

一种基于多特征融合的短期光伏功率预测方法研究

成晓龙¹, 王志文^{1,2,3*}, 令国壁¹, 王浩旭¹, 申博彦¹

(1. 兰州理工大学自动化与电气工程学院, 甘肃省 兰州市 730050; 2. 甘肃省工业过程先进控制重点实验室(兰州理工大学), 甘肃省 兰州市 730050; 3. 兰州理工大学电气与控制工程国家级实验教学示范中心, 甘肃省 兰州市 730050)

Study on Short-Term Photovoltaic Power Prediction Based on Multi-Feature Fusion

CHENG Xiaolong¹, WANG Zhiwen^{1,2,3*}, LING Guobi¹, WANG Haoxu¹, SHEN Boyan¹

(1. College of Automation and Electrical Engineering, Lanzhou University of Technology, Lanzhou 730050, Gansu Province, China; 2. Key Laboratory of Gansu Advanced Control for Industrial Processes (Lanzhou University of Technology), Lanzhou 730050, Gansu Province, China; 3. National Experimental Teaching Demonstration Center for Electrical and Control Engineering, Lanzhou University of Technology, Lanzhou 730050, Gansu Province, China)

摘要:【目的】为提升新能源系统的稳定性并实现光伏发电功率的精确预测,提出了一种融合多尺度时间卷积网络(multi-scale temporal convolutional network, MS-TCN)、门控位置感知编码器(gated position-aware transformer encoder, GPATE)与双向门控循环单元(bidirectional gated recurrent unit, BiGRU)的组合预测模型。【方法】首先,采用MS-TCN模块提取多维时序数据中的局部特征;然后,设计GPATE模块,通过位置多层感知器替代传统前馈网络,并引入门控机制以抑制噪声,增强模型对长期依赖与全局上下文信息的感知能力;最后,融合MS-TCN与GPATE的特征表示,利用BiGRU构建双向时序依赖,进一步强化对复杂时间动态特征的建模能力。【结果】相比Transformer模型,所提模型在RMSE和MAE两项指标上分别实现42.87%和29.37%的显著提升。【结论】通过结构创新有效提升了预测准确性,为高比例新能源接入下的电力系统调度提供了可靠支持。

关键词: 新能源; 光伏; 功率预测; 多尺度时间卷积网络(MS-TCN); 门控位置感知编码器(GPATE); 特征融合; 结构创新

ABSTRACT: [Objectives] To enhance the stability of renewable energy systems and achieve accurate photovoltaic power prediction, this study proposes a hybrid prediction model integrating a multi-scale temporal convolutional network (MS-TCN), a gated position-aware transformer

encoder (GPATE), and a bidirectional gated recurrent unit (BiGRU). [Methods] The MS-TCN module is first employed to extract local features from multi-dimensional time series data. Then, the GPATE module is introduced, in which the traditional feedforward network is replaced by a position-aware multilayer perceptron, augmented with a gating mechanism to suppress noise and enhance the model's ability to capture long-term dependencies and global contextual information. Finally, the feature representation of MS-TCN and GPATE is fused, and BiGRU is used to construct bidirectional temporal dependencies to further strengthen the modeling ability of complex temporal dynamic features. [Results] Compared with the Transformer model, the proposed model achieves significant improvements of 42.87% and 29.37% in RMSE and MAE, respectively. [Conclusions] Through structural innovation, the proposed model effectively improves prediction accuracy and provides reliable support for power system scheduling under high penetration of renewable energy.

KEY WORDS: renewable energy; photovoltaic; power prediction; multi-scale temporal convolutional network (MS-TCN); gated position-aware transformer encoder (GPATE); feature fusion; structural innovation

0 引言

随着化石能源的过度消耗,生态环境问题日益严峻^[1-3]。太阳能因其资源丰富、经济环保、高效安全等优势,在新能源发电领域扮演关键角色^[4-6]。国际能源署发布公告,指出预计到2040年,

基金项目: 国家自然科学基金项目(62263019)。

Project Supported by National Natural Science Foundation of China (62263019).

新能源在全球能源结构中的占比将达到60%，其中光伏和风能的占比将超过50%^[7]。2019年全球光伏装机容量累计为633GW，而2024年全球光伏装机容量已经超过了1200GW，增长趋势显著^[8]。然而，光伏发电系统易受太阳辐照度等环境因素的影响，表现出显著的随机性、间歇性、不确定性和波动性^[9-12]。这些特性给光伏发电功率预测带来了巨大挑战^[13-17]。

根据预测方法原理的差异性，光伏功率预测方法可分为统计学习、机器学习和深度学习3种方法^[18]。基于统计学习的光伏功率预测方法，包括非线性回归模型(nonlinear regression model, NLR)^[19]、马尔科夫链(Markov chain, MC)模型^[20]和自回归移动平均模型(autoregressive moving average model, ARMA)^[21]等。此类模型通常假设天气和光伏系统为线性关系，虽然初步解决了预测精度和稳定性问题^[22]。但光伏发电因素变量间存在强耦合、复杂性、非线性等关系，而上述模型均忽略了多变量间的相互作用，导致预测结果准确性较差。

