

DOI: 10.19783/j.cnki.pspc.230914

## 融合深度误差反馈学习和注意力机制的短期风电功率预测

胡宇晗, 朱利鹏, 李佳勇, 李杨, 曾杨, 郑李梦千, 帅智康

(湖南大学电气与信息工程学院, 湖南 长沙 410082)

**摘要:** 为提高风电功率预测精度, 提出了一种有机融合深度反馈学习与注意力机制的短期风电功率预测方法。首先, 以风电场数值天气预报(numerical weather prediction, NWP)为原始输入, 基于双层长短期记忆网络(long short-term memory, LSTM)模型对风电功率进行初步预测。其次, 利用极端梯度提升(eXtreme gradient boosting, XGBoost)算法构建误差估计模型, 以便在给定未来一段时间内 NWP 数据的情况下对初步预测误差进行快速估计。然后, 利用自适应白噪声完备集成经验模态分解法(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)将初步预测误差分解为不同频段的误差序列, 并将其作为附加性反馈输入, 对风电功率进行二次预测。进一步在二次预测模型中引入注意力机制, 为风电功率预测序列与误差序列动态分配权重, 由此引导预测模型在学习过程中充分挖掘学习与误差相关的关键特征。最后, 仿真结果表明所提方法可显著提高短期风电功率预测的可靠性。

**关键词:** 风电功率预测; 深度学习; 反馈学习; 长短时记忆单元; 注意力机制

### Short-term wind power forecasting with the integration of a deep error feedback learning and attention mechanism

HU Yuhang, ZHU Lipeng, LI Jiayong, LI Yang, ZENG Yang, ZHENG Limengqian, SHUAI Zhikang  
(College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

**Abstract:** To enhance the accuracy of wind power forecasting, a short-term wind power forecasting method is proposed, one that synergistically integrates deep feedback learning with attention mechanisms. First, the historical data of numerical weather prediction (NWP) from the wind farm is taken as the original input. A dual-layer long short-term memory (LSTM)-based learning model is used for the preliminary prediction of wind power. Next, an error estimation model is established based on an extreme gradient boosting (XGBoost) algorithm. This enables fast estimation of the initial prediction errors given the future NWP data. Then, complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) is used to decompose the initial prediction errors into error sequences of different frequency bands. These serve as an additional feedback input for the secondary prediction of wind power. Also, an attention mechanism is introduced into the secondary prediction model to dynamically allocate weights to the wind power forecasting and error sequences and thereby instructing the prediction model to fully mine and learn the key features related to the prediction errors during the learning process. Finally, the simulation results indicate that the proposed method can remarkably enhance the reliability of short-term wind power forecasting.

This work is supported by the National Natural Science Foundation of China (No. 52207094 and No. 52377095).

**Key words:** wind power forecasting; deep learning; feedback learning; LSTM; attention mechanism

## 0 引言

风能具有分布范围广、清洁、可再生等优势, 在过去几十年内, 我国风电产业迅猛发展, 累计

并网装机容量已跃居世界首位<sup>[1-3]</sup>。然而, 由于风力发电存在突出的间歇性、波动性和不确定性, 其大规模并网给电力系统的安全可靠运行带来严峻挑战<sup>[4-6]</sup>。风电功率的高效、可靠预测, 将能有效降低风电场输出功率的不确定性, 为大规模风电接入后电力系统的安全稳定运行提供重要支撑和保障<sup>[7-9]</sup>。

近年来, 国内外学者对风电功率预测进行了广

**基金项目:** 国家自然科学基金项目资助(52207094, 52377095)  
博士后创新型人才计划项目资助(BX20220100)

泛的研究。按照预测模型划分, 目前的风电功率预测方法可分为物理建模法和统计分析法<sup>[10-11]</sup>。物理建模法一般基于风电场的地形、地貌、天气等空气动力学因素, 建立流体力学模型, 模拟风资源分布及风能到输出功率的转化过程。然而, 由于风电场周围的地形、地貌、天气等因素复杂多变, 其流体力学模型难以精确描述。另外, 这类物理建模法计算过程复杂, 在实际电网中计算效率低下, 难以满足短期风电功率实时预测需求<sup>[12]</sup>。统计分析法包括差分自回归移动平均<sup>[13-16]</sup>、卡尔曼滤波<sup>[17]</sup>、支持向量机(support vector machine, SVM)<sup>[18-21]</sup>、马尔可夫<sup>[22]</sup>、神经网络<sup>[23-28]</sup>等数据分析和机器学习方法, 通过建立输入数据与输出数据之间的映射关系来实现风电功率预测。这类方法不受物理模型复杂度的制约, 预测模型训练完成后, 其在线计算效率相对较高, 因此更适用于实际的短期风电功率预测。

目前, 基于统计分析法的风电功率预测已取得较大突破。文献[20]基于经验模态分解将气象数据分解为多个分量, 并基于 SVM 对各分量建立风电功率预测模型, 将各分量的预测结果进行叠加得到最终的预测结果。文献[26]首先对气象数据和风电功率序列进行小波分解, 在此基础上利用多个反向传播(back propagation, BP)网络对各分量进行预测, 最后基于小波逆变换导出风电功率预测结果。文献[27]首先对风电功率与气象数据进行相关性分析, 随后建立双层长短期记忆网络(long short-term memory, LSTM)的预测模型, 对短期风电功率进行预测。文献[28]提出一种基于双向长短期记忆网络(long short-term memory, LSTM)的风电功率预测方法, 并引入时间注意力机制, 以提升 LSTM 对关键时序信息的提取能力。文献[21]基于最小二乘支持向量机

和极端学习机建立组合预测模型, 对风电功率进行预测。事实上, 风电功率的预测结果中不可避免地存在预测误差, 若能充分挖掘和学习误差中潜藏的有用信息, 将有望进一步提高风电功率预测精度。然而, 上述研究<sup>[20-21,26-28]</sup>均试图通过直接改进预测模型本身来提高预测精度, 而未挖掘预测误差对于改善预测性能的潜在价值, 其预测结果面临无法进一步提升的瓶颈。

