

融合频率增强通道注意力机制的 VMD-TCN-NTSformer-FECAM 风电功率预测研究^{*}

杨青濠 张嘉英

(内蒙古工业大学电力学院 呼和浩特 010080)

摘 要: 针对风电功率序列非平稳特性与多尺度动态演化规律。首先采用变分模态分解(VMD)对原始功率序列进行自适应频域分解,分离噪声干扰并提取多尺度动态子模态;其次,利用时间卷积网络(TCN)的膨胀卷积分层捕获局部时序特征,结合 NTSformer 的去平稳化注意力机制动态修正标准化偏差,提升趋势突变与周期波动建模能力;并引入频率增强通道注意力模块(FECAM),通过快速傅里叶变换提取频域特征,动态分配通道权重聚焦关键频率成分,最终构建 VMD-FECAM-TCN-NTSformer 预测模型。实验表明:该模型在 15 min 的单步预测和 15 h 的 60 步预测中较传统 CNN 模型决定系数提高 13%、相较 Transformer 等模决定系数提高 4%。因此,证明所提出的模型有较高预测精度和良好预测效果。

关键词: 风电功率预测;时间卷积网络;变分模态分解;频率增强通道注意力机制;非平稳 Transformer;预测模型

中图分类号: TN91;TP273 **文献标识码:** A **国家标准学科分类代码:** 510.8010

Wind power forecasting based on VMD-TCN-NTSformer integrated with frequency-enhanced channel attention mechanism

Yang Qinghao Zhang Jiaying

(Institute of Electric Power, Inner Mongolia University of Technology, Hohhot 010080, China)

Abstract: To address the non-stationary characteristics and multi-scale dynamic evolution of wind power time series, this study proposes a hybrid prediction model named VMD-FECAM-TCN-NTSformer. Firstly, Variational Mode Decomposition (VMD) is employed to adaptively decompose the original power sequence in the frequency domain, effectively separating noise interference and extracting multi-scale dynamic intrinsic mode functions. Secondly, Temporal Convolutional Networks (TCN) are used to hierarchically capture local temporal features through dilated convolutions. Meanwhile, the NTSformer utilizes a de-stationary attention mechanism to dynamically correct normalization bias, thereby enhancing the modeling of abrupt trends and periodic fluctuations. Furthermore, a Frequency Enhanced Channel Attention Module (FECAM) is introduced to extract frequency-domain features via fast Fourier transform and dynamically assign channel weights to focus on key frequency components. Experimental results show that the proposed model improves the coefficient of determination R^2 by more than 17% compared to traditional CNN models and by more than 5% compared to Transformer-based models, in both 15-minute single-step forecasting and 60-step (15 h) multi-step forecasting. These results demonstrate the model's superior prediction accuracy and robust forecasting performance.

Keywords: windpower forecasting; temporal convolutional network; VMD; frequency-enhanced channel attention mechanism; non-stationary Transformer; prediction model

0 引 言

随着全球能源结构转型加速,风能作为清洁能源的核

心组成部分,其装机容量持续增长^[1]。然而,风电功率数据呈现出显著的非线性、非平稳性和强波动性特征,给电网调度与并网带来严峻挑战。提升风电功率预测精度已成为智

能电力系统研究的关键课题^[2]。

针对风电序列的复杂性,信号分解方法被广泛应用于数据预处理。例如,罗旭等^[3]提出了一种经验模态分解(empirical mode decomposition, EMD)的短期风速和风电功率预测方法。文献[4]提出并使用集合经验模态分解(ensemble empirical mode decomposition, EEMD)将复杂和不规则的风电时间序列转换为相对容易分析的子序列集合,采用核密度估计(kernel density estimation, KDE)对预测结果进行处理。李恺丽等^[5]采用基于自适应噪声完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)的方法,得到了多步超前风速预测。相比以上模态分解方法,变分模态分解(variational mode decomposition, VMD)凭借其频域分解优势和抗模态混叠能力,在风电预测中表现突出,并且在本研究的数据集中 VMD 分解通过限制分解出的本征模态函数(intrinsic mode function, IMF)的数量提高了预测效率和精度。

在使用深度学习方法进行预测的模型选择中,对于时间序列周期性特征的提取方法大多是采用循环神经网络(recurrent neural network, RNN)及其变体来进行,对于短期特征的提取方法大多采用卷积神经网络(convolutional neural network, CNN)及其变体来进行。例如,向阳等^[6]中提出建立 CNN-GRU 模型提取空间特征提供了数据的局部信息,肖良帅等^[7]采用了 RNN 网络作为基础模型架构。张登攀等^[8]提出基于 PCHIP-VMD 数据分析与 SSA-LSTM 模型的短期风电功率预测方法。将长短期记忆网络(long short-term memory, LSTM)作为核心模型,成功捕捉了时间序列中的长期依赖关系,显著提高了风电功率预测的准确性。提取长期特征的方法还主要以基于 Transformer 模型及其变体的特征提取方法为主,例如文献[9-11]提出的多尺度特征提取的 Transforms 的多个变体的预测模型,利用每个元素进行全局建模,并在各元素之间建立联系并提取全局特征,此外,林蔚青等^[12]提出了一种基于多线圈联合学习的核电厂控制棒驱动机构异常检测方法,关注多线圈电流信号的时间序列分析。通过联合学习提取时序特征,并结合图卷积网络进行多尺度动态检测,强调了时序数据的多维耦合性与动态性,为时序问题研究提供了新思路。

尽管深度学习方法在时间序列特征提取方面取得良好效果,有效提升了预测精度,但仍存在局限。例如, RNN、CNN 及其变体主要关注局部信息,难以捕捉长期依赖关系,缺乏全局建模能力;传统 Transformer 在面对非平稳数据时亦难以适应趋势变化与突发扰动,限制了其在复杂时序预测任务中的表现。

