

基于改进生成对抗网络的可控可解释性风光场景生成方法

高峰阳¹,裴淑萍¹,李 龙¹,查鹏堂¹,王钦娟²

(1. 兰州交通大学 自动化与电气工程学院,甘肃 兰州 730070;

2. 国网甘肃省电力公司经济技术研究院(新型电力系统研究院),甘肃 兰州 730050)

摘要:针对风光可再生能源接入电网所带来的不确定性和间歇性,提出一种基于条件 Wasserstein 生成对抗网络-梯度惩罚(cWGAN-GP)的可控可解释的风光出力场景生成方法。cWGAN-GP通过引入条件向量调控风光出力场景的生成过程,使生成数据能够满足特定统计特征要求,结合梯度惩罚提升训练稳定性,确保生成场景质量,并准确捕捉风光出力的时空相关性;利用斯皮尔曼相关系数分析高维气象特征与风光出力之间的关系,筛选关键气象因子作为控制变量,以增强模型的可控性和对气象条件的适应能力。在 IEEE 33 节点系统上进行仿真验证,结果表明,所提方法能有效生成符合统计规律的风光出力场景,并较好地保持时空相关性。

关键词:不确定性;场景生成;可解释性;cWGAN-GP;时空特征

中图分类号:TM73

文献标志码:A

DOI:10.16081/j.epae.202508010

0 引言

风光等可再生能源的间歇性、波动性等特性给电力系统的规划和运行带来诸多挑战^[1-3]。准确的风光场景生成是进行电网风险评估、电力供需平衡和优化调度决策的重要数学方法^[4-5],通过构建时间序列场景,模拟可再生能源输出的不确定性^[6-7]。

基于概率模型算法的场景生成方法先假设风光出力的概率分布,再采用蒙特卡罗^[8]、高斯分布^[9]或拉丁超立方采样^[10]生成场景,但简单的统计假设难以准确刻画风光出力的高维非线性特征。文献[11]使用 Copula 函数综合考虑时间序列特性和时空相关性,以提升场景对实际风光波动的模拟精度。然而,上述方法存在一些局限性:依赖明确的边缘分布假设和结构函数,难以准确模拟复杂气象条件下的风光出力特性;缺乏灵活的特征表达机制,难以有效处理高维输入数据;模型推理过程复杂,难以直接应用于场景预测或调度优化中。

随着人工智能的快速发展,深度生成模型在可再生能源场景生成中的应用备受关注。文献[12]首次将人工神经网络用于电力系统的不确定性建模,为优化调度和风险评估提供支持。近年来,生成对抗网络(generative adversarial network, GAN)广泛应用于风光出力场景生成^[13-14]。文献[15]提出一种基于 GAN 的风光联合出力场景生成方法,摆脱了传统建模对先验假设的依赖。文献[16]在 GAN 框架的

基础上,提出一种基于 Wasserstein 生成对抗网络(Wasserstein generative adversarial network, WGAN)的综合能源系统,实现了短期预测与优化调度。文献[17]提出特征引导图生成对抗网络(knowledge graph-GAN, KG-GAN)模型,用于生成电力系统运行场景,以提高场景模拟的准确性和效率。文献[18]在文献[12-17]的基础上,考虑场景生成的时空相关性,提出一种基于改进条件生成对抗网络(conditional generation adversarial network, CGAN)的场景集生成方法,通过学习潜在的时空特征提升调度与优化决策的准确性。文献[19]提出一种基于 CGAN 的多区域风电出力场景生成方法,强化区域间的时空相关性建模。文献[20]针对数据缺失的风电场,将条件深度卷积生成对抗网络(conditional deep convolutional generative adversarial network, C-DCGAN)和参数优化相结合,考虑多座相邻风电场之间的时空相关性,提升风电场景生成的准确性。然而,上述文献均未考虑可控性和可解释性,使得生成场景缺乏调节手段,难以满足特定应用需求。

文献[21-22]提出一种基于可控 GAN 的可再生能源出力数据驱动场景生成方法,以提高生成场景的可控性和可解释性,满足电力系统调度与优化需求。文献[23]提出一种基于改进变分自编码生成对抗网络(variational autoencoder generative adversarial network, VAEGAN)的可再生能源场景生成方法,结合可控可解释的特征,提高了生成场景的准确性和多样性。文献[24]提出一种基于改进信息最大化生成对抗网络(information maximizing generative adversarial network, InfoGAN)的风光出力场景可控生成方法,通过引入可控向量调整关键统计特征,实现了

收稿日期:2025-03-19;修回日期:2025-08-11

在线出版日期:2025-08-15

基金项目:甘肃省重点研发计划项目(23YFFA0059)

Project supported by the Key R&D Program of Gansu Province (23YFFA0059)

对风光出力场景的精准调节。然而,上述方法在处理高维气象特征时,普遍缺乏有效的特征筛选与表示机制,难以提取与风光出力高度相关的关键信息。同时,生成模型过度依赖判别器对统计特征的反馈,忽视了数据内部结构的建模,限制了生成场景的多样性与可解释性。此外,对均值、方差等统计量的拟合易掩盖时序结构与局部波动的差异,降低了生成结果的准确性。

鉴于上述问题,本文提出一种改进的条件 Wasserstein 生成对抗网络-梯度惩罚(conditional Wasserstein generative adversarial network with gradient penalty, cWGAN-GP)模型,用于可再生能源场景生成与分析。通过引入梯度惩罚机制,有效解决训练过程中的不稳定性与模式崩溃问题;利用控制向量对生成过程进行引导,使风光出力场景更好地满足特定统计特征要求,该模型比传统依赖判别器反馈的模型具有更高的可控性与生成稳定性;结合特征匹配损失强化对风光出力时空相关性的建模,提升生成场景的多样性与细节还原能力;通过斯皮尔曼相关系数(Spearman coefficient correlation, SCC)分析提取与风光出力高度相关的关键气象因子,将其作为控制向量输入,增强模型对复杂气象条件的适应能力。

