

基于风场空间与气象融合的风电集群短期功率预测

魏臻珠¹, 刘明宇¹, 王昱龙¹, 周 燕², 蒋建东¹

(1. 郑州大学 电气与信息工程学院, 河南 郑州 450001; 2. 国网河南省电力公司洛阳供电公司, 河南 洛阳 471000)

摘要: 针对传统风电集群功率预测方法在空间上未有效考虑场站间气象关联特性, 难以基于单场预测高效推演集群整体功率的问题, 为充分挖掘离散型数值气象预报(NWP)异构气象信息的时空耦合复杂特性嵌入表征, 提出一种基于注意力时空嵌入机制的多维度场站时空信息融合框架。首先, 利用多头自注意力机制(Multi-Head Self-Attention)直接融合空间特征, 增强模型对多场站空间功率关联的捕捉能力。其次, 基于最大信息系数解构集群位置信息, 构建反映气象关联的非欧几里得图数据结构, 并结合时空注意力机制实现场站及其邻域时空特征的交叉融合, 动态调整场站间影响权重以捕捉时空动态相关性。并通过编-解码器架构将空间与时空特征集成至统一语义空间, 捕获序列时间连续性。最后, 基于中国西北某地区实际风电场运行数据对所提模型进行验证。实验结果表明: 所提方法在对比其余6种预测模型时, RMSE与MAE两项误差评价指标均显著降低, 有效验证其先进性与适应性。

关键词: 风电集群功率预测; 时空图卷积神经网络; 多头自注意力机制; 图数据结构; 深度学习

中图分类号: TM614; TP183

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2026.02.005

面对日益严峻的全球气候变化和能源短缺问题, 中国积极推动清洁能源发展, 致力于实现碳达峰和碳中和目标。截至2024年6月底, 中国风电和光伏发电装机容量已超过煤电, 突破11.8亿kW。风电作为清洁能源的重要组成部分, 其发展尤为迅猛。截至2023年底, 中国风电装机容量达到4.4亿kW, 同比增长20.7%, 成为全球最大的风电市场^[1]。然而, 由于风资源的波动性和不确定性, 大规模风电并网给电网的稳定运行带来严峻挑战^[2]。

风电集群短期功率的精确预测可以为电力调度提供科学依据, 有效缓解风电波动对电网的冲击, 提高风电利用效率, 并进一步解决大规模风电消纳问题。近年来, 单个风电场的功率预测研究成果显著, 但集群风电功率预测多是把单个场站的预测结果简单相加, 或是进行尺度扩展^[3-4]。这类方法虽计算方便, 却没充分考虑风电集群内部复杂的时空关联, 预测精度因此受限。从时间角度看, 现有方法把连

续的天气过程拆分成独立的时间节点, 打破了气象要素的时序联系, 使得气象条件和功率输出在时间上不匹配; 从空间角度讲, 区域气象变化既有空间关联性, 又有局部差异, 单个站点的气象参数没法反映空间上的不同特征, 进而导致功率预测结果出现异常波动。在人工智能技术快速发展背景下, 集成学习与深度学习模型已成为研究热点。集成学习方法通过融合多模型优势提升预测性能, 朱梓彬等^[5]基于多元变分模态分解(multivariate variational mode decomposition, MVMD)和Blending集成学习, 提高模型稳定性与精度; 吴霓^[6]使用Stacking集成框架整合多个基模型, 实现了多算法协同预测; 向阳^[7]利用CNN-门控循环单元-梯度提升学习算法, 构建的CNN-GRU-LightGBM混合模型兼具特征提取与回归分析能力; 李超峰等^[8]采用马尔可夫链对结果进行误差修正, 使用Informer神经网络架构对风电场功率做出预测, 降低了模型复杂度。现有研究多聚焦

收稿日期: 2026-01-26; 修订日期: 2026-03-29

基金项目: 河南省高等学校重点科研项目(24A470009)

作者简介: 魏臻珠(1977—), 女, 青海西宁人, 郑州大学讲师, 主要从事电力系统电能质量分析与控制研究, E-mail: jdjiang@zzu.edu.cn。

通信作者: 蒋建东(1975—), 男, 河南南阳人, 郑州大学教授, 博士, 主要从事电力系统电能质量分析与控制、新能源技术等研究, E-mail: zzwei@zzu.edu.cn。

于风电功率的时间序列依赖建模,而对风电场之间潜在的空间耦合关系关注不足。针对这一问题,部分学者进行了有益探索。顾婷婷等^[9]提出一种融合多头注意力机制的 ResNet-UNet 混合模型,借助 UNet 结构保留多维气象变量的空间分布信息,从而增强了对风电场间空间相关性的刻画能力;周丽娜等^[10]则结合大气流动的连续性特征,构建 CNN-LSTM 联合架构,挖掘风电出力的时空动态特征,有效提升了集群层面的预测效果。然而,上述方法大多将数值气象预报(NWP)数据简单映射为规则栅格,难以体现风电场在实际地理空间中分布的非均质性。对此,CHEN 等^[11]尝试采用图卷积网络(graph convolutional network, GCN)建模风机间的拓扑关系,但其采用的 MLP (multilayers perception) 结构对时序特征的表达能力有限。

基于上述模型的优缺点,本文以深入挖掘离散型 NWP 异构气象信息嵌入表征为基础,以注意力时空嵌入机制为手段,对场站时空信息进行多维度融合,提出一种融合时间特征的嵌入交叉注意力机制时空图卷积网络(fusion temporal spatial-temporal graph convolutional network embedded with cross-attention mechanism, FT-ASTGCN)的风电集群功率短期预测模型。