而时间卷积网络(temporal convolutional network, TCN)是一种基于卷积结构的时间序列建模方法,具有结构简单、计算速度快等优点。该网络通过在时间轴上引入

一维因果卷积与残差连接机制,能够有效提取序列中的局部短期依赖特征。如文献[13-15]的实验证明,TCN 在建模短期动态变化方面表现出良好的性能,同时具备较高的运算效率,适合处理大规模时序数据。文献[16]提出的非平稳 Transformer(non-stationary transformer, NTSformer)作为一种针对非平稳时间序列设计的改进型 Transformer,通过引入可学习的偏移(shift)与尺度(scale)机制,构建非平稳建模层,有效建模时间序列中的趋势漂移与分布动态变化,相较于传统 Transformer 及其变体,NTSformer 更适用于风电功率等具有显著非平稳性特征的预测任务。

现有的深度学习时间序列预测研究,往往仅引入了信号分解方法,以增强对非平稳时间序列的建模能力,并通过优化算法调整分解参数以提升分解质量,如文献[17]提出北方苍鹰优化算法优化 VMD 参数,文献[18]提出并采用基于减法平均的优化算法(subtraction-average-based optimizer, SABO),如文献[15]提出采用蓝鸢优化算法(blue-winged optimization, BWO)优化 VMD 参数,并结合时序卷积网络-双向门控循环单元混合模型,以实现短期风电功率预测。但这些方法多数仅停留在对原始序列的前处理阶段,分解完成后未进一步有效挖掘各模态中的关键特征,导致模型难以充分利用多尺度信息。

为解决上述问题,本文在模态分解基础上,采用文献[19]所提出的频率增强通道注意力机制(frequency enhanced channel attention module, FECAM),引入对分解后各频率模态的精细建模与增强处理。该机制通过融合频域特征与通道注意力策略,能够动态衡量各频率分量在预测任务中的重要性,从而实现多模态时序特征的有效整合与利用,显著提升整体预测性能。

本文在上述研究的基础上,为进一步提升风电功率多变量时间序列预测的准确性与鲁棒性,本文提出了一种融合频率增强通道注意力机制的 VMD-TCN-NTSformer-FECAM 混合深度预测模型。

1 数据处理与理论基础

1.1 数据预处理

本文首先以内蒙古某风电场历史数据为例进行分析,从风电场数据空间中选取 2021 年 1 月 1 日~2023 年 3 月 12 日,总共收集 76 968 个观测点作为实验样本,采样间隔为 15 min。

由于风电功率数据受多种因素影响,具有高度的波动性和不确定性,因此在建模前需要进行充分的数据预处理。为了将原始数据转换为深度学习模型可以理解的输入,本文需要进行几个基本的预处理步骤,包括数据清洗、数据划分和数据归一化。

1)数据清洗,主要目的是识别并剔除数据集中的错误记录和缺失值,采用线性插值算法对其进行合理修正,从而提升整体数据质量与可靠性,其计算公式如式(1)所示。此

外风速数据的合理范围设定为 $[0, 27]$ m/s。风电功率的上限通常由风电场风机的最大额定功率决定,设定为 50 MW。风向数据位于 $[0^\circ, 360^\circ]$ 之间,若超出此范围,则被视为异常值。

$$x_{t_1} = x_{t_0} + \frac{(t_2 - t_0)}{(t_1 - t_0)}(x_{t_2} - x_{t_0}) \tag{1}$$

式中: x_{t_1} 为某缺失时间步的风速、风向或功率数据, t_0 为前一时刻, t_2 为后一时刻。

2)数据划分。根据 7:2:1 的比例,将原始数据集划分为训练集、验证集和测试集,分别用于模型训练、参数调整与最终性能评估,确保各阶段数据互不干扰,提高评估结果的准确性。

3)数据归一化处理。本文采用的是 Min-Max 归一化方法,其计算公式如式(1)所示。

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{2}$$

式中: x_{norm} 为归一化后的数据值, x 为原始数据值, $x_{\min}$ 和 $x_{\max}$ 为数据集中的最小值和最大值。通过归一化处理,可以将数据映射到固定范围内(通常为 0~1),以消除不同特征之间的量纲影响,促进模型更高效地学习特征信息。

1.2 特征工程

为了减少变量间的高度相关性,避免因自变量共线性问题导致模型贡献度减弱,对经过相关性分析后的候选特征进行了进一步筛选。自变量之间的相关性结果如图 1 所示。




图 1 自变量相关性热力图

Fig. 1 Heat maps of independent variables

分析发现,风速与风向和功率之间存在较强相关性,结合相关性分析与特征重要性评估,选取风速、风向两个因素作为模型的输入特征,以提升预测精度与模型稳定性。根据特征工程的结果,选取采用的数据集的统计信息如表 1 所示。

在模型的输入过程中,风速和功率以原始实测值表示,风向则考虑其周期性特性,采用正余弦函数进行双变量编

表 1 数据集的统计信息

Table 1 Statistical information of different datasets

输入参数	数据尺寸	最大值	最小值	平均值
风电功率/MW		50.00	0.00	26.59
风速/(m·s ⁻¹)	76 968	27.00	0.60	9.42
风向/(°)		356.00	4.00	236.93

码。其变换形式为:

$$\text{wind_x} = \cos(\frac{\theta \cdot \pi}{180}) \tag{3}$$

$$\text{wind_y} = \sin(\frac{\theta \cdot \pi}{180}) \tag{4}$$

式中: wind_x ; wind_y 为变换后的风向特征, θ 为风向角度。最终,每个时间步输入由风速和风向编码组成,形成包含 3 个维度的气象输入向量。最后,每个时间步的输入特征向量的维度为 4,即风速,风向的两个维度特征,功率。采样频率为每 15 min 一次,每个时间步的输入为一个 4 维向量,通过模型输入进行训练。

