



基于图卷积网络和风速差分拟合的中长期风功率预测

陈子含¹, 滕伟¹, 胥学峰², 丁显², 柳亦兵¹

(1. 华北电力大学 电站能量传递转化与系统教育部重点实验室, 北京 102206;

2. 中国绿发投资集团有限公司, 北京 100020)

摘要: 为充分利用数据特征间的先验关系, 提高风电场中长期发电功率预测精度, 提出一种基于图卷积神经网络 (GCN)、风速差分拟合 (DF)、粒子群优化算法 (PSO) 的中长期风功率预测模型。通过分析风力发电全过程, 挖掘风功率影响因素及因素间的相互关联性, 搭建 GCN 模型, 分别拟合风速和功率利用效率, 进一步结合基于 DF 的风速-功率计算模型计算风功率, 模型的损失包含功率损失、风速损失和功率利用效率损失 3 个部分, 采用粒子群优化算法为这 3 部分损失确定合适的权重。2 个风电场的实际算例表明, 该模型未来 10 天风功率预测的相对均方根误差分别为 11.44% 和 13.09%, 具有较高的预测精度。

关键词: 风力发电; 风功率预测; 图卷积神经网络; 风速差分拟合; 粒子群优化算法

DOI: 10.11930/j.issn.1004-9649.202303050

0 引言

风力发电是进行能源战略转型、助力实现双碳目标的重要载体^[1]。然而, 由于风速的随机波动, 风电机组的出力不够平稳, 对构建新型电力系统形成挑战。风功率预测是利用当前信息对风电场未来一段时间内输出功率大小进行预测的技术, 其在电力调度、电力系统维护、电力市场竞价方面具有重要的意义^[2-3]。

风功率预测从时间尺度上可以分为 3 类: 超短期预测 (时/分/秒)、短期预测 (时/天)、中长期预测 (天/周/月/季)。超短期预测主要用于日内发电计划调整, 短期预测主要用于合理安排常规机组发电计划, 解决电网调峰问题^[4-5]。当前, 风功率预测方面的研究更多专注于短期预测, 技术较为成熟, 取得较多实用性成果^[6-7]。中长期风功率预测可以帮助制定运维计划, 在发电较少、气象条件较好的时期大修, 减少发电损失, 也可以为中长期的调度计划和电力交易提供重要的支撑信息^[8-10]。但由于预测时间尺度较长, 预测难度大, 精度较低, 长期预测获得关注

不足。为了充分利用已知信息、提高预测精度, 短期预测中常使用时间序列滚动预测技术^[8-12], 而这一技术在中长期预测中不可避免的面临误差累积的问题, 在预测时间尺度较大时误差会迅速放大。

在中长期预测中经常使用机器学习和深度学习进行拟合, 文献^[13]利用支持向量回归 (SVR) 和随机森林 (RF) 对风电场未来 7 天的风功率进行预测; 文献^[14]提出了一种基于长短期记忆 (LSTM) 和 RF 的中长期风电功率组合预测方法, 利用 LSTM 对中期风电功率进行预测, 然后结合 RF 对短期误差进行修正, 从而提高了整体预测精度; 文献^[15]提出了一种基于历史气象数据 (环境温度、平均风速、风向) 和神经网络 (NN) 模型的风功率预测方法, 能够根据历史数据建立 NN 模型, 对未来 1~7 天的风功率进行预测。但是以上方法存在一个共性问题, 并未考虑各个输入特征之间的本质关联和耦合影响, 而是利用模型直接拟合输入特征和风功率之间的关系。

挖掘关键特征是一个提升准确率的有效方法, 文献^[16]提出了一种基于双向长短期记忆网络 (Bi-LSTM) 和注意力机制 (Attention) 的风电功率点预测和区间预测方法, 能够充分地捕捉时序数据中的动态特征和非线性关系; 文献^[17]使用了基于 copula 函数和长短期记忆网络的方法来

收稿日期: 2023-03-10; **修回日期:** 2023-09-19。

基金项目: 国家自然科学基金资助项目 (半监督环境下风电机组群的智能化故障诊断与寿命预测, 51775186)。

预测中长期风光发电量。这种方法可以有效地从非线性效应和趋势中提取影响发电的关键气象因素，并深入挖掘长期依赖性和季节性变化；文献 [18] 利用 RF 算法对历史风速数据进行特征选择，然后分别使用多元自适应样条回归 (MARS)、广义相加模型 (GAM)、SVR 和深度神经网络 (DNN) 对风功率进行预测；文献 [19] 利用深度自编码器 (DAE) 对原始历史数据进行特征提取，然后将深度特征输入到 LSTM 神经网络进行预测；文献 [20] 利用气象数据和地理信息系统 (GIS) 数据构建区域风资源评估模型，通过挖掘区域间的风资源相似性特征，提高了预测精度和效率。上述方法考虑到了关键特征对预测风功率起到的重要作用，并使用相应方法进行特征提取，但是使用自适应特征提取方法选定特征进行训练需要大量的计算资源和训练数据，且所提取的特征不稳定，对数据来源、模型结构和参数选择比较敏感。

为了解决上述问题，本文提出了一种基于图卷积神经网络 (graph convolutional network, GCN) 和差分拟合 (differential fitting, DF) 的中长期风功率预测模型。该模型具有以下创新点：1) 通过对风力发电过程溯源，确定影响风功率的主要因素并建立图网络；2) 利用图卷积神经网络有效地捕捉特征之间的相互影响，提取高层次特征；3) 采用差分拟合表达输入特征和风功率之间的部分非线性环节，并降低模型拟合难度；4) 采用粒子群优化算法 (particle swarm optimization, PSO) 确定各部分损失函数的权重，并优化整体目标函数。

首先，在理论分析基础上选择了影响中长期风功率最显著且可获取的气象因素作为输入特征，并构建了图网络结构；其次，基于差分拟合建立风速-功率计算模型，与图卷积神经网络组合成完整模型；最后，在 2 个实际风电场数据集上对比了本文模型与其他常见方法在不同时间尺度下的预测效果。

