

DOI: 10.19783/j.cnki.pspc.241221

基于地基云图数据多维特征融合的光伏功率预测算法

吐松江·卡日¹, 吴现², 马小晶¹, 雷柯松³, 余凯峰¹, 司伟壮¹

(1. 新疆大学电气工程学院, 新疆 乌鲁木齐 830049; 2. 国网浙江省电力有限公司丽水供电公司, 浙江 丽水 323000;
3. 国网新疆电力有限公司昌吉供电公司, 新疆 昌吉 831100)

摘要: 针对传统光伏功率预测算法无法获取准确云层状态信息和预测精度低等问题, 提出一种基于地基云图与双流数据融合的光伏功率预测算法。首先, 利用地基云图提供的精确云层状态信息, 结合稠密光流法获取相邻帧图像间的时空特征与细节变化特征。其次, 结合卷积神经网络(convolutional neural network, CNN)在特征提取上的优势和残差网络在模型学习中抑制信息丢失上的优势, 提升预测模型对光伏功率与图像数据间长期映射关系的学习能力。此外, 引入注意力机制弥补模型训练过程中关键信息利用不充分的缺陷。实验结果表明, 地基云图与光流数据的加入为多云天气提供了更多时空特征。与基准模型相比, 其晴天与多云情况下均方根误差(root mean squared error, RMSE)指标和平均绝对误差(mean absolute error, MAE)指标分别降低了 15.50%、11.65%、4.05%与 5.15%, 有助于充分利用云层运动状况来实现准确可靠的光伏电站输出功率预测, 提升光伏电站调度工作的及时性与准确性。

关键词: 深度学习; 功率预测; 地基云图; 注意力机制; 稠密光流算法

Photovoltaic power prediction algorithm based on multidimensional features fusion of ground-based cloud images

TUSONGJIANG Kari¹, WU Xian², MA Xiaojing¹, LEI Kesong³, YU Kaifeng¹, SI Weizhuang¹

(1. School of Electrical Engineering, Xinjiang University, Urumqi 830049, China; 2. Lishui Power Supply Company, State Grid Zhejiang Electric Power Co., Ltd., Lishui 323000, China; 3. Changji Power Supply Company, State Grid Xinjiang Electric Power Co., Ltd., Changji 831100, China)

Abstract: To address the limitations of traditional photovoltaic (PV) power prediction algorithms, particularly their inability to accurately capture cloud conditions and their low prediction accuracy, a PV power prediction algorithm based on the fusion of ground-based cloud images and dual-stream data is proposed. First, accurate cloud condition information from ground-based cloud images is utilized, and dense optical flow is employed to extract spatiotemporal and detail change features between adjacent image frames. Then, the advantages of convolutional neural network in feature extraction and residual network in suppressing information loss in model learning are combined to improve the learning ability of the prediction model on the long-term mapping relationship between PV power output and image data. In addition, an attention mechanism is introduced to compensate for the underutilization of critical information during model training. Experimental results indicate that integrating ground-based cloud images and optical flow data offers more spatiotemporal features under cloudy weather conditions. Compared with benchmark models, the proposed method reduces the root mean square error (RMSE) and the mean absolute error (MAE) by 15.50% and 11.65% under sunny conditions, and by 4.05% and 5.15% under cloudy conditions, respectively. This contributes to accurate and reliable forecasting of PV power output by effectively utilizing cloud motion information, thereby improving the timeliness and accuracy of scheduling operations in PV power stations.

This work is supported by the National Natural Science Foundation of China (No. 52067021).

Key words: deep learning; power prediction; ground-based cloud mapping; attention mechanism; dense optical flow algorithm

基金项目: 国家自然科学基金项目资助(52067021); 新疆维吾尔自治区自然科学基金面上项目资助(2022D01C35); 新疆维吾尔自治区优秀青年科技人才培养项目资助(2019Q012)

0 引言

太阳能作为一种重要的可再生能源, 其具有易获取、无污染且资源充足等特点, 目前太阳能开发与利用已成为我国能源结构调整的重要方向^[1]。据统计, 截至 2023 年底全国光伏累计装机容量达到 6.09 亿 kW, 同比增长 55.2%; 全国新增光伏装机容量约为 2.17 亿 kW, 同比增长 148.12%, 几乎为近 4 年光伏新增装机量之和, 展现出了广阔的应用前景与持续上涨势头^[2]。然而光伏电站发电功率受到诸多气象因子与环境因素影响而表现出强波动性与随机性^[3], 其在一定程度下阻碍了大规模光伏电站的部署。因此准确的光伏功率预测工作不仅能够降低备用容量以提升运行经济性, 而且在保障电力系统安全稳定运行方面 also 具有重要意义。

大气状态的波动性使得太阳辐照度变化呈现出随机性^[4], 快速非定向移动的云团对光伏电站的遮挡使得光伏功率在多云天气下容易产生频繁突变, 为解决上述问题国内外的研究学者提出了多种超短期光伏功率预测算法。按照数据来源主要分为基于历史数据挖掘的技术路线、考虑未来天气因素的技术路线与基于云观测数据的技术路线 3 类^[5]。

基于历史数据挖掘的技术路线的常用方法包括持续预测模型^[6]及灰色理论模型^[7]等。文献[7]根据不同天气对历史功率数据进行划分, 利用基于相似日的小波算法进行光伏功率的逐时预测与日累加预测, 并使用灰色系统模型对预测结果进行校正。相较于其他数据挖掘模型, 该模型预测性能更强, 但因其未考虑温度、云量等气象因素的影响, 不适用于复杂多变的天气情况。基于历史数据的预测模型通常需要充分的历史数据支持并且模型的迭代时间较长, 泛化性能不高, 历史数据只能使模型获取到过去电站的发电规律, 当气候突变时无法为电站提供准确的预测^[8]。

考虑未来天气因素的技术路线, 将数值天气预报数据中例如温度、湿度、降雨量、风速与大气压力等因素与光伏发电功率相结合, 建立映射模型以挖掘其内在联系进而实现对光伏功率的预测^[9]。文献[10]对结合历史天气数据与光伏输出功率的数据集进行研究, 首先利用 K-means++ 聚类算法将数据划分为若干天气类型, 其次借助 WGAN-GP 对数据进行增强, 最后使用基于注意力机制的组合预测模型对光伏功率进行预测。与传统模型相比, 该模型具有更高的精确度, 但由于其未考虑云层不规则运动与云团的生消, 当云团对太阳光线产生遮挡或快速移动时模型预测值与真实值偏差较大。光伏功率预测

精度与数值天气预报数据精确性具有紧密联系, 然而我国大部分光伏电站多建设于偏远地区, 部分电站面临数值天气预报数据缺乏的情况, 在一定程度上提升了预测难度。因此借助云团观测数据来实现光伏功率预测方法成为提升预测精度的新技术手段^[11]。

