

DOI: 10.19783/j.cnki.pspc.241042

考虑可分解多尺度时序特征融合的规划态光荷联合场景生成

黎子律, 王星华, 伏辰阳, 刘希贤, 黄祥源, 赵卓立

(广东工业大学自动化学院, 广东 广州 510006)

摘要: 针对高渗透率可再生能源并网与源荷出力不确定性导致配电网中长期规划偏离实际的问题, 提出一种考虑时序特征分解的规划态源荷联合场景生成方法。首先, 基于局部加权散点平滑法的季节和趋势分解(seasonal and trend decomposition using LOESS, STL)将光荷时间序列数据分解为平滑且具有不同特征的周期分量、趋势分量和残差分量。其次, 利用 TimeMixer 深度学习模型预测规划年份的周期分量和趋势分量, 该模型可以捕捉不同尺度下的时域信息, 进一步聚合微观周期和宏观趋势信息。同时, 针对具有随机性和不确定性的残差分量, 采用时序变化的 Copula 相关性建模方法表征历史光荷相关特性。然后, 结合分量预测结果生成规划态光-荷联合场景, 并利用多种聚类方法生成典型场景进行分析。最后, 以比利时地区 Elia 电力运营商提供的光荷一体数据进行算例仿真, 验证所提方法能生成考虑未来增长变化的规划场景, 有效提升场景精度。

关键词: 规划场景; 时间序列分解; TimeMixer; Copula; 联合场景

Planning-state PV-load joint scenario generation considering decomposable multi-scale temporal feature fusion

LI Zilü, WANG Xinghua, FU Chenyang, LIU Xixian, HUANG Xiangyuan, ZHAO Zhuoli
(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: To address the deviation between medium- and long-term distribution network planning and actual conditions caused by high penetration of renewable energy and the uncertainty of source-load output, a planning-state source-load joint scenario generation method considering temporal feature decomposition is proposed. First, the seasonal and trend decomposition using LOESS (STL) method is used to decompose photovoltaic (PV)-load time series data into periodic, trend, and residual components, each with distinct characteristics. Next, the TimeMixer deep learning model is employed to forecast the seasonal and trend components for the planning year. This model captures temporal information across multiple scales and effectively integrates micro-periodic patterns with macro-trend information. Meanwhile, for the residual components, which contain random and unpredictable features, a time-varying Copula dependence modeling method is adopted to characterize the historical PV-load correlation. By combining the forecasted components, PV-load joint scenarios are generated, and various clustering methods are applied to representative scenarios for analysis. Finally, a case study using integrated PV-load data from Belgium's Elia operator verifies that the proposed method can generate planning scenarios that reflect future growth and significantly improve scenario accuracy.

This work is supported by the National Natural Science Foundation of China (No. 62273104).

Key words: planning scenarios; time series decomposition; TimeMixer; Copula; joint scenarios

0 引言

由于能源转型和“碳达峰、碳中和”目标的提出, 可再生能源在电力系统中的渗透率不断提高。在此背景下, 光伏发电作为重要的环境友好型清洁能源已全面进入规模化发展阶段, 成为电力行业发

展过程中的研究重点^[1-4]。有关光伏功率的不确定性影响, 目前配电网规划中的场景生成方法一般基于数据的历史特征和一定的增长比例确定源荷的未来变化趋势, 缺乏对源荷长期变化的准确描述, 难以适应源荷总功率的随机性和波动性, 无法合理确定中长期规划的边界条件^[5]。此外, 光伏与负荷在日内存存在一定的耦合特性, 为了更全面地刻画系统的运行状态, 需要在精确建模源荷长期变化的同时考

基金项目: 国家自然科学基金项目资助(62273104)

考虑其相关性, 并生成联合场景。因此, 需要能同时考虑光荷增长变化趋势和相关性的场景生成方法。

根据建模方法的不同, 场景生成方法可分为概率建模方法和深度学习方法。概率建模方法通过建立显式概率模型对数据随机过程进行拟合, 基于历史数据特征推导概率密度函数, 从而获得随机场景, 其具有复杂性低、可解释性高的特点, 可人为调控建模过程并还原历史中某些特定场景。马尔可夫链^[6-7]、高斯过程^[8]、自回归滑动平均^[9]等方法在电源与负荷功率特性建模领域得到了广泛应用。但概率模型的准确性受限于随机变量与所建模型的概率分布的一致性, 无法描述复杂的非线性关系。文献[10-11]引入 Copula 函数建立随机变量间的非线性依赖结构模型, 生成考虑源荷相关性的联合场景, 然而, 静态依赖结构模型难以准确刻画电源与负荷相关性在日内时间尺度上的动态变化特性, 因此不能模拟所有情况。

基于数据驱动的深度学习方法能拟合历史数据的高维非线性映射关系, 隐式表达随机变量的不确定性。文献[12]采用条件变分自动编码器(variational autoencoder, VAE)生成带有特定标签的符合观测特点的风光场景, 其能够通过训练样本标签使生成样本的概率分布逼近真实值。文献[13]通过条件生成对抗网络(conditional generative adversarial nets, CGAN)生成多风电场的短期出力场景, 通过添加预测数据作为条件信息以提高生成器生成场景与实际出力的相似度。现有深度学习方法能较好地拟合数据的历史分布特征, 但生成的场景没有考虑源荷的未来增长变化, 在中长期规划时间尺度下, 该方法的预测精度显著下降。

为解决源荷长期演化导致的出力水平增长问题, 本研究提出一种中长期规划场景生成方法。文献[14]根据历史数据得到典型场景均值, 并乘以一定负荷增长比例作为规划场景。文献[15]基于长短期记忆(long-short term memory, LSTM)网络采用历史年运行数据训练直接生成规划年的 8760 个预测点数据作为规划场景, 但模型精度不足, 没有充分考虑时间变化特征。文献[16]通过分析净负荷序列的分形特征, 提出基于分形插值算法的规划年典型场景生成方法, 但其更关注历史与未来典型场景的关系。

在源荷长期变化研究中, 不同时间尺度下长期(年)源荷时间序列会呈现出不同的时间变化特征, 而未来的变化是多个尺度特征的融合。例如在较小采样频率(如小时、天)下, 时间序列能展示出细节丰富的波动和短期周期性变化; 而在频率较大的时间尺度上(如周、月), 则更显现宏观的趋势和长期

周期性波动。如何有效提取此类多尺度时变特征是实现高精度长期时序场景建模的技术难点。文献[17]采用渐进式增长生成对抗网络生成逐月的负荷场景, 提出逐步训练不同分辨率的时间序列, 逐一输出分辨率从低到高的样本, 模型可以学习到由粗到细尺度的时域信息。对于捕获多尺度时序特征的更高级范式, 诸如基于时间卷积网络(temporal convolutional network, TCN)^[18]和基于 Transformer^[19]的模型在预测性能上得到了广泛认可。然而, 前者存在维度限制, 难以挖掘长期依赖关系; 后者引入自注意力机制提取复杂的时间模式, 但需要耗费大量计算资源, 限制了其在电力系统中的应用。因此, 文献[20]采用多层感知机(multilayer perceptron, MLP)建立长期气象数据和多尺度时序数据之间的关系, 但模型复杂度太低, 无法处理高维变量非线性。文献[21]提出一种 TimeMixer 多尺度混合架构, 在时序特征分析上实现双向的粗细尺度混合, 并在预测阶段通过多预测器将多尺度历史信息进行整合汇总, 使其具有整合混合多尺度序列的互补预测能力。TimeMixer 能够捕捉时间序列在不同时间尺度下的变化特征, 其完全基于 MLP 的架构能够实现接近于线性模型的高效率。此外, 源荷时间序列存在非平稳性、非线性和多周期性特征, 有不少研究利用滑动平均分解^[22]、经验模态分解^[23]、小波包分解^[24]等方法将时序分解为可预测的具有独立特征的子序列, 但可解释性较差, 无法表征分量特点与源荷不确定性的关系。

基于以上分析, 本文提出一种综合考虑时间序列分解下多时间尺度变化特征的规划态光荷场景生成方法, 主要内容如下: 1) 针对光伏和负荷数据中存在的混合了多种时序特征的问题, 采用基于局部加权散点平滑法的季节和趋势分解法(seasonal and trend decomposition using LOESS, STL)提取周期、趋势和残差分量, 并在此时序特征分解的框架上生成规划态光荷联合场景; 2) 提出一种基于多尺度时序特征融合的 TimeMixer 模型, 提取周期和趋势分量的长期变化信息并进行预测; 3) 采用时变 Copula 理论对反映不确定性信息的光荷残差分量进行相关性建模。最后联合分量预测和 Copula 模型模拟结果, 得到考虑未来增长变化和日内时间相关性的规划态光荷联合场景。通过算例仿真验证了所提方法的有效性。

