

基于改进条件生成对抗网络的可控场景生成方法

张 帅¹, 刘文霞¹, 万海洋¹, 吕笑影¹, Nawaraj Kumar Mahato¹, 鲁 宇^{1,2}

(1. 华北电力大学 新能源电力系统国家重点实验室, 北京 102206;

2. 国网吉林省电力有限公司经济技术研究院, 吉林 长春 130022)

摘要:可再生能源发电具有较强的随机性和波动性,为实现高效可靠的场景建模,提出一种基于改进条件生成对抗网络的可控场景生成方法。提出基于条件生成对抗网络的场景生成框架,结合Transformer的全局注意力机制以及常规卷积和深度可分离卷积的局部泛化机制,设计适用于提取可再生能源发电不同维度特征的网络结构;利用条件生成对抗网络模型建立低维气象特征隐空间和高维可再生能源发电数据之间的映射关系,提出一种可控场景生成方法,并建立随机场景生成、场景约减、极端场景生成和连续日场景生成4种生成策略。基于实际光伏、风电数据和气象数据的仿真结果表明,所提模型与方法能够有效学习可再生能源发电的随机性、时序性、波动性及空间相关性,实现对不同策略下场景的可控生成。

关键词:场景生成;条件生成对抗网络;特征提取;配电网;可控生成

中图分类号:TM73

文献标志码:A

DOI:10.16081/j.epae.202312038

0 引言

随着可再生能源渗透率的逐渐提高,配电系统的形态结构和运行模式正在发生巨大的变化^[1]。分布式电源(distributed generation, DG)具有强随机性和波动性,多种不确定因素给配电系统的规划和可靠性评估带来了严峻的挑战。因此,如何对DG出力的不确定性进行建模以及可控制地生成所需场景成为当前亟需解决的问题^[2]。

在可再生能源出力不确定性建模领域,学者进行了深入研究并且取得了丰富的成果^[3]。在建模方法方面,存在基于统计学的概率建模方法以及基于深度学习的概率建模方法^[4];在建模对象方面,存在基于气象条件的间接模型以及基于DG发电的直接模型^[5]。

在基于气象条件的间接模型研究中,典型概率模型包括基于Weibull分布的风速模型和基于Beta分布的光照模型。文献[6]在Beta分布的基础上,引入云层覆盖水平,建立多类云层光照状态概率场景,但是这类概率建模方法仅能反映一个时间断面的风电或光伏出力概率分布特征,不能描述中长期规划所需的DG出力时间序列特征。为此,文献[7]基于气象学太阳辐射理论和统计学方法建立光伏中长期时间序列模型,通过模型模拟光伏一年内的时序变化规律。相较于基于气象条件的间接建模,基于DG发电的直接建模法对历史数据进行概率建模。文献

[8]对多风电场出力的随机性与相关性进行分析,建立基于Copula理论的多风电场出力联合概率分布。文献[9]根据列维定理揭示风电场群出力波动概率密度分布特性呈现多种分布的规律,说明单一概率分布对风电场群的拟合能力较弱,并且提出基于高斯混合模型的风电场群概率建模方法。然而,由于天气的动态、时变性以及非线性特性,基于统计学的概率建模方法缺乏通用性,难以准确描述DG出力的不确定性,阻碍了如随机优化等算法的进一步应用。

在基于深度学习方法的概率建模研究中,在Chen Y Z等^[10]提出基于生成对抗网络的数据驱动方法,实现对DG出力历史数据的时序性与不确定性进行建模后,越来越多的研究利用深度学习方法捕捉历史发电数据中的非线性动态过程^[11]。文献[12]为提高模型捕获风电场和光伏电站之间的空间与时间相关性特征的能力,引入网络权重的梯度惩罚策略,提出改进的生成对抗网络模型。然而,文献[10,12]采用多层感知机堆叠方式,模型结构较为简单,缺少对网络结构的深入建模,限制了神经网络的特征提取能力。为此,文献[13]采用卷积模块与残差模块建立深层网络架构,利用卷积模块的局部视野与权值共享能力生成高分辨率的DG出力曲线,但由于受限于卷积核视野大小,难以提取时序特征。文献[14]引入时序卷积模块提取不同时刻之间的时序相关性,采用图神经网络捕获源荷数据间的非欧氏结构相关性,提高了模型对DG出力时序性与相关性的建模能力,但该模型仅能够实现历史数据的概率重构。文献[15]将DG出力特性指标如最大值、均值作为场景条件,基于概率建模思想实现对场景生成约束的建模,提高了场景生成的可解释性,为

收稿日期:2023-02-12;修回日期:2023-10-09

在线出版日期:2024-01-11

基金项目:国网吉林省电力有限公司科技项目(2021JBGS-03)

Project supported by the Science and Technology Program of State Grid Jilin Electric Power Co.,Ltd.(2021JBGS-03)

可控场景生成奠定了基础。综合上述分析可知,亟需提高模型对多种 DG 出力特征的提取能力,并建立相应的场景生成框架,利用模型可控生成实际应用所需场景。

针对上述问题,本文提出一种基于深度条件生成对抗网络(conditional generative adversarial network, CGAN)的数据驱动可控场景生成方法。本文的创新工作包括:提出基于气象数据驱动的场景生成框架,建立低维气象特征隐空间以及高维 DG 出力数据之间的映射关系;提出基于 Transformer 的改进 CGAN 模型,耦合卷积运算局部泛化能力与 Transformer 全局注意力机制,结合预激活残差结构、正则与堆叠模块等机制建立适用于提取不同时空维度 DG 出力特征的 CGAN 结构;提出基于 CGAN 模型可控场景生成方法与具有实际应用价值的 4 种场景生成策略。

