

## 激光与光电子学进展

基于奇异谱分解和双重注意力机制的  
超短期光伏功率预测方法董雪<sup>1,2,3</sup>, 赵生校<sup>1,2</sup>, 陆艳艳<sup>1,2</sup>, 陈晓锋<sup>1,2</sup>, 赵岩<sup>1,2</sup>, 刘磊<sup>3\*</sup>

<sup>1</sup>浙江省深远海风电技术研究重点实验室, 浙江 杭州 311122;  
<sup>2</sup>中国电建集团华东勘测设计研究院有限公司, 浙江 杭州 311122;  
<sup>3</sup>中国科学技术大学工程科学学院, 安徽 合肥 230026

**摘要** 准确的光伏功率预测可以有效促进光伏发电的安全高效利用。针对现有方法预测精度不足的问题,提出一种结合奇异谱分解(SSD)、双重注意力机制和双向门控逻辑单元(BiGRU)时序建模的超短期光伏功率预测方法。首先利用SSD降低光伏信号的随机性和波动性;然后利用BiGRU网络对分解后的信号进行时序建模,并设计了一种同时学习特征序列和时序序列的重要性权重的注意力模块,对BiGRU网络提取的特征进行权重加权;最后经过决策层获得最终的光伏功率预测结果。实验结果表明,SSD和注意力机制可以有效提升深度时序模型的光伏功率预测精度,在不同季节和不同天气情况下均优于其他几种经典方法,具有较高的实用价值。

**关键词** 光电子学; 光伏功率预测; 超短期; 奇异谱分解; 注意力机制

中图分类号 TM615

文献标志码 A

DOI: 10.3788/LOP213335

Ultra-Short-Term Forecasting Method for Photovoltaic Power Based on  
Singular Spectrum Decomposition and Double Attention MechanismDong Xue<sup>1,2,3</sup>, Zhao Shengxiao<sup>1,2</sup>, Lu Yanyan<sup>1,2</sup>, Chen Xiaofeng<sup>1,2</sup>, Zhao Yan<sup>1,2</sup>, Liu Lei<sup>3\*</sup>

<sup>1</sup>Key Laboratory of Far-Shore Wind Power Technology of Zhejiang Province, Hangzhou 311122, Zhejiang, China;

<sup>2</sup>Power China Huadong Engineering Corporation Limited, Hangzhou 311122, Zhejiang, China;

<sup>3</sup>School of Engineering Science, University of Science and Technology of China, Hefei 230026, Anhui, China

**Abstract** Accurate forecasting of photovoltaic power can effectively promote safe and efficient generation and utilization of photovoltaic power. Accordingly, an ultra-short-term photovoltaic power prediction method combining singular spectrum decomposition (SSD), double-attention mechanism, and bidirectional gating logic unit (BiGRU) time-series modeling is proposed to address the insufficient forecasting accuracy of existing methods. First, SSD is used to reduce the randomness and volatility of photovoltaic signals. A BiGRU network is then adopted to model the time series of the decomposed signals. Additionally, an attention module is designed to simultaneously learn the importance (weight) of the feature and time series by weighting the features extracted by the BiGRU network. The final forecast of photovoltaic power is obtained via the decision-making layer. The experimental results demonstrate that the SSD and attention mechanism can improve the accuracy of forecasts obtained from the deep time-series model. The proposed method is superior to several other conventional methods and is highly practical for different seasons and weather conditions.

**Key words** optoelectronics; photovoltaic power forecasting; ultra-short term; singular spectrum decomposition; attention mechanism

## 1 引言

太阳能作为最有前途的可再生能源之一,是人类应对能源挑战的一个重要手段<sup>[1]</sup>。光伏发电功率具有

随机性和波动性<sup>[2]</sup>,给大规模光伏发电并网的安全稳定和经济运行带来了挑战<sup>[3-4]</sup>,准确的光伏功率预测对智能电网系统的集成、运行和调度起着至关重要的作用<sup>[5]</sup>。

收稿日期: 2021-12-24; 修回日期: 2022-02-20; 录用日期: 2022-02-25; 网络首发日期: 2022-03-09

基金项目: 国家自然科学基金(U19B2044,U1865102)

通信作者: liulei13@ustc.edu.cn

由于短期和超短期光伏功率预测可以为电力调度和并网安全提供可靠的电力暂态信息<sup>[6]</sup>,因此,目前光伏功率预测研究主要集中在短期和超短期光伏功率预测上<sup>[7]</sup>。光伏功率预测大致可以分为物理方法和统计方法。物理方法计算复杂且耗时较长,统计方法具有更快的计算速度和更高的精度,在光伏功率预测中应用广泛。