针对上述瓶颈, 本文提出融合深度误差反馈学习和注意力机制的短期风电功率预测方法。该方法以表达能力更强的深度学习方法为基础, 首先利用双层 LSTM 对风电功率进行初步预测, 随后将预测结果所产生的误差作为附加性反馈输入构建二次预测模型, 以提升预测精度。考虑到单纯基于原始误差信息对预测结果进行修正, 其所带来的预测精度提升效果有限, 本文在模型中进一步加入自适应白噪声完备集成经验模态分解法(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)和注意力机制, 充分计及不同频段的误差分量对预测结果影响程度的差异, 挖掘和提取预测误差中的有用信息来优化和调整预测学习过程, 从而实现风电功率预测精度的显著提升。

## 1 短期风电功率预测总体框架

本文所提的融合深度误差反馈学习和注意力机制的短期风电功率预测方法整体框架如图 1 所示。该方法的实施主要分为以下两个阶段。

1) 基于 LSTM 和 XGBoost 的初步预测学习, 具体包含以下两个模块。

模块 1: 基于双层 LSTM 的风电功率初步预测。将描述气象预测结果的数值天气预报(numerical

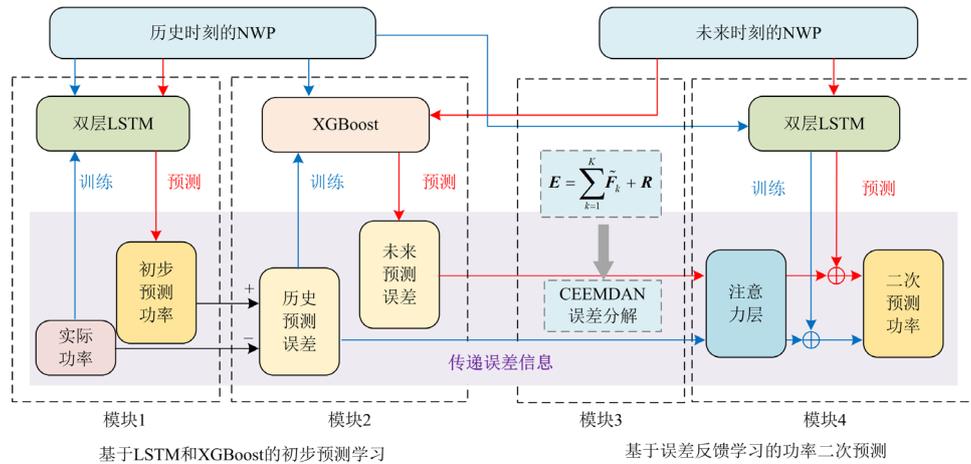


图 1 融合深度误差反馈学习和注意力机制的短期风电功率预测框架

Fig. 1 Short-term wind power forecasting framework with the integration of deep error feedback learning and attention mechanism

weather prediction, NWP)作为双层 LSTM 的输入, 风电功率作为模型输出, 对风电功率进行初步预测。

模块 2: 基于 XGBoost 的风电功率预测误差估计。选择 NWP 数据作为 XGBoost 的模型输入, 风电功率预测误差作为模型输出, 对未来一段时间的风电功率预测误差进行快速估算。

2) 基于误差反馈学习的功率二次预测, 具体包含以下两个模块。

模块 3: 基于 CEEMDAN 的风电预测误差分解。利用 CEEMDAN 分别对历史和未来一段时间的风电功率预测误差按不同频段进行分解, 获得其对应误差分解序列。

模块 4: 基于注意力机制与误差反馈的功率二次预测。将上述误差分解序列作为风电功率预测的附加性输入, 在此基础上引入注意力机制为风电功率预测序列与误差序列动态分配权重, 进而构建融合误差反馈学习和注意力机制的风电功率二次预测模型。

## 2 基于 LSTM 和 XGBoost 的初步预测学习

### 2.1 基于双层 LSTM 的风电功率初步预测

LSTM 模型是一种擅长从时序数据中自主挖掘的递归神经网络。该模型可以充分体现风电出力与气象特征在时序上的对应关系。如图 2 所示, 本文基于双层 LSTM 模型对风电功率进行初步预测, 其网络架构主要包括输入层、LSTM 层、全连接层和输出层。

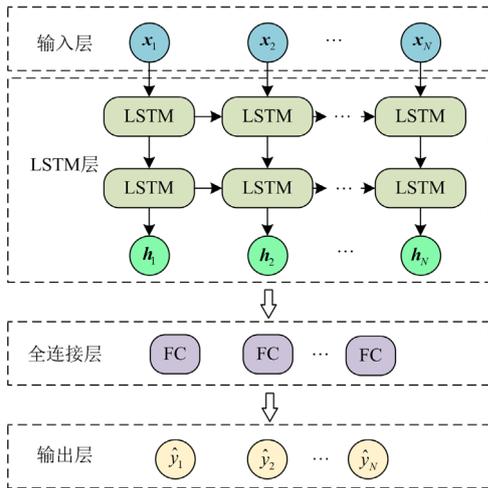


图 2 双层 LSTM 结构图

Fig. 2 Dual-layer LSTM structure

将包含风速、风向气温、气压等特征的 NWP 数据作为模型输入, 假定 NWP 数据包含  $N$  个观测点, 将第  $i$  个观测点的 NWP 数据记为  $\mathbf{x}_i (i \in I)$ , 其

中  $I$  为时间序列  $I=1,2,\dots,N$ 。经过双层 LSTM 提取输入信息中隐藏的时序关联信息, 得到中间输出  $\mathbf{h}_i (i \in I)$ , 最后将  $\mathbf{h}_i$  输入到全连接层, 得到风电初步预测功率  $\hat{y}_i$ 。

为进一步提高预测精度, 本文将会在后续模块中基于误差序列进行二次预测。

### 2.2 基于 XGBoost 的风电功率误差估计

在基于图 2 对风电功率进行初步预测时, 不可避免地存在预测误差, 由于预测误差反映了模型训练时的不足, 因此可以在后续二次预测的过程中引入这部分误差, 以弥补初步预测时的缺陷, 从而达到进一步提高预测精度的目的。

