

DOI: 10.3901/JME.2022.12.213

风电功率短期预测技术研究进展*

唐新姿¹ 顾能伟¹ 黄轩晴² 彭锐涛¹

(1. 湘潭大学机械工程学院 湘潭 411105;
2. 明阳智慧能源集团股份公司 中山 528437)

摘要: 风电不可避免的随机性、间歇性和不确定性给并网、电力调度与消纳带来巨大挑战。通过风电功率预测对风电波动进行有效评估,对于降低风电不确定性风险推进风电稳步发展具有重要意义。针对当前大规模风电发展中至关重要的短期风功率预测精度问题,介绍了风电短期预测误差来源及影响,分类阐述了确定性和不确定性风电功率短期预测方法原理、优缺点、评价指标及适用性,从异常数据的检测与清洗、缺失数据的重构、数据特征的选择或提取、数据聚类、数据分解、优化算法改进和考虑物理模型等方面,探讨并综述了风电功率预测精度提升关键技术及其最新研究进展,最后对未来风电功率预测技术发展趋势进行了展望,为提升风电功率短期预测精度、推进精细化预测技术发展、保障系统安全稳定运行提供参考。

关键词: 风电功率预测; 预测精度; 深度学习; 区间预测; 组合预测模型

中图分类号: TG156

Progress on Short Term Wind Power Forecasting Technology

TANG Xinzi¹ GU Nengwei¹ HUANG Xuanqing² PENG Ruitao¹

(1. School of Mechanical Engineering, Xiangtan University, Xiangtan 411105;
2. Mingyang Smart Energy Group Co., Ltd., Zhongshan 528437)

Abstract: The inevitable randomness, intermittence and uncertainty of wind power bring great challenges to grid connection, power dispatching and consumption. Effective assessment of wind power fluctuations through wind power forecasting is of great significance to reduce the risk of wind power uncertainty and promote the steady development of wind power. Aiming at the crucial problem of short-term wind power prediction accuracy in the current development of large-scale wind power, the sources and influences of short-term wind power prediction error are introduced, the principles, advantages and disadvantages, accuracy evaluation criteria and applicability of deterministic and probabilistic short-term wind power forecasting methods are elaborated. The latest research progress of key technologies to improve the accuracy of wind power prediction from the aspects of abnormal data detection and cleaning, missing data reconstruction, data feature selection or extraction, data clustering, data decomposition, optimization algorithm improvement and consideration of physical model are investigated and summarized, and finally the prospect of future development trend of wind power prediction technology is concluded, providing a reference for improving the short-term prediction accuracy of wind power, promoting the development of refined prediction technology, and ensuring the safe and stable operation of the system.

Key words: wind power forecasting; prediction accuracy; deep learning; interval prediction; combined forecasting model

0 前言

风能是当前最具有应用前景的清洁无污染可再

生能源之一。由于自然风具有强随机性、波动性和间歇性,风电输出随之具有不可消除的随机性、间歇性和不确定性,对风电并网和电力调度与消纳带来巨大挑战。风电功率预测对于缓解电网调峰压力、减小电力系统备用容量、提高风电功率注入水平与系统可靠性具有重要意义。

风电功率预测按照时间尺度划分,可以分为超

* 国家自然科学基金(51305377, 51975504)、湖南省教育厅(19B539)和湖南省自然科学基金(2021JJ30676)资助项目。20210905 收到初稿, 20220330 收到修改稿

短期预测、中期预测、中长期预测。短期预测是指未来 1~3 天的风电功率预测,是当前的研究热点问题,主要用于安排合理的发电计划、机组组合以及对风力发电机进行检修维护等。预测精度是功率预测的核心问题。提升功率预测精度有益于:① 提高风电大规模并网能力和风能质量;② 提升电力系统的安全稳定性;③ 减少电网冲击,降低风电运行成本。目前风电短期功率确定性点预测方法相对成熟,风电功率不确定性预测越来越受到重视。

如何从风电历史数据的完整性、准确性和平稳性、模型结构参数的适用性等方面提升预测精度,并未形成定论。

本文介绍了风电功率预测误差的来源及影响,分类综述了常见风电功率短期预测方法原理、优缺点、评价指标及适用性,阐述了风电功率预测精度提升关键技术及其最新研究进展,如异常数据清理及重构、数据特征选择和提取、数据聚类、数据分解、优化算法改进及考虑物理模型等,探讨了风电功率短期预测技术未来发展趋势。

1 预测误差来源及影响

1.1 预测误差来源

风电功率预测误差是指预测模型输出的功率值与实际功率之间的差异。误差影响因素复杂,按来源可以分为物理因素和认知因素两大类。物理因素是指物理量中无法消除的不可预测的自然变化,如地形、温度、地表摩擦、湍流强度、塔影效应以及尾流效应等^[1]。认知因素指预测模型、数据测量和统计方法等。由于对自然因素认知不足,数值计算模型和实际问题产生的差异性和测量手段带入的不确定性都属于认知因素带来的预测误差。该类误差理论上可以通过采用更好的模型、更高精度的测量设备和使用更多的数据来降低该类不确定性。模型不确定性包括输入数据维度数目以及变量参数的选择,模型本身结构参数的确定等。当前任何数学预测模型输出与真实物理均存在差异,不同预测模型具有各自的优缺点与适用性,提升功率预测精度是风电功率预测研究的核心任务。

1.2 预测误差影响

风电功率预测误差对风电系统和机组运行的影响主要体现在并网能力、风能质量、电力系统安全性、风电运行成本,以及系统动态响应控制效果等方面,通常表现为正误差和负误差。若风电功率预测值高于实测值,则表现为正误差,反之则表

现为负误差。文献[2-3]研究表明,若风电场功率预测长期显著表现为正误差,则容易出现常规机组投资不足,甚至不可避免地出现正常运行机组退役,备用容量增加,导致发电成本增加;若风电场功率预测结果长期显著地表现为负误差,则容易造成常规机组过多建设,增加弃风限电率以及使本该退役机组还处于运行状态。文献[4]研究表明,当风电功率预测误差的标准差增加时,其弃风率和切负荷均随之增加。当预测误差均值大于零,即出现正误差时,切负荷和机组的调峰深度增加,机组弃风现象随着误差均值增大而降低;反之,当预测误差均值低于零,即出现负误差时,切负荷和机组的调峰深度随误差均值减少而降低,机组的弃风现象随着误差均值减少而增加。文献[5]研究结果表明预测误差增加 1%,系统边际价格就会增加 1%;若风电实际发电量比预期少 13%,则动用备用容量造成的发电成本增加 10%;若风电实际发电量比预期高 4%,则发电成本会降低,但系统边际价格会上升 3%。

在机组动态响应控制方面,控制效果与预测误差密切相关。风电预测误差体现为风电功率预测的不确定性,功率预测不确定性对机组运行的动态响应控制带来巨大挑战。文献[6]指出风电功率预测精度和风电控制效果互为表里相辅相成,功率预测模型的相对误差越低,则控制效果越好。当功率不确定性较大时,需要通过偏航或变桨等控制系统使机组出力平稳并降低机组的机械损耗^[7]。文献[8]提出一种桨距角控制,能够在一定程度上最大降低叶片和机组载荷的 30%。文献[9-10]研究表明,基于功率预测信息采用不同的桨距角控制策略,可以降低桨距角波动范围,降低因频繁变桨而产生的机械载荷,增加风力机运行时长,使风力机风能利用系数提高,功率输出更加平稳。文献[11-14]通过有功控制降低风电机组控制系统的频繁启动而造成的机械损耗,使风电机组出力更加平稳。综上,随着预测技术的进步,预测误差减小将大幅降低控制难度,提升控制效果。

2 风电功率短期预测方法

风电功率预测按照获取方式可分为两种:间接法和直接法。间接法指采用物理机理驱动方法,根据风电场等高线、粗糙度、障碍物、气压、气温等地理信息分析风速特性,采用数值天气预报(NWP)模型预测风速从而获得风电功率。直接法是利用统计法与机器学习等方法学习历史数据规律,由数据

和预测模型驱动,得到风电输出功率的方式。根据预测的结果,可以将基于数据的直接法分为风电功率确定性预测和风电功率不确定性预测两类。确定性预测给出未来风电功率确定性点的预测结果;不确定性预测给出未来风电功率可能的波动范围或不确定性。

2.1 风电功率确定性预测

风电功率确定性预测方法可以分为四类基本方法:时间序列模型、机器学习模型、深度学习和组合预测模型等方法。表 1 概括了四类十五种常见风电功率确定性预测方法优缺点与适用性。第一类,时间序列法,如持续法、自回归移动平均(Auto regressive moving average, ARMA)、差分自回归滑动平均模型(Auto regressive integrated moving average, ARIMA),适用于将历史功率数据作为训练样本,数据样本量较少的情况。其中,持续法和 ARMA 适用于风功率预测较短且变化不剧烈的场合^[15-22]。例如,文献[15]基于改进的持续法进行短期功率预测,其预测模型的平均相对误差能达到 11.81%,平均绝对误差能达到 23.48 kW。第二类,基于机器学习的预测方法,包括支持向量机(Support vector machine, SVM)、最小二乘法支持向量机(Least square

support vector machine, LSSVM)、随机森林(Random forest, RF)或高斯过程(Gaussian process, GP)。该类方法具有较强的鲁棒性和对小样本数据具有强大的泛化能力,对于非线性较强的数据也能具有较高的拟合能力,适用于小样本非线性数据的场合,将预测结果用于变桨和偏航系统的控制决策中^[23-34]。第三类,基于深度学习的功率预测方法,包括 BP 神经网络、极限学习机(Extreme learning machine, ELM)、卷积神经网络(Convolutional neural network, CNN)、循环神经网络(Recurrent neural networks, RNN)、长短期记忆神经网络(Long and short term memory networks, LSTM)、门限循环神经网络(Gated recursive unit, GRU)等。该类方法具有较高的容错能力适应性,模型构建需要大量历史数据,对于非线性数据具有较高精度,对输入维数具有较强适应性,适用于风机控制决策和电网调度等应用^[35-55]。第四类,基于模型组合的功率预测,如基于数据分解的组合和基于权重系数的组合,通过简单的算法便可接近或达到复杂原理构建功率预测模型的性能,模型训练的时间更短,因此组合模型具有较强的鲁棒性及广泛的适应性^[56-64]。

表 1 风电功率确定性预测方法及特点

| 方法 | | 优缺点与适用性 | 案例文献 |
|-------|-----------|---|---------|
| 时间序列法 | 持续法 | 计算简单、只适用于超短期预测,且风电功率变化波动不剧烈的情况时,误差最小 | [15-17] |
| | ARMA | 计算相对简单,适用于平稳时间序列 | [18-19] |
| | ARIMA | 对非线性数据进行平稳化,对于强的非线性数据时,难以确定最佳结构参数 | [20-22] |
| 机器学习 | SVM | 较高的阶数(1~11 阶)具有提升预测效果,但 SVM 的核参数和惩罚因子难以选择,一般采用优化算法进行确定 | [23-26] |
| | LSSVM | LSSVM 比 SVM 具有极好的精度和泛化能力参数更少,计算时间更短 | [27-29] |
| | RF | 对非重要影响因素以及噪声数据具有较强的鲁棒性,无需优化结构参数便具有满意的结果 | [30-31] |
| | GP | 对于非线性、小样本数据具有强的泛化能力 | [32-34] |
| 深度学习 | BP | 基于误差反向传播的神经网络,一般作为基准模型 | [35-38] |
| | ELM | 仅需设置隐含单元数,学习速度较快 | [39-41] |
| | CNN | 对数据的隐含关系特征具有强大的提取能力,采用权重参数共享技术,降低模型训练难度 | [42-45] |
| | RNN | | [46-48] |
| | LSTM | 能够处理复杂的时间序列,对数据在时间维度上的特征关系可以很好地挖掘,但 RNN 容易在模型训练过程的误差修正环节发生梯度消失和爆炸等现象。LSTM、GRU 在一定程度上解决长期依赖的现象 | [49-52] |
| | GRU | | [53-55] |
| 组合模型 | 基于数据分解的组合 | 对非线性、非平稳的风速或风功率数据进行处理,降低训练难度;根据不同数据分量的特点,结合不同的预测算法分别建模,具有较强的泛化能力以及预测精度 | [56-59] |
| | 基于权重系数的组合 | 根据不同算法特点进行优缺点互补,在一定程度上提高了预测模型的鲁棒性;基于变权重系数比定权重系数的组合模型具有更强的适应能力 | [60-64] |

2.1.1 时间序列模型

时间序列法的原理是将前面几个时刻和当前时

刻的历史数据当作下一时刻的预测值,主要用于当风电功率变化的波动不是很剧烈的超短期预测,如

持续法^[15-17]、自回归移动平均(ARMA)^[18-19]。ARMA 模型的处理对象数据的条件是平稳时间序列, 风的不确定性导致风功率数据是随机非平稳, 因此使用 ARMA 模型, 需要对风功率非平稳时间序列进行平稳化。常用的方法是差分运算, 即差分自回归滑动平均模型(ARIMA)^[20-22]。

2.1.2 机器学习模型

机器学习模型通过学习历史数据构造出自变量和因变量的映射关系, 将映射关系应用到未知数据上进行预测, 如支持向量机(SVM)^[23-26]、最小二乘法支持向量机(LSSVM)^[27-29]、随机深林(RF)^[30-31]或高斯过程(GP)^[32-34]等方法。SVM 预测模型通常采用核函数降低计算复杂度^[23]。内核参数 σ^2 和惩罚因子 C 的合理选择将会影响 SVM 模型的预测性能。通常 σ^2 和 C 的选择都是基于经验选择的, 导致 SVM 预测模型精度低以及预测结果不稳定。为了确定最佳的内核参数和惩罚因子, 众多研究者将遗传算法^[24]、布谷鸟搜索^[29]等优化算法来对这两个参数进行寻优。随机深林^[30-31]通过引导抽样来随机选择不同子数据进行训练, 可以保持一定的拟合水平。高斯过程^[32-34]对于非线性、高纬度尤其是小样本的复杂问题具有强大的泛化能力, 超参数能够通过在学习的过程中自主获得的优点。

