

DOI:10.19651/j.cnki.emt.2518032

# 基于参数优化和 QR 的短期风电功率预测<sup>\*</sup>

蒲晓云 杨 靖 杨 兴 宁 媛

(贵州大学电气工程学院 贵阳 550025)

**摘要:**针对高波动场景下风电功率预测模型难以兼顾点值精度与区间可靠性的问题,提出一种融合参数优化与非线性分位数回归的混合预测模型。首先,构建基于双重注意力机制的TCN-GRU-DA组合预测模型,利用特征注意力挖掘多维气象特征的空间相关性,并结合多头注意力捕捉功率序列的时序依赖性;其次,提出改进鹫鹰优化算法(ISBOA)实现组合模型的4个超参数的智能寻优,该算法通过融合佳点集和量子计算初始化、分段非线性权重、北方苍鹰优化算法(NGO)的方向因子和柯西分布策略显著提升收敛性能;最后,构建基于多头注意力的非线性分位数回归模型,通过自适应损失函数动态调节不同分位数下的特征权重,显著提升了条件分位数估计的准确性。实例结果表明,在点值预测方面,所提模型较TCN-GRU的MAE和RMSE分别降低30.27%和27.28%;在区间预测方面,95%置信度下的PICP提升3.97%,PINAW下降20.76%。研究表明,所提模型有效解决了风电功率点值估计与区间估计的协同优化难题,不仅提高了极端天气下的预测鲁棒性,更为电网的日前调度与实时控制提供多维决策支持。

**关键词:**风电功率预测;门控循环单元;注意力机制;分位数回归;点值预测;区间预测

**中图分类号:** TN91; TM614   **文献标识码:** A   **国家标准学科分类代码:** 470.4047

## Short-term wind power prediction based on parameter optimization and QR

Pu Xiaoyun Yang Jing Yang Xing Ning Yuan

(School of Electrical Engineering, Guizhou University, Guiyang 550025, China)

**Abstract:** Aiming at the problem that wind power prediction models under high-fluctuation scenarios struggle to balance point-value accuracy and interval reliability, a hybrid prediction model integrating parameter optimization and nonlinear quantile regression is proposed. First, a combined TCN-GRU-DA prediction model based on a dual attention mechanism is constructed, using feature attention to mine the spatial correlation of multidimensional meteorological features and it with combining multi-head attention to capture the temporal dependence of power sequences. Second, the improve secretary bird optimization algorithm is proposed to realize the intelligent optimization of the four hyper-parameters of the combined model. This algorithm significantly enhances convergence performance by integrating good point set theory and quantum computing initialization, time-segmented nonlinear weighting, the directional search mechanism of the northern goshawk optimization algorithm, and a Cauchy distribution strategy to enhance global search capability. Finally, a multi-head attention-based nonlinear quantile regression model is developed, which dynamically adjusts feature weights under different quantiles through an adaptive loss function, thereby improving the accuracy of conditional quantile estimation. Experimental results demonstrate that, for point prediction, the proposed model reduces MAE and RMSE by 33.33% and 31.93%, respectively, compared to TCN-GRU. For interval prediction, at a 95% confidence level, the PICP improves by 3.97% and PINAW decreases by 20.76%. The study confirms that the proposed model effectively addresses the synergistic optimization of point estimation and interval estimation for wind power prediction. It not only enhances prediction robustness under extreme weather but also provides multi-dimensional decision support for day-ahead scheduling and real-time control in power grids.

**Keywords:** wind power prediction; gated recurrent unit; attention mechanism; quantile regression; point value prediction; interval prediction

## 0 引言

随着全球能源结构改革的加速推进,以风能为代表的

可再生能源并网规模持续扩大<sup>[1]</sup>。然而,风力发电的输出功率不稳定,导致风电安全并网和合理资源调配面临严峻挑战。因此,准确的风电功率预测对于更加高效地利用风

收稿日期:2025-02-07

\* 基金项目:国家自然科学基金(61640014,61963009)、贵州省科技支撑项目(黔科合[2022]一般017,黔科合ZK[2022]135)资助

力发电、确保电力系统安全运行和可靠供应具有重要意义。

在确定性预测研究领域,根据建模方式不同,风电功率点值预测可分为物理模型、统计模型和人工智能模型<sup>[2]</sup>。物理模型依靠数值天气预报(numerical weather prediction, NWP)<sup>[3]</sup>和风机等技术参数,但面临计算复杂度与测量误差积累的问题;统计模型<sup>[4]</sup>通过线性假设简化了建模过程,却难以表征风电功率系统的非线性特征;随着信息技术的快速发展,人工智能模型通过端到端实现预测性能的突破。例如,文献[5]采用门控循环网络(gate recurrent unit, GRU)进行功率预测,与长短时记忆网络(long short term memory network, LSTM)相比,模型结构简单且易于扩展,但单一模型预测精度难以满足实际应用需求。文献[6]提出采用卷积神经网络(convolutional neural network, CNN)和LSTM的组合预测模型,分别用于数据特征提取和时序数据处理,虽提升了预测精度,但在面对多维气象特征输入时仍存在局限。值得注意的是,注意力机制的引入为特征选择提供了新的思路。文献[7]提出基于时间注意力机制的双向长短时记忆网络(bidirectional long short term memory, BiLSTM),实现关键气象因子的动态权重分配,有效提升预测精度。此外,人工智能模型的预测性能在很大程度受到参数配置的影响,文献[8]采用改进麻雀优化算法优化CNN-Attention-BiGRU模型超参数,验证了智能优化算法在参数寻优的有效性,有效提高了预测精度和输出稳定性。

在不确定量化方面,区间预测主要分为参数和非参数两种方法。常见的参数法如高斯分布<sup>[9]</sup>、Beta分布函数等需预设误差分布形态,在极端场景下易产生区间覆盖偏差;非参数方法如Bootstrap方法<sup>[10]</sup>、核密度估计和分位数回归<sup>[11]</sup>等,文献[12]采用Bootstrap方法对数据进行重采样,虽避免分布假设,但多次迭代导致计算成本呈指数增长;分位数回归通过损失函数直接估计条件分位数,但传统线性QR模型难以捕捉风电系统的复杂非线性关系。最新研究尝试融合人工智能模型与分位数回归,文献[13]构建GRU-QR模型实现点、区间联合预测,但其固定权重分为难以体现多维特征对不同分位数的动态影响;文献[14]提出的TCN-KDE方法,通过非参数核密度估计后处理生成预测区间,但未能实现点、区间预测的协同优化。

针对高波动场景下点区间预测协同优化难题,提出融合参数优化与自适应分位数回归的混合预测模型,全面提高风电功率预测效果。首先,构建TCN-GRU-DA组合预测模型,通过集成特征注意力与多头注意力双重机制,实现对多维气象特征的筛选及功率序列依赖的捕捉。其次,采用佳点集和量子计算初始化、非线性权重、北方苍鹰优化算法(northern goshawk optimization algorithm, NGO)的方向因子和柯西变异的策略改进鹭鹰优化算法(secretary bird optimization algorithm, SBOA),并利用改进鹭鹰优化算法(improve secretary bird optimization algorithm,

SBOA)对组合预测模型4个超参数进行寻优。最终,构建一种结合多头注意机制损失函数的非线性分位数回归模型,以实现不同置信水平下的条件分位数估计。实验结果表明,所提出的混合模型能实现高精度的点值预测,还能提供包含不确定性的区间预测,为电网日前调度提供兼具确定性与概率性的决策依据。

