

引用格式:郑文杰,谭慧娟,赵瑞锋,等.基于 ARIMA-LSTM-RBF 组合模型的风机出力短期预测[J].电力科学与技术学报,2024,39(4):153-159.

Citation: ZHENG wenjie, TAN Huijuan, ZHAO Ruifeng, et al. Short-term output prediction of wind turbine based on ARIMA-LSTM-RBF combined model[J]. Journal of Electric Power Science and Technology, 2024, 39(4): 153-159.

# 基于 ARIMA-LSTM-RBF 组合模型的风机 出力短期预测

郑文杰<sup>1</sup>, 谭慧娟<sup>1</sup>, 赵瑞锋<sup>1</sup>, 徐展强<sup>1</sup>, 蔡煜<sup>2</sup>, 朱欣悦<sup>2</sup>

(1. 广东电网有限责任公司电力调度控制中心, 广东 广州 510062; 2. 南方电网电力科技股份有限公司, 广东 广州 510180)

**摘要:**为响应中国“双碳”目标,以风电为代表的新能源在电网出力中的比重不断提升,有效的风机出力预测对于提前制定电网的调度与发电计划尤为重要。由于风电数据具有不规则性强、季节性强等特点。为此,针对单模型预测方法无法解决风电间歇性的同时保证预测精度的问题,提出一种利用差分自回归移动平均(autoregressive integrated moving average, ARIMA)时间序列、长短期记忆(long short-term memory, LSTM)网络和径向基函数(radial basis function, RBF)神经网络建立组合模型对某地区风机出力进行短期预测。首先,进行数据预处理及序列平稳性分析与处理,得到平稳性序列并通过 ARIMA 预测,其次,将不满足残差白噪声分析判定的不规则数据通过 LSTM 预测;然后,使用 RBF 神经网络学习和模拟得出预测值以提升精度;最后,基于某风电接入系统数据进行仿真。通过与其他单一模型预测方法对比,结果表明:所提出的组合模型预测方法能够对季节性强和不规则性强的风电数据进行预测并且有更好的预测精度,为相应设备的运行与调度提供参考,提升供电可靠性。

**关键词:** 风机出力短期预测; ARIMA 时间序列; LSTM; RBF 神经网络

DOI: 10.19781/j.issn.1673-9140.2024.04.018 中图分类号: TM863 文章编号: 1673-9140(2024)04-0153-07

## Short-term output prediction of wind turbine based on ARIMA-LSTM-RBF combined model

ZHENG Wenjie<sup>1</sup>, TAN Huijuan<sup>1</sup>, ZHAO Ruifeng<sup>1</sup>, XU Zhanqiang<sup>1</sup>, CAI Yu<sup>2</sup>, ZHU Xinyue<sup>2</sup>

(1. Power Dispatching and Control Center, Guangdong Power Grid Co., Ltd., Guangzhou 510062, China;

2. China Southern Power Grid Technology Co., Ltd., Guangzhou 510180, China)

**Abstract:** In response to China's "dual carbon" goals, the proportion of new energy sources, represented by wind power, in the power output for power grids continues to increase. Effective wind turbine output prediction is particularly important for formulating grid scheduling and power generation plans ahead of time. Due to the strong irregularity and seasonality of wind power data, a single model prediction method cannot solve the problem of wind power intermittency while ensuring prediction accuracy. To address this, a combined model using the autoregressive integrated moving average (ARIMA) time series, long- and short-term memory (LSTM) network, and radial basis function (RBF) neural network is proposed for short-term prediction of wind turbine output in a certain region. First, data preprocessing and sequence stationarity analysis are performed to obtain a stationary sequence and predict it through ARIMA. Secondly, irregular data that do not meet the criteria of residual white noise analysis are predicted through LSTM. Then, the RBF neural network is used to learn and simulate the predicted values to improve accuracy. Finally, simulations are conducted based on data from a wind power station. Compared with other single model prediction methods, the results

收稿日期: 2023-01-31; 修回日期: 2023-11-13

基金项目: 中国南方电网有限责任公司科技项目(036000KK52210054, GDKJXM20210063)

通信作者: 郑文杰(1981—), 男, 博士, 高级工程师, 主要从事电力市场与新型电力系统研究; E-mail: zhengwenjie@csg.cn

show that the proposed combined model prediction method can predict wind power data with strong seasonality and irregularity and has better prediction accuracy, providing a reference for the operation and scheduling of corresponding equipment and enhancing power supply reliability.

