

# 基于融合多尺度卷积与多头注意力机制的 WGAN-GP 新能源场景生成方法

刘自兵, 崔双喜, 刘庆庆

(新疆大学电气工程学院, 新疆维吾尔自治区 乌鲁木齐市 830047)

## New Energy Scenario Generation Method Based on an Improved WGAN-GP Integrating Multi-scale Convolution and Multi-head Attention Mechanisms

LIU Zibing, CUI Shuangxi, LIU Qingqing

(School of Electrical Engineering, Xinjiang University, Urumqi 830047, Xinjiang Uygur Autonomous Region, China)

**ABSTRACT:** With the continuous increase in the penetration of renewable energy, the accurate characterization and effective management of its inherent uncertainty have become crucial for the planning and secure operation of modern power systems. To address this challenge, this paper proposes a renewable energy scenario generation method based on a Wasserstein generative adversarial network with gradient penalty (WGAN-GP), integrated with multi-scale convolution and a multi-head attention mechanism. The method efficiently extracts features of renewable energy output at different time scales through a parallel multi-scale convolutional network. It incorporates a multi-head attention mechanism to capture long-term dependencies, thereby significantly enhancing the model's capability to model complex dynamics. Furthermore, a comprehensive interpretability analysis framework is established, combining SHapley additive exPlanations (SHAP) attribution analysis with attention weight visualization to gain deep insights into the model's decision-making process. Experimental results demonstrate that the proposed method provides an effective and interpretable tool for the uncertainty analysis of renewable energy output.

**KEY WORDS:** new energy; WGAN-GP; scenario generation; multi-scale convolution; multi-head attention mechanism; interpretability analysis

**摘要:** 在新能源发电占比持续提升的背景下, 如何精确刻画并有效管理其不确定性, 对新型电力系统规划与安全稳定运行至关重要。对此, 提出一种融合多尺度卷积与多头注意力机制的 Wasserstein 生成对抗网络结合梯度惩罚(Wasserstein generative adversarial network with gradient penalty, WGAN-GP)新能源场景生成方法。该方法通过并行多尺度卷积网络

高效提取新能源出力在不同时间尺度的特征, 并引入多头注意力机制以捕捉长期依赖关系, 显著增强了模型对复杂动态的建模能力。此外, 构建了全面的可解释性分析框架, 利用夏普利加法解释方法(SHapley additive exPlanations, SHAP) 归因分析与注意力权重可视化, 深入剖析了模型的决策过程。实验结果表明, 该方法为新能源出力不确定性分析提供了一种有效且可解释的工具。

**关键词:** 新能源; WGAN-GP; 场景生成; 多尺度卷积; 多头注意力机制; 可解释性分析

**DOI:** 10.13335/j.1000-3673.pst.2025.1065

## 0 引言

在全球能源转型和应对气候变化的背景下, 发展新型电力系统已成为各国的共同目标<sup>[1-2]</sup>。风电、光伏等新能源凭借清洁、可持续的优势大规模并网, 成为实现“双碳”目标的重要支撑<sup>[3]</sup>。然而, 新能源出力的随机性、间歇性与波动性等固有特征, 对电力系统的安全稳定运行构成了严峻挑战<sup>[4-5]</sup>。针对新能源不确定性问题, 场景生成技术通过构建一组具有代表性的出力曲线, 能够有效刻画新能源的随机特性。这不仅为电力系统安全风险评估与电网规划设计提供可靠数据支撑, 还对推动源网荷储协同发展、保障系统安全稳定运行具有重要意义<sup>[6-8]</sup>。因此, 开发高质量的新能源出力场景生成方法, 是确保新能源可靠并网与电力系统安全运行的关键。

新能源场景生成方法主要分为两大类: 基于传统统计建模<sup>[9]</sup>与基于深度学习的生成模型<sup>[10]</sup>。早期的新能源出力场景生成主要依赖于传统的统计学方法, 其核心思想是首先通过历史数据拟合出特定的概率分布, 再从中进行随机采样以生成场景。基于概率分布模型的场景生成方法主要有 Copula

函数<sup>[11]</sup>、Markov 链法<sup>[12]</sup>、场景树生成法<sup>[13]</sup>。这类方法在处理低维、线性或具有明确统计特征的数据时表现尚可。然而,在应对新能源出力的非线性特性和长程时间依赖上仍显局限,这促使学界探索适应性更强的场景生成技术。

近年来,随着大数据与人工智能技术的飞速发展,以深度学习为代表的“黑盒”模型凭借其强大的非线性映射能力和数据驱动特性,为解决新能源场景生成难题带来了新的曙光。在众多深度学习模型中,生成对抗网络(generative adversarial networks, GAN)因其独特的对抗训练机制,在图像、文本等复杂数据生成领域取得了突破性进展,并逐步被引入电力系统以处理场景生成问题。文献[14]提出了基于 GAN 的无模型新能源场景生成方法,并使用 Wasserstein 距离作为判别器损失函数来提高网络训练质量,通过数据驱动的方法捕捉风光发电的时空相关性。文献[15]提出基于条件深度卷积生成对抗网络的场景生成模型,利用卷积网络的特征提取能力对风电、光伏等间歇性分布式电源的出力不确定性进行精确建模,为后续的分布式电源优化配置提供了有效的场景集。文献[16]提出了基于 Wasserstein 距离损失函数的条件生成对抗网络方法,把预测值作为条件信息,通过学习噪声与条件输出间的映射关系,提升了新能源日前场景生成的准确性和稳定性。文献[17]提出了一种基于注意力条件生成对抗网络的风电和光伏出力长期相关情景生成方法,旨在针对新能源系统优化规划中关键的长期情景生成问题。文献[18]提出了基于改进条件生成扩散模型的新能源日前场景生成方法,通过引入条件信息指导扩散过程的噪声添加与去噪机制,提升了风光日前出力场景的生成精度并增强了模型的可解释性。文献[19]构建了集成可控潜在变量的生成对抗网络框架,以平均功率、最大/最小功率、平均波动功率和最大爬坡功率作为控制向量,实现场景生成过程的可控性,从系统规划运行角度实现数据驱动的自适应场景生成。

尽管新能源场景生成技术已经取得了一定的进展,但仍存在一些问题和挑战:

1) 现有模型在表征新能源出力的复杂特性方面存在显著局限。传统统计学模型因其严格的分布假设,导致泛化能力及应用普适性受限。尽管包括生成对抗网络变体在内的深度学习模型增强了非线性拟合能力,但它们在捕捉新能源出力的多尺度时间特征方面仍显不足。

2) 深度学习模型的“黑箱”特性限制实际应

用。深度学习模型凭借强大的非线性映射能力在性能上超越传统方法,但其决策过程的高度复杂性导致“黑箱”问题。而电力系统对安全性和可靠性要求极高,缺乏对模型内部机理的深入理解将极大限制其在实际规划与运行中的可信度和推广应用。

针对上述问题和挑战,本文提出了一种基于融合多尺度卷积与多头注意力机制的 Wasserstein 生成对抗网络结合梯度惩罚(Wasserstein generative adversarial network with gradient penalty, WGAN-GP)新能源场景生成方法,该方法的核心在于学习新能源出力的内在随机过程及多尺度时序依赖性,以生成统计特性一致且多样性丰富的未来可能场景,进而增强电力系统规划与运行决策对不确定性的适应能力。此外,本文还构建了完整的可解释性分析框架,以剖析模型的内部决策机制。本文研究内容主要如下:

1) 设计了融合多尺度卷积与多头时间注意力机制的 WGAN-GP 模型。该模型引入 Wasserstein 距离作为损失函数,用以衡量真实样本与生成样本的分布差异。在此基础上,设计了适用于新能源场景生成的网络结构,在生成器中采用多尺度卷积和多头注意力机制,使其能够主动学习新能源场景中时间多尺度特征与长期依赖,不再仅依赖于判别器的反馈,从而强化了模型的生成能力。算例结果表明,本文所提出的模型能够很好地学习新能源出力特征,并生成高质量的新能源出力场景。