1 具有可解释特征的可控 cWGAN-GP

1.1 cWGAN-GP模型及其改进

GAN^[25]是一种基于深度学习网络的生成模型,基于生成器 G 和判别器 D 之间的博弈,通过对抗训练使 G 生成与真实数据相似的样本,目标函数如式(1)所示。WGAN^[26]将 Jensen-Shannon 散度替换为 Wasserstein 距离以提高训练稳定性,进一步引入梯度惩罚的 WGAN-GP^[27]在提升训练收敛性方面效果显著,目标函数分别如式(2)、(3)所示。

$$\begin{aligned} \min_G \max_D V(D, G) &= E_{\mathbf{x} \sim P_{\text{data}}(\mathbf{x})} [\lg D(\mathbf{x})] + \\ & E_{\mathbf{z} \sim P_z(\mathbf{z})} [\lg (1 - D(G(\mathbf{z})))] \quad (1) \\ \min_G \max_D V(D, G) &= E_{\mathbf{x} \sim P_{\text{data}}(\mathbf{x})} [D(\mathbf{x})] - E_{\mathbf{z} \sim P_z(\mathbf{z})} [D(G(\mathbf{z}))] \quad (2) \\ \min_G \max_D V(D, G) &= E_{\mathbf{x} \sim P_{\text{data}}(\mathbf{x})} [D(\mathbf{x})] - E_{\mathbf{z} \sim P_z(\mathbf{z})} [D(G(\mathbf{z}))] + \\ & \lambda E_{\hat{\mathbf{x}} \sim P_{\hat{\mathbf{x}}}} \left[\left(\left\| \nabla_{\hat{\mathbf{x}}} D(\hat{\mathbf{x}}) \right\|_2 - 1 \right)^2 \right] \quad (3) \end{aligned}$$

式中: $V(D, G)$ 为判别器 D 和生成器 G 之间博弈的交叉熵函数; $D(\mathbf{x})$ 为输入数据 $\mathbf{x}$ 来自真实样本的概率; $E_{\mathbf{x} \sim P_{\text{data}}(\mathbf{x})}$ 表示对真实数据分布 $P_{\text{data}}(\mathbf{x})$ 上的样本 $\mathbf{x}$ 求期望,反映判别器在真实样本上的输出情况; $E_{\mathbf{z} \sim P_z(\mathbf{z})}$ 表示对噪声分布 $P_z(\mathbf{z})$ 上的样本 $\mathbf{z}$ 求期望,反映判别器

在生成样本上的判断能力; $D(G(\mathbf{z}))$ 为判别器将生成样本视为真实样本的概率; λ 为梯度惩罚系数,一般取 10; $\hat{\mathbf{x}} = \varepsilon \mathbf{x} + (1 - \varepsilon) G(\mathbf{z})$, ε 为随机数; $E_{\hat{\mathbf{x}} \sim P_{\hat{\mathbf{x}}}}$ 表示对插值样本 $\hat{\mathbf{x}}$ 的分布求期望,用于衡量判别器梯度的偏离程度。

cWGAN-GP^[28]引入条件输入,通过控制向量 $\mathbf{c}$ 来实现生成样本的条件控制,允许生成器根据特定条件生成多样化的样本。 G 不仅接收随机噪声 $\mathbf{z}$ 作为输入,还接收条件控制向量 $\mathbf{c}$,使得生成过程可以根据不同的控制条件进行调整。 G 根据给定的条件生成特定类型的数据,条件输入使得模型具备更强的控制能力,生成更加多样化和定制化的样本。cWGAN-GP 目标函数如式(4)所示。

$$\begin{aligned} \min_G \max_D V(D, G) &= E_{\mathbf{x} \sim P_{\text{data}}(\mathbf{x})} [D(\mathbf{x}, \mathbf{c})] - \\ & E_{\mathbf{z} \sim P_z(\mathbf{z})} [D(G(\mathbf{z}, \mathbf{c}), \mathbf{c})] + \\ & \lambda E_{\hat{\mathbf{x}} \sim P_{\hat{\mathbf{x}}}} \left[\left(\left\| \nabla_{\hat{\mathbf{x}}} D(\hat{\mathbf{x}}, \mathbf{c}) \right\|_2 - 1 \right)^2 \right] \quad (4) \end{aligned}$$

式中: $D(\mathbf{x}, \mathbf{c})$ 为判别器根据控制向量 $\mathbf{c}$ 对真实数据 $\mathbf{x}$ 输出的样本; $G(\mathbf{z}, \mathbf{c})$ 为生成器根据输入噪声 $\mathbf{z}$ 和控制向量 $\mathbf{c}$ 生成的样本。

传统 cWGAN-GP 模型虽能生成受控制的样本,但仍存在两大问题:一是条件信息的融合问题,生成器直接将控制向量 $\mathbf{c}$ 和噪声 $\mathbf{z}$ 作为输入,并通过全连接层或卷积层生成样本,但对于较为复杂的控制条件,简单的输入方式可能无法充分挖掘和利用控制向量 $\mathbf{c}$ 中的信息;二是生成样本的多样性不足问题,对于复杂的场景生成任务,生成器在不同条件下难以生成足够多样化的样本,尤其是在处理连续控制信息时,生成样本的质量和多样性往往受到影响。

为此,本文引入条件批归一化^[29](conditional batch normalization, CBN)技术。CBN 允许控制向量 $\mathbf{c}$ 参与每层归一化参数计算,使得生成器在不同控制条件下对输出特征分布进行自适应调整,从而提高控制信息利用率和样本多样性。CBN 技术在不改变目标函数结构的前提下,对生成器内部结构进行改造,有效强化了条件对输出结果的约束能力。