1 图结构定义

本文采用的离散型数值天气预报数据(NWP)时间分辨率为 15 min、空间分辨率为 3 km×3 km。当前用于构建图结构数据的方法有基于因果关系的图构建算法,如 Granger 因果关系^[12]、 k 最近邻^[13]等算法,但这些方法往往需要严格的假设条件且对数据的分布形式敏感,导致聚类或关联的准确性降低。因此,为研究多尺度天气系统的不同特性,本文借助数据挖掘来提取与气象过程密切相关的场站集群特征,选用最大信息系数^[14]来构建图结构数据,这种方法能更有效捕捉和量化非线性关系,提供更全面的时空关联分析。

最大信息系数的计算基于互信息,互信息的公式为

$$I[X;Y] = H(X) - H(X|Y)。 \quad (1)$$

其中, $I[X;Y]$ 表示场站 X 与 Y 之间的互信息。 $H(X)$ 表示随机变量 X 的熵,定义为

$$H(X) = - \sum_{x \in X} p(x) \log_2 p(x)。 \quad (2)$$

$H(X|Y)$ 表示 X 在 Y 条件下的条件熵,定义为

$$H(X|Y) = - \sum_{x \in X} \sum_{y \in Y} p(x,y) \log_2 p(x|y)。 \quad (3)$$

$p(x|y)$ 表示给定 Y 的情况下 X 的条件概率,计算公式为

$$p(x|y) = \frac{p(x,y)}{p(y)}。 \quad (4)$$

式中: $p(x|y)$ 表示场站 X 和 Y 的联合概率分布; $p(x)$ 表示场站 X 的边际概率分布; $p(y)$ 表示场站 Y 的边际概率分布。

MIC 通过对各场站功率进行离散化处理,并将其映射到一个二维网格中,从而实现对互信息的量化。其取值范围在 0~1,值越接近 1 表示两者之间的关系越强。MIC 系数可定义为

$$\text{MIC}(X;Y) = \max_{a,b < B} \frac{I(X;Y)}{\log_2 \min(a,b)}。 \quad (5)$$

式中: a 和 b 分别为变量 X 和 Y 在网格中划分的数量,代表了对变量取值的离散化程度; B 为样本总数的 0.6 次方。

本文通过计算风电集群内各场站历史功率的最大信息系数确定邻接矩阵 A 如下:

$$A = \begin{bmatrix} 1 & E_{12} & \cdots & E_{1N} \\ E_{21} & 1 & \cdots & E_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ E_{N1} & E_{N2} & \cdots & 1 \end{bmatrix}。 \quad (6)$$

式中: $A \in R^{N \times N}$ 是一个对称矩阵; E 表示边集合 $E = \{E_{ij} | i \neq j\}$; N 表示集群内的场站个数。

由此,可定义风电集群原始气象信息构成的气象网络 G :

$$G = (V, E)。 \quad (7)$$

式中: $V = \{v_1, v_2, \dots, v_N\} \in R^{F \times N}$ 表示风电集群各场站对应的节点特征。

2 注意力嵌入机制研究

由于气象过程和地理环境的复杂性和多样性,仅依靠最大信息系数表达的空间信息,对于描述风在空间上的连续性和波动性是远远不够的。融合嵌入注意力机制^[15],能够根据时空特征的变化自动调整不同风电场的影响权重,从而实现对风场波动性更准确的建模。

2.1 空间注意力机制

在空间维度上,为捕捉气象信息在场站位置上的空间动态特征,利用场站位置特征的注意力得分机制,可定义空间注意力嵌入矩阵 S 的计算公式如下:

$$S = V_s \cdot \sigma((X_T^{i-1} W_1) W_2 (W_3 X_T^{i-1})^T + b_s)。 \quad (8)$$

式中: $X_T^{i-1} = (V_1^{i-1}, V_2^{i-1}, \dots, V_t^{i-1}) \in R^{N \times F_{i-1} \times t}$ 表示计

算第 i 层时空注意力矩阵的输入,即 t 时间步下的场站集群特征; $\mathbf{W}_1 \in R^t, \mathbf{W}_2 \in R^{F_{i-1} \times t}, \mathbf{W}_3 \in R^{F_{i-1}}, \mathbf{V}_s \in R^{N \times N}, \mathbf{b}_s \in R^{N \times N}$ 分别表示不同特征维度下的可学习参数矩阵; σ 表示 Sigmoid 激活函数。

通过学习不同场站位置的时间特征与气象特征,并将其映射至非线性空间融合提升其表征能力,动态计算注意力矩阵 \mathbf{S} 。利用 Softmax 函数对节点的注意力权重进行归一化:

$$\mathbf{S}'_{i,j} = \frac{\exp(S_{i,j})}{\sum_{j=1}^N \exp(S_{i,j})} \quad (9)$$

式中: $\mathbf{S}'_{i,j} \in R^{N \times N}$ 表示场站 i 与场站 j 之间的注意力分数; $S_{i,j}$ 表示原始的注意力得分。在执行空间图卷积操作时,通过结合邻接矩阵 \mathbf{A} 与空间注意力矩阵 $\mathbf{S}'_{i,j}$,可以动态地调节场站之间的影响权重。

2.2 时间注意力机制

在时间维度上,为捕捉气象信息在时间序列上的动态特征,类似地,利用时间序列特征的注意力得分机制,可定义时间注意力嵌入矩阵 \mathbf{I} 的计算公式如下:

$$\mathbf{I} = \mathbf{V}_e \cdot \sigma((\mathbf{X}_T^{i-1})^T \mathbf{U}_1) \mathbf{U}_2 (\mathbf{U}_3 \mathbf{X}_T^{i-1}) + \mathbf{b}_e \quad (10)$$

