

DOI:10.19651/j.cnki.emt.2518426

基于时频域学习的中长期光伏功率预测^{*}

王文 朱文忠 成荣

(四川轻化工大学计算机科学与工程学院 宜宾 644000)

摘要: 针对现有的多变量长时间序列预测模型在光伏发电功率中长期预测中存在特征提取不足导致预测结果较差的问题,提出了一种基于频域和时域学习的多变量长时间序列预测模型 FFTEMixer,该模型能准确预测光伏发电功率的同时能保持较高的运行效率。该模型首先利用快速傅里叶变换将时序数据投影至频域,通过可学习的频率滤波器选择性增强或抑制特定频率分量,以提取全局特征和变量间相关性特征,紧接着再通过一个交互式卷积模块学习局部依赖关系,进一步提高特征表达能力;然后,通过特征融合器进一步整合周期性特征,并建立特征变量与时间戳协变量的关联;最后,采用多头自注意力机制全面建模序列的长期依赖性和时间依赖性,从而实现对时序数据的全面的特征提取。实验结果表明,在两个公开光伏发电数据集上,该模型的预测性能显著优于基准模型,均方误差和平均绝对误差始终为最低值。与当前主流次优模型相比,其均方误差和平均绝对误差分别降低了12.6%和15.8%,验证了模型的有效性。

关键词: 频域信息;时域信息;iTransformer;光伏发电;中长期功率预测

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

Medium- and long-term photovoltaic power prediction based on time-frequency domain learning

Wang Wen Zhu Wenzhong Cheng Rong

(School of Computer Science and Engineering, Sichuan University of Science and Engineering, Yibin 644000, China)

Abstract: Aiming at the existing multivariate long time series prediction model in the medium and long term prediction of photovoltaic (PV) power, which has the problem of poor prediction results due to insufficient feature extraction, a multivariate long time series prediction model FFTEMixer based on learning in both frequency and time domains is proposed, which is capable of accurately predicting the PV power while maintaining a high operational efficiency. The model first uses the fast Fourier transform to project time-series data into the frequency domain. It then selectively enhances or suppresses specific frequency components through learnable frequency filters to extract global features and inter-variable correlation features. Next, an interactive convolution module is used to learn local dependencies, further enhancing feature expression capabilities. Subsequently, a feature fusion module is employed to further integrate periodic features, and establishes associations between feature variables and time stamp covariates. Finally, a multi-head self-attention mechanism is employed to comprehensively model the long-term dependencies and temporal dependencies of the sequence, thereby achieving comprehensive feature extraction from time-series data. Experimental results show that on two publicly available photovoltaic power generation datasets, the model's predictive performance significantly outperforms the baseline model, with mean squared error (MSE) and mean absolute error (MAE) consistently achieving the lowest values. Compared to the current mainstream second-best model, its MSE and MAE are reduced by 12.6% and 15.8%, respectively, validating the model's effectiveness.

Keywords: frequency-domain information; temporal-domain information; iTransformer; photovoltaic power generation; medium- and long-term power prediction

0 引言

随着全球能源需求的不断增长和环境保护意识的增

强,可再生能源的开发和利用已经成为世界各国关注的焦点,并且在未来的发展中可再生能源将成为能源体系的重要组成部分。在众多可再生能源中,光伏发电因其清洁、可

收稿日期:2025-03-24

* 基金项目:企业信息化与物联网测控技术四川省高校重点实验室开放基金(2024WYJ03)、四川省智慧旅游研究基地基金(ZHYJ24-01)、四川省科技计划重点研发项目(2023YFS0371)资助

再生、无污染、采集方便和成本低等优点,得到了广泛的应用和快速发展,并且已成为电力行业不可或缺的重要组成部分^[1]。随着光伏发电装机容量占比的不断提升以及光伏发电功率受到天气、季节、时间等多种因素影响导致电力输出断断续续、波动不定,这给光伏发电并入电网以及电网调度和管理带来了巨大的挑战^[2-3]。因此,准确的光伏发电功率预测特别是中长期预测对降低光伏发电对电网产生的负面影响以及为光伏并网决策提供依据具有极为重要的实际意义^[4]。

常见用于光伏发电功率预测方法主要有物理模型方法、统计学方法和机器学习方法^[5]。然而物理模型方法和统计学方法对非线性和非平稳时间序列数据建模的能力有限^[6]。因此,现在主流的光伏发电功率预测是使用机器学习方法。如文献[7]提出的 XGBoost-LSTM 组合模型通过误差倒数法加权融合两种算法的预测结果,显著提高了短期光伏发电功率的预测精度。文献[8]提出了一种基于气候特征分析及改进 XGBoost 算法,通过划分气候预测数据为多个子模型,结合特征工程和超参数优化,提升了 XGBoost 模型在中长期光伏发电量预测中的精度。尽管上述方法在光伏发电功率预测中取得了一定的优势,但机器学习方法仍存在一些问题,包括对数据的高度依赖、特征选择的复杂性、计算成本较高以及难以完全捕捉复杂的非线性关系等。

近年来,深度学习方法因其强大的特征提取能力和非线性映射能力,在时间序列预测领域展现出巨大的优势和潜力,吸引了学术界和工业界的广泛关注,并被广泛应用于光伏发电功率预测,这些模型大体可以分为两类^[9-10]。一类是基于循环神经网络(recurrent neural network, RNN)结构的模型,主要有长短期记忆网络(long short term memory, LSTM)^[11] 和门控循环单元(gated recurrent unit, GRU)^[12]。例如,文献[13]通过引入灰狼算法对 GRU 模型进行超参数优化,用以提升光伏发电功率预测的精准度。文献[14]通过引入序列分解的方法降低数据的复杂性,再通过时间卷积网络与双向门控循环单元对各个分解序列进行特征提取,实现了较好的预测效果。