1 基于时序特征分解的规划态场景生成思路

1.1 时间序列的 STL 分解

对于长时间跨度的光伏和负荷时间序列, 它们

的变化趋势受多方面因素的共同影响。首先由于天气等自然不确定因素以及生产活动规律，光伏和负荷时间序列呈现周期性波动；其次受到经济发展需要的影响，例如装机容量变化，其出力水平呈现出较为平缓的变化趋势；最后受不确定性因素影响，光伏出力呈现较大的波动性。不同特征混杂的原始序列对于模型训练来说十分困难。因此，基于分解预测的思想，本文首先利用 STL 分别将光伏和负荷序列分解为各自的周期分量、趋势分量和残差分量，其分解式表示为

$$y_t = S_t + T_t + R_t \quad (1)$$

式中： S_t 、 T_t 、 R_t 分别为 t 时刻的序列周期分量、趋势分量和残差分量； y_t 为原始序列。周期分量代表用电负荷或者光伏出力序列中的规律性部分；趋势分量代表时间序列中平滑的趋势线，波动幅度较小；残差分量代表由不确定性因素导致的细微变化。

STL 是一种使用局部加权回归法作为平滑方法的时间序列分解方法，其使用局部加权散点平滑法 (locally estimated scatterplot smoothing, LOESS) 来提取分量的平滑估计，实现不同成分的分离^[25]。算法基于内外循环双层结构，其中内循环对去趋势后的序列进行 LOESS 平滑操作，得到周期分量和趋势分量，外循环用于调节算法的鲁棒权重，降低异常值影响。算法流程如图 1 所示。

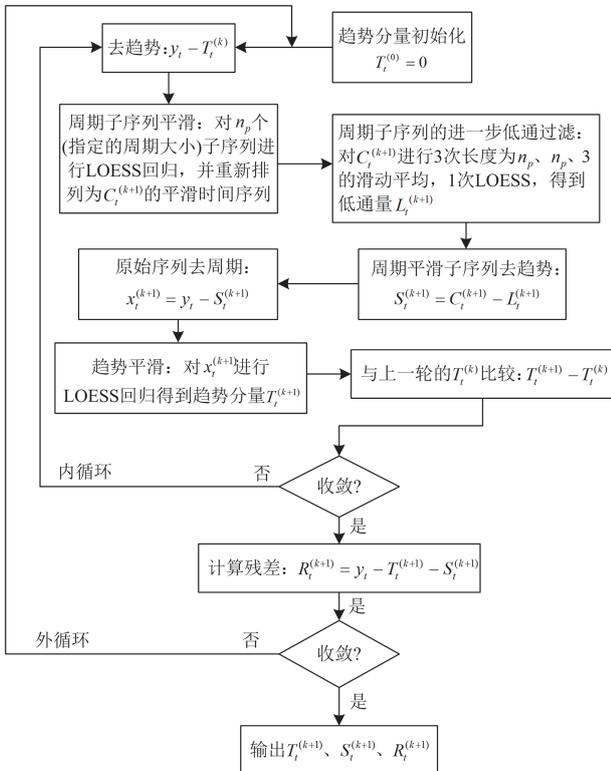


图 1 STL 分解算法流程图

Fig. 1 Flow chart of STL decomposition algorithm

STL 分解在外循环中基于残差项计算鲁棒权重，以更新内循环中 LOESS 回归的参数，将数据中的噪点分离在残差项，提高算法的鲁棒性。鲁棒性权重 ρ_t 通过 Bisquare 函数计算，具体表示为

$$\rho_t = B(\mu) = \begin{cases} (1 - \mu^2)^2, & 0 \leq \mu < 1 \\ 0, & \mu \geq 1 \end{cases} \quad (2)$$

$$\mu = \frac{|R_t|}{6 \text{median}(|R_t|)} \quad (3)$$

式中： $B(\mu)$ 为 Bisquare 函数； R_t 为残差分量； $\text{median}(\cdot)$ 为中位数计算函数。

1.2 总体框架

光伏和负荷时间序列分解后得到的分量具有更明显的变化规律。基于此，本文分别对光伏和负荷的周期分量和趋势分量进行规划年预测，提出了基于 TimeMixer 的规划年光荷分量预测模型；而对仅显现随机特征的残差分量进行光荷相关性建模，以得到光荷的联合场景，整体规划态光荷联合场景生成框架如图 2 所示。

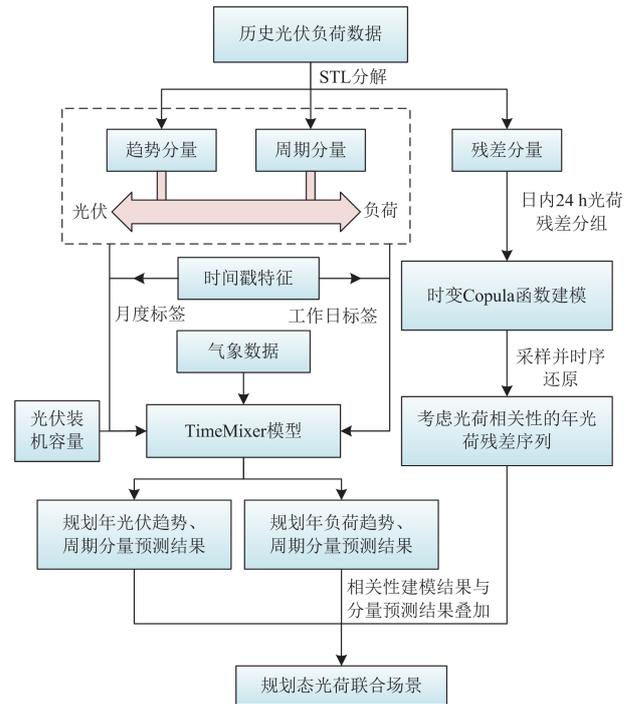


图 2 本文规划态光荷联合场景生成框架

Fig. 2 Planning state PV-load joint scene generation framework

2 基于 TimeMixer 的规划年分量预测模型

对于长尺度时间序列来说，其冗杂着以上基于分量的不同特征信息，且不同采样尺度下的时间序列也会呈现不同的信息。为了获取精确的未来光荷信息，本文采用多尺度特征提取和融合的 TimeMixer 模型。

2.1 TimeMixer 模型

针对时间序列的多尺度特征融合问题, TimeMixer 使用基于 MLP 的多尺度特征混合架构, 该架构通过过去可分解混合(past-decomposable-mixing, PDM)模块提取历史变化中的不同尺度时序特征, 然后通过未来多重预测器混合(future-multipredictor-mixing, FMM)模块集合提取的多尺度历史信息来预测未来序列。TimeMixer 模型在长期预测任务中兼具优异的预测性能与计算效率, 其整体架构如图 3 所示。

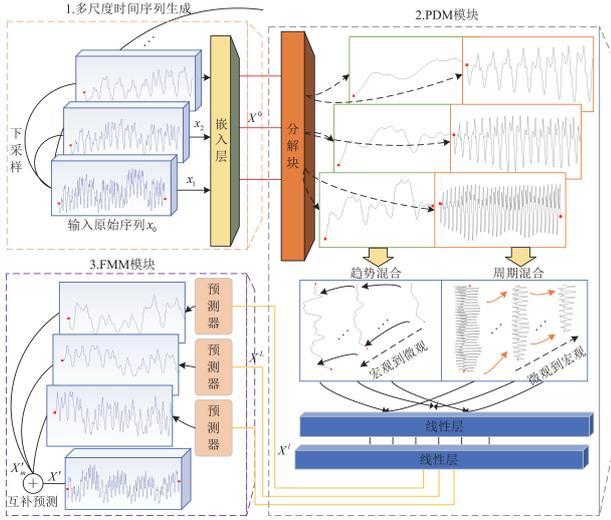


图 3 TimeMixer 模型架构

Fig. 3 Model architecture of TimeMixer

具体来说, TimeMixer 首先将原始序列 $x_0 \in R^{P \times C}$ 平均池化生成 M 个尺度的子序列, 得到多尺度时间序列 $X = \{x_0, \dots, x_M\}$, 其中 $x_m \in R^{\lfloor \frac{P}{2^m} \rfloor \times C}$, $m \in \{0, \dots, M\}$, C 为变量个数, P 为原始序列的长度。由原始序列经过不同时间步的下采样生成不同尺度的子序列, 原始序列 x_0 包含了最细微的变化信息, 下采样层级最高的 x_M 表示提取到的最远的宏观特征。通过嵌入层将多尺度序列 X 投影为深度特征 X^0 , 可以表示为 $X^0 = \text{Embed}(X)$, 以此来实现输入序列的多尺度表示。

即使是最粗糙的尺度序列也存在多个特征混合的变化信息, 为了使模型学习到不同特性, TimeMixer 对每个尺度序列进行分解, 再进行多尺度混合。在第 l 个 PDM 模块中, 分解块^[26]首先将 X^l 分解为趋势项 $T^l = \{t_0^l, \dots, t_M^l\}$ 和周期项 $S^l = \{s_0^l, \dots, s_M^l\}$, 然后分别对季节和趋势项进行特征混合, 实现同一特征的多尺度交互, 表示为

$$\{s_m^l, t_m^l\} = \text{Decomp}(x_m^l), l \in \{1, \dots, L\}, x_m^l \in R^{\lfloor \frac{P}{2^m} \rfloor \times C} \quad (4)$$

$$X^l = X^{l-1} + \text{FeedForward}(\text{Mix}_S(\{s_m^l\}_{m=0}^{m=M}) + \text{Mix}_T(\{t_m^l\}_{m=0}^{m=M})) \quad (5)$$

