

基于CWGAN-GP的新型配网源荷场景生成方法

吴霜¹, 刘汇川¹, 翟晓萌¹, 仓敏¹, 王静怡¹, 章兴睿²

(1. 国网江苏省电力有限公司 经济技术研究院, 江苏 南京 210000;

2. 东南大学 电气工程学院, 江苏 南京 210096)

摘要:针对传统生成对抗网络(GANs)在新型电力系统源荷场景生成中存在的训练不稳定、模式崩溃及生成可控性不足等问题,提出一种基于条件Wasserstein生成对抗网络-梯度惩罚(CWGAN-GP)的新型配网源荷场景生成方法。首先,阐述CWGAN-GP的理论基础,包括Wasserstein距离与梯度惩罚机制的优势,以及条件生成对抗网络的条件控制能力。通过优化网络结构与训练策略,构建了面向源荷场景生成的CWGAN-GP模型。为全面评估生成场景的质量,构建包含累积分布函数(CDF)、Fréchet起始距(FID)及均值绝对百分比误差(MAPE)的多维评价体系。算例结果表明:所提方法在FID和MAPE指标上较传统方法提升显著,生成的负荷与光伏出力时序曲线在周期性波动特性上与真实数据高度吻合,验证了模型的有效性与鲁棒性。

关键词:源荷场景生成;条件Wasserstein生成对抗网络-梯度惩罚;Wasserstein距离;梯度惩罚;条件GAN;数据驱动

中图分类号:TP18;TM73 文献标识码:A DOI:10.19457/j.1001-2095.dqcd26623

Source and Load Scenario Generation for Novel Distribution Networks Based on CWGAN-GP

WU Shuang¹, LIU Huichuan¹, ZHAI Xiaomeng¹, CANG Min¹, WANG Jingyi¹, ZHANG Xingrui²

(1. Economic and Technological Research Institute, State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210000, Jiangsu, China; 2. School of Electrical Engineering, Southeast University, Nanjing 210096, Jiangsu, China)

Abstract: A method for generating source and load scenarios of novel distribution networks based on conditional Wasserstein generative adversarial network with gradient penalty (CWGAN-GP) was proposed to address the issues of training instability, mode collapse, and insufficient controllability in traditional generative adversarial networks (GANs) in source and load scenario generation for novel power system. The theoretical foundation of CWGAN-GP was first discussed, including the advantages of Wasserstein distance and the gradient penalty mechanism, as well as the conditional control capabilities of conditional generative adversarial networks. By optimizing the network structure and training strategy, a CWGAN-GP model for source and load scenario generation was constructed. To comprehensively evaluate the quality of the generated scenarios, a multi-dimensional evaluation system was developed, which includes the cumulative distribution function (CDF), Fréchet inception distance (FID), and mean absolute percentage error (MAPE). The results of the case study demonstrate that the proposed method significantly outperforms traditional methods in terms of FID and MAPE. The generated load and photovoltaic output time-series curves are highly consistent with real data in terms of periodicity and fluctuation characteristics, validating the effectiveness and robustness of the model.

Key words: source and load scenario generation; conditional Wasserstein generative adversarial network with gradient penalty (CWGAN-GP); Wasserstein distance; gradient penalty (GP); conditional generative adversarial network (GAN); data-driven

随着新型电力系统的建设及高比例可再生能源的接入,源荷双侧的不确定性与时空耦合特

性对新型配电网的规划与运行带来了严峻挑战。配电网负荷与光伏出力受温度、辐照度、用户行

基金项目:国家电网有限公司科技项目(J2024010)

作者简介:吴霜(1989—),女,硕士,高级工程师,主要研究方向为电网投资决策研究、电网发展分析评价,Email:15950532260@163.com

为等多因素影响,呈现复杂的时空关联特性,传统的场景生成方法如蒙特卡洛模拟和时序自回归模型,通常依赖于对数据分布的人工假设,这限制了其捕捉复杂非线性映射关系的能力。相较之下,数据驱动方法无需显式构建复杂的物理模型,在处理此类问题时展现出显著优势并逐渐成为主流研究途径。此外,新型电力系统背景下,配电网运行场景具有显著季节性和天气敏感性,需生成可控的条件化场景以支撑电网规划。生成对抗网络(generative adversarial networks, GAN)作为一种新兴的深度学习方法,凭借其强大的分布拟合能力,在源荷场景生成中展现出潜力。该方法能够有效拟合历史数据的高维非线性映射关系,并基于此生成新的数据样本。

