

基于生成对抗网络的综合能源负荷 场景生成方法

朱庆¹, 郑红娟¹, 唐子逸², 韦思雅¹, 邹子骁³, 吴熙³

(1. 国电南瑞科技股份有限公司, 南京市 211106; 2. 国网浙江杭州市余杭区供电有限公司, 杭州市 311100; 3. 东南大学电气工程学院, 南京市 210096)

摘要: 综合能源负荷场景生成是研究能源计量、规划运行等领域问题的基础, 具有重要意义。但由于数据采集困难、综合能源负荷多能耦合等因素的限制, 综合能源负荷场景的多样化生成仍是一大难题。提出了一种基于生成对抗网络(generative adversarial networks, GAN) 的综合能源负荷场景生成方法。首先建立梯度惩罚优化的 Wasserstein 生成对抗网络模型, 解决综合能源负荷的高随机性可能带来的不收敛或模式崩溃问题。其次, 基于深度长短期记忆(long short-term memory, LSTM) 的循环神经网络构建生成对抗网络的生成器和判别器, 使模型更适用于复杂综合能源负荷数据生成。算例结果表明, 所提模型的生成负荷场景在概率分布、曲线标志性特征和冷热电负荷之间相关性等方面相较于蒙特卡洛法和原始生成对抗网络均获得了较好结果, 可以在不同模式下生成具有多样性且逼真的负荷场景。

关键词: 综合能源系统; 场景生成; 深度学习; 生成对抗网络(GAN); 长短期记忆网络(LSTM)

Load Scenario Generation of Integrated Energy System Using Generative Adversarial Networks

ZHU Qing¹, ZHENG Hongjuan¹, TANG Ziyi², WEI Siya¹, ZOU Zixiao³, WU Xi³

(1. NARI Technology Co., Ltd., Nanjing 211106, China; 2. Hangzhou Yuhang District Power Supply Company of State Grid Zhejiang Electric Power Co., Ltd., Hangzhou 311100, China; 3. School of Electrical Engineering, Southeast University, Nanjing 210096, China)

ABSTRACT: Load scenario generation is the basis of studying energy measurement, operation scheduling and other fields, which is of great significance. Due to difficulty of data collection and multi-energy coupling of integrated energy system, it is still a big challenge to generate load data with diversity. A novel multi-load scenario generation method based on generative adversarial network (GAN) is proposed in this paper. Firstly, the Wasserstein generative adversarial network model with gradient penalty optimization is established to overcome the misconvergence and mode collapse caused by high randomness of load. Secondly, on the basis of the recurrent neural network with deep long-term and short-term memory, the generator and discriminator in the GAN are constructed to be more suitable for load data generation of complex integrated energy system. The result shows that the scenarios generated by proposed model achieves better results in probability distribution, curve signature features and correlation in cooling, heating and power load than original GAN and Monte Carlo method. The model can generate realistic load scenarios with diversity in different modes.

This work is supported by State Grid Corporation of China Research Program (No. 5600-201955167A-0-0-00).

KEYWORDS: integrated energy system; scenario generation; deep learning; generative adversarial network (GAN); long short-term memory (LSTM)

中图分类号: TM 712 文献标志码: A 文章编号: 1000-7229(2021)12-0001-08
DOI: 10.12204/j.issn.1000-7229.2021.12.001

0 引言

综合能源系统是多种能源协调形成的产消一体化系统,在提高能源利用率,推进能源供给改革等方面发挥了巨大作用^[1]。由于数据采集和传输过程中存在不可避免的干扰甚至故障,导致实际计量数据的丢失或异常,对基于综合能源负荷场景的计量仿真和规划运行研究造成很大影响^[2],因此亟需一种适用于综合能源高随机和多能耦合特点的场景生成方法。此外,随着高比例新能源和储能系统的加入,原本就存在能源耦合的综合能源系统负荷场景所面临的情况更加复杂^[3-4]。

目前较为常用的场景生成方法是基于统计模型^[5-10]和基于人工智能的方法^[11-17]。基于统计模型的方法主要有马尔可夫链法、时间序列法、蒙特卡洛法等;基于人工智能的方法主要有生成对抗网络(generative adversarial networks, GAN)方法。基于统计模型的场景生成方法有赖于实践经验,很难对系统结构存在差异的综合能源系统进行概率分布的显式建模。近些年生成对抗网络方法逐渐应用于传统负荷场景^[11-12]、风光新能源场景^[13-14]和电动汽车场景^[15]的生成。文献[13]基于条件卷积生成对抗网络,学习目标新能源电站临近电站的场景数据,补充该目标电站的缺失数据。文献[14]基于条件生成对抗网络研究可再生能源日前场景生成,提高了风电预测的准确性。文献[15]结合了聚类算法和改进生成对抗网络模型,从而获得更丰富的电动汽车充电电流场景。文献[16]应用了梯度惩罚项,以改善生成对抗网络拟合效果、提高风电功率场景的生成质量。文献[17]以日期、温度和历史数据作为条件,提出了一种对分布式能源随机性负荷建模的条件生成对抗网络模型。

