第 49 卷 第 6 期：2253-2263 高电压技术 Vol.49, No.6: 2253-2263
2023 年 6 月 30 日 High Voltage Engineering June 30, 2023
DOI: 10.13336/j.1003-6520.hve.20230459

基于条件生成对抗网络的风电功率极端场景生成

米 阳[1]，卢长坤[1]，申 杰[1]，杨 熙[1]，葛磊蛟[2]
（1. 上海电力大学电气工程学院，上海 200090；2. 天津大学电气自动化与信息工程学院，天津 300110）

摘 要：针对风电功率不确定的电力系统调度和规划问题，提出了一种极端场景生成框架。首先，采用迭代方式对历史数据集的分布进行转移，解决了历史数据集中极端样本不足的问题。其次，根据风电功率特征定义不同的极端度量，并对风电功率场景设置不同的极端度量范围，实现不同极端度量范围下的可控生成，增强场景生成的可解释性。然后，通过条件生成对抗网络实现极端场景的可控场景。最后基于风电功率实时数据进行验证。结果表明：所设计的框架不需要复杂的概率建模和采样过程，同时可以捕捉到不同极端情况下的随机特性和动态特性。所提出的方案生成场景的极端度量值准确率在 90%以上，能够在可控的极端度量范围以及误差范围内有效生成场景。
关键词：场景生成；极端情况；生成对抗网络；数据增强；调度和规划

Wind Power Extreme Scenario Generation Based on Conditional Generative Adversarial Network

MI Yang[1], LU Changkun[1], SHEN Jie[1], YANG Xi[1], GE Leijiao[2]
(1. College of Electrical Engineering, Shanghai Electric Power University, Shanghai 200090, China;
2. College of Electrical Automation and Information Engineering, Tianjin University, Tianjin 300110, China)

Abstract: Aiming at the problem of uncertain wind power in the scheduling and planning of power system, we propose an extreme scenario generation framework. Firstly, the distribution of historical data set is transferred by iterative method to solve the problem of insufficient extreme samples in historical data set. Secondly, different extreme measurements are defined according to wind power characteristics, and different extreme measurement ranges are set for wind power scenarios, so as to achieve controllable generation under different extreme measurement ranges and to enhance the interpretability of scene generation. Then, conditional generation adversarial network is used to achieve controllable scenario generation of extreme scenarios. Finally, numerical results based on real-time wind power data show that the designed framework does not require complex probabilistic modeling and sampling process, and can capture random and dynamic characteristics in different extreme cases. The proposed scheme can generate scenes effectively within the controllable range of extreme measures and error, and the accuracy of extreme measures is more than 90%.
Key words: scenario generation; extreme conditions; conditional generative adversarial network; data augmentation; dispatch and planning

0 引言

为应对能源危机和环境污染等问题[1]，需要大力发展清洁高效的新能源电力系统。风能等可再生能源由于清洁无污染和资源丰富，其并网比例显著增加，但是由于其波动性和间歇性会给电力系统的稳定性和经济性带来巨大的挑战[2]，因此需要充分考虑不同因素导致的极端场景[3-4]给新型电力系统的规划运行带来的影响，研究如何对历史数据中的极端数据进行处理并提出极端条件下可再生能源场景生成框架。

场景分析法是处理可再生能源出力不确定性的方法之一，通过对不确定性场景进行概率建模，将产生的随机场景用于电力系统的鲁棒优化和随机优化等不确定性分析中[5]。场景生成方法通常有含参数的概率模型和不含参数的深度生成模型 2 种[6]。常用的含参数方法是蒙特卡洛抽样或者拉丁超立方抽样等基于采样的方法[7]。目前已有研究提出了几种概率模型来表征概率分布，例如高斯分布、贝塔

基金资助项目：国家自然科学基金(61873159)；上海市自然科学基金(22ZR1425500)。
Project supported by National Natural Science Foundation of China (61873159), Shanghai Natural Science Foundation (22ZR1425500).

分布用于对可再生能源的不确定建模[8]。也有研究应用 Copula 技术对参数分布进行建模，捕获随机过程的相关性[9-10]，然而上述基于模型的方法不能充分考虑可再生能源出力的各种时空相关性，在实际应用环境复杂的情况下需要进行先验假设和琐碎的建模，可能会造成参数拟合误差较大，降低生成场景的质量。

深度学习在数据挖掘、特征提取领域展现出了优越的性能，随着人工智能的发展，不含参数的深度生成模型广泛应用于可再生能源场景的生成。文献[11]首次将生成对抗网络(generative adversarial networks，GAN)应用于可再生能源发电场景中，生成符合概率分布的可再生能源功率曲线以及不同条件下的可再生能源功率曲线。文献[12]基于条件时序生成对抗网络生成空调负荷的典型场景，实现了基于空间和时间的特征捕捉。文献[13]提出一种基于时序卷积网络结构的序列生成对抗网络方法，并通过聚类筛选生成长期的月度可再生能源出力场景。文献[14]采用联邦学习的技术，实现在多个配电网运营商条件下的分布式场景生成，为隐私保护提供保障。文献[15]提供了一种基于天气预测的日前场景生成方法，采用样式化的生成对抗网络，不仅能够提升生成场景的质量，还能描述不同天气条件下可再生能源场景的概率分布特征。文献[16]使用像素卷积生成网络对可再生能源场景进行生成，生成的场景能够涵盖可再生能源的发电特征。文献[17]采用条件生成对抗网络对风电功率日前场景进行概率预测，学习预测曲线与实际曲线的相关性，获得较为准确的实际曲线概率分布。然而以上方法中，忽略了在不同的极端条件下可再生能源场景的分布特征，未研究极端情况下可再生能源出力特征与深度生成模型网络结构之间的关系，可解释性较差。因此，本文针对不同条件下电力系统的运行规划中的场景进行极端度量，从而对风电功率场景进行细致的可控生成。

改进的条件生成对抗网络能够针对风电功率的固有特征进行连续范围生成，通过合理设置极端度量来对风电功率特征进行描述。已有文献采用离散条件通过条件生成对抗网络对场景进行生成[18]，或者根据单一日前场景进行生成[17]。而在复杂的气候条件引发的各种极端条件下的场景研究尚且存在不足，无法获得极端条件下的随机场景。

基于以上研究，本文提出了一个基于条件生成对抗网络的场景生成框架，主要优势和创新点有：

1）结合极端数据增强方法对风电功率场景进行生成，采用数据增强技术能够解决历史样本中极端样本不足的问题，提高生成模型的训练效果。

2）将 3 种极端度量方式作为条件信息，采用改进的条件生成对抗网络对场景的不同极端度量进行场景生成，增加场景生成的可解释性，能够根据不同的场景特征要求，生成符合电力系统运行规划方案要求的风电功率曲线。

3）能够对某一极端范围进行连续生成，精确描述场景生成的概率分布和生成曲线的极端特征，为优化决策提供了数据支持。

1 条件生成对抗网络与数据增强

1.1 条件生成对抗网络

GAN 是由 Goodfellow 提出的一种基于博弈论的无监督生成式模型[19]，模型结构中包含生成器和判别器 2 个深度神经网络，通过 2 个神经网络之间相互对抗博弈逐渐生成与真实样本相似的假样本。条件生成对抗网络(conditional generative adversarial networks，CGAN)将监督学习与半监督学习结合，允许在生成样本的过程中将附加信息作为生成器的输入，指导样本的生成过程。

