

DOI:10.11784/tdxbz202501011

# 考虑出力区间预测和储能优化配置的风电场 调频容量估计两阶段模型

葛磊蛟<sup>1</sup>, 郑轶文<sup>1</sup>, 朱光明<sup>2,3</sup>, 杨丹<sup>4</sup>

(1. 天津大学电气自动化与信息工程学院, 天津 300072;

2. 国网湖南省电力有限公司电力科学研究院, 长沙 410007;

3. 高效清洁发电技术湖南省重点实验室, 长沙 410007; 4. 国网湖南省电力有限公司, 长沙 410000)

**摘要:** 风电场配置储能参与调频辅助服务具有显著意义, 既能大幅增加风电场收益, 又能有效提升电力系统的灵活性与稳定性。然而, 当前风电场在实际应用中面临风电场出力预测精准度欠佳、储能容量配置缺乏合理性、参与调频容量估计难度较大等诸多问题。为此, 针对上述问题, 本文提出一种考虑出力区间预测和储能优化配置的风电场调频容量估计两阶段模型。阶段 1 模型主要针对风电场出力预测精度不高的难题, 采用时间卷积网络(TCN)-长短期记忆(LSTM)网络-Transformer(TCN-LSTM-Transformer)分位数回归模型进行风电功率区间预测, 其中, TCN 能够高效提取出丰富的时序特征, LSTM 进行时序模型建模, Transformer 则有效捕捉数据的长时间依赖性, 三者协同, 精准获知风电场功率的波动区间; 进一步从风电场的历史弃风数据出发, 利用改进的蝴蝶算法实现风电场储能容量优化配置, 确保在风电功率出现波动时, 有足够的储能容量满足电力系统的调频需求; 在阶段 1 基础上, 阶段 2 模型基于风阻限值估算风电场在不同置信概率下的最佳调频容量, 进一步优化风电场的经济效益和系统稳定性。最后, 选取我国南方某地区风电场的实际数据进行仿真验证, 结果表明, 与点预测方法相比, 所提出的两阶段模型估计误差下降 55.6%, 经济效益提升 2%。该案例充分证明所提方法可为风电场接入下电力系统的灵活性改造提供有效技术支持。

**关键词:** 风电场调频容量估计; 改进蝴蝶算法; 储能优化配置; TCN-LSTM-Transformer 分位数回归; 风电功率预测  
**中图分类号:** TM73 **文献标志码:** A **文章编号:** 0493-2137(2026)02-0121-14

## Two-Stage Model for Estimation of Wind Farm Frequency Modulation Capacity Considering Power Probabilistic Prediction and Optimal Configuration of Energy Storage

Ge Leijiao<sup>1</sup>, Zheng Yiwen<sup>1</sup>, Zhu Guangming<sup>2,3</sup>, Yang Dan<sup>4</sup>

(1. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China;

2. Electric Power Research Institute, State Grid Hunan Electric Power Co., Ltd., Changsha 410007, China;

3. Hunan Province Key Laboratory of Efficient and Clean Power Generation Technology, Changsha 410007, China;

4. State Grid Hunan Electric Power Co. Ltd., Changsha 410000, China)

**Abstract:** The configuration of energy storage in wind farms to participate in frequency modulation (FM) auxiliary services is of great significance because this can considerably increase the income of wind farms and effectively improve the resulting power systems' flexibility and stability. However, in their actual application in wind farms, they currently face several challenges, including poor accuracy of wind farm output prediction, lack of rationality in energy storage capacity allocation, and greater difficulty in FM capacity estimation. To address this issue, a two-stage model of FM capacity estimation for wind farms is proposed, considering output interval prediction and the opti-

收稿日期: 2025-01-10; 修回日期: 2025-05-26.

作者简介: 葛磊蛟(1984—), 男, 博士, 副教授.

通信作者: 葛磊蛟, legendgj99@tju.edu.cn.

基金项目: 国家电网有限公司科技资助项目(5100-202323430A-3-2ZN).

Supported by the Science and Technology Project of State Grid Corporation of China (No. 5100-202323430A-3-2ZN).

mized configuration of energy storage. The Stage 1 model addresses the problem of the low output prediction accuracy of wind farms, and the TCN-LSTM-Transformer quantile regression model is used to predict the wind power interval. Specifically, TCN can efficiently extract rich time-series characteristics, LSTM performs time-series model modeling, and Transformer effectively captures the long-term dependence of data. These three components work together to accurately determine the fluctuation range of the power of the wind farm. Furthermore, starting from the wind farm's historical wind abandonment data, the improved butterfly algorithm is used to optimize the allocation of the wind farm's energy storage capacity. This ensures sufficient energy storage capacity to meet the power system's frequency modulation needs when the power of the wind power fluctuates. Then, building upon Stage 1, the Stage 2 model estimates the wind farm's optimal FM capacity under different confidence probabilities based on the wind resistance limit, further optimizing the wind farm's economic benefits and system stability. Finally, the actual data of a wind farm located in southern China are selected for simulation verification. The results indicate that the estimation error of the proposed two-stage model is reduced by 55.6%, and the economic benefits are increased by 2% compared with the point prediction method. This case fully proves that the proposed method can provide effective technical support for the flexible transformation of power systems driven by wind farms.

**Keywords:** wind farm frequency modulation capacity estimation; improved butterfly algorithm; optimal configuration of energy storage; TCN-LSTM-Transformer quantile regression; wind power prediction

风电场调频(frequency modulation, FM)容量估计是强随机性的风电场参与电力系统调频辅助服务的关键,面临诸多挑战。主要问题之一是风电本身的随机性和间歇性,使得单一数值的预测不够精准,无法满足实际调度需求<sup>[1]</sup>。传统的风电出力预测方法较难有效捕捉风速变化带来的功率波动,加大了调频容量精确估算的难度<sup>[2]</sup>。因此,通过应用概率密度模型,可较好预测风电功率在不同置信水平下的分布范围,进而获得更好的调频容量估计<sup>[3]</sup>。同时,现在的风电场均配置了一定容量的储能系统,以确保在风电波动时能提供稳定可靠的调频支持,进而保障风电场稳定运行。

针对风电出力预测研究,近年来一些学者聚焦于概率预测领域<sup>[4]</sup>。文献[5]根据预测误差时间相依性,进行误差校正,该方法在提升风电功率预测质量方面的显著成效。文献[6]提出了一种结合  $K$  均值聚类算法( $K$ -means clustering algorithm,  $K$ -means)和长短期记忆(long short-term memory, LSTM)网络的风电点预测方法,通过构建前后数据的相关性提高预测准确性。然而,点预测存在难以量化预测的缺点,对此文献[7]提出了一种基于朴素贝叶斯的正态指数平滑法的风电功率区间预测方法,进一步提高了风电功率的预测精度。文献[8]提出了一种基于自然梯度适用于短期风电功率概率分布预测的改进梯度提升算法,增强了预测结果的准确性。文献[9]构建了一个基于 LSTM 的分位数回归神经网络模型,结果证明了分位数回归估计条件分布具有较强的鲁棒性。文献[10]结合分位数回归与时间卷积网络(temporal convolutional network, TCN)进行概率密度预测,为

风电预测领域的研究开辟了新的路径。

另外,数据驱动的预测方法,在风电出力预测方面也得到一些应用。Transformer 模型是 2017 年被提出的典型代表,由于其自注意力机制的设计,能够有效地处理时间序列数据<sup>[11]</sup>。文献[12]对离散化海上风电机组进行聚类,并采用 Transformer 模型进行海上风电功率的超短期预测。文献[13]采用多级注意力机制捕捉风电功率序列的自相关性以及功率与气象数据间的耦合关系,并通过全连接层进行点预测和区间预测。文献[14]根据风电出力的季节性特点划分风电功率大小不同的月份进行测试,该方法需要更多的超参数且划分较为粗糙,不具有普适性。尽管上述方法一定程度提升了风电出力预测的准确性,但仍然存在参数设计复杂、预测效果不佳、计算精度不高系列问题,并且对于复杂时间序列学习能力依旧不足。