2.1.3 深度学习

深度学习^[65-67]能深度挖掘数据的固有抽象信息, 相比于浅层机器学习, 该方法对于含有噪声的原始数据的影响敏感性低, 具有高可靠性、稳定性和准确性的性能。深度学习神经网络的种类有很多, 按照有无反馈形式分为前馈型和反馈型神经网络。前馈型神经网络主要有 BP 神经网络^[35-38]、极限学习机(ELM)^[39-41]、卷积神经网络(CNN)^[42-45]、堆叠式自动编码器(Stacked auto encoders, SAE)^[65-66]等, 反馈型神经网络主要有时间卷积神经网络(Temporal convolutional network, TCN)^[67-69]、循环神经网络(RNN)^[46-48]、长短期记忆神经网络(LSTM)^[49-52]、门限循环神经网络(GRU)^[53-55]、受限玻尔兹曼机^[70]、深度信念神经网络(Deep belief network, DBN)^[71]、回波状态神经网络(Echo state network, ESN)^[72-73]等。

BP 神经网络是一种基于误差反向传播训练机制的多层前馈神经网络, 具有自适应, 非线性映射, 泛化能力强等优点, 被广泛用于非线性建模问题。理论上三层的 BP 神经网络可以以任意的精度构造任意的连续函数。BP 神经网络初始的权值和阈值对预测结果的影响很大, 因此文献[35-36]利用遗传算法、粒子群算法对神经网络的权值进行优化, 集成

经验模态分解与 BP 神经网络结合起来, 预测结果的绝对百分误差能降低到 6.82%~8.08%。

极限学习机^[39-41]是一种单层前馈的神经网络算法, 无需像 BP 神经网络等传统算法设置大量的参数, 仅需要设置隐含层单元个数, 从而在一定程度上降低了认知不确定性。该算法随机产生输入层与隐含层的权值和阈值, 则隐含层与输出层的权值系数就可以唯一被确定, 在训练过程中不用调整, 比常规算法更快地运行, 减少训练神经网络的时间。

卷积神经网络^[42-45]对输入参数间的耦合隐含特征具有强大的提取能力。与 BP 神经网络不同的是, 卷积层采用权重参数共享技术, 相同卷积层不同的神经元具有相同的权值和阈值的参数, 在有效提取数据中隐含特征的同时, 极大简化了前馈过程和反向传播过程, 降低了模型结构参数的数量以及训练难度和学习时间。通过池化层结构, 有效降低数据维度, 减少数据结构的大小, 还在一定程度提高模型的容错性。文献[44]采用 Taguchi 正交数组的可靠设计来确定 CNN 的结构参数, 避免了基于经验选取或者反复试验选取导致模型精度不稳定、建模时间过长的缺陷。

循环神经网络^[46-48]采用误差反向传播修正的方式进行训练, 则从输出端到输入端的这一过程, 常常会发生梯度爆炸或消失等现象, 导致模型无法有效训练。长短期记忆网络^[49-52]和门控循环神经网络^[53-55]是 RNN 的一种改进方式, 在一定程度上能够缓解训练时梯度消失或爆炸现象。

2.1.4 组合预测模型

由于单一模型拥有各自的优缺点^[74], 鲁棒性低, 适用性弱, 因此发展了组合模型。第一类基于数据分解的组合模型, 指的是利用数据分解方法将数据分解为不同的分量, 根据预测算法的不同特点对不同的数据分量进行预测, 然后将各预测结果进行分量叠加, 原理如图 1 所示, 其中预测模型数字中的 1 和 n 分别代表不同的预测算法。文献[56]基于奇异谱分析、最小二乘法支持向量机和深度信念神经网络等多种算法, 提出了一种新的风电功率预测组合模型, 通过奇异谱分析将风电功率历史序列分解为趋势成分和波动分量, 利用最小二乘法支持向量机对趋势成分进行预测, 深度信念神经网络具有高数据拟合能力以及快速分析能力, 因此对分解后的高随机波动分量进行预测, 结果证明组合预测模型比单一预测模型具有更高的预测精度。文献[57]基于 BP、ARMA 以及 LSSVM 三个预测模型, 分别对经变分模态法分解后的高中低频三个分量进行预

测, 结果证明组合预测模型的预测效果比其他单一模型的预测效果更加有效和健壮。

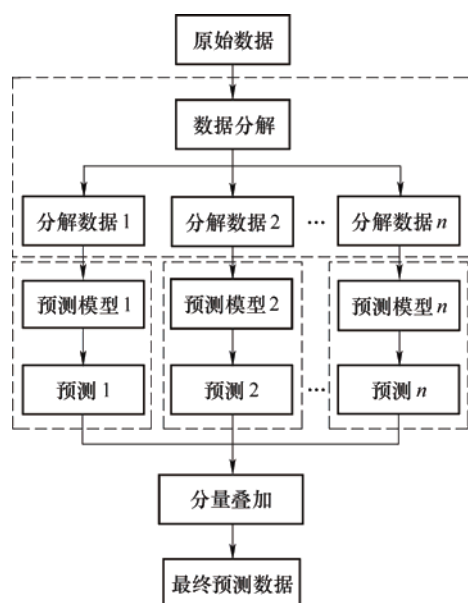


图1 基于数据分解的组合模型

第二类基于权重系数的组合模型, 指的是对多种单一预测模型分配一定的权重系数进行组合, 原理如图2所示。加权组合模型可分为定权组合预测模型和变权组合预测模型。相对定权组合预测模型而言, 基于变权系数的组合模型具有更高的鲁棒性, 适用性更强。常见的权重系数确定方式主要有熵值法^[60]、等权重法^[61]、协方差^[62]及采用优化算法^[63-64]等方式。文献[75]基于预测误差平方和原理求出RBF神经网络和ARIMA模型的权重系数, 结果证明组合方法比单一预测模型具有更好的预测效果。文献[76]表明小世界变权法比等权重方法具有更好的预测性能。文献[77-78]采用多目标蚱蜢优化算法优化后

的极限学习机以及改进的支持向量机对ARIMA、BP神经网络和Elman神经网络三种预测模型的预测结果进行变权组合以进一步提高预测精度。

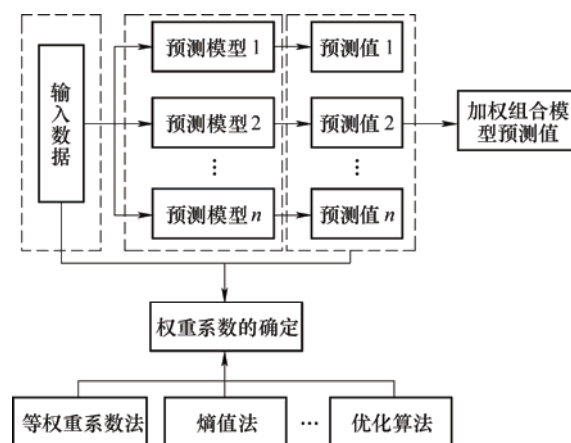


图2 加权组合模型

2.2 风电功率不确定性预测

风电功率不确定性预测主要包括基于误差分布的概率性功率预测和基于实测数据的区间上下限预测两种方式。概率性预测可以分为参数化与非参数化两类方法^[79-81]。常见方法优缺点及适用性如表2所示。第一种, 概率型预测, 包含参数化方法和非参数化方法。参数化方法, 如高斯分布、Beta分布、混合高斯或t分布等, 计算简单快速, 适用于某一时段内风电功率预测误差服从特定概率分布的场合^[82-90]。例如, 文献[86]对比使用t分布和混合t分布的模型预测性能, 结果表明在相同置信度下, 基于混合t分布比t分布的预测区间平均宽度小11.4%。非参数化方法, 包括Bootstrap重采样法、分位点回归技术(Quantile regression, QR)、云模型理论(Cloud model, CM)、证据理论(Evidence theory, ET)、

表2 风电功率不确定性预测方法优缺点及适用性

| 方法 | | 优缺点及适用性 | 案例文献 | |
|-------|-------------|--|---|----------|
| 概率性预测 | 参数化方法 | 高斯分布 Beta 分布 混合高斯或 t 分布等 | 计算较简单, 假设的误差分布不符合实际时, 将会造成较大建模误差。混合分布函数能够对有偏、重尾等现象很好拟合。 | [82-90] |
| | 非参数化方法 | Bootstrap 重采样 | 直接利用原始预测误差数据进行重采样来分析其分布, 对小样本数据进行重采样时, 精度相对较差。 | [91-92] |
| | | 分位点回归 | 能全面解释自变量对因变量分布特征的影响, 对异常数据具有强大的稳健性。若误差项为非正态时, 具有更高的精度。不适用于过于复杂的非线性问题。 | [93-95] |
| | | 云模型理论 | 描述定性概念和定量值之间的不确定性关系, 能够准确描述各个时刻下的不确定性结果, 且具有良好的可靠性以及适应性。 | [81, 96] |
| | | 证据理论 | 能够对不同区间的概率分布进行融合, 同时考虑风电功率的边界约束, 形成整体性的概率分布, 更加符合实际情况。 | [97-98] |
| | 核密度估计 | 无需假设任何分布, 在大样本数据的条件下获得更高的精度, 但带宽参数的选择没有一个标准, 带宽参数过大(过小), 容易引起较大的误差(波动性)。 | [99-102] | |
| 区间预测 | 直接构造预测区间上下限 | 不需要预测误差数据, 避免了因预测误差导致的认知不确定误差, 预测算法和损失函数的选择是关键。 | [103-107] | |

非参数核密度(Non-parametric kernel density, NPKD)、高斯过程等。该方法计算不同置信度下风电功率的预测区间,需要较多的历史预测误差数据,可以避免因假设误差分布函数而导致的认知不确定性^[91-102]。例如,文献[100]对比了非参数估计、正态分布和 t 分布的参数化方式,以积分均方误差作为评价指标,研究表明正态分布、 t 分布和非参数化核密度估计的积分均方误差分别 1.08×10^{-4} 、 1.36×10^{-5} 和 4.07×10^{-7} ,非参数化核密度估计的积分均方误差大大降低。第二种,区间预测方法,即直接构造预测区间上下限,不需要预测误差数据,可以避免讨论误差数据而引入的认知不确定性,直接得到不同置信度下功率预测结果的上下限,为实时调度带来快速的参考结果^[103-107]。例如,文献[106]基于核极限学习机(Kernel extreme learning machine, KELM)和分位数回归(QR)结合在一起,通过给定不同置信度得到的区间结果,研究表明在不同置信度的条件下 KELM-QR 的区间覆盖率都能满足置信度的要求,在 97% 的置信度下, KELM-QR 比传统的分位数回归 QR,其平均覆盖率提升了 4.3%,区间平均宽度降低 16.4%。

2.2.1 概率性预测

参数化建模假设预测误差的分布函数主要有高斯分布^[82-83]、Beta 分布^[84-85]、混合 t 分布^[86]、广义误差分布^[87]、混合高斯分布^[88]、威布尔分布^[89]、瑞利分布^[90]等。文献[108-109]表明,风电功率的误差存在有偏和重尾的现象,混合 t 分布或混合高斯分布可以对多峰、有偏以及重尾的现象进行很好的拟合。文献[110]分别对风电功率预测误差采用不同的分布函数来进行比较,结果是在不同条件下描述风电功率预测误差分布的分布函数不一致,说明在不同的条件下误差模型的分布具有多样性。文献[111-112]在不同的条件下对风电功率的预测误差进行描述,再次证明了此结论的正确性。文献[79]采用了高斯、伽马和拉普拉斯等分布进行组合对误差进行描述,比单个分布模型具有更好的预测效果。因此采用不同的分布函数进行组合或者在不同条件下如按照风速或者功率区间进行划分、分别描述不同区间段内的误差分布,对于提高风电不确定预测的精确度具有一定的借鉴意义。

常见非参数化方法有 Bootstrap 重采样法^[91-92]、分位数回归技术(QR)^[93-95]、云模型理论(CM)^[96]、证据理论(ET)^[97-98]、非参数核密度(NPKD)^[99-102]、高斯过程(GP)^[113-115]等方法。云模型^[96]利用期望、熵和超熵三个数字特征计算任意置信水平的风电功率

区间。分位数回归^[93-95]对于异常数据具有更强的稳健性;当误差项为非正态时,分位数回归估计器具有更好的精度。核密度估计方法需要大量样本进行估计,当样本数量过少,对数据进行估计会有一定的误差。同时,带宽参数选择会对估计精度造成影响^[100-101],利用优化算法对带宽的选择是一个很好的方式,有利于降低带宽对误差精度的影响。文献[116]基于小波变换和卷积神经网络的确定性预测方法得到功率的预测误差,计算均值和方差,根据高斯方差来得到区间的上下限,与 BP-QR 和 SVM-QR 相比,得到区间覆盖率和区间宽度的测试结果均好。

2.2.2 区间预测

基于实测数据的不确定性预测,首先给定预测区间名义置信度(Prediction interval normalized confidence, PINC),然后将预测模型输出数目设置为两个输出,分别对应为预测功率的上下限,具有无需任何先验知识和功率预测误差分布假设的优点^[103-107]。该方法的关键在于损失函数的选取,合适的损失函数既可满足预测区间覆盖率(Prediction interval coverage probability, PICP)的同时,又能够降低预测区间平均宽度(Prediction interval normalized average width, PINAW)。文献[104]基于预测区间覆盖率和预测区间平均宽度准则,提出了一种覆盖宽度指标准则(Coverage width criterion, CWC)作为不确定直接预测模型的损失函数,若 PICP 低于 PINC,使损失函数朝着 PICP 指标数值最大的方向进行,而不用考虑 PINAW;若 PICP 高于 PINC,则损失函数数值大小主要由 PINAW 指标决定,与 PICP 的指标无关,该方法既能满足预测可靠度的要求,又能够使预测区间宽度最低。文献[105]基于脉冲神经网络和群组搜索优化器,提出了一种连续排名概率得分(Continuous ranking probability score, CRPS)作为模型的损失函数,可以在优化预测可靠性和区间宽度预测平均区间宽度最低的同时调整脉冲神经网络结构参数。与 BP、SVM 和 ELM 三种预测模型相比,该方法的预测可靠度和预测区间平均宽度最低分别改善了 51.3% 和 21.0%,证明了该方法的有效性。

