

# 基于 NRBO-CNN-BiGRU-MHA 的分布式 智能配电网源荷功率超短期预测

曹玉媛<sup>1</sup>, 黄达文<sup>1</sup>, 李 丰<sup>1</sup>, 李必伟<sup>1</sup>, 陈 磊<sup>2\*</sup>, 杨 满<sup>2</sup>,  
李逸飞<sup>2</sup>, 陈红坤<sup>2</sup>

(1. 广东电网有限责任公司 肇庆供电局, 广东 肇庆 526040;

2. 武汉大学 电气与自动化学院, 湖北 武汉 430072)

## Source-Load Power Ultra-Short-Term Forecasting in Distributed Smart Distribution Networks Based on NRBO-CNN-BiGRU-MHA

CAO Yuyuan<sup>1</sup>, HUANG Dawen<sup>1</sup>, LI Feng<sup>1</sup>, LI Biwei<sup>1</sup>, CHEN Lei<sup>2\*</sup>,  
YANG Man<sup>2</sup>, LI Yifei<sup>2</sup>, CHEN Hongkun<sup>2</sup>

(1. Zhaoqing Power Supply Bureau, CSG Guangdong Power Grid Corporation, Zhaoqing 526040, China;

2. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

**Abstract:** [Objective] To address the renewable energy curtailment caused by the mismatch between stochastic renewable generation and time-varying load characteristics in distributed smart grids, this paper proposes a source-load power ultra-short-term forecasting model integrating convolutional neural network (CNN), bidirectional gated recurrent unit (BiGRU), and multi-head attention (MHA) mechanisms. [Methods] Firstly, a CNN was employed to extract spatiotemporal features of renewable power. Subsequently, a BiGRU was utilized to capture bidirectional temporal dependencies in load sequences. Thirdly, MHA was introduced to dynamically assign weights to critical time-step information, and a Newton-Raphson based optimizer (NRBO) was utilized for the automatic hyperparameter tuning to enhance model generalization capability. Finally, this paper presented the NRBO-optimized CNN-BiGRU-MHA modeling framework, achieving accurate ultra-short-term forecasting of source-load power. [Results] Case studies demonstrated that compared to CNN-BiGRU and BiGRU models, the proposed CNN-BiGRU-MHA model reduced the relative error by 51.5% and 74.1%. The proposed NRBO-CNN-BiGRU-MHA model outperformed other commonly used algorithm models in prediction accuracy, with its predicted

peak values closely matching the actual values in both magnitude and trend. The model excelled in handling smooth features and exhibited strong adaptability and robustness under both peak and off-peak power load conditions.

[Conclusion] The model proposed in this paper demonstrates more stable prediction performance under different weather conditions, verifying the effectiveness of its spatio-temporal feature mining. It provides a new idea for power forecasting in scenarios with high-proportion new energy integration and has practical value for promoting the consumption of renewable energy.

**Key words:** distributed smart distribution network; source-load power; ultra-short-term forecasting; multi-head attention mechanism

**摘要:** [目的]为解决分布式智能配电网中因新能源出力随机性与负荷时变特性不匹配导致的弃能问题,本文提出了一种融合卷积神经网络(CNN)-双向门控循环单元(BiGRU)-多头注意力(MHA)机制的源荷功率超短期预测模型。[方法]首先,采用CNN提取风光功率的时空关联特征,通过BiGRU捕捉负荷序列的前后向时序依赖关系;其次,引入MHA机制动态加权关键时间步信息,采用牛顿-拉夫逊优化算法(NRBO)进行超参数自动调优,提升模型泛化能力;最后,给出了NRBO优化CNN-BiGRU-MHA模型的流程,实现了源荷功率超短期预测。[结果]案例仿真和比较结果表明,相较于CNN-BiGRU和BiGRU模型,所提CNN-BiGRU-MHA模型的相对误差分别降低

基金项目:南方电网科技项目(GDKJXM20231387)

Science and Technology Project of China Southern Power Grid  
(GDKJXM20231387)

了 51.5% 和 74.1%;所提 NRBO-CNN-BiGRU-MHA 模型的预测准确率优于其他常用算法模型,其预测峰值的高度和趋势与实际值非常吻合,该模型擅于处理平缓特征,并且面对用电高峰与低谷工况的适应性和鲁棒性强。【结论】本文所提 NRBO-CNN-BiGRU-MHA 模型在不同天气条件下均表现出更稳定的预测性能,验证了其时空特征挖掘的有效性,为高比例新能源接入场景下的功率预测提供了新思路,对促进可再生能源消纳具有实用价值。

**关键词:** 分布式智能配电网;源荷功率;超短期预测;多头注意力机制

## 0 引言

在全球能源转型加速推进的背景下,以“碳达峰、碳中和”目标为导向的新型电力系统建设正驱动配电网发生根本性变革<sup>[1-2]</sup>。随着风电、光伏等新能源渗透率突破 30% 的临界阈值,其出力间歇性与负荷时变特性共同作用,使得配电网潮流由传统单向流动转变为复杂的多向动态分布,加速了传统辐射状配电网向“源-网-荷-储”协同互动的分布式智能配电网演进<sup>[3-4]</sup>。

尽管高比例可再生能源接入显著提升了电力系统的清洁化程度,但由日内功率波动及源荷时空不匹配引发的弃风弃光问题,已成为制约新能源高效消纳的主要瓶颈<sup>[5-6]</sup>。根据全国新能源消纳监测预警中心发布的《2025 年 3 月全国新能源并网消纳情况》报告,2025 年 3 月单月全国弃风弃光率为 7.2% 和 6.4%,西北部分地区超 10%,如陕西弃光 13.3%、甘肃弃光 10.8% 以及青海弃风 10.2% 等。研究表明,风光出力的概率性消纳与负荷需求的弹性调节呈现出高度非线性耦合特征,亟需通过高精度源荷超短期预测技术构建动态平衡机制,这对于优化储能系统和备用电源的调度策略、提升可再生能源消纳能力具有重要价值<sup>[7-9]</sup>。

当前,在风光荷短期预测技术领域,国内外学者已基于机器学习方法开展了系列研究。文献[10]通过改进长短期记忆卷积神经网络(Convolutional Neural Network, CNN)架构,提高了风电功率预测精度。文献[11]将 K 均值聚类算法与双向长短期记忆网络相结合,并引入核局部保持投影技术实现数据降维。文献[12]构建了融合奇异谱分析、CNN、双向门控循环单元(Bidirectional Gated Recurrent Unit, BiGRU)及

Attention 机制的混合预测框架,一定程度上提高了功率超短期预测精度。此外,文献[13-17]从模型优化、算法改进和参数优化等角度推进了相关研究。传统模型在高渗透率新能源电网中存在局限性,具体表现为长序列数据处理能力相对薄弱,复杂数据捕捉性能和超参数优化性能还有待进一步提升。

然而,现有基于机器学习的预测方法仍存在明显局限性:一方面,模型性能过度依赖数据质量,难以有效处理含噪声、缺失或采样频率不一致的实测数据。另一方面,对多源非线性因素的耦合作用缺乏有效建模手段,且模型泛化能力不足<sup>[18-19]</sup>。这些缺陷严重制约了预测精度的进一步提升。