若风电场的实际出力为  $y_i$ , 则初步预测误差序列  $\mathbf{E}=[e_1, e_2, \dots, e_i, \dots, e_N]$  中的  $e_i$  可表示为

$$e_i = \hat{y}_i - y_i \quad (1)$$

由于在后续误差反馈模块中, 需要基于预测误差对风电功率进行二次预测, 因此本文基于 XGBoost 并结合历史 NWP 数据与历史预测误差建立误差估计模型, 以充分提取预测误差与 NWP 数据间的映射关系, 并基于当前时刻的 NWP 数据对未来的预测误差进行估计, 为后续的误差反馈环节进行铺垫。将风电功率初步预测的输入数据  $\mathbf{x}_i$  作为 XGBoost 模型的输入, 风电功率预测误差  $e_i$  作为模型的输出, 训练得到基于 XGBoost 的风电功率误差估计模型, 如式(2)所示。

$$\hat{e}_i = \sum_{l=1}^L f_l(\mathbf{x}_i), f_l \in F \quad (2)$$

式中:  $\hat{e}_i$  为初步预测误差  $e_i$  的估计值;  $f_l(\cdot)$  为第  $l$  棵树的估计值;  $L$  为树的数量;  $F$  为回归树空间。

在每次迭代中, XGBoost 模型会生成一棵新树用于拟合前一棵树的残差, 则第  $t$  次迭代时  $e_i$  的估计值  $\hat{e}_i^{(t)}$  为

$$\hat{e}_i^{(t)} = f_t(\mathbf{x}_i) + \hat{e}_i^{(t-1)} \quad (3)$$

因此, XGBoost 的优化目标函数  $f_{\text{obj}}$  可表示为

$$f_{\text{obj}} = \sum_{i=1}^N l_{\text{oss}}(e_i, \hat{e}_i^{(t-1)} + f_t(\mathbf{x}_i)) + o(f_t) \quad (4)$$

式中:  $l_{\text{oss}}(\cdot)$  为损失函数;  $o$  为控制模型复杂程度的正则项;  $f_t$  为模型的复杂程度。

## 3 基于误差反馈学习的功率二次预测

### 3.1 基于 CEEMDAN 的风电预测误差分解

为进一步提高后续二次预测的精度, 本文通过 CEEMDAN 对误差序列分解, 充分提取不同频段的误差信息。CEEMDAN 以经验模态分解(empirical

mode decomposition, EMD)为基础, 通过自适应添加白噪声使其分解结果更加准确, 其误差分解的流程如图3所示。

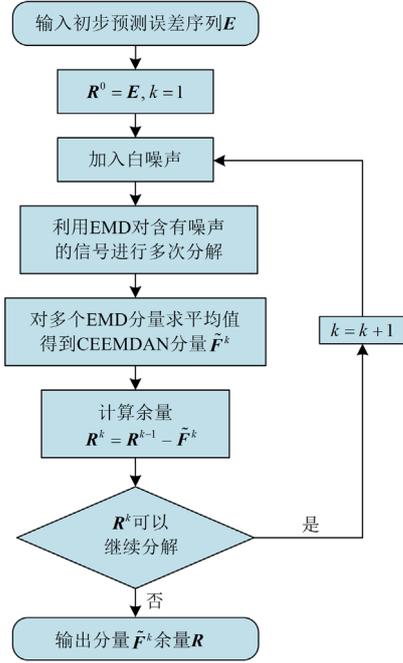


图3 基于 CEEMDAN 的风电预测误差分解的流程图

Fig. 3 Flowchart of wind power prediction error decomposition based on CEEMDAN

定义  $EMD_{\mu}(\cdot)$  为 EMD 分解后获得的第  $\mu$  个误差分解序列;  $\Omega_m (m=1, 2, \dots, M)$  为白噪声;  $\varepsilon_k (k=0, 1, \dots, K)$  为自适应系数, 基于 CEEMDAN 的误差分解过程如下。

步骤 1: 对初步预测误差序列  $E$  多次添加白噪声, 并进行  $M$  次 EMD, 则误差序列的第 1 个分解序列  $\tilde{F}^1 = [f_1^1, f_2^1, \dots, f_N^1]$  如式(5)所示。

$$\tilde{F}^1 = \frac{1}{M} \sum_{m=1}^M EMD_1(E + \varepsilon_0 \Omega_m) \quad (5)$$

步骤 2: 当  $k=1$  时, 计算第一个误差分解序列的余量  $R^1$  如式(6)所示。

$$R^1 = E - \tilde{F}^1 \quad (6)$$

步骤 3: 对  $R^1 + \varepsilon_1 EMD_k(\Omega_m)$  进行  $M$  次 EMD。第 2 个误差分解序列  $\tilde{F}^2 = [f_1^2, f_2^2, \dots, f_N^2]$ , 如式(7)所示。

$$\tilde{F}^2 = \frac{1}{M} \sum_{m=1}^M EMD_1[R^1 + \varepsilon_1 EMD_1(\Omega_m)] \quad (7)$$

步骤 4: 当  $k=2, 3, \dots, K$  时, 计算第  $k$  个余量  $R^k$  与第  $k+1$  个分解序列  $\tilde{F}^{k+1}$ , 如式(8)和式(9)所示。

$$R^k = R^{k-1} - \tilde{F}^k \quad (8)$$

$$\tilde{F}^{k+1} = \frac{1}{M} \sum_{m=1}^M EMD_1[R^k + \varepsilon_k EMD_k(\Omega_m)] \quad (9)$$

