

基于条件流模型的可再生能源短期出力场景生成

施永浩¹, 罗萍萍¹, 林济铿²

(1. 上海电力大学电气工程学院, 上海 200090; 2. 同济大学电子与信息工程学院, 上海 201804)

摘要: 有效准确地刻画可再生能源短期出力不确定性是电力系统稳定运行的重要基础。近年来, 科研人员对生成模型进行了大量研究, 其中基于流的生成模型展现出了巨大的潜力。然而, 流模型很少用于刻画可再生能源的不确定性。因此, 提出了一种基于条件流模型的可再生能源短期出力场景生成方法。所提方法能够在已知功率预测的基础上从历史实测数据生成短期出力场景。首先使用实际出力数据训练一系列可逆函数将数据的概率分布映射到标准高斯分布, 训练完成后将服从高斯分布的随机噪声输入经过训练的流模型生成新的出力曲线。该方法可以直接通过最大似然估计进行训练, 并采用一系列特殊设计的可逆变换, 能够高效地计算训练目标。此外, 构建了生成场景评价指标体系对生成场景的质量进行评估, 实现了人工智能黑盒模型生成结果的可解释性。算例验证了所提方法的有效性和先进性。

关键词: 可再生能源; 不确定性; 场景生成; 生成模型; 流模型

Short-Term Output Scenario Generation of Renewable Energy Based on Conditional Flow Model

SHI Yonghao¹, LUO Pingping¹, LIN Jikeng²

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China; 2. College of Electronic and Information Engineering, Tongji University, Shanghai 201804, China)

Abstract: Effectively and accurately portraying the short-term output uncertainty of renewable energy is an important foundation for the stable operation of power systems. In recent years, researchers conduct a lot of studies on generative models, among which flow-based generative models show great potential. However, flow models are rarely used to portray the uncertainty of renewable energy. Therefore, a short-term output scenario generation method of renewable energy based on conditional flow model is proposed. Firstly, a series of invertible functions are trained using real output data to map the probability distribution of the data to a standard Gaussian distribution. After the training is completed, the new output curve can be generated by inputting random noise obeying Gaussian distribution into the trained flow model. The method can be trained directly by maximum likelihood estimation and employs a series of specially designed invertible transformations, which can efficiently compute the training target. In addition, a generated scene evaluation index system is constructed to assess the quality of generated scenes, achieving interpretability of the results generated by the artificial intelligence black box model. The examples verify the effectiveness and sophistication of the proposed method.

Key words: renewable energy; uncertainty; scenario generation; generative model; flow model

0 引言

近年来随着电力系统中可再生能源占比不断上升, 准确预测可再生能源出力, 尤其是短期(小时至天)出力预测^[1]对于电力系统决策至关重要。然而, 由于环境条件复杂, 可再生能源短期出力难以

准确预测。因此, 有必要对可再生能源的不确定性进行建模^[2]。场景分析法是刻画可再生能源不确定性的主要方法, 该方法的基本思想是通过构建确定性场景集来分析电力系统不确定性问题^[3]。与传统的确定性点预测只进行一次预测不同, 场景集能够提供有关不确定性的更多信息, 对于含可再生能源的经济调度^[4]和机组组合^[5]等问题非常有价值。

现有可再生能源场景生成大多采用基于概率模型的方法, 首先根据历史数据并利用参数估计或非

基金项目: 国家自然科学基金资助项目(51177107)。

Foundation item: Supported by the National Natural Science Foundation of China (51177107).

参数估计的方法建立符合可再生能源出力特性的概率模型, 然后结合抽样的方法生成所需要的场景。文献[6]假设风电出力的预测误差服从正态分布并通过抽样的方法生成场景。文献[7]采用 Markov 链模型生成能够有效描述风电出力时间相关性的场景。文献[8]采用自回归滑动平均(auto-regressive moving average model, ARMA)模型对风电出力预测误差进行建模, 求得模型参数后再生成初始场景集。文献[9]采用 Copula 函数建立风功率时空相关性模型并结合抽样的方法生成场景。基于概率模型的方法虽然具有可解释性, 但这种方法需要根据统计经验对可再生能源的不确定性做出假设, 假设是否合理将直接影响生成场景的质量。此外, 可再生能源出力不确定性包含了复杂的时空、气象以及可能存在的一些未知相关性, 而多数概率模型仅针对其中的某一特征进行建模, 难以刻画其所有的显著特征^[10-11]。而且不同时空下的可再生能源出力对应的分布特征也具有很大的差异性, 这进一步限制了概率模型的适用性^[12]。

随着深度学习技术在各领域的兴起, 利用深度生成模型刻画可再生能源的不确定性受到空前的关注, 生成模型具有强大的学习能力, 无需分析数据的分布特性, 无需概率建模, 能够自动提取历史数据中蕴含的统计规律并生成相应的场景。其中应用最为广泛的两种生成模型为变分自编码器(variational auto-encoder, VAE)^[13]和生成对抗网络(generative adversarial nets, GAN)^[14]。文献[15]提出了一种基于条件 VAE 的风电光伏场景生成方法, 并利用 one-hot 编码生成特定类别的场景。文献[16]提出了一种基于 VAE 的主动配电网多源-荷场景生成方法, 利用图神经网络与时序卷积网络分别提取非欧氏与时序相关性特征。文献[10]提出了一种基于条件 GAN 的可再生能源日前场景生成方法, 通过设计网络结构提高 GAN 的学习能力。文献[17]提出了一种基于条件 GAN 的多区域风电出力场景生成方法, 对 GAN 的结构进行设计, 以学习多区域风电出力的时空相关性。然而, VAE 和 GAN 也存在一定的局限性。VAE 采用似然函数的变分下界代替实际数据的分布, 只能得到近似的分布, 导致生成数据的精度较低。GAN 需要平衡生成器和判别器之间的博弈训练, 因此存在训练不稳定和梯度消失等问题^[18]。此外, 生成模型作为一种

