文章编号:1674-7607(2026)02-0098-15 DOI:10.19805/j.cnki.jcspe.2026.250174

风功率预测关键技术及其研究应用综述

王 磊, 滕 伟, 武 鑫, 高青风, 柳亦兵
(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)

摘 要: 风电有显著的间歇性与随机性特征,其输出功率随风速变化剧烈波动,特别是在电网疏散、渗透和并网方面,给电力系统的管理带来许多挑战。风功率预测技术作为缓解风电不确定性的核心手段,对提升电网稳定性、降低弃风率、优化电力市场交易及推动风电可持续发展具有重要意义。系统地解析了风功率预测的类型划分、基本原理架构及主流方法,深入对比物理建模法、统计分析法、机器学习法、组合法等风功率预测方法的适用场景、优势、局限及评价指标体系。在此基础上,全面综述预测精度提升的关键技术路径,涵盖多源数据融合、深度学习算法优化、误差校正机制等前沿研究方向,并总结最新研究成果。最后展望了风功率预测技术的未来发展趋势,提出基于数字孪生、强化学习与气象耦合建模的创新解决方案。

关键词: 风功率; 预测; 精度; 机器学习; 预测模型
中图分类号:TK83 **文献标志码:**A **学科分类号:**470.30

A Review of Key Technologies and Research Applications in Wind Power Prediction

WANG Lei, *TENG Wei*, *WU Xin*, *GAO Qingfeng*, *LIU Yibing*
(Key Laboratory of Power Station Energy Transfer, Conversion and System, Ministry of Education, North China Electric Power University, Beijing 102206, China)

Abstract: Wind power exhibits significant intermittency and stochastic characteristics, with its output power experiencing severe fluctuations due to wind speed variations. This poses substantial challenges for power system management, particularly in grid dispersion, penetration, and grid connection. As a core means to mitigate wind power uncertainty, wind power prediction technology plays a crucial role in enhancing grid stability, reducing wind curtailment rates, optimizing electricity market transactions, and promoting the sustainable development of wind power. This study systematically analyzed the classification, fundamental principles, and mainstream methodologies of wind power prediction, conducting an in-depth comparisons of the application scenarios, advantages, limitations, and evaluation index systems of various wind power prediction methods, such as physical modeling, statistical analysis, machine learning, and hybrid methods. Based on this, a comprehensively review was presented about the key technological pathways for improving prediction accuracy, covering cutting-edge research directions such as multi-source data fusion, deep learning algorithm optimization, and error correction mechanisms, and the latest research findings were also summarized. Finally, the prospect of the future development trends in wind power pre-

收稿日期:2025-03-27 **修订日期:**2025-05-07
基金项目:国家自然科学基金资助项目(51775186)
作者简介:王 磊(1986—),男,河南确山人,博士,研究方向为风电机组故障,E-mail:hais1998@163.com。

diction technology was provided, proposing innovative solutions based on digital twins, reinforcement learning, and meteorological coupled modeling.

Key words: wind power; prediction; accuracy; machine learning; prediction model

在“碳达峰、碳中和”战略目标指引下，我国成为全球最大的风能市场，2024 年风电装机容量达 86.99 GW，累计并网容量突破 5.3 亿 kW·h，占全球总装机容量的近 45%[1]。在此基础上，我国于 2025 年提出构建以高比例新能源消纳、清洁低碳、安全高效为核心特征的新型电力系统[2]。风具有很强的不确定性，如风速、风向随时间不断变化，同时也具有阵风特性，即风速在短时间内突然增大，形成阵风[3]。风电输出在风的作用下具有不可消除的随机性、间歇性和不确定性，为风电并网和电力调度与消纳带来巨大挑战[4]。风功率预测对于缓解电网调峰压力、减小电力系统备用容量、提高风功率注入水平与系统可靠性具有重要意义[5]。本文介绍了风功率预测的分类、主要方法及其优缺点，预测精度的评价指标及适用性，提升风功率预测精度的技术手段等，最后探讨了风功率预测技术未来的发展趋势。

1　风功率预测的分类

1.1　按时间尺度预测分类

时间尺度是风功率预测最核心的分类依据，直接影响模型的选择与优化方向[6]。

(1) 长期预测(时长 1 周至数月)：用于风电场选址规划与电网扩容评估。主要方法包括气候模式降尺度分析、历史数据趋势外推及贝叶斯层次模型[7]。

(2) 中期预测(3 d 至一周)：用于支撑风电场运维计划与跨区域电力交易。关键技术为计算流体力学(computational fluid dynamics，CFD)与天气研究和预报模型(weather research and forecasting model，WRF)的耦合模拟、数值天气预报值动态校正及随机森林集成学习[8-9]。

(3) 短期预测(4～72 h)：服务于电力市场竞价与机组组合优化，主流方法包括数值天气预报驱动的混合模型、梯度提升树(light gradient boosting machine，LightGBM)等[10]。

(4) 超短期预测(分钟级至 4 h)：主要应用于电网实时调度、频率控制、储能系统充放电决策等。常用方法为自回归积分滑动平均模型(autoregressive integrated moving average，ARIMA)、支持向量机(support vector machine，SVM)及长短时记忆网络(long short-term memory，LSTM)，结合边缘计算技术实现实时推理等[11]。

(5) 实时预测(秒级)：依托风电机组端部署轻量化模型，实现高频数据在线推理与频率紧急响应[12]。

1.2　按预测模型输出形式分类

(1) 确定性预测：输出为单一功率值，主要应用于基础调度决策，需配合误差区间使用[13]。

(2) 概率预测：输出功率概率分布(如分位数预测、密度估计)，主要用于量化不确定性，支撑风险感知型调度[14]。

(3) 区间预测：提供置信区间(如 95%置信度下的功率波动范围)，主要用于备用容量优化、电网规划等[15]。

1.3　按预测对象分类

(1) 单机预测：用来预测单个风力发电机组功率输出。主要技术手段有：湍流、尾流效应建模。

(2) 场站级预测：需建模尾流效应、机组间风速空间差异及复杂地形影响，常用方法有 WRF-CFD 耦合模拟与时空图卷积网络(spatio-temporal graph convolutional network，STGCN)[16]。

(3)区域级：用来预测多个风电场的联合输出功率技术难点，包括广域气象传播延迟建模、多风电场电网约束集成等[17]。

2　常用风功率预测方法及关键技术

风功率预测的方法大致归为 4 类：物理建模方法、统计方法、机器学习方法和组合方法[18]。物理建模方法基于流体力学方程模拟风场与风电机组动态，需依赖高精度气象数据及风电机组参数，计算复杂度较高；统计方法基于历史数据和统计模型进行预测，常见的统计方法包括时间序列分析、回归分析和概率模型等[19]；机器学习方法基于多维数据(如风速、风向、温度、气压、历史功率等)及实时气象数据，建立输入特征与输出功率之间的非线性映射关系，让模型从数据中学习规律，从而预测未来时刻的风功率[20]。组合方法是统计方法和物理建模方法的结合，以提高预测的准确性和可靠性[21]。

2.1 物理建模方法

物理方法基于气象学原理，通过数值天气预报(NWP)模型来预测未来时段的风速和风向，再结合风电机组的功率曲线计算出风功率[22]。该方法是最早应用于风功率预测的技术路径，其核心优势在于依赖气象学机理，适用于新建风场。物理建模方法预测主要流程如图 1 所示。

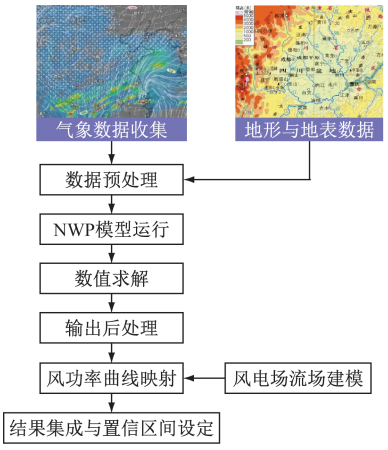


图 1 物理建模方法风功率预测流程

Fig. 1 Process of wind power prediction using physical modeling methods

基于 CFD 预计算的物理方法主要有：李莉等[23]提出一种短期风速预测方法，通过离散化风电场来流条件预先计算 CFD 流场，构建流场特性数据库，结合 NWP 数据插值预测轮毂高度风速，其年均绝对误差小于 2 m/s。基于数据驱动修正技术的物理方法主要有：Ouyang 等[24]利用数据挖掘算法建立多变量模型，修正 NWP 系统误差；Gu 等[25]则提出基于 t-SNE(t-distributed stochastic neighbor embedding)的 NWP 数据降维方法，通过归一化与可视化预处理显著提升预测效果。基于混合模型创新的物理方法主要有：牛东晓等[26]针对物理模型误差来源，提出误差源量化分析方法，为模型优化提供依据。基于工程优化与参数改进的物理方法有：朱霄珣等[27]基于粒子群优化算法(particle swarm optimization，PSO)优化最小二乘支持向量机(least squares support vector machine，LS-SVM)参数(正则化参数 γ、核宽度 δ 等)，建立高精度风速预测模型。冯双磊等[28]对基于物理原理的风电场功率预测方法进行研究，提出了适用于工程应用的预测方法，该方法采用解析原理分析风电场局地效应与风电机组尾流影响。

