基于云-辐照度-功率耦合机理的超短期光伏功率预测

孙映萱[1,2]，杨苹[1,2]，孙涛[1,2]，段凯玥[1]，简文清[2]
（1. 华南理工大学电力学院，广州市 510640；2. 广东省绿色能源技术重点实验室（华南理工大学），广州市 510640）

摘　要：【目的】为解决云团快速变化导致光伏功率预测精度下降的难题，提出一种基于云-辐照度-功率耦合机理的超短期光伏功率预测方法。【方法】首先，构建双流卷积网络提取云团的空间与运动特征，并基于Transformer编码器提取辐照度时序特征；其次，通过交叉注意力机制对二者进行特征融合，以实现对地表辐照度的多步预测；最后，为克服纯数据驱动方法的局限性，以预测辐照度为输入，引入地表辐照度-光伏出力物理约束构建光伏功率预测模型。【结果】实验结果表明，所提地表辐照度预测方法在不同天气类型下均优于基准模型，进一步将辐照度预测结果作为光伏功率预测输入，相较于直接引入云信息的方法，光伏功率预测精度有所提升。此外，通过引入物理约束，光伏功率预测进一步提高，同时模型的泛化性能得到有效增强。【结论】深度挖掘三维云信息的动态变化对辐照度的影响，并引入辐照度与光伏功率的物理先验知识，是提升超短期光伏功率预测精度与模型泛化能力的一条有效途径。

关键词：超短期光伏功率预测；三维云信息；特征融合；地表辐照度预测；辐照度-功率耦合机理
中图分类号：TM615　　**文献标志码**：A　　**文章编号**：1000-7229（2026）03-0012-12
DOI：10.12204/j.issn.1000-7229.2026.03.002

Ultra-Short-Term Photovoltaic Power Prediction Based on the Cloud-Irradiance-Power Coupling Mechanism

SUN Yingxuan[1,2], YANG Ping[1,2], SUN Tao[1,2], DUAN Kaiyue[1], JIAN Wenqing[2]
（1. School of Electric Power Engineering, South China University of Technology, Guangzhou 510640, China; 2. Key Laboratory of Clean Energy Technology of Guangdong Province, South China University of Technology, Guangzhou 510640, China）

ABSTRACT: [**Objective**] To address the challenge of declining accuracy in photovoltaic power prediction caused by rapidly changing cloud conditions, this paper proposes an ultra-short-term photovoltaic (PV) power prediction method based on the cloud-irradiance-power coupling mechanisms. [**Methods**] First, a two-stream convolutional network is constructed to extract spatial and motion features of clouds, while a Transformer encoder is employed to capture the temporal features of irradiance sequences. Then, cross-attention mechanism is applied to fuse these features for multi-step ahead prediction of surface irradiance. Finally, to overcome the limitations of purely data-driven approaches, this study constructs a photovoltaic power prediction model by using irradiance forecasts as inputs and incorporating physical constraints governing the surface irradiance-to-power output conversion. [**Results**] Experimental results show that the proposed irradiance prediction method outperforms baseline models under various weather conditions. Furthermore, using the predicted irradiance as input significantly improves PV power forecasting accuracy compared to methods that directly incorporate cloud information. The introduction of physical constraints further enhances PV power prediction performance and improves the model's generalization capability. [**Conclusions**] This study demonstrates that deeply mining the impact of dynamic 3D cloud information on irradiance and incorporating physical prior knowledge between irradiance and PV power represents an effective way to enhance the accuracy and model generalization capability of ultra-short-term PV power prediction.

This work is supported by National Key Research and Development Program of China (No. 2023YFB4203100).

基金项目：国家重点研发计划项目（2023YFB4203100）

© Editorial Department of Electric Power Construction. OA under CC BY-NC-ND 4.0.

KEYWORDS：ultra-short-term photovoltaic power forecasting；3D cloud information；feature fusion；surface irradiance prediction；irradiance-power coupling mechanism

0　引　言

在“双碳”目标驱动下，能源结构转型加速，光伏发电在电力系统中的渗透率持续提升[1-2]。然而，光伏出力的间歇性和波动性给电网的功率平衡与安全稳定运行带来了新的挑战。在此背景下，提升光伏功率预测精度，已成为保障新型电力系统经济高效运行的重要技术手段之一[3-4]。

光伏发电功率与气象条件密切关联[5]，数值天气预报（numerical weather prediction，NWP）通常作为光伏功率预测模型的气象因素输入源[6]。而NWP难以准确刻画局部云层瞬变引发的辐照度短时波动，限制了光伏功率预测的精度。因此，现有研究主要通过加入地基云图或者卫星云图的云层光学特征提升光伏功率预测精度[7]。

地基云图具有高采样频率、高分辨率的特点，能对云团特征及运动进行精准描述[8-9]。文献[10]提出了一种基于多层次云图特征与宽度学习的超短期光伏功率预测方法，提高了模型的爬坡功率预测能力，兼顾了预测性能与预测效率。文献[11]提出了一种改进Transformer网络，并引入低秩多模态融合算法提取和融合云图特征和气象特征，以提升预测精度。然而，地基云图视域范围有限，仅能进行较短时间尺度的光伏功率预测。此外，全天空成像仪等设备的部署会增加光伏场站的硬件成本。

卫星云图覆盖范围广、预测时间尺度更长，且无需额外部署硬件设备。文献[12]提出了一种基于卫星云图特征区域定位的超短期光伏功率预测模型，在云图中精准定位到太阳光线产生遮挡作用的相关云区域以捕捉云对光伏功率波动产生的影响。文献[13]对云移动轨迹进行预测，并构建云遮模型以量化云层对辐照度的影响，最终与光电转换模型结合，提升了功率预测的精度。文献[14]提出了一种基于卫星云图和数据集蒸馏的光伏发电功率超短期预测模型，在云量特征基础上加入数据蒸馏算法提取的云类型特征，使得预测误差大大降低。然而，卫星云图无法体现云层的垂直结构，忽略了不同层高云团的影响。

除了地基云图和卫星云图存在的局限性以外，现有研究大都将提取的云图特征与其他气象因素同时作为光伏功率预测模型的输入特征，仅采用数据驱动的方式挖掘各气象特征与功率的关系，忽略了云团状态变化对辐照度的直接影响以及辐照度与光伏功率之间的物理关系。目前采用数据-物理驱动模型进行光伏功率预测的研究较少[15]。文献[16]提出了一种基于人工神经网络（artificial neural network，ANN）和光伏电站晴空曲线的物理混合人工神经网络方法，将计算得到的晴空辐照度和数值天气预报数据一同作为神经网络的输入，得到光伏功率预测结果。文献[17]提出了一个基于参数在线更新的改进晴空功率模型，基于此方程对小波动天气下光伏功率做出超短期预测。然而，仅仅通过引入晴空模型，无法对波动天气下光伏功率出现大幅波动的情况实现精准预测。

针对以上问题，本文基于三维云融合分析业务系统（3DCloudA-V1.0）的三维云量实况分析数据[18]，提出一种基于云-辐照度-功率耦合机理的超短期光伏功率预测方法，其主要内容如下：

1）提出一种基于云-辐照度耦合特征的地表辐照度预测算法。首先，分别通过双流卷积网络和Transformer编码器对三维云序列和辐照度序列进行特征提取；然后，采用交叉注意力机制融合云和辐照度特征；最后，基于非自回归解码器实现地表辐照度的多步预测。

2）构建数据-物理驱动的超短期光伏功率预测模型，在损失函数中引入辐照度-光伏出力物理约束惩罚项，提升光伏功率预测的精度和模型的泛化能力。

1　基于云-辐照度耦合特征的地表辐照度预测

1.1　地表辐照度预测模型概述

光伏功率预测精度受限于NWP中辐照度无法考虑短时间内云团状态的变化，本节将云团的实时变化纳入考量，生成精度更高的地表辐照度预测结果，作为后续超短期光伏功率预测模型的输入。