针对上述挑战,本文提出一种基于 CNN-BiGRU-多头注意力(Multi-Head Attention, MHA)机制的分布式智能配电网源荷功率超短期预测模型。首先,采用 CNN 提取风光功率的时空关联特征,通过 BiGRU 捕捉负荷序列的前后向时序依赖关系;其次,引入 MHA 机制动态加权关键时间步信息,采用牛顿-拉夫逊优化算法(Newton-Raphson Based Optimizer, NRBO)进行超参数自动调优,提升模型泛化能力;最后,给出了 NRBO 优化 CNN-BiGRU-MHA 模型的流程,通过多场景仿真验证了所提预测模型 NRBO-CNN-BiGRU-MHA 的性能优势。

## 1 CNN-BiGRU-MHA 模型构建

### 1.1 数据预处理

为消除数据噪声对预测的影响,本文采用  $3\sigma$  统计法检查所得到的历史源功率信息数据。假定某一数据序列为  $\{x_1, x_2, x_3, \dots, x_i\}$ ,  $x_i$  为序列  $i$  时段的测量值,根据式(1)、式(2)计算数据序列的期望和标准差。

$$E(i) = \sum_{k=1}^N X(N, i) \quad (1)$$

$$\sigma(i) = \sqrt{\frac{1}{N} \sum_{k=1}^N [X(N, i) - E(i)]^2} \quad (2)$$

式中: $E(i)$  为该数据序列的数学期望; $\sigma(i)$  为该数据序列的标准差。

根据  $3\sigma$  统计法,依次判断每一时刻数据是否处于  $[E(i) - 3\sigma(i), E(i) + 3\sigma(i)]$  的范围内。如果该时刻数据不在  $3\sigma$  范围内,则判断其为异

常数据并剔除。

针对剔除异常数据产生的数据缺失,采用平均值法进行插值处理,插入的数据值可由式(3)计算:

$$X(N, i) = \frac{X(N-1, i) + X(N+1, i)}{2} \quad (3)$$

### 1.2 CNN 模型

CNN 模型的结构如图 1 所示,其具有局部连接和权重共享的特点<sup>[20-21]</sup>。CNN 通过多层结构逐步提取从简单到复杂的特征,其核心流程为:卷积层利用可学习的卷积核提取局部特征,权值共享减少参数冗余;激活层 ReLU 引入非线性增强表达能力;池化层通过下采样降低维度并增强平移不变性;多层堆叠后,全连接层将抽象特征映射到输出空间<sup>[22]</sup>。

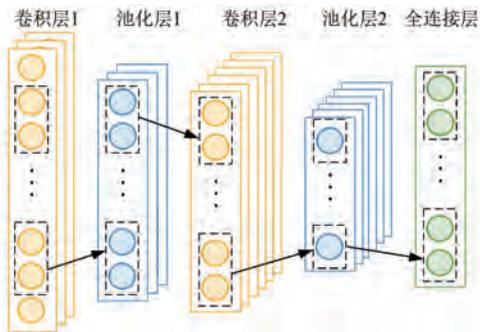


图 1 CNN 结构示意图

Fig. 1 CNN structural schematic diagram

### 1.3 GRU 模型

GRU 核心原理是通过门控机制来控制信息的流动,有选择性地更新隐藏状态<sup>[23-24]</sup>。GRU 设计重置门和更新门两种门控单元,其结构如图 2 所示。

重置门控制前一时刻隐藏状态  $h_{t-1}$  的信息遗

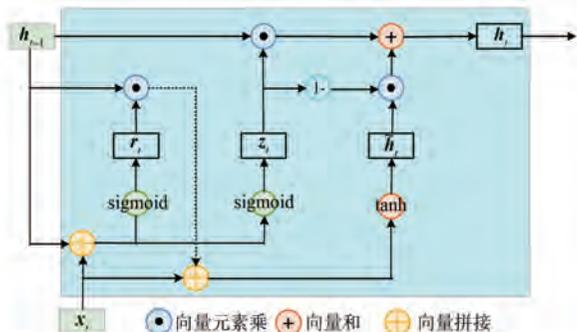


图 2 GRU 模型结构图

Fig. 2 GRU model structure diagram

忘程度,其计算式为

$$r_t = \text{sigmoid}(W_r x_t + U_r h_{t-1} + b_r) \quad (4)$$

式中: $r_t$  为重置门的输出; $x_t$  为当前输入; $h_{t-1}$  为前一时刻的隐藏状态; $W_r$ 、 $U_r$  和  $b_r$  为重置门参数。

更新门平衡旧状态继承与新状态采纳的比例,其计算式为

$$z_t = \text{sigmoid}(W_z x_t + U_z h_{t-1} + b_z) \quad (5)$$

式中: $z_t$  为更新门的输出; $W_z$ 、 $U_z$ 、 $b_z$  为更新门参数。

候选隐藏状态融合当前输入  $x_t$  与经重置门筛选的历史信息,其计算式为

$$\tilde{h}_t = \tanh[W_h x_t + U_h(r_t \odot h_{t-1}) + b_h] \quad (6)$$

式中: $\tilde{h}_t$  为候选隐藏状态; $W_h$ 、 $U_h$  和  $b_h$  为模型参数; $\odot$  为逐元素乘法。

最终隐藏状态动态融合候选状态  $\tilde{h}_t$  与前一状态  $h_{t-1}$ ,其计算式为

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (7)$$

式中: $h_t$  为当前时刻的隐藏状态; $z_t \rightarrow 0$  时,保留历史状态, $z_t \rightarrow 1$  时,采纳候选状态。

### 1.4 MHA 模型

MHA 模型的结构如图 3 所示<sup>[25-26]</sup>。

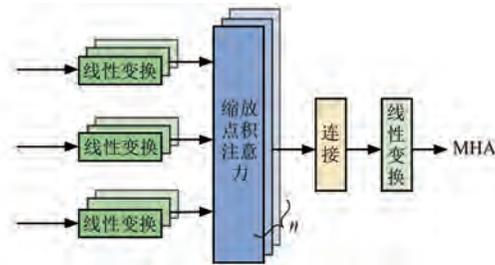


图 3 MHA 模型结构图

Fig. 3 MHA model structure diagram

自注意力机制又称内部注意力机制,是一种将单个序列的不同位置关联起来计算同一序列的注意机制,如式(8)所示:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (8)$$

式中: $Q$ 、 $K$ 、 $V$  分别为查询、键、值矩阵; $d_k$  为关键向量的维度,用于缩放点积以稳定 softmax 函数。

MHA 能够让模型在不同的位置捕捉到多种信息,更全面地理解数据。相关计算步骤如下。

步骤 1:线性变换。对序列中每个位置的向量分别进行三次加权和偏置,生成查询矩阵  $Q$ 、键

矩阵  $\mathbf{K}$  和值矩阵  $\mathbf{V}$ 。

步骤 2: 计算并行注意力。应用自注意力机制计算每个子空间的注意力权重, 然后加权求和值矩阵  $\mathbf{V}$ , 得到每个头的输出, 即:

$$Head_i = Attention(\mathbf{Q}\mathbf{W}_i^Q, \mathbf{K}\mathbf{W}_i^K, \mathbf{V}\mathbf{W}_i^V) \quad (9)$$

式中:  $\mathbf{W}_i^Q$ 、 $\mathbf{W}_i^K$ 、 $\mathbf{W}_i^V$  分别为第  $i$  个头的查询、键、值变换矩阵。