2.3 短期功率预测方法发展趋势

为体现风电功率短期预测方法近年发展趋势,根据 EI Compendex 数据库和 Web of Science 数据库,检索统计近年风电功率短期预测文献 160 篇,获得每种方法论文撰写数量和年代的统计数据,确定性预测方法 87 篇,不确定预测方法 73 篇,各方法发展趋势如图 3 所示。

图 3a 为确定性预测方法数据统计结果。由图 3a 可知, 近年文献数据总量最多的方法为基于深度学习的预测方法, 文献数量为 76 篇; 并且近年来研究者对深度学习的比例不断增加, 由 2018 年的 11 篇增长到 2020 年的 26 篇。由此可见, 基于深度学习的预测方法是当前风电功率预测领域的热点。

图 3b 进一步给出深度学习不同算法的数据统计结果。其中 ONN 表示其余的神经网络, 卷积神经网络 CNN、时间卷积神经网络 TCN、循环神经网络 RNN、长短期记忆神经网络 LSTM 和门控循环神经网络 GRU 共计 48 篇, 占据深度学习预测文献的 63.16%, 其主要特征表现在能够深度挖掘输入参数间的耦合特征以及时间维度上的特征^[42-55]。SVM 等机器学习和

BP、ELM 等浅层神经网络近年来比例也不断增加, 主要应用在风电组合模型预测方法^[56-57, 74-78]、优化算法^[29]、输入特征参数^[117-118]等研究中。

图 3c 给出不确定预测方法统计结果。其中, 非参数化方法(CM、Bootstrap、QR、NPKD、ET 和 GP)共 52 篇文献, 占据现有不确定统计文献的 71.23%, 可见非参数化方法是风电不确定预测的主流方法。此外, 区间预测方法研究不断增长, 成为未来发展的一个趋势。

图 3d 为各种非参数化方法研究趋势统计结果。由图可知, 分位点回归 QR 和非参数化核密度估计 NPKD 占主体地位。其中, 非参数化核密度估计方法近年增长比例不断扩大, 呈稳定增长趋势。

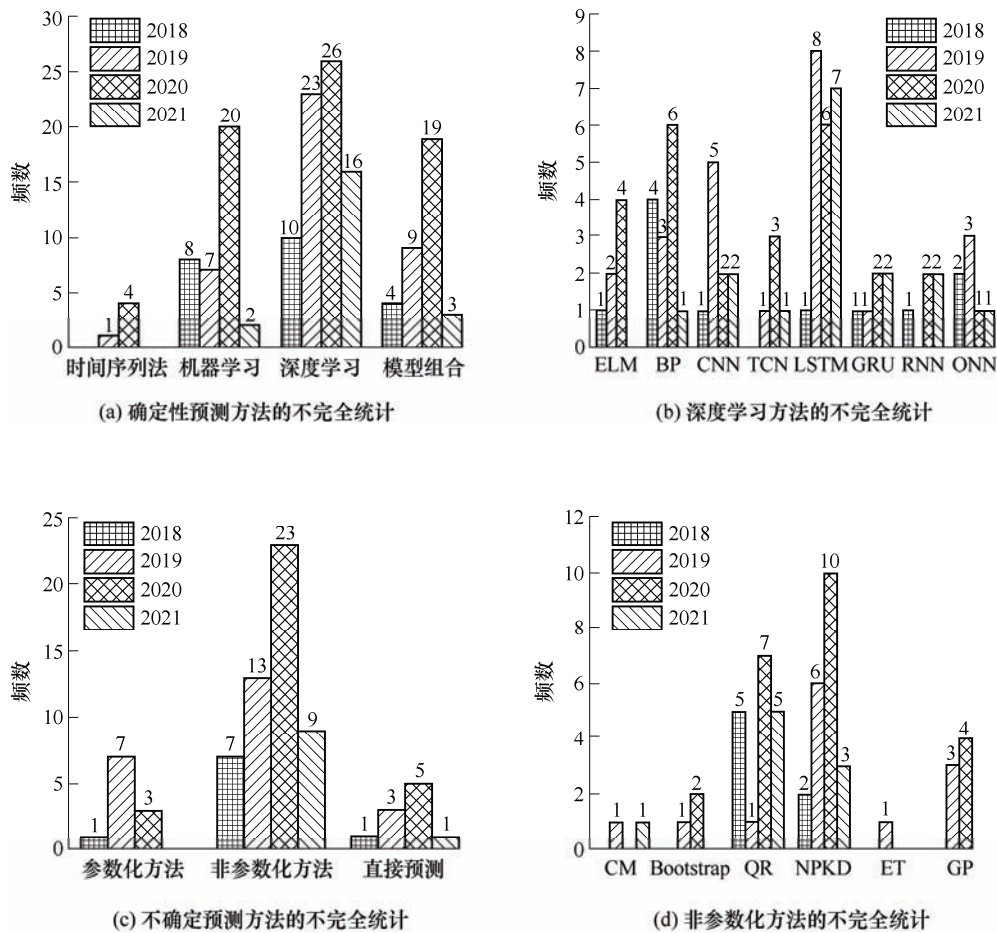


图 3 功率预测方法的不完全统计

3 精度评价指标

功率预测模型评价指标可以对预测模型误差特征进行量化。常见预测评价指标数学表达式及适用范围, 如表 3 所示。平均绝对误差、平均相对误差以及方均根误差, 一般用于风电功率确定性预测评估^[119-120]。其中, 平均绝对误差和方均根误差常用

作评估的必要条件。友好度^[121]是反映风电产能和电网所需负荷的预测结果对电力系统稳定运行的影响程度, 友好度越低, 说明预测结果更有利于电网的运行。风电不确定性预测评价需要综合考虑准确度和精确度, 如 PICP 和 PINAW^[122]。PICP 是指实际值落在预测区间的整体概率, PICP 越大, 说明预测区间结果越可靠。PINAW 是指功率预测上下边界的距离, 区间平均宽度越小, 说明不确定性越小, 预测

模型的实用价值就越高。在满足区间覆盖率即可靠型的质量越高，则对实际参考价值就越大。度的要求下，平均预测区间宽度越低，说明预测模

表 3 常见功率预测评价指标及适用性

| 评价指标 | 数学表达 | 特点和适用性 |
|---------------|---------------------|--|
| 基本指标 | 绝对误差(AE) | $ y_a^i - y_p^i $ 描述单个估计值与实际值之间的差异 |
| | 相对误差(RE) | $ (y_a^i - y_p^i) / y_a^i $ 描述单个预测结果的可靠性 |
| | 偏差(Bias) | $\frac{1}{N} \sum_{i=1}^N (\frac{y_a^i - y_p^i}{y_{nom}})$ 偏差的无量描述，适用于不同预测模型间评估 |
| 基于均值的 评价指标 | 平均绝对误差(MAE) | $\frac{1}{N} \sum_{i=1}^N (y_a^i - y_p^i)$ |
| | 平均相对误差百分比(MAPE) | $\frac{1}{N} \sum_{i=1}^N (\frac{ y_a^i - y_p^i }{y_a^i}) \times 100\%$ 描述预测值和实际值的偏差，反映了误差的总体水平，适用于大规模数据评估 |
| | 归一化平均绝对误差百分比(NMAE) | $\frac{1}{N} \sum_{i=1}^N (\frac{ y_a^i - y_p^i }{y_{nom}}) \times 100\%$ |
| 方均根 评价指标 | 方均根误差(RMSE) | $\frac{1}{N} \sqrt{\sum_{i=1}^N (y_a^i - y_p^i)^2}$ 通过对预测偏差进行评估，适用于差异较小的多目标评估 |
| | 归一化方均根误差(NRMSE) | $\frac{1}{N} \sqrt{\sum_{i=1}^N [(y_a^i - y_p^i) / y_{nom}]^2}$ 无量纲化的方均根误差，适用于差异较小的多目标评估 |
| | 方均根相对误差(RMSRE) | $\frac{1}{N} \sqrt{\sum_{i=1}^N [(y_a^i - y_p^i) / y_a^i]^2}$ 评估预测值和实际值的偏差 |
| | 方均根对数误差(RMSLE) | $\frac{1}{N} \sqrt{\sum_{i=1}^N (\log^2(y_a^i + 1) - \log^2(y_p^i + 1))^2}$ 适用于某个时刻预测值与实际值相差过大，导致方均根误差过大的情况 |
| 其他 评价指标 | 提高平均绝对误差(IMAE) | $ (E_{MAE1} - E_{MAE2}) / E_{MAE1} $ |
| | 提升方均根误差(IRMSE) | $ (E_{RMSE1} - E_{RMSE2}) / E_{RMSE1} $ 适用于评价不同模型间的预测效果 |
| | 平均趋势偏差(MTD) | $\frac{1}{y_{nom}(N-1)} \sum_{i=2}^N (\Delta y_a^i - \Delta y_p^i)$ |
| | 友好度(F) | $\sum_{i=1}^N (e_a^i - e_p^i) - k(y_a^i - y_p^i) / N$ 适用于功率预测对电网的稳定性评价 |
| | 相关系数(IC) | $IC = \frac{COV(y_a, y_p)}{\sqrt{D(y_a)} \sqrt{D(y_p)}}$ 反映预测与实际值的相关性，适用中等数据规模 |
| 不确定 预测 | 决定系数 R ² | $R^2 = 1 - \sum_{i=1}^N (y_a^i - y_p^i)^2 / \sum_{i=1}^N (y_a^i - \bar{y}_a)^2$ 反映实际数据与训练模型拟合的程度 |
| | 平均覆盖误差(ACE) | $PICP - PINC$ 描述预测间隔的可靠性，适用于小规模数据 |
| | 预测区间可靠度(PICP) | $\sum_{i=1}^N C_i / N$ |
| | 预测区间平均宽度(PINAW) | $\sum_{i=1}^N (U_i - L_i) / N$ 反映预测模型的可靠度和质量水平，是风电功率不确定预测模型的必要条件 |
| | 归一化预测区间平均宽度(NPINAW) | $\sum_{i=1}^N (U_i - L_i) / (N \times y_{nom})$ 反映预测间隔的总体宽度，适用于大规模数据 |
| | 区间锐度(IS) | $\frac{1}{N} \sum_{i=1}^N \begin{cases} -2\alpha \times \Delta Y_i - 4 \times [L - y_i] & y_i < L_i \\ -2\alpha \times \Delta Y_i, & y_i \in I_i \\ -2\alpha \times \Delta Y_i - 4 \times [y_i - U_i] & U_i < y_i \end{cases}$ 区间锐度 IS 主要是用奖励较窄的预测间隔且惩罚较宽的预测间隔，进而来评估预测间隔的质量 |
| | 连续排名概率得分(CRPS) | $\frac{1}{N} \sum_{i=1}^N \int_{y=0}^{\infty} [CDF_i - H(y - y_i)]^2 dy$ 同时考虑了预测可靠性 PICP 和间隔锐度 IS |

注： y_a 、 y_p 、 y_{nom} 分别为风电功率实际功率值、预测功率值、额定功率值。 \bar{y}_a 为测试数据集的实际平均功率； N 为测试数据集长度， e_a 、 e_p 分别为风电功率实际负荷值、预测负荷值，若 $y_a \in [L_i, U_i]$ 则 $C_i = 1$ ，否则 $C_i = 0$ ； L_i 、 U_i 为预测功率区间的上下边界， $I_i = [L_i, U_i]$ 。 CDF_i 为给定累计分布函数；若 $y < y_i$ ，则 $H(y - y_i) = 0$ ；否则 $H(y - y_i) = 1$ 。

表 4 和表 5 总结了近年文献所采用的确定性和不确定性风电功率预测精度评价指标。不同的评价指标对模型性能的不同方面进行诠释。单一评估指标难以全面反映预测值和实际性的变化趋势、误差的波动性以及预测误差对风电并网运行调度的影响。目前没有一种通用的预测评价指标适合对预测

模型的性能进行完整诠释。对于确定性风电功率预测，文献多采用绝对误差、相对误差以及方均根误差指标来评价预测精度。对于不确定性风电功率预测，文献多采用预测区间平均宽度、预测可靠度或平均覆盖误差指标来评价预测模型的可靠度和质量。

表 4 常见确定性预测模型及其预测精度

| 方法 | 时间 | 输入 | 时间分辨率 | MAE (NMAE) | MAPE | RMSE (NRMSE) | R^2 | IC |
|-----------------------------------|------|----------------------------|--------|-----------------------|-----------|-----------------------|---------|---------|
| IDA-SVM ^[25] | 2020 | WS/WD | 1 hour | 2.75% | 10.58% | 3.25% | 0.979 1 | — |
| BP ^[25] | | | | 5.52% | 13.46% | 8.70% | 0.899 4 | — |
| 持续型 ^[32] | | | | 18.9% | — | 18.5% | — | — |
| ARMA ^[32] | 2016 | WP | 1 hour | 9.2% | — | 10.9% | — | — |
| RBF ^[32] | | | | 11.3% | — | 10.2% | — | — |
| GP ^[32] | | | | 10% | — | 5.49% | — | — |
| RF ^[30] | 2017 | WS/WD/WP | 10 min | 1.882 3 MW (3.485 8%) | 14.383 3% | 3.035 4 MW (5.673 6%) | — | 0.971 8 |
| TCN ^[67] | 2019 | WS/WP/T/P/ ρ | 1 hour | 0.016 MW (0.533 3%) | — | 0.023 MW (0.766 7%) | — | — |
| VMD-SIRAE ^[66] | 2021 | WP | 15 min | 1.947 6% | — | 2.827 1% | — | — |
| LSSVM ^[66] | | | | 3.926 2% | — | 6.015 8% | — | — |
| VMD-ELM ^[39] | | | | 3.58% | — | 5.51% | — | 0.974 4 |
| SGD-CNN ^[45] | 2016 | WS/WD/WP | 15 min | 3.76% | — | 4.99% | 0.974 4 | — |
| SRNN-PSAF ^[48] | 2021 | WS/WD/P/H/T/ ρ | 1 hour | 0.060 2 MW (3.01%) | 0.936 0% | 0.119 5 MW (5.975%) | 0.784 7 | — |
| LSTM ^[48] | | | | 0.065 4 MW (3.27%) | 0.871 8% | 0.126 9 MW (6.345%) | 0.757 2 | — |
| GRU ^[48] | | | | 0.066 9 MW (3.345%) | 1.254 0% | 0.127 8 MW (6.39%) | 0.753 7 | — |
| DBN ^[71] | 2018 | WS/WD/P/H/T/W _P | 10 min | 2.36% | — | 3.22% | — | — |
| WT-ESN ^[73] | 2019 | WP | 15 min | 1.54% | 1.23% | 2.71% | 0.984 | — |
| LSSVM-DBN-SSA-LSH ^[56] | | | 10 min | 1.64% | — | 2.12% | — | — |
| VMD-BP-ARMA-LSSVM ^[57] | | | | 0.749 5 MW (1.499%) | — | 1.032 3 MW (2.0646%) | — | — |