然而,随着预测长度的增加,基于循环神经网络的模型面临着梯度消失或梯度爆炸问题,尤其是在处理长时间序列时,模型难以有效捕捉到长期预测的依赖关系。此外,随着预测步长的增加,误差会逐步累积,导致预测精度下降。为了克服这些问题,另一类基于注意力机制的编码器-解码器架构的 Transformer 模型^[13]应运而生。Transformer 模型能够高效地挖掘光伏发电功率数据中不同特征间的复杂关系和长期依赖,显著提高了预测精度。如文献[16]采用 Transformer 编码器和解码器结构来提取数据特征之间的复杂关系和长期依赖关系,实现了对光伏发电功率的超短期预测。文献[17]结合多种特征融合器和改进的 Transformer 模型,在光伏发电功率短期多步预测中取得

了优异的结果。文献[18]通过引入主成分分析(principal component analysis, PCA)进行数据降维,再结合一维双通道注意力机制与 Informer 模型,提升了模型对时间特征和空间特征的提取能力,进一步提高了预测准确率。尽管基于 Transformer 改进的模型在光伏功率预测领域已取得一定进展,但仍存在诸多不足。同时光伏数据通常具有显著的周期性和非线性特征^[19],而现有预测方法在特征提取方面仍存在缺陷,未能充分挖掘数据中的周期性特征和全局特征。此外,这些方法的计算复杂度较高,导致模型在训练和推理过程中面临较大的计算负担。

因此针对上述问题,本文提出了一种基于频域和时域学习的中长期光伏发电功率预测模型 FFTEMixer,其目的是提升中长期时间范围内光伏发电功率预测的稳定性、准确性与效率。该模型主要由 3 部分组成分别为频率特征提取模块(frequency feature extraction block, FFEBlock)、特征融合器和时间特征提取模块(temporal feature extractor block, TFEBlock)。通过引入频域分析手段,从全局视角对光伏功率序列展开深入剖析,以挖掘其中的周期性特征、全局特征和潜在的变化模式^[20-21]。本文的主要贡献如下:

1) 本文提出了一种用于中长期光伏发电功率预测的 FFTEMixer 模型,该模型创新性的将频域信息与时域信息融合,使其能够更精准地捕捉周期性特征和全局特征。具体而言,模型首先通过 FFEBlock 将时序数据转换到频域空间,有效提取全局特征和变量间相关性特征;随后利用特征融合器挖掘周期性模式并建立特征变量与时间协变量的关联;最后再通过 TFEBlock 学习时间维度的长期依赖关系,从而实现了全面的特征提取。并针对光伏发电功率数据的周期性和非平稳性特点进行了优化,提高了模型在中长期光伏发电功率预测的准确率。

2) 提出了一种自适应误差混合损失函数(adaptive hybrid loss, AHLoss),通过动态调整损失权重,在训练过程中自适应平衡精度与鲁棒性。具体而言,一方面引入基于误差分布的自适应调整策略,有效增强了模型对异常值和噪声数据的鲁棒性;另一方面采用训练进度感知的权重调度方法,显著提升了优化过程的收敛稳定性。并通过实验验证了其有效性。

1 模型建立与分析

1.1 问题定义

光伏发电功率预测任务可以表述为一个多变量预测单变量的时间序列预测问题,根据现有的历史观测数据预测未来一段时间内的光伏发电功率。设 $\mathbf{X} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_T\} \in \mathbb{R}^{T \times N}$ 表示一组定期采样的多变量光伏发电数据,其中 T 是该数据集的序列的长度, N 是该数据集的特征数量。

将时间步 t 处长度为 L 的时间序列作为模型的输入序列,即 $\mathbf{X}_t = \{\mathbf{X}_{t-L+1}, \mathbf{X}_{t-L+2}, \dots, \mathbf{X}_t\} \in \mathbb{R}^{L \times N}$ 。将时间步 t

处长度为 H 的未来窗口作为预测的目标序列,表示为 $\mathbf{Y}_t = \{\mathbf{X}_{t+1}, \mathbf{X}_{t+2}, \dots, \mathbf{X}_{t+H}\} \in \mathbb{R}^{H \times 1}$ 。多变量时间序列预测任务是使用历史观察值 \mathbf{X}_t 来预测未来值 $\hat{\mathbf{Y}}_t$, 表示为 $\hat{\mathbf{Y}}_t = f_\theta(\mathbf{X}_t)$, 其中 f_θ 是预测模型, θ 是模型参数。

1.2 模型整体框架

本文提出了一种基于频域和时域学习的中长期光伏发电功率预测模型 FFTEMixer, 其结构如图 1 所示。该模型主要由 FFEBlock、特征融合器和 TFEBlock 三部分组成。首先将输入序列的特征变量与时间截协变量分别通过反转嵌入层进行特征维度与序列维度的反转, 再通过一维卷积模块将每个变量的时间序列投射到 D 维潜在空间, 使得特征变量与时间截协变量获得相关性更强的局部特征表示; 然后通过 FFEBlock 将特征变量投影到频域中, 通过一个可学习的频率滤波器选择性地增强或抑制特定频率分量从而实现对特征变量的全局特征特征和变量相关性特征的提取, 紧接着再通过一个交互式卷积模块学习局部依赖关系, 提高特征表达能力; 然后再通过特征融合器将特征变量与时间截协变量进行融合, 建立特征变量和时间截协变量的联系, 同时引入可学习的频域滤波器对融合后的特征进行频谱调制, 以增强关键周期性分量的表征能力; 然后再通过 TFEBlock 的多头自注意力机制全面的提取时间依赖性特