式中: L 为总层数; s_m^l 、 t_m^l 分别为第 l 层 PDM 模块中尺度为 m 的周期和趋势信息; $\text{Decomp}(\cdot)$ 为分解块网络; x_m^l 为具有 d 个通道数的不同时间尺度下的深度特征; $\text{FeedForward}(\cdot)$ 为由两个线性层组成的前馈层网络; $\text{Mix}_S(\cdot)$ 和 $\text{Mix}_T(\cdot)$ 分别为周期和趋势信息的混合操作网络。

分解块网络利用滑动平均处理得到趋势项, 把剩余项作为周期项, 并通过 padding 操作^[27]使序列长度不变; 前馈网络通过 GELU 激活函数在通道间进行信息交互; 由式(5)可以看出, TimeMixer 利用堆叠的 PDM 模块来混合多个不同尺度的历史信息, 使每一层都可以从前一层的输出中提取多尺度信息, 有助于逐层捕捉数据中的复杂模式和高层特征, 以提升模型的表示能力。

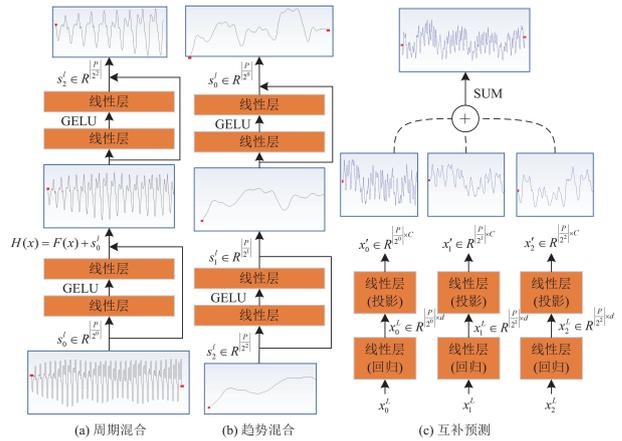


图 4 周期混合、趋势混合和互补预测中的网络层连接方式

Fig. 4 Network layer connection methods in seasonal mixing, trend mixing and complementary prediction

根据不同特征的变化特性, 需要采用不同的混合模式。对于周期项, 大尺度的周期信息可以看作是小尺度周期信息的集合^[28], 例如日尺度周期序列向上融合信息可形成月尺度周期序列。因此周期项采取自下而上的混合方法。在模型的技术架构上, 采用残差连接实现多尺度周期项信息 $S^l = \{s_0^l, \dots, s_M^l\}$ 的交互, 其直观理解如图 4(a)所示, 可以表示为

$$S_m^l = \text{Mix}_S^{\text{Bottom-Up}}(s_{m-1}^l) + s_{m-1}^l \quad (6)$$

式中: $\text{Mix}_S^{\text{Bottom-Up}}(\cdot)$ 为自下而上融合信息的周期项混合网络, 它由两个线性层组成, 输入和输出维度分别为 $\frac{P}{2^{m-1}}$ 、 $\frac{P}{2^m}$ 。通过残差连接, 它允许上一层的尺度信息直接传递到后面的层中, 在不丢失上一

层信息的同时使网络拟合残差映射 $H(x) - s'_m$ ，因此网络只关注当前尺度与下一尺度的信息交互，避免网络退化的现象发生^[29]。

对于趋势项，细尺度的变化会将噪声引入到宏观趋势信息中，以负荷趋势序列为例，粗尺度的趋势分量更能清晰地展现整个研究时段的总负荷水平。因此采用自上而下的方向混合多尺度趋势信息，以总体趋势指导细尺度的变化。具体如图 4(b)所示，多尺度趋势项信息 $T^l = \{t'_0, \dots, t'_M\}$ 表示为

$$T_m^l = \text{Mix}_T^{\text{Top,Down}}(t'_{m-1}) + t'_{m-1} \quad (7)$$

式中： $\text{Mix}_T^{\text{Top,Down}}(\cdot)$ 为由两个线性层组成的周期项混合网络，输入和输出维度分别为 $\frac{P}{2^{m+1}}$ 、 $\frac{P}{2^m}$ ，其技术架构同样采用残差连接。

经过多个 PDM 模块后，得到了完整的多尺度历史信息 $X^L = \{x_0^L, \dots, x_M^L\}$ 。不同尺度的历史信息展现不同的预测能力，利用 FMM 模块实现基于多尺度信息的互补预测，其中每一尺度的历史信息 x_m^L 都输入到对应尺度的预测器中，并聚合得到预测结果。

$$x'_m = \text{Pred}_m(x_m^L) \quad (8)$$

$$x' = \sum_{m=0}^M x'_m \quad (9)$$

式中： x'_m 为第 m 个尺度序列对未来的预测结果， $x'_m \in R^{F \times C}$ ，其中 F 为预测长度； x' 为最终输出， $x' \in R^{F \times C}$ ； $\text{Pred}_m(\cdot)$ 为第 m 个尺度序列的预测器，

它首先采用单线性层直接提取长度为 $\frac{P}{2^m}$ 的历史信息来得到长度为 F 的未来信息，然后将回归的深度表征投影到 C 个目标变量中，最后对多尺度结果进行聚合得到预测结果，具体如图 4(c)所示。

2.2 光伏发电和用电负荷的分量特征预测模型构造

光伏发电受天气因素影响较大，周期性和随机性波动明显，而趋势性变化主要受光伏装机容量的影响。基于 TimeMixer 的光伏分量预测模型用于挖掘不同分量特征和多个外部因素的相关特性，将光伏发电的分量预测初始输入数据 x_0^{PV} 表示为

$$x_0^{\text{PV}} = \begin{bmatrix} s_1^{\text{PV}} & t_1^{\text{PV}} & C_1 & T_1 & H_1 & R_1 & L_1 & M_1 \\ \vdots & \vdots \\ s_n^{\text{PV}} & t_n^{\text{PV}} & C_n & T_n & H_n & R_n & L_n & M_n \end{bmatrix} \quad (10)$$

式中： n 为样本数量； s_i^{PV} 、 t_i^{PV} 分别为光伏发电的周期分量和趋势分量， $i = \{1, \dots, n\}$ ； C_i 、 T_i 、 H_i 、 R_i 、 L_i 分别为该地区的光伏装机容量、温度、湿度、辐射度和降雨量； M_i 为月度标记特征，用于反映光伏发电随全年季节变换的月度变化。

光伏发电的分量特征变化还受自身历史变化的影响，具有一定自相关性。训练过程可表示为

$$x'_{I,K} = F_{\text{train}}(x_{0,I}^{\text{PV}}, x_I, M_K; \theta) \quad (11)$$

式中： $x'_{I,K}$ 为输入历史长度为 I 的数据得到的预测步长为 K 的未来光伏分量； $x_{0,I}^{\text{PV}}$ 为长度为 I 的初始输入数据； x_I 为输入长度为 I 的光伏历史出力； M_K 为输入未来 K 步的月份标记特征； θ 为训练得到的模型参数向量； $F_{\text{train}}(\cdot)$ 为训练的映射函数。本文对多维数据输入进行滑动窗口处理，预测过程如图 5 所示。

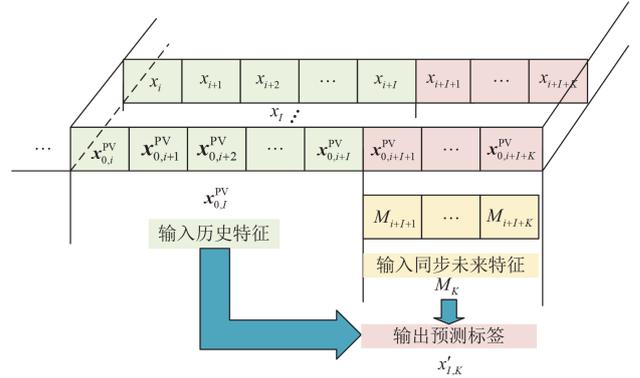


图 5 多维数据滑动窗口处理

Fig. 5 Multidimensional data sliding window processing

用电负荷不同于光伏发电，其周期特征主要受人们工作生产规律影响，总体变化较为规律。负荷分量预测的初始输入数据 x_0^{LOAD} 可表示为

$$x_0^{\text{LOAD}} = \begin{bmatrix} s_1^{\text{LOAD}} & t_1^{\text{LOAD}} & T_1 & H_1 & L_1 & R_1 & W_1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ s_n^{\text{LOAD}} & t_n^{\text{LOAD}} & T_n & H_n & L_n & R_n & W_n \end{bmatrix} \quad (12)$$