1 理论分析

1.1 图卷积神经网络

从气象特征数据到风速、功率的预测过程

中，不仅每一特征都与结果存在关联，而且这些特征相互之间也具有影响关系，这些关系中隐藏着大量先验信息，若能充分利用，可以大大降低特征提取难度、提高预测精度。

图卷积神经网络是一种能从图数据提取特征的深度学习方法，所谓图数据，是指数据以图网络的形式描述多个特征节点的相互关联，如图 1 所示。风功率预测所需要的参数具有显著的时空关联关系，GCN 为解决这一问题提供了思路。




图 1 图网络示例

Fig. 1 Graph network sample

图卷积算子为

$$h_i^{l+1} = \sigma \left(\sum_{j \in N_i} c_{ij} h_j^l w_{ij}^l \right) \quad (1)$$

式中： h_i^{l+1} 为节点 i 在第 $l+1$ 层的特征表达； $\sigma(\cdot)$ 为非线性函数，如 $\text{relu}(\cdot)$ ； N_i 为节点 i 的邻居集合，包含自身； c_{ij} 为归一化因子； w_{ij}^l 为 l 层节点 i 和 $l+1$ 层节点 j 的连接权重。

GCN 一个卷积层的操作可以表示为

$$h^{l+1} = \sigma \left(D^{-\frac{1}{2}} \tilde{A} D^{\frac{1}{2}} h^l W^l \right) \quad (2)$$

式中： \tilde{A} 为邻接矩阵， $\tilde{A} = A + I$ ， I 是单位阵， A 为描述所有节点连接关系的矩阵，若节点 i 与节点 j 存在连接关系，则 $A_{ij} = A_{ji} = 1$ ； D 为 \tilde{A} 的度矩阵， $D_{ii} = \sum_{j=1}^n A_{ij}$ ； W^l 为第 l 层的节点特征线性变换矩阵； h^l 为第 l 层所有节点的特征表达。

1.2 基于 DF 的风速-功率计算模型

风电机组的风速-功率关系属于典型的非线性关系，相比于直接由模型拟合功率，此处先拟合风速，再根据已知的历史信息 and 数学关系确定功率，可以有效降低模型拟合难度、提高预测精度。差分拟合在针对复杂非线性拟合问题中具有

较好的表现, 尤其适合输入输出变量间存在惯性环节的情形, 其核心在于增加输入变量的差分项作为输入, 再进行拟合 (如最小二乘拟合), 拟合表达式为

$$\begin{cases} \hat{y}_i = f_{\psi}(x_i, \dot{x}_i) \\ \hat{\psi} = \arg \min \sum_{i=1}^n (y_i - \hat{y}_i)^2 \end{cases} \quad (3)$$

式中: \hat{y}_i 为第 i 个拟合输出值; $f_{\psi}(\cdot)$ 为以 ψ 为参数的目标拟合函数; x_i 为第 i 个输入值; \dot{x}_i 为 x_i 的差分项, $\dot{x}_i = x_i - x_{i-1} (i = 2, \dots, n)$; ψ 为拟合函数的参数; $\hat{\psi}$ 为拟合函数参数估计值; y_i 为第 i 个目标值。

根据风轮叶片的动量理论, 风功率与风速的关系式为

$$P = \frac{1}{2} C_p \rho A v^3 \quad (4)$$

式中: P 为发电功率; C_p 为风能利用系数; ρ 为空气密度; v 为风速; A 为风轮面积。

但实际风电机组运行时, 需要考虑风速波动、风轮惯性和风向偏转等因素 (暂时不考虑人为干预因素), 建立如下功率计算式。

$$P = \frac{1}{2} C_p \rho A (v_n + \tilde{b} \dot{v}_n)^3 \quad (5)$$

式中: v_n 为法向风速, $v_n = v \cos \theta$, θ 为风向与风轮轴线夹角; \tilde{b} 为惯性参数。通过加入 $\tilde{b} \dot{v}_n$ 项, 可以补偿风速波动时风轮惯性和风偏向对输出功率的影响, 此处的 \dot{v}_n 使用 v_n 的差分序列替代。

理论上风电机组发电功率与风速的关系如图 2 所示。




图 2 风电机组发电功率与风速关系
Fig. 2 Relationship between wind power and wind velocity

图 2 中: v_{in} 为切入风速; v_r 为额定风速; v_{out} 为切出风速。在 $v_{in} \sim v_r$ 阶段, 控制系统执行变

转速控制, 保持 C_p 为恒定值 C_{pmax} , 保证最大风能利用; 在 $v_r \sim v_{out}$ 段, 控制系统执行定转速变桨控制, 保持输出功率恒定。基于此, 将式 (5) 调整为

$$P = \eta (a \cdot v_n + b \dot{v}_n + c)^3 \quad (6)$$

式中: η 为功率利用效率; a 为比例参数, $a = \frac{1}{2} C_{pmax} \rho A \cos \theta$; b 为比例参数, $b = \frac{1}{2} C_{pmax} \rho A \tilde{b} \cos \theta$; c 为偏置参数, 用于补偿误差。

理论上, $v_{in} < v_n < v_r$ 时, $\eta = 1$; 其他情况时, $\eta < 1$ 。而实际上, η 是一个难以分析的非线性函数。相比于直接拟合输入变量和功率的关系, 本文提出的思路如下。

1) 模型拟合法向风速 v_n 和功率利用效率 η 。

2) 用 $v_{in} < v_n < v_r$ 的风速-功率数据进行差分拟合, $(av_n + b\dot{v}_n + c)^3$ 来逼近理论上可以获取的功率 P , 由于 $v_{in} < v_n < v_r$ 时, $\eta \rightarrow 1$, 因此使用这一区间的风速-功率数据拟合 $(av_n + b\dot{v}_n + c)^3 \rightarrow P$ 最为合适。

