

# 基于 SE-CNN-BiLSTM 与改进 Transformer 的光伏功率多时间尺度预测方法

李增伟, 王娅云, 张容福, 马元明, 方 晨, 魏永瑜

(国网青海省电力公司信息通信公司, 西宁 810003)

**摘要:** 分布式光伏输出功率的随机性和波动性给电力调度工作的精准预测和调度决策带来了挑战。对此, 提出一种基于 SE-CNN-BiLSTM(压缩激励-卷积神经网络-双向长短期记忆)与改进 Transformer 的多时间尺度融合的光伏功率超短期预测模型及方法。首先, 基于光伏功率的日趋势相似特性, 提出一种融合通道注意力机制的特征提取方法, 构建光伏输出功率趋势特征预测模型; 接着, 考虑光伏功率短期波动特性, 提出一种基于 STM(相似时间段匹配)的波动特征提取方法, 利用光伏输出功率的天气波动特征构建基于改进 Transformer 的预测模型; 然后, 融合长、短时间尺度的光伏功率趋势特征和波动特征, 构建多时间尺度融合的光伏功率预测方法。最后, 结合实际光伏电站运行数据和仿真数据对提出的模型进行验证。结果表明, 所提方法能有效提高预测模型的表征能力和预测精度。

**关键词:** 光伏功率预测; 注意力机制; LSTM; 改进 Transformer; 特征融合

**DOI:** 10.19585/j.zjdl.202603011

开放科学(资源服务)标识码(OSID):



## A multi-timescale photovoltaic power prediction method based on SE-CNN-BiLSTM and improved Transformer

LI Zengwei, WANG Yayun, ZHANG Rongfu, MA Yuanming, FANG Chen, WEI Yongyu

(Information & Telecommunication Branch, State Grid Qinghai Electric Power Company, Xining 810003, China)

**Abstract:** The random and volatile distributed photovoltaic (PV) power pose challenges for accurate forecasting and dispatch decision-making in power system operations. To address this, A multi-timescale photovoltaic power prediction method based on SE-CNN-BiLSTM and improved Transformer is proposed. Firstly, leveraging the diurnal trend similarity characteristics of PV power, a feature extraction method incorporating a channel attention mechanism is proposed to construct a prediction model for PV power trend features. Subsequently, based on the short-term fluctuation characteristics of PV power, a fluctuation feature extraction method based on similar time-period matching (STM) is proposed, utilizing the weather-induced fluctuation features of PV power to build a prediction model based on an improved Transformer. Then, by fusing the long- and short-timescale trend features and fluctuation features of PV power, a multi-timescale fusion method for PV power prediction is constructed. Finally, the proposed model is validated using actual operational data from a PV power station and simulation data. Results demonstrate that the proposed method effectively enhances the representational capacity and prediction accuracy of the forecasting model.

**Keywords:** PV power prediction; attention mechanism; LSTM; improved Transformer; feature fusion

## 0 引言

太阳能因其储量巨大、成本低廉、环境友好及安全可靠等突出特点, 在可再生能源发电领域占据重要地位并得到大规模开发<sup>[1]</sup>。然而, 光伏功率受太阳辐射强度、温度等外界环境因素影响

较大, 具有出力不稳定、间歇性强以及难以精确预测等特点<sup>[2]</sup>。光伏发电的不稳定性给电力系统的安全可靠运行以及发电调度计划的优化带来了严峻考验。

现有的光伏功率预测研究在提高预测精度和稳定性方面虽已取得显著进展, 但仍然存在诸多不足<sup>[3]</sup>。当前光伏短期功率预测方法主要分为基于物理模型和基于数据驱动两类<sup>[4]</sup>。物理模型方法依托气象环境参数和光伏组件特性, 通过建立

光电转换机理模型实现功率预测<sup>[5]</sup>。数据驱动方法则利用机器学习算法对海量历史运行数据进行训练,构建光伏电站的功率输出映射关系。近年来,统计学模型如马尔科夫链、自回归移动平均等<sup>[6]</sup>,以及深度学习模型如人工神经网络、循环神经网络、GRU(门控循环单元)等<sup>[7]</sup>已被广泛应用于光伏功率预测领域。然而,无论是统计学模型还是深度学习模型,单一的模型由于数据质量和噪声干扰等问题难以从光伏功率数据中提取有效特征,导致预测精度降低。

提取光伏历史功率数据中的趋势特征信息可有效提高超短期光伏功率的预测精度<sup>[8-9]</sup>,LSTM(长短期记忆)网络因在时间序列的长期依赖关系特征提取方面具有显著优势,因而得到广泛应用<sup>[10]</sup>。文献[11]提出了一种基于MODWT(最大重叠离散小波变换)和CEEMDAN(互补集合经验模态分解)的短期光伏功率区间预测方法,通过多尺度分解和集成学习提高了预测的准确性。文献[12]强调数据聚类在预测中的作用,并利用K-medoids-GPR组合模型进行短期光伏功率预测。此外,有研究结合LSTM-Attention机制和GRU误差修正技术,进一步提升了光伏功率预测精度<sup>[13]</sup>。文献[14]采用K-means分层聚类与GAM(广义相加模型)动态组合策略,文献[15]通过改进灰狼算法优化LSTM网络并将其应用于光伏预测中。文献[16]对比分析了气象预报数据对光伏功率预测的影响,并将其应用于不同类型的LSTM预测模型中,验证了通过总辐照度观测可以显著降低预测误差。文献[17]提出了一种基于小波变换、CNN(卷积神经网络)和BiLSTM(双向长短期记忆)网络的混合深度学习模型,该模型能够有效捕捉光伏功率的时间和空间动态特性,提高了预测精度。

除了光伏功率长期趋势特征的提取,光伏功率的短期波动对于超短期光伏功率预测也至关重要。Transformer模型通过其自注意力机制和并行化处理能力,能够高效捕捉光伏功率短期波动中的复杂依赖关系和全局特征,从而提升预测准确性。文献[18]提出了一种结合变分模态分解、麻雀搜索算法与Transformer-LSTM架构的模型,在保证预测精度的同时,有效减少了预测对于输

入数据的需求。文献[19]利用FOX算法优化Transformer参数,并结合Transformer的特征提取优势提高了短期光伏功率预测的准确性。文献[20]利用数字孪生模型结合领域适应技术,增强了实时光伏功率预测的能力。文献[21]针对不同辐照度区间气象因素的影响,提出了一种基于分布式Transformer-LSTM的预测模型,实现了光伏系统剧烈波动场景下的精准预测。