机器学习方法因其强大的非线性映射能力，对各种随机干扰的气象因素有着较好的适应性^[23]，因此大量基于机器学习的光伏功率预测模型涌现出来。Liu等人^[24]为了高效利用气象因素，首先采用相关系数法来确定模型的输入，其次结合鸡群优化算法(chicken swarm optimization, CSO)和极限学习机(extreme learning machine, ELM)方法进行光伏功率预测。结果表明，在实际光伏功率预测中，所提方法优于统计学方法，但由于季节性差异，数据波动巨大，影响预测精度。尽管机器学习方法在处理非线性时序数据比统计学方法灵活性和预测精度高，但当面临比较复杂的问题时，容易陷入局部最优等问题，反而使预测误差变大^[25-26]。

近年来，随着数据采集技术及存储技术的迅猛发展，深度学习方法被广泛应用于光伏功率预测，并取得了良好的效果^[27-30]。在这些深度学习方法中，常采用卷积神经网络(convolutional neural network, CNN)来捕捉时序数据中的局部相关性^[31]。Lim等人^[32]考虑时序数据之间的局部变化及

天气状况的影响，提出一种基于CNN的光伏功率预测方法，并在真实数据集中验证了该方法的有效性。但是，由于CNN卷积非因果，其在处理时序数据计算某个位置特征时，会使用过去、现在、未来的信息，导致训练和推理效率无法有效提高且存在数据泄漏问题。而时间卷积网络(temporal convolutional network, TCN)采用膨胀卷积结构，不仅能够灵活调整感受野，还占用较低的内存，有效克服了CNN的上述缺陷^[33-38]。在时序预测任务中，陈禹帆等人^[39]通过将TCN与注意力机制相结合，利用TCN捕捉序列中的局部特征，并通过注意力机制强化关键气象因素对光伏输出的影响，提升了预测精度与鲁棒性。尽管如此，该类方法在捕获长期依赖关系方面仍存在明显局限。

在长期依赖建模方面，Transformer模型的兴起为时序预测领域带来了重要变革。与传统模型相比，Transformer能够有效捕捉时序数据中的长期依赖关系，克服了长序列预测的局限性^[40-42]。Zhou等人^[43]基于陕西太阳辐射数据，对比分析了长短期记忆网络(long short-term memory, LSTM)与Transformer的预测性能，结果表明：LSTM受固有结构所限，在捕捉太阳辐射时间序列的长距离依赖方面存在明显不足；而Transformer则能够更好地建模远距离依赖关系，它的自注意力机制能够捕获全局依赖，弥补LSTM等模型仅能捕捉局部模式的缺陷。此外，Transformer模型在位置感知能力上存在固有缺陷，这一问题已成为制约其序列建模性能的关键瓶颈。针对该缺陷，文献[44-46]提出旋转位置编码等创新性改进方案。相关研究结果验证了这类改进策略的有效性，使得模型对序列中元素的相对位置与绝对位置感知能力得到显著增强。

尽管光伏功率预测研究已取得显著进展，但现有方法仍难以兼顾序列中的局部波动特征与长期依赖关系。因为局部波动易受极端天气等短时因素影响，而长期依赖则与季节变化等宏观因素密切相关，二者共同制约了预测精度。针对这一问题，本文提出一种融合多尺度时间卷积网络(multi-scale temporal convolutional network, MS-TCN)与门控位置感知编码器(gated position-aware

transformer encoder, GPATE)模块的短期光伏发电功率预测方法,通过组合不同模型,以全面提升光伏功率的预测精度。

1 光伏发电功率预测模型

1.1 多尺度时间卷积网络

时间卷积网络是基于卷积神经网络改进的深度学习架构,专为时间序列建模设计。其创新在于通过因果卷积、膨胀卷积的协同作用,以及更少的网络层数来实现更大的感受野^[34]。TCN通过因果卷积确保模型不会泄露未来的信息,适合时间序列预测。TCN结构如图1所示。为进一步强化模型对时序特征捕获能力,多尺度时间卷积网络(MS-TCN)在TCN的基础上优化结构设计,采用堆叠的膨胀卷积模块,每层的膨胀因子 d 按 2^n (n 为层数)递增,由此构建出多尺度特征金字塔,这种层级化的膨胀结构显著提升了模型的建模效率。




图1 时间卷积网络结构图
Fig. 1 Architecture of TCN

1.2 残差模块

残差模块是残差网络中的核心组成部分,通过引入跳跃连接、模块化设计及并行计算能力,不仅在时序任务中表现出优越性能,还有效缓解了深度神经网络中普遍存在的梯度消失和网络退

化问题。残差块输出可表示为

$$Y=g[f(X)+Conv1D(X)]$$
 (1)

式中: Y 为残差块的输出; X 为残差块的输入; $f(\cdot)$ 表示左分支的变换; $Conv1D(\cdot)$ 为一维卷积; $g(\cdot)$ 为激活函数ReLU。

