

基于双图结构的时空图卷积网络短期风电功率预测模型

郑哲明^{1,2}, 孔玲玲^{1,2*}, 何印^{1,2}

(1. 云南民族大学电气信息工程学院, 云南 昆明 650504; 2. 云南省无人自主系统重点实验室(云南民族大学), 云南 昆明 650504)

摘要:针对传统风电功率预测方法忽略时空特征交互的问题,提出一种融合双图结构与注意力机制的时空图卷积网络模型(spatial-temporal graph convolutional network with attention, STGCN-A)。基于最大信息系数构建相关性矩阵,形成基于统计相关性的空间图,结合欧氏距离构建地理邻近性空间图,实现风电机组间的双图建模;采用图卷积网络(graph convolutional network, GCN)提取空间特征,结合门控循环单元(gated recurrent unit, GRU)深度挖掘时间依赖关系,引入注意力机制(attention mechanism, AM)对时间步进行动态加权,以增强时空特征中关键信息的表示能力。在实际风电数据集集中开展对比试验,结果表明,该模型在均方根误差 E_{RMS} 、平均绝对误差 E_{MA} 和决定系数 R^2 评价指标上优于传统方法,表现出较高的预测精度,具有较好的实际应用潜力。

关键词:风电功率;图卷积网络;门控循环单元;注意力机制;最大信息系数

中图分类号:TM614 **文献标志码:**A

引用格式:郑哲明,孔玲玲,何印. 基于双图结构的时空图卷积网络短期风电功率预测模型[J]. 山东大学学报(工学版), 2026, 56(2): 130-138.

ZHENG Zheming, KONG Lingling, HE Yin. Short-term wind power prediction model based on spatial-temporal graph convolutional network with dual-graph structure[J]. Journal of Shandong University (Engineering Science), 2026, 56(2): 130-138.

Short-term wind power prediction model based on spatial-temporal graph convolutional network with dual-graph structure

ZHENG Zheming^{1,2}, KONG Lingling^{1,2*}, HE Yin^{1,2}

(1. School of Electrical and Information Engineering, Yunnan Minzu University, Kunming 650504, Yunnan, China; 2. Yunnan Province Key Laboratory of Unmanned Autonomous Systems (Yunnan Minzu University), Kunming 650504, Yunnan, China)

Abstract: To address the limitations of traditional wind power prediction methods that ignored the interaction of spatial-temporal features, a spatial-temporal graph convolutional network with attention (STGCN-A) was proposed. A correlation matrix was constructed by the maximal information coefficient to form a statistical correlation-based spatial graph, while an Euclidean distance-based geographic proximity spatial graph was built to achieve dual-graph modeling among wind turbines. Spatial features were extracted through a graph convolutional network (GCN), and temporal dependencies were captured by a gated recurrent unit (GRU). An attention mechanism (AM) was introduced to dynamically weight different time steps, enhancing the representation of critical information in spatial-temporal features. Comparative experiments on real wind power datasets demonstrated that the proposed model outperformed traditional methods in terms of root mean square error (E_{RMS}), mean absolute error (E_{MA}), and coefficient of determination (R^2). The results indicated higher prediction accuracy and strong potential for practical applications.

Keywords: wind power; graph convolutional network; gated recurrent unit; attention mechanism; maximal information coefficient

收稿日期:2025-03-12

基金项目:国家自然科学基金资助项目(52061042)

第一作者简介:郑哲明(2000—),男,福建泉州人,硕士研究生,主要研究方向为风电功率预测与优化调度。E-mail:18016697736@163.com

* 通信作者简介:孔玲玲(1979—),女,河南鹿邑人,副教授,硕士生导师,硕士,主要研究方向为电网中电力电子技术和电气工程教育教学。

E-mail:kongling0104@163.com

0 引言

随着“双碳”目标的深入推进,清洁能源的开发已成为全球能源转型的核心方向之一。风能作为一种重要的可再生能源,在推动节能减排、实现绿色低碳目标方面具有重要地位^[1]。风电功率预测(wind power prediction, WPP)的准确性对提升风电场运营效率、优化电力调度、提高风电场在电力市场中的竞争力具有重要意义^[2]。短期风电功率预测(通常为1~2 d的发电量预测)对减少弃风、调度和维护风力发电机起着关键作用^[3-4]。由于风速和风电功率的高波动性与地理分布的非均匀性,WPP不仅涉及时间维度上的动态变化,还需考虑空间维度上风电机组之间的协同作用。因此,开展时空特征交互建模是提升WPP准确率的重要方向。

传统短期风电功率预测方法主要分为物理方法和统计方法。物理方法通常基于复杂的数学模型,通过数值天气预报(numerical weather prediction, NWP)结合外部环境特征对风电功率进行预测,但对历史气象数据的依赖性较高,且要求较高的计算能力。统计方法依托统计模型(如贝叶斯框架^[5])有效建模风电功率的动态特性,但难以捕捉其中复杂的非线性特征。深度学习技术的快速发展为风电功率预测提供新的解决思路,尤其是神经网络能从数据中自动提取特征,建模非线性关系,在风电功率预测领域取得显著进展。长短期记忆网络(long short-term memory, LSTM)广泛用于捕捉风速的长期时间依赖特性^[6],卷积神经网络(convolutional neural network, CNN)擅长提取风电功率的局部时间特征^[7]。然而,在处理具有高度随机性的风电历史数据时,传统的单一深度学习模型常常存在较大的预测误差。