## 1 改进鹭鹰优化算法

针对鹭鹰优化算法收敛速度慢、易陷入局部最优等不足,提出以下3种改进方法:首先,采用融合佳点集和量子计算的种群初始化,提高初始种群在搜索空间的分布质量和多样性;其次,在狩猎阶段引入分段非线性权重因子平衡全局探索和局部开发能力;最后,在逃跑阶段的伪装策略引入柯西逆累积分布函数提高算法勘探水平,快速奔跑策略融合NGO的追逐过程增强局部搜索能力。

### 1.1 佳点集和量子计算初始化

鹭鹰随机生成位置的初始化难以保证种群多样性和分布情况,可能导致算法寻优较慢,采用佳点集保证初始种群分布更加均匀,进一步结合量子计算优化个体初始位置,使其更接近潜在的全局最优解。因此,新的初始化策略为:

$$X_{i,j} = lb_j + \{q_j^{(i)} \times k\} \times (ub_j - lb_j) + \Delta x_i^Q \quad (1)$$

式中: $q$  为佳点且  $q_j = 2\cos(2\pi i/p)$ ,  $p$  为满足  $(p-3/2) \geqslant g$  的最小素数,  $1 < m < n$ ,  $\Delta x_i^Q$  为量子计算调整量。

### 1.2 分段非线性自适应权重

SBOA 狩猎阶段采用固定的搜索策略和权重,主要依赖于差分变异和随机移动进行位置更新。如果搜索空间无法进行自适应调整,可能导致算法收敛较慢或存在一定局限性。本文引入分段非线性自适应权重增加算法动态适应性,使其在不同时间间隔自适应调整权重占比,从而更有效的改善探索与开发的平衡、提高收敛速度。

$$\text{weight} = \begin{cases} 1 - \left(\frac{t}{T}\right)^{\frac{3}{2}}, & t > \frac{T}{3} \\ 0.6 \times \left(1 - \sqrt{\frac{t}{T}}\right), & \frac{T}{3} < t < \frac{2T}{3} \\ 0.05 \times \left(1 - \frac{t}{T}\right)^2, & t > \frac{2T}{3} \end{cases} \quad (2)$$

$$x_{i,j}^{new,P1} = x_{i,j} + weight \times x_{i,j}^{new,P1} \quad (3)$$

式中: $t$  为当前迭代次数,  $T$  为最大迭代次数。

由上式可以看出,动态权重能调整在不同阶段所需的迭代时间,非线性自适应权重能在探索与开发间找到更好的平衡。在初期给予较大权重扩大搜索范围,防止陷入局部最优;而在后期逐步减小权重,使个体更加专注于精细开发,加快调高算法整体优化能力。

### 1.3 融合 NGO 方向因子和柯西分布函数

在SBOA的逃跑阶段中,伪装策略通过目标解的最佳位置进行方向调整,虽然能够有效引导个体向最优解靠近,但容易导致种群多样性缺失和易陷入局部最优。为此,本

文采用融合 NGO 方向因子<sup>[15]</sup>  $D_{NGO}$  的混合引导机制,使个体在保留最优解的同时,根据迭代过程自适应的调整搜索方向,提升解空间的搜索范围和跳出局部能力。快速奔跑策略通过当前解与随机解进行线性组合并引入正态分布扰动实现位置更新,然而正态分布生成的随机数集中在均值附近,导致位置更新步长受限。当算法接近局部最优解时,此类较小扰动不足以使个体跳出局部最优,故采用具有重尾特性的柯西分布机制<sup>[16]</sup>代替,可产生更大范围的扰动幅度,提高位置更新的不确定性,增强算法在全局解空间的搜索效率。位置更新公式改进如式(4)所示。

$$\left\{ \begin{array}{l} X_{i,j}^{new',P2} = \\ C1: x_{best} + (2 \times RB - 1) \times (1 - \frac{1}{T})^2 \times x_{i,j} + \omega \times \\ D_{NGO}, if \ rand < r_i \\ C2: Cauchy(0, \varphi) \times (x_{random} - M \times x_{i,j}) + x_{i,j}, else \end{array} \right. \quad (4)$$

$$D_{NGO} = x_{i,j} - \delta \times (x_{best} + x_{rand} - 2 \times x_{i,j}) \quad (5)$$

式中: $\omega$  为权重因子,用于控制 NGO 方向因子对位置更新的影响, $\delta$  为控制方向更新的缩放因子, $Cauchy(0, \varphi)$  为从均值为 0、尺度参数为  $\varphi$  的柯西分布生成的随机数。

综上所述,ISBOA 超参数寻优流程如图 1 所示。

#### 1.4 算法性能测试

为评估 ISBOA 的寻优能力,选择 6 个基准测试函数<sup>[17]</sup>进行仿真试验。ISBOA 算法分别与 MTBO、SBOA、NGO、GJO、APO、GWO 进行对比实验<sup>[18]</sup>。ISBOA 算法初始种群规模设置为 30,最大迭代次数为 500,测试函数收敛曲线如图 2 所示。ISBOA 算法在收敛速度和寻优精度均

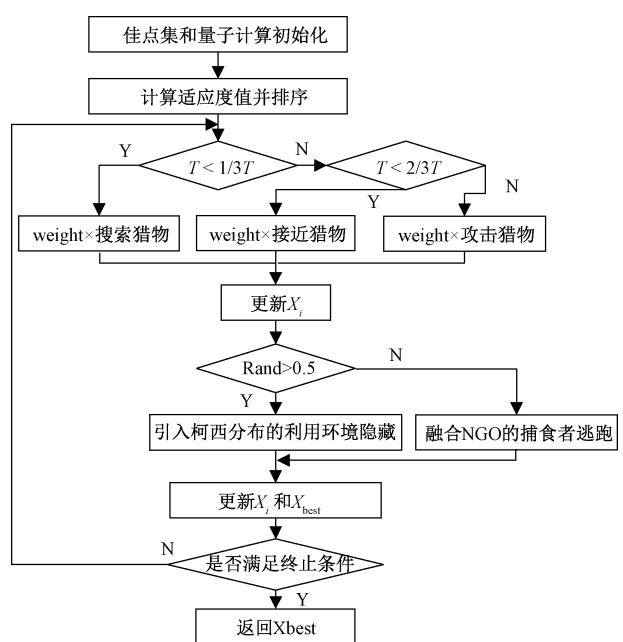
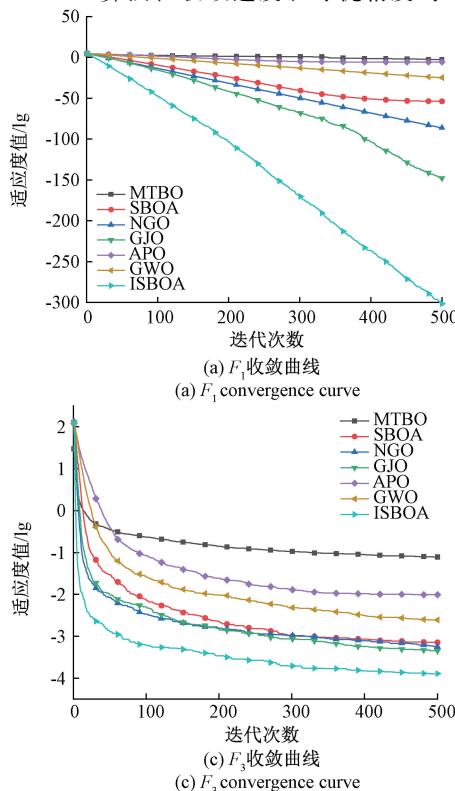
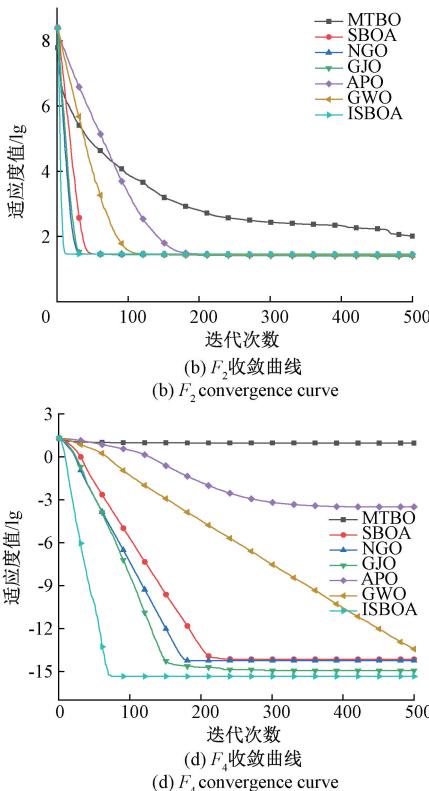