文献[22-23]提出了一种变体Transformer网络,通过整合单步和多步预测,使用一维CNN层和Transformer模型捕捉时间模式,实现了光伏功率的超短期预测和长期趋势判断。文献[24]提出了一种基于数字孪生的光伏功率预测方法,结合CNN提取局部特征、Transformer捕捉长期依赖,并通过DANN实现跨域自适应;模型在实时数据更新中持续优化,显著提升了预测精度。文献[25]提出了一种混合深度学习光伏功率预测模型,结合动态均值预处理、改进鲸鱼优化算法的变分模态分解和上下文嵌入因果卷积Transformer结构,增强了预测的鲁棒性。文献[26]使用TimeGAN算法扩充寒潮数据样本,确保时序特征不变;利用XGBoost和Transformer分别建立基准值和损失值预测模型;并通过Seq2Seq(序列到序列)结合注意力机制预测功率损失时段。文献[27]通过移动平均分析功率变化趋势,然后用双重自适应滑动窗口检测转折点。对于不同的天气时段,采用不同的预测模型:非转折性时段使用LightGBM-GRU组合模型,转折性时段则使用改进的核密度估计概率预测方法。

针对光伏输出功率的波动性,传统Transformer预测模型存在信息颗粒度不够精细、对天气变化引起的功率波动捕捉能力不强的问题。本文提出了一种基于SE(压缩激励)-CNN-BiLSTM与改进Transformer的多尺度融合光伏功率超短期预测模型,实现了光伏预测过程中空间-时间-全局特征的协同融合。该模型由以下三个模块组成:长时间尺度趋势特征提取模块、短时间尺度波动特征提取模块以及模型融合机制模块。长时间趋势特征提取模块利用SE-CNN网络提升通道特征的辨识能力,并结合BiLSTM网络的特征提取能力,实现长时间尺度功率趋势特征提取。短时间

适度波动特征提取模块由基于相似时间匹配机制的Transformer网络构成,利用相似时间机制获得小时级时间-功率特征信息,并结合Transformer获得短时间的尺度波动特征信息。此外,本文还设计了一种长短时间尺度特征信息融合模块,将功率数据的长短时间特征信息进行有机融合,以提升模型预测精度。最后,通过试验验证了本文所提方法的有效性和合理性。

## 1 基于SE-CNN和BiLSTM的长时间尺度趋势特征提取

从统计数据角度看,光伏发电功率具有日相似性和月度相似性。日相似或者月相似特征所表征的长时间尺度趋势特征是光伏训练数据以及模型预测的重要特征。光伏功率预测的输入数据具有多通道特性,不同通道的特征对功率预测的贡献度不同,且其重要性可能随时间或天气动态变化。SE模块是一种轻量级的通道注意力机制,其核心思想是让网络自主学习每个特征通道的重要性权重,并在特征重标定阶段动态地增强关键特征通道的响应。本文通过构建融合SE模块的CNN网络,增强对通道特征序列数据趋势特征重要性的辨识能力,并结合BiLSTM神经网络提取光伏功率的长时间尺度趋势特征。

### 1.1 结合SE注意力机制的CNN网络

CNN因其强大的特征提取能力被广泛应用于光伏功率预测中。CNN网络由输入层、卷积层、池化层、全连接层和输出层构成。SE模块是一种轻量级网络子结构,能够建模特征通道间的依赖关系,通过动态调整特征图的通道权重来增强有效特征并抑制冗余信息。SE模块通过全连接网络自主学习各特征通道的重要性,并据此分配相应的权重系数,使模型能够关注更具判别性的特征通道,从而提升模型的预测性能。SE-CNN模型结构如图1所示,由挤压、激励和缩放环节构成。

1)挤压。通过全局平均池化技术将原先的多个特征图转化为一个具有固定长度的一维特征数组,以此来表示原始数据的浓缩特征 $d$ :

$$Z_c = F_{sq} U_c = \frac{1}{h \times w} \sum_{i=1}^h \sum_{j=1}^w U_c(i, j) \quad (1)$$

式中: $F_{sq}$ 为挤压操作; $U_c$ 为每个通道的特征图; $h$ 和 $w$ 分别为特征图的高度和宽度; $Z_c$ 为 $F_{sq}$ 的权

重输出; $U_c(i, j)$ 为特征通道 $c$ 中第 $i$ 行第 $j$ 列的值。

2)激励。可使模型能够依据输入数据自适应地调整不同通道的影响程度,通过学习得到各通道的权重值:

$$S_c = F_{ex}(Z_c) = \sigma(W_2 \delta(W_1 Z_c)) \quad (2)$$

式中: $S_c$ 为通道 $c$ 的权重值; $F_{ex}$ 为激励操作; $Z_c$ 为挤压操作输出的特征向量; $\sigma$ 和 $\delta$ 为激活函数; $W_1$ 和 $W_2$ 分别为维度 $c/r \times c$ 和维度 $c \times c/r$ 的权重矩阵; $S$ 为特征通道的权重系数; $r$ 为降维比例因子。

3)加权。通过激励模块计算得到权重系数,并按通道应用到对应特征图上,实现对特征响应的增强或抑制:

$$X = F_{we}(U_c, S_c) = S_c \otimes U_c \quad (3)$$

式中: $F_{we}$ 为加权操作; $\otimes$ 表示逐元素相乘。

SE模块使CNN从被动接收所有通道信息转变为主动选择并强化关键通道信息。通过抑制噪声和不相关信息的干扰,提升CNN在多通道时间序列数据上的特征提取能力。




图1 SE-CNN模型结构

Fig.1 Structure of the SE-CNN model

### 1.2 长时间尺度趋势特征提取

光伏功率的周期性趋势表明,当前时刻的功率输出不仅受历史数据的影响,同时也与未来预测模式相关。BiLSTM网络通过前向和后向LSTM,融合历史上下文和未来上下文,能够更全面地捕捉序列的全局演化模式和周期性结构。两个LSTM单元分别沿时间序列的前向和后向方向进行信息传递,同时捕捉气象数据在正向与反向时间维度上的依赖关系。通过融合双向的时间特征信息,BiLSTM更全面地学习气象数据的演化规律,从而获得更精确的预测结果。BiLSTM单元内的计算过程如下所示:

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ \hat{o}_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \end{cases} \quad (4)$$