为应对这一挑战,许多学者提出组合预测方法。组合预测的核心思想在于通过融合多个单一预测模型,结合特征工程、信号分解、智能优化算法等技术手段,有效减轻模型的过拟合问题,提升整体预测性能。文献[8]将变分模态分解(variational mode decomposition, VMD)用于特征提取,将改进海洋捕食者算法用于优化支持向量机(support vector machine, SVM)模型,克服模型过拟合问题,增强模型预测性能;文献[9]利用自适应噪声完全集合经验模态分解风电数据,并利用改进飞蛾扑火优化算法优化Attention-LSTM的超参数,以提高预测精度。然而,上述方法多聚焦于单一风电场或风机的时间序列

建模,难以有效捕捉风电场群中机组之间的空间关联性,限制模型预测性能的进一步提升^[10]。

为解决上述问题,部分研究引入时空建模方法融合风电功率数据的空间与时间信息。文献[11]采用Seq2Seq架构实现时空依赖性建模;文献[12]通过CNN和门控循环单元(gated recurrent unit, GRU)混合架构增强时空特征提取能力;文献[13]提出融合时空神经网络与变分贝叶斯推理的复合模型;文献[14]基于自动编码器构建风电场相关性模型。尽管这些模型在一定程度上考虑了时空依赖性,但仍存在以下不足:多从单一视角建模空间结构,忽略风电机组间统计相关性与地理邻近性的协同作用;空间图构建方式较为粗糙,无法精确表达风资源传播路径及风电机组实际运行中的复杂交互关系。基于上述问题,为更加全面刻画风电机组间的空间关联特性,本研究提出一种融合双图结构与注意力机制的时空图卷积网络(spatial-temporal graph convolutional network with attention, STGCN-A)短期风电功率预测模型。双图结构中,其一为基于历史发电数据的统计相关性图,通过计算风电机组间的最大信息系数揭示风机之间在运行行为上的非线性依赖关系;其二为基于地理位置信息的地理邻近性图,利用风电机组经纬度构建物理空间距离,结合功率时间序列差异度生成欧氏相似性矩阵。两种图结构分别从数据统计视角和物理空间视角建立风机间的连接关系,在建模视角上互为补充。前者有助于发现隐藏在运行数据中的潜在关联,后者则考虑风资源传播和地理位置对风力发电的实际影响。双图结构的引入有效补充单一空间特征建模的局限性,提高风电机组之间空间信息的表达能力。通过图卷积运算提取风电机组间的空间依赖关系,结合多层GRU深度挖掘时间序列特征。引入注意力机制(attention mechanism, AM)以突出关键节点及重要时间步特征。基于江苏省某地部分风电机组的算例分析表明,相较于其他功率预测模型,本研究所提模型表现出优良性能。

1 基于STGCN-A的短期风电功率预测模型

1.1 双图结构的构建

为有效建模风电机组间复杂的空间关联性,本研究构建两类图结构,即统计相关性图与地理邻近性图,分别从历史发电行为的相似性与物理地理拓扑结构两方面刻画风电场之间的空间依赖关系。

两类图结构在建模视角上具有互补性,其中统计相关性图强调运行趋势间的耦合关系,地理邻近性图反映风电场之间的静态空间布局特征。图结构的核心在于邻接矩阵的设计。邻接矩阵不仅定义风电机组间的连接关系与权重分布,也是后续图卷积操作中信息传播路径的基础。

1.1.1 基于最大信息系数的统计相关性图构建

在风电功率预测研究中,不同风电机组之间存在显著的空间相关性。为科学量化这种关联性,引入最大信息系数,全面捕捉风电场间的潜在关联模式。相比传统的线性相关性度量,最大信息系数具备更高的敏感性与鲁棒性,能够识别复杂的非线性关系,提供更精确的相关性评估依据。本研究利用最大信息系数构建风电机组间的统计相关性矩阵,通过筛选与目标风电机组高度相关的邻域风电机组构建邻接矩阵,形成统计相关性图结构。其中,风电机组 X 与 Y 间的互信息

$$I[X;Y]=H(X)-H(X|Y)=\sum_{x \in X} \sum_{y \in Y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}, \quad (1)$$

式中, $H(X)$ 为 X 的熵, $H(X|Y)$ 为在 Y 已知条件下 X 的熵, $p(x,y)$ 为风机 x,y 的联合概率密度函数, $p(x)$ 和 $p(y)$ 分别为风机 x,y 的边缘密度函数。

最大信息系数通过将各风电机组的功率数据映射到二维空间进行网格化处理,计算变量之间的最大互信息。为便于比较,该互信息经归一化映射至 $[0,1]$ 。最大信息系数

$$C_{MI}(X;Y)=\max_{ab < B^{0.6}} \frac{I[X;Y]}{\log[\min(a,b)]} B^{0.6}, \quad (2)$$