上述文献主要研究了电力负荷场景、电动汽车场景、风力发电场景等均为单一类型负荷场景的生成方法,并不涉及到多元负荷形式及其相互耦合关系。本文研究的综合能源系统负荷场景涉及到冷、热、电等多种能源形式,存在多能源系统的耦合以及不同能源之间的交互影响,具有时序性、高随机性和耦合性等特点,问题的复杂性使得上述文献提及的生成方法在本文综合能源负荷场景中可用性大大降低。

本文提出一种结合基于梯度惩罚优化的 Wasserstein 生成对抗网络模型和深度长短期记忆(long short-term memory, LSTM)的综合能源负荷场景生成方法。首先,模型使用 Wasserstein 距离和梯度惩罚机制优化负荷场景中容易出现的梯度消失和

模式崩溃的问题,提高生成对抗网络的可靠性、稳定性和拟合概率分布能力,更适用于随机性较高的综合能源负荷场景。其次,为更有效地提取场景中的时序特征,采用深度 LSTM 网络构建 GAN 的生成器和判别器,强化网络的时序特性和非线性拟合能力,使其更能突出综合能源场景多元负荷之间的时序特性和关联性。最后,通过算例验证所提方法在概率分布、时序特征和负荷相关性方面的生成效果,并与蒙特卡洛法和原始生成对抗网络算法进行对比。

1 综合能源负荷场景

综合能源系统的负荷具有随机性,同时也存在能源之间的相互耦合。多能源耦合使得负荷之间的关系比单一能源系统更紧密,某种负荷用能变化会对其他负荷产生相应影响。例如,电负荷和热负荷之间通过电锅炉等方式耦合,冷负荷和电负荷之间通过电制冷机耦合。

综合能源系统负荷的复杂动态特性、耦合与时变特性对建模提出了独特的挑战。一方面,生成负荷的概率分布要与高随机性真实负荷保持一致;另一方面,生成负荷的时变特性要在幅值、波动、峰值等方面有所体现。

综合能源计量历史场景中,单个样本被表示为 $x_{s,t}$ ($t=1, \dots, T; s=1, \dots, M$)。其中, t 表示采样时刻, s 表示负荷类型。将总场景集 $S = \{x_{s,t}\}_{n=1}^N$ 随机划分为训练集 S_{train} 和测试集 S_{test} 。对于综合能源系统负荷的真实数据分布 p_r ,使用训练集 S_{train} 训练 GAN 模型,以获得符合要求的生成分布 p_g 。

2 改进的 GAN 模型

2.1 生成对抗网络模型

生成对抗网络由 Ian Goodfellow 首次提出^[18],其核心思想是生成器和判别器相互竞争的纳什均衡。在博弈训练过程中,生成器的生成能力和判别器的判别能力越来越强,直到达到平衡点为止,此时判别器无法对生成器样本的真假进行判别。生成器和判别器经过相互训练提高生成能力和判别能力的过程,也即二者探索纳什均衡的过程^[19]。

生成器和判别器的损失函数可以分别定义为:

$$L_G = -E_Z\{D[G(Z, \theta_G), \theta_D]\} \quad (1)$$

$$L_D = -E_X\{D(S_{\text{train}}, \theta_D)\} + E_Z\{D[G(Z, \theta_G), \theta_D]\} \quad (2)$$

式中: L_G 、 L_D 分别为生成器和判别器的损失函数; θ_G 表示生成器的网络参数; θ_D 表示判别器的网络参数; $G(Z, \theta_G)$ 表示生成器接收随机的噪声 Z , 通过

不同功能的神经元进行一系列采样操作,输出生成的样本数据; $D(S_{\text{train}}, \theta_D)$ 和 $D[G(Z, \theta_G), \theta_D]$ 分别表示训练样本和生成样本作为输入时判别器的输出; $E_Z(\cdot)$ 和 $E_X(\cdot)$ 分别表示对噪声分布的期望值和训练样本分布的期望值。当输入来自真实样本数据时,损失函数 L_D 期望输出尽可能接近 1;当输入来自生成器生成的样本时,损失函数 L_G 期望输出尽可能接近 0。

根据 GAN 的训练规则,可以分别固定生成器和判别器,形成一个极大极小博弈问题。令 GAN 网络的目标函数为 $V(G, D)$,则该博弈问题可以表示为:

$$\min_G \max_D V(G, D) = E[D(S_{\text{train}}, \theta_D)] - E\{D[G(Z, \theta_G), \theta_D]\} \quad (3)$$

2.2 Wasserstein GAN

相关研究表明,原始 GAN 模型存在训练不收敛问题^[2]。训练过程中生成器和判别器的损失函数都不会出现明显的收敛过程,模型的训练程度只能通过观察生成样本的好坏间接判断,缺少直接显示训练程度的表征。