深度学习作为一种重要的统计方法,具有强大的非线性映射能力,已广泛应用于光伏发电领域。由于光伏发电具有时序性,许多研究者采用长短期记忆(LSTM)网络和门控逻辑单元(GRU)网络对光伏功率预测进行时序建模。文献[8]分别利用卷积神经网络(CNN)、LSTM和两者的混合模型进行光伏功率预测,并对3种网络的预测效果进行比较。文献[9]将LSTM网络与注意力机制相结合,使得光伏功率预测模型对长时间序列输入的处理更加有效。文献[10]利用双向长短期记忆(BiLSTM)网络对光伏功率进行预测,并实验证明了深度学习方法比浅层方法更有效。文献[11]基于多门控逻辑单元(Multi-GRU)网络进行光伏功率预测,并与几种传统机器学习方法相比较,证明该网络在提高预测速度的同时提高了预测精度。文献[12]提出一种基于粒子群优化(PSO)GRU(PSO-GRU)模型的短期光伏功率预测方法。利用PSO算法对GRU网络的超参数进行优化,提升了模型的预测效果。文献[13]研究了LSTM网络和GRU网络在光伏功率预测中的性能,实验结果表明,GRU网络在多个指标上取得最优效果。

GRU网络有效缓解了传统循环网络(RNN)的长期记忆丢失问题,但在模型训练时对所有特征赋予相同的重要权重,存在注意力分散的问题。为了解决这个问题,一些研究者将注意力机制与GRU时序建模相结合。文献[14]将注意力机制和双向GRU(BiGRU)网络相结合,从不同角度对当前数据进行分析,提升了电网故障检测精度。文献[15]在GRU预测模型中设计注意力模块,进一步提升了太阳能发电区间预测的性能。文献[16]设计了时间注意力模块对输入时序数据进行关键特征提取,再送到GRU网络中,实现电力短期负荷的有效预测。文献[17]提出了一个基于注意力的GRU的短期负荷预测模型,并证明在输入序列较长时,注意力机制可以显著提升网络性能。

信号分解是将原始信号分解为几个内在模态函数,以削弱原始信号的非线性<sup>[18]</sup>。利用信号分解抑制光伏信号的随机性和波动性,在光伏功率预测任务中越来越受到重视<sup>[19]</sup>。文献[20]通过小波分解获得光伏信号中的不同特征分量,并对每个分量进行LSTM时序建模,提升了光伏功率预测的精确率。文献[21]提出一种基于小波变换与神经网络的光伏电站短期功率预测。文献[22]利用变分模态分解(VMD)和双重注意力机制LSTM网络相结合进行短期光伏功率预测。

文献[23]采用小波包分解和快速集成经验模态分解相结合的二次分解算法对原始数据进行预处理,有效降低了数据的不稳定性。文献[24]提出了一种基于VMD、改进麻雀搜索算法和门控循环网络的混合光伏功率预测模型,实验证明信号分解有利于光伏功率预测精度的提升。本文采用奇异谱分解(SSD)进行原始光伏信号的分解。SSD在奇异谱分析(SSA)分解方法的基础上,解决了相移问题,并且可以自适应地选择嵌入维度,避免了复杂的调参过程,已在多种任务中得到应用<sup>[25]</sup>。

为了进一步提升光伏发电功率预测的精确率,本文在前人的基础上,提出了一种融合SSD、双重注意力机制(DAttention)和BiGRU的超短期光伏功率预测方法。首先采用SSD降低输入数据的非线性;然后输入到BiGRU网络中进行时序信号建模,并设计和融合了一种同时学习特征序列和时序序列重要权重的注意力模块,对BiGRU网络的输出进行重要性加权;最后通过决策层获取最终的光伏功率预测结果。与其他经典方法相比,本文提出的方法有效提升了光伏功率预测的精确率。

## 2 数据分析与处理

### 2.1 数据集简介

实验数据选择某光伏发电系统2020年全年共366天的实际光伏发电功率数据,采样间隔为15 min,每天采集96个样本点。本文仅选择具有光伏功率稳定输出的时间段,即每日6:00–18:00的数据(48个样本点)进行仿真分析。为了模型训练和验证方法的预测性能,选择每月前15天的数据作为训练样本集,其余数据作为测试样本集。同时将测试集进行季节划分和天气类型划分,用于光伏功率预测方法的工程性能验证。

### 2.2 特征选择和归一化

光伏发电是将太阳辐射转换成电能,太阳辐照度与光伏发电功率紧密相关,而光伏发电的历史功率与未来时刻的光伏功率具有时序相关性,因此选择太阳辐照度和历史功率作为光伏功率预测网络的输入特征。

为了避免太阳辐照度与光伏历史功率的量纲不同对网络训练产生不利影响,本文采用如下公式进行数据归一化:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (1)$$

式中: $x$ 表示太阳辐照度或光伏历史功率; $x_{\max}$ 表示太阳辐照度或光伏历史功率的最大值; $x_{\min}$ 表示太阳辐照度或光伏历史功率的最小值。