步骤 5: 直到余量误差无法继续分解时停止迭代, 则最终余量  $R = [r_1, r_2, \dots, r_N]$  如式(10)所示。

$$R = E - \sum_{k=1}^K \tilde{F}^k \quad (10)$$

最终, 预测误差  $E$  的分解序列组成的矩阵  $\tilde{E}$  可以表示如式(11)所示。

$$\tilde{E} = \begin{bmatrix} \tilde{F}^1 \\ \tilde{F}^2 \\ \vdots \\ \tilde{F}^k \\ R \end{bmatrix} = \begin{bmatrix} f_1^1, f_2^1, \dots, f_N^1 \\ f_1^2, f_2^2, \dots, f_N^2 \\ \vdots \\ f_1^k, f_2^k, \dots, f_N^k \\ r_1, r_2, \dots, r_N \end{bmatrix} \quad (11)$$

### 3.2 基于注意力机制与误差反馈的功率二次预测

为充分利用初步预测结果中的误差信息来指导和优化模型训练, 减小风电功率预测误差, 本文在 NWP 输入数据的基础上将基于 CEEMDAN 获得的误差分解序列作为附加性反馈输入, 构建包含两类输入、单类输出的风电功率二次预测模型。在风电功率二次预测中, 通过引入上述误差分解序列来引导预测模型有针对性地改进其学习过程中存在的缺陷和不足, 从而进一步提高预测精度。

基于注意力机制与误差反馈的功率二次预测模型主要由双层 LSTM 与注意力层两部分构成, 其结构如图4所示。本文在输入层后加入注意力层, 为不同频段的误差分解序列动态分配权重, 从而深度挖掘初步预测误差中的有效信息, 大幅提高网络模型的预测精度<sup>[29]</sup>。

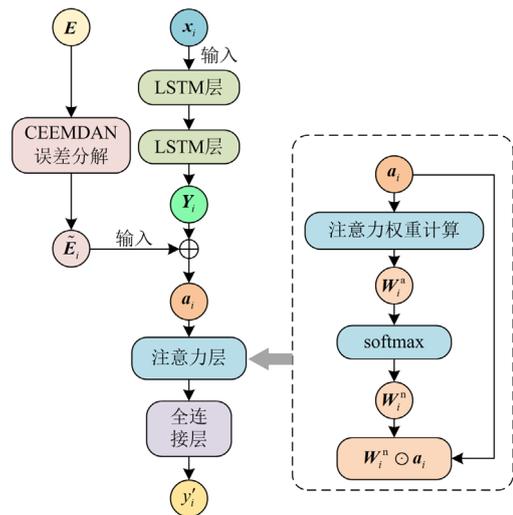


图4 基于注意力机制与误差反馈的功率二次预测结构图

Fig. 4 Structure of wind power secondary prediction based on attention mechanism and error feedback

在图 4 的模型中, 将式(11)中第  $i$  时刻误差分解结果记作  $\tilde{\mathbf{E}}_i = [f_i^1, f_i^2, \dots, f_i^k, r_i]^T$ , 双层 LSTM 输出的风电功率预测序列记为  $\mathbf{Y}_i = [y_i^1, y_i^2, \dots, y_i^H]$ , 其中  $H$  为第二层 LSTM 中神经元的个数, 并将二者的组合向量记为  $\mathbf{a}_i = [f_i^1, f_i^2, \dots, f_i^k, r_i, y_i^1, y_i^2, \dots, y_i^H]$ 。采用单层网络计算注意力权重, 如式(12)所示。

$$\mathbf{W}_i^a = \sigma(\mathbf{W}_i^w \mathbf{a}_i + \mathbf{b}^w) \quad (12)$$

式中:  $\mathbf{W}_i^a$  为组合向量的注意力权重系数序列,  $\mathbf{W}_i^a = [w_{i,1}^a, w_{i,2}^a, \dots, w_{i,k+H+1}^a]$ ;  $\sigma(\cdot)$  为激活函数;  $\mathbf{W}_i^w$  和  $\mathbf{b}^w$  分别为注意力层的权重矩阵和偏置向量。

基于 Softmax 函数对  $\mathbf{W}_i^a$  进行归一化处理, 归一化后的注意力权重  $\mathbf{W}_i^n = [w_{i,1}^n, w_{i,2}^n, \dots, w_{i,k+H+1}^n]$ , 则  $i$  时刻的第  $\kappa (1 \leq \kappa \leq k+H+1)$  个组合向量所对应的权重  $w_{i,\kappa}^n$  为

$$w_{i,\kappa}^n = \frac{\exp(w_{i,\kappa}^a)}{\sum_{\kappa=1}^K w_{i,\kappa}^a} \quad (13)$$

式中, 含有误差信息的组合向量  $\mathbf{a}_i$  经注意力层动态分配权重后记作  $\mathbf{E}'_i$ , 其计算表达式为

$$\mathbf{E}'_i = \mathbf{W}_i^n \odot \mathbf{a}_i = \begin{bmatrix} w_{i,1}^n f_i^1, w_{i,2}^n f_i^2, \dots, w_{i,k}^n f_i^k, w_{i,k+1}^n r_i, \\ w_{i,k+2}^n y_i^1, w_{i,k+3}^n y_i^2, \dots, w_{i,k+H+1}^n y_i^H \end{bmatrix} \quad (14)$$

式中, “ $\odot$ ” 为哈达玛积。

将  $\mathbf{E}'_i$  输入到全连接层中, 得到最终的风电功率二次预测结果  $y'_i$ 。

## 4 算例分析

为全面验证本文所提方法的有效性和优越性, 利用我国华中地区某实际风电场 2021 年 9 月到 2022 年 9 月的风电功率实测数据及相应的 NWP 数据进行算例分析, 其中风电场总装机容量为 95.5 MW, 时间分辨率为 15 min, 一天共计 96 组数据。

### 4.1 误差评价指标

为对基于误差反馈的风电功率预测模型进行评价, 本文采用绝对平均误差(mean absolute error, MAE)与均方根误差(root mean square error, RMSE)作为评价指标<sup>[30]</sup>, 误差评价指标的值越小代表模型预测精度越高, MAE 与 RMSE 的具体计算分别如式(15)和式(16)所示。

$$M_{AE} = \frac{1}{N_y} \sum_{\theta=1}^{N_y} |y_{\theta} - \hat{y}_{\theta}| \quad (15)$$

$$R_{MSE} = \sqrt{\frac{1}{N_y} \sum_{\theta=1}^{N_y} \frac{(y_{\theta} - \hat{y}_{\theta})^2}{C_{\theta}}} \quad (16)$$