在 CGAN 中假设生成器 G 的输入样本为噪声 z，服从分布 $p(z)$，真实样本为 x，服从数据分布 $p(x)$，c 表示输入的附加样本信息，$G(x|c)$表示生成的样本，生成的样本作为判别器 D 的输入，判别器 D 的输出为一个标量 $D(G(x|c))$。生成器的目标是使生成样本更加接近真实样本的分布，判别器的目标是对生成器生成的数据辨别真伪，判别器的输出可以表示为

$$\begin{cases} P_{\text{real}} = D(x \mid c) \\ P_{\text{fake}} = D(G(x \mid c)) \end{cases} \tag{1}$$

式中 P_{real}、P_{fake} 分别表示判别器对真实样本和生成样本的输出值。

在 CGAN 中生成器的目标函数 L_{G} 和判别器的目标函数 L_{D} 可以表示为：

$$L_{\text{G}} = E_{z\sim p(z)}(\ln(1 - D(G(z \mid c)))) \tag{2}$$

$$\begin{aligned} L_{\text{D}} = &-E_{x\sim p(x)}(\ln D(x \mid c)) - \\ &E_{z\sim p(z)}(\ln(1 - D(G(z \mid c)))) \end{aligned} \tag{3}$$

式中 $E_{x\sim p(x)}$、$E_{z\sim p(z)}$ 表示每一批样本的期望值。

最终，2 个网络不断进行迭代，直到网络参数稳定达到纳什均衡，其表达式为

$$\min_G \max_D V(D,G) = E_{x\sim p(x)}(\ln D(x\mid c)) + E_{z\sim p(z)}(\ln(1-D(G(z\mid c)))) \tag{4}$$

1.2　数据增强

使用 GAN 进行数据增强已经广泛用于数据科学领域中，如在异常检测、医疗应用、自然语言处理中通过数据增强来解决数据之间的不平衡问题。在极端条件下的风电功率场景生成中，由于风电功率随机性强和极端样本数量不足，导致模型训练困难，因此，需要增强极端样本。原始 GAN 在样本增强过程中容易出现不稳定和崩溃的问题，因此使用带有梯度惩罚的生成对抗网络(Wasserstein generative adversarial networks with gradient penalty, WGAN-GP)进行样本增强。在 WGAN-GP 中采用 Wasserstein 距离作为损失函数[20]，其表达式为

$$W(p(x),p(g)) = \inf_{\pi(x,g)} \int d(x,g)\pi(x,g)\mathrm{d}x\mathrm{d}g \tag{5}$$

式中：inf 表示下界；$p(g)$表示生成样本的分布；$\pi(x,g)$为满足 $p(x)$与 $p(g)$边缘分布的联合概率密度分布；$d(x,g)$为场景间距离测度。

使用 Wasserstein 距离代替 JS 散度进行数据增强能缓解训练不稳当带来的崩溃问题，在 WGAN 中的表达式为

$$W(p(x),p(g)) = \sup_{\|f_D\|_L} E_{x\sim p(x)}(D(x)) - E_{z\sim p(z)}(D(G(z))) \tag{6}$$

式中：sup 表示上界；$||f_D||_L \le 1$ 表示判别器 D 需要满足 1-Lipschitz 连续。

引入梯度惩罚增强 Lipschitz 连续性使模型更快收敛[21]，其表达式为

$$L_p\big|s = E_{s\sim p(s)}((\|\nabla_s D(s)\|_2 - 1)^2) \tag{7}$$

式中 $s = tx + (1-t)G(z)$，是对生成样本和真实样本之间插值的变量，t 服从 0~1 的均匀分布。

根据式(6)和式(7)，判别器的损失函数为[20]

$$L_{\mathrm{GP}} = E_{z\sim p(z)}(D(G(z))) - E_{x\sim p(x)}(D(x)) + \lambda L_p\big|s \tag{8}$$

式中 λ 表示梯度惩罚的权重。

采用 WGAN-GP 的方法进行数据增强，能够保证模型训练的收敛性和稳定性，避免生成崩溃的样本，进而影响极端条件下的样本训练。

2　极端条件下的场景生成框架

2.1　分布转移

由于风电功率极端场景在极端度量分布中一般为尾部部分，例如，图 1 所示的某地风电日平均功率分布中，高功率出现在分布的右尾部分，需要重点针对右尾进行场景生成。直接提取尾部部分的数据进行训练不能达到训练数据中数据多样性以及数量的要求，因此，需要一种能够提取尾部分布并且使尾部数据满足训练数据多样性和数量要求的方法。对于上述问题，本文采用一种基于 WGAN-GP 的分布转移方法[22]，方法的流程如图 2 所示。核心思想是通过选取合适的转移因子 ϵ 过滤掉相对普通的场景，将生成的场景并入数据集，重新进行分布转移。首先按照极值度量递减顺序对数据集进行排序，使用 WGAN-GP 对场景数据进行训练，假设数据集样本个数为 n，从原始数据集中选取 $\epsilon^i n$ 个较为极端的样本，然后从训练的模型中生成$(n-(\epsilon^i n))/\epsilon^i$

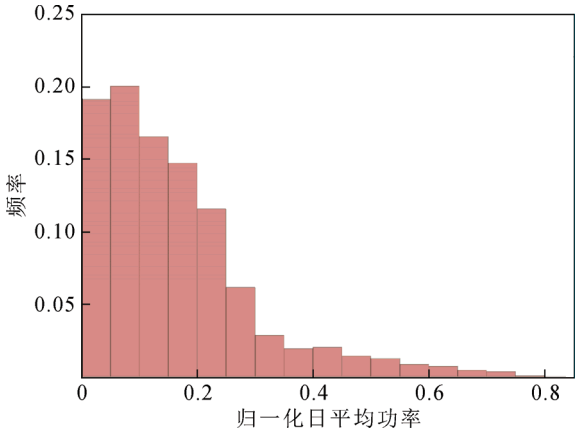


图 1　某地日平均功率分布图

Fig.1　Average daily power distribution of a place

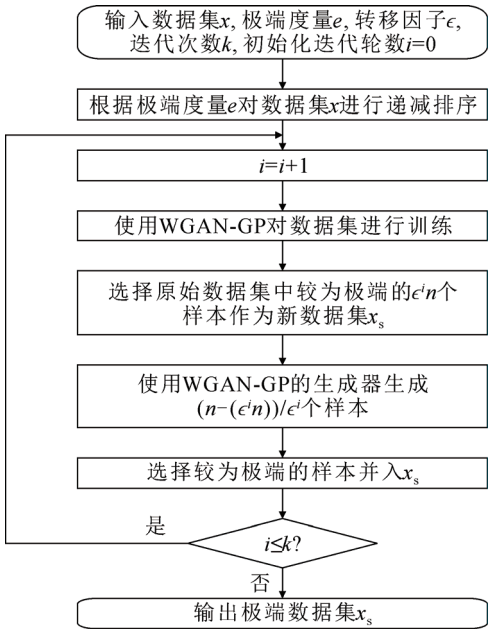


图 2　极端数据增强流程

Fig.2　Process of extreme data augmentation

个样本，选取其中较为极端的 n–($\epsilon^t n$)个样本，将从原始数据集和生成数据集中选取的极端样本合并为新的数据集。这样就确保了数据集的大小不变，且生成的样本更接近极端条件的样本，同时生成的分布也更接近极端尾部分布。

