

DOI: 10.19783/j.cnki.pspc.230875

## 基于 MBI-PBI-ResNet 的超短期光伏功率预测

黄泽<sup>1</sup>, 毕贵红<sup>1</sup>, 谢旭<sup>2</sup>, 赵鑫<sup>3</sup>, 陈臣鹏<sup>1</sup>, 张梓睿<sup>1</sup>, 骆钊<sup>1</sup>

(1. 昆明理工大学电力工程学院, 云南 昆明 650500; 2. 华能澜沧江水电股份有限公司糯扎渡水电站, 云南 普洱 665000; 3. 中国长江电力股份有限公司乌东德水力发电厂, 云南 昆明 651212)

**摘要:** 为了增强光伏并网的稳定性, 提高光伏发电功率预测精度, 提出一种基于相似日聚类、群分解(swarm decomposition, SWD)和 MBI-PBI-ResNet 深度学习网络模型的光伏发电功率超短期预测方法。首先, 使用快速傅里叶变换(fast fourier transform, FFT)提取太阳辐照度的期望频率, 将其作为聚类特征向量, 并根据此聚类特征向量采用自适应仿射传播聚类(adaptive affinity propagation clustering, AdAP)实现相似日聚类。其次, 对每一类相似日分别使用群分解算法进行分解, 以提取原始数据的多尺度波动规律特征。最后, 利用 MBI-PBI-ResNet 来实现对天气环境多变量关联影响下的时序特征挖掘以及对多尺度分量的局部波形空间特征和长时间依赖时序特征的同时挖掘, 并对不同类型特征进行综合集成来实现光伏发电功率超短期预测。研究表明: 所提方法在光伏发电功率超短期预测领域相较于其他深度学习方法预测精度提高了3%以上, 说明此方法在光伏发电功率超短期预测领域具有较高的预测精度和较强的泛化能力。

**关键词:** 光伏发电; 功率预测; 相似日聚类; 并联网络

### Ultra-short-term PV power prediction based on MBI-PBI-ResNet

HUANG Ze<sup>1</sup>, BI Guihong<sup>1</sup>, XIE Xu<sup>2</sup>, ZHAO Xin<sup>3</sup>, CHEN Chenpeng<sup>1</sup>, ZHANG Zirui<sup>1</sup>, LUO Zhao<sup>1</sup>

(1. School of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650500, China;  
2. Nuozhadu Hydropower Plant, Huaneng Lancang River Hydropower Inc, Puer 665000, China;  
3. Wudongde Hydropower Plant, China Yangtze Power Co., Ltd., Kunming 651212, China)

**Abstract:** To enhance the stability of photovoltaic (PV) grid connection and improve the accuracy of PV power prediction, an ultra-short-term prediction method of PV power based on similar day clustering, swarm decomposition (SWD) and MBI-PBI-ResNet network deep learning network model is proposed. First, the expected frequency of solar irradiance is extracted using a fast Fourier transform (FFT). This is used as a clustering eigenvector, and similar day clustering is achieved using adaptive affinity propagation clustering (AdAP) based on this clustering eigenvector. Second, each class of similar days is decomposed separately using swarm decomposition algorithms to extract the multi-scale fluctuation pattern features of the original data. Finally, MBI-PBI-ResNet is used to realize the mining of temporal features under the influence of multivariate correlation of weather environment. Also it is used for the mining of spatial features of local waveforms and long time-dependent temporal features of multiscale components at the same time, as well as the combined integration of different types of features to realize ultra-short-term prediction of PV power generation. The results show that this method improves the prediction accuracy by more than 3% compared with other deep learning methods in the field of ultra-short-term prediction of photovoltaic power. This indicates that this method has higher prediction accuracy and stronger generalizability in the field of ultra-short-term prediction of photovoltaic power.

This work is supported by the National Key Research and Development Program of China (No. 2022YFB2700011).

**Key words:** photovoltaic power; power prediction; similar day clustering; parallel network

## 0 引言

随着社会科技的发展, 具有普遍性和可持续

性的太阳能、风能等清洁能源在满足人们对能源需求的同时, 有效缓解环境污染和化石燃料造成的能源匮乏等问题。而近年来, 由于光伏板制造成本的降低, 极大地推进了全球光伏电站的发展<sup>[1-2]</sup>。但光伏发电具有波动性和间歇性, 导致其大规模接入电

基金项目: 国家重点研发计划项目资助(2022YFB2700011)

网时会给电力系统带来很严重的安全隐患，因此光伏发电功率的精确预测对电力系统的稳定运行极其重要<sup>[3]</sup>。

光伏功率预测方法可大致分为物理模型法和数据驱动法，但物理模型预测方法建模过程复杂且对于预测模型和天气预报精准性要求高，难以达到较好的预测效果；数据驱动预测方法以历史数据为研究对象，结合信号处理技术和人工智能算法来建立历史数据和未来光伏功率之间的复杂映射关系，进而实现光伏功率预测<sup>[4]</sup>。文献[5]利用与光伏功率相关系数最高的总水平辐射变量的平均值、最大值和波峰谷数等特征量作为聚类特征，采用模糊 C 均值 (fuzzy c-means, FCM) 进行相似日聚类，最后利用分位数回归-卷积神经网络-双向长短期记忆 (quantile regression-convolutional neural network-bidirectional long short term memory, QR-CNN-BiLSTM) 深度学习网络模型来实现光伏功率区间概率预测。然而直接使用太阳辐照度特征量进行聚类处理，难以提取太阳辐照度的波动特征，导致其聚类得到的相似日中光伏功率的波动规律相差较大，光伏功率预测精度不高。文献[6]采用 FFT 计算出原始电力负荷的期望频率，并将其作为聚类特征使用密度层次聚类算法 (density-based clustering hierarchical clustering, DC-HC) 对负荷进行聚类处理，最后运用长短时记忆 (long short term memory, LSTM) 网络模型进行负荷预测，验证了通过 FFT 进行特征提取再聚类的按类预测方法可有效提高短期预测精度。文献[7]采用自适应白噪声完整集合经验模态分解 (complete ensemble empirical mode decomposition adaptive noise, CEEMDAN) 对太阳辐照度进行分解，并将其分解所得子分量以不同的输入方式输入到卷积神经网络-长短期记忆 (convolutional neural network-long short term memory, CNN-LSTM) 网络模型中预测太阳辐照度，通过信号分解算法降低了原始信号的复杂度，更利于网络模型提取输入信号的深层特征，验证了多分支输入方式相较于其他输入方式可有效提高太阳辐照度的预测精度。但通过 CNN 提取后的特征向量再输入到 LSTM 中，将会导致原始输入数据的时序特征被忽略。文献[8]采用 CNN 和双向门控递归单元 (bidirectional gated recurrent unit, BiGRU) 并联的结构弥补 CNN 和 BiGRU 各自的缺陷，以此来提高分类效果。文献[9]采用空洞卷积神经网络 (dilated convolutional neural network, DCNN) 和双向长短期记忆网络 (bidirectional long short term memory, BiLSTM) 并联的结构来提高光伏功率的预测精度。说明通过卷积网络和时序网络并联可同

时提取原始输入数据的空间特征和时序特征，更利于网络模型挖掘输入数据与输出数据之间的复杂映射关系。

光伏功率预测精度的提高需要从相似日聚类水平、深度挖掘影响光伏发电的天气环境多变量关联关系以及光伏发电功率时序的复杂多尺度波动及其耦合关系等方面进行系统集成来实现，单独研究相似日聚类效果、天气多变量关联关系或光伏发电功率的多尺度分解精度来提高预测精度会出现顾此失彼的情况。