3) 拟合从 $(av_n + b\dot{v}_n + c)^3$ 到实际功率这一过程的系数 (功率利用率 η), 简化了原本复杂的非线性过程, 是本文模型的核心。

4) 在实际使用式 (6) 进行拟合时, 真实 v_n 可能难以获得或计算, 可以使用真实风速 v 替代法向风速 v_n 进行拟合, 即

$$P = \eta (av + b\dot{v} + c)^3 \quad (7)$$

虽与理论情况不同, 但都是从风速到功率的拟合, 只是参数发生了变化, 实现过程无异。

用 $v_{in} < v_n < v_r$ 的风速-功率数据使用最小二乘拟合得到 a 、 b 、 c 后, 可以根据式 (6) 由风速序列计算出功率序列。分别预测功率利用率 η 和风速 v , 再通过式 (6) 计算功率, 有 2 个优势。1) 相比于直接预测功率, 降低了模型从输入到输出的非线性程度, 提升了模型的预测精度; 2) a 、 b 、 c 参数由历史风速-功率数据拟合而来, 充分利用了历史风速-功率数据。

1.3 粒子群优化算法

通过模拟鸟类觅食过程, 粒子群算法仅需要少量参数即可实现快速寻优^[21]。粒子位置更新计算式为

$$v_i = \omega v_i + c_1 \text{rand}() (p_{b_i} - x_i) + c_2 \text{rand}() (g_b - x_i) \quad (8)$$

$$x_i = x_i + v_i \quad (9)$$

式中： x_i 为第 i 个微粒位置向量； v_i 为第 i 个粒子速度向量； p_{bi} 为第 i 个微粒历史最优位置； g_b 为所有微粒历史最优位置； ω 、 c_1 、 c_2 为系数。

PSO 的基本过程如下。1) 初始化 n 个具有速度和位置的微粒；2) 根据每个微粒位置计算适应度，更新 p_b 和 g_b ；3) 根据式 (8) (9) 对所有微粒位置进行更新；4) 若满足结束条件则返回最优粒子位置 g_b ，否则继续步骤 2) ~4)。

2 中长期风功率预测模型

2.1 风速特征图网络与 GCN 结构

根据影响风况的主要因素构建特征图网络，包括地形和气象。在不同的风向下，地貌和地表障碍对风速产生不同的影响；气象因素包括温度、气压等。更进一步地，气象因素变化的本质原因是太阳辐射的周期性变化，分为地球自转（日）周期和地球公转（年）周期 2 种，同时，地球自转（日）周期也与每日风速、温湿度等变量的周期变化具有关联性。影响风速的直接因素是气压梯度和空气密度，这两者直接影响了风速和风向，而风向与地形因素、风电机组尾流效应的关系又间接地影响着风速。由以上分析可以得到风速影响因素的图网络，如图 3 所示。

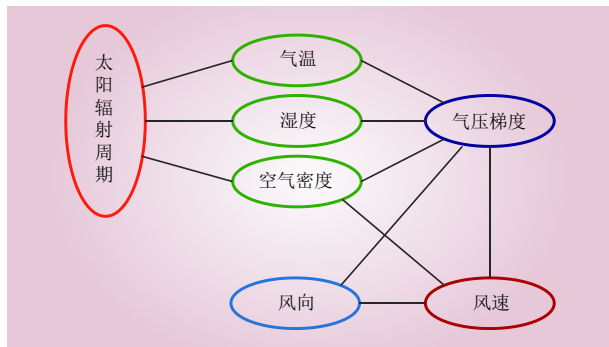


图 3 风速影响因素的图网络
Fig. 3 Graph network of wind velocity influencing factors

由于功率利用效率与图 3 中所示的因素也息息相关，因此对经过 2 个图卷积层处理后的特征节点进行全连接拟合，输出风速和功率利用效率。根据图 3 的图网络，确定 GCN 模型的输入节点及结构，如图 4 所示。

在实际搭建 GCN 模型时，需要根据气象测站的个数及其提供的气象特征确定输入节点个数和




图 4 GCN 模型结构
Fig. 4 GCN model structure

特征图网络。以 n 个气象测站为例，节点个数及特征关系如表 1 所示。

表 1 GCN 图网络节点个数和特征关系
Table 1 Number of nodes and characteristic relation of GCN graph network

节点类型	节点个数	关联节点
时间向量-月份	12	气温、湿度、空气密度
时间向量-小时	24	气温、湿度、空气密度
气温	n	月份、小时、气压梯度
湿度	n	月份、小时、气压梯度
空气密度	n	月份、小时、气压梯度
气压梯度	$n(n-1)/2$	气温、湿度、空气密度、风向、风速
风向	$8n$	气压梯度、风速
风速	n	空气密度、气压梯度、风向

月份和小时时间向量属于周期性数据，使用 one-hot 向量表示；气温、湿度、空气密度和风速在 n 个气象测站分别对应 n 个节点（若气象测站提供 p 组数据，则对应 np 个节点）；气压梯度是一个相对值，每 2 个测站之间有一个气压梯度值，对应 $n(n-1)/2$ 个节点；将每个测站的风向离散为 8 个方向，分别为东、东北、北、西北、西、西南、南、东南，每个方向的角度范围为 45 度，使用 one-hot 向量表示。

该图网络模型的节点选取和连接方式不仅考虑了气象对风功率的直接影响，同时还考虑了太阳辐射周期对风况的影响，考虑了地理环境、机组尾流等与风向之间的关联性。这利用了影响风况的先验知识，也挖掘了独立于气象数据之外的信息。