**Key words:** short-term output prediction of wind turbine; ARIMA time series; long- and short-term memory; RBF neural network

在“双碳”目标的指引下,中国新能源的发展已进入快车道,其中尤以风电更为显著。大量风机并入电网使得风电的辐射面积日趋增长,形成了一个庞大的风力供电网。但由于风电具有不规则强、难以预测等特点<sup>[1-2]</sup>,造成了风电机组出力的随机性,使其无法支撑电网的电压稳定;同时,受风速变化、紊流等影响,风机出力会出现波动和间歇启停,甚至会从满负荷运行状态下突然自动甩负荷。中国的电网调度与发电计划都是基于电网的安全可靠性、预测负荷等条件而制定和实施的。风电的随机和不可预测性会给传统的调度与发电计划的安排和实施带来很多问题,特别是近年来,全国范围内大容量风机的规模迅速增长,风电场对电网的影响将愈加明显。因此,系统内风机出力的预测显得更加重要。

目前,国内外学者对风机出力短期预测的研究创新主要集中在各种算法层面,主要包括单耗法<sup>[3]</sup>、弹性系数法<sup>[4]</sup>、趋势外推法<sup>[5]</sup>、负荷密度法<sup>[6]</sup>、时间序列法、神经网络法、灰色模型法以及回归分析法等算法。传统的预测算法总是以单个的算法形式出现,如文献[7]使用单一的时间序列对短期的风电出力进行预测,虽然在一些小系统的预测中能够起到不错的效果,但是面临现状错综复杂的风机出力预测情况,往往显得有些单薄。随着机器学习的不断发展,神经网络和时间序列在风电出力预测上的应用日趋广泛,在数据量充足的情况下,往往能够实现较好的预测精度,如文献[8]在众多分布式电源接入的背景下,提出在广义神经网络的框架下进行深度学习,建立了风电机组性能预测模型,在众多运行数据的支持下,预测精度在实践运用得到了提高。该模型受限于必须获取大量的精确的运行数据,这就意味着在运行数据收集不及时不准确的地区无法展开预测,而风电预测的数据收集难度很大,出现缺失和异常时常存在,单一的该模型难以对风机出力进行预测分析。

在传统的单一模型缺陷明显情况下,众多的优化和组合模型逐渐产生。具有代表性的是,经由启发式和仿生学算法优化后的神经网络模型有BP神

经网络、径向基函数(radial basis function, RBF)神经网络、循环神经网络(recurrent neural network, RNN)和长短期记忆(long short-term memory, LSTM)网络等。文献[9-10]均给出了典型的优化模型,其中,RBF神经网络模型由于结构简单且受限于隐含层权重的赋值,故提出使用粒子群优化(particle swarm optimization, PSO)算法优化RBF神经网络这一突出弊端,再辅以模糊逻辑以削弱人为设定参数对模型的影响,理论上该模型已经呈现出不错的优化状态。LSTM是神经网络模型发展至今产生的模块式模型,除去RNN上的一些固有弊端,国内外学者在研究出力预测时,多采用该方法或与其他算法结合,如文献[11]、[12]利用LSTM模型分别在光伏出力预测和中长期电力系统负荷预测上取得了不错的预测结果。在风电出力预测上对组合模型的研究也十分广泛,组合预测模型是综合2种模型的长处以提高模型的预测精度,一般利用节点直接结合<sup>[13]</sup>或截取算法中的一部分与其他算法再组合<sup>[14]</sup>,进行模型精度的预测。对于组合模型,文献[15-16]将卷积神经网络和LSTM相结合,试图将卷积神经网络的精细化和LSTM的模块化相结合;文献[17-19]利用K-means聚类算法的中心距离分类特性与众多机器学习算法相结合,在具体实验中均取得了不错的效果。上述方法一定程度上解决了机器学习算法中所面临的几何空间中心定位问题。

研究表明,组合模型能够有效地避免单个模型的固有缺陷,实现模型的扬长避短。为减小风电的波动性、季节性强等特点的影响并提高风电出力的短期预测精度,本文建立一组基于差分自回归移动平均(autoregressive integrated moving average, ARIMA)时间序列和LSTM-RBF组合神经网络的集成模型,该模型基于数据预处理及一阶差分平稳性处理后序列,使用ARIMA时间序列模型进行预测,并结合残差白噪声检验筛选无规律数据,将检验不通过的数据集采用LSTM模型进行预测,最后,使用RBF神经网络进行学习和模拟得出最终预测值。经过算例分析,本文所提ARIMA-LSTM-RBF组合

模型相较于单一模型,其预测方法能够更好地预测季节性 & 波动性强的数据,同时预测精度更高。

## 1 数据预处理与序列平稳性分析

原始的风机出力数据集往往存在缺失和异常数据,无法完成时间序列分析。由于时间序列分析时需要序列有一定的平稳性或周期性,因此,实验开始前本文对数据进行补偿与替换,并对预处理后的数据进行平稳性分析。

### 1.1 数据集的补偿与替换

#### 1.1.1 补偿与替换方法

数据集缺失值与异常值的补偿与替换往往与其存在的位置有关,当该值存在于整个序列的开头或者结尾时,可以采用直接删除的处理方式,但是若该值存在于序列的中间位置,则不能直接删除。一般处理方式有5种:①序列平均值替换,使用整个序列的平均值进行补偿与替换;②临近点的平均值替换,使用相邻若干个点的平均值进行补偿与替换;③临近点的中位数替换,使用相邻若干个点的中位数进行补偿与替换;④线性插值替换,使用相邻多个点进行线性拟合,得出中间点值进行补偿与替换;⑤临近点线性趋势替换,将临近时期数作为自变量,序列值作为因变量进行回归,求取缺失值或异常值。