1.3 VMD 分解

变分模式分解是一种适用于处理风电功率等非平稳时间序列信号的自适应信号分解方法。与 EMD 不同之处是,VMD 可确定模态分解数量,并避免 EMD 出现模态混叠的现象。

具体步骤如下:假设原始信号是 $X(t)$,选择将其分解为 k 个分量 u_k ,每个分量都有一个中心频率。

$$\begin{cases} \min_{\{u_k, \omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ s.t. \sum_k u_k = X(t) \end{cases} \tag{5}$$

式中: u_k 为第 k 个分解量, ω_k 为第 k 个分解量的中心频率, $\delta(t)$ 为狄拉克函数,* 为卷积操作。

通过嵌入二次正则化项和拉格朗日乘数,将原始带约束的变分问题转换为无约束优化模型,以松弛模态正交性限制并提升解稳定性。采用交替方向乘子法,通过分步更新模态分量、中心频率及乘子变量,实现高效收敛至全局最优解。在风电功率预测场景中,利用 VMD 将风电功率序列分解为多个本征模态,有助于从不同时间尺度上刻画风电输出的非平稳动态特征,为本研究的后续深度学习模型提供更加纯净且频率可分的输入。

2 TCN-NTSformer-FECAM 预测模型

2.1 FECAM 模块原理

频率增强通道注意力机制(frequency enhanced channel attention mechanism,FECAM)是为了解决时间序列预测中的频率信息捕捉问题而提出的一种新型模块,其结构图如图 2 所示。

传统的研究方法只进行 VMD 分解对信号进行解构,




图 2 FECAM 模块结构

Fig. 2 FECAM module structure

不具备选择性关注机制。为了解决这一问题,引入 FECAM 对不同频率通道赋予差异化权重,强化关键频率,提高建模精度与泛化能力。此外,传统的频率提取方法通常使用傅里叶变换,但在处理存在边界突变的序列时易出现吉布斯现象,即在信号边缘产生振荡误差并引入高频噪声,影响频率建模的稳定性。

为了解决这一问题,FECAM 模块采用离散余弦变换(discrete cosine transform, DCT)来建模频率信息,避免了高频噪声的引入。并且实现差异化加权,增强了通道之间频率依赖性的建模能力。

具体而言,FECAM 将原始时间序列数据转换到频率域,以提取频率特征。DCT 得到的频域特征通过全连接层压缩并非线性变换,生成一个与通道维度相同的注意力向量。该向量表示每个频率通道的重要性,通过与原始输入进行逐元素乘法,动态增强高权重频率特征,抑制无关频率。最后,增强后的频域特征转换回时域,得到最终的时域增强输出。其处理公式为:

$$X_{freq} = DCT(X) \quad (6)$$

$$X_k = \sum_{n=0}^{T-1} x_n \cos\left(\frac{\pi}{T}(n + \frac{1}{2})k\right) \quad (7)$$

$$Z = FC(X_{freq}) \quad (8)$$

$$A = \sigma(Z) \quad (9)$$

$$Y = A \odot X \quad (10)$$

$$X_{output} = IDCT(Y) \quad (11)$$

式中: X_{freq} 为经过 DCT 变换后的频率域数据, X 为给定输入时间序列数据, N 为样本数量, T 为时间步数, X_k 为变换后的频域系数, k 为频率索引, Z 为经过全连接层处理后的特征表示, $FC(X_{freq})$ 为全连接层操作, σ 为 Sigmoid 激活函数, A 为注意力权重, $\odot$ 为逐元素相乘, X 为原始输入数据, Y 为增强后的输出数据, X_{output} 为逆 DCT 变换后的时域数据, $IDCT(Y)$ 为离散余弦逆变换。

2.2 NTSformer 模块原理

针对风电功率等典型非平稳时间序列预测问题,传统研究通常通过引入平稳化技术(如差分、滑动平均等)来减

少序列在时间维度上的分布差异,以提升数据的可预测性。然而基于实验观察,在平稳化后的数据上进行模型训练会限制 Transformer 建模时序依赖的能力,导致模型仅能学到不易区分的注意力图与较弱的时序依赖,从而产生平稳性过高的预测输出与较大的预测误差,称之为过平稳现象。

为了解决这一问题,本文在风电功率预测中引入 NTSformer 结构,其核心创新在于设计了一对相互补充的模块;其结构图如图 3 所示。其核心思想是在原有注意力计算中引入可学习的动态缩放(scale)和偏移(shift),以显式建模时间序列中的非平稳特性。




图 3 NTSformer 网络结构

Fig. 3 NTSformer network structure

具体而言,该机制首先对原始序列进行标准化处理,计算时间步上的均值和标准差,并得到标准化后的输入,随后,将标准化结果送入线性变换层,生成注意力机制中的三元组,并进行注意力计算;其处理公式为:

$$\mu_x = \frac{1}{S} \sum_{i=1}^S x_i \quad (12)$$

$$\sigma_x^2 = \frac{1}{S} \sum_{i=1}^S (x_i - \mu_x)^2 \quad (13)$$

$$z_i = \frac{x_i - \mu_x}{\sigma_x} \quad (14)$$

$$\log(\tau) = \text{scale_learner}(x_{\text{raw}}, \sigma) \quad (15)$$

$$\Delta = \text{shift_learner}(x_{\text{raw}}, \mu) \quad (16)$$

$$\text{Attn}(Q', K', V') = \text{Softmax}\left(\frac{\tau \odot (Q' K'^T) + \Delta}{\sqrt{d_k}}\right) \cdot V' \quad (17)$$

