DOI:10.3969/j.issn.1009-1831.2026.06.018 文章编号:1009-1831(2026)06-0125-06 中图分类号:TM615

基于DBSCAN-Kmeans-PINN-InformerStack混合模型的多变天气光伏出力预测

周承翰[1],黄艺璇[1],庄 重[1],段梅梅[1],盛 举[1],徐青山[2]
(1. 国网江苏省电力有限公司 营销服务中心,南京 210019;2. 东南大学 电气工程学院,南京 210000)

摘要:为提升光伏出力预测在多变天气条件下的精度,提出了一种融合基于密度的有噪空间聚类应用算法(DBSCAN)、物理信息神经网络(physics-informeel neural network,PINN)与InformerStack的混合预测方法。该方法首先利用DBSCAN的异常点筛选能力,将气象数据划分为极端天气类与常规天气类;随后结合Kmeans聚类与物理阈值对常规天气类进行更细致的分类。根据不同天气类别下的气象特征与光伏出力的关联性,选择相应的输入特征集。进一步地,将PINN的物理约束优势与InformerStack在长时序建模上的性能相结合,以充分利用气象特征对光伏出力的影响规律。基于实测数据的对比实验结果表明,该方法在多变天气情境下的预测精度显著优于传统模型。研究结论显示,该方法的均方根误差由Informer模型的0.248 63减小到0.119 26,融合聚类方法、物理信息约束和深度时序建模的综合框架能够有效提升光伏出力预测的鲁棒性与可靠性。

关键词:InformerStack模型;极端天气;多变天气;光伏发电;出力预测

Photovoltaic power output prediction under variable weather based on a hybrid DBSCAN-Kmeans-PINN-InformerStack model

ZHOU Chenghan[1], *HUANG Yixuan*[1], *ZHUANG Zhong*[1], *DUAN Meimei*[1], *SHENG Ju*[1], *XU Qingshan*[2]
(1. Marketing Service Center, State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210019, China; 2. Electrical Engineering College, Southeast University, Nanjing 210000, China)

Abstract: To improve the accuracy of photovoltaic power output forecasting under variable weather conditions, a hybrid prediction approach integrating DBSCAN, Kmeans, physics-informed neural networks (PINN), and InformerStack is proposed. Abnormal samples are first detected and separated by DBSCAN, and meteorological data are divided into extreme weather and regular weather categories. Subsequently, Kmeans clustering combined with physical thresholds is applied to further refine the classification of regular weather conditions. Based on the relationship between meteorological features and photovoltaic output under different weather categories, appropriate input feature sets are selected. Furthermore, the advantages of PINN in embedding physical constraints are combined with the capability of InformerStack in long-sequence modeling to fully exploit the influence of meteorological factors on photovoltaic output. Comparative experiments on measured data demonstrate that the proposed method significantly outperforms traditional models in prediction accuracy under variable weather scenarios. The research results show that the root mean square error is reduced from 0.248 63 with the Informer model to 0.119 26 using the proposed method. It is concluded that the integrated framework combining clustering techniques, physics informed constraints, and deep temporal modeling can effectively enhance the robustness and reliability of photovoltaic power output forecasting.

Key words: InformerStack model; extreme weather; changeable weather; PV power generation; output forecasting

0 引言

随着“双碳”目标的推进,光伏发电因绿色低碳、可再生而得到迅速发展。但由于光伏发电随机性和波动性强,受气象条件影响显著,其发电功率剧烈变化对电网调度、电力供应安全和储能控制带来挑战。光伏发电预测模型按照预测机制大致可分为物理模型、统计模型和人工智能模型[1-2]。

早期研究主要依赖于物理模型和统计模型(如ARIMA、线性回归),泛化能力有限。为此,研究重心转向人工智能模型,如BP神经网络、支持向量机和随机森林等传统机器学习方法。但它们对长时间序列中动态依赖关系的捕捉能力仍显不足[3-4]。