#### 1.1.2 补偿与替换结果

由于风电具有较强的季节性与波动性,因此,采用线性插值法、临近点线性趋势替换法进行数据补偿。以某地区风场为例,该风场风电功率序列的采样频率为1h,其中7月某日的24h原始风力发电功率序列如图1所示;进行数据预处理之后的风力发电功率序列如图2所示。

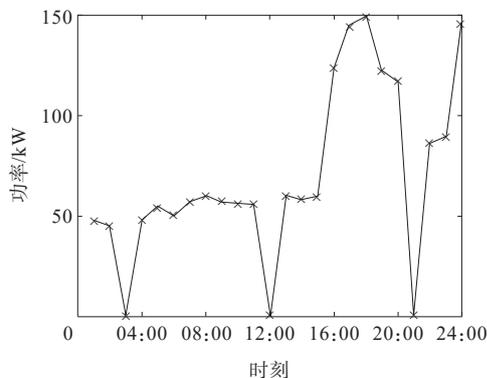


图1 7月某日24h风电功率序列

Figure 1 24 h wind power sequence on one certain day in July

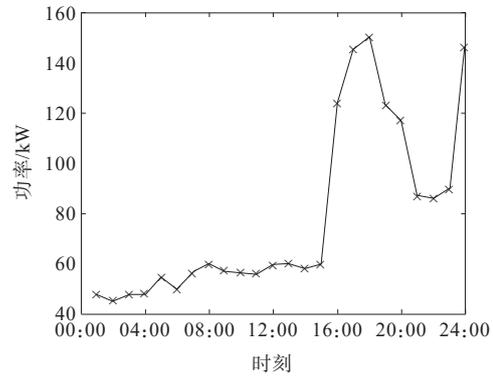


图2 修正后风电功率序列

Figure 2 Corrected wind power sequence

### 1.2 序列平稳性分析与序列平稳化处理

#### 1.2.1 时间序列的平稳性

一般情况下时间序列只需满足如下3个条件即可满足平稳性要求。

$$\begin{cases} E(x_1) = E(x_2) = u \\ V(x_1) = V(x_2) = \sigma^2 \\ \text{Cov}(x_t, x_{t-s}) = \gamma_s \end{cases} \quad (1)$$

式中,  $E(x_t)$  为均值;  $V(x_t)$  为方差;  $\text{Cov}(x_t, x_{t-s})$  为协方差。

当序列均值恒为常数,序列方差存在且恒为常数,序列协方差仅与间隔  $s$  有关而与  $t$  无关。此时说明该序列是平稳序列。满足如下条件时则称该时间序列为白噪声序列,是一种特殊的平稳性序列。

$$\begin{cases} E(x_1) = E(x_2) = 0 \\ V(x_1) = V(x_2) = \sigma^2 \\ \text{Cov}(x_t, x_{t-s}) = 0 \end{cases} \quad (2)$$

一般情况下,时间序列的平稳性能够通过直接通过观看时序图得到粗略的估计,也可使用假设检验的方式对时间序列的平稳性进行检验,最常见的有ADF(augmented dickey fuller)单位根、自相关系数(autocorrelation coefficient function, ACF)和偏自相关系数(partial autocorrelation coefficient function, PACF)检验等。

#### 1.2.2 ARIMA时间序列模型平稳性检验

ARIMA时间序列模型要求所预测的时序数据必须是平稳的或者经过差分处理后是平稳的,因此在使用ARIMA模型进行预测时,必须先行对序列做平稳性检验和处理,本文采用ADF单位根和ACF检验。大部分情况下时序数据都不是平稳的,需要对原始时序数据做多次差分处理,使原序列转变为平稳序列。本文选取某地8月份风力发电功率

数据,对其进行平稳性分析及处理,如图3所示。

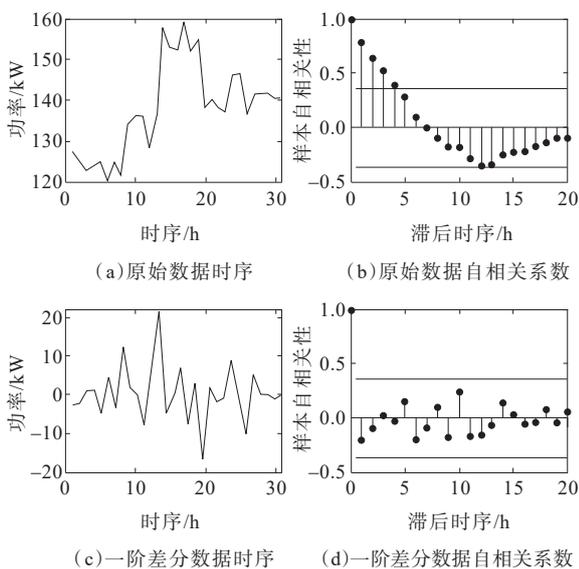


图3 平稳性分析

Figure 3 Stationarity analysis

由图3可知,原始数据波动性不强,而一阶差分处理后的时序数据波动性强,一阶差分的自相关系数是拖尾的,可以选择自回归(autoregressive, AR)时间序列模型。本文选用ARIMA时间序列模型进行预测。