云团对地表辐照度的影响是一个涉及三维空间结构、运动及其与太阳相对位置的复杂物理过程，精确的物理建模面临巨大挑战。为此，本节基于3DCloudA-V1.0提供的多压强层云覆盖数据，提出一种基于云-辐照度耦合特征的地表辐照度预测算法，以挖掘三维云团特征与辐照度变化之间的深层映射关系，规避显式物理投影计算的难题。所提算法采用双流卷积网络提取云团空间与运动特征，利用Transformer编码器提取辐照度时序特征，并通过交叉注意力机制融合多模态特征，最终通过非自回归Transformer解码器实现地表辐照度的多步预测。模型结构如图1所示。

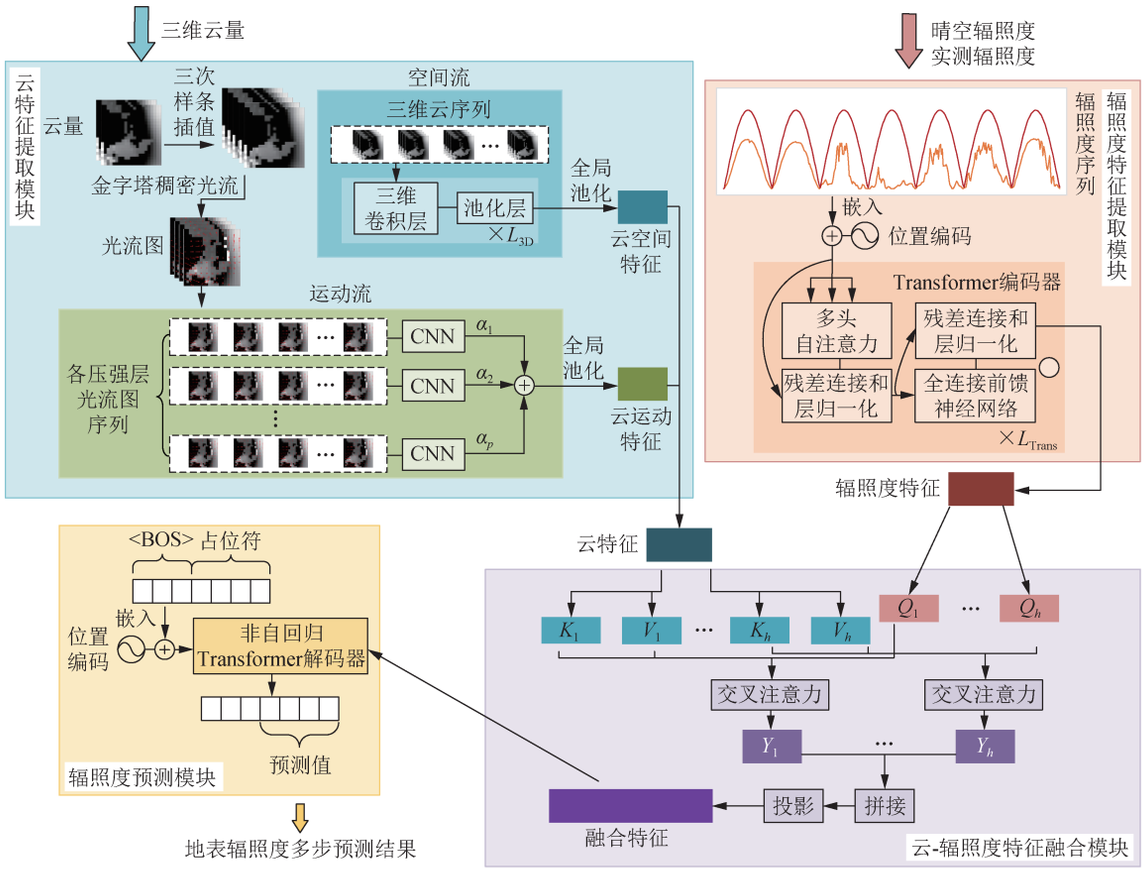


图1 地表辐照度多步预测模型

Fig. 1 Multi-step prediction model for surface irradiance

1.2 基于双流卷积网络的云特征提取

云分支特征提取部分思路为:首先,对云团数据进行插值处理,再计算出相邻帧之间的光流,将插值后的云团数据与计算得到的光流作为双流卷积网络的输入,分别提取云团的空间特征与运动特征,最终融合得到云分支的特征。云层覆盖比数据虽能体现不同时刻对于辐照度的削减作用,但如果仅输入云层覆盖比数据,则需要隐式学习云团的变化规律,效果并不理想,因此,采用光流法加入云团显式运动特征,更好地发掘云团状态变化与地表辐照度预测的关联[19]。

1.2.1 云团数据集来源与插值处理

本文有关云团状态数据来源于国家气象中心研制与开发的3DCloudA-V1.0。3DCloudA-V1.0获取数值预报产品、静止气象卫星成像仪一级数据、静止气象卫星云检测产品、雷达基数据等各类数据,对多源气象资料进行融合,生成覆盖全中国及其周边区域的总云量及三维云量实况分析结果。

本文将采用3DCloudA-V1.0的三维云量实况分析结果作为描述云团状态的数据,体现为1100 hPa至50 hPa不同压强层各网格点云层覆盖比,其空间分辨率为0.05°,时间分辨率为1 h,压强层分辨率为25 hPa。

由于本文采用三维云量数据时间分辨率为1 h,而光伏功率预测时间分辨率为15 min,需对三维云量数据进行插值。云团状态变化具有连续性,在1 h内,云团通常情况下不会剧烈波动,但有时也会出现波动较大的情况,因此需要选用插值曲线连续且光滑、能够满足数据波动性的插值方式。

三次样条插值(cubic spline interpolation)邻接曲线之间不仅值相等,还满足一阶导数和二阶导数连续的条件[20],适合用于本文三维云量数据的插值,其插值公式为:

$$S(x)=y_j+c_j(x-x_j)+\frac{1}{2}M_j(x-x_j)^2+\frac{1}{6h_j}\cdot(M_{j+1}-M_j)(x-x_j)^3,x\in\left[x_j,x_{j+1}\right] \tag{1}$$

式中:$S(x)$为在区间$[x_j, x_{j+1}]$上的三次样条插值函数;x为自变量;x_j和x_{j+1}为已知数据点的节点位置;y_j为节点x_j处的已知函数值;$h_j=x_{j+1}-x_j$为节点间距;M_j和M_{j+1}分别为节点x_j和x_{j+1}处的二阶导数值;c_j为由函数值和二阶导数确定的系数。

设原始三维云量数据为时间序列$\{I_t\in\mathbf{R}^{H\times W\times P}|t=0,1,\cdots,L_T\}$,经过三次样条插值后的时间序列为$I_t^*\in\mathbf{R}^{H\times W\times P}$。

1.2.2　金字塔 Farneback 光流法

云团状态的变化包括云团的整体平流运动和内部的生消演变，传统光流方法在处理此类运动时具有局限性，稠密光流法虽能完整刻画每个像素的运动轨迹，但对云团快速生消引起的变化极为敏感，易产生噪声干扰整体运动趋势的提取；而稀疏光流法虽通过特征点匹配提升了抗噪性，却难以捕捉云团局部的精细变化。为此，本文采用金字塔 Farneback 光流算法，通过高斯金字塔分离不同空间尺度的运动特征。

输入插值后的三维云量数据，其中每个像素值 $I_t(x,y,z)\in[0,\ 100]$，为适配光流计算需求，将云量数据线性映射至 8 位灰度空间。不同压强层的云团变化相互独立、互不干扰，因此，在计算光流时，各压强层独立计算。