1 场景生成架构

1.1 CGAN 基本原理

基于博弈论构建的 CGAN 属于典型的生成式模型,通过训练从按指定分布生成的具有对抗概念的生成器网络自主学习满足条件概率的数据分布模式。CGAN 结构如图 1 所示。由图可知,CGAN 结构的核心思想是对抗训练生成器和判别器这 2 个神经网络,生成器迭代训练生成不确定性场景,直到判别器无法分辨生成数据的真伪。

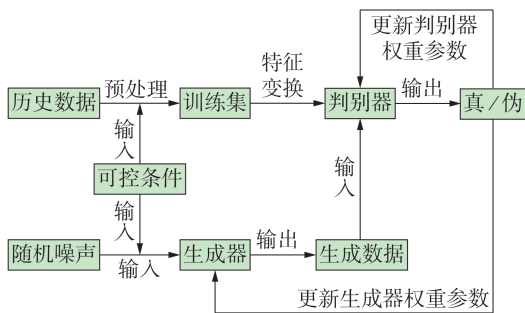


图1 CGAN 结构图

Fig.1 Structure diagram of CGAN

定义真实数据服从概率分布 P_R ,生成器生成的样本服从概率分布 P_G ,随机噪声服从分布 P_Z 。生成器经过训练构建 P_Z 到 P_R 的映射。生成器和判别器分别为 G 和 D 。通过构建如式(1)所示的极小极大博弈估值函数 $\min_c \max_D V(G, D)$ 使模型达到纳什均衡。

$$\min_c \max_D V(G, D) = E_{P_R}[D(\mathbf{x}|\mathbf{y})] - E_{P_G}[D(G(\mathbf{z}|\mathbf{y}))] \quad (1)$$

式中: \mathbf{x} 为输入数据; \mathbf{y} 为条件; \mathbf{z} 为噪声; $D(\cdot)$ 、 $G(\cdot)$

分别为判别器和生成器函数; $E_{P_R}[\cdot]$ 、 $E_{P_G}[\cdot]$ 分别为真实样本分布和随机噪声分布的期望。

针对模型损失函数,采用 Wasserstein 距离度量样本间概率分布的差异性,即:

$$W(P_R, P_G) = \sup_{\|D(\mathbf{x}|\mathbf{y})\|_L \leq \zeta} \left\{ E_{P_R}[D(\mathbf{x}|\mathbf{y})] - E_{P_G}[D(\mathbf{x}|\mathbf{y})] \right\} \quad (2)$$

式中: $W(P_R, P_G)$ 为真实数据服从的概率分布与生成样本服从的概率分布之间的 Wasserstein 距离; \sup 表示最小上界; ζ 为与输入无关的常数; $E_{P_G}[\cdot]$ 为生成样本服从分布的期望; $\|\cdot\|_L$ 为 K -Lipschitz 范数,将权值裁剪至 $[-c, c]$ (c 为权值范围常数)中,如式(3)所示。

$$\|D(x_{i,t}) - D(x_{j,t})\| \leq \zeta \|x_{i,t} - x_{j,t}\| \quad (3)$$

式中: $x_{i,t}$ 、 $x_{j,t}$ 为不同的输入数据。

1.2 场景定义

DG 出力可视为 T 个时刻的随机变量 $\{x_{i,t}\} (i=1, 2, \dots, N; t=1, 2, \dots, T)$, 其中 N 为 DG 类别总数。一条确定的出力曲线称为随机过程的一个时序场景。场景生成模型的目标是建立 DG 出力的概率分布,即:

$$F(x_{1,1}, \dots, x_{i,t}, \dots, x_{N,T}) \quad (4)$$

式中: $F(\cdot)$ 为 DG 出力的概率分布函数。

可将式(4)看作一个生成模型,通过对其进行采样能够生成具有该分布随机性的场景。

针对式(4)中的概率分布,可通过引入条件 \mathbf{y} 建立给定约束下的场景条件概率分布,即:

$$F(x_{1,1}, \dots, x_{i,t}, \dots, x_{N,T} | \mathbf{y}) \quad (5)$$

综上,针对配电网中长期规划、可靠性评估等研究,生成模型需要具有以下特征:

1) 基于数据驱动自主学习数据固有属性,建立 DG 出力概率模型;

2) 场景具有随机性、波动性、时序性及空间相关性,能够表征 DG 出力随时间的变化规律;

3) 基于给定场景可控条件,能够生成满足该条件的所需场景。

1.3 场景生成框架

本文提出如图 2 所示的场景生成框架。场景生成主要由两部分构成:

1) 根据 DG 出力历史数据和气象数据构建样本训练集,训练 CGAN 日出力模型;