受数值天气预报计算网格分辨率与模式的影响，提高 NWP 数据的准确性是改善预测结果的有效手段。一方面由于 NWP 数据更新频率较低(一般 1～3 h)，难以满足 15 min 超短期预测的要求，因此物理方法通常仅适用于短期及中长期预测；另一方面，物理方法的预测精度不高，因此直接使用 NWP 的物理预测模型时精度常常不满足应用需求。物理建模方法预测的优缺点如表 1 所示。

表 1 风功率预测物理建模方法的优缺点

Tab. 1 Advantages and disadvantages of physical modeling methods for wind power prediction

优点	缺点
独立性高，不依赖历史数据	算力消耗大
可解释性强，逻辑结构清晰	风电流场精确建模难度高
适应性强	建模复杂度高

物理预测方法通过严谨的机理建模，为风功率预测提供了可靠的理论基础，但其实际效能依赖于气象数据质量、模型精细化程度及计算资源的协同优化[29]。

物理建模预测法技术未来的发展方向为：(1) AI-物理混合模型，如物理信息神经网络(physics-informed neural network，PINN)嵌入流体力学约束；(2) 实时同化技术，融合数据采集与监视控制系统(supervisory control and data acquisition，SCADA)数据动态修正预报偏差；(3) 量子计算加速，解决高分辨率模拟的计算瓶颈。

2.2 统计方法

统计方法不考虑风速的物理变化过程，通过统计算法得出风电场历史气象、电力数据所表现出的特征规律，然后结合实测功率数据或 NWP 数据预测风电场未来的发电功率[30]。统计方法避免了复杂的物理建模过程，但需要大量数据进行学习建模，适用于历史数据丰富且数据质量较高的场景。

2.2.1 时间序列分析

时间序列法基于历史数据的平稳性与自相关性构建模型，核心方法包括持续法、自回归移动平均模型(autoregressive moving average，ARMA)、自回归积分滑动平均模型(ARIMA)等。李丽等[31]提出小波变换改进持续法，将风速信号分解为高频(瞬变波动)与低频(趋势)分量，经重构与功率曲线转换提升预测精度。Yu 等[32]提出了一种包括时间序列互相关网络(TSCN)和 LSTM 解码器的 TSCN-LSTM 模型，用于预测 30 min 后的风力发电量。

时间序列法在风功率预测中具有计算效率高、可解释性强的优点，但对极端天气事件的突变性响应能力有限。实际应用中常需结合物理模型或深度学习模型提升预测精度。

2.2.2　回归分析

回归分析方法有：(1) 线性回归，通过建立风速、风向等气候变量与功率输出的线性映射关系，利用最小二乘法拟合参数，适用于数据分布平稳、变量间线性相关性显著的风电场；(2) 支持向量回归，通过核函数将线性回归问题映射到高位空间进行回归，适用于小样本数据。杨茂等[33]提出一种基于混合分位数回归长短期记忆神经网络的风功率短期区间预测方法。该方法兼顾复合、平滑和非交叉 3 种特点，通过区间预测评价指标，验证了所提模型的有效性和适用性。柳天虹等[34]提出一种基于分位数回归的改进权重门控循环单元(gated recurrent unit，GRU)风功率区间预测模型，通过风电场的有功功率进行实验验证，所提出的模型在相同实验条件下能提高预测精度。Huang 等[35]提出了一种使用非交叉分位数回归神经网络的风电概率预测模型。引入了一种使用时变滤波经验模态分解的数据预处理方法，以降低风电序列的波动性和复杂性。Yu 等[36]提出一种时空分位数回归算法，结合混合神经网络和分位数回归(quantile regression，QR)的优点，对区域风电进行短期非参数概率预测。

回归分析通过构建风功率与气象、设备参数之间的显式关系，为风电场提供可解释的预测模型。其优势在于灵活整合多源数据，但依赖高质量特征工程[37]。实际应用中，常与时间序列法或深度学习结合，形成混合模型以提升预测精度。统计方法风功率预测的优缺点见表 2。

表 2　统计方法风功率预测优缺点

Tab. 2　Advantages and disadvantages of statistical methods for wind power prediction

优点	缺点
计算效率高、实时性强	依赖历史数据质量与平稳性假设
模型可解释性强	非线性建模能力有限
小样本适应性较好	长期预测误差累积显著

统计方法在风功率预测中仍占据重要地位，尤其适用于数据量有限或实时性要求高的场景。未来需通过数据预处理优化、多模型协同及概率量化技术，进一步提升其鲁棒性与适用性。

2.3　概率预测法

风功率概率预测法旨在量化预测结果的不确定性，不仅提供点预测值，还输出概率分布信息[38]。该模型对电网调度、储能优化和风险控制等场景的决策至关重要[39]。其核心目标包括：(1) 量化气象与机组运行的不确定性；(2) 生成概率密度函数或分位数区间；(3)支持鲁棒性决策优化。为实现上述目标，当前主流方法有：分位数回归、贝叶斯方法、集成方法等[40]。风功率概率预测主要包括数据清洗、特征提取、分布建模及结果验证 4 个阶段[41]。具体实现流程如图 2 所示。

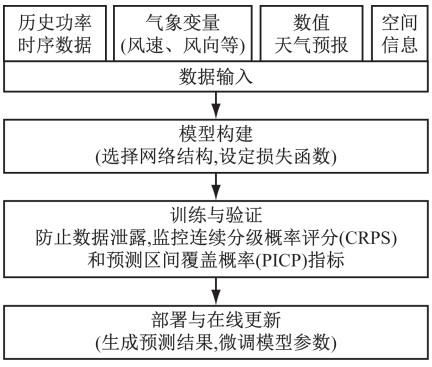


图 2　概率预测法风功率预测流程

Fig. 2　Process of wind power prediction using probabilistic prediction methods

杨楠等[42]提出一种风功率波动性概率建模方法，通过复数据经验模态分解与噪声辅助信号处理抑制高频噪声，并结合改进的非参数核密度估计量化不确定性。Zhang 等[43]进一步设计多步海上风电预测混合模型，融合时变滤波经验模态分解(TVFEMD)、近似熵与 Yeo-Johnson 变换分位数回归，利用高斯分位数近似提升多步预测的稳定性。Li 等[44]开发基于 PDF 的全局收敛自适应集成模型，通过多模态特征生成与自适应误差修正机制整合基准预测器，显著提升复杂场景下的概率预测鲁棒性。

概率模型通过量化风功率预测的不确定性，为电力系统提供更全面的决策支持。分位数回归和深度生成模型因其灵活性和高精度成为主流方法，而连续分级概率评分(continuous ranked probability score，CRPS)和预测区间覆盖概率(prediction interval coverage probability，PICP)是评估概率预测性能的核心指标。未来趋势将聚焦于时空概率建模、多源数据融合及在线学习技术的结合[45]。

2.4　机器学习方法

在风功率预测中，机器学习方法因其强大的非线性建模能力和对多源数据的兼容性，已成为提升预测精度的关键技术。

2.4.1　传统有监督机器学习法

传统有监督机器学习法主要有：(1) 随机森林法，它是一种基于多棵决策树的集成学习算法，其最终预测结果通过投票(分类任务)或平均(回归任务)

所有基决策树的输出获得。该算法尤其适用于中等规模的数据集[46]。(2) 极限梯度提升/轻量梯度提升(XGBoost/lightGBM),利用梯度提升决策树(gradient boosting tree,GBT)的优化,自定义损失函数,主要用于数据规模大的场景[47-48]。(3) 支持向量回归,通过核函数将数据映射到高维空间,寻找最优超平面拟合非线性关系,主要应用于样本数据量较小,样本数据具有强非线性关系的场景[49-50]。Lahouar 等[51]根据相关性和重要性度量选择空间平均风速和风向,提出了随机森林方法来构建小时级风功率预测。李进友等[52]提出一种基于极限梯度提升-广义回归神经网络(XGBoost-GRNN)的风功率预测算法,建立考虑分段式风电数据的风电机组功率预测模型,以获取准确性较高、误差较小的功率预测值。林涛等[53]利用 SCADA 数据建立支持向量回归模型,来预测单个风力发电机的功率与风力、气象、运行状态的关系,考虑到不同空间位置的风力发电机组对风电场输出功率的贡献不同,建立了各风力发电机预测功率和风电场预测功率输出之间的回归模型。