储能系统凭借快速充放电、快速响应和高爬坡速率等特性,能有效平抑风电出力的间歇性,减少弃风限电现象,大幅提升风电并入电网的兼容性与稳定性<sup>[15]</sup>。近年来,风电场及其周边均安装了一定容量的储能系统,保证了风电上网总电量增加<sup>[16]</sup>,从而提升风电场的经济效益。一些学者聚焦于风-储联合系统的调频控制策略,文献[17]提出使用比例-积分-微分控制算法调节频率变化率,并将其应用于风-储联合系统,以实现系统的有功输出的控制。此外,现有的电网调频辅助服务市场运营框架,风-储联合系统可提供的调频容量需要提前申报,且与储能系统容量的大小密切相关,因此,如何有效配置风电场的储能容量,以支持风电系统参与电力系统调频,成为亟

待解决的关键问题之一。

针对风电并网电力系统中储能容量配置问题,国内外学者进行了一些研究,主要包括模型预测控制、聚类分析算法、随机规划和基于功率预测误差的方法等<sup>[18-24]</sup>。文献[18]结合云模型理论与  $K$  均值聚类算法,生成了充放电曲线的典型集合,并将其输入到储能容量优化模型中,以确定储能系统的配置方案;文献[19]构建了一种基于经验模态分解的风电功率分配策略,并据此构建了两阶段储能容量优化配置模型;文献[20]在考虑风电不确定性的基础上,修正了概率分布函数,并以弃风率为约束,建立了鲁棒机会约束规划模型,以确定风电场的最佳储能配置;文献[21]针对传统方法求解精度差、效率低的问题,提出了一种改进的多目标蝗虫优化算法(improved multi-objective grasshopper optimization algorithm, IMOGO),为后续研究奠定了基础。然而,这些研究仅关注于储能系统本身以减少风电出力波动,而较少研究风电与储能联合系统在电力系统调频中的潜力,特别是关于风-储联合调频容量的估计方法及储能系统如何配置以高效辅助风电调频、避免资源浪费的研究尚显不足。文献[25]针对新能源场站参与调频应用场景下的储能系统进行配置,但是又忽略了对于风电出力波动平抑的需求。

综上所述,本文提出了一种考虑风电出力区间预测和储能优化配置的风电场调频容量估计两阶段模型。该模型在阶段 1 采用基于 TCN-LSTM-Transformer 的分位数回归模型,预测不同置信水平下的日前风电功率预测区间;利用风电场历史弃风功率数据,通过改进的蝴蝶算法优化储能系统容量配置,以确定最优的风-储系统配置,增强其在调频市场的参与度。阶段 2 模型基于风电出力的概率区间预测结果,以及储能系统吸收弃风容量,进一步确定风电场申报的调频容量,为电力系统调度决策提供支撑,从而提高风电储能系统的经济效益。通过南方某地区风电场实际数据的案例仿真验证,验证了本文方法显著降低了调频容量估计误差,有效提升了风电场的收益。

## 1 基于概率预测的调频容量估计两阶段模型

### 1.1 风电场调频容量估计基本原理

风储联合系统运行中的弃风和调频过程,基本思路是储能系统在限风时段吸收多余的风电,在非限风时段将吸收的风电用于调频市场<sup>[26]</sup>。在预测风电场可提供的日前调频容量时,根据风电预测功率和调度的功率限值曲线计算弃风功率,并将其转化为储能系

统的存储量,从而保障风电场可提供日前调频容量。通过估算风电场在不同置信概率下的最佳调频容量,可以更有效地利用储能系统来平衡风电功率的不确定性,优化风电场的调频策略。这种方法的核心是利用风电功率预测的概率分布,在特定置信区间内确定储能系统的调频容量,从而在保证电网稳定性的同时,最大化风电的利用效率。

基于概率预测的调频容量估计的主要步骤如下。

**步骤 1** 确定储能系统需要补偿的功率波动区间。假设风电功率的实际值为  $P_{\text{actual}}$ , 预测值为  $P_{\text{pred}}$ , 则储能系统需要补偿的偏差为

$$\Delta P = P_{\text{actual}} - P_{\text{pred}} \quad (1)$$

**步骤 2** 通过置信区间确定不同情境下的储能容量需求  $C_R$ 。假设选择 90% 的置信区间,则需要满足

$$C_R = \max\{Q_{90\%} - Q_{50\%}, |Q_{10\%} - Q_{50\%}|\} \quad (2)$$

式中  $Q$  为风电功率偏差的分位数。

**步骤 3** 储能调频容量优化。定义储能系统的容量需求为  $C_\alpha$ , 其中  $\alpha$  表示置信区间,则优化公式可表示为

$$C_\alpha = k_\alpha \sigma_{\text{forecast}} \quad (3)$$

式中:  $k_\alpha$  为基于置信区间  $\alpha$  的扩展因子,可以通过正态分布的累积分布函数得到,例如在 90% 的置信区间下,  $k_{90\%} \approx 1.28$ ;  $\sigma_{\text{forecast}}$  表示预测误差的标准差。

**步骤 4** 设定优化储能容量配置的目标函数,采用改进后的蝴蝶算法进行求解,得到储能容量的最优配置,平衡系统稳定性与储能成本。

### 1.2 模型求解流程

在进行风储联合系统运行优化时,风电功率的波动性和预测的不确定性是主要挑战之一。为解决这一问题,本文提出了基于两阶段模型的求解方法。在阶段 1 中,重点是从长期运行数据中提取风电场的历史特性,结合储能系统的优化策略,确定储能容量和功率配置方案。这一阶段的核心目标是为后续阶段提供稳定可靠的储能配置基础,并通过概率预测方法尽量降低风电功率预测误差对模型求解的影响。而在阶段 2 中,则聚焦于短期调频容量的估算,进一步结合风电功率预测的区间范围和储能配置方案,动态优化不同置信水平下的调频容量估计值。通过此分阶段求解,能够有效地分离长时间尺度的容量配置问题和短时间尺度的调频优化问题,从而降低问题的复杂度,提升求解效率和准确性。

#### 1.2.1 阶段 1 模型

(1) 收集风电场的风速和功率数据,进行数据预处理。删除缺失值、停机点、限功率点以及分散异常

数据点等不合理或异常数据. 停机点、限功率点和分散异常数据点使用统计分析<sup>[27]</sup>方法进行识别和删除, 以保证数据集的完整性和准确性. 具体步骤如下.

**步骤 1** 针对异常数据, 采用风速与功率的联合相关性分析进行同步识别. 具体而言, 通过构建风速-功率散点图, 剔除显著偏离理论功率曲线(超出  $\pm 3\sigma$  范围)的数据点, 同时结合滑动窗口统计法检测时间序列中的突变点.

**步骤 2** 对于时间序列中因异常值删除导致的缺失点, 则采用线性插值法利用前后相邻点进行填充.

(2) 基于风电场 1a 的历史运行数据和年弃风率, 采用随机模拟方法生成风电场 365 d 的弃风功率数据, 进而使用改进的蝴蝶算法深度优化储能容量配置策略, 确定风电场最合适的储能容量和功率配置方案. 具体步骤如下:

**步骤 1** 统计历史弃风事件的持续时长与功率幅值, 拟合为威布尔分布(形状参数  $k = 2.1$ , 尺度参数  $\lambda = 3.5$ );

**步骤 2** 采用蒙特卡洛模拟生成 365 d 的弃风功率序列, 每日弃风时段与功率值通过随机抽样确定, 并约束年弃风率为 4%.

**步骤 3** 通过 K-S 检验验证生成数据与历史数据的分布一致性( $p > 0.05$ ).

(3) 根据特定的置信水平, 利用 TCN-LSTM-Transformer 分位数回归模型, 可以计算得到预测风功率的上分位点和下分位点, 从而确定风功率的预测区间.

