电力系统网络重构[J]. 电力自动化设备, 2020,40(08):160-168.
- [3] 余建树, 李朝霞, 龚雪娇, 等. 基于并行粒子群算法的电力系统分区抗差状态估计[J]. 电网技术, 2022,46(08):3139-3149.
- [4] 孙舒婷. 含分布式能源接入的配电网优化调度研究[J]. 自动化与仪器仪表, 2022(02):43-47.
- [5] 谭朝华. 分布式能源接入电力系统的影响[J]. 中国高新技术企业, 2014(17):65-66.
- [6] 严晨晨, 王洪涛, 邹斌. 基于贝叶斯网络的分布式电源的选址与定容[J]. 工业控制计算机, 2021,34(05):139-142,145.
- [7] 许珊, 谈金晶. 配电网规划中分布式电源的选址和定容[J]. 电工电气, 2017(08):8-13.
- [8] 季佳伸, 吴俊勇, 王彦博, 等. 基于深度残差网络的电力系统暂态电压稳定评估[J]. 电网技术, 2022,46(07):2500-2511.
- [9] MORADIM H, TOUSI S M R, ABEDINI M. Multi-objective PFDE algorithm for solving the optimal siting and sizing problem of multiple DG sources [J]. International Journal of Electrical Power & Energy Systems, 2014, 56:117-126.
- [10] 宁昕, 王同勋, 陈涵, 等. 基于目标规划法的配电台区无功电压优化[J]. 电力电容器与无功补偿, 2022,43(03):1-7.
- [11] 阙华坤, 冯小峰, 郭文翀, 等. 基于模糊双目标规划的充电站布局模型[J]. 计算机科学, 2022,49(S1):753-758.
- [12] 申洪涛, 岳凡丁, 史轮, 等. 考虑 DG 及负荷时序性的多目标配电网重构与 DG 调控综合优化规划[J]. 现代电力, 2022,39(02):182-194.
- [13] 张宏军, 尹成祥, 蔡秀利, 等. 多准则决策中的鲁棒有序回归方法综述[J]. 控制与决策, 2017,32(05):769-779.
- [14] 马钊, 丛伟, 苏剑, 等. 主动配电系统和分布式能源技术发展—CIGRE SC6 2018 专题报道及思考[J]. 电网技术, 2019,43(03):982-988.
- [15] 李国栋, 王峥, 郝帅, 等. 分布式电源接入对配电网运行指标的影响评估[J]. 电器与能效管理技术, 2021(06):79-85.
- [16] 刘星, 陈众, 陈李杰, 等. 含高渗透率光伏的配电网就地-分布式电压控制[J]. 电力电容器与无功补偿, 2021,42(06):268-275.
- [17] 李艳梅, 陈增. 基于联系度优化 TOPSIS 法的区域电能替代潜力评估研究[J]. 电网技术, 2019,43(02):687-695.
- [18] WANG Gaige, DEB S, COELHO L D S. Coelho. Elephant herding optimization [C]//2015 3rd International Symposium on Computational and Business Intelligence (ISCBI). Bali, Indonesia; IEEE, 2015: 1-5.
- [19] 王永刚. 改进 EHO 算法在无线传感网络入侵检测中的应用[J]. 黑龙江工业学院学报(综合版), 2021,21(04):96-101.
- [20] LI Jiuling, LI Wei, CHANG Xiaomin, et al. Real-time predictive control for chemical distribution in sewer networks using improved elephant herding optimization[J]. IEEE Transactions on Industrial Informatics, 2022,18(1): 571-581.
- [21] SULTANAS, ROY P K. Multi-objective quasi-oppositional teaching learning based optimization for optimal location of distributed generator in radial distribution systems[J]. International Journal of Electrical Power & Energy Systems, 2014, 63: 534-545.
- [22] HUNG D Q, MITHULANANTHAN N. Multiple distributed generator placement in primary distribution networks for loss reduction[J]. IEEE Transactions on Industrial Electronics, 2013, 60(4):1700-1708.

(上接第 79 页)

- [16] AZAD R, ASADI-AGHBOLAGHI M, FATHYM, et al. Bi-directional convlstm U-Net with densely connected convolutions [C]//2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW). Seoul, Korea (South); IEEE, 2019: 406-415.
- [17] ASADI-AGHBOLAGHI M, AZAD R, FATHYM, et al. Multi-level context gating of embedded collective knowledge for medical image segmentation[J]. arXiv preprint arXiv: 2003.05056, 2020.
- [18] HUANG Gao, LIU Zhuang, MAATEN V D L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA; IEEE, 2017:2261-2269.
- [19] WANC Qilong, WU Banggu, ZHU Pengfei, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Seattle; IEEE, 2020: 11531-11539.
- [20] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997,9(8):1735-1780.
- [21] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA; IEEE, 2016:770-778.
- [22] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998,86(11):2278-2324.
- [23] BURGESS N. Prenormalization rounding in IEEE floating-point operations using a flagged prefix adder [J]. IEEE Transactions on Very Large Scale Integration Systems, 2005,13(2):266-277.
- [24] WU Congzhong, HOU Guosong, DING Zhenglong, et al. Pixellevel skin segmentation and face color grading[J]. Computer Engineering Science, 2019,41(11):1985-1990.
- [25] NAIR V, HINTON G E. Rectified linear units improve restricted boltzmann machines [C]//Proc. of the 27th International Conference on Machine Learning. Madison, WI, USA; ACM, 2010:807-814.
- [26] CHEN L C, ZHUYukun, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]//Proceedings of the European Conference on Computer Vision (ECCV). Munich, Germany; dblp, 2018:801-818.