为了解决上述问题,采用基于 Wasserstein 距离的 WGAN 模型进行综合能源负荷场景生成。Wasserstein 距离代表模型训练过程中负荷真实分布与生成分布之间的距离,会随网络参数训练不断收敛。因此 Wasserstein 距离可以作为算法训练程度和生成质量的评估指标,用于衡量 GAN 训练拟合程度和生成负荷场景概率分布的合理性。

Wasserstein 距离的定义为:

$$W[p(x), p(x')] = \inf_{\pi(x, x')} \int d(x, x') d\pi(x, x') \quad (4)$$

式中: $\pi(x, x')$ 为满足 $p(x)$ 与 $p(x')$ 边缘分布的联合概率密度函数; $d(x, x')$ 为场景间距离测度。

由于 Wasserstein 距离的计算成本较高,在 GAN 中可以使用 Kantorovich-Rubinstein 对偶简化 Wasserstein 距离的计算,其公式为:

$$W(p_r, p_g) = \sup_{\|f(x)\|_L \leq 1} \{E_{x \sim p_r}[f(x)] - E_{x \sim p_g}[f(x)]\} \quad (5)$$

式中: $\|f(x)\|_L \leq 1$ 表示 $f(x)$ 遵循 1-Lipschitz 函数,其导数绝对值上界为 1; p_r 为真实历史数据的样本分布; p_g 为生成对抗网络生成样本的概率分布; $\sup(\cdot)$ 函数是可以求解某条件下最小上边界的函数。

虽然 WGAN 目标函数使生成器的优化更加容易,但是对于某些特定的输入,其仍然可能产生低质量的样本,或者在某些设置下无法收敛。通过引入梯度罚分项 G_p 来限制生成器和判别器的梯度下降,改善 WGAN 算法在收敛速度和收敛稳定性方面存在的

问题。

$$G_p = \lambda \cdot E_{x' \sim p(x')} \{ [\|\nabla D(x')\| - 1]^2 \} \quad (6)$$

因此,目标函数 $V(G, D)$ 转换为:

$$\min_G \max_D V(G, D) = E[D(S_{\text{train}}, \theta_D)] - E\{D[G(Z, \theta_G), \theta_D]\} - G_p \quad (7)$$

2.3 基于 LSTM 的生成器和判别器

为了确保模型有效捕捉综合能源负荷数据的时序特征,挖掘多元负荷中隐含的相互依赖关系,本文采用 LSTM 模型构建深度 LSTM 网络设计生成器和判别器。由于 LSTM 内部的记忆机制,深度 LSTM 模型能够捕捉时间相关性^[20],在时序上反向传播不容易出现梯度消失,且更适用于综合能源多元负荷时间序列数据的非线性和时序性。

生成器和判别器结构如图 1 所示。生成器和判别器由输入层、深度 LSTM 层、全连接层和池化层构成,深度 LSTM 层由多层 LSTM 模型构成。通过状态信息在同层之间、层与层之间的传递,该神经网络理论上能够应对更复杂的时间序列,比浅层架构的神经网络具有更好的泛化效果。

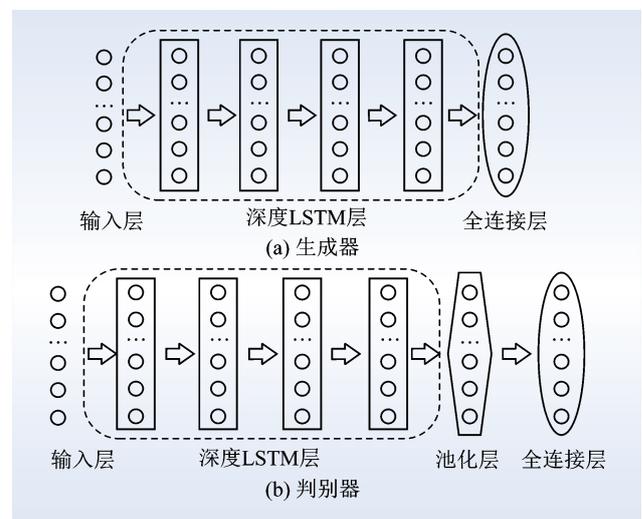


图 1 生成器和判别器结构

Fig. 1 Structure of generator and discriminator

2.4 模型训练

基于图 1 生成对抗网络架构,构建综合能源负荷生成模型,具体实现方法为:1) 构建浅层架构和较少神经网络节点的初始模型,选择通用超参数配置以保证收敛的稳定性;2) 根据初始模型确定超参数调节阈值,寻找模型最优超参数。为提高生成数据质量,并在避免过拟合的前提下保证 Wasserstein 距离最近,参考文献[21-23],设置超参数阈值如表 1 所示。

依据模型调参结果,确定生成器由一个深度 LSTM 层和一个全连接层组成。深度 LSTM 层具有 4 个隐藏层,每层有 300 个 LSTM 单位,全连接层使用

表 1 负荷生成模型的超参数阈值
Table 1 Hyper-parameter threshold of load generation model

| 超参数 | 阈值 |
|---------|---------------------|
| 神经网络层数 | 3 ~ 6 |
| 每层神经元个数 | 100 ~ 300 |
| 训练速率 | 0.000 1 ~ 0.001 0 |
| 迭代次数 | 1 000 ~ 10 000 |
| 激活函数 | ReLU, tanh, sigmoid |
| 下降算法 | Adam, lbfgs, sgd |
| 正则化系数 | 0.000 1 ~ 0.000 5 |