式中, a,b 为 X,Y 在二维网格中的划分数, B 为样本数。 C_{MI} 的统计相关性热力图如图 1 所示。




图1 统计相关性热力图

Fig.1 Heat map of statistical correlation

为提取风电机组间显著的统计相关性,通过计算不同编号风电机组历史功率序列之间的 C_{MI} ,生成对称的相关性矩阵。考虑过密连接会引入冗余和噪声信息,本研究设置阈值 $\tau=0.8$,筛选出相关性强的边(即 C_{MI} 大于阈值的条目),据此构建邻接矩阵。该邻接矩阵将在图神经网络中作为结构输入之一,引导空间特征的提取与传播。

1.1.2 基于地理位置信息的空间邻接图构建

风电机组的地理位置信息往往是清晰的,风机之间的空间分布关系能够直接反映它们相互影响的程度。由于风资源在空间上的扩散特性,相邻风电机组通常受到相似的气象条件(如风速、气压等)影响,其发电特性之间存在较强的关联性。基于这一特性,本研究以风电机组的经纬度坐标信息为基础,采用 Haversine 距离公式计算目标风机与其他风机之间的地理距离,筛选距离最近的 N 个风机作为目标风机的邻居节点。为进一步强化邻接矩阵的物理意义及量化节点间的动态相似性,使用欧氏距离计算功率时间序列之间的差异性。风机 x,y 之间的欧氏距离

$$d(x,y)=\sqrt{\sum_{t=1}^T (P_{x,t}-P_{y,t})^2}, \quad (3)$$

式中, $P_{x,t}, P_{y,t}$ 分别为风机 x,y 在时间点 t 的输出功率, T 为时间序列总长度。

计算不同风机间的欧氏距离组成地理距离矩阵。为将距离信息转化为更具表达性的相似度量,本研究进一步使用高斯核函数对距离矩阵进行非线性映射。风机 x,y 之间的相关性系数

$$S(x,y)=\exp\left(-\frac{d(x,y)^2}{2\sigma^2}\right), \quad (4)$$

式中, σ 为欧氏距离的标准差,决定高斯核函数的平滑程度或敏感性。计算不同风机间的相关性系数,生成地理邻接矩阵。地理邻接矩阵热力图如图 2 所示。




图2 地理邻接矩阵热力图

Fig.2 Heat map of the geographical adjacency matrix

基于地理信息构建邻接矩阵的方法不仅通过距离度量筛选邻居节点反映风电机组的物理空间布局,还引入时间序列变化特征,增强图结构的物理表达能力和语义丰富性。相较于统计相关性图依赖历史序列建图,地理图结构以物理位置为主导,能更好地反映空间拓扑约束与结构性依赖,对提升模型在空间结构上的泛化建模能力具有补充作用。

1.2 图卷积神经网络

风电场的拓扑结构本质上可以建模为一个图结构,其中每个节点的特征可以视为图上的信号^[15]。然而,传统的卷积神经网络缺乏平移不变性,在处理此类非欧几里得空间数据时,难以直接实现卷积和池化等操作。图卷积网络(graph convolutional network, GCN)通过将卷积运算从欧几里得空间扩展到图结构数据,能够聚合一个节点及其相邻节点的特征,生成该节点的新表示^[16]。从谱域定义的图卷积(即谱方法)可以有效提取图中节点之间的局部领域信息,为复杂图结构数据的特征表达和分析提供理论支持。

在谱图分析中,图通常用对应的拉普拉斯矩阵表示。正则化的拉普拉斯矩阵

$$\mathbf{L} = \mathbf{I}_N - \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \in \mathbf{R}^{N \times N}, \quad (5)$$

式中: \mathbf{I}_N 为单位矩阵, $\mathbf{I}_N \in \mathbf{R}^{N \times N}$; \mathbf{D} 为节点的度矩阵, $\mathbf{D} \in \mathbf{R}^{N \times N}$; \mathbf{A} 为节点间的邻接矩阵, $\mathbf{A} \in \mathbf{R}^{N \times N}$ 。

图卷积操作通过邻接矩阵与节点特征结合,实现节点表示的更新。传统频谱方法中,图卷积定义为

$$g_\theta * \mathbf{f} = \mathbf{U} g_\theta(\mathbf{A}) \mathbf{U}^T \mathbf{f}, \quad (6)$$

式中, g_θ 为带参数 θ 的谱域滤波函数,*为图卷积运算, \mathbf{f} 为输入特征, $g_\theta(\mathbf{A})$ 为作用于特征值矩阵 \mathbf{A} 的谱域滤波函数, \mathbf{U} 为图拉普拉斯矩阵的特征向量。然而,该方法计算复杂度高。为了降低正则化拉普拉斯矩阵分解引入的计算复杂度,引入切比雪夫多项式方法^[17],将图卷积运算简化为

$$\mathbf{G}_c(\mathbf{f}) = \sum_{k=0}^{K-1} \theta_k T_k(\bar{\mathbf{L}}) \mathbf{f}, \quad (7)$$

式中: $\mathbf{G}_c(\cdot)$ 为简化后的图卷积过程; T_k 为 k 阶切比雪夫多项式, $k \in \{0, 1, \dots, K-1\}$; θ_k 为需要学习的滤波器参数; $\bar{\mathbf{L}}$ 为归一化的拉普拉斯矩阵, $\bar{\mathbf{L}} = \mathbf{U} \bar{\mathbf{A}} \mathbf{U}^T$,其中 $\bar{\mathbf{A}}$ 为归一化特征值矩阵。