黑盒模型, 无法以可解释的方式给出所生成场景的准确性。

基于流的生成模型^[19-21]是继 VAE 和 GAN 之后又一种深度生成模型, 已经被应用于图像生成、语音合成、缺失数据生成和数据增强^[22-24]等领域, 且效果显著。相较于前两者, 流模型通过采用一系列特殊设计的可逆变换来精确地计算对数似然, 能够生成高质量的样本并且训练过程稳定。文献[25]提出了一种基于条件流模型的住宅负荷场景预测方法, 能够根据历史数据生成代表未来住宅负荷的时间序列。文献[26]提出了一种基于流模型的日负荷场景生成方法, 能够较好地捕获日负荷的时空相关性以生成真实的日负荷曲线。文献[27]在文献[26]的基础之上进一步提出了一种具有卷积层的流模型以生成真实的负荷曲线。尽管流模型取得了非常有前景的结果, 但流模型应用于可再生能源方面鲜见报道。

条件生成模型在模型的输入中添加额外的条件信息, 可用于指导模型的生成过程。文献[28]将类别标签作为条件信息来生成具有特定特征的场景。文献[29]将输入分为随机噪声和具有可解释特征的连续向量, 利用设置的连续向量控制生成过程。随着先进预测技术的发展, 预测平台积累的海量预测数据在场景生成中具有参考价值。在已知功率预测的基础上从历史实测数据生成短期出力场景, 从而包含预测数据和实测数据之间的相关性, 能够通过捕捉预测数据和实测数据之间不规则的时间动态来描述由不确定性引起的局部波动^[30], 而文献[25-27]主要基于历史实测数据, 忽略了预测数据的参考价值。

在此研究背景下, 本文提出了一种基于条件流模型的可再生能源短期出力场景生成方法。与传统的确定性点预测不同, 本文旨在通过历史实测数据和预测数据生成可再生能源短期出力场景。首先, 将预测数据和实测数据分别作为流模型的数据输入和条件输入, 并训练一系列可逆函数, 将数据分布映射到标准高斯分布。训练完成后, 将实测数据作为条件输入, 并将来自高斯分布的随机噪声输入经过训练的流模型即可生成可再生能源短期出力场景。流模型的优势在于可以直接通过最大似然估计进行训练, 通过采用一系列特殊设计的可逆变换, 能够高效地计算训练目标, 并且基于可逆变换无需

另外设计生成网络,与训练网络参数相同。此外,针对人工智能黑盒模型无法以可解释的方式给出所生成场景的准确性,本文构建了生成场景评价指标体系对生成场景的质量进行评估。算例结果表明,本文所提方法能够较为准确地刻画可再生能源的不确定性。

1 流模型

流模型的基本结构如图1所示。流模型通过一系列可逆函数将真实样本的概率分布映射到先验分布,然后对先验分布进行采样以获得随机噪声,并利用逆变换生成新的样本。




图1 流模型基本结构

Fig. 1 Basic structure of flow model

具体地,设 $X \sim P_X(\mathbf{x})$ 为真实样本 $\mathbf{x} \in \mathbb{R}^D$ 的分布, D 为样本的维度数量, $Z \sim P_Z(\mathbf{z})$ 为先验隐变量 $\mathbf{z} \in \mathbb{R}^D$ 的分布。假设存在一个参数化的双射函数 $f_\theta: \mathbb{R}^D \rightarrow \mathbb{R}^D$ 使得 $f_\theta(\mathbf{x}) = \mathbf{z}$ 和 $f_\theta^{-1}(\mathbf{z}) = \mathbf{x}$,则根据随机变量的变量替换定理可得:

$$P_X(\mathbf{x}; \theta) = P_Z(f_\theta(\mathbf{x})) |\det(\frac{\partial f_\theta(\mathbf{x})}{\partial \mathbf{x}})| \quad (1)$$

式中: P_Z 为标准高斯分布; $\det(\frac{\partial f_\theta(\mathbf{x})}{\partial \mathbf{x}})$ 为 f_θ 在 $\mathbf{x}$ 处的雅可比矩阵的行列式; θ 为需要估计的参数。函数 f_θ 必须是可逆的,并且其雅可比矩阵的行列式必须易于计算。根据最大对数似然估计法,流模型的训练目标为:

$$\max_{\theta} \log P_X(\mathbf{x}; \theta) = \log P_Z(f_\theta(\mathbf{x})) + \log |\det(\frac{\partial f_\theta(\mathbf{x})}{\partial \mathbf{x}})| \quad (2)$$

当训练过程结束时通过采样概率分布 $Z \sim P_Z(\mathbf{z})$ 获得随机噪声,并通过逆变换 $f_\theta^{-1}(\mathbf{z})$ 生成新的样本。

在流模型中,双射函数 f_θ 为一系列可逆变换的组合: $f_\theta = f_1, f_2, \dots, f_n$,其中 n 为可逆变换的数量, $\mathbf{y}^{(i)}$ 为第 i 次变换得到的结果,则从 $\mathbf{x}$ 到 $\mathbf{z}$ 的映射以及从 $\mathbf{z}$ 到 $\mathbf{x}$ 的逆映射可以表示为:

$$\mathbf{x} = \mathbf{y}^{(0)} \xrightarrow[f_1^{-1}]{f_1} \mathbf{y}^{(1)} \dots \mathbf{y}^{(i)} \dots \mathbf{y}^{(n-1)} \xrightarrow[f_n^{-1}]{f_n} \mathbf{y}^{(n)} = \mathbf{z} \quad (3)$$

