

DOI: 10.19666/j.rlfed.202506097

# 基于 TimeVAE 的 1DCNN-S-Mamba 组合模型光伏功率短期预测

许可证<sup>1</sup>, 文中<sup>1</sup>, 王秋杰<sup>1,2</sup>

(1. 三峡大学电气与新能源学院, 湖北 宜昌 443002;

2. 新能源微电网湖北省协同创新中心(三峡大学), 湖北 宜昌 443002)

[摘要] 针对极端天气下光伏功率预测存在的气象响应失准、突变特征捕捉困难及数据稀缺等问题, 提出一种基于模糊 C 均值 (fuzzy C-means, FCM)、最大信息系数 (maximum information coefficient, MIC)、时序变分自编码器 (time variational auto-encoders, TimeVAE)、一维卷积神经网络 (1D convolutional neural network, 1DCNN) 和 simple-Mamba (S-Mamba) 的组合功率预测模型。首先, 通过气象特征结合 FCM 聚类将天气划分为晴天、多云、降雪和降雨 4 类; 然后, 结合 MIC 筛选出最佳气象特征子集, 同时针对极端天气样本匮乏问题, 采用 TimeVAE 进行数据生成, 利用其分解式重构机制生成仿真数据; 最后, 使用 1DCNN-S-Mamba 组合模型通过局部卷积捕获短时突变特征, 结合双向状态空间建模实现长程依赖解析进行预测。实验结果表明, 该模型提升了复杂天气下光伏功率预测的时效性与准确性。相较于 S-Mamba, 所提模型平均绝对误差和均方根误差在降雪天气下分别降低了 3.65% 和 5.10%。

[关键词] 模糊聚类; 时序变分自编码器; 数据增强; 一维卷积神经网络; S-Mamba

[引用本文格式] 许可证, 文中, 王秋杰. 基于 TimeVAE 的 1DCNN-S-Mamba 组合模型光伏功率短期预测[J]. 热力发电, 2026, 55(1): 122-133. XU Kezheng, WEN Zhong, WANG Qiujie. Short-term photovoltaic power forecasting based on TimeVAE and 1DCNN-S-Mamba combined model[J]. Thermal Power Generation, 2026, 55(1): 122-133.

## Short-term photovoltaic power forecasting based on TimeVAE and 1DCNN-S-Mamba combined model

XU Kezheng<sup>1</sup>, WEN Zhong<sup>1</sup>, WANG Qiujie<sup>1,2</sup>

(1. College of Electrical and New Energy, China Three Gorges University, Yichang 443002, China;

2. Hubei Provincial Collaborative Innovation Center for New Energy Microgrid, China Three Gorges University, Yichang 443002, China)

**Abstract:** To address the challenges of meteorological-power response inaccuracy, difficulty in capturing abrupt features, and data scarcity in photovoltaic power prediction under extreme weather conditions, a hybrid prediction framework is proposed based on fuzzy C-means (FCM), maximum information coefficient (MIC), time variational auto-encoders (TimeVAE), 1D convolutional neural network (1DCNN), and simple-Mamba (S-Mamba). Firstly, meteorological features are clustered using FCM to categorize weather into four types: sunny, cloudy, snowy, and rainy. Subsequently, MIC is employed to select the optimal subset of meteorological features. To mitigate the scarcity of extreme weather samples, TimeVAE is adopted for data generation, leveraging its decomposed reconstruction mechanism to synthesize realistic time-series data. Finally, a 1DCNN-S-Mamba combined model is utilized, where 1DCNN captures short-term abrupt features through local convolution, while bidirectional state-space modeling in S-Mamba enables long-range dependency analysis for prediction. Experimental results demonstrate that the proposed model enhances both timeliness and accuracy in PV power prediction under complex weather conditions. Compared to S-Mamba, it reduces the mean absolute error (MAE) and root mean square error (RMSE) by 3.65% and 5.10%, respectively, in snowy weather scenarios.

收稿日期: 2025-06-03 修回日期: 2025-07-01 接受日期: 2025-07-04 网络首发日期: 2025-11-05

基金项目: 湖北省自然科学基金创新发展联合基金项目 (2024AFD362)

Supported by: Innovation and Development Joint Fund Program of Hubei Provincial Natural Science Foundation (2024AFD362)

第一作者简介: 许可证 (2001), 男, 硕士研究生, 主要研究方向为基于深度学习的光伏功率预测, 17686263606@163.com.

**Key words:** fuzzy clustering; time variational auto-encoder; data augmentation; 1D convolutional neural network; S-Mamba

随着气候变化引发的极端天气事件日益频繁,全球能源格局正在经历深刻变革<sup>[1]</sup>。作为清洁能源的重要载体,光伏发电系统的出力特性与气象条件存在强耦合关系,这种关联性在极端天气条件下表现得尤为突出。典型案例如 2021 年 7 月 20 日河南省特大洪涝灾害导致 246 座光伏电站受损,受损总装机容量达 45 572.9 kW; 2022 年 4 月 30 日内蒙古通辽光伏电站因暴雪灾害造成直接经济损失达 7 307.65 万元<sup>[2]</sup>。这些事件表明,极端天气对电网安全的威胁已从偶发性风险升级为系统性挑战。值得注意的是,传统基于历史气象数据的预测模型在应对复杂极端天气事件时,其预测误差率一般超过 30%,严重制约了电网调度系统的应急响应效能。尽管深度学习技术在常规时间序列预测中展现出卓越性能,但其在应对复杂极端天气场景时仍存在明显局限<sup>[3]</sup>。如何实现精准预测极端复杂天气光伏出力曲线是当前的关键课题。

当前极端气候下的光伏功率预测方法主要分为物理方法和统计方法两大类。物理方法通过建立辐照衰减模型,整合光伏设备特性与天气云层变化数据,具体实现途径有数值天气因数模型<sup>[4]</sup>、天空图像云图分析<sup>[5]</sup>及卫星遥感数据应用<sup>[6-7]</sup>。相关研究显示,文献[8]提出了一种基于地基云图云量特征的光伏发电功率区间预测方法,实现了对光伏出力的评估;文献[9]创新性地将数值天气预报的大尺度气象场预测与地基云图的局部特征相融合,设计了动态权重分配模块,从而实现数据协同运算。然而,这类方法对气象数据精度要求苛刻、难以准确模拟动态环境因素、对天气突变适应性较差、计算成本高昂且不适用于复杂地形场景。因此,物理方法更适合作为基础参考模型或与数据驱动方法结合使用,而非独立应用于高精度预测场景。

在统计方法领域,随着机器学习技术的进步,深度学习已成为主流预测手段。然而,这类方法依赖大量历史数据进行训练学习,在数据不足场景下,数据增强技术成为提升模型精度的有效解决方案<sup>[9-11]</sup>。文献[12]提出的基于生成对抗网络的多尺度判别器联合优化方法,通过时域频域特征协同处理降低了误码率;文献[13-14]开发的时间序列生成对抗网络(generative adversarial networks, GAN)模型,成功生成符合真实市场分布的多维时序数据,

缓解了数据稀疏性问题。但是,GAN 算法需要大量训练数据,这使得 VAE 模型在小数据集场景中更具应用优势,也促使研究者致力于开发更适合时间序列生成的改进 VAE 模型。