文献[10]利用自适应仿射传播聚类可自动确定最佳聚类结果以及振荡消除能力强等特点提高 GIS 局放缺陷分类效果。文献[11]利用 SWD 的可分性强、降噪效率高等特点来提高非线性信号的分解效果，进一步提高往复压缩机轴承故障识别率。本文基于综合集成的思想，结合自适应仿射传播聚类和 SWD 算法各自的特点来提高相似日聚类水平和光伏发电功率时序的多尺度分解质量，再利用多分支结构以实现天气环境多变量关联影响下的时序特征挖掘，以及对多尺度分量的局部波形空间特征和长时间依赖时序特征的同时挖掘，并对不同类型特征进行系统集成以实现光伏发电功率超短期预测。具体处理如下：1) 对光伏功率与其环境变量进行相关性分析，选取与光伏功率呈强相关性的环境变量，利用 FFT 提取其期望频率作为聚类特征向量，使用 AdAP 进行相似日聚类；2) 对各天气类型下的光伏功率进行 SWD 分解处理，再利用其所得子分量与光伏功率呈强相关性和中等相关性的环境变量来构造输入特征向量，并设置分解对比实验来验证 SWD 分解算法在光伏功率预测领域中对光伏功率信号进行分解处理的适用性；3) 使用 MBI-PBI-ResNet 网络模型先挖掘光伏功率历史数据子分量的相邻空间特征和双向传递时序特征，再将其整合得到输入的光伏功率的多尺度互补时空特征，并设置模型对比实验验证 MBI-PBI-ResNet 网络模型相较于其他模型在光伏功率超短期预测领域的优势；4) 利用多分支 BiLSTM 结构来提取与光伏功率呈强相关性和中等相关性的环境变量的深层时序关联特征，将其与光伏功率的多尺度互补时空特征融合来共同预测未来的光伏功率。最后，根据 Yulara 太阳能系统中沙漠风帆项目的实测数据通过实验验证了该方法的有效性，并与其他方法进行对比。

## 1 数据处理

本文实验数据来自于沙漠知识太阳能中心 (desert knowledge Australia solar centre) Yulara 太阳

能系统中沙漠风帆(sails in the desert)项目的实测数据, 该项目的光伏电机具体参数如表 1 所示。

表 1 光伏电机参数

| 关键参数         | 规格                                    |
|--------------|---------------------------------------|
| 额定功率/kW      | 106.6                                 |
| 单块太阳能板额定功率/W | 327                                   |
| 太阳能板数量       | 324                                   |
| 太阳能板材料       | 单晶硅                                   |
| 太阳能板类型       | SunPower SPR-327NE                    |
| 逆变器尺寸/类型     | SMA STP 25000TL-30/20000TL-30         |
| 阵列倾角/方位角倾角   | $\beta = 10^\circ / \theta = 0^\circ$ |

原始数据集中涵盖了除发电功率外的其他环境变量, 如辐照度、风速、温度等<sup>[12]</sup>。对 2017 年全年数据进行研究, 由于设备维修、故障等导致原始数据集出现缺失, 将含有缺失数据的全天数据剔除后得到 342 天的实测数据, 其采样间隔为 15 min, 由于光伏发电在凌晨和夜晚的功率输出大部分为零或接近零, 因此其研究意义不大, 故本文只考虑每天 07:00—19:00 的电力数据。

### 1.1 相关性分析

由于光伏发电时会受到各种环境变量的影响, 而不同环境变量对发电功率的影响程度不同, 故确定环境变量与光伏发电功率的出力关系尤为重要, 选取影响程度高的环境变量作为预测模型的输入, 可有效提高模型的预测精度<sup>[13]</sup>。因此本文采用 Pearson 和 Spearman 秩相关系数来分析各环境因子对光伏发电功率的影响程度, 两个变量  $(X, Y)$  之间的 Pearson 相关系数  $\rho_{P(X,Y)}$  和 Spearman 秩相关系数  $\rho_{S(X,Y)}$  可分别用式(1)和式(2)表示。

$$\rho_{P(X,Y)} = \frac{\sum_{i=1}^n (x_i - \bar{x}_i)(y_i - \bar{y}_i)}{\sqrt{\sum_{i=1}^n (x_i - \bar{x}_i)^2 \sum_{i=1}^n (y_i - \bar{y}_i)^2}} \quad (1)$$

$$\rho_{S(X,Y)} = 1 - \frac{6 \sum_{i=1}^n (R(x_i) - R(y_i))^2}{n(n^2 - 1)} \quad (2)$$

式中:  $\bar{x}_i$  和  $\bar{y}_i$  分别为  $x_i$  和  $y_i$  的平均值;  $R(x_i)$  和  $R(y_i)$  分别为  $x_i$  和  $y_i$  在各自向量中的排名;  $n$  表示  $X$  和  $Y$  的长度。相关系数值介于  $[-1, 1]$  之间, 当两个变量的相关系数值小于 0 时则判定属于负相关, 在  $[0, 0.1]$  之间属于极弱相关性, 在  $[0.1, 0.9]$  之间属于中等相关性, 在  $[0.9, 1]$  之间属于极强相关性<sup>[14]</sup>。各环境变量的 Pearson 相关系数和 Spearman 秩相关系数如表 2 所示。

表 2 发电功率与各环境变量的相关系数

Table 2 Correlation coefficient between power generation and various environmental factors

| 环境变量 | $\rho_{P(X,Y)}$ | $\rho_{S(X,Y)}$ |
|------|-----------------|-----------------|
| 辐照度  | 0.9478          | 0.9512          |
| 温度   | 0.3307          | 0.3366          |
| 风速   | 0.3045          | 0.2958          |
| 风向   | -0.1822         | -0.2248         |
| 降雨量  | 0               | 0               |
| 大气压  | -0.0353         | -0.0573         |

由表 2 可知, 辐照度与光伏发电功率间的相关性极强, 说明辐照度的波动规律和光伏发电功率高度相似, 故根据其每一天辐照度数据的波动规律来聚类, 可以有效地将波动规律相似的光伏发电功率各天聚为一类。温度和风速与光伏发电功率呈现中等相关性, 说明温度和风速对光伏发电功率也有一定的影响<sup>[15]</sup>。而风向和大气压与光伏发电功率呈负相关, 此外, 由于本文实验数据来源于沙漠地区, 其降雨量极少, 所以对光伏发电功率影响极小, 故降雨量与光伏发电功率之间呈极弱相关性甚至没有相关性。因此本文在进行相似日聚类处理时只利用了与光伏发电功率呈极强相关性的辐照度数据, 而利用深度学习模型对光伏发电功率进行预测的过程中, 考虑与光伏发电功率呈极强相关性和中等相关性的辐照度、温度和风速等历史数据。

### 1.2 自适应仿射传播聚类

自适应仿射传播聚类通过自适应扫描其聚类个数空间以获得不同聚类数目的聚类结果, 同时调整其阻尼因子和相似度矩阵中对角线的偏向参数, 从而解决 AP 聚类可能会发生的振荡问题, 最后采用轮廓系数 Silhouette 指标筛选出最优的聚类结果<sup>[16]</sup>。Silhouette 指标可以反映聚类结果中各类间的可分性和各类的紧密性, 假设数据集有  $n$  个样本, 聚类结果为  $K_s$  个  $C_i (i=1, 2, \dots, K_s)$ , 其中一个样本  $t$  的 Silhouette 指标可表示为

$$S_{it}(t) = \frac{b(t) - a(t)}{\max\{a(t), b(t)\}} \quad (3)$$

式中:  $a(t)$  为聚类结果  $C_j (j \in i)$  中的样本  $t$  与  $C_j$  中除  $t$  外所有其他样本之间的平均不相似度;  $b(t) = \min\{d(t, C_i)\}$ , 其中  $d(t, C_i)$  为样本  $t$  与其他所有类  $C_i$  (除  $C_j$  外) 中所有样本之间的平均不相似度。以此类推, 计算出数据集中所有样本的  $S_{it}$  值, 将其取平均值即可得到数据集的轮廓系数值  $S_{av}(C)$ , 其值越大代表聚类效果越好, 而最大值所对应的聚类结果个数则为自适应仿射传播聚类的最优聚类结果个

数<sup>[17]</sup>。一般认定  $S_{ij} \geq 0.5$  表示各聚类结果分明，效果优越， $0.2 \leq S_{ij} < 0.5$  则表示部分聚类结果存在重叠现象， $S_{ij} < 0.2$  则表示聚类结果不合理。

本文采用快速傅里叶变换提取每天太阳辐照度的期望频率，将其作为每天的聚类特征向量。经自适应仿射传播聚类处理后得到 4 类天气类型，其中第 1 类天气类型的辐照度数据较为平滑，且波动极小，故将其命名为晴天天气类型；第 2 类天气类型的辐照度数据波动范围稍大，但其数据大部分都较为平滑，只有少部分数据有较为剧烈的波动，说明可能是由于少量云层遮挡了部分光伏板，导致一天内有部分时间光伏发电功率不高，故将此类天气类型命名为少云天气类型；第 3 类天气类型和第 2 类天气类型较为相似，但其辐照度波动范围更大，说明可能是有较多云层遮挡了光伏板，故将其命名为多云天气类型；第 4 类天气类型的辐照度数据波动极大，甚至部分接近于 0，目前无法用某一天气类型对其概括，故将其描述为极端天气类型。此聚类结果的轮廓系数值为 0.7728，说明自适应仿射传播聚类能有效地将不同规律性的辐照度数据区分开，且此次聚类效果较好。具体结果如图 1 所示，其中晴天 144 天，少云 75 天，多云 78 天，极端天气 45 天。