基于 Farneback 多项式展开理论，同一压强层相邻帧 I_t^* 与 I_{t+1}^* 的局部运动场可通过二次多项式近似，对图像域 $\mathbf{R}^{H\times W}$ 内每个像素点 $A(x,\ y)$，构建以下优化问题：

$$\min_{\boldsymbol{d}}\sum_{\boldsymbol{\xi}\in U(A_0)}\boldsymbol{\omega}(\boldsymbol{\xi})[\,I_{t+1}^*(\boldsymbol{\xi}+\boldsymbol{d})-\boldsymbol{a}^{\mathrm{T}}\boldsymbol{\xi}+\boldsymbol{b}\,]^2 \tag{2}$$

式中：$\boldsymbol{d}=(u,v)^{\mathrm{T}}$ 为待求位移向量；$U(A_0)$ 为以 A_0 为中心的邻域窗口；$\boldsymbol{\omega}(\boldsymbol{\xi})$ 为高斯权重函数；$\boldsymbol{a}$、$\boldsymbol{b}$ 均为多项式系数。

为增强对整体运动趋势的捕捉能力，引入高斯金字塔多尺度分解。设原始图像为金字塔底层 L_0，第 k 层图像通过下采样得到：

$$L_k(x,y)=\frac{1}{4}\sum_{i=-1}^{1}\sum_{j=-1}^{1}L_{k-1}(2x+i,2y+j)\cdot G(i+1,j+1) \tag{3}$$

式中：G 为 3×3 高斯卷积核。

光流计算从顶层 L_k 开始逐层向下传递，通过由粗到精（coarse-to-fine，C2F）策略优化位移场，可得到相邻帧的光流图。分别计算不同压强层各时间步之间的光流图，最终得到光流图时间序列 $\{F_t\in\mathbf{R}^{H\times W\times P\times 2}|t=1,\cdots,L_T\}$，第 t 个时间步第 p 层压强层的光流图可表示为 $F_t^p\in\mathbf{R}^{H\times W\times 2}$。

1.2.3　云特征提取

采用双流卷积网络进行云分支特征提取，双流卷积网络通过并行处理空间结构和运动动态特征，实现对三维云量数据的全面表征[21-22]。该网络由空间流（spatial stream）和运动流（temporal stream）2 个分支组成，最终通过特征融合模块输出统一表征。

1）空间流。

空间流分支旨在提取云场的三维空间结构特征。其输入为经过插值处理后的三维云量数据 $I_t^*\in\mathbf{R}^{H\times W\times P}$，该分支采用三维卷积神经网络，通过分层递进的卷积与池化操作[23]，捕获从局部细节到全局范围的云场多尺度空间模式，经全局池化后最终输出空间流特征序列 $S_t\in\mathbf{R}^{D_S}$。

2）运动流。

运动流分支旨在捕捉云场的演变动态信息。其输入为 1.2.2 节中由金字塔 Farneback 光流法计算得到的光流场序列 $F_t\in\mathbf{R}^{H\times W\times P\times 2}$。鉴于不同压强层的云运动相对独立，本分支采用分层处理、加权融合的策略：首先，对每个压强层 p 的光流场 $F_t^p\in\mathbf{R}^{H\times W\times 2}$ 使用共享权重的二维卷积网络进行特征提取；随后，将各层提取的特征进行加权求和，权重为可训练参数 α_p，经全局池化后最终输出运动流特征序列 $T_t\in\mathbf{R}^{D_T}$。

3）特征融合。

为将空间与运动模态的特征融合为统一表征，将 2 个分支的输出特征 S_t 与 T_t 分别通过一个全连接层，投影至同一特征空间，并进行元素相加融合：

$$h_S=W_SS_t+b_S \tag{4}$$

$$h_T=W_TT_t+b_T \tag{5}$$

$$C_t=h_S+h_T \tag{6}$$

式中：W_S、b_S 和 W_T、b_T 分别为 2 个全连接层的权重与偏置参数。融合后的特征 $C_t\in\mathbf{R}^D$ 即为 t 时刻云数据的最终表征，它同时蕴含了云场的空间结构与动态变化信息。对所有历史时刻 $t=1,\cdots,L_T$ 重复此过程，即可得到云模态的特征序列 $X_{\mathrm{cloud}}\in\mathbf{R}^{L_T\times D}$。

1.3　基于 Transformer 编码器的辐照度特征提取

辐照度分支时间序列特征提取的思路为：先计算目标场站晴空辐照度，再与场站真实辐照度拼接输入 Transformer 编码器进行时序特征提取。

1.3.1　晴空辐照度计算

晴空辐照度仅与地球自转、公转相关，依据天文几何关系，可以计算出全年任意时刻晴空条件下地表辐照度，作为地表辐照度预测模型的输入，其计算公式为：

$$I_{\mathrm{nc}}=r_{\mathrm{aq}}r_{\mathrm{sc}}E_{\mathrm{d}}\cos\theta_{\mathrm{z}} \tag{7}$$

式中：I_{nc} 为晴空地表辐照度；r_{aq} 为空气质量引起辐照度衰减系数；r_{sc} 为太阳常数，约为 1368 W/m^2；E_{d} 为基于日地距离修正的归一化因子；θ_{z} 为太阳天顶角。

1.3.2　辐照度特征提取

采用 Transformer 编码器对辐照度特征进行提取，Transformer 编码器由多头自注意力机制（multiheaded self-attention，MSA）和前馈神经网络（feedforward neural network，FNN）堆叠而成，用于挖

掘辐照度时序数据中的长程依赖关系和复杂非线性特征[24]。

首先，输入场站实测辐照度时间序列$\{G_{\text{real}}^{t}|t=1,2,\cdots,L_T\}$和计算得出的晴空辐照度时间序列$\{G_{\text{clear}}^{t}|t=1,2,\cdots,L_T\}$，拼接得到$[G_{\text{real}}^{t}\|G_{\text{clear}}^{t}]$，通过线性投影映射到$d$维空间，并进行位置编码：

$$y_0=[(G_{\text{real}}^{1}\|G_{\text{clear}}^{1})\boldsymbol{E};\ \cdots;(G_{\text{real}}^{L_T}\|G_{\text{clear}}^{L_T})\boldsymbol{E}]+\boldsymbol{E}_{\text{pos}} \tag{8}$$

式中：$\boldsymbol{E}$为线性投影矩阵；$\boldsymbol{E}_{\text{pos}}$为位置编码矩阵。

位置编码后输入由L_{Trans}层多头自注意力机制和前馈神经网络堆叠而成的Transformer编码器中，每一层计算可表示为：

$$\tilde{y}_l=\text{LN}[\text{MSA}(y_{l-1})+y_{l-1}] \tag{9}$$

$$y_l=\text{LN}[\text{FNN}(\tilde{y}_l)+\tilde{y}_l] \tag{10}$$

式中：l为编码器第l层；LN(·)为层归一化操作。

重复上述操作，得到辐照度时间序列特征$X_{\text{irradiance}}\in\mathbf{R}^{L_T\times d}$。

1.4 基于交叉注意力的云-辐照度特征融合

为实现云与辐照度模态间深层、动态的特征交互[25]，本文采用交叉注意力(cross-attention)机制进行融合[26]。该机制允许辐照度特征主动查询并聚合与之最相关的云运动特征，从而精准建模“云况变化如何导致辐照度波动”这一核心物理关系。