收稿日期:2026-01-07;**修回日期**:2026-03-19
基金项目:国网江苏省电力有限公司科技项目(J2024165)

研究者普遍认识到，单一模型的预测效果常逊于混合模型。文献[5]集成了时变滤波经验模态分解(time-varying filter-based empinzal mode decomposition，TVF-EMD)和极端学习机，采用TVF-EMD对原始光伏功率时间序列进行分解，将非平稳、非线性的功率数据分解为多个相对稳定的本征模态函数分量，减少模态混叠现象，提升数据质量。文献[6]采用改进蜣螂优化算法优化长短期记忆网络模型进行光伏发电功率预测，算法的收敛速度和寻优能力得到提高。文献[7]提出了一种基于广义场景划分的RIME-algorithm convolutional neural network-long short term memory-attention(RIME-CNN-LSTM-Attention)光伏出力组合预测模型。该方法在波动性强的场景下相较于传统气象分型以及未引入优化算法的预测模型预测精度分别提高17.4%和27.3%。文献[8]提出一种以马尔科夫方法进行修正误差的BP神经网络预测模型，能在数据较少的情形下建模，预报总体趋势，且对波动性较大的随机序列也有一定的预测能力。文献[9]提出了一种基于自注意力机制的神经网络模型，用于在多场景下实现高精度光伏发电功率预测。实验结果表明，该方法在多种天气条件下均能精准跟踪功率变化，决定系数达到0.985 1。

现有混合模型大多追求一个通用模型，期望其在所有天气条件下均表现优异[10]。然而，晴天、多云、阴雨等不同天气类型下的光伏出力数据生成机制迥异。一个在平稳序列上训练优化的模型，难以自适应地捕捉突变天气下的剧烈波动特征。文献[11]提出一种结合主成分分析、双通道注意力机制和Informer的短期光伏发电量预测新模型。该模型在晴天下的预测效果很好，但在阴天、雨天下的预测效果略差。文献[12]给出了一种结合经验模态分解、小波阈值去噪和麻雀搜索算法优化Informer模型的短期光伏发电功率预测方法。结果表明，即便是先进的混合模型，其在阴雨天的误差仍是晴天的数倍。

当前混合模型多为数据驱动的“黑箱”模型，虽通过信号预处理间接反映了数据的某些物理特性，但未能将光伏发电的物理规律以显式约束的方式深度嵌入到模型的训练与推理过程中[13-15]。这种物理机制缺失的模型，在训练数据覆盖不足的极端或骤变天气场景下，容易产生违背物理常识的预测结果，泛化能力与可解释性受到限制。

针对以上问题，本文对InformerStack模型进行改进，在数据分辨率达到15 min时，能够较好地预测多变天气下的光伏出力。

1 气象条件分类

1.1 气象特征选取

依据《光伏发电站设计规范》，光伏出力可按下式计算

$$E = H_A \times \frac{P_{AZ}}{E_S} \times K \tag{1}$$

式中：E为上网发电量；H_A为水平面太阳能总辐射量；E_S为标准条件下的辐照度；P_{AZ}为组件安装容量；K为综合效率系数。

式(1)表明，水平面太阳能总辐射量直接决定光伏发电量的大小，是决定出力的重要变量。同时，综合效率系数受多种气象因素的影响，如温度影响组件效率与热衰减，云层覆盖影响直散与短时波动，风速与风向影响组件散热性能等。

因此，本文以水平面太阳能总辐射量、高云层云量、中云层云量、低云层云量、温度、湿度、风速、风向作为模型必要输入特征。

1.2 极端天气类的划分

基于密度的有噪空间聚类应用(density-based spatial clustering of application with noise，DBSCAN)是一种基于密度的无监督机器学习方法，该方法通过分析辐照度、温度、湿度等气象要素的密度分布特征，能够自动识别出对光伏发电具有相似影响的气象条件簇，剔除异常气象数据点。