表 5 常见不确定性预测模型及其预测精度

| 方法 | 时间 | 输入 | 时间分辨率 | PINC | PICP | PINAW (NPINAW) | CRPS | IS | ACE |
|-------------------------------|------|--------|--------|------|------|--------------------|---------|--------|--------|
| Beta-PSO-LSTM ^[84] | 2019 | WP | 10 min | — | 95% | 0.540 MW (0.18%) | — | 84 | — |
| Norm-PSO-LSTM ^[84] | | | | | | 0.574 MW (19.13%) | — | 98 | — |
| LSSVM ^[84] | | | | | | 0.728 MW (24.27%) | — | 116.59 | — |
| 正态分布 ^[85] | 2015 | — | 15 min | 95% | 93% | 29.76% | — | — | — |
| Beta 分布 ^[85] | | — | | | | 36.69% | — | — | — |
| 混合 t 分布 ^[86] | | — | | | | 190.86 MW (47.66%) | — | — | — |
| Bootstrap 方法 ^[111] | 2020 | WS/WD | 1 h | 95% | 100% | 40.11% | — | — | -1.43% |
| NPKDE ^[112] | | | | | | 15.61% | — | — | — |
| FIG-SVQR ^[93] | | | | | | 19.87% | — | — | — |
| WT-CNN ^[116] | 2017 | WP | 5 min | 95% | — | — | 1.781 3 | -11.8 | -1.23% |
| BP-QR ^[116] | | | | | | — | 2.419 5 | -5.68 | -3.85% |
| GSO-SNN ^[105] | | | | | | — | — | -2.53 | -0.84% |
| SVM ^[105] | 2020 | 15 min | — | — | — | — | — | -3.24 | -1.39% |
| ELM ^[105] | | | | | | — | — | -3 | -1.3% |

注：WS 为风速；WD 为风向；WP 为风电功率。

4 风电功率预测精度提升关键技术

数据的完整性、准确性和平稳性、模型结构参数的适用性直接影响预测结果。异常数据的检测与清洗、缺失数据重构,数据特征的选择或提取、数据聚类,数据分解以及优化算法改进是风电功率预测精度提升的主要关键技术。

表 6 异常功率类型及产生原因

| 数据异常类型 | 特征 | 产生原因 |
|------------|--------------------------------|---|
| 功率曲线底部异常堆积 | 风速大于切入风速时,风力机输出功率为零甚至为负,水平堆积 | 风机出现故障或检修、记录设备出现损坏或风力控制系统需要从电网额外接入功率等情况时 |
| 功率曲线中间异常堆积 | 功率输出远低于正常值,在不同风速水平下,功率输出呈现水平堆积 | 风电产能大于电网所需负荷,为了保证电网安全,强制进行减风措施或功率输出记录设备出现故障 |
| 功率曲线顶部异常堆积 | 在未达到额定风速前,功率输出达到额定值 | 风速传感器通常是按照在很高的位置,容易损坏,造成风速测量不正确 |
| 功率曲线周边异常堆积 | 功率输出随机呈现在功率曲线附近 | 传感器故障、噪声以及极端天气等不受控制的随机因素造成 |

现有的数据检测与清洗方式主要分为两类,第一类清洗方式是通过建立功率边界线模型,将位于功率曲线边界之外的数据视为异常数据^[125-127]。第二类清洗方式是根据异常数据和正常数据具有不同的数学统计特性来区分和清洗,如方差^[128-129]、熵^[130]或方差变化率^[131]等,或根据异常值的位置分布来检测,如四分位数法^[132-133],其主要流程如图 4 所示。利用四分位数法、熵曲线或方差曲线等方式进行清理异常数据时,首先需要对数据集按照风速大小划分不同的区间段,再对风速区间内的功率按照其值大小进行排序。四分位数法主要是通过计算第一、第三分位点的大小,进而计算上下内限的值,将数据落在上下内限的数据视为正常数据。而基于熵、方差或方差变化率判断异常数据,主要是计算该风速区间段内的统计特性,寻找显著变化的统计特性的数据点,该数据点为正常数据与异常数据的阈值。

对于大量堆叠的异常数据传统的异常数据,基于统计特性的清洗方法,可能无法达到很好的清洗效果。为了降低大量叠加异常数据对统计特性的影响,提高数据清洗效果和清洗效率,文献[134-135]将图像识别技术运用于风电功率曲线异常数据识别,其流程如图 5 所示。首先,对低于切入风速以及风电功率输出小于 0 的数据进行过滤,然后将筛选后的散点图数据转换为二值图像数据,再对图像数据进行数学形态学操作(Mathematical morphology operation, MMO)和 Hu 矩的图像相异度计算,确定最佳提取主要图像与参考功率曲线的相似度,最终

4.1 异常数据检测与清洗

异常数据是不符合正常风电功率输出特性的曲线范围。根据异常数据发生的原因和分布特征,将异常数据主要分为底部异常、中间异常、顶部异常以及功率曲线周边异常数据四大类^[123-124],如表 6 所示,可以得出,记录仪器出现故障以及极端天气等不可控因素是导致异常数据产生的主要来源。

对正常数据进行标记。该方法无需考虑分散数据点,仅需要考虑二值图像,在计算数据点的距离等统计特性时,大量降低计算成本,识别过程更为直观,具有很好的清理效果,还可以对异常数据分类。但由于 Hu 矩的缩放不变特性,对于形状较小的图像不能很好地提取主要特征图像,需要考虑其他评价指标对阈值分割进行指导,以便有效提取主要特征图像。

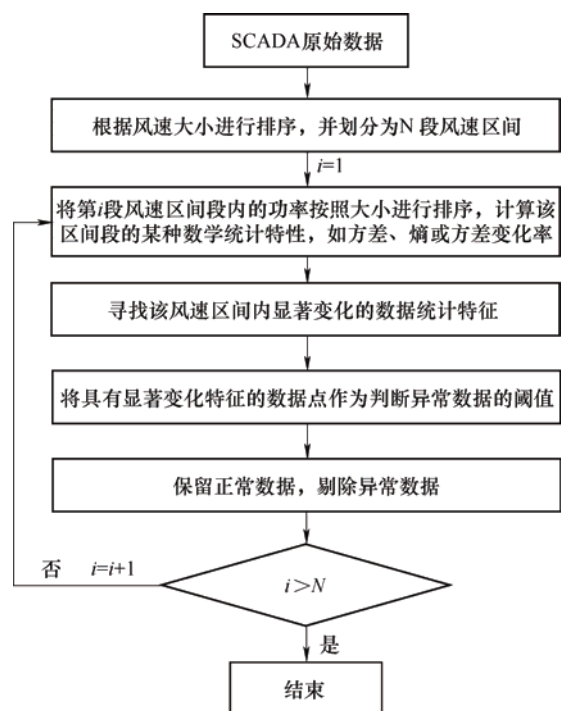


图 4 基于数据统计特性的异常数据判断及清理流程

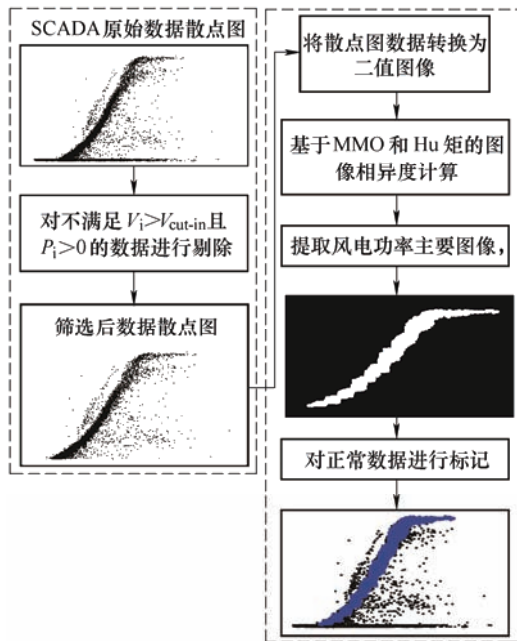


图5 基于图像识别的风电功率异常数据清洗

4.2 缺失数据修复与数据重构

风力机在数据采集过程中受到各种因素的影响, 或对异常数据清理后造成数据缺失。数据的完整性对于风电功率预测至关重要, 需要对缺失数据进行修复与重构。对于缺失数据量大的数据集, 一般采用支持向量机^[124]、高斯回归^[34]、Kriging 模型^[136]、神经网络^[137]等数据驱动方法进行重构。对于数据缺失级别小的数据集, 一般采用插补法、数值替换法进行重构。现有插值方法有三次样条插值^[138]、四点插值法^[133]、Hermite 插值理论^[126]等。基于插补法主要是利用缺失点前后的数据计算后构造样条曲线对缺失点位置进行插值计算。这种方式不适用数据大规模的连续缺失。若数据连续缺失, 采用插值法则会容易造成实际功率值与插补法计算值不符合, 引入认知不确定性。基于数值替换法是利用 Person 等相关系数选择与缺失数据相关性强的数据集, 对寻找的数据集直接或经过比例缩小替换缺失点的数据。因此, 数值替换法的关键是如何准确高效地寻找相关性强的数据, 而且仅适用于拥有大规模数据集的风电场。文献[139-141]分别利用 Couple 理论、秩相关系数以及风电场出力特性和时延性来判断数据序列的相关性, 进而选择与缺失数据相关性较强的数据序列作为替换数据。

4.3 数据特征选择与提取

基于数据驱动的风电功率预测, 输入信息的选择会对模型的预测精度造成严重影响^[142]。影响风电功率输出的因素众多, 为避免维数灾难和增加训练难度及预测误差, 需要对输入数据降维。常用方法

有特征选择以及特征提取。

数据特征选择是从现有的数据特征集, 按照一定的选择准则选择合适的特征子集。通常采用相关系数等指标去寻找与风电输出功率相关性强的参数作为输入参数, 常见的相关性评价指标主要有 Pearson 系数^[143]、互信息系数^[144]、Spearman 系数^[144]、Kendall 系数^[144]、灰色关联度^[76]及偏相关系数^[31]。文献[31]利用偏相关系数矩阵和解释结构模型从天气因素、风资源参数以及空气环境等方面确定模型结构的输入参数。文献[145]综合 Pearson 和互信息等相关系数考虑风电功率相关性因素。文献[146]利用偏依赖量识别影响风电功率的主要因素。文献[118]表明湍流动能是除风速外对预测模型精度影响最大的参数。文献[147]将风速、桨距角等输入特征参数与输出功率的 Person 相关系数以热图的方式表示出来, 如图 6 所示。其中风速和桨距角与功率输入呈正相关, 表明这三个变量的值高度相关。此图不仅可以用来判断输入与输出的相关性, 还可以展示输入参数之间的相关性变化规律。




图6 输入参数与功率相关性热图

数据特征提取是利用原始数据映射关系产生新的特征数据, 分为线性降维和非线性降维。常见的线性特征提取方式有主成分分析 (Principal component analysis, PCA)^[148]、线性判别分析 (Linear discriminant analysis, LDA) 和核奇异值分解等方式。PCA 在风电预测领域是一种常见特征提取方式, 其核心是构造参数样本的协方差, 然后根据求出协方差矩阵的特征值和特征向量。将计算后的特征值由大到小进行排序并累加, 当累加的特征值达到总特征值的 90% 或设定的一个值, 则累加的参数个数为原始数据特征提取后的维数。对于非线性特征提取主要有内核主成分分析 (Kernel principal component analysis, KPCA)^[149]、等距特征映射 (Isometric mapping, ISOMAP)^[150]、堆叠式自动编码器 (Stacked

auto encoder, SAE)^[149]等方式。KPCA 是 PCA 在非线形领域的一种变体,主要是通过核函数对样本数据进行非线性变换,对变换后的数据空间内进行 PCA。因此 KPCA 的关键是对样本空间进行非线性变换。

4.4 数据聚类

数据聚类能发现数据集中隐藏有用的信息特征,可以有效提高风电功率预测模型的预测精度。风电功率主要受风速的影响,而风速受到温度、气压和湿度等诸多气象因素影响。考虑气象数据对风速和风向进行全面地诠释,可以有效提高风电功率预测效果^[171]。由于气象数据和风力数据具有相似性,通过寻找与待预测日的相似数据作为模型的训练数据,降低待预测日数据和训练数据的差异性,可以有效提高风电功率预测模型的预测精度^[151-153]。

聚类技术主要有分层聚类、分区聚类、密度聚类、网络聚类以及基于模型等聚类算法等方式^[154]。现有的聚类技术大部分需要人为指定聚类数如 K 均值聚类^[44],容易造成主观误差,引入认知不确定性。大部分数据聚类技术的聚类效果容易受到初始聚类中心的影响,如 K 调和均值聚类技术^[153]和模糊 C 均值聚类^[41]等。文献[153]利用布谷鸟算法对 K 调和均值聚类技术的聚类数和聚类中心进行寻优,使得聚类效果更加明显,有效提高功率预测模型精度。文献[154]提出一种基于数学形态学的聚类方式,具有无需事先设定聚类数等优点,避免了人为设置聚类个数带来的认知不确定性,降低了风电功率预测误差。文献[155]将基于欧氏距离和角度余弦结合作为聚类相似的度量函数,可以有效识别空间距离近且综合具有相似变化趋势的数据,风电功率预测精度得到明显改善。