为了提高转移效率，在每一轮转移的过程中，采用热启动的方式，使用上一轮迭代的生成器参数对每一轮新的数据集进行训练，减少每一轮训练的次数，从而减少训练时间。通过使用 WGAN-GP 的方式进行训练并生成样本，然后采用分布转移的方法，对生成样本进行多次过滤后，得到新的数据集，新数据集涵盖极端场景的功率特征，可以使用该数据集以及对应的数据集样本的极端度量作为CGAN的输入部分进行样本生成。

2.2 极端条件下场景生成

在规划运行的决策过程中，无监督的场景生成方案可能在某些方面难以获得精确的结果，由于潜在空间中的数据表示缺乏解释能力，因此无法在基于无监督学习的场景生成期间实现模式偏好。电力系统规划和管理的研究需要考虑相对极端的运行场景，场景生成预计将结合极端度量以及领域知识的复杂度量方法进行风电功率场景生成，考虑到不同的极端风电功率场景带来的影响，使用风电功率均值的大小代表风电功率的高低，使用风电功率的峰谷差表示风电功率的变化情况，将 3 种极端度量方式进行适当的处理作为 CGAN 的附加条件信息，由于 CGAN 能够学习到附加条件信息和生成内容之间的相关性，通过附加不同的极端度量就可以指导极端度量下的风电功率场景生成。训练好生成模型后，运行人员可以根据需要的极端度量从一定连续的极端范围中对风电功率场景进行生成，从而结合自身需求和领域知识在极端范围内确定典型场景分布，准确描述风电功率变化的不确定性，针对图 3 所示的问题做出更有效的决策。

根据风电功率曲线特点，本文重新设计了判别器和生成器的神经网络架构。图 4 展示了生成器和判别器的细节。如图 4 所示，本文全部采用线性层或卷积层、实例归一化和激活函数组成的神经网络块构成模型的主体，图中 D_{in} 表示输入维度，D_{out}

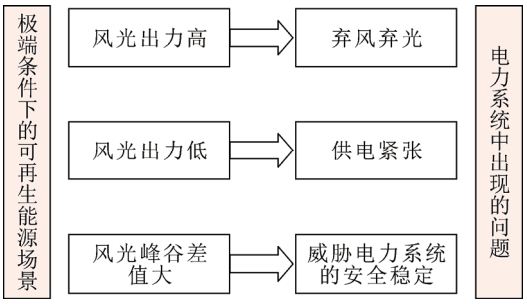


图 3 极端场景下电力系统中的问题

Fig.3 Problems in power systems under extreme scenarios

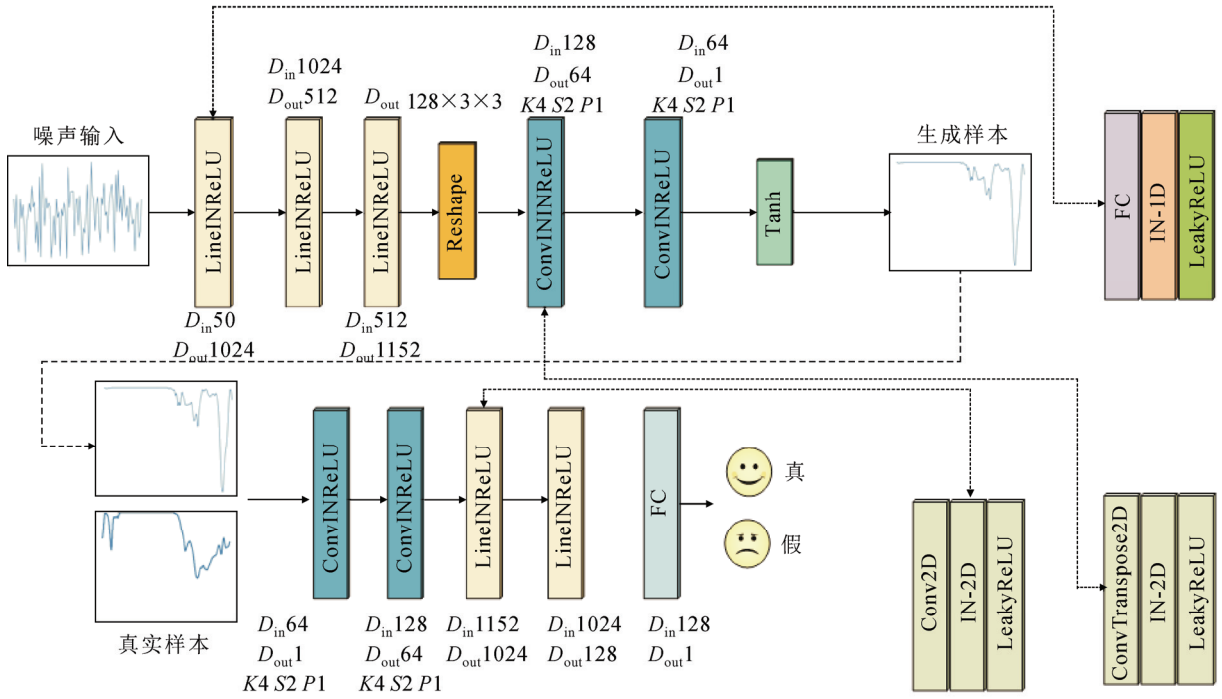


图 4 极端条件生成模型网络结构

Fig.4 Network structures of extreme conditions generation

表示输出维度，K 表示卷积核大小，S 表示步长大小，P 表示填充大小，D_{in}、D_{out}、K、S、P 后的数字表示参数的取值，FC 表示全连接层，Conv 表示卷积层，IN-1D 表示实例归一化。

由于生成的目标的变化，需要对 CGAN 的损失函数需要进行一定调整，使其适应生成目标的要求。为了减少生成器生成样本的极端度量值偏差，需要在基础的损失函数上添加一项极端损失 L_{e}，该项损失由生成样本极端度量值偏离真实样本极端度量值的程度来表示，即

$$L_{\text{e}} = E_{z,e}\left(\frac{|e - E_x(G(z,e))|}{e}\right) \tag{9}$$

式中：$E_{z,e}$ 表示标准化极端度量的期望；z 是从标准正态分布中进行采样的噪声；e 是真实样本的极端度量；$E_x(G(z,e))$是生成样本的极端度量。在生成器中添加这项损失可以使整个模型倾向于生成符合目标要求的样本，使生成的样本能够根据极端度量值减少产生的误差，提高场景的生成质量，所提出的完整极端条件下的风电功率场景生成框架如图 5 所示，图中标幺功率的基准值为 16 MW。

通过上述对历史数据集中尾部极端数据的处理，CGAN 生成器损失函数的改进以及针对极端条件下的风电功率场景生成神经网络结构的设计，使用 CGAN 的场景生成框架能够适应风电功率曲线

