

基于Informer-LSTM-MLP的短期光伏发电功率预测

邓文倩, 王世刚

广西科技大学自动化学院, 广西 柳州

收稿日期: 2026年3月18日; 录用日期: 2026年3月31日; 发布日期: 2026年4月30日

摘要

针对光伏发电功率预测精度较差的问题, 提出一种基于Informer-LSTM-MLP的短期光伏发电功率预测混合模型。首先, 利用 3σ 法则、箱线图法及孤立森林法检测异常数据, 结合邻近窗口均值法与三次样条插值填补缺失值。通过Pearson相关系数筛选关键气象要素, 并采用改进K-means算法将历史数据聚类为晴天、阴天及复杂天气3类。在此基础上, 构建Informer-LSTM-MLP混合模型: 采用LSTM网络提取环境特征的时序信息, 生成隐含状态矩阵; 采用Informer模型对功率序列进行深层时序依赖建模, 提取全局特征; 将两类特征输入Cross-Attention机制进行多源信息融合, 最后通过MLP实现端到端功率预测。实验结果表明, 该混合模型在不同天气条件下均能有效提升光伏发电功率预测精度。

关键词

时间序列, 深度学习, 混合预测模型, 光伏发电功率预测

Short-Term Photovoltaic Power Forecasting Based on Informer-LSTM-MLP

Wenqian Deng, Shigang Wang

School of Automation, Guangxi University of Science and Technology, Liuzhou Guangxi

Received: March 18, 2026; accepted: March 31, 2026; published: April 30, 2026

Abstract

To address the problem of low prediction accuracy in photovoltaic (PV) power forecasting, this paper proposes a hybrid short-term PV power prediction model based on Informer-LSTM-MLP. First, the 3σ criterion, box plot method, and Isolation Forest algorithm are adopted to detect anomalous

data, while the adjacent window mean method and cubic spline interpolation are used to impute missing values. Key meteorological factors are selected via the Pearson correlation coefficient, and an improved K-means algorithm is employed to categorize historical data into three weather types: sunny, cloudy, and complex. On this basis, the Informer-LSTM-MLP hybrid model is constructed: the Long Short-Term Memory (LSTM) network extracts temporal information from environmental features to generate hidden state matrices; the Informer model performs deep modeling of long-term dependencies in power sequences to capture global features; these two types of features are then fed into a Cross-Attention mechanism for multi-source information fusion, and finally, the Multi-Layer Perceptron (MLP) realizes end-to-end power prediction. Experimental results demonstrate that the proposed hybrid model can effectively improve the prediction accuracy of PV power generation under various weather conditions.

Keywords

Time Series, Deep Learning, Hybrid Prediction Model, Photovoltaic Power Forecasting

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

近年来, 全球社会与经济的飞速发展是能源消费激增的核心驱动力, 而由此产生的能源安全与生态环境恶化, 已成为人类社会亟待解决的双重挑战[1], 如何利用可再生能源已经成为当前世界的研究主流[2][3]。据报告显示, 从 2005 年至 2025 年, 全球光伏发电累计装机容量呈现指数级增长, 尤其是 2015 年后进入爆发式增长; 从 2010 年到 2020 年, 全球光伏发电总装机容量从约 40 GW 增长到约 766 GW, 增长了约 19.15 倍, 然而光伏发电系统的安装成本下降了 81.2% [4]; 同时, 中国光伏发电累计装机容量从 2016 年的 77 GW 跃升至 2020 年的 253 GW, 自 2015 年超越德国后, 累计装机量连续六年位居全球首位[5]。太阳能作为一种清洁能源, 虽具有资源丰富、分布广和易获取等优势, 但同时也具备间歇性、波动性与随机性等典型特征, 这导致发电曲线难以实时匹配用电负荷动态变化, 由此引发的功率失衡与调度困境已成为制约产业规模化发展的核心瓶颈[6]。构建高可靠性的光伏发电功率预测模型, 能够为电网的经济、高效运行提供关键技术支撑, 也在光伏产业中发挥不可或缺的作用[7]。

光伏发电功率预测方法可以分为物理方法、统计方法、机器学习方法及深度学习方法。其中, 物理方法虽不依赖历史数据, 通过光伏电站的地理信息与辐照数据进行建模, 但其建模过程复杂, 抗干扰能力较差, 难以适应多变的环境; 统计方法通过挖掘历史功率与气象数据的关系进行预测, 但其高度依赖数据质量, 在处理突发天气状况时实时响应能力不足, 预测精度受限; 传统机器学习方法(如支持向量机、浅层神经网络)在一定程度上平衡了计算复杂度与预测性能, 但在处理高维非线性特征及复杂时序依赖关系时, 其特征表达能力与泛化能力仍显不足[8]-[10]。深度学习模型凭借其强大的特征提取与非线性拟合能力, 在光伏发电功率预测任务中表现出显著优势。

为克服传统单一深度学习模型在光伏发电功率预测中精度不足的问题, 混合模型逐渐成为研究热点, 其通过组合不同算法的优势, 更有效地捕捉光伏出力的动态变化规律[11]-[13]。文献[14]引入改进的鲸鱼优化算法增强全局搜索能力, 构建了 PCA-Attention-TCN-LSTM 融合模型, 并通过消融实验验证了模型的有效性; 文献[15]提出改进的 Transformer 架构, 将各影响因子的时间序列嵌入独立通道(token)中, 利用注意力机制进行多变量相关性分析, 将 LSTM 和 iTransformer 的表征输入到 MLP, 构建了 LSTM-

iTransformer-MLP 融合模型, 但均未考虑不同天气, 尤其是复杂天气对光伏发电功率的影响。文献[16]采用自组织映射神经网络(SOM)和逐次变分模态分解(SVMD)对数据进行处理, 根据子序列复杂度高低分别采用 Transformer 和 BP 神经网络进行预测, 最后结合两者的输出, 但 SVMD 作为迭代分解算法, 在大规模数据上耗时较长, Transformer 模型在小样本条件下优势难以发挥, 且与 SOM 聚类后的短序列可能存在适配性问题。文献[17]采用变分模态分解(VMD)处理光伏发电功率时序数据, 结合主成分分析降维, 利用极限学习机实现短期功率预测, 其时序依赖建模能力不足。文献[18]利用一维小波卷积网络(WTC)进行多尺度特征提取, 结合 KAN 的非线性映射能力作为输出层, 提高了模型的泛化能力, 但各模块参数空间相互耦合, 难以进行端到端的高效训练, 易陷入局部最优。