征和长期依赖性特征; 最后将提取的特征通过一个线性层进行映射得到输出结果。算法描述如算法 1 所示。

算法 1 FFTEMixer 预测算法

输入时间序列数据 $\mathbf{X}_t \in \mathbb{R}^{L \times N}$

输出时间序列数据 $\mathbf{Y}_t \in \mathbb{R}^{H \times 1}$

1. $\mathbf{X}_t^1 = \mathbf{X}_t + FilterBlock(\mathbf{X}_t)$
2. $\mathbf{X}_t^2 = \mathbf{X}_t^1 + ICB(\mathbf{X}_t^1)$
3. $\mathbf{X}_t^* = FeatureFusion(\mathbf{X}_t^2)$
4. for l in $\{1, 2, \dots, N\}$
5. $\mathbf{X}_t^{*,l} = Attention(\mathbf{X}_t^{*,l-1})$
6. $\mathbf{X}_t^{*,l} = LayerNorm(\mathbf{X}_t^{*,l} + \mathbf{X}_t^{*,l-1})$
7. $\mathbf{X}_t^{*,l} = LayerNorm(FFN(\mathbf{X}_t^{*,l}) + \mathbf{X}_t^{*,l})$
8. End for
9. $\mathbf{Y}_t = projection(\mathbf{X}_t^{*,N})$
10. return \mathbf{Y}_t

1.3 FFEBlock

FFEBlock 由两部分组成分别是可学习的频率滤波器与交互式卷积块, 用于高效提取全局特征、变量相关性特征和局部特征。同时考虑到时间序列数据通常是在较长时间内收集的, 数据间普遍存在非平稳性, 这种非平稳性通常会对模型的泛化能力产生不利影响。因此本文在模型输入的序列 \mathbf{X}_t 上使用了一种可逆实例归一化方法 RevIN^[22] 用于降低长期时间序列中分布偏移对预测的影响。

频率滤波器它的核心思想是循环卷积, 用于发现变量间的潜在相关性。该模块首先通过快速傅里叶变换将特征变量从时域映射到频域, 使不同变量的频谱信息得以表达, 其中相似的变量可能在相同频率分量上具有较强能量; 然后将序列的频率信息与滤波器进行元素相乘选择性地增强或抑制特定频率分量, 实现频域上的变量交互, 使得相关变量的频谱模式相互作用并得到增强, 而无关变量的频谱特征被削弱, 从而提取变量的潜在相关性; 最后再通过逆傅里叶变换将处理后的数据变换回时域。具体计算过程如式(1)所示。

$$FilterBlock(\mathbf{X}_t) = IFFT(FFT(\mathbf{X}_t) \odot H_{filter}) \quad (1)$$

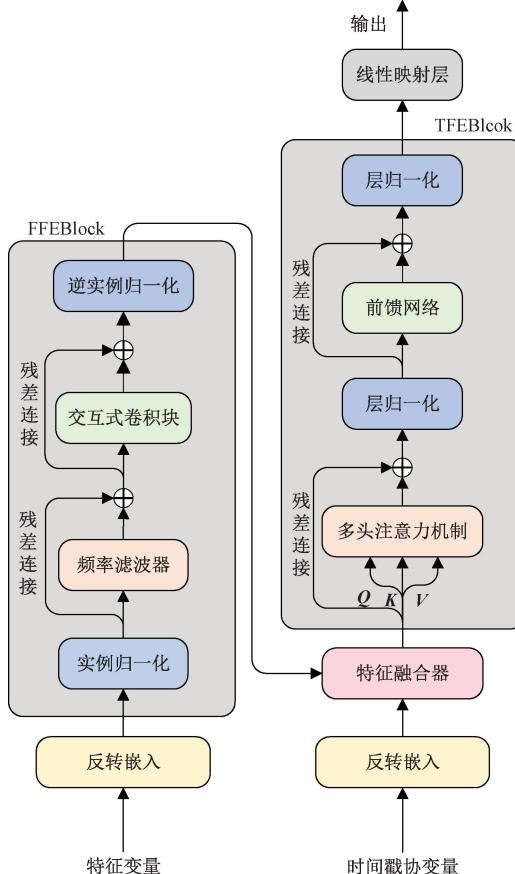
其中, FFT 是快速傅里叶变换, IFFT 是逆傅里叶变换, \odot 表示元素乘积, H_{filter} 是采用随机初始化可学习权重的普通滤波器。

交互式卷积模块(interactive convolution block, ICB)由两个不同内核大小的卷积模块组成, 用以捕捉较大范围的局部特征。具体来说, 第一个卷积模块旨在用较小的内核捕捉数据中细粒度的局部模式; 第二个卷积模块的目的是用较大的内核识别较大范围的依赖关系; 然后通过元素乘积操作将不同尺度的特征进行交互, 从而更好地对复杂关系进行建模。具体实现过程如下:

$$\mathbf{A}_1 = GELU(Conv1(\mathbf{X}_t)) \odot Conv2(\mathbf{X}_t) \quad (2)$$

图 1 FFTEMixer 模型结构图

Fig. 1 Structural diagram of the FFTEMixer model



$$\mathbf{A}_2 = GELU(Conv2(\mathbf{X}_t)) \odot Conv1(\mathbf{X}_t) \quad (3)$$

$$ICB(\mathbf{X}_t) = Conv3(\mathbf{A}_1 + \mathbf{A}_2) \quad (4)$$

其中, $Conv1$ 、 $Conv2$ 、 $Conv3$ 是一维卷积模块, $GELU$ 是激活函数。

1.4 特征融合器

时间序列数据是一种特殊类型的数据, 它按照时间记录了一系列数据点, 这就使时序数据具有很强烈的时间依赖性, 每个数据点都有一个与之关联的时间戳, 显示出时间相关性。时间序列数据在分析和预测时, 需要着重对这种时间依赖性考虑。

