

DOI: 10.19783/j.cnki.pspc.250197

计及源-荷-环境之间多影响因素耦合的风-光-荷联合场景生成

杨大坤¹, 张大海¹, 严嘉豪², 李亚平², 孙 锴¹, 焦治杰¹

(1. 北京交通大学电气工程学院, 北京 100044; 2. 中国电力科学研究院有限公司, 江苏 南京 210003)

摘要: 在电力系统能源快速转型的背景下, 高比例可再生能源和多元负荷的接入加剧了电网运行场景的复杂性, 源-荷-环境间多影响因素的深度耦合增加了运行场景特征提取难度。针对上述问题, 提出一种综合考虑复杂环境耦合和多维时序特征的风-光-荷场景生成方法。首先, 考虑到风-光-荷的强时序耦合与非线性特性, 采用双向门控循环单元(bidirectional gated recurrent unit, Bi-GRU)对环境因素和风-光-荷数据的初始特征进行提取, 并通过误差迭代技术优化特征向量。其次, 为精确捕捉风-光-荷及其环境因素之间的概率依赖关系, 将提取的初始特征作为输入, 并基于条件变分自编码器(conditional variational auto encoder, CVAE)构建风-光-荷场景生成模型。然后, 针对风-光-荷功率曲线的时间序列非等长问题, 采用动态时间规整(dynamic time warping, DTW)算法对生成的风-光-荷场景进行约简, 确保最终生成的风-光-荷场景具有时序一致性。最后, 基于中国某地区实测的风-光-荷数据, 对所提方法进行验证。结果表明, 该方法能够生成更加接近实际情况的风-光-荷联合场景。

关键词: 时序耦合; 特征提取; 条件变分自编码器; 风-光-荷场景生成

Multi-factor coupled scenario generation for wind-solar-load systems considering source-load-environment interactions

YANG Dakun¹, ZHANG Dahai¹, YAN Jiahao², LI Yaping², SUN Kai¹, JIAO Zhijie¹

(1. School of Electrical Engineering, Beijing Jiaotong University, Beijing 100044, China;

2. China Electric Power Research Institute, Nanjing 210003, China)

Abstract: With the rapid energy transition in power systems, the growing penetration of renewable energy and diversified loads has increased the complexity of grid operating scenarios. The deep coupling of multiple influencing factors among energy sources, loads, and environmental conditions further complicates scenario feature extraction. To address these challenges, this paper proposes an integrated wind-solar-load scenario generation method incorporating complex environmental coupling and multi-dimensional temporal features. First, considering strong temporal coupling and nonlinear characteristics of wind, solar, and load profiles, a bidirectional gated recurrent unit (Bi-GRU) is used to extract initial features from environmental factors and historical data, with feature vectors refined via error iteration. Subsequently, to accurately capture the probabilistic dependencies among wind, solar, load, and environmental variables, the extracted initial features are fed into a conditional variational autoencoder (CVAE) to construct a wind-solar-load scenario generation model. Then, to address the issue of unequal sequence lengths in wind-solar-load power curves, the dynamic time warping (DTW) algorithm is employed to reduce the generated scenarios, ensuring temporal consistency across the final output. Finally, the proposed method is validated using real-world wind-solar-load data from a region in China. The results demonstrate that the method can generate joint scenarios that more closely reflect real-world operating conditions.

This work is supported by the National Key Research and Development Program of China (No. 2022YFB2403400).

Key words: temporal coupling; feature extraction; conditional variational autoencoder; wind-solar-load scenario generation

0 引言

随着可再生能源大规模接入电力系统, 风电与

光伏固有的波动性和不确定性给电力系统安全经济运行带来了挑战^[1-3]。在此背景下, 对其进行准确建模已成为应对这些挑战的关键途径。在风-光-荷的建模过程中, 需要从多角度充分考虑风、光、负荷之间的耦合关系, 包括辐射、湿度、风速、降水、

基金项目: 国家重点研发计划项目资助(2022YFB2403400)

气压等多种环境因素,而源-荷之间时序耦合关系尤其受到上述共同环境因素的驱动^[4-6]。因此,在风-光-荷场景生成过程中,需要充分考虑源-荷-环境间存在的多维耦合影响。

在特征提取方面,已有研究提出基于主成分分析(principal component analysis, PCA)^[7-9]、离散傅里叶变换^[10]、深度学习^[11-12]等方法,通过数据降维提取出复杂数据的主要特征。然而,这种做法可能导致提取出的潜在特征空间并不完全适合后续的聚类分析。为此,文献[13]提出一种数据降维和聚类过程的联合优化策略,特别适用于处理多维时序变量所具有的非线性等复杂特性。

在场景生成方面,随着可再生能源渗透率的提高,风-光-荷之间耦合关系日趋复杂化,天气等环境因素的非线性时变特性进一步增加了场景生成的难度^[14]。其中,温度、相对湿度、降水量等环境因素直接影响风电、光伏出力的波动性与负荷不确定性^[15-16],因此其可作为表征风-光-荷相关性的耦合特征^[17]。文献[18]研究了极端天气对电力系统的交互影响;文献[19]利用长短期记忆网络(long short-term memory, LSTM)生成了包含光伏输出、系统负荷和环境数据的典型场景。尽管这些研究在场景生成中引入了环境因素,但仍未全面计及如湿度、电价等多维环境变量与源荷之间的时序耦合关系,影响了生成场景的准确性与适应性^[20]。

现有方法多采用聚类技术对长期时序场景进行约简。如基于 Kantorovich 概率距离的同步回代约简算法^[21]、改进的 K-means 聚类算法^[22-24]、基于密度的噪声应用空间聚类^[25-26]及改进的 K-medoids 聚类算法^[27]等。此外,模糊 C 均值聚类思想和以距离最小为目标的优化模型^[28-29]方法也被用于场景约简。然而,当时间序列存在伸缩或扭曲时,传统方法难以有效筛选出时序一致的场景。

针对上述问题及挑战,本文提出一种考虑源-荷-环境之间多维影响因素耦合的风-光-荷联合场景生成方法。首先,运用斯皮尔曼相关系数筛选出对风-光-荷影响显著的关键环境因素。其次,为解决多维时序耦合特征提取难题,采用双向门控循环单元(bidirectional gated recurrent unit, Bi-GRU)对风-光-荷及关键环境因素数据进行特征提取,利用其双向结构捕获复杂的前后向时序依赖,并结合误差迭代技术优化特征向量。然后,为表征关键环境因素与风-光-荷的复杂概率耦合关系,以条件变分自编码器(conditional variational auto encoder, CVAE)为基础,将筛选出的关键环境因素作为条件变量,对提取的特征向量进行概率建模并生成联合场景。最

后,为保证约简场景时的时序形态一致性,采用动态时间规整(dynamic time warping, DTW)^[30-32]算法度量场景间的相似性,对生成的风-光-荷联合场景集进行有效的约简,实现场景集的优化。

在实验过程中,为体现计及源-荷-环境之间多影响因素耦合的风-光-荷联合场景生成的优越性,将新方法与现有基于深度学习框架的场景生成方法进行比较,如表 1 所示。文献[12]主要专注风光出力,对环境与源荷耦合关系考虑不足;文献[33]仅适用于风电场景;文献[34]对时序一致性处理较为欠缺。故本文在文献[12, 33-34]的基础上对场景生成方法进行改进,全面考虑源-荷-环境多维时序因素耦合,实现在不同环境与负荷条件下灵活生成场景,并有效提升时序一致性与代表性。

表 1 场景生成模型对比表

Table 1 Comparison of scenario generation models

模型	生成场景类型	场景生成考虑因素		
		多维时序耦合因素处理	场景生成灵活性	时序一致性
文献[12]	风-光	否	否	否
文献[33]	光-荷	否	否	否
文献[34]	风	否	否	否
本文方法	风-光-荷	是	是	是