2) 基于 CGAN 模型提出可控场景生成方法与 4 种场景生成策略,根据研究问题需求对模型输入数据进行调整,实现可控场景生成。

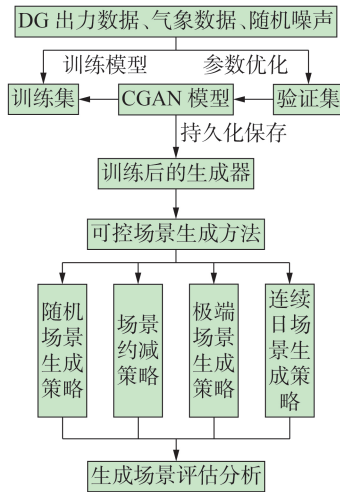


图2 基于CGAN的场景生成框架

Fig.2 CGAN based scenario generation framework

2 CGAN 模型

2.1 网络架构思路

利用流形上潜空间的可控性建立场景的信息条件与场景之间的隐式映射,这实质上是使模型建立不同条件下的场景分布。

基于多层感知机^[10,12]建立的模型可解释性较差。卷积神经网络(convolutional neural network, CNN)因其卷积核对特征的视野限制在较小区域,很容易丢失 DG 出力曲线的局部细节信息。文献[16]表明,Transformer 具有更强的泛化性,由于受益于归纳偏置的先验条件,其收敛速度更快。Transformer 有较强的拟合能力,但对局部特征的提取能力较弱,泛化性较差。因此,本文耦合 CNN 与 Transformer,考虑残差、Dropout、正则等机制,建立 CGAN 场景生成模型。模型整体结构如图 3 所示。图中:Relu、LeakyRelu、Gelu 为激活函数;Normalize、LayerNorm、BatchNorm 为正则模块;Conv 3×3 表示卷积核为 3×3 的常规卷积模块;Linear 为线性变换模块;Softmax 为(0,1)概率映射模块;Feed Forward 为前馈模块;Rel-Attention 为卷积自注意力机制模块;MBConv 为多重卷积模块。由式(1)可知,在博弈训练策略中,判别器提供关于生成数据的反馈,使生成器能够生成更接近真实的时序数据。判别器采用时序 Rel-Attention 等模块堆叠方式,实现对时序场景多重特性的判别;生成器可采用具有更低计算复杂度的 CNN 模块,判别器优化更新生成器网络参数,使生成器具有生成时序数据的能力。

2.2 模型基本原理

2.2.1 模型输入策略

生成器输入包括随机噪声和条件值,判别器输入为 DG 出力曲线与条件值,因此,设定随机噪声与 DG 出力曲线具有相同的维度,均为 $N \times T$ 维,批尺寸

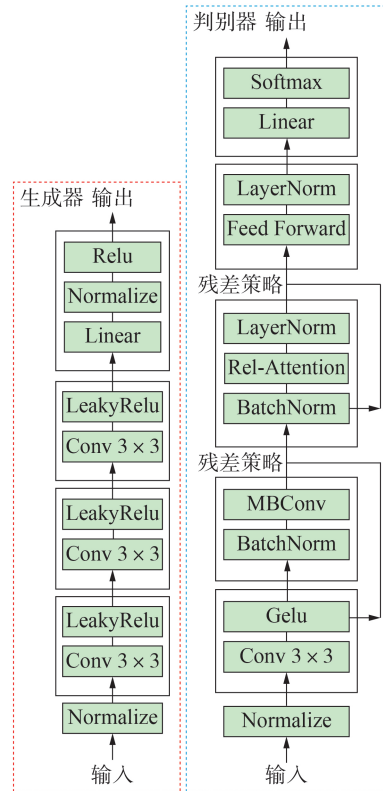


图3 生成器和判别器框架

Fig.3 Framework of generator and discriminator

为 N , DG 出力总时刻数为 T 。条件值可分为 3 种:具有时间属性的历史气象数据,如风速和光照强度;场站位置、地形、地貌等空间特征;DG 出力特征,如出力最大值、均值等,若特征维度小于 T ,则需要进行补零填充处理。最后,将多种特征矩阵纵向拼接,形成 M 个 $N \times T$ 维的输入矩阵。输入数据的维度如附录 A 图 A1 所示。

2.2.2 模型搭建策略

生成器的目的是生成满足概率分布的场景,但场景质量取决于判别器对于场景的认知。判别器的目的是区分真实场景和生成器生成的场景,因此,判别器需要具有对场景和条件值较强的特征提取能力。

由于卷积模块和 Transformer 模块堆叠能够有效提高模型的拟合能力,其中卷积模块更擅长处理早期的局部模式,因此,在图 3 的判别器网络中,输入场景数据先经过卷积模块后再经过 Transformer 模块 (Rel-Attention 和 Feed Forward) 进行特征提取。

为了提高模型的一致性,在模型的 Rel-Attention 和 MBConv 模块中借鉴 ResNet 模型中的残差预激活结构,以提高模型的泛化能力,即:

$$\mathbf{o}^{\text{res}} = \mathbf{x} + M(N^{\text{norm}}(\mathbf{x})) \quad (6)$$

式中: \mathbf{o}^{res} 为残差模块的运算输出; $M(\cdot)$ 表示 Rel-Attention 和 MBConv 模块; $N^{\text{norm}}(\cdot)$ 表示 MBConv 模块

中的BatchNorm和Rel-Attention模块中的LayerNorm。

综上:判别器首先对输入数据进行规范化处理,通过Normalize模块实现数据的无量纲化,减少网络内部的协变量偏移,提高模型对数据分布的拟合能力;其次,通过MBConv模块提取数据的逐维特征,加强模型对不同条件特征值影响的分析能力;然后,通过残差预激活机制保障模型在满足概率分布下生成多样化场景,通过Rel-Attention模块对局部特征以及全局特征进行聚合,减少模型学习高效表达的冗余与依赖问题,该模块是判别器识别DG出力特性的核心模块;最后,通过Feed Forward模块、Linear全连接模块以及Softmax模块对真实样本与生成样本进行判别。

2.2.3 Rel-Attention 模块

卷积定义为感受视野内的数值加权和,采用固定卷积核从局部视野提取特征,识别局部波动特征,即:

$$\mathbf{o}_i^{\text{con}} = \sum_{j \in \Theta(i)} \mathbf{w}_{i,j} \otimes \mathbf{x}_j \quad (7)$$

式中: $\mathbf{o}_i^{\text{con}} \in \mathbf{R}$ 为第*i*个元素卷积运算的输出; $\Theta(i)$ 为第*i*个元素的卷积核邻域; $\mathbf{w}_{i,j}$ 为卷积权重;“ \otimes ”表示卷积运算,即对应元素乘积之和。

自注意力机制表示为:

$$\mathbf{o}_i^{\text{att}} = \sum_{j \in \Xi} \frac{\exp(\mathbf{x}_i^T \mathbf{x}_j)}{\sum_{k \in \Xi} \exp(\mathbf{x}_i^T \mathbf{x}_k)} \mathbf{x}_j \quad (8)$$

式中: $\mathbf{o}_i^{\text{att}}$ 为自注意力运算的输出; Ξ 为全局空间; \mathbf{x}_i^T 为第*i*条输入数据的转置。