式中:  $N_y$  为样本个数;  $\theta$  为计数变量;  $y_{\theta}$  为样本数据的真实值;  $\hat{y}_{\theta}$  为模型的预测值;  $C_{\theta}$  为开机总容量。

### 4.2 模型参数设置

在风电功率初步预测阶段, 设置第一层 LSTM 神经元个数为 256, 第二层 LSTM 神经元个数为 16, 激活函数为 Relu, 选择 Adam 优化器对模型进行训练, 设置学习率为 0.001, 迭代 400 次。在风电功率初步预测误差估计阶段, 其参数设置如表 1 所示。

表 1 XGBoost 参数设置

Table 1 XGBoost parameter settings	
参数	数值
迭代次数	100
树深度	10
学习率	0.1
下采样	0.8

此外, 为充分验证本文所提方法对初步预测环节精度的改善效果, 二次预测环节各参数均保持与初步预测环节相同。

### 4.3 预测结果对比

为验证本文所提方法的有效性, 本文选取 SVM、卷积神经网络(convolutional neural network, CNN)-门控循环单元(gate recurrent unit, GRU)、CNN-LSTM、初步预测(与本文方法相比未加入误差反馈、误差分解、注意力机制)、误差反馈(与本文方法相比加入误差反馈, 但未引入误差分解和注意力机制)作为本文所提方法的对照组。从每个季度随机抽取 2 作为典型日, 对不同方法的预测性能进行展示和对比分析, 具体评价结果如表 2 所示。

由表 2 可知, 在全部典型日中, 本文所提方法相较于与其他对照组(其中 CNN-LSTM、与 CNN-GRU 均为混合模型), 其预测精度均能达到最高。此外, 基于误差反馈的学习方法在挖掘预测误差中蕴含的信息基础上, 在多数典型日下实现了精度更高的功率预测, 本文所提方法在误差反馈学习的基础上加入了误差分解与注意力机制, 将注意力集中于对风电场实际出力最相关的误差序列, 从而进一步改善风电功率的预测性能。因此本文所提方法尽管在预测过程中引入了预测误差, 但是在注意力机制对各误差序列的引导下, 本文所提方法相较于初步预测, 其预测精度存在显著提升。

表 2 典型日误差统计  
Table 2 Error statistics on typical days

典型日	本文方法		误差反馈		初步预测		CNN-LSTM		CNN-GRU		SVM	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
1	2.30	3.66	3.19	4.69	2.50	4.07	2.44	3.94	2.50	3.99	3.06	4.09
2	1.12	1.74	1.84	2.44	2.52	3.14	1.82	2.55	2.94	4.08	2.74	3.20
3	1.35	2.41	1.54	2.72	1.38	2.45	1.82	2.85	2.21	3.13	3.60	4.83
4	2.16	3.04	2.50	3.51	2.91	4.59	3.86	4.96	4.24	6.15	6.73	8.51
5	1.74	2.50	1.86	2.76	2.00	2.81	1.99	2.61	2.21	3.05	2.34	2.89
6	2.02	2.79	2.63	4.17	3.10	4.53	2.96	4.18	3.56	4.91	5.34	6.22
7	2.58	3.71	2.58	3.65	4.43	6.98	5.23	7.73	4.12	6.55	6.70	8.29
8	1.70	2.52	2.06	2.94	2.15	3.24	2.48	3.66	2.83	3.85	3.20	3.97

为更加直观地展示不同方法的预测效果, 以典型日 1 为例, 图 5 给出上述 6 种方法的预测曲线。整体而言, 本文所提方法得到的预测功率曲线相比于其他方法更贴近风电场真实出力, 其预测偏差在不同时间点均维持在较低的水平。

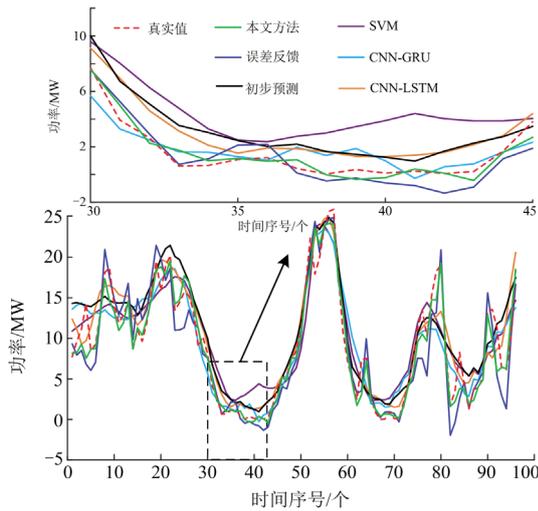


图 5 典型日 1 预测结果

Fig. 5 Prediction results on typical day 1

为进一步统计分析该典型日下不同方法的预测误差水平, 图 6(a)~图 6(f)分别展示了本文所提方法、误差反馈、初步预测、CNN-LSTM、CNN-GRU、SVM 的误差的分布情况。与其他方法相比, 本文所提方法得到的误差分布更加集中且接近于 0, 预测误差超过 65% 的样本占比小于 1%, 最大预测误差不超过 7%。因此, 相较于其他方法, 本文所提方法预测精度更高。

模型存储空间大小可以在一定程度体现模型的复杂度<sup>[31]</sup>。表 3 中展示了典型日 1 中本文方法、初步预测、CNN-LSTM 的预测时长与文件大小。