根据链式法则,雅可比矩阵的对数行列式可以表示为:

$$\log |\det(\frac{\partial f_\theta(\mathbf{x})}{\partial \mathbf{x}})| = \sum_{i=1}^n \log |\det(\frac{\partial \mathbf{y}^{(i)}}{\partial \mathbf{y}^{(i-1)}})| \quad (4)$$

为了使得雅可比矩阵的对数行列式易于计算,每个可逆变换 f_i 都被设计为一个加性耦合层,并通过交叉耦合的方式将相邻的加性耦合层相连接。以非线性独立成分估计(non-linear independent component estimation, NICE)模型^[19]中的加性耦合层设计为例,如图2所示,将 D 维输入样本 $\mathbf{x}$ 分为两个部分: $\mathbf{x}_{1:d}$ 和 $\mathbf{x}_{d+1:D}$,则加性耦合层的输出 $\mathbf{y}$ 可以表示为:

$$\begin{cases} \mathbf{y}_{1:d} = \mathbf{x}_{1:d} \\ \mathbf{y}_{d+1:D} = \mathbf{x}_{d+1:D} + m(\mathbf{x}_{1:d}) \end{cases} \quad (5)$$

式中: $\mathbf{y}_{1:d}$ 和 $\mathbf{y}_{d+1:D}$ 为加性耦合层生成的新变量; d 为样本的维度; $m(\cdot)$ 为任意复杂的函数。对于任意函数 $m(\cdot)$,该耦合层都具有单位雅可比行列式。其逆和雅可比矩阵分别为:

$$\begin{cases} \mathbf{x}_{1:d} = \mathbf{y}_{1:d} \\ \mathbf{x}_{d+1:D} = \mathbf{y}_{d+1:D} - m(\mathbf{y}_{1:d}) \end{cases} \quad (6)$$

$$\frac{\partial \mathbf{y}}{\partial \mathbf{x}} = \begin{bmatrix} \mathbf{I}_{1:d} & 0 \\ \frac{\partial \mathbf{y}_{d+1:D}}{\partial \mathbf{x}_{1:d}} & \mathbf{I}_{d+1:D} \end{bmatrix} \quad (7)$$

式中 $\mathbf{I}_{1:d}$ 和 $\mathbf{I}_{d+1:D}$ 为单位矩阵,该雅可比矩阵是一个三角矩阵,并且所有对角线元素都为1,因此其行列式等于1,这使得式中的训练目标能够得到有效计算。

NICE通过交叉耦合来连接相邻的两个加性耦合层,将加性耦合层1的两部分输出交换作为加性耦合层2的输入,即:

$$\begin{cases} \mathbf{y}_{1:d}^{(1)} = \mathbf{y}_{d+1:D}^{(1)} \\ \mathbf{y}_{d+1:D}^{(1)} = \mathbf{y}_{1:d}^{(1)} \end{cases} \quad (8)$$

由图2可知,加性耦合层的第一部分是恒等变




图2 NICE网络框架

Fig. 2 Network frame of NICE

换, 只在第二部分进行耦合。而交叉耦合在每次进行加性耦合之前交换两部分输入的位置, 可以使得信息得到充分混合。

2 短期出力场景生成

2.1 条件流模型

针对真实样本 $\mathbf{x} \in \mathbb{R}^D$ 和相关的条件信息 $\mathbf{c} \in \mathbb{R}^{D'}$, 训练一个条件流模型来估计在给定 $\mathbf{c}$ 的情况下, X 在点 $\mathbf{x}$ 处的条件概率密度函数为 $P_{\text{XIC}}(\mathbf{x}|\mathbf{c})$ 。具体地, 首先从分布 P_Z 中采样 $\mathbf{z} \in \mathbb{R}^D$, 然后构建一个参数化的双射函数 $f_\theta: \mathbb{R}^D \rightarrow \mathbb{R}^D$, 并考虑条件信息 $\mathbf{c}$, 使得 $f_\theta(\mathbf{x}, \mathbf{c}) = \mathbf{z}$ 且 $f_\theta^{-1}(\mathbf{z}, \mathbf{c}) = \mathbf{x}$, 由此可得:

$$P_{\text{XIC}}(\mathbf{x}|\mathbf{c}; \theta) = P_Z(f_\theta(\mathbf{x}, \mathbf{c})) |\det(\frac{\partial f_\theta(\mathbf{x}, \mathbf{c})}{\partial \mathbf{x}})| \quad (9)$$

根据最大对数似然估计法训练该模型以选择适

当的 θ 值, 使得式(9)的对数似然函数最大化。

$$\max_{\theta} \log P_{\text{XIC}}(\mathbf{x}|\mathbf{c}; \theta) = \log P_Z(f_\theta(\mathbf{y}, \mathbf{c})) + \log |\det(\frac{\partial f_\theta(\mathbf{x}, \mathbf{c})}{\partial \mathbf{x}})| \quad (10)$$

在构建条件流模型的双射函数 f_θ 时, 将 $\mathbf{c}$ 作为每个加性耦合层的函数 $m(\cdot)$ 的额外输入, 即给定输入 $\mathbf{x}$, 加性耦合层的输出为:

$$\begin{cases} \mathbf{y}_{1:d} = \mathbf{x}_{1:d} \\ \mathbf{y}_{d+1:D} = \mathbf{x}_{d+1:D} + m(\mathbf{x}_{1:d}, \mathbf{c}) \end{cases} \quad (11)$$