1.3 门控位置感知编码器结构

Transformer因其出色的上下文理解能力,在处理时间序列预测问题上展现出显著的优势^[47]。然而,在深层网络中,尤其是在经过多头注意力机制聚合与残差连接反复叠加之后,特定位置的信息容易被稀释或与其他位置信息发生过度融合,导致预测精度下降。为进一步强化模型对位置信息的感知能力并提升预测性能,本文将编码器中的前馈神经网络替换为位置多层感知器(positional multi-layer perceptron, PMLP)。前馈神经网络对序列中每个token施加相同的变换,与位置无关,因而无法充分利用序列中的位置信息。而PMLP通过引入位置感知机制,打破了对token位置的无差别处理,能够依据其绝对或相对位置进行自适应的特征变换,从而更有效地捕捉时间序列中的位置依赖模式。此外,PMLP在处理过程中可能引入一定的随机噪声,干扰模块的学习过程并对预测结果产生负面影响。为缓解该问题,在PMLP输出端引入门控机制,构成一个新模块——门控位置感知编码器,其结构如图2所示。该门控机




图2 GPATE结构图
Fig. 2 Architecture of GPATE

制能够动态识别重要信息与噪声，调节信息流动，从而提升模型的表达能力和预测准确性。

1.4 双向门控循环单元

门控循环单元 (gated recurrent unit, GRU) 有效缓解了传统 RNN 处理长序列时的梯度消失问题，在序列数据建模中得到广泛应用。为进一步突破单一方向信息流仅能捕捉单侧时序依赖的局限，本文采用双向门控循环单元 (bidirectional GRU, BiGRU) 网络模型^[48]结合了正向传播和反向传播 2 个双向 GRU 模型，其结构如图 3 所示。BiGRU 网络模型在任一时刻都能接收同一个输入，克服了单一方向信息流的局限性，其表达式如下：

$$\begin{cases} \vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}) \\ \tilde{h}_t = \text{GRU}(x_t, \tilde{h}_{t-1}) \\ h_t = W_{\vec{h}} \vec{h}_t + W_{\tilde{h}} \tilde{h}_t + b_t \end{cases} \quad (2)$$

式中：GRU 函数表示对输入时间数据进行非线性变换； x_t 、 h_t 分别为 t 时刻隐藏层的输入、输出； $\vec{h}_t$ 、 $\tilde{h}_t$ 分别为 t 时刻正、反向隐藏层的状态输出； $W_{\vec{h}}$ 与 $W_{\tilde{h}}$ 分别为 $\vec{h}_t$ 与 $\tilde{h}_t$ 所对应的权重向量； b_t 为 t 时刻 BiGRU 隐藏层状态的偏置量。




图3 BiGRU 结构图

Fig. 3 Architecture of BiGRU

2 光伏发电功率预测流程

本文提出了一种 MSTCN-GPATE 与 BiGRU 组合模型的光伏功率预测方法，其整体预测流程如图 4 所示。首先，采用皮尔逊相关系数 (Pearson correlation coefficient, PCC) 对历史光伏数据进行特征相关性分析，筛选出与功率输出显著相关的关键气象及环境变量。随后在特征提取阶段，针对优选特征构建了一个多尺度时间卷积网络，通过组合不同尺度的卷积核 (3/5/7) 与逐层递增的膨胀系数 (1/2/4)，构建具有金字塔结构的空洞卷积层次。同时，引入门控位置感知编码器模块，该模块集成了位置多层感知器、门控循环机制及多头注意力。最后，将多尺度时间卷积与门控位




图4 模型预测流程图

Fig. 4 Model prediction flowchart

置感知编码器提取的特征输入双向门控循环单元，利用双向门控机制实现时间上下文的信息整合，进而输出最终的光伏功率预测值。

3 仿真验证

3.1 数据集说明

本文实验数据来源于我国榆林某工业园区光伏电站(装机容量 50 MW)，采样时间为 2021 年 1 月 1 日 00:00:00—12 月 31 日 23:45:00，该数据集包含了相对应的气象数据和功率数据，采样间隔 15 min，总共收集了 35 040 个样本条。

为提高数据质量，提升预测精度，采用数据清洗方式对原始数据进行处理。采用数据均值对数据中的缺失值进行填补；使用 Z-Score 标准化数据，识别数据中的异常值。上述计算公式如下：

$$\bar{X} = \frac{1}{m} \sum_{i=1}^m s_i \quad (3)$$

$$Z = \frac{s - \mu}{\sigma} \quad (4)$$

式中： $\bar{X}$ 为均值； m 为数据样本数量； s_i 为原始数据样本； Z 为标准化值； s 是数据点； μ 是均值； σ 是标准差。

鉴于光伏数据集各特征之间存在显著差异，为确保模型训练与预测的准确性，首先进行归一化处理。计算公式如下：

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

式中： x' 为归一化后的值； x 为原始值； $x_{\max}$ 、 $x_{\min}$ 分别为原始值中最大值和最小值。

3.2 光伏发电功率影响因素

影响光伏发电功率的气象因素具有显著的随机性和不稳定性，其中主要包括组件温度、辐照度、环境温度、相对湿度、相对气压、降雨量、风速和风向等^[49]。不同气象因素对发电功率的影响程度各异，因此本文采用 PCC 对各特征与输出功率之间的相关性进行分析，以剔除冗余及不相关特征。PCC 的绝对值越大，表示该气象变量与输出功率的相关性越强，其计算公式如式(1)所示，分析结果如表 1 所示。

$$r(a, b) = \frac{\sum_{i=1}^N (a_i - \bar{a})(b_i - \bar{b})}{\sqrt{\sum_{i=1}^N (a_i - \bar{a})^2 \sum_{i=1}^N (b_i - \bar{b})^2}} \quad (6)$$