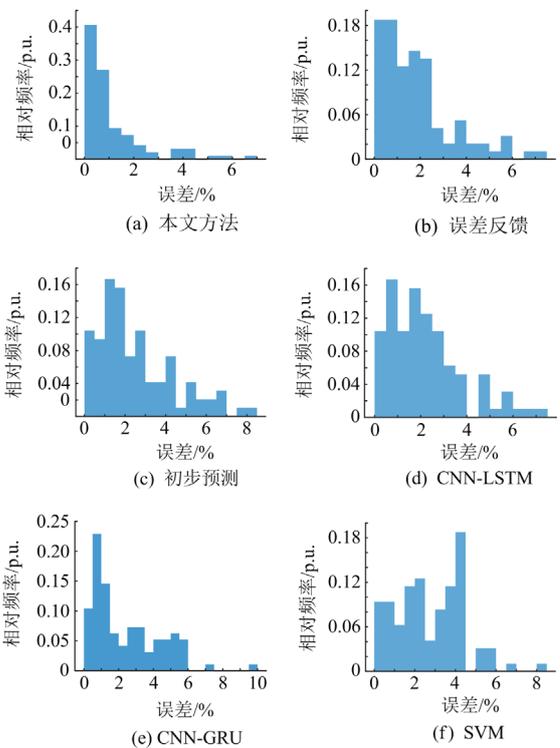


图 6 典型日 1 误差相对频率分布

Fig. 6 Error relative frequency distribution on typical day 1

表 3 模型复杂度与预测时长

Table 3 Model complexity and prediction duration

方法	存储空间/kB	预测时长/ms
本文方法	7647	151
初步预测	3813	71
CNN-LSTM	4792	97

基于表 3 结果进行分析, 本文所提方法的模型文件大小与预测时长相较于对比方法未出现显著增大, 因此本文所提方法并未显著增加模型的复杂度。

为了阐述注意力机制的作用机理, 本文分析误

差序列与风电场实际出力的相关系数以及其自身的注意力权重，如图 7 所示。

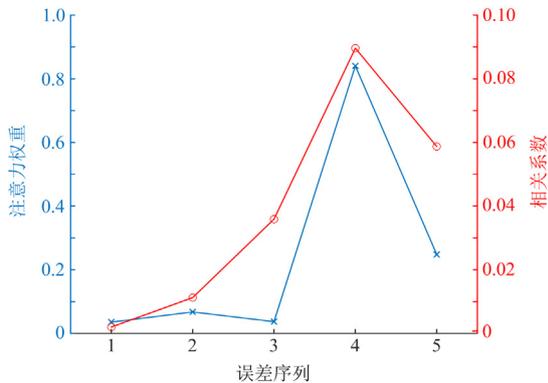


图 7 典型日 1 相关系数与注意力权重

Fig. 7 Correlation coefficient and attention weights of typical day 1

本文所提方法基于 CEEMDAN 将误差信息分解为 5 个序列，并基于注意力对其分配权重。由图 7 分析可知，本文所提方法的注意力权重和误差序列与风电场出力的相关系数具有相似的变化趋势，由此可以推断：在注意力机制的作用下，能够改善预测性能的误差序列被赋予了更高的权重。因此，本文所提方法可以将注意力集中于这些重要的误差序列，从而提升风电功率预测的精度。

为进一步验证本文所提方法的预测效果，在全年范围内对不同方法的平均预测精度进行统计。表 4 给出了本文所提方法、误差反馈方法、初步预测、CNN-LSTM 在全年的 MAE 与 RMSE。相较于初步预测模型，仅加入误差反馈的学习方法整体上小幅提升了预测精度，其 MAE 下降 0.20%，RMSE 下降 0.36%。本文方法在进一步加入误差分解与注意力机制后，其预测精度较初步预测有进一步提高，MAE 下降 0.62%，RMSE 下降 0.88%。

表 4 全年预测精度对比

Table 4 Comparison of annual prediction precision

方法	MAE	RMSE
本文方法	2.69	4.10
误差反馈	3.11	4.62
初步预测	3.31	4.98
CNN-LSTM	3.94	5.52

本文对全年不同季节的预测精度进行统计，结果分别如图 8、图 9 所示。

对比图 8、图 9 中初步预测与仅加入误差反馈的预测方法可以发现，在春季加入误差反馈后预测

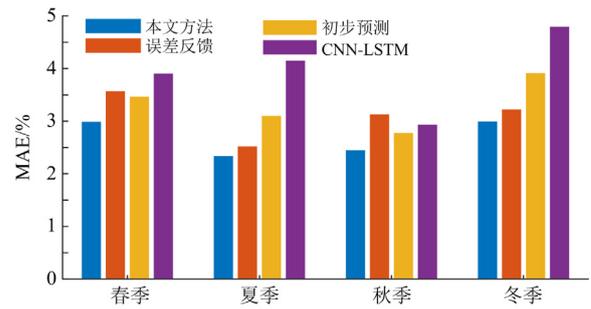


图 8 全年 MAE 统计

Fig. 8 Annual MAE statistics

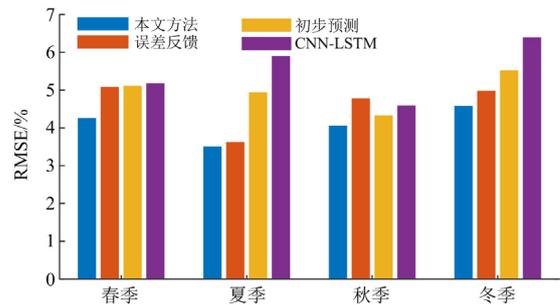


图 9 全年 RMSE 统计

Fig. 9 Annual RMSE statistics

精度没有明显变化，在夏季、冬季加入误差反馈后预测精度有明显提高，而在秋季加入误差反馈后预测精度反而有明显下降。这是因为仅加入误差反馈对误差序列学习不充分，直接对模型进行反馈训练无法稳固地实现全年各季度预测精度的全面提升。相比之下，本文所提方法进一步引入误差分解与注意力机制，为不同频段的误差分配权重，充分学习各误差中所蕴含的大量信息，使得其风电功率预测结果在全年不同季节的预测精度均能实现稳固提升。