2.2 风功率预测模型

GCN_DF_PSO 实现风功率预测的训练过程如图 5 所示。

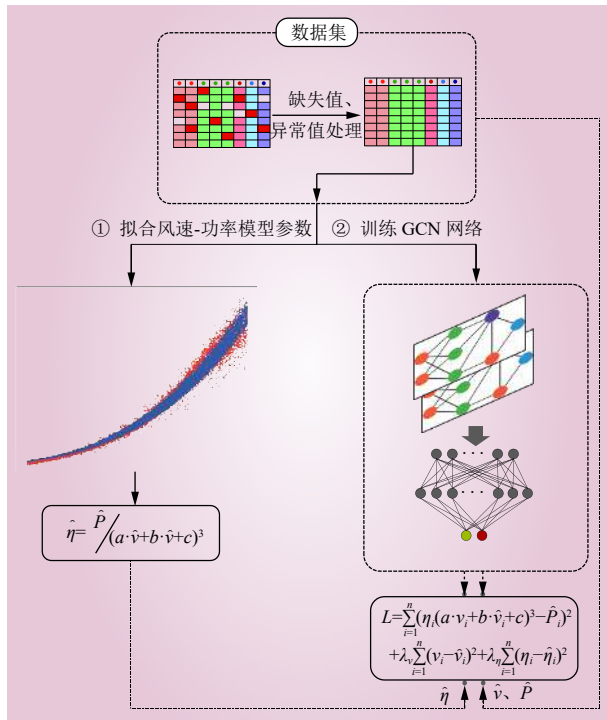


图 5 模型训练过程

Fig. 5 Model training process

1) 数据清洗。处理缺失值、异常值，建立数据集以供训练。按四分位法标记数据中的异常值并置为空值，再对所有空值进行线性插值填补处理。

2) 拟合风速-功率模型。使用最小二乘法，根据 $v_{in} \sim v_t$ 段的历史风速-功率数据，拟合 a 、 b 、 c 。

3) 构建 GCN 模型，并采用 PSO 算法确定 GCN 模型损失权重。以当前时刻之前的 s 组历史气象数据作为 GCN 节点输入，真实风速 \hat{v} 和功率利用效率 $\hat{\eta}$ 作为输出的标签值。 $\hat{\eta}$ 的计算式为

$$\hat{\eta} = \hat{P} / (a\hat{v} + b\hat{v} + c)^3 \quad (10)$$

损失 L 计算式为

$$L = \sum_{i=1}^n \left(\eta_i (a\hat{v}_i + b\hat{v}_i + c)^3 - \hat{P}_i \right)^2 + \lambda_v \sum_{i=1}^n (v_i - \hat{v}_i)^2 + \lambda_\eta \sum_{i=1}^n (\eta_i - \hat{\eta}_i)^2 \quad (11)$$

式中： n 为训练样本数； η_i 为模型第 i 个功率利用效率输出值； v_i 为模型第 i 个风速输出值； $\hat{\eta}_i$ 为第 i 个训练样本的功率利用效率标签值； \hat{v}_i 为第 i 个训练样本的风速标签值； \hat{P}_i 为第 i 个训练样本的

功率标签值； λ_v 为风速损失权重系数； λ_η 为功率利用系数损失权重系数。

该损失函数分为 3 个部分，1) 最小化拟合功率和实际功率的误差，用 $b\hat{v}_i$ 代替 bv_i 是为了提高该损失项的稳定性；2) 最小化图网络的风速预测值和实际风速的误差；3) 最小化图网络的功率利用系数预测值和实际功率利用系数的误差。由于 3 个部分分别对应功率、风速、功率利用系数的误差，数值尺度差别很大，本文使用 PSO 对权重进行优化， λ_v 和 λ_η 为待优化变量，以得到最优的损失函数。

4) 训练 GCN 模型。使用误差反向传播更新 GCN 模型参数。

2.3 中长期风功率预测

完成训练后，即可利用历史气象数据和未来一段时间的数值气象预报 (numerical weather prediction, NWP) 数据进行中长期风功率预测，以未来 10 天预测为例，具体流程如下。

1) 从目标场站附近多个气象站点获取历史气象数据和未来 10 天的 NWP 数据进行预处理，每个节点目标时刻的输入是一个长度为 s 的向量，该向量表示节点变量从 s 个时间步长之前到目标时刻范围内的历史数据，输入模型的数据形状为 (s_{10}, N, s) ， s_{10} 表示未来 10 天时间点总数， N 表示模型节点个数。数据输入 GCN 模型，输出风速序列 $\{v\}$ 和功率利用率序列 $\{\eta\}$ 。

2) 对风速序列 $\{v\}$ 进行差分，得到风速差分序列 $\{\hat{v}\}$ ，再根据 $\{v\}\{\hat{v}\}\{\eta\}$ 和拟合所得的 a 、 b 、 c 参数代入式 (7) 即可得到未来 10 天预测风功率值序列 $\{P\}$ 。

3 算例结果与分析

3.1 风电场数据及误差评价指标

选取 2020 年国内 A 和 B 2 个风电场的历史风速-功率数据和邻近 6 个气象测站提供的气象数据作为数据组，2 个风电场的装机总容量分别为 100 MW 和 150 MW，选取的时段为 2020 年 1 月 1 日 12:00—2021 年 1 月 10 日 23:59，数据采样间隔为 15 min，共计 376 天 36 048 组数据，对异常值、缺失值清洗后得到数据集，取前 35 088 组数据为训练集、后 960 组数据为测试集。

数据中囊括了 2 个风电场不同海拔的全年气象，涵盖了雷电、冰雹、大风、短时强降雨、强对流天气等复杂天气数据 3 824 组和 3 164 组，测试集中风速、气温、湿度、气压的范围以及天气

情况如表 2 所示。从表 2 中可见，测试集的气象数据具有一定复杂性，包含了常见的天气类型，在一定程度上可以验证模型应对不同气象时的鲁棒性。

表 2 测试集部分气象数据范围
Table 2 Partial meteorological data range of test set

风电场	风速/(m·s ⁻¹)	气温/°C	湿度/%	气压/Pa	天气情况
A	0.41~10.42	-6.53~7.41	24.67~94.52	1021.79~1034.56	晴、阴、雪、雨
B	0.48~10.70	-14.95~4.69	20.89~93.92	850.60~861.31	阴、雪、冰雹、晴、扬沙

采用相对均方根误差 (RMSE) 和合格率 (PP) 为评价指标。

$$E_{\text{RMS}} = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{P_i - \hat{P}_i}{P_n} \right)^2} \times 100\% \quad (12)$$