在特征空间中，极端天气事件通常表现为远离主要簇中心的孤立点或小范围聚集簇。例如，高温、强风、强降水、沙尘暴等极端事件在气象要素的密度分布上与正常天气模式差异明显。DBSCAN能够将这些点标记为噪声或小簇，从而划分出极端天气类，再通过设定物理阈值对极端天气类做进一步划分。

依赖于多个气象要素的复合型标准，在实际应用中确实可能面临交叉影响、区域适用性不足等挑战。由于某一地区的划分标准并不一定适用于其他地区，因此，为了提升标准的科学性和普适性，现将天气划分标准区域化通过融合多源数据、允许地方弹性调整、并紧密关联社会影响，才能使其在各种复杂的气象条件和地域背景下，都保持高度的科学性和实用性。以南京地区为例，如表1所示，气温超过35 ℃的天气可判定为高温天气，风速大于10.8 m/s的天气可判定为大风天气。

表1　极端天气划分标准

Table 1　Extreme weather classification standards

极端天气类别	判定条件
高温	温度大于等于35 ℃
极寒	温度小于等于−10 ℃
强降水	12 h降水量大于等于30 mm
大风	风速大于10.8 m/s
沙尘暴	水平能见度小于等于1 km
强霾	水平能见度小于等于1 km且相对湿度大于等于80%
暴雪	12 h降雪量大于等于10 mm

1.3　常规天气类的划分

对于常规天气类样本，采用Kmeans聚类算法对气象数据进行无监督分类，具体流程如图1所示。根据辐照度、云量等气象指标的分布特征，可将其划分为晴天、多云天、阴天、雨天和多变天气，具体划分标准如表2所示。这种结合密度聚类与物理阈值的双重划分方式，不仅能够反映气象要素的客观分布特征，还能保证结果符合气象学定义，从而为光伏出力预测提供更加精准的天气模式分类依据。

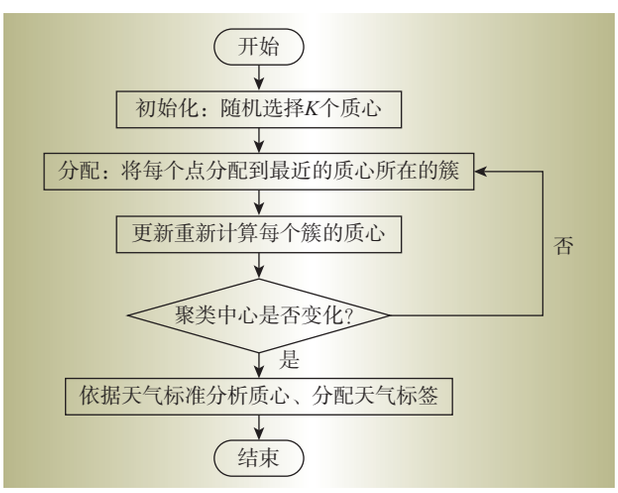


图1　数据分类流程

Fig. 1　Data classification process

在实际判定过程中，为了避免出现冲突或多标签，优先根据降水量是否大于等于1 mm判定当天是否为雨天（或雪天），再根据云层数据将剩余数据划分为晴天、多云天、阴天和多变天。

C_i^{L}、C_i^{M}和C_i^{H}分别为第i个样本点的为低云层云量、中云层云量、高云层云量。对于给定的云层权重λ_1、λ_2、λ_3，满足式(2)

$$\lambda_1+\lambda_2+\lambda_3=1 \tag{2}$$

定义天气类型划分指标

$$C_i=\lambda_1 C_i^{\mathrm{L}}+\lambda_2 C_i^{\mathrm{M}}+\lambda_3 C_i^{\mathrm{H}} \tag{3}$$

云量的均值、标准差分别表示当日云量的整体水平、变化的剧烈程度，可按式(4)、式(5)计算

$$\bar{C}=\frac{1}{N}\sum_{i=1}^{N}C_i \tag{4}$$

$$\sigma_{\mathrm{C}}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}(C_i-\bar{C})^2} \tag{5}$$