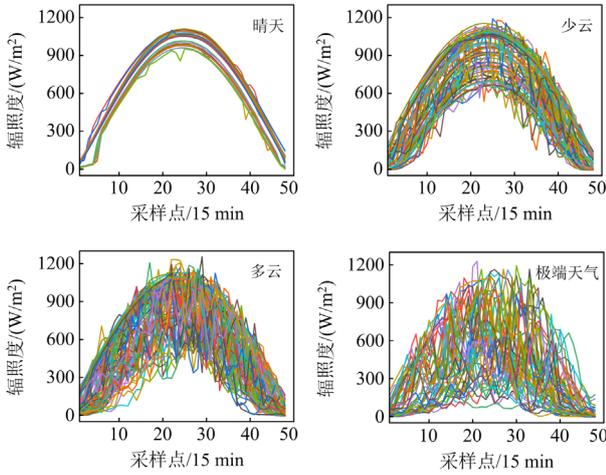


图 1 自适应仿射传播聚类结果

Fig. 1 Adaptive affinity propagation clustering results

### 1.3 群分解

群分解通过适当参数化群滤波 (swarm filter, SWF) 以得到复杂信号的振荡分量，再对比 SWF 滤波器参数与提前设置好的阈值，以此来限制振荡分量的频率，直至剩余分量中没有足够能量的振荡时则停止迭代<sup>[19]</sup>。其具体分解步骤如下。

1) 假设输入信号为  $x[n]$ ，初始阈值  $S_{IDth}$  和  $P_{th}$

后，先估算此时的最优频率  $\omega_{dom}^q$  为

$$\omega_{dom}^q = \arg \max(s_x(\omega) > P_{th}) \quad (4)$$

式中： $s_x(\omega)$  为韦尔奇功率谱； $q$  为分解过程中的迭代次数； $P_{th}$  为规定与最优频率相近的阈值。

2) 计算 SWF 中的参数  $M$  和  $\delta$ 。

$$M = odd(33.46(w_d^q)^{-0.735} - 29.1) \quad (5)$$

$$\delta = -1.5(w_d^q)^2 + 3.454w_d^q - 0.01 \quad (6)$$

式中： $w_d^q$  为转化为无量纲后的频率； $M$  为拟合后的幂级数； $\delta$  为经回归分析法拟合后得到的函数模型； $odd$  为取整运算。

3) 计算经 SWF 滤波处理后得到的输出信号的方差  $S_{ID}$ 。

$$S_{ID} = \sum_n \frac{|y[n] - x[n]|^2}{x^2[n]} \quad (7)$$

式中， $y[n]$  为经 SWF 滤波处理后的输出信号。当  $S_{ID} \geq S_{IDth}$  时， $y[n]$  重新作为输入信号再次进行 SWF 滤波处理；当  $S_{ID} < S_{IDth}$  时，滤波停止，此时  $x_i[n] = y[n]$ 。

4) 更新输入信号。

$$x_0[n] = x[n] - \tilde{c}_{\omega\delta}[n] \quad (8)$$

$$\tilde{c}_{\omega\delta}[n] = x_i[n - \tau_{delay}] \quad (9)$$

$$\tau_{delay} = \arg \max(R_{(x,x)}(\tau)) \quad (10)$$

式中： $x_0[n]$  为更新后的输入信号； $x[n]$  为原始的输入信号； $\tau$  为时延； $R_{(x,x)}$  为互关函数。

5) 重复步骤 1) — 步骤 4)，直至满足  $s_x(\omega) \leq P_{th}$ ，则迭代停止，此时输入信号为  $r(t)$ ，振荡分量  $C_{Ock}$  为

$$C_{Ock} = \sum_q C_{\omega}(t) \quad (11)$$

式中： $q$  为分解过程中的迭代次数； $C_{\omega}$  为当前提取的振荡分量； $k$  为振荡分量个数， $k = 1, \dots, |\Omega_q|$ ，其中  $\Omega_q$  为已被识别振荡模式的集合， $\omega \in \Omega_q$ ， $\Omega_q = \{\omega : \omega = \omega_d\}$ ， $|\Omega_q|$  为已被识别振荡模式的集合的个数<sup>[20]</sup>。

本文分别对自适应仿射传播聚类所得四种天气类型的光伏发电功率数据进行群分解处理，得到不同天气类型下光伏发电功率的子分量。以多云天气类型为例，其光伏发电功率数据分解得到的子分量如图 2 所示，15 条子分量 (IMF<sub>1</sub> — IMF<sub>15</sub>) 和残余分量 (R) 的波动规律都有较大区别，但每条子分量的波动都有较强的规律性，从而大大降低了原始功率数

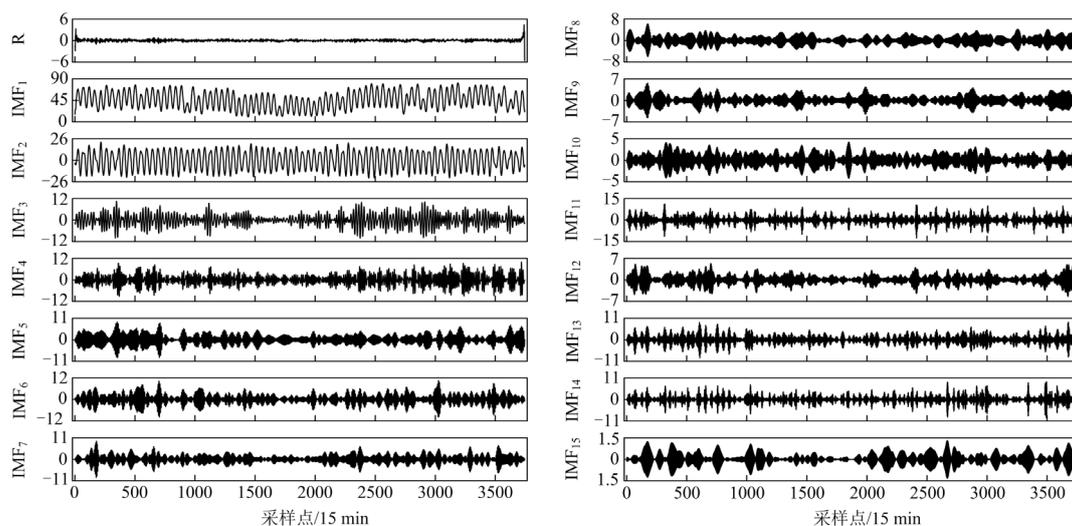


图 2 多云天气类型下光伏功率数据群分解结果

Fig. 2 Results of PV power data swarm decomposition under cloudy weather type

据的复杂度, 因此以子分量形式输入深度学习模型后更利于该模型学习功率数据的变化规律和特征。

## 2 深度学习模型

### 2.1 Inception 网络模型

Inception 网络结构在 2014 年 ImageNet 竞赛上由 Google 团队提出, 其利用不同大小的卷积窗和池化提取输入图片中特征规律不同的空间特征矩阵, 再将其堆叠后给到下一模块, 这样很好地保留了各空间特征矩阵不同的规律性, 增加了网络的宽度, 具备较强的空间特征提取能力<sup>[21]</sup>。Inception 网络结构如图 3 所示。

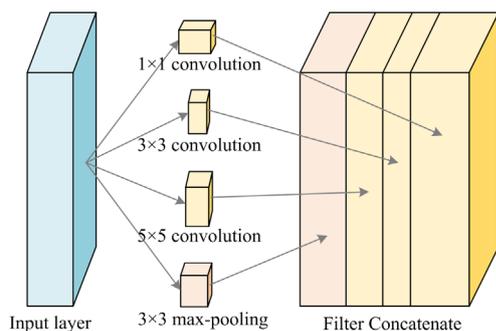


图 3 Inception 网络结构

Fig. 3 Inception network structure

该网络采用  $1 \times 1$ 、 $3 \times 3$  和  $5 \times 5$  三个卷积窗大小不同的卷积层和一个池化层来提取输入数据的空间特征, 不同的卷积窗大小可提取到的空间特征不同, 池化层所提取到的特征与卷积层提取到的特征不同, 将其组合成一个多通道的空间特征矩阵, 使得不同的卷积层和池化层的特征提取优势得到互补,