式中: μ_x ; σ_x 为所有时间步 S 的平均与标准差, z_i 为标准化数据, x_i 为样本点, τ 为可学习的缩放系数向量, Δ 为可学习的偏移项矩阵, $\odot$ 表示逐元素相乘, Q' ; K' ; V' 为线性变换后的注意力三元组。该机制能够自适应地调整注意力分布,从而提升模型对分布变化的响应能力。

2.3 TCN 模块原理

在时序预测任务中,常规网络结构常面临长期依赖捕捉难题,当模型输出仅依赖当前隐藏层状态及有限历史信息时,单纯增加网络深度或输入维度易引发梯度信息消散。

而 TCN 是一种融合膨胀卷积及残差块连接的改进卷积神经网络,其原理是利用 CNN 的思想,改进卷积层结构。膨胀卷积与标准卷积的核心差异在于其独特的间隔采样机制。相较于标准卷积的连续数据扫描方式,膨胀卷积通过在输入数据中引入可控的采样间隔(由膨胀率参数 d 调控),膨胀卷积的结构如图 4 所示,在不增加网络深度的情况下实现感受野的几何级数扩展。这种结构创新有效解决了传统时序建模中因线性堆叠网络层导致的梯度衰减问题。




图 4 膨胀卷积

Fig. 4 Dilated convolution

本文采用分层膨胀率调控机制,使各卷积层的有效感知范围满足下式。

$$d = 2^{n-1} \quad (18)$$

$$y[t] = \sum_{k=0}^{K-1} w[k] \cdot x[t-d \cdot k] \quad (19)$$

式中: n 为当前层级序数, $y[t]$ 为卷积操作的输出, $w[k]$ 为卷积核的权重, $x[t-d \cdot k]$ 为输入序列的元素, d 为膨胀率。最终通过复合残差模块整合局部特征与全局上下文,确保不同时间尺度的特征得到充分融合。

此外,TCN 模型的另一个部分残差块由两个卷积层和一个残差连接组成。残差块的计算过程为:

$$\text{Output} = y[t] + \text{Conv1D}(y[t]) \quad (20)$$

式中:Output 为 TCN 网络的输出, $y[t]$ 为膨胀卷积的输出。残差块的数学表达式如式(20)所示,模型的总体结构如图 5 所示。

2.4 预测模型流程

本文提出的预测模型整体结构如图 6 所示,首先,对原始时间序列数据进行标准化处理,并采用 VMD 分解将序列分解为 6 个本征模态函数 (intrinsic mode function, IMF)。首先,采用时序卷积网络 TCN 对分解后的 IMF 进行初步处理,建模其局部的短期时序依赖关系;然后,将提取到的中间特征进一步输入到 NTSformer 中,用于捕捉序列中的长期依赖结构与非平稳动态特征。两阶段建模过程均包含 Dropout 与线性层设计,以提升网络的泛化能力。

在特征融合阶段,引入了频率增强通道注意力机制 FECAM,融合所有 IMF 的预测信息。该模块首先对输入特征施加离散余弦变换 DCT 以提取其频域主成分,再基于




图 5 TCN 模块结构

Fig. 5 TCN module structure




图 6 预测模型流程图

Fig. 6 Flow chart of the prediction model

频谱特征引导通道注意力分配。最终,融合后的特征通过全连接层生成功率预测值,结合误差评估与反归一化操作,输出最终的风电功率预测结果。

3 实验结果与分析

3.1 实验环境

为确保所提出的基于 VMD-FECAM-TCN-NTSformer 的风电功率预测模型在多维度、非平稳风电时间序列数据上的有效性与稳定性,进行了模型单步预测和多步预测训练与性能评估。所有实验均在相同硬件与软件环境下进行,以保证结果的可比性和复现性。模型训练过程中,依托深度学习框架构建了包含 VMD 分解、频率注意力增强、局部时序建模以及非平稳 Transformer 编码结构的预测网络,统一配置的实验平台的环境如表 2 所示。

3.2 实验伪代码

为更直观地呈现本文提出的基于 VMD-FECAM-TCN-NTSformer 风电功率预测模型的整体运行机制,本文在模型结构介绍的基础上,进一步将模型的主要处理流程以伪代码形式进行了描述,内容如算法 1 所示。

表 2 实验环境参数

Table 2 Experimental environment parameters

实验环境配置	主要信息
实验平台	Pycharm
GPU 型号	4060ti-8G
编程语言	Python3. 11
CUDA 版本	12. 1. 1
深度学习框架	Pytorch2. 2. 1

算法 1: 本文提出的风电功率预测算法

输入: 风机历史时刻数据 X
输出: 风机未来时刻数据 $\hat{y}$
1: 对数据标准化处理得到 x_{norm}
2: 进行 VMD 分解得到 6 个模态分量 IMF1~6
3: 对每个 IMF 应用 FECAM 模块, 提取频率增强特征, 组合得到频率特征表示与原时域特征拼接, 得到融合特征输入 $\mathbf{X}_{output}$
4: 进入 TCN 网络得到 $\mathbf{X}_{TCN}$
5: 由式(9)~(11)计算均值准差得到标准化 z_l
6: while $l = N$ do(编码器堆叠)
7: Projector 模块生成非平稳因子 Δ, τ ;
8: 应用去平稳化注意力, 动态调整注意力权重
9: 通过前馈网络更新特征表示
10: endwhile
11: 得到编码器最终输出 H
12: while $l = M$ do(解码器堆叠)
13: 将编码器输出与掩码后的目标输入一起送入第 l 层 NTSformer 解码器, 预测下一时刻特征并更新解码器隐藏状态;
14. endwhile
15: 解码器最终输出通过反标准化(De-normalization), 还原为实际物理量尺度;
16: return $\hat{y}$ (输出未来时刻预测值)