因此该模块主要是用于特征变量与时间戳协变量进行融合。对于时间戳, 分别从月、周、日、时、分、秒等时间粒度嵌入, 然后与特征变量进行特征融合。首先该模块将FFEBLOCK输出序列 \mathbf{X}_t 的特征变量与目标变量进行分离; 然后再将目标变量其与时间戳协变量进行连接形成新的序列; 最后为了进一步提高特征的表达能力将其再通过一个可学习的频率滤波器捕捉周期性特征与全局依赖性特征, 以增强关键周期性分量的表征能力。具体计算过程如下:

$$\mathbf{S}_t^i = \{t_1, t_2, \dots, t_k\} \quad (5)$$

$$\mathbf{S}_t = \{\mathbf{S}_{t-L+1}, \mathbf{S}_{t-L+2}, \dots, \mathbf{S}_t\} \quad (6)$$

$$\mathbf{X}_t^* = Concat(\mathbf{X}_t, \mathbf{S}_t) \quad (7)$$

$$\mathbf{X}_t^* = FilterBlock(\mathbf{X}_t^*) \quad (8)$$

其中, \mathbf{S}_t^i 代表第 i 个时间戳向量表示, k 表示时间戳中的细粒度个数, \mathbf{S}_t 是时间步 t 处对应的时间戳向量, $\mathbf{X}_t^* \in \mathbb{R}^{(k+1) \times D}$ 是融合时间戳信息的模型输出序列。

1.5 TFEBlock

TFEBlock 采用了 iTTransformer^[23]的模型的编码器结构, 该编码器由多个相同的编码层堆叠组成, 用于捕获目标变量与时间戳协变量的长期依赖性和时间依赖性。每个编码层由多头注意力机制、层归一化和前馈网络组成。该模块首先通过自注意力机制对全局信息进行建模提取长期依赖性特征和时间依赖性特征, 其注意力权重计算公式如下。

$$Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = softmax\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_K}}\right)\mathbf{V} \quad (9)$$

其中, \mathbf{Q} 为查询向量, \mathbf{K} 为关键词向量, \mathbf{V} 为值向量, d_k 为关键词向量的维度, $softmax(\cdot)$ 为数据归一化计算。

然后再通过前馈神经网络将注意力机制层输出的特征映射到更高维度的非线性空间, 用于提升模型的非线性表达能力以及进一步增强模型对复杂模式的学习能力。具体计算过程如下。

$$\mathbf{X}_t^{*,l} = LayerNorm(Attention(\mathbf{X}_t^{*,l-1}) + \mathbf{X}_t^{*,l-1}) \quad (10)$$

$$FFN(\mathbf{X}_t^{*,l}) = GELU(\mathbf{X}_t^{*,l}\mathbf{W}_1 + \mathbf{b}_1)\mathbf{W}_2 + \mathbf{b}_2 \quad (11)$$

$$\mathbf{X}_t^{*,l} = LayerNorm(FFN(\mathbf{X}_t^{*,l}) + \mathbf{X}_t^{*,l}) \quad (12)$$

其中, $\mathbf{X}_t^{*,l-1}$ 表示前一层的输出结果, \mathbf{W}_1 和 \mathbf{W}_2 是权重矩阵, \mathbf{b}_1 和 \mathbf{b}_2 是偏置项。

1.6 线性映射层

特征序列经过 TFEBlock 后, 将其输出结果通过一个线性层进行映射得到预测结果, 实现从历史长度 L 至目标预测长度 H 的映射。具体计算过程如下。

$$\mathbf{Y}_t = projection(\mathbf{X}_t^{*,N}) \quad (13)$$

最后的输出结果为 $\mathbf{Y}_t \in \mathbb{R}^{H \times 1}$ 。

1.7 AHLoss

AHLoss 结合了平均绝对误差和均方误差损失函数, 并通过误差自适应调整和训练进度自适应调整进行优化。具体计算如式(14)所示。

$$L = \lambda_1(t) \cdot L_{MAE} + \lambda_2(t) \cdot L_{MSE} \quad (14)$$

其中, L_{MAE} 为绝对误差损失, L_{MSE} 为均方误差损失, $\lambda_1(t)$ 和 $\lambda_2(t)$ 是随误差大小和训练进度自适应变化的权重。当误差较大时, 提高 L_{MAE} 的权重, 以增强模型对异常值的鲁棒性; 当误差较小时, 提高 L_{MSE} 的权重, 以提升拟合精度。通过结合两种损失的梯度信息, 确保训练稳定性和提高收敛速度。

2 数据处理与分析

2.1 数据集准备与处理

为了验证本文模型在中长期光伏发电功率预测任务中的可靠性, 本文使用了两个不同场地的光伏发电数据集用来验证本文模型有效性。

PV-1 数据集来源数据来源于新疆某地光伏发电站 2019 年 1 月 1 日~12 月 31 日发电功率数据, 共有 35 040 条数据, 采样频率间隔 15 min, 经过数据预处理后该数据集中除了时间戳还有 7 列特征, 包括组件温度、空气温度、湿度、总辐射、直射辐射、散射辐射和发电功率, 共 35 040 行数据。

PV-2 数据集来源于宁夏某光伏发电厂 2016 年 1 月 1 日~2020 年 10 月 6 日的光伏发电数据, 共有 41 783 条数据, 采样频率为 1 h。经过数据预处理后该数据集中除了时间戳还有 9 列特征, 包括空气温度、散射辐射、直接辐射、总水平辐射、固定倾角辐射、跟踪倾角辐射、相对湿度、天顶角和发电功率。

本文对该数据进行了数据预处理, 首先是检查这两个数据集是否存在异常值和缺失值, 并通过线性插值法替换这些异常数据, 同时为便于模型收敛, 模型在对输入的数据做了标准化处理。最后将处理好的两个数据集进行分割, 选择时间序列的 70% 用于训练集, 10% 用于验证集, 20% 用于测试集。

