

文章编号: 2095-2163(2022)05-0081-08

中图分类号: TM715

文献标志码: A

基于改进条件生成对抗网络的分布式电源优化配置

胡攀, 邓坤

(贵州大学电气工程学院, 贵阳 550025)

摘要: 分布式电源由于其出力存在不确定性的特点对配电网的规划有着明显的影响,为使规划结果更加合理,需对其出力的不确定性进行建模。首先利用改进的条件生成对抗网络模型对风电和光伏出力的不确定性进行建模,在模型中加入月份标签信息以生成具有时序特性的风电和光伏出力场景,并通过 K-means 聚类方法对生成的大量场景进行聚类。其次,建立了以年综合费用最小为目标的分布式电源优化配置模型,通过二阶锥松弛方法将模型转换为混合整数二阶锥规划问题快速求解。最后,通过 IEEE 33 节点算例系统验证构建模型的有效性。

关键词: 不确定性; 条件生成对抗网络; K-means 聚类; 优化配置; 二阶锥规划

Optimal allocation of distributed generation based on improved conditional generative adversarial networks

HU Pan, DENG Kun

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

[Abstract] Distributed generation has a significant impact on the planning of distribution network due to its characteristics of uncertainty. In order to make the planning results more reasonable, it is necessary to model the uncertainty of its output. Firstly, the improved conditional generative adversarial networks model is used to model the uncertainty of wind power and photovoltaic output, the month label information is added to the model to generate wind power and photovoltaic output scenarios with timing characteristics, and a large number of scenes are clustered by K-means clustering method. Secondly, a distributed generation optimal allocation model aiming at minimizing the annual comprehensive cost is established, and the model is transformed into a mixed integer second-order cone programming problem by the second-order cone relaxation method. Finally, the effectiveness of the model is verified by an IEEE33-bus example system.

[Key words] uncertainty; conditional generative adversarial networks; K-means; optimal allocation; second-order cone programming

0 引言

在节能减排和环境保护的背景下,以风力发电(wind turbine, WT)和光伏发电(photovoltaic, PV)为代表的分布式电源(distributed generation, DG)因其清洁环保、安装地点灵活、可提高供电可靠性等优点得到了快速发展^[1-2]。然而,由于 WT 和 PV 的输出功率存在较强的随机性,给配电网带来了一定影响,成为 DG 在配电网中发展的主要障碍。因此,科学地对 DG 进行规划对配电网的安全经济运行具有重要意义。

目前, DG 规划问题已经开展了许多研究。文献[3-4]在模型中考虑多种类型 DG 的时序特性并在成本函数中充分考虑环境污染费用,搭建了 DG 社会年综合成本最小为目标的规划模型,利用智能算法进行求解。然而,上述模型中忽略了风、光和负

荷的不确定性,最终得到的 DG 优化配置结果存在一定的不合理性。为了降低不确定性的影响,一些学者在进行优化配置时考虑源荷不确定性的影响。文献[5]考虑待规划地区的风、光和负荷的不确定性,采用拉丁超立方和快速向前选择法分别进行场景生成和削减,构建了以年综合费用最少为目标的 DG 规划模型。文献[6]采用概率密度建模的方法构造风、光和负荷的典型日出力数据,以经济性和环保性为目标,建立基于随机场景的 DG 多目标优化模型,并采用改进的非劣排序遗传算法对模型进行了求解。文献[7]基于蒙特卡洛模拟抽样得到间歇式新能源和负荷出力情况以解决间歇式新能源消纳及功率波动问题。

尽管上述文献在 DG 容量随机优化配置问题上取得了一定进展,但目前生成场景大多采用拉丁超立方和蒙特卡洛等抽样方法,而使用这些抽样方法

作者简介: 胡攀(1997-),男,硕士研究生,主要研究方向:电力系统规划;邓坤(1996-),男,硕士研究生,主要研究方向:储能配置。

收稿日期: 2022-01-06

哈尔滨工业大学主办 ◆ 系统开发与应用

之前需要事先假设数据服从特定的概率分布。生成对抗网络(generative adversarial network, GAN)提出后受到广泛关注, GAN 不需要事先假设数据服从特定的概率分布, 直接从数据中学习并生成新的数据样本^[8]。文献[9]虽然研究了单种类型 DG 出力场景生成问题, 但忽略了在实际规划中存在不同类型的 DG。文献[10]利用 GAN 模拟大量风光出力场景, 再用 K-medoids 聚类得到若干典型场景, 构建微电网容量随机优化配置模型, 虽然考虑了 DG 的出力不确定性, 但却忽略了 DG 的时序出力特性。

针对上述研究现状, 为了避免传统抽样方法中假设的数据分布与真实数据分布不同而导致生成的场景不合理, 本文采用改进的条件生成对抗网络模型无需事先假设原始数据分布, 训练结束后即可生成与实际数据分布相近的风光出力场景。为了得到有效的规划场景集, 使用 K-means 聚类算法进行场景聚类。然后构造了以年综合费用最小为目标的分布式电源优化配置模型, 模型中充分考虑了政府补

贴及环境污染等费用。由于模型中具有非线性项, 通过二阶锥松弛方法将模型转换为混合整数二阶锥规划问题。用 IEEE 33 节点系统验证所提出规划模型的有效性。

1 改进的条件生成对抗网络

1.1 条件 GAN 模型

GAN 是 Goodfellow 提出的一种深度学习模型, 由生成器和判别器两个部分组成。其中, 生成器通过学习真实数据的概率分布来生成新的样本。判别器则判断输入的数据是否为真实数据, 两者通过博弈学习来提高生成样本的质量。条件 GAN 是在 GAN 基础上进行改进的一种生成式网络, 是将监督学习和无监督学习相结合, 并在模型的输入中添加了标签信息, 可用于指导数据的生成过程, 对指定类型数据样本的泛化有较好的效果, 能够较好地适应风电和光伏出力场景构建问题^[11]。条件 GAN 的基本结构如图 1 所示。