3.3 评价指标

为量化评估模型性能, 本研究选用平均绝对误差(mean absolute error, MAE)和均方误差(mean squared error, MSE)以及决定系数(coefficient of determination, R^2)作为评价体系。其中, MAE 和 MSE 数值越低, 表明预测值与真实值偏差越小; R^2 取值区间为 $[0, 1]$, 其值越趋近于 1, 代表模型对数据分布的拟合程度越高。具体计算公式定义为:

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

(21)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2$$

(22)

$$MAE = \frac{1}{n} \sum_{i=1}^n |p_i - y_i|$$

(23)

式中: p_i 为预测值, y_i 为真实值, $\bar{y}$ 为平均值, n 为样本数量。

3.4 预测结果及分析

在本实验中, 通过对风电功率序列应用 VMD 分解, 分别选择将序列分解为 3~8 个 IMF。选择这一实验范围的原因在于: 当 IMF 数量 < 3 时, 分解不足, 无法有效捕捉数据的多尺度特征, 容易出现欠拟合; 而 > 8 个 IMF 时, 可能引入过多的冗余信息和噪声, 增加过拟合的风险, 且计算复杂度较高。因此, 重点评估了 4、5、6、7 这 4 个 IMF 数量。实验结果表明, 6 个 IMF 时, 模型的 R^2 达到最高值, MSE 和 MAE 最小, 表现最为优越。因此, 选择 6 个 IMF 作为 VMD 分解的最优参数, 能够在保证高精度的同时避免过拟合, 提升风电功率预测的稳定性和有效性。

为了验证所提出预测方法在风电功率预测中的有效性和优越性, 采用实际风电场的实测数据作为研究数据, 进行模型对比研究。验证样本上的 IMF 分量预测结果如图 7(a)~(f)所示, 总共包含 7 696 个时间步, 即取的数据集中的验证集部分。可以看出, 各 IMF 分量的预测值与实际值拟合效果良好。实验数据表明, IMF1~IMF4 的 $R^2 > 0.99$; IMF5 和 IMF6 的 R^2 为 0.97, 但幅值波动范围较小。

3.5 对比实验

为对比验证其他预测模型在该风电功率数据集上的表现, 本文在 15 min 的单步预测步长下, 对比了 8 种主流预测模型的性能, 包括传统循环神经网络(LSTM、GRU)、卷积网络(CNN、TCN)、经典 Transformer 系列(Transformer、Autoformer、TimeNet)以及本文所提出的融合频率增强注意力机制的 VMD-FECAM-TCN-NTSformer 模型, 随机取出 15 h 60 预测步长的样本组结果如图 8 所示。

为更直观地展示各对比模型的风电功率预测能力, 不同模型在测试集上的指标如表 3 所示。在所有模型中, 本文模型在 3 种预测步长下均取得最优表现, 15 min 单步预测的 R^2 达 0.966, MSE 和 MAE 分别为 0.408 和 0.497, 在 15 h 的多步预测中也维持了较高的精度, 显著优于其他模型。这说明融合 VMD 分解、TCN 局部特征提取、NTSformer 去平稳建模与 FECAM 频域增强的结构, 能够有效提取多尺度、非平稳的风电功率波动特征, 提升模型对趋势、周期与扰动的综合学习能力。

相较之下, Transformer 与 Autoformer 虽具备较强的全局依赖建模能力, 但对局部扰动与频率特征不敏感, 在长时预测中误差显著增加。TimeNet 表现相对稳定, 优于 TCN 与 GRU 等传统模型, 但在 MAE 方面仍略逊一筹; 而 LSTM、GRU 与 CNN 等传统结构模型在处理复杂非线性波动数据方面存在较大局限性, 预测精度明显不如深度注




图 7 各 IMF 分量预测结果

Fig. 7 The prediction results of each IMF component




图 8 不同预测模型的预测结果比较

Fig. 8 Comparison of prediction results of different prediction models

意力机制模型。

综上所述,本文所提出的模型在标准数据集上展现出优秀的拟合能力与预测精度,尤其在短期预测场景下表现出更强的泛化能力与误差控制能力,验证了其结构设计在风电功率多尺度建模任务中的有效性。

此外,为更全面验证所提出 FECAM 注意力机制的有效性,本文设计对比实验,将注意力模块替换为当前主流 3 种注意力机制:压缩-激励注意力机制(squeeze-and-excitation, SE)、卷积块注意力模块(convolutional block attention module, CBAM)和自注意力机制(self-attention, SA)4 种模型均基于相同的 VMD 分解、TCN-NTSformer 主干结构,保持一致的数据预处理、训练策略与损失函数,

仅在注意力机制部分进行替换。为保证对比的公平性,所有模型均在相同的数据集上进行训练,并使用 MSE、决定系数 R^2 作为评估指标,并在 15 min 单步预测上进行性能比较,结果如表 4 所示。

表 3 不同模型的性能指标

Table 3 Performance indexes of different models				
预测模型	预测步长	R^2	MSE	MAE
本文模型	15 min	0.966	0.408	0.497
	15 h	0.910	0.468	0.528
Transformer	15 min	0.942	0.452	0.528
	15 h	0.886	0.475	0.541
Autoformer	15 min	0.921	0.441	0.519
	15 h	0.870	0.485	0.552
TimeNet	15 min	0.925	0.433	0.512
	15 h	0.858	0.492	0.558
TCN	15 min	0.911	0.462	0.532
	15 h	0.842	0.503	0.567
GRU	15 min	0.883	0.464	0.537
	15 h	0.825	0.512	0.573
CNN	15 min	0.821	0.475	0.551
	15 h	0.800	0.535	0.597
LSTM	15 min	0.872	0.488	0.563
	15 h	0.812	0.526	0.589