2.4.2 深度学习方法

深度学习方法凭借强大的非线性建模能力与复杂时序模式捕捉特性,成为风功率预测的核心技术。其对含噪声原始数据的敏感性低,兼具高可靠性、稳定性及准确性[54]。深度学习方法神经网络学习模型有多种,如表 3 所示。

表 3 深度学习方法不同模型风功率预测优缺点

Tab. 3 Advantages and disadvantages of different deep learning models for wind power prediction

模型类型	优点	缺点	适用场景	参考文献
卷积神经网络(CNN)	捕捉局部模式,参数共享减少计算量,适合空间相关性建模	对长时序依赖,建模能力有限	多风电场联合预测(CNN-LSTM),高频数据的空间特征提取	[55-56]
前馈神经网络(FNN)	结构简单,训练快速,适合静态数据建模	无法处理时序依赖,对空间/时间结构不敏感	简单的风速-功率曲线拟合,结合滞后特征的短期预测	[57-59]
Transformer	并行计算高效,长程依赖建模强,适合超长序列	数据需求量大,计算资源消耗高,需精细调参	中长期预测(24～72 h),复杂气象波动建模(如台风路径影响)	[60-61]
生成对抗网络(GAN)	生成多样化场景,增强数据丰富性,适合概率预测	训练不稳定,存在模式坍塌风险,结果解释性差	极端天气多场景生成,数据增强(合成罕见天气样本)	[62-63]
深度强化学习(DRL)	动态适应环境变化,支持预测-调度联合优化	需精准环境建模,训练复杂度高,收敛困难	实时调度优化(储能充放电策略),在线学习适应长期变化(风电机组老化)	[64-65]
自编码器(AE/VAE)	有效降维去噪,支持数据生成和特征提取	直接预测能力弱,常需与其他模型结合	数据降噪(SCADA 异常值处理),特征压缩(气象数据降维)	[66-67]
LSTM/GRU	适合时序数据,可处理多变量输入,长期记忆能力强	训练速度慢,超长序列效果下降,计算资源消耗高	单/多变量短期预测(1～24 h),动态时序模式建模	[68-69]

机器学习方法在风功率预测中展现出显著优势,尤其在处理高维非线性数据与复杂时空关联性方面[70-71]。然而,其实际应用仍面临数据异构性(如多源数据融合困难)、模型泛化能力不足(如跨风电场迁移失效)及实时性瓶颈(如边缘端计算资源受限)三大挑战。未来需结合新兴技术突破上述限制。

(1) 多模态 AI 技术:融合气象图像、文本(运维日志)与时序数据,构建多模态输入模型。

(2) 可解释性增强:应用 SHapley 值加和解释(SHapley additive explanations,SHAP)或局部可解释模型(local interpretable model-agnostic explanations,LIME)技术,提升深度学习的决策透明度。

(3) 边缘-云协同架构:在风电机组端部部署轻量模型实现实时预测,云端负责进行大模型训练与更新。

2.5 组合方法

单一预测模型难以全面捕捉复杂非线性特征,尤其在极端天气下,单一预测模型因训练数据不足易产生显著偏差。组合预测方法通过融合多模型优势,利用模型多样性与互补性降低预测偏差与方差,已成为提升预测鲁棒性的主流策略[72]。其核心方法可分为加权平均组合与数据分解组合两类,分别通过动态权重分配和信号分解重构优化预测精度。加权平均组合方法通过评价指标动态调整各子模型的权重系数,实现预测结果的线性或非线性融合,典型流程如图 3 所示。

李军等[73]提出基于遗传算法(genetic algorithm, GA)优化最小二乘支持向量机(least squares support vector machine, LSSVM)与 ARIMA 的加权组合方法。通过均方根误差(RMSE)与平均绝对百分比误差(MAPE)动态修正权重系数,实现短期预测。Li 等[74]利用深度确定性策略梯度(deep deterministic policy gradient, DDPG)构建自

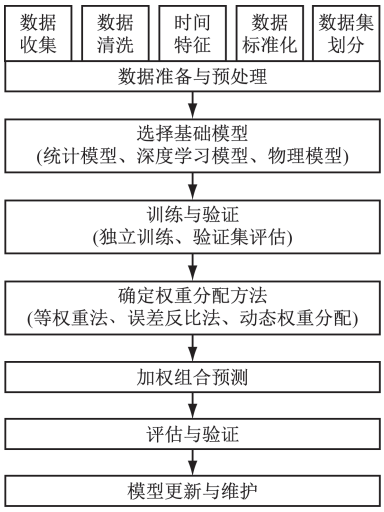


图 3　风功率预测加权组合方法流程

Fig. 3　Process of weighted combination method for wind power prediction

适应权重生成器，通过等似然指数与离散度指数筛选子模型，结合环境交互奖励机制动态调整权重，在风速突变场景下预测误差波动减小 18%。风功率预测数据分解组合方法通过信号分解技术（如经验横态分解（EMD）、小波变换）将原始功率序列解耦为多尺度子序列，分别建模后重构结果，流程如图 4 所示。



图 4　风功率预测数据分解组合方法流程

Fig. 4　Deterministic error indices for accuracy evaluation of wind power prediction

张学清等[75]提出 EMD-样本熵（sample entropy，SE）联合分解方法，根据复杂度差异构建 LSSVM、极限学习机（extreme learning machine，ELM）与岭回归改进的极限学习机（principle ridge regression-extreme learning machine，PRR-ELM）混合模型，通过相空间重构确定输入维度，超短期预测纳什效率系数（NSE）达 0.93。Azimi 等[76]开发基于时间序列行为（time series behavior，TSB）的 K-means 聚类与离散小波变换（discrete wavelet transform，DWT）混合方法，通过识别异常波动模式优化多层感知机（multilayer perceptron neural network，MLPNN）训练集，使风功率预测确定性系数（R^2）提升至 0.89。Jiang 等[77]设计变分模态分解（variational mode decomposition，VMD）-交叉注意力网络，利用余弦相关性筛选本征模态函数（IMF）分量，结合 LSTM 与 Transformer 提取时序依赖特征，从而实现多时间尺度预测误差降低 21%～34%。

组合方法通过集成多模型优势，显著提升了风功率预测的准确性和鲁棒性，尤其在处理非线性、非平稳数据时表现突出。

2.6　风功率预测关键技术

风功率预测的关键技术是指在风电场的运行管理中能够准确地预测风电场未来输出功率的一系列技术手段和方法，主要关键技术如下。

（1）高精度数值天气预报技术

高精度 NWP 技术是提升风功率预测精度的核心，尤其在应对风电随机性、时空关联性及复杂地形影响方面具有关键作用。Zhen 等[78]提出了一种基于重叠历史 NWP 的时空表示学习网络，从多组历史更新的 NWP 数据中提取潜在的气象预报信息，可以显著提升多风电场日内风电功率预测精度及稳定性。

（2）高效数据预处理与处理技术

风功率预测的高效数据处理技术是提升预测精度和实时性的关键，涉及数据预处理、特征工程、模型优化及计算加速等多个环节。付炳喆等[79]提出一种涵盖异常值检测、增强特征选择和超参数调整等多个环节的风电功率预测策略。通过新疆某风电场群 2019-01-01—03-03 的历史 NWP 与风电功率数据进行算例分析，数据采样间隔均为 15 min，共 5 664 个样本点验证，所提出的北方苍鹰优化算法（NGO）-CNN-GRU 模型与 CNN、GRU 和 LSTM 模型相比，R^2 平均提高了 4.44%，平均绝对误差（MAE）和均方根误差分别降低了 62.02% 和 61.51%，表明该模型在风电功率预测任务中具有较高的预测性能和准确性。