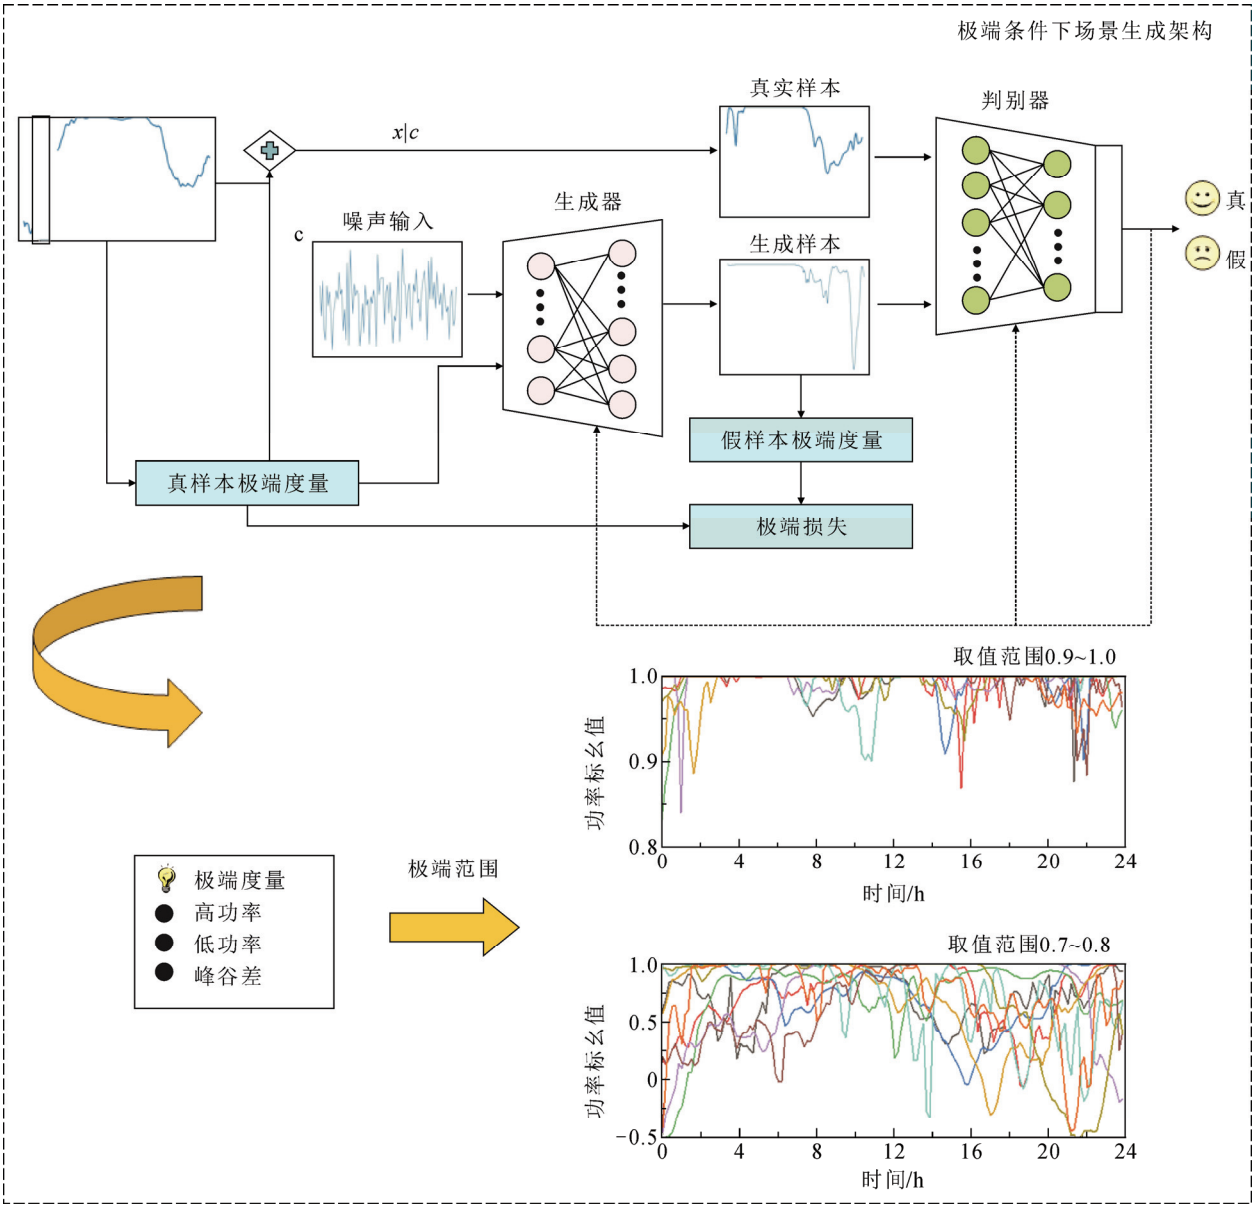


图 5　极端条件场景生成架构

Fig.5　Framework of extreme scenario generation

生成过程中潜在空间的复杂变化，所生成的场景可以准确再现风电功率的极端度量特征。采用本方法生成场景无需对风电功率进行复杂的建模，避免抽样过程中产生的误差，只要足够的历史数据集，就可以描述风电功率的不确定性，并且能够根据极端度量的不同获得高质量的极端条件下的风电功率场景集，为电力系统的调度过程以及规划方案的决策提高准确的数据支撑，减少电力系统决策过程中产生的经验偏差，使整个电力系统更可靠。

3 算例分析

3.1 数据集分析

本文使用某实验室收集的风电功率数据[23]进行试验，包括 16 个采样间隔为 10 min 的风力发电站，对于每一种极端度量，使用 80%的数据集作为训练集，20%的样本作为测试集，首先对训练集和测试集同时进行样本增强，然后选择 80%的样本进行训练，实验全部使用 Python3.7 版本下的 Pytorch 深度学习框架，硬件参数为 Intel(R) Core (TM) i7-12700H CPU, Nvidia GTX 3080 GPU，64.00 GB RAM。

3.2 模型参数设置

经过反复实验，生成模型的训练批数大小(batchsize)设置为 128，卷积层的初始化服从标准差为 0.02 的正态分布，增强参数设置为 0.75，增强轮数设置为 5。增强样本的学习率为 0.000 02，极端样本生成的学习率为 0.0002，实验中采用的 Adam 优化器参数 β_1 和 β_2 分别设置为 0.5 和 0.999。中间层的激活函数为 LeakyrReLU，参数设置为 0.2。所有生成器的激活函数采用双曲正切函数(tanh)使输出值的范围在–1~1 之间，极端样本判别器的激活函数使用 S 函数(sigmoid)。

3.3 极端场景生成

本节通过定义好的极端度量方式，采用上述框架进行极端场景生成。使用功率曲线的高功率值、低功率值、峰谷值 3 种极端度量进行样本生成，其中高功率值和低功率值使用功率曲线平均功率值来衡量，峰谷差使用功率曲线的最大功率值和最低功率值之差来衡量。由于使用同一模型进行训练，为了方便数据处理，需要将极端度量范围统一。风电功率曲线均值大小归一化的取值范围均为–1~1，功率最大值和功率最小值的归一化范围同样为–1~1，而峰谷差的取值范围为 0~2，为了将峰谷差的度量形式与高功率值和低功率值的范围统一，对传统峰谷差的度量计算式减去常数 1 进行修正，如下：

$$\delta_{\mathrm{MaxMin}} = \max(P) - \min(P) - 1 \tag{10}$$

式中：δ_{MaxMin} 表示峰谷差度量；P 表示一天的风电功率曲线。

生成极端功率曲线的场景图和分布图如图 6 所示，其中(a)、(b)、(c)分别对应 3 种极端度量，上半部分是极端场景，下半部分为极端场景对应的极端度量值分布，极端值分布的横轴标幺功率基准值为 16 MW，纵轴频率表示极端值度量出现的次数与生成样本总数的比值。选用极端范围值分别为 0.7~0.8 和 0.9~1.0 来验证方法的有效性。3 种极端度量下符合极端度量值范围的发电功率曲线占比见表 1。