图 1 ISBOA 超参数寻优流程

Fig. 1 ISBOA hyperparameter optimization process

优于其他 6 种算法。在  $F_1 \sim F_3$  单峰函数中,ISBOA 显著优于其他算法的寻优效果和速度,尤其在  $F_1$  中能够找到全局最优解。在  $F_4 \sim F_6$  多峰函数中,由于存在多个局部最优解的干扰,ISBOA 展现出一定跳出局部最优并持续探索的能力,可以有效避免算法过早收敛,从而达到全局最优解。



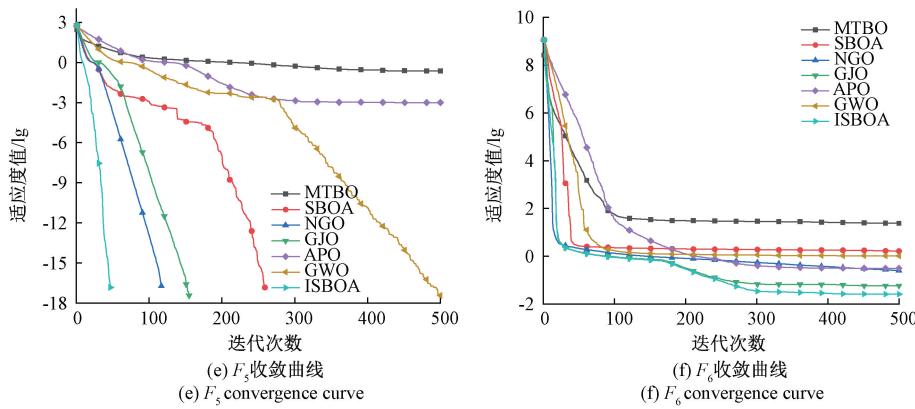


图 2 测试函数收敛曲线  
Fig. 2 Convergence curves of the test function

## 2 融合 QR 的 TCN-GRU-DA 预测模型

### 2.1 融合特征注意力机制的时间卷积网络

时间卷积网络(temporal convolution network, TCN)是一种利用卷积层处理时间序列数据的方法,其网络结构通常由因果卷积、膨胀卷积和残差连接组成。因果卷积采用单向结构,使模型在预测当前时刻的输出时仅依赖历史数据,从而有效避免未来信息的泄露。同时,因果卷积的感受野与网络深度线性相关,采用膨胀卷积来增加感受野,更好捕捉时序序列之间的长期依赖关系。

假设输入序列  $u$ ,则在  $j$  处的因果卷积输出为:

$$R_j(t) = \sum_{j=0}^{\theta-1} a_j(j) \cdot u_{t-j} \quad (6)$$

式中: $u$  为输入向量,包括历史功率和气象特征, $a(\cdot)$  为卷积核, $O$  为卷积核元素位置, $\theta$  为卷积核大小, $c$  为膨胀因子,与网络层数成指数关系。

特征注意力机制主要用于挖掘风电功率相关的气象特征与实际功率、预测功率之间的关系,提升模型对关键特征的关注度。特征注意力机制将  $M$  个气象特征和功率作为输入向量,通过多层感知机得到注意力权重向量:

$$e^t = \sigma(\mathbf{W}_e \mathbf{x}' + \mathbf{b}_e) \quad (7)$$

式中: $e^t$  为各输入特征的对应权重系数组合, $\mathbf{x}'$  为输入特征向量, $\mathbf{W}_e$  为训练感知机的权重矩阵, $\mathbf{b}_e$  为偏置向量。

采用  $softmax(\cdot)$  函数对各个注意力权重系数进行归一化处理:

$$\varphi_m^t = softmax(e^t) = \frac{\exp(e_m)}{\sum_{m=1}^M e_m^t} \quad (8)$$

将输入特征向量  $\mathbf{x}'$  和与注意力权重相乘得到加权向量  $\mathbf{x}'t$ ,将该向量重新作为 TCN 的输入向量进行预测,可表示:

$$\mathbf{x}'t = \varphi_m^t \odot \mathbf{x}' = [\varphi_1^t x_1', \varphi_2^t x_2', \dots, \varphi_M^t x_M'] \quad (9)$$

### 2.2 门控循环网络

门控循环网络<sup>[19]</sup>是循环神经网络的一种,模型结构

与 LSTM 相似,不同点是改进了门控机制,将 LSTM 的遗忘门和输入门合并为单一的更新门,使结构更加简洁,计算效率更高,对时序序列特征具有较好的捕捉能力。GRU 通过重置门和更新门对上一时刻的隐藏状态  $h_{t-1}$  和当前时刻的输入信息  $x_t$  进行处理,从而更新当前时刻的隐藏状态  $h_t$  进行模型训练。

$$z_t = \sigma(\mathbf{W}^{(z)} x_t + \mathbf{U}^{(z)} h_{t-1}) \quad (10)$$

$$r_t = \sigma(\mathbf{W}^{(r)} x_t + \mathbf{U}^{(r)} h_{t-1}) \quad (11)$$

$$h'_t = \tanh(\mathbf{W}x_t + r_t \odot \mathbf{U}h_{t-1}) \quad (12)$$

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot h'_{t-1} \quad (13)$$

式中: $\mathbf{W}^{(z)}$ 、 $\mathbf{W}^{(r)}$ 、 $\mathbf{W}$ 、 $\mathbf{U}^{(z)}$ 、 $\mathbf{U}^{(r)}$ 、 $U$  为相应输入权重矩阵, $z_t$  为当前时刻隐藏状态输出, $r_t$  为重置门输出, $h'_t$  为候选隐藏状态, $\sigma$  为 Sigmoid 激活函数, $\odot$  为 Hadamard 运算, $\tanh$  为双曲正切函数。其中, $z_t, r_t$  取值范围为  $[0, 1]$ ,这不仅是对输入信息的筛选,也是对上一时刻隐藏状态的选择,通过 GRU 网络实现对时序序列规律的学习,从而建立风电功率预测模型。

