

## 基于Informer的风电场超短期功率预测

李超峰<sup>1</sup>,原升耀<sup>2</sup>,王灵梅<sup>3\*</sup>,王贺贤<sup>3</sup>,贾成真<sup>3</sup>,刘玉山<sup>3</sup>,常馨元<sup>3</sup>

(1.太原重工技术中心,山西太原 030006;

2.山西粤电能源有限公司,山西太原 030006;

3.山西大学 自动化与软件学院,山西太原 030006)

**摘要:**为提高预测精度,解决超短期风电场功率预测中风能持续性和稳定性差、风机出力中多种因素对风电场超短期功率预测影响程度不同以及原始Transformer神经网络架构注意力机制受限、缺乏全局信息等问题,提出了一种基于Informer网络架构与马尔可夫链修正相结合的风电功率预测模型。该模型使用随机森林、拉格朗日插补法等算法对数据进行预处理;使用Informer神经网络架构对风电场功率做出预测,并用马尔可夫链对超短期风功率预测结果进行误差修正,以提高模型预测准确率。现场实验结果表明,该模型提高了风电场功率的预测时间步长及预测精度,月平均准确率最高可达97%,年平均准确率可达95%。

**关键词:**超短期风功率预测;Informer;多头稀疏概率自注意力机制;预测误差修正

中图分类号:O436

文献标志码:A

文章编号:0253-2395(2024)06-1201-10

## Ultra-short-term Power Prediction for Wind Farms Based on Informer

LI Chaofeng<sup>1</sup>, YUAN Shengyao<sup>2</sup>, WANG Lingmei<sup>3\*</sup>, WANG Hexian<sup>3</sup>, JIA Chengzhen<sup>3</sup>, LIU Yushan<sup>3</sup>,

CHANG Xinyuan<sup>3</sup>

(1. Technical Center of Taiyuan Heavy Machinery Group Co., Ltd, Taiyuan 030006, China;

2. Shanxi Yuedian Energy Co., Ltd., Shanxi Taiyuan 030006, China;

3. School of Automation and Software, Shanxi University, Taiyuan 030006, China)

**Abstract:** Aiming at the problems of poor sustainability and stability of wind power in ultra-short-term wind electric power prediction, the varying degrees of influence of various factors in wind turbine output on ultra-short-term wind electric power prediction, and the limited attention mechanism and lack of global information of the original Transformer neural network architecture, a wind power prediction model based on the combination of Informer network architecture and Markov chain correction was proposed. The model uses algorithms including random forest and Lagrangian interpolation to preprocess data, uses the Informer neural network architecture to predict wind electric power, and uses Markov chains to correct errors in ultra-short-term wind power prediction results to improve model prediction accuracy. Field experiment results show that the model improves the prediction time step and prediction accuracy of wind electric power, with the monthly average accuracy reaching up to 97% and the annual average accuracy reaching 95%.

**Key words:** ultra-short term wind power forecast; Informer; multi-headed self-attention; prediction error correction

收稿日期:2024-04-15;接受日期:2024-09-11

基金项目:山西省重点研发计划项目(202202060301004)

作者简介:李超峰(1972-),男,山西太原人,大学本科,研究方向为风力发电。E-mail:lichao Feng@tz.com.cn

\*通信作者:王灵梅(WANG Lingmei),E-mail:13546468676@163.com

引文格式:李超峰,原升耀,王灵梅,等.基于Informer的风电场超短期功率预测[J].山西大学学报(自然科学版),2024,47(6):1201-1210. DOI:10.13451/j.sxu.ns.2024115

## 0 引言

由于风是不对称流动的,且受气候和天气状况不断变化的影响较大,使得风能具有间歇和波动的固有属性,导致风电功率预测具有非线性、强波动性等特点,因此难以提升风电功率预测的准确性。国内外学者做了大量有关提升风电功率预测精度方面的研究,提出了各种不同的预测模型。程江涛等<sup>[1]</sup>提出了一种基于变分模态分解的生成对抗网络(Generative Adversarial Network, GAN)模型,该模型由变分模态分解与注意力机制、长短期记忆神经网络结合作为生成器,卷积神经网络作为判别器,并利用李普希茨连续条件对判别器进行限制,以提高模型稳定性。Shahid等<sup>[2]</sup>利用遗传算法的生物启发框架的优势,控制长短期记忆神经网络(Neural Networks for Long and Short Term Memory, LSTM)层的窗口大小和神经元数目的优化,将遗传长短期神经(Genetic LSTM, GLSTM)的误差度量与基线性回归量和现有深度学习技术进行了比较,提高了预测精度。Zhang等<sup>[3]</sup>提出了一个深度学习模型(LSTM),结合气象数据进行短期风功率预测,显著提高了预测精度。Zhen等<sup>[4]</sup>提出了一个混合方法,首先使用特征选择技术从气象数据中提取关键特征,然后应用深度学习模型(如LSTM)进行风功率预测。针对LSTM网络在长序列数据中的不足,Ren等<sup>[5]</sup>提出了基于CNN-LSTM-LightGBM(Convolutional Neural Network-Long Short-term Memory-light Gradient Boosting Machine)结合注意力机制的混合深度学习模型,实现了预测精度的显著提升。Zhang等<sup>[6]</sup>提出了一种二阶段混合模型,结合了长短期记忆网络(LSTM)和集成经验模态分解(Empirical Mode Decomposition, EMD)。该模型通过先使用EEMD对风电功率数据进行分解,再利用LSTM进行预测,有效提高了预测精度和稳定性。González等<sup>[7]</sup>采用了一种人工神经网络到脉冲神经网络(Artificial Neural Network to Spiking Neural Network, ANN-to-SNN)转换方法来预测风电功率并使用神经形态硬件Loihi模拟或运行尖峰模型来获得更好的预测效果。Li等<sup>[8]</sup>提出了循环神经网络(Recur-

