

基于时空图谱聚类与时序二维化 Transformer的风电集群功率 多尺度融合预测方法

朱嘉宁¹, 王钊^{1,2}, 李奕陶³, 杨茂¹, 江任贤¹

- (1. 现代电力系统仿真控制与绿色电能新技术教育部重点实验室(东北电力大学), 吉林省吉林市 132012;
2. 新能源与储能运行控制国家重点实验室(中国电力科学研究院有限公司), 北京市 100192;
3. 华能吉林发电有限公司新能源分公司, 长春市 130022)

摘要:【目的】针对风电集群功率预测中时空特征提取不足和多尺度特征难以有效融合的问题, 提出一种时空图谱聚类 (spatio-temporal graph spectral clustering, ST-SpecCluster) 与时序二维化 Transformer (time-series 2D-resaping transformer, T2Dformer) 的风电集群功率多尺度融合预测方法。【方法】首先, 以风电场地理坐标构建空间骨架, 并基于滑动时间窗口内的功率数据动态计算风电场间的皮尔逊相关系数, 构建了一种能同时感知静态地理邻近性与动态运行关联性的混合时空图; 通过时空图卷积网络提取深度时空特征, 并融合注意力聚合机制与谱聚类划分出强相关子集; 随后, 利用局部加权回归的季节与趋势分解 (seasonal-trend decomposition procedure based on loess, STL) 将子集群内功率及数值天气预报序列分解出趋势项、周期项和残余项。最后, 设计了新的预测模型, 通过快速傅里叶变换周期提取、时序二维化、Inception 卷积与注意力机制的协同, 实现多尺度特征联合建模。利用时序二维化 Transformer 分别预测各个集群的各个分量, 并合并重构结果, 将该方法应用于中国吉林某风电场集群。【结果】与前沿的预测方法相比, 所提方法的归一化均方根误差降低了 1.89%, 归一化平均绝对误差降低了 2.87%, 决定系数提升了 10.87%。【结论】所提方法为高精度风电功率预测提供了一种有效解决方案, 对提升电力系统调度能力与新能源消纳具有重要实际意义。

关键词: 风电功率预测; 时空图谱聚类 (ST-SpecCluster); 季节分解; 时序二维化 Transformer (T2Dformer); 时空多尺度融合

中图分类号: TM614

文献标志码: A

文章编号: 1000-7229(2026)03-0039-12

DOI: 10.12204/j.issn.1000-7229.2026.03.004

Multi-scale Fusion Prediction Method for Wind Power Cluster Power Based on Spatio-Temporal Graph Spectral Clustering and Time-Series 2D-Reshaping Transformer

ZHU Jianing¹, WANG Zhao^{1,2}, LI Yitao³, YANG Mao¹, JIANG Renxian¹

- (1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of Education (Northeast Electric Power University), Jilin 132012, Jilin Province, China; 2. State Key Laboratory of Operation and Control of Renewable Energy & Storage Systems (China Electric Power Research Institute), Beijing 100192, China; 3. Huaneng Jilin Power Generation Co., Ltd. New Energy Branch, Changchun 130022, China)

ABSTRACT: [Objective] To address limitations in spatio-temporal feature extraction and the integration of multi-scale features in wind power cluster prediction, this paper proposes a multi-scale fusion prediction method based on spatio-temporal graph spectral clustering (ST-SpecCluster) and a time-series 2D-resaping Transformer (T2Dformer). [Methods] A spatial skeleton is constructed utilizing the geographical coordinates of wind farms. A hybrid spatio-temporal graph is built to capture both static geographical proximity and dynamic operational correlations by dynamically calculating the Pearson correlation coefficients between wind farms using power data within sliding time windows. Deep spatio-temporal features are

extracted via a spatio-temporal graph convolutional network (ST-GCN), and an attention aggregation mechanism is combined with spectral clustering to partition the wind farms into highly correlated sub-clusters. For each sub-cluster, the power and numerical weather prediction (NWP) sequences are decomposed into trend, periodic, and residual components using the seasonal-trend decomposition procedure based on loess (STL). A novel prediction model, the T2Dformer, is then designed to jointly model multi-scale features through the collaboration of fast Fourier transform (FFT) period extraction, time-series 2D reshaping, Inception convolution, and attention mechanisms. Each component of every cluster is predicted separately, followed by aggregation and reconstruction. **[Results]** The proposed method was applied to a wind farm cluster in Jilin Province, China. Compared with state-of-the-art prediction methods, the proposed approach reduced the normalized root mean square error by 1.89%, reduced the normalized mean absolute error by 2.87%, and increased the coefficient of determination (R^2) by 10.87%. **[Conclusions]** This paper provides an effective solution for high-precision wind power prediction, with practical significance for enhancing the dispatching capability of power systems and the consumption of renewable energy.

This work is supported by National Natural Science Foundation Young Scientists Fund Project (No. 52307151).

KEYWORDS: wind power prediction; spatio-temporal graph spectral clustering (ST-SpecCluster); STL decomposition; T2Dformer; spatio temporal multi-scale fusion

0 引言

在“双碳”目标的持续推动下,风电已成为能源结构转型的核心力量。根据全球风能理事会最新数据,全球风电装机容量持续快速增长,2025年全球风电新增装机容量攀升至约170 GW^[1]。随着风电开发向集群化、规模化演进,其出力的随机性、波动性与间歇性对区域电网的稳定运行与实时调度构成了严峻挑战^[2-5]。在此背景下,实现高精度的风电集群功率预测,对于保障电力系统安全、促进新能源消纳具有至关重要的现实意义^[6-7]。

由于风电场群所在的大空间尺度近地风速场具有连续性,在风电场群区域内各风电场的功率波动呈现一定的时空相关性^[8-9]。准确量化这种动态关联,是构建高精度预测模型的关键。现有风电集群功率预测方法主要包括整体法^[10]、累加法^[11]、统计升尺度法^[12]及集群划分法^[13]。其中,前3类方法难以有效利用风电场间的空间关联信息,预测精度受限。尤其对于地理跨度广、内部资源分布不均的大规模集群,若将其视为整体进行预测,模型难以刻画内部各异的出力特性,导致预测结果对实际调度的指导性不足。相比之下,集群划分法的核心优势在于,其能将大集群划分为多个相似的子集群。此举旨在将具有强相关性的风电场归为一类,从而有效规避异质场站数据引入的噪声干扰,不仅显著降低了单模型的建模复杂度,提升预测精度,其划分结果更能直接对应电网的实际调度分区,为精准调度与控制提供关键决策依据。