文献[1]率先将深度生成方法应用于场景生成,提出了一种基于生成对抗网络(GAN)的无模型驱动方法,能够捕捉可再生能源出力的时间和空间模式,无需复杂的抽样技术即可高效生成可再生能源出力场景。文献[2]进一步发展了这一方向,提出了一种基于条件GAN的可再生能源出力场景生成方法。文献[3]通过在GAN模型中引入dropout层,增强了模型的学习能力并有效减少了过拟合现象。文献[4]则采用基于元学习的GAN方法,进一步提升了生成新能源出力场景的精度。文献[5]构建了一种辅助分类-校正器连续条件生成对抗网络,通过提取预测数据与实测数据之间的预测误差,准确刻画源荷功率的局部波动特性。文献[6]提出了一种基于校正条件生成对抗网络的方法,通过设计条件校正器识别预测误差,生成考虑风电不确定性的质量出力场景。文献[7]在GAN的基础上引入时间相关增强块,通过增强卷积层的时间感知能力,生成中长期尺度下的风电场景集。文献[8]则在典型日功率状态下刻画日状态转移过程,并采用时序生成对抗网络生成单日风/光场景。

虽然新型电力系统场景生成研究已取得一定进展,但针对源荷场景生成的特殊性,传统GAN仅以噪声为输入,生成过程缺乏条件引导,难以保证场景与实际运行条件的匹配性。此外,配电网源荷时序数据(如96时间步/d)固有的高维特性,使得传统GAN在训练过程中易遭遇梯度消失问题,导致生成器难以学习长序列依赖关系,最终导致生成数据偏离真实分布。

针对上述问题,本文提出一种改进的基于条

件 Wasserstein 生成对抗网络-梯度惩罚(CWGAN-GP)的新型配网源荷场景生成方法。相比传统GAN,该方法通过 Wasserstein 距离提供稳定梯度信号,引入梯度惩罚(GP)机制提升了训练稳定性,并结合条件GAN(conditional GAN, CGAN)增强了场景生成的可控性。为了评估生成场景的质量,本文构建了多维度的评估体系,并基于江苏省某地2 a实测负荷与光伏出力数据进行实验验证。实验结果表明,所提方法生成的场景在关键指标上优于传统方法,并能准确捕捉负荷与光伏出力时序数据的周期性和波动特性,验证了该方法在源荷场景生成中的有效性与鲁棒性。

1 条件 Wasserstein 生成对抗网络-梯度惩罚网络模型

1.1 生成对抗网络结构

生成对抗网络由Goodfellow等人^[9]于2014年提出,是一种无监督学习方法,旨在通过两个神经网络的对抗性训练生成逼真的样本。GAN由生成器(Generator)和判别器(Discriminator)两部分组成,生成器通过对随机噪声的输入进行训练,生成近似真实数据的样本;判别器则用于判断样本是否来自真实数据分布。生成器和判别器通过博弈过程共同优化:生成器的目标是尽可能生成能够欺骗判别器的假数据,而判别器的目标则是区分生成的假数据与真实数据。通过这种对抗性训练机制,GAN能够学习生成与真实数据分布高度相似的高质量样本。

在源荷场景生成中,将源荷历史数据 x 的分布规律记为 P_r ,同时定义一个噪声变量 z 。生成器 G 将噪声变量 z 映射到一个生成的数据空间 $G(z)$,将它的分布记为 P_z 。判别器 D 接受真实数据和 G 生成的数据。GAN中 G 和 D 两个神经网络的损失函数为

$$L_G = E_{z \sim P_z} \{ \log [1 - D(x)] \} \quad (1)$$

$$L_D = E_{x \sim P_r} \{ \log [D(x)] \} + E_{z \sim P_z} \{ \log [1 - D(x)] \} \quad (2)$$