1.2 具有可控可解释特征的 cWGAN-GP 模型

cWGAN-GP 通过引入条件向量实现对生成样本的控制,特别是在处理气象特征、环境变化等因素时,能够根据给定的条件生成符合预期的输出。核心思想是将外部环境因素作为条件向量,通过生成器生成符合条件的样本。

在可控 cWGAN-GP 模型中,生成器 G 接收随机噪声 $\mathbf{z}$ 和外部控制向量 $\mathbf{c}$ 作为输入,并生成输出样本 $G(\mathbf{z}, \mathbf{c})$ 。判别器 D 接收输入样本 $\mathbf{x}$ 和控制向量 $\mathbf{c}$,并输出 $D(\mathbf{x}, \mathbf{c})$ 来判断该样本是否为真实数据。通过

引入条件向量, G 可以生成特定模式的可再生能源输出场景, 而 D 则学习如何基于给定条件来判别样本的真实性。

可控 cWGAN-GP 模型结合 GAN, 通过引入可控向量增强了对生成样本的可控性。该模型的生成器 $G(z, c)$ 以随机噪声 z 和外部控制向量 c 为输入, 生成与条件一致的样本。判别器 $D(x, c)$ 在判断样本 x 是否为真实样本的同时, 还要考虑外部控制向量 c , 以根据特定条件判定样本的真实性。

可控 cWGAN-GP 整体的损失函数由生成器损失 L_G 和判别器损失 L_D 组成。判别器的损失函数如式(5)所示。

$$L_D = E_{x \sim P(x), c \sim P(c)} \left[\lg D(x, c) + \lg (1 - D(G(z, c), c)) \right] + \lambda_{GP} L_{GP} \quad (5)$$

式中: λ_{GP} 为梯度惩罚系数, 用于确保判别器的梯度接近 1, 从而稳定训练过程; L_{GP} 为梯度惩罚项, 用于确保判别器的梯度稳定性。

1.3 具有内部可解释特征的可控 cWGAN-GP

为进一步提高生成的可再生能源场景的可解释性, 从外部环境条件和内部功率特征 2 个维度构建可控向量, 分别实现基于物理含义的外部约束与基于统计行为的内部闭环调控。引入辅助网络, 提出一种基于内部特征 (如最大功率、最小功率、功率波动等) 的可控 cWGAN-GP 模型, 有效处理外部气象特征。外部气象特征具有明确的物理因果属性, 通过控制这些特征, 可引导生成结果更贴近特定气候场景; 而内部功率特征体现输出行为的统计变化趋势, 可有效反映系统运行的行为状态, 具有良好的解释性与调控价值。引入的辅助网络对外部特征与目标输出之间的关系进行建模, 学习非线性映射, 使得控制向量 c_{ex} 在潜在空间中具备更强的表达能力, 不仅能够提升条件向量的表示能力, 还能通过反馈机制动态优化输入特征的权重分配, 从而增强生成器对气象变化的响应性。辅助网络不仅优化条件向量 c 的表示, 还通过对气象特征的动态调整, 使得生成器能够根据这些条件生成更准确的可再生能源场景, 生成的样本更加符合实际气象条件, 提高场景数据的可用性和多样性。

选择具有代表性的气象特征作为可控向量 c_{ex} , 以生成符合实际气象条件的可再生能源场景。利用 SCC 分析气象特征与可再生能源输出之间的关系, 选择相关性较高的气象特征作为条件向量 c_{ex} 。SCC 计算公式如式(6)所示。

$$\rho = \frac{\sum_{i=1}^n (e_{x_i} - \bar{e}_x)(x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (e_{x_i} - \bar{e}_x)^2 (x_i - \bar{x})^2}} \quad (6)$$

式中: ρ 为 SCC; e_{x_i} 为气象特征 i (如风速、光照强度、温度等) 的值; $\bar{e}_x$ 为气象特征值的均值; x_i 为可再生能源输出 i (如风能、太阳能输出等) 的值; $\bar{x}$ 为可再生能源输出值的均值; n 为数据点总数。

选择 3 个关键指标作为内部可解释特征, 连续输出功率序列可以表示为 $\{P_t\} (t=1, 2, \dots, T, T$ 为时段数): 最大功率 $P_{\max} = \max\{P_t\}$, 表示一天中最大功率输出, 反映输出的峰值能力; 最小功率 $P_{\min} = \min\{P_t\}$, 表示一天中最小功率输出, 体现系统的最低输出能力; 最大波动功率 $P_{\text{fluct}} = \max\{P_t - P_{t-1}\}$, 表示功率输出波动最大幅度, 反映输出波动强烈程度。

将内部特征作为条件向量 c_{in} 输入生成器中, 以生成具有特定功率波动特征的可再生能源输出场景。步骤如下。

1) 特征提取: 从历史可再生能源数据中提取最大功率、最小功率和最大波动功率等特征, 构成内部可控向量 c_{in} 。

2) 辅助网络建模: 设计辅助网络, 将其作为控制向量编码模块, 将 c_{in} 动态映射至高维语义空间, 增强其表达能力与非线性建模能力。

3) 联合训练生成器: 将辅助网络输出作为中间条件信息注入生成器的每层, 实现更细粒度的条件控制。

4) 场景模拟: 通过设置或扰动 c_{in} 值, 实现风电或光伏场景的合成, 有助于电力系统在调度优化等场景中进行评估。

为提升内部特征与实际气象变量之间的协同控制能力, 采用 SCC 进行特征筛选, 将相关性最高的气象变量作为外部控制向量 e_{x_i} , 实现外部与内部条件信息的联合建模与解释, 增强生成场景与实际运行情况的一致性。

2 时空关联学习方法

利用改进的 cWGAN-GP 生成可再生能源场景, 将气象特征作为控制向量, 自动提取和学习可再生能源输出数据的时空特性, 生成符合实际分布的场景。本文不仅考虑空间上的地理依赖性, 还引入气象条件等外部因素的影响, 实现可再生能源数据在时空维度上的高效建模。