针对极端天气下复杂多变的光伏出力曲线,理想的预测模型需兼具状态突变响应能力和平稳序列生成能力。传统单一模型如卷积神经网络(CNN)、长短时记忆(LSTM)神经网络等的预测效果有限<sup>[15-19]</sup>,难以满足精度要求。近期研究涌现出多种改进方案:文献[20]结合特征优化与混合改进灰狼算法优化双向 LSTM 神经网络,在预测精度和效率上展现出双重优势;文献[21]基于改进 Transformer 架构开发的双通道编码器,通过分别捕捉长时序特征提升了故障诊断可靠性;文献[22]采用一种新型相似日方法和 VMD-NGO-BiGRU 混合模型的光伏短期功率预测方法,通过优化气象因子选取和深度学习超参数调整,显著提升了预测精度和计算效率。然而现有方法仍存在明显不足:多算法组合模型长期建模能力欠佳且结构复杂;全局建模算法对状态突变响应迟钝且算力需求高;某些改进模型虽提升了对中长期数据的预测能力,却无法有效处理短期预测任务和双向时序数据。

基于上述研究现状,本文提出一种融合时序变分自编码器(time variational auto-encoders, TimeVAE)、一维卷积神经网络(1D convolutional neural network, 1DCNN)和 simple-Mamba (S-Mamba)的 1DCNN-S-Mamba 复合模型,用于复杂气象条件下的光伏功率短期预测。该研究方案包含 3 个创新点:首先,通过气象因素聚类构建特殊数据集并进行特征筛选,为模型训练提供高质量数据基础;其次,针对数据稀缺和模型泛化问题,采用 TimeVAE 技术模拟生成复杂特殊天气数据;最后,创新性地结合一维卷积与 S-Mamba 结构,通过卷积操作和双向处理增强多尺度数据特征提取能力,在保证模型泛化性能的同时显著提升短期功率预测精度。实验验证表明,本文方法在复杂天气条件下的光伏出力曲线预测中表现出优越性能。

## 1 基本原理

### 1.1 模糊 C 均值聚类

光伏功率受天气因素影响显著。由于天气变化

具有一定的连续性和不确定性,FCM 聚类是一种基于模糊集理论的聚类方法,它允许数据点以一定的隶属度属于多个类别,而不像传统聚类将每个数据点明确划分到一个类别<sup>[23]</sup>。尤其是在天气突然变化的情况下,它不会强行划分到某一个类别。而是根据其特性,分别计算它属于不同类别的隶属度,从而给出更加灵活的聚类结果。其基本流程如图 1 所示。

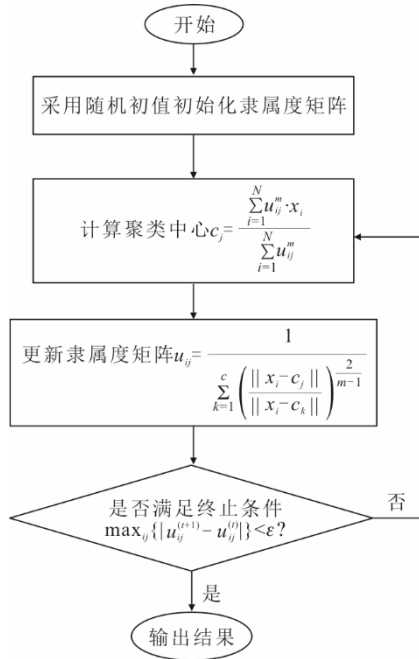


图 1 FCM 聚类流程  
Fig.1 FCM clustering flowchart

算法通过最小化目标函数来求解。其目标函数为:

$$J(u, c) = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2, \quad 1 \leq m < \infty \quad (1)$$

式中:  $N$  为聚类的种类;  $u$  为隶属度;  $u_{ij}^m$  为在  $m$  模糊决策加权指数条件下第  $i$  个特征数据对第  $j$  个聚类中心的隶属度;  $c$  为聚类数目, 本文聚类中心数目为 3;  $c_j$  为第  $j$  个聚类中心;  $x_i$  为第  $i$  个特征数据。

本文构建具有气象特征天气分类, 先通过 FCM 聚类光伏出力曲线, 将天气分为晴天、多云和特殊天气 3 类。随后结合其具体气象特征, 进一步识别并提取出具有降雨和降雪特征的复杂天气类型。

## 1.2 最大互信息数

最大互信息数 (MIC) 是一种衡量 2 个变量之间依赖关系的统计方法, 尤其适用于捕捉非线性关系。与传统的线性相关性度量方法不同, 该方法不

仅能够识别线性相关, 还能够检测线性关系、非线性关系、周期性模式等复杂且叠加的依赖关系。MIC 是基于互信息的理念发展而来, 旨在量化 2 个变量之间的信息共享程度<sup>[24]</sup>。互信息衡量了 2 个变量共同包含的信息量, MIC 的目标是寻找在多种不同划分方式下, 能够最大化变量间信息共享的分区。计算流程如下。

首先, 将变量数据分别划分为 2 个网格。然后, 在每个网格划分下, 计算变量  $x$  和  $y$  的互信息  $I(X, Y)$ , 该值反映了 2 个变量之间的相关性。互信息的定义为:

$$I(X, Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log_2 \left( \frac{p(x, y)}{p(x)p(y)} \right) \quad (2)$$

式中:  $p(x, y)$  为  $x$  和  $y$  的联合概率分布;  $p(x)$  和  $p(y)$  均为其边缘概率分布。

MIC 计算公式为:

$$\text{MIC}(X, Y) = \max_{G_x, G_y} \left( \frac{I(X, Y)}{\log_2(\min(G_x, G_y))} \right) \quad (3)$$

最终, 通过归一化, MIC 的值在 0~1 之间, 1 表示 2 个变量之间有非常强的相关性, 0 则表示几乎没有相关性。

## 1.3 时序变分自编码器

TimeVAE 模型于 2022 年提出, 旨在专门用于时间序列数据的生成任务<sup>[25]</sup>。相较于传统 GAN 的方法, TimeVAE 在捕捉时间序列中的动态演化特征方面表现更为出色。尽管部分基于 GAN 的变体尝试引入时间特征建模机制, 但通常依赖于大量训练数据和长时间训练过程, 难以适用于小样本场景。在本文背景下, TimeVAE 基于 VAE 架构, 通过潜在随机变量, 在小数据集上展现出更高的生成效率与表现能力, 能实现对时序数据的高质量生成。

TimeVAE 采用编码器-解码器架构实现时间序列生成。编码器通过卷积网络提取输入三维的局部时序特征, 映射为潜在空间参数, 并基于重参数化采样获得潜在变量  $z$ 。解码器将潜在变量重构为时序数据, 并分解为趋势项、季节项和残余项三部分, 三者叠加还原原始动态特征。训练时, 联合优化重构损失与 KL 散度, 确保生成数据贴近真实分布且结构可解释。其结构如图 2 所示。

对于时间序列, 在解码器部分加入趋势项, 将时间序列的趋势分解为多项式空间基函数的线性组合, 计算公式为:

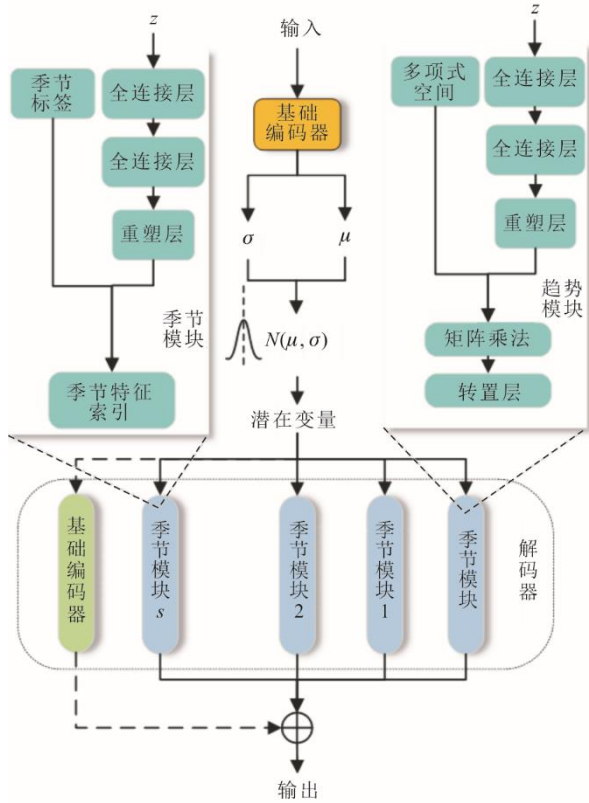


图 2 TimeVAE 结构流程

Fig.2 Flow diagram of the TimeVAE structure

$$\mathbf{V}_{tr} = \boldsymbol{\theta}_{tr} \cdot \mathbf{R} \quad (4)$$

$$\mathbf{R} = \begin{bmatrix} 1 & r_0 & r_0^2 & \cdots & r_0^{p-1} \\ 1 & r_1 & r_1^2 & \cdots & r_1^{p-1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & r_{T-1} & r_{T-1}^2 & \cdots & r_{T-1}^{p-1} \end{bmatrix}, r_t = \frac{t}{T} \quad (5)$$

式中:  $t$  为时间步;  $T$  为总时间步长;  $\mathbf{V}_{tr}$  为趋势项输出;  $\boldsymbol{\theta}_{tr}$  为从解码的多项式趋势系数;  $\mathbf{R}$  为多项式空间基函数矩阵。

对于季节项, 使用索引操作, 通过对时间步结合季节标签进行周期性索引处理, 捕捉序列中的重复结构。最终通过加和得到不同季节模式的总输出。其计算公式为:

$$\mathbf{V}_{sn} = \sum_{j=1}^S \boldsymbol{\theta}_{sn}^{(j)}(n, d, \mathbf{K}_t^{(j)}) \quad (6)$$

$$\mathbf{V}_{sn} = \sum_{j=1}^S \mathbf{V}_{sn}^{(j)} \quad (7)$$

式中:  $n$  为样本数量索引;  $d$  为特征维度索引;  $\mathbf{V}_{sn}^{(j)}$  为第  $j$  个周期性序列;  $S$  为季节模式个数;  $\boldsymbol{\theta}_{sn}^{(j)}$  为第  $j$  个周期的季节系数矩阵;  $\mathbf{K}_t^{(j)}$  为每个时间步所属的季节标签索引。

最终由残差项  $\mathbf{V}_{res}$  补充趋势项与周期项之外的复杂变化, 并与趋势项、季节项共同组成最终输出。其计算公式为:

$$\hat{\mathbf{X}} = \mathbf{V}_{tr} + \mathbf{V}_{sn} + \mathbf{V}_{res} \quad (8)$$

最终通过生成的数据最小化损失函数来确保生成质量, 该函数由重构误差和 KL 散度构成, 前者衡量潜在在重构输入数据时的信息损失, 并加入权重因子, 以增加或减少对重构误差的重视, 使生成样本贴近真实输入。后者用于度量后验分布与先验分布之间差异, 约束潜在空间的结构, 使其逐渐逼近设定的先验分布。提升潜在变量的泛化能力与分布一致性。计算公式为:

$$\mathcal{L}_{VAE} = -\lambda E_{q(z|x)}[\log_2 p(x|z)] + D_{KL}[q(z|x) \| p(z)] \quad (9)$$

式中:  $\lambda$  为权重因子;  $x$  为输入变量;  $z$  为潜在变量;  $E_{q(z|x)}$  为近似后验分布的数学期望;  $\log_2 p(x/z)$  为信息损失量;  $D_{KL}$  为 2 种分布的差异;  $q(z/x)$  为近似后验分布;  $p(z)$  为先验分布。

## 2 预测模型

### 2.1 一维卷积神经网络

为提升光伏时间序列数据的特征提取能力, 设计了一种轻量级的组合卷积结构, 该结构由一个普通卷积层与一个空洞卷积层串行构成, 可在不改变序列长度的前提下提取多尺度时间特征。CNN 能有效地提取局部特征, 获取数据的关键信息, 加快模型的处理速度和提高泛化能力。

1DCNN 模块在光伏预测中的作用是通过局部特征提取将原始时间序列数据转换为高层次时空特征表示, 在第 1 层卷积层中, 通过卷积核进行滑动扫描, 捕捉短时局部特征。第 2 层选择空洞卷积采取间隔采样的方式, 在不增加参数量或卷积核尺寸的前提下, 捕捉中期依赖关系。同时引入 ReLU 激活函数, 增强模型的非线性表达能力。整个模型输入输出时间步一致, 适配后续序列长度建模, 满足超短期光伏功率预测的需求。

### 2.2 S-Mamba 预测模型

Mamba 是一类构建于状态空间模型 (state space models, SSM) 基础上的新型序列建模算法。相较于 LSTM 神经网络在面对极端天气场景时因“记忆衰减”而难以捕捉长期滞后效应的局限, S-Mamba 能够有效对历史输入中跨天、跨周的依赖关系建模。而 Transformer 虽然理论上可建模任意长度的序列, 但

其计算复杂度  $O(N^2)$  在实际面对上千时间步的长序列时, 面临巨大的资源开销, 导致实用性下降。

**S-Mamba** 通过零阶保持技术来处理离散化的光伏数据, 并通过卷积进行计算<sup>[26]</sup>, 其卷积公式为:

$$y_t = \sum_{\tau=0}^t K_{t-\tau} x_\tau \quad (10)$$

$$K_t = CA^t B, [t=0,1,\dots,k] \quad (11)$$

式中:  $y_t$  为模型输出;  $x_t$  为模型输入;  $A$  为离散化后状态转移矩阵;  $B$  和  $C$  分别为离散输入和输出映射矩阵;  $K_t$  为时间步  $t$  卷积核值;  $k$  为卷积核长度;  $t$  为当前时间步。

通过 **HiPPO** (high-order polynomial projection operators) 初始化生成一个记忆其历史的隐藏状态, 以处理长距离依赖关系。数据选择依赖机制通过生成动态参数以提高捕捉输入序列中的关键事件的能力, 硬件感知算法通过并行计算和树状整合大大提高计算速度。