## 2 ARIMA-LSTM组合模型

### 2.1 ARIMA时间序列模型

ARIMA模型包含3个十分重要的内在变量,即参数 $p, d, q$ ,分别代表 $p$ 阶自回归模型、 $d$ 阶差分处理以及 $q$ 阶移动平均。AR模型、移动平均模型和差分过程分别为

$$y_t = \mu + \sum_{i=1}^p \alpha_i y_{t-i} + \epsilon_t \quad (3)$$

$$y_t = \mu' + \sum_{i=1}^q \beta_i y_{t-i} + \epsilon'_t \quad (4)$$

$$(1 - \sum_{i=1}^p \alpha_i y_{t-i})(1 - L)^d y_t = (1 + \sum_{i=1}^q \beta_i L^i) \epsilon'_t \quad (5)$$

式(3)~(5)中, $\mu, \mu'$ 为常数; $\alpha_i, \beta_i$ 为相关系数; $y_t$ 为当前值; $\epsilon_t, \epsilon'_t$ 为误差值。

ARIMA时间序列模型简单,不需要借助其他的外在变量,只需要依靠本身的内在变量就能够完成预测。但是该模型十分依赖输入序列的平稳性,对其预测精度有一定的影响,故必须进行差分平稳性处理。

一般而言,在一个时间序列模型中加入的参数

越多,模型拟合效果越好,但是这是以提高模型复杂度作为代价。因此,所建立的模型需要在模型的复杂度和数据解释能力之间寻求平衡。本文采用赤池信息准则(akaike information criterion, AIC)和贝叶斯信息准则(Bayesian information criterion, BIC)为依据来选择参数,分别为

$$A_{IC} = 2T - 2 \ln L \quad (6)$$

$$B_{IC} = 2 \ln T - 2 \ln L \quad (7)$$

式中, $T$ 为参数个数,代表模型的复杂程度; $L$ 为模型的极大似然函数值或称序列宽度,反映模拟对数据的解释程度。

由于AIC、BIC更适用于小模型,为在模型复杂程度和数据解释能力上达到最佳平衡效果,需要获得最小值的 $A_{IC}$ 或 $B_{IC}$ 。

在ARIMA模型中, $p, q$ 增加时 $T$ 随之增加,而序列宽度增加时则 $L$ 会增加,如此得到AIC或BIC的最小值,从而确定 $p, q$ 。本文确定 $p=1, q=1$ 。因此,本文建立的时间序列模型为ARIMA(1,1,1)模型。

### 2.2 LSTM模型的建立

LSTM网络实质是一种改进型的RNN,能够解决RNN无法解决的长距离依赖问题。原始的RNN隐含层只有一个状态量,记为 $C$ 状态,用于储存短期状态。在LSTM模型中多加入一个状态,记为 $h$ ,用来储存长期记忆。LSTM网络模仿细胞神经元的记忆方式来构建模型,以细胞状态向量的形式来储存过往序列的信息和记忆,把上一个时间的序列状态、当前时间的序列状态以及上一时间的隐藏状态综合起来,从而构建长期神经元的历史长期记忆。

LSTM模型主要是利用三道门来实现预测,三道门分别是遗忘门、输入门、输出门。遗忘门决定上一时刻有多少单元状态 $C_{t-1}$ 将保存到当前状态 $C_t$ ;输入门决定有多少输入 $X_t$ 将保存到 $C_t$ ;输出门决定有多少控制单元的当前状态 $C_t$ 将输出到当前输出值 $h_t$ 。具体LSTM模型如图4所示。

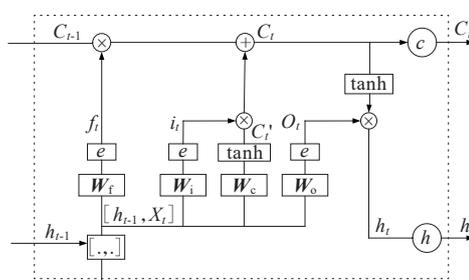


图4 LSTM模型

Figure 4 Schematic diagram of LSTM model

图 4 中  $e$  为 sigmoid 函数,  $W_f$ 、 $W_i$ 、 $W_c$ 、 $W_o$  分别为遗忘门、输入层遗忘门、输入门、计算单位状态的权重矩阵。遗忘门和输入门输入分别为图 4 中  $f_i$ 、 $i_i$ , 具体表达式如下:

$$f_i = e(W_f[h_{t-1}, x_t] + u) \quad (8)$$

$$i_i = e(W_i[h_{t-1}, x_t] + u) \quad (9)$$

当前单元记忆状态、单元状态、输出值分别由  $C'_t$ 、 $C_t$ 、 $h_t$  来描述, 具体表达式如下:

$$C'_t = \tanh(W_c[h_{t-1}, x_t] + u) \quad (10)$$

$$C_t = f_i \cdot C_t + i_i \cdot C'_t \quad (11)$$

$$h_t = O_i \cdot \tanh(C_t) \quad (12)$$

### 2.3 RBF 模型的建立

RBF 神经网络是一种单隐层前向反馈神经网络, 其隐含层的每个节点都有一个参数向量, 称为中心, 该中心用于与网络输入向量进行比较, 以产生径向对称的响应; 通过输出层的连接权值对隐含层的响应进行缩放, 然后组合产生网络输出。隐含层神经元是以高斯函数作为核函数的神经元。核函数是在中心点处响应最大的局部激活函数, 在远离中心点处响应呈指数递减。与其他神经网络模型相比, RBF 神经网络具有更强的学习、分类和逼近能力。RBF 神经网络结构如图 5 所示。