式中: x 为真实数据; $D(x)$ 为判别器对真实数据的判断。

将两个网络参与的零和博弈记为 $V(D, G)$ 。对于损失函数的优化,都需要根据对方网络的更新,同时只更新自身网络参数。两个网络不断交替训练,不断各自更新参数,直到对抗的网络达

到纳什平衡。生成对抗网络的原理就是一个极小极大的优化问题,其目标函数为

$$\min_G \max_D V(D, G) = E_{x \sim P_r} [\log D(x)] + E_{z \sim P_z} \{\log \{1 - D[G(z)]\}\} \quad (3)$$

式中: $G(z)$ 为生成器根据噪声 z 生成的假数据; $D[G(z)]$ 为判别器对于假数据的判断结果。

通过对抗训练,生成器逐渐学习到数据的真实分布,从而生成高质量的样本。然而,传统GAN在训练过程中容易发生训练不稳定与模式崩溃(mode collapse)问题^[10],导致生成的场景存在样本重复、内容畸变及帧间跳变等现象,严重影响生成质量。

1.2 Wasserstein 距离与梯度惩罚机制

为缓解GAN的训练缺陷,Arjovsky等人^[11]提出Wasserstein GAN(WGAN),采用Wasserstein距离来衡量生成分布与真实分布之间的差异。Wasserstein距离在生成分布与真实分布差异较大时仍能提供连续且非零的梯度信号,使生成器始终获得改进方向,能够避免训练过程中因JS(Jensen-Shannon)散度引起的模式崩溃问题,同时在优化过程中提供更加稳定的梯度信息。Wasserstein距离定义为

$$W(P_r, P_z) = \inf_{\gamma \in \Gamma(P_r, P_z)} E_{(x,y) \sim \gamma} [\|x - y\|] \quad (4)$$

式中: P_r, P_z 分别为真实数据和生成数据的分布; $W(P_r, P_z)$ 为真实数据和生成数据之间的Wasserstein距离; $\Gamma(P_r, P_z)$ 为联合分布,同时满足 P_r 和 P_z 边缘概率分布。

由于Wasserstein距离难以直接求得,采用Kantorovich-Rubinstein对偶形式衡量距离,即

$$W(P_r, P_z) = \sup_{L \leq 1} E_{x \sim P_r} [\log D(x)] + E_{z \sim P_z} \{\log \{1 - D[G(z)]\}\} \quad (5)$$

式中: $\sup$ 为最小上界; $L \leq 1$ 为1-Lipschitz的期望值差值上界,以保证网络能够正常进行梯度优化。

为确保WGAN中判别器满足1-Lipschitz连续性约束,传统WGAN多采用权重裁剪(weight clipping)方法,然而该策略常引发训练不稳定问题。为此,梯度惩罚(GP)机制得到应用。梯度惩罚机制通过约束判别器输出对输入的梯度范数,确保其满足1-Lipschitz连续性,避免传统WGAN权重裁剪导致的训练不稳定。梯度惩罚项定义为

$$G_p|x = E_{x \sim P_r} [(\|\nabla_x D(x)\|_2 - 1)^2] \quad (6)$$

通过引入梯度惩罚,能够有效提升WGAN的

训练稳定性,并使得生成器能够学习到更为逼真的数据分布。

1.3 条件生成对抗网络

由于缺乏先验信息,传统GAN的训练方向较为盲目,易导致训练结果不佳或不稳定。CGAN是对传统GAN的一种扩展,生成器和判别器均接收条件信息作为输入,从而能够生成符合特定条件的数据样本。条件信息的引入使得CGAN不仅能够生成样本,还能够控制生成样本的属性,使得生成过程具有更强的可控性。

在CGAN中,生成器和判别器的输入不仅包括噪声向量 z ,还包含一个条件变量 y 。生成器通过条件变量 y 生成与之相应的假样本,判别器则根据真实样本或生成样本以及条件变量 y 来判断样本的真实性。CGAN的损失函数可以表示为

$$\min_G \max_D V(D, G) = E_{x \sim P_r} [\log D(x|y)] + E_{z \sim P_z} \{\log \{1 - D[G(z)|y]\}\} \quad (7)$$