了线性整流函数(rectified linear unit , ReLU)。判别器由一个深度 LSTM 层、一个全连接层和一个平均池化层组成。LSTM 层由 4 个隐藏层组成,每层有 300 个 LSTM 单位,全连接层采用 ReLU 函数。

依据文献[24-25],生成对抗网络生成器的输入噪声分布会一定程度影响训练收敛速度,考虑到电负荷波动较大,冷热负荷波动较小,采用 $N(0, 5)$ 分布作为电负荷模型的噪声输入,采用 $N(0, 1)$ 分布作为冷负荷和热负荷的噪声输入。

3 综合能源多元负荷场景生成

3.1 数据预处理

由于神经网络的激活函数在 $[0, 1]$ 区间输入时具有良好的非线性,因此需要对数据进行归一化。为了保证数据量级的统一,使用最大最小归一化对数据进行标准化,实现对原始数据的等比例缩放。每个数据的值被缩放为介于 0 和 1 之间的值,如下所示:

$$x_{s,t}^* = \frac{x_{s,t} - x_{s,\min}}{x_{s,\max} - x_{s,\min}} \quad (8)$$

式中: $x_{s,t}^*$ 为多元负荷 s 在 t 时刻的样本数据 $x_{s,t}$ 归一化后的数值; $x_{s,\min}$ 、 $x_{s,\max}$ 分别表示多元负荷 s 样本数据中的最小值和最大值。

3.2 生成步骤

综合能源负荷场景生成模型如图 2 所示,生成器基于噪声 Z 产生的生成负荷场景和经过预处理后的真实负荷场景混合在一起传递给判别器识别。判别器根据原始网络参数和样本标签计算损失函数,通过反向传播更新网络参数。

GAN 通过 2 个对抗性网络交替训练实现损失函数和网络权重的更新。经过算法验证,综合能源负荷场景生成中生成器和判别器的训练进度以 1:1 交替训练时,生成器与判别器的权重更新速率不匹配。为了确保每次更新生成器时,判别器都有足够的步数移动到最佳点,本文模型中生成器的学习率设置为判别

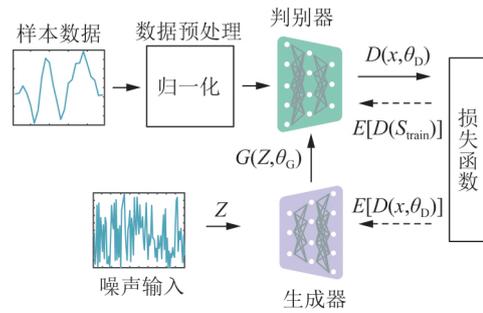


图 2 GAN 训练流程

Fig. 2 Training process of generative adversarial networks

器的 5 倍^[26]。即判别器训练 5 次,生成器训练一次。不断重复上述训练过程,直至 2 个网络损失函数收敛,此时生成器具备生成逼真样本的能力。

4 算例分析

4.1 数据描述

本文使用来自美国亚利桑那州立大学 Campus Metabolism 综合能源平台的每日 24 h 的电、冷、热负荷数据构建场景集。数据的时间间隔为 1 h。

4.2 模型训练与场景生成

Wasserstein 作为真实负荷场景与基于训练集的生成负荷场景的距离指标,指导并反映模型的训练程度和训练效果。在训练的早期阶段,Wasserstein 距离相对较大,真实样本和生成样本表现出很大的差异,这是因为生成器此时还未学习到真实数据的分布。Wasserstein 距离随训练变化情况如图 3 所示。随着训练的进行,判别器通过和生成器的持续对抗提升判别能力,Wasserstein 距离越来越小,最终保持在 0.01 附近波动。这表明判别器已经无法准确判别出样本的来源是真实样本还是生成样本,生成器已经具备生成逼真样本的能力。

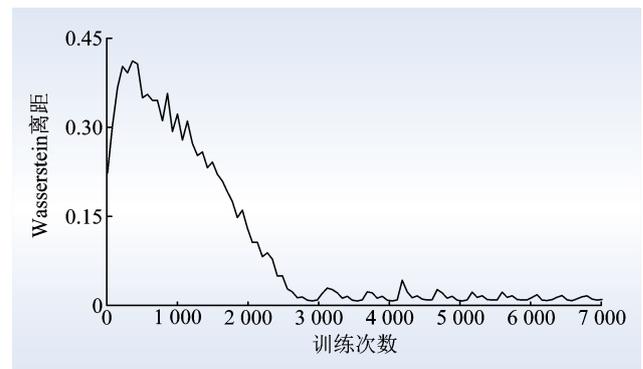


图 3 Wasserstein 距离随训练变化情况

Fig. 3 Wasserstein distance changes with training

从未被模型学习过的测试集中随机抽取真实场景,对多条生成场景进行验证。生成场景与真实场景

样本数据比较如图 4 所示。本文方法所生成的负荷场景与真实样本基本一致,准确地捕捉了冷热电负荷场景的标志性特征,如峰值、谷值和波动性。譬如,冷负荷和热负荷波动较为平稳,其分别在 15:00、07:00 左右到达用电高峰,04:00、16:00 左右到达用电低谷;电负荷随机性、波动性强,白天相比夜晚负荷更高。