为了提高复杂突变天气下光伏功率预测精度, 气象信息需要尽可能满足数据的完整性和实时性。在“分钟级”时间尺度下, 运动型云团的云状及局部特征通常变化较小。根据预测结果进一步分析云团对太阳光线遮挡影响从而最终实现辐照度或光伏功率的精细化预测^[12]。目前基于云观测数据的光伏功率预测方法分为两种不同的技术路线, 分别是基于地基云图的功率预测路线与基于卫星云图的功率预测路线。文献[13]针对卫星云图提出了一种图像处理过程中的经验参数选择方法, 并建立了一种基于特征区域定位的短期光伏功率预测模型, 结果表明该模型表现出了较好的预测性能。文献[14]利用卷积神经网络(convolutional neural network, CNN)对卫星云图进行特征提取, 并将通过相关性分析后的 4 种气象特征进行融合, 作为光伏发电功率预测模型输入, 最后利用长短期记忆神经网络实现对光伏输出功率的时间序列预测。但由于卫星云图的数据特点, 其时间间隔较大, 导致光伏功率超短期预测精度较低。地基云图能够提供特定区域上空云层分布短时变化信息, 这在一定程度上补充了卫星图像在短期预测方面的不足^[15]。文献[16]使用基于 VGG16 的预训练模型对云图特征信息进行提取, 但 VGG16 模型在提取云图特征时所获取的有效信息较少, 因此模型的预测性能方面还有待提升。文献[17]利用云观测数据, 通过云层灰度分析技术来识别云图的关键特征, 并采用云点跟踪算法提取云团的位移和速度信息。在此基础上, 利用神经网络构建了一个能够适应多种场景的光伏功率预测模型, 以实现超短期预测。但该模型假设云团是线性运动的, 鉴于云团运动的随机性该算法无法实现较为精准的预测。文献[18]对地基云图中所涵盖的云特征分量进行挖掘并结合大气质量与图像亮度等影响因子作为输入变量来建立光伏功率预测模型, 实验结果表明计及地基云图信息的超短期预测模型效果明显优于无图像信息输入的模式。文献[19]以云观测数据为基础通过云层灰度鉴别技术筛选出云图关键特征信息, 并利用云点跟踪算法对云位移与云速度等云团运动信息进行提取, 最后利用神经网络建立了能够多场景切换的功率预测模型实现了光伏功率的超短期预测。文献[20]利用奇异光谱分析对历史辐照度和气象特征信息进行分解和重建, 最后搭建

双向长短期记忆神经网络模型进行预测。文献[21]提出了一种两阶段的分类预测框架对同期的光伏功率进行预测并对比了不同分类器的分类结果对预测结果的影响,但该模型没有考虑到云图相邻帧之间的关联性与云图中存在的差异性。

为解决上述无法获取准确云层状态信息的问题,本文提出了一种基于双流数据融合的光伏功率预测方法,为传统数值预测方案提供参考。为了获取相邻帧之间的时序特征对其开展了稠密光流计算,且针对传统单数据流模型,本文引入了一种并行输入的功率预测模型,在模型中同时提取原始云图的细节特征和光流图像的时序特征,更好地捕捉云层变化趋势获取云遮挡信息,进一步提升模型的预测精度。

1 稠密光流数据提取

本文首先利用稠密光流算法对图像进行特征提取工作。光流法能够计算出相邻像素间的运动信息,获取图像间所蕴含的时序特征^[22]。光流场中光流矢量分布存在差异,故为充分利用图像中的深层信息,实现对光伏功率的准确映射,本文采用 Gunnar Farneback 提出了稠密光流算法^[23]以提取相邻地基云图间云层运动信息。

使用稠密光流算法对云图进行光流特征提取,得到的光流结果如图 1 所示。经过光流特征提取后的图像尺寸为 64×64 ,两帧图像时间间隔为 1 min。相邻时间点的云图中,云团局部特征往往具有高度相似性。这种相似性为光伏功率预测模型提供了重

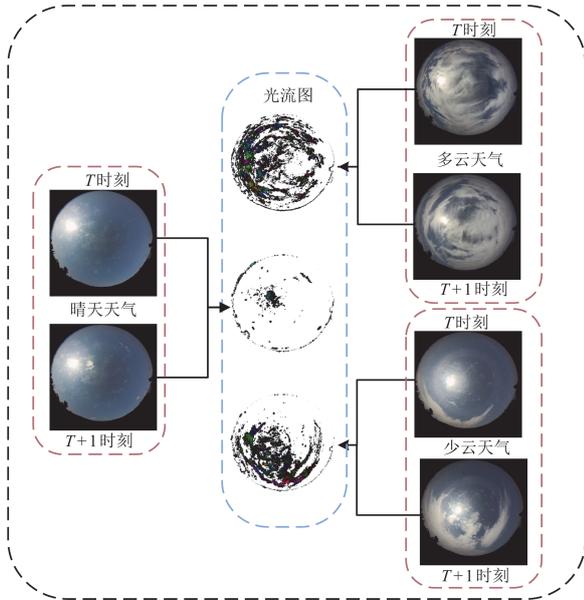


图 1 不同天气情况下光流图像对比

Fig. 1 Comparison of optical flow images under different weather conditions

要线索,尤其是在云层变化较为缓慢的情况下,通过对相邻时间段云图特征进行分析,可以更加精确地预测光伏发电功率输出。

Gunnar Farneback 稠密光流算法采用展开多项式对像素点进行建模,在局部坐标空间中,领域信号的二次多项式表达式如式(1)所示。

$$f(x) = x^T A x + b^T x + c \quad (1)$$

式中: x 为像素点所对应的坐标矩阵; A 为对称矩阵; b 、 c 分别为向量与标量。实际应用中多项式估计可由式(2)表示。

$$f_1(x) = x^T A_1 x + b_1^T x + c_1 \quad (2)$$

式中: A_1 为对称矩阵; b_1 为向量; c_1 为标量。

两幅相邻地基云图所经过的全局位移可以由平移向量 d 表示,其与两帧图像之间的关系如式(3)所示。

$$f_2(x) = f_1(x-d) = (x-d)^T A_1 (x-d) + b_1^T (x-d) + c_1 = x^T A_1 x + (b_1 - 2A_1 d)^T x + d^T A_1 d - b_1^T d + c_1 \quad (3)$$

另外,设 A_2 为对称矩阵; b_2 为向量; c_2 为标量;则令式(4)一式(6)等式成立。

$$A_2 = A_1 \quad (4)$$

$$b_2 = b_1 - 2A_1 d \quad (5)$$

$$c_2 = d^T A_1 d - b_1^T d + c_1 \quad (6)$$

正常情况下 A_1 为非零矩阵,根据式(4)、式(5)可以求出平移向量 d ,如式(7)、式(8)所示。

$$2A_1 d = -(b_2 - b_1) \quad (7)$$

$$d = -\frac{1}{2} A_1^{-1} (b_2 - b_1) \quad (8)$$

2 理论基础

由于云层变化的混沌特性,使得太阳辐照强度在云层变化时呈现出了强烈非线性变化趋势,影响电站对光伏出力功率预测的准确性,因此本文构建了一种基于多维数据融合的功率预测模型,以削弱云层运动对光伏功率预测准确率的影响。

2.1 卷积残差网络原理

CNN 的主要结构包括输入层、卷积层、池化层、全连接层和输出层。输入层读取数据后,卷积层通过稀疏连接和权值共享技术,对输入的多维特征网格数据进行卷积运算,最后通过池化层进行降维采样,使得网络在层数较少情况下也能拥有更强的信息提取与表达能力^[24]。