rent Neural Network, RNN)与门控循环单元(Gated Recurrent Unit, GRU)结合的组合预测模型,来预测德国每天( $t+1$ )和多步( $t+3$ 、 $t+5$ 和 $t+12$ )小时之前的风功率数据,在长序列上具有较快的学习速度。Lu等<sup>[9]</sup>提出了一种基于白鲸优化算法优化的变分模态分解和时序卷积网络双向门控循环单元联合构建的短期风力发电预测模型,将时间序列分解进而提高模型特征提取能力。针对高维输入的处理,Wan等<sup>[10]</sup>提出了结合小波变换与神经网络的混合模型,显著提高了短期预测的稳定性。对于数据的预处理与特征选择,Mi等<sup>[11]</sup>通过结合小波分解和极限学习机(Extreme Learning Machine, ELM),成功解决了风速数据的噪声问题,增强了模型对风电功率的预测能力。Guo等<sup>[12]</sup>则利用经验模态分解(Empirical Mode Decomposition, EMD)与神经网络的结合,实现了风速的多步预测,为风功率预测模型的构建提供了新思路。针对多步预测的研究,Deng等<sup>[13]</sup>引入领域适应与深度学习相结合的方法,有效提升了预测精度。时空图卷积神经网络(Spatio-Temporal Graph Convolutional Networks, ST-GCN)<sup>[14]</sup>结合了图卷积网络(GCN)和时间卷积网络,能够同时建模交通数据的空间和时间依赖关系,可用于风电场功率预测建模。

智能学习算法中,RNN的变体长短期记忆网络(LSTM)是风功率预测的常用方法,但其存在只能处理短序列时间序列和训练过程中会出现梯度爆炸等问题。Vaswani等<sup>[15]</sup>提出了一种新型网络架构Transformer,该方法可弥补上述循环神经网络存在的短板。但Transformer中所有自注意层直接堆叠在一起,增加了网络架构的内存占用量。Autoformer<sup>[16]</sup>是一种针对时间序列预测的自注意力网络架构,该模型通过引入自适应时间卷积机制来捕捉时间序列中的周期性和趋势性,从而增强了Transformer在处理时间序列数据时的灵活性和效率。Reformer<sup>[17]</sup>是一种改进型Transformer模型,主要通过引入局部敏感哈希和可逆层设计来减少计算复杂度和内存占用。从而在处理长序列数据时显著提高了模型的效率和可扩展性。Crossformer<sup>[18]</sup>结合了Transformer的自

注意力机制与交叉时间建模技术。该模型通过引入交叉时间编码器,能够有效捕捉时间序列数据中的长期和短期依赖关系。Zhou等<sup>[19]</sup>在其基础上提出了一种新的网络架构——Informer,该神经网络架构通过引入多层次的注意力机制和优化内存计算效率,提高模型在时间序列预测任务的性能。Informer是超短期风功率预测的理想选择,因为它通过多层次自注意力机制和稀疏自注意力机制,能够高效地捕捉风功率数据中的长短期依赖关系,同时显著减少计算复杂度和内存消耗。这种设计使得Informer能够快速处理大量历史数据,并提供高精度的实时预测,特别适合于风功率的瞬时变化和短期波动。

为了进一步提高风电功率预测的准确性,本研究提出了一种结合了Informer网络架构和马尔可夫链的风电功率预测模型。Informer网络通过其高效的自注意力机制有效解决了传统神经网络在处理长时间序列数据时的效果差、输入序列长度限制以及在处理大规模数据时的内存和计算效率问题。然而,尽管Informer在捕捉时间序列中的复杂模式和依赖关系方面表现出色,但它的预测结果仍可能受到模型误差和不确定性的影响。为了进一步提升预测精度,本研究引入了马尔可夫链作为一种后处理方法。马尔可夫链能够对预测结果进行误差修正,利用其在状态转移建模方面的优势,根据风电功率的历史数据和预测误差的概率特性进行动态调整。通过这种结合,模型不仅能够更准确地捕捉风电功率的时间依赖关系,还能有效地校正预测误差,从而提高整体预测的可靠性和精度。

本文以我国华北某平原风电场作为研究对象,将基于Informer的超短期风电功率预测模型在风电场的实际预测效果分别与基于SVR、AM-LSTM的超短期风功率预测模型的预测结果进行对比分析,算例分析表明,所提出的预测模型能够有效提升风电功率预测的精度,具有广泛的适用性。

## 1 相关性分析

### 1.1 风速

风力发电是将风能转化为电能的过程。流动的风带动风机叶片转动,后带动与风机叶片

连接的主轴转动,再经过风机机舱内的齿轮箱变速,之后发电机转子开始动作,发电机开始出力,以上是风力机组发电的基本过程。在理想状况下,风电机组的实际风功率 $P$ 随瞬时风速 $V$ 的大小变化而变化,如式(1)所示。

$$P = \frac{1}{2} C_p A \rho V^3, \quad (1)$$

其中 $P$ 为风电机组的实际输出功率,单位是kW; $C_p$ 为风能利用系数; $A$ 为风轮叶片转动所形成的面积,单位是 $m^2$ ; $\rho$ 为空气密度,标况下( $0^\circ C$  101 325 Pa),空气密度约为 $1.29 kg/m^3$ ; $V$ 为瞬时风速,单位是 $m \cdot s^{-1}$ 。

根据图1可以看出,风力发电机组的输出功率在趋势走向上与流过风力发电机组的瞬时风速变化趋势基本保持一致,由此也可看出风力发电机组的瞬时风速和输出功率不仅在数值上呈现正相关关系,而且在时序性和波动性上也呈现正相关关系。