式中： s_i^{LOAD} 和 t_i^{LOAD} 分别为负荷的周期分量和趋势分量；其他变量同式(10)； W_i 为周度标记特征，用于反映用电负荷在工作日中的变化。同时，采取与光伏分量相似的训练过程，可表示为

$$u'_{I,K} = G_{\text{train}}(x_{0,I}^{\text{LOAD}}, v_I, W_K; \sigma) \quad (13)$$

式中： $u'_{I,K}$ 为输入长度为 I 的历史数据得到的预测长度为 K 的未来负荷分量； $x_{0,I}^{\text{LOAD}}$ 为长度为 K 的初始输入数据； v_I 为长度为 I 的历史负荷出力； W_K 为输入未来 K 步的周度标记特征； σ 为参数向量； $G_{\text{train}}(\cdot)$ 为训练的映射函数。

3 基于时变 Copula 函数的光荷相关性建模

经过 STL 分解后的残差序列分量是由外部不确定性因素引起的，无法从现有条件中总结其变化

规律。因此, 本文利用残差分量捕捉历史光荷相关性, 将光荷的残差分量概率分布进行 Copula 相关性建模, 并与预测结果结合得到规划年的联合场景。

Copula 函数可以描述变量之间的相依特性, 其由 Sklar^[30]提出, 由多个随机变量 $\mathbf{x}_N = [x_1, \dots, x_N]$ 的边缘累积分布组成其联合分布函数, 表示为

$$F(x_1, x_2, \dots, x_N) = C(F_1(x_1), F_2(x_2), \dots, F_N(x_N)) \quad (14)$$

式中: $F(\cdot)$ 为 N 维变量的联合分布函数;

$F_1(x_1), \dots, F_N(x_N)$ 为对应变量的边缘累计分布; $C(\cdot)$ 为 Copula 函数。

考虑历史光荷日内变化的相关性, 可以反映在不同时间断面下的光伏、负荷出力的耦合情况。总体思路是: 将历史光荷残差分量分成日内 24 组, 每一组含有该时段的不同历史随机出力情况, 然后分别对每组光荷残差进行 Copula 拟合, 得到随日内时间变化的动态光荷相依性结构。

对于 Copula 的建模过程, 本文首先采用秩变换方法进行概率积分变换, 然后以最大似然估计法和赤池信息准则(akaike information criterion, AIC)确定 Copula 函数的参数和类型。

1) 秩变换。秩变换保留了随机变量转换前后的秩相关性, 可以得到服从[0,1]区间的均匀分布, 变换公式为

$$\mathbf{u}_j = R_j / (n_r + 1) \quad (15)$$

式中: \mathbf{u}_j 为伪观测矩阵; R_j 为第 j 个变量在样本中的秩; n_r 为样本数大小。其对每个变量进行大小排序, 计算秩并进行线性缩放变换。

2) Copula 函数参数计算和类型选定。采用最大似然估计法计算各类型 Copula 函数的参数, 它可以将参数的计算转化为非参数优化问题。

$$\theta_a = \max \sum_{i=1}^{n_c} \ln C(F_j(x_{j,i}), F_k(x_{k,i}); \theta_a) \quad (16)$$

式中: $\max(\cdot)$ 为取最大值; θ_a 为取最大值时的 Copula 参数; n_c 为变量 x_j 和 x_k 的样本数。

使用 AIC 选择最优的 Copula 函数类型拟合变量对, 以最小化 AIC 指标为目标, 表示为

$$\rho_{\text{AIC}} = 2k - 2 \ln(L_1(\theta)) \quad (17)$$

式中: ρ_{AIC} 为 AIC 指标值; k 为参数个数。

在得到日内光荷残差时变 Copula 模型后, 通过拉丁超立方采样生成若干样本。生成的模拟样本丢失了时序性, 因此需要对模拟样本进行时序重构, 还原成残差序列 \mathbf{R}_T 。

$$\mathbf{R}_T = \begin{bmatrix} R_{11} & R_{12} & \dots & R_{1T} \\ R_{21} & R_{22} & \dots & R_{2T} \end{bmatrix} \quad (18)$$

式中: T 为一年内的小时数; \mathbf{R}_T 为规划年份内 8760 h 的光荷残差分量。

残差样本的光荷关系是对应的, 因此只需研究其中一个残差分量的时序关系。本文重构依据是利用马尔可夫转移概率最大化确定每一时刻光伏残差的时序关系。首先按照分组将光伏残差大小定义为 s 个等间隔划分的区间, 然后通过计算 s 个区间的转移概率矩阵来寻找每个残差值之间最佳的时序关系, 限于篇幅, 具体过程参见文献[31]。光荷残差的相关性建模过程如图 6 所示。

4 算例分析

本文以比利时地区 Elia 集团^[32]收集的光伏和负荷供应数据为例, 并以欧洲中期天气预报中心的 era5 再分析数据^[33]作为气象数据。其中, 以 2019 年 9 月至 2022 年 9 月数据作为训练集, 生成下一年的规划场景, 时间颗粒度为 1 h。实验采用 Python3.11.5 和 pytorch2.1.1 + CPU 深度学习框架, 相关硬件采用 Intel i5-13400 4.6 GHz-10cores CPU、32 GB 机带 RAM, 每轮训练 128 次。

4.1 光伏和负荷的 STL 分解结果

本文采用 STL 分解方法将光伏和负荷时间序列分解为趋势分量、周期分量和残差分量, 结果如图 7 所示。

观察可知, 在长时间范围内, 趋势分量呈现季节变化特性; 周期分量呈现细时间尺度的日间变化规律。每年局部窗口内, 受雨雪季太阳辐照度低的影响, 光伏出力水平整体较低, 常规月份恢复正常。光伏发电的周期分量、趋势分量都呈现逐年上升的趋势, 这是因为随着新能源的开发, 光伏装机容量增大。负荷用电趋势变化相对平缓, 趋势分量变化特征更为显著; 周期分量较平稳, 其不受季节变化的影响。两者残差分量均在其总体变化中占比最小, 呈现正态分布, 但分布形状略有区别。光伏残差分量受气象等突变因素影响大, 在不同月份占比有所变化, 残差分布相对集中, 且总负荷规模较大, 因此随机波动对其影响较小, 残差分布相对均匀。

进一步地, 利用文献[34]的方法对各序列的可预测性进行度量, 如表 1 所示。可以看出, 分解后的残差分量均具有较低的可预测性, 同时趋势分量和周期分量均比原始序列的可预测性高, 证明本文分解思路的有效性。