在本研究的风电功率预测框架中,图卷积网络作为空间特征提取模块,对构建的统计相关性邻接矩阵及地理位置信息邻接矩阵进行图卷积操作,生成包含空间依赖信息的结构化嵌入表示,实现风电机组间的空间关联性建模。将这些空间嵌入特征

输入时序建模模块中,以捕捉功率随时间演化的动态特征。通过形成从空间特征提取到时间序列建模的信息流处理路径,实现时空特征交互建模。

1.3 门控循环单元网络

为有效刻画风电功率在时间维度上的动态演化规律,本研究在空间特征提取后引入GRU,对序列数据进行时间建模。GRU是循环神经网络(recurrent neural network, RNN)的一种变体,具备结构简洁、训练稳定、参数量少等优势,能够有效捕捉风电功率时间序列中的长期依赖关系与短期波动特征。与传统RNN不同,GRU通过引入更新门与重置门机制控制当前时刻隐状态对历史状态与输入特征的依赖程度,动态调整记忆内容的保留与遗忘。更新门与重置门分别为

$$\mathbf{u}_t = \sigma(\mathbf{W}_u \cdot \mathbf{G}_c(\mathbf{A}, \mathbf{H}_t) + \mathbf{V}_u \cdot \mathbf{h}_{t-1} + \mathbf{b}_u), \quad (8)$$

$$\mathbf{r}_t = \sigma(\mathbf{W}_r \cdot \mathbf{G}_c(\mathbf{A}, \mathbf{H}_t) + \mathbf{V}_r \cdot \mathbf{h}_{t-1} + \mathbf{b}_r), \quad (9)$$

式中, σ 为Sigmoid激活函数, \mathbf{W}_u 、 \mathbf{W}_r 、 \mathbf{V}_u 、 \mathbf{V}_r 为权重矩阵, \mathbf{H}_t 为图中节点在 t 时刻的特征信息, \mathbf{h}_{t-1} 为 $t-1$ 时刻的隐藏状态, \mathbf{b}_u 、 \mathbf{b}_r 为偏置项。

候选隐藏状态与当前隐藏状态分别为

$$\tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_c \cdot \mathbf{G}_c(\mathbf{A}, \mathbf{H}_t) + \mathbf{V}_c \cdot (\mathbf{r}_t \odot \mathbf{h}_{t-1}) + \mathbf{b}_c), \quad (10)$$

$$\mathbf{h}_t = \mathbf{u}_t \odot \mathbf{h}_{t-1} + (1 - \mathbf{u}_t) \odot \tilde{\mathbf{h}}_t, \quad (11)$$

式中, \mathbf{W}_c 、 \mathbf{V}_c 为权重矩阵, \mathbf{b}_c 为偏置项, \odot 为Hadamard乘积。

在本研究模型框架中,GRU不仅用于处理风电功率的时间序列变化,还承担与图卷积模块输出的空间特征进行融合的任务。在 t 时刻,GRU的输入不仅包含目标风机该时刻的原始特征,还包含由GCN提取出的空间结构信息。通过这一设计,模型可在时序建模过程中保持对空间特征的持续感知,在预测过程中实现历史空间状态与时间动态信息的融合。

1.4 注意力机制

为进一步提升模型对时序特征中关键时间节点的识别能力,本研究在GRU时序建模模块基础上引入注意力机制,实现对不同时间步特征重要性的动态加权。通过计算隐藏状态与全局特征的相关性分布,自动分配每个时间步的重要性权重,突出关键时刻的特征信息,抑制无关信息的干扰。注意力机制以GRU输出的隐状态序列 $\{\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_t\}$ 为输入,计算每一时刻的注意力系数

$$a_i = \frac{\exp(\tanh(\mathbf{W}_s \mathbf{h}_i + \mathbf{b}_s))}{\sum_{i=1}^t \exp(\tanh(\mathbf{W}_s \mathbf{h}_i + \mathbf{b}_s))}, \quad (12)$$

式中, W_s 为权重矩阵, b_s 为偏置项, h_i 为序列中第 i 个时间步的 GRU 隐藏状态。经过加权处理后, 全局特征

$$v = \sum_{i=1}^t a_i h_i \quad (13)$$

在本研究模型框架中, 注意力机制不仅用于衡量各时间步特征对预测任务的相对重要性, 还对空间结构特征与时间动态演化特征进行交互融合。考虑 GRU 模块已接收由 GCN 提取并编码的空间嵌入特征作为输入序列, 注意力机制对整个时空特征序列进行加权聚合, 实现对关键时刻及关联空间模式的显式建模。输出的 v 作为预测模块的输入, 为风电功率预测任务提供具有针对性与判别性的高质量特征表达, 提升模型的稳定性与泛化能力。