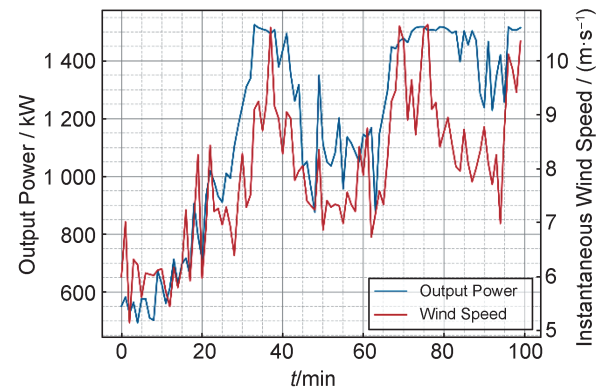


图1 输出功率与瞬时风速时序对比

Fig. 1 Comparison between output power and instantaneous wind speed timing

### 1.2 风向

由图2可以看出,从时序性和波动性方面来看,瞬时风向的变化趋势与输出功率的变化趋势无较大相关性,仅从瞬时风向的变化难以得出其对风电机组输出功率波动的影响。但是,由于风机对正向气流风能的转化效率最高,而风轮截面又不可能时时刻刻正对着风向,所以现有的风力发电机组都装载有偏航技术,来不断调整风轮,使其与风向正对。但从偏航装置控制效果来看,从偏航指令下达达到风力发电机组开始偏航存在着一定的延迟时间,导致瞬时风向与风力发电机组的机舱方向之间存在夹角,称该角为偏航延迟

角。图1和图2中数据来自华北某平原风电场的2022年全场单机SCADA系统(数据采集与监视控制系统)数据集,其中包括该风电场历史风机出力功率、风速、风向等特征量。




图2 输出功率与瞬时风向时序性对比

Fig. 2 Comparison between output power and instantaneous wind direction timing

表1 地面粗糙度的常用系数

Table1 Common coefficients of ground roughness

地面覆盖物	地面粗糙度
水面和光滑冰面(风速越大地面粗糙度越大)	一般情况下为0.001
石头路面	0.05
草场	0.2
城郊区	0.6
森林和城市区	1~5

1.3 其他因素

风电机组的安装位置和环境也会影响风力发电机组的出力。风电机组所处安装位置和环境的地面粗糙度主要与地形、地面覆盖物等因素有关<sup>[20]</sup>,当地面粗糙度较高时,地面上的气流就会受到阻挡,风速就会减小;当地面粗糙度较低时,地面对气流的阻力就会减弱,对风速的削弱也会减小,从而影响风力发电机

组的出力。表1为地面粗糙度的常用系数。

2 基于Informer的超短期风功率预测模型

2.1 Informer网络架构的稀疏概率自注意力机制

稀疏概率自注意力机制(Sparse Probabilistic Self-Attention Mechanism)通过引入稀疏矩阵和概率选择方法,以降低自注意力机制的计算复杂度和内存消耗。该方法采用局部敏感哈希(Locality-Sensitive Hashing, LSH)或其他概率模型,仅选择与查询向量相关性较大的键向量进行相似度计算,从而将计算复杂度降低。此改进显著提升了长序列和大规模数据处理的效率,确保稀疏矩阵仍能有效捕捉关键相关性信息。

从原理上来说,Informer中的稀疏概率自注意力机制实质上是Transformer中的注意力矩阵转化为稀疏注意力矩阵而得<sup>[21]</sup>。自注意力机制有三个输入:查询语句(query),关键字(key),值(value),之后再进行矩阵乘积运算,从而得到自注意力机制的计算式为:

$$A(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right) \quad (2)$$

公式(2)中Q、K、V为历史数据集中输入模型的变量经过运算得到的同型矩阵,Q为查询语句矩阵,K为关键字矩阵,V为值矩阵;d为Q、K、V生成向量空间的维数。

Informer稀疏性原理认为,对注意力有杰出贡献的点积对会使得其相对的查询注意力稀疏概率分布“疏远”均匀分布。稀疏概率自注意力机制原理图如图3所示。

2.2 Informer网络架构的蒸馏机制

Informer的蒸馏机制主要包括三个部分<sup>[22]</sup>:卷积层(1D Convolutional Layer, Conv1d)、

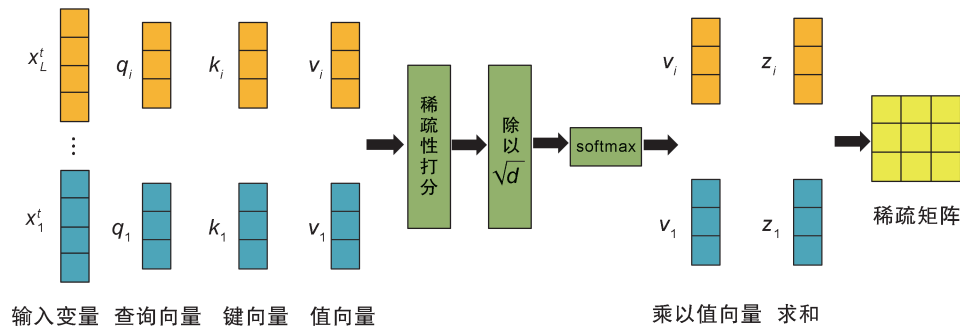


图3 稀疏概率自注意力机制原理

Fig. 3 The principle of sparse probabilistic self-attention mechanism

激活函数 (Activation Function) 和池化层 (Pooling Layer)。

(1) 卷积层表示在某区间内, 两变量相乘并求和的过程, 其原理可用公式表示为:

$$h(x) = \int_{-\infty}^{+\infty} f(X)g(x-X)dX, \quad (3)$$

其中  $h(x)$  称为函数  $f$  和  $g$  的卷积, 在 Informer 神经网络架构中使用的主要为一维卷积层, 其作用主要是降低输入变量数据的维度。

(2) 本文选取 ELU 函数作为 Informer 超短期风功率预测模型的激活函数。在 Informer 预测模型中加入 ELU 函数的原因是其能够加快模型训练<sup>[23]</sup>, 同时又能够提高模型的稳定性。

$$\text{ELU}(x) = \begin{cases} \exp(x) - 1, & x < 0, \\ x, & x \geq 0. \end{cases} \quad (4)$$

(3) 池化层主要有两种模式: 平均池化模式和最大池化模式, 池化层通常加在卷积层之后, 本文池化层主要采用最大池化模式, 其作用主要为压缩输入变量的数据量, 避免在进行点积运算过程中占用过多内存, 引起模型训练速度变得迟缓, 在一定程度上还能提高模型的泛化性。