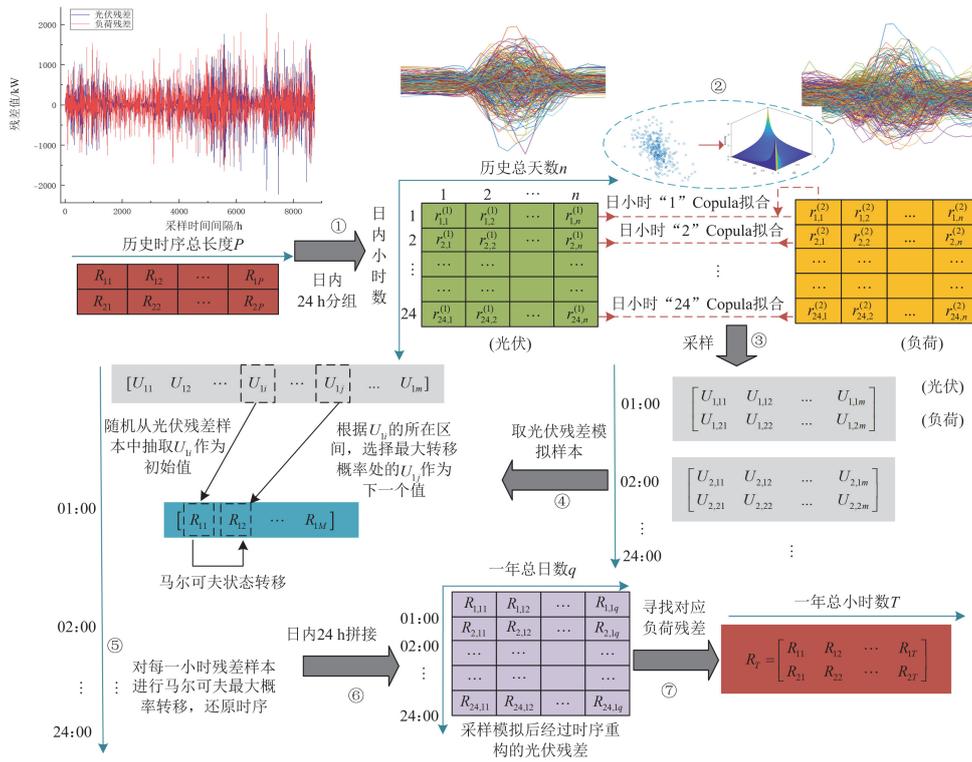


图 6 光荷残差序列的相关性建模与还原

Fig. 6 Correlation modeling and restoration of residual sequence of PV-load

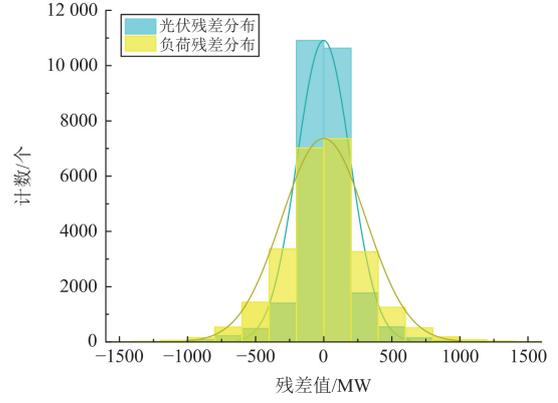
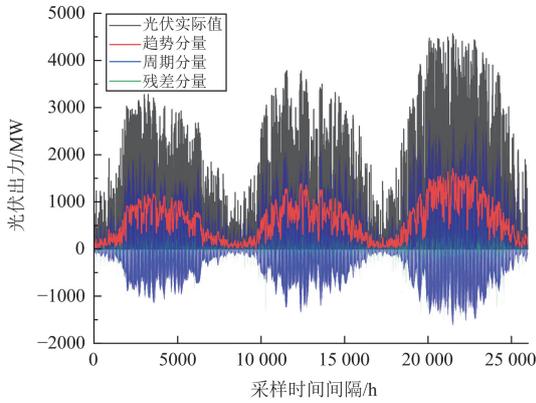
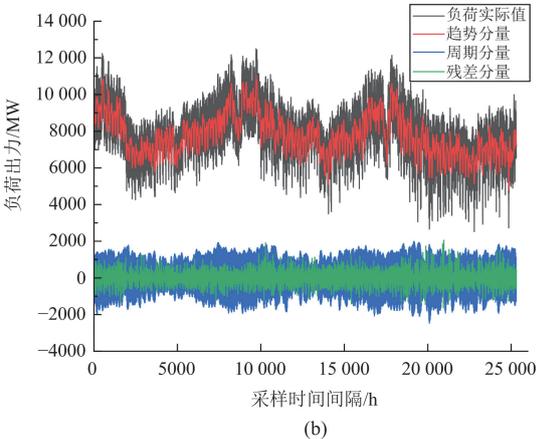


图 7 光伏和负荷时间序列的 STL 分解结果

Fig. 7 STL decomposition results of PV and load series



4.2 方法验证和结果分析

本文使用 TimeMixer 模型构建多变量预测任务，分别对光伏和负荷的周期分量、趋势分量进行预测建模，以周期分量和趋势分量为预测对象，按照 2.2 节分别构造光伏和负荷分量预测模型的输入数据。光伏分量预测模型以输入窗口长度 3 天、输出窗口 1 天为单位形成滚动数据集，负荷分量预测模型的输入窗口长度为 5 天，输入输出窗口的最佳长度经过多次仿真确定。其他超参数包括网络层数

L 、模型采样尺度 M 、编码器层数、通道数 d 等, 通过网格搜索得到的预测模型参数如表 2 所示。

表 1 各序列可预测性度量结果

Table 1 Forecastability measurement results of various sequences

| 序列名称 | 可预测性 |
|--------|--------|
| 原始光伏序列 | 0.6749 |
| 光伏趋势分量 | 0.7242 |
| 光伏周期分量 | 0.8010 |
| 光伏残差分量 | 0.2417 |
| 原始负荷序列 | 0.6211 |
| 负荷趋势分量 | 0.6753 |
| 负荷周期分量 | 0.7025 |
| 负荷残差分量 | 0.2037 |

表 2 光伏和负荷分量预测模型参数

Table 2 Parameters of PV and load component prediction model

| 模型目标 | 输入窗口长度 | 输出窗口长度 | 网络层数 L | 下采样尺度 M | 嵌入层维度 | 通道数 d | 前馈层维度 |
|------|--------|--------|----------|-----------|-------|---------|-------|
| 光伏分量 | 72 | 24 | 3 | 3 | 6 | 128 | 256 |
| 负荷分量 | 120 | 24 | 5 | 3 | 5 | 128 | 256 |

采用均方误差(mean square error, MSE)指标 γ_{MSE} 和平均绝对误差(mean absolute error, MAE)指标 γ_{MAE} 评估预测模型的准确性, 计算公式为

$$\gamma_{\text{MSE}} = \frac{1}{F} \sum_{i=1}^F (p_i - p'_i)^2 \quad (19)$$

$$\gamma_{\text{MAE}} = \frac{1}{F} \sum_{i=1}^F |p_i - p'_i| \quad (20)$$

式中: p_i 为第 i 个时间步的实际值; p'_i 为第 i 个时间步的预测值; F 为预测步长。

为了验证 TimeMixer 模型对历史信息分解提取的有效性以及对重要超参数的敏感性, 截取光伏分量预测模型中部分超参数组合下的 MSE 预测结果, 如表 3 所示。

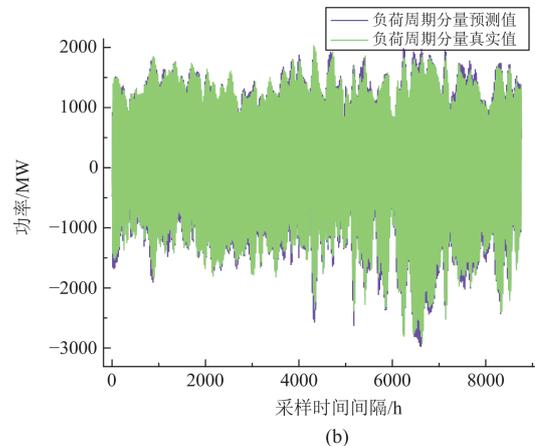
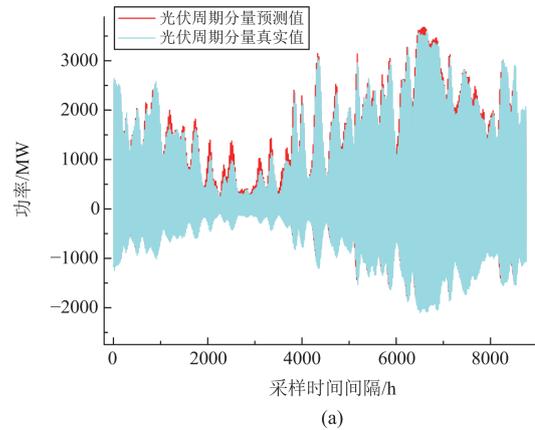
由表 3 可以看出, TimeMixer 模型利用下采样得到的多尺度历史信息, 提高了预测的准确性。下采样尺度太大会增加了模型的复杂性, 即使相应增大网络层数也无法有效提高预测精度。同时, 输入输出窗口长度决定了模型训练中的特征提取能力, 预设模型通过 3 天历史信息来预测未来一天的窗口是最佳的训练模式, 对于单点预测(输出长度为 1)来说, 预测长度太短会使模型在历史数据的训练中无法看到更多的未来变化信息, 因此会限制整体的准确度。

表 3 不同超参数组合下光伏分量的 MSE 指标

Table 3 MSE of PV components prediction results under different hyperparameter combinations

| 输入长度 | 输出长度 | 下采样尺度 M | | | | | | |
|------|------|-----------|-------|-------|--------------|-------|-------|-------|
| | | 1 | 1 | 2 | 3 | 3 | 4 | 3 |
| | | 网络层数 L | | | | | | |
| | | 1 | 2 | 3 | 3 | 4 | 4 | 5 |
| 24 | 1 | 0.289 | 0.255 | 0.181 | 0.163 | 0.159 | 0.171 | 0.155 |
| | 12 | 0.292 | 0.265 | 0.175 | 0.155 | 0.141 | 0.163 | 0.149 |
| 48 | 1 | 0.332 | 0.239 | 0.189 | 0.162 | 0.158 | 0.166 | 0.146 |
| | 24 | 0.382 | 0.214 | 0.162 | 0.147 | 0.162 | 0.154 | 0.169 |
| 72 | 12 | 0.374 | 0.222 | 0.142 | 0.109 | 0.111 | 0.107 | 0.115 |
| | 24 | 0.393 | 0.191 | 0.121 | 0.082 | 0.089 | 0.087 | 0.091 |
| 96 | 72 | 0.408 | 0.258 | 0.183 | 0.131 | 0.117 | 0.119 | 0.113 |
| | 12 | 0.388 | 0.231 | 0.156 | 0.18 | 0.173 | 0.114 | 0.144 |
| 168 | 24 | 0.412 | 0.283 | 0.145 | 0.122 | 0.133 | 0.095 | 0.125 |
| | 24 | 0.390 | 0.322 | 0.217 | 0.234 | 0.227 | 0.123 | 0.187 |
| 72 | 72 | 0.449 | 0.350 | 0.277 | 0.268 | 0.195 | 0.183 | 0.172 |