**S-Mamba** 主要由 4 层组成。第 1 层是线性标记层, 用线性层对时间序列进行标记。第 2 层是 **Mamba** 变分量编码层, 采用双向 **Mamba** 块捕获变量间的互信息。第 3 层是前馈网络时序编码层, 进一步学习时间序列信息, 通过前馈网络生成未来序列表示。第 4 层, 即投影层, 负责将上述各层的处理信息映射为模型的预测。

#### 1) 线性标记层

将原始时间序列数据通过线性变换标准化为高维特征, 目的是标准化时间序列格式, 通过单一线性层对时间序列进行标记化。计算公式为:

$$U_{in} \in R^{B \times V \times T} \quad (12)$$

$$U = \text{Linear}(\text{Batch}(U_{in})) \quad (13)$$

式中:  $U$  为线性标记输出;  $U_{in}$  为原始输入序列,  $B$  为批次大小;  $T$  为总时间步数;  $V$  为变量数。

#### 2) Mamba 变分量编码层

该层主要动态生成 **SSM** 参数, 通过关联不同变量间的相似趋势来获取它们的隐含特征, 从而学习变量间的信息。**Mamba** 的选择性机制类似于注意力机制, 但是其单向性限制了其对全局变量的建模能力。因此选择使用 2 个 **Mamba** 模块构成双向 **Mamba** 层, 用以捕捉所有变量间的相关性。其函数表达式为:

$$\vec{Y} = \overrightarrow{\text{Mamba Block}(U)} \quad (14)$$

$$\overleftarrow{Y} = \overleftarrow{\text{Mamba Block}(U)} \quad (15)$$

$$Y = \vec{Y} + \overleftarrow{Y} \quad (16)$$

$$U' = Y + U \quad (17)$$

式中:  $\vec{Y}$  为向前扫描输出;  $\overleftarrow{Y}$  为向后扫描输出;  $Y$  为特征融合;  $U'$  为残差连接输出。

双向 **Mamba** 的输出通过聚合并与残差网络连接, 形成该层的最终输出保留原始特征。

#### 3) 前馈网络时序编码层

这层主要提取单个变量的时间演化规律, 进一步处理变分量编码层的输出。采取了一个归一化层将输入数据标准化为高斯分布, 以提升深度网络的收敛速度和训练稳定性, 同时消除因测量尺度不同导致的差异。接着, 在前馈网络层对观察到的时间数据进行编码。通过非线性变换隐式建模时间依赖, 避免显式循环或注意力机制。最后设置另一个归一化层对未来序列进行调整。通过 2 次归一化分别约束输入和输出的分布范围, 避免深度网络因数据分布偏移导致的性能下降。

#### 4) 投影层

位于模型末端, 主要负责将高维特征映射到预测目标空间, 将经过前馈网络时序编码层处理后的标记化时间信息映射为需要预测的时间序列, 随后进行转置以产生最终的预测结果。

### 2.3 1DCNN-S-Mamba 组合模型

本文提出了一种基于 **1DCNN-S-Mamba** 架构的多尺度时序预测模型, 创新性地融合 **CNN** 与结构化状态空间模型, 实现了精准的短期功率预测。该模型采用分层递进架构进行时序信号分析, 其结构如图 3 所示。

1) 在特征提取阶段, 首先通过一维卷积层捕获光照强度突变等短期局部模式;

2) 采用空洞卷积层扩展感受野, 建立相邻中期趋势的关联规律;

3) 将聚合的多尺度特征输入 **S-Mamba** 预测模块, 先经线性分词层对时序进行标记化处理, 通过可学习线性变换完成高维特征空间映射; 继而采用双向 **Mamba** 编解码结构建模跨周期变量间的互信息关联性, 利用选择性状态空间算法捕捉动态时变依赖关系; 随后通过门控前馈网络整合历史信息, 构建时空关联的上下文表征; 最终借助动态权重投影层融合多级抽象特征, 通过可解释的特征组合机制生成未来序列预测结果。

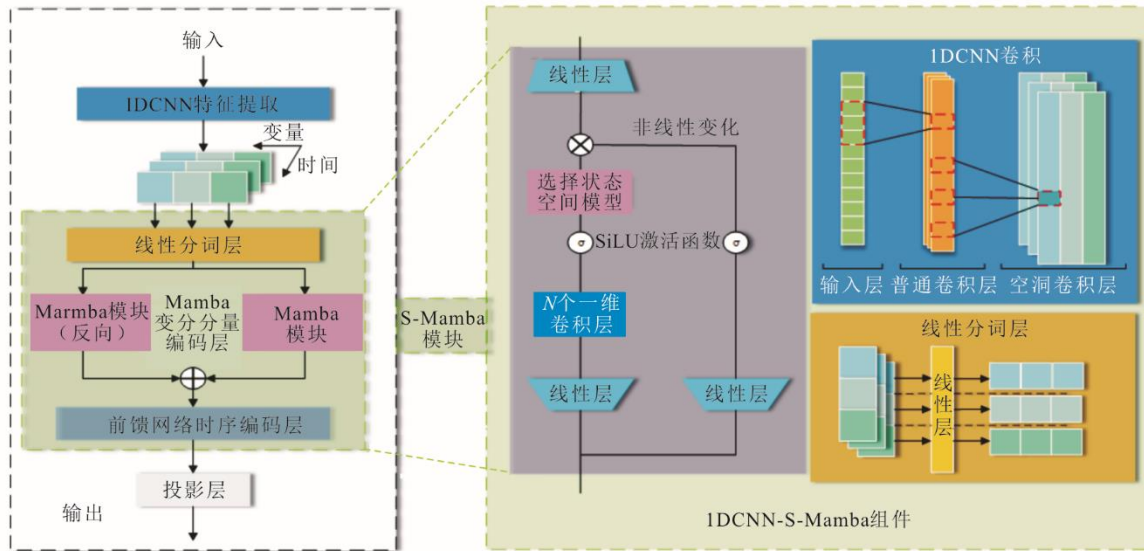


图 3 1DCNN-S-Mamba 结构  
Fig.3 Structure diagram of the 1DCNN-S-Mamba

### 3 模型整体流程

传统预测模型在气象突变场景下存在特征解耦能力不足、长周期依赖建模失效等问题。本文提出的融合聚类、特征筛选、数据增强和 1DCNN-S-Mamba 组合预测框架，具体预测步骤如图 4 所示。

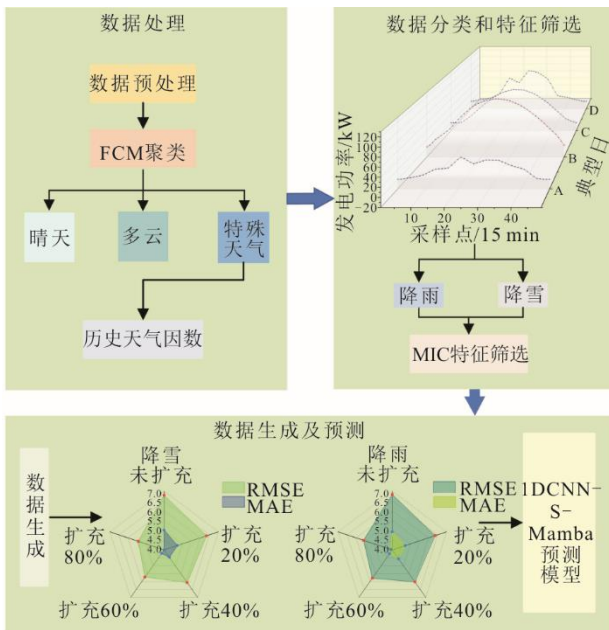


图 4 光伏功率组合预测流程  
Fig.4 Flowchart of the PV power mix forecast

第 1 步对数据集进行预处理。根据数据清洗原则对一些异常值进行删除，以及通过前后 5 天的同一时刻均值对数据的缺失值进行填充。

第 2 步通过 FCM 算法进行初步聚类，得到晴天、多云、特殊天气 3 类。然后结合特殊天气特征通过原则确定降雨、降雪特殊天气。

第 3 步使用 MIC 分别进行特征选择，并根据相关性和线性相关选出最佳特征子集。

第 4 步基于特殊天气较小的情况，使用 TimeVAE 进行数据生成，以扩充数据集提高后续预测模型的准确度；同时，采用 T-SNE 可视化分析（观察生成数据与原始数据的分布相似度）和 1DCNN-S-Mamba 预测误差分析（对比使用生成数据前后的模型误差），综合评价生成数据的质量。