1.2节和1.3节分别得到了云分支特征$X_{\text{cloud}}\in\mathbf{R}^{L_T\times D}$和辐照度分支特征编码$X_{\text{irradiance}}\in\mathbf{R}^{L_T\times d}$，为进行注意力计算，首先将二者通过线性层投影至相同的特征空间，以得到查询、键和值矩阵$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$[27]：

$$\boldsymbol{Q}=X_{\text{irradiance}}\boldsymbol{W}_Q \tag{11}$$

$$\boldsymbol{K}=X_{\text{cloud}}\boldsymbol{W}_K \tag{12}$$

$$\boldsymbol{V}=X_{\text{cloud}}\boldsymbol{W}_V \tag{13}$$

式中：$\boldsymbol{W}_Q$、$\boldsymbol{W}_K$、$\boldsymbol{W}_V$均为可学习的参数矩阵。投影后，计算以辐照度特征为查询、以云特征为键值的交叉注意力：

$$\boldsymbol{Y}=\text{softmax}(\boldsymbol{Q}\boldsymbol{K}^{\text{T}}/\sqrt{d_k})\boldsymbol{V} \tag{14}$$

式中：$\sqrt{d_k}$为缩放因子，用于防止点积结果过大导致梯度消失；softmax函数用于将注意力权重归一化。

为增强模型的融合能力，采用多头自注意力机制将上述过程在多个不同的投影子空间中并行执行，并将结果拼接后再次投影，得到融合特征：

$$Y_{\text{cloud-irradiance}}=\text{Concat}(Y_1,\cdots,Y_h)\boldsymbol{W}_0 \tag{15}$$

式中：Y_h为第h个注意力头的输出结果；Concat(·)为拼接操作；$\boldsymbol{W}_0$为输出投影矩阵。

最终，融合特征$Y_{\text{cloud-irradiance}}$汇聚了历史云状态变化与辐照度变化的耦合信息，作为后续解码器的输入。

1.5 基于非自回归解码器的辐照度预测

为实现未来的多步辐照度预测，本文采用基于Transformer的非自回归解码器(non-autoregressive decoder，NAT)。该解码器以融合后的历史特征为条件，并行地生成未来所有时间步的预测，具有较高的推理效率[28]。

输入1.4节中得到的融合特征$Y_{\text{cloud-irradiance}}$，为解码器提供历史云-辐照度的耦合信息。

此外，为启动预测，需构建解码器的初始输入序列。首先，输入长度为L_{token}的历史实测辐照度序列，映射到d维空间，得到$X_{\text{token}}\in\mathbf{R}^{L_{\text{token}}\times d}$作为<BOS>。设辐照度预测步长为$L_{\text{forecast}}$，则引入占位符$X_{\text{forecast}}\in\mathbf{R}^{L_{\text{forecast}}\times d}$，与$X_{\text{token}}$拼接后得到$X_{\text{input}}=[X_{\text{token}}\|X_{\text{forecast}}]$，编码后作为后续掩码多头自注意力的输入。

掩码多头自注意力机制仅关注过去和当前位置，屏蔽未来位置，与多头自注意力机制的差别主要在于注意力得分计算阶段：

$$\boldsymbol{A}_{\text{mask}}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\sum_{i=1}^{h}\text{softmax}\left(\frac{\boldsymbol{Q}_i\boldsymbol{K}_i^{\text{T}}}{\sqrt{d_k}}+\boldsymbol{M}\right)\boldsymbol{V}_i \tag{16}$$

式中：$\boldsymbol{M}$为因果掩码矩阵，其元素M_{ij}为：

$$M_{ij}=\begin{cases}0, i\geqslant j\\ -\infty, i<j\end{cases} \tag{17}$$

$\boldsymbol{A}_{\text{mask}}$经过残差连接和层归一化后与编码器部分的输出$\boldsymbol{E}_{\text{final}}$共同输入多头自注意力机制及后续的全连接前馈网络。

重复上述操作，即通过L_{Dec}层掩码注意力机制、多头自注意力机制与全连接前馈网络，最终通过一个可学习的噪声注入模块后得到地表辐照度多步预测的输出结果。

2 考虑辐照度-功率物理约束的光伏功率预测

由于第1章中引入云信息的地表辐照度预测结果更加实时、准确，更能真实反映地表辐照度受云团遮挡而引起的变化，因此本章以其作为超短期光伏功率预测模型的输入，而不采用传统NWP中的辐照度预测值。

此外，数据驱动与物理机理相结合可防止过拟合并提高模型的可解释性[29-30]，因此本章的预测模型采用数据-物理驱动的方式，在Transformer模型的基础上构建融合数据驱动与物理先验知识的损失函数，以提升超短期光伏功率预测的物理合理性与模

型泛化能力。

2.1　辐照度-光伏功率物理模型构建

对于某个固定位置的光伏系统，地表辐照度G与功率P之间存在如下关系：

$$P = \eta A G \tag{18}$$

式中：η为光伏系统效率；A为受照面积。

光伏电站实际运行时，η受运行温度、辐照度、电站运行环境、光伏组件表面清洁程度以及元件老化等因素的影响[31]。文献[14]建立的辐照度到功率的参数映射模型为：

$$P = \left[m + \alpha \sin\left(\frac{\pi n}{365}\right) + \beta \cos\left(\frac{\pi n}{365}\right)\right] \cdot (a_1 + a_2 G + a_3 \ln G)[1 - 0.005(T_C - 25)]G \tag{19}$$

式中：m、α、β、a_1、a_2、a_3为方程的待定参数，在2.2节中进行分析；n为一年中的第n天；T_C为光伏板运行温度，估算式为：

$$T_C = T_e + \frac{G}{G_{NOCT}}(T_{C,NOCT} - T_e) \tag{20}$$

式中：$T_{C,NOCT}$为标准测量环境下光伏板运行温度，一般取20 ℃；G_{NOCT}为标准测量环境下的辐照度，一般取800 W/m²；T_e为环境温度，本文采用NWP中的温度近似替代。

2.2　数据-物理驱动的超短期光伏功率预测模型构建

本节基于Transformer结构，建立融合数据驱动与辐照度-功率物理模型的损失函数$L_{D\text{-}P}$如下：

$$L_{D-P} = L_{RMSE} + \lambda_P L_P \tag{21}$$

式中：L_{RMSE}、L_P分别为基础均方根误差项、物理约束项；λ_P为物理约束的可调惩罚系数。

物理约束项可通过辐照度与功率转换规律实现，由于式(19)中待估参数较多，本文对其进行如下简化：

1)温度对光伏系统效率的影响与式(19)保持一致，即：

$$\eta_T = 1 - 0.005(T_C - 25) \tag{22}$$

2)假设近N日内电站运行环境、光伏组件老化以及清洁程度等因素对于效率的影响保持不变，视为一个常数η_e。

3)将辐照度分为K个连续区间$g = \{g_1, g_2, \cdots, g_K\}$，假设在同一辐照度区间$g_k$内，辐照度与功率转换效率仅与$\eta_T$与$\eta_e$有关。本文参考国际电工委员会IEC 61853标准对光伏组件性能测试的分段方法[32]，并结合本站辐照度实测数据均分布于0~1000 W/m²的特点，将辐照度划分为$\{g_{1(0\sim200)}, g_{2(200\sim400)}, g_{3(400\sim600)}, g_{4(600\sim800)}, g_{5(800\sim1000)}\}$ W/m²，该划分方式与标准中关注的200 W/m²(低辐照度性能)、400 W/m²、600 W/m²、800 W/m²及1000 W/m²(标称工作温度下的性能测试点)[33]等关键阈值保持一致，使得每个区间得以表征不同的光伏物理特性，保证参考效率值η_{ref}^t计算的科学性。

对预测时刻t，计算其近7日同一辐照度区间内所有时刻的转换效率，除去温度对效率的影响后取中位数，作为预测时刻t的参考效率值η_{ref}^t：

$$\eta_{ref}^t = \text{median}\left(\frac{P}{G\eta_T}\right), G_{pred}^t, G \in g_k \tag{23}$$

式中：G_{pred}^t为预测时刻t的辐照度。

经过以上讨论，定义式(21)中的物理约束惩罚项L_P为：

$$L_P = \frac{1}{n}\sum_{t=1}^{n}\left|\frac{P_{pred}^t}{G_{pred}^t \eta_T^t} - \eta_{ref}^t\right| \tag{24}$$