为缓解梯度消失等问题对模型性能的负面影响,文献[25-26]提出了残差网络结构。Resnet 在传统

深度神经网络中引入了一系列具有独特结构的残差模块, 缓解了梯度消失或爆炸问题并提升了模型特征表达能力, 残差块结构如图 2 所示^[27]。

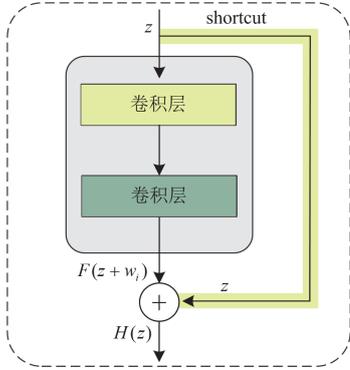


图 2 残差块结构示意图

Fig. 2 Schematic diagram of residual block structure

图 2 中: z 为模型的输入; $H(z)$ 为模型的输出; 输入端与输出端直接相连的通道被称为 shortcut 路径。假设不存在 shortcut 路径, 残差块由两部分卷

积块构成, 此时网络学习的是 $H(z)$ 与 z 的直接映射关系, $H(z)$ 为

$$H(z) = F(z + w_i) \quad (9)$$

但当 shortcut 存在, 此时 $H(z)$ 为

$$H(z) = F(z + w_i) + z \quad (10)$$

在大部分情况下残差并非恒等于零, 即输入与输出之间存在差异。shortcut 路径允许网络对残差部分进行学习, 缓解了随着网络堆叠产生的网络退化问题。本文利用具有较强特征提取能力的残差模块对双流输入图像数据进行处理, 以此充分挖掘图像与光伏功率输出之间的耦合特征。

2.2 SPD-Conv 理论

由于 CNN 采用的跨步卷积及池化层固有不足, 将导致地基云图中云层边缘部分特征与形状细节信息的丢失, 进而造成网络无法充分提取有效特征信息。本文引入了 SPD-Conv^[28] 模块以替代残差网络中的部分池化层, 进一步抑制细节信息的损失, 提升模型在针对小分辨率云图时的预测精度, SPD-Conv 的具体结构如图 3 所示。

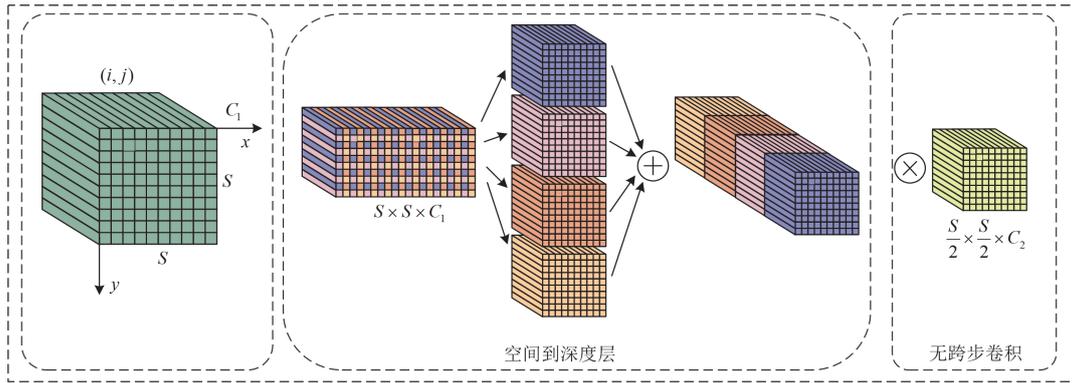


图 3 SPD-Conv 模块结构示意图

Fig. 3 Structure diagram of SPD-Conv module

SPD-Conv 由空间到深度(space-to-depth, SPD)层和非跨步卷积层组成。SPD 针对任何大小为 $S \times S \times C_1$ 的特征图 X 按照 k_{scale} 的比例因子进行下采样, 如式(11)所示。

$$\begin{cases} f_{0,0} = X[0:S:k_{\text{scale}}, 0:S:k_{\text{scale}}], \dots, \\ f_{k_{\text{scale}}-1,0} = X[k_{\text{scale}}-1:S:k_{\text{scale}}, 0:S:k_{\text{scale}}] \\ f_{0,1} = X[0:S:k_{\text{scale}}, 1:S:k_{\text{scale}}], \dots, \\ f_{k_{\text{scale}}-1,1} = X[k_{\text{scale}}-1:S:k_{\text{scale}}, 1:S:k_{\text{scale}}] \\ \vdots \\ f_{0,k_{\text{scale}}-1} = X[0:S:k_{\text{scale}}, k_{\text{scale}}-1:S:k_{\text{scale}}], \dots, \\ f_{k_{\text{scale}}-1,k_{\text{scale}}-1} = X[k_{\text{scale}}-1:S:k_{\text{scale}}, k_{\text{scale}}-1:S:k_{\text{scale}}] \end{cases} \quad (11)$$

式中: $f_{x,y}$ 为生成的子图; k_{scale} 为比例因子。

在图 3 中, 以比例因子 $k_{\text{scale}} = 2$ 为例, 每个子图的尺寸为 $S/2 \times S/2 \times C_1$, 将这 4 张子图在通道维度上进行拼接, 以获得新的大小为 $S/2 \times S/2 \times 2^2 C_1$ 的特征图 X' , 在无跨步卷积部分, SPD-Conv 模块使用了一个步长为 1 的卷积层, 将特征图 X' 的尺寸变为 $S/2 \times S/2 \times C_2$, 其中 $C_2 < 2^2 C_1$ 。

2.3 注意力机制理论

为提高功率预测模型的预测准确率, 本文在基于云图的功率预测模型中引入了卷积块注意力机制(convolutional block attention module, CBAM)^[29] 以提升模型对边缘细节信息的提取能力与云层轮廓结构信息的感知能力。CBAM 能够使模型专注于云层状

态特征的提取，并忽略图像中天空背景中存在的无关信息。

CBAM 的总体流程如式(12)所示。

$$\begin{cases} F' = M_c(F) \otimes F \\ F'' = M_s(F') \otimes F' \end{cases} \quad (12)$$

式中：“ \otimes ”表示逐元素乘法； F 表示中间特征图； F' 表示经过通道子模块后的输出； F'' 表示最终的特征信息； $M_c(F')$ 表示通道注意力； $M_s(F')$ 表示空间注意力。

CBAM 模块首先将特征图输入通道注意力模块以获得初步通道注意力图，然后对特征信息分别从空间与通道两个维度进行二次提取。因此，CBAM 能够提升预测模型在通道维度与空间维度上的信息学习能力，本文使用的 CBAM 结构如图 4 所示。