本文主要选用一层卷积层, ELU 作为激活函数, 最大池化层组成 Informer 的蒸馏机制。实现“蒸馏作用”的数学原理可以用公式表示为:

$$\chi_{j+1} = \text{MaxPool}\left(\text{ELU}\left(\text{Conv1d}\left([\chi_j]_{AB}\right)\right)\right), \quad (5)$$

其中  $\chi_{j+1}, \chi_j$  表示从  $j$  层到  $j+1$  层的蒸馏作用,  $[\cdot]_{AB}$  表示除多头稀疏概率自注意力操作以外的其他操作。

### 2.3 Informer 网络架构的编码器和译码器

Informer 的编码器能够提取出长期时间序列中输入-输出之间长时间的交互关系<sup>[24]</sup>, 将输入的变量数据转化为全连接的特征图, 如图 4 所示。

Informer 的译码器是一种一步到位式的译码器, 其通过接收来自编码器的特征量以及外部输入变量, 再经过一个全连接层, 以此来实现一步输出所有的预测结果, 如图 5 所示。

### 2.4 基于马尔可夫链的超短期风功率预测误差修正

1907 年, 马尔科夫开创了分析对象当前状态及其状态变化规律的理论, 其被称为马尔科夫过程<sup>[25]</sup>。通过马尔科夫链对 Informer 超短期风功率预测结果进行误差修正, 进而得到最终修正后

的预测风功率数据<sup>[26]</sup>。具体流程如下:

(1) 计算 Informer 超短期风功率预测模型的预测误差  $e_i$ , 如式 (6), 其中  $Y_i$  为第  $i$  个实际风功率数据,  $Y'_i$  为第  $i$  个预测风功率数据,  $i = 1, 2, \dots, n$  ( $n$  是数据长度):

$$e_i = Y_i - Y'_i. \quad (6)$$

(2) 选用模糊 C 均值聚类方法将式 (1) 中的预测误差序列划分为  $c$  类, 并得出聚类序列  $l = \{l_1, l_2, \dots, l_c\}$  和聚类中心序列  $\delta = \{\delta_1, \delta_2, \dots, \delta_c\}$ 。

(3) 建立马尔科夫链的状态序列, 写作  $L = \{L_1, L_2, \dots, L_c\}$ , 其中  $L_c = [L_{1j}, L_{2j}]$  且  $L_{2j} = \frac{(\max l_j + \min l_{j+1})}{2}$ 。

(4) 结合步骤 (3) 中的状态序列, 求得  $k$  步状态转移概率矩阵  $P^{(k)}$ , 如式 (7) 和式 (8), 其中  $M_{ij}$  为状态  $i$  使用  $k$  步到达状态  $j$  的回数,  $M_i$  为状态  $j$  的回数:

$$P^{(k)} = \begin{pmatrix} P_{11}^{(k)} & P_{12}^{(k)} & \dots & P_{1c}^{(k)} \\ P_{21}^{(k)} & P_{22}^{(k)} & \dots & P_{2c}^{(k)} \\ \vdots & \vdots & \vdots & \vdots \\ P_{c1}^{(k)} & P_{c2}^{(k)} & \dots & P_{cc}^{(k)} \end{pmatrix}, \quad (7)$$

$$P_{ij}^{(k)} = \frac{M_{ij}^{(k)}}{M_i^{(k)}}. \quad (8)$$

(5) 求得第  $n, n-1, \dots, n-k+1$  个风功率预测误差所处的状态  $E = E_1, E_2, \dots, E_k$ , 结合  $P^{(k)}$  算出这  $k$  个状态到达第  $n+1$  个风功率预测误差对应状态的概率, 进而求得状态计算矩阵  $Q$ :

$$Q(r, j) = P^{(r)}(E, j). \quad (9)$$

(6) 求解  $e_i$  的  $r$  阶自相关系数  $d_r$ , 式中  $\hat{e}$  为预测误差序列  $e_i$  的均值,  $\hat{e}$  为预测误差序列  $e_{i+r}$  的均值:

$$d_r = \frac{\sum_{i=1}^{n-r} (e_i - \hat{e})(e_{i+r} - \hat{e})}{\sqrt{\sum_{i=1}^{n-r} (e_i - \hat{e})^2} \sqrt{\sum_{i=1}^{n-r} (e_{i+r} - \hat{e})^2}}. \quad (10)$$

(7) 对  $d_r$  进行归一化处理, 并将  $d_r$  作为马尔科夫链的权重系数:

$$\omega_r = \frac{|d_r|}{\sum_{r=1}^c |d_r|}. \quad (11)$$

(8) 求解状态转移概率预测矩阵  $P'$ :

