

DOI:10.19651/j.cnki.emt.2417544

基于双流特征增强网络的超短期光伏功率预测^{*}辛峰悦¹ 寇志伟^{1,2} 刘焱晨¹ 崔啸鸣^{1,2} 齐咏生^{1,2}

(1. 内蒙古工业大学电力学院 呼和浩特 010080; 2. 大规模储能技术教育部工程研究中心 呼和浩特 010080)

摘要: 云层的遮挡会导致光伏功率发生剧烈波动,给电力系统的稳定运行带来巨大的挑战。本研究针对云层遮挡时光伏功率波动大、复杂天气条件下预测精度低等问题,提出了一种基于双流特征增强网络的超短期光伏功率预测模型(TSFE-LSTM)。首先,基于畸变校正算法和光流计算优化处理了地基云图,通过双流卷积网络提取了地基云图序列的时空特征。其次,设计了基于长短期记忆网络的超短期光伏功率预测模型,实现了未来15 min光伏功率的预测。实验结果表明,TSFE-LSTM模型融合地基云图与光流图后,光伏功率预测值的MAE、RMSE较单独输入地基云图分别提高了5.81%、4.61%。在晴天时,TSFE-LSTM模型较CNN模型MAE、RMSE分别提高了7.23%、14.99%,阴天时,TSFE-LSTM模型预测精度略有下降,较CNN-MLP模型MAE、RMSE分别提高了3.53%、1.26%。为云层遮挡时光伏功率预测提供了新思路。

关键词: 地基云图;特征提取;长短期记忆网络;光伏功率预测

中图分类号: TM615;TN06 **文献标识码:** A **国家标准学科分类代码:** 470.4047

Ultra-short-term photovoltaic power prediction based on two-stream feature enhancement network

Xin Fengyue¹ Kou Zhiwei^{1,2} Liu Yanchen¹ Cui Xiaoming^{1,2} Qi Yongsheng^{1,2}

(1. College of Electric Power, Inner Mongolia University of Technology, Hohhot 010080, China; 2. Engineering Research Center of Large Energy Storage Technology, Ministry of Education, Hohhot 010080, China)

Abstract: Cloud cover can cause dramatic fluctuations in photovoltaic (PV) power, which poses a great challenge to the stable operation of the power system. In order to address the problems of large fluctuation of PV power with cloud cover and low accuracy under highly complex weather conditions, we propose an ultra-short-term PV power prediction model based on two-stream feature enhancement network (TSFE-LSTM). Firstly, the ground-based cloud images are processed by fish-eye image correction algorithm and optical flow estimation algorithm, and the spatiotemporal feature of the ground-based cloud image is extracted by the two-stream convolutional network. Secondly, an ultra-short-term PV power prediction model based on two-stream feature enhancement network is built to predict the PV power in the next 15 min. The results of the experiment show that the MAE and RMSE of the TSFE-LSTM model for PV power prediction in the next 15 min are 6.49% and 10.76% with the input of ground-based cloud image and optical flow, respectively, which are improved by 5.81% and 4.61%, respectively, compared with the single input data. In sunny conditions, the MAE and RMSE of TSFE-LSTM model improved 7.23% and 14.99% than the CNN model, respectively. In cloudy conditions, the accuracy of the model is slightly decreased, but the MAE and RMSE are improved by 3.53% and 1.26%, respectively, compared with the CNN-MLP model. This provides new ideas for PV power prediction with cloud cover.

Keywords: ground-based cloud image; feature extraction; long short-term memory; photovoltaic power prediction

0 引言

近年来,我国在“双碳”战略的指引下,可再生能源实现

跨越式发展,其中尤以光伏发电增长势头迅猛^[1-2]。光伏功率受太阳辐射、云量、气溶胶厚度、湿度等各类因素的影响较大,具有较强的间歇性和波动性^[3],这些特性使得大规模

收稿日期:2024-12-04

^{*} 基金项目:国家自然科学基金(62363029)、内蒙古科技计划项目(2020GG0283,2021GG0256)资助

光伏发电接入电网后会给电网的运行和调度造成巨大的冲击与挑战。因此,需要准确的光伏功率预测来减少光伏发电的不确定性对电力系统稳定运行的影响。

光伏发电系统受云层遮挡影响巨大,一旦照射到光伏电站内的太阳辐射受到云层遮挡,光伏功率将产生分钟级的剧烈波动^[4],且几乎与历史光伏功率无相关性。地基云图数据能确切地描述云层在短时间内的运动变化,在超短期光伏功率预测任务中得到广泛应用^[5-6]。