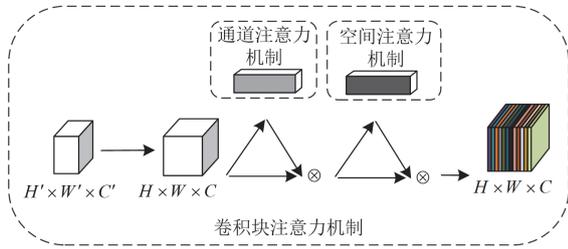


图 4 CBAM 特征提取流程

Fig. 4 CBAM feature extraction process

图 4 中的通道注意力模块与空间注意力的计算方法如式(13)、式(14)所示。

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) = \sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))) \quad (13)$$

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) = \sigma(f^{7 \times 7}([F_{\text{avg}}^s; F_{\text{max}}^s])) \quad (14)$$

式中： σ 表示 sigmoid 函数；MLP 表示多层感知机； $\text{AvgPool}(F)$ 、 $\text{MaxPool}(F)$ 分别表示对输入特征 F 进行平均池化、最大池化操作； W_0 、 W_1 表示多层感知机网络的权重系数； $f^{7 \times 7}$ 表示卷积中的 7×7 过滤器； F_{avg}^c 、 F_{max}^c 分别表示通道注意力模块全局平均池化特征、最大池化特征； F_{avg}^s 、 F_{max}^s 分别表示空间注意力模块特征经过平均池化、最大池化操作后的特征图。

3 基于 SPD-Conv 与 CNN-Attention 的双流融合预测模型

传统预测模型针对的是单输入图像处理任务，但本文为了考虑图像帧间的差异性将生成的光流图

也作为模型输入的一部分，在原模型基础上将其改进为双端口输入的功率预测模型，以便将两种不同数据输入各自分支后进行特征同步提取，并将提取出的信息转化为具有相同维度的特征序列以便后续的图像融合操作。

模型在特征提取部分进行了分支的扩展以便将大小为 $H_{\text{flow}} \times W_{\text{flow}} \times C_{\text{flow}}$ 的光流数据 X_{flow} 与大小为 $H_{\text{flow}} \times W_{\text{flow}} \times C_{\text{flow}}$ 的地基云图数据 X_{cloud} 同时输入模型，保证数据处理的一致性与同步性。首先，在特征提取部分中对双流输入数据进行特征的初步提取。其次，将 CBAM 施加于初始特征以促进对重要特征信息的专注力。然后，使用 SPD-Conv 模块取代了模型中部分池化层的降维操作，处理后的特征经过残差网络来进行深度特征信息的二次收集。最后，将模型在两条分支上所获取的多维特征进行拼接，依次经过全连接层与输出层输出最终预测结果。本文提出的双流融合预测模型整体结构如图 5 所示。

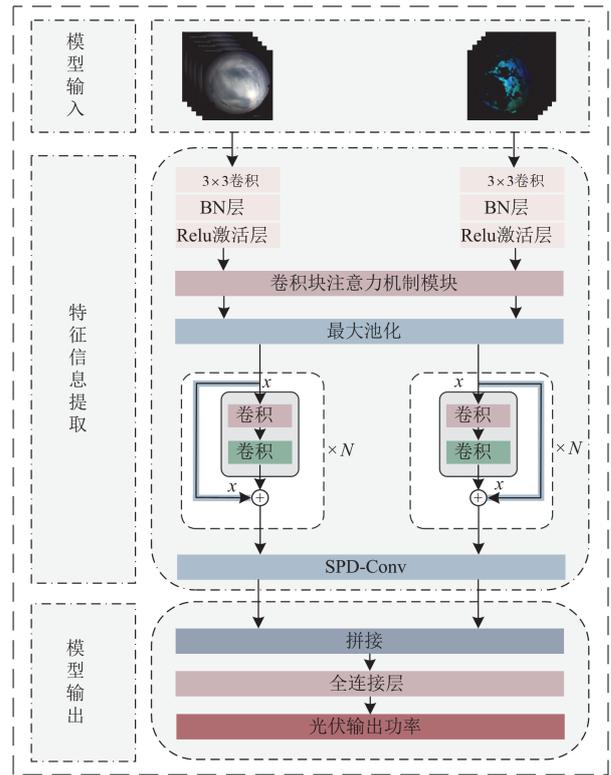


图 5 基于 SPD-ResNet-Attention 的光伏功率预测模型

Fig. 5 PV power prediction model based on SPD-ResNet-attention

本文为超短期间接预测方法，利用云图预测算法获取地基云图建立挖掘图像与光伏功率间潜在关系的回归任务，利用下一时刻未来地基云图进行间接预测光伏功率，具体流程如图 6 所示。

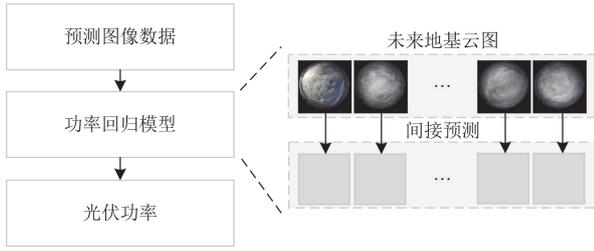


图 6 光伏功率预测流程图

Fig. 6 Flowchart of PV power prediction

4 算例分析

4.1 训练策略与优化方法

4.1.1 优化函数

自适应矩估计(adaptive moment estimation, Adam)优化函数是通过计算梯度的一阶矩估计和二阶矩估计, 实现对不同参数设置下模型学习率的自适应调整, 提升模型的收敛性能与预测性能。因此本文实验利用 Adam 训练策略对模型训练进行优化。

4.1.2 早停策略

在 Adam 优化器训练过程中, 模型的预测误差会随迭代次数的增加而逐渐下降, 过早的停止训练会使模型未达到收敛从而导致预测精度较低, 训练时间过长会导致模型的过拟合也将导致模型预测精度较低。早停训练策略能够在预测误差最小时及时保存模型的参数与权重, 提升模型的预测性能。训练策略设置的最大 Epochs 为 200 次, 当验证集的 MSE 评价指标在 5 个训练周期没有降低则提前终止训练, 早停算法流程图如图 7 所示。图中: i 为迭代次数; j 为验证集评价指标不下降次数; w 与 w^* 分别为更新前后模型参数; m 与 m^* 分别为更新前后验证集评价指标。

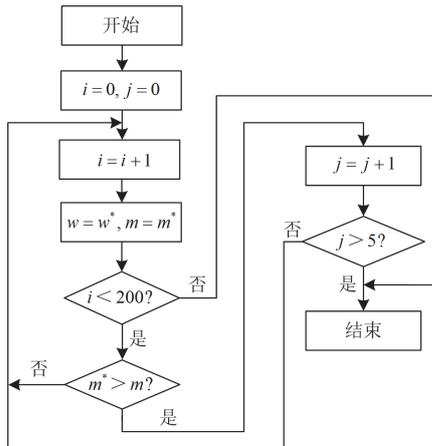


图 7 早停优化策略示意图

Fig. 7 Schematic diagram of the early stopping optimization strategy

4.2 实验平台及数据集介绍

本实验在 Tensorflow 配置环境下开展, 实验设备采用处理器 Intel(R) Xeon(R) Gold 6330 CPU @ 2.00 GHz, 安装内存为 80 GB, GPU 型号为 RTX 3090(24 GB)。