1 风-光-荷场景生成总体框架

首先,采用斯皮尔曼相关系数对风-光-荷及影响因素进行分析,筛选出关键影响因素,并进行数据预处理。同时,为了有效地提取风-光-荷数据及关键环境因素的高维非线性时序特征,采用 Bi-GRU 模型进行特征提取。通过反复迭代优化,确保特征提取结果的偏差在设定的阈值以下,输出优化后的特征向量。

然后,将融合了多维耦合信息的特征向量输入 CVAE 进行编码,以获得潜在空间的表征。在此过程中,考虑到复杂环境因素对风-光-荷场景的影响,通过在 CVAE 的潜在空间中进行抽样,利用解码器生成符合输入环境条件的风-光-荷联合场景。

最后,针对生成场景中可能存在的时序伸缩或相位差异,采用 DTW 技术基于曲线整体形态相似性对各个场景进行约简,得到一组具有高度时序一致性和代表性的风-光-荷场景集。

基于源-荷-环境之间多影响因素耦合的风-光-荷联合场景生成框架如图 1 所示。

2 风-光-荷时序场景生成方法

2.1 关键影响因素选取

环境因素对风-光-荷功率具有显著影响,提取

关键环境因素有助于更准确地捕捉风-光-荷时序数据的动态特征。为此, 本文运用斯皮尔曼相关系数

P 定量分析环境参数与风-光-荷功率的相关性, 其斯皮尔曼相关系数如图 2 所示。

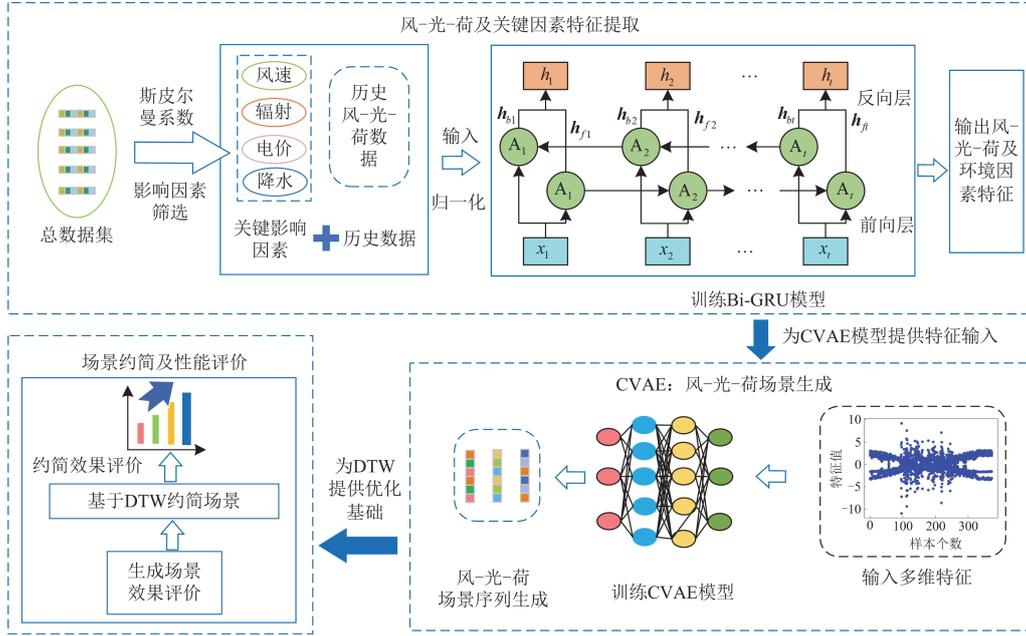


图 1 风-光-荷联合场景生成框架

Fig. 1 Integrated scenario generation framework for wind, photovoltaic, and load systems

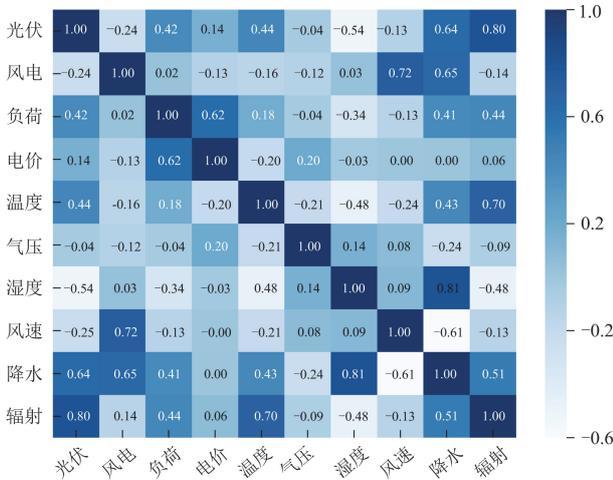


图 2 斯皮尔曼相关系数图

Fig. 2 Spearman correlation coefficients

由图 2 可知, 按照斯皮尔曼相关系数划分, 相关系数绝对值在[0.6, 1]区间内表示变量间存在较强的相关性。因此本文选取风速、电价、辐射、降水作为影响风-光-荷的关键环境因素, 以进一步分析其与风-光-荷时序数据间的关系。

2.2 基于 Bi-GRU 的多维时序影响因素特征提取

传统线性降维方法(如 PCA、离散傅里叶变换)难以有效捕捉如风速-风电、辐射-光伏等非线性耦

合关系, 而单向 GRU/LSTM 无法利用未来时序信息, 导致特征提取不完整。Bi-GRU 能够同时处理多维时序输入(如风电、光伏、负荷、风速、辐射、电价等), 并在特征提取中考虑变量间的交互作用, 从而更好地捕捉数据中的复杂模式。因此, 本文采用 Bi-GRU 进行非线性耦合特征的提取。

Bi-GRU 算法分为输入层、Bi-GRU 层和输出层。输入层接收预处理后的时间窗口数据, 维度是 24×7 , 分别代表一天中的 24 个时段和 7 个特征(风电、光伏、负荷、风速、电价、辐射、降水)。为增强特征提取能力, 将两个方向独立且叠加的 GRU 网络构成 Bi-GRU, 其结构如图 3 所示。

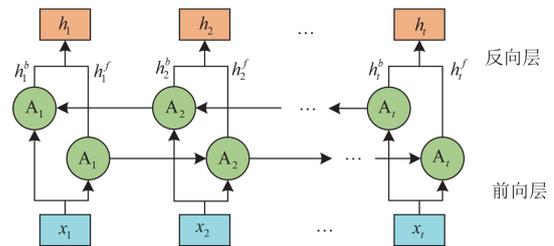


图 3 Bi-GRU 结构图

Fig. 3 Bi-GRU structure diagram

Bi-GRU 层具体函数为^[35]

$$R_t = \sigma(W_r \cdot x_t + U_r \cdot h_{t-1} + b_r) \quad (1)$$

$$Z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (2)$$

$$\tilde{h}_t = \tanh(W \cdot [R_t \odot h_{t-1}, x_t]) \quad (3)$$

$$h_t = Z_t \odot \tilde{h}_t + (1 - Z_t) \odot h_{t-1} \quad (4)$$

式中： R_t 表示重置门，可以在计算当前状态时忽略非相关特征，如风电和电价； σ 表示 sigmoid 函数； W_r 、 U_r 表示权重矩阵； x_t 表示输入的数据； b_r 表示偏置； Z_t 表示更新门，决定了从过去时间步中保留多少风电量和负荷等变化信息； W_z 表示拼接后向量对应的权重矩阵； \tilde{h}_t 表示候选隐藏状态，它结合了当前时间步的重要信息； W 表示对应输入和隐藏状态拼接后的权重矩阵； h_t 表示最终隐藏状态； h_{t-1} 表示上一时刻隐藏状态。

Bi-GRU 前向层捕捉风-光-荷历史数据关系，反向层学习未来气象数据，适用于处理风电-风速的滞后效应。通过 Adam 优化算法迭代更新权重矩阵(输入到隐藏层、更新门等)，并结合误差迭代技术将特征偏差控制在 0.1 以内。在处理辐射与光伏出