步骤 3: 合并及最终变换。将所有头拼接起

来并经过线性变换和归一化得到多头注意力的输出, 即:

$$MultiHead(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = Concat(Head_1, \dots, Head_n) \mathbf{W}^O \quad (10)$$

式中:  $\mathbf{W}^O$  为输出变换矩阵;  $Concat$  为拼接操作。

### 1.5 CNN-BiGRU-MHA 模型

本文提出的 CNN-BiGRU-MHA 模型包含 CNN 层、BiGRU 层和 MHA 层, 其结构如图 4 所示。

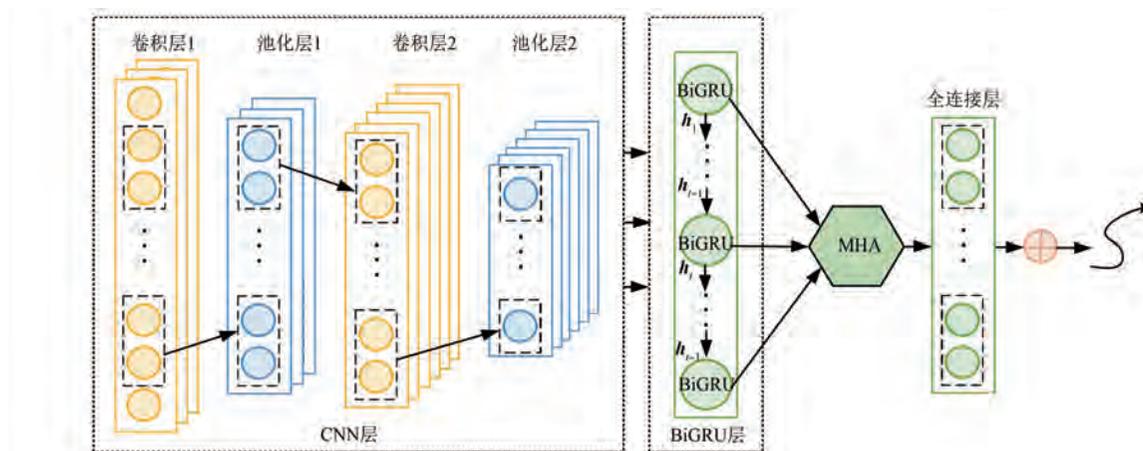


图 4 CNN-BiGRU-MHA 模型结构图

Fig. 4 CNN-BiGRU-MHA model structure diagram

在所提模型中, CNN 用于历史负荷数据特征的提取, 其包含卷积层、最大池化层和全连接层<sup>[27]</sup>。因 ReLU 作为激活函数能缓解梯度消失、加快收敛并减少过拟合, 适用于 CNN 层和 BiGRU 层的特征提取与序列建模。sigmoid 函数则用于输出层, 可将结果映射到 (0, 1) 区间, 便于分类决策且能稳定训练。因此, 将卷积层 1 和卷积层 2 设计为一维卷积层, 选择 ReLU 激活函数进行激活。池化层采用最大池化的方法, 以保留数据中的更多信息。卷积层和池化层处理过的数据通过全连接层映射到隐藏特征空间, 全连接层使用 sigmoid 函数, 最后建立 CNN 框架, 从原始数据中提取出特征向量。具体如式 (11) ~ 式 (15) 所示:

$$\mathbf{C}_1 = ReLU(\mathbf{X} \otimes \mathbf{W}_1 + \mathbf{b}_1) \quad (11)$$

$$\mathbf{P}_1 = \max(\mathbf{C}_1) + \mathbf{b}_2 \quad (12)$$

$$\mathbf{C}_2 = ReLU(\mathbf{P}_1 \otimes \mathbf{W}_2 + \mathbf{b}_3) \quad (13)$$

$$\mathbf{P}_2 = \max(\mathbf{C}_2) + \mathbf{b}_4 \quad (14)$$

$$\mathbf{H}_c = \text{sigmoid}(\mathbf{P}_2 \times \mathbf{W}_3 + \mathbf{b}_5) \quad (15)$$

式中:  $\mathbf{C}_1$ 、 $\mathbf{C}_2$ 、 $\mathbf{P}_1$  和  $\mathbf{P}_2$  分别为卷积层 1、卷积层 2、池化层 1 和池化层 2 的输出;  $\mathbf{W}_1$ 、 $\mathbf{W}_2$ 、 $\mathbf{W}_3$  和  $\mathbf{b}_1$ 、

$\mathbf{b}_2$ 、 $\mathbf{b}_3$ 、 $\mathbf{b}_4$ 、 $\mathbf{b}_5$  分别为权重矩阵和偏差;  $\otimes$  和  $\max(\cdot)$  为卷积和最大值函数; CNN 层的输出长度为  $i$ , 记作  $\mathbf{H}_c = [h_{c_1} \dots h_{c_{i-1}} \dots h_{c_i} \dots h_{c_i}]^T$ 。

BiGRU 层通过其独特的双层反向 GRU 结构继续充分学习 CNN 层提取的特征向量的特征, 以捕捉内部变化规律, 结构如图 5 所示。该层在第  $t$  步的输出  $\mathbf{h}_t$  可表示为

$$\mathbf{h}_t = GRU(\mathbf{H}_{c,t-1}, \mathbf{H}_{c,t}), t \in [1, i] \quad (16)$$

需要补充的是, MHA 层的输入即为 BiGRU 网络层的输出向量  $\mathbf{h}_t$ 。MHA 中, 输入序列被分割成多个头, 每个头独立地计算注意力, 然后将结果拼接起来, 并通过一个线性层进行转换, 以获得最终的输出。

## 2 基于 NRBO 的 CNN-BiGRU-MHA 优化策略

### 2.1 NRBO 算法原理

NRBO 算法通过在候选解的边界内产生初始随机种群, 开始搜索最优解。对于  $N_p$  个种群, 每个种群由  $dim$  个决策变量/向量组成<sup>[28]</sup>。随机种

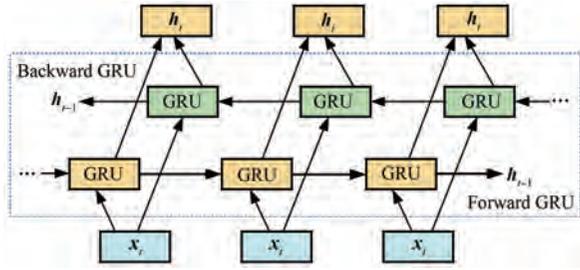


图 5 BiGRU 模型结构图

Fig. 5 BiGRU model structure diagram

群生成的表达式为

$$x_j^n = lb + rand \cdot (ub - lb),$$

$$n = 1, 2, \dots, N_p, j = 1, 2, \dots, dim \quad (17)$$

式中:  $x_j^n$  为第  $n$  个群体中第  $j$  个维度的位置;  $rand$  为  $(0, 1)$  之间的随机数;  $ub$ 、 $lb$  分别为优化参数上限、下限。

种群矩阵的表达式为

$$X_n = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_{dim}^1 \\ x_1^2 & x_2^2 & \dots & x_{dim}^2 \\ \vdots & \vdots & \ddots & \vdots \\ x_1^{N_p} & x_2^{N_p} & \dots & x_{dim}^{N_p} \end{bmatrix}_{N_p \times dim} \quad (18)$$