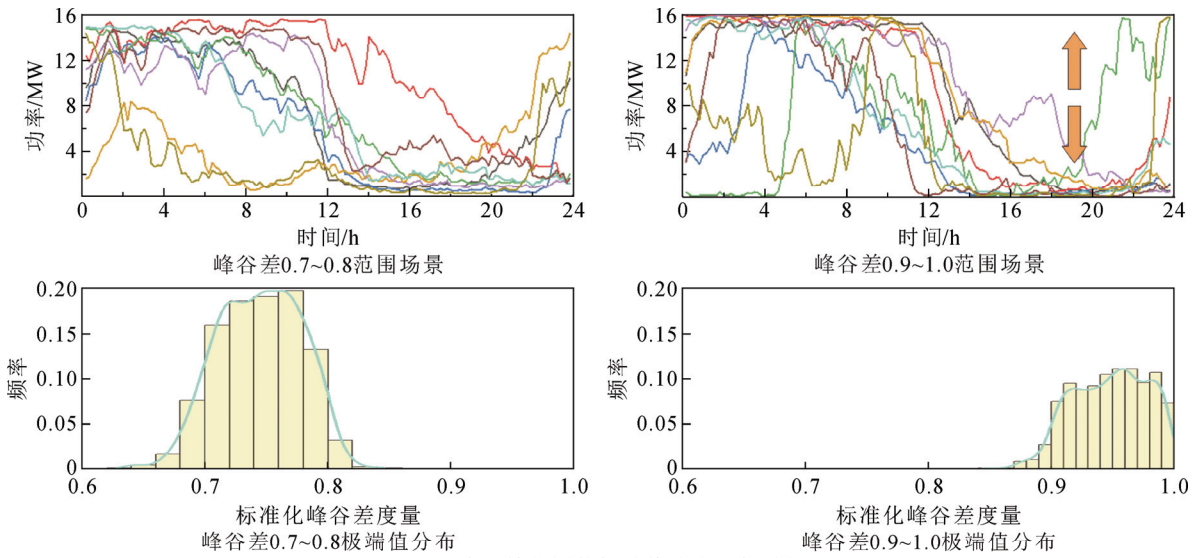
在所有情况中符合极端度量范围要求的极端风电功率曲线均达到了 90%。证明了该方法能够实现基于可控极端度量范围下的风电功率场景生成。图 6 上半部分的场景图展示了采用该方法生成的 3 种极端度量在不同极端度量值范围下的风电功率曲线，其中，每条曲线表示一天的风电功率变化，可以直观地看出所有生成的风电功率曲线均符合对应极端度量的功率特征，并且在不同极端度量值范围下，其功率特征也存在明显的差异，证明该场景生成方法能够生成各种极端条件下的风电功率场景。图 6 分布图中的曲线表示极端度量值分布，能够看出两端出现的误差与符合极端范围要求的极端度量值分布相比所占的比例较小，属于可容忍的误差范围。

为验证本文所提极端场景生成方法的有效性，图 7 展示了真实样本的极端度量分布、使用 DCGAN 方法生成极端样本的极端度量分布以及本文方法生成样本的极端度量分布，其中功率度量的标幺功率为 16 MW。在场景生成中，期望生成的样本分布与真实的样本分布尽量相似，能够准确表达真实样本的不确定性。在极端条件下的场景生成中，同样期望真实样本的极端度量值分布接近与真实样本的极端度量值分布，能够明确反映真实样本在极端条件下的不确定性。由图 7 左侧的密度分布图可知，相

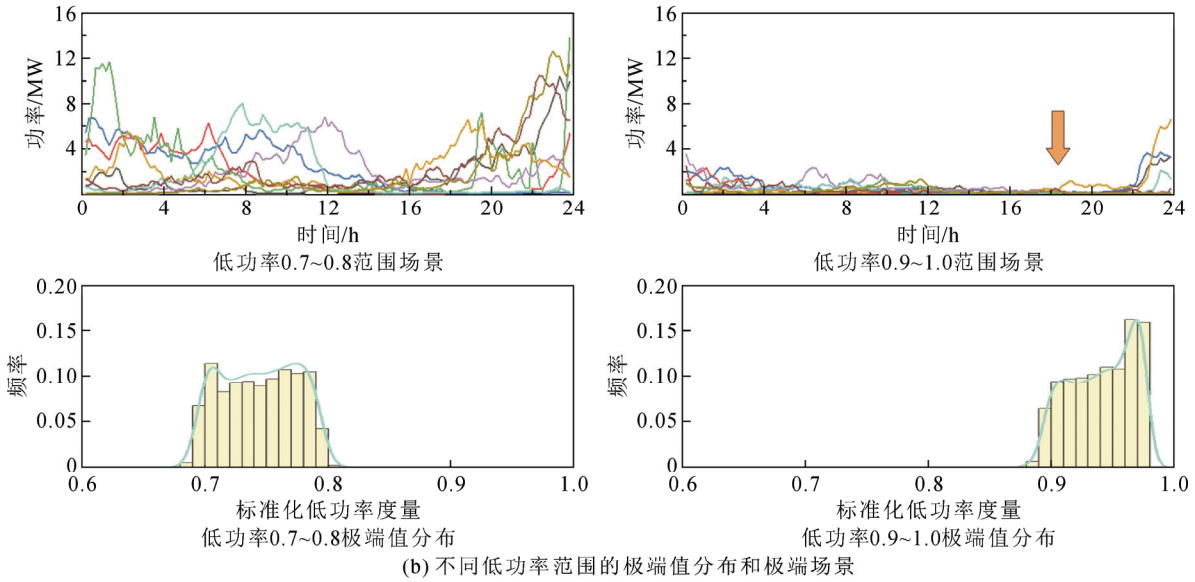
表 1 不同范围度量值准确率

Table1 Accuracy of different ranges of measurements

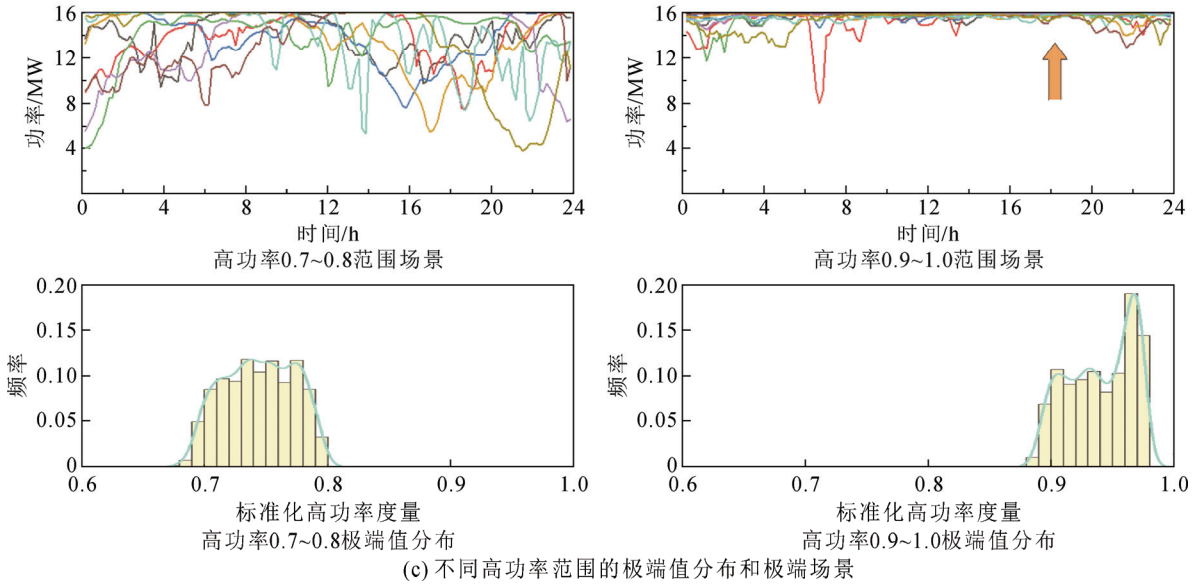
极端度量	峰谷差准确率/%	高功率准确率/%	低功率准确率/%
0.7~0.8 度量范围	90.2	94.3	92.6
0.9~1.0 度量范围	95.3	92.1	93.0