该耦合层仍然具有单位雅可比行列式, 因此能够有效计算式中的训练目标。

2.2 场景生成步骤

条件流模型的训练和场景生成结构如图 3 所示。

假设在 t 时刻, 已知可再生能源过去的实测数




图 3 条件流模型的训练和场景生成结构

Fig. 3 Training and scenario generating structure of flow model

据 $\mathbf{x}_{\text{hist}}$ 和预测数据 $\mathbf{x}_{\text{fore}}$, 本文的目标是基于 $\mathbf{x}_{\text{hist}}$ 和 $\mathbf{x}_{\text{fore}}$ 生成一组短期出力场景, $\mathbf{x}_{\text{hist}}$ 和 $\mathbf{x}_{\text{fore}}$ 可以表示为:

$$\begin{cases} \mathbf{x}_{\text{hist}} = [x_{t-h}, \dots, x_t] \in \mathbb{R}^{h+1} \\ \mathbf{x}_{\text{fore}} = [x_{t+1}, \dots, x_{t+k}] \in \mathbb{R}^k \end{cases} \quad (12)$$

式中: h 为历史实测数据的时间范围; k 为预测范围; $\mathbf{x}_{\text{hist}}$ 为条件输入; $\mathbf{x}_{\text{fore}}$ 作为数据输入。假设通过式中的训练目标优化得到的参数 θ 的学习值为 $\hat{\theta}$, 学习到的双射函数为 $f_{\hat{\theta}}$, 则可以使用 $f_{\hat{\theta}}$ 的逆变换生成未来 k 个时间点的场景。

$$\hat{\mathbf{x}} = f_{\hat{\theta}}^{-1}(\mathbf{z}, \mathbf{x}_{\text{hist}}) \quad (13)$$

式中 $\mathbf{z} \in \mathbb{R}^k$ 为来自标准高斯分布的样本。如果从标准高斯分布中获取 M 个样本, 那么可以通过式(13)生成 M 个场景。

场景生成的具体步骤为:

步骤1: 数据归一化。为了使得模型能够高效地训练, 在将数据输入进流模型之前, 需要对数据进行归一化, 否则损失函数可能无法收敛^[23-24]。本文采用最小-最大归一化方法将输入数据转换到 $[0, 1]$ 区间, 归一化公式如式(14)所示。

$$x'_i = \frac{x_i - x_{i,\min}}{x_{i,\max} - x_{i,\min}} \quad (14)$$

式中: x'_i 和 x_i 分别为归一化前、后第 i 个时刻的出力数据; $x_{i,\max}$ 和 $x_{i,\min}$ 分别为第 i 个时刻的最大值和最小值。

步骤2: 模型训练。将预测数据作为模型的数据输入, 将历史实测数据作为条件输入, 通过一系列可逆函数将数据分布映射到标准高斯分布; 然后, 以服从高斯分布的随机噪声作为模型的数据输入, 将实测数据作为条件输入, 通过逆变换生成新的样本。

步骤3: 更新参数。利用生成数据和输入数据计算损失函数, 并利用反向传播算法更新网络权重。

步骤4: 短期出力场景生成。训练完成后, 将实测数据作为条件输入, 经过训练的流模型将来自高斯分布的少量样本作为数据输入, 并使用学习到的双射函数将这些噪声样本转换为一组场景。

2.3 评价指标

生成模型可以方便地挖掘数据的统计特征并生成与之相似的场景, 但无法给出所生成场景的质量评估。因此, 本文从有效性、可靠性与锐度和综合性3个方面综合评价生成场景的质量^[31-33], 实现人

工智能黑盒模型生成结果的可解释性。

1) 有效性

本文采用自相关系数 (autocorrelation function, ACF) 和偏自相关系数 (partial autocorrelation function, PACF) 来衡量生成场景的有效性。ACF 和 PACF 分别描述了可再生能源出力在间隔 τ 时刻时两出力序列场景之间的相关性和间隔 τ 时刻两出力点之间的相关性。ACF 随着时间间隔的变长逐渐减小, 而 PACF 仅在较短的时间间隔内有较强的相关性。计算公式如式(15)~(16)所示。

$$F_{\text{ACF}}(\tau) = \frac{E[(X_t - \mu)(X_{t+\tau} - \mu)]}{E(X_t - \mu)^2} \quad (15)$$

$$F_{\text{PACF}}(\tau) = \frac{E[(X_t - \hat{E}(X_t))(X_{t-\tau} - \hat{E}(X_{t-\tau}))]}{\sqrt{E(X_t - \hat{E}(X_t))^2} \sqrt{E(X_{t-\tau} - \hat{E}(X_{t-\tau}))^2}} \quad (16)$$

式中: $F_{\text{ACF}}(\tau)$ 、 $F_{\text{PACF}}(\tau)$ 分别为 τ 时刻的自相关系数和偏相关系数; X_t 为 t 时刻历史实测数据或生成数据的出力值; $\hat{E}(X_t) = E(X_t | X_{t-1}, \dots, X_{t-\tau+1})$ 为 X_t 与 $X_{t-\tau}$ 之间 $\tau-1$ 个时刻出力值对 X_t 的相关性; μ 为出力均值; τ 为时间间隔。

2) 可靠性与锐度

可靠性是指生成场景应尽可能覆盖实际值, 而锐度是指生成场景集中于实际值的程度。因此, 本文采用覆盖率 (coverage rate, CR) 和功率区间宽度 (power interval width, PIW) 来衡量生成场景的可靠性与锐度, 计算公式如式(17)所示。

$$F_{\text{CRF}(1-\alpha)} = \frac{N_{(1-\alpha)}}{N} \times 100\% \quad (17)$$

式中: $1-\alpha$ 为生成风电场景集的置信度; $F_{\text{CRF}(1-\alpha)}$ 为置信度 $1-\alpha$ 下的覆盖率; $N_{(1-\alpha)}$ 为置信度 $1-\alpha$ 下实测值在置信区间内的数量; N 为测试集采样点的数量。CR 的值越接近于置信度 $1-\alpha$, 说明生成场景的可靠性越高。

$$F_{\text{PIW}(1-\alpha)} = \frac{1}{N} \sum_{n=1}^N (P_{n,1-\alpha}^{\max} - P_{n,1-\alpha}^{\min}) \quad (18)$$