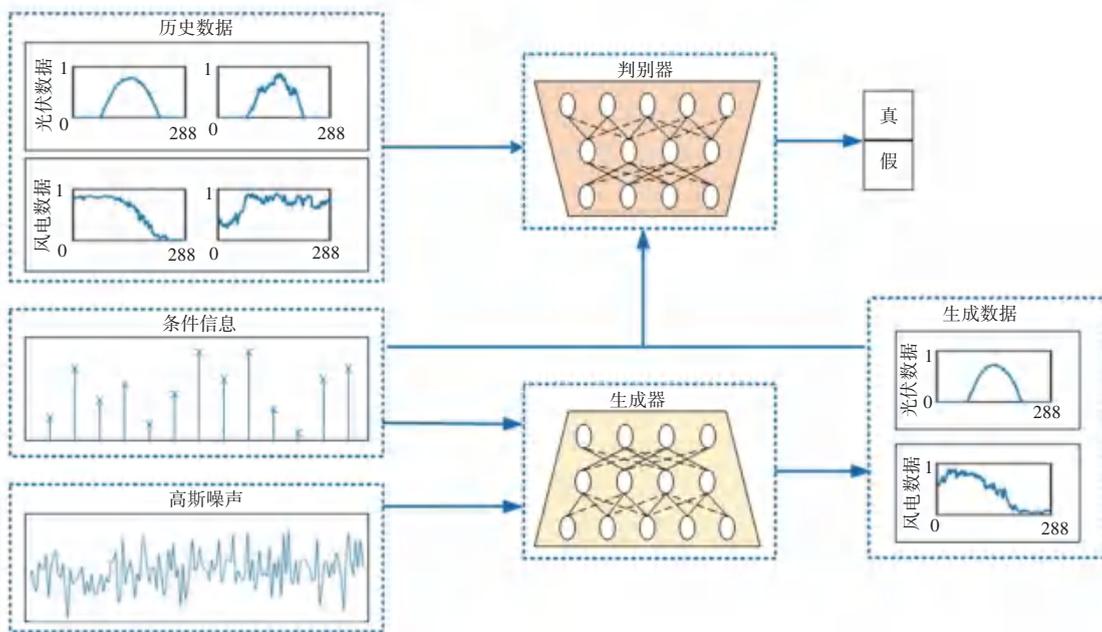


图 1 条件 GAN 的基本结构

Fig. 1 Basic structure of conditional GAN

由图 1 可知, 条件信息 c 和噪声向量 z 作为生成器 G 的输入, 生成器 G 输出生成样本 $x' = G(z|c)$ 。判别器 D 在判断生成样本分布 $p(x')$ 与真实样本分布 $p(x)$ 的相似程度的同时还判断生成样本 x' 是否满足条件信息 c 。条件 GAN 中生成器与判别器的损失函数如式(1)~(2)所示:

$$Loss_G = -E_{x' \sim p(x')} [D(x'|c)] \quad (1)$$

$$Loss_D = -E_{x \sim p(x)} [D(x|c)] + E_{x' \sim p(x')} [D(x'|c)] \quad (2)$$

其中, E 为对应分布的期望值, $D(\sim)$ 为判别器函数。

在条件 GAN 训练的过程中, 训练目标是带有条

件的极小极大值博弈, 如式(3)所示:

$$\min_G \max_D V(G, D) = E_{x \sim p(x)} [D(x|c)] - E_{x' \sim p(x')} [D(x'|c)] \quad (3)$$

在训练结束后, 生成器 G 可学习到真实样本 x 的概率分布特征, 从而能在条件信息 c 下生成服从真实规律的数据。

1.2 条件 WGAN-GP 模型

传统 GAN 在训练过程中容易出现训练困难和模式崩溃的问题, 从而影响生成样本 x' 的准确性。为了避免上述问题, 用 Wasserstein 距离的损失函数来替换传统 GAN 中的 JS 散度, Wasserstein 距离可衡量 2 个不同概率分布之间的相似程度^[12-13], 其值越小代表 2 个概率分布的相似程度更高, 其定义如式(4)所示:

$$W(p(x), p(x')) = \inf_{\pi(x, x')} \int d(x, x') \pi(dx, dx') \quad (4)$$

其中, $\pi(x, x')$ 为满足 $p(x)$ 与 $p(x')$ 边缘分布的联合概率密度分布, $d(x, x')$ 为场景间距离测度。

一般用 Kantorovich - Rubinstein 对偶形式对 Wasserstein 距离进行求解^[14], 当其应用于条件 WGAN 中时, 如式(5)所示:

$$W_{(p_x, p_{x'})} = \sup_{\|f_D\|_L \leq 1} E_{p(x)} [D(x|c)] - E_{p(x')} [D(x'|c)] \quad (5)$$

其中, $\|f_D\|_L \leq 1$ 表示判别器 D 需满足 1-Lipschitz 连续。

本文通过修正判别器 D 的损失函数, 在原有的损失函数中添加梯度惩罚项来使其满足 1-Lipschitz 条件限制^[15], 具体形式如式(6)所示:

$$GP|_{\hat{x}} = \lambda E_{\hat{x} \sim p(\hat{x})} [(\|\tilde{\mathbf{N}}_x D(\hat{x})\|_p - 1)^2] \quad (6)$$