对比式(7)和式(8)可知,卷积权重 $\mathbf{w}_{i,j}$ 与卷积核取值相关,与输入值无关,实现卷积平移不变性能有效提高模型泛化能力。自注意力机制参数与输入值相关,可以模拟不同位置的复杂关系。在运算过程中,不同的视野分别作用于局部与全局,使二者具有不同的关注视角,从而使模型既可以利用全局视野提取长期的DG出力特征,又可以利用局部视野提取短期的波动特征,提高特征提取能力。

本文对Transformer中的原始自注意力机制进行修改,建立如下Rel-Attention机制:

$$\mathbf{o}_i^{\text{rel}} = \sum_{j \in \Xi} \frac{\exp(\mathbf{x}_i^T \mathbf{x}_j + \mathbf{w}_{i,j})}{\sum_{k \in \Xi} \exp(\mathbf{x}_i^T \mathbf{x}_k + \mathbf{w}_{i,k})} \quad (9)$$

式中: $\mathbf{o}_i^{\text{rel}}$ 为Rel-Attention运算的输出。

在Rel-Attention机制中,采用相对位置编码使自注意力机制提取时序特征,即:

$$\mathbf{F}^{\text{rel}} = S^{\text{softmax}} \left(\frac{QK^T + S^{\text{rel}}}{\sqrt{d}} \right) \mathbf{V} \quad (10)$$

式中: \mathbf{F}^{rel} 为Rel-Attention运算得到的时序特征; $S^{\text{softmax}}(\cdot)$ 为权重归一化函数; Q 、 K 、 V 分别为自注意

力机制中query、key、value, Q 与 K 的点积得到相似度分数; S^{rel} 为相对位置编码; \sqrt{d} 为放缩的点积注意力,起调节作用,实质是计算 V 的加权表征。

2.2.4 MBConv 模块

MBConv模块由常规卷积、深度可分离卷积和SeBlock层构成,具有捕获空间特征的能力,从而提高模型对不同空间位置之间相互关系的认知。常规卷积对数据进行升维和降维;深度可分离卷积提取逐维特征;SeBlock计算通道之间的相互依赖关系,通过全局损失函数自适应调整通道间的特征强度。模块结构如附录A图A2所示。

3 可控场景生成方法与策略

3.1 可控场景生成方法

场景生成模型能够生成日内可再生能源不确定性场景,但是对于实际应用仍然存在以下问题:①对于缺少可再生能源历史出力数据的场景,如何根据历史气象数据生成大量随机场景?②在场景生成模型的基础上,如何基于CGAN模型约简场景,生成少量但精确的场景?③极端天气可能会对电网可靠运行造成巨大影响,如何在该情况下生成可再生能源出力场景?④CGAN模型能够捕获可再生能源出力日时间尺度特征,如何生成周、月等中长时间尺度场景?

针对上述问题,本文提出一种基于CGAN模型的可控场景生成方法,具体步骤如下。

1)构建训练集。采用可再生能源出力历史数据以及对应的气象或者空间位置数据来建立训练数据集。

2)设置控制条件。为实现不同的生成需求,建立不同的可控条件值。

3)训练模型。交替训练判别器和生成器,将场景间的Wasserstein距离作为模型训练的收敛判别依据。

4)生成可控场景。将步骤2)中设置的控制条件输入已训练好的生成器网络中,实现按预定模式生成场景。

3.2 可控场景生成策略

1)随机场景生成策略。

基于历史DG出力数据和气象数据训练CGAN模型,使模型拟合DG出力的概率分布,并学习出力数据时序、波动等特性。相较于无监督模型,所提模型能够结合特定的偏好或专家知识生成新的场景,该场景生成策略建立了气象条件和场景分布之间的映射关系,能实现对场景的可控生成。

将规划地区的气象数据作为具有可解释性且能够预先描述规划场景的特征,控制场景模式的偏好,并利用转移的先验条件建立概率分布。在已训练好

的模型基础上,将规划地区的气象数据作为生成器的输入条件,基于随机噪声生成满足该气象条件的DG出力随机场景。同时,对模型结构和参数进行调整,以使模型适应于不同类型或不同时空要求下大量随机场景生成的情景。

2) 场景约简策略。

场景约简是一种在保留场景生成重要信息的前提下,缩小场景集规模、减少计算量的有效方法。为实现场景约简与深度学习模型相耦合,本文提出基于条件值聚类的场景约简方法。对于条件值,如气象数据,采用模糊C均值方法进行聚类;根据聚类中心位置自动调整聚类数,以实现有代表性的聚类。最后,将聚类后的条件值输入生成器中,得到约简后的场景集。

3) 极端场景生成策略。

为建立可再生能源在极端场景下的出力模型,必须明确定义极端场景。气象学^[17]将极端天气定义为大风、日食等极端事件;文献^[18]将极端场景定义为对系统造成严重和持久损失的极端天气,如损失超过10%的负荷或持续停电超过24h;IEEE^[19]考虑系统平均停电持续时间(system average interruption duration index, SAIDI)等可靠性指标,将极端场景定义为SAIDI值较大的场景。然而,这些定义并不统一,没有考虑系统规模和中断原因,并且缺少对气象要素数值化和分类的实际量化。本文基于气象数据,将极端场景定义为天气变量值高于(或低于)变量观测值范围上限(或下限)阈值的场景,如式(11)所示。

$$\delta = \begin{cases} 1 & \mu < \beta, \mu > \alpha \\ 0 & \beta \leq \mu \leq \alpha \end{cases} \quad (11)$$

式中: δ 表示是否为极端场景; μ 为极端天气关键气象要素,如气温、风速、辐照度等; α 、 β 分别为极端天气要素下限、上限阈值。

根据该策略生成的气象数据,生成极端天气下DG出力不确定性场景。为验证生成极端场景的有效性,本文提出场景评估指标,如表1所示。表中: P_t 为 t 时刻的发电功率; τ 为DG出力判别0-1变量,若 $P_t > 0$,即DG有出力时,则 $\tau = 1$,否则 $\tau = 0$,对所有时刻判别DG是否出力的 τ 进行求和得到出力小时数。