（3）先进预测模型与算法

先进预测模型与算法在风功率预测中扮演着核心角色，通过提升数据处理能力、捕捉复杂特征、优化模型性能及量化不确定性，显著提高了预测精度

与可靠性。薛阳等[80]为提高超短期风功率的预测精度,提出一种改进的基于变分模态分解的卷积神经网络(AVMD-CNN)、GRU 和注意力机制的超短期风功率预测模型。采用中国某风电场机组 2019-01-01—02-16 采集的风速、风向、温度、气压、实时风功率等共 9 维时间序列数据进行研究分析,实际算例表明,所提出模型的 R^2 较文中其他方法的 R^2 平均提高 12.06%。宋江涛等[81]为提高超短期风功率预测精度,提出一种基于率几何模态分解-样本熵(SGMD-SE)与优化的时间卷积网络-双向长短期记忆网络-双向门控循环单元(TCN-BiLSTM-BiGRU)组合预测模型,以新疆某风电场 2019-06-01—07-01 的实际风功率及 3 000 个气象数据为研究对象,所提模型相较于其他模型具有更优的预测效果,其 RMSE、MAPE、MAE、R^2 分别为 1.962 6 MW、1.558 5 MW、1.385 7%和 0.998 6。韩宇超等[82]针对风功率日前存在的预测问题提出一种混合预测模型,该模型采用 Transformer 网络结构和基于概率密度分布的区间预测框架,使用公开数据集 GEF-Com2014 中的 10 个风电场数据进行验证,在与其他 3 个对比模型的实验中,其所提方法的性能优异,不论在区间预测还是确定性预测方面都得到了最小误差。

(4) 误差分析与校正

误差分析与校正是提升预测精度和可靠性的关键环节,通过精准溯源、动态修正、不确定性管理等,使风功率预测从“粗放预测”转向“精细化调控”。丁华杰等[83]基于风电场日前功率预测“从风速到功率”的实际过程,提出了确定日前风电功率预测误差的分析方法。使用某装机容量为 100 MW 的风电场 2011-02—2012-02 的相关数据,通过对风电场功率特性曲线的拟合和对日前风速预测误差的模拟,使用最大似然估计技术,研究了两者对风电场日前功率预测误差的影响。与仅考虑风速预测误差的结果相比,考虑了功率特性拟合误差的风功率预测误差分布更加均匀、对称。张晓英等[84]针对实际风电场风电功率预测误差呈现出的季节、时序和功率变化特性,提出基于聚类分析与非参数核密度估计的方法研究风电功率预测误差的概率分布特性。以比利时电力运营商 Elia 公开的风电场 2016 年 1—12 月的风电功率预测值及实际生产值数据为研究对象,采用上面提到的方法进行处理,采用聚类分析的方法进行月份和时段的缩减,能有效地将误差特性相似的误差数据归为一组,避免过细描述预测误差而忽略整体特性。

3 风功率预测的精度评价

风功率预测模型的精度可通过确定性指标、概率性指标及适应性指标三类综合评价,以量化模型误差特征、不确定性和动态环境适应性,为电网调度、市场交易与风险管理提供科学依据。

3.1 确定性误差指标

确定性指标通过量化预测值与实际值的绝对或相对偏差,直接反映模型准确性,是优化算法与工程应用的核心依据,主要指标如表 4 所示。表中,$P_{a,i}$ 为第 i 时刻实际功率;$P_{p,i}$ 为第 i 时刻预测功率;N 为总样本数量;R_{MSE} 为平均方根误差;P_c 为风电场总装机容量。

表 4 风功率预测精度评价确定性误差指标

Tab. 4 Process of data decomposition and combination method for wind power prediction

评价指标	数学表达式	适用场景
均方根误差 RMSE	$\sqrt{\frac{1}{N}\sum_{i=1}^{N}(P_{a,i}-P_{p,i})^2}$	电网安全调度(需严控大偏差风险)
平均绝对误差 MAE	$\frac{1}{N}\sum_{i=1}^{N}\lvert P_{a,i}-P_{p,i}\rvert$	日常运维监控(均衡评估整体精度)
平均绝对百分比误差 MAPE	$\frac{1}{N}\sum_{i=1}^{N}\left\lvert\frac{P_{a,i}-P_{p,i}}{P_{a,i}}\right\rvert\times 100\%$	风电场间的预测性能排名
标准化均方根误差 NRMSE	$\frac{R_{MSE}}{P_c}\times 100\%$	不同规模风电场的预测精度对比
决定系数 R^2	$1-\frac{\sum_{i=1}^{N}(P_{a,i}-P_{p,i})^2}{\sum_{i=1}^{N}(P_{a,i}-P_{a,i}^{-1})^2}$	评估模型是否捕捉到功率变化的趋势

确定性误差指标是风功率预测评价的基础，在实际应用中（如电网调度、经济性分析、跨场对比等）可以灵活选择组合。

3.2　概率性指标

概率性指标评估预测区间或概率分布的可靠性、锐度与校准性，为不确定性量化提供依据。与确定性指标不同，概率性指标不仅关注预测值与实际值的偏差，还关注预测结果的可信度，从而为电网调度、电力市场投标和风险管理提供更全面的决策支持。具体指标如表 5 所示。表中，L_i 为预测区间下限；U_i 为预测区间上限；α 为置信水平；τ 为目标分位数；$l(\cdot)$为指示函数；$P_{\tau,i}$为模型预测的 τ 分位数值；$F_i(P)$为预测功率的累计分布函数；P 为实际观察功率值；y_i 为实际值；I_i 为第 i 个时间点的预测区间 L 在置信水平 α 下，时刻 i 的风功率预测区间的最小可能值；ΔY_i 为区间宽度；y_{nom} 为名义值（即参考值）。

表 5　风功率预测精度评价概率性误差指标

Tab. 5　Probabilistic error indices for wind power forecasting accuracy evaluation

评价指标	数学表达式	适用场景
预测区间覆盖率(PIC)	$\frac{1}{N}\sum_{i=1}^{N} l(P_{\mathrm{a},i} \in [L_i, U_i])$	验证预测区间是否合理（如风电参与电力市场时需确保报价区间覆盖实际出力）
平均预测区间宽度(APIW)	$\frac{1}{N}\sum_{i=1}^{N} (U_i - L_i)$	对比不同模型的预测区间效率
分位数损失(QL)	$\frac{1}{N}\sum_{i=1}^{N} [\tau \cdot \max(P_{\mathrm{a},i} - P_{\tau,i}) + (1-\tau) \cdot \max(P_{\tau,i}, P_{\mathrm{a},i}, 0)]$	训练概率预测模型（如分位数回归、准循环神经网络）
连续排名概率评分(CRPS)	$\frac{1}{N}\sum_{i=1}^{N} \int_{-\infty}^{\infty} [F_i(P) - 1(P \geqslant P_{\mathrm{a},i})]^2 \mathrm{d}P$	评估预测分布与实际分布的匹配度
区间锐度	$\frac{1}{N}\sum_{i=1}^{N} \begin{cases} -2\alpha \times \Delta Y_i - 4 \times (L - y_i), & y_i < L_i \\ -2\alpha \times \Delta Y_i, & y_i \in I_i \\ -2\alpha \times \Delta Y_i - 4 \times (L - U_i), & U_i < y_i \end{cases}$	主要用于奖励较窄的预测间隔且惩罚较宽的预测间隔，进而评估预测间隔的质量
归一化预测区间平均宽度(NPINAW)	$\sum_{i=1}^{N} (U_i - L_i)/(N \times y_{\mathrm{nom}})$	反映预测间隔的总体宽度，适用于大规模数据

3.3　适应性指标

适应性指标评估模型在动态环境下的鲁棒性、泛化能力与持续学习效率，确保其在数据分布变化、设备老化以及极端事件的冲击时，维持稳定且精准预测的能力。

3.3.1　时间滑动窗口稳定性

时间滑动窗口稳定性反映风功率预测模型在不同时间段的预测误差波动的程度。评价方法为将测试集划分为多个时间窗口（如每月一个窗口），计算各窗口误差的标准差，标准差越小越稳定。

3.3.2　跨风电场泛化能力

跨风电场泛化能力预测模型在未参与训练的风电场（不同地理位置、风电机组型号）中的预测性能保持率。评价计算方法为

$$G_{\mathrm{ER}} = \frac{T_{\mathrm{we}}}{S_{\mathrm{we}}} \tag{1}$$

式中：G_{RE}为归一化泛化误差率；T_{we}为目标风场预测误差；S_{we}为源风场预测误差。

当 $G_{ER} < 1.2$ 时，模型表现优秀；当 $G_{ER} > 1.5$ 时，模型偏差较大。

3.3.3　在线学习效率

在线学习效率预测模型增量更新后达到稳定性能所需的样本量或时间，评价指标有：(1) 收敛样本数，模型在新数据流中误差收敛至阈值（如比初始误差降低 90%）所需的最小样本数；(2) 遗忘率，模型在更新后对历史知识的保留能力，可通过旧数据集的误差变化率衡量。