在风电集群划分的早期研究中,传统聚类算法如 K -means^[14]、模糊 C 均值算法 (fuzzy C -means, FCM)^[15] 和基于密度的噪声应用空间聚类算法

(density-based spatial clustering of applications with noise, DBSCAN)^[16]等,主要依赖风电场的地理坐标、历史出力曲线或静态相关系数矩阵,将风电场视为孤立点,忽略了风电场之间动态变化的空间拓扑结构和相互作用关系。

近年来,图神经网络 (graph neural network, GNN)^[17] 为突破上述局限提供了新路径。该方法能同时利用图的结构信息与节点属性信息,从而生成内聚性强且节点属性同质的聚类结果。文献[18]提出了一种基于动态图卷积网络的短期预测方法,通过风速传播机理动态构建图结构,有效捕捉了风电场群的空间关联特性。文献[19]进一步引入了动态图建模框架,通过自适应调整风电场节点嵌入的关联权重,捕捉场群交互关系。文献[20]引入了注意力机制以增强图卷积网络对气象图节点相关性的提取能力。然而,现有基于GNN的方法多数仅侧重空间或时间单一维度,或对二者进行简单串联处理,难以有效捕捉风电场群在时空演变过程中高度耦合的深度特征。这种时空关联性建模的缺失,导致模型输入特征的表征能力不足,无法为后续更精准的风电集群功率预测提供充分的特征信息。

以人工神经网络为代表的深度学习算法是风电预测中应用最广泛的方法,如循环神经网络 (recurrent neural network, RNN)^[21] 和卷积神经网络 (convolutional neural network, CNN)^[22] 模型在时间序列依赖关系建模方面具有突出的优势,能够捕捉局部时序模式或短期依赖。Transformer 及其变体^[23-24] 凭借自注意力机制在长程依赖的风电功率预测任务中表现出显著优势。但是由于风电信号本身复杂,尤其是其多尺度物理特性和非平稳性,仅依靠深度学习模型很难直接捕获其复杂模式。

因此,现在通常将深度学习模型与信号分解技术相结合形成组合风电预测模型。通过信号分解技术捕捉风电信号的多时间尺度特征,将非平稳的原始数据转换为规律性更强的子序列,为后续预测模型提供了更具解释性的输入特征,提高模型预测准确率。文献[25]提出了一种基于集合经验模态分解(ensemble, empirical mode decomposition, EEMD)-Transformer的风速预测方法,该方法首先利用EEMD将风速数据转换为16维序列,再进行建模预测。文献[26]提出了一种基于变分模态分解(variational mode decomposition, VMD)与多目标优化的混合预测系统,通过将风速序列分解为不同频率的模态分量并分别建模,显著降低了序列的非线性波动对预测精度的影响。文献[27]将序列转换为频率张量,利用傅里叶变换分解提取长期趋势,虽然该模型增强了对低频分量的建模能力,但对高频残差的过度抑制导致空间波动细节丢失。文献[28]联合VMD与图卷积网络提取空间特征,以捕捉时序依赖。然而,这些方法大多对分解后的分量进行独立或简单的序列化建模,缺乏对多分量间复杂关联的有效联合建模机制,难以充分挖掘和融合风电功率序列中固有的多尺度信息。

综上所述,现有研究在2个方面存在明显不足:一是对风电集群场站间深度时空关联特征的提取不足;二是对时序多尺度分量的联合建模能力有限,导致特征融合不充分。针对这些问题,本文提出一种基于时空图谱聚类(spatio-temporal graph spectral clustering, ST-SpecCluster)与时序二维化Transformer(time-series 2D-resaping transformer, T2Dformer)的风电集群功率多尺度融合预测方法。构建一个能够统一实现时空特征深度提取与多尺度特征充分融合的完整框架。

首先,提出ST-SpecCluster方法,构建同时感知静态地理邻近性与动态运行关联的混合时空图,通过时空图卷积网络提取深度特征,并融合注意力聚合机制与谱聚类算法,划分出内部时空特性相似的子集群,为后续分区预测奠定基础。其次,考虑风电功率序列的非平稳性与多尺度特性,采用利用局部加权回归的季节与趋势分解(seasonal-trend decomposition procedure based on loess, STL)将划分后的各子集群的功率及气象序列解耦为趋势、周期与残差等不同时间尺度的分量,降低每个分量序列的非平稳性和非线性,使后续预测模型更容易学习和捕捉其变化规律,提升模型的稳定性和精度。最后,在预测建模层面,为克服现有模型对多分量、多周期特征联合建模能力的不足,设计时序二维化

Transformer预测模型,通过快速傅里叶变换周期提取、时序二维化、Inception卷积与注意力机制的多层次协同,模型能够自适应地提取局部多尺度周期模式并兼顾全局长程依赖关系,最终实现对各子集群功率分量的精准预测与重构。

1 整体预测框架

本文提出了时空图谱聚类与时序二维化Transformer的风电集群功率多尺度融合预测方法,其整体技术路线如图1所示。




图1 风电集群功率多尺度融合预测框架

Fig. 1 Multi-scale fusion prediction framework for wind power clusters

具体流程如下:

1)数据准备与预处理:对各风电场的原始地理坐标、历史功率数据及数值天气预报(numerical weather prediction, NWP)风速数据,进行清洗与插补,

处理其中存在的异常值与缺失值;对功率和NWP风速数据进行归一化处理,以消除量纲差异。最终输出标准化后的地理信息、功率序列及NWP风速序列,为构建预测方法提供高质量输入。

2)时空图谱聚类分析:基于预处理得到的地理坐标、历史功率数据和NWP风速数据,采用时空谱聚类算法对风电场集群进行划分,识别出多个强相关性风电子集群。

3)子集群序列聚合与分解:针对划分后的每个子集群,分别聚合其内部所有风电场的功率数据,形成子集群总功率序列;同时对NWP风速数据进行空间平均,得到子集群平均NWP风速序列。随后,分别对这2个聚合序列进行STL分解,得到各自的趋势项、周期项和残差项。每个子集群共输出功率趋势、功率周期、功率残差、NWP趋势、NWP周期、NWP残差6个分量序列。