1.5 预测流程

为充分考虑风电机组之间的时空关联特性, 本研究提出一种融合双图结构信息的时空预测模型。模型整体框架如图 3 所示。

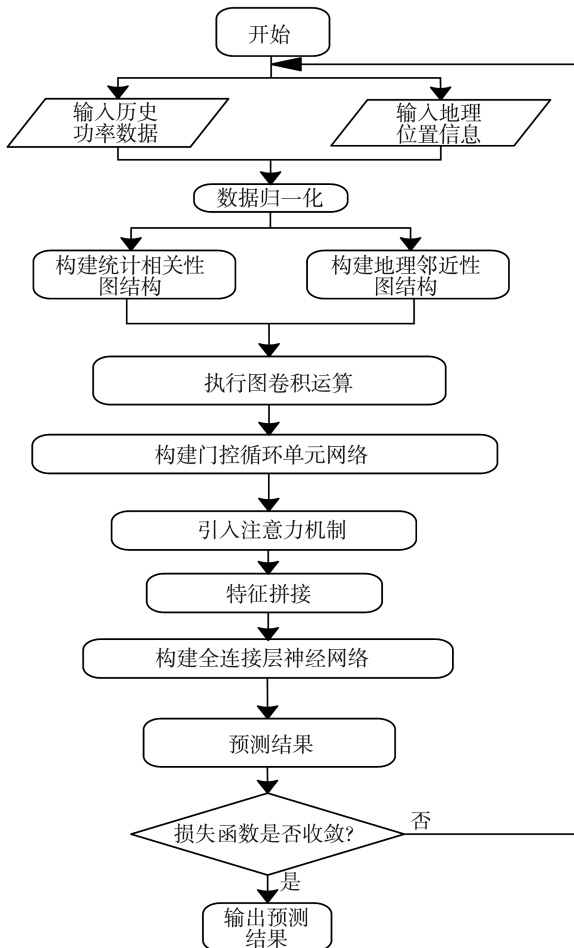


图3 预测模型框架图

Fig.3 Framework diagram of prediction model

以目标风电机组及其关联机组的历史功率数据和地理位置信息为输入, 通过构建两类异构图

(统计相关性图与地理邻近性图), 分别从数据相关性与物理空间结构两个维度建模风电机组间的空间关联性。分别将两类图结构输入 GCN 中, 通过图卷积运算提取多维度的空间依赖特征。提取得到的两路空间特征经拼接后输入 GRU, 建模风电功率的时序动态变化。为进一步增强模型对关键时序信息的关注能力, 引入注意力机制对 GRU 输出进行加权融合, 强化关键信息的表达能力。将融合的特征输入全连接层, 输出未来时刻的风电功率预测结果, 通过损失函数进行监督优化。

2 算例分析

2.1 数据准备与处理

本研究选取江苏省某地 40 台单机风力发电机 (每台风电机均有编号) 的历史运行功率数据进行算例分析。样本时间分辨率为 15 min, 训练集与测试集比例为 8:2。其中, 将 2022-01-07—2022-07-15 数据作为训练集, 2022-07-16—2022-08-30 数据作为测试集, 并选取训练集后 10% (即 2022-06-26—2022-07-15) 数据作为验证集。采用时间滑动窗口避免数据过拟合, 同时保留对时间序列数据的依赖性和规律^[18]。历史时间窗口长度为 3, 预测未来 48 h, 属于短期预测。各风电机组的地理位置分布如图 4 所示。




图4 风电机组地理位置分布图

Fig.4 Wind turbine geographic distribution map

为消除量纲差异对数据分析和模型训练的影响, 采用极差变换方法对样本数据进行归一化处理^[19], 具体计算式为

$$z' = \frac{z - z_{\min}}{z_{\max} - z_{\min}} \quad (14)$$

式中, z 和 z' 分别为归一化前、后的样本数据, z_{\max} 为最大样本数据, z_{\min} 为最小样本数据。

2.2 模型结构与流程

本研究所提模型融合 GCN 的空间特征提取能

力、GRU的时间建模能力及注意力机制的动态加权能力,主要划分为以下5个模块。

(1)输入模块。以目标风电机组及其关联机组的历史发电功率数据作为时序输入特征,采用滑动窗口方式生成训练样本。每个样本以连续 T 步的历史数据作为输入窗口,预测未来 T' 步的输出目标功率。在本模型试验中,取 $T=3, T'=1$,即每3个时间步构成1个训练样本,将所有输入样本归一化,按照时间顺序划分数据集,其中数据集的前80%作为训练集,后20%作为测试集。在图结构构建中,输入路径包含统计相关性图和地理邻近性图两类结构。

(2)双图结构构建模块。基于 C_{MI} 计算风电机组间的非线性相关性,构建加权邻接矩阵,生成统计相关性图结构;根据经纬度与功率欧氏差异生成风电机组间的空间距离矩阵,并基于高斯核构造相似性,构建地理邻近性图结构。两类图结构分别生成归一化图拉普拉斯矩阵,利用多价切比雪夫多项式展开,为后续图卷积操作提供结构支撑。

(3)空间特征提取模块。在空间特征提取阶段,输入特征与图结构一并输入图卷积网络,采用两层图卷积操作,输出通道数分别为32和16,逐层捕捉不同层次的空间依赖关系。

(4)时序建模与注意力机制模块。为实现时间维度上的深层特征建模,采用3层GRU网络对图卷积输出进行序列建模,逐层提取时间动态信息,引入注意力机制对GRU输出的多时间步状态进行加权融合,提升模型对关键时刻信息的表达能力。

(5)输出模块。在融合两类图结构的时空特征后,通过注意力机制进行加权处理,拼接后输入全连接网络进行非线性映射,以完成对目标风机未来时刻功率的预测。训练过程中以均方误差作为损失函数,并采用Adam优化器进行参数迭代更新。