3.3.4　鲁棒性指标

模型在输入数据异常（如噪声、缺失）或极端事件下的性能退化程度。评价方法有：(1) 在输入数据中添加高斯噪声（如±10%风速扰动），计算误差上升的比例。(2) 极端事件误差。

$$E_{\mathrm{EE}} = \frac{E_{\mathrm{ce}}}{N_{\mathrm{ce}}} \tag{2}$$

式中：E_{EE}为极端工况下预测模型的误差比；E_{ce}为极端时段误差；N_{ce}为正常时段误差。当 $E_{\mathrm{EE}} > 2.0$ 时，

模型在极端条件下鲁棒性不足。

4 提升风功率预测精度的技术手段及实际应用

风功率预测精度的提升依赖于数据质量优化、模型架构创新与算法优化的协同改进，需结合多源数据融合、物理规律嵌入及轻量化部署策略，为风电场运营与电网调度提供可靠性支撑[85]。

4.1 提升风功率预测精度的技术手段

4.1.1 数据质量优化

(1) 数据清洗与修复

数据清洗是风功率预测中至关重要的预处理步骤，直接影响模型的精度和可靠性[86]。常见数据问题与清洗方法有：(1) 异常值检测，剔除超出可行范围的值；(2) 缺失值处理，对于有些数据可以采用插值法进行时间序列插值；(3) 噪声平滑，用卡尔曼滤波小波变换等信号处理方法分离噪声频段并去噪。通过系统化数据清洗，可显著提升风功率预测模型的鲁棒性与精度，为后续建模奠定高质量数据基础，数据清洗流程如图 5 所示。

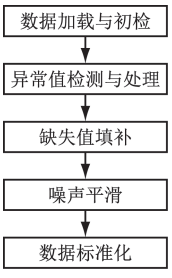


图 5 风功率预测数据清洗流程

Fig. 5 Process of data cleaning for wind power prediction

(2) 多元数据融合

通过整合多维度、多来源的数据，并确保其高质量和一致性，可显著增强模型的鲁棒性和泛化能力。多源数据类型有：数值天气预报、SCADA 系统数据、激光雷达(LiDAR)测风数据、卫星遥感数据等，通过不同层级的数据融合构建高维度输入特征。在实际应用中需结合风电场特性(如地形、设备类型)选择融合方法，并通过持续监控与迭代优化，实现预测性能的长期稳定提升。

4.1.2 预测模型架构创新

风功率预测模型的架构创新是提升预测精度与泛化能力的关键。随着深度学习、物理信息融合和新型网络结构的快速发展，学者们提出了多种创新架构以应对复杂的气象条件、空间异质性和动态系统特性。主要的模型架构有：(1) 物理-数据混合建模，将物理方程(如流体力学、风电机组功率曲线)嵌入数据驱动模型，实现物理规律与数据特征的协同优化。(2) 时空联合建模，旨在同时捕捉风电场内风电机组间的空间依赖关系(如尾流效应、地形影响)和时间动态变化(如风速波动和功率时序演化)。时空联合建模通过融合两者信息，显著提升了复杂场景下的预测精度。(3) 元学习与自适应建模，通过从多任务中学习共享知识，减少对目标场景数据的依赖，解决风功率预测模型在新风电场、季节变化或极端天气等动态环境下的快速适应问题。通过从多任务中提炼共享知识、动态调整模型行为，显著提升了风功率预测模型在新场景下的适应能力。风功率预测模型架构的创新正朝着物理-数据深度融合、时空多模态联合建模、自适应轻量化的方向发展。

4.1.3 模型算法优化

(1) 超参数智能调优

超参数调优是风功率预测模型优化的关键环节，直接影响模型的精度、训练效率和泛化能力。传统手动调参耗时且难以找到全局最优解，智能调优技术通过自动化搜索和优化策略，显著提升了调参效率。主要的调优方法见表 6。

表 6 不同模型优化算法优缺点的对比

Tab. 6 Comparison of advantages and disadvantages of different model optimization algorithms

调优方法	优点	缺点
贝叶斯优化	样本效率高，减少不必要的试验；通过高斯过程建模参数与目标关系，适合高成本调优；支持并行化与分布式优化	高维参数空间效果下降；初始阶段依赖随机采样，可能收敛到局部最优；实现复杂度高
遗传算法	全局搜索能力强，适合复杂非凸空间；支持离散与连续参数混合优化；天然并行化，适合分布式计算	收敛速度慢，需大量计算资源；算法参数(如种群大小、变异率)需手动调整；可能过早收敛到次优解
强化学习	动态适应环境变化，适合在线学习；可结合时序决策过程优化(如动态超参数调整)	实现复杂度高，需设计合理的奖励函数；训练代理模型耗时，需大量计算资源
网络搜索与随机搜索	简单直观，覆盖所有预设组合；结果确定性高，适合小规模参数空间	计算开销大，维数灾难问题显著；无法发现预设范围外的潜在最优解

超参数智能调优通过算法自动化替代人工试错，显著提升风功率预测模型的开发效率与性能。实践中需根据场景需求（如计算资源、参数规模）选择合适方法（贝叶斯优化、遗传算法等），并结合早停、并行化等策略优化资源利用。

（2）轻量化模型部署

轻量化模型部署旨在将复杂的高精度风功率预测模型转化为计算资源占用低、推理速度快、适合边缘设备（如风电机组本地控制器、边缘服务器）或云端微服务架构的轻量版本，同时尽可能保持预测性能。轻量化模型部署需从模型设计（剪枝、量化）、框架优化和硬件适配（边缘计算、NPU）三方面协同推进。

4.2　实际应用

挖掘预测模型关键影响因素，对相关参数进行持续不断的调整和优化是预测精度提升的必经之路。

4.2.1　外部环境方面

影响风功率预测精度的外部客观因素涉及数据采集、传输、处理等多个环节，其中测风塔布局与数据质量、通信通道的可靠性、气象数据来源的准确性等是核心因素。

（1）测风塔选址与传感器配置

测风塔的安装位置需能反映风电场全域的风资源分布。山地或复杂地形区域需通过线性拟合筛选最佳点位和高度，确保数据代表性强。在不同的测风高度安装适合的风速仪、风向标、温湿度传感器等设备以灵敏捕捉风切变及其他气象变化[87]。Buhan等[88]基于新的风型识别技术以及参考测风塔（RWM）数据与NWP的相关性，提出了一种新的统计方法，用于改进风力发电厂（WPP）的短期风电功率预测。所提出的模型已成功应用于7个装机容量在10～200 MW内的WPP的风功率预测。结果表明，所提出的风型识别技术和通过使用RWM为每个WPP开发的风对风模型带来了2.3%～5%的改进。

（2）数据传输与通信因素

数据传输要稳定可靠，比如采用光纤、无线数据传输单元（data transfer unit，DTU）等不同方式影响数据传输的实时性与可行性。数据传输前需进行完整性检验，对异常数据（如限电期间的功率突变）进行标识或修正，避免污染模型训练。

（3）气象数据

NWP的时空分辨率直接影响预测结果。例如，1 km×1 km的空间分辨率和15 min时间分辨率可显著提升模型输入数据的准确性。Sheng等[89]提出一种基于深度聚类改进的时间卷积网络（TCN）的短期风电功率预测方法，通过3个风电场的实际运行数据验证了所提风电功率预测方法的有效性和鲁棒性。结果表明：与其他传统预测方法相比，该方法可以将3个风电场的预测误差（均方根误差）从7.18%降低到12.87%。

4.2.2　预测算法及模型方面

在风功率预测中，算法和模型的性能直接影响预测精度及实用性。算法选择需综合考虑数据特性、环境复杂性及电力系统需求，而模型优化需从数据预处理、特征工程、算法融合等多维度突破。刘丽珺等[90]以黄土高原沟壑区的中国华电集团公司甘肃省环县南湫风电场为研究区域，首先利用CFD模拟风电场风速分布特征和划分风区，再利用Kalman滤波订正北京快速更新循环数值预报系统（BJ-RUC）模式预报的各风区长时间序列风速变化，并对比不同风区的订正效果，最终基于发电能力评估风电场的风功率预报效果与效益。结果表明，CFD与Kalman滤波的集成订正方法使风速预报准确率由BJ-RUC的20%～30%提高到90%以上，并使风功率预报准确率达到80%以上，显著提高了微尺度沟壑区的风速-风功率预报精度。