图 8 为光伏和负荷分量的规划年预测结果, 可见, 对历史信息分量进行多尺度提取得到未来一年的预测结果与实际相符。整年的分量序列曲线与实际曲线趋势相似, 仅在峰值值上略有偏差。



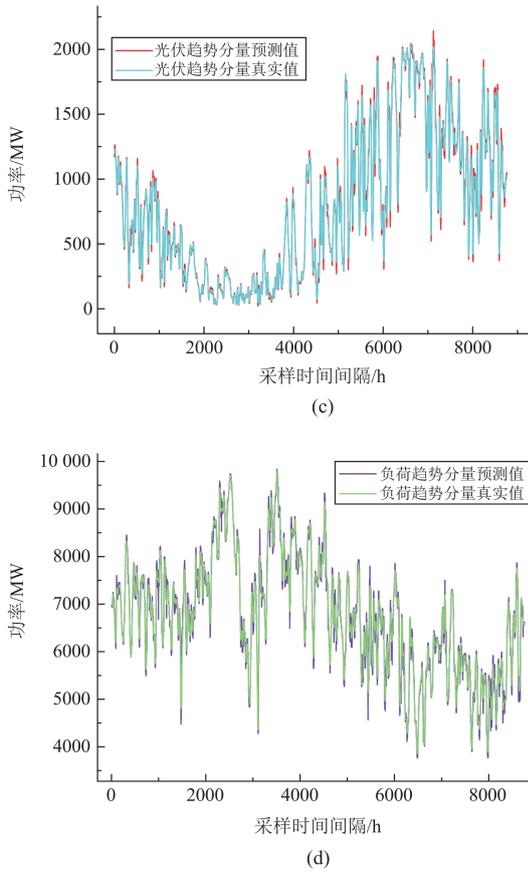


图 8 规划年光伏和负荷分量预测结果

Fig. 8 Forecast results of PV and load components for the planning year

结合超参数组合实验设置和规划年预测结果分析可知,本文输入 STL 分解后的分量结果进行预测能够提升预测效果,其原因是:模型的预测目标经过了多次平滑和特征分离,通过 PDM 模块能将原分解分量进一步平滑处理,并分离出不属于原分量特征的其他特性,由此再通过多尺度的特征交互使模型更好地学习到特定的特征变化。

随后,针对光荷残差分量的随机性,本文对不确定性特征进行时序 Copula 的相关性建模。将历史年光荷残差分量按日内 24 h 分别进行 Copula 拟合,光荷残差时序相关性建模效果如图 9 所示。

从图 9 可以看出,历史真实光荷残差和采样生成的光荷残差散点分布相似,均呈负相关关系。其中,不同颜色的点代表不同日内时刻的生成样本和真实样本,无论在时间尺度依赖性方面还是在光荷相关性层面,两者均呈现出高度相似的特征。其中子图进一步对比采样数据和真实数据随着日内时间变化的光荷残差相关性,可以看出,在午间表现出极高的相关性,符合光伏发电出力高峰时段对电力

负荷抵消效应最为明显的运行特性。因此本文采用残差分量构建光荷相关性模型是合理的,能够有效利用分离后的随机特征。

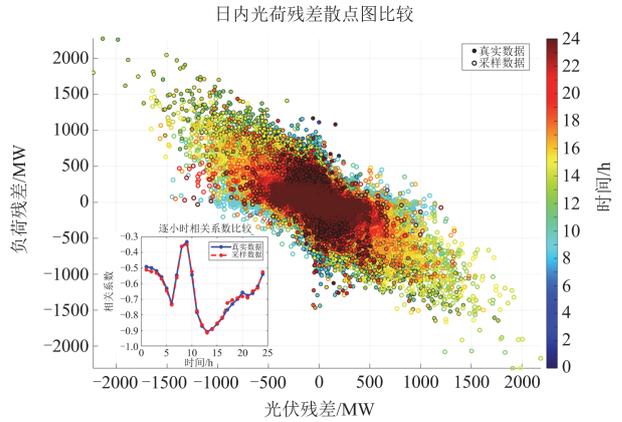


图 9 光荷残差时序相关性建模效果

Fig. 9 Modeling effect of temporal correlation of residual PV-load

4.3 规划场景生成结果分析与对比验证

将分量预测结果和残差相关性建模结果结合,可以得到考虑光荷历史相关特征的规划场景,为了验证生成的最终规划场景的有效性,本文采用累积概率分布函数(cumulative probability density function, CDF)和自相关系数(autocorrelation coefficient, ACC) ρ_{ACC} 来度量生成场景的精度。CDF 是概率密度函数的积分,可以用来表征生成场景的概率分布特性。ACC 用于验证生成场景序列的时间相关特性,衡量方法能否还原时序特征,可表示为

$$\rho_{ACC} = \frac{\text{Cov}(Y_t, Y_{t-z})}{\sqrt{\text{Var}(Y_t) \cdot \text{Var}(Y_{t-z})}} \quad (21)$$

式中: Y_t 为时间序列在 t 时刻的观测值; Cov 为协方差; Var 为方差; z 为滞后期数。

采用常用的 CGAN^[13]算法和基于 Copula 的概率方法^[10]生成光荷联合场景与本文的生成场景进行对比验证。其中,将两种对比方法生成场景均值乘以一定的增长比例来得到规划场景。图 10 为采用不同方法时生成场景和实际场景的 CDF 和 ACC 曲线。

从图 10 可以看出,采用本文方法时生成场景的 CDF 和 ACC 更接近实际场景。相较于传统的基于 Copula 的概率方法和常用的 CGAN 深度学习方法,所提方法融合了神经网络时序特征学习的优势与历史光荷相关性建模的特点,所生成的场景能够更好地反映未来长期变化趋势。由自相关系数曲线可知,3 种方法生成场景的 CDF 整体上区别不大,但通过放大的子图可以看出,相较于其他方法,本文方法

生成的场景的概率分布与实际分布更相符。由 ACC 曲线可知, 对比方法得到的规划场景时序特性与实际场景相差较大, 而本文方法经过多尺度时序信息的提取, 能更好地保留时序特性。

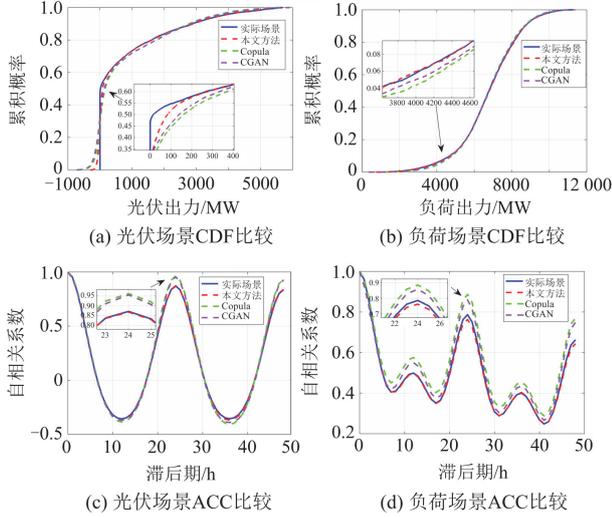


图 10 不同方法生成场景的 CDF 和 ACC 对比

Fig. 10 Comparison of CDF and ACC generated by different methods for scenes

表 4 给出 3 种方法生成的规划场景误差对比。其中, 均方根差(root mean square error, RMSE)是 MSE 的开根号。可以看出, 本文方法生成的场景误差明显小于其他方法, 相比 Copula 方法和 CGAN 方法, 本文方法生成的光伏规划场景的 RMSE 误差分别降低了 68.9%、53.5%。

表 4 不同方法的规划场景的 RMSE 和 MAE 指标

Table 4 RMSE and MAE indicators for planning scenarios using different methods

| 方法 | 误差类型 | 误差值/MW | |
|-----------|------|---------|---------|
| | | 光伏 | 负荷 |
| 本文方法 | RMSE | 96.862 | 163.762 |
| | MAE | 70.448 | 124.623 |
| Copula 方法 | RMSE | 311.477 | 393.426 |
| | MAE | 200.698 | 292.654 |
| CGAN 方法 | RMSE | 212.612 | 290.439 |
| | MAE | 114.557 | 182.119 |

为了进一步验证 TimeMixer 模型预测性能的优势, 表 5 展示了不同预测模型(Transformer^[19]、TCN^[18]、CNN-GRU^[35]、XGBoost、LSTM)对光伏和负荷分量的预测性能, 所有模型均采用网格搜索法进行超参数调整。

从表 5 可以看出, TimeMixer 模型表现出最优越的预测性能, 以可预测性相对较低的负荷趋势分

量为例, TimeMixer 的 MSE 相较于 Transformer、TCN、CNN-GRU 分别降低了 16.8%、27.8%、29.6%, 且耗时均减少了 20 min 以上。相对于需要经过多个卷积层的 TCN、CNN-GRU, 基于 MLP 的 TimeMixer 模型训练时间大大减少。完全基于注意力机制的 Transformer 有多层编码器和解码器, 每层具有多个残差块, 需要进行大量的参数优化, 因此训练耗时非常长; XGBoost 和 LSTM 虽然耗时较短, 结构简单, 但精度不足。