力的非线性饱和特性时，Bi-GRU 的隐藏状态能保留更多高频特征。

在训练和前向传播过程中，Bi-GRU 层的权重矩阵通过 Adam 优化算法进行迭代更新，确保模型提取出的风-光-荷数据及关键环境因素的多维时序特征更加精准。

2.3 考虑复杂环境耦合的风-光-荷场景生成

特征提取完成后，进入场景生成阶段。传统方法未引入环境条件变量，需为风速、辐射等因素建立独立物理模型，难以反映“源-荷-环境”交互机制。本文引入多环境因素输入，并通过 CVAE 精准捕捉风-光-荷与环境间的时序耦合关系，将环境因素作为条件变量，学习其与源荷之间的隐式映射。

在 CVAE 中，环境特征同时影响编码器的潜在表示和解码器的场景生成，其结构主要包括编码器、与解码器，如图 4 所示。

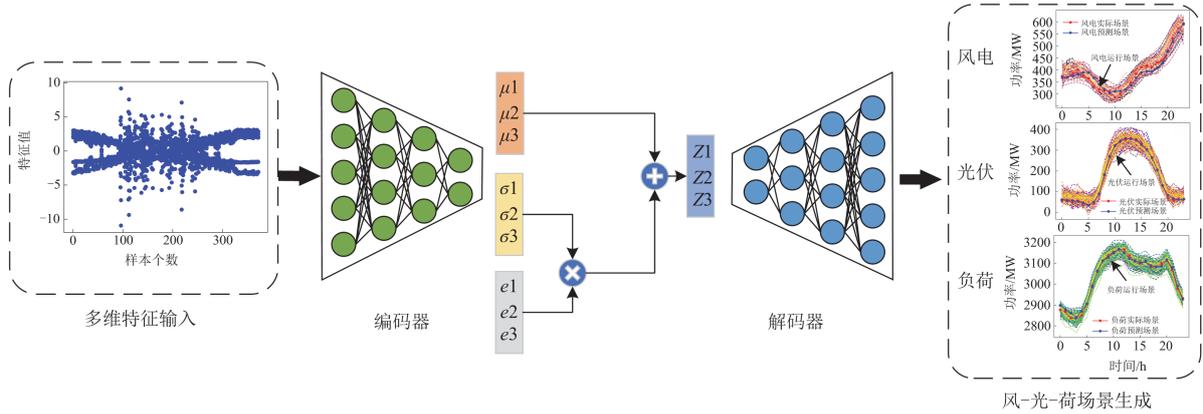


图 4 CVAE 结构图

Fig. 4 CVAE structure diagram

CVAE 中的编码器负责将输入数据 x 转换成潜在空间中的表示，即潜在变量 z 的分布参数。

CVAE 的损失函数主要由两部分组成：重构损失和 KL 散度损失^[36]。

将重构损失和 KL 散度损失整合，如式(5)所示。

$$L_{CVAE} = E_{q(z|x,c)}[\log(x|z,c)] - \text{KL}(q(z|x,c) \| p(z|c)) \quad (5)$$

式中： L_{CVAE} 表示损失函数； $E_{q(z|x,c)}[\cdot]$ 表示重构损失，用于衡量解码器性能； $\log(x|z,c)$ 表示对输入数据 x 的对数似然估计， x 表示输入变量， z 表示潜在变量， c 表示作为条件输入的关键环境因素向量； $\text{KL}(\cdot)$ 表示 KL 散度； $q(z|x,c)$ 表示编码后的潜在变量的分布； $p(z|c)$ 表示预设的先验分布。

CVAE 将环境因素(如风速、降水)作为条件变

量 c ，通过编码器将输入数据 x 映射为潜在变量 z 的分布，解码器利用 z 和 c 生成场景。其损失函数新增的条件 KL 散度项强制潜在分布与先验分布一致，确保生成场景在不同环境条件下的多样性。

2.4 基于 DTW 算法的风-光-荷场景约简

生成场景后，进行场景约简以选取代表性场景替代完整数据集，并确保场景集合准确反映风-光-荷的时序特征。

DTW 算法通过动态规划调整时间匹配，允许局部伸缩或平移，能更准确地度量存在相位差异但形态相似的序列，避免严格时间点匹配造成的误判，因此本文采用 DTW 算法进行场景约简。

DTW 算法中，首先假定两个一维时序数据风-光-荷实际功率曲线 w 和风-光-荷生成功率曲线 y ，计算出 w 和 y 之间的距离矩阵 D ^[25]，如式(6)所示。

$$\mathbf{D} = \begin{bmatrix} d(1,1) & d(1,2) & \cdots & d(1,j) \\ d(2,1) & d(2,2) & \cdots & d(2,j) \\ \vdots & \vdots & & \vdots \\ d(i,1) & d(i,2) & \cdots & d(i,j) \end{bmatrix} \quad (6)$$

式中: $d(i, j)$ 表示第 1 个时间序列中第 i 个元素与第 2 个时间序列中第 j 个元素之间的距离, $d(i, j) = |w_a - w_b|$, w_a 、 w_b 分别是两个时间序列对应位置的元素。

其次, 利用递归的方法来求解最短路径距离, 如式(7)所示。

$$\gamma(i, j) = d(i, j) + \min(d(i-1, j), d(i, j-1), d(i-1, j-1)) \quad (7)$$

式中: $\gamma(i, j)$ 表示从坐标 (1,1) 到坐标 (i, j) 的最短路径距离。

然后, 寻找并确定最短路径, 进而计算两个一维数据的 DTW, 如式(8)所示。

$$U(w, y) = \min \sum d(i, j) \quad (8)$$

式中: $U(w, y)$ 表示两个时间序列 w 与 y 之间的 DTW 距离。

2.5 风-光-荷场景质量评价指标

本文选取爬坡相似度、时间自相关性、场景覆盖率和场景宽度 4 个指标, 综合评估生成场景在复现实际功率场景方面的性能^[37], 确保生成的场景能够充分反映风-光-荷的波动性和非线性。各类指标含义及计算方式如下。

1) 爬坡相似度

爬坡相似度 P_{clim} 指标展现了生成场景与实际场景在功率爬坡特征上的匹配程度, 该值越低, 表明生成场景的功率爬坡特性与实际更为吻合、更符合实际变化。

$$P_{\text{clim}} = \frac{1}{N_t - 1} \sum_{t=1}^{N_t-1} \sum_{s=1}^{N_s} |A_{\text{real}, t, t+1} - A_{s, t, t+1}| \quad (9)$$

式中: N_t 为时间点的数量; N_s 为生成场景总个数; $A_{\text{real}, t, t+1}$ 为生成的风-光-荷场景 t 到 $t+1$ 时刻的爬坡功率差值; $A_{s, t, t+1}$ 为第 s 个生成风-光-荷场景 t 到 $t+1$ 时刻的爬坡功率差值。