### 2.3 时序序列长度选择

适当的时序序列长度选择有利于BiGRU网络的特征学习,因此,本文计算了前7个时刻的输入信息与

预测功率之间的 Pearson 相关系数。由表 1 可知,随着时滞时间增加,输入信息与预测功率之间的 Pearson 相

关系数值逐渐减小。本文选择前 6 个时刻的输入信息 ( $|\rho| > 0.8$ ) 进行时序建模。

表 1 时滞输入与预测功率之间的 Pearson 系数

Table 1 Pearson coefficients between time-delayed features and photovoltaic power

Variable	$t-1$	$t-2$	$t-3$	$t-4$	$t-5$	$t-6$	$t-7$
Historical power	0.982	0.961	0.933	0.899	0.858	0.812	0.761
Solar irradiance	0.969	0.947	0.920	0.887	0.847	0.802	0.752

### 3 超短期光伏功率预测算法

#### 3.1 SSD

SSD<sup>[26]</sup>是一种信号处理方法,可以将多分量时间序列分为几个子序列。对于多分量时间序列  $\mathbf{x}(n)$ , SSD 方法总结如下:

1) 建立一个新的轨迹矩阵。对于给定的时间序列  $\mathbf{x}(n)$ , 假设嵌入维度为  $m$ , 则可以建立一个矩阵:

$$\mathbf{X} = [\mathbf{x}_1^T, \mathbf{x}_2^T, \dots, \mathbf{x}_m^T]^T. \quad (2)$$

2) 从高频开始依次重建第  $j$  个低频子序列, 建立子集  $I_j (I_j = \{i_1, i_2, \dots, i_p\})$ , 然后通过对矩阵  $\mathbf{X}_{ij} = \mathbf{X}_{i1} + \mathbf{X}_{i2} + \dots + \mathbf{X}_{ip}$  进行对角线平均运算重构对应的子序列。

3) 当残差序列  $\mathbf{v}^{(j+1)}(n)$  和原始序列  $\mathbf{x}(n)$  之间的归一化均方误差低于预定义的阈值  $h$  时, 它将停止 SSD 的分解过程。最终原始时间序列  $\mathbf{x}(n)$  被分解为几个子序列和剩余序列  $\mathbf{v}^{(j+1)}(n)$  之和:

$$\mathbf{x}(n) = \sum_{k=1}^m \mathbf{g}^{(k)}(n) + \mathbf{v}^{(m+1)}(n), \quad (3)$$

式中:  $m$  表示子序列数量;  $\mathbf{g}^{(k)}(n)$  表示第  $k$  个子序列。

#### 3.2 特征时间注意力 (FT-Attention)

注意力机制通过获取信息的重要程度, 实现对信息的选择性学习。为了提高光伏功率预测网络的特征选择和学习能力, 受通道注意力模块 (SE-Block)<sup>[27]</sup> 启发, 针对光伏功率预测问题, 设计了一种简单高效的注意力模块, 称之为特征时间注意力 (FT-Attention)。图 1 为 FT-Attention 模块的结构图。FT-Attention 包含两部分, 分别学习不同特征和不同时刻的重要程度。输入为包含  $h$  个特征和  $w$  个时序时刻的矩阵  $\mathbf{X} \in R^{h \times w}$ , 当对特征进行学习时, 首先通过全局平均池化得到矩阵  $\mathbf{Z}_f = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_h]$ , 其中  $\mathbf{z}_k = 1/w \sum_i^w \mathbf{X}(k, i)$ ; 然后通过两次一维卷积和非线性映射得到权重向量; 最后将权重向量与原始输入矩阵  $\mathbf{X}$  相乘得到特征加权后的矩阵  $\hat{\mathbf{U}}_F$ 。同理可得时序加权后的矩阵  $\hat{\mathbf{U}}_T$ 。经过特征加权和时序加权后的信息  $\hat{\mathbf{U}}_{FT} = \hat{\mathbf{U}}_F + \hat{\mathbf{U}}_T$ 。




图 1 FT-Attention 的结构图

Fig. 1 Structure of feature-temporal attention (FT-Attention)

#### 3.3 BiGRU

GRU<sup>[28]</sup>将输入门和遗忘门合并, 形成更加简洁高效的网络结构。GRU 的计算主要涉及 4 个部分:

1) 重置门。重置门决定放弃前一时刻哪些信

息, 其中  $\mathbf{W}_{xr}$  和  $\mathbf{W}_{hr}$  为权重,  $\mathbf{h}_{t-1}$  为前一时刻的输入, 则有

$$\mathbf{R}_t = \sigma(\mathbf{W}_{xr} \mathbf{x}_t + \mathbf{W}_{hr} \mathbf{h}_{t-1} + \mathbf{B}_r). \quad (4)$$