4.5 数据分解

信号分解是将数据分解获得不同子序列的序列,根据不同序列数据的特征建立不同的预测模型。分解后的子序列数据相对于原始数据具有相对平稳的特性,可以有效提高风电功率预测的准确性。根据分解原理,主要分为时域分解、频域滤波分解方法以及时频域分解方法。基于时域的数据分解方法主要是经验模态分解(Empirical mode decomposition, EMD)^[94]以及互补集合经验模式分解(Complementary ensemble empirical mode decomposition, CEEMD)^[22]和集合经验模态分解(Ensemble empirical mode decomposition, EEMD)^[29]等方式。基于频域分解方法的分解方法主要有小波

包分解(Wavelet packet decomposition, WPD)^[156]、经验小波变换(Empirical wavelet transform, EWT)^[157]以及变分模态分解(Variational mode decomposition, VMD)^[158]等方式。基于时频域的分解方法主要是小波分解(Wavelet decomposition, WD)^[159]。采用数据分解方式得到的高频数据序列仍然具有强的非线性和非平稳性。为解决高频率序列非线性,学者提出二次分解^[160],利用 VMD 对 EMD 分解后的高频率序列进行二次分解,预测模型在一步、两步和三步预测中绝对误差降低了 18.4%、28.5%和 29.5%,能够明显提升预测模型的预测效果。

4.6 优化算法改进

基于数据驱动的风电功率预测模型,其预测模型的结构参数,如支持向量机罚系数、内核参数;神经网络隐含层数、神经元数以及学习效率等超参数没有固定的选定标准,只能基于经验或不断试错调整。基于经验选择或随机试错调整,导致风电功率预测模型的准确度和稳定性难以把握。优化算法是对结构参数最优确定的有效解决办法^[161]。通过提升算法寻优效率和跳出局部最优点的性能,确定最佳模型的结构参数,进而提升风电功率预测模型的预测精度。

优化算法根据原理可分为四大类,如基于进化思想、群体社会智能、物理思想和地理思想等优化算法^[162],其典型算法及特点,如表 7 所示。不同算法的优化算法具有不同的特性,如基于进化思想的优化算法具有较好全局搜索能力,对于变量数目较多的寻优也能达到较好的寻优,但寻优迭代时间较长;基于群体社会的优化算法搜索迭代效率高,对于变量数较少的寻优能力在一定程度上能满足要求。基于物理思想的优化算法,迭代过程简洁清晰,容易跳出迭代过程中的局部最优。基于地理思想的优化算法在局部寻优能力比较强,但全局搜索能力弱。因此,针对上述优化算法的不同优缺点,现有研究者主要将上述优化算法进行组合,使之具有更强的全局搜索能力及跳出局部最优能力。文献[26]和文献[163-164]为了提升布谷鸟局部搜索能力,分别与混沌搜索算法和模拟退火算法结合在一起,能够有效提升传统布谷鸟算法局部搜索能力弱的问题,进而提升了风电功率预测效果。文献[165]针对差分进化算法在优化过程中出现的停滞以及陷入局部最优现象,将混沌萤火虫算法与差分进化算法结合在一起,能够跳出局部最优明显提升全局寻优的效果,从而保证预测模型在满足预测可靠度的前提下具有较低的预测区间宽度。

表 7 优化算法的种类及其特点

| 根据算法原理分类 | 具体算法 | 特点 |
|----------|--|---|
| 基于进化思想原理 | 遗传算法 ^[166] 、差分进化算法 ^[167] 、多重猎物的进化捕食者和猎物策略 ^[168] | 通过模拟生物进化的原理，使个体不仅具有强大满足环境的能力，还要将这种能力传递给后代，但有时候容易陷入局部最优解 |
| 基于群体社会智能 | 粒子群算法 ^[169] 、布谷鸟搜索算法 ^[26] 、蜻蜓算法 ^[25] 、果蝇优化算法 ^[170] 、蚂蚁优化器 ^[171] | 尽管群体中的个体比较简单，但是可以通过合作的集体行为，能够为复杂问题提供简洁快速而有效的解决方案 |
| 基于物理思想原理 | 模拟退火 ^[172] 、引力搜索算法 ^[173] 、水循环算法 ^[174] 、原子搜索算法 ^[175] | 遵循物理界的物理规律，思想简洁易懂，一般常用于和其他算法进行结合，实现全局优化 |
| 基于地理思想原理 | 禁忌搜索算法 ^[176] 、帝国主义竞争算法 ^[177] 和生物地理学优化算法 ^[178] | 通过在地理空间形成随机解，然后在当前解的领域内附近搜索，简单易于实现，但容易陷入极值点，无法保证全局优化 |

4.7 考虑物理模型的精度提升方法

风电功率预测精度的提升还可以从物理模型上考虑。在风电功率预测中，考虑物理方面因素对风电功率预测的影响，如气象因素和风力机运行状态，可以进一步提高预测精度。

风电输出功率预测的输入参数较多，根据 EI Compendex 数据库和 Web of Science 数据库近三年文献数据检索，统计风电功率预测文献共 160 篇，其中将历史功率单独作为预测模型输入，下一时刻功率作为输出的文献有 59 篇；在剩余的 101 篇文献中，各输入参数选择统计频次概率结果如图 7 所示。大多数文献的主要输入参数为历史功率和气象特征数据。其中，输入参数采用频次由高到低前 5 项依次是：风速、历史功率、风向、温度和大气压。也有文献采用桨距角、偏航角、偏航误差、风剪切和发电机温度、齿轮箱温度等工况监测数据。




图 7 风电功率预测参数选择不完全统计

风电功率波动是风况和风电场状态共同作用的结果，将风力机状态考虑在功率预测中十分必要。文献[179]分析了风力机运行状态对功率的相关性，将风力机运行状态参数作为预测模型的输入，结果证明归一化绝对误差下降了 64.46%，而

归一化方均根误差下降了 68.58%。文献[180]证明相同模型下，考虑了风力机状态的预测模型，其准确率和合格率分别提高 3.13% 和 9.45%，方均根误差和平均绝对误差分别降低 1.3 MW 和 0.84 MW。文献[181]研究对数风轮廓线、地转拖拽定律、地表粗糙度变化以及地形变化等物理方面对风电预测功率预测的影响，结果表明，通过考虑上述物理因素对 NWP 风速进行矫正或考虑更高分辨率的 NWP 数据，将在一定程度上降低因地形地貌等物理条件而造成 NWP 因素的数据偏差，从而提高预测精度。

5 结论

介绍了风电功率预测误差来源及影响，分类综述了基于数据驱动的风电功率短期预测确定性和不确定性两类方法原理、优缺点、评价指标及适用性，重点阐述了异常数据检测、清理及重构等数据预处理技术、数据特征选择和提取、数据聚类、数据分解、优化算法改进等预测精度提升关键技术，总结了风电功率预测应用中的最新研究进展。主要结论如下。

(1) 不确定性预测能给出风电功率波动区间范围和不确定度，能更好的描述风电波动本质，将成为风电预测领域重点关注内容和主流方向。基于预测误差的风电功率不确定预测容易引入建模不确定，而基于实测数据的不确定性预测可以避免误差分布假设带来的误差，但其关键在于损失函数的选取，合适的损失函数既可满足置信度要求又能够降低预测区间平均宽度。

(2) 在高效采集存储天气数据的前提下，深度学习风电功率预测中的应用将进一步加深。由于单一预测模型的鲁棒性低，未来发展更倾向于组合模型预测，而权重系数对组合预测精度的影响

至关重要。预测模型的结构参数,如支持向量机罚系数、内核参数;神经网络隐含层数、神经单元数以及学习效率等超参数没有固定的选定标准,利用混合优化算法对超参数进行寻优是有效的解决方式。

(3) 风电功率预测精度提升可以从异常数据检测与清洗、缺失数据重构、数据特征选择或提取、数据分解、数据聚类与优化算法改进,以及物理模型等多方面进行考虑。未来将重点关注数据高频率列非线性、非平稳性与数据相似性。

参 考 文 献

- [1] 范忠瑶,康顺,赵萍. 上风向风力机塔影效应的数值模拟研究[J]. 工程热物理学报, 2012, 33(10): 1707-1710.
FAN Zhongyao, KANG Shun, ZHAO Ping, Numerical simulations of upwind wind turbine tower shadow effects[J]. Journal of Engineering Thermophysics, 2012, 33(10): 1707-1710.
- [2] 郁琛,薛禹胜,文福拴,等. 风电功率预测误差的风险评估[J]. 电力系统自动化, 2015, 39(7): 52-58.
YU Chen, XUE Yusheng, WEN Fushuan, et al. Risk assessment of wind power prediction errors[J]. Automation of Electric Power Systems, 2015, 39(7): 52-58.
- [3] 郁琛,吴培华,谢东亮,等. 风电预测正、负误差对电力系统运行的不同影响[J]. 煤炭工程, 2017, 49(增刊1): 85-89.
YU Chen, WU Peihua, XIE Dongliang, et al. Different impacts of wind power prediction positive error and negative error on power system operation[J]. Coal Engineering, 2017, 49(Suppl.1): 85-89.
- [4] 夏添,查晓明,秦亮. 计及风电功率误差的短期风电消纳评估[J]. 水电能源科学, 2015, 33(2): 200-204.
XIA Tian, ZHA Xiaoming, QIN Liang. Evaluation of short-term wind power accommodating considering wind power forecasting error[J]. Water Resources and Power, 2015, 33(2): 200-204.
- [5] HIGGINS P, FOLEY A M, DOUGLAS R, et al. Impact of offshore wind power forecast error in a carbon constraint electricity market[J]. Energy, 2014, 76: 187-197.
- [6] 陈曦寒,高赐威. 考虑定桨距和变桨距风机联合控制的风电场有功功率控制策略[J]. 电网技术, 2015, 39(7): 1892-1899.
CHEN Xihan, GAO Ciwei. Active power control strategy for wind farm considering fixed and variable pitch wind turbines combined control[J]. Power System Technology, 2015, 39(7): 1892-1899.
- [7] 王江江,王维庆,王海云,等. 风速波动时基于UKF-DFNN的变桨距控制[J]. 安徽大学学报, 2021, 45(2): 55-62.
WANG Jiangjiang, WANG Weiqing, WANG Haiyun, et al. Variable pitch control of wind turbine based on UKF-DFNN[J]. Journal of Anhui University, 2021, 45(2): 55-62.
- [8] MAHDIZADEH A, SCHMID R, OETOMO D. LIDAR-assisted exact output regulation for load mitigation in wind turbines[J]. IEEE Transactions on Control Systems Technology, 2019, 29(3): 1102-1116.
- [9] 王晓兰,李家亮,马呈霞. 基于功率预测的变速变桨距风电系统的优化控制[J]. 电力系统保护与控制, 2013, 41(13): 88-92.
WANG Xiaolan, LI Jialiang, MA Chengxia. Optimization control of variable-speed variable-pitch wind power generation system based on power prediction[J]. Power System Protection and Control, 2013, 41(13): 88-92.
- [10] 李立成,叶林. 采用虚拟调节算法的风电场有功功率控制策略[J]. 电力系统自动化, 2013, 37(10): 41-47.
LI Licheng, YE Li. Wind farm active power control strategy based on virtual regulation algorithm[J]. Automation of Electric Power Systems, 2013, 37(10): 41-47.
- [11] 路朋,叶林,汤涌,等. 基于模型预测控制的风电集群多时间尺度有功功率优化调度策略研究[J]. 中国电机工程学报, 2019, 39(22): 6572-6583.
LU Peng, YE Lin, TANG Yong, et al. Multi-time scale active power optimal dispatch in wind power cluster based on model predictive control[J]. Proceedings of the CSEE, 2019, 39(22): 6572-6583.
- [12] 陈宁,谢杨,汤奕,等. 考虑预测功率变化趋势的风电场有功分群控制策略[J]. 电网技术, 2014, 38(10): 2752-2758.
CHEN Ning, XIE Yang, TANG Yi, et al. Strategy for active power control of wind farm in cluster considering variation trend of forecasting power[J]. Power System Technology, 2014, 38(10): 2752-2758.
- [13] 邓鹤鸣,汤亮亮,吴晓刚,等. 基于风机调控能力排序的风电场实时有功控制策略[J]. 电网技术, 2018, 42(8):