2.1 时空相关性

为确保可再生能源输出特性在时间和空间维度上的一致性与准确性, 在场景生成过程中引入时空关联学习方法, 重点建模时间相关性与空间相关性 2 类核心关系。时间相关性主要体现在连续时间之间的输出变化趋势, 受气象条件影响, 风电和光伏通常呈现出平稳或周期性波动的特征。模型通过将时间序列与区域信息联合构建为区域-时间矩阵, 利用卷积和反卷积操作提取其中的时空联合特征, 学习

风速、光照等因素在时间维度上的演化规律。空间相关性体现为不同地理区域之间因气象系统相似而产生的输出协同关系。模型通过卷积操作提取空间维度上的局部依赖结构,并引入跨通道特征融合机制整合多区域特征,增强区域间的协同表征能力。模型在训练过程中能够同时捕捉时间维度的变化趋势与空间维度的协同模式,从而生成在时空特性上与真实场景高度一致的可再生能源数据。

2.2 数据准备与结构设计

假设不同区域的可再生能源输出序列 $x_N = \{x_{N,1}, x_{N,2}, \dots, x_{N,T}\}$, 其中 N 为区域数。为了保留时空依赖性,在生成数据时,首先将这些序列拼接成一个 $N \times T$ 阶的时空数据矩阵。该矩阵不仅能够反映各区域之间的空间关系,还能够体现时间序列的变化趋势,为 cWGAN-GP 提供丰富的输入信息,使其能够在训练过程中学习到时空特性。

卷积操作中的时空特征提取如图1所示。图中: X 为输入数据矩阵中的元素,即各区域在不同时间的可再生能源输出值; $X_1 \sim X_8$ 为连续时间步(或不同空间位置)的输入特征向量,用于表征风电功率的时空序列特性; P 为输入通道中特定位置的特征值。卷积核在空间和时间维度上同时滑动,能够有效捕捉输入数据的局部特征,有助于生成器学习到时间和空间上的相关模式,从而生成符合实际的可再生能源输出场景。




图1 卷积操作中的时空特征提取

Fig.1 Spatiotemporal feature extraction in convolutional operation

2.3 cWGAN-GP网络结构

cWGAN-GP 通过引入控制向量 c 和梯度惩罚,

显著提高了传统 GAN 的训练稳定性,特别是在生成复杂数据分布时。生成器的设计结合了卷积神经网络(convolutional neural network, CNN)和时空特征提取机制,确保网络能够从时空数据中提取出动态变化和空间分布特性。在判别器的设计中,通过多层卷积网络对生成场景和真实场景的时空特征进行提取和比较,确保生成的场景在时空特性上与真实数据更加一致。采用 LeakyReLU 激活函数,以保持梯度流动并避免梯度消失,同时增强判别器的非线性表达能力。梯度惩罚机制通过改进损失函数,提高了判别器的鲁棒性,使生成数据更接近真实分布。cWGAN-GP 的生成器和判别器结构分别如附录 A 图 A1、A2 所示。

2.4 数学表达

生成器输出如式(7)所示。

$$G^{\text{feat}}(z, c) = C_{\text{conv}} 1D/2D(G_{\text{layers}}, z, c) \quad (7)$$

式中: $G^{\text{feat}}(z, c)$ 为生成器的时空特征输出; G_{layers} 为生成器的卷积层结构; $C_{\text{conv}} 1D$ 、 $C_{\text{conv}} 2D$ 分别表示一维、二维卷积操作,用于提取输入序列的时间特征或时空联合特征。

判别器输出如式(8)所示。

$$D^{\text{score}}(x, c) = C_{\text{conv}} 1D/2D(D_{\text{layers}}, x, c) \quad (8)$$

式中: $D^{\text{score}}(x, c)$ 为判别器输出的评分,用于构建对抗目标函数,表示输入样本 x 和控制向量 c 是否属于真实样本。

2.5 时空特征提取与融合

cWGAN-GP 的生成器通过时空特征提取与融合机制,有效提升生成数据的质量和一致性,其核心在于利用一维或二维卷积操作提取时间序列与空间区域间的相关性,捕捉数据的动态变化和空间分布特性。在生成过程中,不同时间点和区域的特征图被融合为统一的时空特征表示,确保生成数据在时间和空间维度上保持一致性和真实性。卷积操作使生成器能够在时间维度上学习数据的变化趋势,在空间维度上捕捉区域间的相互影响。特征融合机制进一步加强时空信息的整合,使得生成的可再生能源场景不仅符合时间上的波动规律,还能准确反映地理分布的空间模式。

在生成器的设计中,输入包含随机噪声向量和气象控制向量 c ,通过多层 CNN 提取时空特征。卷积操作不仅能分析相邻时段之间的依赖性,还能捕捉不同区域之间的空间相关性。生成器通过跨通道的特征融合机制,将多通道的时空特征整合为整体特征图,以生成符合实际分布的可再生能源场景。

用于跨通道特征融合的 cWGAN-GP 结构如图2所示。生成器通过多个卷积核提取特征,并融合来自不同通道的特征图,以生成与目标分布高度匹配

的数据。判别器则学习并区分生成数据与真实数据之间的差异,从而提升整体生成质量。




图2 用于跨通道特征融合的cWGAN-GP结构
Fig.2 cWGAN-GP architecture for cross-channel feature fusion

3 生成场景评价指标

采用多个指标从确定性预测和概率性预测2个角度对场景生成方法进行评估。为防止随机性,对案例重复10次,计算平均指标。

3.1 确定性预测

在确定性预测中,采用如下评估指标。

1) 弗雷德曼相似度(Fréchet inception distance, FID)用于衡量生成数据与真实数据之间的相似性。计算公式如附录B式(B1)所示。

2) 平均绝对误差(mean absolute error, MAE)是评估预测值和训练值之间误差的常用指标。其值越小,表示模型性能越好。计算公式如附录B式(B2)所示。