2) 时间自相关性

风-光-荷功率受关键因素影响, 各时刻出力存在一定相关性。可借助生成场景自相关系数^[33]的动态变化特性来评估场景在时间维度上的有效性, 如式(10)所示。

$$\rho(\zeta) = \frac{E[(P_t - \mu)(P_{t+\zeta} - \mu)]}{\sigma^2} \quad (10)$$

式中: $\rho(\zeta)$ 表示自相关系数, ζ 是时间间隔; $E[\cdot]$

代表数学期望; P_t 是场景 t 时刻的功率值; μ 是 P_t 的均值; σ^2 是 P_t 的方差。

3) 场景覆盖率

场景覆盖率 C 反映了生成场景对实际功率分布的覆盖程度, 其值越高, 表明越能充分体现生成场景的波动性。其具体的表达式为

$$C = \frac{1}{N_t} \sum_{t=1}^{N_t} B_t \quad (11)$$

式中: B_t 是 0-1 变量。如果风-光-荷场景功率值在生成场景的最大值与最小值之间, 则 $B_t = 1$, 否则 $B_t = 0$ 。

4) 场景宽度

场景宽度 W 衡量了生成场景集合内各场景的最大功率差异, 宽度较小意味着生成场景在较窄的数值范围内概括实际场景。 W 具体的计算公式为

$$W = \max_{s, l \in S} (\max_{t \in [1, N_t]} |P_{s,t} - P_{l,t}|) \quad (12)$$

式中: S 是生成风-光-荷场景集合; $P_{s,t}$ 、 $P_{l,t}$ 分别是生成风-光-荷场景 s 、 l 在 t 时刻的功率值。

3 算例

本文采用中国北方某地区 2018 年 1 月 1 日至 2018 年 12 月 31 日的实测与日前预测数据, 采样间隔为 1 h, 即每日 24 点数据, 采样时间共 713 天。维度是 24×7 , 24 代表时间维度, 也就是一天的时段数, 7 代表特征数。特征包含风电、光伏、负荷、风速、电价、辐射和降水等。输入数据长度和输出数据长度为 24, 以 1 h 为步长循环截取数据, 从而形成实验数据集, 并分别按照 80% 与 20% 的比例将数据集划分为训练集与测试集。

实验平台硬件配置如下: 处理器采用 Intel(R) Core(TM) i7-12700 CPU, 内存容量为 16 GB。软件为 Windows11 环境下安装的 Pytorch 库, 编程语言为 Python。

3.1 模型预处理

实际采集的风、光、荷及环境数据可能因传感器故障、传输干扰等原因存在噪声或异常值。因此, 须通过系统的数据预处理流程进行修正, 同时不同类型数据的量纲和取值范围差异较大, 通过归一化可消除量纲影响, 本文借助文献[38]中的数据修正方法对初始数据实施清洗操作, 再对数据展开归一化处理, 从而消除数据量纲所产生的影响, 归一化公式见附录 A 式(A1)。

3.2 模型参数设置

Bi-GRU 输入层接收归一化后的多维时序数据, 维度为 24×7 , 对应 24 个时段及风电、光伏、负荷、

风速、电价、辐射、降水共 7 个维度。全连接层将 Bi-GRU 输出的 24×256 维高阶特征压缩为 24×10 维的低维特征向量，输出层采用线性激活以保持特征尺度与原始数据一致。训练过程中，通过反向传播计算特征向量与真实数据的均方误差，若偏差超过阈值，则动态调整 Bi-GRU 隐藏状态权重，从而实现风-光-荷与环境因素动态耦合关系的精准表征。

编码器输入为 Bi-GRU 提取的 24×10 维特征向量以及风速、辐射、电价和降水 4 维关键环境因素；潜在空间采样环节从受环境条件约束的高斯分布中抽样生成 10 维潜在变量 z 。解码器采用三层反卷积网络结构，其输入为潜在变量 z 与环境条件的拼接向量，最终输出为 24 h 风-光-荷联合场景，包含风电、光伏、负荷 3 通道。

Bi-GRU 和 VAE 模型都是采用 Adam 优化算法对初始学习率、最大训练次数等超参数进行优化。模型参数如附录 A 表 A1 所示。

3.3 风-光-荷联合场景生成分析

Bi-GRU 的主要功能是从风-光-荷及其关键环境影响因素中提取多维的时间序列动态特征。在此过程中，Bi-GRU 不仅利用隐藏状态的更新机制实现数据降维，并借助特征压缩和噪声过滤提取出具有代表性的信息。在特征提取后，Bi-GRU 的倒数第二层隐藏状态被用作关键特征向量，该向量有效融合了各类影响因素的关键信息，并通过优化迭代过程确保其偏差控制在阈值范围内，进而为 CVAE 场景生成模型提供输入。

为进一步体现复杂环境因素对风-光-荷场景的影响，在 CVAE 的潜在空间中以风速、电价、辐射、降水为约束进行有针对性的采样。

1) 生成场景

利用训练完成的 CVAE 模型，生成 100 组风电场景、100 组光伏场景、100 组负荷场景。图 5—图 7 为 2018 年 5 月 23 日风-光-荷场景生成结果。结

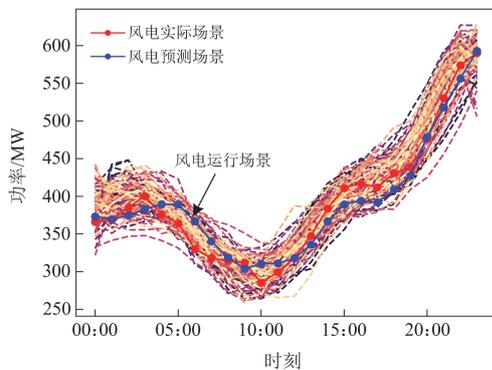


图 5 风电运行场景生成

Fig. 5 Wind power operation scenario generation

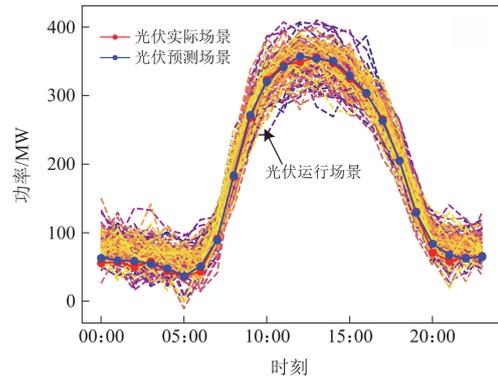


图 6 光伏运行场景生成

Fig. 6 Photovoltaic operation scenario generation

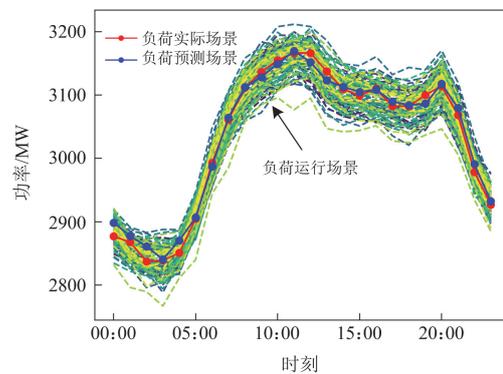


图 7 负荷运行场景生成

Fig. 7 Load operation scenario generation

合图 5—图 7 可知，生成的风-光-荷联合场景不存在明显的波动性，生成的场景能够较好地包含实测值。

2) 生成风-光-荷场景质量评价

为了验证本文方法的优越性，采用以下 4 种方案进行对比分析：方案 1，利用本文方法生成场景集；方案 2，不考虑多维时序数据特征的 CVAE 模型生成场景集；方案 3，不考虑复杂耦合环境的 CVAE 模型生成场景集；方案 4，采用一阶马尔可夫状态转移生成场景集。其中：方案 1、方案 2 可以用于验证多维时序特征的必要性；方案 1、方案 3 可以用于验证考虑环境耦合相关性的必要性；方案 1、方案 4 可以用于验证不同方法的性能。

在附录 A 图 A1 中，分别展示了采用方案 2、方案 3 和方案 4 生成的风-光-荷场景。方案 2 在场景生成方面与真实场景的切合度不够。方案 3 采用的是不考虑复杂耦合环境的 CVAE 模型，由于该方案没有充分考虑源-荷-环境之间多维时序影响因素的复杂交互关系，在场景生成呈现上与真实场景出现了较大程度的偏离。方案 4 生成的风-光-荷场景曲线表现出较多的波动。这种频繁的波动可能源于一阶马尔可夫状态转移方法难以精准捕捉环境因素