NRBO 算法基于泰勒级数展开, 通过迭代更新求解位置, 逐步逼近并确定最优解, 其过程从随机选择的初始解出发, 沿着特定方向迭代更新后续解的位置:

$$x^{it+1} = x^{it} - \frac{f'(x^{it})}{f''(x^{it})} \quad (19)$$

式中:  $x^{it}$  为当前解的位置;  $x^{it+1}$  为更新后解的位置;  $f(x)$  为适应度函数。

基于泰勒级数展开原理, NRBO 算法通过引入参数  $\rho$  引导种群向正确的进化方向推进, 如式 (20) ~ 式 (24) 所示:

$$\rho = a \cdot (X_b - X_n^{it}) + b \cdot (X_{r_1}^{it} - X_{r_2}^{it}) \quad (20)$$

$$NRSR = randn \cdot \frac{(Y_w - Y_b) \cdot \Delta X}{2(Y_w + Y_b - 2X^{it})} \quad (21)$$

$$Y_w = r_3 \cdot [Mean(Z^{it+1} + X^{it}) + r_3 \Delta X] \quad (22)$$

$$Y_b = r_3 \cdot [Mean(Z^{it+1} + X^{it}) - r_3 \Delta X] \quad (23)$$

$$Z^{it+1} = X^{it} - randn \cdot \frac{(X_w - X_b) \cdot \Delta X}{2(X_w + X_b - 2X^{it})} \quad (24)$$

式中:  $a$ 、 $b$  为介于 0 到 1 之间的随机数;  $X_n^{it}$  为第  $i$  次迭代后种群  $n$  的位置;  $randn$  为标准正态分布随机数;  $X_b$ 、 $X_w$  分别为附近较好、较差的种群的位置;

$r_1$ 、 $r_2$  为介于 0 到  $n$  之间的随机整数;  $Y_w$ 、 $Y_b$  分别为利用  $Z^{it+1}$ 、 $X^{it}$  生成的两个位置;  $r_3$  为  $[0, 1]$  区间均匀分布的随机数;  $\Delta X$  为体现当前最佳位置与当前位置差别的扰动量。

进而, NRBO 算法结合牛顿-拉夫逊搜索规则和最佳向量构造策略, 实现高效最优解搜索, 计算如式 (25)、式 (26) 所示:

$$X1_n^{it} = X_n^{it} - randn \cdot \frac{(Y_w - Y_b) \cdot \Delta X_n}{2(Y_w + Y_b - 2Y_n^{it})} + \rho \quad (25)$$

$$X2_n^{it} = X_b - randn \cdot \frac{(Y_w - Y_b) \cdot \Delta X_n}{2(Y_w + Y_b - 2Y_n^{it})} + \rho \quad (26)$$

式中:  $X1_n^{it}$ 、 $X2_n^{it}$  分别为  $X_n^{it}$  通过第一种、第二种方式更新得到的位置;  $\Delta X_n$  为体现种群  $n$  当前最佳位置与当前位置差别的扰动量;  $Y_n^{it}$  为算法在第  $i$  次迭代中, 种群第  $n$  个个体的中间引导变量。

式 (25) 在局部搜索中表现优异, 但在全局搜索能力上存在一定局限; 而式 (26) 则更侧重于全局搜索, 却在局部搜索方面有所不足。NRBO 算法通过巧妙结合这两种方法的优势, 优化了整体搜索性能。因此, 下一次迭代的新位置由式 (27) ~ 式 (29) 确定:

$$X_n^{it+1} = r_4 [r_4 \cdot X1_n^{it} + (1 - r_4) \cdot X1_n^{it}] + (1 - r_4) \cdot X3_n^{it} \quad (27)$$

$$X3_n^{it} = X_n^{it} - \text{sigmoid}(X2_n^{it} - X1_n^{it}) \quad (28)$$

$$\delta = \left[ 1 - \left( \frac{2K^{it}}{K_{max}^{it}} \right) \right]^5 \quad (29)$$

式中:  $X3_n^{it}$  为  $X_n^{it}$  通过第三种方式更新得到的位置;  $K^{it}$  为迭代次数;  $K_{max}^{it}$  为最大迭代次数;  $r_4$  为介于 0 到 1 之间的随机数;  $\delta$  为自适应系数。

## 2.2 NRBO 与 CNN-BiGRU-MHA 的协同性分析

NRBO 算法的全局优化与自适应超参数调整能力, 可为 CNN-BiGRU-MHA 提供最优超参数配置, 增强其特征提取与序列建模能力。NRBO 算法能根据数据特性动态调整学习率等超参数, 确保 CNN 有效提取特征、BiGRU 稳定捕捉序列信息、MHA 准确建模特征间关系。鉴于 CNN-BiGRU-MHA 模型架构的高度复杂性和训练的高计算成本, 利用 NRBO 这样高效的优化算法进行超参数调优, 对提升模型训练效率和最终预测性能至关重要。

为提高 CNN-BiGRU-MHA 模型的预测性能,

本文采用 NRBO 算法对关键超参数进行优化,在优化过程中兼顾全局搜索与局部搜索能力,使得学习率、BiGRU 隐藏单元数、MHA 键值数量和卷积核大小这 4 个超参数能够更快速地收敛到最优解,流程如下。

步骤 1: 数据处理。将数据集划分为 70% 训练集和 30% 测试集,同时对数据进行归一化处理,如式(30)所示:

$$y = (y_{\max} - y_{\min}) \cdot \frac{x - x_{\min}}{x_{\max} - x_{\min}} + y_{\min} \quad (30)$$

式中: $y$  为数据归一化后的值; $y_{\max}$ 、 $y_{\min}$  分别为归一化设定上限、下限; $x$  为数据原始值; $x_{\max}$ 、 $x_{\min}$  分别为数据原始最大值、最小值。

步骤 2: 模型搭建。构建 CNN-BiGRU-MHA 模型,CNN 提取数据的局部特征、BiGRU 捕获长时依赖、MHA 机制提升重要特征的权重,将各层连接起来形成完整网络并进行网络训练。

步骤 3: 预测与性能评估。使用训练好的模型预测训练集和测试集的数据,将预测结果从归一化还原为原始尺度,计算误差指标平均绝对误差(Mean Absolute Error, MAE)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)、均方误差(Mean Squared Error, MSE)、均方根误差(Root Mean Squared Error, RMSE)和决定系数(R-squared,  $R^2$ )如式(31)~式(35)所示:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (31)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (32)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (33)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (34)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (35)$$

式中: $y_i$  为实际值; $\hat{y}_i$  为预测值; $n$  为样本数量。

步骤 4: 参数优化。利用 NRBO 算法优化学习率、BiGRU 隐藏单元数、MHA 键值数量和卷积核大小。

步骤 5: 使用 NRBO 算法找到最优参数重新

训练网络,生成新的预测结果。

## 3 分布式智能配电网源荷功率超短期预测试验分析

### 3.1 学习模型及优化参数设置

本文采用 Adam 优化器对 CNN-BiGRU-MHA 模型进行训练,利用分段常数衰减,在训练 60 次后进行学习率调整,调整因子为 0.1。其参数设置如表 1 所示。