$$P' = \sum_{i=1}^n \omega_i P_i. \quad (12)$$

(9) 计算预测误差修正值, 将概率最大的状

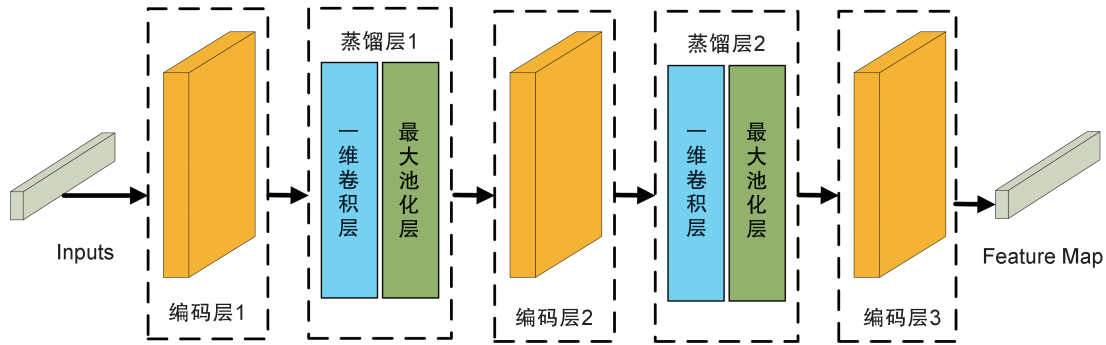


图4 Stack网络结构

Fig. 4 Structure of stack network

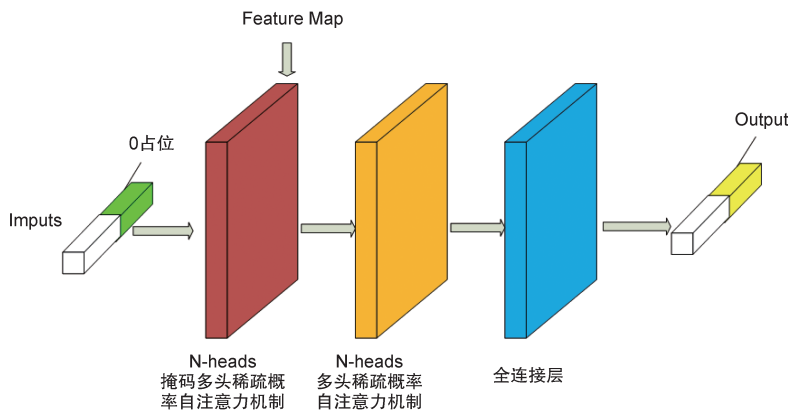


图5 译码器的网络结构

Fig. 5 The network structure of the decoder

态作为风功率预测误差所处的状态,可以求解出该状态下的风功率预测误差修正值:

$$\Delta e = \begin{cases} \frac{L_{2j}J}{(j+0.5)}, & |J-j| \leq 0.5 \text{ 且 } J > j \\ \frac{L_{1j}J}{(j-0.5)}, & |J-j| \leq 0.5 \text{ 且 } J \leq j \\ 0, & |J-j| > 0.5 \end{cases} \quad (13)$$

$$J = \sum_{j=1}^c j \times \frac{P(j)^2}{\sum_{j=1}^c P(j)^2} \quad (14)$$

(10) 风功率预测误差修正值与风功率预测值之和即为修正后的风功率预测值:

$$Y'' = Y' + \Delta e \quad (15)$$

将马尔科夫链引入 Informer 模型在超短期风功率预测中具有显著优势。马尔科夫链能够有效捕捉风速和风功率的局部状态变化,通过建模状态转移概率提供对短期趋势的精确预测。这种状态转移矩阵的引入,使得 Informer 模型能够获得更多的先验信息,从而增强其对短

期风功率波动的响应能力。马尔科夫链能够量化不同状态之间的转移概率,提供了一种有效的方式来描述风速和风功率的状态转移规律,弥补了 Informer 模型在捕捉短期变化上的不足。马尔科夫链计算简单高效,能够在不显著增加计算复杂度的前提下提升预测性能,并增强模型对突发变化的适应能力,从而提高预测的鲁棒性和准确性。这些优势使得马尔科夫链和 Informer 模型的结合在风功率预测中具有广泛的应用前景。基于马尔科夫链误差修正的 Informer 超短期风功率预测具体流程如下图6所示。

### 3 算例分析

#### 3.1 基于 Informer 的风功率预测结果分析

采用华北某平原风电场的2022年全场单机 SCADA 系统(数据采集与监视控制系统)数据集,其中包括该风电场历史风机出力功率、风速、风向等特征量。Informer 超短期风功率预测模型初始超参数设置:输入窗口大小为10,输出窗口大小为1,批次处理大小为32, Informer

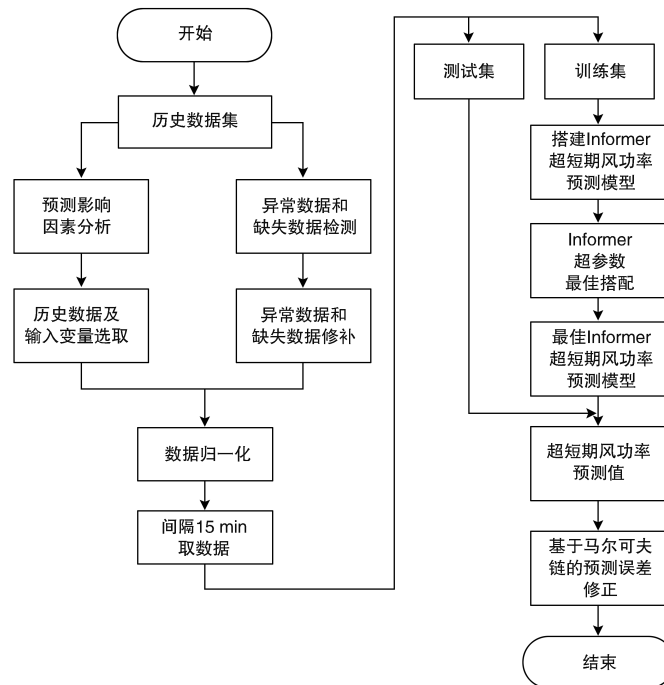


图6 基于马尔可夫链误差修正Informer的超短期风功率预测流程图

Fig. 6 Flow chart of ultra short term wind power prediction based on MC-Informer

网络架构的自注意力机制头数为10,网络层数为1,时间步长为32,特征图大小为250,随机失活率为0,学习率为0.005,Informer网络架构迭代次数为100。本文中采用了孤立森林算法对历史运行数据集中的异常数据进行检测。孤立森林算法时常用于具有连续性特性的数据集进行异常检测的机器学习算法。孤立森林算法通过随机选择 $m$ 个数据特征,随后在所选特征中随机选择一个特征来分割数据。当一个数据需要被分割很多次后才能与其他数据分离开时,则证明这个数据为正常数据;而当一个数据只需要被分割寥寥几次后就能与其他数据分离开时,则证明这个数据为异常数据。本节使用常用来进行数据分析和数据挖掘的python编程语言,利用其自带函数库中的孤立森林函数对数组中的瞬时风速和实际输出功率两个要素进行异常检测。本文采用拉格朗日插补法对异常数据和缺失数据进行插补,拉格朗日插补法是一种基于曲线拟合原理的修补法。该方法通过构造拉格朗日函数,使用历史运行数据集中已有数据点来拟合出该函数的曲线图,继而得到该函数的各项常数,之后再讲异常数据和缺失数据对应的数据点位代入拉格朗日函数中,进而求解出异常数据或者缺失数据的值。该方法