式中: $F_{\text{PIW}(1-\alpha)}$ 为置信度 $1-\alpha$ 下的功率区间宽度; $P_{n,1-\alpha}^{\max}$ 和 $P_{n,1-\alpha}^{\min}$ 分别为置信度 $1-\alpha$ 下第 n 个采样点的功率最大值和最小值。采用 CR 与 PIW 共同分析生成场景的锐度性能, 在相近的 CR 下 PIW 越小说明生成场景的锐度性能更优。

3) 综合评价指标

连续等级概率分数 (continuous ranked prob-

ability score, CRPS)用于综合评价场景生成的整体性能,计算公式如式(19)—(20)所示^[34]。

$$F_{\text{CRPS}_n} = \frac{1}{M} \sum_{i=1}^M |\hat{x}_n^i - x_n| - \frac{1}{2M^2} \sum_{i,j=1}^M |\hat{x}_n^i - \hat{x}_n^j| \quad (19)$$

$$\overline{F_{\text{CRPS}}} = \frac{1}{N} \sum_{n=1}^N F_{\text{CRPS}_n} \quad (20)$$

式中: F_{CRPS_n} 为第 n 个连续等级概率分数; $\overline{F_{\text{CRPS}}}$ 为连续等级概率分数平均值; $\hat{x}_n^i$ 和 $\hat{x}_n^j$ 分别为第 n 个采样点第 i 和 j 个场景的出力值; x_n 为第 n 个采样点的实测值; M 为生成场景的数量。CRPS 越低说明场景生成的整体性能越好。

分位数得分(quantile score, QS)用于综合评价场景在置信度下的整体误差,计算公式如式(21)—(22)所示。

$$F_{\text{QS}_q}(\hat{x}_n^q, x_n) = \begin{cases} (1-q)(\hat{x}_n^q - x_n), & x_n < \hat{x}_n^q \\ q(x_n - \hat{x}_n^q), & x_n \geq \hat{x}_n^q \end{cases} \quad (21)$$

$$\overline{F_{\text{QS}}} = \frac{1}{Q} \sum_{q=1}^Q \frac{1}{N} \sum_{n=1}^N F_{\text{QS}_q}(\hat{x}_n^q, x_n) \quad (22)$$

式中: Q 为分位数量; $F_{\text{QS}_q}(\hat{x}_n^q, x_n)$ 为第 n 个采样点第 q 个分位数得分; $\overline{F_{\text{QS}}}$ 为分位数分数平均值; $\hat{x}_n^q$ 为第 n 个采样点第 q 个分位数的生成场景出力值; x_n 为第 n 个采样点的实测值。QS 的值越低说明生成场景的整体误差越小。

3 算例分析

3.1 算例概况

算例以风电短期出力场景生成为例对本文所提方法进行分析验证。采用文献[35]的共享数据进行训练和测试,从中选取2012年1月1日至2013年12月31日的风电实测数据和预测数据作为数据集,数据间隔为1 h,共有17 544组数据,每组数据均有实测和预测两个数值,以一天24组数据作为一天样本,选取了631 d的样本对模型进行训练,其余100 d的样本作为测试集。算例首先验证了所提方法的有效性,然后将所提方法与传统 Markov 链、VAE 和 GAN 方法进行对比。

算例采用 Pytorch 深度学习框架搭建条件流模型^[36-37]。模型由4个加性耦合层组成,其中 $m(\cdot)$ 为多层感知机(multi-layer perceptron, MLP),每个 MLP 由5个全连接层组成,每层神经元数量均为1 000个,激活函数为 ReLU,使用 Adam 优化器进

行训练。

为了观察流模型的训练稳定性,流模型的训练过程如图4所示。随着迭代次数的增加,损失函数逐渐减小,在第600次迭代之后趋于稳定,此时流模型训练收敛。整个训练过程比较稳定,不会出现类似 GAN 难以收敛的问题。




图4 流模型的训练过程

Fig. 4 Training process of flow model

本文将3种深度学习方法的训练速度进行了对比,在训练中取 epoch = 600 对训练时间进行对比,结果见表1,可以看出 VAE 的训练速度最快,其次是 GAN,而流模型的训练速度是最慢的,这是由于可逆变换要求输入维度必须等于输出维度,使得模型训练效率较低。

表1 训练速度对比

Tab. 1 Train speed comparison

深度学习方法	流模型	VAE 值	GAN 值
训练时间/s	239.98	22.29	34.33

3.2 有效性分析验证

训练完成后,将100个服从标准高斯分布的随机噪声作为流模型的输入数据,并将历史实测数据作为条件输入,使用学习到的双射函数将这些噪声样本转换为100个场景,如图5所示。由图5可见,生成场景能够围绕预测值,且实测值可以较好地被包括在场景集内。

为验证生成场景的有效性,利用箱型图展示生成场景相关系数的分布情况,并与实测数据的相关系数进行对比。生成场景相关系数的箱型图如图6所示。图6中蓝色叉表示风电实测数据的相关系数,最上方和最下方的横线表示生成的场景集在当前滞后时间 ACF 和 PACF 的最大值和最小值,黑色方框上下两条横线分别表示当前滞后时