式中: $\mathbf{U}_1 \in R^N, \mathbf{U}_2 \in R^{F_{i-1} \times N}, \mathbf{U}_3 \in R^{F_{i-1}}, \mathbf{V}_e \in R^{t \times t}, \mathbf{b}_e \in R^{t \times t}$ 分别表示不同特征维度下的可学习参数矩阵。利用 Softmax 函数对时间序列的注意力权重进行归一化,使得每个节点的权重之和为 1。

$$\mathbf{I}'_{i,j} = \frac{\exp(I_{i,j})}{\sum_{j=1}^t \exp(I_{i,j})} \quad (11)$$

式中: $\mathbf{I}'_{i,j} \in R^{t \times t}$ 表示时刻 i 与时刻 j 之间的依赖性的强度,即注意力分数; $I_{i,j}$ 表示原始的注意力得分。基于 $i-1$ 层输入的 \mathbf{X}_T^{i-1} 场站集群特征,将时间注意力矩阵 $\mathbf{I}'_{i,j}$ 嵌入,可得

$$\widetilde{\mathbf{X}}_T^{i-1} = \mathbf{X}_T^{i-1} \mathbf{I}' = \mathbf{X}_T^{i-1} \begin{bmatrix} \mathbf{I}'_{1,1} & \mathbf{I}'_{1,2} & \cdots & \mathbf{I}'_{1,t} \\ \mathbf{I}'_{2,1} & \mathbf{I}'_{2,2} & \cdots & \mathbf{I}'_{2,t} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{I}'_{i,1} & \mathbf{I}'_{i,2} & \cdots & \mathbf{I}'_{i,t} \end{bmatrix} \quad (12)$$

式中: $\widetilde{\mathbf{X}}_T^{i-1} \in R^{N \times F_{i-1} \times t}$ 表示融合序列特征后的新的输入。通过这种方式,动态调整输入数据,实现对时间注意力的嵌入表征。

2.3 多头自注意力机制

自注意力机制(self-attention mechanism)是近年来深度学习中广泛应用的一种技术。自注意力机制通过多通道提取时空特征,并通过动态分配注意力权重,强化关键历史信息的权重,从而提供更全面的

时空关联特征。具体计算公式为

$$\mathbf{A}_{ij} = \text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right) \mathbf{V} \quad (13)$$

式中: $\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V})$ 表示经过得分计算后的输出; \mathbf{A}_{ij} 表示输入序列中的第 i 个元素对第 j 个元素的注意力权重,其取值在 $0 \sim 1$; $\sqrt{d_k}$ 表示缩放因子,用于避免值过大带来的数值不稳定性问题; $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别表示查询(query)、键(key)和值(value)矩阵,计算公式为

$$\begin{cases} \mathbf{Q} = \mathbf{X}_T \mathbf{W}_Q; \\ \mathbf{K} = \mathbf{X}_T \mathbf{W}_K; \\ \mathbf{V} = \mathbf{X}_T \mathbf{W}_V. \end{cases} \quad (14)$$

式中: $\mathbf{X}_T = (X_1, X_2, \dots, X_t), X_i \in R^d$ 表示一组给定的输入序列; $\mathbf{W}_Q, \mathbf{W}_K, \mathbf{W}_V \in R^{d \times d_k}$ 是可学习的权重矩阵。

为了进一步提升模型的表达能力,通常在实际应用中使用时多头机制(multi-head)。多头机制通过引入多个独立的注意力头来捕捉不同的相关性模式,每个头对应一个独立的查询、键和值计算过程,其公式为

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = [\text{head}_1, \text{head}_2, \dots, \text{head}_n] \mathbf{W}^O \quad (15)$$

其中,每个注意力头 head_i 通过独立的自注意力机制计算:

$$\text{head}_i = \text{Attention}(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i) \quad (16)$$

最终,通过拼接多个头的结果,并通过一个线性变换矩阵 $\mathbf{W}^O \in R^{nd_k \times d}$ 进行映射。

3 短期预测模型研究

3.1 空间卷积

谱图理论将卷积操作从网格数据扩展到图结构数据中^[16]。为充分利用场站位置的拓扑性质,在每个时间切片采用基于谱图理论的图卷积来直接处理,从而在空间维度上挖掘场站位置中的空间信息。

谱图方法依赖于图的拉普拉斯矩阵(Laplacian Matrix),对于图 \mathbf{G} ,其拉普拉斯矩阵 \mathbf{L} 通常表示为 $\mathbf{L} = \mathbf{D} - \mathbf{A}$,其中 \mathbf{A} 为图的邻接矩阵, \mathbf{D} 为度矩阵。为了方便归一化操作,广泛采用的是归一化拉普拉斯矩阵形式:

$$\mathbf{L}_{\text{norm}} = \mathbf{I}_N - \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \in R^{N \times N} \quad (17)$$

式中: \mathbf{L}_{norm} 表示归一化后的拉普拉斯矩阵; \mathbf{I}_N 表示单位矩阵。通过对拉普拉斯矩阵进行特征值分解,

可以得到 $L = UAU^T$, 其中, A 为对角矩阵, 其对角元素为拉普拉斯矩阵的特征值, 矩阵 U 为特征向量矩阵, 亦称为傅里叶基。

因此, 图卷积可以视作一种在傅里叶域中对信号进行处理的操作。对卷积核 $g_\theta(A)$ 简化后, 将每个切比雪夫多项式项 $T_k(\tilde{L})$ 与空间注意力嵌入矩阵 $S \in R^{N \times N}$ 结合, 动态捕捉图卷积中节点间的关联性。相应地, 图卷积操作的公式更新为

$$g_\theta *_{\mathcal{C}} x = U g_\theta(A) U^T x = \sum_{k=0}^{K-1} \theta_k (T_k(\tilde{L}) \odot S) x_0. \quad (18)$$