在数据集方面, 本文基于数据集 SKIPP'D 进行实验分析^[30]。该数据由斯坦福大学环境评估与优化小组收集和编制。科研人员利用架设的鱼眼全景摄像机对云团状态进行捕获, 该摄像机具有 600 万像素的全自动、全彩色成像系统, 能够实现以每秒 20 帧的频率进行视频拍摄, 使用的地基云图数据是以 1 min 的采样频率从视频中进行提取的, 其初始分辨率大小为 2048×2048, 由于数据采集时摄像头可能出现断电等情况, 造成部分数据丢失及图像与功率无法一一对应的情况。为了解决该问题, 本文首先对数据进行了初步筛选, 剔除部分成像异常的数据; 其次, 通过遍历操作读取了约 7 万个时间节点的图像数据与光伏功率数据; 然后, 将对应同一时刻的图像与光伏功率数据进行打包封装; 随后, 在不同季节, 选取相同天数下的晴天和云遮挡数据以确保数据分布大体一致。最后, 随机挑选了一年中包含春、夏、秋和冬季的晴天天气数据与云遮挡天气数据各 15 天的数据, 共计约 1.5 万个时间节点的图像数据与光伏功率数据作为模型测试集。数据集中的典型天气示意与训练集测试集分布如图 8 所示。

4.3 评价指标

本文采用平均绝对误差(mean absolute error, MAE)与均方根误差(root mean squared error, RMSE)两种评价指标对模型的性能进行定量评估, 较低的 MAE 与 RMSE 表示模型具有更好的性能, 其具体如式(15)、式(16)所示。

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |X_{Si} - X_{Yi}| \quad (15)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_{Si} - X_{Yi})^2} \quad (16)$$

式中: X_{Si} 、 X_{Yi} 分别为第 i 个采样点时光伏功率的实测值、预测值; n 为预测样本个数。

4.4 图像尺寸对比实验

为探究不同图像像素尺寸云图对模型预测准确性的影响, 本文考虑将 4 种不同尺寸云图作为模型的输入, 其大小分别为 16×16、32×32、48×48、64×64, 并为每种尺寸的图像进行独立的模型训练, 其结果如表 1 所示。

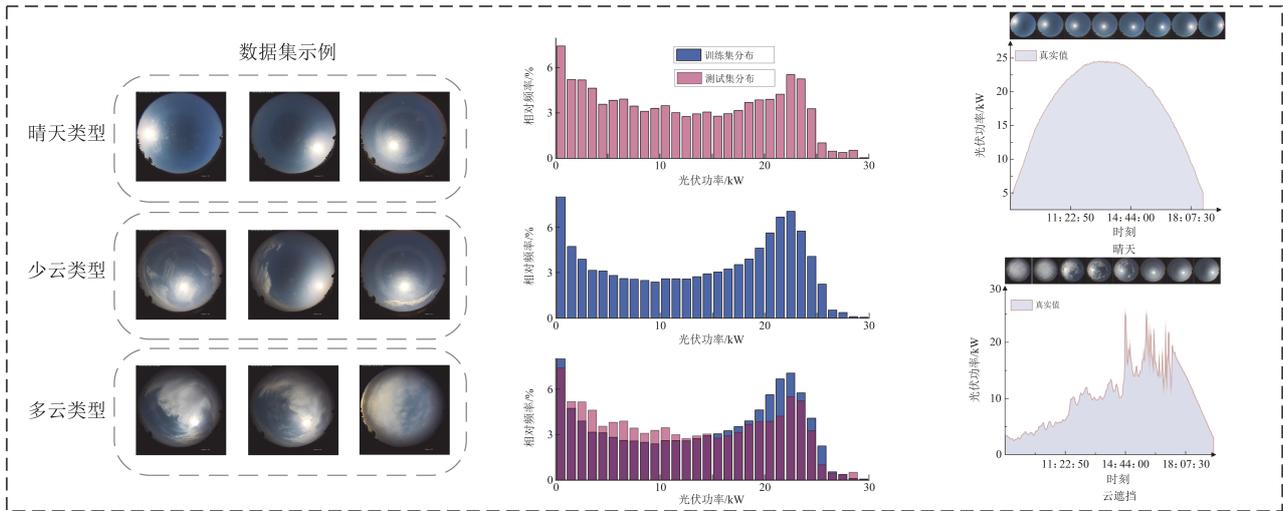


图 8 3种天气类型数据示例与数据集划分

Fig. 8 Three examples of weather types with dataset segmentation

表 1 不同尺寸数据对模型预测性能影响
Table 1 Impact of different sizes of data on model prediction performance

图像尺寸	RMSE/kW		MAE/kW		Epoch/s
	晴天	云遮挡	晴天	云遮挡	
16×16	1.235	4.551	0.846	3.420	7
32×32	1.217	4.307	0.843	3.165	9
48×48	1.177	4.189	0.789	3.130	15
64×64	1.116	4.173	0.747	3.128	38

从表 1 中能够得出，不同尺寸的图像作为输入时都能够使得模型预测的误差保持在较小的范围内，表明了云图与功率之间具有较强的相关性。同时当图像尺寸不断增加时，其 MAE 与 RMSE 不断减少，说明当图像蕴含着更多细节特征时，模型预测性能也会得到逐步增强。

当图像尺寸由 16×16 逐步提升至 64×64 时，MAE 在晴天与云遮挡情况下分别降低了 11.70% 和 8.54%；RMSE 在晴天与云遮挡情况下分别降低了 9.64% 和 8.34%。当数据维度达到 64×64 时，其无论在晴天与雨天情况下的预测性能都达到了最优。不同尺寸下超短期预测功率效果及预测曲线分别如表 2 和图 9 所示。

表 2 为少云情况下，10:20 至 10:40 光伏功率波动较为明显的时间段内不同图像尺寸的预测效果，结果表明使用 64×64 的图像预测效果更好，对比其他尺寸的图像 RMSE 分别降低了 38.28%、24.09% 和 23.51%，MAE 分别降低了 33.75%、24.51% 和 20.07%。结合表 2 与图 9 分析可知，在云团短暂遮挡引起光伏功率快速变化时，利用尺寸更大的图像可以更准

确地把握云团变化趋势，为预测提供更全面的信息，因此使用 64×64 维度云图情况下，光伏功率的预测值在波动较大的区域与实际值最为吻合。

表 2 波动较大处不同图像尺寸对预测效果的影响
Table 2 Impact of different image sizes on prediction performance in highly volatile regions

图像尺寸/px	16×16	32×32	48×48	64×64
RMSE/kW	4.049	3.292	3.267	2.499
MAE/kW	3.348	2.938	2.775	2.218
Epoch/s	7	9	15	38