传统的基于地基云图的光伏功率预测研究通常利用数字图像处理技术手工提取云图特征,并在此基础上进行光伏功率预测^[7]。余光正等^[8]手工提取地基云图中的特征点并进行匹配,实现云轨迹跟踪和辐照系数计算,将辐照系数作为数据输入 IAM-CNN-LSTM 模型进行超短期光伏功率预测,通过误差修正达到更高的预测精度。柴闵康等^[9]将利用云层灰度鉴别算法和云点跟踪算法手工提取的云图特征作为模型输入,通过由晴空辐照度作为标准的 CEM-LSTM 切换模型实现了在全气候条件下高精度、高稳定性的光伏功率预测。仝勐峰等^[10]利用阈值分割、随机森林算法和模板匹配等手工设计方法提取云团的多维特征,并通过 stacking 方法融合多种机器学习模型预测太阳直接辐射。这些方法通过手工特征提取方法实现了直观的地基云图序列的特征提取,但是,这种方法特征提取过程复杂,且高度依赖先验知识,不能实现端到端的光伏功率预测,难以在实际中应用。随着深度学习在计算机视觉领域的发展,基于深度学习的直接预测模型逐渐开始在基于地基云图的光伏功率预测研究中得到广泛应用^[11]。Chai 等^[12]针对传统手工特征提取方法输入云图长度和线性外推能力有限的问题,提出了基于卷积自编码的地基云图预测模型,可以输入两张以上的地基云图,学习更加丰富的时空信息,进而提高模型的预测性能,实验结果表明基于卷积自编码的方法比基于数字图像处理技术的方法效果更佳。Zhang 等^[13]将 Vision Transformer 应用在云图特征提取中,进而融合数值数据来预测太阳辐射,通过对比分析验证了基于 Transformer 的预测方法在太阳辐射预测领域的可行性和单张图像在较长时间的预测任务中的局限性。Wen 等^[14]提出了一种基于卷积神经网络的太阳辐照度多步预测方法,将 3 张地基云图的 R 通道堆叠,通过卷积神经网络 ResNet18 提取云图特征并预测太阳辐照度。总之,利用深度学习提取云图特征可以提高复杂天气下分钟级光伏功率预测精度。但是,过去的研究所使用的地基云图序列长度有限,对地基云图序列中运动信息的学习能力有限,难以有效充分地地基云图序列,进而影响超短期光伏功率预测精度。

地基云图的特征提取对复杂天气条件下超短期光伏功率精度影响较大。为了提高复杂条件下超短期光伏功率预测精度,本研究提出一种基于双流特征增强网络的超短期光伏功率预测模型(two stream feature enhanced long

short-term memory, TSFE-LSTM),通过双流特征增强网络提取地基云图序列的时空特征,进而提高超短期光伏功率预测精度。首先,利用鱼眼畸变校正算法处理地基云图并计算光流;然后,通过双流卷积网络提取地基云图序列的时空特征;最后,将时空特征和历史统计数据输入长短期记忆网络进行未来光伏功率预测。本研究在公开数据集上进行对比试验,实验结果验证了地基云图的时空特征在光伏功率预测任务中的重要性,证明了本研究所提模型的有效性。

1 地基云图预处理

1.1 鱼眼图像校正

地基云图是一种由鱼镜头采集的能够捕捉整个天空圆顶信息的图像数据。由于鱼镜头的结构特点,采集到的地基云图有一定的畸变,会影响目标测量与特征提取精度。为了能够减少由畸变带来的影响,本文通过图像校正算法对地基云图进行畸变校正。

目前,最常用的图像畸变校正方法有基于相机标定的校正方法和基于坐标投影的校正方法两种^[15]。经纬度校正算法因其无需借助外部设备标定而被广泛使用,在此基础上本文使用改进的经纬度鱼眼校正算法^[16]进行畸变校正,校正步骤如图 1 所示。

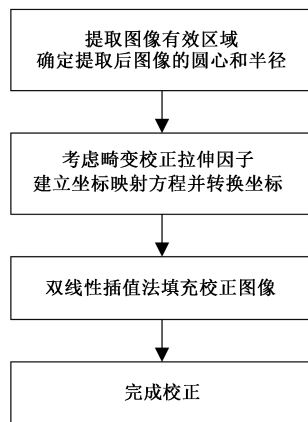


图 1 鱼眼图像校正算法步骤

Fig. 1 Fish-eye image correction algorithm steps

该算法引入了畸变校正拉伸因子,改善了校正图像在边缘部分的失真情况,计算复杂度低,运算速度快,校正效果明显。地基云图的校正效果如图 2 所示。

1.2 光流法

连续的地基云图包含了丰富的云层细节信息和云层随时间扩散的复杂运动信息。相对于云层细节而言,运动信息的获取更为困难。因此,本研究通过光流估计对地基云图进一步处理,使模型更容易学习到云层的运动信息。

光流是利用图像序列中相邻图像之间的相关性来确定每个像素点的位移信息,表示了空间运动物体在成像平面上投影的瞬时速度,通常用于视频相邻帧之间的运动估计。




图2 校正效果对比图

Fig. 2 Comparison of correction result

本文通过 Farneback 稠密光流算法^[17]计算相邻两张地基云图的光流。

利用二次多项式对地基云图进行近似建模,则上一帧地基云图可表示为:

$$f_1(\mathbf{x}) = \mathbf{x}^T \mathbf{A}_1 \mathbf{x} + \mathbf{b}_1^T \mathbf{x} + c_1 \quad (1)$$