4)基于T2Dformer的功率预测:将每个子集群的6个分量序列作为T2Dformer模型的输入(通道维度 $C=6$),分别预测各子集群未来的功率趋势、周期与残差分量。将各功率分量预测结果叠加,得到子集群功率预测值,最后汇总所有子集群的预测功率,得到集群总功率的最终预测结果。

2 时空图谱聚类

基于时空图谱聚类的风电集群划分方法,通过将风电场建模为图结构,并利用时空图卷积网络提取时空特征,进而结合谱聚类方法实现集群划分。方法分为4个关键阶段:

- 1)时空图构建:将风电场建模为时空拓扑图;
- 2)特征提取:通过时空图卷积网络提取节点特征为嵌入向量;
- 3)相似性建模:构建高斯相似性矩阵;
- 4)谱聚类:实现基于谱划分的集群识别。

2.1 时空图构建

要进行风电场站的特征提取,首先要定义所需的时空图。本文利用风电场的地理位置以及NWP风速和功率的时间序列构造时空图,如图2所示。

每个场站作为一个节点,每个节点特征向量包括NWP风速和功率的时序数据,对于节点 i 在时间 t 的特征向量 $X_i^{(t)}$ 为:

$$X_i^{(t)} = [P_i^{(t)}, V_{\text{NWP},i}^{(t)}] \in \mathbf{R}^2 \quad (1)$$

式中: $P_i^{(t)}$ 、 $V_{\text{NWP},i}^{(t)}$ 分别为时间 t 节点 i 的功率和NWP风速。

所有节点在时间 t 的特征矩阵 $X^{(t)}$ 为:




图2 时空图

Fig. 2 Spatiotemporal diagram

$$X^{(t)} = \begin{bmatrix} P_0^{(t)} & V_{\text{NWP},0}^{(t)} \\ \vdots & \vdots \\ P_{n-1}^{(t)} & V_{\text{NWP},n-1}^{(t)} \end{bmatrix} \in \mathbf{R}^{n \times 2} \quad (2)$$

采用滑动时间窗口策略,动态计算节点间功率序列的皮尔逊相关系数,构建随时间变化的动态邻接矩阵 W ,节点 i 与节点 j 在时间 t 的连接权重 $W_{ij}(t)$ 为:

$$W_{ij}(t) = \begin{cases} \exp\left\{-\frac{[1 - \rho_{ij}(t)]^2}{\sigma_\rho^2}\right\}, & \rho_{ij}(t) > \varepsilon, i \neq j \\ 0, & \text{其他} \end{cases} \quad (3)$$

式中: σ_ρ^2 、 ε 分别为控制 W 矩阵稀疏度和分布的阈值; $\rho_{ij}(t)$ 为节点 i 和节点 j 在时间窗口内功率序列的皮尔逊相关系数。该图结构同时感知静态地理邻近性与动态运行关联性。

2.2 时空图卷积网络

为有效提取风电场间复杂的时空特征,本文采用时空图卷积网络(spatio-temporal graph convolutional network, ST-GCN)^[29-30],其架构如图3所示,该网络由2个时空卷积块堆叠而成,通过交替处理图的空间结构信息与时间动态信息,实现对非欧几里得结构数据的深度特征挖掘。

网络输入为 T 个时间步的图特征向量 X 及动态邻接矩阵 W 。具体而言,ST-GCN利用图卷积层捕捉




图3 时空图卷积网络整体框架

Fig. 3 ST-GCN overall framework

空间邻域特征,并结合时间卷积网络提取时间维度的演变规律。本文中,经过特征提取与全连接层映射,最终输出节点的时空嵌入表示为 $H_{st} \in \mathbf{R}^{n \times d}$,其中, n 为节点数; d 为嵌入维度。

为得到稳定、统一的集群划分,采用注意力聚合方法为每个节点生成凝练了长期动态特性的稳定表征向量,对于节点 i ,其稳定表征 R_i 为:

$$\alpha_i' = \frac{\exp(q^T h_i^t)}{\sum_{k=1}^T \exp(q^T h_i^k)} \quad (4)$$

$$R_i = \sum_{t=1}^T \alpha_i' h_i^t \quad (5)$$

式中: α_i' 为节点 i 在 t 时刻的归一化注意力权重; h_i^t 为节点 i 在 t 时刻的特征向量; q 为可学习的共享查询向量。

2.3 相似性建模和谱聚类

谱聚类^[31-32]本质是将数据点视为图论中的顶点,通过拉普拉斯矩阵的谱分析实现聚类。将原始数据空间转换到特征空间,在特征值分解后的低维空间中实现聚类。

基于ST-GCN提取的节点稳定表征向量,采用谱聚类算法对风电场群进行划分。谱聚类本质上是将聚类问题转化为图拉普拉斯矩阵的特征值分解问题,能够有效识别非凸形状的簇结构。

本文首先基于节点间的稳定表征 R ,利用高斯核函数构建相似性矩阵 S ,其元素 S_{ij} 衡量了风电场 i 与 j 在时空特征上的相似度。随后,计算归一化拉普拉斯矩阵,并进行特征值分解,选取前 k 个最小特征值对应的特征向量构建低维特征空间。最后,利用K-means算法在该特征空间内完成子集群的划分,从而识别出具有强时空相关性的风电场集合。

3 STL分解

针对风电功率序列极强的非平稳性和非线性,本文引入STL分解^[33]方法。STL分解通过嵌套的内循环与外循环迭代过程,利用Loess平滑技术将原始序列解耦为3个分量:

$$X_t = T_t + S_t + R_t \quad (6)$$

式中: X_t 为原始序列; T_t 为趋势分量; S_t 为周期分量; R_t 为残差分量。

相比于其他信号分解方法,STL分解对外循环中的异常值权重调整机制使其具有较强的鲁棒性。该方法能有效分离出风电功率的长期趋势与显著的周期性波动,从而降低了后续预测模型对非平稳数据的建模难度,使T2Dformer能更专注于捕捉各分量特定的时序模式。