表 4 不同模型的性能指标

Table 4 Performance indexes of different models			
预测模型	MAE	MSE	R^2
本文模型	0.497	0.408	0.966
SE-TCN	0.512	0.535	0.945
CBAM-TCN	0.587	0.641	0.938
SA-TCN	0.601	0.453	0.926

虽然 SE、CBAM 和 SA 在各自的机制层面上具有一定优势,但 FECAM 在频率域特征建模方面展现了独特的优势。具体而言:

SE 机制:通过对通道的加权来增强重要特征,但它主要依赖于全局信息,对频率特征的关注较弱。在处理风电功率这种具有频率依赖特性的非平稳时间序列时,SE 模块的频率建模能力较为有限,无法充分捕捉到关键的频率成分。

CBAM 机制:融合了通道注意力和空间注意力,能够在时空维度上进行特征加权,提升了特征表达能力。然而,CBAM 仍然主要聚焦在空间维度,而对于频率成分的建模并不具有特化机制,且空间注意力在频率特征的提取上存在一定的局限性。

SA 机制:自注意力机制通过捕捉全局依赖性,能够在

序列的每一位置建立长程依赖关系,在时序建模中具有一定优势。然而,标准 SA 机制在面对频率特征时,未能专门针对频域特性进行建模,其对风电功率这种具有显著频率波动的数据,表现出较弱的频率依赖捕捉能力。

与上述机制相比,FECAM 通过引入频率增强的通道注意力策略,专门针对频率域的特征进行建模。FECAM 利用 DCT 提取频域特征,并通过动态调整通道权重,有效强化关键频率成分的建模能力。此外,FECAM 避免了常见的高频噪声问题,具有更好的频率特征感知能力。通过结合频域和时域信息,FECAM 在提升模型对频率依赖特征的学习能力、增强模型对周期性波动的敏感性方面表现得更为突出。

最后,为验证提出的 VMD 与 FECAM 在风电功率预测中的有效性,本文设计了包含 4 组模型的对比实验,分别考察 VMD 和 FECAM 对预测性能的独立与协同贡献。并使用 MSE、决定系数 R^2 作为评估指标,并在 60 时间步上进行性能比较,结果如表 5 所示。

表 5 不同模型的性能指标

Table 5 Performance indexes of different models			
预测模型	MAE	MSE	R^2
本文模型	0.497	0.408	0.966
VMD-TCN-NTSformer-FECAM	0.489	0.603	0.931
CEEMDAN-TCN-NTSformer-FECAM	0.509	0.620	0.936
TCN-NTSformer-FECAM	0.475	0.641	0.944

实验结果表明,尽管 CEEMDAN 在一定程度上提升了特征提取能力,其预测性能仍低于本文提出的 VMD 分解方法,VMD 在有效分离频率信息与控制模态混叠方面表现更优。只使用 VMD 的模型在 R^2 指标上取得 0.931 的表现,表明模态分解在抑制非平稳干扰、提取多尺度频率特征方面具有良好效果。另一方面,只使用 FECAM 模型在 R^2 指标上达到 0.944,略优于只使用 VMD,说明即使在未进行模态分解的情况下,FECAM 也能通过通道加权机制有效增强模型对关键频率特征的建模能力。而本文提出的完整模型在所有指标上均表现最优,验证了两种机制在频率解构与特征增强方面的协同增益作用,有效提升了风电功率预测模型的精度与稳定性。

综上可得,FECAM 注意力机制在与 VMD 分解结合处理风电功率时序信号方面具有显著优势。

3.6 消融实验

消融实验对比验证 FECAM 与 NTSformer 的结合,能够更全面地挖掘风电功率序列中的多尺度动态规律和非平稳特征,明显提升风电功率预测的整体性能。结果如表 6 所示,本文所提出的模型在测试集上取得了最优的预测性能,MSE 为 0.408, R^2 达到 0.966,在所有对比模型中表现最为优越。相较于仅包含时间建模结构的 NTSformer

模型,本模型的 MSE 降低了 0.005, R^2 提升 4.4%,说明加入 TCN 与 FECAM 模块后,模型对局部时序特征与频率成分的建模能力显著增强。进一步比较中间组合结构可以发现:TCN-former 模型(即移除 FECAM 模块)在 MSE 和 R^2 上分别为 0.419 和 0.951,说明频域注意力机制对模型性能仍有重要提升作用;TCN-FECAM 模型(移除 NTSformer)表现较弱, R^2 降至 0.934,说明在缺乏去平稳建模的机制下,模型对风电功率中趋势变化的拟合能力下降。从图 9 可知,本文所提出的模型在风电功率预测中对极值点的表现更优,主要得益于其融合了频域建模、局部依赖建模与去平稳建模 3 种能力,从而在整体性能和边界样本处理能力上均表现出明显优势。

表 6 消融实验性能指标

预测模型	MAE	MSE	R^2
本文模型	0.497	0.408	0.966
TCN-NTSformer	0.532	0.419	0.951
TCN-FECAM	0.541	0.422	0.934
NTSformer	0.687	0.443	0.892




图 9 消融实验模型的预测结果比较

Fig. 9 Comparison of the prediction results of the ablation experimental

综上,消融实验表明,TCN 与 NTSformer 的协同结构有助于建模非平稳时序中的多尺度依赖关系,而 FECAM 模块则有效增强了对关键频率特征的感知能力。三者融合构建的完整模型在预测精度和拟合能力上均优于任一子结构组合,验证了各模块在整体架构中的必要性与有效性。

