

# 基于时变深度前馈神经网络的风电功率概率密度预测

彭曙蓉<sup>1</sup>, 彭家宜<sup>1</sup>, 杨云皓<sup>2</sup>, 张恒<sup>1</sup>, 李彬<sup>1</sup>, 王冠南<sup>3</sup>

(1.长沙理工大学电气与信息工程学院,湖南长沙 410114;2.浙江大学计算机科学与技术学院,浙江杭州 310058;  
3.国网江西省电力有限公司电力科学研究院,江西南昌 330006)

**摘要:**针对传统循环神经网络(RNN)和卷积神经网络(CNN)模型对风电功率进行较长时间尺度的短期预测时出现的时不变性问题,应用时变深度前馈神经网络(ForecastNet)模型进行短期风电功率不确定性预测。该模型的网络结构随时间变化以提高多步提前预测能力,模型交错输出以缓解梯度消失问题,使用混合密度网络得到各个时刻的概率密度分布。在避免传统深度学习模型中,该模型能避免递归多步预测累积误差的同时可以充分考虑相邻时刻风电功率的相关性;在模型隐藏层中,使用美国PJM网上的风电功率实际数据,分别应用全连接网络、卷积神经网络以及基于注意力机制的卷积神经网络3种神经网络模型进行预测,每次预测未来12h的风电功率,滚动预测得到未来500h的风电功率区间和概率密度,实验仿真结果能够证明所提预测模型的有效性。

**关键词:**神经网络;风电功率预测;时变深度前馈神经网络;概率密度;风电功率区间预测

DOI:10.19781/j.issn.1673-9140.2023.03.009 中图分类号:TM61 文章编号:1673-9140(2023)03-0084-10

## Wind power probability density prediction based on time-variant deep feed-forward neural network

PENG Shurong<sup>1</sup>, PENG Jiayi<sup>1</sup>, YANG Yunhao<sup>2</sup>, ZHANG Heng<sup>1</sup>, LI Bin<sup>1</sup>, WANG Guannan<sup>3</sup>

(1.School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China;  
2.College of Computer Science and Technology, Zhejiang University, Hangzhou 310058, China; 3.Electric Power Research Institute, State Grid Jiangxi Electric Power Co., Ltd., Nanchang 330006, China)

**Abstract:** Traditional RNN and CNN models have the issue of the time-invariance problem when they are used to make short-term predictions of wind power on longer time scales. This paper proposed a short-term wind power uncertainty prediction method based on the time-variant deep feed-forward neural network architecture (ForecastNet) model. This method has a time-varying network structure to improve multi-step ahead prediction, and has an interlaced output capability to mitigate the gradient disappearance problem. The probability density distribution can be obtained by using mixture density network. This model not only avoids the cumulative error of recursive multi-step prediction in the traditional deep learning model, but also fully considers the correlation of wind power at adjacent moments. In the hidden layer of the model, the actual data of wind power from PJM network in the United States are used to test three kinds of neural network models, namely, fully connected network, convolutional network, convolutional network with attention

收稿日期:2022-05-01;修回日期:2022-10-25

基金项目:湖南省教育厅重点项目(20A021);国家自然科学基金面上项目(52177069)

通信作者:彭曙蓉(1975—),女,博士,副教授,主要从事智能电网中的信息处理研究;E-mail:1106131612@qq.com

mechanism. The wind power of the next 12 hours is predicted each time, and the range and probability density of wind power of the next 500 hours are obtained by rolling prediction. The results of the experimental simulations prove the effectiveness of the proposed prediction model.

**Key words:** neural network; wind power probability prediction; time-variant deep feed-forward neural network; probability density; interval prediction of wind power

进入21世纪以来,全球能源需求总量出现了强劲增长势头,由此引发了能源和环保2个事关人类社会未来发展的全球性热点问题。清洁低碳、安全高效已成为世界能源发展的主流方向。风电可作为规模庞大、技术先进成熟的绿色新能源,在全球能源板块的优化方面发挥着重要的作用,但是随着风电在电网中比例的提高,风电的随机性、波动性等缺点也逐步凸显,风力发电的随机性和不可控制性给电力系统的安全稳定运行带来了严峻的挑战。因此,提前准确预测风电功率对于提高电力系统的可靠性具有重大战略意义<sup>[1]</sup>。