式中: \mathbf{x} 为地基云图中像素点的二维坐标; \mathbf{A}_1 为对称矩阵; \mathbf{b}_1 为向量; c_1 为标量。

假设下一帧图像产生了位移 \mathbf{d} , 那么下一帧地基云图可表示为:

$$f_2(\mathbf{x}) = f_1(\mathbf{x} - \mathbf{d}) = (\mathbf{x} - \mathbf{d})^T \mathbf{A}_1 (\mathbf{x} - \mathbf{d}) + \mathbf{b}_1^T (\mathbf{x} - \mathbf{d}) + c_1 = \mathbf{x}^T \mathbf{A}_2 \mathbf{x} + \mathbf{b}_2^T \mathbf{x} + c_2 \quad (2)$$

则对应系数之间的关系为:

$$\begin{cases} \mathbf{A}_2 = \mathbf{A}_1 \\ \mathbf{b}_2 = \mathbf{b}_1 - 2\mathbf{A}_1 \mathbf{d} \\ c_2 = \mathbf{d}^T \mathbf{A}_1 \mathbf{d} - \mathbf{b}_1^T \mathbf{d} + c_1 \end{cases} \quad (3)$$

计算可得位移向量 \mathbf{d} 为:

$$\mathbf{d} = -\frac{1}{2} \mathbf{A}_1^{-1} (\mathbf{b}_2 - \mathbf{b}_1) \quad (4)$$

最后,将光流计算扩展到整个图像,得到前后两帧图像中每个像素点在水平方向和垂直方向上的光流值。为了更直观地可视化光流,将光流值转换到极坐标并映射到 HSV 颜色空间,最后转换到 RGB 颜色空间,即可得到如图 3 所示的光流图。在光流图中,色相表示像素运动方向,饱和度表示像素运动速度。




图3 光流可视化结果

Fig. 3 Visualization of optical flow

2 基于双流卷积网络的时空特征提取模块

2.1 双流卷积网络

连续的地基云图包含丰富的时空信息,和单张地基云图相比增加了时间维度,给特征提取增加了难度。

基于地基云图的光伏功率预测模型通常将地基云图进行简单的堆叠并使用卷积神经网络提取特征。但是,卷积神经网络提取到的特征并不能有效的表示物体的运动信息,受人类视觉通路假说启发,Simonyan 等^[18]提出了双流卷积网络。双流卷积网络通常被用来完成视频行为识别任务,网络输入单帧 RGB 图像和多帧光流,通过双流结构分别处理空间和时间信息,最后将时间流和空间流结果平均融合并输出分类结果,在控制复杂度的同时提高了准确率。考虑到地基云图序列和视频数据都具有时间、通道、高度和宽度 4 个维度,且同样涉及到图像中物体的运动信息,本文将视频行为识别任务中经典的双流网络创新性地应用在超短期光伏功率预测任务的时空特征提取模块中,并在此基础上,改进了双流卷积网络的融合部分,然后,通过改进的双流卷积网络提取了地基云图序列的时空特征。

该网络主要由两个分支组成:空间网络分支和时间网络分支,这两条分支分别在单张地基云图和由地基云图序列提取的堆叠光流图上进行训练,分别提取地基云图序列的空间特征和时间特征,最后,经过特征线性调制方法将提取到的时空特征进行融合,获得更有效的时空特征表示。网络的具体结构如图 4 所示。

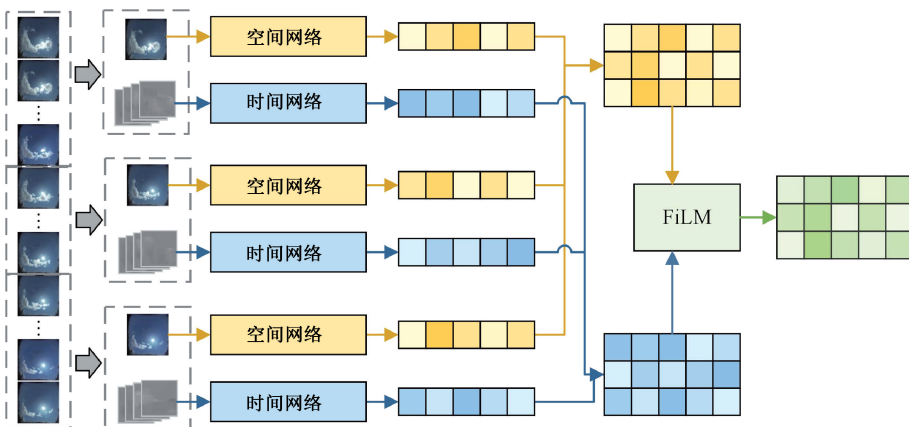


图4 图像特征提取模块

Fig. 4 Sky image feature extraction module

在双流卷积网络中,空间网络输入单张地基云图,将三维的图像序列处理任务转换为对二维图像的处理,可以充分利用现有的二维卷积神经网络的图像特征提取能力,学习地基云图中云层的分布信息。光流本身就包含了地基云图序列间的云层运动信息,将多张堆叠的光流图作为时间网络的输入在一定程度上可以降低卷积神经网络学习云层运动特征的难度,极大地降低网络的复杂程度,同时也可以提高光伏功率预测精度。