式中： E_{RMS} 为相对均方根误差； N 为样本总数； P_i 为 i 时刻的预测功率； \hat{P}_i 为 i 时刻的实际功率； P_n 为风电场的总装机容量。

$$P_p = \frac{1}{N} \sum_{i=1}^N Q_i \times 100\% \quad (13)$$

$$Q_i = \begin{cases} 1, & \frac{|P_i - \hat{P}_i|}{P_n} < 0.25 \\ 0, & \frac{|P_i - \hat{P}_i|}{P_n} \geq 0.25 \end{cases} \quad (14)$$

式中： P_p 为合格率； Q_i 为 i 时刻合格评分。

3.2 风速-功率 DF 模型参数拟合

首先根据 A 和 B 风电场历史风功率散点图确定 $v_{\text{in}} \sim v_r$ 的范围，数据清洗后 2 个风电场的历史风功率散点图如图 6 所示。

估计 A 和 B 风电场的 v_{in} 和 v_r 分别为 1.5 m/s 和 9 m/s。使用 $v_{\text{in}} \sim v_r$ 范围内的数据拟合 2 个风电场风速-功率模型的 a 、 b 、 c 参数，A: $a = 5.2346$, $b = -0.1374$, $c = 1.9754$; B: $a = 5.3292$, $b = -0.1655$, $c = 6.4749$ 。

3.3 GCN_DF_PSO 模型的构建与训练

首先根据气象测站的数据和表 1 确定 GCN 网络的输入节点个数。

月份和小时时间向量有 12+24=36 个节点；气温、湿度、空气密度每个测站提供一组数据，则有 3×6=18 个节点；风向对应 48 个节点；气压梯度对应 15 个节点；每个测站分别提供 10 m、

30 m、50 m 和 70 m 高度的风速，则有 4×6=24 个节点，总计 141 个输入节点。输入节点和邻接关

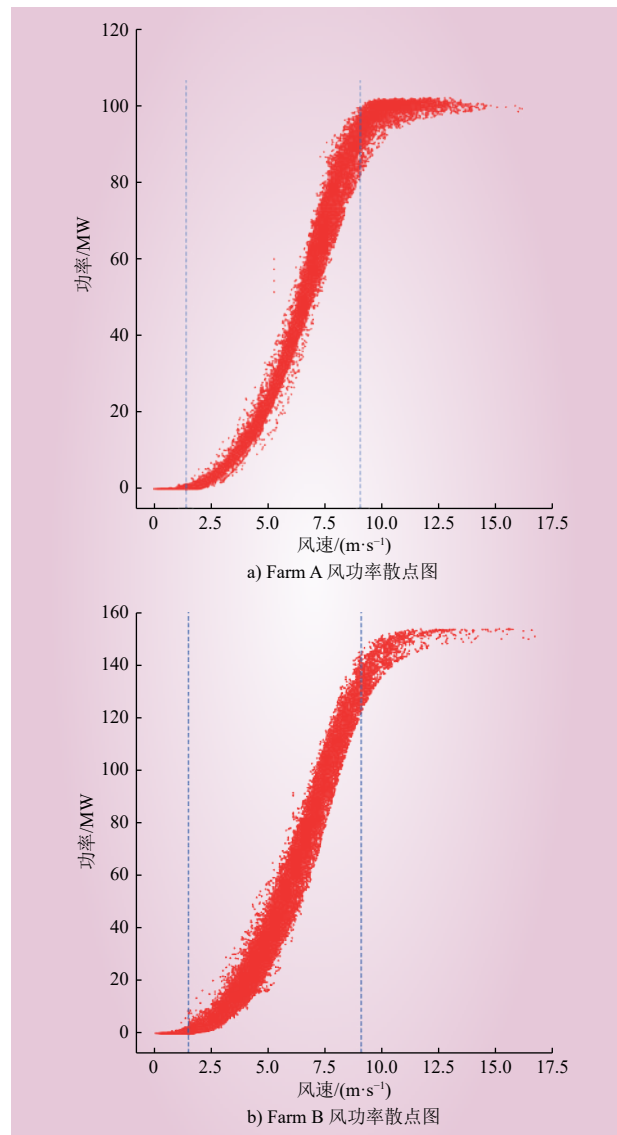


图 6 风电场的风功率散点图

Fig. 6 Wind power scatter plot of wind farms

系确定后, 搭建 GCN_DF_PSO 网络, 并按 2.2 节所述步骤确定损失函数权重, 并训练模型, 经过 PSO 算法优化后的损失函数权重, 其中, 风电场 A: $\lambda_v = 10^{1.7732}$ 、 $\lambda_\eta = 10^{7.7732}$; 风电场 B: $\lambda_v = 10^{1.3712}$ 、 $\lambda_\eta = 10^{6.9425}$ 。

将前 s 个时间步长的气象数据输入模型, 即可得到当前时间步长的风功率预测值。综上, 预测模型构建完成, GCN 网络和风速-功率模型相结合, 并基于 PSO 优化的 GCN_DF_PSO 模型即为本文的预测模型。

3.4 预测结果验证与对比

取 $s = 128$, 经过训练和测试, GCN_DF_PSO 模型针对 A 和 B 2 个风电场的风速和风功率预测结果如图 7 所示, 风功率预测未来 10 天的平均相对均方根误差分别为 11.44% 和 13.09%。