2.3 评价指标

为客观量化模型在风电功率预测任务中的表现,本研究选用多种回归评价指标刻画预测值与实际值之间的误差。结合风电功率数据特性,采用平均绝对误差 E_{MA} 、决定系数 R^2 和均方根误差 E_{RMS} 作为评估指标,从不同层面反映模型预测误差的大小和分布情况^[20]。3个指标的具体计算式分别为

$$E_{MA} = \frac{1}{n} \sum_{j=1}^n |(y_j - \hat{y}_j)|, \quad (15)$$

$$R^2 = 1 - \frac{\sum_{j=1}^n (\hat{y}_j - y_j)^2}{\sum_{j=1}^n (y_j - \bar{y}_j)^2}, \quad (16)$$

$$E_{RMS} = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2}, \quad (17)$$

式中, \hat{y}_j 为预测风电功率, y_j 为实际风电功率, \bar{y}_j 为平均风电功率, n 为风电功率数据序列的长度。

2.4 试验结果与分析

为验证本研究模型在风电功率预测领域的有效性,将所提模型与典型的单一模型和组合模型进行对比。对比模型涵盖传统时序模型(支持向量回归(support vector regression, SVR)、RNN、GRU、LSTM)、融合注意力机制的改进模型(LSTM-AM、图注意力网络(graph attention network, GAT)、CNN-LSTM-AM)及引入图结构学习的深度时空模型(GCN-LSTM),具备较强的代表性与覆盖广度。通过网格搜索法遍历不同的超参数组合,以 E_{RMS} 作为验证指标对模型进行训练和评估。最终确定的最佳超参数配置为:训练轮次设为100,批量大小设为32,滑动窗口大小设为3,学习率为0.001,GCN层数为2,GRU层数为3,选择Adam优化器,激活函数为ReLU,设置均方误差为损失函数。以编号063的风机为目标风电,不同模型预测对比如图5所示,相应指标如表1所示。

由图5和表1可以看出,本研究提出的双图融合架构时空模型在误差评估指标和拟合能力方面展现出显著优势。SVR的 R^2 为93%,说明该模型具有一定的全局拟合能力,但 E_{MA} 和 E_{RMS} 分别为7.13和13.85,明显高于本研究模型的6.69和9.82,说明SVR在误差控制方面存在较大偏差,预测稳定性较差。与GRU和LSTM相比,本研究模型的 E_{MA} 分别降低4.70%和8.98%, E_{RMS} 分别降低24.59%和30.30%, R^2 达到97%,显著高于GRU和LSTM,说明本研究模型在拟合能力上更优越,能够更有效地捕捉时间序列中的动态变化和空间结构中的依赖关系。与RNN相比,本研究模型的 E_{MA} 和 E_{RMS} 分别降低3.32%和22.80%。相较于CNN-LSTM-AM,本研究模型通过引入双图结构,进一步挖掘潜在的空间依赖关系, E_{MA} 和 E_{RMS} 分别降低8.23%和30.55%,展现出更优的时空特征提取能力。与GCN-LSTM相比,本研究模型引入多维度时间序列注意力机制,使 E_{MA} 和 E_{RMS} 分别降低7.47%和10.73%,进一步表明本研究模型能够更深入地挖掘时间序列与空间关系之间的交互信息。对比当前流行的GAT,本研究模型的 E_{MA} 和 E_{RMS} 分别降低22.12%和32.79%, R^2 提升7.78%,进一步凸显其在时空序列建模任务中的优越性。




图5 不同预测模型预测功率与实际功率曲线对比

Fig.5 Comparison of predicted power and actual power curves for different models

表1 不同模型评价对比

Table 1 Evaluation comparison of different models

预测模型	E_{MA}	$R^2/\%$	E_{RMS}
SVR	7.13	93	13.85
GRU	7.02	94	13.03
RNN	6.92	94	12.72
LSTM	7.35	94	14.09
GAT	8.59	90	14.61
LSTM-AM	6.92	94	13.05
GCN-LSTM	7.23	95	11.00
CNN-LSTM-AM	7.29	93	14.14
本研究模型	6.69	97	9.82

2.5 模型组件消融分析

为进一步验证本研究所提模型中关键结构设计的有效性,从图结构配置与注意力机制两个方面开展组件消融试验,剖析不同结构因素对模型性能的具体影响。

2.5.1 不同图结构对模型的影响

图结构作为描述风电场空间拓扑关系的重要载体,其构建方式直接影响预测模型对空间依赖特征的提取能力与最终预测性能。为系统评估不同图结构对模型预测效果的影响,本研究设计对比试验,从图结构输入层面构建3类模型进行性能分析,分别为仅使用第一类图结构的模型N1、仅使用第二类图结构的模型N2及融合两类图结构的组合模型N1-N2。3类模型在网络结构、参数设置等方面保持一致,唯一变量为输入的图结构类型。试验结果如图6所示,定量评估指标对比如表2所示。