按照预测模型的不同,预测方法可分为物理方法和统计方法。物理方法基于风电场内部及周边的地形、海拔高度等基础信息,利用数值天气预报数据,采用微观气象学理论或流体力学方法,通过列写方程组建立描述风电场风能资源分布特征的模型,模型复杂且不确定性因素较多<sup>[2]</sup>。相对于物理模型,统计学习方法在短期风电功率预测上预测精度较高。利用较长数据的历史风电功率数据进行规律挖掘的预测方法,利用学习算法在历史数据之间建立内部联系。根据最终预测结果形式的不同,统计学习模型种又分为点预测(确定性预测)和区间预测(不确定性预测),目前大多数风电功率预测技术为确定性预测,预测方法主要包含支持向量机、时间序列、神经网络<sup>[3-5]</sup>等。但需要指出的是:点预测不能对风电功率不确定性做出定量描述。在电网调度规划和运行风险评估领域中,不能只依据通过点预测得到的一个确定性的风电功率预测值,需要对风电功率的不确定性进行描述,即需要对其波动区间或概率分布有一个较为准确的预测<sup>[6]</sup>。不确定性预测是对未来时刻风电功率波动范围或概率密度的预测,风力发电十分依赖自然因素,容易受天气因素的影响,传统的点预测无法避免预测误差,不确定性预测的预测结果可以反映具体时刻风

电功率波动范围及其概率,主要包括区间预测和情景预测,其结果形式为某一置信度下的功率区间或者风电功率的概率密度函数。与确定性预测相比,不确定性预测能够量化风电功率的不确定性,给电力系统调度人员带来更加全面的决策依据<sup>[2]</sup>。国内外学者也进行了一些相关预测的研究,文献[7]利用风速波动特性与风电功率之间的对应关系,建立了不同风速波动类型下的短期风电功率预测模型;文献[8]针对具有偏态特征的风电功率预测误差分布,把区间分段方法和优化贝塔分布模型相结合,实现了风电功率的波动区间估计;文献[9]基于极限学习机(extreme learning machine, ELM)提出了一种新的风电功率概率预测方法,该方法是一种用于训练单隐藏层前馈神经网络的新型学习算法,考虑风电时间序列的异方差性构建预测区间,用澳大利亚风电场的测量数据进行仿真分析,证明了所提方法的有效性;文献[10]提出混合t Location-scale分布的风电功率超短期预测误差分布模型,通过改进K-means聚类算法确定模型参数,对时间序列和支持向量机2种预测模型产生的误差进行分析,验证了该模型可以有效描述预测误差概率分布。风电功率概率密度预测的方法主要有3种:区间估计、核密度估计(kernel density estimation, KDE)以及分位数回归。文献[11]将长短期记忆网络分位数回归(quantile regression long short-term memory, QRLSTM)与KDE相结合对风电功率概率密度进行短期预测;文献[12]提出了基于集成学习的风电功率概率预测方法,使用ELM和分位数回归模型作为个体学习器,在优化算法寻优后加权输出预测区间,在较窄的预测区间内具有较高的可靠性;文献[13]在现有概率密度预测基础上采用时变过滤器的经验模态分解,用样本熵、转换分位数回归和高斯核密度构建概率密度预测模型,在保证分位数不交叉的情况下可以提升预测效果;文献[14]采用

了将粗糙集和加权马尔可夫链与KDE结合的方法,进行风电概率区间预测,验证了其方法的有效性。但需要指出的是:传统基于循环神经网络(recurrent neural network, RNN)或卷积神经网络(convolutional neural network, CNN)模型及其变体是时不变的。RNN包含一组链式连接的循环单元,循环单元的参数随着时间的推移保持不变,即每一时刻都采用相同的权重参数。但是随着时间的推移,权重共享会带来梯度消失问题,意味着无法通过增加模型的网络层数来改善预测效果,因为真正能够起到学习作用的仅是邻近输出层的若干层,这使得模型不能有效地学习数据中存在的长期依赖关系。长短期记忆人工神经网络(long short-term memory, LSTM)通过引入门控单元解决了循环神经网络中的梯度消失问题,但是,LSTM结构的参数是不随时间变化的。CNN具有局部连接和参数共享的特性,这是对图像数据处理的关键,但是在处理时间序列时,平移不变性会转换为时间不变性。基于循环和卷积的神经网络的参数是共享的,即在时间上重复使用具有固定参数的一组固定架构,可以在一定程度上减少网络的参数数量,但会使整个模型网络的体系结构是时不变的,对风电功率进行较长时间尺度的短期预测时,上述模型的时不变性会降低多步提前预测能力<sup>[15]</sup>。