式中:  $\tilde{c}_t$ 代表记忆单元的输入;  $c_t$ 为细胞的状态;  $f_t$ 、 $i_t$ 、 $o_t$ 分别表示遗忘门、输入门和输出门的激活状态;  $h_t$ 为LSTM单元的隐藏层输出;  $W_f$ 、 $W_i$ 、 $W_o$ 、 $W_c$ 分别表示遗忘门、输入门、输出门及细胞状态的权重矩阵;  $b_f$ 、 $b_i$ 、 $b_o$ 、 $b_c$ 分别为其对应的偏置量;  $\sigma$ 为激活函数, 用于引入非线性变换。

为了更好地突出光伏功率长时间周期特征, 本文构建了融合SE-CNN和BiLSTM神经网络的长时间尺度趋势特征提取混合模型。SE-CNN通道注意力机制能够优化特征通道, 而BiLSTM的门控机制能够同时捕捉气象数据的正向和反向演化模式, 从而挖掘特征的时序依赖。通过两者的互补特性, 该模型提升了长时间尺度趋势特征的提取能力。融合SE-CNN和BiLSTM模型的长时间趋势特征提取流程如下:

1) 基于SE-CNN模型对长时间趋势特征信息进行通道权重优化:

$$X_{SE-CNN} = SE(X_{CNN}) \quad (5)$$

式中:  $X_{CNN} \in \mathbb{R}^{T \times C}$ 为SE-CNN模块的输出特征向量;  $T$ 为时间步;  $C$ 为通道数。

2) 基于BiLSTM神经网络捕捉时序特征, 并进行前向和后向的输出拼接:

$$X_{BiLSTM} = BiLSTM(X_{SE-CNN}) \quad (6)$$

$$H = [h_{forward}, h_{backward}] \quad (7)$$

SE-CNN负责通道维度的特征优化与选择, 输出高质量的特征向量序列; BiLSTM负责时间维度的长距离依赖建模。SE-CNN作为前置处理器, 其输出的经过通道注意力优化的特征序列包含了更清晰、更相关的时空模式信息。

## 2 融合STM(相似时间段匹配)与改进Transformer模型的短时间尺度波动特征提取

### 2.1 STM

STM旨在从历史发电数据中筛选出与当前预

测时段特征最匹配的参考时段, 并将该参考数据作为预测模型的输入特征。本文提出的STM流程如图2所示, 通过引入STM机制, 能够准确识别并利用历史数据中的周期性模式, 从而提升对光伏功率短期波动的特征提取能力。

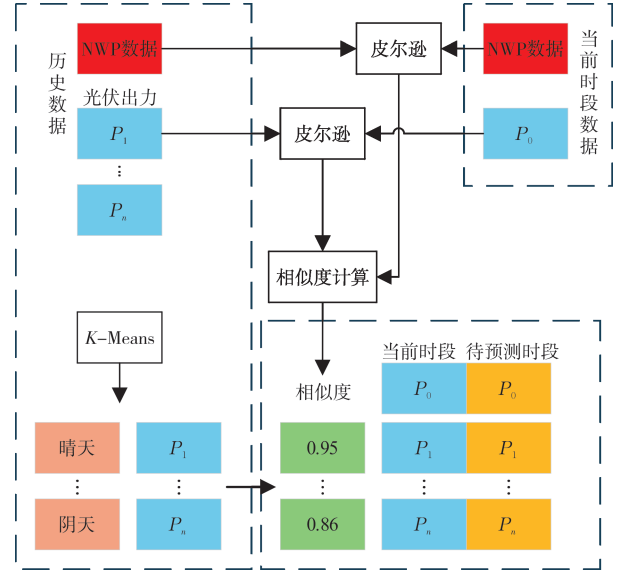


图2 STM流程

Fig.2 Flowchart of STM

本研究运用K-Means聚类算法对历史光伏功率曲线进行智能分类。通过无监督学习将功率数据自动划分为三类典型天气模式: “晴天”“多云”和“阴天”。与当前时段天气类型一致的时间段将被进一步评估。计算不同日当前时间段内的光伏发电功率序列向量 $p_1$ 和 $p_2$ 的Pearson相关系数, 其计算公式如下:

$$\rho_{p_1, p_2} = \frac{COV(p_1, p_2)}{\sigma_{p_1} \sigma_{p_2}} \quad (8)$$

在考虑多种环境因素对光伏出力的复合影响时, 除太阳辐照度这一主要因素外, 还整合了气压、环境温度、相对湿度、风速及云量等关键气象参数。基于NWP(数值天气预报)提供的预测数据, 构造气象特征为:

$$h = \{v_{max}, v_{min}, v_{ave}, \sin \theta_{ave}, \cos \theta_{ave}, P_{ave}, H_{ave}, T_{ave}\} \quad (9)$$

式中:  $v_{max}$ 为最大风速;  $v_{min}$ 为最小风速;  $v_{ave}$ 为平均风速;  $\sin \theta_{ave}$ 为平均风向的正弦值;  $\cos \theta_{ave}$ 为平均风向的余弦值;  $P_{ave}$ 为平均压强;  $H_{ave}$ 为平均湿度;  $T_{ave}$ 为平均温度。计算不同日待预测时段气象特征的Pearson相关系数, 计算方法同上。

结合功率因素和气象因素,设计综合相似度衡量标准为:

$$S_{12} = [\alpha\rho(p_1, p_2) + (1 - \alpha)\rho(h_1, h_2)] \quad (10)$$

式中:  $\alpha$  为权重系数;  $h_1$  和  $h_2$  为不同日待预测时段的气象特征向量;  $\rho(\cdot)$  为特征向量间的 Pearson 相关系数。

## 2.2 改进 Transformer 模型

传统 Transformer 网络在处理周期性规律时存在周期性特征建模缺陷,无法有效捕捉周期性规律的本质特征。本文通过重构网络输入向量结构,将相似多时段功率数据分别输入编码器和解码器,构建双通道输入机制,提升相似训练数据的特征挖掘能力;在编码环节引入前馈信息通道,防止特征信息衰减,同时增强编码输出的稳定性;在解码阶段采用双重注意力协同机制,通过两次注意力计算的信息互补,精准建模时序特征间的动态关联关系。改进 Transformer 网络结构如图 3 所示。