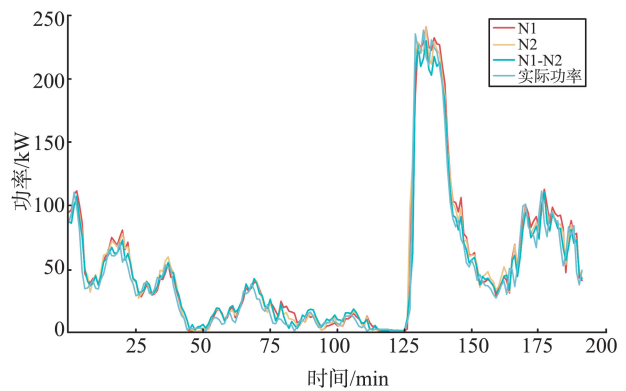


图6 不同图结构对模型的影响对比

Fig.6 Comparison of the influence of different graph structures on the model

表2 图结构对模型性能的影响评估

Table 2 Evaluation of the influence of graph structure on model performance

图结构	E_{MA}	$R^2/\%$	E_{RMS}
N1	8.21	92	13.35
N2	8.62	91	14.69
N1-N2	6.69	97	9.82

由图6可以看出,双图结构下本研究模型的预测曲线与真实曲线的拟合程度优于单图结构模型。由表2可知,双图结构模型的 E_{MA} 和 E_{RMS} 均显著低于单图N1和单图N2。根据预测曲线形态的对比分析,双图结构模型在拟合实际风电功率变化趋势方面表现更优,尤其在功率波动剧烈的区域(如峰值、谷值及拐点)具有更强的动态响应能力,能更精准地捕捉短时变化特征。单图结构模型在剧烈变化的局部特征区域存在一定程度的滞后与偏差,在

刻画非平稳动态特征方面的能力存在一定局限性。综上分析,双图结构模型通过融合多种图结构信息,在空间特征的表达与时间序列建模之间建立更紧密的联系,增强模型对复杂非线性关系的拟合能力,在整体数据分布拟合、局部关键点响应等方面均表现出更强的鲁棒性与适应性,验证了图结构融合设计的有效性与优势。

2.5.2 注意力机制对模型的影响

本研究模型设计中特别引入注意力层,用于捕获不同风电机组节点间的动态依赖关系。为了进一步探究注意力机制对本研究模型的影响,设置对比试验,试验组采用引入注意力机制的完整模型,对照组在保持其他结构和超参数设置一致的基础上,移除注意力机制。预测结果如图7所示,不同指标对比结果如表3所示。




图7 注意力机制对模型影响对比

Fig.7 Comparison of the influence of attention mechanism on the model

表3 注意力机制对模型性能的影响评估

Table 3 Evaluation of the effect of attention mechanism on model performance

模型	E_{MA}	$R^2/\%$	E_{RMS}
引入注意力机制	6.69	97	9.82
未引入注意力机制	8.21	93	13.12

由图7和表3可以看出,引入注意力机制的模型在预测性能上显著优于未引入注意力机制的模型。引入注意力机制模型的 E_{MA} 和 E_{RMS} 更低, R^2 达到97%,显著高于未引入注意力机制模型,表明注意力机制通过增强对局部特征和全局依赖关系的捕捉能力,提高模型对真实数据的拟合精度,尤其在数据分布复杂或动态波动较大的区域,引入注意力机制的模型表现更为优越。综上分析,注意力机制在强化局部特征建模与全局信息捕捉方面发挥积极作用,能够提升模型对复杂风电功率序列的拟合能力与预测稳定性。

3 结论

针对传统风电功率预测模型未能充分考虑风电场内各风电机组之间时空相关性的局限性,本研究提出一种融合双图结构与注意力机制的时空图卷积网络模型。通过实际算例验证并与传统预测模型对比分析,得出以下结论。

(1)在空间结构建模方面,本研究模型构建融合统计相关性图与地理邻近性图的双图结构,分别从历史功率的统计关联与物理位置的几何约束出发,刻画风电场中风电机组间复杂而多变的空间依赖关系。相比单一图结构,双图建模策略能够更全面地挖掘风机间的潜在交互和协同作用,显著提升模型对空间分布特征的表达能力。

(2)在时间建模方面,本研究模型通过GRU层与注意力机制的协同作用,增强模型对长时间序列中的关键信息提取能力,强化模型对时空特征中关键信息的关注度,从而提高对非平稳时序行为的建模效果。

(3)在预测性能方面,本研究模型在各项性能指标上均优于对比模型, E_{MA} 、 R^2 和 E_{RMS} 分别为6.69、97%和9.82,表明本研究模型通过双图结构设计及GRU与注意力机制的有效融合,在风电功率短期预测任务中具备更高的预测精度和更强的特征提取能力,有效提升模型对复杂时空关系的捕捉能力。

后续研究可以考虑引入有向图结构,增强对风场内部因果关系与异步交互的建模能力,并考虑融合外部环境因素(如温度、湿度、大气压力等)对模型的影响,通过多模态数据融合技术进一步提升模型的预测精度和泛化能力。

参考文献:

- [1] 陶冶. 供需两侧齐发力, 新能源产业成为培育新质生产力的重要引擎: 2023年我国新能源发展形势分析与2024年展望[J]. 中国能源, 2024, 46(增刊1): 11-18. TAO Ye. The joint efforts of supply and demand have made the new energy industry an important engine for cultivating the new quality productive forces development in China: analysis of China's new energy development situation in 2023 and development prospects in 2024[J]. Energy of China, 2024, 46(Suppl.1): 11-18.
- [2] 曹胡辉, 裘智峰, 向劲勇, 等. 考虑中长期交易与短期调度衔接的风电消纳模型[J]. 电网技术, 2020, 44(11): 4200-4209.