### 2.3 多头注意力机制

多头自注意力机制(multihead-attention, MA)<sup>[20]</sup>通过多个并行的注意力头使模型从不同维度学习关键信息,采用各自的权重分配方式,削弱其他非关键信息对预测精确度的干扰,使模型能够适应不同气象因素下的风电功率预测任务。

$$\begin{aligned} MultiHead(Q, K, V) &= Concat(head_1, \dots, head_l) \\ W^{output} \end{aligned} \quad (14)$$

$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V) \quad (15)$$

式中: $MultiHead$  为多头注意力机制输出, $Concat$  为维度拼接函数, $head_i$  为注意力头, $W^{output}$  为变换矩阵。

### 2.4 分位数回归

分位数回归(quantile regression, QR)模型是最小二乘回归的改进和扩展。用于研究自变量和因变量之间的条件分位数关系,且无需对因变量进行特殊假设。通过构建一系列不同条件分位数下的功率曲线,能够提供更全面

的风电功率输出不确定性特征,QR 模型如下:

$$\tilde{P}(\tau | x) = \beta(\tau)x \quad (16)$$

式中:  $\tilde{P}(\tau | x)$  为第  $\tau$  个条件分位数下功率预测点,  $\tau$  为分位点且范围为  $(0,1)$ ,  $\beta(\tau)$  为回归系数。

当输入给定数据集时,将求解不同分位数的回归系数  $\beta(\tau)$  可以转换为最小损失函数 Loss 的问题。

$$Loss = \sum_{i=1}^n \gamma_\tau(P_i - \tilde{P}(\tau | x_i)) \quad (17)$$

$$\gamma_\tau(s) = \begin{cases} \tau s, & s \geq 0 \\ (\tau-1)s, & s < 0 \end{cases} \quad (18)$$

式中:  $s = P_i - \tilde{P}(\tau | x_i)$ ,  $P_i$  为实际功率,  $\gamma_\tau$  为不对称函数。

当 TCN-GRU-DA 的输出为  $O \in R^{n \times l}$ ,  $l$  是多头注意力的头数。

为应对复杂的非线性功率问题,提出一种基于多头注意力机制的分位数回归损失函数。该方法通过对不同时间步长的输入特征进行加权,能够准确地捕捉时序特征,从而使模型灵活地适应不同分位数的需求。改进后的 Loss 函数如式(19)所示。

$$Loss_\tau = \sum_{i=1}^n \gamma_\tau(P_i - \tilde{P}(\tau | O_i)) \quad (19)$$

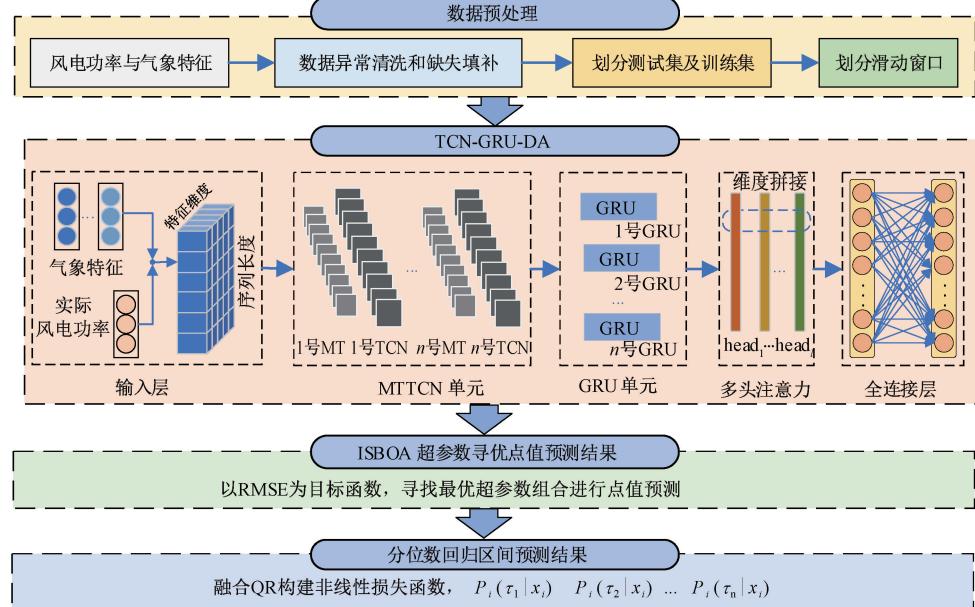


图 3 基于 QR-ISBOA-TCN-GRU-DA 模型预测流程

Fig. 3 QR-ISBOA-TCN-GRU-DA model-based prediction process

## 2.6 模型评价指标

### 1) 点值评价指标

本文选取平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE) 和决定系数 (R-square, R<sup>2</sup>) 作为风电功率点值预测评价指标<sup>[21]</sup>。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (21)$$

$$\tilde{P}(\tau | O_i) = f(O_i, W(\tau)) \quad (20)$$

式中:  $\tilde{P}(\tau | O_i)$  为模型在第  $i$  个样本处。通过多头注意力机制输出的  $O_i$  和分位数  $\tau$  下的预测值,  $W(\tau)$  是与分位数  $\tau$  相关的权重参数。因此, 通过不断优化权重参数  $W(\tau)$ , 能够动态调整在不同的分位数下的预测输出, 从而有效应对预测中的不确定性。

### 2.5 融合参数优化和 QR 的功率预测模型

本文建立了融合参数优化和非线性分位数回归的 TCN-GRU-DA 短期风电功率预测模型, 预测模型搭建流程如图 3 所示。

1) 数据预处理, 采用四分位法识别并清洗异常值, 采用插值法对缺失值进行填补, 并划分数据集。

2) 构建融合特征注意力和多头注意力的双重注意力机制的 TCN-GRU-DA 组合预测模型, 较单一预测模型具有更佳的预测性能。

3) 引入改进优化算法 ISBOA 对组合模型 4 个关键超参数进行寻优, 进一步提高风电功率点值预测的准确性。

4) 融合非线性分位数回归, 生成置信度分别为 95%、90%、85% 下的区间预测上限和下限, 提供了更全面的不确定性信息, 有效增强了功率预测的可靠性。

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (22)$$

式中:  $y_i$  为实测值,  $\hat{y}_i$  为预测值,  $\bar{y}_i$  为实测值的平均值。

### 2) 区间评价指标

区间评价指标采用区间覆盖率 (predict interval coverage probability, PICP)、区间平均宽度 (prediction

interval normalized average, PINAW) 和综合指数 (composite indicator, CWC) 作为风电功率区间预测效果评价指标。

(1) 区间覆盖率表示真实值落在预测区间上、下界的概率,用来度量预测区间的有效性,即该指标越大表明区间预测效果越好。

$$PICP = \frac{1}{n} \sum_{i=1}^n \mu(\epsilon_i) \quad (23)$$

$$\mu(y_i) = \begin{cases} 1, & \epsilon_i \in [L_i, U_i] \\ 0, & \epsilon_i \notin [L_i, U_i] \end{cases} \quad (24)$$

式中: $n$  为测试样本数量,  $\alpha(\epsilon_i)$  为  $[0, 1]$  的变量,  $y_i$  为测试样本数值,  $L_i, U_i$  分别是预测区间的下界和上界。此外,为保证预测区间最大程度包含实际值,从而提高预测精度, PICP 应大于或等于预先设置的预测区间置信度 (PI nominal confidence, PINC), 即  $PINC \geq (1 - \alpha)\%$ , 否则说明区间预测效果未达到期望,存在较大误差。