其中, $\|\cdot\|_p$ 表示 p 范数; λ 表示正则项系数; \hat{x} 是真实样本 x 与生成样本 x' 间的连线上随机插值采样获得, $\hat{x} = \varepsilon x + (1 - \varepsilon)x'$, ε 服从 $[0, 1]$ 上的均匀分布。

综上所述, 条件 WGAN-GP 的整体训练目标函数为:

$$\min_G \max_D V(G, D) = E_{x \sim p(x)} [D(x|c)] - E_{x' \sim p(x')} [D(x'|c)] - \lambda E_{\hat{x} \sim p(\hat{x})} [(\|\tilde{\mathbf{N}}_{\hat{x}} D(\hat{x}|c)\|_p - 1)^2] \quad (7)$$

1.3 条件 WGAN-GP 结构设计

本文采用卷积神经网络代替传统的多层感知器来构建生成器和判别器, 生成器和判别器为对称的网络结构。生成器共有 4 层, 滤波器数量分别为

256、128、64 和 1。第一层卷积核大小为 5, 后 3 层卷积核大小为 4。前 3 层以 *ReLU* 作为激活函数, 最后一层以 *Tanh* 作为激活函数。同时为了加快网络训练速度, 提高网络的鲁棒性, 在前 3 个卷积层后面均添加批量归一化 (batch normalization, BN) 层, 考虑到 BN 层会是输出规范化到 $N(0, 1)$ 的正态分布, 因此输出层后不添加 BN 层。判别器也为 4 层, 卷积核大小为 4, 滤波器数量分别为 16、32、64 和 1。前 3 层以 *LeakyReLU* 作为激活函数, 由于条件 WGAN-GP 模型的结构特点, 最后一层不添加激活函数。生成器和判别器的网络结构及参数分别参见表 1 和表 2。

表 1 生成器结构

层数	名称	参数名称	参数
Layer1	2D 反卷积层 批归一化层	卷积核	5 × 5
		激活函数	ReLU
		步长	2
Layer2	2D 反卷积层 批归一化层	卷积核	4 × 4
		激活函数	ReLU
		步长	2
Layer3	2D 反卷积层 批归一化层	卷积核	4 × 4
		激活函数	ReLU
		步长	2
Layer4	2D 反卷积层	卷积核	4 × 4
		激活函数	tanh
		步长	2
		滤波器数量	1

表 2 判别器结构

层数	名称	参数名称	参数
Layer1	2D 卷积层	卷积核	4 × 4
		激活函数	LeakyReLU
		步长	2
Layer2	2D 卷积层 批归一化层	卷积核	4 × 4
		激活函数	LeakyReLU
		步长	2
Layer3	2D 卷积层 批归一化层	卷积核	4 × 4
		激活函数	LeakyReLU
		步长	2
Layer4	2D 卷积层	卷积核	4 × 4
		步长	2
		滤波器数量	1

2 基于 K-means 的风光时序出力场景削减

由于风电和光伏出力有较强的随机性和波动性,随季节和天气的变化而变化,仅以某日数据值作为规划参数,不能体现风电和光伏出力的特点,会导致规划结果不合理。本文基于条件 WGAN-GP 学习风光历史数据的分布,生成大量 1~12 月风光出力场景集,但若利用全部数据进行大量的仿真计算,都将由于运算量巨大而导致求解困难,对于规划人员来说不可行、也无应用价值。因此,有必要对生成的大量风光出力场景进行聚类。

为了在减少计算量的同时充分考虑风光出力的时序性和随机性,本文采用 K-means 聚类算法对生成的风光出力场景进行聚类。根据一年 4 个季节,把不同季节下的风光出力场景聚类为晴、阴、雨三种典型场景,故聚类后共有 12 个场景,K-means 聚类削减步骤如下。

(1) 从原始风光出力场景中随机选取 K 个场景作为初始聚类中心 $T^{(0)} = (\psi_1^{(0)}, \psi_2^{(0)}, \dots, \psi_K^{(0)})$ 。

(2) 分别计算每个场景到聚类中心的欧氏距离,并将每个场景划分到距离最近的聚类簇中。每个场景到聚类中心的欧氏距离的计算公式如下:

$$D(\psi_i, \psi_j) = \sqrt{\sum_{k=1}^n (\psi_i(k) - \psi_j(k))^2} \quad (8)$$

其中, $D(\psi_i, \psi_j)$ 为场景曲线间的距离, $\psi_i(k)$ 为第 i 个场景的第 k 维数据。

(3) 分别计算 K 个聚类簇的中心点,更新聚类中心 $T^{(1)} = (\psi_1^{(1)}, \psi_2^{(1)}, \dots, \psi_K^{(1)})$ 。

(4) 重复步骤(2)和(3),最终的聚类中心曲线即对应 K 个典型场景 $\{\xi_1, \xi_2, \dots, \xi_K\}$ 。

3 考虑不确定性的 DG 优化配置模型

3.1 目标函数

本文以 WT、PV 和 MT 三种 DG 为研究对象,建立了年综合费用最少的 DG 优化配置模型,费用包括 DG 的建设投资费用、运行维护费用、网络损耗费用、主网购电费用以及 DG 发电产生的环境效益,具体形式如下:

$$\min C = C_I + C_{OM} + C_L + C_P - C_S \quad (9)$$

式(9)中, DG 的各种费用的数学表达形式如下。

(1) 折算到每年的 DG 建设投资费用 C_I , 其值可由如下数学公式计算得到:

$$C_I = A(d, y) \sum_{k=1}^{N_{type}} \sum_{j \in \Omega^{DGk}} (c_I^{DGk} P_{r,j}^{DGk}) \quad (10)$$