2) 构建了完整的模型可解释性分析框架。本文将注意力权重可视化与夏普利加性解释方法(SHapley additive exPlanations, SHAP)分析相结合。通过注意力权重可视化,可以直观揭示模型在生成过程中对历史数据关键时间点的关注模式和权重分布。利用 SHAP 值归因分析,探索隐空间整体结构与生成数据宏观语义特征之间的内在关联,通过操控隐向量的不同维度,实现对生成场景关键宏观特性(如平均功率、波动性和爬坡率)的有效控制。结果表明,该方法能够深入剖析模型输出背后的驱动因素,增强了模型的实用价值和可信度。

## 1 深度学习模型机理

### 1.1 GAN 网络结构

生成对抗网络是由 Goodfellow 等<sup>[20]</sup>于 2014 年提出的一种无监督深度学习框架。该框架通过生成器(generator, G)与判别器(discriminator, D)两个神经网络的对抗性博弈,隐式地学习训练数据的复杂内在分布,从而生成与真实数据高度相似的新样

本。生成器的作用是挖掘真实样本数据  $x$  的内在特征从而生成大量与真实数据相似的新数据样本，其输入为服从先验分布  $P_z(z)$  的随机噪声数据  $z$ ，输出为生成样本  $x'$ ， $x'$  服从生成分布  $P_g(x')$ 。判别器的作用是尽可能准确区分真实样本和生成样本，其输入为  $x$  和  $x'$ ，其中  $x$  服从真实分布  $P_r(x)$ ，输出为一个标量  $D(x)$ ，用于判断输入样本的真实性。GAN 网络的基本结构如图 1 所示。

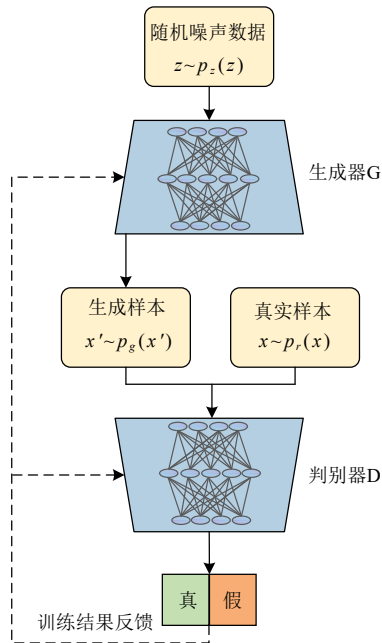


图 1 GAN 网络基本结构  
Fig. 1 Basic structure of GAN

在新能源场景生成任务中，将历史新能源出力数据作为真实样本  $x$ 。生成器  $G$  以随机噪声  $z$  为输入，生成模拟的新能源出力数据。判别器  $D$  则通过对真实数据和生成数据进行鉴别，通过反向传播使生成器不断优化，直至其生成的场景在统计特性上与真实场景无法区分。GAN 在训练过程中生成器和判别器的损失函数分别如式(1)和式(2)所示：

$$L_G = E_{x' \sim P_g(x')} [D(x')] \tag{1}$$

$$L_D = -E_{x \sim P_r(x)} [D(x)] + E_{x' \sim P_g(x')} [D(x')] \tag{2}$$

式中： $L_G$  和  $L_D$  分别为生成器和判别器的损失函数； $E$  表示对应分布的期望值； $D(\sim)$  表示判别器函数。GAN 采用交替优化的训练策略，通过数据驱动的对抗训练，能够有效模拟新能源出力的复杂动态行为，而非局限于稳态分布学习。在训练过程中，通过固定生成器优化判别器、再固定判别器优化生成器的方式，两个网络交替更新参数，形成动态博弈过程，并最终趋向纳什均衡，如式(3)所示的极小极大博弈估计函数。

$$\min_G \max_D V(D, G) = E_{x \sim P_r(x)} [D(x)] - E_{x' \sim P_g(x')} [D(D(x'))] \tag{3}$$

### 1.2 WGAN-GP 网络结构

原始生成对抗网络(GAN)在训练过程中，其损失函数通常与 JS 散度或 KL 散度相关联，用于衡量生成数据分布与真实数据分布的相似性。然而，在处理高维复杂数据(如新能源出力)时，由于数据分布在特征空间中的稀疏性，生成分布与真实分布极易出现不重叠的情况。在此条件下，JS/KL 散度会失去有效的梯度信息，导致训练过程中出现严重的梯度消失问题，进而引发模式崩溃现象<sup>[21]</sup>。

为了克服原始 GAN 训练中的不稳定性和模式崩溃问题，Wasserstein 生成对抗网络采用 Wasserstein 距离来衡量两个概率分布的相似性<sup>[22]</sup>。与 JS/KL 散度不同，当分布不重叠或重叠度很小时，Wasserstein 距离依然能提供连续且有意义的梯度。该特性保证了训练过程的梯度稳定性，有效缓解了梯度消失和模式崩溃现象。其中 Wasserstein 距离基于最优传输理论，用于生成对抗网络可表示为

$$W(P_r, P_g) = \sup_{\|f_D\|_L \leq 1} E_{x \sim P_r} [D(x)] - E_{x' \sim P_g} [D(x')] \tag{4}$$

式中： $\|f_D\|_L \leq 1$  表示判别器  $D$  构成的黑盒函数需满足 1-Lipschitz 连续，其导数的绝对值上界为 1。

然而，在实际神经网络训练中，严格满足判别器的 1-Lipschitz 条件仍具挑战性。为此文献[23]提出了一种梯度惩罚(gradient penalty, GP)机制，使 WGAN-GP 不再直接裁剪判别器权重，而是在其损失函数中额外添加一项正则化项。该正则化项惩罚判别器在插值样本上梯度范数偏离 1 的情况。这些插值样本  $\hat{x}$  是真实数据与生成数据之间随机线性采样的点。通过这种软约束方式，WGAN-GP 近似实现了判别器的 Lipschitz 条件，从而提升了 GAN 训练的稳定性和生成样本的质量。WGAN-GP 的目标函数表示为

$$\min_G \max_D V(D, G) = E_{x \sim P_r(x)} [D(x)] - E_{x' \sim P_g(x')} [D(x')] + \lambda E_{\hat{x} \sim P_{\hat{x}}} [(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1)^2] \tag{5}$$

式中： $\lambda$  为梯度惩罚系数，通常取 10。

### 1.3 多尺度卷积

卷积神经网络凭借其局部感受野和权值共享机制，在特征提取方面表现出色<sup>[24]</sup>。然而，在处理风电、光伏等新能源出力这类具有复杂时序动态和多重时间尺度的数据时，单一尺寸的卷积核可能难以充分捕获不同时间粒度的特征信息。为有效提取新能源出力序列的多尺度特征，本文引入了多尺度卷积(multi-scale convolution, MSC)结构，其核心思

想是在同一输入特征图上并行应用多个不同尺寸的卷积核,以同时捕获不同时间跨度下的局部特征<sup>[25]</sup>,其基本结构如图2所示。

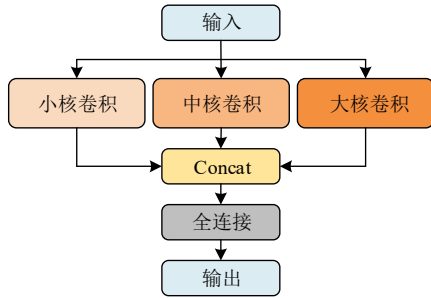


图2 多尺度卷积基本结构

Fig. 2 Basic structure of multi-scale convolution

对于一个包含  $k$  个并行分支的多尺度卷积模块,其中第  $k$  个分支的卷积操作可表示为

$$F_k = \text{Conv}(X, W_k, b_k) \quad (6)$$

式中:  $X$  为输入的时间序列;  $W_k$  为第  $k$  个分支的卷积核权重;  $b_k$  为对应的偏置项; Conv 为 Convolution 的缩写,代表卷积操作;  $F_k$  为第  $k$  个分支的输出特征图,所有并行分支的输出特征图 ( $F_1, F_2, \dots, F_k$ ) 在经过各自的卷积操作后,将在通道维度上进行拼接 (Concat 为 Concatenation 的缩写,表示特征拼接),形成一个包含多尺度信息的综合特征表示  $F_{\text{multi}}$ :

$$F_{\text{multi}} = \text{Concat}(F_1, F_2, \dots, F_k) \quad (7)$$

#### 1.4 多头注意力机制

注意力机制<sup>[26]</sup>是深度学习领域处理时间序列数据的关键技术之一,其核心在于通过动态权重分配,使模型能够自适应地聚焦于输入序列中的关键信息,并有效捕捉长距离依赖关系。对于新能源出力时间序列(如风电出力)所具有的周期性与高频随机波动等复杂动态特性,单头注意力机制虽能有效关注序列中的重要部分,但其在单一表示子空间内进行加权,可能难以全面捕捉数据中的多种模式和不同类型的时间相关性。为克服这一局限,Transformer 模型引入了多头注意力(multi-head attention, MHA)机制<sup>[27]</sup>,其核心在于将注意力机制并行化为多个“注意力头”,从而从不同时间尺度和特征维度捕捉序列中的重要信息。多头注意力机制的基本结构如图3所示。