3) 均方根误差(root mean square error, RMSE)表示预测值和训练值之间差异的样本标准差。其值越小,表示模型的性能越优越。计算公式如附录B式(B3)所示。

3.2 概率性预测

在概率性预测中,将分位数损失(pinball score, PS)和连续分级概率评分(continuous ranked probability score, CRPS)作为边际分布概率预测的评估指标。计算公式为:

$$P_{PS_u} = \frac{1}{m} \sum_{j=m+1}^{m+M} \phi_j^u \quad (12)$$

$$\phi_j^u = \begin{cases} u(P_j - \hat{P}_j^u) & P_j \geq \hat{P}_j^u \\ (u-1)(P_j - \hat{P}_j^u) & P_j < \hat{P}_j^u \end{cases} \quad (13)$$

$$C_{CRPS} = \frac{1}{m} \sum_{j=1}^K \int_{-\infty}^{+\infty} (\hat{P}_j - P_j)^2 dt \quad (14)$$

式中: P_{PS_u} 为PS, u 为累积分布函数值,取值范围为0.05~0.95,取值间隔为0.05; m 为分位数水平数,即

所选取的不同分位点的总数; M 为测试样本数; ϕ_j^u 为样本 j 在分位点 u 下的分位损失; P_j 为样本 j 对应的真实观测值; $\hat{P}_j^u$ 为在分位点 u 下样本 j 的预测值; K 为用于CRPS评估的预测样本数。

4 算例分析

4.1 数据说明和仿真设置

风电、光伏和负荷数据均来自甘肃某地,为准确预测电网场景,考虑温度、湿度、降水、风速、太阳辐射这5种天气条件,利用现场自动气象站收集温度、湿度、降水、风速、风向、太阳辐射等9种天气数据。实验旨在研究不同GAN模型在场景生成方面的特性和性能。考虑6种基于GAN的生成模型,即GAN、CGAN、WGAN、DCGAN、cWGAN-GP与所提模型。模型的结构参数如附录C表C1所示。所有模型均使用RMS优化器进行训练,批量大小为32,使用Python 3.12和TensorFlow 1.15实现,硬件参数包括:2.30 GHz的intel Core i7-8750处理器,8 GB RAM。

本文模型生成器 G 的输入包括随机噪声 z 以及 e_{x_i} 和 e_{m_i} ,生成器通过多层感知机和反卷积层生成 12×12 的样本,生成器的隐藏层使用ReLU激活函数,输出层使用tanh激活函数。本文模型判别器 D 包含卷积层和多层感知机层,输出太阳能和风能曲线,经过归一化并重塑为 12×12 阶的矩阵。判别器的输出使用Sigmoid激活函数。辅助网络 W 与判别器 D 共享卷积层,在最后一层添加一个全连接层,用于额外的监督信号。

4.2 气象特征控制场景生成分析

本节采用主成分分析(principal component analysis, PCA)评估6种基于GAN的数据生成模型的性能,该方法通过从给定数据中提取主成分来减少数据维度,从而表示多维数据。PCA的执行方式是,将第一个主成分定义为最大化数据方差的方向,将第二个主成分定义为与第一个主成分正交并最大化数据方差的方向,将2个主成分作为坐标轴来可视化数据,可以更容易地比较不同数据之间的相似性。真实数据与6种模型生成数据的分布如附录C图C1所示。由图可知,所提模型生成数据的分布与训练数据最为接近,相较于cWGAN-GP,所提模型更充分地考虑了气象特征的控制能力,更准确地刻画了关键气象因素对风光出力的影响。

4.3 气象特征控制场景生成相关性分析

通过PCA将多维数据可视化为二维数据是比较真实数据和生成数据的简单方法,但不足以验证所提模型的有效性。为此,采用皮尔逊相关系数(Pearson correlation coefficient, PCC)分析方法。PCC取值范围为-1~1,其值离0越远,表示2个变量之间的线性关系越强。PCC的符号表示变量关系的

方向,例如,当PCC为正时,一个变量增加,另一个变量也会增加。使用PCC分析真实数据和生成数据变量之间的关系,并将结果以热图的形式表示。如果生成数据与真实数据相似,那么其热图也会相似。表示真实数据和生成数据中变量之间关系的PCC热图分别如图3和附录C图C2所示。




图3 表示真实数据中变量之间关系的PCC热图

Fig.3 PCC heatmap representing relationship between variables in real data

为全面评估不同生成模型在生成数据质量上的表现,采用多种定量评估指标,包括FID、MAE、RMSE、PS和CRPS。其中:FID、PS为无量纲指标,分别衡量生成数据在特征分布上的相似度和模式匹配程度;MAE、RMSE和CRPS在本文中均基于归一化后的数据计算,结果为标么值,可用于不同方法之间的统一比较。这些指标能够有效反映生成数据与真实数据之间的相似度、误差程度以及生成精度,数值越小,表示模型的拟合能力越强。不同生成模型的评估指标如表1所示。

表1 不同生成模型的评估指标

Table 1 Evaluation metrics of different generative models

模型	FID	MAE	RMSE	PS	CRPS
GAN	35.0	2.34	3.78	0.68	0.75
CGAN	28.5	1.89	3.12	0.58	0.62
WGAN	26.2	2.05	2.93	0.61	0.68
DCGAN	23.6	1.72	3.01	0.55	0.59
cWGAN-GP	18.7	1.56	2.87	0.52	0.54
本文模型	15.3	1.42	2.65	0.48	0.50

由表1可知,本文模型在所有指标上均表现最优,相较于cWGAN-GP,其FID降低18.18%,表明生成数据分布更接近真实数据,其MAE和RMSE分别

降低8.97%和7.67%,显示出更高的生成精度,其PS和CRPS分别降低7.69%和7.41%,进一步验证了模型的拟合能力。综上所述,所提模型在生成风光场景的概率特征拟合方面表现出色,其拟合精度显著优于其他模型,能更好地捕捉风光发电的高维概率特征。