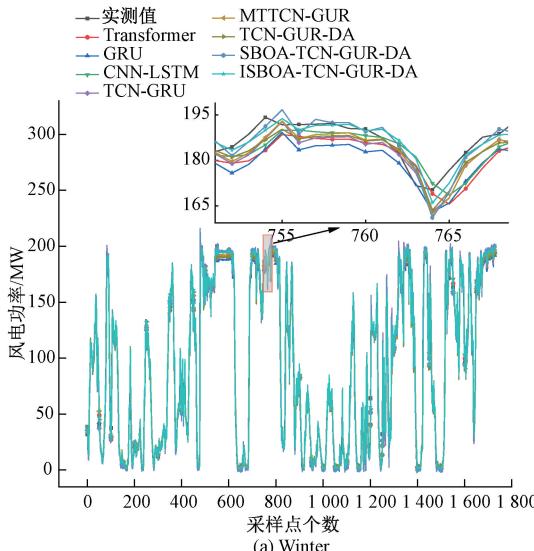
(2) 区间平均宽度是用于衡量预测分布的离散程度, 表示所有预测区间宽度的平均值。相较于宽泛的预测区间, 狹窄的区间可以更有效捕捉到数据的真实趋势, 从而增加预测的可信度和实用性, 故该指标越小表明区间预测效果越好。

$$PINAW = \frac{1}{nE} \sum_{i=1}^n L_i - U_i \quad (25)$$

式中: $E$  为观测值最大值和最小值之间的差。

(3) 理想风电功率置信区间应同时兼顾较高的区间覆盖率和较低的区间平均宽度。综合指数是采用 PICP 和 PINAW 的比值综合衡量拟合效果, 用来评估预测模型的准确度和可靠性, 该指标越小表明预测效果越好, 预测结果评价最为全面。

$$CWC = PICP / PINAW \quad (26)$$



(a) Winter

### 3 算例仿真分析

#### 3.1 数据来源

为验证所提模型的有效性, 本文以新疆某风电场历史数据进行仿真实验。该风电场装机容量为 250 MW, 选取 2022 年 1 月 1 日~3 月 31 日的实际功率数据(包含测风塔 10、30、50、70 m 和轮毂高度的风速和风向, 温度, 湿度, 大气压强共 13 维气象特征)作为冬季数据, 共 8831 组数据, 将前 80% 作为训练数据, 后 20% 作为测试数据。选取 6 月 1 日~8 月 31 日的数据作为夏季数据, 数据集划分方式与冬季相同。数据采样间隔为 15 min, 时间窗口大小经过多次实验对比, 设置模型的输入序列长度为 12, 表征当前时刻的点值预测和区间预测输入由过去 3 h 的气象数据和功率数据构成。

#### 3.2 基于 ISBOA 的参数优化点值预测模型

改进鹭鹰优化算法具有较高的寻优能力和收敛精度, 因此, 采用 ISBOA 算法对 TCT-GRU-DA 模型超参数进行寻优。设置算法初始种群数目为 15, 迭代次数为 50, 以 RMSE 作为算法适应度函数。搜索空间维度为 4 维, 分别为隐藏层神经元个数、初始学习率、正则化系数和多头注意力头数。通过迭代寻优可知, 冬季数据集上最优超参数组合为 105、0.0001、0.0506、5, 夏季数据集上最优参数组合为: 98、0.0031、0.0378、4。因此, 超参数优化不仅有助于提升模型的预测精度, 还在平衡模型复杂度与泛化能力发挥着关键作用。

#### 3.3 预测结果对比分析

##### 1) 点值预测对比实验

为验证模型点值预测效果, 采用 Transformer、GRU、CNN-LSTM、TCN-GUR、MTTCN-GUR、TCN-GUR-DA、SBOA-TCN-GUR-DA、ISBOA-TCN-GUR-DA 进行实验。点值预测曲线如图 4 所示, 点值评价指标对比如表 1 所示。

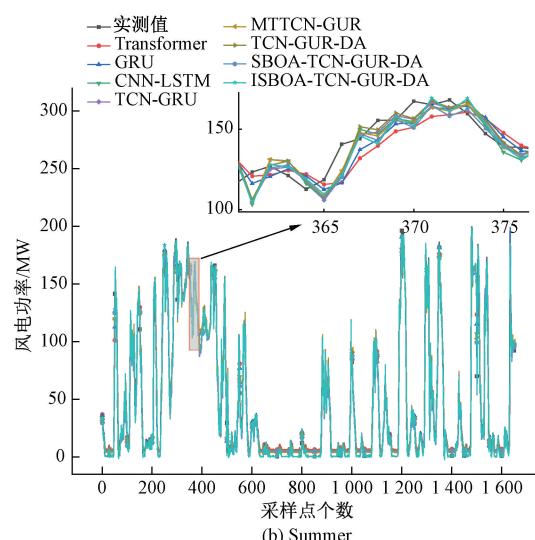


图 4 点值预测模型曲线对比

Fig. 4 Comparison of point value prediction model curves

表 1 点值预测误差评价指标对比

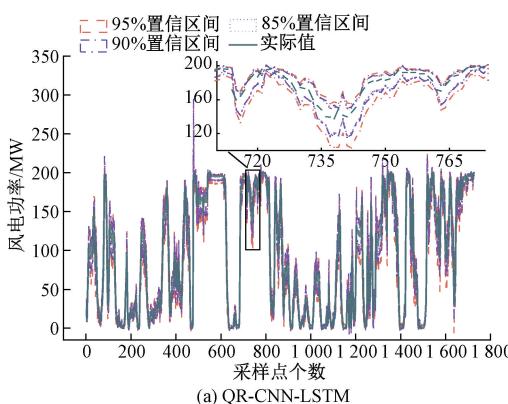
Table 1 Comparison of indicators for evaluating point value prediction errors

| 模型               | 冬季      |          |                | 夏季      |          |                |
|------------------|---------|----------|----------------|---------|----------|----------------|
|                  | MAE     | RMSE     | R <sup>2</sup> | MAE     | RMSE     | R <sup>2</sup> |
| Transformer      | 7.387 7 | 11.705 3 | 0.973 9        | 8.101 0 | 12.787 0 | 0.951 1        |
| GRU              | 7.298 9 | 11.525 2 | 0.974 2        | 6.542 1 | 10.098 9 | 0.969 5        |
| CNN-LSTM         | 7.236 5 | 11.623 6 | 0.975 3        | 6.157 3 | 9.835 4  | 0.972 2        |
| TCN-GRU          | 6.918 7 | 10.786 7 | 0.977 6        | 5.943 8 | 9.232 0  | 0.974 5        |
| MTTCN-GRU        | 6.568 8 | 9.817 6  | 0.980 5        | 5.710 0 | 9.079 2  | 0.975 4        |
| TCN-GUR-DA       | 6.089 2 | 9.127 6  | 0.983 5        | 5.671 4 | 8.852 9  | 0.976 6        |
| SBOA-TCN-GUR-DA  | 5.154 2 | 8.326 1  | 0.987 6        | 4.854 3 | 8.245 1  | 0.979 2        |
| ISBOA-TCN-GUR-DA | 4.824 4 | 7.844 1  | 0.988 3        | 4.233 5 | 7.918 2  | 0.981 3        |