对源荷的多维耦合影响。

图 8 和附录 A 表 A2 展示了不同生成场景方案的爬坡相似度, 可以看到, 在风电场景中, 方案 4 的爬坡相似度为 11.94, 明显小于其他 3 种方案, 这可能是因为方案 4 在风电动态特性建模方面的能力较强。但值得注意的是, 在光伏和负荷场景中, 方案 1 的爬坡相似度分别是 12.57 和 12.31, 明显低于方案 2、方案 3 和方案 4。因此, 本文提出的方法在整体性能上依然具备显著优势。

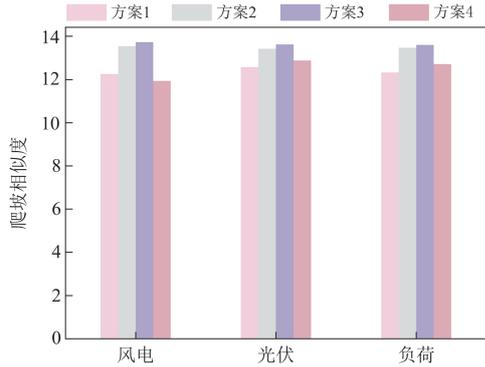


图 8 不同场景生成方案的爬坡相似度

Fig. 8 Climbing similarity of different scenario generation schemes

图 9 与附录 A 图 A2 展示了对 3 类场景集在不同滞后时间下的时间自相关性分布结果。从图中可以观察到, 方案 1 所生成场景的时间自相关性分布上下界范围更窄、集中度更高, 且其标准线分布更为均匀。这表明, 通过综合考虑多维时序特征与复杂环境耦合作用, 该方法能够更精确地捕捉风电场景中不同时刻数据间的时间依赖关系。相较于方案 2、方案 3 和方案 4, 方案 1 在时间自相关性建模方面表现出更优的准确性与实际拟合度, 其结果更贴近真实风电场景的时间分布特性。

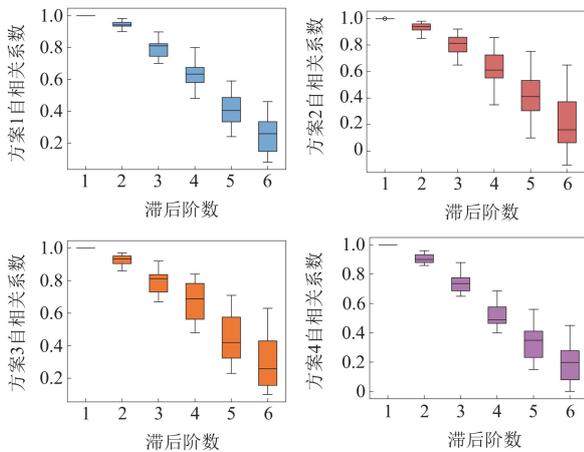


图 9 不同方案的风电时间自相关性

Fig. 9 Time autocorrelation of wind power of different schemes

由表 2 可知, 方案 1 和方案 4 的场景覆盖率均达到 100%, 说明这两种方案在相关能源场景覆盖上表现较好, 但本文所提出的方法在保持有效包络新能源预测场景与实际场景的同时, 实现了更小的场景宽度, 这表明方案 1 生成的场景更贴合风-光-荷联合场景的实际情况。方案 2 和方案 3 中, 风电、光伏和负荷的场景宽度均高于其他两种方案, 这表明相较于不同场景生成方法, 多维时序特征和复杂耦合环境因素对场景宽度的影响更为显著。

表 2 不同方案的评价对比

Table 2 Evaluation comparison of different schemes

方案	风电		光伏		负荷	
	C/%	W/MW	C/%	W/MW	C/%	W/MW
1	100	136.99	100	143.75	100	139.27
2	95.58	209.52	100	198.66	91.66	217.98
3	87.5	231.31	85.33	258.92	88.64	251.51
4	100	185.10	100	188.05	100	184.65

3.4 风-光-荷场景约简

基于 DTW 算法对生成的风电、光伏和负荷时序场景进行约简, 取和预测曲线相似度前 10% 的场景为约简的场景。为评估约简效果, 引入 K-means 和 K-medoids 聚类算法对时序场景进行约简, 并对比分析了 DTW、K-means 和 K-medoids 聚类算法的约简质量。

根据图 10 及附录 A 表 A3 可知, 在场景相似度的分析中, 应用 DTW 算法后的风电、光伏及负荷场景的爬坡相似度则分别为 12.42、12.58 和 12.33。相较之下, K-means 和 K-medoids 聚类算法得到的各项评价指标均不如 DTW 算法。这表明本文方法在提升爬坡相似度方面具有更卓越的性能。

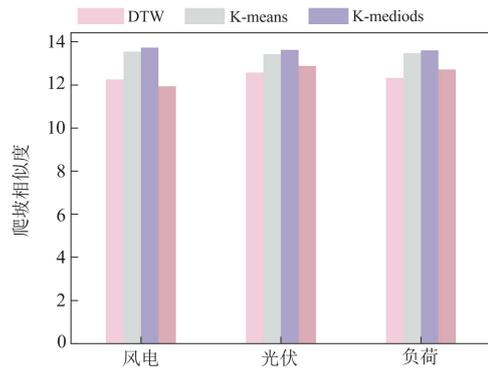


图 10 不同约简方法的爬坡相似度

Fig. 10 Climbing similarity of different reduction methods

图 11 展示了不同约简方法生成场景的时间自相关性。结合图 11 与附录 A 图 A3, 基于箱线图分析可知, DTW 算法约简后的场景相较 K-means 和

K-medoids 聚类算法优势显著。从数据集中趋势看, DTW 算法约简场景数据分布更紧密, 能有效将数据集中于代表性区间, 表达时间自相关性特征。且其数据呈对称分布, 时间序列变化规律均衡, 无明显偏态。

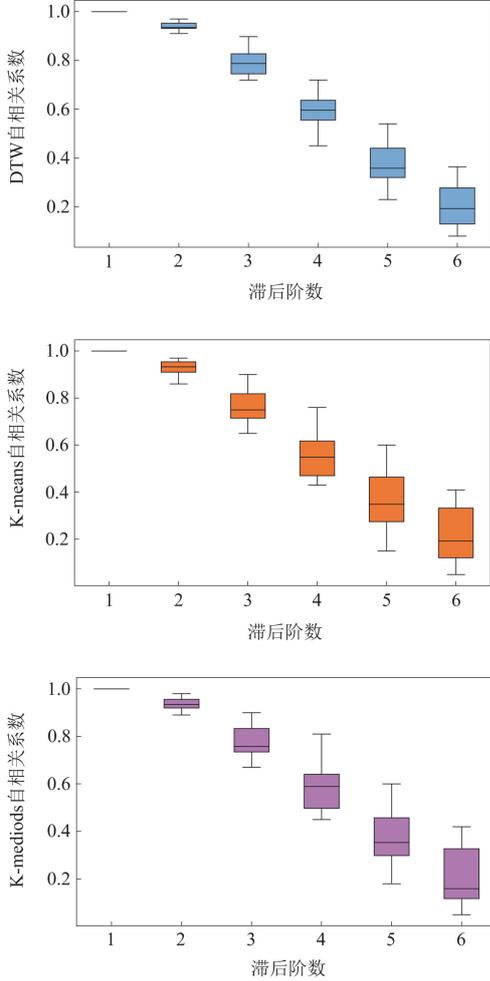


图 11 不同约简方法的风电时间自相关性
Fig. 11 Wind power time autocorrelation with different reduction methods

表 3 中, 方案 1 是 DTW 算法场景约简方案, 方案 2 和方案 3 分别是 K-means、K-medoids 聚类算法约简方案。根据表 3 的数据分析, 本文的约简算法所获得的风-光-荷场景覆盖率指标值分别为 91.47%、

表 3 不同约简方法场景评价对比

Table 3 Comparison of scenarios evaluation of different reduction methods

方案	风电		光伏		负荷	
	C/%	W/MW	C/%	W/MW	C/%	W/MW
1	91.47	58.41	95.46	63.24	93.83	68.38
2	89.86	100.45	90.35	110.62	86	107.36
3	92.67	80.41	93.47	87.66	92.68	83.87