为进一步分析风光发电场景中的空间相关性,本文针对500组风光场景数据,分别计算3座光伏场和3座风电场之间的SCC。SCC作为一种非参数统计量,能够有效衡量不同光伏集群与风电场之间的秩次相关性,特别适用于处理风光资源之间复杂的非线性关系。计算相关系数,分析其在不同地理位置、气候条件和时间尺度下的共同波动规律,对于提高电网系统的调度效率、优化能源分配以及增强系统稳定性具有重要作用。不同生成模型的SCC如附录C图C3所示,直观地反映了光伏与风电之间的相关性强度和变化趋势。

通过比较不同生成模型在生成风光发电场景时的表现发现,不同模型在捕捉实际相关系数的能力上存在显著差异:所提模型的相关性系数整体较高且波动最小,该模型表现出最佳的生成质量;GAN、CGAN、WGAN在相关性保持上存在较大偏差,生成数据与真实数据的相关结构不够一致;而DCGAN和cWGAN-GP虽然在一定程度上提高了相关性保持能力,但结果仍存在一定的波动性和偏差。

综上所述,所提模型在风光发电场景生成任务中不仅具备更优的相关性保持能力,还能够更精准地再现风光出力的统计特性,为电网优化调度与风险评估提供更可靠的数据支持。

4.4 可控风电功率场景生成及特征分析

以风电场景的生成为例,验证可控生成过程的有效性。在生成过程中,对可控向量的每个可解释特征(即平均功率、最大功率、最小功率和平均波动功率)依次进行调整,然后为每个可控向量生成若干调制后的场景。可控生成功率场景的变化趋势如图4所示。可控向量的期望值与生成样本的实际统计值在每个特征指标上的对比如表2所示。数值结果表明,在各特征合理相关的情况下,所提出的可控模型能够独立地控制指定特征,并以每个预设可控向量对应的5个目标值准确实现目标,生成与期望特征一致的风电功率场景。

由表2可知:真实指标与可控向量保持较高的一致性,反映出风电功率随时间的动态变化规律;平均功率和最大功率均呈现稳步上升趋势,说明风电场整体发电能力随风速变化而提升,但最大功率的部分实际数值略低于可控向量,这表明极端风速条件下仍存在一定的不确定性;最小功率的变化趋势




图4 可控生成功率场景的变化趋势

Fig.4 Variation trend of controllable generation power scenario

表2 可解释特征预设可控向量与实际统计指标的比较

Table 2 Comparison between presented controllable vectors of interpretable features and actual statistical indicators

单位: MW

可解释特征	比较对象	特征指标变化趋势
平均功率	可控向量	[1.0, 10.0, 20.0, 28.0, 36.0]
	真实指标	[1.0, 11.2, 18.9, 28.0, 37.4]
最大功率	可控向量	[10.0, 20.0, 28.0, 36.0, 46.0]
	真实指标	[10.5, 19.5, 29.7, 37.0, 46.3]
最小功率	可控向量	[0, 10.0, 16.0, 24.0, 32.0]
	真实指标	[0, 10.3, 17.2, 22.8, 30.5]
平均波动功率	可控向量	[2.0, 5.0, 10.0, 13.0, 17.0]
	真实指标	[1.7, 5.6, 9.8, 13.5, 17.6]

也较为稳定,但部分真实指标略低于可控向量,这可能是受局部风速降低的影响;平均波动功率随着功率水平的提高而增加,说明风电输出的波动性在较高功率区间更为明显,这一特性对电网的调度和优化具有重要参考价值。

4.5 模型泛化能力验证

为进一步验证所提模型的泛化能力,采用文献[30]中的历史发电功率数据进行验证。该数据集涵盖东北地区6座风电场和6座光伏站点的实测功率输出,具有较强的代表性和较大的波动性。不同生成模型的评估指标如附录C表C2所示。由表可知,本文模型在所有评估指标上均展现出优越性,与cWGAN-GP相比,本文模型的FID降低19.23%,

MAE和RMSE分别降低9.55%和5.96%,PS和CRPS分别降低7.14%和10.53%,这表明本文模型在数据生成质量和精度方面比cWGAN-GP有所提升,能够更有效地适应实际数据的波动性,并展现出更强的泛化能力。

5 结论

本文提出一种基于改进cWGAN-GP的可再生能源场景可控生成方法,采用我国甘肃地区历史发电功率数据,验证了所提方法的有效性。主要结论如下。

1)针对不同气象特征,构建层次化控制向量,通过集成气象数据的多层次特征表达与动态调整机制,实现全时间尺度下模型不确定性的量化,提高了生成场景在不同气象条件下的准确性。

2)所提模型在捕捉风光出力的时空相关性方面优于其他模型,相较于cWGAN-GP,其FID、MAE、RMSE、PS和CRPS分别降低18.18%、8.97%、7.67%、7.69%和7.41%,生成数据能够准确反映不同地理位置和时段的风光出力模式,并保持较高的相关性和一致性。

3)通过引入气象特征控制,采用SCC分析风光出力与气象因子之间的关联性,筛选出对出力影响显著的关键气象特征,从而提升模型的可控性与可解释性。在风电功率的解释性特征中,平均功率、最大功率、最小功率及平均波动功率的最大偏差分别为3.7%、2.7%、5.3%和3.5%,整体误差较小,充分体现了所提方法在特征可控性方面的高精度与稳定性,有效增强了其在不同气象条件下生成风光场景的能力。