基于上述理论基础与分析, 本文提出一种基于 Informer-LSTM-MLP 的短期光伏发电功率预测混合模型。首先开展数据预处理工作, 综合 3δ 法则、箱线图法及孤立森林法实现异常数据的检测, 结合邻近窗口均值法与三次样条插值法完成缺失值填补, 保障输入数据质量。随后通过 Pearson 相关系数筛选影响光伏发电功率的关键气象特征, 采用改进 K-means 算法将历史数据聚类为晴天、阴天及复杂天气 3 类, 实现数据的分层优化。模型构建阶段, 利用 LSTM 网络的门控机制提取环境特征的时序关联信息并生成隐含状态矩阵, 借助 Informer 模型的 ProbSparse 自注意力机制对功率序列进行深层时序依赖建模、提取全局特征, 通过 Cross-Attention 机制实现两类特征的深度融合, 最后由 MLP 完成端到端的功率预测。实验结果表明, 该混合模型可有效弥补单一模型的不足, 在不同天气条件下均能显著提升短期光伏发电功率预测精度, 验证了所提方法的有效性。

2. 数据预处理与分析

2.1. 数据预处理

异常值检测旨在识别光伏发电功率与气象数据中的离群观测值, 这些异常值可能源于传感器测量误差、噪声干扰、数据传输异常等系统缺陷, 若不予以处理, 可能会增加预测模型的学习难度, 进而影响模型预测精度。本文采用 3δ 准则、箱线图法以及孤立森林法检测异常值, 结合邻近窗口均值法以及三次样条插值法对异常值进行处理, 主要流程如图 1 所示。

在 3δ 准则中, \overline{data} 为平均值, σ_x 为标准差, 数据分布在 1~3 个标准差内的概率分别为 0.6827、0.9545 和 0.9973, 各数据类型基本集中在 3 个标准差内, 因此可将超出这个范围的数据视为异常数据。

在箱线图法中, 下边缘(剔除异常值后的最小值)、第一四分位数(Q1)、中位数(Q2)、第三四分位数(Q3)和上边缘(剔除异常值后的最大值)为五个关键数值。四分位距 $IQR = Q3 - Q1$, 异常值通常定义为低于 $Q1 - 1.5IQR$ 或高于 $Q3 + 1.5IQR$ 的数据点, 并在图中单独标出。

在孤立森林法中, 假设一个含 N 个样本的数据集: $X = \{x_1, x_2, \dots, x_N\} \subset \mathbb{R}^d$, 从 X 中随机取 n 个数据点构成子样本集; 从子样本集中随机选择一个特征, 并在该特征区间内选择一个随机切分点 p ; 子样本集被切分为两个子空间, 小于切分点的放在左叶子节点, 大于则放在右子节点; 在每个分支节点不断重复以上步骤, 递归构建树, 直到每个叶子节点只包含一个样本或达到树的高度限制。

重复训练 t 棵孤立树组成孤立森林, 再整合 t 棵树的切割结果得到异常分数, 其计算如式(1)所示。

$$s(x, n) = 2^{-\frac{E[h(x)]}{c(n)}} \quad (1)$$

式中, $h(x)$ 为 x 在某棵孤立树中的路径长度; $E[h(x)]$ 为样本 x 在所有 t 棵树中路径长度的均值; $c(n)$ 为归一化因子, 其计算方法如式(2)所示。 s 越接近 0 表示样本为正常值的可能性大, 反之, s 越接近 1 表示样本为异常值的可能性大, s 越接近 0.5 则无法去本样本是否为异常值。

$$c(n) = 2H(n-1) - \frac{2(n-1)}{n} \tag{2}$$

式中, $H(k) \approx \ln(k) + \gamma$, γ 为欧拉常数, $\gamma \approx 0.5772$ 。

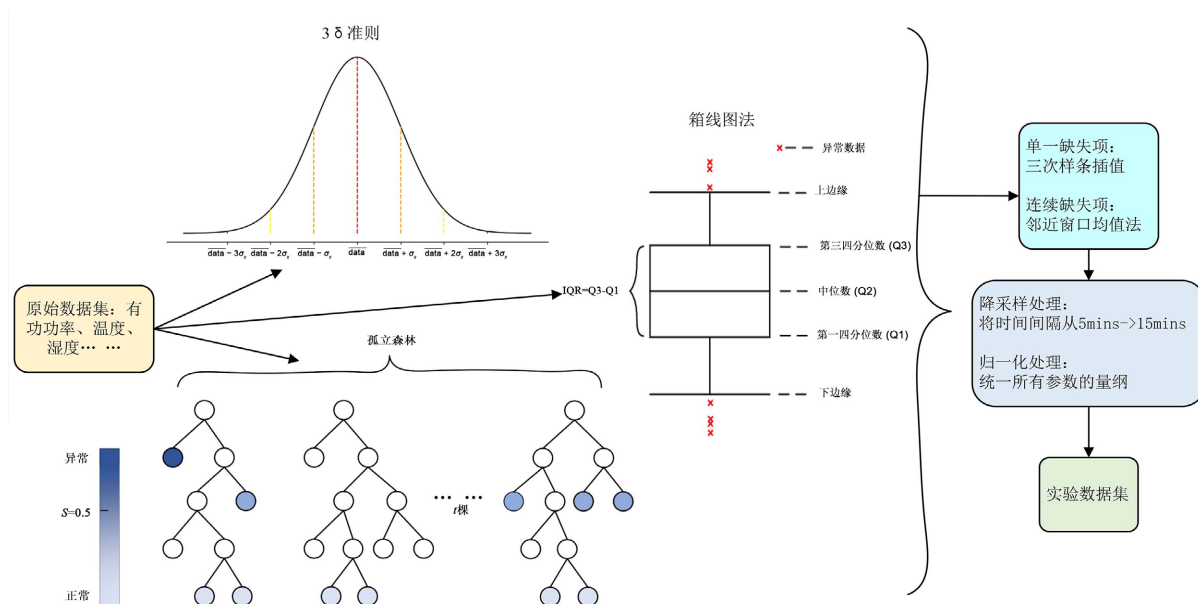


Figure 1. Flowchart of abnormal data processing

图 1. 异常数据处理流程图

2.2. 光伏发电功率影响因素分析

为探究不同气象特征对光伏发电功率的影响程度, 本文采用 Pearson 相关系数对气象特征与有功功率的相关程度进行分析。相关程度取值范围均为[-1, 1], 相关性等级划分如表 1 所示。