图5 短期风电场景


Fig. 5 Short-term wind power scenarios

间ACF和PACF的上四分位数和下四分位数,红色线表示当前滞后时间ACF和PACF的中位数,红色加号表示当前滞后时间ACF和PACF的离群点。

由图6(a)可以看出,生成场景的ACF随着时间间隔的变长逐渐减小。由图6(b)可以看出,生成场景在时间间隔1h以内有一定偏自相关性,1h之后偏自相关系数在0附近徘徊。无论是ACF还是PACF,生成场景相关系数箱型图均能够较好地包含实测数据的相关系数,并且相关系数的变化特征与风电出力特征一致,表明生成的场景能够有效地刻画风电出力的时间相关性。



(a) 自相关系数箱型图



(b) 偏自相关系数箱型图

图6 相关系数箱型图

Fig. 6 Plot-box of correlation coefficient

3.3 方法对比

为验证本文所提方法的可靠性与锐度性能以及综合性能,算例将所提方法与传统Markov链^[7]、VAE^[15]和GAN^[10]方法进行对比。传统Markov链方法针对预测误差构建状态转移矩阵,并叠加预测值生成场景。VAE采用似然函数的变分下界代替实际数据的分布,只能得到近似的分布,导致生成数据的精度较低。由于条件信息是连续的向量值,且GAN的生成器和判别器不断竞争,因此GAN的训练通常是不稳定的。相比之下,流模型通过采用一系列特殊设计的可逆变换来精确地计算对数似然,且适用于连续值条件信息的处理,还易于使用。

表2给出了置信度100%、90%、80%和60%下的CR值和PIW值的计算结果。由表2可知,4种方法生成的场景集均有较高的覆盖率。在相同的置信度下所提方法的CR值高于其余3种方法,且PIW值更小,说明所提方法的可靠性与锐度性能更优。

图7和表3给出了生成场景的综合评价指标结果。从中可以看出,所提方法生成场景的CRPS值和QS值均小于其余3种方法,说明所提方法生成的场景整体性能更好,整体误差更小。

综上所述,4种方法生成的场景均有较好的可靠性,而传统Markov链、VAE和GAN方法生成场景的功率区间宽度较大,结果较为保守。本文所提方法生成的场景精度更高,综合性能效果更优,能够更为准确地刻画风电的短期不确定性。此外,通过一系列评价指标的分析验证,能够以可解释的方式给出所生成场景的准确性。

表2 可靠性与锐度指标计算结果

Tab. 2 Reliability and sharpness index results

置信度/%	流模型		VAE值		GAN值		Markov链	
	CR值/%	PIW值/p. u.	CR/%	PIW值/p. u.	CR值/%	PIW值/p. u.	CR值/%	PIW值/p. u.
100	95.83	0.531	92.25	0.643	94.83	0.557	97.18	0.784
90	83.08	0.293	81.00	0.369	82.83	0.339	95.92	0.589
80	75.58	0.195	72.50	0.251	73.42	0.220	88.25	0.412
60	62.25	0.058	58.42	0.077	59.42	0.067	72.33	0.241

4 结论

本文提出了一种基于条件流模型的可再生能源




图 7 综合评价指标示意图

Fig. 7 Diagram of comprehensive evaluation indexes

表 3 综合评价指标计算结果

Tab. 3 Comprehensive evaluation index results %

模型	$\overline{F}_{CRPS}$	$\overline{F}_{QS}$
流模型	8.68	4.53
VAE	9.67	5.07
GAN	8.95	4.70
Markov链	12.04	6.15

短期出力场景生成方法, 将历史实测数据作为条件信息, 从而能够根据给定的历史实测数据生成短期出力场景。具体结论如下。

1) 本文采用基于流的深度生成模型生成了一组风电短期出力场景。与传统的点预测不同, 基于预测功率结果构建场景集能够提供有关短期不确定性的更多信息, 所提方法能够生成既多样化又遵循风电实际出力的场景。

2) 本文将所提方法与 Markov 链、VAE 和 GAN 方法进行对比。相较于后两者, 流模型能够通过最大似然估计进行训练, 对于网络结构的设计和参数的选择更加容易, 训练过程更加稳定。结果表明所提方法能够生成更可靠和更具有锐度的场景, 且综合评价指标更优, 能够更为准确地刻画风电的