(a) 峰谷差范围的极端值分布和极端场景



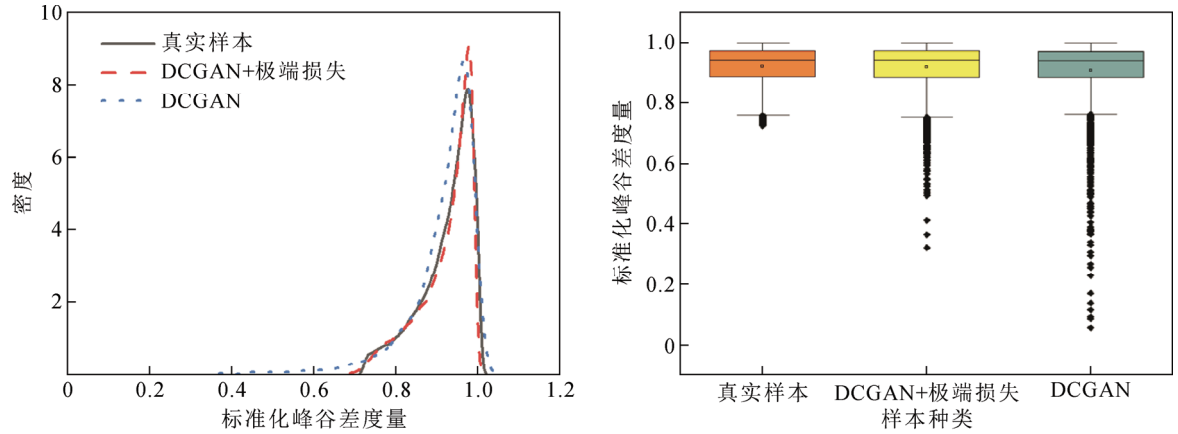
(b) 不同低功率范围的极端值分布和极端场景



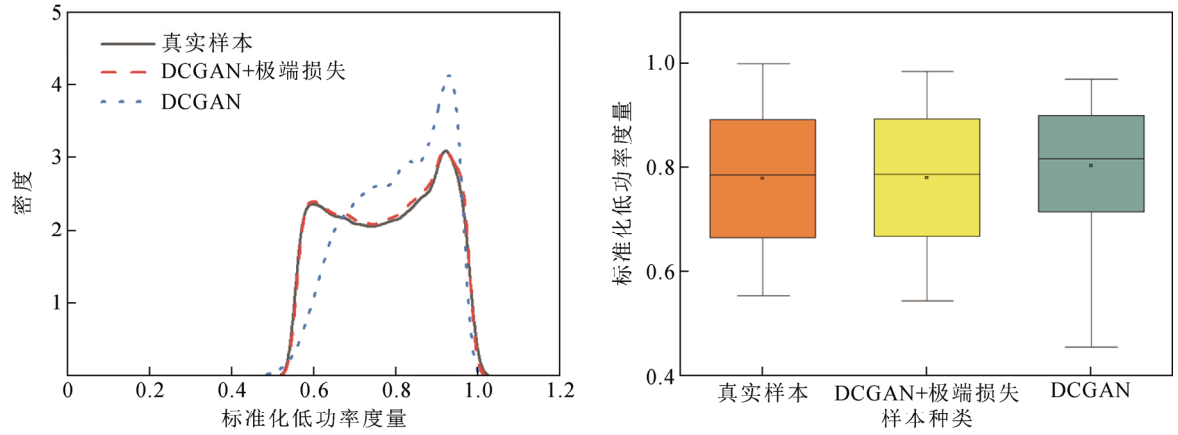
(c) 不同高功率范围的极端值分布和极端场景

图 6　不同极端范围下极端值分布及随机极端度量的场景

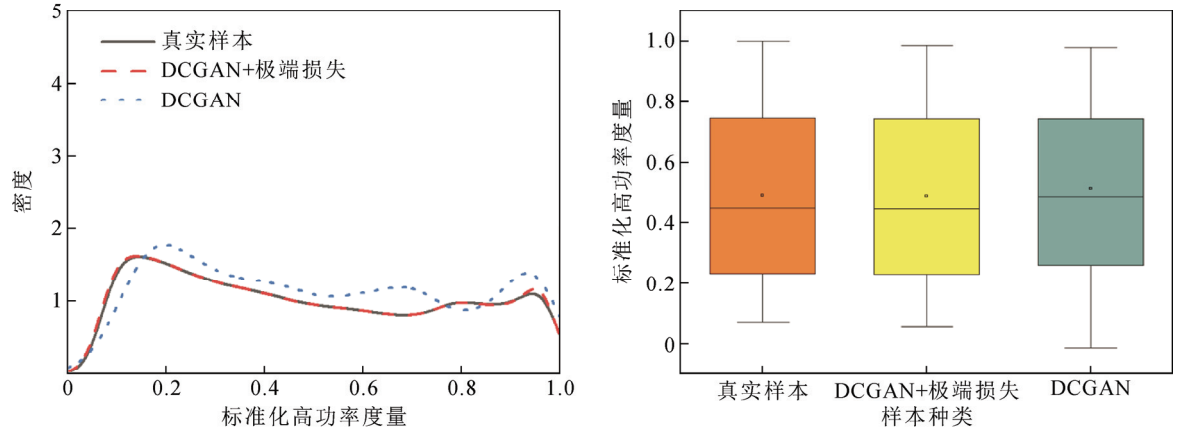
Fig.6　Scenarios and extreme value distributions of random extreme measures in different extreme ranges



(a) 峰谷差值分布



(b) 低功率值分布



(c) 高功率值分布

图 7 不同极端度量下样本极端值分布对比

Fig.7 Comparison of distribution of sample extreme values under different extreme measures

较于真实的样本度量值分布，采用 DCGAN 方法生成的样本度量值分布会整体进行偏移，说明 DCGAN 在生成极端样本方面会产生一定偏差。采用 DCGAN 和极端损失方法生成的样本可以在一定程度上纠正这种样本偏移的现象，使生成样本的度量值分布更接近真实的度量值分布。图 7 右侧的箱型图将这种分布的差异数值化，箱型图的数据差异越小，生成场景的质量越高。在峰谷差度量中，3 种方法度量范围差异较小，但是只采用 DCGAN 会生成较多的数据异常点，偏离中心分布；在低功率度量中，真实样本的箱体范围与采用极端损失的 DCGAN 生成方法箱体范围下限相差 0.3%，箱体范围的下限会相对于真实样本减少 15.6%，而整体的分布范围则会增大，说明只采用 DCGAN 进行极端