在图 4 中, ISBOA-TCN-GUR-DA 预测曲线与实测曲线的贴合度最高, 即使在剧烈波动情况下, 该模型仍然能够紧密跟随实测值, 表明预测效果更好。在表 1 中, 以冬季数据为例, 相较于单一模型 Transformer 和 GRU 相比, 组合模型在 3 种误差评价指标上均有不同程度的提升, 进一步验证了其优越性。与 TCN-GRU 模型相比, 融入特征注意力的 MTTCN-GRU 模型的 MAE 和 RMSE 分别降低了 5.32%、9.87%, 表明特征注意力能够增强 TCN 的特征提取能力, 从而提升预测精度。在此基础上, 进一步引入多头注意力后, MAE 和 RMSE 分别降低了 7.88%、7.56%, 充分说明了多头注意力能够有效提升模型预测效果, 使其对复杂风电功率数据的学习能力更强。此外, 经过 ISBOA 算法的超参数寻优后, 模型的 MAE 和 RMSE 分别降低了 20.77%、14.06%, 证明了 ISBOA 在参数优化方面的有效性, 能够有效提高模型点值预测精度。

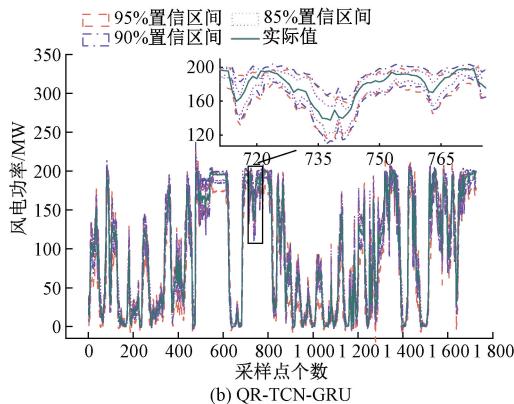
## 2) 区间预测实验

通过融合分位数回归的对风电功率的点值预测结果进行拟合, 从而实现区间预测。在置信度为 95%、90% 和 85% 的条件下, 对待预测的风电功率预测模型进行对比实验。采用四种融合非线性分位数回归的组合模型 QR-CNN-LSTM、QR-TCN-GRU、QR-TCN-GRU-DA、QR-ISBOA-TCN-GRU-DA 进行可视化, 预测曲线如图 5、图 6 所示, 区间预测评价指标如表 2 所示。



由图 5、6 可知, 在数据波动较为平缓时, 4 种模型的预测上限和下限大致符合风电功率的不确定性区间预测。其中, QR-ISBOA-TCN-GRU-DA 表现出更窄的预测宽度和更高的覆盖率, 表明该模型在不确定性描述方面更具优势。当数据出现剧烈波动时, QR-CNN-LSTM 在预测过程中易出现明显的峰值异常, 导致预测区间过宽, 进而引入了较大的不确定性, 从而降低了预测结果的可信度。而 QR-TCN-GRU 模型在一定程度上缓解了峰值的影响, 使预测区间相较于 QR-CNN-LSTM 更为收敛, 预测精度有所提高。然而, 在 95% 置信区间下, QR-TCN-GRU 预测范围部分被遮盖, 表明该模型对不确定性的捕捉能力相对不足, 未能充分考虑潜在输入的不确定性。在此基础上, 结合特征注意力和多头注意力的 QR-TCN-GRU-DA 模型, 其预测区间更加清晰, 进一步增强了对风电功率数据不确定性的刻画能力, 但该模型整体预测范围仍存在轻微的预测偏差, 且预测区间呈现一定的不对称性。为进一步优化模型性能, 采用 ISBOA 算法进行超参数寻优后, QR-ISBOA-TCN-GRU-DA 模型的预测区间分布更加均衡, 有效改善了区间预测的准确性与稳定性, 使模型区间预测效果更为理想。

由表 2 可知, 在 95% 置信水平下, 以冬季数据为例, QR-CNN-LSTM 相较于 QR-TCN-GRU, PINAW 和 CWC 分别降低 13.45%、12.41%, 表明模型区间预测性能有所