增强其特征提取性能<sup>[22]</sup>。

### 2.2 Inception-ResNet 网络模型

Inception-ResNet 网络结构在 2016 年由 Google 团队提出, 其在 Inception 网络结构的基础上加入了 ResNet 的思想<sup>[23]</sup>。将原始的池化操作用残差连接所替代, 为使 Inception 结构与残差结构的维度相同, 在 Inception 结构后加入  $1 \times 1$  卷积对齐维度后再与残差结合, 如此在结合 Inception 和 ResNet 结构的基础上大大降低了深度学习模型的计算量, 提高了运算速度<sup>[24]</sup>。其具体结构如图 4 所示, 其中的  $K$  和  $L$  为对应卷积的卷积核数量。

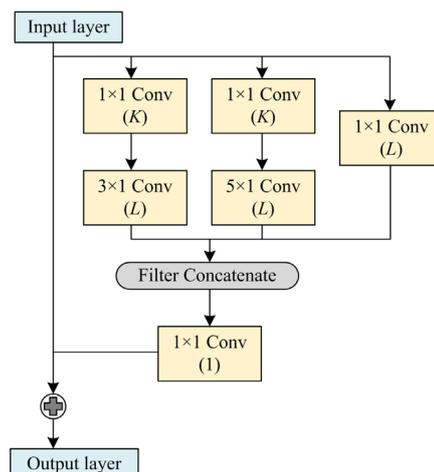


图 4 Inception-ResNet 网络结构

Fig. 4 Inception-ResNet network structure

### 2.3 MBI-PBI-ResNet 深度学习模型

考虑到 Inception-ResNet 网络只能提取到输入数据的空间特征, 而输入数据具有时序性, 故本文

引进并联结构, 在 Inception-ResNet 网络结构的基础上加入了 BiLSTM 网络结构与其并行, 得到 PBI-ResNet 网络, 提取输入数据的空间特征的同时提取其中的双向时序特征。文献[25]在短时记忆神经网络的基础上提出了双向长短时记忆神经网络 (BiLSTM), 其弥补了 LSTM 无法学习未来和过去序列数据间所存在的规律性的缺点, 充分利用了正向传递和反向传递的优势, 提高了模型的时序特征提取能力, 因此被大量应用于时间序列数据处理等领域<sup>[26]</sup>。再引入多分支输入的思想, 提出了 MBI-PBI-ResNet 网络结构, 利用多分支上的 PBI-ResNet 网络提取不同分支输入数据的一维相邻空间特征和双

向传递时序特征, 再分别将每条分支所提取到的一维相邻空间特征和双向传递时序特征各自组合, 得到输入数据的空间特征和双向时序特征, 将其通过全连接层后再组合, 得到输入数据的时空特征, 最后再通过全连接层给到回归层, 使其学习输入数据的时空特征与输出量之间的复杂非线性映射关系。MBI-PBI-ResNet 网络具体结构如图 5 所示。为增强 BiLSTM 块的特征提取能力, 设置了两层 BiLSTM, 其中  $M_1$  表示第一层 BiLSTM 的神经元个数,  $M_2$  表示第二层 BiLSTM 的神经元个数, 本文在后续实验中设置了模型参数对比试验以确定其合适的卷积核个数  $K$  和  $L$ , 以及 BiLSTM 的神经元个数  $M_1$  和  $M_2$ 。

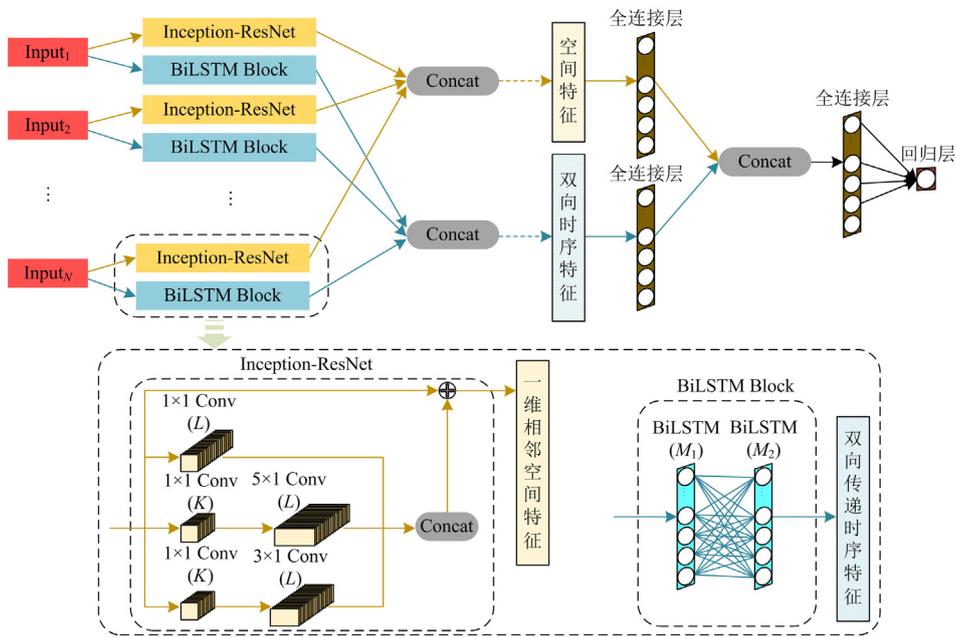


图 5 MBI-PBI-ResNet 网络结构

Fig. 5 MBI-PBI-ResNet network structure

### 3 实验框架及流程

本文首先利用 Pearson 相关系数和 Spearman 秩相关系数, 确定与光伏发电功率数据相关性强和相关性中等的环境变量为辐照度、风速和温度, 再采用 FFT 提取每一天太阳辐照度数据的期望频率, 将其作为每一天的聚类特征向量, 利用 AdAP 将一年的光伏发电功率数据分为 4 类, 分别对应晴天、少云、多云和极端天气。随后使用 SWD 分别对 4 类光伏发电功率数据进行分解, 使每一类光伏发电功率数据被分解为多条子分量  $IMF_1 \sim IMF_N$  和 1 条残余分量  $R$ 。然后将每一类中分解得到的所有分量进行 Min-Max 归一化处理, 同时由于辐照度、温度和风速与光伏发电功率呈极强相关性或中等相关性,

故将与每一类中光伏发电功率对应的辐照度、温度和风速数据也进行 Min-Max 归一化处理, 并根据 MBI-PBI-ResNet 网络模型构造输入所需的辐照度特征量  $Input_I$ 、温度特征量  $Input_T$ 、风速特征量  $Input_S$  和光伏发电功率特征量  $IMF_1 \sim IMF_N$ 。1 步实验时, 输入光伏功率分解后所有子分量的前 48 个数据点, 即每条光伏发电功率特征量大小为  $48 \times 1$ , 共有  $N$  条光伏发电功率特征量, 再加上辐照度、温度和风速序列的前 48 个点, 即辐照度特征量  $Input_I$ 、温度特征量  $Input_T$  和风速特征量  $Input_S$  大小都为  $48 \times 1$ , 输出第 49 个光伏功率数据点。6 步实验时, 输入光伏功率分解后所有子分量的前 48 个数据点, 加上辐照度、温度和风速序列的前 48 个点, 输出第

49—54 个光伏功率数据点, 每组输入输出数据根据步长需要依次往后调整。将光伏发电功率特征量  $Input_1 - Input_N$  输入到 MBI-PBI-ResNet 网络模型中, 利用 Inception-ResNet 结构提取每一条光伏发电功率特征的一维相邻空间特征, BiLSTM 块结构提取每一条光伏发电功率特征的双向传递时序特征, 将每一条光伏发电功率特征的一维相邻空间特

征和双向传递时序特征各自组合, 得到输入的光伏发电功率数据的空间特征和双向时序特征, 再将其结合即可得到输入的光伏发电功率数据的时空特征。最后将提取到的光伏发电功率数据的时空特征和对应的辐照度、风速、温度数据的深层时序特征相结合来提高光伏发电功率的预测精度。具体实验预测流程如图 6 所示。