短期不确定性。

3) 本文构建了生成场景评价指标体系对生成场景的质量进行评估, 实现了人工智能黑盒模型生成结果的可解释性, 为决策者提供参考。

参考文献

- [1] 董晓翀, 张姝, 李烨, 等. 电力系统中时序场景生成和约简方法研究综述[J]. 电网技术, 2023, 47(2): 709–721.
DONG Xiaochong, ZHANG Shu, LI Ye, et al. Review of power system temporal scenario generation and reduction methods[J]. Power System Technology, 2023, 47(2): 709–721.
- [2] 薛禹胜, 雷兴, 薛峰, 等. 关于风电不确定性对电力系统影响的评述[J]. 中国电机工程学报, 2014, 34(29): 5029–5040.
XUE Yusheng, LEI Xing, XUE Feng, et al. A review on impacts of wind power uncertainties on power systems [J]. Proceedings of the CSEE, 2014, 34(29): 5029–5040.
- [3] 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.
- [4] 要金铭, 赵书强, 韦子瑜, 等. 基于场景分析的电力系统日前调度及其快速求解方法[J]. 电力自动化设备, 2022, 42(9): 102–110.
YAO Jinming, ZHAO Shuqiang, WEI Ziyu, et al. Day-ahead dispatch and its fast solution method of power system based on scenario analysis [J]. Electric Power Automation Equipment, 2022, 42(9): 102–110.
- [5] 崔承刚, 郝慧玲, 杨宁, 等. 基于优化 Kriging 代理模型的场景分析法求解机组组合问题[J]. 电力系统保护与控制, 2020, 48(22): 49–56.
CUI Chenggang, HAO Huiling, YANG Ning, et al. Scenario analysis based on the optimization Kriging model for solving unit commitment problems [J]. Power System Protection and Control, 2020, 48(22): 49–56.
- [6] 高海淑, 张玉敏, 吉兴全, 等. 基于场景聚类的主动配电网分布鲁棒综合优化[J]. 电力系统自动化, 2020, 44(21): 32–41.
GAO Haishu, ZHANG Yumin, JI Xingquan, et al. Scenario clustering based distributionally robust comprehensive optimization of active distribution network [J]. Automation of Electric Power Systems, 2020, 44(21): 32–41.
- [7] 董雷, 孟天骄, 陈乃仕, 等. 采用马尔可夫链—多场景技术的交直流主动配电网优化调度[J]. 电力系统自动化, 2018, 42(5): 147–153.
DONG Lei, MENG Tianjiao, CHEN Naishi, et al. Optimized scheduling of AC/DC hybrid active distribution network using markov chains and multiple scenarios technique [J]. Automation of Electric Power Systems, 2018, 42(5): 147–153.
- [8] 雷宇, 杨明, 韩学山. 基于场景分析的含风电系统机组组合的两阶段随机优化[J]. 电力系统保护与控制, 2012, 40(23): 58–67.
LEI Yu, YANG Ming, HAN Xueshan. A two-stage stochastic optimization of unit commitment considering wind power based

- on scenario analysis[J]. *Power System Protection and Control*, 2012, 40(23):58–67.
- [9] 赵书强, 金天然, 李志伟, 等. 考虑时空相关性的多风电场出力场景生成方法[J]. *电网技术*, 2019, 43(11):3997–4004. ZHAO Shuqiang, JIN Tianran, LI Zhiwei, et al. Wind power scenario generation for multiple wind farms considering temporal and spatial correlations[J]. *Power System Technology*, 2019, 43(11):3997–4004.
- [10] 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 Xiaochong, SUN Yingyun, PU Tianjiao. Day-ahead scenario generation of renewable energy based on conditional GAN[J]. *Proceedings of the CSEE*, 2020, 40(17):5527–5536.
- [11] 江聪美. 基于深度生成模型的可再生能源场景生成与预测研究[D]. 重庆:重庆大学, 2020.
- [12] 廖文龙, 杨德昌, 葛磊蛟, 等. 基于像素卷积生成网络的可再生能源场景生成[J]. *高电压技术*, 2022, 48(4):1320–1331. LIAO Wenlong, YANG Dechang, GE Leijiao, et al. Renewable energy scenario generation based on pixel convolutional generative networks[J]. *High Voltage Engineering*, 2022, 48(4):1320–1331.
- [13] KINGMA D P, WELING M. Auto-encoding variational bayes [DB/OL]. (2013–12–20)[2022–12–10]. <https://arxiv.org/abs/1312.6114>.
- [14] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. *Advances in neural information processing systems*, 2014(27):2672–2680.
- [15] 王守相, 陈海文, 李小平, 等. 风电和光伏随机场景生成的条件变分自动编码器方法[J]. *电网技术*, 2018, 42(6):1860–1869. WANG Shouxiang, CHEN Haiwen, LI Xiaoping, et al. Conditional variational automatic encoder method for stochastic scenario generation of wind power and photovoltaic system[J]. *Power System Technology*, 2018, 42(6):1860–1869.
- [16] 王新迎, 李烨, 董晓翀, 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.
- [17] 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):63–77. 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):63–77.
- [18] 朱瑞金, 廖文龙, 王玥珑, 等. 基于生成匹配网络的光伏和风电随机场景生成[J]. *高电压技术*, 2022, 48(1):374–385. ZHU Ruijin, LIAO Wenlong, WANG Yuelong, et al. Stochastic scenarios generation for wind power and photovoltaic system based on generative moment matching network[J]. *High Voltage Engineering*, 2022, 48(1):374–385.
- [19] DINH L, KRUEGER D, BENGIO Y N. Non-linear independent components estimation [DB/OL]. [2024-04-02]. <https://arxiv.org/abs/1410.8516>.
- [20] DINH L, SOHL-DICKSTEIN J, BENGIO S. Density estimation using real nvp [DB/OL]. (2016–5–27)[2017–2–27]. <https://arxiv.org/abs/1605.08803>.
- [21] KINGMA D P, DHARIWAL P G. Generative flow with invertible 1x1 convolutions[J]. *Advances in Neural Information Processing Systems*, 2018(31):1–10.
- [22] PRENGER R, VALLE R, CATANZARO B. Waveglow: a flow-based generative network for speech synthesis [C]// ICASSP 2019 – 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). May 12–17, 2019, Brighton, UK. New York: IEEE, 2019: 3617–3621.
- [23] 张博玮, 郑建飞, 胡昌华, 等. 基于流模型的缺失数据生成方法在剩余寿命预测中的应用[J]. *自动化学报*, 2023, 49(1):185–196. ZHANG Bowei, ZHENG Jianfei, HU Changhua, et al. Missing data generation method based on flow model and its application in remaining life prediction[J]. *Acta Automatica Sinica*, 2023, 49(1):185–196.
- [24] 薛阳, 杨艺宁, 廖文龙, 等. 基于非线性独立成分估计的分布式光伏窃电数据增强方法[J]. *电力系统自动化*, 2022, 46(2):171–179. XUE Yang, YANG Yining, LIAO Wenlong, et al. Data augmentation method for distributed photovoltaic electricity theft based on non-linear independent components estimation[J]. *Automation of Electric Power Systems*, 2022, 46(2):171–179.
- [25] ZHANG L, ZHANG B. Scenario forecasting of residential load profiles[J]. *IEEE Journal on Selected Areas in Communications*, 2019, 38(1):84–95.
- [26] GE L, LIAO W, WANG S, et al. Modeling daily load profiles of distribution network for scenario generation using flow-based generative network[J]. *IEEE Access*, 2020(8):77587–77597.
- [27] SILVA W N, BANDÓRIA L H T, DIAS B H, et al. Generating realistic load profiles in smart grids: an approach based on nonlinear independent component estimation (NICE) and convolutional layers[J]. *Applied Energy*, 2023(351):121902. 1–121902. 11.
- [28] CHEN Y, WANG Y, KIRSCHEN D, et al. Model-free renewable scenario generation using generative adversarial networks[J]. *IEEE Transactions on Power Systems*, 2018, 33(3):3265–3275.
- [29] DONG W, CHEN X, YANG Q. Data-driven scenario generation of renewable energy production based on controllable generative adversarial networks with interpretability[J]. *Applied Energy*, 2022(308):118387. 1–118387. 10.
- [30] 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.
- [31] 李洪裕, 董晓翀, 王新迎, 等. 考虑数据隐私保护的风电场景生成框架[J]. *电网技术*, 2023, 47(9):3690–3698. LI Hongyu, DONG Xiaochong, WANG Xinying, et al. Framework for renewable energy scenario generation considering data privacy-preservation[J]. *Power System Technology*, 2023, 47(9):3690–3698.