(4) 将求出的储能容量和功率配置方案以及风功率的预测区间输入阶段 2 模型进行下一步的求解.

### 1.2.2 阶段 2 模型

阶段 2 模型主要结合风电功率预测区间和优化后的储能配置方案, 并考虑风电功率的限制条件, 进一步分析不同置信水平下的调频容量估计值. 通过比较和评估, 最终确定最优的调频容量估计, 以支持风电场调频策略的制定和实施.

基于风电功率预测区间(上分位点  $U_\alpha$ 、下分位点  $L_\alpha$ )和储能配置容量  $E_{ESS}$ , 调频容量  $C_{FM}$  计算式为

$$C_{FM} = \min \left\{ E_{ESS}, \sum_T \max [0, U_\alpha(t) - P_{limit}(t)] \cdot T \right\} \quad (4)$$

式中:  $P_{limit}(t)$  为  $t$  时段的风阻限值;  $T$  为时间分辨率. 该式确保调频容量不超过储能容量, 并覆盖预测区间内的弃风功率.

综上所述, 本文所提出的两阶段模型整体的求解流程如图 1 所示.

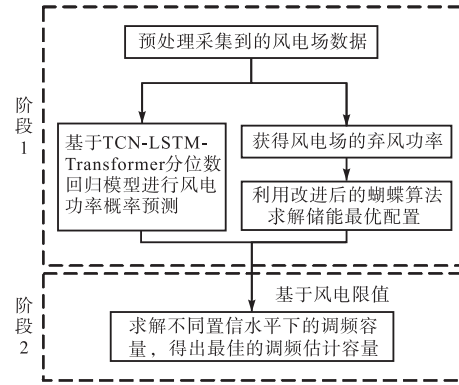


图 1 两阶段模型求解流程

Fig.1 Solving process of two-stage model

在两阶段模型的求解过程中, 需进一步结合具体的概率预测与优化配置, 以提升模型的实用性与精确性, 这是因为风电功率的概率预测是调频容量优化的关键基础. 由于风电功率的波动性和不可控性, 精准的概率预测可以为模型提供可靠的风电功率预测区间. 这不仅能够有效减少预测误差对储能配置的影响, 还能为调频容量估计提供精确的输入数据, 从而保证模型优化结果的科学性与准确性. 因此, 本文采用了 TCN-LSTM-Transformer 分位数回归模型, 通过结合 TCN、LSTM 和 Transformer 模型的优势, 进一步提高风电功率预测的准确性, 为后续优化配置奠定坚实基础.

其次, 储能容量配置是平衡系统稳定性与经济性的核心. 储能系统的容量配置需要充分考虑风电功率的波动特性和弃风功率的时序分布, 优化储能的容量与功率输出, 不仅能够有效吸收多余的风电, 还能确保储能系统在调频市场中的经济效益最大化. 通过基于改进蝴蝶算法的深度优化方法, 可以更高效地在多目标之间寻找平衡点, 从而进一步完善风储联合系统的运行优化策略.

因此, 在两阶段模型的基础上, 开展风电功率的概率预测与储能系统的优化配置, 能够为风储联合系统的调频策略制定提供全面支持. 这种方法论的衔接使得模型具备从数据预测到优化实施的完整链条, 确保了理论分析与工程实际的紧密结合.

## 2 基于 TCN-LSTM-Transformer 分位数回归的风电功率概率预测

风电功率数据通常呈非对称分布, 而均值回归在处理类似非对称分布和离散的数据时面临挑战<sup>[28]</sup>. 相比之下, 分位数回归能够生成目标变量的多个分位数预测, 从而为不确定性分析提供更精确的信息. 与

常规的回归模型不同,分位数回归不仅预测平均值,还可以预测特定分位数下的值(如0.1分位数、0.5分位数和0.9分位数),以应对各种风险场景.在风电功率预测或其他时间序列预测中,单一点预测不足以反映数据的波动性和风险,而分位数回归提供了预测结果的完整概率分布.TCN模型能够通过因果卷积有效捕捉时间序列的长期依赖性,能够在较短的计算时间内提取出丰富的时序特征;LSTM模型能够通过其门控机制防止梯度消失,从而建模复杂的时序关系;Transformer模型则作为一种强大的序列到序列模型,能够有效捕捉长时间依赖性,尤其在处理复杂的时间序列问题时,优势显著.将TCN、LSTM、Transformer与分位数回归结合,可以同时处理非线性、长时依赖性和不确定性问题.其目标函数为

$$\min \frac{1}{N} \sum_{n=1}^N \{\omega_{\varepsilon} [y_n - \hat{P}_{y_n}(\varepsilon)]\} = \frac{1}{N} \sum_{n=1}^N \{\{\varepsilon - M[y_n - \hat{P}_{y_n}(\varepsilon)]\} [y_n - \hat{P}_{y_n}(\varepsilon)]\} \quad (5)$$

式中:  $\omega_{\varepsilon}$  表示检查函数;  $N$  表示总的样本数;  $y_n$  表示样本  $n$  的实际值;  $\hat{P}_{y_n}(\varepsilon)$  表示不同分位数  $\varepsilon$  下的输出,即风电功率点预测误差随机变量  $y$  的条件分位数估计值,  $\varepsilon \in (0, 1)$ ; 指数函数  $M(x)$  为

$$M(x) = \begin{cases} 0 & x \geq 0 \\ 1 & x < 0 \end{cases} \quad (6)$$

$$x = y_n - \hat{P}_{y_n}(\varepsilon) \quad (7)$$

TCN-LSTM-Transformer分位数回归实现风电功率预测的主要步骤如图2所示.

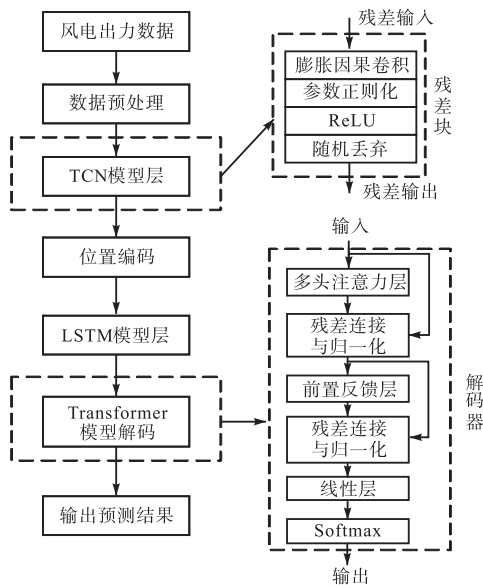


图2 TCN-LSTM-Transformer分位数回归模型

Fig.2 Regression model of TCN-LSTM-Transformer quantile

(1) 数据预处理. 模型输入数据为时间序列数据,主要包括目标变量(风电功率)以及相关的特征变量(气象数据),首先对输入数据进行标准化处理,确保模型输入数据的尺度一致.

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (8)$$

(2) 膨胀卷积计算. TCN通过一系列的因果卷积和残差连接构建深层网络,提取风电功率序列的长期依赖特征,每层包含残差连接(residual connection)与归一化(LayerNorm).本文采用的是膨胀卷积,这种操作保证了信息在时间序列中的传播而不会造成信息泄露.

$$y(t) = \sum_{k=0}^{K-1} w(k)x(t-bk) \quad (9)$$

式中:  $y(t)$  表示卷积操作的输出;  $w(k)$  表示卷积核的权重;  $x(t-bk)$  表示输入序列的元素;  $b$  表示膨胀率.

(3) TCN的残差输出经标准化后,与正弦位置编码(sinusoidal positional encoding)逐元素相加,保留时序位置信息.

$$Z'_t = Z_t + \text{PosEnc}(t) \quad (10)$$

式中:  $Z_t$  表示位置  $t$  的TCN输出;  $\text{PosEnc}(t)$  表示基于位置  $t$  的编码.

(4) 将融合后的特征输入双向LSTM(隐藏单元数=128),捕捉时序动态特性.