增加网络的深度可以帮助模型从地基云图中学习到更多的特征,但传统的深层神经网络会随着深度的增加而变得越来越难以训练。ResNet 是 2015 年由 He 等^[19]提出的一种卷积神经网络。ResNet 利用残差结构实现输入和输出间的跳跃连接,这种设计可以缓解网络深度增加而导致的梯度消失和模型退化问题。ResNet18 收敛速度快,计算复杂度低,在特征提取任务中得到广泛应用,本文选择两个独立的 ResNet18 分别作为空间网络和时间网络,其残差结构如图 5 所示。




图 5 ResNet18 残差结构

Fig. 5 Residual structure of ResNet18

传统的双流卷积网络仅从连续的视频帧中抽取一部分作为输入,不能对长时间序列信息进行有效建模,针对这一问题,Wang 等^[20]提出了 TSN 网络,采用分段采样的策略巧妙的实现了长时间序列建模。因此,为了提取长时间序列特征,本文采用了 TSN 网络分段采样的策略,将多张连续的地基云图分为 n 段,分别提取时间特征和空间特征并进行拼接融合。计算过程可以表示为:

$$\mathbf{F}_S = [f_S(\mathbf{I}_{S,1}); f_S(\mathbf{I}_{S,2}); \dots; f_S(\mathbf{I}_{S,n})] \quad (5)$$

$$\mathbf{F}_T = [f_T(\mathbf{I}_{T,1}); f_T(\mathbf{I}_{T,2}); \dots; f_T(\mathbf{I}_{T,n})] \quad (6)$$

式中: \mathbf{F}_S 表示云层的空间特征; \mathbf{F}_T 表示云层的时间特征; $f_S(\cdot)$ 为空间网络函数; $f_T(\cdot)$ 为时间网络函数; $\mathbf{I}_{S,i}$ 表示片段 i 的地基云图数据; $\mathbf{I}_{T,i}$ 表示片段 i 的光流数据; $[\cdot; \cdot]$ 表示拼接操作。

2.2 时空特征融合

传统的双流卷积网络通常使用两个卷积网络分别提取时间和空间特征,然后通过加权平均进行融合并得到最终结果。这种融合只是对时间特征和空间特征的简单集成,缺乏灵活性,不利于时空特征的表达。因此,本研究采用特征线性调制 (FiLM)^[21] 来融合时间特征和空间特征。FiLM 通过对时空特征进行特征仿射变换处理,可以实现

自适应特征融合。FiLM 可以表示为:

$$\text{FiLM}(\mathbf{F}_S, \mathbf{F}_T) = g(\mathbf{F}_S)\mathbf{F}_T + h(\mathbf{F}_S) \quad (7)$$

式中: $g(\cdot)$ 和 $h(\cdot)$ 分别表示缩放函数和偏移函数,可以是任意的神经网络。

3 基于 LSTM 的多步光伏功率预测

3.1 长短期记忆网络

长短期记忆网络(long short-term memory, LSTM)是一种循环神经网络,可以处理时间序列数据并捕捉其时间依赖关系,被广泛用于序列学习任务。相较于普通的循环神经网络,长短期记忆网络在单元内部增加了遗忘门、输入门和输出门 3 个门结构。网络通过记忆细胞单元存储和更新信息,可以有效捕捉数据的长期依赖关系,缓解梯度消失和梯度爆炸问题^[22]。长短期记忆网络的单元结构如图 6 所示。




图 6 LSTM 的内部结构

Fig. 6 Internal structure of LSTM

LSTM 单元内部更新过程可以表示为:

$$f_t = \text{sigmoid}(\mathbf{W}_f[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f) \quad (8)$$

$$i_t = \text{sigmoid}(\mathbf{W}_i[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i) \quad (9)$$

$$\tilde{\mathbf{c}}_t = \tanh(\mathbf{W}_c[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_c) \quad (10)$$

$$o_t = \text{sigmoid}(\mathbf{W}_o[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o) \quad (11)$$

$$\mathbf{c}_t = f_t \odot \mathbf{c}_{t-1} + i_t \odot \tilde{\mathbf{c}}_t \quad (12)$$

$$\mathbf{h}_t = o_t \odot \tanh(\mathbf{c}_t) \quad (13)$$

式中: $\mathbf{W}_f, \mathbf{W}_i, \mathbf{W}_c, \mathbf{W}_o$ 为权重矩阵; $\mathbf{b}_f, \mathbf{b}_i, \mathbf{b}_c, \mathbf{b}_o$ 为偏置项; \mathbf{x}_t 表示 t 时刻输入向量; \mathbf{h}_t 表示 t 时刻隐藏状态; \mathbf{c}_t 表示 t 时刻记忆细胞状态; \odot 是哈达玛积。

3.2 光伏功率预测

基于 LSTM 的光伏功率预测采用编码器-解码器架构进行时序建模,以解决输入输出序列长度不同的问题^[23]。编码器和解码器均采用长短期记忆网络,网络结构如图 7 所示。