表 5 不同预测模型对光荷分量的预测性能对比

Table 5 Prediction performance comparison for the PV-load components with different models

| 模型 | 目标 | 光伏周 期分量 | 光伏趋 势分量 | 负荷周 期分量 | 负荷趋 势分量 |
|-------------|-----|--------------|--------------|--------------|--------------|
| TimeMixer | MSE | 0.079 | 0.085 | 0.092 | 0.109 |
| | MAE | 0.173 | 0.181 | 0.223 | 0.257 |
| | 总耗时 | 50 min | | | |
| Transformer | MSE | 0.103 | 0.119 | 0.122 | 0.131 |
| | MAE | 0.210 | 0.214 | 0.244 | 0.268 |
| | 总耗时 | 161 min | | | |
| TCN | MSE | 0.094 | 0.112 | 0.136 | 0.151 |
| | MAE | 0.198 | 0.209 | 0.252 | 0.289 |
| | 总耗时 | 79 min | | | |
| CNN-GRU | MSE | 0.128 | 0.130 | 0.142 | 0.155 |
| | MAE | 0.227 | 0.243 | 0.277 | 0.294 |
| | 总耗时 | 75 min | | | |
| XGBoost | MSE | 0.217 | 0.246 | 0.259 | 0.271 |
| | MAE | 0.296 | 0.320 | 0.388 | 0.402 |
| | 总耗时 | 28 min | | | |
| LSTM | MSE | 0.148 | 0.156 | 0.161 | 0.173 |
| | MAE | 0.240 | 0.252 | 0.303 | 0.326 |
| | 总耗时 | 36 min | | | |

本文利用 K-Means 聚类、模糊 C 均值(fuzzy-c means, FCM)聚类和空间密度聚类(density-based spatial clustering of applications with noise, DBSCAN) 3 种方法生成规划典型场景, 探究规划场景与实际场景的差别对典型场景生成结果的影响。图 11 展示了不同方法生成的规划场景采用 3 种聚类方法生成的典型场景对比。图中实际场景指的是采用相同聚类算法对规划年实际出力场景进行聚类生成的典型场景。

图 11 结果表明, 本文方法生成的规划场景下得到的典型场景更贴合实际, 得到的不同典型场景与实际的情况一致。不同方法生成的规划场景会出现某些不符实际的典型场景, 如图 11(b)中的 CGAN 和 Copula 方法生成的中间簇典型场景, 其原因是: 其他方法的自相关时序特性和增长特性与实际相差较大, 生成的典型场景不能准确反映配电网

的运行状态。在各种聚类算法下，本文方法均能生成最准确的典型场景，为配电网的规划提供更加丰富的源荷运行状态信息，不同方法生成场景的偏差可能会对电网规划和评估造成影响。

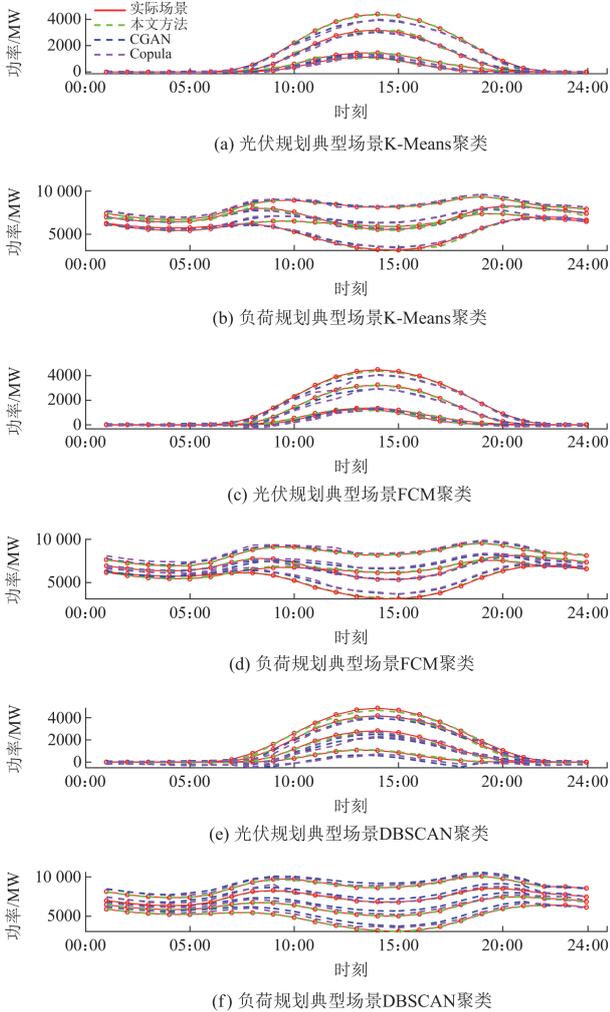


图 11 规划态典型场景对比

Fig. 11 Comparison of typical scenarios in planning state

5 结论

面对新能源渗透率不断提高的新型电力系统，本文针对源荷不确定性造成配电网规划偏离实际的问题，提出了一种基于 TimeMixer 的深度学习模型进行多尺度不同时序特征的融合，并生成规划场景，同时，利用时变 Copula 函数对历史光荷相关性进行建模，生成考虑光荷日内耦合特征的规划态场景，并用于构建实际规划中所需的典型运行状态。算例结果证明，相较于其他场景生成方法，本文方法基于原始时序的趋势性、周期性和随机性，同时考虑光伏和负荷的不确定性和相关性，提供更加准确的源荷运行状态信息，通过对比验证了本文方法的有

效性和优越性，结论如下。

1) 在生成规划场景中，需保证主要分量具有较高精度，因此对于可预测性较强的周期分量和趋势分，选择 TimeMixer 模型重复调参调用。结果表明相较于以增长比例考虑未来变化的方法，生成规划场景的精度指标提升 50% 以上。

2) 残差分量能够有效表征光伏出力与电力负荷的相关特性，使用动态变化的时序 Copula 模型能准确还原日内光荷耦合特性。

本文通过实验仿真验证了所提方法具有一定的优势。配电网规划中心及相关售电企业能通过更精确的规划态典型运行场景得到用电需求变化和新能源发展趋势，从而形成更准确的规划方案。但研究内容未考虑不同地区的源荷出力场景关系，后续工作可开展源荷空间相关性研究。

参考文献

[1] 张智刚, 康重庆. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报, 2022, 42(8): 2806-2819. ZHANG Zhigang, KANG Chongqing. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future[J]. Proceedings of the CSEE, 2022, 42(8): 2806-2819.

[2] 朱彦名, 徐潇源, 严正, 等. 面向电力物联网的含可再生能源配电网运行展望[J]. 电力系统保护与控制, 2022, 50(2): 176-187. ZHU Yanming, XU Xiaoyuan, YAN Zheng, et al. Prospect of renewable energy integrated distribution network operation in the power internet of things[J]. Power System Protection and Control, 2022, 50(2): 176-187.

[3] 陈瑶, 陈晓宁. 基于自适应 Kmeans 和 LSTM 的短期光伏发电预测[J]. 电测与仪表, 2023, 60(7): 94-99. CHEN Yao, CHEN Xiaoning. Prediction of short-term photovoltaic power generation based on adaptive Kmeans and LSTM[J]. Electrical Measurement & Instrumentation, 2023, 60(7): 94-99.

[4] 周伊, 肖先勇, 赵清华, 等. 基于组合数据清洗与改进注意力机制的光伏发电功率预测[J]. 供用电, 2024, 41(10): 31-37, 49. ZHOU Yi, XIAO Xianyong, ZHAO Qinghua, et al. Photovoltaic power forecasting based on combined data cleaning and improved attention mechanism[J]. Distribution & Utilization, 2024, 41(10): 31-37, 49.