Table 1. Correlation magnitude classification table

表 1. 相关性程度划分表

取值范围	[-1, -0.6)	[-0.6, -0.2)	[-0.2, 0)	0	(0~0.2]	(0.2~0.6]	(0.6~1]
相关程度	强负相关	弱负相关	极弱负相关	无关	极弱相关	弱相关	强相关

由表 1 可看出, 越往 1 靠近, 正线性相关程度越高; 越往-1 靠近, 负线性相关程度越高; 0 表示无线性相关, 其计算方法如式(3)所示。

$$r = \frac{\sum_{i=1}^m (a_i - \bar{a})(b_i - \bar{b})}{\sqrt{\sum_{i=1}^m (a_i - \bar{a})^2} \sqrt{\sum_{i=1}^m (b_i - \bar{b})^2}} \tag{3}$$

式中, m 表示样本数; a_i 、 b_i 分别为两个变量的值; \bar{a} 、 \bar{b} 分别为两个变量的均值。

2.3. 改进 K-Means 聚类分析

对于短期功率预测, 各环境因素与光伏发电功率关系紧密, 将相似的环境条件聚成簇, 同一簇内功

率数据和环境特征之间的相似性最高,能有效降低模型训练的难度,为本文最终构建 Informer-LSTM-MLP 深度学习模型提供数据基础。聚类算法是一种无监督的机器学习方法,本文基于改进的 K-means 算法进行数据聚类,其主要改进点为:

- 1) 选取强相关性的环境特征构建均值、标准差、一阶差分并作为聚类向量;
- 2) 结合肘部法则和轮廓系数法则确定簇数 K 值;
- 3) 采用欧式距离进行簇分配。

3. 基于 Informer-LSTM-MLP 的光伏发电功率预测模型构建

构建 Informer-LSTM-MLP 的光伏发电功率混合预测模型主要包括 3 个核心板块,分别是:数据预处理与分析、混合模型搭建与预测、结果分析。其具体搭建流程如图 2 所示。

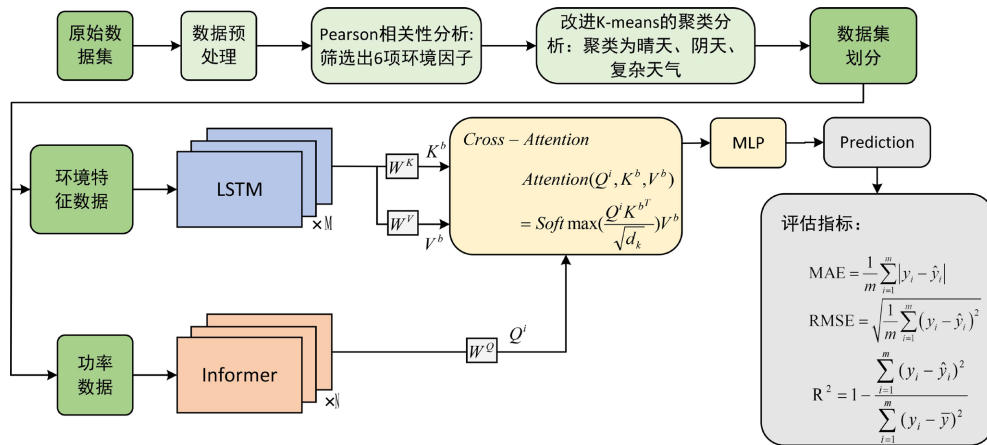


Figure 2. Flowchart of the informer-LSTM-MLP hybrid prediction model construction
图 2. Informer-LSTM-MLP 混合预测模型搭建流程图

Informer-LSTM-MLP 光伏发电功率预测模型的搭建过程基本如下:

步骤 1: 数据预处理与分析。采用利用 3δ 法则、箱线图法、孤立森林法剔除异常值,结合邻近窗口均值法和三次样条插值法对异常值进行合理补偿。

步骤 2: 相关性分析。采用 Pearson 相关系数分析各环境特征对功率的影响,去除相关性低的特征。

步骤 3: 聚类分析。采用改进的 K-means 聚类算法将数据集划分为多种显著的天气类型。

步骤 4: 数据集划分。将数据集中 70%作为训练集,15%作为验证集,15%作为测试集,训练集用于模型的训练与参数拟合,验证集用于模型调优与性能监控,测试集用于性能评估与泛化能力的检验。

步骤 5: 构建 Informer-LSTM-MLP 光伏发电功率预测模型。确定模型中 Informer、LSTM 以及 MLP 的层数以及模型中隐含层神经元的个数,算法迭代次、学习率等参数。

步骤 6: 将训练得到的超参数组合在验证集上进行性能验证与迭代优化,记录最佳模型参数配置。使用测试集对最终优化后的模型进行性能评估,生成预测结果并用所选评估指标来评估模型的性能,完成模型泛化能力检验。若效果未达预期,可返回步骤 5 调整寻优区间或模型结构重新优化。

3.1. Informer 网络

Informer 是一种基于 Transformer 改进的预测模型。Informer 采用 ProbSparse 自注意力机制、自注意力蒸馏技术和生成式解码器,减少了长序列预测中的时间复杂度与内存占用,使得其能够处理大规模的

时序数据并保持较高的实时性与预测精度, 大幅提高了效率。Informer 在捕捉长时序依赖特征方面表现优越, 能够有效应对光伏发电系统在不同气象条件下所呈现的长期依赖性, 其整体架构如图 3 所示。