在循环神经网络训练中,Teacher Forcing 是一种常见的训练策略。在训练过程中,将上一时间步的真实值作为下一时间步的输入以避免序列生成中产生累积误差,提高训练稳定性。但是在测试阶段,待预测时间步的真实值是未知的,这就会导致测试阶段和训练阶段的输入分布不一致,从而产生预测偏差。而在时间序列预测问题中,历史

统计数据在训练阶段和测试阶段均可获取,将历史统计数据作为解码器输入可以使模型的输入在训练阶段和测试阶段分布相同。因此,本文引入历史光伏功率均值 P_{mean} 、标准差 P_{std} 、最大值 P_{max} 和最小值 P_{min} 作为输入,以进一步提高预测精度。此外,受日照的昼夜交替变换影响,光伏功率具有较强的周期性。将时间信息 t 作为模型输入可以使模型更好的学习光伏功率的周期性变化规律。因此, i 时刻的输入数据 x_i 为 $[t_i; P_{\text{mean}, i}; P_{\text{std}, i}; P_{\text{max}, i}; P_{\text{min}, i}]$ 。

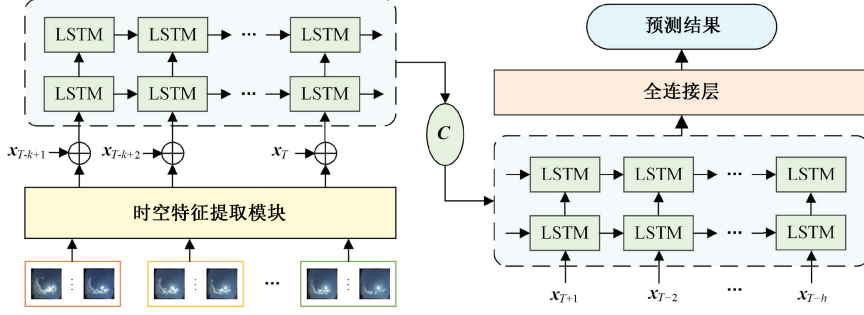


图7 TSFE-LSTM 的整体结构

Fig. 7 The structure of TSFE-LSTM

3.3 多步预测策略

多步光伏功率预测是指通过对输入历史数据 $[y_{T-k+1}, y_{T-k+2}, \dots, y_T]$ 的建模,预测未来多个时间步的光伏功率值 $[\hat{y}_{T+1}, \hat{y}_{T+2}, \dots, \hat{y}_{T+h}]$, 其中 $h > 1$ 。常见的预测策略有递归策略,直接策略和多输入多输出策略。

递归策略将上一时间步的预测值作为输入预测下一时间步的功率值,可以表示为:

$$\hat{y}_{T+h} = \begin{cases} f_R(y_{T-k+1}, \dots, y_T), h = 1 \\ f_R(y_{T-k+h}, \dots, y_T, \hat{y}_{T+1}, \dots, \hat{y}_{T+h-1}), 1 < h \leq k \\ f_R(\hat{y}_{T-k+h}, \dots, \hat{y}_{T+h-1}), k < h \leq H \end{cases} \quad (14)$$

递归策略将预测值作为输入,误差会随着预测时间步长的增加而累积增加。

直接策略通过建立多个单步预测模型进行多步预测,可以表示为:

$$\hat{y}_{T+h} = f_D(y_{T-k+1}, \dots, y_T) \quad (15)$$

直接策略所需建立模型数量随着预测时间步长的增加而增加,导致计算成本也随之增加。

与直接策略和递归策略不同,多输入多输出策略通过建立一个多输出模型来实现多步预测,可以表示为:

$$[\hat{y}_{T+H}, \dots, \hat{y}_{T+1}] = f_M(y_{T-k+1}, \dots, y_T) \quad (16)$$

多输入多输出策略考虑了预测值之间的相关性,避免了直接策略的独立性假设,一次性输出所有时间步的预测值,避免了误差累积。

4 实验结果与分析

4.1 数据来源

本文选用来自斯坦福大学的 SKIPP'D 数据集^[24]。该

将双流卷积网络提取的时空特征和历史统计数据输入到编码器,经过编码器编码为一个固定长度的状态向量 C 。然后,解码器将状态向量 C 作为初始状态,输入历史统计数据对未来时序建模,经过全连接层输出光伏功率预测值。此外,为了进一步学习输入数据的时序信息,本文将解码器的隐藏状态与输入数据的拼接作为解码器部分的输入。

数据集包含了 2017~2019 年的地基云图数据和光伏功率数据,采样频率为 1 min,地基云图大小为 64×64 像素。本文通过滑动窗口法处理数据,获得长度为 15 的输入和输出数据。

4.2 实验设置

实验设备采用的处理器为 intel(R) Xeon(R) Gold 5218R CPU @ 2.10 GHz,显卡为 NVIDIA GeForce RTX 3090,操作系统为 Windows 10。本文利用 PyTorch 框架构建模型,选择 MSE 损失函数,采用 Adma 优化器,地基云图序列分为 3 段, LSTM 共 2 层,各层神经元数量均为 64。