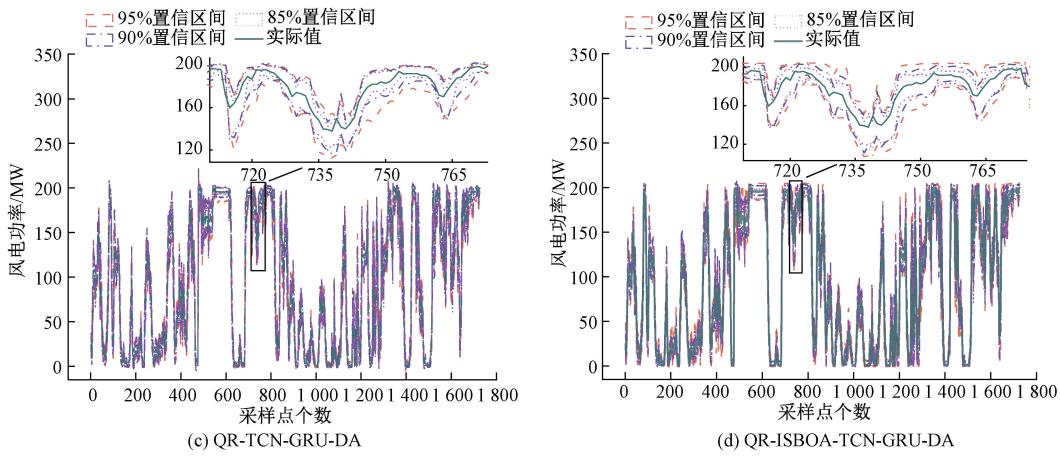


图 5 在冬季数据集上的区间预测模型曲线对比

Fig. 5 Comparison of interval prediction model curves on the winter dataset

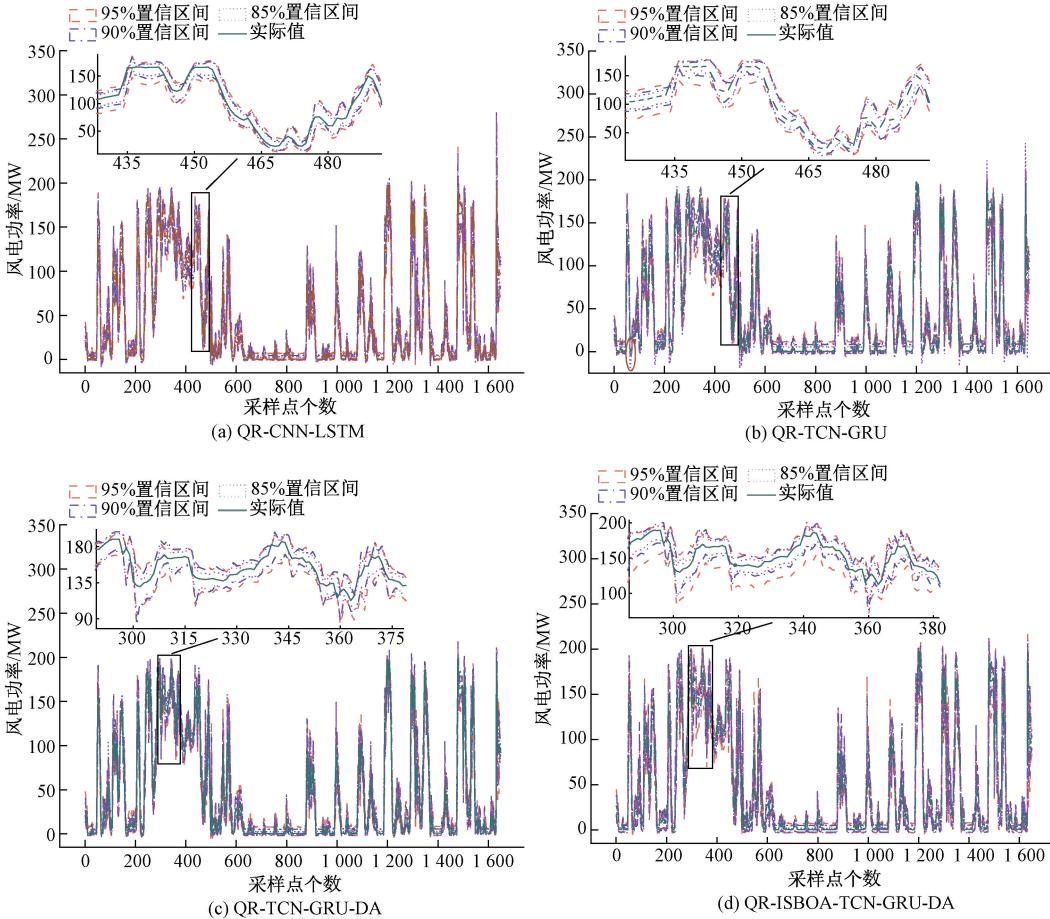


图 6 在夏季数据集上的区间预测模型曲线对比

Fig. 6 Comparison of interval prediction model curves on the summer dataset

优化。然而,在此基础上引入特征注意力和多头注意力后,QR-TCN-GRU-DA 的 PINAW 和 CWC 进一步降低了 17.63%、22.51%,充分说明双重注意力机制能够有效提升模型的预测性能。进一步采用 JSBOA 进行参数寻优,

QR-ISBOA-TCN-GRU-DA 模型的 PINAW 和 CWC 分别降低了 26.19%、48.44%，验证了合适的超参数优化不仅能够提升点值预测的精度，同时也对区间预测的性能具有显著影响。因此，融合参数寻优、双重注意力机制的组合

表 2 四种区间预测模型在 95%、90%、85% 置信度下的评价指标对比

Table 2 Comparison of evaluation metrics of four interval prediction models at 95%, 90%, and 85% confidence levels

| 置信区间 | 预测模型                | 冬季      |         |         | 夏季      |         |         |
|------|---------------------|---------|---------|---------|---------|---------|---------|
|      |                     | PICP    | PINAW   | CWC     | PICP    | PINAW   | CWC     |
| 95%  | QR-CNN-LSTM         | 0.926 4 | 1.968 6 | 0.630 8 | 0.920 5 | 1.875 5 | 0.604 6 |
|      | QR-TCN-GRU          | 0.931 1 | 1.703 8 | 0.552 5 | 0.947 8 | 1.681 4 | 0.529 4 |
|      | QR-TCN-GRU-DA       | 0.946 7 | 1.403 4 | 0.428 1 | 0.968 9 | 1.393 1 | 0.411 5 |
| 90%  | QR-ISBAO-TCN-GRU-DA | 0.968 1 | 1.350 1 | 0.372 2 | 0.971 0 | 1.320 7 | 0.341 8 |
|      | QR-CNN-LSTM         | 0.785 0 | 1.576 6 | 0.803 4 | 0.821 2 | 1.545 2 | 0.794 5 |
|      | QR-TCN-GRU          | 0.866 3 | 1.458 0 | 0.737 8 | 0.896 6 | 1.312 8 | 0.686 6 |
| 85%  | QR-TCN-GRU-DA       | 0.903 2 | 1.275 2 | 0.598 3 | 0.959 8 | 1.276 6 | 0.565 8 |
|      | QR-ISBAO-TCN-GRU-DA | 0.920 4 | 1.030 8 | 0.576 6 | 0.944 5 | 1.060 5 | 0.514 9 |
|      | QR-CNN-LSTM         | 0.710 5 | 0.879 5 | 0.967 2 | 0.792 8 | 0.846 2 | 0.930 9 |
| 85%  | QR-TCN-GRU          | 0.783 8 | 0.843 2 | 0.886 1 | 0.811 0 | 0.815 1 | 0.820 8 |
|      | QR-TCN-GRU-DA       | 0.823 9 | 0.827 4 | 0.619 4 | 0.843 9 | 0.854 8 | 0.648 5 |
|      | QR-ISBAO-TCN-GRU-DA | 0.863 8 | 0.756 0 | 0.595 5 | 0.899 5 | 0.722 1 | 0.581 2 |

模型在区间预测方面表现最佳, 预测覆盖率最高, 预测区间宽度最窄, 综合评价指标最优, 充分证明了该模型在不确定性预测中的有效性。

为验证融合非线性分位数回归方法对区间预测的优越性, 在 95% 置信度下, 将基于改进 Loss 函数的 QR 模型与传统 QR、Bootstrap 方法进行对比分析, 区间误差评价指标对比如表 3 所示。

表 3 不同区间预测模型在 95% 置信度下的评价指标对比

Table 3 Comparison of evaluation metrics of different interval prediction models at 95% confidence level

| 数据集 | 融合不同方法的区间预测    | 95% 置信区间 |         |         |
|-----|----------------|----------|---------|---------|
|     |                | PICP     | PINAW   | CWC     |
| 冬季  | Bootstrap      | 0.843 2  | 1.972 3 | 0.741 0 |
|     | 传统 QR          | 0.921 7  | 1.543 2 | 0.531 6 |
| 夏季  | 改进 Loss 函数的 QR | 0.968 1  | 1.350 1 | 0.372 2 |
|     | Bootstrap      | 0.834 7  | 2.082 3 | 0.694 6 |
|     | 传统 QR          | 0.940 8  | 1.573 1 | 0.502 2 |
|     | 改进 Loss 函数的 QR | 0.971 0  | 1.320 7 | 0.341 8 |

通过表 3 可知, 以冬季预测为例, 经过改进 Loss 函数的 QR 模型 PINAW 和 CWC 比 Bootstrap 分别降低 21.76% 和 28.26%, 比传统 QR 分别下降了 12.51% 和 29.98%。因此, 所提出的改进 loss 函数的 QR 方法在进行预测时可得到更为良好的置信区间, 更符合实际应用场景。

## 4 结 论

准确预测风电功率对电力系统稳定运行和电网智能调度至关重要。传统模型在捕捉功率序列的长期依赖性

方面存在局限, 且大多仅提供单一点值预测, 缺乏对不确定性的量化分析, 导致区间可靠性不足。为此, 提出一种基于双重注意力机制的 TCN-GRU-DA 的短期风电功率组合预测模型, 通过点-区间协同优化实现预测性能的全面提升。首先, 构建融合特征注意力和多头注意力的双重注意力机制组合预测模型, 深入挖掘数据特征与时间信息之间的关系, 增强对时序序列长期依赖性的捕捉能力。然后, 引入改进鹭鹰优化算法优化模型四个超参数, 使模型迅速找到更优的参数组合, 提升点值预测精度。最后, 构建基于多头注意力机制的分位数回归损失函数, 更好地反映在不同置信度下风电功率数据变化的阈值, 确保区间预测的可靠性, 增强模型在复杂场景下的适应性与实用性。