95.46%和 93.83%, 风电的场景宽度是 58.41 MW, 光伏的场景宽度是 63.24 MW, 负荷的场景宽度是 68.38 MW, 相较于 K-means、K-medoids 聚类算法, 通过 DTW 算法进行场景约简得到的时序场景在覆盖实际场景方面和场景宽度方面更贴合实际情况。

4 结论

本文提出了一种考虑源-荷-环境多维影响因素耦合的风-光-荷联合场景生成方法, 通过“特征提取-概率建模-场景优化”的技术路径构建联合场景生成模型。通过算例分析, 得出以下结论。

1) 针对多维强时序耦合特征提取的难题, 提出了基于 Bi-GRU 的特征提取方法。Bi-GRU 凭借其双向结构能够同时捕捉历史与未来信息对当前状态的影响, 有效处理了风-光-荷及环境因素之间复杂的双向时序依赖关系, 提升了模型对风-光-荷动态时序变化的表征能力。

2) 针对环境因素与风-光-荷之间复杂概率耦合关系的建模问题, 提出了基于 CVAE 的场景生成方法。该方法以关键环境因素为条件, 通过概率建模不仅保持了环境因素与风-光-荷之间的时序耦合特性, 同时确保了生成场景的多样性及其与输入环境条件之间的严格相关性。实验结果表明, 在复杂环境耦合条件下, CVAE 所生成的风-光-荷联合场景更符合实际运行特征。

3) 针对场景约简过程中保持时序形态一致性的问题, 提出了基于 DTW 算法的场景约简方法, 该方法克服了 K-means、K-medoids 聚类算法对时间序列伸缩与相位差异敏感的局限性。算例对比分析表明, DTW 算法在爬坡相似度、场景覆盖率、场景宽度以及时间自相关性保持等方面, 综合性能均优于 K-means 和 K-medoids 聚类算法, 所得到的约简场景集能够更准确地反映原始场景集的典型波动特征, 有效保持了风-光-荷时序形态的一致性。

未来该研究可应用于智能电网领域, 通过该方法能够生成贴合实际运行状况的场景, 为电网的动态规划、实时调度提供更精准的决策支撑, 提升电网对高比例可再生能源的接纳能力。