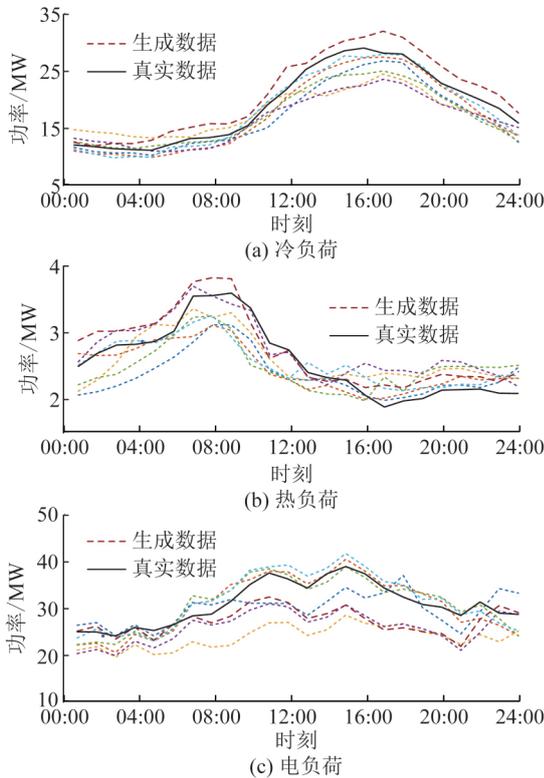


图 4 生成场景与真实场景样本数据比较
Fig. 4 Comparison of sample data between generated and real scenarios

4.3 场景生成质量评估

综合能源负荷生成场景可以从场景集的时序特性、概率分布特性、冷热电负荷之间相关性 3 个方面进行评估。

1) 时序特性。

为研究生成场景与真实场景在时序特性方面的相关性,引入自相关系数对比场景的时序相关性^[27]。自相关系数反映了原负荷序列与滞后 τ h 负荷序列之间的相关性,具有验证生成样本学习时间序列相关性的能力,可应用于场景生成领域。

本文方法生成场景与真实场景自相关系数比较如图 5 所示,在滞后 0 ~ 10 h 的范围内,本文方法所生成的冷、热、电场景和真实场景的自相关系数一致性较高,生成场景的时序特性满足真实场景时序特性的要求。

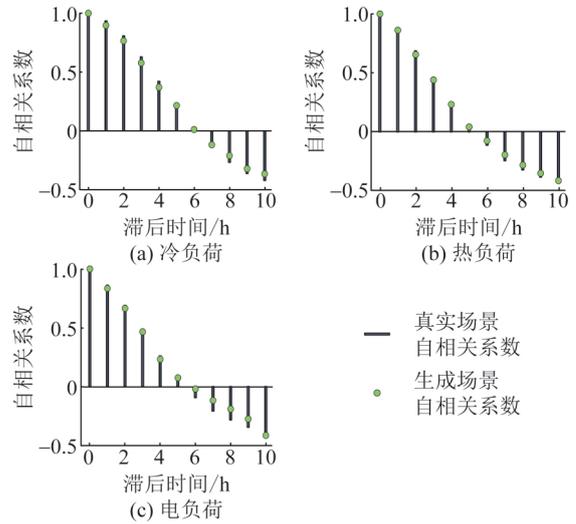


图 5 本文方法生成场景与真实场景自相关系数比较
Fig. 5 Comparison of autocorrelation between generated and real scenarios

2) 概率分布特性。

累积分布函数 (cumulative distribution function, CDF) 可以直观表征负荷场景的概率分布,方便对比真实负荷场景与生成负荷场景之间的关系。本文采用累积分布函数分析生成场景的概率分布特性。

图 6 给出了本文方法、蒙特卡洛法和原始 GAN 方法生成的多元负荷场景集与真实场景集的 CDF 曲线对比,本文方法在冷、热、电负荷生成中拟合效果最优。3 种方法对热负荷和冷负荷的生成结果在概率分布方面差异较小,这与冷、热负荷波动小、较稳定的特点相一致,蒙特卡洛法用于电负荷场景生成效果较差,2 种 GAN 方法相对较优,这种差异可能是源于电负荷的高随机性和波动性,GAN 的对抗式算法拟合概率分布的能力更强。相较于原始 GAN 算法,本文方法生成的多元负荷场景集的 CDF 曲线与真实场景