式中：P_{pred}^t为预测时刻t的功率。

3　整体预测流程

本文基于3DCloudA-V1.0的三维云量实况分析数据，提出了一种基于云-辐照度-功率耦合机理的超短期光伏功率预测方法，整体技术方案如图2所示。

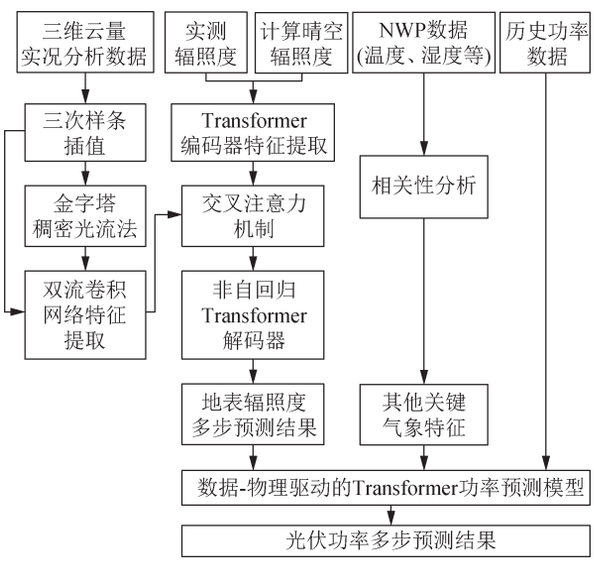


图2　基于云-辐照度-功率耦合机理的超短期光伏功率预测流程

Fig. 2　Flowchart of ultra-short-term photovoltaic power prediction based on the cloud-irradiance-power coupling mechanism

具体流程如下：

1)对云团数据进行三次样条插值处理，基于金字塔Farneback光流法计算出相邻帧之间的光流，通过双流卷积网络分别提取云团空间特征和运动特征，得到能表征云团空间结构和动态变化的云分支

融合特征。

2)根据光伏电站经纬度坐标计算晴空辐照度,与场站实测辐照度拼接后输入Transformer编码器得到辐照度分支特征。

3)通过交叉注意力机制得到云运动特征和辐照度时间序列特征的融合特征,输入非自回归编码器,实现地表辐照度的多步预测。

4)输入地表辐照度预测结果、其他相关性较高的NWP气象特征以及历史功率数据,通过在损失函数中引入辐照度与光伏功率转换的物理约束,建立基于数据-物理驱动模型的超短期光伏功率预测模型,得到光伏功率预测结果。

4 算例分析

4.1 实验数据说明

为验证本文所提方法的有效性,使用以下多种来源的数据进行实验:

1)历史光伏功率与地面实测辐照度数据来自海南省某集中式光伏电站,时间范围为2024年全年,时间分辨率为15 min。

2)云层覆盖比数据来源于国家气象中心研制与开发的3DCloudA-V1.0的三维云量实况分析产品,空间分辨率为0.05°,时间分辨率为1 h,共43层压强层。

3)NWP数据由中国气象局提供,包含时间分辨率为15 min的气象要素预测值(如温度、湿度、风速、气压等)。

上述数据通过异常值提出和缺失值插补后,将2024年1—8月的数据作为训练集,9—10月的数据作为验证集,11—12月的数据作为测试集。

为筛选出与光伏功率显著相关的NWP气象要素,本文计算了各气象要素与光伏功率之间的皮尔逊相关系数[34-35],结果如表1所示。

表1 NWP气象要素皮尔逊相关系数

Table 1 Pearson correlation coefficients of NWP meteorological elements

NWP气象要素	皮尔逊相关系数
辐照度	0.906
温度	0.517
湿度	−0.402
风速	0.237
气压	−0.059
风向	0.121

基于皮尔逊相关系数分析,本文选定温度与湿度作为辐照度之外的关键气象输入特征。此外,为验证本文所提地表辐照度预测方法的有效性,实验将NWP辐照度预测值与本文方法预测的地表辐照度值分别作为输入,进行对比实验,以评估其对最终光伏功率预测精度的影响。

4.2 评价指标

为客观描述本文模型的性能,采用平均绝对误差(mean absolute error,MAE)σ_{MAE}、均方根误差(root mean square error,RMSE)σ_{RMSE}和决定系数R^2作为预测精度评价标准,计算公式为:

$$\sigma_{\mathrm{MAE}}=\frac{1}{n_{\mathrm{sample}}}\sum_{i=1}^{n_{\mathrm{sample}}}|\hat{y}_i-y_i| \tag{25}$$

$$\sigma_{\mathrm{RMSE}}=\sqrt{\frac{1}{n_{\mathrm{sample}}}\sum_{i=1}^{n_{\mathrm{sample}}}(\hat{y}_i-y_i)^2} \tag{26}$$

$$R^2=1-\frac{\sum_{i=1}^{n_{\mathrm{sample}}}(y_i-\hat{y}_i)^2}{\sum_{i=1}^{n_{\mathrm{sample}}}(y_i-\bar{y}_i)^2} \tag{27}$$

式中:y_i、$\hat{y}_i$、$\bar{y}_i$分别为预测值、真实值、真实值的均值;n_{sample}为样本个数。

4.3 地表辐照度预测结果分析

4.3.1 消融实验

为验证本文所提地表辐照度预测方法各组成部分的有效性,本节设计了消融实验,所得结果如表2所示。

表2 地表辐照度预测模型消融实验结果

Table 2 Ablation experiment results on surface irradiance prediction models

模型	MAE/(W/m²)	RMSE/(W/m²)	R^2
移除云分支	32.32	88.205	0.880
云分支仅输入三维云序列	25.22	70.882	0.924
云分支仅输入光流序列	24.13	68.452	0.927
移除交叉注意力(云与辐照度特征简单拼接)	22.81	65.951	0.932
用Transformer自回归解码器替换非自回归解码器	19.87	60.127	0.945
本文方法	12.02	56.020	0.953

消融实验结果表明,本文所提出的各模块均对提升地表辐照度预测性能具有重要贡献。首先,仅依赖辐照度时序输入的模型(移除云分支)性能最弱,显著劣于融合云数据的模型,印证了云动态信息对辐照度预测的关键作用。在云分支中,仅使用三维云序列或光流序列均优于无云分支模型,其中光流序列的单独使用略优于仅使用

三维云序列，说明云团运动信息对预测未来辐照度变化尤为重要。若将交叉注意力机制替换为特征简单拼接，模型性能出现明显下降，表明交叉注意力能更有效地挖掘云与辐照度间的深层时空耦合关系。此外，使用自回归解码器虽优于拼接模型，但仍差于本文非自回归解码器，说明非自回归结构通过并行解码有效缓解了误差累积问题。最终，本文完整模型在各项指标上均达到最优，验证了整体架构设计的有效性。

4.3.2　不同预测方法精度对比

本节选用 ConvLSTM、TCN-Informer[36-37]、ST-Former[38]这 3 种时空预测模型与本文方法进行对比。所有对比模型均采用与本文方法一致的输入与输出设置，以确保对比的公平性：模型输入为历史三维云数据及辐照度序列，输出为未来地表辐照度预测值。模型性能均采用 MAE、RMSE 与 R^2 指标进行统一评价。

为评估模型在不同典型场景下的性能，本文区分晴天和波动天气 2 种典型天气场景进行精度分析[39]。具体地，根据每个实验日内辐照度序列的标准差进行天气类型划分，将实验日按标准差从低到高排列，其中前 30%（即标准差较小）的实验日定义为“晴天”，后 30%（即标准差较大）的实验日定义为“波动天气”，定量结果见表 3，典型天气案例预测曲线如图 3 所示。