## 5 结论

为提升风电功率预测精度，本文提出了一种融合深度误差反馈学习和注意力机制的短期风电功率预测方法。结合算例仿真并与多种传统预测方法对比，可得到以下结论。

1) 相比于传统的风电功率预测，加入误差反馈后的方法能够提升模型预测精度。

2) 在误差反馈模型中引入基于 CEEMDAN 的误差分解与注意力机制后，可以更加充分地学习误差中的信息。本文所提方法可稳固提高不同季节的风电预测精度，从而可靠地实现全年范围内预测性能的提升。

## 参考文献

- [1] 彭星皓, 李艳婷. 基于时空协方差函数的风能场景生成方法与应用[J]. 上海交通大学学报, 2023, 57(12): 1531-1542.  
PENG Xinghao, LI Yanting. Wind power scenario generation method and application based on spatiotemporal covariance function[J]. Journal of Shanghai Jiaotong University, 2023, 57(12): 1531-1542.
- [2] 鲁业安, 马玲, 张磊, 等. 计及火电机组热储能的含风电系统柔性调度[J]. 电力系统保护与控制, 2022, 50(23): 75-84.  
LU Anye, MA Ling, ZHANG Lei, et al. Flexible dispatch of a power system with wind power considering thermal energy storage retrofit of thermal power units[J]. Power System Protection and Control, 2022, 50(23): 75-84.
- [3] YAN C, TANG Y, DAI J, et al. Uncertainty modeling of wind power frequency regulation potential considering distributed characteristics of forecast errors[J]. Protection and Control of Modern Power Systems, 2021, 6(1): 276-288.
- [4] 余浩, 张哲萌, 彭穗, 等. 海上风电经柔性直流并网技术标准对比分析[J]. 上海交通大学学报, 2022, 56(4): 403-412.  
YU Hao, ZHANG Zhemeng, PENG Sui, et al. Comparative analysis of technical standards for offshore wind power via VSC-HVDC[J]. Journal of Shanghai Jiaotong University, 2022, 56(4): 403-412.
- [5] 刘晓明, 谭祖颀, 袁振华, 等. 柔性直流接入海上风电并网选址综合优化[J]. 发电技术, 2022, 43(6): 892-900.  
LIU Xiaoming, TAN Zukuang, YUAN Zhenhua, et al. Comprehensive optimization of access point selection for offshore wind farm integrated with voltage source converter high voltage direct current[J]. Power Generation Technology, 2022, 43(6): 892-900.
- [6] 涂思嘉, 杨悦荣, 林舜江, 等. 考虑风电不确定性的交直流混联电网静态电压稳定优化控制方法[J]. 电力科学与技术学报, 2023, 38(3): 94-104.  
TU Sijia, YANG Yuerong, LIN Shunjiang, et al. An optimal control method for static voltage stability of AC/DC hybrid power grid considering the uncertainty of wind power[J]. Journal of Electric Power Science and Technology, 2023, 38(3): 94-104.
- [7] 彭曙蓉, 彭家宜, 杨云皓, 等. 基于时变深度前馈神经网络的风电功率概率密度预测[J]. 电力科学与技术学报, 2023, 38(3): 84-93.  
PENG Shurong, PENG Jiayi, YANG Yunhao, et al. Wind power probability density prediction based on time-variant deep feed-forward neural network[J]. Journal of Electric Power Science and Technology, 2023, 38(3): 84-93.
- [8] 苏向敬, 宇海波, 符杨, 等. 基于 DALSTM 和联合分位数损失的海上风电功率概率预测[J]. 中国电力, 2023, 56(11): 10-19.  
SU Xiangjing, YU Haibo, FU Yang, et al. Probabilistic forecasting of offshore wind power based on dual-stage attentional LSTM and joint quantile loss function[J]. Electric Power, 2023, 56(11): 10-19.
- [9] 雷旭, 马鹏飞, 宋智帅, 等. 计及风电预测误差的柔性负荷日内调度模型[J]. 发电技术, 2022, 43(3): 485-491.  
LEI Xu, MA Pengfei, SONG Zhishuai, et al. A flexible intraday load dispatch model considering wind power prediction errors[J]. Power Generation Technology, 2022, 43(3): 485-491.
- [10] 冯双磊, 王伟胜, 刘纯, 等. 风电场功率预测物理方法研究[J]. 中国电机工程学报, 2010, 30(2): 1-6.  
FENG Shuanglei, WANG Weisheng, LIU Chun, et al. Study on the physical approach to wind power prediction[J]. Proceedings of the CSEE, 2010, 30(2): 1-6.
- [11] 牛东晓, 纪会争. 风电功率物理预测模型引入误差量化分析方法[J]. 电力系统自动化, 2020, 44(8): 57-67.  
NIU Dongxiao, JI Huizheng. Quantitative analysis method for errors introduced by physical prediction model of wind power[J]. Automation of Electric Power Systems, 2020, 44(8): 57-67.
- [12] 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 short-term prediction of wind farm power generation based on VMD-WSGRU[J]. Power System Technology, 2022, 46(3): 897-904.
- [13] CHEN P, PEDERSEN T, BAK-JENSEN B, et al. ARIMA-based time series model of stochastic wind power generation[J]. IEEE Transactions on Power Systems, 2010, 25(2): 667-676.
- [14] WU F, JING R, ZHANG X P, et al. A combined method of improved grey bp neural network and MEEMD-ARIMA for day-ahead wave energy forecast[J]. IEEE Transactions on Sustainable Energy, 2021, 12(4): 2404-2412.
- [15] 曹俊波, 周任军, 邓兴华, 等. 考虑优化 ARIMA 模型差分次数的风功率预测[J]. 电力系统及其自动化学报, 2019, 31(1): 105-111.  
CAO Junbo, ZHOU Renjun, DENG Xuehua, et al. Wind power forecast considering differential times of optimal ARIMA model[J]. Proceedings of the CSU-EPSA, 2019, 31(1): 105-111.
- [16] 关永锋, 喻敏, 胡佳. 基于自适应组合模型的超短期风速预测[J]. 电力系统保护与控制, 2022, 50(4): 120-128.  
GUAN Yongfeng, YU Min, HU Jia. Ultra-short-term wind speed prediction based on an adaptive integrated model[J]. Power System Protection and Control, 2022, 50(4): 120-128.
- [17] 李智, 韩学山, 韩力, 等. 地区电网风电场功率超短期