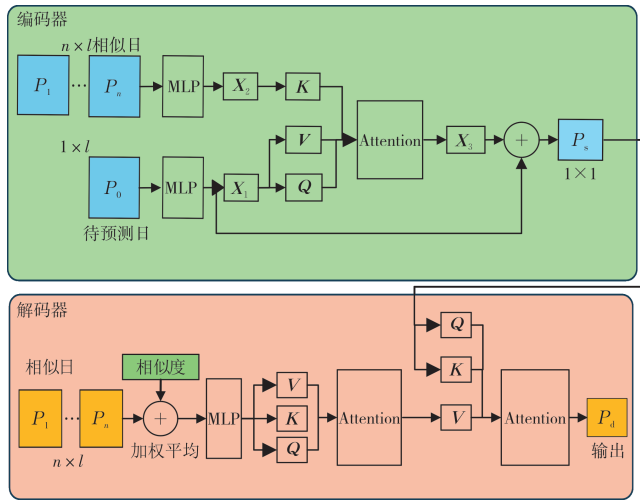


图 3 改进 Transformer 结构

Fig.3 Structure of the improved Transformer

在编码器阶段,将待预测日的搜索时段数据  $p_0$  和相似日的搜索时段数据  $P_n$  通过 MLP(多层感知机制)映射为特征向量  $X_1$  和  $X_2$ , 如下所示:

$$X_1 = MLP(P_0) \quad (11)$$

$$X_2 = MLP(P_n) \quad (12)$$

将  $X_1$  同时作为查询向量  $Q$  和数值向量  $V$ ,  $X_2$  作为键向量使用注意力机制计算特征向量  $X_3$ :

$$X_3 = \text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (13)$$

最后,将注意力机制计算后的向量  $X_3$  与  $X_1$  相加作为编码器的输出。前馈通道的设计不仅维持了原始数据的完整性,还显著提升了编码器输出的鲁棒性。

在解码器阶段,以相似时段的待预测时段数据为基础,设计相似时段的待预测时段数据依据相似度加权平均的结果,经过 MLP 映射为输入向量  $X_5$ 。采用双路注意力机制并行处理特征向量  $X_5$  的不同维度。第一路注意力模块的查询向量  $Q$ 、键向量  $K$ 、值向量  $V$  均来自向量  $X_5$  本身,着重捕捉预测时段的固有特征;第二路注意力模块则融合编码器输出和第一路注意力结果,通过自注意力机制实现信息互补。这种双重注意力架构有效提升了模型对时序上下文关联的建模能力。

本文设计的 Transformer 模型重构输入向量结构,将相似时段匹配结果有机融入模型输入。同时采用双重注意力协同机制,增强模型对时间序列特征的解析能力。不仅充分利用了历史相似时段的参考价值,还通过多层次注意力计算实现了对时序动态特征的深度挖掘。

## 2.3 短时间尺度波动特征提取

为了更高效地提取光伏功率数据中的短时间尺度波动特征,本文提出了一种融合 STM 与改进 Transformer 模型的协同机制,如图 4 所示。该机制通过 STM 筛选与当前预测时段气象条件高度相似的历史时段,并利用改进的 Transformer 模型深入挖掘这些时段内的复杂依赖关系和动态特征。

STM 的“粗粒度筛选”能力通过聚类与相似度计算,将历史数据划分为具有代表性的天气类别,并筛选出与当前气象条件最匹配的时段;改进的 Transformer 的“细粒度建模”能力则通过自注意力机制捕捉匹配时段内小时级甚至分钟级的功率波动。在多云转阴场景中,STM 筛选出的历史样本包含类似辐照度突变模式,而改进的 Transformer 通过双重注意力机制动态建模云层移动引发的功率波动。STM 与改进的 Transformer 的协同作用不仅提升了模型对短时间尺度波动模式的捕捉能力,还通过信息互补机制显著增强了预测精度。

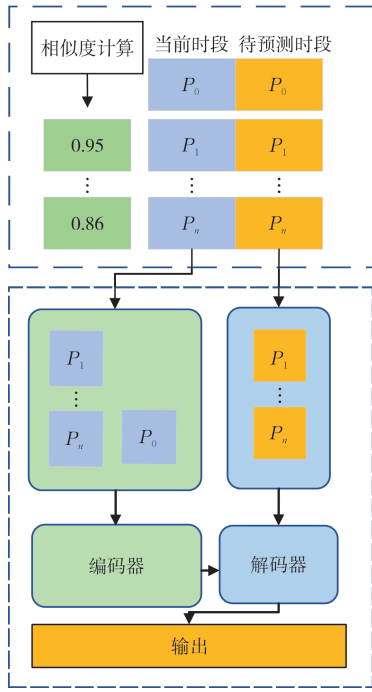


图 4 STM 与改进 Transformer 协同机制

Fig.4 Collaborative mechanism between STM and the improved Transformer

### 3 融合多时间尺度的光伏功率预测模型

为了更好地融合光伏训练数据的长时间尺度趋势特征信息和短时间尺度波动特征信息, 本文设计了一个双分支架构的组合预测模型。该模型包括两个独立分支, 分别捕捉和提取不同类型的特征信息, 以提升两者的互补特性。预测模型的结构如图 5 所示。

为了将长时间尺度趋势特征信息与短时间尺度波动特征信息充分融合, 将包含长时间尺度趋势特征信息的完整输入向量  $x_{long}$  输入到长时间尺度趋势分支, 将最能体现短时间尺度波动特征信息的末尾段数据的输入向量  $x_{short}$  输入到短时间尺度波动分支进行特征提取计算, 具体公式如下:

$$z_{long} = f_{long}(x_{long}) \quad (14)$$

$$z_{short} = f_{short}(x_{short}) \quad (15)$$

式中:  $f_{long}$  为基于 SE-CNN 模型的长时间尺度趋势分支;  $f_{short}$  为基于相似时间匹配和改进 Transformer 模型的短时间尺度波动分支;  $z_{short}$  为短时间尺度波动分支的输出;  $z_{long}$  为长时间尺度趋势分支的输出。