其中第 10 天 2 个风电场的风速和风功率预测结果如图 8 所示, 第 10 天的相对均方根误差分别为 16.97% 和 21.20%。

为验证本文所使用的 GCN_DF_PSO 模型的有效性及其鲁棒性, 将本文模型与卷积神经网络 (CNN_DF_PSO)、全连接神经网络 (DNN_DF_PSO)、长短时记忆网络 (LSTM_DF_PSO) 进行对比, 这 4 种模型均先预测风速, 再使用 DF 模型计算功率, 并使用相同的损失函数。为验证文本所使用的基于 PSO 优化 DF 模型的有效性, 使用 GCN、DNN、LSTM、CNN 4 种模型直接预测功率, 使用功率的均方误差作为损失函数。上述试验中 DF 和 PSO 需要同时使用或弃用, 使用时模型同时输出 v 和 η , 以式 (10) 为损失函数, 不使用时模型直接输出 P , 损失函数为

$$L = \sum_{i=1}^n (P_i - \hat{P}_i)^2 / n \quad (15)$$

对每种方法进行 10 次试验, 在测试集上计算评价指标平均值, 预测结果的评价指标如表 3 所示。分析表 3 的结果可知: 基于 GCN 的模型相较于基于 CNN、DNN、LSTM 模型的准确率更高, 这验证了 GCN 模型对数据特征先验关系的有效利用; 基于 PSO 优化的 DF 模型相较于直接预测功率的模型具有更高的准确率, 验证了本文所提模型在提升功率计算准确率、降低模型拟合复杂度的有效性。

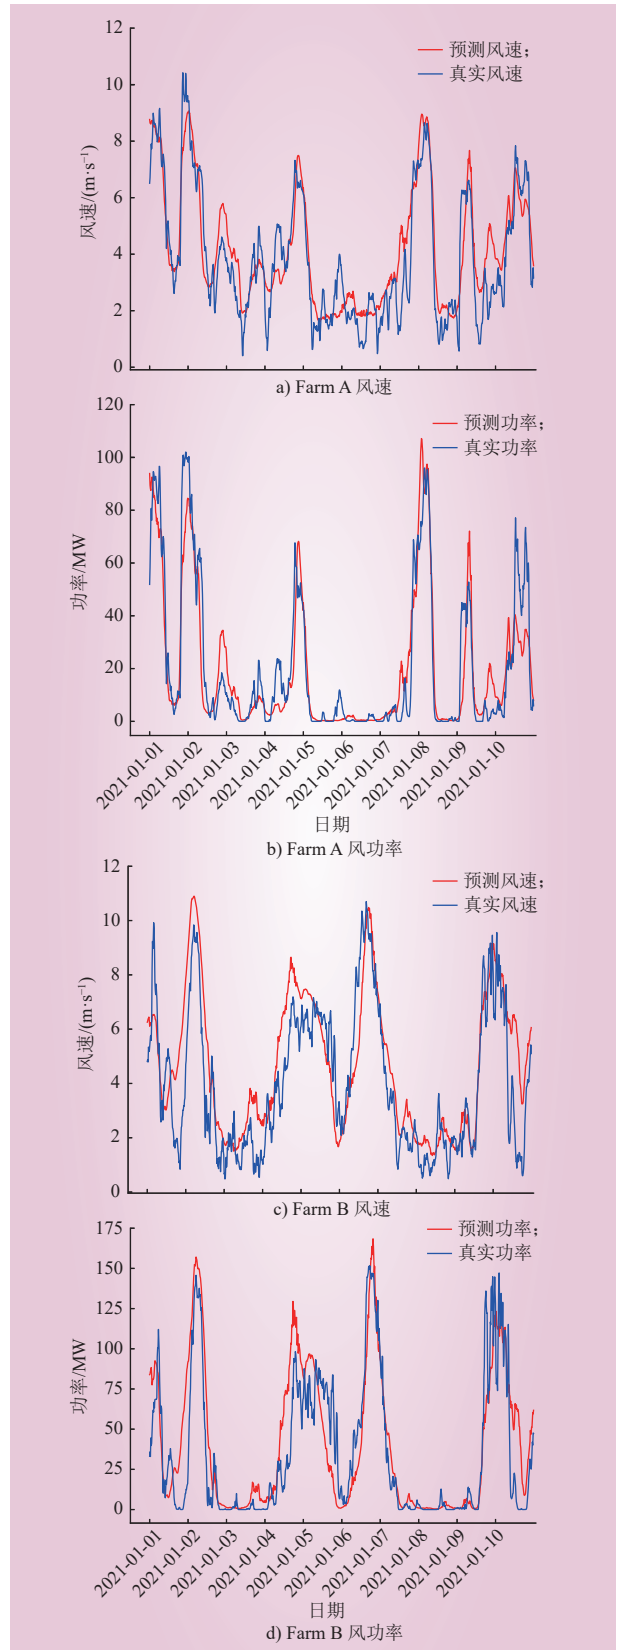


图 7 GCN_DF_PSO 模型的风速和风功率预测结果
Fig. 7 Wind velocity and wind power prediction results of GCN_DF_PSO model