场景生成会产生较大误差；在高功率度量中，真实样本的箱体范围与采用极端损失的 DCGAN 生成方法箱体范围下限相差 0.7%，采用 DCGAN 箱体范围下限相对于真实样本减少 5.27%，同样会产生整体分布范围增大的问题。在 3 种度量方式分析中，可以明显看出添加极端损失的生成方法能够提高场景生成的质量，使生成的极端场景更接近真实的极端场景。

3.4　极端场景静态指标评估

为了比较采用极端条件下场景生成方法的优越性，本文采用了几种通用的评估场景质量的评价指标，并对损失函数的改进和数据增强方法进行评估，其中对 80%初始样本进行训练，20%初始样本作为测试集。

1）Fréchet 起始距 (Fréchet inception distance，FID)用于深度生成模型的视觉任务中，用来衡量 2 个分布的相似程度，通过预训练的神经网络提取图片特征，然后通过 Fréchet 距离衡量相似性。为了使用 FID 进行评估，本文采用测试集构建了一个 50 个神经元的隐藏层自编码器用于提取场景特征，FID 距离表达式为

$$d_{\mathrm{FID}}=\|\mu_{\mathrm{r}}-\mu_{\mathrm{g}}\|^2+d_{\mathrm{Tr}}(\Sigma_{\mathrm{r}}+\Sigma_{\mathrm{g}}-2(\Sigma_{\mathrm{r}}\Sigma_{\mathrm{g}})^{1/2}) \tag{11}$$

式中：d_{Tr} 表示矩阵的迹；$(\mu_{\mathrm{r}},\Sigma_{\mathrm{r}})$和$(\mu_{\mathrm{g}},\Sigma_{\mathrm{g}})$分别表示真实场景和生成场景的均值和协方差。FID 数值越小，说明场景的分布越接近，场景的生成质量越高。

2）重构损失(reconstruction loss，REC)用来衡量生成器的生成效果[24]。生成器的重构损失计算式为

$$L_{\mathrm{rec}}=\frac{1}{m}\sum_{i=1}^{m}\min_{z_i}\|G(\boldsymbol{z}_i)-\boldsymbol{x}_i\|_2^2 \tag{12}$$

式中：$\boldsymbol{z}_i$ 表示潜在的空间向量；m 表示场景数量；$\boldsymbol{x}_i$ 表示测试集第 i 个样本。对于一个极端条件场景生成器，重构损失为

$$L_{\text{rec-ex}}=\frac{1}{m}\sum_{i=1}^{m}\min_{z_i}\|G(\boldsymbol{z}_i,E(\boldsymbol{x}_i))-\boldsymbol{x}_i\|_2^2 \tag{13}$$

计算重构损失时，初始化潜在向量为零向量，然后最小化上述目标，学习率设置为 0.001，使用 Adam 优化器训练 2000 轮。重构损失越小，说明生成器生成效果越好。

3）能量分数(energy score, ES)主要用来衡量风电功率场景概率密度偏差，其计算式为

$$\delta_{\mathrm{ES}}=\frac{1}{m}\sum_{i=1}^{m}\|\varsigma-\xi_i\|-\frac{1}{2m^2}\sum_{i=1}^{m}\sum_{j=1}^{m}\|\xi_i-\xi_j\| \tag{14}$$

式中：ς 表示风电功率输出；ξ_i 表示生成的第 i 个时间序列。ES 越低，说明场景质量越高。

4）均值绝对百分比误差(mean absolute percentage error，MAPE)用来进行极端值误差的评价，表达式为

$$\delta_{\mathrm{MAPE}}=E\left|\frac{e-u}{e}\right|\times 100\% \tag{15}$$

式中 u 为生成样本极端度量值。MAPE 越低，生成场景质量越高。

5）时间序列相关性用于时间序列分析中反映源荷在一段时间内的内在联系，表征一段时间的实际运行情况，自相关系数可以衡量时间序列的自相关性，自相关系数的表达式为

$$R(\tau)=\frac{E((S_t-\mu)(S_{t+\tau}-\mu))}{\sigma^2} \tag{16}$$

式中：E 表示期望运算符；τ 为时间间隔；S_t 为真实样本或生成样本在时刻 t 的功率值；μ为该出力序列的均值；σ 表示该序列功率标准差，生成样本自相关系数与真实样本的自相关系数越接近，生成极端场景的质量越高。

各种方法的静态指标数值如表 2 所示，与不加极端损失的场景生成框架相比，采用本文提出的极端场景生成方法在各种指标上都有提升，采用极端损失能够大幅度提升极端值偏差的误差，采用数据增强能够弥补由于数据不足引起的训练损失，2 种处理方法使生成的场景更接近真实的风力发电场景的极端情况，证明了所提方法的有效性。时间相关性及其误差图如图 8 所示，可知实际样本和生成样本的自相关系数非常接近，误差接近于 0，证明了该方法能够保留实际功率曲线的时间相关性，生成符合实际电力系统运行要求的功率曲线。

4　结论

针对风电功率的输出不确定性问题以及在电力系统中不同运行情况和条件下对场景的要求，本文提出了一种在连续范围内可控的极端条件下的场景生成框架，通过仿真得到以下结论：

1）通过一种数据增强方法解决历史数据集中极端数据不足的问题，同时对损失函数进行改进使生成模型能够在没有任何统计假设的情况下捕获风电功率的极端特征。

2）所提方法无需任何统计假设，避免了参数拟合误差，能够生成高质量的风电功率样本，并且满足实际电力系统的运行要求。

表 2 静态指标对比

Table 2 Static index comparison

方法	FID	REC	ES	MAPE
DCGAN	0.0582	0.0384	1.053	0.0375
DCGAN+极端损失	0.0357	0.0263	0.927	0.0168
DCGAN+极端损失+数据增强	0.0324	0.0254	0.918	0.0152

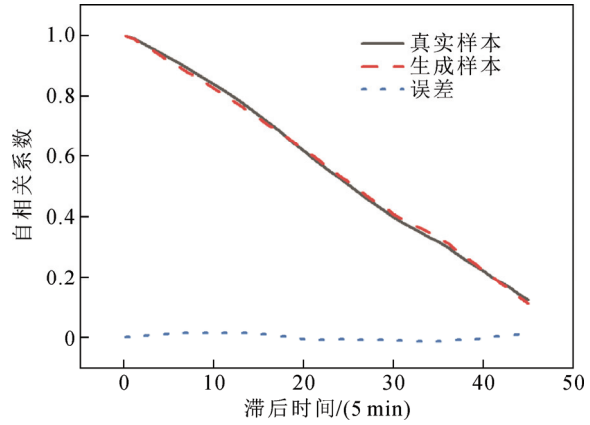


图 8 时间相关性分析

Fig.8 Temporal correlation analysis

3）实现了在不同极端条件要求范围内的精确采样，采样曲线的极端值在误差允许范围内，更加接近真实的极端分布。

然而，所提框架针对的极端度量值仅为常见需求的极端度量，在实际的电力系统运行规划方案中采用的极端度量可能更加复杂，仅仅通过公式可能难以度量，需要更复杂的数学模型或者采用数据驱动的方式进行度量，在这种条件下难以保证使用所提框架的稳定性。未来可以考虑一种通用的极端度量建立方法，比如将采用神经网络的方法建立需要的极端度量，再将通用的极端度量方法融入框架中。采用 GAN 的基础框架面对复杂的度量方法可能加剧模式崩溃的问题，如何高效稳定地生成高质量的场景仍然需要进一步的研究，未来会考虑采用其他更稳定的新型生成模型进行场景生成，比如扩散生成模型来建立满足广泛需要的生成框架。此外，考虑到可再生能源高度渗透，还可以采用所提方法生成不同条件的极端度量场景来验证不同电力系统决策方案和控制策略的有效性。

参考文献 References

[1] 韩肖清，李廷钧，张东霞，等. 双碳目标下的新型电力系统规划新问题及关键技术[J]. 高电压技术，2021，47(9)：3036-3046.
HAN Xiaoqing, LI Tingjun, ZHANG Dongxia, et al. New issues and key technologies of new power system planning under double carbon goals[J]. High Voltage Engineering, 2021, 47(9): 3036-3046.