(5) LSTM的输出经线性投影后,输入Transformer编码层(头数=8),通过多头注意力机制建模变量间全局依赖关系;多头注意力计算输入序列的表示为

$$A(Q, K, V) = \text{Softmax} \left( \frac{QK^T}{\sqrt{\sigma}} \right) V \quad (11)$$

式中:  $Q$ 、 $K$ 、 $V$  分别代表查询矩阵、键矩阵和值矩阵;  $\sigma$  表示缩放因子,也就是键矩阵的维度.

(6) 最终通过分位数回归层生成不同置信水平的预测区间.针对每个分位数  $\tau$ ,分位数回归损失函数为

$$L_{\tau}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \tau(y_i - \hat{y}_i) M(y_i - \hat{y}_i) + \frac{1}{n} \sum_{i=1}^n (1 - \tau)(\hat{y}_i - y_i) M(y_i - \hat{y}_i) \quad (12)$$

式中:  $y_i$  为真实值;  $\hat{y}_i$  为模型预测值;  $\tau$  为分位数.

在完成风电功率的概率预测后,得到不同置信水平下的风电功率预测区间,这些预测结果为储能系统的优化配置和调频容量的精准估计提供了重要依据,具体分析如下.

首先,概率预测结果为储能容量配置提供准确的

输入数据. 通过确定风电功率的上分位点和下分位点, 可以估算出储能系统在不同功率波动场景下的需求, 确保储能配置方案能够覆盖绝大部分实际运行情况, 从而提升系统的可靠性和经济性. 此外, 预测区间可以反映风电功率的波动范围, 有助于储能系统更精确地匹配风电功率的上下限, 减少弃风损失.

其次, 概率预测结果是调频容量优化的重要基础. 结合风电功率的预测区间, 可以在调频容量估算中引入置信水平的概念, 使得调频策略能够更加灵活地应对风电功率的波动. 不同置信水平下的预测结果可以为风电场提供多种调频方案的选择, 从而在系统稳定性与储能成本之间寻找平衡.

因此, 有了概率预测的结果, 不仅能够更加精确地优化储能系统的容量配置, 还能为后续的调频容量估算和风储联合系统的运行优化提供科学依据.

### 3 风电场储能容量配置

在风电场运行过程中, 由于风电功率的波动性和不可控性, 常常会出现弃风现象, 即部分风电因未被及时消纳而浪费. 为提升风电的利用率并参与调频辅助服务市场, 配置合理的储能系统成为风储联合系统优化的关键任务. 储能系统通过在弃风时吸收多余的风电, 在调频需求时释放电能, 不仅能够减少弃风损失, 还能为风电场带来额外的经济收益. 因此, 科学合理地进行储能容量配置至关重要.

#### 3.1 目标函数及约束条件

(1) 储能成本: 功率成本主要与储能系统充放电功率的大小有关, 能量成本决定储能系统的充放电时长, 则有

$$C = C_p P_{ESS} + C_E E_{ESS} \quad (13)$$

式中:  $P_{ESS}$  为储能系统配置的功率, MW;  $E_{ESS}$  为储能系统配置的容量, MW · h;  $C_p$  为储能功率的单位投资, 万元;  $C_E$  为储能系统容量的单位投资, 万元.

储能系统的等年值利率折算公式为

$$C(u, h) = \frac{u(1+u)^h}{(1+u)^h - 1} \quad (14)$$

式中:  $u$  为储能系统的年利率;  $h$  为储能系统的运行寿命.

此外, 考虑到资金投入的时间价值, 需要对储能系统的投资成本进行修正, 修正后为

$$C' = C(u, h)(C_p P_{ESS} + C_E E_{ESS}) \quad (15)$$

(2) 风储系统年收益主要通过储能系统消纳弃风后投入调频辅助市场获得, 即

$$R = \sum_{d=1}^{365} E_{ESS(d)} \cdot (P_1 + P_2) \quad (16)$$

式中:  $E_{ESS(d)}$  为第  $d$  天储能系统利用弃风吸收的容量, MW · h;  $P_1$  为风电的上网价格, 万元/(MW · h);  $P_2$  为调频服务申报补偿价格, 万元/(MW · h).

$E_{ESS(d)}$  由储能系统配置的容量、功率以及第  $d$  天风电场的弃风功率决定, 其表达式分别为

$$E_{ESS(d)} = \begin{cases} \sum_v P_d^v \cdot T & \sum_v P_d^v \cdot T < E_{ESS}^{\max} \\ E_{ESS} & \sum_v P_d^v \cdot T \geq E_{ESS}^{\max} \end{cases} \quad (17)$$

$$P_d^v = \begin{cases} P_d^v & P_d^v \leq P_{ESS}^{\max} \\ 0 & P_d^v > P_{ESS}^{\max} \end{cases} \quad (18)$$

式中:  $P_d^v$  和  $P_d^v$  为修正前、后的第  $d$  天  $v$  时刻风电场的弃风功率, MW;  $E_{ESS}^{\max}$  为配置储能系统的最大容量, MW · h;  $P_{ESS}^{\max}$  为配置储能系统的最大功率, MW.

(3) 综合目标函数为

$$F = \max(R - C) \quad (19)$$

#### 3.2 改进蝴蝶算法

在评估风电场调频容量时, 由于风电场储能配置的功率和容量有限, 当弃风功率超过储能系统的最大处理能力时, 储能系统无法完全吸收多余的风能. 因此, 优化风电场的储能容量配置是关键任务. 合理配置储能容量对于风电场的经济效益至关重要, 同时能有效利用储能资源, 避免浪费, 并提升系统的整体经济性.

本文基于风电场历史弃风功率数据, 建立了一个储能优化配置模型, 其目标是最大化风-储联合系统的年度净收益. 考虑到风电并网过程中由于电网负荷波动性所导致的变化, 本研究采用了随机模拟技术, 基于历史弃风率和功率数据, 提取并生成风电场的 365 d 的历史弃风数据集. 模型采用改进蝴蝶算法进行求解, 改进蝴蝶算法实现储能最优配置求解的工作原理具体如下.

(1) 种群初始化. 初始化蝴蝶种群  $S$ .

(2) 适应度计算. 计算种群中所有个体的适应度值, 即每个蝴蝶个体的香味强度为

$$f = cS_1^\lambda \quad (20)$$

式中:  $c$  表示感觉模态;  $S_1$  表示刺激强度;  $\lambda$  表示幂指数.

(3) 将所有蝴蝶个体按照其香味强度升序进行排列.

(4) 将整个蝴蝶种群分为 3 个组: 第 1 组蝴蝶占总蝴蝶数量的 10% ~ 20%; 第 2 组蝴蝶占总数的

50% ~ 60%; 其余的是第3组蝴蝶的一部分。

第1组蝴蝶被认为是所有蝴蝶中的精英成员, 并保持不变。

第2组蝴蝶按照原始搜索空间进行搜索, 结合切换概率  $p$  分为全局搜索和本地搜索, 计算式为

$$S_i^{t+1} = \begin{cases} S_i^t + [\text{rand}()g^* - S_i^t]f^i & \text{rand}() \leq p \\ S_i^t + [\text{rand}()S_j^t - S_i^t]f^i & \text{rand}() > p \end{cases} \quad (21)$$

式中:  $S_i^t$ 、 $S_j^t$  以及  $S_k^t$  分别表示迭代次数为  $t$  时刻第  $i$  个蝴蝶、第  $j$  个蝴蝶以及第  $k$  个蝴蝶的解;  $g^*$  表示当前迭代次数下的最佳解决方案;  $f^i$  表示第  $i$  个蝴蝶的香味强度;  $\text{rand}()$  表示  $0 \sim 1$  之间的随机数。