未来可结合不同地区的风光资源特征优化控制向量的设计,并引入动态建模方法,以提升模型在复杂气象条件下的泛化能力,进一步提高风光出力场景生成的准确性和适用性。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 顾光荣,杨鹏,汤波,等. 源-荷-储协同优化的配电网平衡能力提升方法[J]. 中国电机工程学报, 2024, 44(13): 5097-5108.
Gu Guangrong, Yang Peng, Tang Bo, et al. A method for improving the balance ability of distribution networks through source-load-storage collaborative optimization [J]. Proceedings of the CSEE, 2024, 44(13): 5097-5108.
- [2] 杨续松,罗先觉,王建国,等. 含大规模可再生能源的电力系统中长期时序-随机生产模拟方法[J]. 电力自动化设备, 2026-02-10. <https://doi.org/10.16081/j.epae.202602011>.
- [3] 李夫刚,李夫海,琚承乾,等. 新能源不确定性表征方法及关键技术问题研究现状、挑战及展望[J]. 电力系统保护与控制, 2025, 53(15): 172-187.
Li Fugang, Li Fuhai, Ju Chengqian, et al. Methods for charac-

- terizing renewable energy uncertainty and key technical issues: research status, challenges, and prospects[J]. *Power System Protection and Control*, 2025, 53(15): 172-187.
- [4] 兰健, 郭庆来, 周艳真, 等. 基于生成对抗网络和模型迁移的电力系统典型运行方式样本生成[J]. *中国电机工程学报*, 2022, 42(8): 2889-2899.
- Lan Jian, Guo Qinglai, Zhou Yanzhen, et al. Generation of power system typical operation mode samples: a generation adversarial network and model-based transfer learning approach[J]. *Proceedings of the CSEE*, 2022, 42(8): 2889-2899.
- [5] 殷佳敏, 谢宁, 王承民, 等. 基于分形理论的新型电力系统规划场景生成方法[J]. *电力自动化设备*, 2024, 44(7): 94-100, 188.
- Yin Jiamin, Xie Ning, Wang Chengmin, et al. Generation method of planning scenario for new power system based on fractal theory[J]. *Electric Power Automation Equipment*, 2024, 44(7): 94-100, 188.
- [6] 邹金, 卢斯煜, 卓映君, 等. 基于多场景时序运行模拟的电力电量平衡评估方法[J]. *电力系统自动化*, 2025, 49(23): 139-148.
- Zou Jin, Lu Siyu, Zhuo Yingjun, et al. Evaluation method of electric power and energy balance based on multi-scenario time-series operation simulation[J]. *Automation of Electric Power Systems*, 2025, 49(23): 139-148.
- [7] 葛彦硕, 周艳真, 兰健, 等. 电力电量平衡视角下基于LSTM-ACGAN的特定风电时序场景生成[J]. *电力自动化设备*, 2025, 45(11): 10-16, 24.
- Ge Yanshuo, Zhou Yanzhen, Lan Jian, et al. Specific wind power sequential scenario generation based on LSTM-ACGAN from perspective of electric power and energy balance[J]. *Electric Power Automation Equipment*, 2025, 45(11): 10-16, 24.
- [8] Aliabadi M J, Radmehr M. Optimization of hybrid renewable energy system in radial distribution networks considering uncertainty using meta-heuristic crow search algorithm[J]. *Applied Soft Computing*, 2021, 107: 107384.
- [9] Song Y, Liu T, Hill D J. Chance constrained economic dispatch considering the capability of network flexibility against renewable uncertainties[J]. *IEEE Transactions on Power Systems*, 2024, 39(5): 6636-6648.
- [10] Liu Z H, Liu S L, Li Q H, et al. Optimal day-ahead scheduling of islanded microgrid considering risk-based reserve decision[J]. *Journal of Modern Power Systems and Clean Energy*, 2021, 9(5): 1149-1160.
- [11] 牟长兴, 张俊涛, 程春田, 等. 考虑时空相关性的流域水风光多能互补系统高维不确定性场景生成方法[J]. *电网技术*, 2024, 48(9): 3614-3623.
- Mu Changxing, Zhang Juntao, Cheng Chuntian, et al. High-dimensional uncertainty scenario generation method for hydro-wind-solar multi-energy complementary system considering spatio-temporal correlation[J]. *Power System Technology*, 2024, 48(9): 3614-3623.
- [12] Vagropoulos S I, Kardakos E G, Simoglou C K, et al. ANN-based scenario generation methodology for stochastic variables of electric power systems[J]. *Electric Power Systems Research*, 2016, 134: 9-18.
- [13] 吴艳梅, 陈红坤, 陈磊, 等. 基于改进MMD-GAN的可再生能源随机场景生成[J]. *电力系统保护与控制*, 2024, 52(19): 85-96.
- Wu Yanmei, Chen Hongkun, Chen Lei, et al. Stochastic scenario generation for renewable energy based on improved MMD-GAN[J]. *Power System Protection and Control*, 2024, 52(19): 85-96.
- [14] 陈浩, 张文朝, 黄志光, 等. 考虑极端天气的先验知识引导风/光短期出力场景生成方法研究[J]. *智慧电力*, 2025, 53(3): 44-52.
- Chen Hao, Zhang Wenchao, Huang Zhiguang, et al. Research on prior knowledge-guided short-term wind/photovoltaic output scenario generation method considering extreme weather[J]. *Smart Power*, 2025, 53(3): 44-52.
- [15] 王成磊, 匡熠, 濮永现, 等. 基于改进生成对抗网络场景生成的长-短期储能优化配置[J]. *高电压技术*, 2024, 50(3): 1131-1144.
- Wang Chenglei, Kuang Yi, Pu Yongxian, et al. Optimal configuration of long-term and short-term energy storage based on improved generative adversarial network scenarios[J]. *High Voltage Engineering*, 2024, 50(3): 1131-1144.
- [16] Wang Y B, Liu Y X, Yang Q. Operational scenario generation and forecasting for integrated energy systems[J]. *IEEE Transactions on Industrial Informatics*, 2024, 20(2): 2920-2931.
- [17] 陈志威, 吴毓峰, 潘振宇, 等. 基于图表示学习和特征引导的电力系统运行场景生成方法[J]. *中国电机工程学报*, 2024, 44(24): 9521-9532.
- Chen Zhiwei, Wu Yufeng, Pan Zhenning, et al. A power system operating scenario generation method based on graph representation learning and feature guidance[J]. *Proceedings of the CSEE*, 2024, 44(24): 9521-9532.
- [18] 张帅, 刘文霞, 万海洋, 等. 基于改进条件生成对抗网络的可控场景生成方法[J]. *电力自动化设备*, 2024, 44(6): 9-17.
- Zhang Shuai, Liu Wenxia, Wan Haiyang, et al. Controllable scenario generation method based on improved conditional generative adversarial network[J]. *Electric Power Automation Equipment*, 2024, 44(6): 9-17.
- [19] 黄越辉, 孙亚南, 李驰, 等. 基于条件生成对抗网络的多区域风电短期出力场景生成方法[J]. *电网技术*, 2023, 47(1): 63-72.
- Huang Yuehui, Sun Yanan, Li Chi, et al. Constructing method of short-term output scenarios for multi-regional wind power based on conditional generative adversarial network[J]. *Power System Technology*, 2023, 47(1): 63-72.
- [20] Tan Y H, Zhang Q, Shi L, et al. A novel short-term wind power scenario generation method combining multiple algorithms for data-missing wind farm Considering spatial-temporal correlativity[J]. *International Journal of Electrical Power & Energy Systems*, 2024, 162: 110227.
- [21] Dong W, Chen X Q, Yang Q. Data-driven scenario generation of renewable energy production based on controllable generative adversarial networks with interpretability[J]. *Applied Energy*, 2022, 308: 118387.
- [22] 罗萍萍, 盛奥, 林济铿, 等. 基于可解释性条件生成对抗网络的台风气象负荷场景生成方法[J]. *电力系统自动化*, 2025, 49(2): 186-197.
- Luo Pingping, Sheng Ao, Lin Jikeng, et al. Scenario generation method of typhoon meteorological load based on interpretability conditional generative adversarial network[J]. *Automation of Electric Power Systems*, 2025, 49(2): 186-197.
- [23] Li Z L, Peng X G, Cui W B, et al. A novel scenario generation method of renewable energy using improved VAEGAN with controllable interpretable features[J]. *Applied Energy*, 2024, 363: 122905.
- [24] 陈凡, 陈刘明, 王曼, 等. 基于改进信息最大化生成对抗网络的风光出力场景可控生成方法[J]. *电网技术*, 2024, 48(4): 1477-1486.
- Chen Fan, Chen Liuming, Wang Man, et al. Controllable scenario generation method for wind power and photovoltaic output based on improved InfoGAN[J]. *Power System Technology*, 2024, 48(4): 1477-1486.
- [25] Wang Q, Zhang X G, Xu D G. 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.
- [26] 邵振国, 张承圣, 陈飞雄, 等. 生成对抗网络及其在电力系统中的应用综述[J]. 中国电机工程学报, 2023, 43(3):987-1003.
Shao Zhenguo, Zhang Chengsheng, Chen Feixiong, et al. A review on generative adversarial networks for power system applications[J]. Proceedings of the CSEE, 2023, 43(3):987-1003.
- [27] 米阳, 周杰, 卢长坤, 等. 基于改进生成对抗网络与碳足迹的配电网多目标双层规划[J]. 中国电机工程学报, 2024, 44(21):8421-8434.
Mi Yang, Zhou Jie, Lu Changkun, et al. A multi-objective bi-level planning of distribution network based on improved generative adversarial network and carbon footprint[J]. Proceedings of the CSEE, 2024, 44(21):8421-8434.
- [28] Li Y, Cao J T, Xu Y, et al. Deep learning based on Transformer architecture for power system short-term voltage stability assessment with class imbalance[J]. Renewable and Sustainable Energy Reviews, 2024, 189:113913.
- [29] Ye S M, Wang H, Tan M K, et al. Recurrent affine transformation for text-to-image synthesis[J]. IEEE Transactions on Multimedia, 2024, 26:462-473.
- [30] 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.