在多头时间注意力模块中,输入序列首先经过线性映射,分别转换为查询(Query)、键(Key)和值(Value)3种不同的向量表示。随后,这些向量被均匀分割成  $h$  个部分,分别送入  $h$  个独立的“注意力头”进行并行计算。每个注意力头均在各自的表示子空间内,独立进行缩放点积注意力计算,从而捕获多样化的时间依赖关系。第  $i$  个注意力头的计算

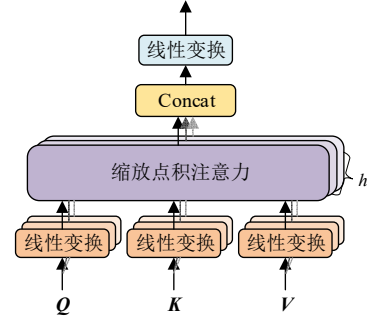


图3 多头注意力机制基本结构

Fig. 3 Basic structure of multi-head attention mechanism

公式如下所示:

$$\text{Head}_i = \text{soft max}\left(\frac{(QW_Q^i)(KW_K^i)^T}{\sqrt{d_k}}\right)(VW_V^i) \quad (8)$$

式中:  $\text{Head}_i$  代表第  $i$  个注意力头(Attention Head);  $Q$ 、 $K$ 、 $V$  分别为查询、键和值的矩阵;  $W_Q^i$ 、 $W_K^i$ 、 $W_V^i$  为第  $i$  个注意力头的线性变换矩阵;  $d_k$  为键向量的维度,作为缩放因子以防止点积结果过大。 $h$  个注意力头并行计算得到输出向量。随后在通道维度上进行拼接,形成包含多维度信息的综合特征表示。拼接后的结果再通过一个最终的线性变换矩阵  $W^o$  进行融合,生成最终的多头注意力输出,公式如式(9)所示:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{Head}_1, \dots, \text{Head}_h)W^o \quad (9)$$

## 2 模型设计

为精准捕捉新能源出力时序的复杂特性,本文所提模型在 WGAN-GP 框架的基础上,对生成器与判别器的网络结构进行了深度优化。具体而言,生成器首先采用多尺度卷积架构,通过并行设置不同尺寸的卷积核,同步提取序列在多个时间尺度下的特征模式;随后,级联多头注意力机制以有效建模长程时序依赖关系,并通过注意力权重的可视化提升模型可解释性。对于判别器,则引入谱归一化技术以稳定训练过程,有效缓解了梯度爆炸与消失问题。上述结构设计协同作用,显著提升了模型生成高质量、具备物理一致且能精确复现多尺度动态特性的新能源出力序列的能力。

### 2.1 生成器和判别器网络结构设计

#### 2.1.1 生成器结构设计

生成器的任务是从一个随机隐向量出发,逐步构建具有复杂内部结构和高度真实性的时间序列。这一过程要求模型精确学习并复现真实数据中的固有因果关系与长期依赖特性。因此,本文在生成器网络结构设计中引入了多尺度卷积和多头注意

力机制。生成器的网络结构如下：

1) 输入层。通过噪声投影层对 100 维噪声向量进行投影，并重塑为(2,12)的特征图。

2) 多尺度卷积层。本文在 WGAN-GP 生成器中引入多尺度卷积架构，通过并行设置 3 个具有不同卷积核尺寸的分支，分别捕捉时间序列在小时级短时波动、日级周期变化及跨日级长期趋势等不同时间尺度上的特征。具体而言，小核分支(卷积核尺寸为 5)：用于捕捉相邻时间的短时波动与局部依赖关系；中核分支(卷积核尺寸为 13)：用于提取日内关键时段的动态模式，为日级周期特征学习提供基础；大核分支(卷积核尺寸为 29)：用于建模跨日级长期趋势，并结合深度网络捕捉长期的新能源出力变化。最后，各分支的输出特征在通道维度上拼接融合，并通过融合卷积、批归一化及残差连接，进一步增强特征表达能力和训练稳定性。

3) 多头注意力层。采用 4 个头的注意力机制，通过计算各时刻的关联权重，动态聚焦关键信息，并将输出的上下文嵌入与多尺度卷积特征融合。本文将多头注意力层与残差连接和层归一化相结合，以增强训练稳定性，并采用 Dropout 等正则化方法抑制过拟合，进一步提升模型泛化能力。

4) 输出层。采用  $1 \times 1$  卷积输出单通道序列。为了使生成的新能源出力场景符合实际物理规律，使用 ReLU 激活函数，确保生成的序列均大于 0。

### 2.1.2 判别器结构设计

与生成器的数据生成任务不同，判别器的任务是对已完成的时间序列进行整体评估与鉴别，判断其来源是真实数据还是由生成器生成的数据，并输出一个判别值。为此，判别器的网络结构采用卷积架构。判别器的网络结构如下：

1) 输入层。把生成数据与真实数据通过输入卷积层处理，以满足特征提取层的输入要求。同时在输入卷积层使用了谱归一化技术，通过对卷积层的权重矩阵进行归一化处理，使得网络在训练过程中更加稳定。

2) 特征提取层。特征提取层采用多个卷积层堆叠，每个卷积层的输出通过 LeakyReLU 激活函数进行非线性变换，以避免传统 ReLU 激活函数的死区效应。同时，采用 Dropout 正则化技术抑制过拟合，从而提高模型的泛化能力。

3) 输出层。由于需要输出判别值，为此仅使用全连接层对高维数据进行展平，并输出一个最终判别值。

综上，本文设计的生成器和判别器的整体结构

如图 4 所示。生成器和判别器的具体网络结构参数详见附录 A 表 A1 和表 A2。

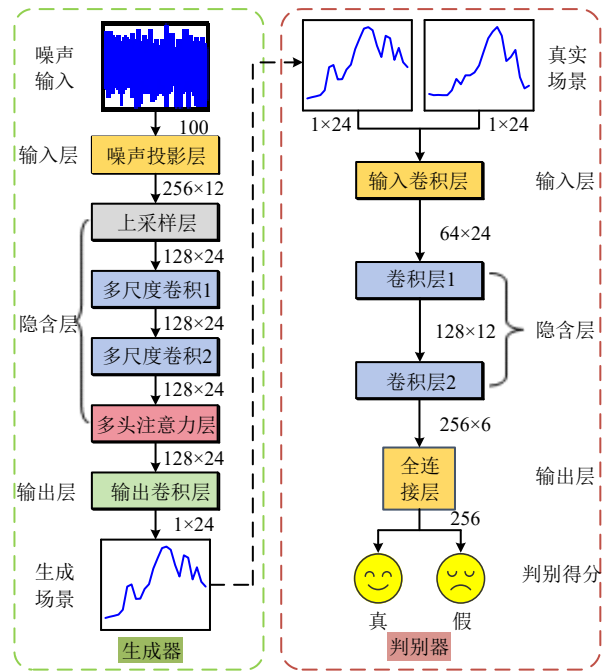


图 4 生成器和判别器的整体网络结构

Fig. 4 Overall network architecture of generator and discriminator

## 2.2 新能源场景生成步骤

基于多时间尺度改进的 WGAN-GP 新能源场景生成的步骤如下：

1) 数据预处理。首先，对历史新能源出力数据进行清洗，以识别并修复缺失值和异常值。对于缺失值，采用线性插值法，即利用相邻时间点的数据进行线性插值，以保持时间序列的连续性。对于异常值，则通过  $3\sigma$  规则检测识别，并使用 24h 邻域窗口内非异常值的均值进行替代。随后，对历史新能源出力数据进行归一化处理。鉴于不同能源类型及区域的出力范围存在差异，为避免训练过程中的数值偏置，本文采用 Min-Max 归一化方法将功率值映射至  $[0,1]$  区间。最后，将数据按 8:2 的比例划分为训练集和测试集。该比例是机器学习领域的通行做法，能够在保证训练数据充分性(80%确保模型学习复杂特征)的同时，实现对模型泛化能力的有效验证(20%用于测试)，从而降低过拟合风险并提升模型的鲁棒性。