第3组蝴蝶按照交易所市场交叉算法 (exchange market algorithm, EMA) 的平衡阶段进行交叉, 即

$$Y_e^{\text{group}2} = aY_{1,e}^{\text{group}1} + (1-a)Y_{2,e}^{\text{group}1} \quad (22)$$

$$X_k = 2r_1(Y_{1,e}^{\text{group}1} - Y_k^{\text{group}3}) + 2r_2(Y_{2,e}^{\text{group}1} - Y_k^{\text{group}3}) \quad (23)$$

式中:  $Y_e^{\text{group}2}$  表示第2组中的第  $e$  个蝴蝶个体;  $Y_{1,e}^{\text{group}1}$  和  $Y_{2,e}^{\text{group}1}$  表示第1组中随机选择的两个蝴蝶个体;  $Y_k^{\text{group}3}$  表示从第3组中随机选择的第  $k$  个蝴蝶个体;  $a$ 、 $r_1$  以及  $r_2$  均为  $0 \sim 1$  之间的随机数。

按照非均匀突变进行变异, 即

$$\Delta = \begin{cases} (u_{b_i} - d_i)(1 - a^y) & a \geq 0.5 \\ (l_{b_i} - d_i)(1 - a^y) & a < 0.5 \end{cases} \quad (24)$$

$$Y = \left(1 - \frac{g}{\mu}\right)^z \quad (25)$$

式中:  $u_{b_i}$  表示要更新的控制变量的最大限制;  $l_{b_i}$  表示所有要更新的控制变量的最小限制;  $d_i$  表示要更新的控制变量;  $g$  表示当前迭代次数;  $\mu$  表示迭代总次数;  $z$  为形状参数。

(5) 迭代和收敛. 判断是否满足最大迭代次数, 若满足, 则输出最优解; 若不满足, 则重复上述步骤, 直至算法收敛到一个较优的储能容量配置。

综上所述, 本文所提出的改进蝴蝶算法整体流程如图3所示。

在完成阶段1的储能容量与功率优化配置后, 已经得到了基于历史弃风数据和风电功率概率预测的储能系统配置方案. 该方案提供了储能系统的最优功率和容量, 以最大化风储联合系统的年净收益为目标. 在此基础上, 阶段2主要针对储能系统的调频容量估计问题展开研究, 旨在进一步优化风电场的经济效益和系统稳定性。

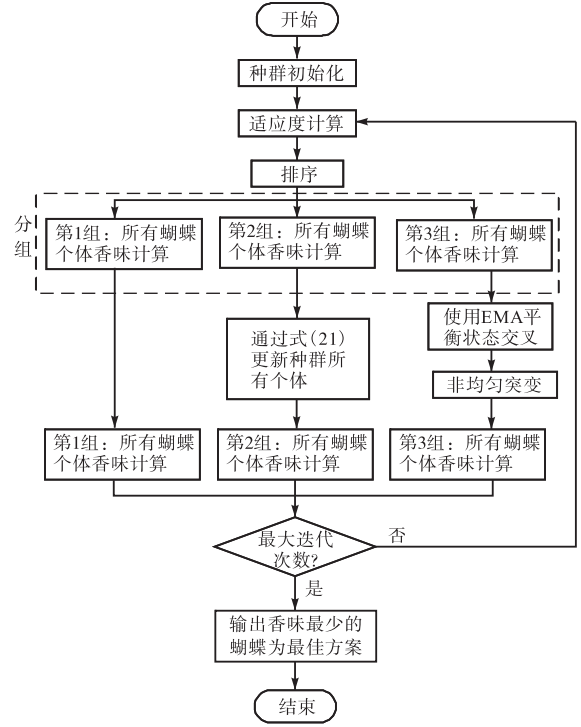


图3 改进蝴蝶算法流程

Fig.3 Flow chart of the improved butterfly algorithm

## 4 算例分析

采用南方某地区风电场实际风电历史数据, 采样率为  $10 \text{ min}$ . 其中, 该风场共有  $25$  台  $2 \text{ MW}$  变桨距调节三叶片双馈异步风力发电机组。

### 4.1 阶段1模型求解

#### 4.1.1 储能容量配置

首先选取本文储能所用电池, 这里选取了3种类型, 各参数具体如表1所示<sup>[29-30]</sup>. 风电场对应的调频储能容量配置过程如下。

表1 不同储能电池

Tab.1 Different energy storage batteries

电池类型	功率成本/ (万元/MW)	容量成本/ (万元/(MW·h))	充放电 效率	寿命/ a
磷酸铁锂电池	600	1 600	0.95	25
钠硫电池	800	1 400	0.85	15
全钒液流电池	1 000	1 200	0.75	20

(1) 根据国家能源局数据显示, 我国南方地区的弃风率约为  $4\%$ , 对该风电场  $1a$  的历史功率进行处理, 抽取其中  $4\%$  的数据作为风电场  $1a$  的弃风功率。

(2) 改进蝴蝶算法的参数设置如下: 种群规模为  $100$ , 最大迭代次数为  $300$ , 配置容量范围为  $[0, 50] \text{ MW} \cdot \text{h}$ , 配置功率范围为  $[0, 10] \text{ MW}$ . 通过与交易所市场交叉算法结合的改进蝴蝶算法, 以最大化风储

系统的年经济收益最大化为目标,优化求解风电场的最佳储能容量与功率配置.结果如图 4 和图 5 所示,由此可知,储能容量和功率配置随着迭代次数的增加而趋于稳定,同时风储系统的年收益也随之增加并最终趋于稳定.




图 4 风储系统年收益变化曲线

Fig.4 Change curve of wind storage system annual revenue




图 5 储能功率以及容量配置的优化

Fig.5 Optimization of energy storage power as well as allocated capacity

结合蝴蝶优化算法对式(16)中的调频补偿价格  $P_2$  进行分析,选取适当的  $P_2$ ,其中  $P_2 \in [8, 16]$ 元/(MW·h),步长为 2 元/(MW·h).具体结果如表 2 所示,由此可知本文调频补偿价格取 12 元/(MW·h),风电上网价格为 570 元/(MW·h).

表 2 不同调频补偿价格的影响

Tab.2 Impact of different FM compensation prices

$P_2$ /(元/(MW·h))	调频容量误差/(MW·h)	风储系统最优年收益/万元
8	1.3	19.2
10	1.1	22.6
12	0.7	25.8
14	0.9	29.1
16	1.2	32.4

此外,根据改进后的蝴蝶算法不同储能方式的优化结果(见表 3),可知相比较钠硫电池和全钒液流电池,磷酸铁锂电池更符合本文设定的约束范围要求,且年收益最高.因此,本文后续实验选取磷酸铁锂电

池为代表,最优的储能设备配置为 10 MW × 1.34 h.

表 3 最佳储能配置方案

Tab.3 Optimized programme of energy storage

电池类型	最优储能容量配置/(MW·h)	最优储能功率/MW	风储系统最优年收益/万元
磷酸铁锂电池	13.4	10	24.5
钠硫电池	15.2	12	22.1
全钒液流电池	18.6	14	20.3

此外,将本文所提出的改进蝴蝶算法分别与传统的粒子群算法(particle swarm algorithm, PSO)、灰狼算法(gray wolf algorithm, GWO)、非支配遗传排序算法 II(non-dominated genetic sorting algorithm II, NSGA-II)、非支配遗传排序算法 III(non-dominated genetic sorting algorithm III, NSGA-III)以及蝴蝶算法(butterfly optimization algorithm, BOA)求解的结果对比,如表 4 所示.由表 4 可知,无论是最优储能容量的配置,还是风储系统最优年收益,本文所提算法都得到了更优的结果.

表 4 不同优化求解算法的结果对比

Tab.4 Results comparison of different optimization solving algorithms

算法	最优储能容量/(MW·h)	风储系统最优年收益/万元
PSO	13.2	22.7
GWO	12.6	17.2
NSGA-II	12.9	21.3
NSGA-III	12.4	15.1
BOA	13.1	22.4
本文算法	13.4	24.5

#### 4.1.2 风电功率概率预测

首先选取评价指标体系检验本文所提出的基于 TCN-LSTM-Transformer 分位数回归模型的可靠性和准确性.