2.2 评价指标

为了评估模型的性能, 本文使用了平均绝对误差 (mean absolute error, MAE) 和均方误差 (mean squared error, MSE) 为模型预测结果与真实值差异的衡量标准。预测结果越接近真实值, MSE 和 MAE 的值越小。其计算公式为:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (15)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (16)$$

其中, n 表示测试集的样本总数, \hat{y}_i 表示预测值, y_i 表示真实值。

3 实验结果与分析

本文实验环境采用 Intel i5-12400f 处理器, NVIDIA GeForce RTX 4060 显卡, 内存 16 G, 编程语言采用 Python 3.12, 基本框架为 Pytorch。最终的超参数设置由表 1 所示。

3.1 光伏发电功率预测结果

为了探究本文模型在不同预测长度上的性能表现, 本文选择了 5 个当前主流的基准模型进行比较, 分别为 MEAformer^[24]、SOFTS^[25]、TimeXer^[26]、iTransformer 和 PatchTST^[27]。遵循长期时间序列预测任务标准选择历史序列长度为 96, 预测步长分别为 96、192、336 和 720。实验

表 1 模型超参数
Table 1 Model hyperparameters

参数名称	参数值
输入序列长度	96
注意力头数	8
隐藏层特征数	512
编码层个数	2
丢失率	0.1
激活函数	GELU
学习率	0.0001
批次大小	32
损失函数	AHLoss
优化器	Adam
训练轮数	10

结果如表 2 所示, 表中加粗的数据表示对比模型中表现最出色的结果。

表 2 各个模型光伏数据预测结果

Table 2 Results of photovoltaic data prediction for each model

数据集	预测步长	本文		MEAformer		SOFTS		TimeXer		iTransformer		PatchTST	
		MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
PV-1	96	0.142	0.191	0.170	0.233	0.166	0.215	0.156	0.223	0.173	0.231	0.165	0.229
	192	0.154	0.202	0.197	0.249	0.187	0.231	0.185	0.259	0.210	0.255	0.179	0.239
	336	0.150	0.206	0.201	0.252	0.193	0.238	0.185	0.255	0.205	0.254	0.181	0.241
	720	0.151	0.217	0.203	0.255	0.189	0.241	0.175	0.247	0.196	0.254	0.180	0.241
	Avg	0.149	0.204	0.192	0.247	0.183	0.231	0.175	0.246	0.196	0.248	0.176	0.237
PV-2	96	0.077	0.137	0.087	0.161	0.084	0.157	0.090	0.186	0.085	0.162	0.091	0.190
	192	0.079	0.142	0.090	0.165	0.087	0.161	0.095	0.193	0.086	0.163	0.096	0.191
	336	0.080	0.149	0.094	0.169	0.088	0.165	0.097	0.195	0.087	0.165	0.101	0.202
	720	0.082	0.154	0.103	0.183	0.093	0.177	0.098	0.195	0.088	0.171	0.113	0.212
	Avg	0.079	0.145	0.093	0.169	0.088	0.165	0.095	0.192	0.086	0.165	0.100	0.198

由实验结果可知, 本文提出的光伏发电功率长期预测方法在多个预测步长上显著优于当前主流模型, 在 PV-1 和 PV-2 数据集上本文模型相比次优模型在 MSE 上平均降低 12.6%, 在 MAE 上平均降低 15.8%, 展现了更强的预测精度和长期预测的稳定性。具体而言, 在 PV-1 数据集中, 本文方法的 MSE 比次优的 TimeXer 降低了 14.9%, MAE 比次优模型 SOFTS 降低 11.7%; 在 PV-2 数据集中, MSE 比次优的 SOFTS 降低了 10.2%, MAE 比次优模型 SOFTS 与 iTransformer 降低 12.1%。随着预测长度的增加, 本文方法的误差增长幅度最小, 在 PV-1 和 PV-2 数据集中 MSE 从 96 到 720 仅增长 6.3% 和 6.4%, 远低于次优模型 SOFTS 的 13.9% 和 10.7%, 表明其能有效缓解长期预测中的误差累积问题。以上实验结果说明本文所提模型通过将频域与时域特征进行融合, 有效的提取到更多的全局特征、周期性特征和长期依赖性特征, 使

得本文模型在中长期光伏发电功率预测任务中更加具有优势。

3.2 消融实验

为了验证 FFTEMixer 模型各个优化模块的有效性, 进行了消融实验。数据集选择本文使用的两个光伏发电功率数据集, 预测步长选择 96、192、336 和 720, 消融实验结果如表 3 所示。实验设置为: 模型 1 去除 FFEBlock 组件; 模型 2 去除 TFEBlock 组件; 模型 3 去除特征融合器; 模型 4 去除 AHLoss 损失函数。

消融实验结果表明, 各模块对模型性能均具有重要贡献。其中, TFEBlock 的移除导致性能下降最为显著: 在 PV-1 和 PV-2 数据集上, 平均 MSE 分别增加 32.9% 和 23.8%, MAE 分别上升 23.2% 和 14.3%, 这验证了该模块作为模型核心组件的重要性, 进一步体现了对时间截协变量进行特征提取的重要性。FFEBlock 的缺失使两个数据

表 3 消融实验结果
Table 3 Results of ablation experiments

数据集	预测步长	本文		模型 1		模型 2		模型 3		模型 4	
		MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
PV-1	96	0.142	0.191	0.150	0.204	0.170	0.231	0.155	0.203	0.147	0.212
	192	0.154	0.202	0.167	0.218	0.194	0.255	0.166	0.214	0.163	0.232
	336	0.150	0.206	0.160	0.214	0.197	0.263	0.183	0.224	0.163	0.237
	720	0.151	0.217	0.161	0.217	0.199	0.266	0.170	0.218	0.156	0.238
PV-2	96	0.077	0.137	0.082	0.143	0.086	0.156	0.084	0.156	0.076	0.149
	192	0.079	0.142	0.082	0.148	0.088	0.159	0.082	0.156	0.078	0.153
	336	0.080	0.149	0.083	0.150	0.091	0.163	0.086	0.160	0.080	0.157
	720	0.082	0.154	0.083	0.152	0.099	0.176	0.095	0.172	0.083	0.162