4.3 评价指标

为了验证所提出模型的预测性能,本文采用常见的平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE)作为评价指标^[25],其计算公式为:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (17)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (18)$$

式中: n 为样本数; \hat{y}_i 表示 t 时刻归一化光伏功率预测值; y_i 表示 t 时刻归一化光伏功率真实值。

4.4 预测结果分析

1) 不同预测策略对预测精度的影响

为了研究预测策略对多步光伏功率预测精度的影响,并选取最佳的预测策略进行后续实验,将前文所提到的 3 种预测策略进行对比分析。具体的对比结果如表 1 所示。

表 1 不同策略下功率预测结果

Table 1 The results of prediction with different strategies

预测策略	预测步长/min	MAE/%	RMSE/%
递归策略	1	6.47	10.03
	5	6.40	10.22
	10	6.50	10.66
	15	6.66	10.92
直接策略	1	6.19	9.98
	5	6.31	10.26
	10	6.54	10.72
	15	6.75	11.04
多输入 多输出 策略	1	5.98	9.69
	5	6.06	9.90
	10	6.18	10.38
	15	6.49	10.76

由表 1 可知,在所有预测步长中,多输入多输出策略都有最佳的预测精度。所有预测策略的精度都随着时间步长的增加而下降,直接策略较其他策略预测精度下降更快,这是因为预测步长的增加降低了待预测时间步与输入时间步之间的相关性,进而影响预测精度。而递归策略将上一时间步的输出作为输入来预测下一时间步的光伏功率,虽然弥补了这一缺点,但同时也导致了误差累积,一定程度上也降低了光伏功率预测精度。

图 8 展示了不同预测策略的预测结果对比,可以直观地得到多输入多输出策略预测精度最佳的结论。因此,在之后的实验中均采用多输入多输出策略进行预测。




图 8 不同预测策略下光伏功率预测结果对比图

Fig. 8 Comparison of PV power prediction results with different forecasting strategies

2)不同输入信息对预测精度的影响

为了研究时空特征提取模块中不同输入信息的重要性,分别将地基云图、光流图以及两者的组合作为特征提取模块的输入信息进行对比实验。实验结果如表 2 所示。

表 2 输入不同信息的功率预测结果

Table 2 The results of prediction for different inputs

地基云图	光流图	融合方法	MAE/%	RMSE/%
√	—	—	6.89	11.28
—	√	—	7.35	11.75
√	√	加权平均	6.58	10.90
√	√	特征线性调制	6.49	10.76

由表 2 可知,融合两种信息的结果最佳,单独使用地基云图次之,单独使用光流最差。通过特征线性调制方法融合两种信息后,模型的 MAE 和 RMSE 分别达到 6.49% 和 10.76%,相较于单独使用地基云图,MAE 和 RMSE 分别提高了 5.81% 和 4.61%。特征线性调制的融合方法优于加权平均的方法表明通过特征线性调制融合两种信息有利于时空特征的表达。实验结果表明了融合不同信息在光伏功率预测任务中的有效性。

3)不同天气情况对预测精度的影响

光伏功率受天气情况影响较大,为了验证模型在不同天气情况下的光伏功率预测性能,本文分别在晴天和阴天情况下进行了未来 15 min 的光伏功率预测,并将预测结果与常见的光伏功率预测方法 CNN^[26] 和 CNN-MLP^[27] 在相同实验条件下输入校正后地基云图数据和历史统计数据对比。CNN 模型将地基云图序列输入至多层卷积网络中进行预测。CNN-MLP 使用 VGG-16 提取云图特征并进行太阳辐照度预测。各模型在不同天气情况下的预测结果如表 3 和图 9 所示。

表 3 不同天气情况下功率预测结果

Table 3 The results of prediction under different weather conditions

天气类型	预测模型	MAE/%	RMSE/%
晴天	CNN	2.49	3.47
	CNN-MLP	3.37	4.70
	TSFE-LSTM	2.31	2.95
阴天	CNN	11.91	16.43
	CNN-MLP	11.04	15.10
	TSFE-LSTM	10.65	14.91
综合	CNN	7.21	11.67
	CNN-MLP	7.21	11.19
	TSFE-LSTM	6.49	10.76

由表 3 可得,在不同天气情况下,本研究所提出的 TSFE-LSTM 模型预测性能最佳。晴天情况下,本研究模型对比 CNN 模型 MAE 和 RMSE 分别提高了 7.23% 和 14.99%,预测表现更加稳定。阴天情况下,预测精度有所下降,但是仍高于其他模型,对比 CNN-MLP 模型,本研究模型的 MAE 和 RMSE 分别提高了 3.53% 和 1.26%。

从图9中可以看出,本研究所提模型在晴天和阴天都有较高的预测精度,且晴天情况下光伏功率的预测精度远高于阴天情况。这是因为云层的遮挡极大地增加了功率预测的难度,预测模型不能对云层的快速变化做出及时的反应。