4) 连续日场景生成策略。

可再生能源中长期出力模拟是制定电力系统中长期运行方式的重要依据,由于中长期天气预测存在混沌现象,预测结果精度较低,难以作为模型输入来模拟可再生能源中长期出力变化特征。为此,基于马尔可夫链刻画可再生能源日发电状态转移规律,提出基于马尔可夫链的连续日场景生成方法,具体如下。

表1 场景评估指标

Table 1 Scenario evaluation indexes

编号	指标	公式
1	平均出力	$P_{ave} = \sum_{t=1}^T P_t / T$
2	最大出力	$P_{max} = \max\{P_t\}$
3	最小出力	$P_{min} = \min\{P_t\}$
4	平均波动率	$P_{flu} = \sum_{t=2}^T P_t - P_{t-1} / (T-1)$
5	最大波动率	$P_{mf} = \max\{ P_t - P_{t-1} \}$
6	出力小时数	$T_h = \sum_{t=1}^T \tau (\tau = 1 P_t > 0)$

定义日状态,如聚类典型日、不同天气情况(晴天、多云、阴雨等)、极端气象场景等。

连续日场景生成首先需要计算马尔可夫链状态转移矩阵 P^r ,即:

$$P^r = \begin{bmatrix} p_{11} & p_{12} & \cdots & p_{1k} \\ p_{21} & p_{22} & \cdots & p_{2k} \\ \vdots & \vdots & & \vdots \\ p_{k1} & p_{k2} & \cdots & p_{kk} \end{bmatrix} \quad (12)$$

$$p_{m_1, m_2} = P^s(S_t = m_2 | S_{t-1} = m_1) \quad (13)$$

式中: k 为日场景数;矩阵元素 p_{m_1, m_2} ($m_1, m_2 = 1, 2, \dots, k$)为DG出力状态 m_1 转移到状态 m_2 的概率; $P^s(\cdot)$ 为转移概率函数; S_t 为 t 时刻的状态。

计算状态转移概率:

$$p_{m_1, m_2} = \frac{n_{m_1, m_2}}{\sum_{m_2'} n_{m_1, m_2'}} \quad (14)$$

式中: n_{m_1, m_2} 为历史数据中从状态 m_1 转换到状态 m_2 的频数。

根据状态转移矩阵 P^r 进一步得到累积状态转移矩阵 P^{cum} ,即:

$$P^{cum} = \begin{bmatrix} p_{10}^{cum} & p_{11}^{cum} & \cdots & p_{1(k+1)}^{cum} \\ p_{20}^{cum} & p_{21}^{cum} & \cdots & p_{2(k+1)}^{cum} \\ \vdots & \vdots & & \vdots \\ p_{k0}^{cum} & p_{k1}^{cum} & \cdots & p_{k(k+1)}^{cum} \end{bmatrix} \quad (15)$$

P^{cum} 元素 p_{m_1, m_2}^{cum} 定义为:

$$p_{m_1, m_2}^{cum} = \begin{cases} 0 & l = 0 \\ \sum_{m_2 \leq l} p_{m_1, m_2} & 0 < l < k + 1 \end{cases} \quad (16)$$

式中: l 为状态 m_2 的限值。

在选定初始日后,对下一场景进行采样,生成 $[0, 1]$ 内均匀分布的随机数,并与累积状态转移矩阵 P^{cum} 第 m_1 行元素进行比较,若该随机数处于该行第 m_2 个元素和第 m_2+1 个元素之间,则表明状态 m_2 为下一场景。在给定的时间尺度内重复抽样,模拟生

成连续日场景。

4 算例分析

4.1 算例介绍

本文采用Elia电力运营商所提供的布鲁塞尔地区2015年1月到2021年10月的光伏发电和气象站数据,采样间隔为1 h,共计2496组典型日数据。实验在Windows操作系统下的Spyder平台进行,使用PyTorch 1.10.0深度学习框架,计算机硬件配置为Intel(R) Core(TM) i5-9600KF CPU 3.70 GHz,内存为32.0 GB,GPU为NVIDIA GeForce RTX 2060,显存为6.0 GB。

4.2 气象特征分析

对布鲁塞尔光伏出力与气象特征进行相关性分析,结果如图4所示。图中:横轴刻度值1—9分别表示气象数据为气温、湿度、气压、降水量、风速、风向、地表水平辐射、直接辐射和散射辐射;Pearson相关性系数与显著性水平均为标么值。




图4 Pearson相关性系数与显著性水平
Fig.4 Pearson correlation coefficient and significance level

由图4可知,光伏出力与上述9种气象特征间具有不同程度的相关性:光伏出力与3种太阳辐射特征(地表水平辐射、直接辐射和散射辐射)间的Pearson相关性系数分别为0.9863、0.9211、0.9813,对应的显著性水平均小于0.05,这表明光伏出力与太阳辐射特征间具有强相关性;光伏出力与气温间的Pearson相关性系数为0.7007;其他气象特征对应的显著性水平均大于0.05,这说明它们与光伏出力间不具有显著相关性。因此,选择具有显著相关性的地表水平辐射、直接辐射、散射辐射和气温作为场景条件值。

4.3 CGAN模型训练分析

采用Adam梯度下降算法进行模型训练,学习率为0.0001,批大小为200,序列长度为24。在模型训练过程中,由于深度神经网络训练具有一定的随机性,对判别依据Wasserstein距离进行高斯平滑处理,更好地表现模型训练的趋势,如附录A图A3所示。