- CAO Huhui, QIU Zhifeng, XIANG Jinyong, et al. Wind power accommodation model considering the link of medium and long-term transactions with short-term dispatch[J]. *Power System Technology*, 2020, 44(11): 4200-4209.
- [3] WAN C, WANG J H, LIN J, et al. Nonparametric prediction intervals of wind power via linear programming [J]. *IEEE Transactions on Power Systems*, 2018, 33(1): 1074-1076.
- [4] 武新章, 梁祥宇, 朱虹谕, 等. 基于 CEEMDAN-GRA-PCC-ATCN 的短期风电功率预测[J]. *山东大学学报(工学版)*, 2022, 52(6): 146-156.
- WU Xinzhang, LIANG Xiangyu, ZHU Hongyu, et al. Short-term wind power prediction based on CEEMDAN-GRA-PCC-ATCN [J]. *Journal of Shandong University (Engineering Science)*, 2022, 52(6): 146-156.
- [5] ZHANG J H, YAN J, INFELD D, et al. Short-term forecasting and uncertainty analysis of wind turbine power based on long short-term memory network and Gaussian mixture model [J]. *Applied Energy*, 2019, 241: 229-244.
- [6] SHAHID F, ZAMEER A, MEHMOOD A, et al. A novel wavenets long short term memory paradigm for wind power prediction[J]. *Applied Energy*, 2020, 269: 115098.
- [7] 薛禹胜, 陈宁, 王树民, 等. 关于利用空间相关性预测风速的评述[J]. *电力系统自动化*, 2017, 41(10): 161-169.
- XUE Yusheng, CHEN Ning, WANG Shumin, et al. Review on wind speed prediction based on spatial correlation[J]. *Automation of Electric Power Systems*, 2017, 41(10): 161-169.
- [8] 刘金朋, 邓嘉明, 高鹏宇, 等. 基于 VMD-IMPA-SVM 的超短期风电功率预测[J]. *智慧电力*, 2024, 52(7): 24-32.
- LIU Jinpeng, DENG Jiaming, GAO Pengyu, et al. Ultra short term wind power prediction based on VMD-IMPA-SVM [J]. *Smart Power*, 2024, 52(7): 24-32.
- [9] 宋立业, 鞠亚东, 张鑫. 基于改进 MFO 优化 Attention-LSTM 的超短期风电功率预测 [J]. *电气工程学报*, 2023, 18(3): 359-366.
- SONG Liye, JU Yadong, ZHANG Xin. Ultra-short-term wind power prediction based on improved MFO optimized Attention-LSTM [J]. *Journal of Electrical Engineering*, 2023, 18(3): 359-366.
- [10] JIANG G Q, XIE P, HE H B, et al. Wind turbine fault detection using a denoising autoencoder with temporal information [J]. *IEEE/ASME Transactions on Mechatronics*, 2018, 23(1): 89-100.
- [11] FU X B, GAO F, WU J, et al. Spatiotemporal attention networks for wind power forecasting [C] // 2019 International Conference on Data Mining Workshops (ICDMW). Beijing, China: IEEE, 2020: 149-154.
- [12] AFRASIABI M, MOHAMMADI M, RASTEGAR M, et al. Advanced deep learning approach for probabilistic wind speed forecasting [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(1): 720-727.
- [13] LIU Y Q, QIN H, ZHANG Z D, et al. Probabilistic spatiotemporal wind speed forecasting based on a variational Bayesian deep learning model [J]. *Applied Energy*, 2020, 260: 114259.
- [14] YU J J Q, GU J T. Real-time traffic speed estimation with graph convolutional generative autoencoder [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 20(10): 3940-3951.
- [15] QI Y L, LI Q, KARIMIAN H, et al. A hybrid model for spatiotemporal forecasting of PM_{2.5} based on graph convolutional neural network and long short-term memory [J]. *Science of the Total Environment*, 2019, 664: 1-10.
- [16] KHODAYAR M, WANG J H. Spatio-temporal graph deep neural network for short-term wind speed forecasting [J]. *IEEE Transactions on Sustainable Energy*, 2019, 10(2): 670-681.
- [17] ZHOU J, CUI G Q, HU S D, et al. Graph neural networks: A review of methods and applications [J]. *AI Open*, 2020, 1: 57-81.
- [18] SUN C, CHEN Y Y, CHENG C. Imputation of missing data from offshore wind farms using spatio-temporal correlation and feature correlation [J]. *Energy*, 2021, 229: 120777.
- [19] 冯俊磊, 吕卫东, 段雪艳, 等. 基于模态分解和 TCN-BiLSTM 的风电功率预测 [J]. *电子测量技术*, 2024, 47(14): 49-56.
- FENG Junlei, LYU Weidong, DUAN Xueyan, et al. Wind power prediction based on mode decomposition and TCN-BiLSTM [J]. *Electronic Measurement Technology*, 2024, 47(14): 49-56.
- [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 Energetica Solaris Sinica*, 2024, 45(5): 95-103.