采用 NRBO 算法对模型中的学习率、BiGRU 神经元个数、MHA 键值和卷积核大小 4 个超参数进行优化,算法参数如表 2 所示。

表 1 CNN-BiGRU-MHA 模型参数

Tab. 1 CNN-BiGRU-MHA model parameters

参数名称	参数值
最大训练次数	30
梯度阈值	1
学习率开始调整训练次数	60
学习率调整因子	0.1
头数	8
模型维度	24
卷积核数量	2
池化窗口大小	[2, 2]
隐藏单元数	30

表 2 NRBO 算法参数

Tab. 2 Parameters of the NRBO algorithm

参数名称	参数值
初始种群规模	10
最大进化代数	30
TAO 决定因子	0.6
学习率最大值	0.1
学习率最小值	0.001
BiGRU 神经元最大个数	50
BiGRU 神经元最小个数	10
MHA 键值最大值	50
MHA 键值最小值	2
卷积核最大维度	10
卷积核最小维度	2

NRBO 算法在全局搜索和局部优化中的优势源于其独特的搜索规则和陷阱规避机制(Trap

Avoidance Operator, TAO)<sup>[29]</sup>。与灰狼优化 (Grey Wolf Optimization, GWO) 算法和粒子群优化 (Particle Swarm Optimization, PSO) 算法相比, NRBO 算法能更有效地探索搜索空间, 避免陷入局部最优<sup>[30]</sup>, 并且在局部优化中可通过随机扰动增强搜索能力, 进一步提升优化解的质量<sup>[31]</sup>。

为验证 NRBO 算法在 CNN-BiGRU-MHA 模型超参数优化中的性能优势, 选取 GWO 算法和 PSO 算法进行性能对比。NRBO、GWO 和 PSO 三种算法在适应度值收敛过程中的对比特性如图 6 所示。

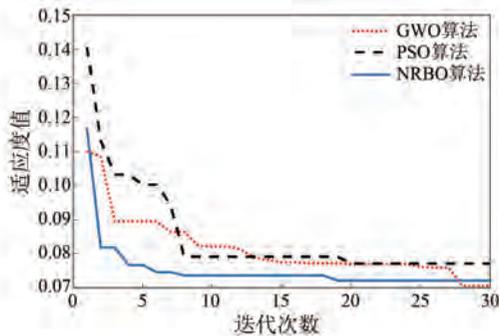


图 6 NRBO、GWO 和 PSO 算法适应度收敛曲线对比  
Fig. 6 Comparison of adaptation convergence curves of NRBO, GWO and PSO algorithms

由图 6 可知, 在优化初期, NRBO 算法展现了最快的适应度下降速率, 其初始适应度值为 0.117, 经过 5 次迭代下降至 0.075。而 GWO 和 PSO 算法在相同迭代次数内的适应度值分别下降至 0.092 和 0.1。在中后期迭代次数超过 15 后, NRBO 算法适应度值进一步下降并最终稳定在 0.072, 显著优于 GWO 算法的 0.075 和 PSO 算法的 0.078。

为可视化 NRBO 算法优化超参数的过程, 本文绘制学习率、BiGRU 隐藏单元数等参数随迭代次数的变化曲线, 如图 7 所示。

由图 7 可知, 在学习率优化中, 其初期从  $5.3 \times 10^{-3}$  快速下降至  $4.9 \times 10^{-3}$  后趋于稳定, 平衡了收敛速度与稳定性。BiGRU 神经元数量从 27 优化至 21, 减少 22%, 降低了模型复杂度。此外, 注意力键值在优化过程中保持为 2, 适配模型需求。卷积核数量从 4 迅速降至 2, 降幅达 50%, 削减了计算量与参数量。

### 3.2 源荷功率超短期预测分析

本文选取 Matlab 平台导入欧洲电网数据集, 该数据集涵盖了从 2023 年 12 月 13 日至 12 月 14

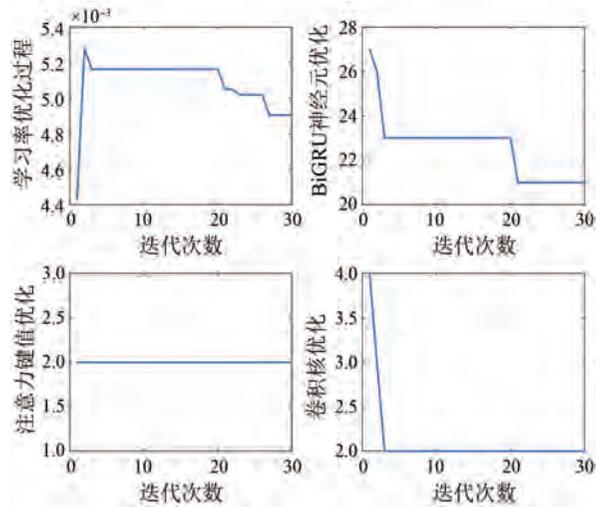


图 7 超参数优化过程

Fig. 7 The process of hyperparameter optimization

日的比利时电网运行数据, 时间分辨率为 15 min, 负荷数据信息包含风电、光伏和配电负荷。

针对风电功率预测任务, 本文模型通过 CNN-BiGRU-MHA 三级架构实现高效协同处理: CNN 使用  $3 \times 1$  卷积核提取风速-功率的局部特征, 在样本点 12~20 处检测到短时波动, 相关系数提升 0.23; BiGRU 通过双向门控机制融合时序信息, 反向 GRU 对数值天气预报的响应强度比正向高 42%, 使预测误差降低 23.7%; MHA 则动态聚焦关键时段, 注意力权重升至 0.92, 使突变时段 MAE 下降 21.3%。

不同模型的风电功率预测结果如图 8 所示, 不同模型的预测误差指标如表 3 所示。

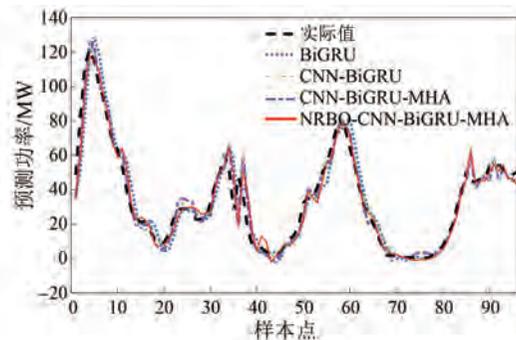


图 8 不同模型的风电功率预测曲线与误差对比  
Fig. 8 Comparison of wind power prediction curves and errors of different models

由图 8 可知, NRBO-CNN-BiGRU-MHA 模型的预测结果与真实值的拟合度最高。CNN-BiGRU-MHA 模型次之, 通过引入 MHA 提升了对

表 3 不同模型的风电功率预测误差指标  
 Tab.3 Indicators of wind power prediction error under different models

误差指标	CNN	CNN-BiGRU	CNN-BiGRU-MHA	NRBO-CNN-BiGRU-MHA
MSE/[ (MW) <sup>2</sup> ]	107.14	112.39	120.397	104.82
RMSE/MW	10.351	10.973	10.602	10.238 1
MAE/MW	6.656 7	6.354 4	6.304 5	6.263 8
MAPE/%	46.816	33.698	33.177	31.375
R <sup>2</sup> /%	81.163	96.89	97.094	97.23