- 2577-2584.
- DENG Heming, TANG Liangliang, WU Xiaogang, et al. Active power control strategy of wind farms based on wind turbine regulation ability ranking[J]. *Power System Technology*, 2018, 42(8): 2577-2584.
- [14] 路朋, 叶林, 裴铭, 等. 风电集群有功功率模型预测协调控制策略[J]. *中国电机工程学报*, 2021, 41(17): 5887-5899.
- LU Peng, YE Lin, PEI Ming, et al. Coordinated control strategy for active power of wind power cluster based on model, predictive control[J]. *Proceedings of the CSEE*, 2021, 41(17): 5887-5899.
- [15] 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.
- [16] SUN Y, LI Z, YU X, et al. Research on ultra-short-term wind power prediction considering source relevance[J]. *IEEE Access*, 2020(8): 147703-147710.
- [17] LU P, YE L, ZHONG W Z, et al. A novel spatio-temporal wind power forecasting framework based on multi-output support vector machine and optimization strategy[J]. *Journal of Cleaner Production*, 2020, 254: 119993.
- [18] TORRES J L, GARCIA A, MD B, et al. Forecast of hourly average wind speed with ARMA models in Navarre (Spain)[J]. *Solar Energy*, 2005, 79(1): 65-77.
- [19] KORPRASERTSAK N, LEEPHAKPREEDA T. Robust short-term prediction of wind power generation under uncertainty via statistical interpretation of multiple forecasting models[J]. *Energy*, 2019, 180: 387-397.
- [20] LIU H, TIAN H Q, LI Y F. An EMD-recursive ARIMA method to predict wind speed for railway strong wind warning system[J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2015, 141: 27-38.
- [21] HAIGES R, WANG Y D, GHOSHRAY A, et al. Forecasting electricity generation capacity in Malaysia: An auto regressive integrated moving average approach[J]. *Energy Procedia*, 2017, 105: 3471-3478.
- [22] 赵征, 汪向硕. 基于 CEEMD 和改进时间序列模型的超短期风功率多步预测[J]. *太阳能学报*, 2020, 41(7): 352-358.
- ZHAO Zheng, WANG Xiangshuo. Ultra-short-term multi-step wind power prediction based on ceemd and improved time series model[J]. *Acta Energiæ Solaris Sinica*, 2020, 41(7): 352-358.
- [23] CHERKASSKY V, MA Y. Practical selection of SVM parameters and noise estimation for SVM regression[J]. *Neural Networks*, 2004, 17(1): 113-126.
- [24] LIU D, NIU D, WANG H, et al. Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm[J]. *Renewable Energy*, 2014, 62: 592-597.
- [25] LI L L, ZHAO X, TSENG M L, et al. Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm[J]. *Journal of Cleaner Production*, 2020, 242: 118447.
- [26] LI L L, CEN Z Y, TSENG M L, et al. Improving short-term wind power prediction using hybrid improved cuckoo search arithmetic - Support vector regression machine[J]. *Journal of Cleaner Production*, <https://doi.org/10.1016/j.jclepro.2020.123739>.
- [27] 刘畅, 郎劲. 基于混核 LSSVM 的批特征风功率预测方法[J]. *自动化学报*, 2020, 46(6): 1264-1273.
- LIU Chang, LANG Jin. Wind power prediction method using hybrid kernel LSSVM with batch feature[J]. *Acta Automatica Sinica*, 2020, 46(6): 1264-1273.
- [28] DING M, ZHOU H, XIE H, et al. A time series model based on hybrid-kernel least-squares support vector machine for short-term wind power forecasting[J]. *ISA Transactions*, 2020, 108: 58-68.
- [29] 姜贵敏, 陈志军, 李笑竹, 等. 基于 EEMD-ACS-LSSVM 的短期风电功率预测[J]. *太阳能学报*, 2020, 41(5): 83-90.
- JIANG Guimin, CHEN Zhijun, LI Xiaozhu, et al. Short-term prediction of wind power based on EEMD-ACS-LSSVM[J]. *Acta Energiæ Solaris Sinica*, 2020, 41(5): 83-90.
- [30] LAHOUE A, SLAMA J B H. Hour-ahead wind power forecast based on random forests[J]. *Renewable Energy*, 2017, 109: 529-541.
- [31] LIU J C, LI Y H. Study on environment-concerned short-term load forecasting model for wind power based on feature extraction and tree regression[J]. *Journal of Cleaner Production*, 2020, 264: 121505.
- [32] YAN J, LI K, BAI E W, et al. Hybrid probabilistic wind power forecasting using temporally local Gaussian

- process[J]. IEEE Transactions on Sustainable Energy, 2016, 7(1): 87-95.
- [33] YAN J, LI K, BAI E, et al. Time series wind power forecasting based on variant Gaussian process and TLBO[J]. Neurocomputing, 2016, 189: 135-144.
- [34] LIU T H, WEI H K, ZHANG K J. Wind power prediction with missing data using Gaussian process regression and multiple imputation[J]. Applied Soft Computing, 2018, 71: 905-916.
- [35] WANG S X, ZHANG N, WU L, et al. Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and GA-BP neural network method[J]. Renewable Energy, 2016, 96: 629-636.
- [36] REN C, AN N, WANG J Z, et al. Optimal parameters selection for BP neural network based on particle swarm optimization: A case study of wind speed forecasting[J]. Knowledge-Based Systems, 2014, 56: 226-239.
- [37] ZHANG Y, CHEN B, PAN G, et al. A novel hybrid model based on VMD-WT and PCA-BP-RBF neural network for short-term wind speed forecasting[J]. Energy Conversion and Management, 2019, 195: 180-197.
- [38] MEDINA S V, AJENJO U P. Performance improvement of artificial neural network model in short-term forecasting of wind farm power output[J]. Journal of Modern Power Systems and Clean Energy, 2020, 8(3): 484-490.
- [39] ABDOOS A A. A new intelligent method based on combination of VMD and ELM for short term wind power forecasting[J]. Neurocomputing, 2016, 203: 111-120.
- [40] 文孝强, 许洋. 基于 EMD 分解的风力机功率特性分析与预测建模[J]. 太阳能学报, 2021, 42(11): 293-298.
- WEN Xiaoqiang, XU Yang. Analysis and prediction modeling of wind power characteristics based on EMD decomposition[J]. Acta Energetica Sinica, 2021, 42(11): 293-298.
- [41] 张红涛, 韩婧, 谭联, 等. 基于 FCM 和 SSA - ELM 的超短期风功率预测[J]. 工程科学与技术, 2020, 52(6): 234-241.
- ZHANG Hongtao, HAN Jing, TAN Lian, et al. Ultra-short-term wind power prediction based on combination of FCM and SSA - ELM[J]. Advanced Engineering Sciences, 2020, 52(6): 234-241.
- [42] KAZUTOSHI H, YU F, YASUHIRO H. Feature extraction of NWP data for wind power forecasting using 3D-convolutional neural networks-ScienceDirect[J]. Energy Procedia, 2018, 155: 350-358.
- [43] HARBOLA S, COORS V. One dimensional convolutional neural network architectures for wind prediction[J]. Energy Conversion and Management, 2019, 195: 70-75.
- [44] HONG Y Y, SATRIANI T R A. Day-ahead spatiotemporal wind speed forecasting using robust design-based deep learning neural network[J]. Energy, 2020, 209: 118441.
- [45] YILDIZ, C, ACIKGOZ, H, KORKMAZ, D, et al. An improved residual-based convolutional neural network for very short-term wind power forecasting[J]. Energy Conversion and Management, 2021, 228: 113731.
- [46] HU J M, TANG J W, LIN Y Y. A novel wind power probabilistic forecasting approach based on joint quantile regression and multi-objective optimization[J]. Renewable Energy, 2020, 149: 141-164.
- [47] TOUBEAU J F, DAPOZ P D, BOTTIEAU J, et al. Recalibration of recurrent neural networks for short-term wind power forecasting[J]. Electric Power Systems Research, 2021, 190: 106639.
- [48] LIU X, ZHOU J, QIAN H M. Short-term wind power forecasting by stacked recurrent neural networks with parametric sine activation function[J]. Electric Power Systems Research, 2021, 192: 107011.
- [49] YU R G, GAO J, YU M, et al. LSTM-EFG for wind power forecasting based on sequential correlation features[J]. Future Generation Computer Systems, 2019, 93: 33-42.
- [50] SHAHID F, ZAMEER A, MUNEEB M. A novel genetic LSTM model for wind power forecast[J]. Energy, 2021, 223: 120069.
- [51] HAN L, JING H, ZHANG R C, et al. Wind power forecast based on improved long short term memory network[J]. Energy, 2019, 189: 116300.
- [52] DUAN J D, WANG P, MA W T, et al. Short-term wind power forecasting using the hybrid model of improved variational mode decomposition and Correntropy Long Short-term memory neural network[J]. Energy, 2021, 214. <https://doi.org/10.1016/j.energy.2020.118980>.
- [53] DING M, ZHOU H, XIE H, et al. A gated recurrent unit neural networks based wind speed error correction model for short-term wind power forecasting[J]. Neurocomputing, 2019, 365: 54-61.
- [54] NIU Z W, YU Z Y, TANG W H, et al. Wind power

- forecasting using attention-based gated recurrent unit network[J]. *Energy*, 2020, 196: 117081.
- [55] KISVARI A, LIN Z, LIU X. Wind power forecasting: A data-driven method along with gated recurrent neural network[J]. *Renewable Energy*, 2021, 163: 1895-1909.
- [56] ZHANG Y C, LE J, LIAO X B, et al. A novel combination forecasting model for wind power integrating least square support vector machine, deep belief network, singular spectrum analysis and locality-sensitive hashing[J]. *Energy*, 2019, 168: 558-572.
- [57] ZHANG G, LIU H C, ZHANG J B, 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.
- [58] WU Z C, XIA X J, XIAO L Y, et al. Combined model with secondary decomposition-model selection and sample selection for multi-step wind power forecasting[J]. *Applied Energy*, 2020, 261: 114345.
- [59] YUAN X H, TAN Q X, LEI X H, et al. Wind power prediction using hybrid autoregressive fractionally integrated moving average and least square support vector machine[J]. *Energy*, 2017, 129: 122-137.
- [60] 刘大贵, 王维庆, 张慧娥, 等. 马尔科夫修正的组合模型在新疆风电中长期可用电量预测中的应用[J]. *电网技术*, 2020, 44(9): 3290-3297.
- LIU Dagui, WANG Weiqing, ZHANG Huie, et al. Application of markov modified combination model mid-long term available quantity of electricity forecasting in Xinjiang wind power[J]. *Power System Technology*, 2020, 44(9): 3290-3297.
- [61] ZHAO H, LI B, ZHAO Z H. Short-term wind speed forecasting simulation research based on ARIMA-LSSVM combination method[C]// *International Conference on Materials for Renewable Energy & Environment (ICMREE)*, 2011: 583-586.
- [62] 刘纯, 范高锋, 王伟胜, 等. 风电场输出功率的组合预测模型[J]. *电网技术*, 2009, 33(13): 74-79.
- LIU Chun, FAN Gaofeng, WANG Weisheng, et al. A combination forecasting model for wind farm output power[J]. *Power System Technology*, 2009, 33(13): 74-79.
- [63] ZHANG W Y, QU Z X, ZHANG K Q, et al. A combined model based on CEEMDAN and modified flower pollination algorithm for wind speed forecasting[J]. *Energy Conversion and Management*, 2017, 136: 439-451.
- [64] ZHOU Q G, WANG C, ZHANG G F. A combined forecasting system based on modified multi-objective optimization and sub-model selection strategy for short term wind speed[J]. *Applied Soft Computing Journal*, 2020, 94: 106463.
- [65] HU Q H, ZHANG R J, ZHOU Y C. Transfer learning for short-term wind speed prediction with deep neural networks[J]. *Renewable Energy*, 2016, 85: 83-95.
- [66] WANG L, TAO R, HU H L, et al. Effective wind power prediction using novel deep learning network: Stacked independently recurrent autoencoder[J]. *Renewable Energy*, 2021, 164: 642-655.
- [67] ZHU R J, LIAO W L, WANG Y S. Short-term prediction for wind power based on temporal convolutional network[J]. *Energy Reports*, 2020(6): 424-429.
- [68] 黄睿, 杜文娟, 王海风. 计及湍流强度的风电功率短期预测[J]. *电网技术*, 2019, 43(6): 1907-1914.
- HUANG Rui, DU Wenjuan, WANG Haifeng. Short-term prediction of wind power considering turbulence intensity[J]. *Power System Technology*, 2019, 43(6): 1907-1914.
- [69] MEKA R, ALAEDDINI A, BHAGANAGAR K. A robust deep learning framework for short-term wind power forecast of a full-scale wind farm using atmospheric variables[J]. *Energy*, 2021, 221: 119759.
- [70] SANTHOSH M, VENKAIAH C, KUMAR D M V. Short-term wind speed forecasting approach using ensemble empirical mode decomposition and deep Boltzmann machine[J]. *Sustainable Energy, Grids and Networks*, 2019, 19: 100242.
- [71] WANG K J, QI X X, LIU H D, et al. Deep belief network based k-means cluster approach for short-term wind power forecasting[J]. *Energy*, 2018, 165: 840-852.
- [72] 王新友, 李青, 郑少鹏. 基于 EWT-ESN 的短期风电功率预测研究[J]. *太阳能学报*, 2018, 39(3): 633-642.
- WANG Xinyou, LI Qing, ZHENG Shaopeng. Short-term wind power prediction based on EWT-ESN[J]. *Acta Energetica Solaris Sinica*, 2018, 39(3): 633-642.
- [73] WANG H Z, LEI Z X, LIU Y, et al. Echo state network based ensemble approach for wind power forecasting[J]. *Energy Conversion and Management*, 2019, 201: 112188.
- [74] TASICARAOGLU 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.
- [75] 李玲玲, 许亚惠, 田晓越, 等. 基于组合模型的风电功率短期预测[J]. *电工技术学报*, 2014, 29(增刊 1): 475-480.
- LI Lingling, XU Yahui, TIAN Xiaoyue, et al. Based on the combined model of short-term wind power prediction[J]. *Transactions of China Electrotechnical Society*, 2014, 29(Suppl.1): 475-480.
- [76] 赵欣, 王爽心, 刘如九. 基于灰色关联和协整理论的风功率组合预测研究[J]. *太阳能学报*, 2017, 38(5): 1299-1306.
- ZHAO Xin, WANG Shuangxin, LIU Rujiu. Research on combination wind power forecasting based on gray correlation and cointegration theory[J]. *Acta Energaie Solaris Sinica*, 2017, 38(5): 1299-1306.
- [77] JIANG P, LIU Z K. Variable weights combined model based on multi-objective optimization for short-term wind speed forecasting[J]. *Applied Soft Computing*, 2019, 82.
- [78] LI H M, WANG J Z, LU H Y, et al. Research and application of a combined model based on variable weight for short term wind speed forecasting[J]. *Renewable Energy*, 2018, 116: 669-684.
- [79] SUN M C, FENG C, ZHANG J. Multi-distribution ensemble probabilistic wind power forecasting[J]. *Renewable Energy*, 2020, 148: 135-149.
- [80] XIN P Z, LIU Y, YANG N, et al. Probability distribution of wind power volatility based on the moving average method and improved nonparametric kernel density estimation[J]. *Global Energy Interconnection*, 2020, 3(3): 247-258.
- [81] GU B, ZHANG T R, MENG H, et al. Short-term forecasting and uncertainty analysis of wind power based on long short-term memory, cloud model and non-parametric kernel density estimation[J]. *Renewable Energy*, 2021, 164: 687-708.
- [82] JIANG Y, HUANG G Q, YANG Q S, et al. A novel probabilistic wind speed prediction approach using real time refined variational model decomposition and conditional kernel density estimation[J]. *Energy Conversion and Management*, 2019, 185: 758-773.
- [83] SUN M C, FENG C, ZHANG J. Conditional aggregated probabilistic wind power forecasting based on spatio-temporal correlation[J]. *Applied Energy*, 2019, 256: 113842.
- [84] YUAN X H, CHEN C, JIANG M, et al. Prediction interval of wind power using parameter optimized Beta distribution based LSTM model[J]. *Applied Soft Computing*, 2019, 82: 105550.
- [85] 杨宏, 苑津莎, 张铁峰. 一种基于 Beta 分布的风电功率预测误差最小概率区间的模型和算法[J]. *中国电机工程学报*, 2015, 35(9): 2135-2142.
- YANG Hong, YUAN Jinsha, ZHANG Tiefeng. A model and algorithm for minimum probability interval of wind power forecast errors based on beta distribution[J]. *Proceedings of the CSEE*, 2015, 35(9): 2135-2142.
- [86] 杨茂, 杨春霖, 董骏城. 基于预测误差分布优化模型的风电功率超短期概率区间预测研究[J]. *太阳能学报*, 2019, 40(10): 2967-2978.
- YANG Mao, YANG Chunlin, DONG Junqin. Ultra-short term probabilistic intervals forecasting of wind power based on optimization model of forecasting error distribution[J]. *Acta Energaie Solaris Sinica*, 2019, 40(10): 2967-2978.
- [87] 吴晓刚, 孙荣富, 乔颖, 等. 基于风电场功率特性的风电预测误差分布估计[J]. *电网技术*, 2017, 41(6): 1801-1807.
- WU Xiaogang, SUN Rongfu, QIAO Ying, et al. Estimation of error distribution for wind power prediction based on power curves of wind farms[J]. *Power System Technology*, 2017, 41(6): 1801-1807.
- [88] 黄越辉, 曲凯, 李驰, 等. 基于 K-means MCMC 算法的中长期风电时间序列建模方法研究[J]. *电网技术*, 2019, 43(7): 2469-2476.
- HUANG Yuehui, QU Kai, LI Chi, et al. Research on modeling method of medium-and long-term wind power time series based on K-means MCMC algorithm[J]. *Power System Technology*, 2019, 43(7): 2469-2476.
- [89] 张家安, 仇实, 宋关羽, 等. 考虑时序波动的风速分布描述方法[J]. *太阳能学报*, 2020, 41(8): 330-336.
- ZHANG Jiaan, QIU Shi, SONG Guanyu, et al. Wind speed distribution description method considering time series fluctuation[J]. *Acta Energaie Solaris Sinica*, 2020, 41(8): 330-336.
- [90] 王坤玉, 余侃胜, 张立栋, 等. 风功率三种概率分布特性对比分析[J]. *应用能源技术*, 2014(5): 35-38.
- WANG Kunyu, YU Kansheng, ZHANG Lidong, et al. Three kinds of comparative analysis of the probability distribution characteristics of wind power variations[J],