作者简介:

高峰阳(1970—), 男, 教授, 博士研究生导师, 主要研究方向为电力系统优化运行及配电网运行规划(E-mail: ljdgaofy@lztu.edu.cn);

裴淑萍(2000—), 女, 硕士研究生, 主要研究方向为电力系统优化调度(E-mail: pshuping_2000@163.com)。

(编辑 王锦秀)

Controllable and interpretable wind-solar scenario generation method based on improved generative adversarial network

Gao Fengyang¹, Pei Shuping¹, Li Long¹, Zha Pengtang¹, Wang Qinjuan²

(1. School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. Economic and Technological Research Institute of State Grid Gansu Electric Power Company
(New Energy Power System Research Institute), Lanzhou 730050, China)

Abstract: Aiming at the uncertainty and intermittency brought by the integration of wind and solar renewable energy into power grid, a controllable and interpretable wind-solar output scenario generation method based on the conditional Wasserstein generative adversarial network with gradient penalty (cWGAN-GP) is proposed. The generation process of wind-solar output scenarios is regulated by introducing conditional vectors in cWGAN-GP, which ensures that the generated data meets specific statistical characteristics requirement. The gradient penalty is incorporated to enhance the training stability, which ensures the quality of generated scenarios while accurately capturing the spatiotemporal correlation of wind-solar output. The Spearman correlation coefficient is employed to analyze the relationship between high dimensional meteorological features and wind-solar output, and key meteorological factors are selected as the control variables to improve the model controllability and its adaptability to meteorological conditions. The IEEE 33-bus system is used for simulation and verification, and the results show that the proposed method can effectively generate wind-solar output scenarios conforming to statistical rules, and maintain spatiotemporal correlation well.

Key words: uncertainty; scenario generation; interpretability; cWGAN-GP; spatiotemporal characteristic