其中, $A(d, y) = d(1+d)^y / [(1+d)^y - 1]$ 表示 DG 的现值转等年值系数,这里 d 为贴现率, y 为规划年限; N_{type} 为 DG 的类型,用 1、2 和 3 分别代表 WT、PV 和 MT; j 为 DG 安装的节点; Ω^{DGk} 为第 k 种 DG 安装的节点集合; c_I^{DGk} 为安装在节点 j 处的第 k 种 DG 的单位容量建设投资成本系数; $P_{r,j}^{DGk}$ 为安装在节点 j 处的第 k 种 DG 的额定容量。

(2) DG 年运行维护费用 C_{OM} , 其值可由如下数学公式计算得到:

$$C_{OM} = t_d \omega_s \sum_{s=1}^{N_s} \sum_{t \in T} \sum_{k=1}^{N_{type}} \sum_{j \in \Omega^{DGk}} c_{OM}^{DGk} P_{j,s,t}^{DGk} \quad (11)$$

其中, $t_d = 365$; ω_s 为场景 s 发生的概率; N_s 为总场景数; c_{OM}^{DGk} 为安装在节点 j 处的第 k 种 DG 发出单位电量所需的运行维护成本系数; $P_{j,s,t}^{DGk}$ 为安装在节点 j 处的第 k 种 DG 在 s 场景 t 时刻下发出的有功功率。

(3) 网络损耗费用 C_L , 其值可由如下数学公式计算得到:

$$C_L = t_d \omega_s \sum_{s=1}^{N_s} \sum_{t \in T} \sum_{ij \in \Omega^{Grid}} (c_{Loss} I_{ij,s,t}^2 r_{ij}) \quad (12)$$

其中, Ω^{Grid} 为所有节点集合; c_{Loss} 为网损成本系数; $I_{ij,s,t}$ 表示场景 s 在 t 时刻由节点 i 流向节点 j 的电流; r_{ij} 表示节点 i 和节点 j 之间线路的电阻值。

(4) 向上级电网购电费用 C_P , 其值可由如下数学公式计算得到:

$$C_P = t_d \omega_s \sum_{s=1}^{N_s} \sum_{t \in T} \sum_{j \in \Omega^{TR}} (c_{TR} P_{j,s,t}^{TR}) \quad (13)$$

其中, Ω^{TR} 为变压器节点集合; c_{TR} 为向主网购电的单位购电成本系数; $P_{j,s,t}^{TR}$ 为主网购电量。

(5) DG 发电环境效益 C_S 。环境效益包括 2 个部分:环境污染费用和政府补贴。这里,环境污染费用是 MT 发电所产生的环境污染赔偿费用;政府补贴是 DG 发电所产生的效益。 C_S 值可由如下数学公式计算得到:

$$C_S = t_d \omega_s \left(\sum_{s=1}^{N_s} \sum_{t \in T} \left(\sum_{j \in \Omega^{MTw=1}} \sum_{w=1}^n (V_w + F_w) D_w P_{j,s,t}^{MT} - \sum_{k=1}^{N_{type}} (c_f P_{j,s,t}^{DGk}) \right) \right) \quad (14)$$

其中, Ω^{MT} 为 MT 安装的节点集合; V_w 和 F_w 分别为污染物的环境价值和所受罚款; D_w 为污染物的排

放量; $P_{j,s,t}^{MT}$ 为安装在节点 j 处的 MT 在场景 s 下 t 时刻发出的有功功率; c_j 为政府补贴成本系数。

3.2 约束条件

(1) 潮流方程约束

$$\sum_{k \in \delta(j)} P_{jk,s,t} - \sum_{i \in \pi(j)} (P_{ij,s,t} - I_{ij,s,t}^2 r_{ij}) = \sum_{j \in \Omega^{TR}} P_{j,s,t}^{TR} + \sum_{k=1}^{N_{type}} \sum_{j \in \Omega^{DGk}} P_{j,s,t}^{DGk} - \sum_{j \in \Omega^{Grid}} P_{j,s,t}^{Load} \quad (15)$$

$$\sum_{k \in \delta(j)} Q_{jk,s,t} - \sum_{i \in \pi(j)} (Q_{ij,s,t} - I_{ij,s,t}^2 x_{ij}) = \sum_{j \in \Omega^{TR}} Q_{j,s,t}^{TR} + \sum_{k=1}^{N_{type}} \sum_{j \in \Omega^{DGk}} Q_{j,s,t}^{DGk} - \sum_{j \in \Omega^{Load}} Q_{j,s,t}^{Load} \quad (16)$$

$$U_{j,s,t}^2 = U_{i,s,t}^2 - 2(P_{ij,s,t} r_{ij} + Q_{ij,s,t} x_{ij}) + I_{ij,s,t}^2 (r_{ij}^2 + x_{ij}^2) \quad (17)$$

$$I_{ij,s,t}^2 = \frac{P_{ij,s,t}^2 + Q_{ij,s,t}^2}{U_{j,s,t}^2} \quad (18)$$

其中, $\delta(j)$ 为终点集合; $\pi(j)$ 为起点集合; $P_{ij,s,t}$ 和 $Q_{ij,s,t}$ 分别表示场景 s 在 t 时段从节点 i 向节点 j 流出的有功功率和无功功率; r_{ij} 和 x_{ij} 表示节点 i 和节点 j 间线路的电阻值和电抗值; $Q_{j,s,t}^{TR}$ 、 $Q_{j,s,t}^{DGk}$ 分别为 s 场景 t 时段下 j 节点所连接的变压器、第 k 种 DG 的无功功率; $P_{j,s,t}^{Load}$ 、 $Q_{j,s,t}^{Load}$ 分别为 s 场景 t 时段下 j 节点所连接的负荷有功、无功功率; $U_{j,s,t}$ 和 $U_{i,s,t}$ 分别为 s 场景 t 时段下节点 j 和节点 i 的电压幅值。