2) WGAN-GP 训练。首先，随机生成 100 维标准正态分布  $N(0,1)$  的噪声向量作为生成器的输入。生成器采用多尺度卷积层和多头注意力机制，通过多层网络结构生成与实际样本维度相同的 24h 新能源出力场景。然后，计算损失函数，并结合梯度惩罚项以确保训练稳定性。训练过程中采用

Adam 优化器, 学习率设置为 0.0001, Batch Size 为 32, 训练轮次设为 2000。为了提高判别器的稳定性并防止生成器过早收敛, 采用不平衡的训练策略, 即判别器训练 5 次, 生成器训练 1 次。最后, 当模型收敛达到最优时, 保存训练好的 WGAN-GP 模型权重, 以供后续场景生成任务使用。

3) 场景生成。首先, 设定所需生成的场景数  $m$ , 生成  $m$  个符合标准正态分布的 100 维随机噪声向量。然后, 将其输入训练好的生成器网络, 输出  $m$  个 24h 新能源出力时序数据。最后, 通过对比概率密度分布、核密度估计、累积分布函数和自相关函数等评估指标, 对生成的数据与真实数据的分布相似性和时间相关性进行定量评估, 验证其统计分布相似性和时间相关性。

### 2.3 生成场景评价指标

为全面、客观地评估所提生成模型在新能源出力场景生成任务中的性能, 本文选取以下指标对生成数据与真实数据的分布相似性、时间相关性以及频域相关性进行定量评估, 以验证其统计特性、时序关联性以及频域一致性。

#### 1) 概率密度函数与核密度估计。

经验概率密度函数(probability density function, PDF)通过将序列值域划分为若干等宽区间, 统计每个区间内样本频数, 并归一化得到各区间的出现概率密度, PDF 计算如式(10)所示:

$$\hat{f}_{\text{PDF}}(x \in B_j) = \frac{1}{N\Delta} |\{t | x_t \in B_j\}| \quad (10)$$

式中:  $N$  表示样本的总数;  $\Delta$  表示数据区间的宽度。PDF 直观反映了生成样本与真实样本在各取值区间的频率分布差异。为消除分段估计带来的离散噪声, 本文进一步采用核密度估计(kernel density estimation, KDE)对数据进行平滑处理。KDE 使用高斯核, 其带宽  $h$  参数控制平滑程度。KDE 曲线能够更精细地揭示两组数据在峰度、偏度及尾部行为上的微小差异, 从而辅助识别极端值生成的准确性。KDE 计算如式(11)所示:

$$\hat{f}_{\text{KDE}}(x) = \frac{1}{Nh} \sum_{i=1}^N K\left(\frac{x-x_i}{h}\right) \quad (11)$$

#### 2) 自相关函数。

自相关函数(autocorrelation function, ACF)用于衡量时间序列与其自身滞后版本的相关性, 是分析时间序列内部依赖结构的关键指标。对于风电出力等具有显著时序特性的数据, ACF 能有效反映其周期性、持续性以及不同时间步长间的相关关系。通过对比生成场景与真实场景的 ACF 曲线, 可以验

证模型捕捉风电出力时序动态的准确性。自相关系数计算如式(12)所示:

$$\hat{\rho}_\tau = \frac{\sum_{t=1}^{T-\tau} (x_t - \bar{x})(x_{t+\tau} - \bar{x})}{\sum_{t=1}^T (x_t - \bar{x})^2} \quad (12)$$

式中:  $\tau$  表示时间间隔;  $\bar{x}$  表示生成数据或真实数据的均值。

#### 3) 功率谱密度估计。

本文除了传统时域指标外, 还引入了基于功率谱密度(power spectral density, PSD)的频域一致性检验指标。该方法从频域视角评估模型对动态特性的复现能力, 主要包括谱斜率和频带能量分布两个指标。

谱斜率分析是量化 PSD 的整体衰减趋势, 该值通过在指定中频带内, 对  $\lg(S_{xx}(f))$  和  $\lg(f)$  进行线性回归计算得到式(13):

$$\lg(S_{xx}(f)) = \alpha \lg(f) + \beta \quad (13)$$

式中:  $\lg(\sim)$  表示以 10 为底的对数;  $S_{xx}(f)$  为功率谱密度, 采用汉宁窗单边周期图法进行估算;  $\alpha$  为斜率, 反映序列的长期相关性。若生成场景的  $\alpha$  与历史数据接近, 则表明其成功捕捉了谱形规律。

频带能量分布分析是用于更精细地分解不同时间尺度的能量占比, 评估模型对多尺度动态的捕捉能力。频带能量分布通过对 PSD 在特定频带  $[f_{\text{start}}, f_{\text{end}}]$  积分, 计算该频带的能量  $E_b$ , 进而得到归一化占比  $R_b$ , 其计算公式如式(14)所示:

$$\begin{cases} E_b = \int_{f_{\text{start}}}^{f_{\text{end}}} S_{xx}(f) df \\ R_b = \frac{E_b}{\int_0^{F_s/2} S_{xx}(f) df} \times 100\% \end{cases} \quad (14)$$

#### 4) 累积分布函数。

累积分布函数(cumulative distribution function, CDF)用于评估样本小于等于某阈值的累积概率, 通过对比两组数据的 CDF 曲线可反映其整体分布一致性, 并采用 Kolmogorov-Smirnov(KS)统计量来描述生成数据与真实数据之间的最大偏差, 累积分布函数和 KS 统计量计算如式(15)所示:

$$\begin{cases} \hat{F}(x) = \frac{1}{N} |\{t | x_t \leq x\}| \\ D_{\text{KS}} = \sup_x |\hat{F}_x(x) - \hat{F}_y(x)| \end{cases} \quad (15)$$

上述 4 类指标互为补充, 共同构成了多维度的评估框架。其中, PDF/KDE 侧重于评估概率分布形态的局部细节与整体轮廓的吻合度; ACF 聚焦于模型对时序自相关结构的复现能力; PSD 则从频域视角检验动态特性的一致性; CDF 则衡量累积概率

分布的全局一致性。因此，综合应用这些指标，可为新能源场景生成模型的性能评估与优化提供全面且精确的量化依据。

### 3 算例分析

#### 3.1 算例概括

本文提出的模型适用于风电和光伏两类新能源的场景生成。算例采用 2015 年 1 月 1 日至 2016 年 12 月 31 日奥地利境内风电和光伏发电的实测数据<sup>[28]</sup>，数据集包括每小时的风电和光伏时间采样点和功率出力值。选取 80% 的数据作为训练集用于模型训练，剩余 20% 的数据作为测试集，以验证模型的有效性和泛化能力。

模型训练基于深度学习框架 Pytorch 搭建<sup>[29]</sup>，版本为 Torch2.7.0+cu12.8，并通过调用 GPU 进行 CUDA 并行计算以加速训练。实验所用硬件配置为 Intel Core i5-12400F CPU (2.50 GHz)、NVIDIA GeForce RTX 4060 GPU(显存 8GB, CUDA 核心 3072 个)。

#### 3.2 模型训练

为了直观地了解模型的训练情况，本文对损失函数值随着训练次数而减小的变化过程进行了可视化。其训练过程的损失函数如图 5 所示。




图 5 判别器损失函数

Fig. 5 Value of discriminator loss function

由图 5 可知，在训练的初始阶段，由于生成器并未充分学习到风机出力的特性，判别器损失函数绝对值较大。随着训练不断进行，判别器损失函数绝对值开始减小并趋于 0 附近稳定波动，此时生成器与判别器已经达到纳什平衡，判别器已经无法甄别出生成数据与真实数据的区别。在这一过程中，生成器逐渐对风机出力的特征进行挖掘，生成器生成的数据在不断地逼近真实数据。