4 时序二维化Transformer

本章所提T2Dformer模型如图4所示。T2Dformer的核心思想在于捕捉时间序列的局部周期性模式,并利用Transformer强大的全局依赖建模能力进行深层特征提取。模型主要由4个顺序连接的模块构成:1)TimesBlock模块,负责提取局部周期特征;2)位置编码层;3)Transformer编码器;4)预测输出层。下文将详细阐述各模块的设计与功能。

4.1 TimesBlock模块

TimesBlock模块通过2维卷积捕捉时序的局部模式,提升了多周期建模能力,具体过程如图5所示。

1)通过快速傅里叶变换提取一维时序特征 $X_{1D} \in \mathbf{R}^{T \times C}$ (T 为时间长度; C 为通道维度)的周期为:

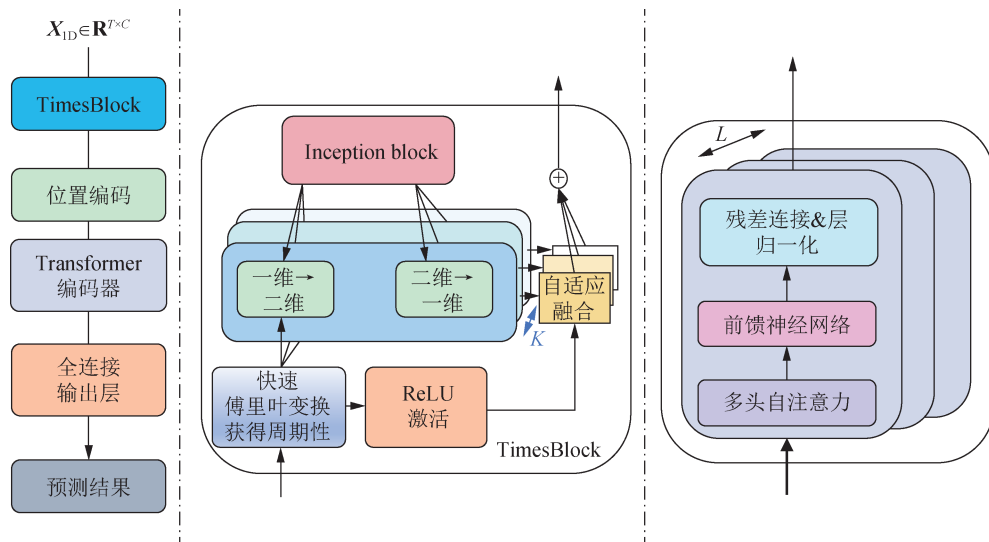


图4 T2Dformer框架

Fig. 4 T2Dformer framework




图5 TimesBlock 模块原理

Fig. 5 Schematic diagram of the TimesBlock module

$$\mathbf{A} = \text{Avg}\{\text{Amp}[\text{FFT}(\mathbf{X}_{1D})]\} \quad (7)$$

$$f_1, \dots, f_k = \arg \text{Topk}(\mathbf{A}) \quad (8)$$

$$p_1, \dots, p_k = \left\lceil \frac{T}{f_1} \right\rceil, \dots, \left\lceil \frac{T}{f_k} \right\rceil \quad (9)$$

式中: $\mathbf{A} \in \mathbf{R}^T$ 表示 $\mathbf{X}_{1D}$ 中每个频率分量的强度, 强度最大的 k 个频率 $\{f_1, \dots, f_k\}$ 对应着最显著的 k 个周期长度 $\{p_1, \dots, p_k\}$ 。上述过程简记为:

$$\mathbf{A}, \{f_1, \dots, f_k\}, \{p_1, \dots, p_k\} = \text{Period}(\mathbf{X}_{1D}) \quad (10)$$

2) 基于选定的周期将原始的一维时间序列 $\mathbf{X}_{1D}$ 折叠成为二维张量 $\mathbf{X}'_{2D}$:

$$\mathbf{X}'_{2D} = \text{Reshape}_{p,f}[\text{Padding}(\mathbf{X}_{1D})] \quad (11)$$

式中: $\text{Padding}(\cdot)$ 为在序列末尾补 0, 使得序列长度可以被 p_i 整除。

3) 选取经典的 Inception 模型, 通过 2D 卷积提取二维张量的时序变化表征 $\hat{\mathbf{X}}'_{2D}$ 。

4) 对于提取的时序特征, 将其转化回一维空间以便进行信息聚合得到一维张量的时序变化表征, 如式(12)所示。

$$\hat{\mathbf{X}}'_{1D} = \text{Trunc}[\text{Reshape}_{1,(p \times f)}(\hat{\mathbf{X}}'_{2D})] \quad (12)$$

5) 将得到的一维表征以其对应频率的强度进行加权求和, 得到最终输出特征 $\mathbf{Z} \in \mathbf{R}^{T \times h}$, 其中, h 为输出的隐藏维度。

$$\hat{\mathbf{A}}_{f_1}, \dots, \hat{\mathbf{A}}_{f_k} = \text{ReLU}(\mathbf{A}_{f_1}, \dots, \mathbf{A}_{f_k}) \quad (13)$$

$$\mathbf{Z} = \sum_{i=1}^k \hat{\mathbf{A}}_{f_i} \times \hat{\mathbf{X}}'_{1D} \quad (14)$$

4.2 位置编码

将标准正弦位置编码添加到 TimesBlock 模块输出的特征序列上, 以保留序列的顺序信息, 得到新的特征 $\mathbf{Z}'$ 。

$$\mathbf{Z}' = \mathbf{Z} + \mathbf{E}_{\text{pos}} \quad (15)$$

采用标准的正弦编码:

$$\begin{cases} E_{\text{pos}}^{(i, 2j)} = \sin(\delta_{\text{pos}}/10\,000^{2j/h}) \\ E_{\text{pos}}^{(i, 2j+1)} = \cos(\delta_{\text{pos}}/10\,000^{2j/h}) \end{cases} \quad (16)$$