通过条件生成,CGAN能够生成多样化的样本,并且可以根据特定的需求调整生成过程。

1.4 CWGAN-GP

为了更好地描述新型配网源荷数据之间的不确定关系,本文结合WGAN-GP和CGAN的特点,提出了一种基于CWGAN-GP的源荷场景生成方法。CWGAN-GP继承了WGAN的优点,利用Wasserstein距离来衡量生成样本与真实样本之间的差异,同时引入梯度惩罚以保证判别器的1-Lipschitz连续性,从而避免了WGAN中的权重裁剪问题。

在CWGAN-GP中,生成器接收随机噪声 z 和条件信息 y 作为输入,输出与真实数据分布相似的假样本。判别器则根据生成样本和真实样本,结合条件信息 y ,对样本进行判断。通过梯度惩罚,CWGAN-GP能够确保判别器的输出关于输入的梯度在训练过程中保持平滑,从而提升训练的稳定性。CWGAN-GP的基本结构如图1所示。




图1 CWGAN-GP的基本结构

Fig.1 Basic structure of CWGAN-GP

CWGAN-GP的损失函数包括生成器损失、判别器损失和梯度惩罚项,具体形式为

$$\min_G \max_D V(D, G) = E_{x \sim p_x} [\log D(x|y)] + E_{z \sim p_z} \{\log \{1 - D[G(z|y)]\}\} + \lambda G_p \quad (8)$$

式中: λ 为梯度惩罚系数。

CWGAN-GP的优化过程涉及生成器和判别器的交替训练。在每次迭代中,首先通过最大化判别器的 Wasserstein 距离和梯度惩罚损失,优化判别器的参数;然后通过最小化生成器的损失,优化生成器的参数。这种交替训练策略可以有效保证生成器和判别器的性能逐步提高,并且能够根据输入的条件信息生成具有特定属性的源荷场景。

2 基于CWGAN-GP的源荷场景生成方法

2.1 生成器与判别器网络结构设计

在基于CWGAN-GP的源荷场景生成模型中,生成器和判别器分别承担着生成与判别源荷场景数据的任务。生成器的目标是根据给定的条件信息生成具有时序性和空间一致性的源荷场景数据;判别器则负责评估生成数据与真实数据之间的差异。为确保模型的训练稳定性与生成效果,合理的网络结构设计是至关重要的。

生成器的输入是随机噪声向量 z 和条件信息 y ,输出为与输入条件信息相对应的源荷场景数据。生成器 $G(z|y)$ 中,月份标签 y 经嵌入层映射为128维的条件向量 e_c ,与100维的噪声 z 拼接后输入全连接层。生成器通过学习这些输入数据的分布特征,生成模拟的负荷波动和光伏出力数据。生成器网络采用了全连接层与批量归一化(Batch Normalization)相结合的设计,并在每一层使用ReLU激活函数,以提高模型的非线性拟合能力。生成器的网络结构参数如表1所示。

表1 生成器网络结构参数

层类型	输出形状	激活函数
Concat	(z, y)	—
Dense	512	ReLU
Dense	1024	ReLU
Dense	2048	ReLU
Batch Normalization	2048	ReLU
Dense	$(96, n)$	Linear

生成器输出的是形状为 $(96, n)$ 的源荷场景数据,96代表一天内每15 min的时序数据, n 为每时间步的特征维度,包括负荷数据、光伏出力等。

判别器的输入包括生成的配电网数据和真实场景数据,并结合条件信息 y 来判断数据的真实性。判别器网络使用卷积神经网络(CNN)来处理时序数据。卷积层能够通过局部感知区域提取时序数据中的特征,从而避免全连接层导致的参数量过多和过拟合问题。判别器 $D(x|y)$ 采用条件投影,将标签 y 投影至特征空间并与中间层特征 f_x 内积。在每一层卷积操作后,判别器通过LeakyReLU激活函数增加模型的非线性表达能力,并通过Batch Normalization层稳定训练过程。判别器的网络结构参数如表2所示。