将长时间尺度趋势特征信息与短时间尺度波

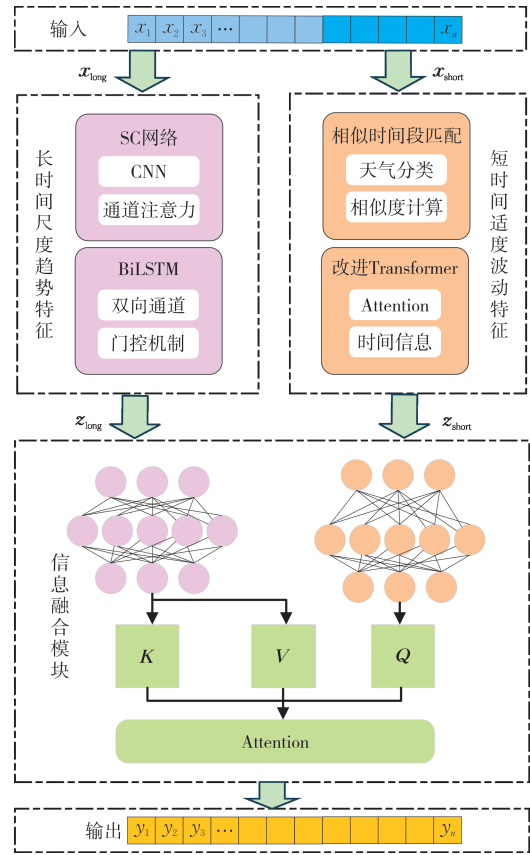


图 5 组合模型结构

Fig.5 Structure of the composite model

动特征信息通过 MLP 映射到隐藏维度, 然后使用短时间尺度波动特征信息作为查询向量  $Q$ , 长时间尺度趋势特征信息作为键向量  $K$  和数值向量  $V$  构建注意力融合机制:

$$q = MLP(z_{short}) \quad (16)$$

$$\begin{cases} k = MLP(z_{long}) \\ v = MLP(z_{short}) \end{cases} \quad (17)$$

最后, 利用短时间尺度波动特征信息查询长时间尺度趋势, 通过式(19)整合时间和空间信息, 进一步提升预测精度。

$$Attention(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_q}}\right)V \quad (18)$$

### 4 算例分析

实验所用数据来自某地区光伏电站的公开数据集, 涵盖了该电站的气象观测信息及历史发电功率记录。气象参数包括大气压强、气温、相对湿度、风速、云层覆盖度以及太阳辐射强度, 数

据采集时间范围为2020年1月至2021年12月，时间间隔为15 min。数据集按照7:3的比例划分为训练样本和测试样本，以验证模型的泛化能力。为了充分评估模型在不同气象条件下的表现，测试阶段重点分析了多种典型天气状况下的预测效果。实验平台配置为：Python 3.9编程环境，基于PyTorch 1.11深度学习框架，并利用NVIDIA RTX 4060Ti GPU进行加速计算。

#### 4.1 预测误差评估指标

为了评估本文所提出的预测模型的效果，选取MAE(平均绝对误差)、RMSE(均方根误差)和拟合系数 $R^2$ 三种评价指标来衡量模型的预测精度，其计算表达式分别如下：

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (19)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (20)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \frac{1}{n} \sum_{i=1}^n y_i)^2} \quad (21)$$

式中： $n$ 为测试样本数量； $y_i$ 为光伏功率的真实值； $\hat{y}_i$ 为模型预测值。

MAE反映了所有预测值与真实值之间绝对误差的平均值，能够体现模型预测结果的整体平均偏差水平。RMSE反映了预测误差平方和的平均值的平方根，合理的RMSE表明模型不仅能保证整体精度，还能有效抑制预测结果中出现的极大误差。 $R^2$ 是衡量模型预测值对真实值变化的解释能力，能够准确复现光伏功率的周期和趋势特征。

配对 $t$ 检验的原理是通过比较本文提出的预测模型与对比模型在相同测试样本上的预测误差差值，检验这些差值的均值是否显著小于零。其核心思想是判断本文模型的误差优势是否具有一致性和统计显著性，而非偶然波动。该检验的计算过程如下：

$$\bar{d} = \frac{1}{n} \sum_{i=1}^n d_i \quad (22)$$

式中： $\bar{d}$ 为所有配对误差差值的平均值； $n$ 为测试样本的总数量； $d_i$ 为第 $i$ 个时间点模型预测误差的差值。

$$s_d = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (d_i - \bar{d})^2} \quad (23)$$

式中： $s_d$ 表示配对差值的样本标准差，用于衡量差值的离散程度。标准差越小，说明本文模型相对于对比模型的误差优势越稳定。

$$t = \frac{\bar{d}}{s_d / \sqrt{n}} \quad (24)$$

该 $t$ 值反映了差值均值 $\bar{d}$ 的标准化大小。根据计算出的 $t$ 值，可通过 $t$ 分布表或统计软件计算得到 $p$ 值。 $p$ 值表示在“两种模型性能无差异”的原假设下，观察到当前差值或更极端差值的概率。若 $p$ 值小于预设的显著性水平(如0.05)，则拒绝原假设，认为本文模型的性能提升具有统计显著性。

#### 4.2 训练数据STM选择

本文通过相似时间窗口尺度优化策略确定匹配相似时间段长度。图6给出了不同时间段长度不同时间端窗口测试集RMSE指标的变化趋势。从图中可以看出，随着时间窗口的增加，预测误差也随之降低，表明较大的时间窗口有利于降低预测误差。基于综合性能评估，本文选择22个时间步长的窗口尺寸作为相似时间段长度。




图6 不同滑动窗口长度下的RMSE

Fig.6 RMSE under different sliding window lengths

为评估相似时段匹配策略对预测性能的影响程度，本文将历史数据匹配相似度划分为三个等级区间，分别是：高相似度(0.7~1.0)、中相似度(0.4~0.7)和低相似度(0~0.4)。基于不同的相似度进行测试日数据的训练和测试，不同相似度下平均性能指标MAE、RMSE和 $R^2$ 值的变化如图7所示。由图7可以看出，不同相似度区间下预测精度与匹配质量存在明显的量化关系。随着相似度等级的提高，各项评价指标均呈现显著改善趋势，

这进一步说明了本文提出的相似度匹配的有效性。




图 7 相似度与预测结果关系

Fig.7 Relationship between similarity and prediction results

### 4.3 预测结果对比分析

为了验证本文所提方法的有效性, 将本文方法与 BiLSTM、Transformer、STM-Transformer、SC-BiLSTM 以及 LSTM、BP、TCN 等传统模型进行对比分析, 预测结果如图 8 所示。由图 8 可知, 本文提出的组合模型展现出很高的预测精度, 相较于 STM-Transformer 和 SC-BiLSTM 等改进模型具有明显优势。