#### 3.3 场景生成

模型训练完成后，为直观验证所提出模型的泛化能力、生成场景质量及其对不同运行工况的覆盖能力，本文将模型生成的风电出力场景与测试集中的真实数据进行了对比分析。首先，从测试集中选

取 3 组(24h)典型场景作为参照。然后，向训练好的生成器网络输入 5000 组随机噪声向量，生成 5000 组 24h 风电出力场景。最后，通过计算每个生成场景与这 3 组典型参照场景的平均欧氏距离，筛选距离最小的 50 个场景进行可视化对比。风电的场景对比如图 6 所示，光伏的场景可视化对比详见附录 B 图 B1。

如图 6 所示，根据功率水平和波动特性的不同组合，选取 3 种典型场景构成子图(a)–(c)，(a)高功率高波动场景，代表极端天气条件下的电网冲击，主要用于评估系统稳定性挑战；(b)中功率低波动场景，代表常规运行，侧重于日常调度优化；(c)低功率低波动场景，代表弱风期，主要用于揭示预测的低出力风险。这 3 种场景通过不同的功率-波动组合(高-高、中-低、低-低)，覆盖了从极端到常规的全工况谱系，确保模型对多样化新能源出力的全面表征，以全面验证模型的全面表征能力。图中结果清晰表明，生成的场景(灰色曲线)与测试集真实数据(彩色曲线)呈现出良好的一致性。生成场景的整体出力趋势、波动幅度及峰谷特征均与真实数据高度吻合。这一结果表明，所提出的融合多尺度卷积与多头注意力机制的 WGAN-GP 模型具有优异的泛




图 6 风电典型场景对比

Fig. 6 Comparison of typical wind power scenarios

化性能，能够有效捕获新能源出力的内在动态规律，生成高保真度且多样化的出力场景。

为定量评估模型在复现动态特性方面的性能，本文通过对比历史数据与生成数据的功率谱密度进行了频域一致性检验。频谱估计采用汉宁窗单边周期图法，数据采样周期均为 1h。结果表明，二者在中频带(1 次/周~1 次/6h)内的对数谱-对数频率斜率分别为-1.93 与-1.97，均近似 $1/f^2$  的幂律分布形态，这验证了生成序列在整体谱形上与历史数据具有高度的一致性。在此基础上，本文进一步将频谱能量分解至 4 个关键运行尺度频带，详细的能量分布对比如表 1 所示。光伏对比结果详见附录 A 表 A3。

表 1 的结果显示，在作为能量主体的多日尺度频带(1 次/周~1 次/日)，生成场景与真实场景间的相对能量误差仅为 0.11%，表明模型能够高保真地复现关键的周期性节律。在其余频带中，最大绝对误差亦未超过 1.09%，进一步证实了二者在全频域内的高度一致性。这些结果从频域角度定量地验证了所提方法在捕捉新能源出力多尺度动态特性方面的有效性与精确性。

表 1 风电真实场景与生成场景在不同频带的能量分布对比  
Table 1 Comparison of energy distribution across different frequency bands between real and generated wind power scenarios

| 频带           | 时间尺度   | 真实场景<br>能量占比/% | 生成场景<br>能量占比/% | 对比<br>差异/% |
|--------------|--------|----------------|----------------|------------|
| <1 次/周       | 长周期趋势  | 18.72          | 19.81          | 1.09       |
| 1 次/周~1 次/日  | 多日尺度   | 62.85          | 62.74          | 0.11       |
| 1 次/日~1 次/6h | 日内尺度   | 15.39          | 14.76          | 0.63       |
| >1 次/6h      | 高频随机波动 | 3.05           | 2.79           | 0.26       |

为进一步验证生成场景的有效性，本文对风电的真实数据与生成数据的概率密度函数(PDF)以及核密度估计(KDE)进行了对比，结果如图 7 所示。同时，还绘制了风电真实数据与生成数据时间间隔在 1~10h 的自相关系数，如图 8 所示。光伏的评估对比结果详见附录 B 图 B2 和图 B3。

图 7 展示了风电出力的分布一致性评估结果。




图 7 真实数据与生成数据的分布对比(KDE 为核密度估计)  
Fig. 7 Distribution comparison between real data and generated data(KDE: kernel density estimation)

由图 7 可知，在低功率区间(0~500 MW)，生成数据与真实数据的 KDE 曲线高度吻合，这准确地反映了风力发电的间歇性特征；在中功率区间(500~1500 MW)，两者的概率密度均呈现出典型的长尾衰减形态；在高功率区间(>1700 MW)，则观察到轻微偏差。评估结果表明，所提出的生成模型能够有效地复现风电功率的分布特性。

图 8 展示了风电出力的时间相关性评估结果。由图 8 可知，生成的风电出力场景均有一定的自相关性，并随滞后时间的增长，自相关系数逐渐降低。结果表明，该模型成功地捕捉并再现了真实风电数据在时间序列上的动态依赖关系。




图 8 风电自相关系数曲线图

Fig. 8 Autocorrelation coefficient curve of wind power

### 3.4 方法对比

为全面验证本文所提出的融合多尺度卷积与多头注意力机制的 WGAN-GP 模型(以下简称“本文方法”)在新能源出力场景生成任务中的优越性与有效性，本节将其与两种主流基线方法进行对比评估:包括传统的 WGAN-GP 模型(以下简称“方法 1”其不含多尺度卷积与时间注意力机制)以及基于 Copula 函数的方法(以下简称“方法 2”)。鉴于风电出力具有更强的不确定性与波动性，本文将其作为代表性案例以凸显所提方法的性能优势。

为系统评估所提方法的性能，本文从整体分布、关键统计量、时间相关性及几何分布 4 个互补角度出发，对比了该方法与多种基线方法所生成数据同真实数据的一致性。

首先，为衡量整体分布的拟合优度，采用累积分布函数(CDF)进行可视化对比，并计算 KS 统计量进行定量检验。其次，为精确复现分布的非对称性与拖尾特征，本文量化了偏度与峰度的差异，这对于捕捉新能源出力的极端事件尤为关键。此外，考虑到场景数据固有的时间依赖性，本文引入自相关函数均方根误差(root mean square error of the autocorrelation function, RMSE\_ACF)作为关键指标，用以精确评估各方法对原始序列动态结构的复现保真度。最后，为从几何角度量化高维数据分布

的差异,采用 Wasserstein 距离进行对比。其中,各方法的 CDF 对比见图 9,而 KS 统计量、偏度与峰度差异、RMSE\_ACF 及 Wasserstein 距离等关键指标的具体数值详见表 2。




图 9 不同方法生成场景的数据概率分布特性对比

Fig. 9 Comparison of data probability distribution characteristics for scenarios generated by different methods

图 9 展示了各方法生成的风电出力场景累积分布函数(CDF)对比结果。结果显示,本文方法生成的 CDF 曲线与真实风电出力数据的 CDF 曲线高度重合,拟合精度最高,表明其对概率分布的整体拟合效果最佳。相比之下,传统 WGAN-GP 和 Copula 方法生成的 CDF 曲线与真实曲线存在明显偏差,未能完全捕捉风电出力的完整概率分布特征。

表 2 不同方法生成场景的统计特性和自相关性能对比  
Table 2 Comparison of statistical characteristics and autocorrelation performance for scenarios generated by different methods

| 方法   | 峰度<br>差异    | 偏度<br>差异     | KS<br>统计量    | RMSE<br>_ACF | Wasserstein<br>距离 |
|------|-------------|--------------|--------------|--------------|-------------------|
| 本文方法 | <b>0.20</b> | <b>0.060</b> | <b>0.022</b> | <b>0.028</b> | <b>0.014</b>      |
| 方法 1 | 0.44        | 0.13         | 0.075        | 0.069        | 0.13              |
| 方法 2 | 0.56        | 0.31         | 0.088        | 0.11         | 0.37              |