表2　常规天气划分标准

Table 2　Conventional weather classification standards

常规天气类	判定标准
晴天	$\bar{C}<0.2$
多云天	$0.2\leqslant\bar{C}\leqslant0.8$
阴天	$\bar{C}>0.8$
多变天	$\sigma_{\mathrm{C}}\geqslant0.3$

2　改进的InformerStack模型

2.1　InformerStack模型

InformerStack模型在光伏出力预测任务中引入了多层级堆叠结构，每层Encoder都会使用ProbSparseAttention来捕捉长序列依赖

$$\mathrm{Attention}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\mathrm{softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^T}{\sqrt{d_k}}\right)\boldsymbol{V} \tag{6}$$

式中：$\boldsymbol{Q}$为查询矩阵；$\boldsymbol{K}$为键矩阵；$\boldsymbol{V}$为值矩阵；d_k为键的维度。多个Encoder模块按顺序堆叠，每层都输出一个特征表示

$$\boldsymbol{H}^{(l)}=\mathrm{Encoder}^{(l)}(\boldsymbol{H}^{(l-1)}),l=1,2,\cdots,L \tag{7}$$

式中：$\boldsymbol{H}^{(0)}$为输入特征矩阵。经过Encoder−Decoder后，预测光伏出力$\hat{y}_t$

$$\hat{y}_{t+\tau}=f(\boldsymbol{H}_{t:t+\tau}^{(L)}) \tag{8}$$

式中：τ为预测步长；f为Decoder及全连接层映射。

该结构能够在不同时间尺度上有效捕捉气象因素的时序特征，从而更全面地揭示气象条件与光伏出力之间的动态依赖关系，提升模型在复杂多变天气场景下的泛化性能。

2.2　物理信息神经网络

物理信息神经网络（physics informal neural network，PINN）是一种将气象物理机理方程与数据驱动预测模型相融合的深度学习方法。通过在损失函数中显式引入光伏系统的物理约束，保证预测结果既能拟合数据，又符合光伏发电的物理规律。

在PINN中，损失函数由数据驱动损失与物理约束损失两部分组成

$$L=L_{\mathrm{data}}+\lambda L_{\mathrm{physics}} \tag{9}$$

式中：λ为平衡数据驱动部分和物理约束部分的重要性。数据驱动损失用于衡量模型预测值与真实

光伏出力之间的偏差，按式(10)计算

$$L_{\text{data}}=\frac{1}{N_{\text{d}}}\sum_{i=1}^{N_{\text{d}}}\left|y_{\text{P}}(i)-y_{\text{T}}(i)\right|^2 \tag{10}$$

式中：N_{d} 为样本总数；$y_{\text{P}}(i)$ 为模型第 i 个光伏出力预测值；$y_{\text{T}}(i)$ 为光伏出力第 i 个真实值。物理约束损失用于衡量预测结果是否满足光伏系统的物理规律，需要考虑光伏出力的非负性、气象要素和光伏出力的关系，分别按式(11)和式(13)计算

$$L_{\text{p},1}=\frac{1}{N_{\text{d}}}\sum_{i=1}^{N_{\text{d}}}\left(\max\left\{0,-y_{\text{P}}(i)\right\}\right)^2 \tag{11}$$

$$y_{\hat{\text{P}}}(i)=\eta G(i)A[1-\gamma(T_{\text{cell}}(i)-T_{\text{ref}})] \tag{12}$$

$$L_{\text{p},2}=\frac{1}{N_{\text{d}}}\sum_{i=1}^{N_{\text{d}}}\left|y_{\text{P}}(i)-y_{\hat{\text{P}}}(i)\right|^2 \tag{13}$$

$$L_{\text{physics}}=L_{\text{p},1}+L_{\text{p},2} \tag{14}$$

式中：η 为系统效率；$G(i)$ 为第 i 个样本的辐照度；A 为组件受光面积；γ 为温度系数；$T_{\text{cell}}(i)$ 为第 i 个样本的温度；T_{cell} 为参考温度，取25 ℃。在模型中，将 η 和 γ 设为可学习参数，其中 η 的取值范围限定为0.10~0.24，γ 的取值范围限定为0.004~0.005 ℃。