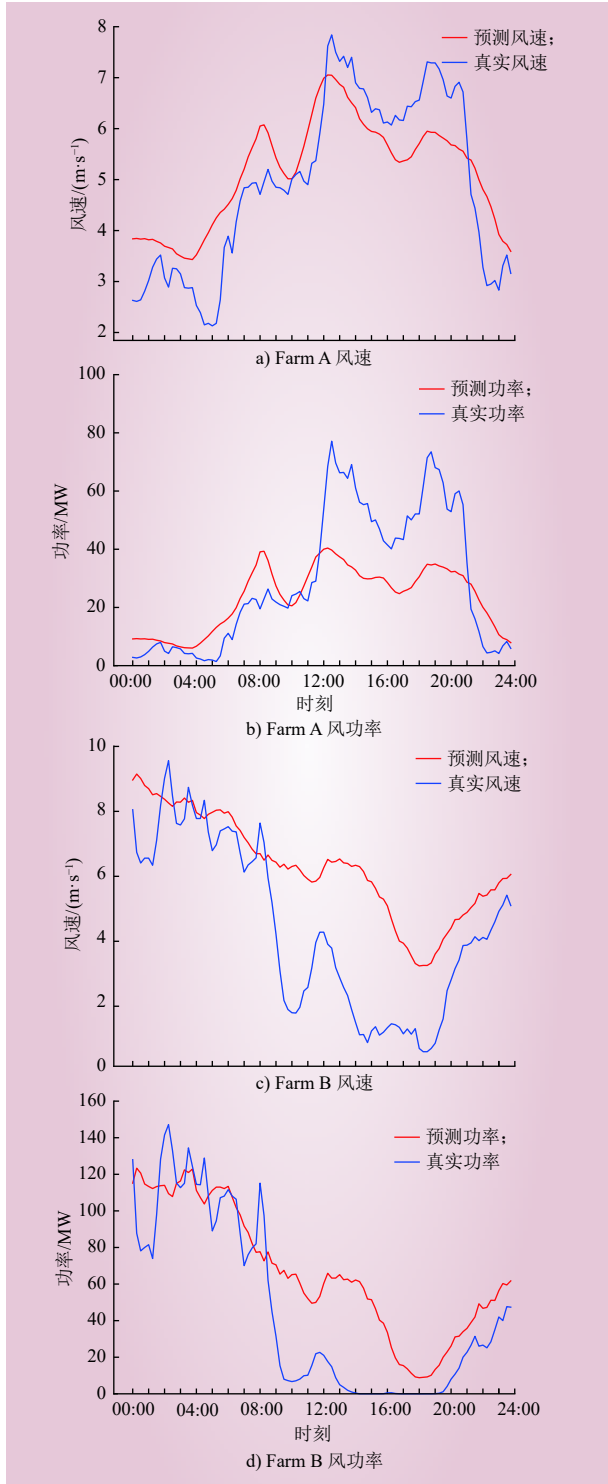


图 8 GCN_DF_PSO 模型第 10 天的风速和风功率预测结果
Fig. 8 Wind velocity and wind power predicted by GCN_DF_PSO model on day 10

4 结论

本文采用 GCN 模型充分利用了气象数据特征

表 3 各方法预测结果评价指标对比
Table 3 Comparison of evaluation index of prediction results of each method

风电场	方法	$E_{RMS}/\%$	$P_p/\%$
A	GCN_DF_PSO	11.44	95.04
	CNN_DF_PSO	14.38	90.11
	DNN_DF_PSO	12.14	93.66
	LSTM_DF_PSO	14.29	90.89
	GCN	13.81	90.28
	CNN	13.08	91.71
	DNN	15.50	87.05
	LSTM	19.90	81.36
B	GCN_DF_PSO	13.09	91.76
	CNN_DF_PSO	14.73	90.43
	DNN_DF_PSO	16.11	87.14
	LSTM_DF_PSO	16.23	88.24
	GCN	16.57	86.99
	CNN	15.15	88.09
	DNN	16.45	85.93
	LSTM	17.85	83.99

间的先验关系，并采用 PSO 优化 DF 风速-功率计算模型的损失函数权重，形成了 GCN_DF_PSO 复合模型，经过验证，该模型在面对未来 10 天的风功率预测中可以有效提升预测精度，在针对 2 个风电场的预测实例中，10 天总体的相对均方误差为 11.44% 和 13.09%，准确率为 95.04% 和 91.76%，预测效果好于对比的其他模型，验证了提出的方法及中长期风功率预测模型的准确性。

参考文献：

[1] 曹钰, 房磊. “双碳”背景下热发电机组-储热联合运行消纳弃风策略[J]. 中国电力, 2022, 55(10): 142-149, 160.
CAO Yu, FANG Lei. Combined operation strategy of CHP unit and heat accumulator for eliminate abandoned wind under "double carbon" background[J]. Electric Power, 2022, 55(10): 142-149, 160.

[2] 吴晓刚, 阎洁, 葛畅, 等. 基于改进 GRU-CNN 的风光水一体化超短期功率预测方法[J]. 中国电力, 2023, 56(9): 178-186, 205.
WU Xiaogang, YAN Jie, GE Chang, et al. Ultra-short-term power forecasting method for wind-solar-hydro integration based on improved GRU-CNN[J]. Electric Power, 2023, 56(9): 178-186, 205.