2) 更新门。更新门选择并更新当前时刻的信

息为

$$Z_t = \sigma(W_{xz}x_t + W_{hz}h_{t-1} + B_z) \quad (5)$$

3) 计算候选记忆内容为

$$\tilde{h}_t = \tanh[W_{xh}x_t + W_{hh}(R_t \odot h_{t-1}) + B] \quad (6)$$

4) 计算输出结果为

$$h_t = (1 - z_t)h_{t-1} + \tilde{h}_t \quad (7)$$

BiGRU 网络是由两个方向相反的 GRU 网络构成, 每个节点都可获取整个输入序列的信息, 能够更好地对整个输入时序序列进行特征表达。

### 3.4 功率预测算法框架

本文方法的框架流程如图 2 所示。首先从光伏数据中选择太阳辐照度和历史功率作为输入信息; 其次经过数据预处理后, 进行 SSD, 获得  $m$  个不同中心频率的辐照度分量和  $n$  个不同中心频率的历史功率分量; 再次, 将各分量输入到 BiGRU 网络中进行时序信息建模, 并通过 FT-Attention 模块对时序建模的输出进行特征维度及时序维度的权重学习; 最后经过双层全连接层 (FC) 进行决策, 获得光伏预测功率。

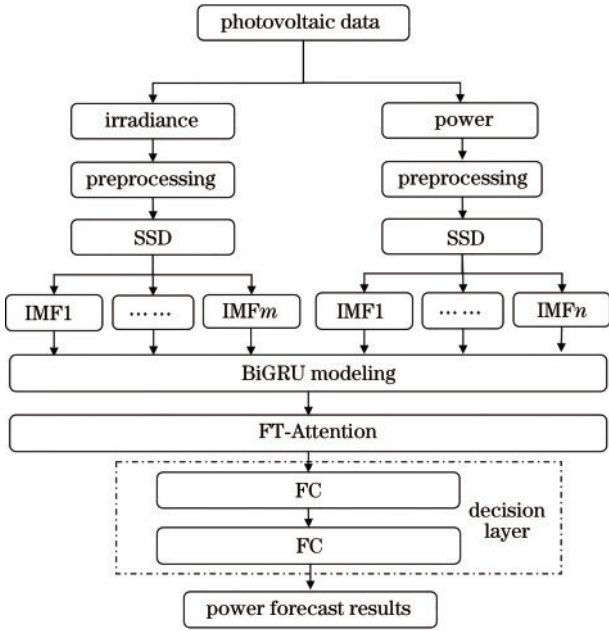


图 2 超短期光伏功率预测方法流程图

Fig. 2 Flow chart of ultra-short-term photovoltaic power forecasting method

以光伏功率为例, 原始信号经过 SSD, 结果如图 3 所示 (仅展示前 5 个分解信号), 可以看出, 原始信号波动的突变性较强, 且不具备明显的波动规律。经过 SSD 后得到一系列不同中心频率的简单信号, 降低了原始信号的非线性, 有利于提升后续网络的学习效果。

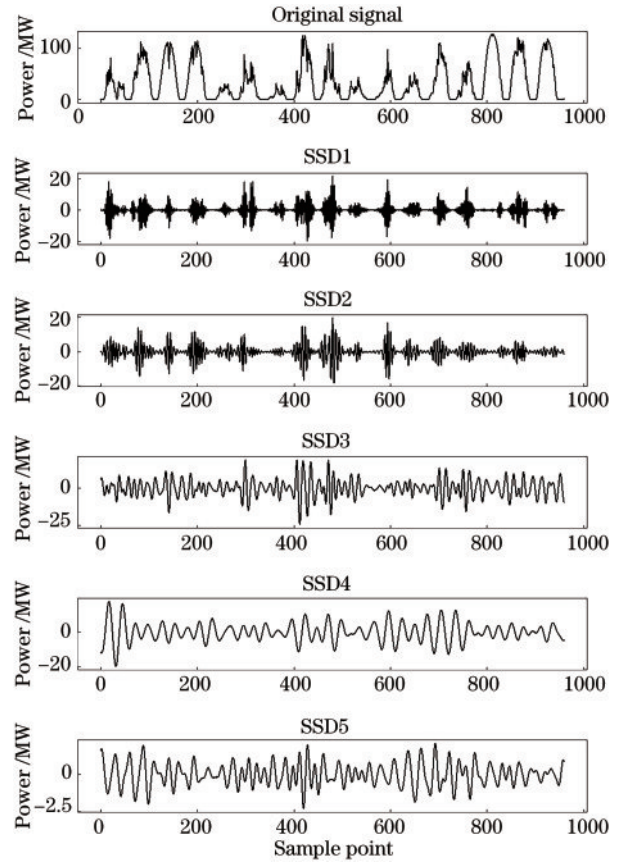


图 3 原始信号的 SSD 结果

Fig. 3 SSD results of original signals

## 4 实验结果与分析

### 4.1 评价指标

单一评价指标不能够全面分析模型的预测效果, 为了综合评价本文方法的性能, 以下采用标准平均绝对误差 (NMAE)、标准化均方根误差 (NRMSE)、平均绝对百分比误差 (MAPE)、 $R^2$  和 Pearson 系数对仿真结果进行定量评估和比较。