改进的InformerStack模型如图2所示，PINN与InformerStack的结合不涉及网络结构的改动，而是在训练阶段通过损失函数的叠加实现。InformerStack作为主干预测网络，负责提取时序特征并输出预测值。PINN的物理约束以正则化项的形式加入总损失，引导模型输出符合物理规律的预测结果。

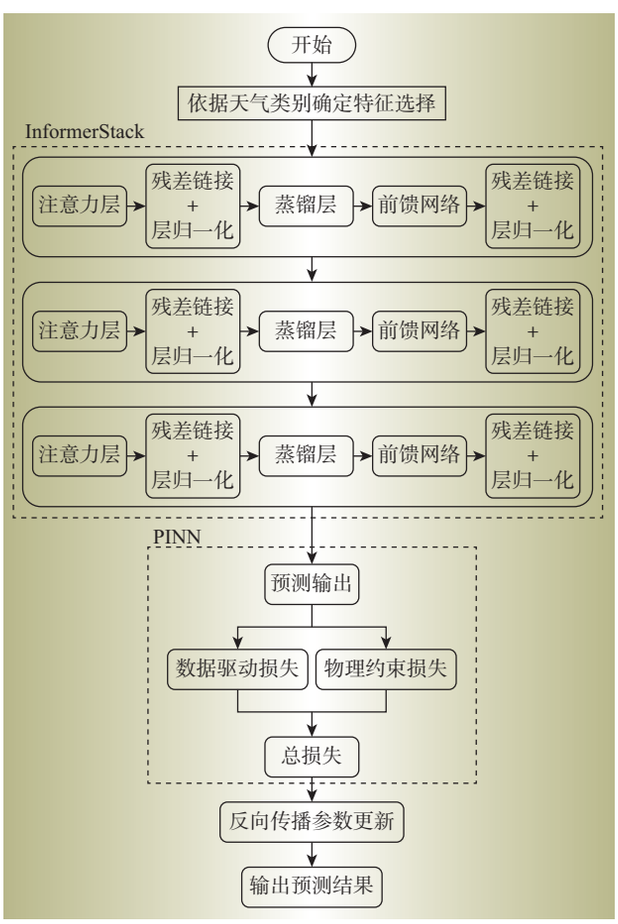


图2 改进的InformerStack模型

Fig. 2 Improved InformerStack workflow

在常规天气类样本下，主要通过引入辐照度、温度与光伏出力的关系，确保模型预测的出力与气象条件之间满足光电转换机理。在极端天气类样本下，进一步引入物理阈值约束，增强了模型在极端天气下的鲁棒性和可解释性。

3 光伏发电预测算例

3.1 数据来源

本文以南京六合地区的某光伏发电设备作为研究对象，选取历史气象数据和光伏出力值作为样本数据，时间段为2024年1月至12月全天，采样分辨率为15 min。考虑到南京六合地区的极端天气样本点较少，以预测多变天气下的光伏出力为例。

3.2 模型输入特征分析

Spearman相关系数是一种非参数统计方法，用于衡量两个变量的秩次之间的单调关系，优点在于无须数据服从正态分布。本文用Spearman相关系数来衡量气象变量与光伏发电之间的相关性，计算如式(15)所示