表2 判别器网络结构参数

层类型	输出形状	激活函数
输入层	$(96, n)$	—
Conv1D	$(96, 64)$	LeakyReLU
Conv1D	$(96, 128)$	LeakyReLU
Batch Normalization	$(96, 128)$	LeakyReLU
Conv1D	$(96, 256)$	LeakyReLU
Dense	512	LeakyReLU
Dense	1	Sigmoid

判别器的输出为一个标量 $D(x)$,其值介于0和1之间,表示输入数据 x 为真实数据的概率。若 $D(x)$ 接近1,说明数据为真实样本;若 $D(x)$ 接近0,则说明数据为生成样本。

生成器和判别器网络的优化通过交替训练的方式进行。在训练过程中,使用Adam优化器,学习率设置为 10^{-4} ,以保证稳定的训练过程。批次大小设为64,确保每次训练都能高效更新模型参数。设定梯度惩罚系数为10,以有效控制梯度的大小,避免训练过程中的不稳定性。

为了避免训练过程中的梯度消失或爆炸问题,网络参数初始化采用He正态分布初始化。训练过程中,判别器和生成器交替优化,通常每训练1次判别器后,再训练生成器5次,以维持生成器和判别器之间的平衡。训练完成后,生成器将用于生成多样化的源荷场景数据,供后续的分析和优化任务使用。

2.2 模型训练流程

基于CWGAN-GP的源荷场景生成模型的训练步骤如下:

步骤1):将负荷数据和光伏出力数据按照日

维度进行切割,每个样本包含一天的96个时间步,即每15 min一个数据点。

步骤2):初始化生成器和判别器的网络参数,包括各层的神经元数目、激活函数、损失函数。初始化CWGAN-GP的梯度惩罚项,设置惩罚系数 λ ,以保证训练过程中判别器的梯度规范性。

步骤3):从训练集中采样真实数据 x 和对应的条件标签 y ,生成器 G 生成假数据 $G(z|y)$ 。计算判别器对真实数据和假数据的输出 $D(x|y)$ 和 $D[G(z|y)]$ 。计算梯度惩罚项,确保判别器满足1-Lipschitz连续性。更新判别器参数。

步骤4):每隔一定次数的判别器更新后,更新生成器参数,生成器的目标是最大化判别器对生成数据的误判概率。

步骤5):重复步骤3)和步骤4),直到生成器和判别器的损失收敛。训练过程中,生成器逐渐学习到源荷场景数据的真实分布。

步骤6):完成训练后,使用训练好的生成器根据输入的条件信息生成大量的源荷场景数据。

2.3 场景生成质量评价体系构建

在源荷场景生成的研究中,评估生成数据的质量是至关重要的,以下是对几个常用场景生成评估指标。

1)累积分布函数(cumulative distribution function, CDF)。CDF是衡量生成数据与真实数据分布相似性的一种直观方法。对于给定的数据集 $X=\{x_1, x_2, \dots, x_n\}$,其累积分布函数定义为

$$F_X(x) = P(X \leq x) = \frac{1}{n} \sum_{i=1}^n I(x_i \leq x) \quad (9)$$

式中: $I(\cdot)$ 为指示函数。

通过比较生成数据和真实数据的CDF曲线,可以直观地评估生成数据在分布上的接近程度。CDF曲线越接近,表明生成数据与真实数据的分布一致性越高。

2)Frechet起始距(Frechet inception distance, FID)。FID是一种衡量生成数据与真实数据分布相似性的量化指标,广泛应用于生成对抗网络的性能评估中。FID基于生成数据和真实数据的特征嵌入分布,计算两者的Frechet距离。具体而言,假设真实数据和生成数据的特征嵌入分别为 X 和 Y ,其均值和协方差分别为 (μ_X, Σ_X) 和 (μ_Y, Σ_Y) ,则FID定义为

$$FID = \|\mu_X - \mu_Y\|_2^2 + \text{Tr}[\Sigma_X + \Sigma_Y - 2(\Sigma_X \Sigma_Y)^{1/2}] \quad (10)$$