4.4 场景生成策略分析

4.4.1 待规划DG场景生成策略

该策略旨在利用待规划建设区域气象数据生成场景,为验证本文模型能够有效生成符合光伏出力不确定性的场景,采用核密度估计方法进行比较分析。通过核密度估计方法建立真实样本和生成样本的概率密度函数,如图5所示(图中光伏出力为标么值)。由图可知,2条曲线近乎重合,这表明所提CGAN模型能有效拟合光伏出力的不确定性。为了进一步证明本文模型的效果,对生成的数据进行自相关性分析,计算时间间隔为0~7 h的自相关性系数,通过箱线图进行可视化,结果如图6所示,图中箱体由生成样本统计生成,箱体内部直线表示生成样本的中位数,实心圆点表示真实样本的中位数。




图5 光伏出力分布

Fig.5 Distribution of photovoltaic output




图6 自相关性系数箱线图

Fig.6 Boxplot of autocorrelation coefficient

由图6可知:生成数据在0~7 h的时间间隔内具有一定的自相关性,随着时间间隔的增长,自相关性系数逐渐减小,这表明本文模型具有模拟光伏出力时序性的能力;真实样本与生成样本自相关性系数的中位数很接近,这表明本文模型能够有效捕获真实样本的自相关性。

为了检验本文模型是否具有捕获光伏出力波动性的能力,通过周期图法计算样本的功率谱密度,结果如图7所示。由图可知,生成样本和真实样本的各频率分量基本相同,这表明本文模型能够有效刻画光伏出力在不同频率的波动性。功率谱定义了各频率上的能量值,生成样本与真实样本的相似度说明本文模型能够实现对光伏出力波动性的有效模拟。




图 7 功率谱密度示意图

Fig.7 Schematic diagram of power spectral density

4.4.2 场景约简策略

利用模糊 C 均值聚类法对气象数据进行聚类,再将聚类中心输入 CGAN 模型,生成对应气象条件下的光伏出力场景,如附录 A 图 A4 所示。

4.4.3 极端场景生成策略

为生成极端场景,对 2015 年布鲁塞尔气温数据进行统计。布鲁塞尔地区全年平均气温 $\geq 18^\circ\text{C}$ 和平均气温 ≤ 0 的场景数占比分别为 2.74% 和 1.64%,统计结果如附录 B 表 B1 所示。因此,选取平均气温作为关键气象特征,将阈值设定为 18°C 和 0,建立该地区极端高温场景和极端低温场景,如附录 A 图 A5 所示。

为验证极端天气下场景生成的有效性,计算表 1 中的场景评估指标,结果如表 2 所示。表中:出力与波动率均为标幺值; S_1 — S_4 分别表示真实的极大出力场景、生成的极大出力场景、真实的极小出力场景和生成的极小出力场景。

表 2 场景评估指标结果

Table 2 Results of scenario evaluation indexes

场景	平均出力	最大出力	最小出力	平均波动率	最大波动率	出力小时数/h
S_1	0.2484	0.7062	0	0.0623	0.1797	16.5
S_2	0.2438	0.7075	0	0.0605	0.1783	16.4
S_3	0.0035	0.0253	0	0.0028	0.0157	8.1
S_4	0.0037	0.0249	0	0.0024	0.0152	8.2

由表 2 可知,生成的极端光伏场景与真实的极端光伏场景在各项指标上均较相近,如在光伏极大出力场景中,生成场景的平均出力仅比真实场景的平均出力低 1.85%,这表明了极端场景生成策略的有效性。

4.4.4 连续日场景生成策略

为了生成连续日光伏出力场景,以场景约简策略中气象数据聚类标签为日状态,构建状态转移矩阵。初始日选定为 2015 年 1 月 1 日,根据所提方法抽样生成月度出力曲线,如附录 A 图 A6 所示。

为验证本文所提方法能够有效生成任意长时间尺度的光伏出力曲线,将生成样本与 2015 年 1 月的历史数据进行 Pearson 相关性分析,滞后 1~7 d,结果

如附录 A 图 A7 所示。由图可知,真实样本与生成样本的 Pearson 相关性系数误差相对较小,这表明所提方法具有实现可再生能源长时间尺度特性建模的能力。

4.5 模型泛化能力分析

光伏建模采用的数据集不具有空间属性,缺少单一光伏发电机组的出力数据、气象数据及经纬度坐标,为进一步验证本文所提模型和方法能够表征 DG 出力的空间属性,采用 *Data science for wind energy*^[20] 中的风电场数据进行仿真分析。风电出力数据与风速数据的时间间隔均为 1 h。本节重点分析模型能否捕获风电出力的空间特性,选取与 4.3 节中相同的训练参数,使用经纬度坐标来表示风电的空间特征。计算生成样本和历史样本的各机组相关性系数,可视化结果如图 8 所示。




图 8 风电出力数据相关性对比

Fig.8 Comparative analysis of wind power output data

通过对比图 8(a)、(b) 可知,生成场景能够表征历史数据的空间相关性,这表明本文方法能够有效刻画多风电出力之间的空间关联关系,本文模型对于模拟风电和光伏出力均有良好的泛化能力。

5 结论

针对配电网可再生能源发电不确定性建模问题,本文提出一种基于 Transformer 的改进 CGAN 架构和可控场景生成方法,经仿真分析验证了所提模型与方法的有效性,得到如下结论。

1) 所提数据驱动方法可以在不依赖于任何统计假设的情况下捕捉 DG 出力的随机特征,在给定气象条件下,利用深度学习和数据驱动技术生成符合相同历史数据分布的场景。

2) Transformer 的全局注意力机制以及常规卷积、深度可分离卷积的局部视野,使模型具有提取不同时间维度可再生能源发电特征的能力。通过合理堆叠方式、正则化和残差预激活结构提高网络的表达能力与泛化能力,使得网络有效学习可再生能源发电随机性、波动性和时空关联特性。