式中: i 为时间步索引; δ_{pos} 为位置索引; $j \in [0, h/2 - 1]$ 。

4.3 Transformer 编码器

嵌入位置信息后的特征序列 $\mathbf{Z}'$ 被馈入一个 Transformer 编码器。该编码器由多层堆叠的自注意力层和前馈神经网络层构成, 其中自注意力机制使模型能够动态地捕捉序列元素之间复杂的长程依赖关系和全局交互模式。Transformer 编码器在此阶段对已提取的局部周期特征进行进一步的抽象、融合和上下文理解, 生成高层次、信息丰富的时序表示。

编码器将输入的时序数据 $\mathbf{Z}'$ 计算为查询向量 $\mathbf{Q}$ 、关键词向量 $\mathbf{K}$ 、值向量 $\mathbf{V}$ 。其中, $\mathbf{V}$ 结合自注意力结果, $\mathbf{Q}$ 和 $\mathbf{K}$ 的作用是两两相乘计算自注意。 $\mathbf{Z}^{(n)}$ 为第 n 个多头注意的特征向量, 计算式为:

$$\mathbf{Z}^{(n)} = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (17)$$

式中: d_k 为关键词向量 $\mathbf{K}$ 的维度; $\text{softmax}(\cdot)$ 为归一化函数。

将 n 个自注意计算的特征矩阵 $\mathbf{Z}^{(n)}$ 拼接后乘相应的线性变换权重矩阵 $\mathbf{W}^0$ 得到最终特征 $\mathbf{Z}_f$ 的表达式:

$$\mathbf{Z}_f = \mathbf{C}_{\text{concat}}(\mathbf{Z}^{(1)}, \dots, \mathbf{Z}^{(n)})\mathbf{W}^0 \quad (18)$$

式中: $\mathbf{C}_{\text{concat}}(\cdot)$ 为拼接矩阵。

4.4 全连接输出层

通过全连接层将 Transformer 输出的特征维度投影到模型最终需要预测的时间步长上, 最终输出即为模型对未来指定时长的预测值序列。

5 算例分析

5.1 数据集描述与预处理

本文选择中国吉林省 50 个风电场站的实测功率以及 NWP 数据集验证所提方法的有效性。数据集详细情况见表 1, 其中训练集、验证集和测试集的比例为 7:1:2。

表 1 数据集介绍

Table 1 Introduction to the dataset

参数	数值
风电场站数量/个	50
总装机容量/MW	5280
实测数据	功率
NWP 数据	风速
时间分辨率/min	15
数据长度	2021-01-02—2021-07-23

为保证后续聚类与预测模型的可靠性,对50个风电场的功率及NWP数据进行数据预处理,具体流程为:

1)多源数据时间对齐:以15 min为标准时间轴,对所有50个风电场的功率序列和NWP序列进行时间戳对齐。对于采样时间偏差在 ± 1 min内的数据视为同一时刻,偏差较大者通过线性插值校正至标准时刻,确保时空图构建时各节点在同一时间断面上。

2)异常值剔除:受传感器故障或通信干扰影响,原始数据中可能存在死值或越限值。采用 3σ 准则结合风机物理约束识别并剔除异常数据,将其标记为缺失值。

3)缺失数据分级填补:针对数据缺失问题,采用分级填补策略以保证序列连续性。短时缺失(连续缺失点数 ≤ 4 ,即1 h以内),鉴于风电功率具有短时惯性,采用拉格朗日插值法进行补全;长时缺失(连续缺失点数 > 4),由于长时间跨度下单一插值误差较大,利用此时段内该场站的NWP风速数据,结合临近时刻的风速-功率转换关系进行拟合填补。

4)数据归一化:功率数据按装机容量归一化至 $[0, 1]$;NWP风速数据进行Z分数线标准化。

此预处理流程确保了输入数据的质量与一致性,为后续分析奠定了可靠基础。

本文采用归一化均方根误差 R_{RMSE} 、归一化平均绝对误差和 R_{MAE} 和决定系数 R^2 对所提风电功率预测方法的预测性能进行评估。为保障结果的稳健性,所有指标均为30次独立实验的均值。

$$R_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_{Mi} - P_{Pi})^2} \quad (19)$$

$$R_{MAE} = \frac{1}{NP_{Cap}} \sum_{i=1}^N |P_{Mi} - P_{Pi}| \quad (20)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (P_{Mi} - P_{Pi})^2}{\sum_{i=1}^N (P_{Mi} - \bar{P}_{Mi})^2} \quad (21)$$

式中: P_{Cap} 为装机容量; P_{Mi} 为每一时刻的实际发电量; P_{Pi} 为每一时刻的预测发电量; $\bar{P}_{Mi}$ 为实际发电量的平均值; N 为测试样本数。

5.2 风电集群的划分

为确定聚类的最佳簇数,使用时空图谱聚类算法对吉林省风电集群进行聚类,并计算每次聚类结果轮廓系数,如图6所示。

轮廓系数随着聚类数量的增加呈现出先增大后减小的趋势。当聚类数量为3时,轮廓系数达到最大值。因此,聚类数量选择3是最合理的。采用时空图谱聚类划分结果如图7所示。




图6 轮廓系数

Fig. 6 Contour coefficient




图7 集群划分结果

Fig. 7 Results of cluster division

将3个风电集群内部的风电场进行相邻排列,绘制聚类后风电集群的皮尔逊相关系数热力图,如图8所示。

不难看出,对大规模风电集群进行子群划分后,属于同一子群的风电场,其风速之间的皮尔逊相关系数普遍较高,表明它们之间存在显著的相关性。这验证了本文划分方法能够将风速特性相似、关联紧密的风电场聚集到相同的子集群中。

为验证时空图谱聚类在时空特征建模上的优越性,将其与3种经典聚类算法(K -means^[14]、FCM^[15]、DBSCAN^[16])在统一预测框架(STL-T2Dformer)下进行对比。实验固定特征分解与预测模块,仅替换聚类方法,以隔离评估聚类性能差异。

评估指标包括归一化均方根误差 R_{RMSE} 、归一化平均绝对误差 R_{MAE} 和轮廓系数,同时记录各算法达到最优时的聚类数。预测结果如表2和图9所示。

对比结果显示,相较于传统聚类算法,本文的时空图谱聚类方法能获得更高的轮廓系数,意味着其聚类结果内聚性更强,更重要的是在统一预测框架




图 8 聚类后风电集群的皮尔逊相关系数热力图

Fig. 8 Heat map of Pearson correlation coefficient of wind power cluster after clustering