5　结论

（1）基于时间尺度的预测方法可适配电网规划、市场交易、实时调度等多元需求，但需结合物理建模与数据驱动方法提升精度。概率预测与区间预测通过量化不确定性，显著增强了电网调度决策的鲁棒性，但需进一步优化分位数回归与深度生成模型的效率。组合方法通过集成多模型优势，有效缓解了单一模型在极端场景下的性能退化问题，成为提升预测鲁棒性的主流策略。

（2）机器学习方法在非线性建模与时空特征提取方面表现突出，但面临数据异构性、模型泛化能力不足及边缘端部署效率低等挑战，需结合多模态融合与轻量化技术以优化数据质量并实现超参数的智能调优，这是提升预测精度的基础支撑。

（3）风功率预测技术正从单一模型驱动转向多源数据融合与物理-数据混合驱动，未来需在精度、实时性与可靠性3个维度持续突破，为构建高比例可再生能源的新型电力系统提供核心支撑。

（4）未来研究方向为：数字孪生与气象耦合建模，构建虚实交互的风电场数字孪生平台，实时同化

SCADA 数据与气象模型，动态修正预测偏差；强化学习与在线学习相结合，开发预测-调度联合优化框架，通过动态环境建模与增量学习适应风电场的长期变化；边缘-云协同架构，在单台风电机组边缘侧部署轻量级实时预测模型，实现秒级实时预测，云端通过联邦学习整合多风电场数据，提升模型泛化能力。

参考文献：

[1] 国家能源局. 国家能源局发布 2024 年全国电力工业统计数据[EB/OL]. (2025-01-21)[2025-03-17]. https://www.nea.gov.cn/20250121/097bfd7c1cd349-8897639857d86d5dac/c.html.

[2] 国家能源局. 章建华：全面构建现代能源体系 推动新时代能源高质量发展[EB/OL]. (2022-05-18)[2025-03-17]. https://www.nea.gov.cn/2022-05/18/c_1310597330.htm.

[3] 易俊，赵明欣，秦晓辉，等. 电碳协同理论技术探索与实践[J/OL]. 中国电机工程学报，[2025-03-13]. https://doi.org/10.13334/j.0258-8013.pcsee.242745.
YI Jun, ZHAO Mingxin, QIN Xiaohui, et al. Research on exploration and practice of electric-carbon coordination theory and technology[J/OL]. Proceedings of the CSEE, [2025-03-13]. https://doi.org/10.13334/j.0258-8013.pcsee.242745.

[4] 武鑫，冯歌，熊星宇. 用于风功率平抑的 SOEC 系统功率控制策略[J]. 动力工程学报，2023，43(12)：1626-1633，1674.
WU Xin, FENG Ge, XIONG Xingyu. Power control strategy of the SOEC system for smoothing wind power fluctuations[J]. Journal of Chinese Society of Power Engineering, 2023, 43(12): 1626-1633, 1674.

[5] EL RAFEI M, SHERWOOD S, EVANS J P, et al. Analysis of extreme wind gusts using a high-resolution Australian regional reanalysis[J]. Weather and Climate Extremes, 2023, 39: 100537.

[6] 王勃. 风力发电功率预测技术及应用[M]. 北京：中国电力出版社，2019.

[7] 国家能源局. 风电功率预测技术规定：NB/T 10205-2019[S]. 北京：中国电力出版社，2019.

[8] 国家能源局. 风电功率预测系统功能规范：NB/T 31046-2022[S]. 北京：中国电力出版社，2022.

[9] YU Guangzheng, LIU Chengquan, TANG Bo, et al. Short term wind power prediction for regional wind farms based on spatial-temporal characteristic distribution[J]. Renewable Energy, 2022, 199: 599-612.

[10] SHAO Lei, HUANG Wenxuan, LIU Hongli, et al. Study of wind power prediction in ELM based on improved SSA[J]. IEEJ Transactions on Electrical and Electronic Engineering, 2025, 20(6): 853-861.

[11] 曾娜梅，霍志红，许昌，等. 基于改进 HHT 的分钟级超短期风速预测[J]. 动力工程学报，2021，41(4)：309-315，329.
ZENG Namei, HUO Zhihong, XU Chang, et al. Minute-scale ultra-short-term wind speed prediction based on improved HHT[J]. Journal of Chinese Society of Power Engineering, 2021, 41(4): 309-315, 329.

[12] ZHANG Fei, LI Pengcheng, GAO Lu, et al. Application of autoregressive dynamic adaptive (ARDA) model in real-time wind power forecasting[J]. Renewable Energy, 2021, 169: 129-143.

[13] WANG Jianzhou, NIU Tong, LU Haiyan, et al. A novel framework of reservoir computing for deterministic and probabilistic wind power forecasting[J]. IEEE Transactions on Sustainable Energy, 2020, 11(1): 337-349.

[14] SUN Mucun, FENG Cong, ZHANG Jie. Multi-distribution ensemble probabilistic wind power forecasting[J]. Renewable Energy, 2020, 148: 135-149.

[15] CHEN Yinsong, YU S S, LIM C P, et al. Multi-objective estimation of optimal prediction intervals for wind power forecasting[J]. IEEE Transactions on Sustainable Energy, 2024, 15(2): 974-985.

[16] SHARMA N, BHAKAR R, JAIN P. Optimal reconciliation of hierarchical wind power forecasts of correlated wind farms[J]. Sustainable Energy, Grids and Networks, 2023, 35: 101091.

[17] OZKAN M B, KARAGOZ P. Reducing the cost of wind resource assessment: using a regional wind power forecasting method for assessment[J]. International Journal of Energy Research, 2021, 45(9): 13182-13197.

[18] 魏乐，戴泽，陈远野，等. 考虑多对一时空特征的短期风功率组合预测模型[J]. 动力工程学报，2024，44(12)：1869-1877.
WEI Le, DAI Ze, CHEN Yuanye, et al. Combined prediction model of short-term wind power by considering many-to-one spatial-temporal features[J]. Journal of Chinese Society of Power Engineering, 2024, 44(12): 1869-1877

[19] OUYANG Tinghui, ZHA Xiaoming, QIN Liang, et al. Prediction of wind power ramp events based on residual correction[J]. Renewable Energy, 2019, 136: 781-792.

[20] LIU Lei, LIU Jicheng, YE Yu, et al. Ultra-short-

term wind power forecasting based on deep Bayesian model with uncertainty [J]. Renewable Energy, 2023, 205: 598-607.

[21] LIU Zhuoyi, HARA R, KITA H. Hybrid forecasting system based on data area division and deep learning neural network for short-term wind speed forecasting[J]. Energy Conversion and Management, 2021, 238: 114136.

[22] CHEN Gonggui, TANG Bangrui, ZENG Xianjun, et al. Short-term wind speed forecasting based on long short-term memory and improved BP neural network[J]. International Journal of Electrical Power & Energy Systems, 2022, 134: 107365.

[23] 李莉，刘永前，杨勇平，等. 基于 CFD 流场预计算的短期风速预测方法[J]. 中国电机工程学报，2013，33(7)：27-32.
LI Li, LIU Yongqian, YANG Yongping, et al. Short-term wind speed forecasting based on CFD precalculated flow fields[J]. Proceedings of the CSEE, 2013, 33(7): 27-32.

[24] OUYANG Tinghui, HUANG Heming, HE Yusen. Ramp events forecasting based on long-term wind power prediction and correction[J]. IET Renewable Power Generation, 2019, 13(15): 2793-2801.

[25] GU Jiu, WANG Yining, XIE Da, et al. Wind farm NWP data preprocessing method based on t-SNE[J]. Energies, 2019, 12(19): 3622.

[26] 牛东晓，纪会争. 风电功率物理预测模型引入误差量化分析方法[J]. 电力系统自动化，2020，44(8)：57-65.
NIU Dongxiao, JI Huizheng. Quantitative analysis method for errors introduced by physical prediction model of wind power [J]. Automation of Electric Power Systems, 2020, 44(8): 57-65.

[27] 朱霄珣，韩中合. 基于 PSO 参数优化的 LS-SVM 风速预测方法研究[J]. 中国电机工程学报，2016，36(23)：6337-6342，6598.
ZHU Xiaoxun, HAN Zhonghe. Research on LS-SVM wind speed prediction method based on PSO [J]. Proceedings of the CSEE, 2016, 36(23): 6337-6342, 6598.

[28] 冯双磊，王伟胜，刘纯，等. 风电场功率预测物理方法研究[J]. 中国电机工程学报，2010，30(2)：1-6.
FENG Shuanglei, WANG Weisheng, LIU Chun, et al. Study on the physical approach to wind power prediction[J]. Proceedings of the CSEE, 2010, 30(2): 1-6.