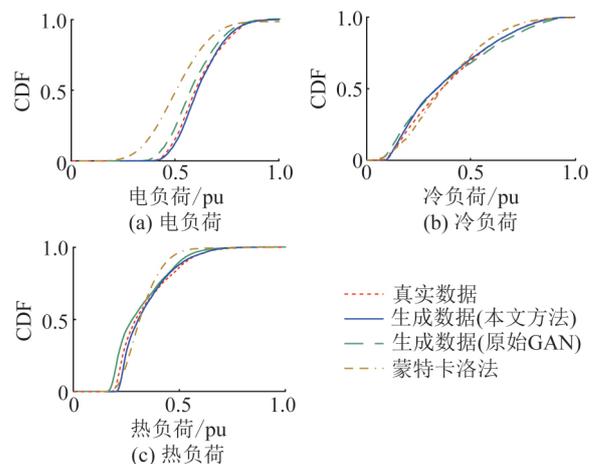


图 6 生成场景与真实场景数据概率分布特性比较
Fig. 6 Comparison of probability distribution characteristics between generated and real scenarios

的拟合度更高,学习给定数据潜在概率分布的能力更强。

3) 负荷相关性。

综合能源系统中的冷热电负荷间协调互补的耦合机制也是衡量综合能源负荷场景的重要指标,通过皮尔森(Pearson)相关系数 $\rho_{x,y}$ 衡量能源 x 与能源 y 之间的相关性:

$$\rho_{x,y} = \text{corr}(x,y) = \frac{\text{cov}(x,y)}{\sigma_x \sigma_y} = \frac{E[(x - \mu_x)(y - \mu_y)]}{\sigma_x \sigma_y} \quad (9)$$

式中: $\text{cov}(x,y)$ 表示 x 和 y 之间的协方差; σ_x 和 σ_y 分别表示 x 和 y 之间的标准差; μ_x 和 μ_y 分别表示 x 和 y 的均值。

真实场景、本文方法生成场景、原始 GAN 和蒙特卡洛方法生成场景下的负荷相关性如表 2—5 所示。

表 2 真实场景下的负荷相关性

Table 2 Correlation of load in real scenarios

| 负荷类型 | 电负荷 | 冷负荷 | 热负荷 |
|------|-------|-------|-------|
| 电负荷 | 1.00 | 0.83 | -0.35 |
| 冷负荷 | 0.83 | 1.00 | -0.57 |
| 热负荷 | -0.35 | -0.57 | 1.00 |

表 3 本文方法生成场景下的负荷相关性

Table 3 Correlation of load scenarios generated by proposed method

| 负荷类型 | 电负荷 | 冷负荷 | 热负荷 |
|------|-------|-------|-------|
| 电负荷 | 1.00 | 0.79 | -0.38 |
| 冷负荷 | 0.79 | 1.00 | -0.55 |
| 热负荷 | -0.38 | -0.55 | 1.00 |

表 4 原始 GAN 生成场景下的负荷相关性

Table 4 Correlation of load scenarios generated by original GAN

| 负荷类型 | 电负荷 | 冷负荷 | 热负荷 |
|------|-------|-------|-------|
| 电负荷 | 1.00 | 0.89 | -0.54 |
| 冷负荷 | 0.89 | 1.00 | -0.63 |
| 热负荷 | -0.54 | -0.63 | 1.00 |

表 5 蒙特卡洛生成场景下的负荷相关性

Table 5 Correlation of load scenarios generated by Monte Carlo

| 负荷类型 | 电负荷 | 冷负荷 | 热负荷 |
|------|-------|-------|-------|
| 电负荷 | 1.00 | 0.51 | -0.26 |
| 冷负荷 | 0.51 | 1.00 | -0.34 |
| 热负荷 | -0.26 | -0.34 | 1.00 |

为了更清晰地量化真实场景与生成场景在多元化方面的真实程度,定义多元负荷相关系数特征向量 v 的欧几里得范数 δ 衡量冷热电相关系数特征向量之间的距离:

$$v = \begin{bmatrix} \rho_{1,2} \\ \rho_{2,3} \\ \rho_{3,1} \end{bmatrix} \quad (10)$$

$$\delta = \|v_{\text{real}} - v_{\text{gen}}\|_2 \quad (11)$$

式中: $\rho_{1,2}$ 、 $\rho_{2,3}$ 、 $\rho_{3,1}$ 分别表示某种场景下的电冷、电热、冷热相关系数; v_{real} 、 v_{gen} 分别表示真实数据和生成数据的相关系数特征向量。

本文方法所生成场景与真实场景的距离为 0.053 85,原始 GAN 生成场景与真实场景的距离为 0.123 69,蒙特卡洛法生成场景与真实场景的距离为 0.393 19,本文方法生成的负荷场景与真实场景更接近,生成的场景整体更符合真实数据的相关性规律。这说明本文的多元负荷场景生成方法能很好地学习到冷热电负荷之间的复杂耦合性,并有很好的泛化效果。