对历史运行数据这种具有非线性的数据集有很好的拟合效果,修补数据与实际运行生产数据差距较小,降低了异常数据和缺失数据对预测结果的影响。

Informer超短期风功率预测模型经过100次迭代训练后,得到了预测效果最佳的预测模型,继而再凭借测试数据集对Informer超短期风功率预测模型进行验证,并将预测结果与SVR、AM-LSTM两种风电功率预测模型的预测结果进行对比分析,如图7所示。

表2给出了以上三种超短期风功率预测模型的各项模型评价指标。可得出基于Informer

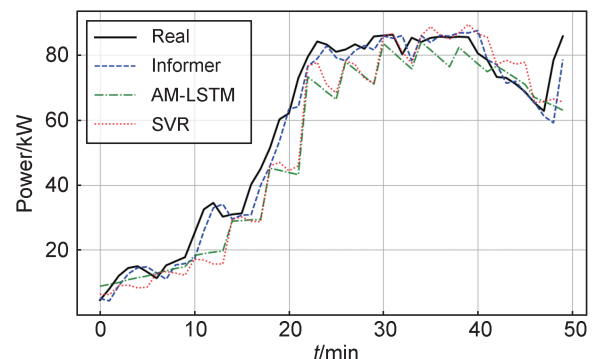


图7 三种超短期风功率预测模型结果对比

Fig. 7 Comparison of results among three ultra short term wind power prediction models

超短期功率预测模型的预测准确率更高,预测效果更佳。

表2 三种超短期风功率预测模型的各项模型评价指标  
Table 2 Evaluation indicators of three ultra short term wind power prediction models

评价指标	Informer	LSTM	SVR
平均绝对误差(MAE)	0.065	0.112	0.148
均方根误差(RMSE)	0.100	0.186	0.253
平均绝对百分比误差(MAPE)	0.113	0.143	0.361
拟合优度( $R^2$ )	0.961	0.861	0.702
准确率(Acc')	0.961	0.861	0.702

### 3.2 Informer 超短期风功率预测模型的泛化性验证

本节通过将华北某平原风电场2020年全年历史运行数据分为四个季度,并在四个季度中随机各抽取一个月历史运行数据,以此来测试Informer超短期风功率预测模型的泛化性能力。经过历史数据集所分出20%的数据作为测试集数据测试后,随机在四个季度中随机各选取一个月,得到图8,分别为3月份、5月份、9月份、10月份的Informer超短期风功率预测模型与其他两种对比模型的泛化性测试结果。

从以上四个月测试结果可以看出,本文模型较AM-LSTM、SVR两种对比模型具有更好的泛化性能和鲁棒性。Informer超短期风功率预测模型月平均预测准确率分别为90.53%、97.44%、95.73%、96.21%。在气象状况较为平缓,Informer超短期风功率预测模型的误差相对较小;而在气象状况由平稳状态向激烈状态变化,或者由激烈状态向平稳状态变化时,Informer超短期风功率预测模型的预测曲线与实际风功率变化曲线几乎重叠。可以看出Informer超短期风功率预测模型在这四个月的预测效果较佳,充分证明了本文采用的Informer超短期风功率预测算法具有较高的稳定性和泛化性。表3中给出了2020年12个月Informer超短期风功率预测模型的各项模型评价指标。

由上表可知,采用Informer超短期风功率预测算法,预测出该华北平原风电场在2020年全年12个月的超短期风功率预测准确率皆达到了90%以上,年平均准确率更是达到了95.2%,充分证明了本文采用的Informer超短期风功率预测算法所建立的预测模型具有较高的稳定性和泛化性。

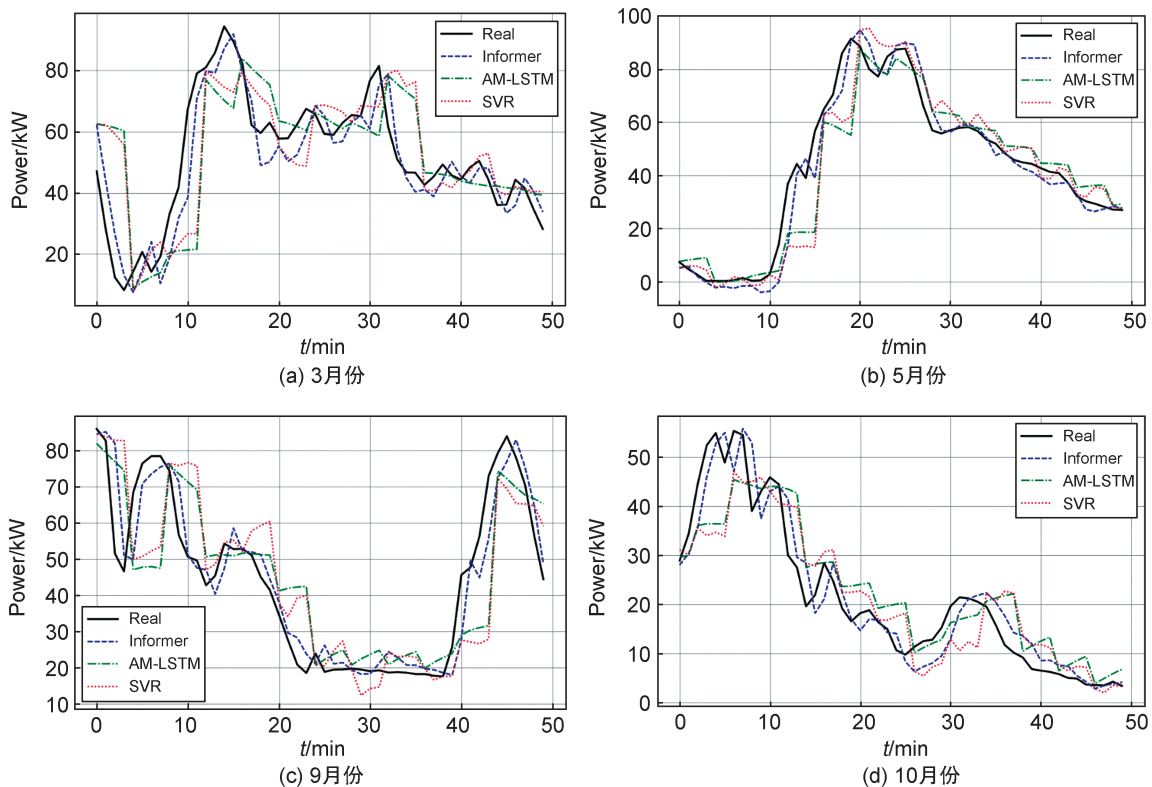


图8 不同月份的超短期风功率预测效果

Fig. 8 The forecasting performance of ultra-short-term wind power in different months