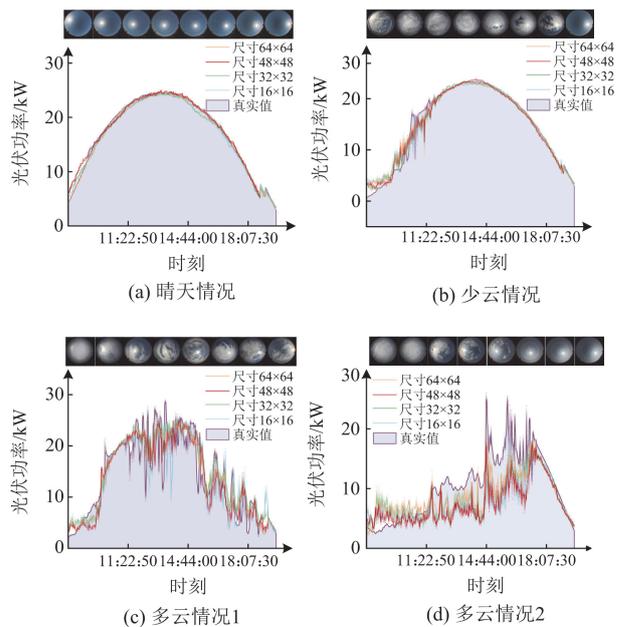


图 9 不同尺寸下预测功率曲线图

Fig. 9 Predictive power curve graphs with different image sizes

此外, 随着图像数据量的增加, 其运算消耗时快速增长。当图像尺寸由 16×16 逐步提升至 64×64 时, 其训练每个 Epoch 消耗的时间分别为 7 s、9 s、15 s 和 38 s。通过对比维度为 16×16 与 64×64 大小云图的预测结果可知, 其训练时间增加了大约 443% (由 7 s 增加至 38 s)。若继续增大维度, 则将导致训练时间增加, 不利于后续预测的及时性, 故本次实验选择尺寸为 64×64 地基云图作为该模型输入。

4.5 SPD-Conv 模块和双流残差对预测性能的影响

为了探究 SPD 模块对模型预测性能的影响, 本文设计了不同模型进行算例验证, 包括 LSTM 模型、多维 CNN 模型、单流残差模型-NS、单流残差模型、单流残差模型-SPD 模块和双流残差模型-SPD 模块等 6 类模型, 实验结果如表 3 所示。

表 3 SPD-Conv 模块对模型预测性能的影响

Table 3 Impact of SPD-Conv module on model prediction performance

预测模型类型	RMSE/kW		MAE/kW	
	晴天	云遮挡	晴天	云遮挡
LSTM 模型	1.416	4.464	1.053	3.215
多维 CNN 模型	1.070	4.184	0.827	3.135
单流残差模型-NS(结构 1)	1.116	4.173	0.747	3.128
单流残差模型(结构 2)	1.089	4.148	0.741	3.084
单流残差模型-SPD 模块(结构 3)	1.082	4.078	0.750	3.052
双流残差模型-SPD 模块(结构 4)	0.992	4.078	0.683	2.995

从整体实验结果而言, 在多云天气情况下, 由于云层细节信息的增加, 提升了预测难度, 相较于晴天情况, 在多云情况下其误差相对较高。在与不同类型的模型对比中, 使用 SPD 模块的模型在晴天和多云情况下光伏功率预测效果更优; LSTM 在处理图像时没有考虑像素间的空间结构, 只通过将每个像素线性化成序列来进行处理, 无法充分捕捉图像的空间结构; 而 CNN 模型面对复杂的时空动态变化, 缺乏足够的建模能力。为了充分说明引入 SPD 模块和双流残差模型的优越性, 本文将重点阐述上述改进对预测性能的影响。本文在实验设计中引入了文献[28]计算卫星云图地面状态信息的相关算法, 将其拓展到了地基云图中对天空状态信息的计算。对比表 3 中未考虑天空状态信息的结构 1 与考虑了天空状态信息的结构 2 可得, 经过处理后无论是晴天还是在云遮挡情况下, 多种评价指标都得到了提升。对比表 3 中结构 2、结构 3 与结构 4 模型的实验结果可得, 当 SPD 模块加入到单流残差网络时其在云遮挡情况下的预测性能得到了提升, 其 RMSE 与 MAE 分别降低了 1.72% 与 1.04%; 但在晴天情况下 SPD 模块对性能提升不显著, 分析其原因可能是由于 SPD 模块的加入使得在特征提取过程

中有效保留了部分云团的细节信息。在晴天和云遮挡情况下 RMSE 与 MAE 分别降低了 2.42%、0.60%、0.80% 和 1.41%。

当光流图像数据加入模型训练时, 模型在两种天气情况下性能都得到明显提升, 具体如图 10 所示。其在晴天天气下的 RMSE 与 MAE 分别降低了 8.32% 与 8.93%, 在云遮挡情况下其 MAE 降低了 1.87%。分析其原因可知, 光流图像包含了地基云图数据间的云团运动信息, 云团运动信息与细节信息融合提升了模型在不同天气情况下的预测性能, 且实验显示在晴天天气下提升效果更加显著。

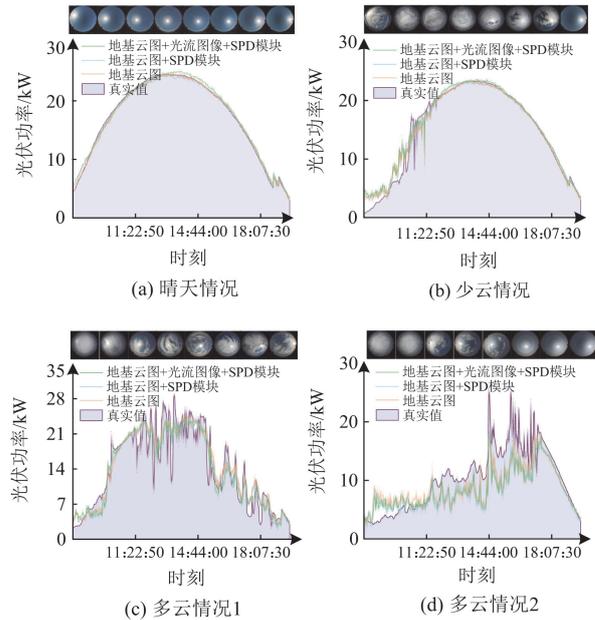


图 10 SPD 模块与光流数据对预测性能的影响

Fig. 10 Impact of SPD module and optical flow data on prediction performance

4.6 不同注意力算法对模型预测性能的影响

地基云图数据中特征信息的重要程度不同, 主要集中在中间成像区域内, 为解决本文深度学习预测模型在特征提取与学习时可能发生的注意力分散与转移的问题, 本节探讨了 3 种先进的注意力机制, 包括挤压激励注意力机制 (squeeze-and-excitation, SE)、高效通道注意力机制 (efficient channel attention, ECA) 及 CBAM 对模型预测性能的影响。

当 3 种不同的注意力机制分别加入时, 模型的预测性能都有不同程度的提升, 其实验结果如表 4 所示。

相较于 ECA 注意力机制, SE 注意力机制对模型不同天气情况下的预测效果提升不显著, 表明该注意力机制不适用在本文所提出的特定预测模型结构中。但相较于 SE 注意力机制, ECA 注意力机制的加入使模型预测性能有了进一步提升, 对比表

4 中未加入注意机制的结构 4 模型, 其晴天与云遮挡情况下 RMSE 与 MAE 分别降低了 2.02%、0%、0.49%和 0.97%。实验结果表明其在晴天条件下的 MAE 与未加入注意力机制前的指标相同, 模型预测性能提升相对不显著。不同天气下基于不同注意力机制的模型预测性能结果如图 11 所示。