FID值越小,表明生成数据与真实数据的分布越接近,生成质量越高。

3)重构损失(reconstruction loss, REC)。REC用于衡量生成数据与真实数据在特征空间中的接近程度。它通常通过计算生成数据与真实数据之间的均方误差(MSE)或平均绝对误差(MAE)来实现。具体而言,假设真实数据为 x ,生成数据为 $G(z)$,则重构损失定义为

$$REC = \frac{1}{N} \sum_{i=1}^N \|x_i - G(z_i)\|_2^2 \quad (11)$$

式中: N 为数据样本的数量。

重构损失越小,表明生成数据在特征空间中与真实数据的匹配度越高。

4)能量分数(energy score, ES)。ES是一种基于能量统计的评估指标,用于衡量生成数据与真实数据的相似性。它通过计算数据点之间的成对距离来评估数据分布的一致性。具体而言,假设真实数据和生成数据分别为 $X=\{x_1, x_2, \dots, x_n\}$ 和 $Y=\{y_1, y_2, \dots, y_n\}$,则能量分数定义为

$$ES = \frac{2}{n^2} \sum_{i=1}^n \sum_{j=1}^n \|x_i - y_j\|_2 - \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n \|x_i - x_j\|_2 - \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n \|y_i - y_j\|_2 \quad (12)$$

能量分数越小,表明生成数据与真实数据的分布越接近。

5)均值绝对百分比误差(mean absolute percentage error, MAPE)。MAPE是一种常用的误差评估指标,用于衡量生成数据与真实数据之间的相对误差。MAPE定义为

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{x_i - \hat{x}_i}{x_i} \right| \times 100\% \quad (13)$$

式中: x_i 为真实数据; $\hat{x}_i$ 为生成数据。

MAPE值越小,表明生成数据与真实数据的相对误差越小,生成质量越高。

上述指标从不同角度评估了生成数据的质量,包括分布相似性(CDF, FID)、特征空间匹配度(REC)、能量统计(ES)以及相对误差(MAPE)。通过综合使用这些指标,可以全面评估源荷场景生成模型的性能,为模型优化和实际应用提供有力支持。

3 算例分析

3.1 算例概况

本文基于江苏省某地区配电网2022—2023

年的负荷及光伏出力实测数据进行实验分析,数据时间分辨率为15 min,每天包含96个时间步。为确保模型的泛化能力,数据集按照80%训练集与20%测试集的比例进行划分。为提高生成过程的可控性,源荷数据与条件信息 y 一同输入模型。设定月度标签 y 作为条件信息,将其编码为独热编码(One-Hot Encoding),使模型能够学习月份对负荷和光伏出力特性的影响。实验在Windows操作系统下进行,使用PyTorch1.10.0深度学习框架,计算机处理器为Intel(R) Core(TM) i5-9600KF CPU 3.70 GHz,机带RAM为16.0 GB, GPU为NVIDIA GeForce GTX 1650 SUPER,显存为4.0 GB。

3.2 生成结果与性能评价

本文提出的CWGAN-GP场景生成模型将负荷及光伏出力的归一化数据作为判别器的输入,并结合月度标签进行训练,集合迭代5 000次,最后生成365组源荷场景,训练结果如图2所示。




图2 所提方法迭代1 000次和5 000次的生成效果对比

Fig.2 Comparison of generation results after 1 000 and 5 000 iterations of the proposed method

在图2中,水平坐标的采样点数为96,代表一个典型日场景。在训练初期,生成的数据主要是随机噪声产生的,无法反映出源荷数据的特点。经过1 000次训练后,生成器开始捕捉到一些配电网源荷数据特征,生成的数据开始呈现周期性变化。经过5 000次迭代,生成器完全掌握了配电网源荷数据的固有特性,与判别器达到纳什平衡,生成的输出曲线变得平滑。并且生成的