全局特征和长期依赖的建模能力,但在某些时刻仍存在一定偏差。相比之下,CNN-BiGRU 模型通过 CNN 提取局部特征,表现优于 BiGRU 模型,但其对全局特征的捕捉能力有限。BiGRU 模型由于仅依赖双向循环神经网络对时序特征进行建模,预测精度最差。

由表 3 可知,在拟合优度方面,本文模型的决定系数 R<sup>2</sup> 为 97.23%,高于 CNN-BiGRU-MHA 的 97.094%、CNN-BiGRU 的 96.89%,从而能更精准刻画数据内在规律。综上,本文模型在 MSE、RMSE、MAE 和 MAPE 等误差指标上均实现最优表现,且 R<sup>2</sup> 指标突出。

不同模型的光伏功率预测性能对比如图 9 所示。

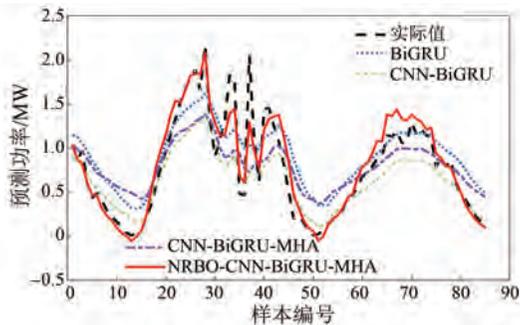


图 9 不同模型的光伏功率预测曲线与误差对比  
 Fig.9 Comparison of PV power prediction curves and errors of different models

由图 9 可知,BiGRU 模型在捕捉序列全局趋势方面表现出一定能力,但在对数据局部复杂波动的拟合上存在明显不足。在样本编号 30~40 和 70~80 区间,预测曲线相较真实值发生显著偏移,表现出滞后性。CNN-BiGRU 模型相较 BiGRU 曲线整体更加平滑,并在样本编号 20~30 和 60~70 区间的拟合效果有明显提升。然而,局部变化

较为剧烈的区域仍存在一定的预测误差。CNN-BiGRU-MHA 能够增强模型对关键特征的关注,使得预测曲线在多个区间(样本编号 40~50 和 70~80)更加贴合真实值。

本文模型在大多数样本区间与真实值高度吻合,显著改善了局部复杂区域的拟合精度。NRBO 算法的引入优化了模型的超参数调整,增强了模型在处理非线性动态序列时的鲁棒性。

不同模型对光伏功率预测的性能指标对比、负荷功率预测结果分别如图 10、图 11 所示。

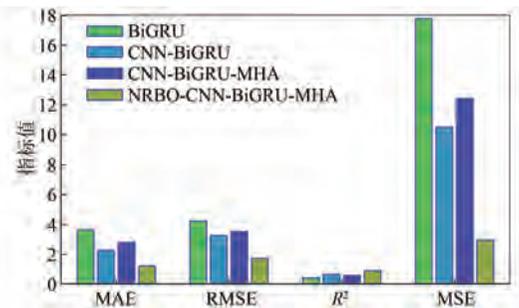


图 10 不同模型的光伏功率预测性能对比  
 Fig.10 Performance comparison of different models for PV power prediction

由图 10 可知,本文模型在各项指标上均表现出明显优势。在 MAE 上,其值为 6.62,优于 BiGRU 的 7.11 和 CNN-BiGRU 的 6.51。NRBO-CNN-BiGRU-MHA 的 MSE 和 RMSE 分别为 115.63 和 10.75,相较于 BiGRU 的 127.90 和 11.31 均有所降低。此外,其 R<sup>2</sup> 指标达到 97.14%,体现出更高的拟合能力。

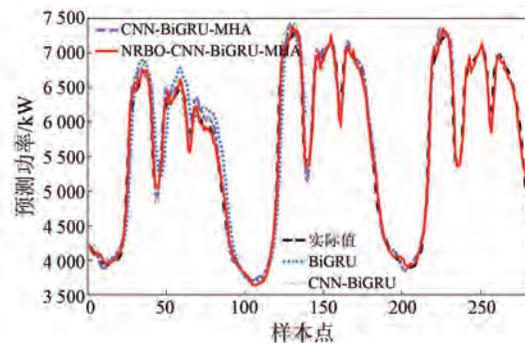


图 11 不同模型的负荷预测曲线与误差对比  
 Fig.11 Comparison of load power prediction curves and errors of different models

由图 11 可知,CNN-BiGRU-MHA 和 NRBO-CNN-BiGRU-MHA 两种模型在负荷功率预测中存在一定差异。NRBO-CNN-BiGRU-MHA 模型的预

测结果在多数采样点上的误差显著低于 CNN-BiGRU-MHA, 平均误差降低了 5.8%。本文模型可更准确地捕获真实负荷的波动, 其偏差幅度降低了 7.2%。

图 11 中, 在 50、125 和 225 等高峰样本点, 各模型表现差异明显。BiGRU 能预测趋势, 但峰值精度差, 刻画复杂特征能力有限。CNN-BiGRU 较 BiGRU 更接近实际峰值, 不过仍有波动, 稳定性欠佳。CNN-BiGRU-MHA 结合了 MHA 机制, 提升了预测精度, 但细微处预测性能有待进一步提升。NRBO-CNN-BiGRU-MHA 模型的预测性能最佳, 峰值高度和趋势与实际值高度吻合, 面对高峰工况的适应性和稳定性强。在 100、200 等低谷样本点, BiGRU 预测值波动大、偏差明显, 处理平缓特征能力弱。CNN-BiGRU 表现有所改善, 但低谷位置的预测精度欠佳。CNN-BiGRU-MHA 挖掘更深入, 但部分低谷点的预测结果仍有一定偏差。NRBO-CNN-BiGRU-MHA 表现优异, 精准把握低谷特征, 在平缓区也保持了高精度, 鲁棒性强。

为更加直观地评价各模型的预测性能, 本文采用样本点的相对误差作为衡量指标, 不同模型在负荷预测中的相对误差分布如图 12 所示。

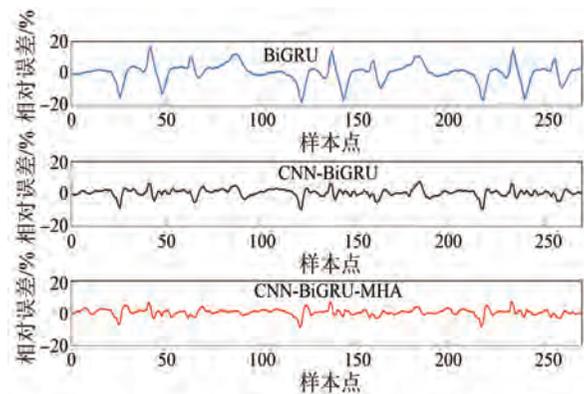


图 12 不同模型在负荷预测中的相对误差分布

Fig. 12 Relative error distribution of different models in load power forecasting

由图 12 可知, BiGRU 模型的误差波动较为剧烈, 在部分样本点处误差接近  $\pm 20\%$ , 显示出其在复杂负荷数据预测上的泛化能力相对不足。CNN-BiGRU 模型通过引入卷积结构, 对原始输入特征进行了更有效的提取, 误差幅度明显减小, 波动范围总体控制在  $\pm 10\%$  以内。CNN-BiGRU-