式中: $*_{\mathcal{C}}$ 表示图卷积操作, \odot 表示 Hadamard 积; k 表示阶数。由此, 场站特征的提取不仅基于切比雪夫多项式项 $T_k(\tilde{L})$, 还通过空间注意力矩阵 S 的作用动态调整节点关联性。

此定义可以进一步推广到具有多个通道的图信号, 以增强对多维特征的学习。对于每个时间片 t 上的图信号 \tilde{X}_T^{i-1} , 每个节点具有 F_{i-1} 个通道的特征, 采用 F_i 个滤波器来卷积特征, 得到

$$g_\theta *_{\mathcal{C}} \tilde{X}_T^{i-1}. \quad (19)$$

式中: $\theta = (\theta_1, \theta_2, \dots, \theta_F) \in R^{K \times F_{i-1} \times F_i}$ 表示卷积核参数。由此, 每个节点将依据其 0 至 $K-1$ 阶邻居中的信息进行更新, 实现多通道邻域信息的动态聚合。

3.2 时间卷积

为更精确地捕捉多层次化的特征支持, 本研究引入沿时间轴的二维卷积操作, 提取时序信息中的

局部特征, 并结合 Padding 操作保持时间长度, 公式如下:

$$X_T^i = \text{ReLU}(W^* (\text{ReLU}(g_\theta *_{\mathcal{C}} \tilde{X}_T^{i-1}))). \quad (20)$$

式中: $X_T^i \in R^{N \times F_i \times t}$ 表示第 $i-1$ 层的输出; W 表示时间卷积核参数。

图 1 为采用时空嵌入注意力机制的卷积示意图。




图 1 时空嵌入注意力卷积示意图

Figure 1 Schematic diagram of spatio-temporal embedding attention convolution

3.3 风电集群功率预测模型

为适应输出位置敏感的多风电场时序功率数据, 捕捉场站集群相互耦合的复杂时空信息, 提出基于 FT-ASTGCN 的单个集中式风电集群功率预测模型, 整体模型架构如图 2 所示。

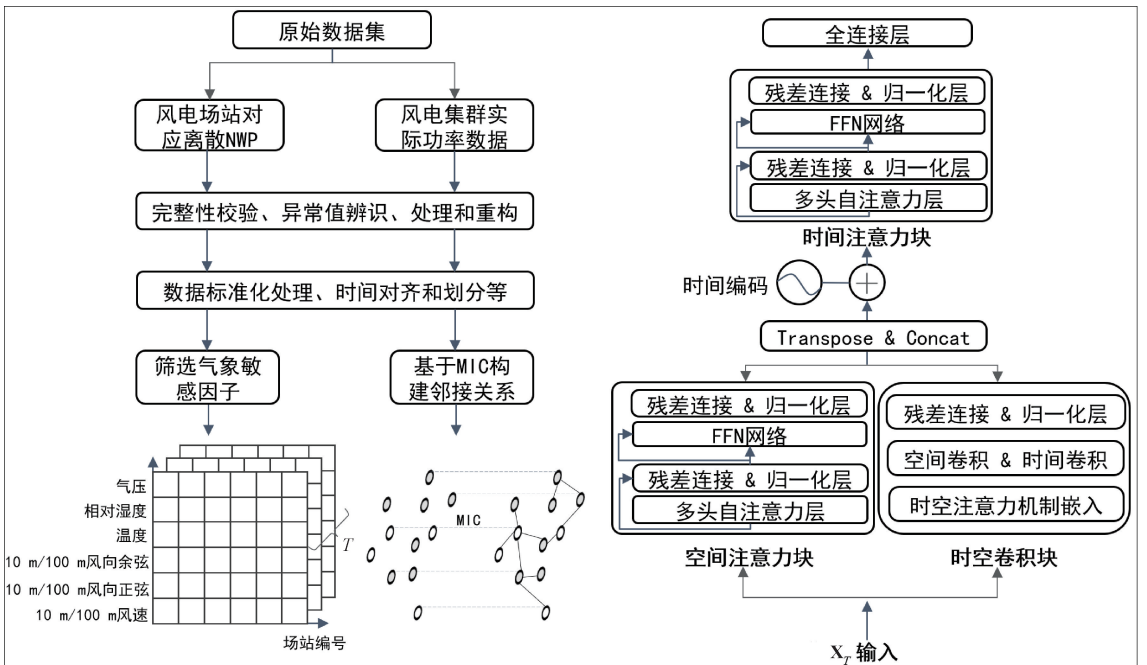


图 2 基于 FT-ASTGCN 的风电集群功率预测模型框架

Figure 2 Framework of wind power cluster forecasting model based on FT-ASTGCN

基于多风电场站集群下的历史功率数据和时空分辨率为 15 min 和 3 km×3 km 的三维 NWP 气象数据 Single_Nwps(N, K, T), 通过完备性校验、异常值剔除和数据重构方法^[17], 实现数据标准化和时间对齐的原始数据集。然后, 取 t 步长为一个时间切片, 并结合最大相关-最小冗余方法^[18] 筛选出 9 种气象敏感因子。 N 表示风电场个数, K 表示气象参数类型, T 表示总时间长度。最后, 通过计算风电集群内各场站历史功率的最大信息系数, 确定邻接矩阵 A , 从而定义风电集群原始气象信息构成的气象网络 G 。