式中： a 为输入变量； b 为因变量； N 为样本数量； a_i 、 b_i 分别为第 i 个输入变量、因变量； $\bar{a}$ 为输入变量平均值； $\bar{b}$ 为因变量平均值。

表1 光伏发电功率与环境因素的相关系数

Tab. 1 Photovoltaic power output and its correlation coefficients with environmental variables

环境因素	相关系数 r
组件温度	0.892
总辐照度	0.883
直射辐照度	0.858
散射辐照度	0.839
相对气压	-0.653
风向	0.062
风速	-0.053
相对湿度	0.707
环境温度	0.145
降雨量	-0.054

根据表 1 相关系数 r 可知，组件温度、总辐照度、直射辐照度、散射辐照度等局部特征的相关系数均在 0.830 以上，以环境温度、相对湿度、相对气压为代表的全局特征对发电功率也存在较大影响，而相对气压、降雨量等特征存在负相关性。相关系数 r 绝对值大于 0.1 的环境因素影响较大，故本文选取组件温度、总辐照度、直射辐照度、散射辐照度、相对气压、环境温度和相对湿度作为影响光伏发电功率的主要气象因素。

3.3 网络参数设置

实验基于 Win11 操作系统、i5-1155G7 处理器，采用 MATLAB 2023b 构建实验环境，网络训练参数设定如下：学习率设定为 0.001，批量大小设定为 200，轮次设定为 100，损失函数设定为 RMSE(root mean square error, RMSE)，优化器选用 Adam Optimizer。此外，将数据按照 8 : 2 划分为训练集和测试集。

3.4 评价指标

为了证明本文所提方法的实验性能，采用均方根误差(RMSE)、平均绝对误差(mean absolute error, MAE)作为模型的评价指标，计算公式

如下：

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

(7)

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

(8)

式中： E_{RMSE} 为均方根误差； E_{MAE} 为平均绝对误差； y_i 为实际的光伏发电功率； $\hat{y}_i$ 为模型预测的光伏发电功率； n 为预测步数。

3.5 实验验证及分析

本文将数据集划分为春夏秋冬4个子数据集，分别对应3—5月，6—8月，9—11月，12、1、

2月。这种划分方式不仅能够捕捉到不同季节光伏功率输出的独特变化模式，还能够验证所提模型在各种气候条件下的适用性和稳定性。以春季数据集为例，将前80%天数的数据作为训练集对模型参数进行更新，后20%天数的数据作为测试集用于评估模型性能，其余3个季节的数据集划分标准与春季数据集相同。为确保数据的完整性和质量，分别选取每个季节中的部分数据集作为实验数据(具体划分方式如表2所示)，该数据涵盖了各季节典型的天气变化，能够有效支撑模型的训练与评估。

表2 选取的部分典型数据集
Tab. 2 Selected typical datasets

类型	数据量(日期)			
	春季	夏季	秋季	冬季
训练集	3 072(2021.03.09—2021.04.09)	3 072(2021.07.03—2021.08.03)	3 072(2021.09.01—2021.10.02)	3 072(2021.01.01—2021.02.01)
测试集	768(2021.04.10—2021.04.17)	768(2021.08.05—2021.08.12)	768(2021.10.03—2021.10.10)	768(2021.02.02—2021.02.09)

为了更好地呈现本文提出的基于多特征融合的短期光伏功率预测模型的优势，选用多种现有的预测方法进行了全面的性能对比。如表3所示，

分别选用CNN-LSTM^[50]、GRU、Transformer^[51]及TCN-BiGRU-Attention多种深度学习方法作为对比组。评价指标涵盖了MAE、RMSE。

表3 不同模型在4个季节的评价指标对比
Tab. 3 Comparison of evaluation indicators of different models across four seasons

模型	春季		夏季		秋季		冬季	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
GRU	2.03	3.11	2.41	3.58	2.54	3.25	3.63	4.31
CNN-LSTM	1.68	2.94	1.74	2.85	1.64	3.36	3.23	3.35
Transformer	1.32	2.29	1.45	2.68	1.26	2.35	2.54	3.16
TCN-BiGRU-Attention	1.54	2.47	1.32	2.57	1.36	2.53	1.75	2.91
本文模型	0.84	1.65	1.21	2.48	0.91	1.85	1.45	2.75

由表3可得，本文所提模型的评估指标在4个季节的数据集上均表现最优。相比4个对比模型中的最优结果，在春夏秋冬4个季节的数据集上，本文所提模型的MAE分别降低了36.36%、8.33%、27.78%和17.14%，RMSE分别降低了27.95%、3.51%、21.28%和5.50%。

本文提出的模型与经典Transformer模型均采用了多头注意力机制作为核心组件。从表3的实验结果可以看出，在春季和秋季，次优模型均为Transformer，其MAE值相较于其他对比模型均最小。此外，Transformer模型四季平均MAE较GRU提升39.25%，可见引入多头注意力机制后，模型