图 8 不同算法的预测对比分析

Fig.8 Comparative analysis of predictions from different algorithms

为全面评估提出模型针对不同天气场景下的预测性能, 本文针对晴天、阴天、多云和晴转多云四种天气场景下的光伏功率预测进行对比分析, 分别从 RMSE、MAE 和  $R^2$  三项指标进行量化分析和评估。不同天气场景下的预测模型的误差对比如表 1—3 所示。基于配对 t 检验, 标注本文模型显著优于对比模型的水平 ( $*p < 0.05$  显著优于对比模型,  $**p < 0.01$  高度显著优于对比模型,  $***p < 0.001$  极显著优于对比模型)。从表 1 可以看出, 在晴天场景下, 本文模型的 RMSE 和 MAE 极显著低

于所有对比模型。这归因于 SE-CNN 通道注意力机制有效聚焦于辐照度主导特征, 同时抑制了温度波动等噪声干扰。在晴转多云场景下, 本文模型的 RMSE 和 MAE 高度显著优于对比模型, 这得益于改进的 Transformer 双重注意力机制能够精准捕捉云层移动引发的功率突变。由于阴天天气变化较多且复杂, 导致阴天光伏预测功率的 RMSE 值明显高于其他天气类型。阴天较常见的天气变化情况是云层变化较快, 导致光照强度随云层的变化而变化, 从而引起光伏输出功率剧烈变化。此外, 由于模型考虑的气象如日均温度、平均风速等难以准确捕捉光伏功率的瞬间变化, 且不同云系引发的功率波动模式差异显著, 降低了模型对这类特殊场景的适应能力。

表 1 预测模型的 RMSE 对比

Table 1 Comparison of RMSE for prediction models

模型	晴天	晴转多云	多云	阴天
Transformer	0.623 1	0.806 1	0.790 7	0.990 4
BiLSTM	0.410 7	0.580 9	0.621 6	0.910 1
STM-Transformer	0.523 7	0.702 4	0.670 1	0.976 7
SC-BiLSTM	0.589 1	0.788 7	0.822 3	1.042 1
本文方法	0.283 2***	0.476 7**	0.544 6*	0.888 4*

表 2 预测模型的 MAE 对比

Table 2 Comparison of MAE for prediction models

模型	晴天	晴转多云	多云	阴天
Transformer	0.471 4	0.709 9	0.777 3	0.970 4
BiLSTM	0.310 6	0.507 5	0.380 1	0.678 4
STM-Transformer	0.360 3	0.609 8	0.707 4	0.819 1
SC-BiLSTM	0.498 6	0.753 3	0.909 5	1.048 9
本文方法	0.199 6***	0.358 5**	0.399 7*	0.698 8*

表 3 预测模型的  $R^2$  对比

Table 3 Comparison of  $R^2$  for prediction models

模型	晴天	晴转多云	多云	阴天
Transformer	0.949 4	0.945 8	0.935 3	0.931 7
BiLSTM	0.966 1	0.955 4	0.943 6	0.948 7
STM-Transformer	0.961 1	0.953 8	0.944 9	0.941 8
SC-BiLSTM	0.940 1	0.938 7	0.928 8	0.923 6
本文方法	0.974 7	0.963 6	0.966 2	0.957 7

图 9—12 给出了不同天气条件下, 光伏出力时段 (06:00—16:00) 的预测效果对比曲线。可以看出, 不同天气条件下, 光伏出力的波动情况存在

差异。在晴天，光伏出力保持高位且平稳运行，各模型均能较好地拟合功率的升降趋势。然而，在正午时段，光伏功率出现了较大的波动，本文方法通过捕捉光伏功率在短时间周期内的波动特性和长时间周期的趋势特征，在云层快速移动、光照剧烈波动的气象条件下，相较于Transformer模型和BiLSTM模型，通过CNN和SE通道注意机制以及STM，能够实现光伏功率的快速跟踪。

图 10 给出了晴转多云条件下光伏预测结果的对比分析。可以看出，在 11:00—14:00 光伏功率的变化比较剧烈，本文提出的方法具有更好的跟踪效果。相较于STM-Transformer和SC-BiLSTM预测模型，本文通过精准捕捉对气象条件因素、相似日功率变化情况的短时间周期波动信息，结合气象条件信息，获得最终的光伏预测功率。另外，图 11 和图 12 分别给出了多云和阴天等气象条件下的光伏功率预测情况。可以看出，在多云和阴天条件下，光伏功率的变化较为频繁且变化的时间点不确定。例如，在图 11 的多云天气中，功率在 09:00—12:00 以及 13:00—14:00 期间变化较为剧烈；在图 12 的阴天天气中，功率在 10:00—13:00 期间变化较为剧烈。从功率预测的角度来看，无论是功率从平稳到波动，还是从波动到平稳的不同过渡阶段，本文提出的模型相较其他模型更加准确。

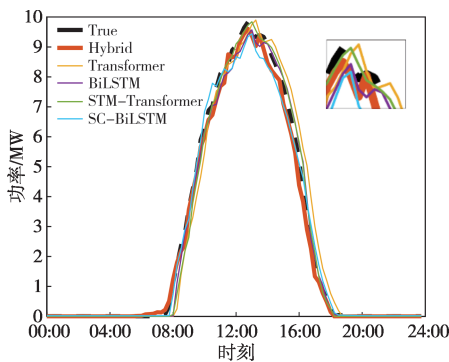


图 9 晴天预测结果

Fig.9 Prediction results for a sunny day

图 13 给出了各模型在光伏功率短期预测中每个时刻的RMSE误差变化情况。可以看出，RMSE随时间步长呈现典型的“先增后减”变化趋势。本文提出的预测模型通过挖掘历史功率数据和气象数据中存在的趋势特征和波动特征，建立更加精