(1) 预测区间覆盖率(prediction interval coverage probability, PICP)指标  $\theta$ . 计算区间的可靠性,即真实值在预测区间内的概率,区间覆盖率的值越大,则表示模型的可靠性越高,其计算式为

$$\theta = \frac{1}{N} \sum_{\beta=1}^N c_{\beta} \quad (26)$$

$$c_{\beta} = \begin{cases} 1 & y_{\beta} \in [L_{\beta}, U_{\beta}] \\ 0 & y_{\beta} \notin [L_{\beta}, U_{\beta}] \end{cases} \quad (27)$$

式中:  $N$  表示预测点个数;  $U_{\beta}$ 、 $L_{\beta}$  分别表示预测区间的上、下界.

(2) 预测区间平均宽度(prediction interval average width, PIAW)指标  $W$ . 区间平均宽度值越小,则表明模型的预测性能越好,计算式为

$$W = \frac{1}{N} \sum_{\gamma=1}^N \frac{U_{\gamma} - L_{\gamma}}{y_{\gamma}} \quad (28)$$

式中  $U_{\gamma}$ 、 $L_{\gamma}$  分别表示置信区间的上、下界, 当预测结果的  $\theta$  相同时, 较小的  $W$  表示预测效果更优。

模型参数设置如下: TCN 层数 = 4, LSTM 隐藏单元 = 128, Transformer 头数 = 8; 划分数据集的 70% 为训练集, 20% 为验证集, 10% 为测试集。

接着分别进行不同置信概率下的风电功率预测, 本文采取的置信水平分别为 90%、80%、70%, 其预测区间结果如图 6 所示。




图 6 不同置信水平下的预测结果

Fig.6 Prediction results at different confidence levels

表 5 展示了不同置信水平下各模型的预测性能对比. 分析结果表明, 在点预测场景中, 本文模型以 84.1% 的覆盖率和 11.4 MW 的区间宽度优于 TCN、LSTM 和 Transformer 模型, 初步验证了其预测精度

和不确定性量化能力. 随着置信水平从 70% 逐步提升至 90%, 本文模型展现出稳定的覆盖率增长和区间宽度控制, 特别是在 90% 置信区间下, 本文模型在保持 94.7% 覆盖率的同时, 将区间宽度压缩至 22.3 MW, 较 LSTM 减少 10.2%, 较 Transformer 模型缩减 2.6%, 实现了覆盖率与区间宽度的更优平衡. 横向对比发现, Transformer 虽在 90% 区间下覆盖率略高 0.7%, 但在低置信区间 (如 70%) 的覆盖率衰减更快, 而本文模型在 70%~90% 置信区间内 PICP 波动幅度更小 ( $\pm 4.1\%$ ), 表现出更强的鲁棒性. 实际应用中, 保守决策场景建议选择 90% 置信区间, 此时本文模型提供 94.7% 的风险覆盖; 精确性优先场景可采用 70% 区间, 在 12.5 MW 的窄宽度下仍保证 90.6% 的覆盖率, 较 Transformer 模型缩减区间宽度达 34.2%. 上述数据充分表明, 本文模型在不同置信水平下均能实现覆盖率与区间宽度的更优解, 其预测结果兼具可靠性和实用性.

表 5 不同置信水平下的预测性能

Tab.5 Prediction performance at different confidence levels

置信区间	预测模型	$\theta/\%$	$W/\text{MW}$
点预测	TCN	82.1	25.6
	LSTM	83.5	22.4
	Transformer	83.7	11.8
	本文模型	84.1	11.4
90%	TCN	91.1	23.8
	LSTM	93.6	24.7
	Transformer	95.4	22.9
80%	TCN	90.9	21.9
	LSTM	91.7	20.4
	Transformer	92.3	18.2
70%	TCN	87.6	16.8
	LSTM	88.6	17.5
	Transformer	89.5	13.3
	本文模型	90.6	12.5

此外, 为了验证本文所提模型的普遍性, 将数据集根据天气类型 (晴天、阴天、大风天、低风天) 进行细分, 结合风电场所在区域的气象观测数据进行标注: 晴天对应日照强度  $> 700 \text{ W/m}^2$  且云量  $< 30\%$ ; 阴天对应日照强度  $< 250 \text{ W/m}^2$  且云量  $> 70\%$ ; 大风天与低风天则基于风速分布, 其中大风天为日平均风速  $> 6 \text{ m/s}$ , 低风天为日平均风速  $< 3 \text{ m/s}$ . 并分别与 TCN、LSTM、Transformer 模型进行对比, 结果如表 6 所示, 证明了本文所体模型的普遍性和适用性.

## 4.2 阶段 2 模型求解

### 4.2.1 风电场调频容量估计

针对低光伏渗透率区域, 根据风电场的功率限值

表 6 不同天气下的预测结果

Tab.6 Predicted results under different weather conditions

天气类型	预测模型	$\theta/\%$	$W/MW$
晴天	TCN	83.1	24.9
	LSTM	84.3	22.1
	Transformer	84.5	11.3
	本文模型	84.9	10.9
阴天	TCN	80.9	25.2
	LSTM	81.4	22.8
	Transformer	81.7	11.9
	本文模型	82.3	11.4
大风天	TCN	80.3	25.7
	LSTM	80.9	23.4
	Transformer	81.1	12.6
	本文模型	81.9	12.2
低风天	TCN	79.7	26.1
	LSTM	80.5	23.8
	Transformer	80.6	13.1
	本文模型	81.4	12.9

设定,每日的 00:00—06:00 为电网调峰受限时段,风电场的出力限值为 25 MW,非受限时段的出力限值为 50 MW;针对高光伏渗透率区域,光伏出力高峰时段(08:00—16:00)风电出力的限值为 30 MW;夜间调峰受限时段(00:00—06:00)的限值为 25 MW;其他时段限值为 50 MW. 此时本文选取的风电场为低光伏渗透区域. 此外,储能系统容量按照第 4.1.1 节中的最佳方案配置为 10 MW × 1.34 h.

在限风时段,储能系统吸收弃风,而风电场不参与调频市场. 反之,在非受限时段,储能系统则放电,同时风电场参与调频市场. 根据预测功率结果和功率限制曲线,计算弃风功率并估算风电场的调频能力. 在考虑储能系统容量配置时,约束条件包括功率上限(10 MW)和最大吸收容量(13.4 MW · h). 当弃风功率超过 10 MW 时,储能无法吸纳;当吸收容量达到 13.4 MW · h 时,储能停止吸收. 表 7 展示了根据不同置信水平下的区间预测结果,生成的风电场调频容量估计. 这些预测基于 TCN-LSTM-Transformer 分位数回归模型,其中点预测结果是在分位点  $\tau = 0.5$  时求解得到的.

随着置信度增加,根据表 7,按预测的功率区间估计调频容量逐渐减少. 点预测的调频容量估计值集中在 70%~80%的置信区间内. 为了进一步评估这些估计的准确性,根据实际风电场发电数据,可得实际提供的调频容量为 12.5 MW · h. 图 7 显示了各调频容量估计与实际值的误差. 根据误差分析,80%置信区间下限的调频容量估计为 11.6 MW · h,是当天的最佳调频容量申报,与实际调频容量的误差为

0.4 MW · h. 相比于点预测的误差要减少 0.5 MW · h,因此,可以得出,采用考虑不确定性的概率区间预测能够更精确地估计调频容量需求.

表 7 不同置信水平下预估的调频容量

Tab.7 Predicted frequency modulation capacities at different confidence levels

不同置信区间	预估调频容量/(MW · h)
点预测	11.6
70%上限	6.3
80%上限	5.8
90%上限	3.7
90%下限	4.3
80%下限	12.9
70%下限	13.3




图 7 预估的调频容量与实际值的误差

Fig.7 Errors between the estimated frequency modulation capacity and the actual value

#### 4.2.2 风储系统收益分析

根据风-储联合运行机制和调频服务市场交易规则,设定风电场上网能量价格为 570 元/(MW · h),调频补偿价格为 12 元/(MW · h),惩罚价格为风电场上网价格的 0.04 倍,计算风储系统收益. 当调频容量存在出力偏差时,将收取惩罚考核费用. 风储系统收益按照风电场上网收益加上提供调频容量收益并减去调频容量偏差造成的惩罚考核费用来进行计算,上述不同调频容量估计方案下风储系统的收益如图 8 所示.