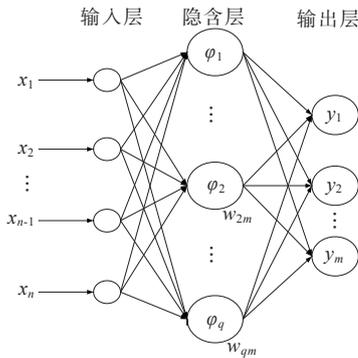


图 5 RBF 神经网络结构

Figure 5 Structure of RBF neural network

常用的 RBF 函数为

$$\varphi(r) = 1/\sqrt{r^2 + \sigma^2} \quad (13)$$

式中,  $r = \|X - c_i\|^2$ ,  $i = 1, 2, \dots, q$ , 其中  $c_i$  为神经元的中心点,  $q$  为隐含层节点数;  $\sigma$  为基函数的扩展常数, 决定 RBF 函数的宽度。

当 RBF 神经网络进行线性加权时, 其网络映射输出为

$$y_m = \sum_{j=1}^q \omega_{jk} \varphi_j \quad (14)$$

式中,  $\omega_{jk}$  为隐藏层中第  $j$  个神经元连接到输出层时

的权重。

### 2.4 ARIMA-LSTM-RBF 组合模型

#### 2.4.1 白噪声检验

白噪声检验又称纯随机数检验, 当一个序列为纯随机数序列时, 使用时间序列模型对其分析将变得毫无意义, 故在序列进行完平稳性分析或处理后, 需要对序列进行白噪声检验。在完成估计时间序列后, 本文对残差进行白噪声分析, 若残差白噪声分析通过, 则认为该时间序列模型已经较好识别序列的规律; 若残差白噪声分析不通过, 则认为该时间序列无法对该序列的时间规律完成识别, 改由 LSTM 对该序列进行预测。

本文白噪声检验时采用 MATLAB 内置函数 Autocorrelation[·] 进行处理, 该函数具体采用 Bartlett 定理作为理论基础。

#### 2.4.2 模型的组合

本文采用残差白噪声分析作为 ARIMA 和 LSTM 模型组合节点。由于 ARIMA 模型在处理周期性和时间规律性强的数据时, 具有精度高、速度快等特点, 又因为大部分的风力发电功率数据的周期性较强, 所以选用 ARIMA 模型作为模型的首选模型。但是当遇到随机性大的序列时, ARIMA 模型无法有效识别序列规律, 此时采用学习性更强的 LSTM 模型对序列进行预测。最后, 将 ARIMA 和 LSTM 模型的预测值作为 RBF 神经网络的输入进行学习, 得到最终的预测值。整个组合模型的运行流程如图 6 所示。

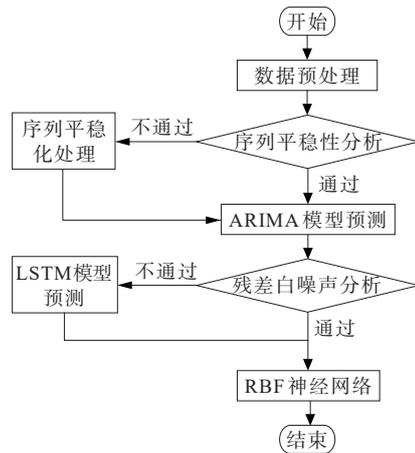


图 6 组合模型流程

Figure 6 Flowchart of combined model

### 3 实验分析

选取某地区风力配网 2020 年 7 月—9 月的风力

发电功率数据作为训练数据集,在MATLAB2018b平台上进行仿真分析。其中选取各月90%的数据作为训练数据,再选取各月中的某一天进行预测后与原始数据进行对比,并且选取均方根误差(root mean square error, RMSE)作为误差评价标准,即

$$e_{\text{RMSE}} = \frac{1}{N} \sum_{i=1}^N (p_i - x_i)^2 \quad (15)$$

式中,  $p_i$  为第  $i$  个预测值;  $x_i$  为第  $i$  个真实值;  $N$  为样本个数。

首先进行平稳性分析(见图3)。以8月数据为例,在该风场8月风力发电功率数据进行残差白噪声分析时,其数据不能通过白噪声,即选用LSTM模型对风力配网7月27日的风力发电功率进行预测并与检测值进行对比,原始值与预测值对比如图7所示。然后对8月数据进行平稳性分析,发现其序列能够通过残差白噪声分析,即采用ARIMA模型对风力配网8月26日的风力发电功率进行预测并与检测值进行对比,原始值和预测值对比如图8所示。经过计算,8月预测的RMSE为5.35。