表3 2020年12个月Informer超短期风功率预测模型的各项模型评价指标

Table 3 Evaluation indexes of Informer ultra-short-term wind power prediction model for 12 months in 2020

评价指标	MAE	RMSE	MAPE	$R^2$	Acc'
1月	0.074	0.143	0.100	0.959	0.959
2月	0.105	0.256	0.375	0.936	0.936
3月	0.513	0.641	0.896	0.905	0.905
4月	0.347	0.458	0.532	0.940	0.940
5月	0.043	0.075	0.089	0.974	0.974
6月	0.103	0.185	0.203	0.951	0.951
7月	0.076	0.114	0.131	0.955	0.955
8月	0.184	0.237	0.361	0.949	0.949
9月	0.072	0.176	0.115	0.957	0.957
10月	0.065	0.100	0.113	0.961	0.961
11月	0.050	0.089	0.093	0.967	0.967
12月	0.042	0.077	0.071	0.977	0.977
均值	0.140	0.213	0.257	0.952	0.952

通过搭建Informer超短期风功率预测马尔科夫链误差修正模型,可以得到修正后的风功率预测值。图9为Informer超短期风功率预测误差修正前与修正后的时序对比图,可得出基于马尔科夫链的预测误差修正方法减小了Informer预测风功率与实际风功率之间的偏差,进一步提高了本文Informer超短期风功率预测模型的预测准确率。

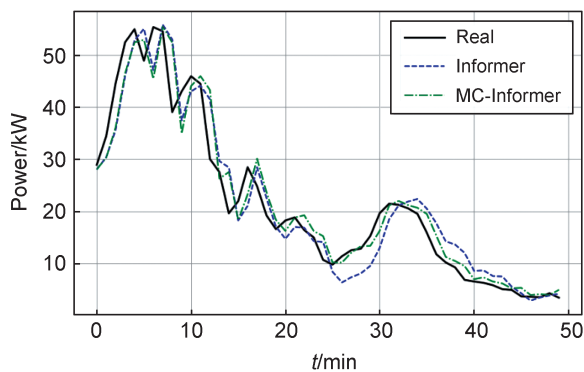


图9 超短期风功率预测误差修正前后对比

Fig. 9 Comparison of pre- and post-correction errors in ultra short term wind power prediction

表4为修正之后的Informer超短期风功率预测各项模型评价指标。

#### 4 结论

本文以中国华北某平原风电场为研究对象,建立了基于Informer网络架构的超短期风功率预

表4 修正之后的Informer超短期风功率预测各项模型评价指标

Table 4 Evaluation indexes of various models of Informer ultra-short-term wind power prediction after modification

评价指标	MAPE	$R^2$	Acc'
修正后	0.057	0.971	0.971
修正前	0.113	0.961	0.961

测模型。首先从时序层面和理论层面对多种影响超短期风功率因素进行详细分析,并且以此为据,从历史运行数据中确定了本文超短期风功率预测模型的输入变量。之后将预测结果与SVR、AM-LSTM模型预测结果进行对比分析,证明了所提出模型的有效性。最后采用基于马尔科夫链的预测误差修正方法,经过修正后的Informer超短期风功率预测更贴合实际生产运行风功率数据,证实了基于马尔科夫链的预测误差修正可进一步提高预测模型的准确率。

#### 参考文献:

- [1] 程江涛,王灵梅,孟恩隆,等.基于VMD-AM-WGAN的超短期风电功率预测[J].机械设计与制造工程,2022,51(10):120-124. DOI: 10.3969/j.issn.2095-509X.2022.10.025. CHENG J T, WANG L M, MENG E L, et al. Ultra-short-term Wind Power Prediction Based on VMD-AM-WGAN[J]. *Mach Des Manuf Eng*, 2022, 51(10): 120-124. DOI: 10.3969/j.issn.2095-509X.2022.10.025.
- [2] SHAHID F, ZAMEER A, MUNEEB M. A Novel Genetic LSTM Model for Wind Power Forecast[J]. *Energy*, 2021, 223: 120069. DOI: 10.1016/j.energy.2021.120069.
- [3] ZHANG W, WANG J, WANG J, et al. Short-term Wind Speed Forecasting Based on a Hybrid Model[J]. *Appl Soft Comput*, 2013, 13(7): 3225-3233.
- [4] ZHEN H, NIU D, YU M, et al. A Hybrid Deep Learning Model and Comparison for Wind Power Forecasting Considering Temporal-spatial Feature Extraction[J]. *Sustainability*, 2020, 12(22): 9490. DOI: 10.3390/su12229490.
- [5] REN J, YU Z P, GAO G L, et al. A CNN-LSTM-LightGBM Based Short-term Wind Power Prediction Method Based on Attention Mechanism[J]. *Energy Rep*, 2022, 8: 437-443. DOI: 10.1016/j.egy.2022.02.206.
- [6] ZHANG X K, ZHANG Q W, ZHANG G, et al. A Novel Hybrid Data-driven Model for Daily Land Surface Temperature Forecasting Using Long Short-term Memory Neural Network Based on Ensemble Empirical Mode Decomposition[J]. *Int J Environ Res Public Health*, 2018, 15(5): 1032. DOI: 10.3390/ijerph15051032.