[2] 雷 宇，杨 明，韩学山. 基于场景分析的含风电系统机组组合的两阶段随机优化[J]. 电力系统保护与控制，2012，40(23)：58-67.
LEI Yu, YANG Ming, HAN Xueshan. A two-stage stochastic optimization of unit commitment considering wind power based on scenario analysis[J]. Power System Protection and Control, 2012, 40(23): 58-67.

[3] PAN G S, HU Q R, GU W, et al. Assessment of plum rain's impact on power system emissions in Yangtze-Huaihe River basin of China[J]. Nature Communications, 2021, 12(10): 6156.

[4] 张 宁，周天睿，段长刚，等. 大规模风电场接入对电力系统调峰的影响[J]. 电网技术，2010，34(1)：152-158.
ZHANG Ning, ZHOU Tianrui, DUAN Changgang, et al. Impact of large-scale wind farm connecting with power grid on peak load regulation demand[J]. Power System Technology, 2010, 34(1): 152-158.

[5] 孙荣富，张 涛，和 青，等. 风电功率预测关键技术及应用综述[J]. 高电压技术，2021，47(4)：1129-1143.
SUN Rongfu, ZHANG Tao, HE Qing, et al. Review on key technologies and applications in wind power forecasting[J]. High Voltage Engineering, 2021, 47(4): 1129-1143.

[6] 董骁翀，张 姝，李 烨，等. 电力系统中时序场景生成和约简方法研究综述[J]. 电网技术，2023，47(2)：709-721.
DONG Zhongchong, ZHANG Shu, LI Ye, et al. A review of power system temporal scenario generation and reduction methods[J]. Power System Technology, 2023, 47(2): 709-721.

[7] 黎静华，骆怡辰，杨舒惠，等. 可再生能源电力不确定性预测方法综述[J]. 高电压技术，2021，47(4)：1144-1155.
LI Jinghua, LUO Yichen, YANG Shuhui, et al. Review of uncertainty forecasting methods for renewable energy power[J]. High Voltage Engineering, 2021, 47(4): 1144-1155.

[8] BLUDSZUWEIT H, DOMINGUEZ-NAVARRO J A, LLOMBART A. Statistical analysis of wind power forecast error[J]. IEEE Transactions on Power Systems, 2008, 23(3): 983-991.

[9] 涂青宇，苗世洪，林毓军，等. 基于动态 R 藤 Copula 模型的区域可再生能源集群超短期功率区间预测方法[J]. 高电压技术，2022，48(2)：456-470.
TU Qingyu, MIAO Shihong, LIN Yujun, et al. Ultra-short-term interval forecasting method for regional wind farms based on dynamic R-vine copula model[J]. High Voltage Engineering, 2022, 48(2): 456-470.

[10] PAPAEFTHYMIOU G, KUROWICKA D. Using copulas for modeling stochastic dependence in power system uncertainty analysis[J]. IEEE Transactions on Power Systems, 2009, 24(1): 40-49.

[11] CHEN Y Z, WANG Y S, KIRSCHEN D, et al. Model-free renewable scenario generation using generative adversarial networks[J]. IEEE Transactions on Power Systems, 2018, 33(3): 3265-3275.

[12] 曾 爽，丁屹峰，李香龙，等. 基于条件时序生成对抗网络的楼宇空调负荷场景生成方法[J]. 电网技术，2022，46(7)：2448-2455.
ZENG Shuang, DING Yifeng, LI Xianglong, et al. Scenario generation of air conditioning loads in buildings based on conditional Time-GAN[J]. Power System Technology, 2022, 46(7): 2448-2455.

[13] 李 辉，任洲洋，胡 博，等. 基于时序生成对抗网络的月度风光发电功率场景分析方法[J]. 中国电机工程学报，2022，42(2)：537-547.
LI Hui, REN Zhouyang, HU Bo, et al. A sequential generative adversarial network based monthly scenario analysis method for wind and photovoltaic power[J]. Proceedings of the CSEE, 2022, 42(2): 537-547.

[14] LI Y, LI J Z, WANG Y. Privacy-preserving spatiotemporal scenario

generation of renewable energies: a federated deep generative learning approach[J]. IEEE Transactions on Industrial Informatics, 2022, 18(4): 2310-2320.

[15] YUAN R, WANG B, SUN Y Q, et al. Conditional style-based generative adversarial networks for renewable scenario generation[J]. IEEE Transactions on Power Systems, 2023.38(2): 1281-1296.

[16] 廖文龙，杨德昌，葛磊蛟，等. 基于像素卷积生成网络的可再生能源场景生成[J]. 高电压技术，2022，48(4)：1320-1331.
LIAO Wenlong, YANG Dechang, GE Leijiao, et al. Renewable energy scenario generation based on pixel convolutional generative networks[J]. High Voltage Engineering, 2022, 48(4): 1320-1331.

[17] 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)：5527-5535.
DONG Xiaochong, SUN Yingyun, PU Tianjiao. Day-ahead scenario generation of renewable energy based on conditional GAN[J]. Proceedings of the CSEE, 2020, 40(17): 5527-5535.

[18] ZHANG Y F, AI Q, XIAO F, et al. Typical wind power scenario generation for multiple wind farms using conditional improved Wasserstein generative adversarial network[J]. International Journal of Electrical Power & Energy Systems, 2020, 114: 105388.

[19] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C] // Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal, Canada: ACM, 2014: 2672-2680.

[20] HOCHREITER R, PFLUG G C. Financial scenario generation for stochastic multi-stage decision processes as facility location problems[J]. Annals of Operations Research, 2007, 152(1): 257-272.

[21] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: ACM, 2017: 5769-5779.

[22] BHATIA S, JAIN A, HOOI B. ExGAN: adversarial generation of extreme samples[C] // Proceedings of the 35th AAAI Conference on Artificial Intelligence. Palo Alto, USA: AAAI, 2021: 6750-6758.

[23] DRAXL C, CLIFTON A, HODGE B M, et al. The wind integration national dataset (wind) toolkit[J]. Applied Energy, 2015, 151: 355-366.

[24] XIANG S T, LI H. On the effects of batch and weight normalization in generative adversarial networks[J]. arXiv, 2017: 10.48550/arXiv.1704.03971.



米　阳
1976—，女，博士，教授，博导
主要从事微电网控制、电力系统稳定与控制等方面的研究
E-mail: miyangmi@163.com；

MI Yang
Ph.D., Professor



卢长坤(通信作者)
1997—，男，硕士生
主要从事人工智能在电力系统中的应用研究
E-mail: lckssolheart@163.com

LU Changkun
Corresponding author

收稿日期　2023-03-28　修回日期　2023-05-24　　编辑　程子丰