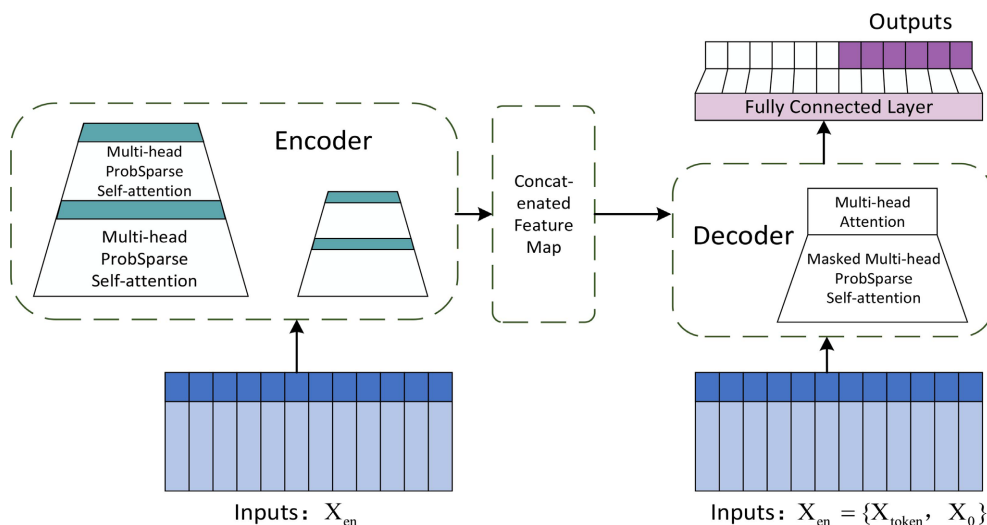


Figure 3. Architecture diagram of Informer network
图 3. Informer 网络结构

3.2. LSTM 网络

长短期记忆网络(Long Short-Term Memory, LSTM)是一种特殊的循环神经网络(Recurrent Neural Network, RNN), 专门设计用于处理和预测时间序列数据。由于 RNN 存在长期依赖的问题, 导致 RNN 面临梯度消失和梯度爆炸的问题, 因此 LSTM 在 RNN 的基础上, 引入了如图 4 所示的遗忘门、输入门和输出门, 通过组合和调节这三种门结构, LSTM 能够选择性地存储、遗忘和输出信息, 使其能够更好地处理长期依赖关系, 并以长序列记住关键信息。这种门控机制允许 LSTM 在许多序列建模任务中表现良好。相较于其他模型如线性回归、支持向量机和极限学习机等, LSTM 算法具有更好的预测精度。




Figure 4. Architecture diagram of LSTM network
图 4. 长短期记忆网络结构图

图 4 中, 遗忘门用于读取上一时刻的波动特征 h_{t-1} 和当前输入特征 x_t , 利用 \tanh 函数进行非线性映射, 得到输出 f_t ; 输入门决定哪些波动特征值得保留, 输出门将处理后的波动特征传递给下一层网络结

构。具体计算方法如式(4)~(9)所示。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (7)$$

$$h_t = o_t * \tanh(C_t) \quad (8)$$

$$C_t = f_t * C_{t-1} + i_t \cdot \tilde{C}_t \quad (9)$$

式中, 遗忘门参数: W_f 为权重矩阵, b_f 为偏置向量; 输入门参数: W_i 、 b_i 、 W_c 均为权重矩阵, b_c 为偏置向量; 输出门: W_o 为权重矩阵, b_o 为偏置向量; 细胞状态: $*$ 表示元素相乘, C_t 为遗忘门和输入门的结果。

3.3. 交叉注意力机制

交叉注意力是注意力机制的核心变体, 与注意力的本质区别在于: 查询(Q)与键/值(K, V)来自不同的输入模块, 而非同一序列。这种设计使模型能够在两个独立模态或序列之间建立依赖关系, 广泛应用于多模态学习、多模型融合等场景。其表达方法如式(10)所示:

$$CA(V_1, V_2) = \text{softmax} \left(\frac{(V_1 W^Q)(V_2 W^K)^T}{\sqrt{d_k}} \right) (V_2 W^V) \quad (10)$$

式中, $CA(\cdot)$ 为交叉注意力运算, $\text{softmax}(\cdot)$ 为行级 softmax 函数, 用于归一化注意力权重; V_1 为查询源输入, $V_1 \in \mathbb{R}^{s_1 \times d_1}$; V_2 为键值源输入, $V_2 \in \mathbb{R}^{s_2 \times d_2}$; s_1 、 s_2 为序列长度, d_1 、 d_2 为特征维度; d_k 为查询/键的隐空间维度, $\sqrt{d_k}$ 为缩放因子, 用于避免点积过大导致 softmax 饱和; $W^Q \in \mathbb{R}^{d_1 \times d_k}$ 、 $W^K \in \mathbb{R}^{d_2 \times d_k}$ / $W^V \in \mathbb{R}^{d_2 \times d_k}$ 为查询、键/值投影矩阵, 分别将 V_1 、 V_2 映射到查询、键/值空间。当 $V_1 = V_2$ 时, 交叉注意力退化为自注意力, 即 $SA(V_1) = CA(V_1, V_2)$ 。

3.4. MLP 网络

多层感知机(MLP)为前馈神经网络, 包含输入、隐藏与输出层(如图 5)。它通过隐藏层非线性变换与激活函数赋予非线性拟合能力, 理论上可高精度逼近任意连续函数, 常用于高维数据映射与回归预测。如图 5 所示, 其中每一层函数的计算方法如式(11)所示:

$$y = T(wx + b) \quad (11)$$

式中, x 为输入, w 为权重, b 为阈值, T 为激活函数。

假设有两个输入, 单层隐藏层, 隐藏层中有 3 个隐神经元, 激活函数为 tanh, 则输出的表达方式如式(12)所示:

$$\begin{aligned} y = & w_{12}^{(3,2)} * \tanh(w_{11}^{(2,1)} x_1 + w_{12}^{(2,1)} x_2 + b_1^{(2)}) \\ & + w_{12}^{(3,2)} * \tanh(w_{21}^{(2,1)} x_1 + w_{22}^{(2,1)} x_2 + b_2^{(2)}) \\ & + w_{13}^{(3,2)} * \tanh(w_{31}^{(2,1)} x_1 + w_{32}^{(2,1)} x_2 + b_3^{(2)}) + b_1^{(3)} \end{aligned} \quad (12)$$