标准平均绝对误差的计算公式为

$$E_{\text{NMAE}} = \frac{1}{N} \sum_{i=1}^N \frac{1}{P_{\text{cap}}} |y_i - p_i| \quad (8)$$

标准化均方根误差的计算公式为

$$E_{\text{NRMSE}} = \frac{1}{P_{\text{cap}}} \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - p_i)^2} \quad (9)$$

平均绝对百分比误差的计算公式为

$$E_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - p_i|}{y_i} \quad (10)$$

$R^2$  的计算公式为

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - p_i)}{\sum_{i=1}^N (y_i - \bar{y})} \quad (11)$$

Pearson 系数的计算公式为

$$C_{\text{pearson}} = \frac{\sum_{i=1}^N (p_i - \bar{p})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (p_i - \bar{p})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}}, \quad (12)$$

式中:  $N$  为样本数量;  $p_i$  和  $y_i$  分别为第  $i$  个样本的预测功率值和真实功率值;  $P_{\text{cap}}$  表示电机最大功率容量;  $\bar{p}$  和  $\bar{y}$  分别表示预测功率值均值和真实功率均值。

$E_{\text{MAPE}}$  指标反映平均每个样本点的预测误差, 当真实值  $y_i$  接近于 0 时,  $E_{\text{MAPE}}$  将变得过大甚至无穷大。为了避免该问题, 本文采用以下计算公式替代:

$$E_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - p_i|}{y_i + 1}. \quad (13)$$

在光伏功率预测中,  $E_{\text{NMAE}}$ 、 $E_{\text{NRMSE}}$  和  $E_{\text{MAPE}}$  指标越小, 说明预测精度越高,  $R^2$  和 Pearson 系数越接近 1 表示算法性能越好。

### 4.2 实验结果分析

本文采用消融实验对方案设计的有效性进行说明, 结果如表 2 所示。分别对 SSD、BiGRU 时序建模和 FT-Attention 模块对本文方法效果的影响进行了对比实验。从表 2 中的对比结果可知, SSD 通过将复杂信号分解为多个中心频率的简单信号, 有效降低了信号的非线性, 提升了光伏功率预测的精确度。融入

FT-Attention 模块后, NMAE、NRMSE 和 MAPE 3 种指标分别下降至 2.57%、4.82% 和 8.14%, 说明了本文设计的双重注意力模块对提升光伏功率预测效果的有效性。图 4 是在连续 2 天数据上的消融实验结果图, 从图中可以看出, SSD、BiGRU 和 FT-Attention 模块相结合, 获得了最优的预测效果。

表 2 消融实验的性能对比

Table 2 Performance comparison of ablation experiments			
Model	NMSE	NRMSE	MAPE
BiGRU	3.70%	5.80%	10.62%
SSD+BiGRU	3.01%	5.22%	9.23%
Proposed	<b>2.57%</b>	<b>4.82%</b>	<b>8.14%</b>

将本文方法与其他几种经典方法进行比较, 实验结果如表 3 所示。其中, SVR 表示支持向量机方法, BPNN 表示反向传播神经网络, LSTM 表示长短期记忆网络, GRU 表示逻辑门控单元网络。经对比可知, 深度学习方法 (BPNN、LSTM、GRU、本文方法) 优于传统机器学习方法 (SVR) 的性能, 而本文方法提出一种简单有效的注意力模块, 并将其与 SSD 信号分解、深度时序建模相结合, 在多个指标上获得了最佳性能。图 5 是上述几种方法在连续 2 天数据上的曲线图, 从图中可以看出, 无论是功率平滑区域还是突变区域, 本文方法都优于其他几种方法。