3)在以气象特征为控制因素的可再生能源发电场景生成过程中,使用气象数据生成可再生能源发电场景;提出多种场景生成策略,为系统规划提供实际应用价值;对不同数据集的仿真验证结果表明,所提模型和方法具有广泛的适用性。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 刘畅,刘文霞,高雪倩,等. 基于主从博弈的配电网-多综合能源系统协调规划[J]. 电力自动化设备,2022,42(6):45-52.
LIU Chang, LIU Wenxia, GAO Xueqian, et al. Coordinative planning of distribution network and multiple integrated energy systems based on Stackelberg game[J]. Electric Power Automation Equipment, 2022, 42(6): 45-52.
- [2] 刘文霞,张舒婷,高雪倩,等. 考虑综合效用和主观认知的配电网模块化储能优化配置[J]. 电网技术,2022,46(6):2074-2083.
LIU Wenxia, ZHANG Shuting, GAO Xueqian, et al. Optimal allocation of modular energy storage in distribution network considering comprehensive utility and subjective cognition[J]. Power System Technology, 2022, 46(6): 2074-2083.
- [3] 韩子娇,李正文,张文达,等. 计及光伏出力不确定性的氢能综合能源系统经济运行策略[J]. 电力自动化设备,2021,41(10):99-106.
HAN Zijiao, LI Zhengwen, ZHANG Wenda, et al. Economic operation strategy of hydrogen integrated energy system considering uncertainty of photovoltaic output power[J]. Electric Power Automation Equipment, 2021, 41(10): 99-106.
- [4] 马燕峰,李鑫,刘金山,等. 考虑风电场时空相关性的多场景优化调度[J]. 电力自动化设备,2020,40(2):55-65.
MA Yanfeng, LI Xin, LIU Jinshan, et al. Multi-scenario optimal dispatch considering temporal-spatial correlation of wind farms[J]. Electric Power Automation Equipment, 2020, 40(2): 55-65.
- [5] ZOU K, MOHY-UD-DIN G, AGALGAONKAR A P, et al. Distribution system restoration with renewable resources for reliability improvement under system uncertainties[J]. IEEE Transactions on Industrial Electronics, 2020, 67(10): 8438-8449.
- [6] 薛世伟,贾清泉,张珂欣,等. 用电数据驱动的低电压配电网负荷随机建模及不平衡评估[J]. 电力系统自动化,2022,46(8):143-153.
XUE Shiwei, JIA Qingquan, ZHANG Kexin, et al. Electricity-consumption-data-driven stochastic modeling and unbalance assessment of load in low-voltage distribution network[J]. Automation of Electric Power Systems, 2022, 46(8): 143-153.
- [7] 管霖,陈旭,吕耀棠,等. 适用于电网规划的光伏发电概率模型及其应用[J]. 电力自动化设备,2017,37(11):1-7.
GUAN Lin, CHEN Xu, LÜ Yaotang, et al. Probability model of PV generation for power system planning and its application[J]. Electric Power Automation Equipment, 2017, 37(11): 1-7.
- [8] 谢敏,熊靖,刘明波,等. 基于Copula的多风电场出力相关性建模及其在电网经济调度中的应用[J]. 电网技术,2016,40(4):1100-1106.
XIE Min, XIONG Jing, LIU Mingbo, et al. Modeling of multi wind farm output correlation based on copula and its application in power system economic dispatch[J]. Power System Technology, 2016, 40(4): 1100-1106.
- [9] 崔杨,杨海威,李鸿博. 基于高斯混合模型的风电场群功率波动概率密度分布函数研究[J]. 电网技术,2016,40(4):1107-1112.
CUI Yang, YANG Haiwei, LI Hongbo. Probability density distribution function of wind power fluctuation of a wind farm group based on the Gaussian mixture model[J]. Power System Technology, 2016, 40(4): 1107-1112.
- [10] 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.
- [11] 廖文龙,任翔,杨哲,等. 基于隐式最大似然估计的风电出力场景生成[J]. 电力自动化设备,2022,42(11):56-63.
LIAO Wenlong, REN Xiang, YANG Zhe, et al. Scenario generation of wind power output based on implicit maximum likelihood estimation[J]. Electric Power Automation Equipment, 2022, 42(11): 56-63.
- [12] HU W, ZHANG H X, DONG Y, et al. Short-term optimal operation of hydro-wind-solar hybrid system with improved generative adversarial networks[J]. Applied Energy, 2019, 250: 389-403.
- [13] TANG R, DORE J, MA J, et al. Interpolating high granularity solar generation and load consumption data using super resolution generative adversarial network[J]. Applied Energy, 2021, 299: 117297.
- [14] 王新迎,李焯,董骁翀,等. 基于变分自编码器的主动配电网多源-荷场景生成方法[J]. 电网技术,2021,45(8):2962-2969.
WANG Xinying, LI Ye, DONG Xiaochong, et al. Multi-source-load scenario generation of active distribution network based on variational autoencoder[J]. Power System Technology, 2021, 45(8): 2962-2969.
- [15] 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.
- [16] DAI Z H, LIU H X, LE Q V, et al. CoAtNet: marrying convolution and attention for all data sizes[J]. Advances in Neural Information Processing Systems, 2021, 34: 3965-3977.
- [17] 鞠冠章,王靖然,崔琛,等. 极端天气事件对新能源发电和电网运行影响研究[J]. 智慧电力,2022,50(11):77-83.
JU Guanzhang, WANG Jingran, CUI Chen, et al. Impact of extreme weather events on new energy power generation and power grid operation[J]. Smart Power, 2022, 50(11): 77-83.
- [18] JUFRI F H, WIDIPUTRA V, JUNG J. State-of-the-art review on power grid resilience to extreme weather events: definitions, frameworks, quantitative assessment methodologies, and enhancement strategies[J]. Applied Energy, 2019, 239: 1049-1065.
- [19] WARREN T C A, SAINT R. IEEE reliability indices standards[J]. IEEE Industry Applications Magazine, 2005, 11(1): 16-22.
- [20] DING Y. Data science for wind energy[M]. Boca Raton, USA: CRC Press, 2019: 206-209.