表 2 不同聚类算法的性能对比
Table 2 Performance comparison among different clustering algorithms

聚类算法	最佳聚类数	R_{RMSE}	R_{MAE}	轮廓系数
时空图谱聚类	3	0.074 3	0.054 4	0.752 5
K-means 聚类	3	0.077 4	0.055 6	0.634 4
FCM 聚类	2	0.076 3	0.056 3	0.613 5
DBSCN 聚类	4	0.079 8	0.057 8	0.643 1




图 9 时空图谱聚类与其他聚类方法预测结果对比

Fig. 9 Comparison of the prediction results of ST-SpecCluster and other clustering methods

下实现了 R_{RMSE} 和 R_{MAE} 最小,这证明其划分出的子集群更能反映风电场群真实的时空相关性,为后续的精准确预测奠定了坚实基础。

5.3 季节分解

利用 STL 分解风电功率,结果如图 10 所示。风电功率的趋势、周期和随机分量分别揭示了其长期走向、周期性规律和内在不确定性。这种分解方式为深度学习模型提供了更优的特征表征。




图 10 季节分解图

Fig. 10 STL decomposition diagram

5.4 模型性能比较

为了验证本文所提模型的优越性,选取 TimesNet^[34]、Informer^[35]、EEMD-Transformer^[25]、ST-GCN、长短期记忆网络 (long short-term memory,

LSTM)、变分模态分解-卷积神经网络-门控循环单元-注意力机制模型(variational mode decomposition-convolutional neural network-gated recurrent unit-attention, VMD-CNN-GRU-Attention)^[36]以及变分模态分解-时空图卷积网络-Transformer 模型(variational mode devolution-spatio-temporal graph convolutional network-Transformer, VMD-STAGCN-Transformer^[28])7类前沿预测模型进行系统对比。表 3 给出了不同方法预测结果的评价指标。

表 3 不同模型的性能对比

Table 3 Performance comparison of different models

预测模型	R_{RMSE}	R_{MAE}	R^2
本文方法	0.074 3	0.054 4	0.921 3
TimesNet	0.082 2	0.065 4	0.887 5
Informer	0.079 3	0.060 7	0.891 3
VMD-CNN-GRU-Attention	0.077 5	0.058 8	0.902 5
EEMD-Transformer	0.078 2	0.059 4	0.864 8
VMD-STAGCN-Transformer	0.076 8	0.057 3	0.911 2
ST-GCN	0.093 2	0.083 1	0.812 6
LSTM	0.090 3	0.074 2	0.825 4

本文方法在所有评价指标上均优于对比模型,具体而言,本文方法的 R_{RMSE} 和 R_{MAE} 分别低至0.074 3和0.054 4,而 R^2 高达0.921 3。相较于表现次优的VMD-STAGCN-Transformer,本文方法的 R_{RMSE} 降低了0.002 5, R^2 提升了0.010 1。

相较于VMD-CNN-GRU-Attention和ST-GCN,本文方法优势显著。ST-GCN的 R^2 仅为0.812 6,而本文方法将其提升至0.921 3,VMD-CNN-GRU-Attention的 R_{RMSE} 落后本文方法0.003 2。Informer、TimesNet和LSTM的 R^2 在0.825 4~0.891 3之间, R_{RMSE} 均在0.079以上。表明此类模型在处理风电功率的高频非平稳波动时,拟合能力存在瓶颈。本文方法通过多尺度特征融合,有效解决了这一问题,将 R_{RMSE} 降低了8%~10%。

本文模型与其他模型的预测结果对比如图 11 所示。本文所提方法的预测值更接近真实值,真实功率的波动趋势大体相同。尤其在功率陡升与陡降阶段,有效捕捉了瞬态特征,显著降低了峰值与谷值的滞后偏差。

为验证本文所提方法的实用性,使用配置中央处理器型号为 Inter-Core i9-10900K 的计算机对上述模型进行仿真验证。经过 30 次的仿真计算,得到了各个模型的平均训练时间和平均运行时间。预测模型的平均训练时间和平均运行时间如附录 A 表 A1 所




图 11 本文模型与其他模型的预测结果对比

Fig. 11 Comparison of prediction results among proposed model and other models

示。模型超参数设置如附录表 A2 所示。

5.5 消融实验

为验证本文所提预测方法中各模块的协同作用,本文构建 3 个消融模型进行对比实验:

- 模型 1:T2Dformer;
- 模型 2:STL-T2Dformer;
- 模型 3:时空图谱聚类-T2Dformer。

所得结果如图 12 和表 4 所示,可以明显看出本文所提预测方法显著提高了风电预测性能,说明了各模块协同优化对于提升预测精度的关键作用。




图 12 本文模型与其他消融模型的预测结果对比

Fig. 12 Prediction results comparison of the model proposed in this paper with those of other ablation models

表 4 消融实验不同模型的性能对比

Table 4 Performance comparison of different models in the ablation experiment

预测模型	R_{RMSE}	R_{MAE}	R^2
本文方法	0.074 3	0.054 4	0.921 3
模型 1	0.078 1	0.058 3	0.891 5
模型 2	0.077 3	0.056 1	0.902 2
模型 3	0.076 4	0.056 4	0.910 3

模型 3 相较于基准模型 1, R_{RMSE} 降低了0.001 7, R^2 提升了0.018 8,证明了所提时空图谱聚类能够有效捕捉复杂的集群时空特征,从而提升了模型对全局时空结构的理解能力。

模型 2 与模型 1 相比, R_{MAE} 降低了0.002 2, R^2 提升了0.010 7,表明 STL 分解技术通过捕获更深层次

的趋势和周期性变化,使其能够更聚焦于对残余分量的建模,从而在预测上带来了实质性的准确率提升。

6 结 论

1)所提时空图谱聚类算法构建了能够同时表征静态地理邻近性与动态运行关联性的混合时空图。通过时空图卷积网络提取深度时空特征并结合谱聚类实现子集群划分,提高了风电集群划分的准确性与对时空特征的捕捉,为后续分区预测奠定基础。在预测阶段,结合STL分解与T2Dformer模型的多尺度建模策略,实现了对多尺度分量的高效联合建模与精准预测。实验结果显示本文方法的 R_{RMSE} 、 R_{MAE} 和 R^2 分别为0.074 3、0.054 4、0.921 3,优于前沿对比模型,对于区域保证供电能力的贡献更大。