对于 $X_T = (V_1, V_2, \dots, V_t) \in \mathbf{R}^{N \times F \times t}$ 原始气象输入的三维张量, 分别用两种编码结构对输入数据进行特征的提取与解构。具体如下: 在时空卷积块 (spatio-temporal convolution blocks) 中, 首先, 通过时间注意力矩阵 I 的嵌入, 聚合气象网络中各时间节点序列特征的动态变化, 得到新的气象网络时间特征表示 $\tilde{X}_{t_1}^{i-1}$ 。然后, 基于空间注意力矩阵 S 与图卷积的嵌入表征, 动态调整不同风电场的影响权重, 获取新的气象网络空间特征表示。并结合时间卷积, 充分捕捉时序信息中的局部特征, 得到下一层融合时空信息特征的输入 $X_{t_1}^i$ 。在空间注意力块 (spatial-attention block) 中, 首先, 通过自注意力机制将输入分解为 Q, K, V 矩阵, 并结合多头机制引入多个独立的注意力头; 然后, 基于 FFN 网络 (Feed-Forward Networks)^[19] 增强气象数据在高维空间中非线性特征的表达, 得到下一层融合时空特征的输入 $X_{t_2}^i$ 。

在解码器中, 用 Transpose 操作把两种编码位置信息对齐后, 将场站特征压缩至同一维度, 再利用 Concat 操作将两者集成至同一语义空间并对时间编码^[20]。然后, 通过时间注意力块 (Temporal-Attention Block) 融合集成特征, 捕捉其在序列时间上的连续性。最后, 基于全连接层, 将融合的复杂时空特征映射回集群功率, 从而完成模型构建。

4 算例分析

4.1 数据来源与评估指标

本研究使用的数据集来自中国西北地区的 26 座风电场, 时间分辨率为 15 min, 总装机容量为 2 743.5 MW, 集群分布如图 3 所示。训练数据范围为 2023 年 1 月 1 日—2024 年 1 月 6 日, 而测试数据取自 2024 年 1 月 7 日—2024 年 2 月 27 日, 用于评估模型的性能。




图 3 风电场站地理位置分布图

Figure 3 Geographical distribution map of wind farms and stations

为了提高模型的精度, 本文对数据进行了标准化处理。采用极差标准化法^[21], 将数据的取值范围调整为 $[0, 1]$, 以消除量纲差异的影响。具体公式如下:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (21)$$

式中: x 表示原始样本数据值; x_{\max} 、 x_{\min} 表示样本数据最大、最小值。

为更好地评估预测结果的精确度及偏离程度, 本文选取归一化均方根误差 $RMSE$ 和归一化平均绝对误差 MAE 作为评估指标^[22], 公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n \left(\frac{y_t - y'_t}{P_{\text{cap}}} \right)^2}; \quad (22)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - y'_t}{P_{\text{cap}}} \right|. \quad (23)$$

式中: n 表示总样本数量; y_t 为 t 时刻的实际风电集群功率值; y'_t 为 t 时刻的预测风电集群功率值; P_{cap} 为风电集群的总装机容量。

4.2 图结构生成

为捕捉风电集群各场站间的空间信息, 深入挖掘 NWP 气象信息在非欧空间上的数据潜力, 将风速等 9 种气象敏感因子形成单风电场站节点特征, 基于各场站间的最大信息系数构建图结构数据。如图 4 所示, 风电集群场站之间呈现稀疏分布, 地势相似的邻近风电场之间强相关。基于最大信息系数确定邻接矩阵 A , 利用空间卷积将其与空间注意力嵌入矩阵 S 结合, 实现各个风电场站气象信息的动态耦合。

4.3 实验环境和参数

本文实验硬件环境基于 RTX 4090 24GB GPU、25 核 Xeon(R) Platinum 8352V CPU; 软件环境基于 CUDA 12.8、PyTorch 2.0.0、Python 3.8。模型主要参数如表 1 所示。




图4 风电场站间出力相关性

Figure 4 Output correlation between wind farms and stations

表1 模型主要参数

Table 1 Core parameters of the model

| 参数名称 | 参数设置 | 作用 |
|-----------|-------|---------|
| 初始学习率 | 1e-03 | 决定更新幅度 |
| Batchsize | 64 | 训练批量数 |
| 损失函数 | MSE | 度量误差程度 |
| 空间注意力块数 | 4 | 提取空间特征 |
| 时间注意力块数 | 6 | 提取时间特征 |
| 时间卷积块数 | 4 | 提取时间特征 |
| 自注意力头数 | 4 | 多通道特征优化 |
| 自注意力层数 | 2 | 注意力提取深度 |

4.4 实验结果与分析

选取经典BP神经网络、SVM模型、ResCNN模型及若干基准模型进行对比分析,各模型预测方法详见表2。

表2 不同预测模型预测路线

Table 2 Prediction routes of different forecasting models

| 模型编号 | 预测模型 | 预测方法 |
|------|-----------|-------|
| 1 | BPNN | 一场一测式 |
| 2 | SVM | 一场一测式 |
| 3 | ResCNN | 集中式 |
| 4 | GCN | 集中式 |
| 5 | STGCN | 集中式 |
| 6 | AM-STGCN | 集中式 |
| 7 | FT-ASTGCN | 集中式 |