$$\rho=1-\frac{6\sum d_i^2}{n(n^2-1)} \tag{15}$$

式中：d_i 为秩次的差(将原始数据 x_i 和 y_i 从大到小排列，排列后的位置即为秩次，x_i 的秩次减去 y_i 的秩次即为秩次差)；n 为数据量。

利用DBSCAN结合多变天气划分标准，划分2024年1月至12月的多变天气，结果如图3所示。

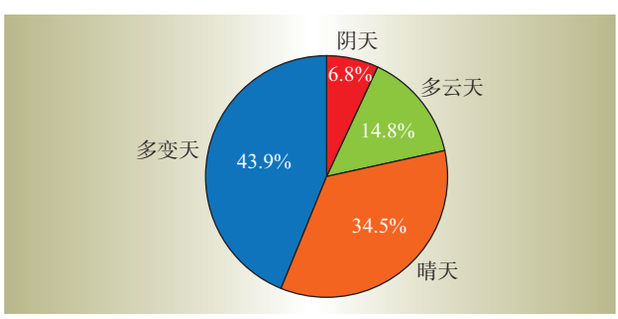


图3 天气类别划分结果

Fig. 3 Results of the weather classification system

表3是2024年1月至12月多变天气的气象数据与所对应的光伏发电量按照式(15)计算得到的Spearman相关性系数。

表3　Spearman相关性系数

Table 3　Spearman correlation coefficient

特征	Spearman相关性系数
辐照度	0.877 7
温度	0.129 7
湿度	−0.321 4
高云层	−0.229 1
中云层	−0.357 8
低云层	−0.432 7
气压	−0.030 3
风速	−0.197 2
风向	0.027 7

表3相关性分析结果显示，辐照度是光伏出力的核心驱动特征，低云层与中云层对光伏发电量具有显著的抑制作用，湿度亦表现出一定的负面影响。结合弱相关的温度与风速等因素，可以在一定程度上提升模型对复杂气象条件的适应能力。因此，在后续建模过程中，将辐照度、低云层、中云层作为核心输入特征，并辅以温度、湿度和风速等辅助特征，以确保预测模型具有更强的解释性与泛化能力。

3.3　预测结果与误差

本文采用平均绝对误差（mean absolute error，MAE）、均方根误差（root mean square error，RMSE）和决定系数 R^2 来衡量预测值与真实值偏离的平均程度和整体拟合程度，计算公式分别如式（16）、式（17）和式（18）所示

$$e_{\mathrm{MAE}}=\frac{1}{n}\sum_{i=1}^{n}\left|y_i-\hat{y}_i\right| \tag{16}$$

$$e_{\mathrm{RMSE}}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(y_i-\hat{y}_i\right)^2} \tag{17}$$

$$R^2=1-\frac{\sum_{i=1}^{n}\left(y_i-\hat{y}_i\right)^2}{\sum_{i=1}^{n}\left(y_i-\bar{y}_i\right)^2} \tag{18}$$

式中：y_i 为光伏出力的真实值；$\hat{y}_i$ 为光伏出力的预测值；n 为预测样本的数量。

用InformerStack模型和其他模型进行训练，并预测接下来3天中06:00~18:00时段的光伏出力（共计144个点），对比结果见图4所示。

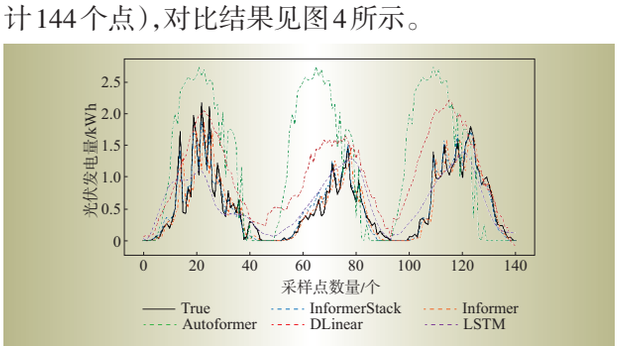


图4　不同模型预测效果

Fig. 4　Predicting results of different models

表4　不同模型的预测结果

Table 4　Prediction results of different models

模型	MAE	RMSE	R^2
InformerStack	0.053 17	0.119 26	0.958 62
Informer	0.103 67	0.248 63	0.820 15
Autoformer	0.866 96	1.146 94	−3.554 98
DLinear	0.499 54	0.603 84	−0.262 56
LSTM	0.242 67	0.325 95	0.632 11