[29] 孙荣富，张涛，和青，等. 风电功率预测关键技术及应用综述[J]. 高电压技术，2021，47(4)：1129-1143.
SUN Rongfu, ZHANG Tao, HE Qing, et al. Review on key technologies and applications in wind power forecasting [J]. High Voltage Engineering, 2021, 47(4): 1129-1143.

[30] 高志伟，王永平，杨根铨. 低纬度高海拔复杂地形风电功率预测预报技术[M]. 北京：气象出版社，2018.

[31] 李丽，叶林. 基于改进持续法的短期风电功率预测[J]. 农业工程学报，2010，26(12)：182-187.
LI Li, YE Lin. Short-term wind power forecasting based on an improved persistence approach [J]. Transactions of the Chinese Society of Agricultural Engineering, 2010, 26(12): 182-187.

[32] YU Ruiguo, SUN Yingzhou, LI Xuewei, et al. Time series cross-correlation network for wind power prediction[J]. Applied Intelligence, 2023, 53(10): 11403-11419.

[33] 杨茂，张书天，王勃，等. 基于混合分位数回归长短期记忆神经网络的风电功率短期区间预测[J]. 太阳能学报，2025，46(2)：582-590.
YANG Mao, ZHANG Shutian, WANG Bo, et al. Short-term wind power interval prediction based on mixed quantile regression long and short-term memory neural network[J]. Acta Energiae Solaris Sinica, 2025, 46(2): 582-590.

[34] 柳天虹，齐胜利，裔扬，等. 基于分位数回归的改进权重 GRU 风电功率区间预测[J]. 太阳能学报，2025，45(12)：291-298.
LIU Tianhong, QI Shengli, YI Yang, et al. Improved weighted GRU wind power interval prediction based on quantile regression[J]. Acta Energiae Solaris Sinica, 2025, 45(12): 291-298.

[35] HUANG Yu, LI Xuxin, LI Dui, et al. Probabilistic prediction of wind farm power generation using non-crossing quantile regression[J]. Control Engineering Practice, 2025, 156: 106226.

[36] YU Yixiao, HAN Xueshan, YANG Ming, et al. Probabilistic prediction of regional wind power based on spatiotemporal quantile regression [J]. IEEE Transactions on Industry Applications, 2020, 56(6): 6117-6127.

[37] WANG Yun, ZOU Runmin, LIU Fang, et al. A review of wind speed and wind power forecasting with deep neural networks [J]. Applied Energy, 2021, 304: 117766.

[38] WANG Sen, SUN Yonghui, ZHANG Wenjie, et al. Optimization of deterministic and probabilistic forecasting for wind power based on ensemble learning

[J]. Energy, 2025, 319: 134884.

[39] NAYAK A K, SHARMA K C, BHAKAR R, et al. Probabilistic online learning framework for short-term wind power forecasting using ensemble bagging regression model[J]. Energy Conversion and Management, 2025, 323: 119142.

[40] LI Yanting, WU Zhenyu, WANG Peng, et al. A farm-level wind power probabilistic forecasting method based on wind turbines clustering and heteroscedastic model[J]. Journal of Renewable and Sustainable Energy, 2024, 16(4): 043309.

[41] CHEN Yuejiang, HE Yingjing, XIAO Jiangwen, et al. Hybrid model based on similar power extraction and improved temporal convolutional network for probabilistic wind power forecasting[J]. Energy, 2024, 304: 131966.

[42] 杨楠, 黄禹, 叶迪, 等. 基于 NACEMD 和改进非参数核密度估计的风功率波动性概率分布研究[J]. 电网技术, 2019, 43(3): 910-917.
YANG Nan, HUANG Yu, YE Di, et al. Study on probability distribution of wind power fluctuation based on NACEMD and improved nonparametric kernel density estimation[J]. Power System Technology, 2019, 43(3): 910-917.

[43] ZHANG Wanying, HE Yaoyao, YANG Shanlin. A multi-step probability density prediction model based on Gaussian approximation of quantiles for offshore wind power[J]. Renewable Energy, 2023, 202: 992-1011.

[44] LI Jianfang, JIA Li, ZHOU Chengyu. Probability density function based adaptive ensemble learning with global convergence for wind power prediction [J]. Energy, 2024, 312: 133573.

[45] TAN Ling, CHEN Yihe, XIA Jingming, et al. Research on the short-term wind power prediction with dual branch multi-source fusion strategy[J]. Energy, 2024, 291: 130402.

[46] CUI Wenkang, WAN Can, SONG Yonghua. Ensemble deep learning-based non-crossing quantile regression for nonparametric probabilistic forecasting of wind power generation[J]. IEEE Transactions on Power Systems, 2023, 38(4): 3163-3178.

[47] CHEN Yuejiang, XIAO Jiangwen, WANG Yanwu, et al. Non-crossing quantile probabilistic forecasting of cluster wind power considering spatio-temporal correlation[J]. Applied Energy, 2025, 377: 124356.

[48] ARRIETA-PRIETO M, SCHELL K R. Spatially transferable machine learning wind power prediction models: v? logit random forests[J]. Renewable Energy, 2024, 223: 120066.

[49] KONG Lingxing, LIU Kailong, FU Deyi, et al. Wind power regression prediction based on stacked LSTMs with attention mechanisms for evaluating technological improvement effects of wind turbines [J]. Journal of Intelligent & Fuzzy Systems, 2023, 45(1): 51-62.

[50] PARRI S, TEEPARTHI K, KOSANA V. A hybrid VMD based contextual feature representation approach for wind speed forecasting[J]. Renewable Energy, 2023, 219: 119391.

[51] LAHOUAR A, BEN HADJ SLAMA J. Hour-ahead wind power forecast based on random forests[J]. Renewable Energy, 2017, 109: 529-541.

[52] 李进友, 李媛, 黄露秋, 等. 基于 XGBoost-GRNN 算法的分段式风功率预测[J/OL]. 计算机集成制造系统, [2023-10-07]. http://kns.cnki.net/kcms/detail/11.5946.tp.20230927.1028.004.html.
LI Jinyou, LI Yuan, HUANG Luqiu, et al. Piecewise wind power forecast based on the XGBoost-GRNN algorithm[J/OL]. Computer Integrated Manufacturing Systems, [2023-10-07]. http://kns.cnki.net/kcms/detail/11.5946. tp. 20230927.1028.004.html.

[53] 林涛, 董栅, 秦冬阳, 等. 基于支持向量回归的风电场短期功率预测[J]. 中南民族大学学报(自然科学版), 2017, 36(4): 95-99.
LIN Tao, DONG Shan, QIN Dongyang, et al. Short-term forecast of wind farm power based on support vector regression model [J]. Journal of South-Central University for Nationalities (Natural Science Edition), 2017, 36(4): 95-99.

[54] HANIFI S, CAMMARONO A, ZARE-BEHTASH H. Advanced hyperparameter optimization of deep learning models for wind power prediction[J]. Renewable Energy, 2024, 221: 119700.

[55] ZHANG Chu, MA Huixin, HUA Lei, et al. An evolutionary deep learning model based on TVFEMD, improved sine cosine algorithm, CNN and BiLSTM for wind speed prediction [J]. Energy, 2022, 254: 124250.

[56] ZHANG Yagang, PAN Zhiya, WANG Hui, et al. Achieving wind power and photovoltaic power prediction: an intelligent prediction system based on a deep learning approach[J]. Energy, 2023, 283: 129005.

[57] ADOMAKO A B, JAMSHIDI E J, YUSUP Y, et al. Deep learning approaches for bias correction in WRF model outputs for enhanced solar and wind energy estimation: a case study in east and west Malay-

sia[J]. Ecological Informatics, 2024, 84: 102898.

[58] BACKHUS J, RAO A R, VENKATRAMAN C, et al. Equipment health assessment: time series analysis for wind turbine performance[J]. Applied Sciences, 2024, 14(8): 3270.

[59] SHAO Haijian, DENG Xing, JIANG Yingtao. A novel deep learning approach for short-term wind power forecasting based on infinite feature selection and recurrent neural network[J]. Journal of Renewable and Sustainable Energy, 2018, 10(4): 043303.

[60] XIANG Ling, FU Xiaomengting, YAO Qingtao, et al. A novel model for ultra-short term wind power prediction based on vision transformer[J]. Energy, 2024, 294: 130854.

[61] YAN Leiming, WU Siqi, LI Shaopeng, 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.

[62] GOH H H, DING Chunyang, DAI Wei, et al. A hybrid short-term wind power forecasting model considering significant data loss[J]. IEEJ Transactions on Electrical and Electronic Engineering, 2024, 19(3): 349-361.