表 4 不同注意力机制对模型预测性能的影响

Table 4 Impact of different attention mechanisms on model prediction performance

注意力机制类型	RMSE/kW		MAE/kW	
	晴天	云遮挡	晴天	云遮挡
双流残差-SPD	0.992	4.078	0.683	2.995
双流残差-SPD-SE	0.989	4.057	0.686	2.993
双流残差-SPD-ECA	0.972	4.058	0.683	2.966
双流残差-SPD-CBAM	0.943	4.004	0.660	2.967

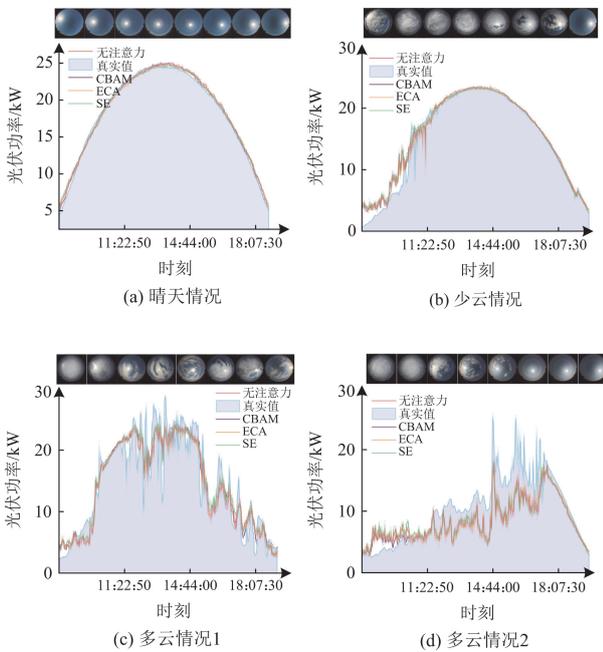


图 11 不同天气情况下各注意力机制的模型预测结果

Fig. 11 Prediction results of models with different attention mechanism under various weather conditions

但 CBAM 较好地弥补了上述缺点, 其在晴天与云遮挡情况下 RMSE 与 MAE 分别降低了 4.94%、1.81%、3.37%和 0.93%。与最初模型相比, RMSE 与 MAE 分别降低了 15.50%、4.05%、11.65%和 5.15%, CBAM 模块的加入使模型的注意力尽可能集中在关键区域, 既能保持双流模型在云遮挡天气下的预测优势, 又能较为准确地实现预测功能。

5 结论

针对当前基于地基云图的功率预测模型中存

在的精度低等问题, 本文提出了基于双流数据融合的光伏功率预测算法, 得出如下结论。

1) 针对传统单流映射模型在处理不同天气条件时难以全面提取数据中包含的云层轮廓和运动信息的问题, 提出了融合光流数据的双流映射模型。该方法结合地基云图在获取云层边缘细节特征上的优势以及光流数据在反映云层运动特征上的优势, 解决了传统预测模型云层信息特征提取不足的问题, 提高了预测模型对地基云图数据的敏感度。

2) 针对多数预测模型中各种池化层对小尺寸、小目标数据进行特征提取时性能下降的问题, 引入 SPD 网络以替代池化模块并对单流与双流网络分组进行实验, 实验结果表明引入 SPD 网络能有效提升单流与双流输入情况下的模型预测性能。

3) 为了增强模型运行时对重要特征区域的专注能力, 本文对比了 3 种先进的注意力机制, 分析了其对模型预测性能的影响, 实验结果表明本文所使用的 CBAM 能够有效保持模型对重要信息的专注度, 提升模型预测准确性。

本文提出的基于 SPD-Resnet-Attention 的双流融合预测算法为云图-功率预测场景提供了一种解决方案。但从实际角度出发, 本文模型在多云天气情况下的预测性能还相对较弱, 在少数情况下无法完全预测云层薄厚对光伏功率输出带来的影响; 实验数据仅局限于一个年度内, 但由于不同年份气候差异变化无明显规律, 本实验无法完全规避年度间的气象差异性。后续本文将基于现有工作对不同云层状态进行精细化分类, 并尝试收集更多年度数据对模型展开训练, 从而提升模型预测精度。

参考文献

- [1] 史加荣, 殷昭. 基于 GRU-BLS 的超短期光伏发电功率预测[J]. 智慧电力, 2023, 51(9): 38-45.
- [2] SHI Jiarong, YIN Zhao. Prediction of ultra short term photovoltaic power generation based on GRU-BLS[J]. Smart Power, 2023, 51(9): 38-45.
- [3] 国家能源局[EB/OL]. [2024-01-26]. <https://www.nea.gov.cn>.
- [4] 赖昌伟, 黎静华, 陈博, 等. 光伏发电出力预测技术研究综述[J]. 电工技术学报, 2019, 34(6): 1201-1217.
- [5] LAI Changwei, LI Jinghua, CHEN Bo, et al. Review of photovoltaic power output prediction technology[J]. Transactions of China Electrotechnical Society, 2019, 34(6): 1201-1217.
- [6] 商立群, 李洪波, 侯亚东, 等. 基于 VMD-ISSA-KELM 的短期光伏发电功率预测[J]. 电力系统保护与控制, 2022, 50(21): 138-148.