附录 A

归一化表达式为

$$x' = \frac{x - \min(X)}{\max(X) - \min(X)} \quad (A1)$$

式中: x' 为特征的归一化值; x 为特征 X 的单个样本值; $\min(X)$ 表示特征 X 的最小值; $\max(X)$ 表示特征 X 的最大值。

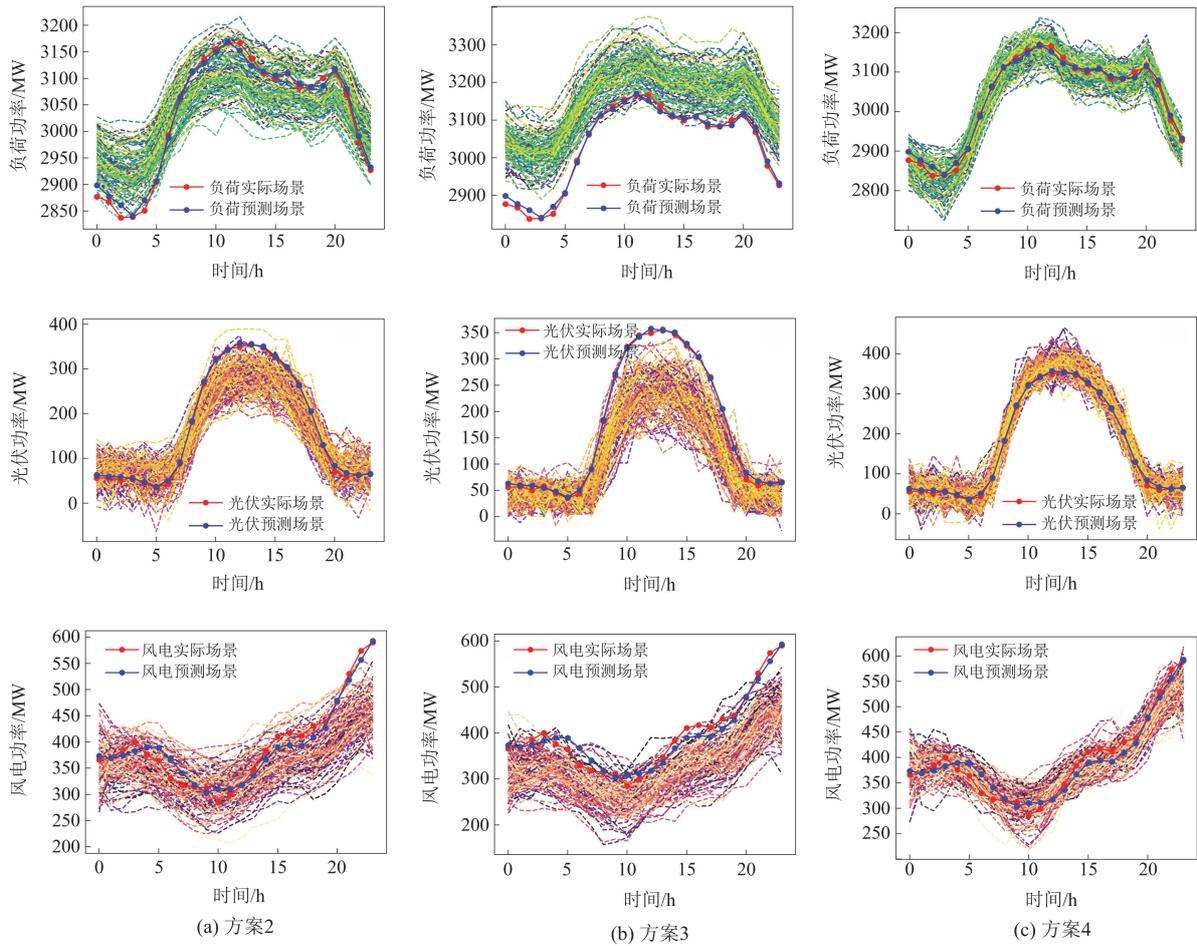


图 A1 不同方案生成的场景

Fig. A1 Scenarios generated by different schemes

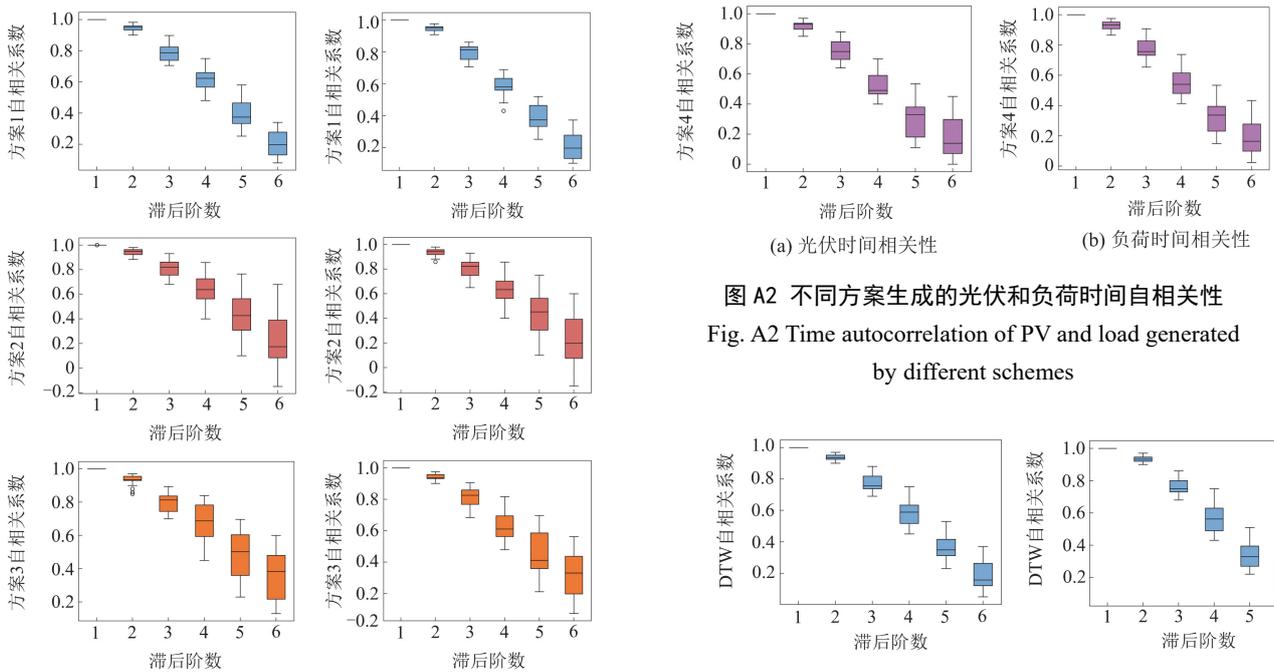


图 A2 不同方案生成的光伏和负荷时间自相关性
Fig. A2 Time autocorrelation of PV and load generated by different schemes

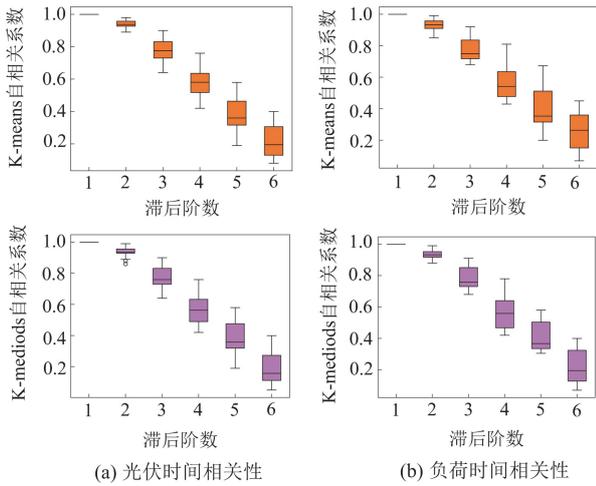


图 A3 不同方案约简的光伏和负荷时间自相关性
Fig. A3 Reduced PV and load time autocorrelation of different schemes

表 A1 模型基本参数

Table A1 Basic parameters of the model

Bi-GRU 参数	参数值	CVAE 参数	参数值
双向 GRU 神经元数	128	迭代误差	0.05
迭代误差	0.1	编码特征维度	10
全连接层神经元数	64	训练批量大小	200
全连接层激活函数	Relu	编码层数	3
特征偏差阈值	0.1	潜在空间维度	10
早停机制轮次	10	KL 散度权重	0.5
输出层激活函数	线性激活	编码层激活函数	Relu
全连接层数	3	解码层激活函数	sigmoid

表 A2 不同生成方法的爬坡相似度

Table A2 Climbing similarity of different generation methods

方案	$P_{c\lim}$		
	风电	光伏	负荷
1	12.25	12.57	12.31
2	13.54	13.42	13.47
3	13.73	13.62	13.60
4	11.94	12.88	12.71

表 A3 不同约简方法的爬坡相似度

Table A3 Climbing similarity of different reduction methods

方案	$P_{c\lim}$		
	风电	光伏	负荷
DTW	12.42	12.58	12.33
K-means	13.21	13.26	13.68
K-medoids	13.05	12.88	12.95

参考文献

[1] 陈艳波, 王德帅, 田昊欣, 等. 基于源荷储协调运行的电网可用输电能力优化方法[J]. 电力系统保护与控制, 2024, 52(23): 119-134.

CHEN Yanbo, WANG Deshuai, TIAN Haoxin, et al. An optimal method for the available transfer capability of a power grid based on coordinated operation of source-load-storage[J]. Power System Protection and Control, 2024, 52(23): 119-134.

[2] WANG T, HUANG Z, YING R, et al. A low-carbon operation optimization method of ETG-RIES based on adaptive optimization spiking neural P systems[J]. Protection and Control of Modern Power Systems, 2024, 9(5): 162-177.

[3] 何方, 张琦立, 魏书荣, 等. 考虑并网灵活性的大规模海上风电场集群接入系统规划研究[J]. 智慧电力, 2024, 52(9): 33-40.

HE Fang, ZHANG Qili, WEI Shurong, et al. Planning of large-scale offshore wind farm cluster access system considering grid-connected flexibility[J]. Smart Power, 2024, 52(9): 33-40.

[4] 吴俊, 薛禹胜. 大规模可再生能源接入下的电力系统充裕性优化: (三)多场景的备用优化[J]. 电力系统自动化, 2019, 43(11): 1-7.

WU Jun, XUE Yusheng. Adequacy optimization for a large-scale renewable energy integrated power system part three reserve optimization in multiple scenarios[J]. Automation of Electric Power Systems, 2019, 43(11): 1-7.

[5] HOU Q, DU E, ZHANG N, et al. Impact of high renewable penetration on the power system operation mode: a data-driven approach[J]. IEEE Transactions on Power Systems, 2020, 35(1): 731-741.

[6] 焦治杰, 王小君, 刘墨, 等. 考虑分布式新能源出力不确定性的虚拟电厂概率可行域构建方法[J]. 电力系统自动化, 2024, 48(18): 129-138.

JIAO Zhijie, WANG Xiaojun, LIU Zhao, et al. Construction method for probability-based feasible region of virtual power plant considering uncertainty of distributed renewable energy output[J]. Automation of Electric Power Systems, 2024, 48(18): 129-138.

[7] MOTLAGH O, BERRY A, O'NEIL L. Clustering of residential electricity customers using load time series[J]. Applied Energy, 2019, 237: 11-24.

[8] 张亚丽, 王聪, 张宏立, 等. 基于非平稳 Transformer 的超短期风电功率多步预测[J]. 智慧电力, 2024, 52(1): 108-115.

ZHANG Yali, WANG Cong, ZHANG Hongli, et al. Multi-step prediction of ultra-short-term wind power based on non-stationary transformer[J]. Smart Power, 2024, 52(1): 108-115.