在捕捉长距离依赖方面展现出明显优势。而在夏季和冬季，数据波动较大，通过融合单层TCN与单头注意力机制的混合模型(即TCN-BiGRU-Attention模型)，其MAE值相比其它对比模型均最小，这是因为TCN模块在数据平滑处理方面具有明显优势；此外，其四季平均MAE较GRU提升26.86%。本模型通过结合上述各自优势，并采用MS-TCN模块和GPATE模块提升模型对数据位置变化的敏感性，使得四季平均MAE较GRU提升了58.14%。

为更直观地展示预测效果，本文从4个季节的测试集中分别选取了4d数据，涵盖晴天、多

云、阴天和降雨等多种天气类型，以全面评估模型在不同气象条件下的性能，并分析天气变化对预测精度的影响。所选具体时段为：2021年4月

12—15日(春)、8月7—10日(夏)、10月7—10日(秋)及2021年2月4—7日(冬)。不同模型短期预测性能对比如图5所示。




图5 各模型短期预测性能对比

Fig. 5 Comparison of short-term prediction performance across different models

通过对比图5中不同模型的拟合效果可看出，传统CNN-LSTM与GRU模型在全天候条件下的预测性能较差，尤其在夏、冬季极端天气中拟合曲线出现明显偏差，其中GRU模型在温度突变时段甚至出现预测失效。主要原因是极端天气导致数据剧烈波动，破坏了时序周期性，使得传统循环神经网络难以建立有效的时序关联。相比之下，基于自注意力机制的Transformer模型与TCN-BiGRU-Attention混合模型表现出更强的鲁棒性，波峰预测准确性高于GRU。然而，Transformer虽能够建模全局依赖，但其动态权重分配机制导致对局部特征的捕捉不稳定。TCN-BiGRU-Attention模型虽强化了局部特征提取，却因结构交互限制未能充分构建跨步全局关联。本文所提出的MSTCN-GPATE与BiGRU组合模型通过多尺度特征融合机制，在结构层面实现显著改进，在实际功率曲线拟合中表现出色，波峰与波谷预测稳定，未出现过拟合，同时有效抑制了噪声，使预测值更贴近真实值。

3.6 消融实验

为验证本文所提模型中各模块的有效性，我们开展了消融实验。通过逐步移除或替换模型中的关键组件，系统评估了各模块对整体性能的贡献。实验严格遵循“单一变量”原则，确保每次仅调整一个组件，以保障结果的可比性与结论的可靠性。具体设置以下4组对比实验：

- 1) 将MS-TCN模块替换为TCN，以评估多尺度时间卷积网络在时间序列建模中的提升效果。
- 2) 将GPATE模块中的位置多层感知器与门控机制替换为标准前馈网络，以探究其在长期依赖建模和动态特征选择中的作用。
- 3) 完全移除TCN模块，仅保留GPATE模块，用于评估TCN对模型性能的独立贡献。
- 4) 移除GPATE模块，仅保留TCN模块，以验证GPATE在特征表达和时序建模中的有效性。

消融实验结果如表4所示。通过上述对比，能够明确各模块的重要性及其协同作用。

3.7 泛化实验

为进一步评估所提模型的泛化能力，本文采

表4 消融实验结果

Tab. 4 Ablation experiment results

模型	RMSE	MAE
TCN-GTrXL-BiGRU	2.616 9	0.949 5
MSTCN-Encoder-BiGRU	2.709 4	1.354 7
Encoder-BiGRU	3.053 6	1.527 6
TCN-BiGRU	3.657 1	1.839 1
本文模型	1.666 3	0.802 1

用一个完整年度的数据集，按8：2的比例划分为训练集和测试集进行实验，结果如表5所示。

实验结果表明，即使在更具挑战性的跨季节泛化任务中，本文所提出的MSTCN-GPATE与BiGRU组合模型仍然取得了最低的RMSE和MAE值，以及最高的 R^2 （决定系数）值，显著优于所有对比模型。这充分验证了该组合模型不仅能够在同一季节内保持优异性能，还能有效学习跨季节的通用时间特征，表现出强大的泛化能力与实际应用潜力。

表5 泛化实验结果

Tab. 5 Generalization experiment results

模型	RMSE	MAE	R^2
GRU	3.9573	2.0325	0.8332
CNN-LSTM	3.3523	1.5627	0.8754
Transformer	3.0157	1.3274	0.8936
TCN-BiGRU-Attention	2.9169	1.2116	0.9026
本文模型	1.723	0.9373	0.9632

4 结论

针对光伏序列中短期波动剧烈与长期依赖关系复杂，且现有方法难以同时有效捕捉这2类特征，提出了一种基于MSTCN-GPATE与BiGRU的预测方法，并通过仿真实验对其性能进行了验证。实验结果表明：

1) 本文对MS-TCN模块与GPATE模块进行了改进：其中改进后的MS-TCN模块强化了局部关键特征的提取效能，改进后的GPATE模块则在提升位置感知精度的同时，优化了对长期依赖关系的建模能力。

2) 考虑到光伏数据受季节变化影响显著的特性，本文通过构建不同季节的数据子集开展实验验证，结果显示所提模型在各季节数据场景下均表现出优异的季节适应性与泛化性能。

3) 为提升预测精度，针对融合后特征的时序演变规律，本文采用BiGRU作为动态时序解码器，为高比例新能源电力系统中的短期功率预测提供了一种技术方案。

参考文献

[1] 李梦宇, 王健, 田野. 碳达峰碳中和目标下中国经济产业发展研究[J]. 全球能源互联网, 2024, 7(6): 629-639.