2)本文所提方法为大型风电集群提供了一种高精度的预测解决方案,为电力系统调度决策提供了可靠支撑。时空图谱聚类模块为电力系统分区调度提供了更加合理的理论依据。

3)本文研究仍存在一些待完善之处,模型复杂度较高,可能影响其在实时性要求极严苛场景中的应用效果,且方法性能对数值天气预报数据质量具有一定依赖性。未来工作将聚焦于模型轻量化设计及在数据缺失条件下的鲁棒性提升。

利益冲突声明(Conflict of Interests):

所有作者声明不存在利益冲突。

作者贡献声明(Authors' Contributions):

杨茂提出研究方向,设计论文框架;王钊设计研究思路,设计研究方案,对研究方案进行可行性分析;朱嘉宁进行实验并进行对比分析,进行文献调研与整理;江任贤确定研究对象范围,采集、清洗与分析数据;李奕陶参与论文修订、论文最终版本修订。所有作者均阅读并同意了论文终稿内容。

7 参考文献

- [1] Global Wind Energy Council (GWEC). Global wind report 2025 [R]. Brussels: GWEC, 2025.
- [2] 朱继忠, 高美云, 肖鹏飞, 等. 大规模海上风电并网与运行技术综述[J]. 电力工程技术, 2025, 44(5): 2-24.
ZHU Jizhong, GAO Meiyun, XIAO Pengfei, et al. Review of grid integration and operation technologies for large-scale offshore wind power[J]. Electric Power Engineering Technology, 2025, 44(5): 2-24.
- [3] 王峰, 姜通海, 高宇, 等. 考虑多元气象特征动态聚类的短期风电功率预测[J]. 电网与清洁能源, 2025, 41(9): 125-131.
WANG Feng, JIANG Tonghai, GAO Yu, et al. Short-term wind power prediction considering dynamic clustering of multiple meteorological features[J]. Power System and Clean Energy, 2025, 41(9): 125-131.
- [4] 司雅昕, 刘训强, 苏向敬, 等. 海上风电功率预测研究综述[J]. 浙江电力, 2025, 44(11): 59-71.
SI Yaxin, LIU Xunqiang, SU Xiangjing, et al. A review of offshore wind power forecasting studies[J]. Zhejiang Electric Power, 2025, 44(11): 59-71.
- [5] YANG M, JIANG R X, WANG B, et al. Multi-channel attention mechanism graph convolutional network considering cumulative effect and temporal causality for day-ahead wind power prediction[J]. Energy, 2025, 332: 137023.
- [6] 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 Yi, HU Hua, WEI Yunbing. Short-term wind power forecasting based on VMD-IBWO-BiLSTM[J]. Power System and Clean Energy, 2025, 41(5): 148-158.
- [7] 陈文进, 王小仲, 张思, 等. 考虑功率-误差相关性的风电功率概率预测模型[J]. 浙江电力, 2025, 44(7): 55-63.
CHEN Wenjin, WANG Xiaozhong, ZHANG Si, et al. A probabilistic wind power forecasting model considering power error correlation[J]. Zhejiang Electric Power, 2025, 44(7): 55-63.
- [8] 付振宇, 王文胤, 凌小明, 等. 基于长短期记忆及自适应Kriging子集模拟优化的风电功率预测方法[J]. 电网与清洁能源, 2024, 40(11): 147-154.
FU Zhenyu, WANG Wenyin, LING Xiaoming, et al. A wind power prediction method based on long short-term memory and adaptive Kriging-subset simulation optimization[J]. Power System and Clean Energy, 2024, 40(11): 147-154.
- [9] 王小明, 徐斌, 尹元亚, 等. 基于空间相关性与Stacking集成学习的风电功率预测方法[J]. 电力工程技术, 2024, 43(5): 224-232.
WANG Xiaoming, XU Bin, YIN Yuanya, et al. Wind power prediction method based on spatial correlation and Stacking ensemble learning[J]. Electric Power Engineering Technology, 2024, 43(5): 224-232.
- [10] ZHANG J A, LIU D, LI Z J, et al. Power prediction of a wind farm cluster based on spatiotemporal correlations[J]. Applied Energy, 2021, 302: 117568.
- [11] PENG X S, WANG H Y, LANG J X, et al. EALSTM-QR: interval wind-power prediction model based on numerical weather prediction and deep learning[J]. Energy, 2021, 220: 119692.
- [12] HENZE J, SIEFERT M, BREMICKER-TRÜBELHORN S, et al. Probabilistic upscaling and aggregation of wind power forecasts[J]. Energy, Sustainability and Society, 2020, 10: 15.
- [13] YANG M, HAN C, ZHANG W, et al. A short-term power prediction method for wind farm cluster based on the fusion of multi-source spatiotemporal feature information[J]. Energy, 2024, 294: 130770.
- [14] YU C S. A comprehensive wind power prediction system based on correct multiscale clustering ensemble, similarity matching, and improved whale optimization algorithm; a case study in China[J]. Renewable Energy, 2025, 243: 122529.