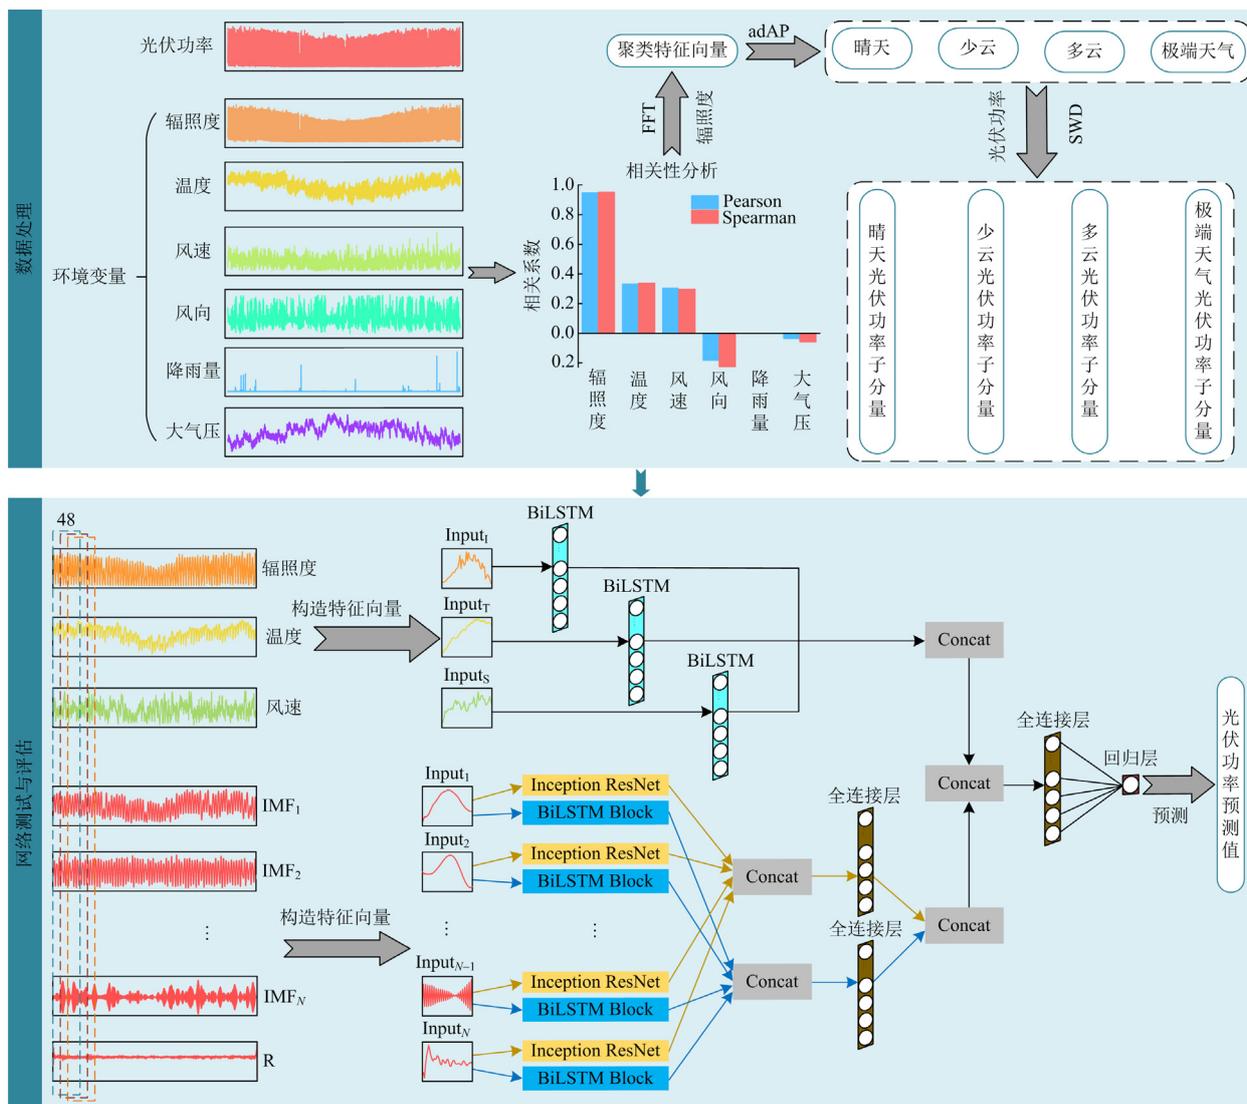


图 6 预测流程

Fig. 6 Prediction process

#### 4 实验及其结果分析

本文分别设置了模型参数对比实验、分解对比实验和模型对比试验, 利用模型参数对比试验验证本文所提模型参数设置的合理性, 利用分解对比试验验证群分解算法相较其他分解算法对光伏发电功

率数据的适用性, 利用模型对比实验验证本文模型相较于其他模型在光伏发电功率预测领域的优势。本文所有对比实验都循环 10 次, 最后以 10 次实验结果的平均值作为最终结果, 且 4 类天气类型下所有实验均随机选择此类天气类型下 3 天的光伏功率数据作为测试样本, 其余天数数据作为训练样本。

为了对本文实验结果进行评估, 选用平均绝对误差( $e_{MAE}$ )、平均绝对百分比误差( $e_{MAPE}$ )、均方根误差( $e_{RMSE}$ )和决定系数( $R^2$ )作为性能评价函数, 其具体表达式如下。

$$e_{MAE} = \frac{1}{n} \sum_{i=1}^n |P_i - \hat{P}_i| \quad (12)$$

$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_i - \hat{P}_i}{P_i} \right| \quad (13)$$

$$e_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - \hat{P}_i)^2} \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (P_i - \hat{P}_i)^2}{\sum_{i=1}^n (P_i - \bar{P})^2} \quad (15)$$

式中:  $P_i$  表示光伏功率真实值;  $\hat{P}_i$  表示光伏功率预测

值;  $\bar{P}$  表示预测日对应的光伏功率真实值的平均值。

#### 4.1 模型参数对比实验

由于卷积核的数量对模型的预测性能有较大影响, 太少的卷积核个数导致卷积层提取到的特征量过少, 模型拟合能力较差, 而太多的卷积核个数会导致计算量过大, 可能出现过拟合现象, 而 BiLSTM 层的神经元个数也会对模型的性能有较大影响。因此为了确定 MBI-PBI-ResNet 网络模型中 BiLSTM 块内两层 BiLSTM 的神经元个数  $M_1$ 、 $M_2$  和 Inception-ResNet 内不同卷积层的卷积核个数  $K$ 、 $L$ , 本文对不同卷积层和不同 BiLSTM 层设置了不同的卷积核个数和神经元个数, 用实验结果来确定最合适的卷积核个数和神经元个数。其中卷积层激活函数都设置为 Leaky ReLU, BiLSTM 层的激活函数都设置为 ReLU。模型参数对比实验以极端天气下 6 步实验为例, 实验结果如表 3 所示。

表 3 不同模型参数的实验误差对比

Table 3 Experimental error comparison of different model parameters

| 模型参数   | 卷积核数      |           | 神经元数       |            | 评价指标         |               |               |
|--------|-----------|-----------|------------|------------|--------------|---------------|---------------|
|        | $K$       | $L$       | $M_1$      | $M_2$      | $e_{MAE}$    | $e_{MAPE}$    | $e_{RMSE}$    |
| 确定卷积核数 | 16        | 16        | 128        | 256        | 2.4664       | 0.0706        | 3.4038        |
|        | <b>16</b> | <b>32</b> | <b>128</b> | <b>256</b> | <b>2.055</b> | <b>0.0588</b> | <b>2.9835</b> |
|        | 32        | 32        | 128        | 256        | 2.4352       | 0.0697        | 3.5007        |
| 确定神经元数 | 16        | 32        | 128        | 128        | 2.6394       | 0.0755        | 3.5783        |
|        | <b>16</b> | <b>32</b> | <b>128</b> | <b>256</b> | <b>2.055</b> | <b>0.0588</b> | <b>2.9835</b> |
|        | 16        | 32        | 256        | 256        | 2.6771       | 0.0766        | 3.7362        |

由表 3 可知, 当 Inception-ResNet 中卷积核数量  $K$  和  $L$  分别为 16 和 32, 且 BiLSTM 层中神经元数量  $M_1$  和  $M_2$  分别为 128 和 256 时, 本文所提出的 MBI-PBI-ResNet 网络模型预测效果最佳, 说明此时本文模型的整体特征提取能力最强, 参数设置最为合适。