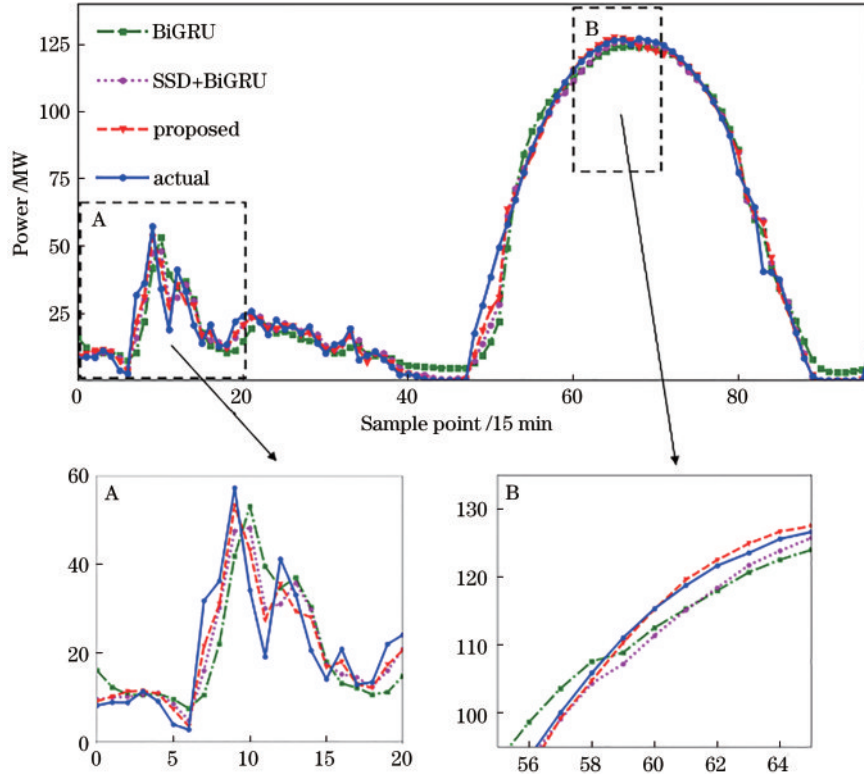


图 4 消融模型的预测结果  
Fig. 4 Forecasting results obtained by ablation models

表 3 与其他方法的性能对比

Table 3 Performance comparison with other methods

Method	NMAE	NRMSE	MAPE	R <sup>2</sup>	Pearson
SVR	4.67%	6.03%	10.68%	0.949	0.979
BPNN	4.15%	6.31%	12.81%	0.944	0.972
LSTM	4.06%	6.24%	11.68%	0.946	0.972
GRU	3.89%	6.03%	11.55%	0.949	0.974
Proposed	<b>2.57%</b>	<b>4.82%</b>	<b>8.14%</b>	<b>0.968</b>	<b>0.984</b>




图 5 不同方法的预测结果

Fig. 5 Forecasting results obtained by different methods

太阳辐照度的强弱与季节和天气类型密切相关,因此,季节变化和天气变化会影响光伏的发电功率。为了验证本文方法的实际工程应用性能,在不同季节和不同天气的数据集上对本文方法进行了性能测试,并在几种常用指标上和其他几种经典方法进行比较,结果如表 4、表 5 和图 6 所示。分析测试结果可得:

1)在 4 个季节和不同天气的测试结果中,深度学习方法(BPNN、LSTM、GRU、本文方法)的性能优于传统机器学习方法(SVR),且深度学习的时序建模方法(LSTM、GRU、本文方法)性能优于浅层神经网络方法(BPNN)。本文方法结合信号分解、时序建模和特征时序注意力机制,在各项指标中取得最佳效果,验证了本文方法在不同季节和不同天气下的预测精确性和有效性。

2)晴天天气下,光伏功率的输出较为平稳,随着太

表 4 不同季节的性能对比结果

Table 4 Performance comparison results in different seasons

Season	Method	NMAE	NRMSE	MAPE	R <sup>2</sup>	Pearson
Spring	SVR	4.91	6.24	11.13	0.948	0.978
	BPNN	4.37	6.48	12.79	0.943	0.972
	LSTM	4.32	6.45	12.06	0.944	0.972
	GRU	4.20	6.36	12.03	0.945	0.973
	Proposed	<b>2.92</b>	<b>5.28</b>	<b>8.74</b>	<b>0.962</b>	<b>0.981</b>
Summer	SVR	5.29	7.19	13.50	0.907	0.958
	BPNN	5.09	7.93	16.91	0.886	0.942
	LSTM	5.36	8.28	17.05	0.876	0.936
	GRU	4.98	7.83	16.05	0.889	0.944
	Proposed	<b>3.68</b>	<b>6.43</b>	<b>12.58</b>	<b>0.925</b>	<b>0.962</b>
Autumn	SVR	4.71	6.14	11.62	0.944	0.977
	BPNN	4.21	6.48	13.93	0.938	0.969
	LSTM	4.33	6.66	13.68	0.934	0.967
	GRU	4.14	6.42	13.34	0.939	0.970
	Proposed	<b>2.83</b>	<b>5.17</b>	<b>9.90</b>	<b>0.960</b>	<b>0.980</b>
Winter	SVR	4.41	5.21	10.52	0.946	0.985
	BPNN	3.32	5.14	15.52	0.948	0.974
	LSTM	3.22	4.82	12.78	0.954	0.977
	GRU	2.87	4.71	12.88	0.956	0.978
	Proposed	<b>1.84</b>	<b>3.49</b>	<b>8.79</b>	<b>0.976</b>	<b>0.988</b>