第 5 步展示 1DCNN-S-mamba 算法给出的完整预测结果，并与其他算法进行对比。说明本文算法可行性和优越型。

### 4 算例及结果分析

#### 4.1 数据描述及评估指标

为了验证本文所建模型及方法的有效性，选取特殊天气进行试验。数据来自宁夏回族自治区某光伏电站 2017—2020 年的测量数据。由于光伏发电具有昼夜特性和季节特性，因此降雪选择每天的 09:00—20:30 时段，降雨选择每天 08:00—21:30 进行预测，数据每 15 min 采集 1 次，其中降雪共计 1 692 步，降雨共计 2 530 步。相关模型在基于 Python 语言的 Pytorch 环境中实现。硬件配置为 CPU, Intel Core i5-12700F; GPU RTX4060, 8 G; RAM, 16 GB。

本文采用评价指标分别为平均绝对误差 (mean

absolute error,  $\delta_{MAE}$ )、均方根误差 (root mean square error,  $\delta_{RMSE}$ )、马氏距离衡量向量距离。其计算公式分别为:

$$\delta_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$


$$\delta_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (19)$$

$$D_M(x, y) = \sqrt{(x - y)^T \Sigma^{-1} (x - y)} \quad (20)$$


式中:  $n$  计算的样本总数;  $y_i$  为第  $i$  个预测值;  $\hat{y}_i$  为第  $i$  个实际值;  $x$  和  $y$  为降维后的变量坐标值。

#### 4.2 聚类结果分析


将清洗后的数据使用 FCM 算法对功率曲线进行聚类, 结合降雪和降雨特征因素分成 4 类。聚类结果如图 5 所示。



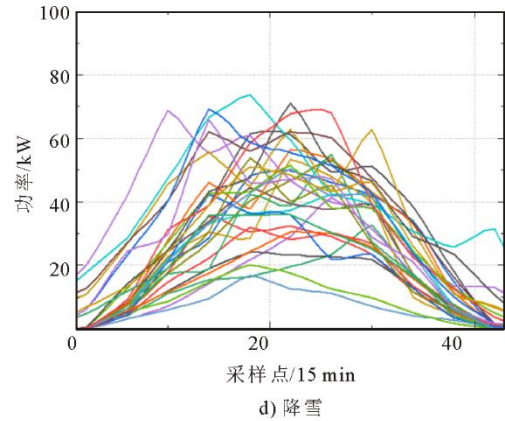
a) 晴天



b) 多云



c) 降雨



d) 降雪

图 5 不同天气聚类结果  
Fig.5 Clustering results of different weathers

由图 5 可见, 晴天时光伏功率曲线高度集中, 呈对称单峰状, 单峰对称性表明功率随时间呈典型“钟形曲线”, 符合正午光照最强、早晚功率较低的规律。晴天光照稳定且充足, 光伏发电或用电设备功率输出规律性强, 无明显外界干扰。多云时峰值比晴天光伏偏低, 整体波形还是处于稳定的状态, 只是功率输出稍微受到影响。云层遮挡导致峰值降低, 但时间分布规律与晴天相似。降雨天气的光伏功率曲线分散、波动大, 无显著峰值; 阵雨天气突发性强, 光照和温度剧烈波动, 导致功率曲线呈现不规则波动。不同样本的降雨时间、强度和持续时间差异较大, 导致聚类分散, 难以形成统一模式。降雪曲线分散且整体功率值较低, 无显著峰值。降雪伴随低温、光照弱且持续时间长, 功率曲线呈现持续低值, 但不同样本的积雪厚度、融化速度差异导致曲线分散。

#### 4.3 特征选择结果

使用 MIC 对所有数据之间进行相关性分析, 根据相关度对不同天气筛选特征。数据相关性热力图如图 6 所示, 图 6 中左侧为降雪数据集, 右侧为降雨数据集。从图 6 可以看出, 5 种辐射统计量之间存在高度的相关性, 为避免多重共线性问题, 只选择表现最好的量即总辐射。其余不同类型变量之间虽然相关性较强, 但是考虑到机制独立性, 不能根据其相关性系数大小直接进行处理。

考虑到特征选择最终是为预测结果做铺垫, 因此使用 S-Mamba 作为预测模型, 同时选取均方根误差作为评价指标。采取淘汰策略, 逐步移除互信息最低的特征, 不断重复这一策略, 直至出现最优特征子集, 表 1 为去除特征均方根误差变化。由表 1