表 2 列出了 3 种方法在峰度差异、偏度差异、KS 统计量、自相关系数的 RMSE 以及 Wasserstein 距离的具体对比结果。结果显示,本文提出的方法在所有评价指标上均表现出显著优势。在统计分布特性方面,本文方法的峰度差异为 0.20,偏度差异为 0.06,远低于对比方法,这表明其能更精确地捕捉风电出力数据的非对称性和尾部特性。KS 统计量为 0.022,显著低于传统 WGAN-GP 的 0.075 和 Copula 方法的 0.088,进一步从定量层面验证了本文方法在整体概率分布拟合上的卓越性能,与图 9 的分析结果相互印证。在时间相关性方面,本文方法的 RMSE\_ACF 仅为 0.028,显著低于传统 WGAN-GP 的 0.069 和 Copula 方法的 0.11,表明其能精准复现真实风电出力的时序依赖结构。同时,本文方法在生成场景的分布相似性上表现优异,其与真实场景的 Wasserstein 距离仅为 0.014,显著低于传统 WGAN-GP 的 0.13 和 Copula 方法的 0.37,

这表明本方法在精确捕捉数据分布的几何结构方面具有明显优势。

综上所述,本文提出的融合多尺度卷积和多头注意力机制的 WGAN-GP 方法,在生成新能源场景方面具有显著优势。其中,KS 统计量为 0.022,远低于显著性水平  $\alpha = 0.05$  (95%置信水平)下的临界值  $D_\alpha \approx 0.064$ 。若选择  $\alpha = 0.02$  (98%置信水平),  $D_\alpha \approx 0.071$ ,仍满足  $D < D_\alpha$ 。因此,本文方法的置信率约为 95%~98%。然而,该置信率反映的是分布一致性,而非对所有电网运行行为的完全覆盖(无法达 100%)。对于未覆盖的极端场景(如罕见气象事件导致的低出力行为),未来研究可引入自适应采样技术,进一步提升覆盖率。

### 3.5 模型可解释性分析

#### 3.5.1 基于 SHAP 值的隐空间特征可控性分析

在生成对抗网络中,生成器通过将高维隐空间中的向量非线性映射到数据空间以生成样本。该隐空间的各维度(即噪声输入的各个维度)从标准概率分布中抽样得到,本身不包含与风电出力相关的明确物理信息。因此,针对单一隐维度进行 SHAP 归因分析所得到的贡献值难以提供关于场景生成背后物理逻辑的有效洞察。为此,本文将分析焦点从孤立、无物理意义的隐维度,转移到探索隐空间整体结构与生成数据宏观语义特征之间的内在关联。通过操纵隐向量的不同维度实现对生成风电出力关键宏观特性(如平均功率、波动性和爬坡率)的有效控制。

基于 SHAP 值生成模型可解释性与可控性的步骤流程如下:

1) 准备阶段。提取已经训练好的生成器 G,针对风机出力场景定义一组能够表征其全局特性的宏观特征函数。为此,本文定义了平均功率、波动性和爬坡率 3 个宏观特征。

2) 关联分析阶段。利用 SHAP 方法对模型进行归因分析<sup>[30]</sup>,通过构建 SHAP 包装器量化计算各隐向量维度对宏观特征的贡献度,构建出隐空间维度与场景宏观特征之间的映射关系。各宏观特征与最重要隐空间维度的 SHAP 值如表 3 所示。

3) 可控生成阶段。依据挖掘的关系对基准隐向量进行定向干预,从而生成具有特定预设属性的目标场景。

4) 验证阶段。为对新型电力系统进行规划和运行风险评估,需生成高平均功率、低波动性的目标场景。由表 3 可知,维度 z\_2 对平均功率影响最大,维度 z\_36 对波动性影响最大。据此,本文通

表 3 各宏观特征的重要维度 SHAP 值  
Table 3 SHAP values of important dimensions for macroscopic features

| 宏观特征 | 最重要维度 | SHAP 值 |
|------|-------|--------|
| 平均功率 | z_2   | 0.073  |
| 波动性  | z_36  | 0.013  |
| 爬坡率  | z_33  | 0.011  |

过调整与目标宏观特征强相关的隐维度构建目标隐向量。具体而言，为提升平均功率，将维度 z\_2 增加 2 个标准差；为抑制波动，将维度 z\_36 降低 2 个标准差。将修改后的隐向量输入生成器 G，获得目标场景，基准场景与目标场景的对比如图 10 所示。

验证结果由图 10 可清晰看出，目标场景的功率值明显高于基准场景，且波动性明显低于基准场景。其目标场景的平均功率上升 27.4%，波动性下降 45.4%。完全符合预期的高平均功率、低波动性要求。




图 10 目标场景与基准场景对比图

Fig. 10 Comparison between target scenarios and baseline scenarios

综上，本文提出的方法通过 SHAP 值分析，建立了隐空间与生成场景宏观特性之间的可解释映射关系，可以按需生成具有特定属性的目标场景，从而实现了新能源出力场景的有效可控生成。

### 3.5.2 注意力权重可视化

为进一步提升生成数据的可解释性，并揭示模型的内部工作机制与决策依据。本文从生成场景中筛选出一个与测试集中“功率爬坡场景”典型日特征高度相似的生成实例。随后，提取生成器在生成该场景过程中各注意力头计算得到的总平均注意力权重值。

平均多头注意力权重以热力图形式呈现，如图 11 所示。其中颜色越深表示模型对相应时间位置的关注强度越高。该热力图清晰地揭示了模型在生成风电出力序列时的关注度分配模式。最显著的特征是沿主对角线的高亮条带，表明模型成功学习到了风电出力序列固有的强局部依赖性。除了紧密的局部关联，该热力图还进一步呈现了模型对关键动态事件的整体性建模能力。早间爬坡(6~10h)与傍晚波动(16~20h)区域权重显著，表明模型在生成过

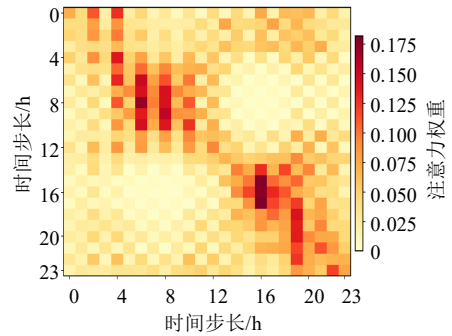


图 11 平均多头注意力权重热力图

Fig. 11 Average multi-head attention weight heatmap

程中聚焦于日内活跃期的跨时段依赖关系。同时，图中远离对角线的亮斑(16~18h 对 1~3h 的关注)直观体现了模型捕捉长程依赖的能力，使其能够参考历史相关模式来辅助当前决策。

注意力权重可视化分析为模型性能提供了有力的解释支撑。结果表明，该模型通过有效学习并结合局部依赖、整体性依赖和跨时段长程依赖 3 种关键模式，精确复现了风电出力的复杂动态特性。这种基于数据内在规律的决策机制显著增强了模型在实际工程应用中的可靠性和可信度。

## 3.6 方法适用性分析与讨论

### 3.6.1 数据规范与要求

为确保模型能够充分学习新能源出力的时空动态特性并达到预期的精度，本文对训练数据提出以下具体要求。

1) 在数据类型与质量方面，数据输入为新能源场站的历史出力时间序列数据。数据的完整性是保证训练质量的关键，训练集整体的数据缺失率应控制在 5% 以内。对于数据集少量缺失，可采用线性插值等方法修复以保证序列连续性；而对于长期连续的缺失数据段，为避免引入伪信息误导模型，建议在预处理阶段予以剔除。

2) 在数据尺度与跨度方面，时间分辨率与覆盖长度共同决定了模型捕捉动态模式的能力。为精准刻画新能源出力的日内波动模式，输入数据的时间分辨率不能低于一天，推荐采用 1h 或更高的时间分辨率以捕捉更精细的随机扰动。此外，为检验本文所提的模型对数据样本的依赖性，验证不同样本数量下模型对数据的分布的挖掘能力，实验对比了 4、10、17 及 24 个月 4 种样本长度的评估结果，评估结果详见附录 B 表 B1。结果表明，为使模型能充分学习并再现样本的统计分布、时间相关性及几何分布，训练数据的时间跨度应至少覆盖一个完整的年度周期，而采用两年或以上的数据，则有助于提升模型的鲁棒性与生成场景的长期代表性。