(2) 节点电压约束

$$U_{\min} \leq U_{j,s,t} \leq U_{\max} \quad (19)$$

其中, U_{\max} 和 U_{\min} 分别为节点 j 电压的上限和下限。

(3) 支路电流约束

$$0 \leq I_{ij,s,t} \leq I_{\max} \quad (20)$$

其中, I_{\max} 为支路 j 所允许的电流最大值。

(4) 变压器节电功率约束

$$\begin{cases} P_j^{TR,\min} \leq P_{j,s,t}^{TR} \leq P_j^{TR,\max} \\ Q_j^{TR,\min} \leq Q_{j,s,t}^{TR} \leq Q_j^{TR,\max} \end{cases} \quad (21)$$

其中, $P_j^{TR,\max}$ 和 $P_j^{TR,\min}$ 分别为变压器有功功率上限和下限; $Q_j^{TR,\max}$ 和 $Q_j^{TR,\min}$ 分别为变压器无功功率上限和下限。

(5) DG 相关约束

$$\begin{cases} 0 \leq P_{j,s,t}^{DGk} \leq P_{j,s,t}^{DGk,\max} \\ 0 \leq Q_{j,s,t}^{DGk} \leq Q_{j,s,t}^{DGk,\max} \\ 0 \leq P_{r,j}^{DGk} \leq P_{r,j}^{DGk,\max} \\ \sum_{k=1}^{N_{type}} \sum_{j \in \Omega^{DGk}} P_{r,j}^{DGk} \leq \mu P_{Ltotal} \end{cases} \quad (22)$$

其中, $P_{j,s,t}^{DGk,\max}$ 为节点 j 处安装的 DG 有功功率出力的上限; $Q_{j,s,t}^{DGk,\max}$ 为节点 j 处安装的 DG 无功功率出力的上限; $P_{r,j}^{DGk,\max}$ 为节点 j 处允许安装 DG 的最大容量; μ 为渗透率; P_{Ltotal} 为配电网总有功负荷。

3.3 模型的二阶锥松弛处理

上述模型中,由于运行成本式(12)、潮流约束式(15)~式(18)存在非线性项,目标函数不容易求解,故需要将其线性化^[16],令:

$$\begin{cases} \tilde{I}_{ij,s,t} = I_{ij,s,t}^2 \\ \tilde{U}_{j,s,t} = U_{j,s,t}^2 \\ \tilde{U}_{i,s,t} = U_{i,s,t}^2 \end{cases} \quad (23)$$

将上式带入得:

$$C_L = t_d \omega_s \sum_{s=1}^{Ns} \sum_{t=1}^T \sum_{ij \in \Omega^{Grid}} (c_{Loss} \tilde{I}_{ij,s,t} r_{ij}) \quad (24)$$

$$\sum_{k \in \delta(j)} P_{jk,s,t} - \sum_{i \in \pi(j)} (P_{ij,s,t} - \tilde{I}_{ij,s,t} r_{ij}) = \sum_{j \in \Omega^{TR}} P_{j,s,t}^{TR} + \sum_{k=1}^{N_{type}} \sum_{j \in \Omega^{DGk}} P_{j,s,t}^{DGk} - \sum_{j \in \Omega^{Grid}} P_{j,s,t}^{Load} \quad (25)$$

$$\sum_{k \in \delta(j)} Q_{jk,s,t} - \sum_{i \in \pi(j)} (Q_{ij,s,t} - \tilde{I}_{ij,s,t} x_{ij}) = \sum_{j \in \Omega^{TR}} Q_{j,s,t}^{TR} + \sum_{k=1}^{N_{type}} \sum_{j \in \Omega^{DGk}} Q_{j,s,t}^{DGk} - \sum_{j \in \Omega^{Grid}} Q_{j,s,t}^{Load} \quad (26)$$

$$\tilde{U}_{j,s,t} = \tilde{U}_{i,s,t} - 2(P_{ij,s,t} r_{ij} + Q_{ij,s,t} x_{ij}) + \tilde{I}_{ij,s,t} (r_{ij}^2 + x_{ij}^2) \quad (27)$$

$$\tilde{I}_{ij,s,t} = \frac{P_{ij,s,t}^2 + Q_{ij,s,t}^2}{\tilde{U}_{j,s,t}} \quad (28)$$

经过处理后上式仍存在非线性项,需要进行松弛处理,将其转化为如下所示的二阶锥形式:

$$\left\| \begin{matrix} 2P_{ij,s,t} \\ 2Q_{ij,s,t} \\ \tilde{I}_{ij,s,t} - \tilde{U}_{j,s,t} \end{matrix} \right\|_2 \leq \tilde{I}_{ij,s,t} + \tilde{U}_{j,s,t} \quad (29)$$