阳辐照度的强弱变化而变化,5种预测方法均表现良好。本文方法在NMAE、NRMSE和MAPE指标上分别取得1.59%、3.50%和3.81%的最佳效果。

3)在阴雨天和突变天气情况下,光伏功率的波动性较强,5种方法的预测性能较晴天状态下均有下降,存在一定的波动误差。本文方法在光伏波动较强时依然取得较优效果,满足光伏发电系统的实际应用要求,并已应用到光伏发电站的电力调度中。

表 5 不同天气状态下的性能对比

Table 5 Performance comparison under different weather types

Method	Sunny day			Rainy day			Abrupt change		
	NMAE	NRMSE	MAPE	NMAE	NRMSE	MAPE	NMAE	NRMSE	MAPE
SVR	3.91%	5.03%	7.61%	4.67%	5.15%	<b>19.31%</b>	5.58%	7.51%	15.20%
BPNN	3.44%	5.38%	8.60%	2.61%	3.90%	34.36%	5.50%	8.26%	18.74%
LSTM	3.03%	4.73%	7.01%	3.01%	4.30%	31.05%	5.63%	8.47%	18.51%
GRU	2.99%	4.76%	6.95%	2.42%	3.81%	31.44%	5.33%	8.06%	17.80%
Proposed	<b>1.59%</b>	<b>3.50%</b>	<b>3.81%</b>	<b>1.66%</b>	<b>2.78%</b>	20.86%	<b>3.95%</b>	<b>6.69%</b>	<b>14.18%</b>

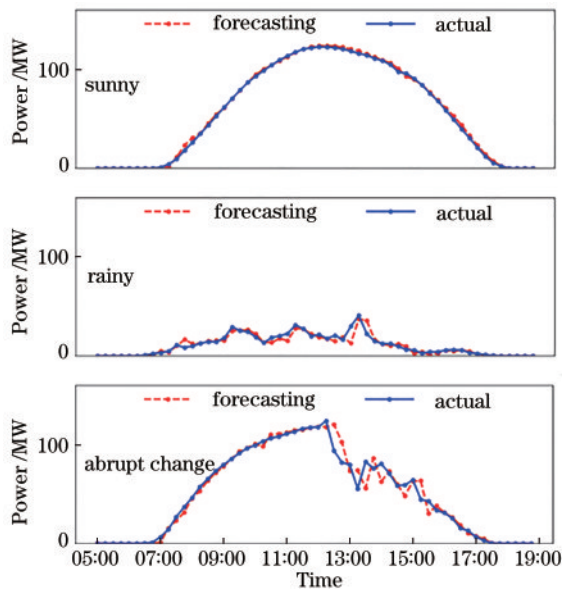


图 6 不同天气类型下的预测结果

Fig. 6 Forecasting results under different weather types

## 5 结 论

本文将信号分解、深度时序建模和注意力机制相结合,进行光伏超短期功率预测。首先利用SSD对原始光伏信号进行分解,有效降低光伏信号的随机性和波动性;然后利用BiGRU网络对分解后的信号进行时序建模,并提出一种简单有效的双重注意力模块,对BiGRU网络提取的特征进行权重加权,从而实现重要信息的特征选择;最后经过决策层获得最终的光伏功率预测结果。采用多种指标进行了评估,实验证明,该方法的效果优于其他几种经典方法。