3.4　误差分析

实验结果表明，InformerStack模型在各方面明显优于其他模型。InformerStack模型相较于基础的Informer模型表现出了显著优势。MAE从0.103 67降至0.053 17，RMSE从0.248 63降至0.119 26，均表明预测误差显著减小，模型在整体拟合精度和对异常波动的敏感性方面均有改善。同时，R^2 从0.820 15提升至0.958 62，说明InformerStack模型能够更好地捕捉时间序列数据中的复杂非线性关系，对光伏出力的预测能力更强。

从误差分布角度看，Informer模型的预测仍存在一定偏差，特别是在光伏出力快速变化的时段，误差放大导致整体RMSE偏高。而InformerStack通过多层堆叠结构增强了多尺度特征的捕捉能力，在应对非平稳性和多变天气条件下的预测任务时表现更稳健。因此，可以认为InformerStack在光伏出力预测中更适合复杂场景。

4　结束语

本文提出了一种基于DBSCAN-Kmeans-PINN-InformerStack的混合光伏出力预测方法。与现有方法相比，该方法在数据预处理、物理约束引入以及长序列预测方面均具有显著优势：

（1）通过DBSCAN算法对样本进行聚类，能够有效识别出极端天气样本与常规天气样本，实现出力模式的初步划分。在此基础上，利用Kmeans算法和物理阈值将常规天气进一步细分为晴天、多云和阴天等类别，将极端天气进一步细分为高温、极寒和强霾等类别使得不同气象情境下的出力预测更加针对性和精细化。

（2）基于PINN框架，将气象因子与光伏发电过程中的物理规律相结合，在模型训练中嵌入物理约束损失函数。这不仅避免了模型过度依赖数据驱动特征，还提升了预测结果的物理一致性与解释性。

（3）InformerStack模型去掉了卷积下采样模块，改用多层Encoder堆叠结构，以保留完整的时序特征并增强多尺度时间依赖的捕捉能力。这一结构

改进不仅维持了稀疏注意力带来的高效计算优势，同时提升了模型在高分辨率下的预测精度和泛化性能。

参考文献：

[1] 宋绍剑，李博涵. 基于LSTM网络的光伏发电功率短期预测方法的研究[J]. 可再生能源，2021，39(5)：594-602.
Song Shaojian, Li Bohan. Short-term forecasting method of photovoltaic powerbased on LSTM[J]. Renewable Energy Resources, 2021, 39(5):594-602.

[2] 王开艳，杜浩东，贾嵘，等. 基于相似日聚类和QR-CNN-BiLSTM模型的光伏功率短期区间概率预测[J]. 高电压技术，2022，48(11)：4 372-4 388.
Wang Kaiyan, Du Haodong, Jia Rong, et al. Short-term interval probability prediction of photovoltaic power based on similar daily clustering and QR-CNN-BiLSTM model[J]. High Voltage Engineering, 2022, 48(11): 4 372-4 388.

[3] 董俊，刘瑞，束洪春，等. 基于BIRCH聚类的L-Transformer分布式光伏短期发电功率预测[J]. 高电压技术，2024，50(9)：3 883-3 893.
Dong Jun, Liu Rui, Shu Hongchun, et al. Short-term distributed photovoltaic power generation prediction based on BIRCH clustering and L-Transformer[J]. High Voltage Engineering, 2024, 50(9):3 883-3 893.

[4] 刘毅力，陈园园. 基于RF特征提取和TCN-BiGRU模型的短期光伏发电功率预测[J]. 太阳能学报，2025，46(7)：682-689.
Liu Yili, Chen Yuanyuan. Short-term photovoltaic output prediction based on RF feature extraction and TCN-BiGRU model[J]. Acta Energiae Solaris Sinica, 2025, 46(7):682-689.

[5] 李威臻，李明，刘杰，等. 基于TVF-EMD-ELM的超短期光伏功率预测[J]. 电工材料，2023，(6)：44-48.
Li Weizhen, Li Ming, Liu Jie, et al. Ultra-short-term photovoltaic power prediction based on TVF-EMD-ELM[J]. Electrical Engineering Materials, 2023, (6):44-48.