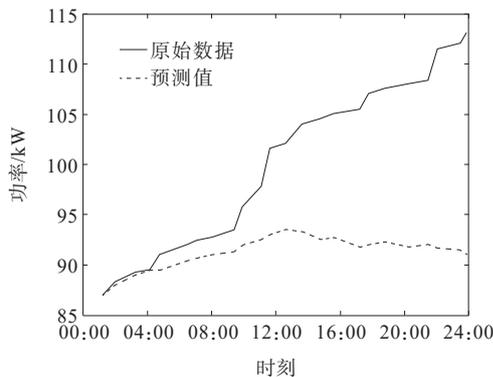


图7 原始值与预测值对比(7月27日)

Figure 7 Comparison of the original and predicted value (July 27)

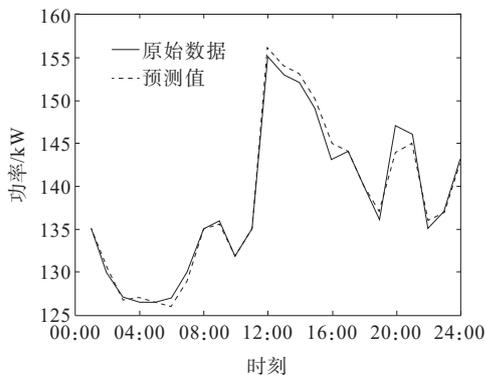


图8 原始值和预测值对比(8月26日)

Figure 8 Comparison of original and predicted value (August 26)

综合7、8月的预测结果,经ARIMA模型预测的结果相较于LSTM的预测结果更为精确,但其受限于残差白噪声分析结果,在数据组不能通过白噪声分析时,此时选择LSTM模型进行预测,7月的预测结果也在可以接受范围之内,达到了较好的预测结果。综合实验结果,对于风力发电功率的预测,本文所建立的组合模型有较高的预测精度,足以满足风电短期风机出力预测的现实需求。

此外,为了比较基于RBF神经网络的ARIMA-LSTM的模型性能,分别采用单一ARIMA和LSTM模型以及基于RBF神经网络优化后的ARIMA-LSTM模型对风机出力进行预测。以9月20日风电出力为例,3种模型的预测值对比如图9所示,其中raw曲线为当天实际用电负荷曲线。

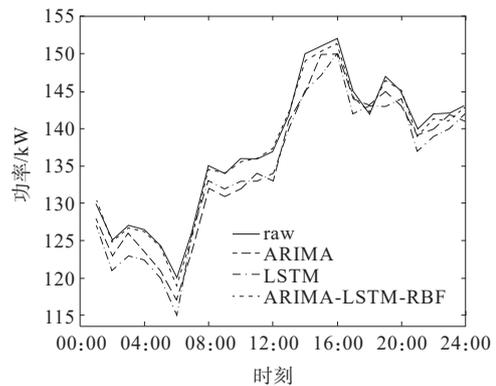


图9 3种模型的预测值对比(9月20日)

Figure 9 Comparison of predicted values of three models (September 20)

由图9可知,3种模型的预测精度随着预测周期的延长而降低。然而,基于RBF神经网络优化后的ARIMA-LSTM模型的预测趋势最接近于原始数据。通过对上述数据集的分析,再使用相对平均误差对3种模型的性能进行比较,如图10所示,基于RBF神经网络的ARIMA-LSTM模型的性能更优。

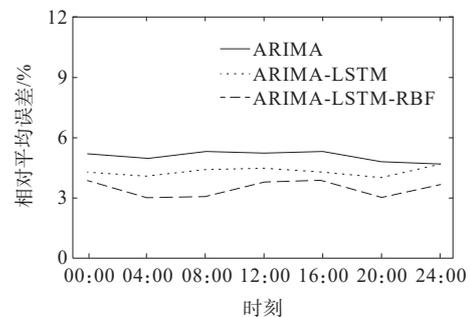


图10 风机出力预测误差对比

Figure 10 Error comparison of output prediction of wind turbine under three models

## 4 结语

针对风机出力所具有的数据分布特性,本文提出了ARIMA-LSTM-RBF组合模型,并对该模型进行了训练与测试。

1) 使用多种补偿、替换法对原始、缺少和异常数据进行预处理,使预测具有更高的准确性与合理性;

2) 基于平稳性检验与平稳化处理,使用ARIMA模型处理平稳性或周期性的数据集,并通过残差白噪声分析判定,对于不满足判定的无规律数据集使用LSTM模型进行预测,使预测具有更广的适用范围;

3) 在ARIMA-LSTM模型的基础上,引入RBF神经网络进行学习和模拟预测值与真实值的映射关系,并得出最终预测值,相较于传统单模型预测方法,该组合模型具有更好的预测精度和实用性;