### 3.6.2 模型适应性分析与局限性

本文所提基于融合多尺度卷积与多头注意力机制的 WGAN-GP 新能源场景生成方法，因其固有的“数据驱动”范式也规定了其适用边界。首先，该模型主要适用于单一或多个新能源场站的出力场景生成与特性分析。若需将其应用于计及全网潮流约束的系统级规划或运行分析，则必须与传统的物理模型进行耦合。其次，在可解释性方面，本文采用的 SHAP 值归因方法与注意力可视化分析，旨在揭示“黑盒”模型内部的决策依据，而非严格的物理因果链。其分析结果可为特征重要度排序和模型行为理解提供宝贵见解，后续仍需要结合电力系统的物理机理进行专业判读。

## 4 结论

本文针对新能源出力场景生成中的复杂时序动态建模和模型“黑箱”问题，提出了一种融合多尺度卷积与多头注意力机制的 WGAN-GP 方法。该方法通过创新的生成对抗网络结构和可解释性分析框架，旨在生成高质量且多样化的未来可能场景，同时增强模型的透明度与可信度。本研究通过风电出力场景的算例验证了所提方法的有效性，具体结论如下：

1) 本文提出的 WGAN-GP 模型通过数据驱动方式，有效提取风电出力序列在小时、日、跨日模式多时间尺度上的特征，并精准捕捉其内在的长程依赖关系。实验结果表明，所生成场景在概率分布拟合、时间相关性保持以及动态特性捕捉方面均表现出色，展现出更高的生成精度和可靠性。

2) 本研究构建了完备的可解释性分析框架。通过 SHAP 值归因分析，成功量化了隐空间各维度对生成场景宏观特性的贡献度，并建立了可解释的映射关系。同时，结合注意力权重可视化，进一步揭示了模型学习并遵循数据内在物理规律的内部机制，从而显著提升了模型决策的透明度与实用价值。

此外，本文系统性地探讨了模型的数据要求和适用边界，为该类数据驱动模型在电力系统中的工程化、规模化应用提供了理论参考和技术路径。未来的研究可集中于将该模型与电网物理约束进行深度融合，并探索其在风电、光伏以及负荷等多能互补系统联合运行场景生成中的应用。

附录见本刊网络版 (<http://www.dwjs.com.cn/CN/1000-3673/current.shtml>)。

## 参考文献

- [1] 卓振宇, 张宁, 谢小荣, 等. 高比例可再生能源电力系统关键技术及发展挑战[J]. 电力系统自动化, 2021, 45(9): 171-191. ZHUO Zhenyu, ZHANG Ning, XIE Xiaorong, et al. Key technologies and developing challenges of power system with high proportion of renewable energy[J]. Automation of Electric Power Systems, 2021, 45(9): 171-191(in Chinese).
- [2] 康重庆, 杜尔顺, 郭鸿业, 等. 新型电力系统的六要素分析[J]. 电网技术, 2023, 47(5): 1741-1750. KANG Chongqing, DU Ershun, GUO Hongye, et al. Primary exploration of six essential factors in new power system[J]. Power System Technology, 2023, 47(5): 1741-1750(in Chinese).
- [3] 陈国平, 董昱, 梁志峰. 能源转型中的中国特色新能源高质量发展分析与思考[J]. 中国电机工程学报, 2020, 40(17): 5493-5505. CHEN Guoping, DONG Yu, LIANG Zhifeng. Analysis and reflection on high-quality development of new energy with Chinese characteristics in energy transition[J]. Proceedings of the CSEE, 2020, 40(17): 5493-5505(in Chinese).
- [4] 畅广辉, 单瑞卿, 李翔硕, 等. 高比例新能源电力系统风电低出力事件多维度评估与分布特性分析[J]. 电网技术, 2025, 49(4): 1369-1378. CHANG Guanghui, SHAN Ruiqing, LI Xiangshuo, et al. Multidimensional assessment and distributional characteristics of Low-wind-power events in high proportion renewable energy power systems[J]. Power System Technology, 2025, 49(4): 1369-1378(in Chinese).
- [5] 李增辉, 于钊, 孙大雁, 等. 新能源预测纳入备用对平衡和消纳的影响研究[J]. 电网技术, 2024, 48(4): 1393-1402. LI Zenghui, YU Zhao, SUN Dayan, et al. Research on influences to power balance & new energy consumption of taken-into-account proportion of New Energy's Predicted Output in Day-ahead power reserve[J]. Power System Technology, 2024, 48(4): 1393-1402(in Chinese).
- [6] MOSTAFANEZHAD M, MOHAMMADI M, AFRASIABI S, et al. Data-driven small-signal and N-1 security assessment considering missing data[J]. IEEE Transactions on Power Systems, 2024, 39(2): 2587-2597.
- [7] 闫炯程, 李常刚, 刘玉田. 数据驱动的新型电力系统安全风险预警综述[J]. 电网技术, 2024, 48(12): 4989-5002. YAN Jiongcheng, LI Changgang, LIU Yutian. Review of data-driven security risk early warning research of the new-type power system[J]. Power System Technology, 2024, 48(12): 4989-5002(in Chinese).
- [8] 谭九鼎, 李帅兵, 李明澈, 等. 计及不确定性的分布式微网参与电网优化调度方法综述[J]. 综合智慧能源, 2024, 46(1): 38-48. TAN Jiuding, LI Shuaibing, LI Mingche, et al. Optimized scheduling of the power grid with participation of distributed microgrids considering their uncertainties[J]. Integrated Intelligent Energy, 2024, 46(1): 38-48(in Chinese).
- [9] 刘洁, 林舜江, 梁炜焜, 等. 基于高阶马尔可夫链和高斯混合模型的光伏出力短期概率预测[J]. 电网技术, 2023, 47(1): 266-274. LIU Jie, LIN Shunjiang, LIANG Weikun, et al. Short-term probabilistic forecast for power output of photovoltaic station based on high order Markov chain and Gaussian mixture model[J]. Power System Technology, 2023, 47(1): 266-274(in Chinese).
- [10] 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(in Chinese).