- SHANG Liqun, LI Hongbo, HOU Yadong, et al. Short-term photovoltaic power generation prediction based on VMD-ISSA-KELM[J]. *Power System Protection and Control*, 2022, 50(21): 138-148.
- [5] 王玉庆, 徐飞, 刘志坚, 等. 基于动态关联表征与图网络建模的分布式光伏超短期功率预测[J]. *电力系统自动化*, 2023, 47(20): 72-82.
- WANG Yuqing, XU Fei, LIU Zhijian, et al. Ultra-short-term power forecasting of distributed photovoltaic based on dynamic correlation characterization and graph network modeling[J]. *Automation of Electric Power Systems*, 2023, 47(20): 72-82.
- [6] DIAGNE M, DAVID M, LAURET P, et al. Review of solar irradiance forecasting methods and a proposition for small-scale insular grids[J]. *Renewable and Sustainable Energy Reviews*, 2013, 27: 65-76.
- [7] 丁明, 刘志, 毕锐, 等. 基于灰色系统校正-小波神经网络的光伏功率预测[J]. *电网技术*, 2015, 39(9): 2438-2443.
- DING Ming, LIU Zhi, BI Rui, et al. Photovoltaic power prediction based on gray system correction-wavelet neural network[J]. *Power System Technology*, 2015, 39(9): 2438-2443.
- [8] 热依娜·马合苏提, 周玮, 彭飞翔, 等. 考虑端对端交易与预测误差的配电网实时能量平衡策略[J]. *电力系统保护与控制*, 2023, 51(23): 1-15.
- REYINA·Mahesuti, ZHOU Wei, PENG Feixiang, et al. Real-time energy balancing strategy for distribution networks considering peer-to-peer trading and prediction errors[J]. *Power System Protection and Control*, 2023, 51(23): 1-15.
- [9] 黄泽, 毕贵红, 谢旭, 等. 基于 MBI-PBI-ResNet 的超短期光伏功率预测[J]. *电力系统保护与控制*, 2024, 52(2): 165-176.
- HUANG Ze, BI Guihong, XIE Xu, et al. Ultra-short-term PV power prediction based on MBI-PBI-ResNet[J]. *Power System Protection and Control*, 2024, 52(2): 165-176.
- [10] 雷柯松, 吐松江·卡日, 伊力哈木·亚尔买买提, 等. 基于 WGAN-GP 和 CNN-LSTM-Attention 的短期光伏功率预测[J]. *电力系统保护与控制*, 2023, 51(9): 108-118.
- LEI Kesong, KARI·Tusongjiang, YAERMAIMAITI·Yilihamu, et al. Prediction of short-term photovoltaic power based on WGAN-GP and CNN-LSTM-Attention[J]. *Power System Protection and Control*, 2023, 51(9): 108-118.
- [11] 张青山, 王丽婕, 郝颖, 等. 基于卫星云图和晴空模型的分布式光伏电站太阳辐照度超短期预测[J]. *高电压技术*, 2022, 48(8): 3271-3281.
- ZHANG Qingshan, WANG Lijie, HAO Ying, et al. Ultra-short-term solar irradiance prediction of distributed photovoltaic power stations based on satellite cloud images and clear sky model[J]. *High Voltage Engineering*, 2022, 48(8): 3271-3281.
- [12] 余光正, 陆柳, 汤波, 等. 基于云图特征提取的改进混合神经网络超短期光伏功率预测方法[J]. *中国电机工程学报*, 2021, 41(20): 6989-7003.
- YU Guangzheng, LU Liu, TANG Bo, et al. An improved hybrid neural network ultra-short-term photovoltaic power forecasting method based on cloud image feature extraction[J]. *Proceedings of the CSEE*, 2021, 41(20): 6989-7003.
- [13] 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.
- [14] 叶畅, 柳丹, 曹侃. 基于云图特征的超短期光伏发电功率预测模型[J]. *电网与清洁能源*, 2023, 39(10): 70-79.
- YE Chang, LIU Dan, CAO Kan. An ultra-short-term photovoltaic power forecasting model based on cloud features[J]. *Power System and Clean Energy*, 2023, 39(10): 70-79.
- [15] 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.
- [16] CRISOSTO C, LUIZ E W, SECKMEYER G, et al. Convolutional neural network for high-resolution cloud motion prediction from hemispheric sky images[J]. *Energies*, 2021, 14(3).
- [17] 陈志宝, 李秋水, 程序, 等. 基于地基云图的光伏功率超短期预测模型[J]. *电力系统自动化*, 2013, 37(19): 20-25.
- CHEN Zhibao, LI Qiushui, CHENG Xu, et al. A very short-term prediction model for photovoltaic power based on ground-based cloud images[J]. *Automation of Electric Power Systems*, 2013, 37(19): 20-25.
- [18] 陈志宝, 丁杰, 周海, 等. 地基云图结合径向基函数人工神经网络的光伏功率超短期预测模型[J]. *中国电机工程学报*, 2015, 35(3): 561-567.
- CHEN Zhibao, DING Jie, ZHOU Hai, et al. A model of very short-term photovoltaic power forecasting based on

- ground-based cloud images and RBF neural network[J]. Proceedings of the CSEE, 2015, 35(3): 561-567.
- [19] 柴闵康, 夏飞, 张浩, 等. 基于云图特征自识别的光伏超短期预测模型[J]. 电网技术, 2021, 45(3): 1023-1035. CHAI Minkang, XIA Fei, ZHANG Hao, et al. Ultra-short-term prediction of self-identifying photovoltaic based on sky cloud chart[J]. Power System Technology, 2021, 45(3): 1023-1035.
- [20] XIE Qiyue, MA Lin, LIU Yao, et al. An improved SSA-BiLSTM-based short-term irradiance prediction model via sky images feature extraction[J]. Renewable Energy, 2023, 219.
- [21] NIE Y, SUN Y, CHEN Y, et al. PV power output prediction from sky images using convolutional neural network: the comparison of sky-condition-specific sub-models and an end-to-end model[J]. Renewable Sustainable Energy, 2020, 12(4).
- [22] 杨子龙, 朱付平, 田金文, 等. 基于显著性与稠密光流的红外船只烟幕检测方法研究[J]. 红外与激光工程, 2021, 50(7): 116-123. YANG Zilong, ZHU Fuping, TIAN Jinwen, et al. Ship smoke detection method based on saliency and dense optical flow[J]. Infrared and Laser Engineering, 2021, 50(7): 116-123.
- [23] FARNEBACK G. Two-frame motion estimation based on polynomial expansion[C]//Scandinavian Conference on Image Analysis, June 29-July 2, 2003, London, USA: 363-370.
- [24] ZHANG H, YI Z, KANG L, et al. a novel supercapacitor degradation prediction using a 1D convolutional neural network and improved informer model[J]. Protection and Control of Modern Power Systems, 2024, 9(4): 51-68.
- [25] 张淑清, 杜灵韵, 王册浩, 等. 基于格拉姆角场与改进 CNN-ResNet 的风电功率预测方法[J]. 电网技术, 2023, 47(4): 1540-1548. ZHANG Shuqing, DU Lingyun, WANG Cehao, et al. Wind power forecasting method based on GAF and improved CNN-ResNet[J]. Power System Technology, 2023, 47(4): 1540-1548.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016, Piscataway, NJ, USA: 770-778.
- [27] 王琛, 王颖, 郑涛, 等. 基于 ResNet-LSTM 网络和注意力机制的综合能源系统多元负荷预测[J]. 电工技术学报, 2022, 37(7): 1789-1799. WANG Chen, WANG Ying, ZHENG Tao, et al. Multi-energy load forecasting in integrated energy system based on ResNet-LSTM network and attention mechanism[J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1789-1799.
- [28] SI Z, YU Y, YANG M, et al. Hybrid solar forecasting method using satellite visible images and modified convolutional neural networks. IEEE Transactions on Industry Applications, 2020, 57(1): 5-16.
- [29] WANG Y, GU J, YUAN L. Distribution network state estimation based on attention-enhanced recurrent neural network pseudo-measurement modeling[J]. Protection and Control of Modern Power Systems, 2023, 8(2): 1-16.
- [30] NIE Y, LI X, SCOTT A, et al. SKIPP'D: a sky images and photovoltaic power generation dataset for short-term solar forecasting[J]. Solar Energy, 2023, 255: 171-179.

收稿日期: 2024-09-09; 修回日期: 2025-01-15

作者简介:

吐松江·卡日(1984—), 男, 博士, 教授, 研究方向为电力系统数字化、人工智能与模式识别等; E-mail: tsj@xju.edu.cn

吴 现(1998—), 男, 硕士研究生, 研究方向为新能源发电与预测; E-mail: wux3579@126.com

马小晶(1983—), 女, 通信作者, 博士, 教授, 研究方向为新能源发电与预测、人工智能与模式识别等。E-mail: minyun229@163.com

(编辑 石晋美)