- Applied Energy Technology, 2014(5): 35-38.
- [91] 杨锡运, 张璜, 关文渊, 等. 基于滑动分块百分位数 Bootstrap 法的风电功率概率区间预测[J]. 太阳能学报, 2019, 40(2): 430-437.
- YANG Xiyun, ZHANG Huang, GUAN Wenyuan, et al. Probabilistic intervals forecasting of wind power based on moving block percentile bootstrap method[J]. Acta Energeticae Solaris Sinica, 2019, 40(2): 430-437.
- [92] TAHMASEBIFAR R, MOGHADDAM M P, SHEIKH-EL-ESLAMI M K, et al. A new hybrid model for point and probabilistic forecasting of wind power[J]. Energy, 2020, 211: 119016.
- [93] HE Y Y, YAN Y D, XU Q F. Wind and solar power probability density prediction via fuzzy information granulation and support vector quantile regression[J]. International Journal of Electrical Power and Energy Systems, 2019, 113: 515-527.
- [94] 杨锡运, 马雪, 张洋, 等. 基于 EMD 与加权马尔可夫链 QR 法的风电功率区间预测[J]. 太阳能学报, 2020, 41(2): 66-72.
- YANG Xiyun, MA Xue, ZHANG Yang, et al. Probabilistic intervals forecasting of wind power based on emd weighted markov chain or method[J]. Acta Energeticae Solaris Sinica, 2020, 41(2): 66-72.
- [95] PENG X S, WANG H Y, LANG J X, et al. EALSTM-QR: Interval wind-power prediction model based on numerical weather prediction and deep learning[J]. Energy, 2020, 220: 119692.
- [96] 阎洁, 李宁, 刘永前, 等. 短期风电功率动态云模型不确定性预测方法[J]. 电力系统自动化, 2019, 43(3): 17-23.
- YAN Jie, LI Ning, LIU Yongqian, et al. Short-term uncertainty forecasting method for wind power based on real-time switching cloud model[J]. Automation of Electric Power Systems, 2019, 43(3): 17-23.
- [97] 林优, 杨明, 韩学山, 等. 基于条件分类与证据理论的短期风电功率非参数概率预测方法[J]. 电网技术, 2016, 40(4): 1113-1119.
- LIN You, YANG Ming, HAN Xueshan, et al. Nonparametric approach for short-term probabilistic wind generation forecast based on conditional classification and evidence theory[J]. Power System Technology, 2016, 40(4): 1113-1119.
- [98] 鲍海波, 韦化, 郭小璇, 等. 考虑风电不确定性的概率区间潮流模型与算法[J]. 中国电机工程学报, 2017, 37(19): 5633-5642, 5840.
- BAO Haibo, WEI Hua, GUO Xiaoxuan, et al. Model and algorithm of probabilistic interval power flow considering wind power uncertainty [J]. Proceedings of the CSEE, 2017, 37(19): 5633-5642, 5840.
- [99] HAN Q K, MA S, WANG T Y, et al. Kernel density estimation model for wind speed probability distribution with applicability to wind energy assessment in China[J]. Renewable and Sustainable Energy Reviews, 2019, 115: 109387.
- [100] 杨楠, 周峥, 陈道君, 等. 基于非参数核密度估计的风功率波动性概率密度建模方法[J]. 太阳能学报, 2019, 40(7): 2028-2035.
- YANG Nan, ZHOU Zheng, CHEN Daojun, et al. Research of modeling method based on non-parametric kernel density estimation of probability of wind power fluctuations[J]. Acta Energeticae Solaris Sinica, 2019, 40(7): 2028-2035.
- [101] 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 Energeticae Solaris Sinica, 2019, 40(12): 3594-3604.
- [102] GUAN J S, LIN J, GUAN J L. et al. A novel probabilistic short-term wind energy forecasting model based on an improved kernel density estimation[J]. International Journal of Hydrogen Energy, 2020, 45(43): 23791-23808.
- [103] DEHNAVI S D, SHIRANI A, MEHRJERDI H, et al. New deep learning-based approach for wind turbine output power modeling and forecasting[J]. IEEE Transactions on Industry Applications, 2020, 99: 1.
- [104] SHRIVASTAVA N A, KHOSRAVI A, PANIGRAHI B K. Prediction interval estimation of electricity prices using PSO-tuned support vector machines[J]. IEEE Transactions on Industrial Informatics, 2015, 11(2): 322-331.
- [105] WANG H, XUE W L, LIU Y T, et al. Probabilistic wind power forecasting based on spiking neural network[J]. Energy, 2020, 196: 117072.
- [106] 杨锡运, 邢国通, 马雪, 等. 一种核极限学习机分位

- 数回归模型及风电功率区间预测[J]. 太阳能学报, 2020, 41(11): 300-306.
- YANG Xiyun, XING Guotong, MA Xue, et al. A model of quantile regression with kernel extreme learning machine and wind power interval prediction[J]. Acta Energiae Solaris Sinica, 2020, 41(11): 300-306.
- [107] ZHOU M, WANG B, GUO S D, et al. Multi-objective prediction intervals for wind power forecast based on deep neural networks[J]. Information Sciences, 2020, 550: 207-220.
- [108] 杨茂, 董骏城. 基于混合分布模型的风电功率波动特性研究[J]. 中国电机工程学报, 2016, 36(增刊 1): 69-78.
- YANG Mao, DONG Juncheng. Study on characteristics of wind power fluctuation based on mixed distribution model[J]. Proceedings of the CSEE, 2016, 36(Suppl.1): 69-78.
- [109] 刘燕华, 李伟花, 刘冲, 等. 短期风电功率预测误差的混合偏态分布模型[J]. 中国电机工程学报, 2015, 35(10): 2375-2382.
- LIU Yanhua, LI Weihua, LIU Chong, et al. Mixed skew distribution model of short-term wind power prediction error[J]. Proceedings of the CSEE, 2015, 35(10): 2375-2382.
- [110] ZHANG J H, YAN J, WU W J, et al. Research on Short-term Forecasting and Uncertainty of Wind Turbine Power Based on Relevance Vector Machine[J]. Energy Procedia, 2019, 158: 229-236.
- [111] 乔颖, 鲁宗相, 吴问足. 考虑误差时序-条件性质的短期风电功率概率预测[J]. 电网技术, 2020, 44(7): 2529-2537.
- QIAO YING, LU Zongxiang, WU Wenzu. Day-ahead wind power probabilistic forecast considering conditional dependency and temporal correlation[J]. Power System Technology, 2020, 44(7): 2529-2537.
- [112] 余沅, 董存, 王铮, 等. 考虑山东近海不同风能天气特征的风电功率区间预测模型[J]. 电网技术, 2020, 44(4): 1238-1247.
- YU Feng, DONG Cun, WANG Zheng, et al. Wind power interval forecasting model considering different wind energy weather characteristics in Shandong offshore areas[J]. Power System Technology, 2020, 44(4): 1238-1247.
- [113] ZHANG J H, YAN J, INFIELD 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.
- [114] XUE H, JIA Y C, WEN P, et al. Using of improved models of Gaussian Processes in order to Regional wind power forecasting[J]. Journal of Cleaner Production, 2020, 262. <https://doi.org/10.1016/j.jclepro.2020.121391>.
- [115] AHMADPOUR A, FARKOUSH S G. Gaussian models for probabilistic and deterministic wind power prediction: Wind farm and regional[J]. International Journal of Hydrogen Energy, 2020, 45(51): 27779-27791.
- [116] WANG H Z, LI G Q, WANG G B, et al. Deep learning based ensemble approach for probabilistic wind power forecasting[J]. Applied Energy, 2017, 188: 56-70.
- [117] JORDAN N, KIRAN B, RAJITHA M, et al. Using atmospheric inputs for Artificial Neural Networks to improve wind turbine power prediction[J]. Energy, 2020, 190: 116273.
- [118] OPTIS M, PERR-SAUER J. The importance of atmospheric turbulence and stability in machine-learning models of wind farm power production[J]. Renewable and Sustainable Energy Reviews, 2019, 112: 27-41.
- [119] MISHRA S, BORDIN C, TAHARAGUCHI K, et al. Comparison of deep learning models for multivariate prediction of time series wind power generation and temperature[J]. Energy Reports, 2020, 6(Suppl.3): 273-286.
- [120] 熊音笛, 刘开培, 秦亮, 等. 基于时序数据动态天气划分的短期风电功率预测方法[J]. 电网技术, 2019, 43(9): 3353-3359.
- XIONG Yindi, LIU Kaipei, QIN Liang, et al. Short-term wind power prediction method based on dynamic wind power weather division of time sequence data[J]. Power System Technology, 2019, 43(9): 3353-3359.
- [121] 吴阳阳, 黄礼波, 林建平, 等. 风电功率预测系统评价方法研究[J]. 应用能源技术, 2019(12): 38-44.
- WU Yangyang, HUANG Libo, LIN Jianping, et al. Research on evaluation method of wind power prediction system[J]. Applied Energy Technology, 2019(12): 38-44.
- [122] YUAN P, MA X, ZHANG X C, et al. A comprehensive error evaluation method for wind power forecasting and