3.7 泛化实验

为进一步验证所提出模型在复杂环境中的泛化性能,本文选取宁夏一风电场的历史运行数据作为研究样本。数据采集时间范围为 2019 年 1 月 1 日~2019 年 12 月 31 日,共计 35 040 个观测点,采样间隔为 15 min,输入特征同样为风速和风向,取出 15 h 的样本组结果如图 10 所示。




图 10 不同预测模型的预测结果比较

Fig. 10 Comparison of prediction results of different models

各模型在该数据集上的预测结果如表 7 所示。从整体趋势来看,所有模型在两个预测步长下的性能均有所下降,表现为 R^2 降低、MSE 与 MAE 指标普遍上升。这表明新数据集中存在更高的不确定性与非线性特征,对模型的稳定性与鲁棒性提出了更高要求。

表 7 不同模型的性能指标

Table 7 Performance indexes of different models				
预测模型	预测步长	R^2	MSE	MAE
本文模型	15 min	0.941	0.539	0.612
	15 h	0.825	0.603	0.668
Transformer	15 min	0.882	0.597	0.659
	15 h	0.77	0.665	0.715
Autoformer	15 min	0.887	0.589	0.642
	15 h	0.761	0.671	0.707
TimeNet	15 min	0.894	0.577	0.636
	15 h	0.773	0.642	0.698
TCN	15 min	0.875	0.606	0.661
	15 h	0.749	0.684	0.724
GRU	15 min	0.854	0.609	0.673
	15 h	0.725	0.692	0.738
CNN	15 min	0.791	0.628	0.688
	15 h	0.726	0.705	0.746
LSTM	15 min	0.836	0.641	0.698
	15 h	0.71	0.723	0.754

具体来看,本文提出的 FECAM-TCN-NTSformer 模型依然保持领先优势,在两个预测步长下均取得最优的 R^2 和最低的误差指标,表现出较强的抗噪能力和频率建模优势。在 15 h 的预测中,仍能保持较高的 R^2 值,远优于 LSTM 和 CNN 等传统模型,说明其频域增强机制在处理长周期、低信噪比的序列中具有更强的适应性。

综上所述,本文提出融合频率增强通道注意力的 VMD-TCN-NTSformer 风电功率预测模型在各项指标上

均表现良好并且优于其他对比模型,证明了其在风电功率预测中的有效性和优越性。

4 结 论

为应对复杂时序数据中非平稳性、多尺度特征及周期性变化规律的建模挑战,本文提出了一种基于时频特征融合的多变量时间序列预测模型。该模型在频域与时域两个层面协同建模,显著提升了风电功率预测的准确性与稳定性。具体结论如下:

在频域建模方面,采用 VMD 分解方法将原始时间序列拆分为多个不同频率的 IMF,增强了数据表达的多尺度性。引入的频率增强通道注意力机制可在频域中自适应提取关键频率特征,提升了模型对周期性规律的敏感性与建模能力。

在时域建模方面,模型融合了时间卷积网络与 NTSformer。其中,TCN 高效建模局部短期依赖,NTSformer 则通过去平稳化注意力机制动态调节注意力权重,增强模型对长期时空依赖和非平稳动态变化的适应能力,提升整体预测性能。

在两个真实风电场数据集上的实验结果表明,本文模型在均方误差(MSE)、平均绝对误差(MAE)以及决定系数(R^2)等多项评估指标上均优于主流对比模型。进一步开展的消融实验验证了 VMD 分解、FECAM 模块以及去平稳注意力机制在提升模型精度和稳定性方面的关键作用。

本文提出的时频融合建模框架不仅能够从时域提取局部与全局特征,还能在频域有效捕捉周期性规律,具有良好的泛化性能和工程适用价值,为多变量非平稳时间序列预测任务提供了切实可行的解决思路与技术路径。

参考文献

[1] 李晖,刘栋,姚丹阳. 面向碳达峰碳中和目标的我国电力系统发展研判[J].中国电机工程学报,2021,41(18): 6245-6259.
LI H, LIU D, YAO D Y. Development analysis of China's power system towards the goal of carbon peak and carbon neutrality[J]. Proceedings of the CSEE, 2021,41(18):6245-6259.
[2] 任大伟,侯金鸣,肖晋宇,等. 支撑双碳目标的新型储能发展潜力及路径研究[J]. 中国电力, 2023, 56(8): 17-25.
REN D W, HOU J M, XIAO J Y, et al. Development potential and path of new-type energy storage supporting the dual-carbon goal[J]. Electric Power, 2023, 56(8): 17-25.
[3] 罗旭,王建平,威佳豪,等. 基于 EMD 和卷积神经网络的脑电信号情感识别[J]. 电子测量技术, 2023, 46(15):88-95.