图 8 不同置信水平下的风储系统收益

Fig.8 Wind storage system returns with different confidence levels

从图 8 可看出,按照 80%置信区间下限进行风电场调频容量估计,此时风电场申报的调频容量为 12.9 MW·h,风储系统收益最大,为 27.135 万元,比点预测调频容量估计方案具有更好的经济性。

#### 4.3 不同储能配置对风电场调频容量估计的影响

由于储能配置参数是调频容量的约束条件,故本文进一步开展储能配置参数变化对本文方法估计的调频容量的影响分析。分别设置储能配置为 6 MW × 1.34 h、8 MW × 1.34 h、10 MW × 1.34 h 和 12 MW × 1.34 h 4 组参数,表 8 给出了风电场的实际调频容

量、基于本文提出的基于 TCN-LSTM-Transformer 分位数回归模型区间预测得到最优调频容量估计和点预测调频容量估计随储能配置变化的情况,其中风电功率区间预测及点预测结果均基于 TCN-LSTM-Transformer 分位数回归模型计算得到,点预测结果为回归模型中分位点  $\tau=0.5$  时求解得到。由表 8 可知,随着储能容量配置的增加,风电场实际提供的调频容量会增加,同时也必然伴随储能设备投资成本增加的问题。

表 8 不同储能配置下风电场调频容量对比

Tab.8 Comparison of wind farm FM capacity under different energy storage configurations

储能功率/MW	储能容量/(MW·h)	实际调频容量/(MW·h)	区间预测最优调频容量/(MW·h)	点预测调频容量估计/(MW·h)
6	9.3	3.4	3.8	1.7
8	11.6	10.2	10.0	8.1
10	13.4	12.5	12.9	11.6
12	16.8	14.7	14.0	16.7

#### 4.4 不同风电功率对风电场调频容量估计的影响

为验证本文所提方法的有效性,选取该风电场另一天的真实数据进行风电场调频容量估计,表 9 给出了不同置信水平下区间预测结果生成的风电场可提供的调频容量估计,其中不同置信概率下的风电功率区间预测及点预测结果均基于 TCN-LSTM-Transformer 分位数回归模型得到;其中点预测结果为回归模型中分位点  $\tau=0.5$  时求解得到。

表 9 改变风电功率后不同置信水平下的预估调频容量

Tab.9 Predicted FM capacity at different confidence levels under another wind power output

不同置信区间	预估调频容量/(MW·h)
点预测	9.6
70%上限	6.4
80%上限	5.3
90%上限	7.1
90%下限	5.5
80%下限	10.8
70%下限	13.2

根据风电场的真实发电数据,求得风电场实际提供的调频容量为 11.5 MW·h,故由表 9 可看出,根据 80%置信区间下限预估的风电场调频容量与风电场可提供的真实调频容量相差最少,仍为该日的最优调频容量申报。表 10 给出了根据 80%置信区间下限预估风电场调频容量和根据点预测预估时,调频容量估计值与真实调频容量之间的误差和风储系统年收益。由表 10 可知,根据置信区间预估风电场调频容量进行申报可减小与真实调频容量之间的误差,增加风储系统年收益。

表 10 不同功率预测调频容量误差及风储系统年收益

Tab.10 Errors in predicted FM capacity at different powers and annual returns from wind storage systems

不同功率预测	调频容量误差/(MW·h)	风储系统年收益/万元
点预测	1.9	42.353
80%预测区间下限	0.7	43.274

## 5 结论

本文基于风电功率的不确定性,开发了一个两阶段模型,该模型整合了风电功率削减数据和储能优化,为调频容量估计提供了全面的方法。

(1) 阶段 1 模型针对具有高度不确定性的风电出力,建立 TCN-LSTM-Transformer 分位数回归预测模型,通过非线性分位数回归结构,能够在给定的置信概率下,生成风电功率的概率预测区间。以最大化风储系统的年净收益为目标,采用与交易所市场交叉算法结合的改进蝴蝶算法,并结合模拟 365 d 弃风功率,优化得到储能容量和功率配置方案,提升了储能配置的经济效益。

(2) 阶段 2 模型针对储能优化配置问题,基于风电功率的概率区间预测,结合风电运行限制和储能配置方案,选择合适的置信度下的概率区间预测结果,实现了风电场的最优调频容量估计。仿真分析表明,本文提出的模型求解相较于传统的点估计方法,显著降低了调频容量估计误差,提高了风电场的经济效益。

综上,本文的研究提供了一个策略框架,使储能系统能够吸收风电削减,优化风电场的调频容量申

报,并支持电力系统的调度决策.通过实际数据进行的实证验证,证实了所提方法在降低调频容量估计误差和提高风储系统盈利能力方面的有效性.其结果有助于提高风电场在电力系统中的运行效率,并为风能整合的经济可行性提供了科学依据.未来可结合风电场全生命周期数据,研究模型在长期优化运行(如储能寿命衰减、电价波动)中的动态优化能力.

#### 参考文献:

- [1] 娄素华, 杨天蒙, 吴耀武, 等. 含高渗透率风电的电力系统复合储能协调优化运行[J]. 电力系统自动化, 2016, 40(7): 30-35.  
Lou Suhua, Yang Tianmeng, Wu Yaowu, et al. Coordinated optimal operation of hybrid energy storage in power system accommodated high penetration of wind power[J]. Automation of Electric Power Systems, 2016, 40(7): 30-35(in Chinese).
- [2] He Y Y, Liu R, Li H Y, et al. Short-term power load probability density forecasting method using kernel-based support vector quantile regression and Copula theory[J]. Applied Energy, 2017, 185: 254-266.
- [3] 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 Energetica Solaris Sinica, 2019, 40(7): 2028-2035(in Chinese).
- [4] Jeon J, Taylor J W. Using conditional kernel density estimation for wind power density forecasting[J]. Journal of the American Statistical Association, 2012, 107(497): 66-79.
- [5] 王森, 孙永辉, 周衍, 等. 计及误差时间相依性的风电功率超短期条件概率预测[J]. 电力自动化设备, 2022, 42(11): 40-46.  
Wang Sen, Sun Yonghui, Zhou Yan, et al. Ultra-short term conditional probability prediction of wind power considering error time dependence[J]. Electric Power Automation Equipment, 2022, 42(11): 40-46(in Chinese).
- [6] Zhou B W, Ma X G, Luo Y H, et al. Wind power prediction based on LSTM networks and nonparametric kernel density estimation[J]. IEEE Access, 2019, 7: 165279-165292.
- [7] 杨锡运, 张艳峰, 叶天泽, 等. 基于朴素贝叶斯的风电功率组合概率区间预测[J]. 高电压技术, 2020, 46(3): 1099-1108.  
Yang Xiyun, Zhang Yanfeng, Ye Tianze, et al. Prediction of combination probability interval of wind power based on naive Bayes[J]. High Voltage Engineering, 2020, 46(3): 1099-1108(in Chinese).
- [8] 庞传军, 尚学伟, 张波, 等. 基于改进梯度提升算法的短期风电功率概率预测[J]. 电力系统自动化, 2022, 46(16): 198-206.  
Pang Chuanjun, Shang Xuewei, Zhang Bo, et al. Short-term wind power probability prediction based on improved gradient boosting machine algorithm[J]. Automation of Electric Power Systems, 2022, 46(16): 198-206(in Chinese).
- [9] 殷豪, 黄圣权, 孟安波, 等. 基于长短期记忆网络分位数回归的短期风电功率概率密度预测[J]. 太阳能学报, 2021, 42(2): 150-156.  
Yin Hao, Huang Shengquan, Meng Anbo, et al. Short-term wind power probability density prediction based on long short term memory network quantile regression[J]. Acta Energetica Solaris Sinica, 2021, 42(2): 150-156(in Chinese).
- [10] 庞昊, 高金峰, 杜耀恒. 基于时间卷积网络分位数回归的短期负荷概率密度预测方法[J]. 电网技术, 2020, 44(4): 1343-1350.  
Pang Hao, Gao Jinfeng, Du Yaoheng. A short-term load probability density prediction based on quantile regression of time convolution network[J]. Power System Technology, 2020, 44(4): 1343-1350(in Chinese).
- [11] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, USA, 2017: 6000-6010.
- [12] 林铮, 刘可真, 沈赋, 等. 考虑海上风电多机组时空特性的超短期功率预测模型[J]. 电力系统自动化, 2022, 46(23): 59-66.  
Lin Zheng, Liu Kezhen, Shen Fu, et al. Ultra-short-