#### 4.2 分解对比试验

光伏发电功率序列可分解为多条不同尺度下复杂度较低的子序列, 以此降低原始功率信号的复杂度, 进而增强深度学习模型提取输入信号深层特征的能力, 最终提高模型预测精度。但由于不同模态分解算法的数学机理不同, 导致分解所得子分量的数量和波动规律也不相同, 因此采用合适的模态分解算法进行光伏发电功率预测极为重要。本文以极端天气下 1 步、3 步、6 步实验为例, 分别采用改进自适应白噪声完全集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)、奇异谱分解(singular spectrum decomposition, SSD)、连续变分模式分解

(successive variational mode decomposition, SVMD)和 SWD 分解算法对极端天气功率数据进行分解, 经归一化处理输入到 MBI-PBI-ResNet 网络模型中, 并将辐照度、温度和风速也进行归一化处理输入到网络模型中用以辅助预测, 由实验结果确定超短期光伏发电功率预测下最合适的模态分解算法, 实验结果如表 4 所示。

由表 4 可知, 本文使用的 SWD 分解算法在极端天气下光伏功率 1 步、3 步、6 步实验所得  $e_{MAE}$ 、 $e_{MAPE}$ 、 $e_{RMSE}$  均低于其余 3 种分解算法, 在极端天气类型下进行光伏功率 1 步实验时, 本文分解方法所得  $e_{MAPE}$  相较于其他分解方法降低了 35.74% 以上; 在极端天气类型下进行光伏功率 3 步实验时, 本文分解方法所得  $e_{MAPE}$  相较于其他分解方法降低了 19.78% 以上; 在极端天气类型下进行光伏功率 6 步实验时, 本文分解方法所得  $e_{MAPE}$  相较于其他分解方法降低了 5% 以上。说明 SWD 分解算法可有效提取原始光伏功率序列的多尺度波动规律特征, 更利于深度学习网络模型提取光伏功率的时空特征,

提高深度学习网络模型在超短期光伏发电功率预测领域的性能。

表 4 不同分解算法的实验误差对比

Table 4 Experimental error comparison of different decomposition algorithms

| 分解算法     | $e_{MAE}$    |               |              | $e_{MAPE}$    |               |               | $e_{RMSE}$    |               |               |
|----------|--------------|---------------|--------------|---------------|---------------|---------------|---------------|---------------|---------------|
|          | 1步           | 3步            | 6步           | 1步            | 3步            | 6步            | 1步            | 3步            | 6步            |
| ICEEMDAN | 4.3355       | 9.257         | 11.7769      | 0.124         | 0.2648        | 0.3369        | 6.0182        | 11.5731       | 15.9892       |
| SVMD     | 4.6764       | 6.7671        | 7.4929       | 0.1338        | 0.1936        | 0.2144        | 6.7584        | 8.7073        | 9.3292        |
| SSD      | 0.9677       | 1.5736        | 2.1638       | 0.0277        | 0.045         | 0.0619        | 1.1371        | 2.0107        | 3.8344        |
| SWD      | <b>0.621</b> | <b>1.2633</b> | <b>2.055</b> | <b>0.0178</b> | <b>0.0361</b> | <b>0.0588</b> | <b>0.7967</b> | <b>1.6658</b> | <b>2.9835</b> |

### 4.3 模型对比试验

为了验证本文提出的 MBI-PBI-ResNet 深度学习模型在光伏发电功率预测领域的优势, 分别将 4 类天气类型都经过群分解并归一化处理, 输入到与本文模型不同的其他方法的深度学习模型中, 且将对光伏发电功率呈极强和中等相关性的环境变量(辐照度、温度和风速)输入到模型中用以辅助预测。

为验证本文模型的泛化能力, 分别对 4 类天气类型都采用不同的深度学习模型进行 1 步、3 步、6 步和 16 步预测。本文选取了 CNN-LSTM 模型<sup>[7]</sup>、P-BiLSTM-DCNN 模型<sup>[9]</sup>和 CNN-BiLSTM 模型<sup>[27]</sup>与本文的深度学习模型进行实验对比, 具体实验结果如表 5 和图 7 所示。

表 5 不同预测模型的实验误差对比

Table 5 Experimental error comparison of different prediction models

| 天气类型 | 模型            | $e_{MAPE}$    |               |               |               | $R^2$         |               |               |               |
|------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|
|      |               | 1步            | 3步            | 6步            | 16步           | 1步            | 3步            | 6步            | 16步           |
| 晴天   | CNN-LSTM      | 0.0116        | 0.0156        | 0.0231        | 0.1204        | 0.9994        | 0.9991        | 0.9979        | 0.9676        |
|      | P-BiLSTM-DCNN | 0.0103        | 0.0136        | 0.0165        | 0.0367        | 0.9987        | 0.9982        | 0.9943        | 0.9947        |
|      | PCNN-BiLSTM   | 0.01          | 0.0118        | 0.0157        | 0.0662        | 0.9994        | 0.9992        | 0.9992        | 0.9837        |
|      | 本文模型          | <b>0.0086</b> | <b>0.0097</b> | <b>0.0127</b> | <b>0.0203</b> | <b>0.9997</b> | <b>0.9994</b> | <b>0.9993</b> | <b>0.9981</b> |
| 少云   | CNN-LSTM      | 0.0123        | 0.0183        | 0.0251        | 0.1297        | 0.9989        | 0.9981        | 0.9976        | 0.9599        |
|      | P-BiLSTM-DCNN | 0.0115        | 0.0127        | 0.0173        | 0.056         | 0.9992        | 0.9985        | 0.9984        | 0.9826        |
|      | PCNN-BiLSTM   | 0.011         | 0.0195        | 0.0312        | 0.0867        | 0.9993        | 0.9978        | 0.9961        | 0.9706        |
|      | 本文模型          | <b>0.0107</b> | <b>0.0119</b> | <b>0.015</b>  | <b>0.0351</b> | <b>0.9993</b> | <b>0.9986</b> | <b>0.9986</b> | <b>0.9941</b> |
| 多云   | CNN-LSTM      | 0.0256        | 0.035         | 0.0559        | 0.2727        | 0.9984        | 0.9977        | 0.9939        | 0.8597        |
|      | P-BiLSTM-DCNN | 0.0143        | 0.0215        | 0.0475        | 0.1513        | 0.9993        | 0.9988        | 0.9952        | 0.9539        |
|      | PCNN-BiLSTM   | 0.0202        | 0.0402        | 0.0568        | 0.2289        | 0.999         | 0.9961        | 0.9914        | 0.8579        |
|      | 本文模型          | <b>0.012</b>  | <b>0.0184</b> | <b>0.0317</b> | <b>0.0875</b> | <b>0.9996</b> | <b>0.9991</b> | <b>0.9991</b> | <b>0.9869</b> |
| 极端天气 | CNN-LSTM      | 0.0378        | 0.1479        | 0.2342        | 0.4168        | 0.9969        | 0.9597        | 0.8822        | 0.6497        |
|      | P-BiLSTM-DCNN | 0.0197        | 0.0546        | 0.1244        | 0.2964        | 0.999         | 0.9948        | 0.9626        | 0.777         |
|      | PCNN-BiLSTM   | 0.0488        | 0.1207        | 0.2397        | 0.4382        | 0.9957        | 0.9674        | 0.8572        | 0.5878        |
|      | 本文模型          | <b>0.0178</b> | <b>0.0361</b> | <b>0.0588</b> | <b>0.1076</b> | <b>0.9995</b> | <b>0.9976</b> | <b>0.9921</b> | <b>0.9716</b> |

由表 5 可知, 本文所提出的 MBI-PBI-ResNet 深度学习模型在超短期光伏发电功率预测实验下的预测误差  $e_{MAPE}$  均比其他模型更低, 说明本文模型在光伏功率预测领域的预测性能更佳。由图 7 可知, 在功率信号波动幅度小的晴天、少云天气类型预测实验下, 其他文献模型与本文模型都能较为精确地预测到未来光伏功率信号的变化规律。但是, 当对功率信号波动幅度很大的极端天气类型进行多步实验时, 只有本文模型在各类天气类型下得到的决定