综上所述,原始模型中由于其非线性项难以求解,通过对非线性项进行二阶锥松弛后,转化为混合整数二阶锥规划模型,此时可利用商业软件 CPLEX

快速求解。

求解 DG 优化配置规划模型流程如图 2 所示。

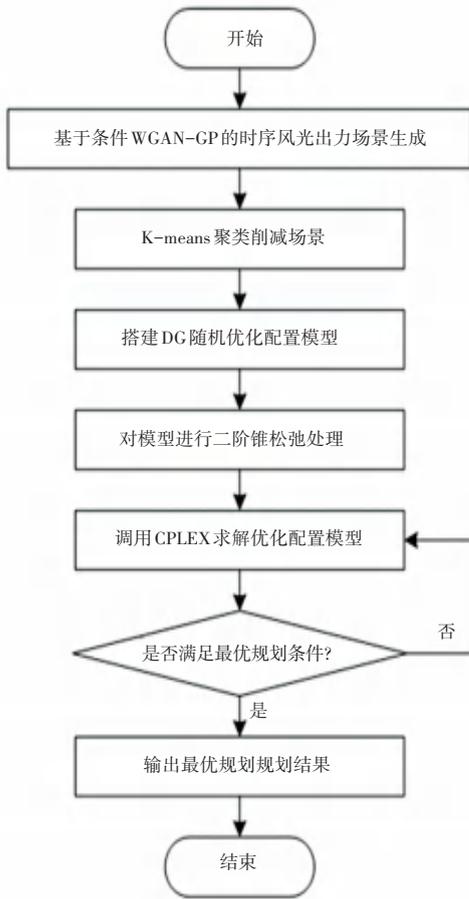


图 2 CPLEX 求解 DG 优化配置模型流程图

Fig. 2 Solution flow of DG optimal allocation using CPLEX

4 算例分析

4.1 算例参数设置

本文通过 IEEE33 节点标准测试系统进行验证,系统参数见文献[17]。IEEE33 节点配电网结构如图 3 所示。

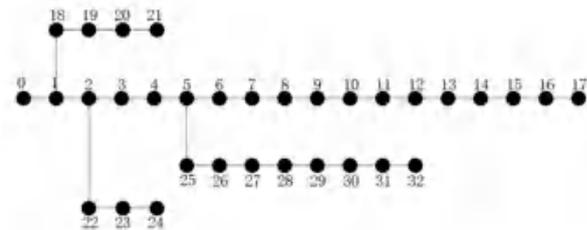


图 3 IEEE33 节点配电网结构

Fig. 3 Structure of IEEE 33-bus distribution network

算例参数参见文献[18-20]。本文以风电、光伏和微型燃气轮机作为 DG 的代表。风电的候选安装节点为 4、7、17、28,光伏的候选安装节点为 13、20、24、32,微型燃气轮机的候选安装节点为 29、30。规划年限为 20 年,贴现率为 0.06。配电网向大电网

单位购电成本为 0.5 元/(kWh), DG 的渗透率为 35%。不同类型 DG 的建设投资成本、运行维护成本和 DG 发电政府补贴见表 3。MT 的污染物排放数据见表 4。

表 3 DG 单位成本

Tab. 3 DG unit cost

DG 类型	建设投资成本/ (元·kW ⁻¹)	运行维护成本/ (元·(kWh) ⁻¹)	政府补贴/ (元·(kWh) ⁻¹)
WT	10 000	0.30	0.28
PV	13 000	0.20	0.28
MT	6 500	0.35	0

表 4 MT 污染物排放数据

Tab. 4 MT pollutant emissions data

	排放量/ (g·(kWh) ⁻¹)	环境价值/ (元·kg ⁻¹)	罚款/ (元·kg ⁻¹)
NO _x	0.618 800	6.550 0	1.640 0
CO ₂	184.082 900	0.018 8	0.008 2
CO	0.170 200	0.820 0	0.130 0
SO ₂	0.000 928	4.920 0	0.820 0

4.2 条件 WGAN-GP 场景生成模型分析

本文基于 PyTorch 深度学习框架搭建条件 WGAN-GP 模型,算例中风光出力数据来源于美国的 NREL 实验室。图 4 和图 5 分别是条件 WGAN-GP 训练过程中生成风电和光伏出力的效果图。

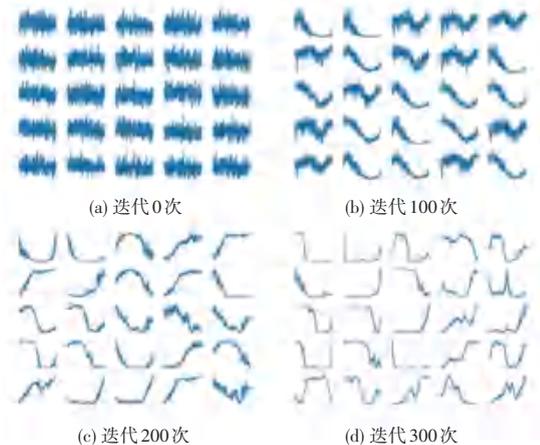


图 4 基于条件 WGAN-GP 的风电出力效果图

Fig. 4 Effect graphs of wind power output based on conditional WGAN-GP

图 5(a)~图 5(d)分别是条件 WGAN-GP 训练过程中迭代 0、100、200、300 次的效果图。迭代次数为 0 时,由于还未开始训练,尚未学习到原始数据的分布特征,生成的风光出力曲线为随机波动的白噪声。随着迭代次数的增加,生成器不断地学习,进而生成的风光出力数据质量逐渐地增高,达到 100 次和 200 次时,从图 5(b)和图 5(c)可以看出,生成的数据已经具有了一些风光出力周期性变化的特征,