4) 仿真结果表明,本文所提风机出力短期预测方法能够在数据波动性强的环境下准确预测风机出力情况,可为相应设备的运行和调度提供参考,继而提升供电可靠性。

### 参考文献:

- [1] 温锦斌,王昕,李立学,等.基于频域分解的短期风电负荷预测[J].电工技术学报,2013,28(5):66-72.  
WEN Jinbin, WANG Xin, LI Lixue, et al. Short-term wind power load forecasting based on frequency domain decomposition[J]. Transactions of China Electrotechnical Society, 2013, 28(5): 66-72.
- [2] 张海亮,王艺博,蔡国伟,等.面向风电消纳与电熔镁高载能负荷调控的源荷协调优化策略[J].电工技术学报,2022,37(17):4401-4410.  
ZHANG Hailiang, WANG Yibo, CAI Guowei, et al. Source-load coordination optimization strategy for wind power accommodation and high energy load regulation of electric fused magnesium[J]. Transactions of China Electrotechnical Society, 2022, 37(17): 4401-4410.
- [3] 靳春旭,董福贵.长期风电负荷预测方法比较[J].广东电力,2018,31(9):70-76.  
JIN Chunxu, DONG Fugui. Comparison of prediction methods for long-term wind power load[J]. Guangdong Electric Power, 2018, 31(9): 70-76.
- [4] 陈宋宋,王阳,周颖,等.基于客户用电数据的多时空维度负荷预测综述[J].电网与清洁能源,2023,39(12):28-40.  
CHEN Songsong, WANG Yang, ZHOU Ying, et al. A review of multi-time-space load forecasting based on customer electricity consumption data[J]. Power System and Clean Energy, 2023, 39(12): 28-40.
- [5] 王强钢,郭莹霏,莫复雪,等.计及变压器短期急救负载的城市高压配电网负荷优化分配[J].电力系统自动化,2023,47(19):106-115.  
WANG Qianggang, GUO Yingfei, MO Fuxue, et al. Optimal load distribution of urban high voltage distribution network considering short-term emergency load of transformer[J]. Automation of Electric Power Systems, 2023, 47(19): 106-115.
- [6] 刘业峰,王婷.基于GRA-LSSVM密度法的配电网空间负荷预测方法研究[J].计算机测量与控制,2018,26(11):256-260.  
LIU Yefeng, WANG Ting. Research on spatial load forecasting of distribution network based on GRA-LSSVM density method[J]. Computer Measurement & Control, 2018, 26(11): 256-260.
- [7] 马庆法,吕晓禄,胡云,等.风电出力的波动特性及预测方法研究[J].山东电力技术,2016,43(9):15-19+23.  
MA Qingfa, LÜ Xiaolu, HU Yun, et al. Fluctuation characteristics and the prediction method of wind power [J]. Shandong Electric Power, 2016, 43(9): 15-19+23.
- [8] 崔恺,许宜菲,李雪松,等.基于广义回归神经网络的风电机组性能预测模型及状态预警[J].科学技术与工程,2020,20(32):13220-13228.  
CUI Kai, XU Yifei, LU Xuesong, et al. Wind turbine performance prediction model and early warning of abnormal condition based on GRNN[J]. Science Technology and Engineering, 2020, 20(32): 13220-13228.
- [9] 李盘荣,华伟东.基于QPSO-RBFNN和模糊理论的电力系统短期负荷预测方法[J].电力科学与技术学报,2008,23(1):60-65.  
LI Panrong, HUA Weidong. Short-term load forecast with QPSO-RBFNN and fuzzy logic for power systems[J]. Journal of Electric Power Science and Technology, 2008, 23(1): 60-65.
- [10] 任建吉,位慧慧,邹卓霖,等.基于CNN-BiLSTM-Attention的超短期电力负荷预测[J].电力系统保护与控制,2022,50(8):108-116.  
REN Jianji, WEI Huihui, ZOU Zhuolin, et al. Ultra-short-term power load forecasting based on CNN-BiLSTM-Attention[J]. Power System Protection and Control, 2022, 50(8): 108-116.
- [11] TORRES J F, MARTÍNEZ-ÁLVAREZ F, TRONCOSO A. A deep LSTM network for the Spanish electricity consumption forecasting[J]. Neural Computing & Applications, 2022, 34(13): 10533-10545.
- [12] KO M, LEE K, KIM J, et al. Deep concatenated residual network with bidirectional LSTM for one-hour-ahead wind power forecasting[J]. IEEE Transactions on Sustainable Energy, 2021, 12(2): 1321-1335.