在风电集群功率预测中,“一场一测式”模型采用分场独立建模策略,即首先为集群内的各风电场分别构建预测模型,再将其预测值进行求和叠加,从而获得集群总功率预测结果;与之相对的“集中式”模型则基于集群整体建模,其输出直接表征为集群各场站输出功率的总预测。不同方法预测曲线与实际功率曲线的对比如图5所示。




图5 不同模型下风电集群预测功率与实际功率曲线对比
Figure 5 Comparison of predicted and actual power curves of wind power clusters under different models

为充分论证本模型预测性能优势,如表3所示,将系统对比分析不同方案的预测值误差统计结果。

表3 不同预测模型风电集群功率预测性能比较

Table 3 Comparison of power prediction performance for wind power clusters among different forecasting models

| 预测模型 | RMSE | MAE |
|-----------|---------|---------|
| BPNN | 0.082 9 | 0.064 7 |
| SVM | 0.081 2 | 0.061 3 |
| ResCNN | 0.085 4 | 0.063 2 |
| GCN | 0.083 7 | 0.058 8 |
| STGCN | 0.075 4 | 0.056 1 |
| AM-STGCN | 0.072 1 | 0.053 0 |
| FT-ASTGCN | 0.070 2 | 0.051 4 |

相较于采用“一场一测式”预测方法的BPNN与SVM模型,基于“集中式”建模的GCN模型在MAE指标上分别降低了9.12和4.08个百分点,在RMSE指标上分别增加了0.97和3.08个百分点。图6展示了3种模型在典型时段内的预测曲线与实际功率的对比结果,可见GCN的预测输出整体上更贴近真实功率轨迹,拟合效果优于两种基准模型。这一性能提升主要得益于GCN的图卷积架构,其通过构建邻接矩阵有效刻画了风电场群间的空间拓扑关系,从而实现了区域气象特征空间分布的精准建模,显著增强了模型的空间感知能力。但在高出力阶段有着一定的时移偏差,在时序特征提取方面存在不足,这种时间维度表征能力的欠缺在误差指标上表现为较大的RMSE。

在“集中式”预测框架下,与ResCNN模型相比,GCN在RMSE和MAE两个关键指标上分别降低了1.99和6.96个百分点,进一步验证了其在处理非欧几里得空间结构数据方面的优越性。

综上两项对比实验表明,在风电集群功率预测任务中,引入基于非欧几里得结构的图卷积操作,能够有效提取并融合多场站间复杂的空间相关性信息,充分挖掘区域气象特征的空间分布规律,从而显

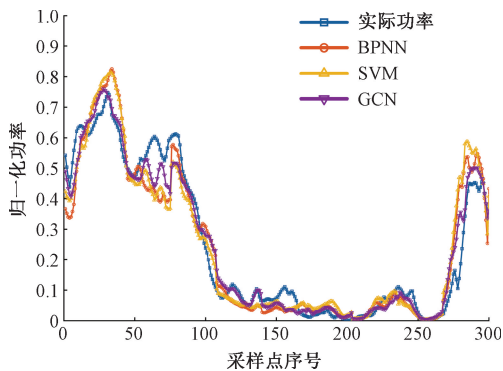


图6 BPNN、SVM和GCN风电集群预测与实际功率局部曲线对比

Figure 6 Comparison of local curves between predicted and actual power of wind power clusters by BPNN, SVM and GCN

著提升预测模型的整体精度与鲁棒性。

本文所提出的 FT-ASTGCN 模型在对比其余 6 个预测模型时, RMSE 误差指标的减小幅度分别为 15.32, 13.55, 17.80, 16.13, 6.90, 2.64 百分点; MAE 误差指标的下降幅度分别为 20.56, 16.15, 18.67, 12.59, 8.38, 3.02 百分点。从整体精度看, FT-ASTGCN 与 AM-STGCN 在多项评估指标上均优于其他 5 个基准模型, 充分验证了注意力机制的引入与时间特征的融合对提升预测精度的有效性。从表 3 中的实验结果可进一步观察到, 本文提出的 FT-ASTGCN 模型在整体预测精度上显著优于未引入时空注意力融合机制的 AM-STGCN 模型, 局部对比曲线如图 7 所示。

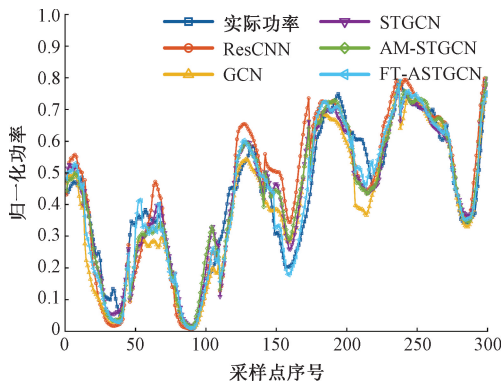


图7 风电集群集中式模型预测与实际功率局部曲线对比

Figure 7 Comparison of local curves between predicted and actual power of wind power clusters in the centralized model

从图中可观察到, FT-ASTGCN 模型所生成的功率预测曲线在走势上与实际值更为接近。原因在于 AM-STGCN 仅考虑不同场站之间整体风电功率下的非欧式空间固定映射关系, 但对于局部风电功率下, 受风速、风向等时变参数的影响, 不同时段内的空间特征会动态变化产生偏差, 从而影响整体预测精度。

而 FT-ASTGCN 通过引入时空注意力机制, 实现了对目标风电场与相邻风电场在不同时间尺度上的特征融合, 使模型能够根据时空特征的变化动态调整场站间的相关性权重, 从而更精准地建模时空依赖关系, 提升整体预测性能。