[5] 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.
- [6] 辛阔, 马骞, 许琴, 等. 基于月份划分与指定日类型的风电出力序列场景生成方法[J]. *电力系统自动化*, 2023, 47(15): 151-161.
XIN Kuo, MA Qian, XU Qin, et al. Wind power output sequence scenario generation method based on monthly division and specified day type[J]. *Automation of Electric Power Systems*, 2023, 47(15): 151-161.
- [7] 荆臻, 王莉, 杨梅, 等. 基于超状态隐马尔可夫模型的智能电表非侵入式故障远程检定[J]. *电测与仪表*, 2023, 60(2): 196-200.
JING Zhen, WANG Li, YANG Mei, et al. Non-intrusive remote error detection and localization for smart meters based on super-state hidden Markov model[J]. *Electrical Measurement & Instrumentation*, 2023, 60(2): 196-200.
- [8] 李峰, 高效海, 郑鹏飞, 等. 基于高斯过程回归与不确定性耦合关系的电力系统规划典型场景提取技术[J]. *电力科学与技术学报*, 2022, 37(1): 64-73.
LI Feng, GAO Xiaohai, ZHENG Pengfei, et al. Extraction of typical scenarios for power system planning based on Gaussian process regression and uncertainty coupling relationship[J]. *Journal of Electric Power Science and Technology*, 2022, 37(1): 64-73.
- [9] 戴剑丰, 阎诚, 汤奕. 基于时序残差概率的风电场超短期风速混合预测模型[J]. *电网技术*, 2023, 47(2): 688-699.
DAI Jianfeng, YAN Cheng, TANG Yi. Ultra-short-term wind speed hybrid forecasting model for wind farms based on time series residual probability modeling[J]. *Power System Technology*, 2023, 47(2): 688-699.
- [10] 段偲默, 苗世洪, 霍雪松, 等. 基于动态Copula的风光联合出力建模及动态相关性分析[J]. *电力系统保护与控制*, 2019, 47(5): 35-42.
DUAN Simo, MIAO Shihong, HUO Xuesong, et al. Modeling and dynamic correlation analysis of wind/solar power joint output based on dynamic Copula[J]. *Power System Protection and Control*, 2019, 47(5): 35-42.
- [11] MULLER A, REUBER M. A copula-based time series model for global horizontal irradiation[J]. *International Journal of Forecasting*, 2023, 39: 869-883.
- [12] 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.
- [13] 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.
- [14] 刘艾旺, 朱萧轶, 姚宝明, 等. 考虑低碳和柔性负荷的有源配网扩展规划模型[J]. *电力需求侧管理*, 2023, 25(4): 15-20.
LIU Aiwang, ZHU Xiaoyi, YAO Baoming, et al. Active distribution network expansion planning model considering low carbon and flexible load[J]. *Power Demand Side Management*, 2023, 25(4): 15-20.
- [15] SALDAÑA-GONZÁLEZ A E, ARAGÜÉS-PEÑALBA M, SUMPER A. Distribution network planning method: integration of a recurrent neural network model for the prediction of scenarios[J]. *Electric Power Systems Research*, 2024, 229.
- [16] 殷佳敏, 谢宁, 王承民, 等. 基于分形理论的新型电力系统规划场景生成方法[J]. *电力自动化设备*, 2024, 44(7): 94-100, 188.
YIN Jiamin, XIE Ning, WANG Chengmin, et al. Generation method of planning scenario for new power system based on fractal theory[J]. *Electric Power Automation Equipment*, 2024, 44(7): 94-100, 188.
- [17] 朱陈政翰, 柳东歌, 黄津钜, 等. 基于渐进式增长生成对抗网络的月度源荷场景生成[J]. *高电压技术*, 2024, 50(9): 3955-3964.
ZHU Chenzhengan, LIU Dongge, HUANG Jinju, et al. Monthly source and load scenario generation based on progressive growing of generative adversarial nets[J]. *High Voltage Engineering*, 2024, 50(9): 3955-3964.
- [18] 李楠, 姜涛, 隋想, 等. 一种时频尺度下的多元短期电力负荷组合预测方法[J]. *电力系统保护与控制*, 2024, 52(13): 47-58.
LI Nan, JIANG Tao, SUI Xiang, et al. A multi-component short-term power load combination forecasting method on a time-frequency scale[J]. *Power System Protection and Control*, 2024, 52(13): 47-58.
- [19] 赵洪山, 吴雨晨, 温开云, 等. 基于时空注意力机制的台区多用户短期负荷预测[J]. *电工技术学报*, 2024, 39(7): 2104-2115.
ZHAO Hongshan, WU Yuchen, WEN Kaiyun, et al. Short-term load forecasting for multiple customers in a station area based on spatial-temporal attention mechanism[J]. *Transactions of China Electrotechnical Society*, 2024,

- 39(7): 2104-2115.
- [20] MAYER M, BIRÓ B, SZÜCS B, et al. Probabilistic modeling of future electricity systems with high renewable energy penetration using machine learning[J]. Applied Energy, 2023, 336.
- [21] WANG Shiyu, WU Haixu, SHI Xiaoming, et al. TimeMixer: decomposable multiscale mixing for time series forecasting[J]. arXiv, 2024, arXiv:2405.14616.
- [22] 陈裕, 张怡, 谢俊峰. 自适应滑动平均与小波包分解平抑风电波动[J]. 控制工程, 2021, 28(7): 1281-1288. CHEN Yu, ZHANG Yi, XIE Junfeng. Adaptive moving average and wavelet packet decomposition to smooth wind power fluctuation[J]. Control Engineering of China, 2021, 28(7): 1281-1288.
- [23] 刘亚琰, 赵倩. 基于聚类经验模态分解的 CNN-LSTM 超短期电力负荷预测[J]. 电网技术, 2021, 45(11): 4444-4451. LIU Yahui, ZHAO Qian. Ultra-short-term power load forecasting based on cluster empirical mode decomposition of CNN-LSTM[J]. Power System Technology, 2021, 45(11): 4444-4451.
- [24] 陆秋瑜, 杨银国, 陈俊生, 等. 考虑风电不确定性的海上风电场混合储能容量优化[J/OL]. 南方电网技术: 1-10[2024-10-16]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20240517.1627.008.html>. LU Qiuyu, YANG Yinguo, CHEN Junsheng, et al. Hybrid energy storage capacity optimization of offshore wind farms considering wind power uncertainty[J]. Southern Power System Technology: 1-10[2024-10-16]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20240517.1627.008.html>.
- [25] 张昆明, 蔡珊珊, 章天晗, 等. 考虑多维时域特征的行业中长期负荷预测方法[J]. 电力系统自动化, 2023, 47(20): 104-114. ZHANG Kunming, CAI Shanshan, ZHANG Tianhan, et al. Medium-and long-term industry load forecasting method considering multi-dimensional temporal features[J]. Automation of Electric Power Systems, 2023, 47(20): 104-114.
- [26] WU Haixu, XU Jiehui, WANG Jiamin, et al. Autoformer: decomposition transformers with auto-correlation for long-term series forecasting[J]. Advances in Neural Information Processing Systems, 2021, 34: 22419-22430.
- [27] 林帆, 张耀, 东琦, 等. 基于分位数插值和深度自回归网络的光伏出力概率预测[J]. 电力系统自动化, 2023, 47(9): 79-87. LIN Fan, ZHANG Yao, DONG Qi, et al. Probability prediction of photovoltaic output based on quantile interpolation and deep autoregressive network[J]. Automation of Electric Power Systems, 2023, 47(9): 79-87.
- [28] NIE Yuqi, NGUYEN H, SINTHONG P, et al. A time series is worth 64 words: long-term forecasting with transformers[J]. arxiv preprint arxiv:2211.14730, 2022.
- [29] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, June 26-30, 2016, Las Vegas, United States: 770-778.
- [30] 许彪, 徐青山, 黄煜, 等. 基于藤 Copula 分位数回归的光伏功率日前概率预测[J]. 电网技术, 2021, 45(11): 4426-4435. XU Biao, XU Qingshan, HUANG Yu, et al. Day-ahead probabilistic forecasting of photovoltaic power based on vine Copula quantile regression[J]. Power System Technology, 2021, 45(11): 4426-4434.
- [31] 吴卫兵, 周松林, 邢时超. 基于 Copula 理论及时序重构技术的相关性风速模拟[J]. 电力系统及其自动化学报, 2019, 31(8): 66-72. WU Weibing, ZHOU Songlin, XING Shichao. Correlative wind speed simulation based on Copula theory and time series reconstruction technology[J]. Proceedings of the CSU-EPSSA, 2019, 31(8): 66-72.
- [32] ELIA GROUP. ELIA grid data, 2019[EB/OL]. <https://www.elia.be/en/grid-data/data-download>.
- [33] HERSBACH H, BELL B, BERRISFORD P, et al. ERA5 hourly data on single levels from 1979 to present[Z]. Copernicus Climate Change Service (C3S) Climate Data Store (CDS), 2018.
- [34] GOERG G. Forecastable component analysis[C] // ICML, June 16-21, 2013, Atlanta, United States: 64-72.
- [35] 姚芳, 汤俊豪, 陈盛华, 等. 基于 ISSA-CNN-GRU 模型的电动汽车充电负荷预测方法[J]. 电力系统保护与控制, 2023, 51(16): 158-167. YAO Fang, TANG Junhao, CHEN Shenghua, et al. Charging load prediction method for electric vehicles based on an LSSA-CNN-GRU model[J]. Power System Protection and Control, 2023, 51(16): 158-167.

收稿日期: 2024-08-05; 修回日期: 2024-11-18

作者简介:

黎子律(2000—), 通信作者, 男, 硕士, 研究方向为人工智能在电力系统中的应用等; E-mail: 1205446089@qq.com

王星华(1972—), 男, 副教授, 硕士生导师, 研究方向为电力系统规划、电力系统自动化等。E-mail: riskmouse@163.com

(编辑 许威)