- 预测方法[J]. 电力系统自动化, 2010, 34(7): 90-94.  
LI Zhi, HAN Xueshan, HAN Li, et al. An ultra-short-term wind power forecasting method in regional grids[J]. Automatic of Electric Power Systems, 2010, 34(7): 90-94.
- [18] BUHAN S, ÖZKAZANÇ Y, ÇADIRCI I. Wind pattern recognition and reference wind mast data correlations with NWP for improved wind-electric power forecast[J]. IEEE Transactions on Industrial Informatics, 2016, 1(3): 991-1004.
- [19] WANG Y, WANG D, TANG Y. Clustered hybrid wind power prediction model based on ARMA, PSO-SVM, and clustering methods[J]. IEEE Access, 2020, 8: 17071-17079.
- [20] 叶林, 刘鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报, 2011, 31(31): 102-108.  
YE Lin, LIU Peng. Combined model based on EMD-SVM for short-term wind power prediction[J]. Proceedings of the CSEE, 2011, 31(31): 102-108.
- [21] 张学清, 梁军, 张熙, 等. 基于样本熵和极端学习机的超短期风电功率组合预测模型[J]. 中国电机工程学报, 2013, 33(25): 33-40.  
ZHANG Xueqing, LIANG Jun, ZHANG Xi, et al. Combined model for ultra short-term wind power prediction based on sample entropy and extreme learning machine[J]. Proceedings of the CSEE, 2013, 33(25): 33-40.
- [22] YANG L, HE M, ZHANG J, et al. Support-vector-machine-enhanced Markov model for short-term wind power forecast[J]. IEEE Transactions on Sustainable Energy, 2015, 6(3): 791-799.
- [23] 陈峰, 余轶, 徐敬友, 等. 基于 Bayes-LSTM 网络的风电出力预测方法[J]. 电力系统保护与控制, 2023, 51(6): 170-178.  
CHEN Feng, YU Yi, XU Jingyou, et al. Prediction method of wind power output based on a Bayes-LSTM network[J]. Power System Protection and Control, 2023, 51(6): 170-178.
- [24] 史加荣, 赵丹梦, 王琳华, 等. 基于 RR-VMD-LSTM 的短期风电功率预测[J]. 电力系统保护与控制, 2021, 49(21): 63-70.  
SHI Jiarong, ZHAO Danmeng, WANG Linhua, et al. Short-term wind power prediction based on RR-VMD-LSTM[J]. Power System Protection and Control, 2021, 49(21): 63-70.
- [25] 琚垚, 祁林, 刘帅. 基于改进乌鸦算法和 ESN 神经网络的短期风电功率预测[J]. 电力系统保护与控制, 2019, 47(4): 58-64.  
JU Yao, QI Lin, LIU Shuai. Short-term wind power forecasting based on improved crow search algorithm and ESN neural network[J]. Power System Protection and Control, 2019, 47(4): 58-64.
- [26] 师洪涛, 杨静玲, 丁茂生, 等. 基于小波-BP 神经网络的短期风电功率预测方法[J]. 电力系统自动化, 2011, 35(16): 44-48.  
SHI Hongtao, YANG Jingling, DING Maosheng, et al. A short-term wind power prediction method based on wavelet decomposition and BP neural network[J]. Automation of Electric Power Systems, 2011, 35(16): 44-48.
- [27] 朱乔木, 李弘毅, 王子琪, 等. 基于长短期记忆网络的风电场发电功率超短期预测[J]. 电网技术, 2017, 41(12): 3797-3802.  
ZHU Qiaomu, LI Hongyi, WANG Ziqi, et al. Short-term wind power forecasting based on LSTM[J]. Power System Technology, 2017, 41(12): 3797-3802.
- [28] 贾睿, 杨国华, 郑豪丰, 等. 基于自适应权重的 CNN-LSTM&GRU 组合风电功率预测方法[J]. 中国电力, 2022, 55(5): 47-56, 110.  
JIA Rui, YANG Guohua, ZHENG Haofeng, et al. Combined wind power prediction method based on CNN-LSTM&GRU with adaptive weights[J]. Electric Power, 2022, 55(5): 47-56, 110.
- [29] 苏向敬, 周汶鑫, 李超杰, 等. 基于双重注意力 LSTM 神经网络的可解释海上风电出力预测[J]. 电力系统自动化, 2022, 46(7): 141-151.  
SU Xiangjing, ZHOU Wenxin, LI Chaojie, et al. Interpretable offshore wind power output forecasting based on long short-term memory neural network with dual-stage attention[J]. Automation of Electric Power Systems, 2022, 46(7): 141-151.
- [30] 国家能源局. 风电功率预测技术规定: NB/T 10205—2019[S]. 北京: 国家能源局, 2019.  
China Electricity Council. Technical rules for wind power forecasting: NB/T 10205—2019[S]. Beijing: National Energy Administration of China, 2019.
- [31] ZHU L P, HILL J D, LU C. Hierarchical deep learning machine for power system online transient stability prediction[J]. IEEE Transactions on Power Systems, 2020, 35(3): 2399-2411.

收稿日期: 2023-07-17; 修回日期: 2023-12-25

作者简介:

胡宇晗(1998—), 男, 硕士研究生, 研究方向为风电功率预测; E-mail: hyuhan@hnu.edu.cn

朱利鹏(1990—), 男, 博士, 教授, 研究方向为机器学习及其在电力系统中的应用、数据驱动的电力系统稳定分析与控制; E-mail: lpzhu@hnu.edu.cn

李佳勇(1990—), 男, 通信作者, 博士, 副教授, 研究方向为大数据和人工智能在智能电网中的应用、电力应急智慧管控技术。E-mail: jyli@hnu.edu.cn

(编辑 张颖)