式中, 激活函数 $\tanh(x) = \frac{2}{1+e^{-2x}} - 1$; 为了不限制输出, 因此输出层无激活函数。




Figure 5. Architecture diagram of MLP network
图 5. 多层感知机网络结构图

3.5. 模型评估指标

为科学评估预测模型性能, 需构建多维度评价体系。本文采用平均绝对误差(MAE, 单位为 KW)、均方根误差(RMSE, 单位为 KW)、决定系数(R^2 , 无度量单位)作为模型评价指标, 后续分别用 MAE、RMSE、 R^2 表示, 其计算方法如式(13)~(15)所示。

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \tag{13}$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \tag{14}$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \tag{15}$$

式中, m 为样本数量, y_i 、 \hat{y}_i 、 \bar{y} 分别为光伏发电功率的真实值、预测值以及真实值的平均值。

4. 算例分析

本文实验用的数据来源于澳大利亚 - 爱丽丝泉某光伏电站从 2018 年 6 月 1 日至 2019 年 5 月 31 日光伏发电功率数据, 该数据采样频率间隔 5 mins, 记录的数据包括有气温、相对湿度、水平面总辐射、水平面散射辐射、日降雨量、倾斜面总辐射、倾斜面散射辐射、有功功率。所有数据共计 365 天, 87,264 组。

4.1. 影响因素分析结果

对本文数据集进行 Pearson 相关系数计算, 得到如图 6 所示的热力图以及如表 2 所示的相关系数表。根据图表结果, 日降雨量与光伏发电功率相关系数为系数为-0.112, 呈极弱负相关关系, 不作为后续研究对象。因此, 本文采用水平面总辐射、水平面散射辐射、气温、相对湿度、倾斜面总辐射、倾斜面散射辐射这 6 个气象特征进行实验分析。

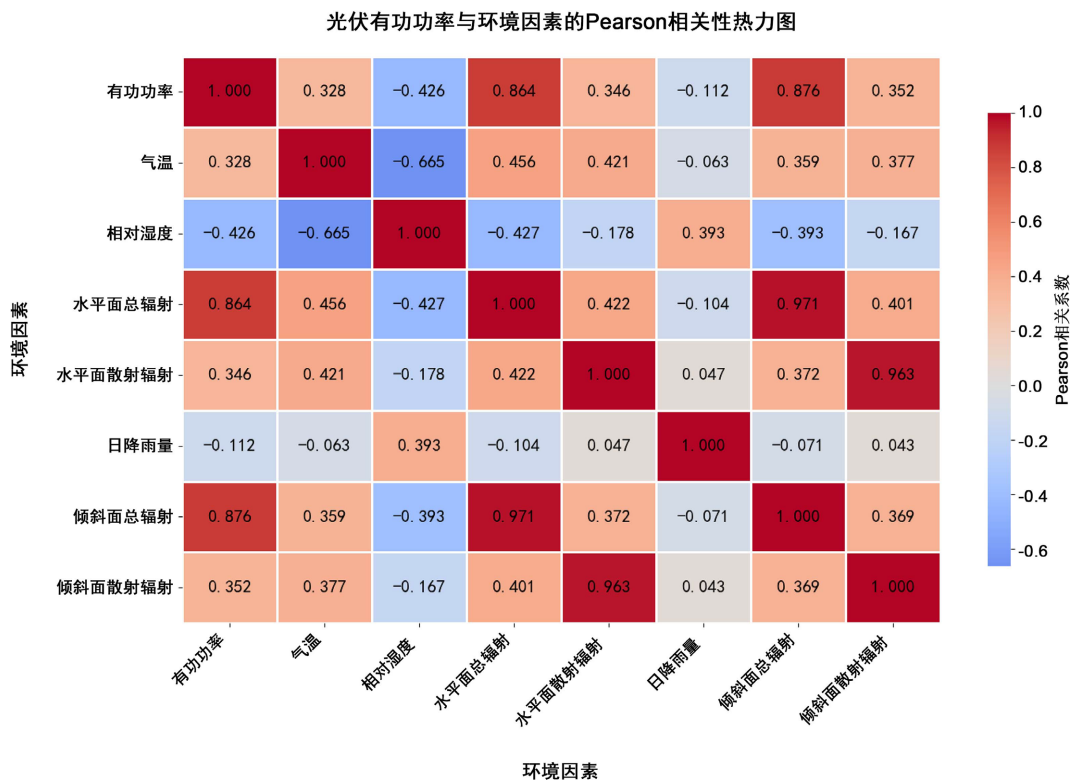


Figure 6. Pearson correlation heatmap of active power and environmental factors
图 6. 有功功率与环境因素的 Pearson 相关性热力图

Table 2. Table of correlation coefficient results
表 2. 相关性系数结果表

环境特征	Pearson 相关性系数
水平面总辐射	0.864
水平面散射辐射	0.346
倾斜面总辐射	0.876
倾斜面散射辐射	0.352
气温	0.328
相对湿度	-0.426
日降雨量	-0.112

4.2. 聚类结果

本实验数据集来自沙漠地区,且由表 2 可知,光伏发电功率与日降水量的相关性极低,可忽略不计;光伏发电功率与辐照度相关的环境特征相关程度最高,水平面总辐射可通过数值天气预报(NWP)直接获取,故选其用作聚类分析。计算每一天水平面总辐射的均值、标准差及一阶差分和作为聚类算法的输入,以此进行天气划分。图 7 展示了基于肘部法则与轮廓系数法得到的聚类数选择曲线。从轮廓系数法来看,当聚类数为 3 时,轮廓系数达到最大值 0.31,表明此时簇间差异性最大;当聚类数大于 3 时,轮廓系数虽有波动,但整体均低于 0.31。从肘部法则来看,当聚类数由 2 增至 3 时,惯性值变化最为显著,斜率变化也最大,呈现明显的“手肘”形态。综合肘部法则与轮廓系数法的结果,确定本数据集的最佳

聚类数为 3。因此, 将峰值较高, 具有一定波动性的簇标记为晴天; 将峰值较低, 波动性较低的簇标记为阴天; 而将峰值不定, 波动性较大的簇标记为复杂天气。




Figure 7. Graph of elbow rule and silhouette coefficient rule curves
图 7. 肘部法则与轮廓系数法则曲线图