而且明显可以看出,由于图 5(c) 迭代次数更多,生成器学习到更多的风光出力特征,因此生成的数据质量要比图 5(b) 更高,但此时仍未充分捕获风光出力数据的内在特性。当迭代次数达到 300 次时,生成器与判别器达到动态平衡,此时生成的风光出力曲线较平滑。可以看出,本文使用的条件 WGAN-GP 模型能较好地学习到风光出力的特征,生成符合真实规律的风光出力数据。

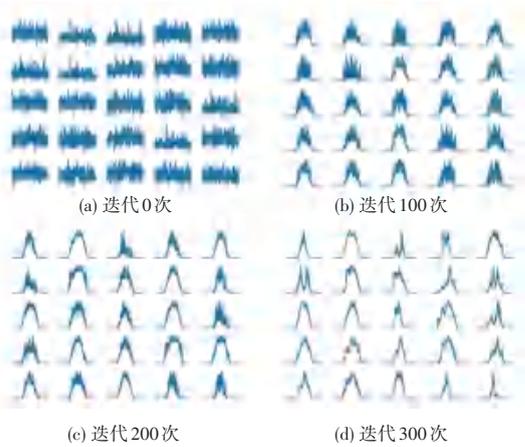


图 5 基于条件 WGAN-GP 的光伏出力效果图

Fig. 5 Effect graphs of photovoltaic power output based on conditional WGAN-GP

为进一步验证生成的风光出力数据的有效性,通过绘制风光的真实数据与生成数据的累积概率分布函数^[21],如图 6 和图 7 所示。从图 6、图 7 中可以看出,生成的数据的概率分布和实际数据的概率分布十分接近,这表明了本文基于条件 WGAN-GP 生成的风光出力数据是合理的。

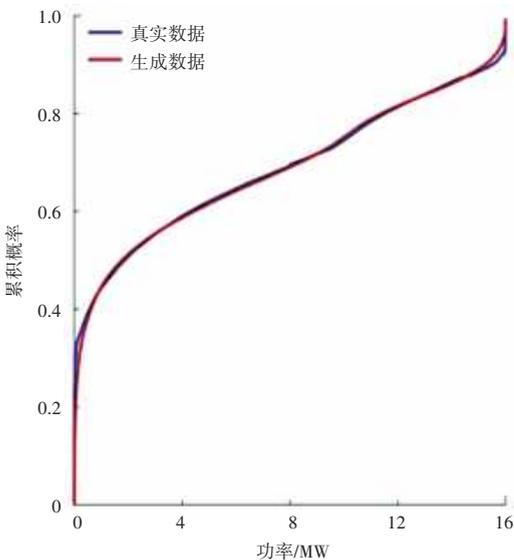


图 6 风电生成数据和真实数据的概率分布比较

Fig. 6 Comparison of probability distribution between wind power generation data and real data

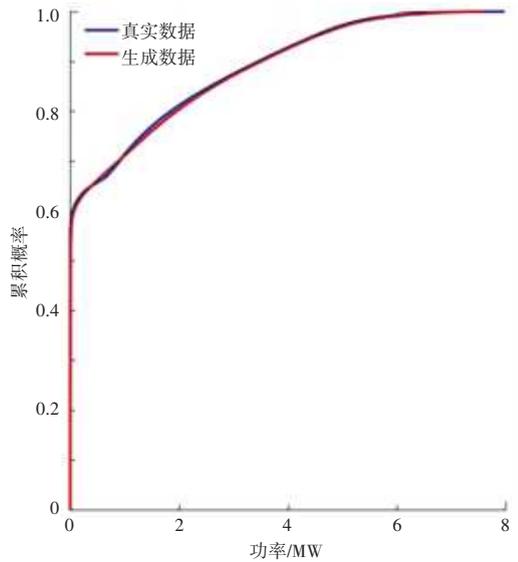


图 7 光伏生成数据和真实数据的概率分布比较

Fig. 7 Comparison of probability distribution between photovoltaic power generation data and real data

4.3 优化规划结果分析

本文设定了 3 种不同的方案进行比较,分述如下:

- (1) 方案 1. 为在本文所提出规划方案下安装 DG。
- (2) 方案 2. 为在负荷水平较高的节点多安装 DG, 但每个节点的 DG 接入容量不超过该节点 80% 的负荷。
- (3) 方案 3. 为不安装 DG, 仅由上级电网向本系统供电。

规划结果见表 5,在风机、光伏和微型燃气轮机配置结果中,括号外的数字代表 DG 的安装节点,括号内的数字代表 DG 在此节点的安装数量。

通过分析表 5,可以得出以下结论:

(1) 从方案 3 的结果可以看出,配电网的网损费用 54.30 万元,向上级电网购电费用为 1 078.74 万元,社会年综合成本为 1 133.04 万元,明显均高于方案 1 和方案 2。这表明 DG 接入配电网能提升配电网运行的经济性。

(2) 与方案 2 和方案 3 相比,采用本文所提出规划方法的方案 1 网损费用最低,这是由于通过在配电网中合理配置 DG,减少了配电网中潮流的流动,有效地降低了网损。

(3) 从方案 1 中 DG 的配置结果可看出,DG 更多地安装在线路的末端。这是因为当首端电压一定时,线路末端电压水平难以维持在所允许水平内,而接入 DG 后,能很大程度上提高线路末端电压水平,减小线路首端和末端电压差,满足系统电压要求。