5 结 论

本文提出了一种基于生成对抗网络的综合能源负荷场景生成方法。该模型使用带梯度惩罚的 Wasserstein 距离作为判别器的损失函数,以适应综合能源负荷场景中容易出现的梯度消失问题。针对综合能源负荷的时序性和关联性,采用深度 LSTM 构建 GAN 的生成器和判别器,使生成对抗网络更适用于高随机性的时间序列数据生成。通过真实负荷的训练和测试,结合原始 GAN 和蒙特卡洛方法的对比算例,表明该模型具有以下优点:

1) 以 Wasserstein 距离作为网络训练程度的指标,避免了 GAN 训练的盲目性,提高了场景生成算法的概率分布拟合能力,优于蒙特卡洛模型和原始 GAN 模型,能更稳定、更高效地产生高质量场景集;

2) 加入的梯度惩罚项 G_p 提高了算法的稳定性,优化了 GAN 训练可能会出现梯度消失、梯度爆炸问题;

3) 深度 LSTM 网络架构强化了生成场景的时序特性和非线性拟合能力,提高了综合能源负荷生成场景与原始场景时序特征和多能耦合关系的一致性。

6 参考文献

- [1] 杨海柱,李梦龙,江昭阳,等.考虑需求侧电热气负荷响应的区域综合能源系统优化运行[J].电力系统保护与控制,2020,48(10):30-37.

- YANG Haizhu, LI Menglong, JIANG Zhaoyang, et al. Optimal operation of regional integrated energy system considering demand side electricity heat and natural-gas loads response [J]. *Power System Protection and Control* 2020 48(10): 30-37.
- [2] FEKRI M N, GHOSH A M, GROLINGER K. Generating energy data for machine learning with recurrent generative adversarial networks[J]. *Energies*, 2019, 13(1): 130.
- [3] GUO Z J, WAN Y M, YE H. A data imputation method for multivariate time series based on generative adversarial network[J]. *Neurocomputing*, 2019, 360: 185-197.
- [4] 熊文, 刘育权, 苏万煌, 等. 考虑多能互补的区域综合能源系统多种储能优化配置[J]. *电力自动化设备*, 2019, 39(1): 118-126.
- XIONG Wen, LIU Yuquan, SU Wanhuang, et al. Optimal configuration of multi-energy storage in regional integrated energy system considering multi-energy complementation [J]. *Electric Power Automation Equipment*, 2019, 39(1): 118-126.
- [5] PAPAETHYMIU G, KLOCKL B. MCMC for wind power simulation[J]. *IEEE Transactions on Energy Conversion*, 2008, 23(1): 234-240.
- [6] 刘纯, 吕振华, 黄越辉, 等. 长时间尺度风电出力时间序列建模新方法研究[J]. *电力系统保护与控制*, 2013, 41(1): 7-13.
- LIU Chun, LÜ Zhenhua, HUANG Yuehui, et al. A new method to simulate wind power time series of large time scale [J]. *Power System Protection and Control*, 2013, 41(1): 7-13.
- [7] 方华亮, 李大虎, 彭辉, 等. 基于“互联网+”的分散式太阳能规划方法[J]. *中国电机工程学报*, 2017, 37(5): 1316-1324.
- FANG Hualiang, LI Dahu, PENG Hui, et al. Distributed solar energy planning method based on Internet plus [J]. *Proceedings of the CSEE*, 2017, 37(5): 1316-1324.
- [8] 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.
- [9] 常小强, 宋政湘, 王建华. 基于蒙特卡罗算法的电动汽车充电负荷预测及系统开发[J]. *高压电器*, 2020, 56(8): 1-5.
- CHANG Xiaoqiang, SONG Zhengxiang, WANG Jianhua. Electric vehicle charging load prediction and system development based on Monte Carlo algorithm [J]. *High Voltage Apparatus*, 2020, 56(8): 1-5.
- [10] 张辰毓, 许刚. 分布式多元随机动态场景生成及快速精准场景降维算法[J/OL]. *电网技术* 2021 (2021-05-27) [2021-06-01]. <https://doi.org/10.13335/j.1000-3673.pst.2021.0373>.
- ZHANG Chenyu, XU Gang. Distributed multivariate random dynamic scenario generation and fast & accurate scenario simplified algorithm [J/OL]. *Power System Technology* 2021 (2021-05-27) [2021-06-01]. <https://doi.org/10.13335/j.1000-3673.pst.2021.0373>.
- [11] 吴钉捷, 李晓露, 陆一鸣. 基于生成对抗网络和联邦学习的非侵入式负荷分解方法[J/OL]. *电测与仪表* 2021 (2020-04-21) [2021-06-01]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20200421.1515.032.html>.
- WU Dingjie, LI Xiaolu, LU Yiming. Non-intrusive load disaggregation method based on GAN and federated learning [J/OL]. *Electrical Measurement & Instrumentation*, 2021 (2020-04-21) [2021-06-01]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20200421.1515.032.html>.
- [12] 林珊, 王红, 齐林海, 等. 基于条件生成对抗网络的短期负荷预测[J]. *电力系统自动化*, 2021, 45(11): 52-60.
- LIN Shan, WANG Hong, QI Linhai, et al. Short-term load forecasting based on conditional generative adversarial network [J]. *Automation of Electric Power Systems*, 2021, 45(11): 52-60.
- [13] 张承圣, 邵振国, 陈飞雄, 等. 基于条件深度卷积生成对抗网络的新能源发电场景数据迁移方法[J/OL]. *电网技术* 2021 (2021-07-23) [2021-08-28]. <https://doi.org/10.13335/j.1000-3673.pst.2021.1008>.
- ZHANG Chengsheng, SHAO Zhenguo, CHEN Feixiong, et al. A renewable power generation data transferring method based on conditional deep convolutions generative adversarial network [J/OL]. *Power System Technology*, 2021 (2021-07-23) [2021-08-28]. <https://doi.org/10.13335/j.1000-3673.pst.2021.1008>.
- [14] 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.
- [15] YANG F, YIN S P, ZHOU S Y, et al. Electric vehicle charging current scenario generation based on generative adversarial network combined with clustering algorithm [J]. *International Transactions on Electrical Energy Systems*, 2021, 31(8): e12971.
- [16] JIANG C M, MAO Y F, CHAI Y, et al. Scenario generation for wind power using improved generative adversarial networks [J]. *IEEE Access*, 2018, 6: 62193-62203.
- [17] WANG Y, HUG G, LIU Z J, et al. Modeling load forecast uncertainty using generative adversarial networks [J]. *Electric Power Systems Research*, 2020, 189: 106732.
- [18] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C]//Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal, Canada: MIT Press, 2014: 2672-2680.
- [19] ZHANG C, KUPPANNAGARI S R, KANNAN R, et al. Generative adversarial network for synthetic time series data generation in smart grids [C]//2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm). Aalborg, Denmark: IEEE, 2018: 1-6.
- [20] 张宇帆, 艾芊, 林琳, 等. 基于深度长短时记忆网络的区域级超短期负荷预测方法[J]. *电网技术*, 2019, 43(6): 1884-1892.
- ZHANG Yufan, AI Qian, LIN Lin, et al. A very short-term load forecasting method based on deep LSTM RNN at zone level [J]. *Power System Technology*, 2019, 43(6): 1884-1892.
- [21] ZANG H X, XU R Q, CHENG L L, et al. Residential load forecasting based on LSTM fusing self-attention mechanism with pooling [J]. *Energy*, 2021, 229: 120682.