4.3. 环境参数配置及模型层数选择

本仿真过程在 python3.10、Intel(R)Core(TM)i7-12650H 处理器、载有 3050 显卡的个人计算机上完成。为验证模型效果, 本文基于 Informer-LSTM-MLP 混合模型进行短期光伏发电功率预测, 通过一天 53 个采样点的数据来预测未来一天 53 个时间点的光伏发电功率值。混合模型的参数配置如下:

Informer 层: 特征维度为 64, 8 头自注意力, 前馈网络中间层为 128, dropout 为 0.1, 输出 Q 矩阵;

LSTM 层: 输入维度为 6, 隐藏层维度为 64, LSTM 层数为 2, dropout 为 0.1, 输出 K、V 矩阵;

Cross-Attention: 注意力特征维度为 64, 8 头交叉注意力, dropout 为 0.1, 实现特征的融合;

MLP 层: 层数为 3, 其神经元个数依次为 128、64、32, 最终输出 53 个时间点的光伏功率预测值。

此外, 学习率为 0.001, epoch 为 80, batch size 为 32, Adam 为优化器。使用 L1Loss (MAE) 作为损失函数, 当验证损失连续 5 个周期未改善时, 学习率衰减为原来的 0.5 倍。采用 early stopping 机制, patience 为 8, 当验证损失连续 8 个周期未下降超过 0.0001 时停止训练, 以防止过拟合。

4.4. 对比实验结果分析

为验证所提 Informer-LSTM-MLP 混合模型在光伏发电功率预测任务中的优越性, 选取子模型 Informer、LSTM、MLP 以及主流时序模型 TCN 和 GRU 等作为基本模型进行对比实验。实验根据不同的天气类型分别进行, 实验结果在各类天气下分别随机取连续 3 天作为可视化和评估指标分析。晴天、阴天和复杂天气的实验结果分别如图 8~10 所示, 其评估指标如表 3 所示。

Table 3. Comparative experiment evaluation metrics
表 3. 对比实验评估指标

模型	晴天天气			阴天天气			复杂天气		
	MAE	RMSE	R ²	MAE	RMSE	R ²	MAE	RMSE	R ²
Informer	0.9329	1.1024	0.8994	0.7037	0.837	0.9073	1.0359	1.462	0.7476

续表

LSTM	1.0979	1.3476	0.8496	0.795	0.8993	0.893	1.1556	1.382	0.7747
MLP	0.8999	1.184	0.8839	0.6225	0.8483	0.9048	1.0135	1.2443	0.8174
TCN	1.1368	1.3637	0.846	0.8328	0.954	0.8795	2.2514	2.9383	0.0263
GRU	1.148	1.4196	0.8331	0.7126	0.9755	0.8741	1.5682	2.0508	0.5039
Informer-LSTM-MLP	0.406	0.5442	0.9755	0.2585	0.3333	0.9853	0.5246	0.7296	0.9372