可见, 选择云层不透明度、露点温度、总辐射、大气可降水量、气温、降雪深度和相对湿度作为最优降雪特征子集。同时由于降雨天气数据集中, 降雪

深度为 0, 因此, 降雨天气最优数据集为云层不透明度, 露点温度、总辐射、气温、大气可降水量和相对湿度。

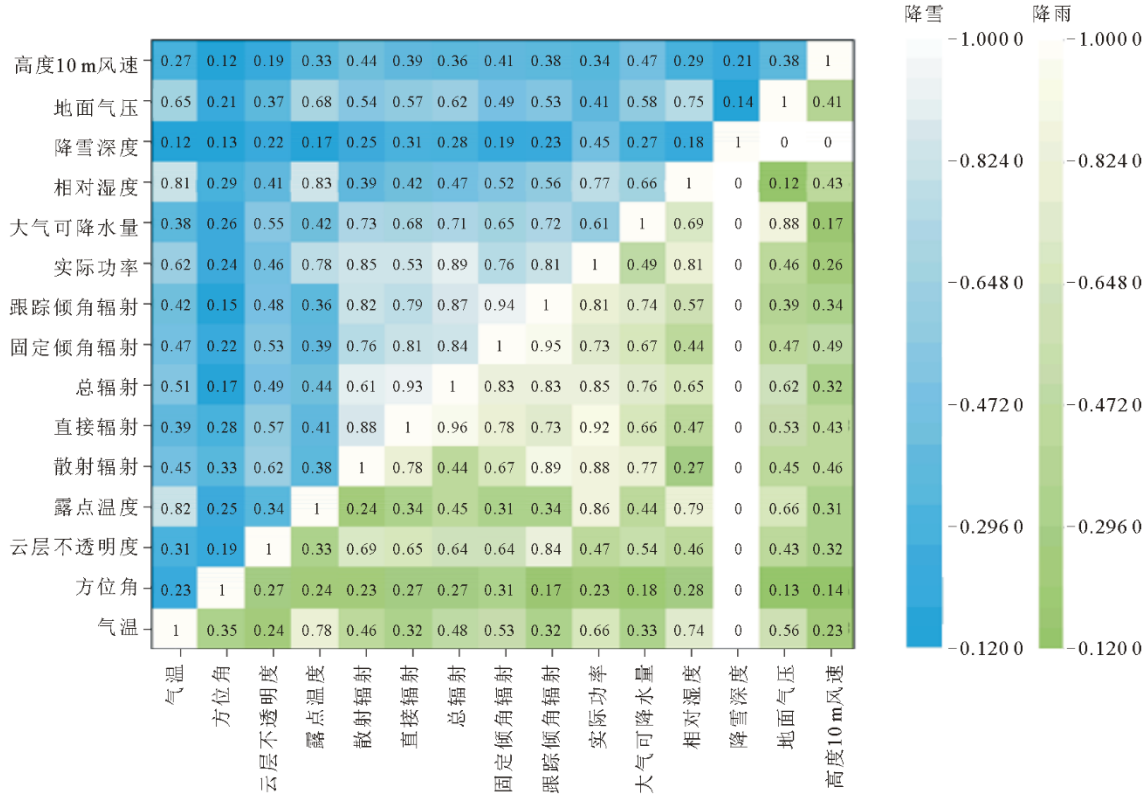


图 6 数据相关性热力图  
Fig.6 Data correlation heat map

表 1 去除特征均方根误差变化  
Tab.1 Changes in RMSE after feature removal

天气类型	去除特征	$\bar{\alpha}_{RMSE}/kW$
降雪	无	7.76
	方位角	7.43
	方位角、高度 10 m 风速	6.85
	方位角、高度 10 m 风速、地面气压	6.53
	方位角、高度 10 m 风速、地面气压、降雪深度	7.23
降雨	无	7.46
	方位角	7.12
	方位角、高度 10 m 风速	6.94
	方位角、高度 10 m 风速、地面气压	6.79
	方位角、高度 10 m 风速、地面气压、云层不透明度	7.02

### 4.4 数据生成结果分析

采用降雨、降雪 2 个数据集验证生成数据的有效性和评估生成数据质量。首先采用原始数据和合成数据的 T-分布随机邻域 (T-distributed stochastic neighbor embedding, T-SNE) 嵌入, 通过将高维数据嵌入二维空间中, 使得对复杂的数据结构的理解更加直观 (图 7)。对 2 种天气类型生成的功率曲线

进行展示, 选择使用 1DCNN-S-Mamba 进行预测。同时对生成结果采用 1% 递增的方式来确定最优数据生成结果。TimeVAE 参数设置见表 2, 图 8 为数据生成评估结果变化, 图 9 为降雪、降雨天气光伏功率对比。




图 7 T-SNE 可视图  
Fig.7 T-SNE visualization diagram

表 2 TimeVAE 参数设置  
Tab.2 TimeVAE parameter settings

参数符号	参数名称	参考值
Latent_dim	潜在空间维度	16
hidden_layer_sizes	隐含层结构	50, 100, 200
reconstruction_wt	重建损失权重	2.0
batch_size	批次大小	32

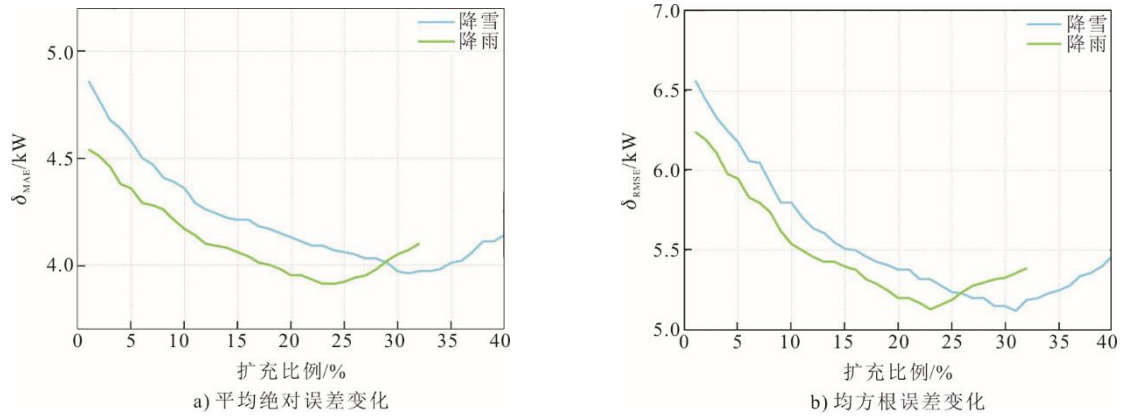


图 8 数据生成评估结果变化  
Fig.8 Changes of data generation evaluation results




图 9 降雪降雨天气光伏功率对比  
Fig.9 The photovoltaic power in snowfall and rainfall weather

由图 7—图 9 可见：


1) 随着数据扩充比例从 0 增至 40%，降雪与降雨天气的平均绝对误差和均方根误差均呈现 U 型曲线。其中降雪天气在 20%~30% 扩充区间内评估指标保持最低值，在扩充 31% 时达到最佳值，其均方根误差为 5.14 kW，平均绝对误差为 3.96 kW；而降雨天气的最优区间提前至 15%~20%，在扩充 23% 达到最佳值，其中均方根误差为 5.13 kW，平均绝对误差为 3.91 kW，超过该阈值后 2 类误差均显著反弹。

2) 生成数据具有较好的周期性，生成数据的整体波形与原数据具备相同的变化趋势，并且针对一些突变情况也能进行模仿。生成数据从具体数值上看还存在一定的差异性，正是这种差异性大大丰富了数据集，增加了数据的多样性。T-SNE 中可以看到原始数据与生成数据在中心区域重叠显著，说明生成数据逼近真实数据。但在边缘区域分布稀疏，这是因为极端天气事件稀少，符合真实天气状况。

#### 4.5 预测结果分析

为了验证模型预测的性能，分别对 2 种天气类

型的样本数据进行预测。针对降雨和降雪，采用 5 种代表性的网络模型进行对比，来验证本文算法的有效性，包括 S-Mamba、LSTM、Transfomer 和 Informer。每种天气类型分别选择测试集第 1 个月的最后 4 天进行可视化分析。各算法模型预测结果误差对比如图 10 所示，不同算法预测结果如图 11 所示。