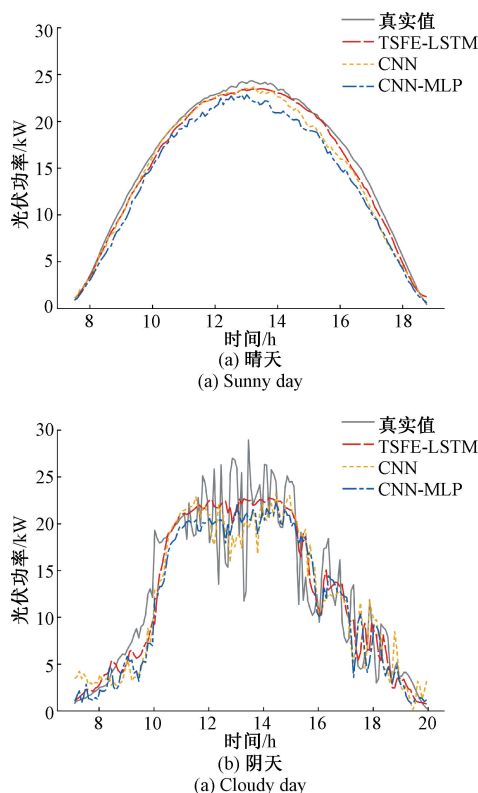


图9 不同天气情况下功率预测结果对比图

Fig. 9 Comparison of prediction results under different weather conditions

综合来看,本研究模型能适应不同天气带来的影响,在各种天气情况下拥有最佳的预测效果。结果表明了充分利用地基云图的时空特征可以在快速和复杂的云层运动场景年实现更准确的光伏功率预测。

5 结 论

本研究针对短时间内云层快速变化引起光伏功率剧烈波动问题,提出了一种基于双流特征增强的光伏功率预测模型(TSFE-LSTM),模型利用双流卷积神经网络提取了地基云图的时间和空间特征,并通过特征线性调制方法融合时空特征,利用长短期记忆网络实现了提前15 min的超短期光伏功率预测。最后,通过实验对比验证了本文所提模型的有效性,在不同天气情况下,TSFE-LSTM都具有较高的预测精度和一定的稳定性。此外,本研究所使用数值数据只有历史功率统计数据,具有一定的局限性,未来可以考虑结合气象数据和太阳位置参数,进一步提高光伏功率预测精度。

参考文献

- [1] 张智刚,康重庆. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报, 2022, 42(8): 2806-2819.
ZHANG ZH G, KANG CH Q. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future[J]. Proceedings of the CSEE, 2022, 42(8): 2806-2819.
- [2] 国家能源局发布 2023 年全国电力工业统计数据[J]. 电力科技与环保, 2024, 40(1): 95.
National energy administration releases the statistics of the national electric power industry in 2023 [J]. Electric power Technology and Environmental Protection, 2024, 40(1): 95.
- [3] 吴硕. 光伏发电系统功率预测方法研究综述[J]. 热能动力工程, 2021, 36(8): 1-7.
WU SH. Review of power forecasting methods of photovoltaic power generation system [J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(8): 1-7.
- [4] 白隆,俞斌,高峰,等. 基于ICEEMDAN和TCN-AM-BiGRU的短期光伏功率预测[J]. 电子测量技术, 2024, 47(9): 61-69.
BAI L, YU B, GAO F, et al. Short-term photovoltaic power prediction based on ICEEMDAN and TCN-AM-BiGRU [J]. Electronic Measurement Technology, 2024, 47(9): 61-69.
- [5] LIU J X, ZANG H X, DING T, et al. Harvesting spatiotemporal correlation from sky image sequence to improve ultra-short-term solar irradiance forecasting[J]. Renewable Energy, 2023, 209: 619-631.
- [6] MEER D V D, WIDEN J, MUNKHAMMAR J. Review on probabilistic forecasting of photovoltaic power production and electricity consumption [J]. Renewable and Sustainable Energy Reviews, 2018, 81: 1484-1512.
- [7] 董存,王铮,白捷予,等. 光伏发电功率超短期预测方法综述[J]. 高电压技术, 2023, 49(7): 2938-2951.
DONG C, WANG ZH, BAI J Y, et al. Review of ultra-short-term forecasting methods for photovoltaic power generation [J]. High Voltage Engineering, 2023, 49(7): 2938-2951.
- [8] 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 G ZH, LU L, TANG B, et al. An improved hybrid neural network ultra-short-term photovoltaic power forecasting method based on cloud image