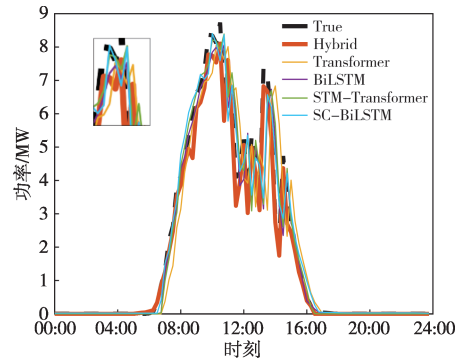


图 10 晴转多云预测结果

Fig.10 Prediction results for a sunny-to-cloudy day

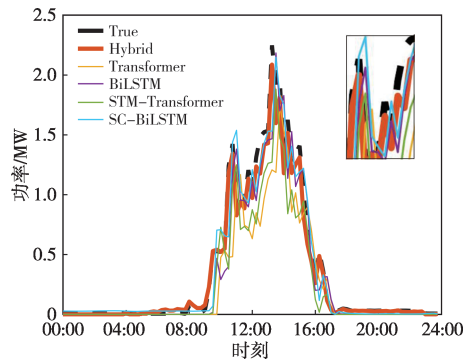


图 11 多云预测结果

Fig.11 Prediction results for a cloudy day

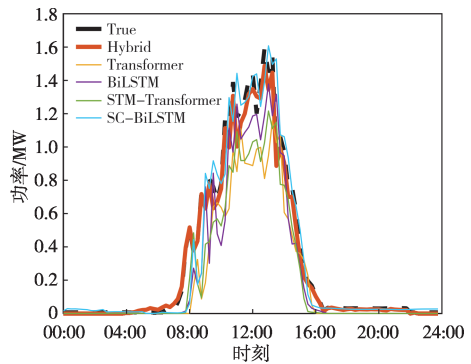


图 12 阴天预测结果

Fig.12 Prediction results for an overcast day

确的时序依赖关系，提取功率变化过程中的动态变化过程，具有较好的误差控制能力，其误差增长率明显低于其他模型。

### 5 结语

本文针对超短期光伏功率预测中存在的长时间尺度趋势与短时间尺度波动特征提取不足的问题，提出了一种基于SC-BiLSTM和改进Trans-

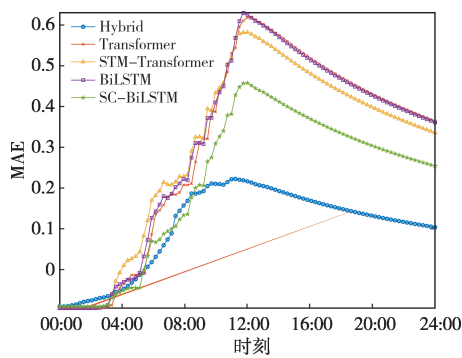


图13 不同模型预测精度曲线

Fig.13 Prediction accuracy curves of different models

former的双分支组合预测模型。该模型设计了双分支架构:长期趋势分支通过构建结合SE通道注意力机制的CNN-BiLSTM网络,实现对光伏功率长时间尺度趋势特征的提取;短期波动分支利用STM算法和改进的Transformer模型,捕捉短时间尺度的波动特征;最后,通过基于注意力机制的特征融合模块,建立短时波动特征能够主动查询并融合长时趋势信息的机制,实现多尺度信息的深度互补与自适应整合。本研究为光伏功率预测提供了新的技术思路,对提升电网调度效率和新能源消纳能力具有重要参考价值。

## 参考文献

- [1] 郝文斌,孟志高,张勇,等.新型电力系统下多分布式电源接入配电网承载力评估方法研究[J].电力系统保护与控制,2023,51(14):23-33.  
HAO Wenbin, MENG Zhigao, ZHANG Yong, et al. Carrying capacity evaluation of multiple distributed power supply access to the distribution network with the background of a new power system[J]. Power System Protection and Control, 2023, 51(14): 23-33.
- [2] BAI R X, SHI Y T, YUE M, et al. Hybrid model based on K-means++ algorithm, optimal similar day approach, and long short-term memory neural network for short-term photovoltaic power prediction[J]. Global Energy Interconnection, 2023, 6(2): 184-196.
- [3] 水恒华,顾阳,徐晓春,等.一种适用于光伏高渗透率地区的太阳辐照短时预测技术研究[J].电测与仪表,2024,61(4):149-154.  
SHUI Henghua, GU Yang, XU Xiaochun, et al. Research on a short-term solar radiation prediction technology for photovoltaic high permeability area[J]. Electrical Measurement & Instrumentation, 2024, 61(4): 149-154.
- [4] 王东风,李青博,张博洋,等.考虑季节性与趋势特征的光伏功率预测模型研究[J].太阳能学报,2025,46(3):348-356.  
WANG Dongfeng, LI Qingbo, ZHANG Boyang, et al. Research on photovoltaic power prediction model considering seasonality and trend characteristics[J]. Acta Energetica Solaris Sinica, 2025, 46(3): 348-356.
- [5] 陈凡,李智,丁津津,等.考虑光伏机理与数据驱动结合的短期功率预测[J].科学技术与工程,2023,23(20):8686-8692.  
CHEN Fan, LI Zhi, DING Jinjin, et al. Consider short-term power prediction combining photovoltaic mechanism and data-driven[J]. Science Technology and Engineering, 2023, 23(20): 8686-8692.
- [6] 仇琦,杨兰,丁旭,等.基于改进EMD-ARIMA的光伏发电系统短期功率预测[J].电力科学与工程,2020,36(8):42-50.  
QIU Qi, YANG Lan, DING Xu, et al. An improved short-term power prediction method of PV power generation system based on EMD-ARIMA model[J]. Electric Power Science and Engineering, 2020, 36(8): 42-50.
- [7] 何威,苏中元,史金林,等.基于双重注意力GRU与相似修正的光伏功率预测[J].太阳能学报,2024,45(3):480-487.  
HE Wei, SU Zhongyuan, SHI Jinlin, et al. Photovoltaic power forecasting based on dual-attention-gru and similarity modification[J]. Acta Energetica Solaris Sinica, 2024, 45(3): 480-487.
- [8] 张静,熊国江.考虑季节特性与数据窗口的短期光伏功率预测组合模型[J].电力工程技术,2025,44(1):183-192.  
ZHANG Jing, XIONG Guojiang. Short-term photovoltaic power prediction combination model considering seasonal characteristic and data window[J]. Electric Power Engineering Technology, 2025, 44(1): 183-192.
- [9] 王涛,王旭,许野,等.计及相似日的LSTM光伏出力预测模型研究[J].太阳能学报,2023,44(8):316-323.  
WANG Tao, WANG Xu, XU Ye, et al. Study on lstm photovoltaic output prediction model considering similar days[J]. Acta Energetica Solaris Sinica, 2023, 44(8): 316-323.
- [10] 陈峰,余轶,徐敬友,等.基于Bayes-LSTM网络的风电出力预测方法[J].电力系统保护与控制,2023,51(6):170-178.  
CHEN Feng, YU Yi, XU Jingyou, et al. Prediction method of wind power output based on a Bayes-LSTM network[J]. Power System Protection and Control, 2023, 51(6): 170-178.
- [11] 陈船宇,熊国江,方厚康,等.基于MODWT-CEEMDAN-LSTM的短期光伏功率区间预测模型[J].太阳能学报,2025,46(2):416-424.  
CHEN Chuanyu, XIONG Guojiang, FANG Houkang, et al. Short-term photovoltaic power interval prediction