集的平均 MSE 分别升高 7.4% 和 3.8%；而特征融合器的移除则导致 PV-1 数据集 192 步长预测的 MSE 增加 7.8%，PV-2 数据集 720 步长预测的 MAE 上升 11.7%。这些结果充分表明，FFEBLOCK 的频域特征提取能力、TFLBLOCK 的时间特征提取能力以及特征融合器的特征整合功能缺一不可，三者协同工作共同提升了模型性能。此外，AHLoss 损失函数通过增强模型对异常值的鲁棒性和训练过程的稳定性，进一步优化了整体预测效果。

3.3 效率分析

本文对 FFTEMixer 模型进行了效率分析，在 PV-1 数据集上将各个模型在训练阶段的每轮运行时间和内存占用进行了比较，其结果如图 2 所示。该图展示了各个模型预测长度为 96 步下训练一轮的平均耗时对比，跟每个模型在训练时内存占用对比。

由图 2 可以看出，在预测步长为 96 时，本文模型与当前主流模型的训练时长与内存占用相比具有一定的优势。内存占用相比于 SOFTS 有略微的提高，但模型的训练速度相近。这表明本文模型能够同时兼顾预测精度和运行效率，具有较高的应用价值。

3.4 结果可视化分析

为了更好的验证 FFTEMixer 模型预测的效果，本文

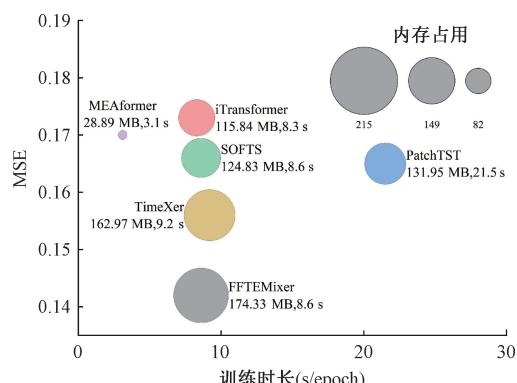
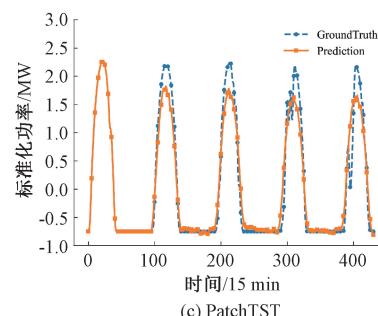
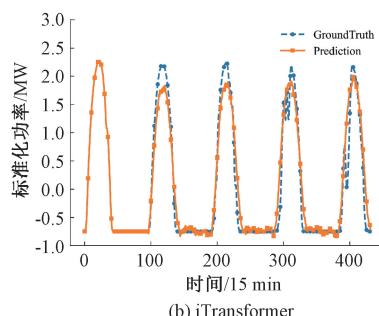
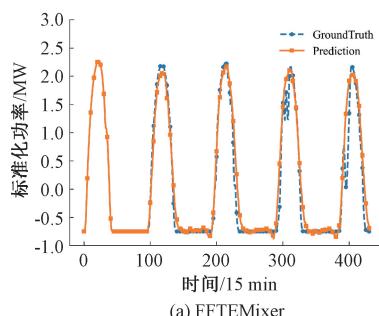


图 2 内存占用和训练时长对比图

Fig. 2 Comparison diagram of memory occupancy and training duration

对部分预测结果进行了可视化。其结果如图 3 和 4 所示。图 3 展示的是 PV-1 数据集在预测步长为 336 时各个模型的预测结果。图 4 展示的是 PV-2 数据集在预测步长为 96 时各个模型的预测结果。其中横轴表示时间步长，纵轴表示标准化后该时间步对应的光伏发电功率。橙色实线表示预测值，蓝色虚线表示真实值。由图 3、4 可以看出，本文模型的预测曲线与真实值曲线更加贴合，这表明 FFTEMixer 模型能够提供更精准的预测。