MHA 模型在误差波动方面表现出显著的优势, 其绝大多数样本点的误差稳定在  $\pm 5\%$  以内, 且误差曲线更加平滑。

在 250 个样本点中, BiGRU、CNN-BiGRU 和 CNN-BiGRU-MHA 的平均相对误差分别为 8.92%、4.76% 和 2.31%。CNN-BiGRU-MHA 相较于 CNN-BiGRU 和 BiGRU 的相对误差降低了 51.5% 和 74.1%, 证明了其在复杂负荷数据预测中的优越性。

本文模型、BiLSTM-Attention 模型预测值与真实值的对比情况如图 13 所示。

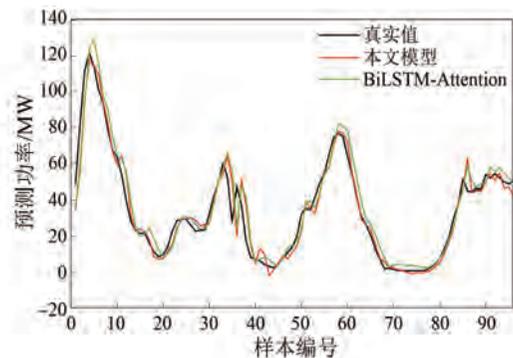


图 13 本文模型与 BiLSTM-Attention 模型对比

Fig. 13 Comparison between the proposed model and the BiLSTM-Attention model

由图 13 可知, 两种模型均能在一定程度上反映数据的波动变化, 但本文模型展现出显著优越性。在多个峰值与谷值处, 本文模型的预测值与真实值更为贴近。从误差角度定量分析, 本文模型在整个样本区间内, 与真实值的偏离程度整体小于 BiLSTM-Attention 模型。这意味着在处理该预测任务时, 本文模型能够更精准地把握数据特征, 有效降低预测误差, 其预测结果具有更高的可信度和准确性。

## 4 结语

本文提出了一种基于 NRBO-CNN-BiGRU-MHA 的分布式智能配电网源荷功率超短期预测模型, 通过理论分析、仿真试验及对比验证, 肯定了所提预测模型的有效性与适应性。主要结论如下。

(1) 所提 NRBO-CNN-BiGRU-MHA 预测模型在 MAE、MAPE、MSE、RMSE 和  $R^2$  多项指标上均优于其他对比模型, 误差可稳定在  $\pm 5\%$  以内, 其在处理风电、光伏功率预测等复杂非线性时序问题

上具有更高的适应性。

(2) 所提模型通过优化参数设置、强化特征提取能力并提升对复杂时序数据的建模能力,证明了其在复杂负荷数据预测中的优越性。

### 利益冲突声明

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

### 作者贡献

曹玉媛、陈磊进行了方案设计、内容总结与论文撰写,黄达文、李丰、李必伟进行了试验研究,杨满、李逸飞、陈红坤参与了论文的审核与修改。所有作者均阅读并同意了最终稿件的提交。

The scheme design, content summary and paper writing were carried out by Cao Yuyuan and Chen Lei. The experiment was conducted by Huang Dawen, Li Feng and Li Biwei. The manuscript was revised by Yang Man, Li Yifei and Chen Hongkun. All authors have read and approved the final version of the paper for submission.

### 参考文献

- [ 1 ] 王艺博,刘红丹,周忠旭,等. 新兴市场背景下考虑高铁配储的日前-日内两阶段优化策略[J/OL]. 电力自动化设备, 2025-4-13. <https://doi.org/10.16081/j.epae.202503017>.
- WANG Y B, LIU H D, ZHOU Z X, et al. Day-ahead and intra-day two-stage optimization strategy considering high speed rail with energy storage in context of emerging markets [J/OL]. Electric Power Automation Equipment, 2025-4-13. <https://doi.org/10.16081/j.epae.202503017>.
- [ 2 ] 祁琪,石富岭,陈宋宋,等. 居民负荷参与电力系统调控关键技术综述与展望[J]. 电网技术, 2024, 48(2): 809-818.
- QI Q, SHI F L, CHEN S S, et al. Review and prospect of key technologies for residential loads participating in power system dispatch and control [J]. Power System Technology, 2024, 48(2): 809-818.
- [ 3 ] 董存,王铮,白捷予,等. 光伏发电功率超短期预测方法综述[J]. 高电压技术, 2023, 49(7):

2938-2951.

DONG C, WANG Z, BAI J Y. et al. Review of ultra-short-term forecasting methods for photovoltaic power generation [J]. High Voltage Engineering, 2023, 49(7): 2938-2951.

[ 4 ] DAI X R, LIU G P, HU W S. An online-learning-enabled self-attention-based model for ultra-short-term wind power forecasting [J]. Energy, 2023, 272: 127173.

[ 5 ] 曹美禾,宋琳,孙军,等. 深度学习及其在电机控制中的研究现状与展望[J]. 电机与控制应用, 2023, 50(5): 1-9.

CAO M H, SONG L, SUN J, et al. Research and prospect on deep learning and its application in motor control [J]. Electric Machines & Control Application, 2023, 50(5): 1-9.

[ 6 ] ALI A, SHAABAN M F, MAHMOUD K. Optimizing hydrogen systems and demand response for enhanced integration of RES and EVs in smart grids [J]. IEEE Transactions on Smart Grid, 2025, 16(2): 1366-1378.

[ 7 ] 魏泓屹,卓振宇,张宁,等. 中国电力系统碳达峰·碳中和转型路径优化与影响因素分析[J]. 电力系统自动化, 2022, 46(19): 1-12.

WEI H Y, ZHUO Z Y, ZHANG N, et al. Transition path optimization and influencing factor analysis of carbon emission peak and carbon neutrality for power system of China [J]. Automation of Electric Power Systems, 2022, 46(19): 1-12.

[ 8 ] 李大中,李颖宇. 基于深度学习与误差修正的超短期风电功率预测[J]. 太阳能学报, 2021, 42(12): 200-205.

LI D Z, LI Y Y. Ultra-short term wind power prediction based on deep learning and error correction [J]. Acta Energetica Solaris Sinica, 2021, 42(12): 200-205.

[ 9 ] 张勇军,羿应棋,李立涅,等. 双碳目标驱动的新型低压配电系统技术展望[J]. 电力系统自动化, 2022, 46(22): 1-12.

ZHANG Y J, YI Y Q, LI L C, et al. Prospect of new low-voltage distribution system technology driven by carbon emission peak and carbon neutrality targets [J]. Automation of Electric Power Systems, 2022, 46(22): 1-12.