[9] 刘岩, 王玉君, 杨晓坤, 等. 基于 KPCA 和 XGBoost 算

- 法的非侵入式负荷辨识方法[J]. 电测与仪表, 2024, 61(5): 71-77.
- LIU Yan, WANG Yujun, YANG Xiaokun, et al. Non-intrusive load identification method based on KPCA and XGBoost algorithm[J]. *Electrical Measurement & Instrumentation*, 2024, 61(5): 71-77.
- [10] ZHONG S, TAM K S. Hierarchical classification of load profiles based on their characteristic attributes in frequency domain[J]. *IEEE Transactions on Power Systems*, 2014, 30(5): 2434-2441.
- [11] 李虹, 韩雨萌. 基于 LSTM-CGAN 的多微网数据驱动分布鲁棒协同优化运行策略[J]. 电力系统保护与控制, 2024, 52(18): 133-148.
- LI Hong, HAN Yumeng. Data-driven distributionally robust collaborative optimization operation strategy for a multi-microgrid based on LSTM-CGAN[J]. *Power System Protection and Control*, 2024, 52(18): 133-148.
- [12] 吴艳梅, 陈红坤, 陈磊, 等. 基于改进 MMD-GAN 的可再生能源随机场景生成[J]. 电力系统保护与控制, 2024, 52(19): 85-96.
- WU Yanmei, CHEN Hongkun, CHEN Lei, et al. Stochastic scenario generation for renewable energy based on improved MMD-GAN[J]. *Power System Protection and Control*, 2024, 52(19): 85-96.
- [13] DOO W, KIM H. Simultaneous deep clustering and feature selection via K-concrete autoencoder[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 36(6): 2629-2642.
- [14] 王勃, 冯双磊, 刘纯. 基于天气分型的风电功率预测方法[J]. 电网技术, 2014, 38(1): 93-98.
- WANG Bo, FENG Shuanglei, LIU Chun. Study on weather typing based wind power prediction[J]. *Power System Technology*, 2014, 38(1): 93-98.
- [15] 韩晓, 王涛, 韦晓广, 等. 考虑阵列间时空相关性的超短期光伏出力预测[J]. 电力系统保护与控制, 2024, 52(14): 82-94.
- HAN Xiao, WANG Tao, WEI Xiaoguang, et al. Ultrashort-term photovoltaic output forecasting considering spatiotemporal correlation between arrays[J]. *Power System Protection and Control*, 2024, 52(14): 82-94.
- [16] ZHU S, MA H, CHEN L, et al. Short-term load forecasting of an integrated energy system based on STL-CPLE with multitask learning[J]. *Protection and Control of Modern Power Systems*, 2024, 9(6): 71-92.
- [17] 黄南天, 王文婷, 蔡国伟, 等. 计及复杂气象耦合特性的模块化去噪变分自编码器多源-荷联合场景生成[J]. 中国电机工程学报, 2019, 39(10): 2924-2934.
- HUANG Nantian, WANG Wenting, CAI Guowei, et al. The joint scenario generation of multi source-load by modular denoising variational autoencoder considering the complex coupling characteristics of meteorology[J]. *Proceedings of the CSEE*, 2019, 39(10): 2924-2934.
- [18] CHEN L, ZHANG H, WU Q, et al. A numerical approach for hybrid simulation of power system dynamics considering extreme icing events[J]. *IEEE Transactions on Smart Grid*, 2017, 9(5): 5038-5046.
- [19] WANG X, LIU X, ZHONG F, et al. A scenario generation method for typical operations of power systems with PV integration considering weather factors[J]. *Sustainability*, 2023, 15(20).
- [20] 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.
- [21] 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.
- [22] 余洋, 陆文韬, 陈东阳, 等. 光伏波动平抑下改进 K-means 的电池储能动态分组控制策略[J]. 电力系统保护与控制, 2024, 52(7): 1-11.
- YU Yang, LU Wentao, CHEN Dongyang, et al. Dynamic grouping control strategy for battery energy storage based on improved K-means under photovoltaic fluctuation smoothing[J]. *Power System Protection and Control*, 2024, 52(7): 1-11.
- [23] 于唯一, 王慧芳, 曹芬, 等. 考虑场景缩减和动态寿命的用户侧新能源配储研究[J]. 电测与仪表, 2024, 61(9): 127-136.
- YU Weiyi, WANG Huifang, CAO Fen, et al. Research on user-side energy storage configuration for renewable energy considering scenario reduction and dynamic lifetime[J]. *Electrical Measurement & Instrumentation*, 2024, 61(9): 127-136.
- [24] YU Yang, LIU Mai, CHEN Dongyang, et al. Dynamic grouping control of electric vehicles based on improved k-means algorithm for wind power fluctuations suppression[J]. *Global Energy Interconnection*, 2023, 6(5): 542-553.
- [25] CHEN Y, ZHOU L, PEI S, et al. KNN-BLOCK DBSCAN: fast clustering for large-scale data[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*,

- 2019, 51(6): 3939-3953.
- [26] HUANG X, MA T, LIU C, et al. GriT-DBSCAN: a spatial clustering algorithm for very large databases[J]. Pattern Recognition, 2023, 142.
- [27] YU D, LIU G, GUO M, et al. An improved K-medoids algorithm based on step increasing and optimizing medoids[J]. Expert Systems with Applications, 2018, 92: 464-473.
- [28] LIU L, HU X, CHEN J, et al. Embedded scenario clustering for wind and photovoltaic power, and load based on multi-head self-attention[J]. Protection and Control of Modern Power Systems, 2024, 9(1): 122-132.
- [29] 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]. 电网技术, 2022, 46(2): 671-681. ZHANG Chenyu, XU Gang. Distributed multivariate random dynamic scenario generation and fast & accurate scenario simplified algorithm[J]. Power System Technology, 2022, 46(2): 671-681.
- [30] 薛展豪, 陈力, 林志颖, 等. 基于双向长短期记忆生成对抗网络的电力系统次同步振荡数据生成方法[J]. 智慧电力, 2024, 52(5): 60-66. XUE Zhanhao, CHEN Li, LIN Zhiying, et al. Subsynchronous oscillation data generation method of power system based on bidirectional long short term memory generative adversarial network[J]. Smart Power, 2024, 52(5): 60-66.
- [31] 王光华, 张纪欣, 崔良, 等. 基于双重注意力变换模型的分布式屋顶光伏变电站级日前功率预测[J]. 全球能源互联网, 2024, 7(4): 393-405. WANG Guanghua, ZHANG Jixin, CUI Liang, et al. Substation-level distributed rooftop photovoltaic power day-ahead prediction based on double attention mechanism transformer model[J]. Journal of Global Energy Interconnection, 2024, 7(4): 393-405.
- [32] 钟声, 李晓洋, 梁胜乐, 等. 基于线圈电流信号及动态时间规整的高压断路器状态评估方法[J]. 高压电器, 2023, 59(4): 24-31. ZHONG Sheng, LI Xiaoyang, LIANG Shengle, et al. Condition assessment method on high voltage circuit breaker based on coil current signal and dynamic time warping[J]. High Voltage Apparatus, 2023, 59(4): 24-31.
- [33] 庄颖睿, 程林, 齐宁, 等. 基于深度时间聚类的微电网典型场景生成方法[J]. 电力系统自动化, 2023, 47(20): 95-103. ZHUANG Yingrui, CHENG Lin, QI Ning, et al. Typical scenario generation algorithm for microgrid based on deep temporal clustering[J]. Automation of Electric Power Systems, 2023, 47(20): 95-103.
- [34] 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.
- [35] 徐俊俊, 程奕凌, 张腾飞, 等. 计及充电行为特征与可调性的电动汽车集群优化调度[J]. 电力系统自动化, 2023, 47(23): 23-32. XU Junjun, CHENG Yiling, ZHANG Tengfei, et al. Optimized scheduling of electric vehicle clusters considering characteristics and adjustability of charging behavior[J]. Automation of Electric Power Systems, 2023, 47(23): 23-32.
- [36] 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.
- [37] 唐锦, 张书怡, 吴秋伟, 等. 基于Copula函数与等概率逆变换的风电出力场景生成方法[J]. 电力工程技术, 2021, 40(6): 86-94. TANG Jin, ZHANG Shuyi, WU Qiuwei, et al. Wind power output scenario generation method based on Copula function and equal probability inverse transformation[J]. Electric Power Engineering Technology, 2021, 40(6): 86-94.
- [38] 沈小军, 付雪姣, 周冲成, 等. 风电机组风速-功率异常运行数据特征及清洗方法[J]. 电工技术学报, 2018, 33(14): 3353-3361. SHEN Xiaojun, FU Xuejiao, ZHOU Chongcheng, et al. Characteristics of outliers in wind speed-power operation data of wind turbines and its cleaning method[J]. Transactions of China Electrotechnical Society, 2018, 33(14): 3353-3361.

收稿日期: 2025-02-27; 修回日期: 2025-08-27

作者简介:

杨大坤(2000—), 男, 硕士研究生, 研究方向为电力系统调度技术; E-mail: 23126382@bjtu.edu.cn

张大海(1973—), 男, 通信作者, 博士, 教授, 博士生导师, 研究方向为智能电网、继电保护与电能质量等。

E-mail: dhzhang1@bjtu.edu.cn

(编辑 周金梅)