Li M Y, Wang J, Tian Y. Research on the development of China's economic industry under the goal of carbon peak and carbon neutrality[J]. Journal of Global Energy Interconnection, 2024, 7(6): 629-639.

[2] 赵德福, 袁家海, 张健, 等. 多层次视角下颠覆性技术驱动的中国能源电力转型路径[J]. 电力建设, 2024, 45(8): 1-10.

Zhao D F, Yuan J H, Zhang J, et al. China's energy and power system transition pathways driven by disruptive technologies: a multilevel perspective[J]. Electric Power Construction, 2024, 45(8): 1-10.

[3] 罗莎莎, 郭经韬, 蔡颖倩, 等. 面向碳中和的广东省电源结构转型分析[J]. 南方能源建设, 2024, 11(4): 102-110.

Luo S S, Guo J T, Cai Y Q, et al. Analysis on power supply structure transformation towards carbon neutrality in Guangdong[J]. Southern Energy Construction, 2024, 11(4): 102-110.

[4] 龙潇, 张晋宾, 陈令特. 未来能源技术展望[J]. 发电技术, 2025, 46(4): 651-693.

Long X, Zhang J B, Chen L T. Prospects for future energy technologies[J]. Power Generation Technology, 2025, 46(4): 651-693.

[5] 孙丽平, 宋子恒, 马骏, 等. 中国太阳能光热发电技术研究综述[J]. 南方能源建设, 2025, 12(5): 70-84.

Sun L P, Song Z H, Ma J, et al. Research overview of solar thermal power technology in China[J]. Southern Energy Construction, 2025, 12(5): 70-84.

[6] 李富春, 刘飞, 邵成成, 等. 光热与光伏发电综合对比[J]. 电力工程技术, 2024, 43(1): 246-253.

Li F C, Liu F, Shao C C, et al. Comprehensive comparison between photothermal power generation and photovoltaic power generation[J]. Electric Power Engineering Technology, 2024, 43(1): 246-253.

[7] Cao L, Yang H Y, Zhou C G, et al. Photovoltaic short-term output power forecast model based on improved complete ensemble empirical mode decomposition with

- adaptive noise - kernel principal component analysis-long short-term memory[J]. *Energies*, 2024, 17(24): 6365.
- [8] 刘宏志, 秦晓辉. “双碳”目标与新型电力系统构建的底层逻辑[J]. *电气应用*, 2025, 44(1): 8-10.
- Liu H Z, Qin X H. The goal of “double carbon” and the underlying logic of new power system construction [J]. *Electrotechnical Application*, 2025, 44(1): 8-10.
- [9] Zheng K, Sun Z Y, Song Y, et al. Stochastic scenario generation methods for uncertainty in wind and photovoltaic power outputs: a comprehensive review[J]. *Energies*, 2025, 18(3): 503.
- [10] 李夫刚, 李夫海, 琚承乾, 等. 新能源不确定性表征方法及关键技术问题研究现状、挑战及展望[J]. *电力系统保护与控制*, 2025, 53(15): 172-187.
- Li F G, Li F H, Ju C Q, et al. Methods for characterizing renewable energy uncertainty and key technical issues: research status, challenges, and prospects[J]. *Power System Protection and Control*, 2025, 53(15): 172-187.
- [11] 张永蕊, 阎洁, 林爱美, 等. 多点数值天气预报风速和辐照度集中式修正方法研究[J]. *发电技术*, 2022, 43(2): 278-286.
- Zhang Y R, Yan J, Lin A M, et al. Integrated correction method of multi-point numerical weather prediction wind speed and irradiance[J]. *Power Generation Technology*, 2022, 43(2): 278-286.
- [12] 管庭基, 罗萍萍, 林济铿, 等. 基于生成对抗网络的中长期光伏出力场景生成方法[J]. *电力科学与技术学报*, 2025, 40(4): 161-170.
- Guan T J, Luo P P, Lin J K, et al. Method for generating medium and long-term photovoltaic output scenarios based on generative adversarial networks[J]. *Journal of Electric Power Science and Technology*, 2025, 40(4): 161-170.
- [13] 张一帆, 王宇强, 潘大志, 等. 基于云图数据的分布式光伏超短期功率预测方法研究[J]. *电网与清洁能源*, 2025, 41(9): 110-115.
- Zhang Y F, Wang Y Q, Pan D Z, et al. Research on prediction methods of distributed photovoltaic ultra-short-term power based on cloud image data[J]. *Power System and Clean Energy*, 2025, 41(9): 110-115.
- [14] 桂前进, 徐文法, 李晓阳, 等. 基于时序分解与共形分位数回归的超短期光伏功率区间预测[J]. *中国电力*, 2025, 58(5): 21-32.
- Gui Q J, Xu W F, Li X Y, et al. Ultra-short-term photovoltaic power interval forecasting based on time-series decomposition and conformal quantile regression[J]. *Electric Power*, 2025, 58(5): 21-32.
- [15] 武光华, 李宏胜, 李鹏, 等. 一种新型光伏能源电力中长期功率波动预测模型构建[J]. *电网与清洁能源*, 2025, 41(1): 130-136.
- Wu G H, Li H S, Li K, et al. Construction of a novel medium and long-term power fluctuation prediction model for photovoltaic power[J]. *Power System and Clean Energy*, 2025, 41(1): 130-136.
- [16] 杨康, 李蓝青, 李艺丰, 等. 一种新型分布式光伏出力区间预测方法[J]. *发电技术*, 2024, 45(4): 684-695.
- Yang K, Li L Q, Li Y F, et al. A novel distributed photovoltaic output interval prediction method[J]. *Power Generation Technology*, 2024, 45(4): 684-695.
- [17] 韩晓, 王涛, 韦晓广, 等. 考虑阵列间时空相关性的超短期光伏出力预测[J]. *电力系统保护与控制*, 2024, 52(14): 82-94.
- Han X, Wang T, Wei X G, et al. Ultrashort-term photovoltaic output forecasting considering spatiotemporal correlation between arrays[J]. *Power System Protection and Control*, 2024, 52(14): 82-94.
- [18] Alshahrani A, Omer S, Su Y H, et al. The technical challenges facing the integration of small-scale and large-scale PV systems into the grid: a critical review[J]. *Electronics*, 2019, 8(12): 1443.
- [19] Babatunde A A, Abbasoglu S. Predictive analysis of photovoltaic plants specific yield with the implementation of multiple linear regression tool[J]. *Environmental Progress & Sustainable Energy*, 2019, 38(4): 13098.
- [20] Chang G W, Lu H J. Integrating gray data preprocessor and deep belief network for day-ahead PV power output forecast[J]. *IEEE Transactions on Sustainable Energy*, 2020, 11(1): 185-194.
- [21] Alvarado-Barrios L, Rodríguez del Nozal Á, Boza Valerino J, et al. Stochastic unit commitment in microgrids: influence of the load forecasting error and the availability of energy storage[J]. *Renewable Energy*, 2020, 146: 2060-2069.
- [22] Sanjari M J, Gooi H B. Probabilistic forecast of PV power generation based on higher order Markov chain[J]. *IEEE Transactions on Power Systems*, 2017, 32(4): 2942-2952.
- [23] 付雪姣, 吕可欣, 吴林林, 等. 考虑不同天气类型样本的光伏功率日内预测模型[J]. *分布式能源*, 2024, 9(2): 39-47.
- Fu X J, Lyu K X, Wu L L, et al. Intraday prediction model for PV power considering samples of different weather types[J]. *Distributed Energy*, 2024, 9(2):