## 参考文献

- [1] ANTONINI E G, VIRGUEZ E, ASHFAQ S, et al. Identification of reliable locations for wind power generation through a global analysis of wind droughts[J]. Communications Earth & Environment, 2024, 5(1): 103.
- [2] 洪国庆, 吴国旸, 金宇清, 等. 电力系统风力发电建模与仿真研究综述[J]. 电力系统自动化, 2024, 48(17): 22-36.  
HONG G Q, WU G Y, JIN Y Q, et al. Review on research of modeling and simulation for wind power generation in power system [J]. Automation of Electric Power Systems, 2024, 48(17): 22-36.
- [3] 王永生, 张哲, 刘利民, 等. 基于改进熵权法和 SECEEMD 的短期风电功率预测[J]. 科学技术与工程, 2023, 23(27): 11688-11697.  
WANG Y SH, ZHANG ZH, LIU L M, et al. Short term wind power prediction based on improved entropy

- weight method and SECEEMD [J]. Science Technology and Engineering, 2023, 23 (27): 11688-11697.
- [4] 王丽婕, 刘田梦, 王勃, 等. 基于奇异值分解与卡尔曼滤波修正多位置 NWP 的短期风电功率预测[J]. 太阳能学报, 2022, 43(12): 392-398.
- WANG L J, LIU T M, WANG B, et al. Short-term wind power prediction based on SVD and kalman filter correction of multi-position NWP[J]. Acta Energiae Solaris Sinica, 2022, 43(12): 392-398.
- [5] KISVARI A, LIN Z, LIN X L. Wind power forecasting-A data-driven method along with gated recurrent neural network [J]. Renewable Energy, 2021, 163: 1895-1909.
- [6] 王愈轩, 刘尔佳, 黄永章. 基于 CNN-LSTM-lightGBM 组合的超短期风电功率预测方法[J]. 科学技术与工程, 2022, 22(36): 16067-16074.
- WANG Y X, LIU ER J, HUANG Y ZH. An ultra-short-term wind power prediction method based on CNN-LSTM-lightGBM combination [J]. Science Technology and Engineering, 2022, 22(36): 16067-16074.
- [7] 王渝红, 史云翔, 周旭, 等. 基于时间模式注意力机制的 BiLSTM 多风电机组超短期功率预测[J]. 高电压技术, 2022, 48(5): 1884-1892.
- WANG Y H, SHI Y X, ZHOU X, et al. Ultra-short-term power prediction for BiLSTM multi wind turbines based on temporal pattern attention[J]. High Voltage Engineering, 2022, 48(5): 1884-1892.
- [8] 欧旭鹏, 任涛, 王玉鹏, 等. 基于改进麻雀搜索算法优化深度学习网络超参数的短期风电功率预测[J]. 智慧电力, 2023, 51(3): 31-38,52.
- OU X P, REN T, WANG Y P, et al. Short-term wind power prediction by optimizing deep learning network hyper-parameters based on ISSA[J]. Smart Power, 2023, 51(3): 31-38,52.
- [9] 孟事业, 罗倩. 基于 CEEMDAN 优化的轴承故障变分推断诊断算法[J]. 电子测量技术, 2023, 46(22): 94-101.
- MENG SH Y, LUO Q. Variational inference algorithm for bearing fault diagnosis based on CEEMDAN optimization[J]. Electronic Measurement Technology, 2023, 46(22): 94-101.
- [10] RIBEIRO M H D, DA SILVA R G, MORENO S R, et al. Variational mode decomposition and bagging extreme learning machine with multi-objective optimization for wind power forecasting[J]. Applied Intelligence, 2024, 54(4): 3119-3134.
- [11] 张亚刚, 赵云鹏, 王思祺. 基于 EVMD 和布谷鸟算法的短期风功率区间预测[J]. 太阳能学报, 2022, 43(8): 292-299.
- ZHANG Y G, ZHAO Y P, WANG S Q. Short term wind power interval prediction based on EVMD and CUCKOO algorithm[J]. Acta Energiae Solaris Sinica, 2022, 43(8): 292-299.
- [12] 李琦, 许素安. 基于 GSABO-BP 和 Bootstrap 的电力负荷区间预测[J]. 现代电子技术, 2024, 47(10): 28-33.
- LI Q, XU S AN. Power load interval prediction based on GSABO-BP and Bootstrap[J]. Modern Electronics Technique, 2024, 47(10): 28-33.
- [13] LIU T H, QI SH L, QIAO X ZH, et al. A hybrid short-term wind power point-interval prediction model based on combination of improved preprocessing methods and entropy weighted GRU quantile regression network[J]. Energy, 2024, 288: 129904.
- [14] WANG M, YING F X. Point and interval prediction for significant wave height based on LSTM-GRU and KDE[J]. Ocean Engineering, 2023, 289: 116247.
- [15] DEHGHANI M, HUBÁLOVSKÝ S, TROJOVSKÝ P. Northern goshawk optimization: A new swarm-based algorithm for solving optimization problems[J]. IEEE Access, 2021, 9: 162059-162080.
- [16] HE X Y, HE B T, QIN T, et al. Ultra-short-term wind power forecasting based on a dual-channel deep learning model with improved coot optimization algorithm[J]. Energy, 2024, 305: 132320.
- [17] 蒋翱徽, 刘文红. 基于改进蜣螂优化算法的无人机三维路径规划[J]. 电子测量技术, 2024, 47(13): 128-135.
- JIANG AO H, LIU W H. Unmanned aerial vehicle three-dimensional path planning based on improved dung beetle optimization algorithm [J]. Electronic Measurement Technology, 2024, 47(13): 128-135.
- [18] 韩莹, 朱宏宇, 李琨. 融合聚类及随机配置网络的短期光伏功率预测[J]. 电子测量与仪器学报, 2023, 37(11): 205-216.
- HAN Y, ZHU H Y, LIU K. Short-term PV power prediction by fusion of clustering and SCN[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(11): 205-216.
- [19] 赵杰, 解则晓, 刘世萱. 基于能量熵 VMD 最优分解与 GRU 循环神经网络的潮汐预测精度提升方法研究[J]. 仪器仪表学报, 2023, 44(12): 79-87.
- ZHAO J, XIE Z X, LIU SH X. Tide prediction accuracy improvement method research based on VMD optimal decomposition of energy entropy and GRU

- recurrent neural network [J]. Chinese Journal of Scientific Instrument, 2023, 44(12): 79-87.
- [20] 张开伟, 文中, 杨生鹏, 等. 基于改进 Cao 算法的 SSA 与误差修正的超短期风电功率预测[J]. 国外电子测量技术, 2024, 43(8): 37-46.  
ZHANG K W, WEN ZH, YANG SH P, et al. Ultra-short-term wind power forecasting through improved Cao algorithm for SSA and error correction [J]. Foreign Electronic Measurement Technology, 2024, 43(8): 37-46.
- [21] 章志晃, 徐启峰, 林穿. 基于 SSA-BiLSTM-AM 的短期风电功率预测 [J]. 国外电子测量技术, 2023, 42(3): 46-51.  
ZHANG ZH H, XU Q F, LIN CH. Short-term wind power prediction based on SSA-BiLSTM-AM [J].

Foreign Electronic Measurement Technology, 2023, 42(3): 46-51.

### 作者简介

蒲晓云,硕士研究生,主要研究方向为功率预测和智能优化算法研究等。

E-mail:3503295417@qq.com

杨靖,博士,教授,主要研究方向为群体智能优化和物联网技术与应用等。

E-mail:jyang7@gzu.edu.cn

杨兴,博士,副教授,主要研究方向为宽带信号合成技术和集成电路设计。

E-mail:xyang@gzu.edu.cn

宁媛(通信作者),硕士,教授,主要研究方向为智能信息处理技术研究等。

E-mail:ee.yning@gzu.edu.cn。