系数 ( $R^2$ ) 能一直保持在 0.97 以上。本文模型在极端天气类型的 1 步试验下得到的决定系数 ( $R^2$ ) 相对于其他模型提高了 0.05% 以上; 在极端天气类型的 3 步试验下得到的决定系数 ( $R^2$ ) 相对于其他模型提高了 0.28% 以上; 在极端天气类型的 6 步试验下得到的决定系数 ( $R^2$ ) 相对于其他模型提高了 3.06% 以上; 在极端天气类型的 16 步试验下得到的决定系数 ( $R^2$ ) 相对于其他模型提高了 25.04% 以上。说明本文

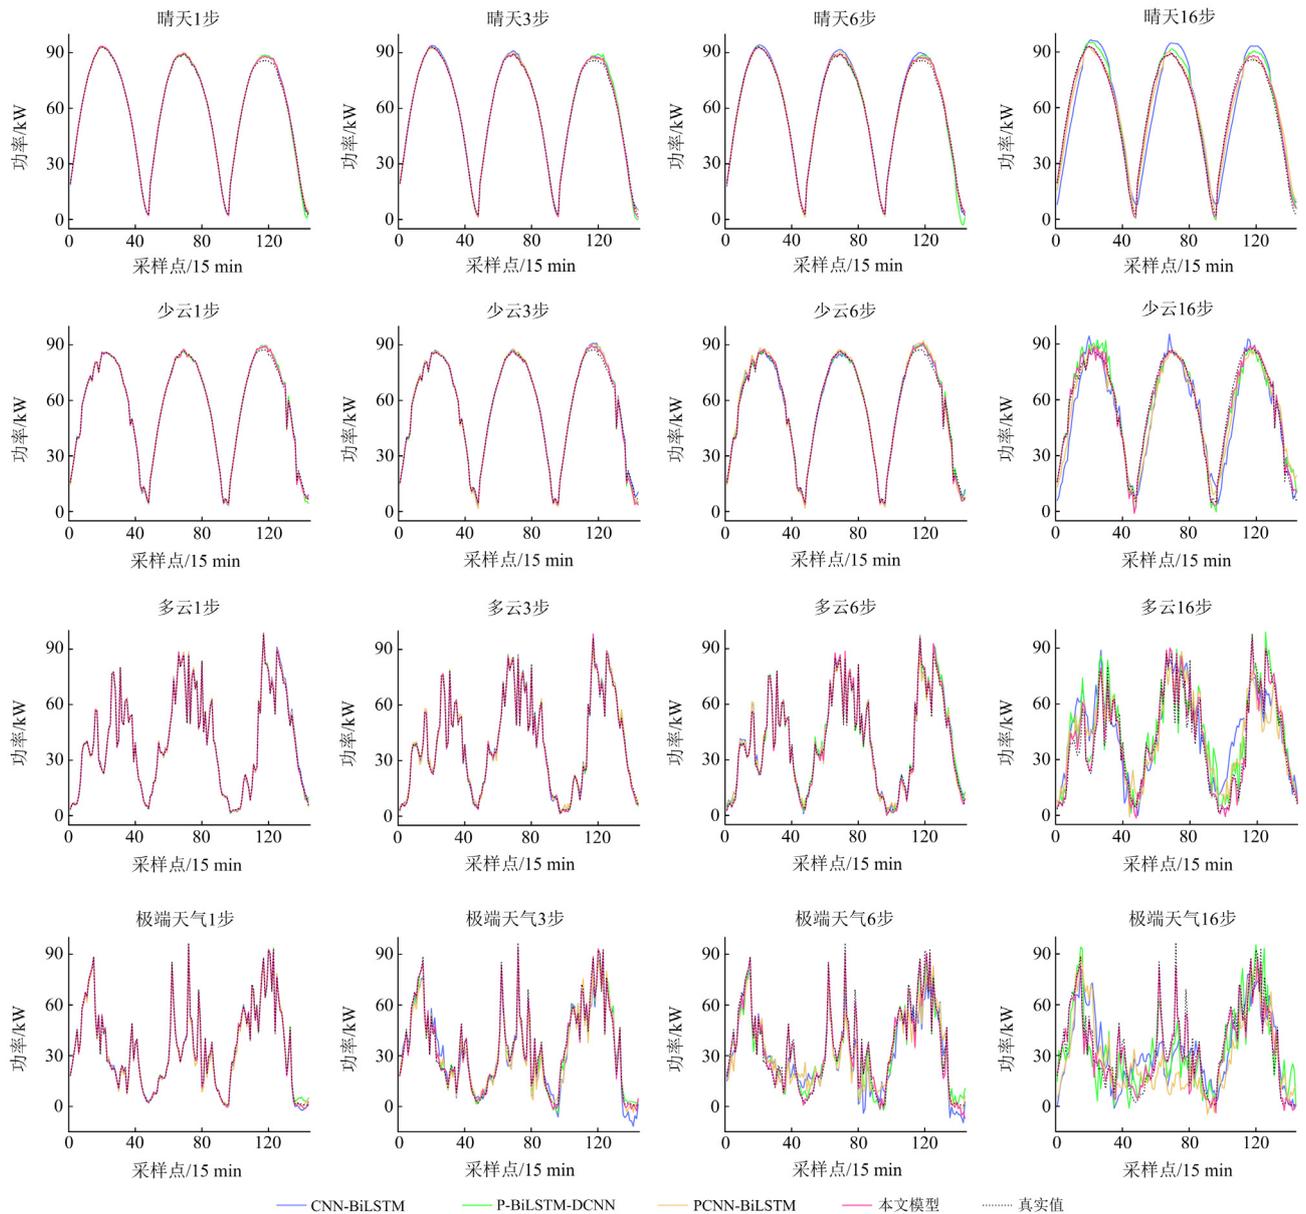


图 7 不同预测模型实验结果

Fig. 7 Experimental results of different prediction models

模型在极端天气类型的多步实验下仍能较好地预测到未来光伏功率信号的变化细节，所以本文模型相较于其他文献模型具有较好的泛化能力。

### 5 结论与展望

1) 通过 FFT 提取每一天太阳辐照度数据的期望频率，并将其作为聚类特征向量，利用 AdAP 聚类方法可有效地将波动规律差异很大的太阳辐照度数据分开，再按类分别进行预测即可有效提高光伏发电功率的预测精度。

2) 利用 SWD 分解算法对原始发电功率进行分

解，可得到多条不同波动规律的子分量，有效降低了原始功率序列的复杂度，使深度学习网络模型更容易学习到当前光伏功率与未来光伏功率之间的复杂映射关系。且经分解对比实验验证，SWD 分解算法对光伏发电功率进行分解后输入到深度学习网络模型中预测未来光伏功率，相较于其他分解算法，平均绝对百分比误差 ( $e_{MAPE}$ ) 降低了 5% 以上，说明了 SWD 分解算法在光伏发电功率预测领域中对光伏功率信号进行分解处理的适用性。

3) 本文提出的 MBI-PBI-ResNet 深度学习网络模型可充分挖掘光伏发电功率子分量的时空特征，

结合环境变量的深层时序特征来共同预测可得到较好的预测效果。相比于其他深度学习网络模型,本文模型在提前 1~4 h 的光伏功率预测实验中得到的决定系数 ( $R^2$ ) 提高了 3% 以上。说明本文模型在超短期光伏发电功率预测领域具有更好的预测精度和泛化能力。

4) 本文应用分解方法时将训练集单独分解后再将测试集和训练集放在一起对整个数据集进行分解。这样虽然可以避免测试数据集中包含的信息泄漏到训练数据集的分解结果中,但由于整个训练数据集是一起分解的,所以在训练阶段仍然存在未来信息泄漏问题,将整个数据集分解来得到测试集的分解结果虽然可以减少测试集端点效应的影响,但由于其是统一对整个数据集进行分解,所以在测试集中会涉及到部分的未来信息泄漏问题,因此边界问题仍旧存在<sup>[28]</sup>。而由于训练集单独分解与整个数据集分解时的时间序列长度不同,所以还可能会出现分解级别不同的问题,因此后续应针对此问题进行改进以开展下一步研究。