- [11] 牛奎焯, 刘金波, 汤奕, 等. 计及极端气象事件的年度系统运行场景生成方法[J]. 电网技术, 2024, 48(10): 3992-4001.  
NIU Kuiye, LIU Jinbo, TANG Yi. A method for generating annual system operating scenarios considering extreme meteorological events [J]. Power System Technology, 2024, 48(10): 3992-4001(in Chinese).
- [12] 辛阔, 马骞, 许琴, 等. 基于月份划分与指定日类型的风电出力序列场景生成方法[J]. 电力系统自动化, 2023, 47(15): 151-161.  
XIN Kuo, MA Qian, XU Qin, et al. Wind power output sequence scenario generation method based on monthly division and specified day type[J]. Automation of Electric Power Systems, 2023, 47(15): 151-161(in Chinese).
- [13] 王群, 董文略, 杨莉. 基于 Wasserstein 距离和改进 K-medoids 聚类的风电/光伏经典场景集生成算法[J]. 中国电机工程学报, 2015, 35(11): 2654-2661.  
WANG Qun, DONG Wenlue, YANG Li. A wind power/photovoltaic typical scenario set generation algorithm based on Wasserstein distance metric and revised K-medoids cluster[J]. Proceedings of the CSEE, 2015, 35(11): 2654-2661(in Chinese).
- [14] 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.
- [15] 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(5): 1742-1749.  
GU Jie, LIU Shuqi, HU Yu, et al. Optimal allocation of intermittent distributed generation based on deep convolutions generative adversarial network in scenario generation[J]. Power System Technology, 2021, 45(5): 1742-1749(in Chinese).
- [16] 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): 5527-5535.  
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(in Chinese).
- [17] LI Hui, YU Haoyang, LIU Zhongjian, et al. Long-term scenario generation of renewable energy generation using attention-based conditional generative adversarial networks[J]. Energy Conversion and Economics, 2024, 5(1): 15-27.
- [18] 王长刚, 刘伟, 曹宇, 等. 基于改进条件生成扩散模型的新能源日前场景生成方法[J]. 电网技术, 2025, 49(4): 1358-1368.  
WANG Changgang, LIU Wei, CAO Yu, et al. The day-ahead scenario generation method for new energy based on an improved conditional generative diffusion model[J]. Power System Technology, 2025, 49(4): 1358-1368(in Chinese).
- [19] DONG Wei, CHEN Xianqing, YANG Qiang. Data-driven scenario generation of renewable energy production based on controllable generative adversarial networks with interpretability[J]. Applied Energy, 2022, 308: 118387.
- [20] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems-Volume 2. Montreal, Canada: MIT Press, 2014: 2672-2680.
- [21] ARJOVSKY M, BOTTOU L. Towards principled methods for training generative adversarial networks[EB/OL]. (2017-01-17) [2017-01-17]. <https://arxiv.org/abs/1701.04862>.
- [22] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein GAN[EB/OL]. (2017-01-26)[2017-01-26]. <https://arxiv.org/abs/1701.07875>.
- [23] 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: Curran Associates, Inc., 2017: 5769-5779.
- [24] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.  
ZHOU Feiyan, JIN Linpeng, Dong Jun. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251(in Chinese).
- [25] 玄英律, 万源, 陈嘉慧. 基于多尺度卷积和注意力机制的 LSTM 时间序列分类[J]. 计算机应用, 2022, 42(8): 2343-2352.  
XUAN Yinglü, WAN Yuan, CHEN Jiahui. Time series classification by LSTM based on multi-scale convolution and attention mechanism [J]. Journal of Computer Applications, 2022, 42(8): 2343-2352(in Chinese).
- [26] 李刚, 方鸿, 刘云鹏, 等. 新型电力系统中的大模型驱动技术: 现状、机遇与挑战[J]. 高电压技术, 2024, 50(7): 2864-2878.  
LI Gang, FANG Hong, LIU Yunpeng. Large-model drive technology in new power system: status, challenges and prospects[J]. High Voltage Engineering, 2024, 50(7): 2864-2878(in Chinese).
- [27] 李卫军, 熊章友, 杨国梁, 等. 关键节点感知与时空自适应的 Transformer 交通流预测方法[J/OL]. 计算机工程与应用, 2025: 1-14[2025-07-10]. <https://link.cnki.net/urlid/11.2127.tp.20250704.1420.006>.  
LI Weijun, XIONG Zhangyou, YANG Guoliang, et al. Transformer traffic flow prediction method based on key node perception and spatial-temporal adaptation[J]. Computer Engineering and Applications, 2025: 1-14[2025-07-10]. <https://link.cnki.net/urlid/11.2127.tp.20250704.1420.006>(in Chinese).
- [28] Open Power System Data. Data package time series[EB/OL]. (2020-10-06). [https://doi.org/10.25832/time\\_series/2020-10-06](https://doi.org/10.25832/time_series/2020-10-06).
- [29] PASZKE A, GROSS S, MASSA F, et al. PyTorch: an imperative style, high-performance deep learning library[C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2019: 721.
- [30] 武宇翔, 韩肖清, 牛哲文, 等. 基于变权重随机森林的暂态稳定评估方法及其可解释性分析[J]. 电力系统自动化, 2023, 47(14): 93-104.  
WU Yuxiang, HAN Xiaoqing, NIU Zhewen, et al. Transient stability assessment method based on variable weight random forest and its interpretability analysis[J]. Automation of Electric Power Systems, 2023, 47(14): 93-104(in Chinese).



刘自兵

在线出版日期: 2025-09-18。

收稿日期: 2025-07-16。

作者简介:

刘自兵(2000), 男, 硕士研究生, 研究方向为人工智能在电力系统中的应用, E-mail: liuzb2433@163.com;

崔双喜(1970), 男, 通信作者, 博士, 副教授, 硕士生导师, 研究方向为电力系统分析、稳定和控制在等, E-mail: ysucsx@126.com;

刘庆庆(1998), 男, 硕士研究生, 研究方向为人工智能在电力系统中的应用, E-mail: liuqq182@163.com。

(责任编辑 马晓华 明月)

附录 A

表 A1 生成器结构及参数

Table A1 Generator structure and parameters

| 层数         | 名称                   | 输入参数  | 参数说明                              |
|------------|----------------------|---|-----------------------------------|
| 噪声投影层      | Linear+BatchNorm1d   | 输入维度: 100<br>输出维度: 256×12<br>LeakyReLU(0.2)           | 噪声向量维度<br>扩展到时间序列<br>激活函数         |
| 上采样层       | ConvTranspose2d      | 卷积核大小: 4<br>步长: 2<br>填充: 1                            | 时间维度扩展<br>序列长度翻倍<br>保持边界信息        |
| 多尺度卷积层 1&2 | MultiScaleConv       | 小时级: 核大小=5<br>日级: 核大小=13<br>跨日级: 核大小=29<br>融合层: 核大小=1 | 短时特征<br>日内特征<br>跨日特征<br>特征融合      |
| 多头注意力层     | Multi-Head Attention | 注意力头数: 4<br>隐藏维度: 128<br>序列长度: 24<br>LayerNorm+残差连接   | 多头注意力机制<br>特征表示维度<br>时间步数<br>稳定训练 |
| 输出层        | Conv1d               | 卷积核大小: 1<br>ReLU<br>输出形状: [batch,24,1]                | 点卷积<br>激活函数<br>24h 功率序列           |

表 A2 判别器结构及参数

Table A2 Discriminator structure and parameters

| 层数      | 名称                  | 参数  | 参数说明                                   |
|---------|---------------------|---|--|
| 输入卷积层   | SpectralNorm+Conv1d | 卷积核大小: 5<br>输出通道: 64<br>步长: 1 填充: 2                                 | 局部特征提取<br>特征图数量<br>保持序列长度              |
| 特征提取层 1 | SpectralNorm+Conv1d | 卷积核大小: 5<br>输出通道: 128<br>步长: 2 填充: 2<br>LeakyReLU(0.2)+Dropout(0.1) | 特征提取<br>特征维度扩展<br>下采样<br>激活函数与正则化      |
| 特征提取层 2 | SpectralNorm+Conv1d | 卷积核大小: 5<br>输出通道: 256<br>步长: 2 填充: 2<br>LeakyReLU(0.2)+Dropout(0.1) | 深层特征提取<br>高维特征表示<br>进一步下采样<br>激活函数与正则化 |
| 全连接层    | Linear              | 隐藏层: 256→256<br>输出层 256→1<br>输出: 实测值                                | 特征变换<br>判别分数<br>WGAN 判别得分              |

表 A3 光伏真实场景与生成场景在不同频带的能量分布对比

Table A3 Comparison of energy distribution across different frequency bands between real and generated photovoltaic power scenarios

| 频带           | 时间尺度   | 真实场景能量占比/% | 生成场景能量占比/% | 对比差异/% |
|--------------|--------|------------|------------|--------|
| <1 次/周       | 长周期趋势  | 5.47       | 5.04       | 0.43   |
| 1 次/周-1 次/日  | 多日尺度   | 38.07      | 39.14      | 1.07   |
| 1 次/日-1 次/6h | 日内尺度   | 56.31      | 55.69      | 0.62   |
| >1 次/6h      | 高频随机波动 | 0.15       | 0.13       | 0.02   |

附录 B




图 B1 光伏典型场景对比

Fig. B1 Comparison of typical photovoltaic power scenarios




图 B2 光伏真实数据与生成数据的分布对比(KDE 为核密度估计)

Fig. B2 Comparison of distributions between photovoltaic real data and generated data (KDE: kernel density estimation)




图 B3 光伏自相关系数曲线图

Fig. B3 Autocorrelation coefficient curve of photovoltaic power

表 B1 不同样本数量下生成场景的统计特性与自相关性对比

Table B1 Comparison of statistical characteristics and autocorrelation under different sample sizes for generated scenarios

| 样本数量    | 峰度差异 | 偏度差异  | KS 统计量 | 自相关系数 RMSE | Wasserstein 距离 |
|---------|------|-------|--------|------------|----------------|
| 4 个月样本  | 0.42 | 0.25  | 0.12   | 0.0832     | 0.17           |
| 10 个月样本 | 0.32 | 0.15  | 0.094  | 0.057      | 0.083          |
| 17 个月样本 | 0.28 | 0.094 | 0.072  | 0.034      | 0.059          |
| 24 个月样本 | 0.20 | 0.060 | 0.022  | 0.028      | 0.014          |