5 结论

(1) 基于不同场站历史功率构建气象网络图结构数据, 有助于充分利用风资源的波动性, 实现目标风电场与邻近风电场间的信息聚合。图卷积层有效提取气象图结构信息以及附属于图节点的属性信息, 有助于挖掘 NWP 数据中蕴含的有效特征信息, 强化对区域气象资源的建模能力。

(2) 引入时空多头自注意力融合机制, 有效解决原始气象数据在非欧式空间图结构下的空间特征时变问题, 自适应调整不同场站间的影响权重, 动态捕捉风电场之间时空关联性变化, 从而更有效地挖掘时空依赖特征, 显著提升风电功率预测的整体准确性和鲁棒性。

(3) FT-ASTGCN 模型将两种编码下的空间特征与气象特征融合, 利用编-解码器架构将两者集成至同一语义空间, 结合时间编码对风资源周期性进行强化, 显著增强模型对关键时空特征的识别, 能够高效实现风电集群总功率的输出, 且在多项评价指标上均优于现有对比模型, 充分体现所提方法的适应性与先进性。

参考文献:

[1] Shao Guiping, Xu Honghua. Research on present situation and future development trend of renewable energy integrated system[J]. Solar Energy, 2024(7): 127-132. [邵桂萍, 许洪华. 可再生能源综合系统现状与未来发展趋势研究[J]. 太阳能, 2024(7): 127-132.]

[2] Solé J, García-Olivares A, Turiel A, et al. Renewable transitions and the net energy from oil liquids: a scenarios study[J]. Renewable Energy, 2018, 116: 258-271.

[3] Zhang Wenyu, Ma Keke, Guo Zhenhai, et al. Multistep prediction of wind speed based on grey wolf algorithm and extreme learning machine[J]. Journal of Zhengzhou University (Engineering Science), 2024, 45(2): 89-96. [张文煜, 马可可, 郭振海, 等. 基于灰狼算法和极限学习机的风速多步预测[J]. 郑州大学学报(工学版), 2024, 45(2): 89-96.]

[4] Tu Qingyu, Miao Shihong, Lin Yujun, et al. Ultra-short-term interval forecasting method for regional wind farms based on dynamic R-vine copula model[J]. High Voltage Engineering, 2022, 48(2): 456-466. [涂青宇, 苗世

- 洪,林毓军,等. 基于动态 R 藤 Copula 模型的区域风电集群超短期功率区间预测方法[J]. 高电压技术, 2022, 48(2): 456-466.]
- [5] Zhu Zhibin, Meng Anbo, Ou Zuhong, et al. Ultra-short-term wind power prediction based on deep ensemble learning model using multivariate mode decomposition and multi-objective optimization[J]. Modern Electric Power, 2024, 41(3): 458-469. [朱梓彬, 孟安波, 欧祖宏, 等. 基于多元模态分解与多目标算法优化的深度集成学习模型的超短期风电功率预测[J]. 现代电力, 2024, 41(3): 458-469.]
- [6] Wu Ni. Research on wind power prediction method based on ensemble model[D]. Wuhan: Hubei University of Technology, 2023. [吴霓. 基于集成模型的风电功率预测方法研究[D]. 武汉: 湖北工业大学, 2023.]
- [7] Xiang Yang. Research on short-term power prediction method for wind farm clusters based on CNN-LSTM modeling[D]. Beijing: North China Electric Power University, 2024. [向阳. 基于 CNN-LSTM 模型的风电场集群短期功率预测方法研究[D]. 北京: 华北电力大学, 2024.]
- [8] Li Chaofeng, Yuan Shengyao, Wang Lingmei, et al. Ultra-short-term power prediction for wind farms based on informer[J]. Journal of Shanxi University (Natural Science Edition), 2024, 47(6): 1201-1210. [李超峰, 原升耀, 王灵梅, 等. 基于 Informer 的风电场超短期功率预测[J]. 山西大学学报(自然科学版), 2024, 47(6): 1201-1210.]
- [9] Gu Tingting, Huang Yinglu, Wang Yanan, et al. ResNet-UNet short-term wind power prediction with introduction of multi-head attention mechanism[J/OL]. Acta Energiae Solaris Sinica, 1-6. [顾婷婷, 黄亦露, 王亚男, 等. 基于多头注意力机制的 ResNet-UNet 短期风电功率预测[J/OL]. 太阳能学报, 1-6.]
- [10] Zhou Lina, Liu Xudong. Research on short term wind power prediction method based on CNN-LSTM[J]. Journal of Heilongjiang Institute of Technology, 2024, 38(6): 44-50. [周丽娜, 刘旭东. 基于 CNN-LSTM 的短期风电功率预测方法研究[J]. 黑龙江工程学院学报, 2024, 38(6): 44-50.]
- [11] Chen Gang, Shan Jingning, Li Dan yang, et al. Research on wind power prediction method based on convolutional neural network and genetic algorithm[C]//Proceedings of the 2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia). Piscataway: IEEE, 2019: 3573-3578.
- [12] Liu Yong, Yang Xihui, Yan Linzi, et al. Wind power prediction based on CEEMD and Granger causality variable selection[J]. China Measurement & Testing Technology, 2023, 49(4): 98-105. [刘勇, 杨熙卉, 燕林滋, 等. CEEMD 双层分解和 Granger 因果变量选择风电功率预测[J]. 中国测试, 2023, 49(4): 98-105.]
- [13] Zheng Yingying, Li Xin, Chen Yanxu, et al. Short-term wind power forecasting method in extreme weather based on stacking multi-model fusion[J]. High Voltage Engineering, 2024, 50(9): 3871-3882. [郑颖颖, 李鑫, 陈延旭, 等. 基于 Stacking 多模型融合的极端天气短期风电功率预测方法[J]. 高电压技术, 2024, 50(9): 3871-3882.]
- [14] Zhang Haotian, Wen Mi, Li Jinguo, et al. Data driven time attention convolution wind power prediction model[J]. Acta Energiae Solaris Sinica, 2022, 43(10): 167-176. [张浩田, 温蜜, 李晋国, 等. 数据驱动的时间注意力卷积风电功率预测模型[J]. 太阳能学报, 2022, 43(10): 167-176.]
- [15] Rao R M, Liu Jie, Verkuil R, et al. MSA transformer[C]//Proceedings of the 38th International Conference on Machine Learning. Singapore: PMLR, 2021: 8844-8856.
- [16] Zhang Gang, Liu Hongchi, Zhang Jiangbin, et al. Wind power prediction based on variational mode decomposition multi-frequency combinations[J]. Journal of Modern Power Systems and Clean Energy, 2019, 7(2): 281-288.
- [17] Bai Jiandong, Zhu Jiawei, Song Yujiao, et al. A3T-GCN: attention temporal graph convolutional network for traffic forecasting[J]. ISPRS International Journal of Geo-Information, 2021, 10(7): 485.
- [18] Ye Lin, Li Yilin, Pei Ming, et al. Combined approach for short-term wind power forecasting under cold weather with small sample[J]. Proceedings of the CSEE, 2023, 43(2): 543-554. [叶林, 李奕霖, 裴铭, 等. 寒潮天气小样本条件下的短期风电功率组合预测[J]. 中国电机工程学报, 2023, 43(2): 543-554.]
- [19] Xu Wu, Fan Xinhao, Shen Zhifang, et al. Short-term wind power prediction using transformer with multi-scale feature extraction[J]. Acta Energiae Solaris Sinica, 2025, 46(2): 640-648. [徐武, 范鑫豪, 沈智方, 等. 多尺度特征提取的 Transformer 短期风电功率预测[J]. 太阳能学报, 2025, 46(2): 640-648.]
- [20] Liu Tengfei, Chen Liyue, Fang Jiangyi, et al. SCFNet: fusion framework of external spatial features for spatio-temporal prediction[J]. Computer Science, 2025, 52(4): 110-118. [刘腾飞, 陈李越, 房江祎, 等. SCFNet: 一种面向时空预测的外部空间特征融合框架[J]. 计算机科学, 2025, 52(4): 110-118.]
- [21] Wang Xiaodong, Li Shanshan, Liu Yingming, et al. Ultra-short-term wind power prediction based on variable feature weight[J]. Acta Energiae Solaris Sinica, 2023, 44(2): 52-58. [王晓东, 栗杉杉, 刘颖明, 等. 基于特征变权的超短期风电功率预测[J]. 太阳能学报,