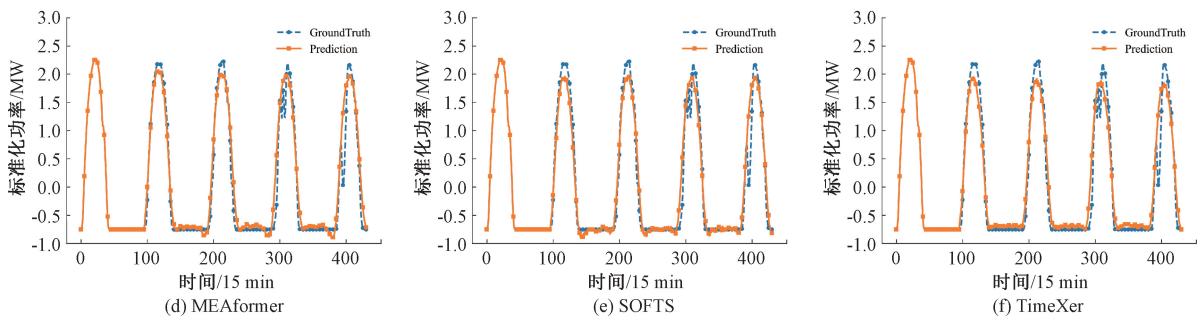


图3 PV-1数据集可视化结果图

Fig. 3 Visualization results diagram of PV-1 dataset

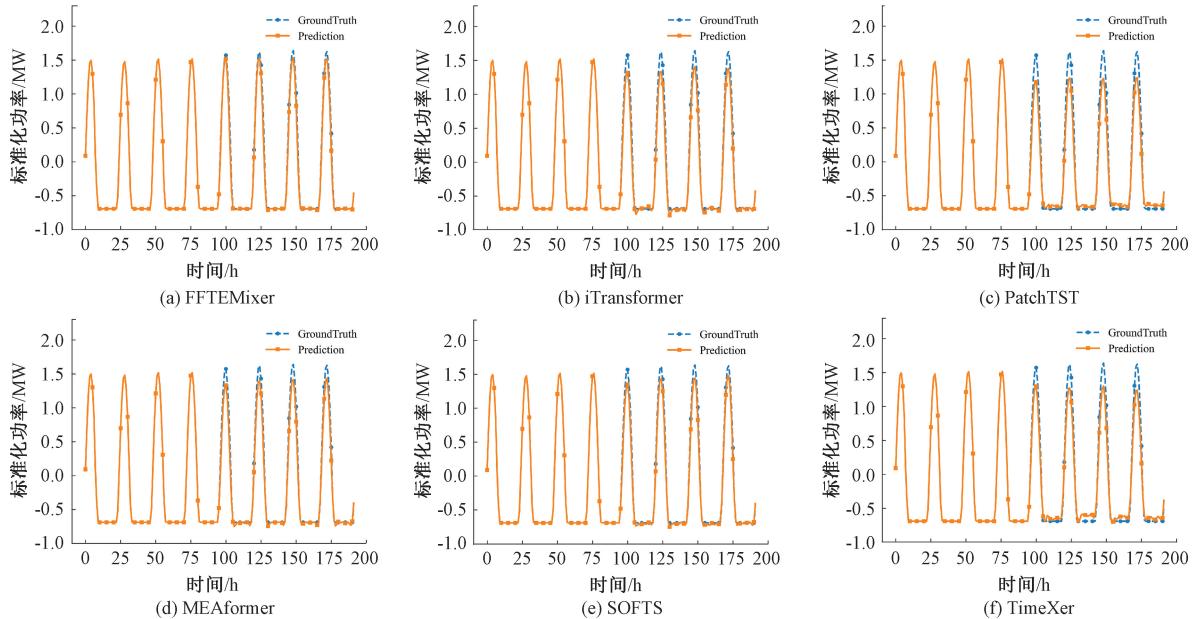


图4 PV-2数据集可视化结果图

Fig. 4 Visualization results diagram of PV-2 dataset

4 结论

由于光伏发电序列具有较强的周期性特征和非线性特征,使得传统的RNN和Transformer系列模型存在特征提取不足导致在光伏发电功率的中长期预测中表现较差,因此本文提出一种用于光伏发电功率中长期预测模型FFTEMixer。通过实验分析,得出以下结论:将FFEBlock与TFEBlock结合使用,使模型能够在频域和时域实现协同特征提取,既能捕获全局特征信息,又能建模长期依赖关系,从而显著提升预测精度;通过引入特征融合器建立特征变量与时间截变量的联系,增强了模型在捕捉周期性特征和时间依赖性特征方面的能力,进一步提高了预测效果。但是本文采用的基于可学习频率滤波器的频域特征提取方法其特征提取能力有限,因此后续研究将重点探索更高效的频域信息处理方式,以期进一步提升模型的频域特征提取能力。

参考文献

- [1] HONG T, PINSON P, WANG Y, et al. Energy forecasting: A review and outlook[J]. IEEE Open Access Journal of Power and Energy, 2020, 7: 376-388.
- [2] 韩莹,朱宏宇,李琨.融合聚类及随机配置网络的短期光伏功率预测[J].电子测量与仪器学报,2023,37(11):205-216.
HAN Y, ZHU H Y, LI K. Short-term PV power prediction by fusion of clustering and SCN[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(11):205-216.
- [3] 黄泽,毕贵红,谢旭,等.基于MBI-PBI-ResNet的超短期光伏功率预测[J].电力系统保护与控制,2024,52(2):165-176.
HUANG Z, BI G H, XIE X, et al. Ultra-short-term