- [15] 牛甲俊, 张薇, 许达明. 基于FCM和ITransformer-TCN的短期风电集群功率预测[J]. 东北电力大学学报, 2024, 44(1): 9-16.
NIU Jiajun, ZHANG Wei, XU Daming. Short-term power prediction of wind power cluster based on FCM and ITransformer-TCN[J]. Journal of Northeast Electric Power University, 2024, 44(1): 9-16.
- [16] HOU G L, WANG J J, FAN Y Z. Wind power forecasting method of large-scale wind turbine clusters based on DBSCAN clustering and an enhanced hunter-prey optimization algorithm [J]. Energy Conversion and Management, 2024, 307: 118341.
- [17] YANG M, GUO Y F, HUANG T, et al. Wind farm cluster power prediction based on graph deviation attention network with learnable graph structure and dynamic error correction during load peak and valley periods[J]. Energy, 2024, 312: 133645.
- [18] YU G Z, LIU C Q, TANG B, et al. Short term wind power prediction for regional wind farms based on spatial-temporal characteristic distribution [J]. Renewable Energy, 2022, 199: 599-612.
- [19] YANG M, WANG D, ZHANG W, et al. A centralized power prediction method for large-scale wind power clusters based on dynamic graph neural network[J]. Energy, 2024, 310: 133210.
- [20] 乔宽龙, 董存, 车建峰, 等. 时空特性下基于图卷积神经网络的风电集群功率短期预测方法[J]. 太阳能学报, 2024, 45(5): 95-103.
QIAO Kuanlong, DONG Cun, CHE Jianfeng, et al. Short-term prediction method of wind power clusters based on graph convolution neural network under spatio-temporal characteristics [J]. Acta Energiae Solaris Sinica, 2024, 45(5): 95-103.
- [21] ABDELKADER A G, ZAINELDIN H, SAAFAN M M. Optimizing wind power forecasting with RNN-LSTM models through grid search cross-validation [J]. Sustainable Computing: Informatics and Systems, 2025, 45: 101054.
- [22] 张哲, 王勃. 基于CBAM-LSTM的风电集群功率短期预测方法[J]. 东北电力大学学报, 2024, 44(1): 1-8.
ZHANG Zhe, WANG Bo. Short-term power prediction method of wind power cluster based on CBAM-LSTM[J]. Journal of Northeast Dianli University (Natural Science Edition), 2024, 44(1): 1-8.
- [23] HONG J T, HAN S, YAN J, et al. Dual-path frequency Mamba-Transformer model for wind power forecasting[J]. Energy, 2025, 332: 137225.
- [24] BENTSEN L Ø, WARAKAGODA N D, STENBRO R, et al. Spatio-temporal wind speed forecasting using graph networks and novel tTransformer architectures[J]. Applied Energy, 2023, 333: 120565.
- [25] WU H J, MENG K, FAN D, et al. Multistep short-term wind speed forecasting using transformer [J]. Energy, 2022, 261: 125231.
- [26] LI J L, SONG Z H, WANG X F, et al. A novel offshore wind farm typhoon wind speed prediction model based on PSO-bi-LSTM improved by VMD[J]. Energy, 2022, 251: 123848.
- [27] YAN L M, WU S Q, LI S P, et al. SEAformer: frequency domain decomposition transformer with signal enhanced for long-term wind power forecasting[J]. Neural Computing and Applications, 2024, 36(33): 20883-20906.
- [28] 杨绍祖, 王海程, 吴金雅, 等. 基于STAGCN-Informer时空组合模型的风电功率预测方法[J]. 计算机与现代化, 2024(7): 13-20.
YANG Shaozu, WANG Haicheng, WU Jinya, et al. Wind power prediction method based on STAGCN-Informer spatiotemporal fusion model[J]. Computer and Modernization, 2024(7): 13-20.
- [29] LIU H Z, HUANG J T, HU J Q, et al. Enhancing wind power prediction accuracy: a novel method integrating seasonal temporal factors and advanced spatio-temporal feature extraction [J]. Energy, 2025, 336: 138514.
- [30] LI P S, ZHU Z D. STGCN-WQ: a new Spatio-temporal graph convolutional network for predicting beach water quality [J]. Environmental Modelling & Software, 2026, 195: 106731.
- [31] YU Y, GUO Y X, LV T Y, et al. Incremental cost-consistent partitioning and power allocation strategy for wind-storage clusters in wind power fluctuation mitigation [J]. Electric Power Systems Research, 2025, 248: 111958.
- [32] WANG J Z, KOU M G, LI R Z, et al. Ultra-short-term wind power forecasting jointly driven by anomaly detection, clustering and graph convolutional recurrent neural networks [J]. Advanced Engineering Informatics, 2025, 65: 103137.
- [33] CLEVELAND R B, CLEVELAND W S. STL: A seasonal-trend decomposition procedure based on Loess [J]. Journal of Official Statistics, 1990, 6(1).
- [34] WU Haixu, HU Tingsong, LIU Jie, et al. TimesNet: temporal 2D-variation modeling for general time series analysis [C]// International Conference on Learning Representations (ICLR). Kigali, Rwanda, 2023: 1-15.
- [35] CHEN W, ZHOU G B. An interpretable prediction model for global horizontal irradiance based on improved-Informer [J]. Measurement, 2026, 258: 119449.
- [36] REN D F, MA J Q, LIU H, et al. The IVMD-CNN-GRU-attention model for wind power prediction with sample entropy fusion [J]. IEEE Access, 2024, 12: 169988-170000.



朱嘉宁

收稿日期: 2025-11-05 修回日期:

2025-12-31

作者简介:

朱嘉宁(2002),男,硕士研究生,主要研究方向为风电功率预测,E-mail:2642348837@qq.com;

王钊(1988),男,博士,高级工程师,研究生导师,主要研究方向为新能源功率预测;

李奕陶(1984),女,硕士,高级经济师,主要研究方向为变频器功率开关总成测试,风机可利用率;

杨茂(1982),男,博士,教授,通信作者,主要研究方向为新能源功率预测、微网及综合能源系统优化调度,E-mail:yangmao820@163.com;

江任贤(2000),男,博士研究生,主要研究方向为极端天气分析。

(编辑 景贺峰)

附录 A

表 A1 不同模型的平均训练时间和运行时间
Table A1 Average training and runtime for different models

预测模型	训练时间/min	运行时间/s
本文方法	30.148	4.314
TimesNet	16.853	1.678
informer	14.379	1.389
VMD-CNN-GRU-Attention	26.128	3.348
EEMD-Transformer	19.637	1.864
VMD-STAGCN-Transformer	28.765	3.571
ST-GCN	18.624	1.579
LSTM	9.542	0.763

表 A2 关键模型参数设置
Table A2 Key model parameter setting

模块	参数	参数值/设置
ST-SpecCluster	切比雪夫阶数 K	3
	滑动时间窗口/个	96 (24 h)
	谱聚类特征数	3
STL分解	周期分量长度	96
	趋势分量平滑窗口	29
T2Dformer	学习率	0.000 1
	批次大小	32
	编码器层数	3
	注意力头数	4
	隐藏层维度	128
	Inception 卷积核	[1, 3, 5]