表 3　2 种典型天气场景下模型精度对比

Table 3　Comparison of model accuracy in two typical weather situations

方法	晴天			波动天气		
	MAE/MW	RMSE/MW	R^2	MAE/MW	RMSE/MW	R^2
ConvLSTM	31.70	66.27	0.938	33.35	80.43	0.885
TCN-Informer	21.84	58.55	0.951	22.00	66.29	0.931
ST-Former	20.69	58.36	0.959	24.63	69.54	0.924
本文方法	11.29	52.36	0.961	13.50	62.68	0.938

晴朗天气（图 3(a)）下，辐照度变化主要受太阳高度角影响，整体呈现平滑的正弦曲线特征，偶有薄云干扰造成小幅波动。ConvLSTM 难以精准跟踪太阳位置连续变化的物理规律，存在时间滞后问题，在日出日落时段误差显著。TCN-Informer 通过膨胀卷积捕捉长时依赖，但其在无突变时过度依赖局部时序波动建模，导致输出产生虚假振荡，破坏平滑趋势预测的稳定性。ST-Former 模型凭借其时空注意力机制，能有效捕捉太阳轨迹的连续变化，其自适应高斯滤波特性使其在稳定晴空场景表现优异。本文方法

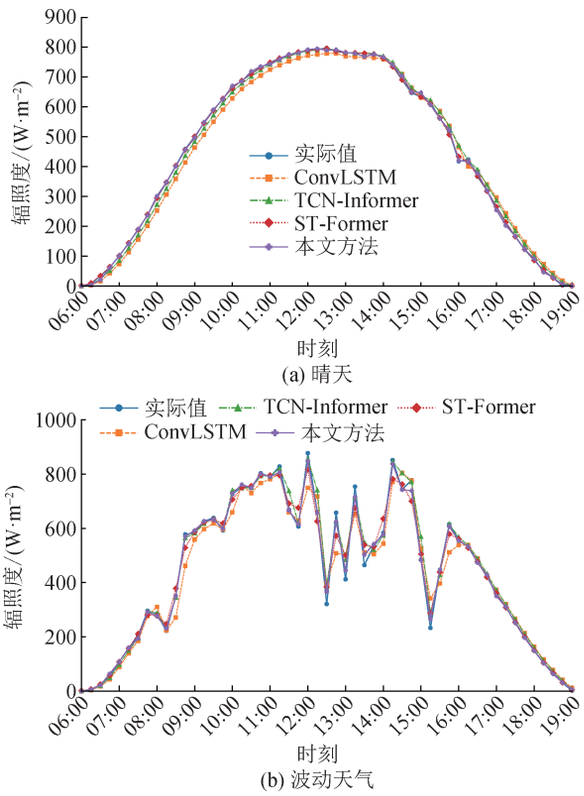


图 3　2 种典型天气场景下模型预测曲线对比

Fig. 3　Comparison of model prediction curves in two typical weather situations

通过三维云空间与运动特征提取，以及云-辐照度交叉注意力融合机制，在波动天气下实现超前预测与动态校正，同时保持晴空条件下趋势预测的稳定性，显著提升预测精度，MAE 和 RMSE 分别下降了 38.6%~45.4%、10.3%~21.0%。

波动天气（图 3(b)）下，快速变化的云团导致辐照度高频突变。ConvLSTM 的滞后效应在波动天气场景进一步放大，对高频突变响应不足。TCN-Informer 能有效提取云团变化的前后时间关联，对突变信号的敏感性使其能快速响应辐照度骤变。ST-Former 存在过度平滑的问题，在云团快速移动时产生滞后误差。本文方法在辐照度突变的情况下仍能实现较高精度的预测，相较于其他对比方法，MAE 和 RMSE 分别下降了 59.5%~64.4%、9.90%~22.06%。

4.4　光伏功率预测效果验证

4.4.1　地表辐照度预测的有效性

为验证本文所提地表辐照度预测方法的有效性，本文设计了 3 种光伏功率预测模型的输入方案进行对比：1）直接输入 NWP 辐照度预报值（方案 1）；2）输入 NWP 辐照度与基于光流外推法的三维云量预测值（方案 2）；3）输入本文方法预测的地表辐照度值（方案 3）。各方案下的预测精度对比结果如表 4

所示。

表 4　3种输入方案下光伏功率预测精度对比

Table 4　Comparison of photovoltaic power prediction accuracy under three input schemes

输入方案	晴天			波动天气		
	MAE/MW	RMSE/MW	R^2	MAE/MW	RMSE/MW	R^2
NWP辐照度	0.67	1.16	0.942	2.86	5.96	0.894
NWP辐照度+三维云量	0.58	1.03	0.950	1.95	3.66	0.917
本文预测的辐照度	0.53	0.94	0.958	1.37	2.45	0.931

对比分析表4结果可知，在不同天气条件下，3种输入方案的光伏功率预测精度呈现显著差异。无论在晴天还是波动天气下，采用本文预测辐照度作为输入（方案3）的精度均最优，其各项指标均显著优于直接使用NWP辐照度的方案1，同时也高于结合NWP与云量光流外推的方案2。

特别是在云况复杂多变的波动天气下，本文方法的优势更为突出：相较于方案1，MAE和RMSE分别降低了52.1%和58.9%，R^2提升了4.1%；即便与方案2相比，MAE和RMSE仍分别显著降低了29.7%和33.1%，R^2提升了1.5%。该结果充分证明，本文所提辐照度预测模型能够更有效地捕捉云团动态变化对地表辐照度的细微影响，其预测准确性优于传统NWP及简单的光流外推方法。

4.4.2　数据-物理驱动模型验证

为验证本文所提数据-物理驱动的超短期光伏功率预测方法的有效性，对比是否添加物理约束2种情况下光伏功率预测结果曲线，如图4所示。

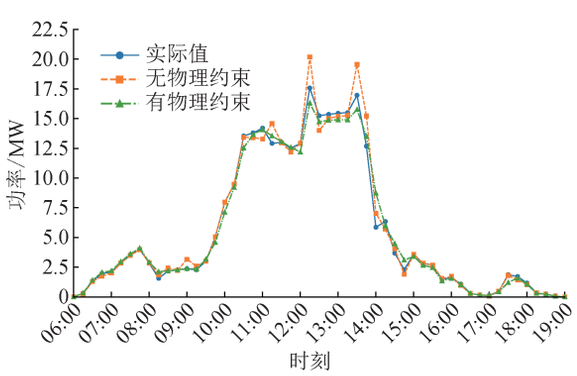


图4　有无物理约束光伏功率预测曲线对比

Fig. 4　Comprision of photovoltaic power prediction curves with and without physical constraints

从整体趋势上看，有物理约束模型相较于无物理约束模型显著提升了预测结果的稳定性与准确性。为进一步体现添加物理约束的合理性以及物理约束的惩罚项系数λ_P对预测精度影响，本文对比了λ_P取不同值时的功率预测精度，如表5所示。

表 5　不同惩罚项系数的光伏功率预测精度对比

Table 5　Comparison of photovoltaic power prediction accuracy with different penalty term coefficients

惩罚项系数λ_P	MAE/MW	RMSE/MW	R^2	训练集RMSE/MW	泛化差距
0（无物理约束）	0.96	1.79	0.937	1.40	0.39
0.1	0.89	1.68	0.944	1.47	0.21
0.2	0.84	1.63	0.947	1.52	0.11
0.3	0.81	1.61	0.949	1.55	0.06
0.4	0.83	1.64	0.946	1.60	0.04
0.5	0.87	1.83	0.939	1.75	0.08
0.6	0.92	2.15	0.930	2.03	0.12