[6] Moon J. A multi-step-ahead photovoltaic power forecasting approach using one-dimensional convolutional neural networks and Transformer[J]. Electronics, 2024, 13(11):2007.

[7] 黄毅，马一力，苗安康，等. 基于GSS的RIME-CNN-LSTM-Attention光伏出力组合预测模型[J]. 太阳能学报，2025，46(10)：250-258.
Huang Yi, Ma Yili, Miao Ankang, et al. RIME-CNN-LSTM-Attention PV output combination prediction model based on GSS[J]. Acta Energiae Solaris Sinica, 2025, 46(10):250-258.

[8] 姜建国，金方承，毕洪波. 多策略改进蜣螂优化算法及其在光伏发电功率预测中的应用[J]. 电力需求侧管理，2024，26(6)：101-106.
Jiang Jianguo, Jin Fangcheng, Bi Hongbo. Multi-strategy improved dung beetle optimization algorithm and its applicationin photovoltaic power generation power prediction[J]. Power Demand Side Management, 2024, 26(6):101-106.

[9] 姜侨娜，陈中. BP-马尔科夫组合预测方法在光伏发电量预测中的应用[J]. 电力需求侧管理，2011，13(6)：21-24.
Jiang Qiaona, Chen Zhong. The study of solar power forecasting based on BP-Markov method[J]. Power Demand Side Management, 2011, 13(6):21-24.

[10] 陈喜军，田培根，刘松民. 融合注意力机制的神经网络光伏发电功率预测研究[J]. 水力发电，2026，52(2)：102-107.
Chen Xijun, Tian Peigen, Liu Songmin. A neural network photovoltaic power prediction method incorporating attention mechanism[J]. Water Power, 2026, 52(2): 102-107.

[11] Zhuang W, Li Z, Wang Y, et al. GCN-informer: a novel framework for mid-term photovoltaic power forecasting[J]. Applied Sciences, 2024, 14(5):2 181.

[12] 龚迪阳，唐雅洁，高为举，等. 基于Q学习和PCA的分布式光伏集群优化调度[J]. 浙江电力，2025，44(11)：72-82.
Gong Diyang, Tang Yajie, Gao Weiju, et al. An optimal dispatch strategy for distributed PV clusters based on Q-learning and pin-ning consensus algorithm[J]. Zhejiang Electric Power, 2025, 44(11):72-82.

[13] 王超，赵永良，王杰，等. 基于TCN-LSTM-SE神经网络的低压有源配电网电压控制方法研究[J]. 供用电，2025，42(4)：48-58.
Wang Chao, Zhao Yongliang, Wang Jie, et al. Research on voltage control method of low voltage active distribution network based on TCN-LSTM-SE neural network[J]. Distribution & Utilization, 2025, 42(4):48-58.

[14] 蔡伟雄，陈志聪，吴丽君，等. 采用PCA-CSA-Informer模型的光伏短期发电量预测[J]. 福州大学学报(自然科学版)，2024，52(6)：681-690.
Cai Weixiong, Chen Zhicong, Wu Lijun, et al. Short-term power generation study of PV based on PCA-CSA-Informer modeling[J]. Journal of Fuzhou University (Natural Science Edition), 2024, 52(06):681-690.

[15] 陈君，王博士，肖媛，等. 基于Informer模型的短期光伏发电功率预测[J]. 西安工程大学学报，2025，39(4)：82-88，96.
Chen Jun, Wang Boshi, Xiao Yuan, et al. Short-term photovoltaic power forecasting basedon the Informer model[J]. Journal of Xi'an Polytechnic University, 2025, 39(4):82-88, 96.

作者简介：

周承翰(1998)，男，安徽合肥人，硕士，助理工程师，研究方向为智能用电、需求侧管理；

黄艺璇(1993)，女，江苏淮安人，硕士，工程师，研究方向为计量新技术、智能用电、需求侧管理。

(责任编辑　崔素媛　张雨悦)