- [32] 黎静华, 骆怡辰, 杨舒惠, 等. 风电电力不确定性预测方法综述[J]. 高电压技术, 2021, 47(4): 1144 – 1157.
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 – 1157.
- [33] 万灿, 宋永华. 新能源电力系统概率预测理论与方法及其应用[J]. 电力系统自动化, 2021, 45(1): 2 – 16.
WAN Can, SONG Yonghua. Theories, methodologies and applications of probabilistic forecasting for power systems with renewable energy sources [J]. Automation of Electric Power Systems, 2021, 45(1): 2 – 16.
- [34] ZAMO M, NAVEAU P. Estimation of the continuous ranked probability score with limited information and applications to ensemble weather forecasts [J]. Mathematical Geosciences, 2018, 50(2): 209 – 234.
- [35] CHEN Y, WANG X, ZHANG B. An unsupervised deep learning approach for scenario forecasts [C]//2018 power systems computation conference (PSCC), June 11 – 15, 2018, Dublin, Ireland. New York: IEEE, 2018: 1 – 7.
- [36] 尚云飞, 姜明军, 张东平, 等. 基于深度学习的理论线损率计算方法研究[J]. 电测与仪表, 2024, 61(10): 33 – 38, 81.
SHANG Yunfei, JIANG Mingjun, ZHANG Dongping, et al. Study on the theoretical line loss rate calculation method based on deep learning [J]. Electrical Measurement & Instrumentation, 2024, 61(10): 33 – 38, 81.
- [37] 吴若冰, 路辉, 朱昱坤, 等. 基于多时间尺度深度学习的窃电用户检测方法研究[J]. 电测与仪表, 2024, 61(12): 178 – 184.
WU Ruobing, LU Hui, ZHU Yukun, et al. Research on user detection method for electricity theft based on multi-time scale deep learning [J]. Electrical Measurement & Instrumentation, 2024, 61(12): 178 – 184.

收稿日期: 2024-03-28; 网络首发日期: 2024-09-30

作者简介:

施永浩(2000), 男, 硕士研究生, 研究方向为电力系统不确定性建模, shiyonghaocc@163.com;

罗萍萍(1969), 女, 通信作者, 副教授, 硕士, 研究方向为电力系统可靠性分析、电力系统控制与保护, luopingping@shiep.edu.cn;

林济铿(1967), 男, 教授, 博士, 研究方向为电力系统优化调度、EMS/DEMS、电力市场、电网规划、电网应急和人工智能, mejklin@126.com。

(上接第 104 页 Continued from Page 104)

- [25] TAHERI A A, ABADLI A, TAGHILOU M, et al. Investigation of mineral oil-based nanofluids effect on oil temperature reduction and loading capacity increment of distribution transformers[J]. Energy Reports, 2021(7): 4325 – 4334.
- [26] WEI Q, TANG W, QIAN T, et al. An improved thermal-electric analogy model for evaluating loading capability of oil-immersed transformers[C]//2021 6th IEEE Asia Conference on Power and Electrical Engineering (ACPEE), April 11 – 14, 2021, Chongqing, China. New York: IEEE, 2021: 102 – 123.
- [27] 张延彪, 高翔. 含轴向油道绕组热性能优化数值研究[J]. 变压器, 2017, 54(2): 36 – 40.
ZHANG Yanbiao, GAO Xiang. Optimization numerical research on thermal characteristics of winding with axial oil duct[J]. Transformer, 2017, 54(2): 36 – 40.
- [28] 刘金泽. 油浸变压器绕组加导油挡板结构时温升计算方法[J]. 电机电器技术, 2003(5): 12 – 14.
LIU Jinze. Calculation method of temperature rise in oil immersed transformer winding with oil guide baffle structure [J]. Electrical Appliances, 2003(5): 12 – 14.

收稿日期: 2024-04-12; 网络首发日期: 2024-09-26

作者简介:

邹德旭(1984), 男, 通信作者, 高级工程师(教授级), 硕士, 从事变电设备的状态评估方面研究工作, 15912592612@139.com;

彭庆军(1981), 男, 高级工程师(教授级), 博士, 从事电气设备多物理场仿真计算工作, pqj221105@163.com;

黎文浩(1985), 男, 高级工程师, 学士, 从事电力变压器方面研究工作, Liwh3@csg.cn。