- [7] GONZÁLEZ SOPEÑA J M, PAKRASHI V, GHOSH B. A Spiking Neural Network Based Wind Power Forecasting Model for Neuromorphic Devices[J]. *Energies*, 2022, **15**(19): 7256. DOI: 10.3390/en15197256.
- [8] LI M L, YANG M, YU Y X, *et al.* A Wind Speed Correction Method Based on Modified Hidden Markov Model for Enhancing Wind Power Forecast[J]. *IEEE Trans Ind Appl*, 2022, **58**(1): 656–666. DOI: 10.1109/TIA.2021.3127145.
- [9] LU J, ZHANG Y, WANG R. Short-term Wind Power Forecasting Based on BWO-VMD and TCN-BiGRU[J/OL]. *Eng Sci Technol*, 2024: 1–14. <http://kns.cnki.net/kcms/detail/51.1773.TB.20240604.1704.013.html>.
- [10] WAN C, XU Z, PINSON P, *et al.* Optimal Prediction Intervals of Wind Power Generation[J]. *IEEE Trans Power Syst*, 2014, **29**(3): 1166–1174. DOI: 10.1109/TPWRS.2013.2288100.
- [11] MI X W, LIU H, LI Y F. Wind Speed Forecasting Method Using Wavelet, Extreme Learning Machine and Outlier Correction Algorithm[J]. *Energy Convers Manag*, 2017, **151**: 709–722. DOI: 10.1016/j.enconman.2017.09.034.
- [12] GUO Z H, ZHAO W G, LU H Y, *et al.* Multi-step Forecasting for Wind Speed Using a Modified EMD-based Artificial Neural Network Model[J]. *Renew Energy*, 2012, **37**(1): 241–249. DOI: 10.1016/j.renene.2011.06.023.
- [13] DENG X, SHAO H J, HU C L, *et al.* Wind Power Forecasting Methods Based on Deep Learning: A Survey[J]. *Comput Model Eng Sci*, 2020, **122**(1): 273–301. DOI: 10.32604/cmesci.2020.08768.
- [14] YU B, YIN H T, ZHU Z X. Spatio-temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting[EB/OL]. (2018-07-18) [2024-02-10]. <https://arxiv.org/abs/1709.04875>.
- [15] VASWANI A, SHAZEER N, PARMAR N, *et al.* Attention is All You Need[J]. *Advances in Neural Information Processing Systems*, 2017, 30. DOI: 0.7503/cjcu20150344.
- [16] WU H, XU J, WANG J, *et al.* Autoformer: Decomposition Transformers with Auto-correlation for Long-term series Forecasting[J]. *Adv Neural Inf Process Syst*, 2021, **34**: 22419–22430.
- [17] KITAEV N, KAISER Ł, LEVSKAYA A. Reformer: The Efficient Transformer[EB/OL]. (2020-02-18) [2024-02-10]. <https://arxiv.org/abs/2001.04451>.
- [18] WANG W, CHEN W, QIU Q, *et al.* CrossFormer++: A Versatile Vision Transformer Hinging on Cross-scale Attention[J]. *IEEE Trans Pattern Anal Mach Intell*, 2024, **46**(5): 3123–3136. DOI: 10.1109/tpami.2023.3341806.
- [19] ZHOU H Y, ZHANG S H, PENG J Q, *et al.* Informer: Beyond Efficient Transformer for Long Sequence Time-series Forecasting[J]. *Proc AAAI Conf Artif Intell*, 2021, **35**(12): 11106–11115. DOI: 10.1609/aaai.v35i12.17325.
- [20] 张琳琳, 李杰. 脉动风速互随机Fourier谱函数[J]. *建筑科学与工程学报*, 2006, **23**(2): 57–61. DOI: 10.3321/j.issn:1673-2049.2006.02.008.
- ZHANG L L, LI J. Cross Stochastic Fourier Spectrum Function of Turbulence Wind Velocity[J]. *J Archit Civ Eng*, 2006, **23**(2): 57–61. DOI: 10.3321/j.issn:1673-2049.2006.02.008.
- [21] 贺春光, 韩光, 赵阳, 等. 双碳背景下计及新能源大规模接入的电量趋势预测与分析[J]. *可再生能源*, 2022, **40**(11): 1554–1562. DOI: 10.3969/j.issn.1671-5292.2022.11.020.
- HE C G, HAN G, ZHAO Y, *et al.* Prediction and Analysis of Electric Quantity Trend Including Large-scale Access of New Energy under Dual Carbon Background[J]. *Renew Energy Resour*, 2022, **40**(11): 1554–1562. DOI: 10.3969/j.issn.1671-5292.2022.11.020.
- [22] HUANG X H, JIANG A H. Wind Power Generation Forecast Based on Multi-step Informer Network[J]. *Energies*, 2022, **15**(18): 6642. DOI: 10.3390/en15186642.
- [23] From Natural to Artificial Neural Computation: International Workshop on Artificial Neural Networks Malaga-Torremolinos, Spain, June 7–9, 1995 Proceedings[M]. Berlin, Heidelberg: Springer Berlin Heidelberg, 1995. DOI: 10.1007/3-540-59497-3.
- [24] 潘立群, 吴中华, 洪标. 基于核技巧改进的Informer模型的长序列时间序列预测方法[J]. *计算机科学*, 2023, **50**(S2): 678–683. DOI: 10.11896/jsjcx.221100186.
- PAN L Q, WU Z H, HONG B. Long Time Series Forecasting Method Based on Improved Informer Model Using Kernel Technique[J]. *Comput Sci*, 2023, **50**(S2): 678–683. DOI: 10.11896/jsjcx.221100186.
- [25] KEILSON J. Markov Chain Models--Rarity and Exponentiality[R]. Berkeley: California Univ Berkeley Operations Research Center, 1974.
- [26] 高淑杰, 田建艳, 王芳. 基于MC的风电场参数预测模型的误差修正[J]. *电子技术应用*, 2016, **42**(7): 114–118. DOI: 10.16157/j.issn.0258-7998.2016.07.029.
- GAO S J, TIAN J Y, WANG F. Error Correction of Parameter Forecasting Model of Wind Farm Based on Markov Chain[J]. *Appl Electron Tech*, 2016, **42**(7): 114–118. DOI: 10.16157/j.issn.0258-7998.2016.07.029.