LUO X, WANG J P, WEI J H, et al. EEG emotion recognition based on EMD and convolutional neural network [J]. Electronic Measurement Technology, 2023,46(15):88-95.
[4] 沈赋,刘思蕊,蔡子龙,等. 考虑相关性的新能源电力系统风光功率短期联合预测模型[J]. 太阳能学报,2025, 46(5):203-212.
SHEN F, LIU S R, CAI Z L, et al. Short-term joint prediction model of wind and solar power for new energy power system considering correlation[J]. Acta Energiae Solaris Sinica,2025, 46(5):203-212.
[5] 李恺丽,王剑斌,沈怡俊,等. 基于 CEEMD-WOA-LSTM 的光伏发电功率预测[J]. 热能动力工程,2025, 40(2):136-147.
LI K L, WANG J B, SHEN Y J, et al. Photovoltaic power prediction based on CEEMD-WOA-LSTM[J]. Journal of Engineering for Thermal Energy and Power,2025,40(2):136-147.
[6] 向阳,刘亚娟,孙志伟,等. 基于帝王蝶算法的 CNN-GRU-LightGBM 模型短期风电功率预测[J]. 太阳能学报,2025,46(1):105-114.
XIANG Y, LIU Y J, SUN ZH W, et al. Short-term wind power prediction based on monarch butterfly optimization algorithm optimized CNN-GRU-LightGBM model[J]. Acta Energiae Solaris Sinica, 2025,46(1):105-114.
[7] 肖良帅,潘晴,黄亦翔,等. 基于注意力机制 RNN 的数控机床主轴热误差建模[J]. 电子测量技术, 2023, 46(24):56-62.
XIAO L SH, PAN Q, HUANG Y X, et al. Thermal error modeling of CNC machine tool spindle based on attention mechanism RNN [J]. Electronic Measurement Technology,2023, 46(24):56-62.
[8] 张登攀,兰征,杜怡衡. 基于 PCHIP-VMD 数据分析与 SSA-LSTM 模型的短期风电功率预测[J]. 电子测量与仪器学报,2025,39(5):251-261.
ZHANG D P, LAN ZH, DU Y H. Short-term wind power forecasting based on PCHIP-VMD data analysis and SSA-LSTM model [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5): 251-261.
[9] 赵静,孙志辉,杨晓雷,等. 基于改进 Transformer 的网络流量异常检测方法[J]. 电子测量技术, 2024, 47(10):110-117.
ZHAO J, SUN ZH H, YANG X L, et al. Network traffic anomaly detection method based on improved Transformer [J]. Electronic Measurement Technology, 2024,47(10):110-117.

- [10] 聂靖杰,刘树鑫,邢朝健,等. 基于 TPE-Informer 模型的铁路继电器寿命预测[J]. 电气工程学报, 2024, 19(3):98-106.
NIE J J, LIU SH X, XING CH J, et al. Railway relay life prediction based on TPE-Informer model [J]. Journal of Electrical Engineering, 2024, 19(3):98-106.
- [11] 滕陈源,丁逸超,张有兵,等. 基于 VMD-Informer-BiLSTM 模型的超短期光伏功率预测[J]. 高电压技术, 2023, 49(7):2961-2971.
TENG CH Y, DING Y CH, ZHANG Y B, et al. Ultra-short-term photovoltaic power prediction based on VMD-Informer-BiLSTM model[J]. High Voltage Engineering, 2023, 49(7):2961-2971.
- [12] 林蔚青,缪希仁,江灏,等. 多线圈联合学习的核电厂控制棒驱动机构动作状态异常检测方法[J]. 仪器仪表学报, 2025, 46(6):290-303.
LIN W Q, MIAO X R, JIANG H, et al. Anomaly detection method for motion status of control rod drive mechanism in nuclear power plants by multi-coil joint learning[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 290-303.
- [13] 张倩,刘玉敏,刘玉娇,等. 基于时序卷积网络的滚动轴承剩余使用寿命预测[J]. 电子测量技术, 2023, 46(17):31-37.
ZHANG Q, LIU Y M, LIU Y J, et al. Remaining useful life prediction of rolling bearing based on temporal convolutional network [J]. Electronic Measurement Technology, 2023, 46(17): 31-37.
- [14] 刘辉,凌宁青,罗志强,等. 基于 TCN-LSTM 和气象相似日集的电网短期负荷预测方法[J]. 智慧电力, 2022, 50(8):30-37.
LIU H, LING N Q, LUO ZH Q, et al. Short-term power load forecasting method based on TCN-LSTM and meteorological similar day set[J]. Smart Power, 2022, 50(8):30-37.
- [15] 逯静,张燕茹,王瑞. 基于 BWO 优化 VMD 和 TCN-BiGRU 的短期风电功率预测[J]. 工程科学与技术, 2025, 57(3):31-41.
LU J, ZHANG Y R, WANG R. Short-term wind power prediction based on BWO optimized VMD and TCN-BiGRU [J]. Advanced Engineering Sciences, 2025, 57(3): 31-41.
- [16] LIU Y, WU H X, WANG J M, et al. Non-stationary transformers: Exploring the stationarity in time series forecasting [J]. Advances in Neural Information Processing Systems, 2022, 35: 9881-9893.
- [17] 黄益,胡骅,魏云冰. 基于 VMD-IBWO-BiLSTM 的短期风电功率预测[J]. 电网与清洁能源, 2025, 41(5): 148-158.
HUANG Y, HU H, WEI Y B. Short-term wind power prediction based on VMD-IBWO-BiLSTM[J]. Power System and Clean Energy, 2025, 41(5):148-158.
- [18] 冯建铭,希望·阿不都瓦依提,蔺红. 基于聚类 SABO-VMD 和组合神经网络的短期光伏发电功率预测[J]. 太阳能学报, 2025, 46(2):357-366.
FENG J M, ABUDUWAYITI X W, LIN H. Short-term photovoltaic power prediction based on clustering SABO-VMD and combined neural network[J]. Acta Energiæ Solaris Sinica, 2025, 46(2):357-366.
- [19] JIANG M W, ZENG P, Y WANG K, et al. FECAM: Frequency enhanced channel attention mechanism for time series forecasting[J]. Advanced Engineering Informatics, 2023, 58: 102158.

作者简介

杨青濠, 硕士研究生, 主要研究方向为新能源及发电技术。

E-mail:1608244996@qq.com

张嘉英(通信作者), 副教授, 主要研究方向为风力发电系统的建模与控制等。

E-mail:zhangjy2222@163.com