图 10 模型预测结果误差对比  
Fig.10 The errors of the model prediction results

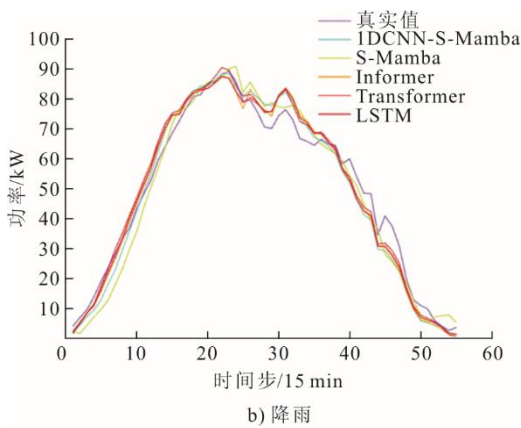
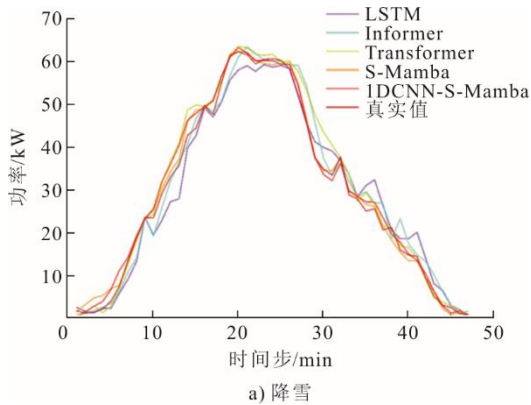


图 11 不同算法预测结果  
Fig.11 Prediction results by different algorithms

由图 10—图 11 可见：

1) 1DCNN-S-Mamba 组合模型在复杂天气条件下的光伏功率预测表现优于单一模型。实验数据显示，在降雪和降雨场景中，该组合模型相比单一 S-Mamba 模型的均方根误差分别降低了 5.1% 和 5.7%，平均绝对误差分别降低了 3.65% 和 4.72%。值得注意的是，S-Mamba 与 1DCNN-S-Mamba 的性

能差距较小，这说明 SSM 本身已具备较强的时序建模能力，而融合卷积模块可以进一步增强局部特征提取的敏感性。这一结果验证了 1DCNN 的局部特征提取能力与 S-Mamba 时序建模能力的协同效应，能够有效预测复杂的光伏功率曲线。另外，所有模型在降雪场景下的均方根误差和平均绝对误差均高于降雨场景，这表明由于降雪数据集相对较小，模型在该场景下的表现不如降雨天气，进一步凸显了数据增强的重要性。

2) 在降雨场景中，功率预测波动范围达到 0~120 kW，其中 1DCNN-S-Mamba 在高功率区的预测误差较 Informer 降低了 43.5%；而在降雪场景中，功率预测波动范围缩小至 0~90 kW，本文模型在低功率区仍能保持平均绝对误差小于 3.5 kW，验证了本文模型的普适性。值得注意的是，在天气突变阶段，所有模型都会出现短暂的滞后现象。其中，1DCNN-S-Mamba 和 S-Mamba 的预测曲线最接近真实值，能够准确跟踪真实功率的变化，特别是在放大图中可以看到其波动幅度较小。相比之下，Informer 和 Transformer 的预测值普遍偏大，LSTM 则存在明显的滞后现象。虽然降雨天的功率波动较大，而降雪天的整体功率较低，但模型在不同天气条件下的相对性能保持一致。无论是处于平稳上升阶段还是波动阶段，本文所提组合模型都能提供良好的预测结果。

## 5 结 论

本文针对复杂天气光伏功率预测精度不足的问题，提出了一种融合 FCM 天气聚类、最大信息系数特征筛选、时序变分自编码数据增强的 1DCNN-S-Mamba 组合模型的预测框架。通过对宁夏地区光伏电站的实证分析，验证了该方法在复杂天气条件下的预测精准度。得到以下结论：

1) 基于 FCM 的天气分类通过光伏功率出力曲线，成功将天气类型划分为晴天、多云及特殊天气 3 类。后结合具体气象特征，成功将特殊天气分为降雪、降雨 2 类，为后续预测模型提供精确的气象场景划分。并通过 MIC 分别选取最佳子集，提高模型精度及运算速度。

2) TimeVAE 在小样本的场景下展现出优异的生成能力，通过趋势项、季节项和残差项对数据进行重构生成。模型均方根误差、平均绝对误差在降雨、降雪场景均有改善。证明生成数据能够有效增

强模型对复杂天气突变状态的泛化能力。

3) 1DCNN-S-Mamba 模型通过局部卷积与全局状态空间的组合建模, 相较传统单一算法在降雨、降雪天气下均有所改进, 其双重卷积模块提高了模型对局部突变情况的预测能力, 双向 mamba 模块对不同变量跨周期的动态编码能力, 提高了模型对动态变化的适应能力。在不同的天气状态下, 该模型仍具有良好的泛化性能。

本研究虽然在复杂天气光伏功率预测方法上有所突破, 但是在“双碳”目标下, 新能源出力激增的双重挑战下, 更需要建立物理-算法模型融合架构, 同时提升对台风、冰雹等复合极端型天气的预测精准度。当前模型仍旧以数据驱动为主, 未能深度融合光伏板积雪融化、云层透射率衰减等物理学方程。未来研究应注重多种物理、算法模型结合。构建适应不同天气状况、地理特征的预测系统。