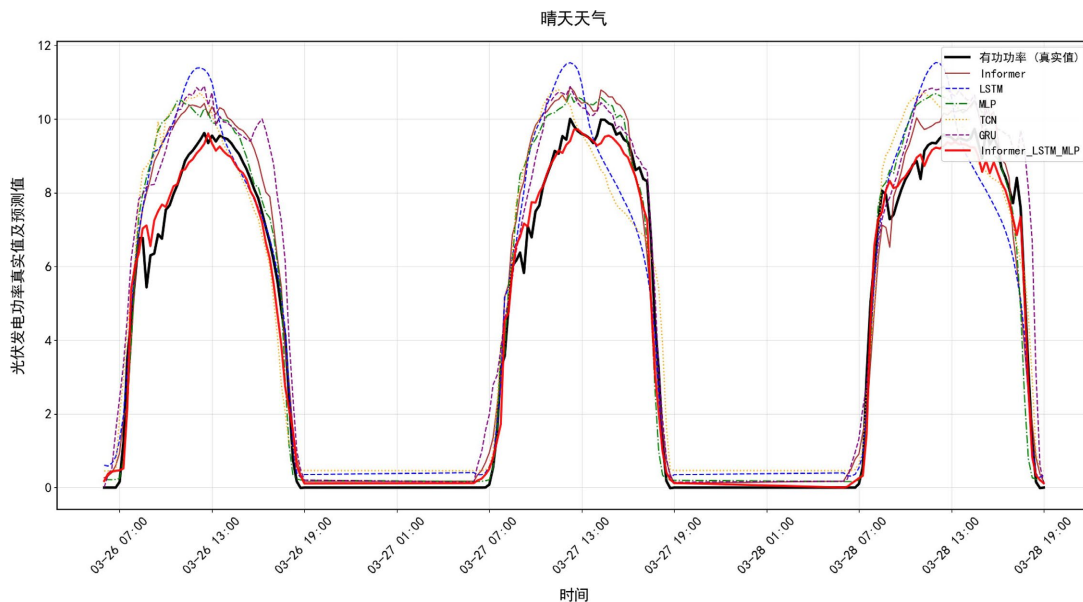


Figure 8. Prediction results of comparative models for clear-sky conditions

图 8. 晴天天气 - 对比实验预测结果图

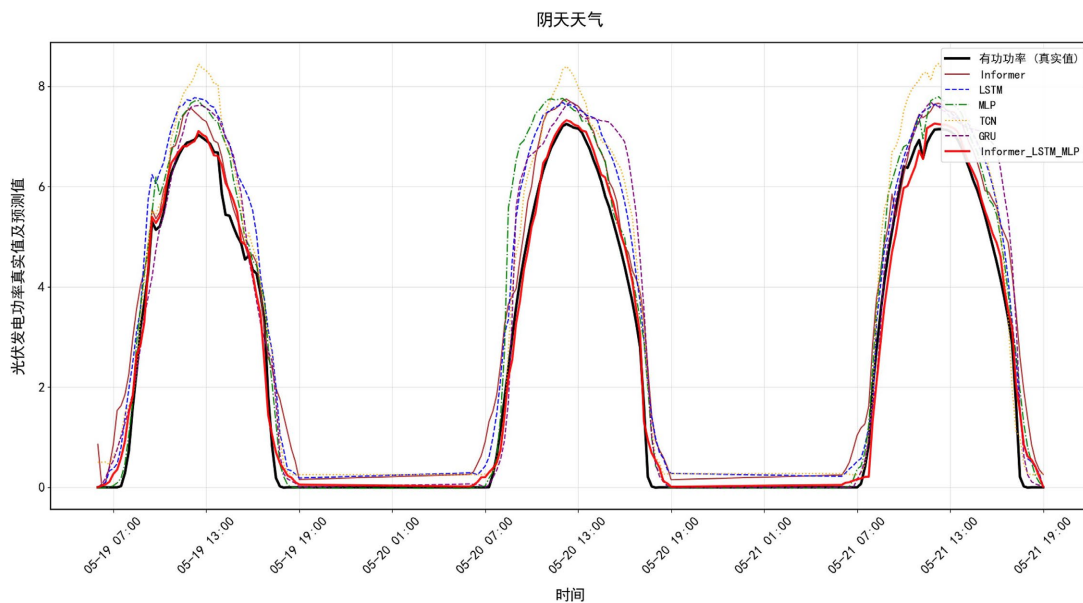


Figure 9. Prediction results of comparative models for cloud conditions

图 9. 阴天天气 - 对比实验预测结果图




Figure 10. Prediction results of comparative models for complex conditions
图 10. 复杂天气 - 对比实验预测结果

对比实验结果显示, 本文提出的 Informer-LSTM-MLP 混合模型在各类天气条件下均取得最优性能。在晴天天气下, 模型 MAE 为 0.406 KW、RMSE 为 0.5442 KW、 R^2 达 0.9755; 在阴天天气下, MAE 为 0.2585 KW、RMSE 为 0.3333 KW、 R^2 达 0.9853; 在复杂天气下, MAE 为 0.5246 KW、RMSE 为 0.7296 KW、 R^2 达 0.9372, 显著优于 Informer、LSTM、MLP、TCN 及 GRU 基准模型。

从模型机制分析, 该混合架构通过多模块协同实现性能提升: Informer 的稀疏注意力有效捕捉光伏序列的长程依赖特征, LSTM 精准建模局部时序非线性关联, 交叉注意力机制实现全局与局部特征的深度融合, 弥补了单一模型的特征提取缺陷。然而, TCN 在复杂天气场景下 R^2 仅为 0.0263, 预测性能严重退化, 归因其因果卷积结构难以适配光伏发电功率的突变特性; LSTM 与 GRU 受限于循环网络的长序列梯度衰减问题, 对平稳晴天序列的建模能力弱于 Informer, 且在非平稳复杂天气下鲁棒性不足; 单一 Informer 模型缺乏对局部时序特征的针对性建模, 预测误差高于混合模型; MLP 虽整体性能优于部分时序模型, 但全连接结构无法有效捕捉序列依赖关系, 仍存在精度瓶颈。

综上, 所提模型通过多模块优势互补, 在不同天气条件, 尤其在强波动的复杂天气场景中展现出显著优势, 验证了该混合模型在光伏功率预测任务中的有效性。

4.5. 消融实验结果分析

为探究所提 Informer-LSTM-MLP 混合模型中各核心模块的有效性, 设置 Informer-LSTM、Informer-MLP 及 LSTM-MLP 三种变体作为消融实验。实验根据不同的天气类型分别进行, 为保证数据分析的有效性, 取 4.4 章节中各类天气对应的时间作为可视化和评估指标分析。晴天、阴天和复杂天气的实验结果分别如图 11~13 所示, 其评估指标如表 4 所示。

消融实验结果显示, Informer-LSTM-MLP 混合预测模型在各天气条件下均显著优于各变体模型。在晴天天气下, 所提模型相较于表现次优的 Informer-LSTM 模型, MAE 和 RMSE 分别降低了 47.4% 和 45.6%, R^2 提升 0.0583。在阴天天气下, 所提模型 MAE 和 RMSE 低至 0.2585 KW 和 0.3333 KW, 较 LSTM-MLP 模型分别降低 57.2% 和 59.1%, R^2 提升 0.0732。在复杂天气这一最具挑战性的场景下, 完整模型 R^2 达

0.9372, 而各变体模型 R^2 介于 0.8208 至 0.8792 之间, 预测精度提升尤为明显。交叉注意力机制与 MLP 映射层的引入, 有效实现了环境特征与功率特征的深度融合与非线性映射, 证明了各模块在提升模型预测性能方面的不可或缺性。通过消融实验, 进一步验证了该混合架构在光伏功率预测任务中的泛化能力。

Table 4. Ablation experiment evaluation metrics
表 4. 消融实验评估指标

模型	晴天天气			阴天天气			复杂天气		
	MAE	RMSE	R^2	MAE	RMSE	R^2	MAE	RMSE	R^2
Informer-LSTM	0.772	0.9998	0.9172	0.689	0.7861	0.9182	0.8209	1.0121	0.8792
Informer-MLP	0.863	1.0633	0.9064	0.6403	0.8024	0.9148	0.801	1.0554	0.8686
LSTM-MLP	0.9316	1.046	0.9094	0.6038	0.8151	0.9121	0.9902	1.2326	0.8208
Informer-LSTM-MLP	0.406	0.5442	0.9755	0.2585	0.3333	0.9853	0.5246	0.7296	0.9372

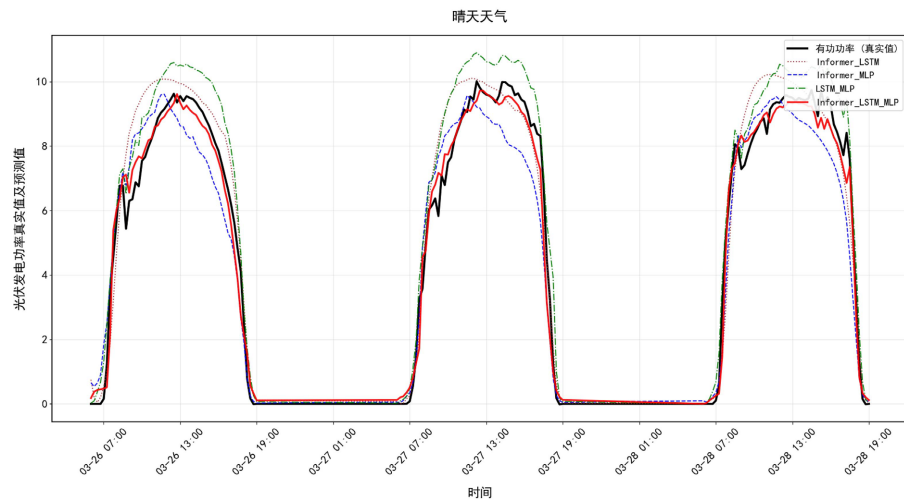


Figure 11. Prediction results of ablation models for clear-sky conditions
图 11. 晴天天气 - 消融实验预测结果