作者简介:

张帅(1994—),男,博士研究生,主要研究方向为电力系统可靠性评估、深度学习等(**E-mail**:zsrkl@ncepu.edu.cn);
刘文霞(1967—),女,教授,博士研究生导师,博士,通信作者,主要研究方向为电力系统规划与可靠性、电力系统风险评估等(**E-mail**:liuwenxia001@163.com)。

(编辑 王锦秀)

Controllable scenario generation method based on improved conditional generative adversarial network

ZHANG Shuai¹, LIU Wenxia¹, WAN Haiyang¹, LÜ Xiaoying¹, MAHATO N K¹, LU Yu^{1,2}

(1. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China;

2. Economic and Technical Research Institute of State Grid Jilin Electric Power Co., Ltd., Changchun 130022, China)

Abstract: The renewable energy generation has strong randomness and volatility, in order to achieve efficient and reliable scenario modelling, a controllable scenario generation method based on an improved conditional generative adversarial network is proposed. A scenario generation framework based on the conditional generative adversarial network is proposed. Combining the global attention mechanism of Transformer and the local generalization mechanism of conventional convolution and depth-separable convolution, a network structure suitable for exacting different dimensional features of the renewable energy generation is designed. The conditional generative adversarial network model is used to establish the mapping relationship between the low-dimensional meteorological feature latent space and the high-dimensional renewable energy generation data, a generation method of the controllable scenario is proposed, and four generation strategies of random scenario generation, scenario reduction, extreme scenario generation and continuous daily scenario generation are established. The simulative results based on the actual photovoltaic, wind power data and meteorological data show that the proposed model and method can effectively learn the randomness, timing, fluctuation and spatial correlation of renewable energy generation, and realize the controllable generation of scenarios under different strategies.

Key words: scenario generation; conditional generative adversarial network; feature extraction; distribution network; controllable generation

(上接第 8 页 continued from page 8)

Stability analysis and oscillation suppression strategy of direct-drive wind power grid-connected system with static var generator

ZHANG Fang¹, WANG He¹, LI Chuandong²

(1. Key Laboratory of Smart Grid of Ministry of Education, Tianjin University, Tianjin 300072, China;

2. Electric Power Research Institute of Fujian Provincial Power Co., Ltd., Fuzhou 350007, China)

Abstract: Most of the stability analysis and oscillation suppression strategies of wind power grid-connected system focus on wind farm itself, but less research is implemented for direct-drive wind power grid-connected system with static var generator (SVG). The control channels that have a significant impact on the stability of grid-connected system are screened out based on eigenvalue sensitivity. The grid-connected system is equivalently split into multiple single-input single-output (SISO) control channels from a multi-input multi-output (MIMO) coupled system based on the individual channel analysis and design (ICAD) theory. The stability of the grid-connected system stability is analyzed qualitatively while the interaction between different control channels is evaluated quantitatively. A sub-synchronous oscillation suppression strategy based on H_∞ robust control is proposed to suppress the interaction between control channels. Through electromagnetic transient simulation, the correctness of the grid-connected system stability analysis based on the ICAD theory and the effectiveness of the sub-synchronous oscillation suppression strategy based on H_∞ robust control are verified.

Key words: direct-drive wind turbines; static var generator; individual channel; H_∞ robust control; oscillation suppression

附录 A

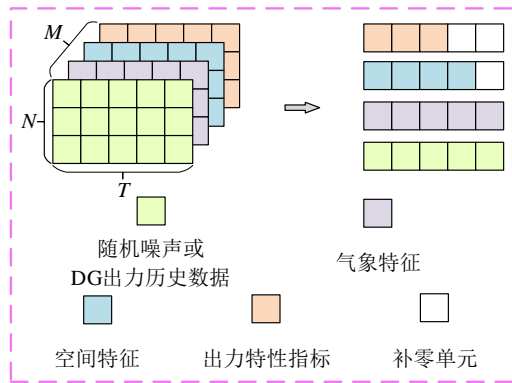


图 A1 模型输入维度

Fig.A1 Model Input Dimension

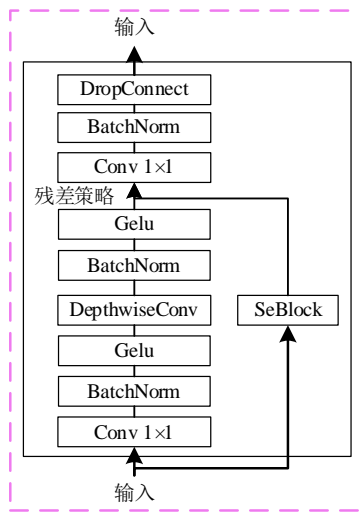


图 A2 MBConv 模块结构

Fig.A2 MBConv Module Structure

图 A2 中, DepthwiseConv 表示深度可分离卷积模块; SeBlock 表示 SENet 模型中特征提取模块, 实现对不同特征重要度加权; DropConnect 表示随机失活模块, 将每个神经元的输入以 p 的概率置为 0, 防止模型过拟合。




图 A3 真实样本与生成样本间 Wasserstein 距离

Fig.A3 Wasserstein distance between real sample and generated sample




图 A4 光伏出力约简场景

Fig.A4 PV output reduction scenario




图 A5 光伏出力极端场景

Fig.A5 PV output extreme scenario




图 A6 光伏出力月度曲线

Fig.A6 Monthly curve of PV output




图 A7 相关性系数

Fig.A7 Correlation coefficient

附录 B

表 B1 气象数据统计

Table B1 Meteorological data statistics

平均气温/°C	最低气温/°C	最高气温/°C	平均最高气温/°C
8.35	-3.0	30.22	11.06
平均最低气温/°C	平均气温≥18°C的天数	平均气温≤0 的天数	最低气温≤0 的天数
5.41	10	6	27