- 39-47.
- [24] Liu Z F, Li L L, Tseng M L, et al. Prediction short-term photovoltaic power using improved chicken swarm optimizer-Extreme learning machine model[J]. Journal of Cleaner Production, 2020, 248: 119272.
- [25] Zhu H L, Sun Y H, Jiang T T, et al. An FCM based weather type classification method considering photovoltaic output and meteorological characteristics and its application in power interval forecasting[J]. IET Renewable Power Generation, 2024, 18(2): 238-260.
- [26] Zhou H X, Zhang Y J, Yang L F, et al. Short-term photovoltaic power forecasting based on long short term memory neural network and attention mechanism[J]. IEEE Access, 2019, 7: 78063-78074.
- [27] 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 K Y, Du H D, Jia R, 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.
- [28] 马成廉, 韩瑞, 宋萌清, 等. 基于多源气象数据的光伏功率预测深度学习架构[J]. 电网与清洁能源, 2025, 41(4): 104-112.
- Ma C L, Han R, Song M Q, et al. Deep learning architecture for photovoltaic power prediction based on multi-source meteorological data[J]. Power System and Clean Energy, 2025, 41(4): 104-112.
- [29] 吐松江·卡日, 吴现, 马小晶, 等. 基于地基云图数据多维特征融合的光伏功率预测算法[J]. 电力系统保护与控制, 2025, 53(11): 84-94.
- Tusongjiang K R, WU X, MA X J, et al. Photovoltaic power prediction algorithm based on multidimensional features fusion of ground-based cloud images[J]. Power System Protection and Control, 2025, 53(11): 84-94.
- [30] 高岩, 吴汉斌, 张纪欣, 等. 基于组合深度学习的光伏功率日前概率预测模型[J]. 中国电力, 2024, 57(4): 100-110.
- Gao Y, Wu H B, Zhang J X, et al. Day-ahead probabilistic prediction model for photovoltaic power based on combined deep learning[J]. Electric Power, 2024, 57(4): 100-110.
- [31] 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.
- [32] Lim S C, Huh J H, Hong S H, et al. Solar power forecasting using CNN-LSTM hybrid model[J]. Energies, 2022, 15(21): 8233.
- [33] Wang M, Rao C J, Xiao X P, et al. Efficient shrinkage temporal convolutional network model for photovoltaic power prediction[J]. Energy, 2024, 297: 131295.
- [34] Limouni T, Yaagoubi R, Bouziane K, et al. Accurate one step and multistep forecasting of very short-term PV power using LSTM-TCN model[J]. Renewable Energy, 2023, 205: 1010-1024.
- [35] Li Y Y, Song L D, Zhang S, et al. A TCN-based hybrid forecasting framework for hours-ahead utility-scale PV forecasting[J]. IEEE Transactions on Smart Grid, 2023, 14(5): 4073-4085.
- [36] 王舒雨, 李豪, 马刚, 等. 基于 TCN 和 DLinear 的光伏发电功率多步预测模型[J]. 电力建设, 2025, 46(4): 173-184.
- Wang S Y, Li H, Ma G, et al. Multistep prediction model for photovoltaic power generation based on time convolution and DLinear[J]. Electric Power Construction, 2025, 46(4): 173-184.
- [37] 彭昱, 符琛, 郭昕, 等. 基于 FCM-BOA-TCN-GRU 的分布式光伏出力异常检测方法[J]. 电工技术学报, 2025, 40(17): 5389-5401.
- Peng Y, Fu C, Guo X, et al. Distributed photovoltaic power output anomaly detection method based on FCM-BOA-TCN-GRU[J]. Transactions of China Electrotechnical Society, 2025, 40(17): 5389-5401.
- [38] 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 H T, Li W J, Li X F, et al. Photovoltaic power forecasting based on TPA-TCN model and variational modal decomposition[J]. Electrical Measurement & Instrumentation, 2024, 61(12): 156-163.
- [39] 陈禹帆, 温蜜, 张凯, 等. 基于相似日匹配及 TCN-Attention 的短期光伏出力预测[J]. 电测与仪表, 2022, 59(10): 108-116.
- Chen Y F, Wen M, Zhang K, et al. Short-term photovoltaic output forecasting based on similar day matching and TCN-Attention[J]. Electrical Measurement & Instrumentation, 2022, 59(10): 108-116.
- [40] Tian F Y, Fan X X, Wang R T, et al. A power forecasting method for ultra-short-term photovoltaic power generation using transformer model[J]. Mathematical Problems in Engineering, 2022, 2022: 9421400.