2023, 44(2): 52-58.]

[22] Pu Xiaoyun, Yang Jing, Yang Xing, et al. IZOA-Transformer-BiGRU short-term wind power prediction based on decomposition technique [J]. *Electronic Measurement*

Technology, 2025, 48(2): 39-48. [蒲晓云, 杨靖, 杨兴, 等. 基于分解技术的 IZOA-Transformer-BiGRU 短期风电功率预测[J]. *电子测量技术*, 2025, 48(2): 39-48.]

Short-term Power Prediction of Wind Power Clusters Based on Wind Field Spatial and Meteorological Fusion

WEI Zhenzhu¹, LIU Mingyu¹, WANG Yulong¹, ZHOU Yan², JIANG Jiandong¹

(1. School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China; 2. Luoyang Power Supply Company of State Grid Henan Electric Power Company, Luoyang 471000, China)

Abstract: Given that traditional wind power cluster prediction methods fail to effectively account for the spatial meteorological correlations among stations and struggle to efficiently deduce the overall cluster power based on single-station predictions, this paper proposes a multi-dimensional spatiotemporal information fusion framework for stations based on an attention-based spatiotemporal embedding mechanism. This framework aims to fully exploit the complex spatiotemporally coupled characteristics embedded within discrete Numerical Weather Prediction (NWP) heterogeneous meteorological information. Firstly, a Multi-Head Self-Attention mechanism is employed to directly fuse spatial features, enhancing the model's ability to capture spatial power correlations across multiple stations. Secondly, cluster location information was deconstructed using the Maximal Information Coefficient (MIC) to construct a non-Euclidean graph data structure reflecting meteorological correlations. This is combined with a Spatial-Temporal Attention mechanism to achieve cross-fusion of spatiotemporal features between stations and their neighborhoods, dynamically adjusting the influence weights among stations to capture spatiotemporal dynamic dependencies. Furthermore, an encoder-decoder architecture integrates spatial and spatiotemporal features into a unified semantic space to capture temporal continuity within sequences. Finally, the proposed model is verified based on the actual wind farm operation data of a certain region in Northwest China. Experimental results show that when the proposed method is compared with the other 6 prediction models, the reduction amplitudes of the E_{RMSE} error index are 15.32, 13.55, 17.80, 16.13, 6.90, and 2.64 percentage points respectively. The decrease amplitudes of the E_{MAE} error index are 20.56, 16.15, 18.67, 12.59, 8.38, and 3.02 percentage points respectively, which effectively verify its advancement and adaptability.

Keywords: wind power cluster forecasting; spatio-temporal graph convolutional neural network; multi-head self-attention mechanism; graph data structure; deep learning