- [J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(1): 11-19.
- [14] PIZARRO-CARMONA V, CASTANO-SOLÍS S, CORTÉS-CARMONA M, et al. GA-based approach to optimize an equivalent electric circuit model of a Li-ion battery-pack[J]. Expert Systems with Applications, 2021, 172: 114647.
- [15] 张金龙, 魏艳君, 李向丽, 等. 基于模型参数在线辨识的蓄电池SOC估算[J]. 电工技术学报, 2014, 29(S1): 23-28. ZHANG Jinglong, WEI Yanjun, LI Xiangli, et al. Battery SOC estimation based on online parameter identification [J]. Transactions of China Electrotechnical Society, 2014, 29(S1): 23-28.
- [16] 贾海峰, 李聪. 动力锂电池SOC估计仿真研究[J]. 计算机仿真, 2021, 38(5): 55-59+228. JIA Haifeng, LI Cong. Simulation study on dynamic lithium battery SOC estimation[J]. Computer Simulation, 2021, 38(5): 55-59+228.
- [17] 邓子豪, 夏向阳, 张嘉诚. 磷酸铁锂电池优化多因子状态在线评估方法[J]. 电网与清洁能源, 2022, 38(3): 90-96. DENG Zihao, XIA Xiangyang, ZHANG Jiacheng. An optimized multi-factor online assessment method of SOH for LiFePO<sub>4</sub> batteries[J]. Power System and Clean Energy, 2022, 38(3): 90-96.
- [18] 刘鹏, 李云伍, 梁新成. 基于遗忘递推最小二乘与自适应无迹卡尔曼滤波的锂电池SOC估计[J]. 汽车技术, 2022(2): 21-27. LIU Peng, LI Yunwu, LIANG Xincheng. Estimation of lithium battery SOC based on FFRLS and AUKF[J]. Automobile Technology, 2022(2): 21-27.
- [19] 刘雨洋, 王顺利, 谢滢馨, 等. 基于在线参数辨识和改进2RC-PNGV模型的锂离子电池建模与SOC估算研究[J]. 储能科学与技术, 2021, 10(6): 2312-2317. LIU Yuyang, WANG Shunli, XIE Yanxin, et al. Research on Li-ion battery modeling and SOC estimation based on online parameter identification and improved 2RC-PNGV model[J]. Energy Storage Science and Technology, 2021, 10(6): 2312-2317.
- [20] 寇发荣, 王甜甜, 王思俊, 等. 基于ABC-RFEKF算法的锂电池SOC估计[J]. 电力系统保护与控制, 2022, 50(4): 163-171. KOU Farong, WANG Tiantian, WANG Sijun. Lithium battery SOC estimation based on an ABC-RFEKF algorithm[J]. Power System Protection and Control, 2022, 50(4): 163-171.
- [21] 卫志农, 原康康, 成乐祥, 等. 基于多新息最小二乘算法的锂电池参数辨识[J]. 电力系统自动化, 2019, 43(15): 139-145. WEI Zhinong, YUAN Kangkang, CHENG Lexiang, et al. Parameter identification of lithium-ion battery based on multi-innovation least squares algorithm[J]. Automation of Electric Power Systems, 2019, 43(15): 139-145.

(上接第159页 Continued from page 159)

- [13] 魏林涵, 郝正航, 郭家鹏, 等. 基于TCA-CNN-LSTM的短期负荷预测研究[J]. 电测与仪表, 2023, 60(8): 73-80. WEI Linhan, HAO Zhenghang, GUO Jiapeng, et al. Research on short-term load forecasting based on TCA-CNN-LSTM[J]. Electrical Measurement & Instrumentation, 2023, 60(8): 73-80.
- [14] 程津, 黎燕, 夏向阳, 等. 基于双组合预测的经济—电力负荷预测模型[J]. 电力科学与技术学报, 2018, 33(3): 18-22. CHENG Jin, LI Yan, XIA Xiangyang, et al. Economic-electricity conduction prediction model based on dual combination prediction[J]. Journal of Electric Power Science and Technology, 2018, 33(3): 18-22.
- [15] LUO S, RAO Y, CHEN J, et al. Short-term load forecasting model of distribution transformer based on CNN and LSTM[C]//IEEE International Conference on High Voltage Engineering and Application (ICHVE), Beijing, China, 2020.
- [16] CHEN L, YU H, TONG L, et al. Research on load forecasting method of distribution transformer based on deep learning[C]//7th IEEE International Conference on Cyber Security and Cloud Computing (CSCloud)/2020 6th IEEE International Conference on Edge Computing and Scalable Cloud (EdgeCom), New York, NY, USA, 2020.
- [17] 荀超, 陈伯建, 吴翔宇, 等. 基于改进K-means算法的电力短期负荷预测方法研究[J]. 电力科学与技术学报, 2022, 37(1): 90-95. XUN Cho, CHEN Bojian, WU Xiangyu, et al. Research on short-term power load forecasting method based on improved K-means algorithm[J]. Journal of Electric Power Science and Technology, 2022, 37(1): 90-95.
- [18] 李春生, 陈光辉. 基于最大信息压缩指标与层次分析法的电力负荷组合预测模型[J]. 电力科学与技术学报, 2008, 23(1): 56-59. LI Chunsheng, CHEN Guanghu. Combination model for power system load forecast based on maximal information compress index and analytic hierarchy process[J]. Journal of Electric Power Science and Technology, 2008, 23(1): 56-59.
- [19] 邢雅, 侯峰, 樊博, 等. 基于改进K-means聚类的变压器局部放电定位诊断方法[J]. 智慧电力, 2023, 51(3): 53-58. XING Ya, HOU Feng, FAN Bo, et al. Transformer partial discharge fault location and diagnosis based on improved K-means clustering algorithm[J]. Smart Power, 2023, 51(3): 53-58.