(4) 考虑风光出力不确定性是合理的,相比于将其视为确定性的方案,与实际情况更加贴近,可实现总体运行成本最低,且可以较大地减少社会年综合费用。

表5 规划结果

Tab. 5 Planning results

	风机配置结果	光伏配置结果	微型燃气轮机配置结果	DG 投资费用/ (万元·年 ⁻¹)	DG 运行维护费用/ (万元·年 ⁻¹)	网络损耗费用/ (万元·年 ⁻¹)	上级电网购电费用/ (万元·年 ⁻¹)	DG 年发电补贴收益/ (万元·年 ⁻¹)	社会年综合成本/ (万元·年 ⁻¹)
方案 1	4(2) 7(0) 17(7) 28(0)	13(2) 20(4) 24(3) 32(6)	29(0) 30(2)	131.21	80.00	26.18	731.14	77.56	890.98
方案 2	3(1) 6(3) 24(6) 31(3)	7(3) 13(1) 23(3) 28(1)	29(3) 30(2)	119.44	95.62	27.53	743.92	72.41	914.10
方案 3	—	—	—	0	0	54.30	1 078.74	0	1 133.04

5 结束语

本文采用多场景分析法对 DG 容量规划当中的不确定因素进行处理,然后构造了以年综合费用最小为目标的分布式电源优化配置模型。利用 IEEE33 节点配电系统进行仿真验证,实验结果表明所构建模型的有效型。得到结论如下:

(1) 提出使用条件 WGAN-GP 模型生成风光出力场景集,用 K-means 聚类算法对场景进行削减。简化了建模和计算的复杂度的同时,充分考虑风光出力的时序性和随机性。

(2) 算例结果表明,通过条件 WGAN-GP 模型生成的风光出力数据的概率分布和真实数据的概率分布十分接近,克服了传统抽样方法中假设的数据分布与真实数据分布不同而导致生成的场景不合理的问题。

(3) DG 优化配置结果表明,DG 接入配电网能明显减少社会年综合费用。与其他规划方案相比,本文所提出方案成本最低且更为合理。有利于未来 DG 进一步的推广和发展。

参考文献

- [1] 肖浩,裴玮,邓卫,等. 分布式电源对配电网电压的影响分析及其优化控制策略[J]. 电工技术学报,2016,31(S1):203-213.
- [2] MORADI M H, ABEDINI M. A combination of genetic algorithm and particle swarm optimization for optimal DG location and sizing in distribution systems[J]. Electrical Power and Energy systems, 2010, 34(1): 66-74.
- [3] 陈家俊,蒋铁铮,周勇,等. 考虑电压压降的分布式电源定容和选址[J]. 电网技术,2014,38(08):2244-2249.
- [4] 徐迅,陈楷,龙禹,等. 考虑环境成本和时序特性的微网多类型分布式电源选址定容规划[J]. 电网技术,2013,37(04):914-921.
- [5] 曹振其,彭敏放,沈美娥. 考虑源荷不确定性的分布式电源选址定容[J]. 电力系统及其自动化学报,2021,33(02):59-65.
- [6] 余金龙,赵文会,赵波,等. 基于多状态建模的独立型微网优化

配置[J]. 电力系统自动化,2015,39(06):11-17.

- [7] 黄金鑫,李华强,陆杨. 基于蒙特卡洛模拟和频谱分析法的孤岛微电网储能容量配置[J]. 电网技术,2020,44(05):1622-1629.
- [8] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Nets[C]//27th International Conference on Neural Information Processing Systems. Berlin:Springer,2014.
- [9] CHEN Yize, WANG Yishen, KIRSCHEN D, et al. Model-free renewable scenario generation using Generative Adversarial Networks[J]. IEEE Transactions on Power Systems,2018,33(3):3265-3275.
- [10] 李康平,张展耀,王飞,等. 基于 GAN 场景模拟与条件风险价值的独立型微网容量随机优化配置模型[J]. 电网技术,2019,43(05):1717-1725.
- [11] 董骁翀,孙英云,蒲天骄. 基于条件生成对抗网络的可再生能源日前场景生成方法[J]. 中国电机工程学报,2020,40(17):5527-5536.
- [12] 刘云鹏,许自强,和家慧,等. 基于条件式 Wasserstein 生成对抗网络的电力变压器故障样本增强技术[J]. 电网技术,2020,44(04):1505-1513.
- [13] 廖一帆,武志刚. 基于迁移学习与 Wasserstein 生成对抗网络的静态电压稳定临界样本生成方法[J]. 电网技术,2021,45(09):3722-3728.
- [14] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein GAN [J]. arXiv preprint arXiv:1701.07875,2017.
- [15] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of wasserstein gans [C]//The 31st International Conference on Neural Information Processing Systems. Long Beach, USA:dblp,2017:5767-5777.
- [16] 高红均,刘俊勇,魏震波,等. 主动配电网分层鲁棒规划模型及其求解方法[J]. 中国电机工程学报,2017,37(05):1389-1401.
- [17] BARAN M E, WU F F. Network reconfiguration in distribution systems for loss reduction and load balancing [J]. IEEE Transactions on Power Delivery,1989,4(2):1401-1407.
- [18] 初壮,李钊,白望望. 计及不确定性和环境因素的多类型分布式电源选址定容[J]. 电力系统保护与控制,2017,45(13):34-41.
- [19] 徐雨田,廖清芬,刘涤尘,等. 主动管理模式下基于多场景分析的分布式电源规划[J]. 电工能新技术,2018,37(02):38-46.
- [20] 张沈习,袁加妍,程浩忠,等. 主动配电网中考虑需求侧管理和网络重构的分布式电源规划方法[J]. 中国电机工程学报,2016,36(S1):1-9.
- [21] 顾洁,刘书琪,胡玉,等. 基于深度卷积生成对抗网络场景生成的间歇式分布式电源优化配置[J]. 电网技术,2021,45(05):1742-1751.