当惩罚项系数过小时（λ_P<0.2），无法充分发挥物理约束的正则化作用，泛化差距>0.2；当惩罚项系数过大时（λ_P>0.4），过强的物理约束会压制模型的数据学习能力，导致训练集RMSE显著上升，测试集精度恶化，出现欠拟合趋势。敏感性分析表明，λ_P=0.3时达到最优平衡点：测试集RMSE最低（1.61 MW），同时保持合理的泛化差距（0.06），较无物理约束模型MAE和RMSE分别下降了15.6%、10.1%。

5　结　论

1）本文所提基于云-辐照度耦合特征的地表辐照度预测算法，有效捕捉了云团动态变化与地表辐照度间的复杂关联关系，显著提升了地表辐照度的多步预测精度。这一高精度辐照度预测结果为后续光伏功率预测奠定了坚实基础。

2）本文所构建的数据驱动-物理约束光伏功率预测模型，通过引入辐照度-光伏出力物理约束惩罚项，并结合更精准的本文辐照度预测结果（优于传统NWP输入），显著增强了模型的泛化能力与预测精度，有效避免了过拟合。

尽管本文达到了预期效果，但仍存在一些局限性。首先，本文依赖于三维云分析业务数据，其空间与时间分辨率存在上限，未来可探索更高精度的云信息以进一步提升预测精度。此外，本文的场景覆盖有提升空间：一方面，当前的天气场景划分相对简化，未来可引入更多源的气象数据以构建更精细化的分类体系；另一方面，模型对台风等极端天气的预测能力仍有待验证，这将是后续工作的重点方向。

利益冲突声明（Conflict of Interests）：

所有作者声明不存在利益冲突。

作者贡献声明（Authors' Contributions）：

孙映萱进行研究设计与实验、撰写论文；杨苹提出研究方向，设计论文框架；孙涛、段凯玥、简文清参与论文修订。所有作者均阅读并同意了论文终稿内容。

6　参考文献

[1] 龚莺飞，鲁宗相，乔颖，等. 光伏功率预测技术[J]. 电力系统自动化，2016，40(4)：140-151.
GONG Yingfei，LU Zongxiang，QIAO Ying，et al. An overview of photovoltaic energy system output forecasting technology [J]. Automation of Electric Power Systems，2016，40(4)：140-151.

[2] 马成廉，韩瑞，宋萌清，等. 基于多源气象数据的光伏功率预测深度学习架构[J]. 电网与清洁能源，2025，41(4)：104-112.
MA Chenglian，HAN Rui，SONG Mengqing，et al. Deep learning architecture for photovoltaic power prediction based on multi-source meteorological data[J]. Power System and Clean Energy，2025，41(4)：104-112.

[3] 叶林，裴铭，路朋，等. 基于天气分型的短期光伏功率组合预测方法[J]. 电力系统自动化，2021，45(1)：44-54.
YE Lin，PEI Ming，LU Peng，et al. Combination forecasting method of short-term photovoltaic power based on weather classification[J]. Automation of Electric Power Systems，2021，45(1)：44-54.

[4] 黄晓燕，郭洒洒，陈成优，等. 考虑时空关联及气象耦合的区域分布式光伏功率预测[J]. 浙江电力，2025，44(3)：79-89.
HUANG Xiaoyan，GUO Sasa，CHEN Chengyou，et al. Regional distributed photovoltaic power forecasting considering spatiotemporal cor-relation and meteorological coupling [J]. Zhejiang Electric Power，2025，44(3)：79-89.

[5] 顾锦，刘宇，顾雷涛，等. 基于气象分类的超短时光伏发电预测模型[J]. 太阳能学报，2025，46(12)：263-270.
GU Jin，LIU Yu，GU Leitao，et al. Forecasting model of ultra-short-term photovoltaic power based on meteorological classification [J]. Acta Energiae Solaris Sinica，2025，46(12)：263-270.

[6] 杨明，李梦林，王勃，等. 面向新型电力系统的数值天气预报技术及应用综述[J]. 电力系统自动化，2025，49(17)：1-20.
YANG Ming，LI Menglin，WANG Bo，et al. Review on technologies and applications of numerical weather prediction for new power system [J]. Automation of Electric Power Systems，2025，49(17)：1-20.

[7] 陶思钰，江福庆. 集群化发展模式下风电场预测、规划及控制关键技术综述[J]. 电力工程技术，2024，43(1)：86-99.
TAO Siyu，JIANG Fuqing. Review of the key technologies of wind farm cluster prediction，planning and control [J]. Electric Power Engineering Technology，2024，43(1)：86-99.

[8] GUO S，FAN H Y，HUANG J. Ultra-short-term PV power prediction based on an improved hybrid model with sky image features and data two-dimensional purification [J]. Energy，2025，331：137018.

[9] MARTINS B J，CERENTINI A，NETO S L M，et al. Systematic literature review on forecasting/nowcasting based upon ground-based cloud imaging[J]. Florianó polis：INCoD，2021.

[10] 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.

[11] 邓芳明，刘涛，王锦波，等. 基于地基云图与气象因素多模态融合的光伏功率预测方法[J]. 中国电机工程学报，2025，45(18)：7193-7205.
DENG Fangming，LIU Tao，WANG Jinbo，et al. Research on photovoltaic power prediction based on multimodal fusion of ground cloud map and meteorological factors [J]. Proceedings of the CSEE，2025，45(18)：7193-7205.

[12] 司志远，杨明，于一潇，等. 基于卫星云图特征区域定位的超短期光伏功率预测方法[J]. 高电压技术，2021，47(4)：1214-1223.
SI Zhiyuan，YANG Ming，YU Yixiao，et al. Ultra-short-term photovoltaic power prediction method based on satellite image feature region positioning [J]. High Voltage Engineering，2021，47(4)：1214-1223.

[13] 白捷予，董存，王铮，等. 考虑云层遮挡的光伏发电功率超短期预测技术[J]. 高电压技术，2023，49(1)：159-168.
BAI Jieyu，DONG Cun，WANG Zheng，et al. Ultra-short-term prediction of photovoltaic power generation considering cloud cover [J]. High Voltage Engineering，2023，49(1)：159-168.

[14] 郑珂，王丽婕，郝颖，等. 基于数据集蒸馏的光伏发电功率超短期预测[J]. 中国电机工程学报，2024，44(13)：5196-5207.
ZHENG Ke，WANG Lijie，HAO Ying，et al. Ultra-short-term prediction of photovoltaic power based on dataset distillation [J]. Proceedings of the CSEE，2024，44(13)：5196-5207.

[15] 朱琼锋，李家腾，乔骥，等. 人工智能技术在新能源功率预测的应用及展望[J]. 中国电机工程学报，2023，43(8)：3027-3047.
ZHU Qiongfeng，LI Jiateng，QIAO Ji，et al. Application and prospect of artificial intelligence technology in renewable energy forecasting[J]. Proceedings of the CSEE，2023，43(8)：3027-3047.

[16] VAN DER MEER D W，WIDÉN J，MUNKHAMMAR J. Review on probabilistic forecasting of photovoltaic power production and electricity consumption [J]. Renewable and Sustainable Energy Reviews，2018，81：1484-1512.

[17] 马原，张雪敏，甄钊，等. 基于修正晴空模型的超短期光伏功率预测方法[J]. 电力系统自动化，2021，45(11)：44-51.
MA Yuan，ZHANG Xuemin，ZHEN Zhao，et al. Ultra-short-term photovoltaic power prediction method based on modified clear-sky model [J]. Automation of Electric Power Systems，2021，45

(11)：44-51.

[18] 朱智，师春香，刘瑞霞，等. 我国三维云融合分析业务系统(3DCloudA-V1.0)研制与开发[J]. 气象科技，2021，49(1)：55-62.
ZHU Zhi，SHI Chunxiang，LIU Ruixia，et al. Research and development of three-dimensional cloud merging analysis operation system (3DCloudA-V1.0) in China[J]. Meteorological Science and Technology，2021，49(1)：55-62.