- model based on modwt-ceemdan-lstm [J]. *Acta Energiae Solaris Sinica*, 2025, 46(2): 416-424.
- [12] 戴朝辉, 陈昊, 刘莘轶, 等. 基于K-medoids-GBDT-PSO-LSTM组合模型的短期光伏功率预测[J]. *太阳能学报*, 2025, 46(1): 654-661.  
DAI Zhaohui, CHEN Hao, LIU Xinyi, et al. Short-term photovoltaic power prediction based on k-medoids-gbdt-pso-lstm combined model [J]. *Acta Energiae Solaris Sinica*, 2025, 46(1): 654-661.
- [13] 吐松江·卡日, 雷柯松, 马小晶, 等. 基于LSTM-Attention和CNN-BiGRU误差修正的光伏功率预测[J]. *太阳能学报*, 2024, 45(12): 85-93.  
KARI·Tusongjiang, LEI Kesong, MA Xiaojing, et al. Photovoltaic power prediction based on lstm-attention and cnn-BiGRU error correction [J]. *Acta Energiae Solaris Sinica*, 2024, 45(12): 85-93.
- [14] 张海涛, 李文娟, 李雪峰, 等. 基于变分模态分解和时间注意力机制TCN网络的光伏发电功率预测[J]. *电测与仪表*, 2024, 61(12): 156-163.  
ZHANG Haitao, LI Wenjuan, LI Xuefeng, et al. Photovoltaic power forecasting based on TPA-TCN model and variational modal decomposition [J]. *Electrical Measurement & Instrumentation*, 2024, 61(12): 156-163.
- [15] 薛阳, 燕宇铖, 贾巍, 等. 基于改进灰狼算法优化长短期记忆网络的光伏功率预测[J]. *太阳能学报*, 2023, 44(7): 207-213.  
XUE Yang, YAN Yucheng, JIA Wei, et al. Photovoltaic power prediction model based on igwo-lstm [J]. *Acta Energiae Solaris Sinica*, 2023, 44(7): 207-213.
- [16] 王晓霞, 俞敏, 冀明, 等. 基于气候相似性与SSA-CNN-LSTM的光伏功率组合预测[J]. *太阳能学报*, 2023, 44(6): 275-283.  
WANG Xiaoxia, YU Min, JI Ming, et al. Photovoltaic power combination forecasting based on climate similarity and ssa-cnn-lstm [J]. *Acta Energiae Solaris Sinica*, 2023, 44(6): 275-283.
- [17] 刘甚臻, 马超. 基于小波变换和混合深度学习的短期光伏功率预测[J]. *可再生能源*, 2023, 41(6): 744-749.  
LIU Shenzhen, MA Chao. Short-term photovoltaic power prediction based on wavelet transform and hybrid deep learning [J]. *Renewable Energy Resources*, 2023, 41(6): 744-749.
- [18] ZHAI C, HE X Y, CAO Z X, et al. Photovoltaic power forecasting based on VMD-SSA-Transformer: Multidimensional analysis of dataset length, weather mutation and forecast accuracy [J]. *Energy*, 2025, 324: 135971.
- [19] TANG H D, KANG F, LI X Y, et al. Short-term photovoltaic power prediction model based on feature construction and improved transformer [J]. *Energy*, 2025, 320: 135213.
- [20] 黄晓燕, 郭洒洒, 陈成优, 等. 考虑时空关联及气象耦合的区域分布式光伏功率预测[J]. *浙江电力*, 2025, 44(3): 79-89.  
HUANG Xiaoyan, GUO Sasa, CHEN Chengyou, et al. Regional distributed photovoltaic power forecasting considering spatiotemporal correlation and meteorological coupling [J]. *Zhejiang Electric Power*, 2025, 44(3): 79-89.
- [21] PIANTADOSI G, DUTTO S, GALLI A, et al. Photovoltaic power forecasting: a Transformer based framework [J]. *Energy and AI*, 2024, 18: 100444.
- [22] CHEN R J, LIU G, CAO Y S, et al. CGAformer: Multi-scale feature Transformer with MLP architecture for short-term photovoltaic power forecasting [J]. *Energy*, 2024, 312: 133495.
- [23] ZHAO X. A novel digital-twin approach based on transformer for photovoltaic power prediction [J]. *Scientific Reports*, 2024, 14: 26661.
- [24] 陆毅, 薛枫, 唐小波, 等. 基于余弦相似度和TSO-BP的短期光伏预测方法[J]. *浙江电力*, 2024, 43(6): 22-30.  
LU Yi, XUE Feng, TANG Xiaobo, et al. A short-term PV power forecasting method based on cosine similarity and TSO-BP neural network [J]. *Zhejiang Electric Power*, 2024, 43(6): 22-30.
- [25] KIM J, OBREGON J, PARK H, et al. Multi-step photovoltaic power forecasting using transformer and recurrent neural networks [J]. *Renewable and Sustainable Energy Reviews*, 2024, 200: 114479.
- [26] 叶林, 李奕霖, 裴铭, 等. 寒潮天气小样本条件下的短期风电功率组合预测[J]. *中国电机工程学报*, 2023, 43(2): 543-554.  
YE Lin, LI Yilin, PEI Ming, et al. Short-term wind power combination forecast under the condition of small sample in cold wave weather [J]. *Proceedings of the CSEE*, 2023, 43(2): 543-554.
- [27] 余光正, 陆柳, 汤波, 等. 考虑转折性天气的海上风电功率超短期分段预测方法研究[J]. *中国电机工程学报*, 2022, 42(13): 4859-4871.  
YU Guangzheng, LU Liu, TANG Bo, et al. Research on ultra-short-term subsection forecasting method of offshore wind power considering transitional weather [J]. *Proceedings of the CSEE*, 2022, 42(13): 4859-4871.

收稿日期: 2025-07-16; 修回日期: 2025-08-06

作者简介:

李增伟(1996), 男, 工学硕士, 高级工程师, 研究方向为多源数据融合的变电站故障诊断等。

(本文编辑: 方明霞)