### 参 考 文 献

- [1] 孟宪龙, 刘备, 段辰星, 等. 一种新型槽式太阳能 CPV/T 聚光器的光学传输特性[J]. 光学学报, 2021, 41(15): 1522002.  
Meng X L, Liu B, Duan C X, et al. Optical transmission characteristic of novel trough type CPV/T concentrator [J]. Acta Optica Sinica, 2021, 41(15): 1522002.
- [2] 王志忠, 韩茂林, 胡海, 等. 基于晴朗系数和多层次匹配的光伏功率预测方法研究[J]. 电测与仪表, 2019, 56(8): 45-50.  
Wang Z Z, Han M L, Hu H, et al. Research on photovoltaic power prediction method based on sunny coefficient and multi-similarity matching[J]. Electrical Measurement & Instrumentation, 2019, 56(8): 45-50.
- [3] Nespoli A, Ogliari E, Leva S, et al. Day-ahead photovoltaic forecasting: a comparison of the most effective techniques[J]. Energies, 2019, 12(9): 1621.
- [4] 张立影, 孟令甲, 王泽忠. 基于双层 BP 神经网络的光伏电站输出功率预测[J]. 电测与仪表, 2015, 52(11): 31-35.  
Zhang L Y, Meng L J, Wang Z Z. Photovoltaic power station output power prediction based on the double BP neural network[J]. Electrical Measurement & Instrumentation, 2015, 52(11): 31-35.
- [5] Qu J Q, Qian Z, Pei Y. 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: 120996.
- [6] Li C D, Zhou C G, Peng W, et al. Accurate prediction of short-term photovoltaic power generation via a novel double-input-rule-modules stacked deep fuzzy method[J]. Energy, 2020, 212: 118700.
- [7] Mei F, Pan Y, Zhu K D, et al. A hybrid online forecasting model for ultrashort-term photovoltaic power generation[J]. Sustainability, 2018, 10(3): 820.
- [8] Wang K J, Qi X X, Liu H D. A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network[J]. Applied Energy, 2019, 251: 113315.
- [9] 马磊, 黄伟, 李克成, 等. 基于 Attention-LSTM 的光伏超短期功率预测模型[J]. 电测与仪表, 2021, 58(2): 146-152.  
Ma L, Huang W, Li K C, et al. Photovoltaic ultra-short-term power prediction model based on Attention-LSTM [J]. Electrical Measurement & Instrumentation, 2021, 58(2): 146-152.
- [10] Sharadga H, Hajimirza S, Balog R S. Time series forecasting of solar power generation for large-scale photovoltaic plants[J]. Renewable Energy, 2020, 150: 797-807.
- [11] Sodsong N, Yu K M, Ouyang W. Short-term solar PV forecasting using gated recurrent unit with a cascade model[C]//2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC), February 11-13, 2019, Okinawa, Japan. New York: IEEE Press, 2019: 292-297.
- [12] Liu J, Zheng W, Liu X. Photovoltaic short-term power prediction based on PSO-GRU model[J]. Frontiers in Science and Engineering, 2021, 1(4): 73-82.
- [13] Lee D H, Kim K. PV power prediction in a peak zone using recurrent neural networks in the absence of future meteorological information[J]. Renewable Energy, 2021, 173: 1098-1110.
- [14] Zhang F, Liu Q Y, Liu Y L, et al. Novel fault location method for power systems based on attention mechanism and double structure GRU neural network[J]. IEEE Access, 2020, 8: 75237-75248.
- [15] Pan C, Tan J, Feng D D. Prediction intervals estimation of solar generation based on gated recurrent unit and kernel density estimation[J]. Neurocomputing, 2021, 453: 552-562.
- [16] Jin X B, Zheng W Z, Kong J L, et al. Deep-learning forecasting method for electric power load via attention-based encoder-decoder with Bayesian optimization[J]. Energies, 2021, 14(6): 1596.
- [17] Jung S, Moon J, Park S, et al. An attention-based multilayer GRU model for multistep-ahead short-term

- load forecasting [J]. *Sensors*, 2021, 21(5): 1639.
- [18] Zhou J G, Wang Q Q. Forecasting carbon price with secondary decomposition algorithm and optimized extreme learning machine[J]. *Sustainability*, 2021, 13(15): 8413.
- [19] Li Q, Zhang X Y, Ma T J, et al. A multi-step ahead photovoltaic power prediction model based on similar day, enhanced colliding bodies optimization, variational mode decomposition, and deep extreme learning machine [J]. *Energy*, 2021, 224: 120094.
- [20] Li P T, Zhou K L, Lu X H, et al. A hybrid deep learning model for short-term PV power forecasting[J]. *Applied Energy*, 2020, 259: 114216.
- [21] 杨丽薇, 高晓清, 蒋俊霞, 等. 基于小波变换与神经网络的光伏电站短期功率预测[J]. *太阳能学报*, 2020, 41(7): 152-157.  
Yang L W, Gao X Q, Jiang J X, et al. Short-term photovoltaic output power prediction based on wavelet transform and neural network[J]. *Acta Energetica Sinica*, 2020, 41(7): 152-157.
- [22] 杨晶显, 张帅, 刘继春, 等. 基于 VMD 和双重注意力机制 LSTM 的短期光伏功率预测[J]. *电力系统自动化*, 2021, 45(3): 174-182.  
Yang J X, Zhang S, Liu J C, et al. Short-term photovoltaic power prediction based on variational mode decomposition and long short term memory with dual-stage attention mechanism[J]. *Automation of Electric Power Systems*, 2021, 45(3): 174-182.
- [23] Liu H, Mi X W, Li Y F. Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short term memory neural network and Elman neural network[J]. *Energy Conversion and Management*, 2018, 156: 498-514.
- [24] Jia P Y, Zhang H B, Liu X M, et al. Short-term photovoltaic power forecasting based on VMD and ISSA-GRU[J]. *IEEE Access*, 2021, 9: 105939-105950.
- [25] Yan X A, Liu Y, Xu Y D, et al. Multistep forecasting for diurnal wind speed based on hybrid deep learning model with improved singular spectrum decomposition [J]. *Energy Conversion and Management*, 2020, 225: 113456.
- [26] Bonizzi P, Karel J M H, Meste O, et al. Singular spectrum decomposition: a new method for time series decomposition[J]. *Advances in Adaptive Data Analysis*, 2014, 6(4): 1450011.
- [27] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [28] Chung J, Gulcehre C, Cho K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling [EB/OL]. (2014-12-11)[2021-02-05]. <https://arxiv.org/abs/1412.3555>.