[3] 赵永宁, 李卓, 叶林, 等. 基于时空相关性的风电功率超短期自适应



- 预测方法[J]. 电力系统保护与控制, 2023, 51(6): 94–105.
- ZHAO Yongning, LI Zhuo, YE Lin, *et al.* A very short-term adaptive wind power forecasting method based on spatio-temporal correlation[J]. *Power System Protection and Control*, 2023, 51(6): 94–105.
- [4] 赵倩, 黄景涛. 基于 EMD-SA-SVR 的超短期风电功率预测研究[J]. *电力系统保护与控制*, 2020, 48(4): 89–96.
- ZHAO Qian, HUANG Jingtao. On ultra-short-term wind power prediction based on EMD-SA-SVR[J]. *Power System Protection and Control*, 2020, 48(4): 89–96.
- [5] 苗长新, 王霞, 李昊, 等. 基于数值天气预报风速误差修正的风电功率日前预测[J]. *电网技术*, 2022, 46(9): 3455–3464.
- MIAO Changxin, WANG Xia, LI Hao, *et al.* Day-ahead prediction of wind power based on NWP wind speed error correction[J]. *Power System Technology*, 2022, 46(9): 3455–3464.
- [6] 陆秋贤, 马刚, 涂孟夫. 基于 IEWT-FE-BO-LSTM 模型的超短期风功率预测[J]. *水电能源科学*, 2023, 41(1): 217–220.
- LU Qiuxian, MA Gang, TU Mengfu. Ultra-short-term wind power prediction based on IEWT-FE-BO-LSTM model[J]. *Water Resources and Power*, 2023, 41(1): 217–220.
- [7] 姜明洋, 徐丽, 张开军, 等. 基于季节指数调整的循环神经网络风速时间序列预测[J]. *太阳能学报*, 2022, 43(2): 444–450.
- JIANG Mingyang, XU Li, ZHANG Kaijun, *et al.* Recurrent neural network prediction of wind speed time series based on seasonal exponential adjustment[J]. *Acta Energetica Sinica*, 2022, 43(2): 444–450.
- [8] 李金龙, 王义民, 畅建霞, 等. 基于并行机器学习的风功率超短期预测[J]. *水力发电学报*, 2023, 42(1): 40–51.
- LI Jinlong, WANG Yimin, CHANG Jianxia, *et al.* Ultra-short-term wind power prediction based on parallel machine learning[J]. *Journal of Hydroelectric Engineering*, 2023, 42(1): 40–51.
- [9] YUAN C, TANG Y M, MEI R, *et al.* A PSO-LSTM model of offshore wind power forecast considering the variation of wind speed in second-level time scale[J]. *Mathematical Problems in Engineering*, 2021, 2021: 1–9.
- [10] ZHA W T, LIU J, LI Y L, *et al.* Ultra-short-term power forecast method for the wind farm based on feature selection and temporal convolution network[J]. *ISA Transactions*, 2022, 129: 405–414.
- [11] 陈海鹏, 李赫, 阚天洋, 等. 考虑风电时序特性的深度小波-时序卷积网络超短期风功率预测[J]. *电网技术*, 2023, 47(4): 1653–1665.
- CHEN Haipeng, LI He, KAN Tianyang, *et al.* DWT-DTCNA ultra-short-term wind power prediction considering wind power timing characteristics[J]. *Power System Technology*, 2023, 47(4): 1653–1665.
- [12] 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 forecasting based on CEEMDAN-GRA-PCC-ATCN[J]. *Journal of Shandong University (Engineering Science)*, 2022, 52(6): 146–156.
- [13] 马丽. 基于机器学习的中长期风功率预测方法研究[D]. 北京: 华北电力大学, 2020.
- MA Li. Research on medium and long-term wind power prediction method based on machine learning[D]. Beijing: North China Electric Power University, 2020.
- [14] 何健伟, 曹渝昆. LSTM-RF 的中长期风电功率组合预测方法[J]. *上海电力大学学报*, 2020, 36(4): 341–350.
- HE Jianwei, CAO Yukun. Wind power mid-long term load forecasting based on LSTM-RF combination forecasting method[J]. *Journal of Shanghai University of Electric Power*, 2020, 36(4): 341–350.
- [15] 李铭. 基于风电场气象数据的风功率预测[D]. 包头: 内蒙古科技大学, 2021.
- LI Ming. Wind power prediction based on meteorological data of wind farm[D]. Baotou: Inner Mongolia University of Science & Technology, 2021.
- [16] 朱满庭. 基于深度学习的风电功率预测研究[D]. 北京: 华北电力大学, 2021.
- ZHU Manting. Research on wind power prediction based on deep learning[D]. Beijing: North China Electric Power University, 2021.
- [17] HAN S, QIAO Y H, YAN J, *et al.* Mid-to-long term wind and photovoltaic power generation prediction based on copula function and long short term memory network[J]. *Applied Energy*, 2019, 239: 181–191.
- [18] AHMED S I, RANGANATHAN P, SALEHFAR H. Forecasting of mid- and long-term wind power using machine learning and regression models[C]//2021 IEEE Kansas Power and Energy Conference (KPEC). Manhattan, KS, USA. IEEE, 2021: 1–6.
- [19] WU Y X, WU Q B, ZHU J Q. Data-driven wind speed forecasting using deep feature extraction and LSTM[J]. *IET Renewable Power Generation*, 2019, 13(12): 2062–2069.
- [20] WANG X X, LIU Y R, HOU J C, *et al.* Medium- and long-term wind-power forecasts, considering regional similarities[J].



Atmosphere, 2023, 14(3): 430.

[21] 孙骊洲, 付敬奇, 朱峰. CGAQPSO 优化 LSSVM 短期风电预测 [J].

电子测量与仪器学报, 2016, 30(11): 1718–1725.

SUN Sizhou, FU Jingqi, ZHU Feng. Short-term wind power prediction based on LSSVM optimized by chaos Gauss attractor quantum-behaved particle swarm optimization[J]. *Journal of Electronic Measurement and Instrumentation*, 2016, 30(11):

1718–1725.

作者简介:

陈子含 (1999—), 男, 硕士研究生, 从事深度学习风功率预测技术研究, E-mail: orczh_hj@163.com;

滕伟 (1981—), 男, 通信作者, 博士, 教授, 从事电力装备的状态监测、故障诊断与寿命预测研究, E-mail: tengw@ncepu.edu.cn.

(责任编辑 许晓艳)

Medium and Long Term Wind Power Prediction Based on Graph Convolutional Network and Wind Velocity Differential Fitting

CHEN Zihan¹, TENG Wei¹, XU Xuefeng², DING Xian², LIU Yibing¹

(1. Key Laboratory of Power Station Energy Transfer, Conversion and System, Ministry of Education, North China Electric Power University, Beijing 102206, China; 2. China Green Development Investment Group Co., Ltd., Beijing 100020, China)

Abstract: In order to make full use of the prior relationships among data features and improve the prediction accuracy of medium and long term wind power at wind farms, a medium and long term wind power prediction model based on graph convolution neural network (GCN), wind velocity differential fitting (DF), and particle swarm optimization (PSO) is proposed. By analyzing the whole process of wind power generation, the influencing factors of wind power and the interrelation among them are explored, and the GCN model is built. The wind velocity and power utilization efficiency are fitted respectively. The wind power is calculated by combining with the wind velocity–power calculation model based on DF. The loss of the model includes three parts: power loss, wind velocity loss and power utilization efficiency loss. PSO algorithm is used to determine the appropriate weight for the three losses. The on-site examples of two wind farms show that the relative root mean square error of the wind power prediction model in the next 10 days is 11.44% and 13.09%, respectively, which has a high prediction accuracy.

This work is supported by National Natural Science Foundation of China (Intelligent Fault Diagnosis and Life Prediction of Wind Turbine Group under Semi-Supervised Environment, No.51775186).

Keywords: wind power generation; wind power prediction; graph convolutional neural network; wind velocity differential fitting; particle swarm optimization algorithm