- PV power prediction based on MBI-PBI-ResNet[J]. Power System Protection and Control, 2024, 52(2): 165-176.
- [4] 袁建华,蒋文军,李洪强,等.基于 SSA-BiLSTM 非线性组合方法的光伏功率预测[J].电子测量技术,2023,46(21):63-71.
YUAN J H, JIANG W J, LI H Q, et al. Photovoltaic power forecasting based on SSA-BiLSTM nonlinear combination method [J]. Electronic Measurement Technology, 2023, 46(21):63-71.
- [5] AGGA A, ABBOU A, LABBADI M, et al. CNN-LSTM: An efficient hybrid deep learning architecture for predicting short-term photovoltaic power production [J]. Electric Power Systems Research, 2022, 208: 107908.
- [6] YU J F, LI X D, YANG L, et al. Deep learning models for PV power forecasting[J]. Energies, 2024, 17(16): 3973.
- [7] 谭海旺,杨启亮,邢建春,等.基于 XGBoost-LSTM 组合模型的光伏发电功率预测[J].太阳能学报,2022,43(8):75-81.
TAN H W, YANG Q L, XING J CH, et al. Photovoltaic power prediction based on combined XGBOOST-LSTM model [J]. Acta Energiae Solaris Sinica, 2022, 43(8):75-81.
- [8] 李永飞,张耀,林帆,等.基于气候特征分析及改进 XGBoost 算法的中长期光伏电站发电量预测方法[J].电力系统保护与控制,2024,52(11):84-92.
LI Y F, ZHANG Y, LIN F, et al. Medium- and long-term power generation forecast based on climate characterisation and an improved XGBoost algorithm for photovoltaic power plants [J]. Power System Protection and Control, 2024, 52(11):84-92.
- [9] 姜建国,杨效岩,毕洪波.基于 VMD-FE-CNN-BiLSTM 的短期光伏发电功率预测[J].太阳能学报,2024,45(7):462-473.
JIANG J G, YANG X Y, BI H B. Photovoltaic power forecasting method based on VMD-FE-CNN-BiLSTM[J]. Acta Energiae Solaris Sinica, 2024, 45(7): 462-473.
- [10] 张研,景超,王慧民,等.基于周期注意力机制的中长期光伏发电功率预测[J].太阳能学报,2024,45(10): 298-308.
ZHANG Y, JING CH, WANG H M, et al. Medium and long term photovoltaic power prediction based on periodic attention mechanism [J]. Acta Energiae Solaris Sinica, 2024, 45(10): 298-308.
- [11] 杨生鹏,文中,丁剑,等.二次分解组合 LSTM 的短期风电功率预测模型[J].国外电子测量技术,2024, 43(1):87-93.
YANG SH P, WEN ZH, DING J, et al. Short-term wind power prediction model for quadratic decompstion combined LSTM[J]. Foreign Electronic Measurement Technology, 2024,43(1):87-93.
- [12] 孙兴伟,杨铜铜,杨赫然,等.基于 CNN-GRU 组合神经网络的数控机床进给系统热误差研究[J].仪器仪表学报,2023,44(10):219-226.
SUN X W, YANG T T, YANG H R, et al. Research on thermal error of CNC machine tool feed system based on CNN-GRU combined neural network [J]. Chinese Journal of Scientific Instrument, 2023, 44(10):219-226.
- [13] 陈庆明,廖鸿飞,孙颖楷,等.基于 GWO-GRU 的光伏发电功率预测[J].太阳能学报,2024,45(7):438-444.
CHEN Q M, LIAO H F, SUN Y K, et al. Photovoltaic power prediction model based on GWO-GRU[J]. Acta Energiae Solaris Sinica, 2024, 45(7): 438-444.
- [14] 白隆,俞斌,高峰,等.基于 ICEEMDAN 和 TCN-AM-BiGRU 的短期光伏发电功率预测[J].电子测量技术,2024,47(9):61-69.
BAI L, YU B, GAO F, et al. Short-term photovoltaic power prediction based on ICEEMDAN and TCN-AM-BiGRU [J]. Electronic Measurement Technology, 2024,47(9):61-69.
- [15] VASWANI A. Attention is all you need[J]. ArXiv preprint arXiv:1706.03762, 2017.
- [16] 黄莉,甘恒玉,刘兴举,等.基于 Transformer 编码器的超短期光伏发电功率预测[J].智慧电力,2024,52(5): 16-22,59.
HUANG L, GAN H Y, LIU X J, et al. Ultra-short-term photovoltaic power generation prediction based on Transformer encoder [J]. Smart Power, 2024, 52(5): 16-22,59.
- [17] 刘世鹏,宁德军,马崛.针对光伏发电功率预测的 LSTformer 模型[J].计算机工程与应用,2024,60(9): 317-325.
LIU SH P, NING D J, MA J. LSTformer model for photovoltaic power prediction [J]. Computer Engineering and Applications, 2024, 60(9): 317-325.
- [18] 蔡伟雄,陈志聪,吴丽君,等.采用 PCA-CSA-Informer 模型的光伏短期发电量预测[J].福州大学学报(自然科学版),2024,52(6):681-690.
CAI W X, CHEN ZH C, WU L J, et al. Short-term power generation forecasting study of PV based on PCA-CSA-Informer modeling[J]. Journal of Fuzhou University(Natural Science Edition), 2024, 52 (6):

- 681-690.
- [19] YU CH M, QIAO J, CHEN CH, et al. TFEformer: A new temporal frequency ensemble transformer for day-ahead photovoltaic power prediction[J]. Journal of Cleaner Production, 2024, 448: 141690.
- [20] ELDELE E, RAGAB M, CHEN ZH H, et al. Tslanet: Rethinking transformers for time series representation learning [J]. ArXiv preprint arXiv: 2404.08472, 2024.
- [21] YI K, FEI J R, ZHANG Q, et al. Filternet: Harnessing frequency filters for time series forecasting[J]. Advances in Neural Information Processing Systems, 2025, 37: 55115-55140.
- [22] KIM T, KIM J, TEA Y, et al. Reversible instance normalization for accurate time-series forecasting against distribution shift[C]. International Conference on Learning Representations, 2021.
- [23] LIU Y, HU T G, ZHANG H R, et al. iTTransformer : Inverted transformers are effective for time series forecasting[J]. ArXiv preprint arXiv:2310.06625, 2023.
- [24] HUANG S Y, LIU Y P, CUI H Y, et al. MEAformer: An all-MLP transformer with temporal external attention for long-term time series forecasting [J]. Information Sciences, 2024, 669: 120605.
- [25] HAN L, CHEN X Y, YE H J, et al. Softs: Efficient multivariate time series forecasting with series-core fusion[J]. ArXiv preprint arXiv:2404.14197, 2024.
- [26] WANG Y X, WU H X, DONG J X, et al. Timexer: Empowering transformers for time series forecasting with exogenous variables[J]. ArXiv preprint arXiv: 2402.19072, 2024.
- [27] NIE Y Q, NGUYEN N, SINTHONG P, et al. A time series is worth 64 words: Long-term forecasting with transformers [C]. The Eleventh International Conference on Learning Representations, San Diego: OpenReview.net, 2023:1-24.

作者简介

王文,硕士研究生,主要研究方向为新能源出力预测。

E-mail:2510083129@qq.com

朱文忠(通信作者),硕士,教授,主要研究方向为深度学习、智能信息处理。

E-mail:zwz@suse.edu.cn

成荣,硕士研究生,主要研究方向为深度学习。

E-mail:1043119400@qq.com