- its application[C]// 2020 5th Asia Conference on Power and Electrical Engineering (ACPEE), 2020: 1977-1982.
- [123] SHEN X J, FU X J, ZHOU C C, et al. A combined algorithm for cleaning abnormal data of wind turbine power curve based on change point grouping algorithm and quartile algorithm[J]. IEEE Transactions on Sustainable Energy, 2019, 10(1): 46-54.
- [124] 杨茂, 翟冠强, 李大勇, 等. 基于风速升降特性及支持向量机理论的异常数据重构算法[J]. 电力系统保护与控制, 2018, 46(16): 31-37.
- YANG Mao, ZHAI Guanqiang, LI Dayong, et al. An algorithm of abnormal data reconstruction based on RISE-FALL-feature of the wind speed and support vector machine[J]. Power System Protection and Control, 2018, 46(16): 31-37.
- [125] YE X, LU Z X, QIAO Y, et al. Identification and correction of outliers in wind farm time series power data[J]. IEEE Transactions on Power Systems, 2016, 31(6): 4197-4205.
- [126] 胡阳, 乔依林. 基于置信等效边界模型的风功率数据清洗方法[J]. 电力系统自动化, 2018, 42(15): 18-23.
- HU Yang, QIAO Yilin. Wind power data cleaning method based on confidence equivalent boundary model[J]. Automation of Electric Power Systems, 2018, 42(15): 18-23.
- [127] 杨茂, 翟冠强, 苏欣. 基于风特征分析的风电机组异常数据识别算法[J]. 中国电机工程学报, 2017, 37(增刊 1): 144-151.
- YANG Mao, ZHAI Guanqiang, SU Xin, et al. An algorithm for abnormal data identification of wind turbine based on wind characteristic analysis[J]. Proceedings of the CSEE, 2017, 37(Suppl.1): 144-151.
- [128] 娄建楼, 胥佳, 陆恒, 等. 基于功率曲线的风电机组数据清洗算法[J]. 电力系统自动化, 2016, 40(10): 116-121.
- LOU Jianlou, XU Jia, LU Heng, et al. Wind turbine data cleaning algorithm based on power curve[J]. Automation of Electric Power Systems, 2016, 40(10): 116-121.
- [129] 杨茂, 杨春霖, 杨琼琼, 等. 计及风向信息的风电功率异常数据识别研究[J]. 太阳能学报, 2019, 40(11): 3265-3272.
- YANG Mao, YANG Chunlin, YANG Qiongqiong, et al. Study on data recognition of wind power abnormality considering wind direction information[J]. Acta Energaie Solaris Sinica, 2019, 40(11): 3265-3272.
- [130] 杨茂, 杨琼琼. 基于云分段最优熵算法的风电机组异常数据识别研究[J]. 中国电机工程学报, 2018, 38(8): 2294-2301.
- YANG Mao, YANG Qiongqiong. The identification research of the wind turbine abnormal data based on the cloud segment optimal entropy algorithm[J]. Proceedings of the CSEE, 2018, 38(8): 2294-2301.
- [131] HAN S, QIAO Y H, YAN P, et al. Wind turbine power curve modeling based on interval extreme probability density for the integration of renewable energies and electric vehicles[J]. Renewable Energy, 2020, 157: 190-203.
- [132] ZHAO Y G, YE L, WANG W S, et al. Data-driven correction approach to refine power curve of wind farm under wind curtailment[J]. IEEE Transactions on Sustainable Energy, 2018, 9(1): 95-105.
- [133] 邹同华, 高云鹏, 伊慧娟, 等. 基于 Thompson tau-四分位和多点插值的风电功率异常数据处理[J]. 电力系统自动化, 2020, 44(15): 156-165.
- ZOU Tonghua, GAO Yunpeng, YIN Huijuan, et al. Processing of wind power abnormal data based on thompson tau-quartile and multi-point interpolation[J]. Automation of Electric Power Systems, 2020, 44(15): 156-165.
- [134] SU Y H, CHEN F, LIANG G Y, et al. Wind power curve data cleaning algorithm via image thresholding[C]// 2019 IEEE International Conference on Robotics and Biomimetics (ROBIO). IEEE, 2019: 1198-1203.
- [135] LONG H., SANG L W, WU Z J, et al. Image-based abnormal data detection and cleaning algorithm via wind power curve[J]. IEEE Transactions on Sustainable Energy, 2020, 11(2): 938-946.
- [136] LIN Q S, LI C X. Kriging based sequence interpolation and probability distribution correction for gaussian wind field data reconstruction[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2020, 205: 104340.
- [137] QU F M, LIU J H, MA Y J, et al. A novel wind turbine data imputation method with multiple optimizations based on GANs[J]. Mechanical Systems and Signal Processing, 2020, 139: 106610.
- [138] HE Y Y, LI H Y, WANG S, et al. Uncertainty analysis of wind power probability density forecasting based on

- cubic spline interpolation and support vector quantile regression[J]. *Neurocomputing*, 2021, 420: 121-137.
- [139] 杨茂, 马剑. 基于 Copula 理论的风电功率缺失数据补齐方法研究[J]. *电测与仪表*, 2018, 55(3): 13-19.
- YANG Mao, MA Jian. Study on wind power data completion method based on Copula theory[J]. *Electrical Measurement & Instrumentation*, 2018, 55(3): 13-19.
- [140] 朱倩雯, 叶林, 赵永宁, 等. 风电场输出功率异常数据识别与重构方法研究[J]. *电力系统保护与控制*, 2015, 43(3): 38-45.
- ZHU Qianwen, YE Lin, ZHAO Yongning, et al. Methods for elimination and reconstruction of abnormal power data in wind farms[J]. *Power System Protection and Control*, 2015, 43(3): 38-45.
- [141] 张东英, 李伟花, 刘燕华, 等. 风电场有功功率异常运行数据重构方法[J]. *电力系统自动化*, 2014, 38(5): 14-18, 24.
- ZHANG Dongying, LI Weihua, LIU Yanhua, et al. Reconstruction method of active power historical operating data for wind farm[J]. *Automation of Electric Power Systems*, 2014, 38(5): 14-18, 24.
- [142] LIU H, CHEN C. Data processing strategies in wind energy forecasting models and applications: A comprehensive review[J]. *Applied Energy*, 2019, 249: 392-408.
- [143] ZHAO X Y, JIANG N, LIU J F, et al. Short-term average wind speed and turbulent standard deviation forecasts based on one-dimensional convolutional neural network and the integrate method for probabilistic framework[J]. *Energy Conversion and Management*, 2020, 203: 112239.
- [144] LIU X J, ZHANG H, KONG X B, et al. Wind speed forecasting using deep neural network with feature selection[J]. *Neurocomputing*, 2020, 397: 393-403.
- [145] 杨茂, 马剑, 李大勇, 等. 基于熵权综合关联度数据挖掘的风电功率实时预测研究[J]. *太阳能学报*, 2019, 40(12): 3578-3585.
- YANG Mao, MA Jian, LI Dayong, et al. Research on real time prediction of wind power based on entropy weight comprehensive association data mining[J]. *Acta Energeticae Solaris Sinica*, 2019, 40(12): 3578-3585.
- [146] 庞传军, 余建明, 张波, 等. 基于偏依赖量的风功率影响因素相关性分析方法[J]. *电网技术*, 2021, 2: 552-558.
- PANG Chuanjun, YU Jianming, ZHANG Bo, et al. Correlation analysis of factors affecting wind power based on partial dependence[J]. *Power System Technology*, 2021, 2: 552-558.
- [147] LIN Z, LIU X L. Wind power forecasting of an offshore wind turbine based on high-frequency SCADA data and deep learning neural network[J]. *Energy*, 2020, 201: 117693.
- [148] 李军, 王星辉. 基于 PCA-区间二型 FLS 的短期风电功率预测[J]. *太阳能学报*, 2019, 40(3): 608-619.
- LI Jun, WANG Xinghui. Short-term wind power forecasting based on pca interval type-2 fuzzy logic systems method[J]. *Acta Energeticae Solaris Sinica*, 2019, 40(3): 608-619.
- [149] JIAO R H, HUANG X J, MA X H, et al. A model combining stacked auto encoder and back propagation algorithm for short-term wind power forecasting[J]. *IEEE Access*, 2018, 6: 17851-17858.
- [150] ZHANG Y, ZHANG Z, QIN J, et al. Semi-supervised local multi-manifold Isomap by linear embedding for feature extraction[J]. *Pattern Recognition*, 2018, 76: 662-678.
- [151] ZHANG Y, LI Y T, ZHANG G Y. Short-term wind power forecasting approach based on Seq2Seq model using NWP data[J]. *Energy*, 2020, 213: 118371.
- [152] KUSIAK A, LI W Y. Short-term prediction of wind power with a clustering approach[J]. *Renewable Energy*, 2010, 35(10): 2362-2369.
- [153] CHEN X J, ZHAO J, JIA X Z, et al. Multi-step wind speed forecast based on sample clustering and an optimized hybrid system[J]. *Renewable Energy*, 2021, 165: 595-611.
- [154] HAO Y, DONG L, LIAO X Z, et al. A novel clustering algorithm based on mathematical morphology for wind power generation prediction[J]. *Renewable Energy*, 2019, 136: 572-585.
- [155] SUN G P, JIANG C W, CHENG P, et al. Short-term wind power forecasts by a synthetical similar time series data mining method[J]. *Renewable Energy*, 2017, 115: 575-584.
- [156] 殷豪, 欧祖宏, 陈德, 等. 基于二次模式分解和级联式深度学习的超短期风电功率预测[J]. *电网技术*, 2020, 44(2): 445-453.
- YIN Hao, OU Zuhong, CHEN De, et al. Ultra-short-term

- wind power prediction based on two-layer mode decomposition and cascaded deep learning[J]. Power System Technology, 2020, 44(2): 445-453.
- [157] 孙国强, 梁智, 俞娜燕, 等. 基于 EWT 和分位数回归森林的短期风电功率概率密度预测[J]. 电力自动化设备, 2018, 38(8): 158-165.
- SUN Guoqiang, LIANG Zhi, YU Nayan, et al. Short-term wind power probability density forecasting based on EWT and quantile regression forest[J]. Electric Power Automation Equipment, 2018, 38(8): 158-165.
- [158] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [159] HU R, HU W H, GOKMEN N, et al. High resolution wind speed forecasting based on wavelet decomposed phase space reconstruction and self-organizing map[J]. Renewable Energy, 2019, 140: 17-31.
- [160] YIN H, OU Z H, HUANG S Q, et al. A cascaded deep learning wind power prediction approach based on a two-layer of mode decomposition[J]. Energy, 2019, 189.
- [161] KHALID R, JAVAID N. A survey on hyperparameters optimization algorithms of forecasting models in smart grid[J]. Sustainable Cities and Society, 2020, 61: 102275.
- [162] LIU H, LI Y, DUAN Z, et al. A review on multi-objective optimization framework in wind energy forecasting techniques and applications[J]. Energy Conversion and Management, 2020, 224: 113324.
- [163] 殷豪, 曾云, 孟安波, 等. 基于奇异谱分析-模糊信息粒化和极限学习机的风速多步区间预测[J]. 电网技术, 2018, 42(5): 1467-1474.
- YIN Hao, ZENG Yun, MENG Anbo, et al. Wind speed multi-step interval prediction based on singular spectrum analysis-fuzzy information granulation and extreme learning machine[J]. Power System Technology, 2018, 42(5): 1467-1474.
- [164] 武小梅, 林翔, 谢旭泉, 等. 基于 VMD-PE 和优化相关向量机的短期风电功率预测[J]. 太阳能学报, 2018, 39(11): 3277-3285.
- WU Xiaomei, LIN Xiang, XIE Xuquan, et al. short-term wind power forecasting based on variational mode decomposition-permutation entropy and optimized relevance vector machine[J]. Acta Energaie Solaris Sinica, 2018, 39(11): 3277-3285.
- [165] 张亚超, 刘开培, 秦亮, 等. 基于聚类经验模态分解-样本熵和优化极限学习机的风电功率多步区间预测[J]. 电网技术, 2016, 40(7): 2045-2051.
- ZHANG Yachao, LIU Kaipei, QIN Liang, et al. Wind power multi-step interval prediction based on ensemble empirical mode decomposition-sample entropy and optimized extreme learning machine[J]. Power System Technology, 2016, 40(7): 2045-2051.
- [166] SUN H Y, QIU C Y, LU L, et al. Wind turbine power modelling and optimization using artificial neural network with wind field experimental data[J]. Applied Energy, 2020, 280: 115880.
- [167] LONG H, LI P K, GU W. A data-driven evolutionary algorithm for wind farm layout optimization[J]. Energy, 2020, 208: 118310.
- [168] CHEN J J, WU Q H, ZHANG L L, et al. Multi-objective mean-variance-skewness model for nonconvex and stochastic optimal power flow considering wind power and load uncertainties[J]. European Journal of Operational Research, 2017, 263(2): 719-732.
- [169] ALNAQI A, MOAYEDI H, SHAHSAVAR A, et al. Prediction of energetic performance of a building integrated photovoltaic/thermal system thorough artificial neural network and hybrid particle swarm optimization models[J]. Energy Conversion and Management, 2019, 183: 137-148.
- [170] 王丽婕, 王勃, 王铮, 等. 基于数学形态学聚类与果蝇优化算法的风电功率短期预测[J]. 太阳能学报, 2019, 40(12): 3621-3627.
- WANG Lijie, WANG Bo, WANG Zheng, et al. Wind power short-term prediction based on mathematical morphology cluster analysis and fruit fly optimization[J]. Acta Energaie Solaris Sinica, 2019, 40(12): 3621-3627.
- [171] DUBEY M H, PANDIT M, PANIGRAHI B K. Ant lion optimization for short-term wind integrated hydrothermal power generation scheduling[J]. International Journal of Electrical Power & Energy Systems, 2016, 83: 158-174.
- [172] EKREN O, EKREN B Y. Size optimization of a PV/wind hybrid energy conversion system with battery storage using simulated annealing[J]. Applied Energy, 2010, 87(2): 592-598.
- [173] 丁明, 张超, 王勃, 等. 基于功率波动过程的风电功率短期预测及误差修正[J]. 电力系统自动化, 2019,

- 43(3): 2-12.
- DI Ming, ZHANG Chao, WANG Bo, et al. Short-term forecasting and error correction of wind power based on power fluctuation process[J]. Automation of Electric Power Systems, 2019, 43(3): 2-12.
- [174] NAIK J, DASH S, DASH P K, et al. Short term wind power forecasting using hybrid variational mode decomposition and multi-kernel regularized pseudo inverse neural network[J]. Renewable Energy, 2018, 118: 180-212.
- [175] LI L L, CHANG Y B, TSENG M I L, et al. Wind power prediction using a novel model on wavelet decomposition-support vector machines-improved atomic search algorithm[J]. Journal of Cleaner Production, 2020, 270: 121817.
- [176] KARAMICHAILIDOU D, KALOUTSA V, ALEXANDRIDIS A. Wind turbine power curve modeling using radial basis function neural networks and tabu search[J]. Renewable Energy, 2021, 163: 2137-2152.
- [177] MAHARI A, ZARE K. A solution to the generation scheduling problem in power systems with large-scale wind farms using MICA[J]. International Journal of Electrical Power & Energy Systems, 2014, 54: 1-9.
- [178] BANSAL J C, FARSWAN P. Wind farm layout using biogeography based optimization[J]. Renewable Energy, 2017, 107: 386-402.
- [179] FANG R M, WANG Y D, SHANG R Y, et al. The ultra-short term power prediction of wind farm considering operational condition of wind turbines[J]. International Journal of Hydrogen Energy, 2016, 41(35): 15733-15739.
- [180] 杨茂, 周宜. 计及风电场状态的风电功率超短期预测[J]. 中国电机工程学报, 2019, 39(5): 1259-1268.
- YANG Mao, ZHOU Yi. Ultra-short-term prediction of wind power considering wind farm status[J]. Proceedings of the CSEE, 2019, 39(5): 1259-1268.
- [181] 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.
-
- 作者简介: 唐新姿, 女, 1981 年出生, 博士, 副教授, 硕士研究生导师。主要研究方向为风力发电技术。
E-mail: xinzitang@163.com
- 彭锐涛(通信作者), 男, 1982 年出生, 博士, 教授, 博士研究生导师。主要研究方向为绿色制造、风能与风力发电技术。
E-mail: pengruitao@xtu.edu.cn