- feature extraction[J]. Chinese Society for Electrical Engineering, 2021, 41(20): 6989-7003.
- [9] 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 M K, XIA F, ZHANG H, et al. Ultra-short-term prediction of self-identifying photovoltaic based on sky cloud chart[J]. Power System Technology, 2021, 45(3): 1023-1035.
- [10] 全勛峰, 金嘉祺, 袁晓军, 等. 基于机器视觉的区域太阳直接辐射动态预测方法研究[J]. 太阳能学报, 2021, 42(6): 247-255.
- TONG X F, JIN J Q, YUAN X J, et al. Research on regional solar direct normal irradiance dynamic forecasting based on machine vision[J]. Acta Energiæ Solaris Sinica, 2021, 42(6): 247-255.
- [11] 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): 3027-3048.
- ZHU Q F, LI J T, QIAO J, et al. Application and prospect of artificial intelligence technology in renewable energy forecasting[J]. Chinese Society for Electrical Engineering, 2023, 43(8): 3027-3048.
- [12] CHAI H, ZHEN ZH, LI K P, et al. Convolutional auto-encoder based sky image prediction model for minutely solar PV power forecasting[C]. 2020 IEEE Industry Applications Society Annual Meeting, 2020: 1-7.
- [13] ZHANG L, WILSON R, SUMNER M, et al. Advanced multimodal fusion method for very short-term solar irradiance forecasting using sky images and meteorological data: A gate and transformer mechanism approach[J]. Renewable Energy, 2023, 216: 118952.
- [14] WEN H R, DU Y, CHEN X Y, et al. Deep learning based multistep solar forecasting for PV ramp-rate control using sky images[J]. IEEE Transactions on Industrial Informatics, 2020, 17(2): 1397-1406.
- [15] 包俊, 刘宏哲, 褚文博. 环视鱼眼图像处理深度学习研究进展[J]. 中国图象图形学报, 2021, 26(12): 2778-2799.
- BAO J, LIU H ZH, CHU W B. Research progress of fisheye image processing based on deep learning[J]. Journal of Image and Graphics, 2021, 26(12): 2778-2799.
- [16] 涂治洲, 孙军艳, 盛强, 等. 针对鱼眼图像边缘校正失真的快速校正算法[J]. 电子测量技术, 2022, 45(15): 100-105.
- TU ZH ZH, SUN J Y, SHENG Q, et al. Fast correction algorithm for edge distortion of fisheye image [J]. Electronic Measurement Technology, 2022, 45(15): 100-105.
- [17] LIU J, 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.
- [18] SIMONYAN K, ZISSERMAN A. Two-stream convolutional networks for action recognition in videos[J]. Advances in Neural Information Processing Systems. 2014: 568-576, DOI: 10. 1002/14651858. CD001941. pub3.
- [19] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [20] WANG L M, XIONG Y J, WANG ZH, et al. Temporal segment networks for action recognition in videos[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 41(11): 2740-2755.
- [21] PEREZ E, STRUB F, DE V H, et al. Film: Visual reasoning with a general conditioning layer[C]. AAAI Conference on Artificial Intelligence, 2018, 32(1): 3942-3951.
- [22] 高超, 孙谊娟, 赵洪峰, 等. 基于 ICOA-LSTM 的短期负荷预测研究[J]. 电子测量技术, 2022, 45(13): 88-95.
- GAO CH, SUN Y Q, ZHAO H F, et al. Research on short-term load forecasting based on ICOA-LSTM[J]. Electronic Measurement Technology, 2022, 45(13): 88-95.
- [23] 李天宇, 周静雷, 李佳斌. 基于 VMD-Seq2seq 模型的扬声器短期寿命预测研究[J]. 国外电子测量技术, 2023, 42(3): 145-151.
- LI T Y, ZHOU J L, LI J B. Prediction of speaker residual life based on VMD-Seq2seq model [J]. Foreign Electronic Measurement Technology, 2023, 42(3): 145-151.
- [24] NIE Y H, LI X T, 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.
- [25] 袁建华, 蒋文军, 李洪强, 等. 基于 SSA-BiLSTM 非线性组合方法的光伏功率预测[J]. 电子测量技术, 2023, 46(21): 63-71.
- YUAN J H, JIANG W J, LI H Q, et al. Photovoltaic power forecasting based on SSA-BiLSTM nonlinear combination method [J]. Electronic Measurement

Technology, 2023, 46(21): 63-71.

[26] RUAN G P, CHEN X Y, LIM E G, et al. On the use of sky images for intra-hour solar forecasting benchmarking: Comparison of indirect and direct approaches[J]. Solar Energy, 2024, 276: 112649.

[27] EL A O, ABRAIM M, GHENNIQUI H, et al. Short term solar irradiance forecasting using sky images based on a hybrid CNN-MLP model [J]. Energy Reports, 2021, 7: 888-900.

作者简介

辛峰悦, 硕士研究生, 主要研究方向为新能源出力预测。
E-mail: xinfy_003@163.com

寇志伟(通信作者), 博士, 副教授, 主要研究方向为模式识别与智能系统、电工理论与新技术。
E-mail: kouzhiwei@imut.edu.cn

刘焱晨, 硕士研究生, 主要研究方向为无线电能传输技术。
E-mail: 13473247115@163.com

崔啸鸣, 硕士, 副教授, 主要研究方向为导航与测控技术、模式识别与智能系统、检测技术与自动化装置。
E-mail: cuixiaoming@imut.edu.cn

齐咏生, 博士, 教授, 主要研究方向为机器人协同控制技术。
E-mail: qys@imut.edu.cn