#### [参考文献]

- [1] 李国荣, 张云鹏, 周海, 等. 基于有效辐照度修正的光伏电池模型参数辨识和输出特性建模研究[J]. 电工技术学报, 2024, 39(23): 7331-7340.  
LI Guorong, ZHANG Yunpeng, ZHOU Hai, et al. Parameter identification and output characteristics modelling of photovoltaic module based on effective irradiance correction[J]. Transactions of China Electrotechnical Society, 2024, 39(23): 7331-7340.
- [2] 陈思宇, 蒋俊霞, 李帅兵. 极端气候条件下光伏发电功率预测方法综述[J]. 电气工程学报, 2025, 20(1): 281-290.  
CHEN Siyu, JIANG Junxia, LI Shuaibing, et al. Review of photovoltaic power prediction methods under extreme climate conditions[J]. Chinese Journal of Electrical Engineering, 2025, 20(1): 281-290.
- [3] 叶林, 裴铭, 李卓, 等. 风电和光伏发电功率联合预测与预调度框架[J]. 高电压技术, 2024, 50(9): 3823-3836.  
YE Lin, PEI Ming, LI Zhuo, et al. Framework for Joint wind and photovoltaic power forecasting and pre-dispatch[J]. High Voltage Engineering, 2024, 50(9): 3823-3836.
- [4] AKPULUMA D, YURCHENKO A V, FIROZ N, et al. Enhanced forecasting of PV power output using LSTM integrated with LASSO-RFR hybrid models in extreme weather conditions[C]//Proceedings of the 2024 IEEE 3rd International Conference on Problems of Informatics, Electronics and Radio Engineering (PIERE), 2024: 780-785.
- [5] 程礼临, 臧海祥, 卫志农, 等. 考虑多光谱卫星遥感的区域级超短期光伏功率预测[J]. 中国电机工程学报, 2022, 42(20): 7451-7465.  
CHENG Lilin, ZANG Haixiang, WEI Zhinong, et al. Ultra-short-term forecasting of regional photovoltaic power generation considering multispectral satellite remote sensing data[J]. Proceedings of the CSEE, 2022, 42(20): 7451-7464.
- [6] 王迎春, 王昱栋, 刘洋, 等. 基于卫星遥感多光谱云图的生成式海上超短期光伏功率预测[J]. 控制与决策, 2025, 40(4): 1136-1144.  
WANG Yingchun, WANG Yudong, LIU Yang, et al. Ultra-short-term prediction of offshore photovoltaic power based on satellite remote sensing multi-spectral cloud image[J]. Control and Decision, 2025, 40(4): 1136-1144.
- [7] 陈殿昊, 臧海祥, 蒋雨楠, 等. 基于多层次云图特征与宽度学习的超短期光伏功率预测[J]. 电力系统自动化, 2024, 48(22): 131-139.  
CHEN Dianhao, ZANG Haixiang, JIANG Yunan, et al. Ultra-short-term photovoltaic power forecasting based on multi-level sky image features and broad learning[J]. Automation of Electric Power Systems, 2024, 48(22): 131-139.
- [8] 刘翼飞, 崔承刚. 基于地基云图云量特征的光伏发电功率区间预测[J]. 南方电网技术, 2023, 17(2): 92-100.  
LIU Yifei, CUI Chenggang. Interval prediction for short-term solar power based on cloud features of ground-based cloud images[J]. Southern Power System Technology, 2023, 17(2): 92-100.
- [9] 尹杰, 刘博, 孙国兵, 等. 基于迁移学习和降噪自编码器-长短期记忆的锂离子电池剩余寿命预测[J]. 电工技术学报, 2024, 39(1): 289-302.  
YIN Jie, LIU Bo, SUN Guobing, et al. Transfer learning denoising autoencoder-long short term memory for remaining useful life prediction of Li-ion batteries[J]. Transactions of China Electrotechnical Society, 2024, 39(1): 289-302.
- [10] 魏书荣, 殷世杰, 闫梦飞, 等. 基于改进生成对抗网络的海上风电机组故障数据增强及诊断[J]. 电力系统保护与控制, 2025, 53(1): 114-124.  
WEI Shurong, YIN Shijie, YAN Mengfei, et al. Offshore wind turbine fault data enhancement and diagnosis based on an improved generative adversarial network[J]. Power System Protection and Control, 2025, 53(1): 114-124.
- [11] 殷豪, 张铮, 丁伟锋, 等. 基于生成对抗网络和 LSTM-CSO 的少样本光伏功率短期预测[J]. 高电压技术, 2022, 48(11): 4342-4351.  
YIN Hao, ZHANG Zheng, DING Weifeng, et al. Short-term prediction of small-sample photovoltaic power based on generative adversarial network and LSTM-CSO[J]. High Voltage Engineering, 2022, 48(11): 4342-4351.
- [12] JIANG J, KIM D, KIM B, et al. GA-VAE: enhancing local feature representation in VQ-VAE through genetic algorithm-based token optimization[J]. IEEE ACCESS, 2025, 13: 34286-34295.
- [13] 刘君, 邓毅, 杨延西, 等. 基于条件生成对抗网络的空气预热器内红外补光监测视频图像清晰化方法[J]. 热力发电, 2021, 50(10): 130-134.  
LIU Jun, DENG Yi, YANG Yanxi, et al. Method for sharpening infrared compensation image for monitoring video inside air preheater based on cGAN network[J]. Thermal Power Generation, 2021, 50(10): 130-134.
- [14] KIM W, JEON J, KIM S, et al. Prediction of index futures movement using time-GAN and 3D-CNN: empirical evidence from Korea and the United States[J]. Applied Soft Computing, 2025, 171: 112748.
- [15] SURESH V, JANIK P, REZMER J, et al. Forecasting solar PV output using convolutional neural networks with a sliding window algorithm[J]. Energies, 2020, 13(3): 723.
- [16] YU Y J, CAO J F, ZHU J Y. An LS-TM short-term solar irradiance forecasting under complicated weather conditions[J]. IEEE ACCESS, 2019, 7: 145651-145666.
- [17] 王家乐, 张耀, 林帆, 等. 基于自注意力特征提取的光

- 伏功率组合概率预测[J]. 太阳能学报, 2024, 45(12): 123-131.  
WANG Jiale, ZHANG Yao, LIN Fan, et al. Combining probabilistic prediction of PV power based on self-attention feature extraction mechanism[J]. Acta Energetica Solaris Sinica, 2024, 45(12): 123-131.
- [18] 李永飞, 张耀, 林帆, 等. 基于气候特征分析及改进XGBoost算法的中长期光伏电站发电量预测方法[J]. 电力系统保护与控制, 2024, 52(11): 84-92.  
LI Yongfei, ZHANG Yao, LIN Fan, et al. Medium- and long-term power generation forecast based on climate characterisation and an improved XGBoost algorithm for photovoltaic power plants[J]. Power System Protection and Control, 2024, 52(11): 84-92.
- [19] IOANNIS K, BAZIONIS, MARKOS A, et al. Investigation of LSTM-based hybrid approaches for short-term PV power forecasting[J]. IET Conference Proceedings, 2025, 2024(29): 346-351.
- [20] 赵如意, 王晓辉, 郑碧煌, 等. 基于特征优化和混合改进灰狼算法优化BiLSTM网络的短期光伏功率预测[J]. 电网技术, 2025, 49(1): 209-222.  
ZHAO Ruyi, WANG Xiaohui, ZHENG Bihuang, et al. Short-term photovoltaic power prediction based on feature optimization and hybrid improved grey wolf algorithm-optimized BiLSTM network[J]. Power System Technology, 2025, 49(1): 209-222.
- [21] 林江, 蔡晓龙, 周剑桥. 基于Transformer模型的光伏系统故障分类与预测方法[J]. 智慧电力, 2025, 53(4): 96-102.  
LIN Jiang, CAI Xiaolong, ZHOU Jianqiao. Transformer model-based fault classification and prediction method for photovoltaic systems[J]. Smart Power, 2025, 53(4): 96-102.
- [22] 常青松, 杨昭, 杨熠辉, 等. 基于相似日聚类的超短期光伏功率组合预测模型[J]. 热力发电, 2023, 52(11): 123-131.  
CHANG Qingsong, YANG Zhao, YANG Yihui, et al. Ultrashort term photovoltaic power combinatorial forecasting model based on similar day clustering[J]. Thermal Power Generation, 2023, 52(11): 123-131.
- [23] 周育才, 肖添, 谢七月, 等. 基于聚类的HPO-BiLSTM光伏功率短期预测[J]. 太阳能学报, 2024, 45(4): 512-518.  
ZHOU Yucai, XIAO Tian, XIE Qiyue, et al. Clustering-based HPO-BiLSTM short-term prediction of PV power[J]. Acta Energetica Solaris Sinica, 2024, 45(4): 512-518.
- [24] 许越, 李强, 崔晖. 基于MIC-EEMD-改进Informer的含高比例清洁能源与储能的电力市场短期电价多步预测[J]. 电网技术, 2024, 48(3): 949-958.  
XU Yue, LI Qiang, CUI Hui. Short-term multi-step price prediction for the electricity market with a high proportion of clean energy and energy storage based on MIC-EEMD-improved informer[J]. Power System Technology, 2024, 48(3): 949-958.
- [25] DESAI A, FREEMAN C, BEAVER I et al. Timevae: a variational auto-encoder for multivariate time series generation[EB/OL]. (2022-05-12) [2025-01-10]. <https://arxiv.org/pdf/2111.08095>
- [26] WANG Z H, KONG F H, FENG S, et al. Is mamba effective for time series forecasting?[J]. Neurocomputing, 2025, 619: 129178.

(责任编辑 杜亚勤)