5) 随着信号处理技术和深度学习的发展,可对本文所提出的组合预测方法进行改进或将本文方法尝试应用于更多领域,以此来进一步体现本文方法的研究价值。

## 参考文献

- [1] 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, TUSONGJIANG Kari, YILIHAMU Yaermaimaiti, et al. Prediction of short-term photovoltaic power based WGAN-GP and CNN-LSTM-Attention[J]. Power System Protection and Control, 2023, 51(9): 108-118.
- [2] 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.
- [3] 贾德香, 吕干云, 林芬, 等. 基于 SAPSO-BP 和分位数回归的光伏功率区间预测[J]. 电力系统保护与控制, 2021, 49(10): 20-26. JIA Dexiang, LÜ Ganyun, LIN Fen, et al. Photovoltaic power interval prediction based on SAPSO-BP and quantile regression[J]. Power System Protection and Control, 2021, 49(10): 20-26.
- [4] 董志强, 郑凌蔚, 苏然, 等. 一种基于 IGWO-SNN 的光伏出力短期预测方法[J]. 电力系统保护与控制, 2023, 51(1): 131-138. DONG Zhiqiang, ZHANG Lingwei, SU Ran, et al. An IGWO-SNN-based method for short-term forecast of photovoltaic output[J]. Power System Protection and Control, 2023, 51(1): 131-138.
- [5] 王开艳, 杜浩东, 贾嵘, 等. 基于相似日聚类 and QR-CNN-BiLSTM 模型的光伏功率短期区间概率预测[J]. 高电压技术, 2022, 48(11): 4372-4388. WANG Kaiyan, DU Haodong, JIA Rong, et al. Short-term interval probability prediction of photovoltaic power based on similar daily clustering and QR-CNN-BiLSTM model[J]. High Voltage Engineering, 2022, 48(11): 4372-4388.
- [6] 魏震波, 余雷. 基于 FFT, DC-HC 及 LSTM 的短期负荷预测方法[J]. 智慧电力, 2022, 50(3): 37-43. WEI Zhenbo, YU Lei. Short-term load forecasting method based on FFT, DC-HC and LSTM[J]. Smart Power, 2022, 50(3): 37-43.
- [7] GAO Bixuan, HUANG Xiaoqiao, SHI Junsheng, et al. Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks[J]. Renewable Energy, 2020, 162.
- [8] 吴迪, 王梓宇, 赵伟超. ELMo-CNN-BiGRU 双通道文本情感分类模型[J]. 计算机工程, 2022, 48(8): 105-112. WU Di, WANG Ziyu, ZHAO Weichao. ELMo-CNN-BiGRU dual-channel text sentiment classification model[J]. Computer Engineering, 2022, 48(8): 105-112.
- [9] TANG Yugui, YANG Kuo, ZHANG Shujing, et al. Photovoltaic power forecasting: a hybrid deep learning model incorporating transfer learning strategy[J]. Renewable and Sustainable Energy Reviews, 2022, 162.
- [10] 郑文栋, 王辉, 钱勇, 等. 基于自适应仿射传播聚类的 GIS 局放缺陷分类研究[J]. 高压电器, 2013, 49(8): 50-55. ZHENG Wendong, WANG Hui, QIAN Yong, et al. Pattern recognition of partial discharge in GIS based on the adaptive affinity propagation clustering algorithm[J]. High Voltage Apparatus, 2013, 49(8): 50-55.
- [11] 王金东, 高鹏超, 赵海洋, 等. 基于 SWD 与 MEMDE 的往复压缩机轴承故障诊断方法[J]. 轴承, 2021(11): 65-69. WANG Jingdong, GAO Pengchao, ZHAO Haiyang, et al. Fault diagnosis method for reciprocating compressor bearings based on SWD and MEMDE[J]. Bearing, 2021(11): 65-69.
- [12] QU Jiaqi, QIAN Zheng, PEI Yan. Day-ahead hourly photovoltaic power forecasting using attention-based CNN-LSTM neural network embedded with multiple

relevant and target variables prediction pattern[J]. Energy, 2021, 232.

[13] 李斌, 张一凡, 颜世焯, 等. 基于改进极限学习机 ELM 的光伏发电预测方法研究[J]. 热能动力工程, 2022, 37(10): 207-214.  
LI Bin, ZHANG Yifan, YAN Shiye, et al. Research on photovoltaic power generation prediction method based on improved extreme learning machine(ELM)[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(10): 207-214.

[14] 贾鹏云. 基于深度学习算法的短期光伏发电功率预测研究[D]. 北京: 华北电力大学, 2021.  
JIA Pengyun. Short-term photovoltaic power forecasting based on deep learning algorithm[D]. Beijing: North China Electric Power University, 2021.

[15] 冯立恒. 环境因素对户外光伏板发电效率的影响[J]. 电气技术与经济, 2019(5): 28-30.  
FENG Liheng. The influence of environmental factors on the power generation efficiency of outdoor PV panels[J]. Electrical Equipment and Economy, 2019(5): 28-30.

[16] 王开军, 张军英, 李丹, 等. 自适应仿射传播聚类[J]. 自动化学报, 2007(12): 1242-1246.  
WANG Kaijun, ZHANG Junying, LI Dan, et al. Adaptive affinity propagation clustering[J]. Acta Automatica Sinica, 2007(12): 1242-1246.

[17] SANDRINE D, JANE F. A prediction-based resampling method for estimating the number of clusters in a dataset[J]. Genome Biology, 2002, 3(7).

[18] KAUFMAN L, ROUSSEEUW P J. Finding groups in data: an introduction to cluster analysis[M]. John Wiley Sons, Inc., 1990.

[19] APOSTOLIDIS G K, HADJILEONTIADIS L J. Swarm decomposition: a novel signal analysis using swarm intelligence[J]. Signal Processing, 2017, 132.

[20] 孙丹铭. SSL4-1800 冲压设备电机轴承故障诊断与剩余寿命预测[D]. 沈阳: 沈阳工业大学, 2022.

[21] 朱阳光, 刘瑞敏, 黄琼桃. 基于深度神经网络的弱监督信息细粒度图像识别[J]. 电子测量与仪器学报, 2020, 34(2): 115-122.  
ZHU Yangguang, LIU Ruimin, HUANG Qiongtao. Fine-grained image recognition of weak supervisory information based on deep neural network[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2): 115-122.

[22] 薛晓璇. 基于数据挖掘的用户行为特征挖掘研究[J]. 自动化与仪器仪表, 2021(12): 16-19.  
XUE Xiaoxuan. Research on user behavior characteristic mining based on data mining[J]. Automation & Instrumentation, 2021(12): 16-19.

[23] SZEGEDY C, IOFFE S, VANHOUCKE V. Inception-v4, inception-ResNet and the impact of residual connections on learning[C]//AAAI'17: Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, February 4-9, 2017, San Francisco, CA, USA: 4278-4284.

[24] 贾嘉敏, 潘文林. 基于改进 Inception-ResNet\_v2 的低资源少数民族语音识别[J]. 软件导刊, 2022, 21(8): 51-55.  
JIA Jiamin, PAN Wenlin. Low resource minority speech recognition based on improved Inception-ResNet\_v2[J]. Software Guide, 2022, 21(8): 51-55.

[25] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks, 2005, 18(5/6): 602-610.

[26] BALDI P, BRUNAK S, FRASCONI P, et al. Exploiting the past and the future in protein secondary structure prediction[J]. Bioinformatics, 1999, 15(11): 937-946.

[27] 毕贵红, 赵鑫, 陈臣鹏, 等. 基于多通道输入和 PCNN-BiLSTM 的光伏发电功率超短期预测[J]. 电网技术, 2022, 46(9): 3463-3476.  
BI Guihong, ZHAO Xin, CHEN Chenpeng, et al. Ultra-short-term prediction of photovoltaic power generation based on multi-channel input and PCNN-BiLSTM[J]. Power System Technology, 2022, 46(9): 3463-3476.

[28] CHEN Yinsong, YU S, ISLAM S, et al. Decomposition-based wind power forecasting models and their boundary issue: an in-depth review and comprehensive discussion on potential solutions[J]. Energy Reports, 2022, 8.

收稿日期: 2023-07-10; 修回日期: 2023-11-03

作者简介:

黄 泽(1999—), 男, 硕士研究生, 研究方向为电力电子与新能源发电技术; E-mail: 1004403104@qq.com

毕贵红(1968—), 男, 通信作者, 博士, 教授, 硕导, 研究方向为新能源系统建模、优化与智能数据分析; E-mail: KM\_BGH@163.com

谢 旭(1996—), 男, 硕士, 研究方向为人工智能算法在电力系统中的应用。E-mail: 369905413@qq.com

(编辑 许 威)