[63] MENG Anbo, ZHANG Haitao, YIN Hao, et al. A novel multi-gradient evolutionary deep learning approach for few-shot wind power prediction using time-series GAN[J]. Energy, 2023, 283: 129139.

[64] LIU Fang, LIU Qianyi, TAO Qing, et al. Deep reinforcement learning based energy storage management strategy considering prediction intervals of wind power[J]. International Journal of Electrical Power & Energy Systems, 2023, 145: 108608.

[65] ZHAO Jing, GUO Yiyi, LIN Yihua, et al. A novel dynamic ensemble of numerical weather prediction for multi-step wind speed forecasting with deep reinforcement learning and error sequence modeling[J]. Energy, 2024, 302: 131787.

[66] WANG Lin, TAO Rui, HU Huanling, et al. Effective wind power prediction using novel deep learning network: stacked independently recurrent autoencoder[J]. Renewable Energy, 2021, 164: 642-655.

[67] ZHENG Zhong, YANG Luoxiao, ZHANG Zijun. Conditional variational autoencoder informed probabilistic wind power curve modeling[J]. IEEE Transactions on Sustainable Energy, 2023, 14(4): 2445-2460.

[68] CHAKA M D, SEMIE A G, MEKONNEN Y S, et al. Improving wind speed forecasting at Adama wind farm II in Ethiopia through deep learning algorithms[J]. Case Studies in Chemical and Environmental Engineering, 2024, 9: 100594.

[69] WANG Shuangxin, SHI Jiarong, YANG Wei, et al. High and low frequency wind power prediction based on Transformer and BiGRU-Attention[J]. Energy, 2024, 288: 129753.

[70] SASSER C, YU Meilin, DELGADO R. Improvement of wind power prediction from meteorological characterization with machine learning models[J]. Renewable Energy, 2022, 183: 491-501.

[71] LÜ Jiaqing, ZHENG Xiaodong, PAWLAK M, et al. Very short-term probabilistic wind power prediction using sparse machine learning and nonparametric density estimation algorithms[J]. Renewable Energy, 2021, 177: 181-192.

[72] TASCIKARAOGLU A, UZUNOGLU M. A review of combined approaches for prediction of short-term wind speed and power[J]. Renewable and Sustainable Energy Reviews, 2014, 34: 243-254.

[73] 李军，贾志强. 基于模型组合的短期风功率预测研究[J]. 自动化应用，2021(9)：1-3.
LI Jun, JIA Zhiqiang. Research on short-term wind power prediction based on model combination[J]. Automation Application, 2021 (9): 1-3

[74] LI Menglin, YANG Ming, YU Yixiao, et al. Adaptive weighted combination approach for wind power forecast based on deep deterministic policy gradient method[J]. IEEE Transactions on Power Systems, 2024, 39(2): 3075-3087.

[75] 张学清，梁军，张熙，等. 基于样本熵和极端学习机的超短期风电功率组合预测模型[J]. 中国电机工程学报，2013，33(25)：33-40.
ZHANG Xueqing, LIANG Jun, ZHANG Xi, et al. Combined model for ultra short-term wind power prediction based on sample entropy and extreme learning machine[J]. Proceedings of the CSEE, 2013, 33(25): 33-40.

[76] AZIMI R, GHOFRANI M, GHAYEKHLOO M. A hybrid wind power forecasting model based on data mining and wavelets analysis[J]. Energy Conversion and Management, 2016, 127: 208-225.

[77] JIANG Li, WANG Yifan. A wind power forecasting model based on data decomposition and cross-attention mechanism with cosine similarity[J]. Electric Power Systems Research, 2024, 229: 110156.

[78] ZHEN Zhao, QIU Gang, MEI Shengwei, et al. An ultra-short-term wind speed forecasting model based on time scale recognition and dynamic adaptive mod-

eling[J]. International Journal of Electrical Power & Energy Systems, 2022, 135: 107502.

[79] 付炳喆，王玮，任国瑞，等. 考虑增强特征选择的深度卷积-时序网络短期风功率预测[J]. 动力工程学报，2024，44(10)：1565-1573.
FU Bingzhe, WANG Wei, REN Guorui, et al. Short-term wind power prediction with deep convolutional-temporal networks considering enhanced feature selection[J]. Journal of Chinese Society of Power Engineering, 2024, 44(10): 1565-1573.

[80] 薛阳，王琳，王舒，等. 一种结合 CNN 和 GRU 网络的超短期风电预测模型[J]. 可再生能源，2019，37(3)：456-462.
XUE Yang, WANG Lin, WANG Shu, et al. An ultra-short-term wind power forecasting model combined with CNN and GRU networks[J]. Renewable Energy Resources, 2019, 37(3): 456-462.

[81] 宋江涛，崔双喜，樊小朝，等. 基于 SGMD-SE 与优化 TCN-BiLSTM/BiGRU 的超短期风功率预测[J]. 太阳能学报，2024，45(10)：588-596.
SONG Jiangtao, CUI Shuangxi, FAN Xiaochao, et al. Ultra-short-term wind power prediction based on SGMD-SE and optimized TCN-BiLSTM/BiGRU [J]. Acta Energiae Solaris Sinica, 2024, 45(10): 588-596.

[82] 韩宇超，同向前，邓亚平. 基于概率密度估计与时序 Transformer 网络的风功率日前区间预测[J]. 中国电机工程学报，2024，44(23)：9285-9295.
HAN Yuchao, TONG Xiangqian, DENG Yaping. Probabilistic distribution estimation and temporal transformer-based interval prediction in day-ahead wind power prediction[J]. Proceedings of the CSEE, 2024, 44(23): 9285-9295.

[83] 丁华杰，宋永华，胡泽春，等. 基于风电场功率特性的日前风电预测误差概率分布研究[J]. 中国电机工程学报，2013，33(34)：136-144.
DING Huajie, SONG Yonghua, HU Zechun, et al. Probability density function of day-ahead wind power forecast errors based on power curves of wind farms [J]. Proceedings of the CSEE, 2013, 33(34): 136-144.

[84] 张晓英，张晓敏，廖顺，等. 基于聚类与非参数核密度估计的风电功率预测误差分析[J]. 太阳能学报，2019，40(12)：3594-3604.
ZHANG Xiaoying, ZHANG Xiaomin, LIAO Shun, et al. Prediction error analysis of wind power based on clustering and non-parametric kernel density estimation[J]. Acta Energiae Solaris Sinica, 2019, 40(12): 3594-3604.

[85] 唐新姿，顾能伟，黄轩晴，等. 风电功率短期预测技术研究进展[J]. 机械工程学报，2022，58(12)：213-236.
TANG Xinzi, GU Nengwei, HUANG Xuanqing, et al. Progress on short term wind power forecasting technology[J]. Journal of Mechanical Engineering, 2022, 58(12): 213-236.

[86] 梅勇，李霄，胡在春，等. 基于风电机组控制原理的风功率数据识别与清洗方法[J]. 动力工程学报，2021，41(4)：316-322，329.
MEI Yong, LI Xiao, HU Zaichun, et al. Identification and cleaning of wind power data methods based on control principle of wind turbine generator system [J]. Journal of Chinese Society of Power Engineering, 2021, 41(4): 316-322, 329.

[87] 孙朋杰，王彬滨，陈正洪，等. 测风塔风速插补对风功率密度误差的影响分析[J]. 气象科技进展，2019，9(2)：62-65.
SUN Pengjie, WANG Binbin, CHEN Zhenghong, et al. Analysis of the influence of wind speed interpolation on wind power density error from wind tower data[J]. Advances in Meteorological Science and Technology, 2019, 9(2): 62-65.

[88] BUHAN S, ÖZKAZANÇ Y, ÇADIRCI I. Wind pattern recognition and reference wind mast data correlations with NWP for improved wind-electric power forecasts[J]. IEEE Transactions on Industrial Informatics, 2016, 12(3): 991-1004.

[89] SHENG Yiwei, WANG Han, YAN Jie, et al. Short-term wind power prediction method based on deep clustering-improved temporal convolutional network [J]. Energy Reports, 2023, 9: 2118-2129.

[90] 刘丽珺，梁友嘉. 集成 CFD 与 Kalman 滤波的微尺度风电场风功率预报方法[J]. 高原气象，2018，37(4)：1061-1073.
LIU Lijun, LIANG Youjia. Wind power prediction method for micro-scale wind farm based on CFD and Kalman filtering integrated correction[J]. Plateau Meteorology, 2018, 37(4): 1061-1073.