[ 10 ] 周勇良,余光正,刘建锋,等. 基于改进长期循环卷积神经网络的海上风电功率预测[J]. 电力系

- 统自动化, 2021, 45(3): 183-191.
- ZHOU Y L, YU G Z, LIU J F, et al. Offshore wind power prediction based on improved long-term recurrent convolutional neural network [J]. Automation of Electric Power Systems, 2021, 45(3): 183-191.
- [11] 朱江, 汪帆, 曹春堂, 等. 基于 KLPP-K-means-BiLSTM 的台区短期电力负荷预测[J]. 电机与控制应用, 2024, 51(3): 108-115.
- ZHU J, WANG F, CAO C T, et al. KLPP-K-means-BiLSTM based short-term power load forecasting for station areas [J]. Electric Machines & Control Application, 2024, 51(3): 108-115.
- [12] 李青, 张新燕, 马天娇, 等. 基于 SSA-CNN-BiGRU-Attention 的超短期风电功率预测模型[J]. 电机与控制应用, 2023, 50(5): 61-71.
- LI Q, ZHANG X Y, MA T J, et al. Ultra-short term forecasting model of wind power based on SSA-CNN BiGRU-Attention [J]. Electric Machines & Control Application, 2023, 50(5): 61-71.
- [13] 陈臣鹏, 赵鑫, 毕贵红, 等. 基于 Kmeans-VMD-LSTM 的短期风速预测[J]. 电机与控制应用, 2021, 48(12): 85-93.
- CHEN C P, ZHAO X, BI G H, et al. Short-term wind speed prediction based on Kmeans-VMD-LSTM [J]. Electric Machines & Control Application, 2021, 48(12): 85-93.
- [14] 徐萌. 基于 MA-SVM 方法的短期光伏功率预测[J]. 电机与控制应用, 2022, 49(7): 104-111.
- XU M. Short-term photovoltaic power prediction based on MA-SVM method [J]. Electric Machines & Control Application, 2022, 49(7): 104-111.
- [15] 郑乐, 徐青山, 冯小峰. 基于层次聚类算法与 ISA-LSSVM 的短期负荷预测研究[J]. 电力需求侧管理, 2022, 24(5): 51-57.
- ZHENG L, XU Q S, FENG X F. Short-term load forecasting based on hierarchical clustering algorithm and ISA-LSSVM [J]. Power Demand Side Management, 2022, 24(5): 51-57.
- [16] 杨龙, 吴红斌, 丁明, 等. 新能源电网中考虑特征选择的 Bi-LSTM 网络短期负荷预测[J]. 电力系统自动化, 2021, 45(3): 166-173.
- YANG L, WU H B, DING M, et al. Short-term load forecasting in renewable energy grid based on bi-directional long short-term memory network considering feature selection [J]. Automation of Electric Power Systems, 2021, 45(3): 166-173.
- [17] 王莲, 简子淋, 张晓斌, 等. 基于 CNN-BiLSTM 和多目标函数优化的省级光伏日内保障出力预测[J/OL]. 高电压技术, 2025-4-13. <https://doi.org/10.13336/j.1003-6520.hve.20241185>.
- WANG L, JIAN Z L, ZHANG X B, et al. Intra-day guaranteed power output forecasting for provincial PV systems based on CNN-BiLSTM and multi-objective function optimization [J/OL]. High Voltage Engineering, 2025-4-13. <https://doi.org/10.13336/j.1003-6520.hve.20241185>.
- [18] WEI J Q, WU X J, YANG T M, et al. Ultra-short-term forecasting of wind power based on multi-task learning and LSTM [J]. International Journal of Electrical Power & Energy Systems, 2023, 149: 109073.
- [19] 杨子民, 彭小圣, 郎建勋, 等. 基于集群动态划分与 BLSTM 深度学习的风电集群短期功率预测[J]. 高电压技术, 2021, 47(4): 1195-1203.
- YANG Z M, PENG X S, LANG J X, et al. Short-term wind power prediction based on dynamic cluster division and BLSTM deep learning method [J]. High Voltage Engineering, 2021, 47(4): 1195-1203.
- [20] COUTO A, ESTANQUEIRO A. Enhancing wind power forecast accuracy using the weather research and forecasting numerical model-based features and artificial neuronal networks [J]. Renewable Energy, 2022, 201(1): 1076-1085.
- [21] 董雪, 赵宏伟, 赵生校, 等. 基于 SOM 聚类 and 二次分解的 BiGRU 超短期光伏功率预测[J]. 太阳能学报, 2022, 43(11): 85-93.
- DONG X, ZHAO H W, ZHAO S X, et al. Ultra-short-term forecasting method of photovoltaic power based on SOM clustering, secondary decomposition and BiGRU [J]. Acta Energetica Solaris Sinica, 2022, 43(11): 85-93.
- [22] 陈巨龙, 李震, 朱永清, 等. 基于深度神经网络的斜坡式重力储能系统质量块抓取装置控制方法[J]. 电机与控制应用, 2023, 50(11): 37-45.
- CHEN J L, LI Z, ZHU Y Q, et al. Control method of mass block grasping device of slope gravity energy storage system based on deep neural network [J]. Electric Machines & Control Application, 2023, 50(11): 37-45.
- [23] 徐艳, 周建勋, 金鑫, 等. 基于 KPCA-K-means-GRU 的短期风电功率预测研究[J]. 电机与控制

- 应用, 2023, 50(2): 49-55.
- XU Y, ZHOU J X, JIN X, et al. Study on short-term wind power prediction based on KPCA-K-means-GRU [J]. *Electric Machines & Control Application*, 2023, 50(2): 49-55.
- [24] CHEN P, DENG Y M, ZHANG X G, et al. Degradation trend prediction of pumped storage unit based on MIC-LGBM and VMD-GRU combined model [J]. *Energies*, 2022, 15(2): 605-625.
- [25] WANG Y, BENNANI I L, LIU X F, et al. Electricity consumer characteristics identification: A federated learning approach [J]. *IEEE Transactions on Smart Grid*, 2021, 12(4): 3637-3647.
- [26] XIAO Y L, ZOU C Z, CHI H T, et al. Boosted GRU model for short-term forecasting of wind power with feature weighted principal component analysis [J]. *Energy*, 2023, 267: 126503.
- [27] SIMEUNOVIC J, SCHUBNEL B, ALET P J, et al. Spatio-temporal graph neural networks for multi-site PV power forecasting [J]. *IEEE Transactions on Sustainable Energy*, 2022, 13(2): 1210-1220.
- [28] 欧阳福莲, 王俊, 周杭霞. 基于改进迁移学习和多尺度 CNN-BiLSTM-Attention 的短期电力负荷预测方法[J]. *电力系统保护与控制*, 2023, 51(2): 132-140.
- OUYANG F L, WANG J, ZHOU H X. Short-term power load forecasting method based on improved hierarchical transfer learning and multi-scale CNN-BiLSTM-Attention [J]. *Power System Protection and Control*, 2023, 51(2): 132-140.
- [29] SOWMYA R, PREMKUMAR M, JANGIR P. Newton-Raphson-based optimizer: A new population-based metaheuristic algorithm for continuous optimization problems [J]. *Engineering Applications of Artificial Intelligence*, 2024, 128: 107532.
- [30] LI B, WANG P Q. A nonlinear inversion method for reservoir fluid factors based on OBN seismic data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5905113.
- [31] SU T, TAN M, THE J. Short-term transmission capacity prediction of hybrid renewable energy systems considering dynamic line rating based on data-driven model [J]. *IEEE Transactions on Industry Applications*, 2025, 61(2): 2410-2420.
- 
- 收稿日期:2025-04-14  
收到修改稿日期:2025-05-19  
作者简介:  
曹玉媛(1994-),女,硕士,助理工程师,研究方向为有源配电网新能源消纳,851515214@qq.com;  
\*通信作者:陈磊(1982-),男,博士,副教授,研究方向为新能源电力系统稳定控制,chen\_lei@whu.edu.cn.