数据与实际数据的特征一致,说明该模型可以更准确地学习和捕捉到新型配网源荷数据的特性。

图3展示了在模型训练过程中生成器和判别器网络的损失在每次迭代中的变化情况。从图中可以看出,生成器的损失在训练初期可能会出现较大的波动,这是因为生成器在刚开始时生成的假数据质量较差,导致判别器能够轻松区分真假数据。训练到后期,生成器和判别器的损失均稳定收敛,没有出现梯度异常波动。判别器的损失趋近于零,表明判别器几乎无法区分真实样本与生成样本,这说明生成的残差场景与真实残差在统计特性上几乎一致。因此,生成器成功地生成了与真实数据具有相似特征的样本,验证了所提CWGAN-GP模型的有效性。




图3 生成器和判别器的损失变化情况

Fig.3 Loss variation of generator and discriminator

为了说明本文所提场景生成方法的有效性,将CWGAN-GP方法的场景生成与基于高斯混合模型-分布耦合(Gaussian mixture models copula, GMC)的场景生成方法进行对比,如图4所示。

由图4可知,CWGAN-GP方法生成的数据与真实数据的趋势较为一致,具有较好的平滑性,噪声较少,且在数据的局部变化上表现较好,能够模拟出负荷与出力的波动特性。而GMC生成数据的整体趋势与真实数据一致,但局部波动更剧烈,且生成数据的随机性较高,出现一些剧烈的抖动。由于GMC逼近边缘分布的能力有限,导致在数据密度较低区域的生成效果较弱。从结果来看,CWGAN-GP方法比GMC方法在场景生成的精度和数据平滑性上更具优势,更适合用于新能源场景模拟。

CWGAN-GP与GMC累计分布函数如图5所示。从图5可以看出,CWGAN-GP生成数据分布与原始数据几乎一致,能够较好地重构数据特征,表明该方法在复杂分布建模方面表现优越。GMC在主趋势上能较好地匹配原始数据,但在局部特征上有所偏差,表明其在复杂数据建模上的




图4 CWGAN-GP与GMC源荷场景生成对比
Fig.4 Comparison of source and load scenarios generated by CWGAN-GP and GMC

能力有限。因此,本文提出的方法可以通过隐式学习获得新型配网源荷数据的分布特征,生成的数据在时间序列特征和统计分布上与真实数据高度匹配。

3.3 方法对比分析

为了进一步验证本文提出的场景生成模型的有效性,对传统GMC方法、CGAN方法、WGAN-GP以及CWGAN-GP模型进行了比较,结果如表3所示。

从表3可以看出,本文提出的CWGAN-GP模型在生成质量与分布匹配度上显著优于GMC方法、CGAN方法与WGAN-GP方法。

在分布相似性方面,CWGAN-GP的FID值较GMC,CGAN与WGAN-GP分别降低31.6%,41.9%




图5 CWGAN-GP与GMC累计分布函数

Fig.5 CDF of CWGAN-GP and GMC

表3 评价指标对比

Tab.3 Comparison of evaluation indicators

方法	<i>FID</i>	<i>REC</i>	<i>ES</i>	<i>MAPE</i>
GMC	0.047 8	0.032 4	1.015 2	0.029 1
CGAN	0.056 3	0.038 1	1.052 4	0.038 9
WGAN-GP	0.036 4	0.025 0	0.964 3	0.016 1
CWGAN-GP	0.032 7	0.026 3	0.942 9	0.015 0

与10.2%,表明生成场景的特征分布与真实数据最为接近。这是由于CWGAN-GP通过条件向量嵌入月度标签与负荷基准,增强了模型对源荷场景季节特性与功率量级的捕捉能力,同时梯度惩罚机制提升了判别器的1-Lipschitz连续性,优化了生成器梯度更新方向。

在特征空间匹配度方面,CWGAN-GP的REC值略高于WGAN-GP,但较GMC和CGAN分别降低18.8%和30.9%。这表明CWGAN-GP在引入条件信息后,模型复杂度增加导致特征重建误差轻微上升,但其生成场景在关键时序模式的匹配度仍显著优于CGAN。并且,特征重建误差波动较小,属于优化整体性能过程中的合理权衡,因此仍处于可接受范围。CWGAN-GP的ES值较CGAN降低10.4%,说明生成场景的成对距离分布更接近真实数据,空间一致性更高。