- term power prediction model considering spatial-temporal characteristics of offshore wind turbines[J]. Automation of Electric Power Systems, 2022, 46(23): 59-66(in Chinese).
- [13] 张越, 臧海祥, 程礼临, 等. 基于自适应时序表征和多级注意力的超短期风电功率预测[J]. 电力自动化设备, 2024, 44(2): 117-125.  
Zhang Yue, Zang Haixiang, Cheng Lilin, et al. Ultra-short-term wind power forecasting based on adaptive time series representation and multi-level attention[J]. Electric Power Automation Equipment, 2024, 44(2): 117-125(in Chinese).
- [14] 盛四清, 金航, 刘长荣. 基于VMD-WSGRU的风电场发电功率中短期及短期预测[J]. 电网技术, 2022, 46(3): 897-904.  
Sheng Siqing, Jin Hang, Liu Changrong. Short-term and mid-short-term wind power forecasting based on VMD-WSGRU[J]. Power System Technology, 2022, 46(3): 897-904(in Chinese).
- [15] 刘军, 甘乾煜, 张泽秋, 等. 考虑储能电池运行寿命的风电功率波动平抑方法研究[J]. 电网技术, 2023, 47(5): 2098-2107.  
Liu Jun, Gan Qianyu, Zhang Zeqiu, et al. Research on wind power fluctuation suppression method considering the operating life of energy storage battery[J]. Power System Technology, 2023, 47(5): 2098-2107(in Chinese).
- [16] 胡泽春, 夏睿, 吴林林, 等. 考虑储能参与调频的风储联合运行优化策略[J]. 电网技术, 2016, 40(8): 2251-2257.  
Hu Zechun, Xia Rui, Wu Linlin, et al. Joint operation optimization of wind-storage union with energy storage participating frequency regulation[J]. Power System Technology, 2016, 40(8): 2251-2257(in Chinese).
- [17] 赵爱云, 陈宽. 储能电池参与风电调频控制策略[J]. 通信电源技术, 2018, 35(7): 29-35, 214.  
Zhao Aiyun, Chen Kuan. Control strategy of energy storage battery participating in wind power frequency modulation[J]. Telecom Power Technology, 2018, 35(7): 29-35, 214(in Chinese).
- [18] Savkin A V, Khalid M, Agelidis V G. A constrained monotonic charging/discharging strategy for optimal capacity of battery energy storage supporting wind farms[J]. IEEE Transactions on Sustainable Energy, 2016, 7(3): 1224-1231.
- [19] 齐晓光, 姚福星, 朱天瞳, 等. 考虑大规模风电接入的电力系统混合储能容量优化配置[J]. 电力自动化设备, 2021, 41(10): 11-19.  
Qi Xiaoguang, Yao Fuxing, Zhu Tiantong, et al. Capacity optimization configuration of hybrid energy storage in power system considering large-scale wind power integration[J]. Electric Power Automation Equipment, 2021, 41(10): 11-19(in Chinese).
- [20] 杨立滨, 曹阳, 魏韡, 等. 计及风电不确定性和弃风率约束的风电场储能容量配置方法[J]. 电力系统自动化, 2020, 44(16): 45-52.  
Yang Libin, Cao Yang, Wei Wei, et al. Configuration method of energy storage for wind farms considering wind power uncertainty and wind curtailment constraint[J]. Automation of Electric Power Systems, 2020, 44(16): 45-52(in Chinese).
- [21] 王欣, 谭永怡, 秦斌. 改进MOGOA及其在风储容量优化配置中的应用[J]. 电力科学与技术学报, 2024, 39(2): 159-169.  
Wang Xin, Tan Yongyi, Qin Bin. Improved multi-objective grasshopper algorithm applied in optimal capacity allocation of energy storage system in wind farms[J]. Journal of Electric Power Science and Technology, 2024, 39(2): 159-169(in Chinese).
- [22] 刘颖明, 王瑛玮, 王晓东, 等. 基于蚁狮算法的风电集群储能容量配置优化方法[J]. 太阳能学报, 2021, 42(1): 431-437.  
Liu Yingming, Wang Yingwei, Wang Xiaodong, et al. Optimization of storage capacity allocation in wind farm cluster based on ant lion optimization algorithm[J]. Acta Energetica Solaris Sinica, 2021, 42(1): 431-437(in Chinese).
- [23] 李滨, 邓有雄, 陈碧云. 含超短期风功率预测增强处理的风储系统超前滚动优化控制策略[J]. 电网技术, 2021, 45(6): 2280-2287.  
Li Bin, Deng Youxiong, Chen Biyun. Advanced rolling optimization control strategy for wind storage system

- with enhanced ultra-short-term wind power prediction[J]. *Power System Technology*, 2021, 45(6): 2280-2287(in Chinese).
- [24] Kou P, Liang D L, Gao L, et al. Probabilistic electricity price forecasting with variational heteroscedastic Gaussian process and active learning[J]. *Energy Conversion and Management*, 2015, 89: 298-308.
- [25] 杨文强, 常 彬. 计及多影响因素的发电侧混合储能系统容量配置方法及配置工具[J]. *储能科学与技术*, 2022, 11(10): 3246-3256.
- Yang Wenqiang, Chang Bin. Research on the configuration method & tool for the hybrid energy storage system on the power generation side[J]. *Energy Storage Science and Technology*, 2022, 11(10): 3246-3256(in Chinese).
- [26] Ghorbani N, Babaei E. Exchange market algorithm[J]. *Applied Soft Computing*, 2014, 19: 177-187.
- [27] 武佳卉, 邵振国, 杨少华, 等. 数据清洗在新能源功率预测中的研究综述和展望[J]. *电气技术*, 2020, 21(11): 1-6.
- Wu Jiahui, Shao Zhenguo, Yang Shaohua, et al. Review and prospect of data cleaning in renewable energy power prediction[J]. *Electrical Engineering*, 2020, 21(11): 1-6(in Chinese).
- [28] Taylor J W. A quantile regression neural network approach to estimating the conditional density of multiperiod returns[J]. *Journal of Forecasting*, 2000, 19(4): 299-311.
- [29] 梅 简, 张 杰, 刘双宇, 等. 电池储能技术发展现状[J]. *浙江电力*, 2020, 39(3): 75-81.
- Mei Jian, Zhang Jie, Liu Shuangyu, et al. Development status of battery energy storage technology[J]. *Zhejiang Electric Power*, 2020, 39(3): 75-81(in Chinese).
- [30] 杨锡运, 刘雅欣, 邢国通, 等. 基于风电概率预测的风电场调频容量估计方法[J]. *太阳能学报*, 2022, 43(7): 409-416.
- Yang Xiyun, Liu Yaxin, Xing Guotong, et al. Method of estimation frequency regulation capacity of wind farm based on wind power probability prediction[J]. *Acta Energetiae Solaris Sinica*, 2022, 43(7): 409-416(in Chinese).

(责任编辑: 孙立华)