- [41] 张禄晞, 石研, 曹志远, 等. 基于深层感知交互Transformer的光伏功率预测[J]. 智慧电力, 2025, 53(8): 70-78.
- Zhang L X, Shi Y, Cao Z Y, et al. Photovoltaic power forecasting based on deep perception-interaction transformer[J]. Smart Power, 2025, 53(8): 70-78.
- [42] 林江, 蔡晓龙, 周剑桥. 基于Transformer模型的光伏系统故障分类与预测方法[J]. 智慧电力, 2025, 53(4): 96-102.
- Lin J, Cai X L, Zhou J Q. Transformer model-based fault classification and prediction method for photovoltaic systems[J]. Smart Power, 2025, 53(4): 96-102.
- [43] Zhou Y, Li Y Z, Wang D J, et al. A multi-step ahead global solar radiation prediction method using an attention-based transformer model with an interpretable mechanism[J]. International Journal of Hydrogen Energy, 2023, 48(40): 15317-15330.
- [44] Xie X, Huang F, Peng Y Y, et al. A new design of an optimized informer wind power prediction model utilizing wind turbine health assessment[J]. Journal of Circuits, Systems and Computers, 2025, 34: 2550020.
- [45] Jiang Y Q, Gao T L, Dai Y X, et al. Very short-term residential load forecasting based on deep-autoformer[J]. Applied Energy, 2022, 328: 120120.
- [46] Cao Y S, Liu G, Luo D H, et al. Multi-timescale photovoltaic power forecasting using an improved Stacking ensemble algorithm based LSTM-Informer model[J]. Energy, 2023, 283: 128669.
- [47] Ahmed S, Nielsen I E, Tripathi A, et al. Transformers in time-series analysis: a tutorial[J]. Circuits, Systems, and Signal Processing, 2023, 42(12): 7433-7466.
- [48] Che C C, Wang H W, Ni X M, et al. Multi-head self-attention bidirectional gated recurrent unit for end-to-end remaining useful life prediction of mechanical equipment[J]. Measurement Science and Technology, 2022, 33(11): 115115.
- [49] 武宇翔, 韩肖清, 牛哲文, 等. 融合多注意力深度神经网络的可解释光伏功率区间预测[J]. 电网技术, 2024, 48(7): 2928-2939.
- Wu Y X, Han X Q, Niu Z W, et al. Interpretable photovoltaic power interval prediction using multi-attention deep neural networks[J]. Power System Technology, 2024, 48(7): 2928-2939.
- [50] Zhang H L, Tang Z, Deng Y Y, et al. Based on CNN-LSTM for photovoltaic output prediction of multi-scale method[J]. Journal of Physics: Conference Series, 2024, 2836(1): 012013.
- [51] Khalil I U, Ul Haq A, Ul Islam N. A deep learning-based transformer model for photovoltaic fault forecasting and classification[J]. Electric Power Systems Research, 2024, 228: 110063.
-
- 收稿日期: 2025-07-03.
修回日期: 2025-10-24.
作者简介:
-
- 成晓龙
- 成晓龙(1998), 男, 硕士研究生, 从事光伏发电功率预测研究, 1021176112@qq.com;
-
- 王志文
- 王志文(1976), 男, 博士, 教授, 从事模式识别与智能系统预测研究, 本文通信作者, wzw@lut.edu.cn;
-
- 申博彦
- 申博彦(2000), 男, 硕士研究生, 从事智能交通流量预测研究, 1779395950@qq.com。
- (责任编辑 苗雪连)