- [22] MUZAFFAR S , AFSHARI A. Residential load forecasting based on LSTM fusing self-attention mechanism with pooling [J]. Energy Procedia ,2019 ,158: 2922-2927.
- [23] BENDAOU D N M M , FARAH N , BEN AHMED S. Comparing generative adversarial networks architectures for electricity demand forecasting [J]. Energy and Buildings ,2021 ,247: 111152.
- [24] MASCIALINO B ,PFEIFFER A ,PIA M G , et al. Evaluation of the power of Goodness-of-Fit tests for the comparison of data distributions [C]//2006 IEEE Nuclear Science Symposium Conference Record. San Diego , CA , USA: IEEE , 2006: 101-103.
- [25] 李洪均,李超波,张士兵. 噪声稳健性的卡方生成对抗网络 [J]. 通信学报,2020 ,41(3): 33-44.
LI Hongjun , LI Chaobo , ZHANG Shibing. Noise robust Chi-square generative adversarial network [J]. Journal on Communications ,2020 ,41(3): 33-44.
- [26] 王德文,李业东. 基于 WGAN 图片去模糊的绝缘子目标检测 [J]. 电力自动化设备,2020 ,40(5): 188-198.
WANG Dewen , LI Yedong. Insulator object detection based on image deblurring by WGAN [J]. Electric Power Automation Equipment ,2020 ,40(5): 188-198.
- [27] 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.
-
- 收稿日期:2021-06-08
- 作者简介:
朱庆(1981)男,博士,高级工程师,主要从事虚拟电厂、人工智能、5G 通信、电力信息通信方面的研究工作,E-mail: dreamathstat@163.com;
郑红娟(1989)女,工程师,长期从事综合能源、需求响应业务方向研究工作,E-mail: 451173096@qq.com;
唐子逸(1994)男,硕士研究生,主要从事综合能源系统等方面的研究工作,E-mail: 25804126@qq.com;
韦思雅(1997)女,硕士研究生,主要从事虚拟电厂等方面的研究工作,E-mail: weisiya_bess@163.com;
邹子骁(1998)男,硕士研究生,主要从事人工智能在电力系统中的应用方面的研究工作,E-mail: 961498170@qq.com;
吴熙(1987)男,博士,副教授,通信作者,主要从事柔性交流输电系统、电力系统稳定与控制、新能源发电与并网技术、分布式控制等方面的研究工作,E-mail: wuxi@seu.edu.cn。
- (编辑 景贺峰)