在相对误差方面,CWGAN-GP的MAPE值较GMC,CGAN与WGAN-GP分别降低48.5%,61.4%与6.8%,表明生成场景在逐点精度上具有显著优势。这得益于条件生成机制对负荷与光伏出力时序关联性的显式建模。

综上所述,本文提出的CWGAN-GP模型在

FID 与 *MAPE* 等关键指标上较现有方法提升显著,验证了其在高维、多条件源荷场景生成中的有效性。生成场景的分布一致性、时序精度及可控性为含高比例可再生能源的新型配电网优化提供了高质量数据基础。

4 结论

本文提出了一种基于CWGAN-GP的新型配网源荷场景生成方法,主要结论如下:

1)通过引入 Wasserstein 距离与梯度惩罚机制,有效解决了传统 GAN 训练不稳定与模式崩溃问题。生成器网络结合全连接层与批量归一化设计,能够精确捕捉负荷与光伏出力的高维时序特征,生成场景的 *FID* 值较传统 CGAN 降低 41.9%,*MAPE* 误差降低 61.4%。

2)通过嵌入月度标签作为条件信息,生成场景的季节特性与输入条件高度匹配。实验表明,生成场景的 CDF 曲线与真实数据分布拟合误差低于 3%,验证了条件生成机制的有效性。

3)提出的多维度评价指标体系从分布相似性、特征空间匹配度以及相对误差角度全面量化生成质量,为生成模型的性能评估提供了系统化方法。

参考文献

- [1] Chen Y, Wang Y, Kirschen D S, et al. Model-free renewable scenario generation using generative adversarial networks[J]. IEEE Transactions on Power Systems, 2018, 33 (3): 3265–3275.
- [2] Sadek S M, Omran W A, Hassan M A M, et al. Data driven stochastic energy management for isolated microgrids based on generative adversarial networks considering reactive power capabilities of distributed energy resources and reactive power costs[J]. IEEE Access, 2021, 9: 5397–5411.
- [3] 董晓翀,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.

- Dong X C, Sun Y Y, Pu T J. Day-ahead scenario generation of renewable energy based on conditional GAN[J]. Proceedings of the CSEE, 2020, 40 (17): 5527–5536.
- [4] Sarmas E, Spiliotis E, Stamatopoulos E, et al. Short-term photovoltaic power forecasting using meta-learning and numerical weather prediction independent long short-term memory models [J]. Renewable Energy, 2023, 216: 118997.
- [5] Wang Q, Zhang X, Xu D. Source-load scenario generation based on weakly supervised adversarial learning and its data-driven application in energy storage capacity sizing[J]. IEEE Transactions on Sustainable Energy, 2023, 14 (4): 1918–1932.
- [6] 朱玲,李威,王骞,等. 基于校正条件生成对抗网络的风电场群绿氢储能系统容量配置[J]. 电工技术学报, 2024, 39 (3): 714–730.
- Zhu L, Li W, Wang Q, et al. Wind farms-green hydrogen energy storage system capacity sizing method based on corrected-conditional generative adversarial network[J]. Transactions of China Electrotechnical Society, 2024, 39 (3): 714–730.
- [7] Ma Y, Ma M, Wang N, et al. Mid-term scenario generation for wind power using GAN with temporal-correlation enhancement block[C]//E3S Web of Conferences, 2020, 182: 01003.
- [8] 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): 537–548.
- Li H, Ren Z Y, Hu B, 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): 537–548.
- [9] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63 (11): 139–144.
- [10] 陈佛计,朱枫,吴清潇,等. 生成对抗网络及其在图像生成中的应用研究综述[J]. 计算机学报, 2021, 44 (2): 347–369.
- Chen F J, Zhu F, Wu Q X, et al. A survey about image generation with generative adversarial nets[J]. Chinese Journal of Computers, 2021, 44 (2): 347–369.
- [11] Arjovsky M, Chintala S, Bottou L. Wasserstein generative adversarial networks[C]//International Conference on Machine Learning, 2017.

收稿日期:2025-05-14
修改稿日期:2025-07-17