Figure 12. Prediction results of ablation models for cloud conditions
图 12. 阴天天气 - 消融实验预测结果




Figure 13. Prediction results of ablation models for complex conditions

图 13. 复杂天气 - 消融实验预测结果

5. 结论

针对传统单一模型在光伏发电功率预测中精度不足的问题, 本文提出一种基于 Informer-LSTM-MLP 的短期光伏发电功率预测混合模型, 通过对比实验和消融实验, 验证了模型的优越性并得到以下结论:

1) 通过对历史光伏发电数据进行预处理、相关性分析以及聚类分析, 可以有效提升输入数据的质量与特征表达能力, 从而降低模型复杂度, 提高模型学习能力。

2) 与传统单一模型相比, 构建合理的混合预测模型, 能发挥各模块的优势, 提高模型预测精度与鲁棒性。

参考文献

- [1] 张健良. 新能源光伏发电技术的应用及未来发展趋势分析[C]//中国电力设备管理协会. 全国绿色数智电力设备技术创新成果展示会论文集(七). 2024: 80-82.
- [2] 邵桂萍, 许洪华. 可再生能源综合系统现状与未来发展趋势研究[J]. 太阳能, 2024(7): 127-132.
- [3] Wei, N., Li, C., Peng, X., Zeng, F. and Lu, X. (2019) Conventional Models and Artificial Intelligence-Based Models for Energy Consumption Forecasting: A Review. *Journal of Petroleum Science and Engineering*, **181**, Article 106187. <https://doi.org/10.1016/j.petrol.2019.106187>
- [4] Dutra, D.S., Maria, E.C., Cláudio, B., et al. (2023) Outlook on the Brazilian Scenario of Floating Photovoltaic Solar Energy. *Energy Reports*, **10**, 4429-4435.
- [5] 陈前, 王盼, 蒋珊, 等. 我国新能源行业“十四五”发展回顾及“十五五”展望[J/OL]. 石油石化绿色低碳: 1-6. <https://doi.org/10.20131/j.cnki.syshlsdt.20251009.002>, 2025-10-22.
- [6] Liu, Y.Y. (2022) Short-Term Prediction Method of Solar Photovoltaic Power Generation Based on Machine Learning in Smart Grid. *Mathematical Problems in Engineering*, **2022**, 1-10. <https://doi.org/10.1155/2022/8478790>
- [7] Visser, L., Al-Skaif, T., Hu, J., et al. (2023) On the Value of Expert Knowledge in Estimation and Forecasting of Solar Photovoltaic Power Generation. *Solar Energy*, **251**, 86-105.
- [8] 万灿, 宋永华. 新能源电力系统概率预测理论与方法及其应用[J]. 电力系统自动化, 2021, 45(1): 2-16.
- [9] 王东风, 刘婧, 黄宇, 等. 结合太阳辐射量计算与 CNN-LSTM 组合的光伏功率预测方法研究[J]. 太阳能学报, 2024, 45(2): 443-450.
- [10] Markovics, D. and Mayer, M.J. (2022) Comparison of Machine Learning Methods for Photovoltaic Power Forecasting Based on Numerical Weather Prediction. *Renewable and Sustainable Energy Reviews*, **161**, Article 112364. <https://doi.org/10.1016/j.rser.2022.112364>

- [11] Dai, Y., Wang, Y., Chen, Y., Wu, J. and Chao, J. (2025) Combining Meteorological and Power Information of Station-Measurement and Model-Prediction with the Hybrid CNN-Transformer and CNN-BILSTM for Ultra-Short-Term Photovoltaic Power Forecasting. *International Journal of Electrical Power & Energy Systems*, **171**, Article 111009. <https://doi.org/10.1016/j.ijepes.2025.111009>
- [12] Zhang, Y. and Ma, X. (2025) Short-Term Photovoltaic Power Prediction Based on a VMD-SE-CNN-LSTM Combined Model. *Engineering Research Express*, **7**, Article 045413. <https://doi.org/10.1088/2631-8695/ae1353>
- [13] Yang, S. and Luo, Y. (2025) Short-Term Photovoltaic Power Prediction Based on RF-SGMD-GWO-BILSTM Hybrid Models. *Energy*, **316**, Article 134545. <https://doi.org/10.1016/j.energy.2025.134545>
- [14] 张晨阳. 基于多模型融合 TCN-LSTM 的光伏发电功率短期预测研究[D]: [硕士学位论文]. 焦作: 河南理工大学, 2024.
- [15] 黄子珊. 基于深度学习的光伏发电功率预测[D]: [硕士学位论文]. 太原: 山西大学, 2024.
- [16] 王瑞, 靳鑫鑫, 逯静. SVM-D-PE-BP-Transformer 短期光伏功率预测[J]. *电网与清洁能源*, 2024, 40(8): 141-150.
- [17] Abed, J.N., Abdoos, A.A. and Ebadi, A. (2026) A New Hybrid Intelligent Method for Short-Term Photovoltaic Power Forecasting Based on Combination of ELM, VMD and PCA. *Electric Power Systems Research*, **250**, Article 112104. <https://doi.org/10.1016/j.epsr.2025.112104>
- [18] Li, J., Ren, X., Zhang, F., Gao, L., Li, J. and Cui, T. (2025) Multi-Timescale Photovoltaic Station Power Prediction Based on Reformer Model. *Energy*, **327**, Article 136423. <https://doi.org/10.1016/j.energy.2025.136423>