[19] LIU J X，ZANG H X，CHENG L L，et al. A Transformer-based multimodal-learning framework using sky images for ultra-short-term solar irradiance forecasting[J]. Applied Energy，2023，342：121160.

[20] 仇晨光，倪杰，王博仑，等. 基于相似日与数据机理混合驱动的光伏发电功率预测[J]. 电网与清洁能源，2025，41(9)：101-109.
QIU Chenguang，NI Jie，WANG Bolun，et al. Photovoltaic power generation forecasting based on hybrid-driven approach combining similar days and data mechanism[J]. Power System and Clean Energy，2025，41(9)：101-109.

[21] SIMONYAN K，ZISSERMAN A. Two-stream convolutional networks for action recognition in videos[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 1. ACM，2014：568-576.

[22] 辛峰悦，寇志伟，刘焱晨，等. 基于双流特征增强网络的超短期光伏功率预测[J]. 电子测量技术，2025，48(5)：65-73.
XIN Fengyue，KOU Zhiwei，LIU Yanchen，et al. Ultra-short-term photovoltaic power prediction based on two-stream feature enhancement network[J]. Electronic Measurement Technology，2025，48(5)：65-73.

[23] JI S W，XU W，YANG M，et al. 3D convolutional neural networks for human action recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2013，35(1)：221-231.

[24] TIAN Z R，LIANG B J. PVMTF：End-to-end long-sequence time-series forecasting frameworks based on patch technique and information fusion coding for mid-term photovoltaic power forecasting[J]. Applied Energy，2025，396：126263.

[25] 潘东，杨欣，施天成，等. 基于量子长短期记忆网络的光伏功率预测模型[J]. 电力建设，2025，46(1)：122-133.
PAN Dong，YANG Xin，SHI Tiancheng，et al. Photovoltaic-power prediction model based on quantum long short-term memory network[J]. Electric Power Construction，2025，46(1)：122-133.

[26] VASWANI A，SHAZEER N，PARMAR N，et al. Attention is all you need[C]// NIPS'17：Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017：6000-6010.

[27] 唐雅洁，龚迪阳，林达，等. 基于SAX-MHA-GCN的区域分布式光伏超短期功率预测[J]. 浙江电力，2025，44(8)：88-98.
TANG Yajie，GONG Diyang，LIN Da，et al. Ultra-short-term power forecasting for regional DPV systems based on SAX-MHA-GCN[J]. Zhejiang Electric Power，2025，44(8)：88-98.

[28] YUAN L，WANG X T，SUN Y，et al. Multistep photovoltaic power forecasting based on multi-timescale fluctuation aggregation attention mechanism and contrastive learning[J]. International Journal of Electrical Power & Energy Systems，2025，164：110389.

[29] 温茂林，邓汉钧，杨帅，等. 基于MPFA内嵌物理神经网络的园区空调负荷短期预测[J]. 电网与清洁能源，2025，41(4)：1-11.
WEN Maolin，DENG Hanjun，YANG Shuai，et al. Short term load forecasting of air conditioning in the park based on MPFA embedded physical neural network[J]. Power System and Clean Energy，2025，41(4)：1-11.

[30] GAO X F，ZANG Y S，MA Q，et al. A physics-constrained deep learning framework enhanced with signal decomposition for accurate short-term photovoltaic power generation forecasting[J]. Energy，2025，326：136220.

[31] 张一帆，王宇强，潘大志，等. 基于云图数据的分布式光伏超短期功率预测方法研究[J]. 电网与清洁能源，2025，41(9)：110-115.
ZHANG Yifan，WANG Yuqiang，PAN Dazhi，et al. Research on prediction methods of distributed photovoltaic ultra-short-term power based on cloud image data[J]. Power System and Clean Energy，2025，41(9)：110-115.

[32] 光电(PV)模块性能试验和额定功率. 第1部分：辐照度，温度性能测量和额定功率：IEC 61853-1[S]. 国际电工委员会，2011.
Photovoltaic (PV) module performance testing and energy rating - part 1：irradiance and temperature performance measurements and power rating：IEC 61853-1[S]. International Electrotechnical Commission，2011.

[33] 王欢. IEC 61853标准光伏组件测量方法研究[D]. 北京：北京交通大学，2015.
WANG Huan. Research on measurement methods of photovoltaic module per IEC 61853[D]. Beijing：Beijing Jiaotong University，2015.

[34] 张静，熊国江. 考虑季节特性与数据窗口的短期光伏功率预测组合模型[J]. 电力工程技术，2025，44(1)：183-192.
ZHANG Jing，XIONG Guojiang. Short-term photovoltaic power prediction combination model considering seasonal characteristic and data window[J]. Electric Power Engineering Technology，2025，44(1)：183-192.

[35] 陆毅，薛枫，唐小波，等. 基于余弦相似度和TSO-BP的短期光伏预测方法[J]. 浙江电力，2024，43(6)：22-30.
LU Yi，XUE Feng，TANG Xiaobo，et al. A short-term PV power forecasting method based on cosine similarity and TSO-BP neural network[J]. Zhejiang Electric Power，2024，43(6)：22-30.

[36] 王舒雨，李豪，马刚，等. 基于TCN和DLinear的光伏发电功率多步预测模型[J]. 电力建设，2025，46(4)：173-184.
WANG Shuyu，LI Hao，MA Gang，et al. Multistep prediction model for photovoltaic power generation based on time convolution

and DLinear[J]. Electric Power Construction, 2025, 46(4): 173-184.

[37] 赵雪锋，张宇宁，詹巍，等. 基于TCN-Informer的多源融合虚拟最优气象源光伏功率预测[J]. 水力发电，2025，51(3)：97-104，124.
ZHAO Xuefeng, ZHANG Yuning, ZHAN Wei, et al. Photovoltaic power prediction based on TCN-informer and multi-source fusion of virtual optimal weather sources[J]. Water Power, 2025, 51(3): 97-104, 124.

[38] 张鹏飞，胡博，胡展硕，等. 基于STD-ST-Former的现货电价长步时空预测[J]. 中国电机工程学报，2025，45(19)：7456-7467.
ZHANG Pengfei, HU Bo, HU Zhanshuo, et al. Long step spatial-temporal prediction of spot electricity price based on STD-ST-Former[J]. Proceedings of the CSEE, 2025, 45(19): 7456-7467.

[39] 张家安，王琨玥，陈建，等. 基于空间相关性的分布式光伏出力预测[J]. 电力建设，2020，41(3)：47-53.
ZHANG Jia'an, WANG Kunyue, CHEN Jian, et al. Research on prediction of distributed photovoltaic output considering spatial relevance[J]. Electric Power Construction, 2020, 41(3): 47-53.

收稿日期：2025-08-28　**修回日期**：2025-10-20


孙映萱

作者简介：

孙映萱(2001)，女，硕士研究生，主要研究方向为新能源功率预测、可调节资源优化调度，E-mail：202321015107@mail.scut.edu.cn；

杨苹(1967)，女，博士，教授，通信作者，主要研究方向为可调节资源优化调度、可再生能源的发电控制、电能质量分析与监控管理等，E-mail：eppyang@scut.edu.cn；

孙涛(2001)，男，博士研究生，主要研究方向为微能源网优化调度、工业需求侧响应，E-mail：202310182841@mail.scut.edu.cn；

段凯玥(2001)，女，硕士研究生，主要研究方向为储能优化配置，E-mail：202321015089@mail.scut.edu.cn；

简文清(2001)，男，硕士研究生，主要研究方向为可再生能源并网技术，E-mail：202321015094@mail.scut.edu.cn。

（编辑　景贺峰）

广告目次

封二　《电力建设》期刊常设栏目及热点专题

封三　《电力建设》期刊广告招商

封底　珍爱地球公益广告

前插1　国网电力科学研究院武汉南瑞有限责任公司