本文应用时变深度前馈神经网络可以有效解决上述模型的时不变问题,结合混合密度网络对较长时间尺度的短期风电功率进行不确定性预测。以美国PJM网上的风电功率数据作为研究数据,应用ForecastNet模型进行较长时间尺度的短期风电功率不确定性预测。该模型可以充分地学习输入和输出之间以及输出之间的依存关系,在避免传统深度学习模型中,避免递归多步预测累积误差的同时可以充分考虑相邻时刻风电功率值的相关性。同时,在ForecastNet隐藏层中,本文分别应用全连接神经网络、卷积网络以及基于注意力机制的卷积网络3种模型,对风电功率进行短期不确定性预测,采用混合密度网络得到未来某段时间内的风电功率的区间以及完整概率分布,能够取得良好的效果,得到一定置信度下的未来风电功率预测区间。

## 1 时变深度前馈神经网络

时变深度前馈神经网络的最大特点是其时变性以及交错输出的特性,在时间序列预测问题中能有效提升多步预测能力和缓解梯度消失问题<sup>[16]</sup>。

### 1.1 时变性

对于时变系统而言,输入序列的时间变化会引起相应的输出序列变化,ForecastNet在 $t$ 时刻的输出序列 $y_t$ 可表示为

$$y_t = f_i(g_i(x_t, h_{t-1}, y_{t-1})) \quad (1)$$

式中, $f_i, g_i$ 分别为输出层、隐含层 $t$ 时刻的激活函数; $x_t$ 为 $t$ 时刻的输入层; $h_{t-1}$ 为 $t-1$ 时刻的隐含层; $y_{t-1}$ 为 $t-1$ 时刻的输出层。

若一个系统是时不变的,则其输入和输出延迟时间应保持一致。为了判断如式(1)系统的时变性,可以作出如下推断:假定有2组相同的隐含层单元 $h'_t = h_{t-t_0}$ 以及2组相同的输入 $x'_t = x_{t-t_0}$ ,在时间延迟为 $t_0$ 的情况下,根据式(1)可得2组输出:

$$y_{t-t_0} = f_{i-t_0}(g_{i-t_0}(x_{t-t_0}, h_{t-t_0-1}, y_{t-t_0-1})) \quad (2)$$

$$y'_t = f_i(g_i(x'_t, h'_{t-1}, y'_{t-1})) = f_i(g_i(x_{t-t_0}, h_{t-t_0-1}, y_{t-t_0-1})) \quad (3)$$

式(2)、(3)中, $y_{t-t_0}, y'_t$ 分别为对应输入和延时下的2组输出; $f_{i-t_0}, g_{i-t_0}$ 分别为隐含层和输出层对应时刻 $t-t_0$ 的激活函数; $h_{t-t_0-1}, y_{t-t_0-1}$ 分别为 $t-t_0-1$ 时刻的隐含层、输出层。

比较式(2)、(3)可以得出 $y'_t \neq y_{t-t_0}$ ,即可证明ForecastNet模型网络结构是时变的,其参数随时间而变化。

### 1.2 交错输出

梯度消失和梯度爆炸问题产生的根源是链式法则在梯度计算时的重复应用,链式法则会将最后一层到该层之间的相关权重进行累乘<sup>[15]</sup>。如果中间的权重大于1,则不断相乘后梯度可能会呈现指数级增大,形成梯度爆炸;如果中间的权重小于1,梯度则会逐渐缩小,快速接近0,形成梯度消失,特别是在深层网络中该现象更为明显。如图

1所示,ForecastNet模型在隐藏层之间是交错输出的。




图1 交错输出

Figure 1 Interlaced output

在ForecastNet模型中连乘链被分解为多个项之和,这些项的总和比因子的乘积更稳定。在模型训练过程中,交错输出可以将局部信息提供给网络的内部隐藏层,这可以显著降低网络的深度。

假定一个 $L$ 层的ForecastNet,每个隐藏层中均包含一个隐藏神经元和一个线性输出神经元。对于第 $l$ 层网络, $W^{[l]}$ 表示权重矩阵, $C$ 表示损失函数, $\bar{b}^{[l]}$ 表示偏置参数矩阵, $a^{[l]}$ 表示输出向量, $z^{[l]} = W^{[l]T} a^{[l-1]} + \bar{b}^{[l]}$ ,应用链式法则求得损失函数 $C$ 关于第 $l$ 层的权重矩阵的偏导数:

$$\frac{\partial C}{\partial W^{[l]}} = \frac{\partial C}{\partial a^{[l]}} \frac{\partial a^{[l]}}{\partial W^{[l]}} \quad (4)$$

计算过程一直持续到最终的输出层,最终的结果为

$$\frac{\partial C}{\partial W^{[l]}} = \sum_{k=0}^{L-1-l} \frac{\partial C}{\partial z^{[l+2k+1]}} \frac{\partial z^{[l+2k+1]}}{\partial a^{[l+2k]}} \Psi_k \frac{\partial a^{[l]}}{\partial W^{[l]}} \quad (5)$$

其中,

$$\Psi_k = \begin{cases} 1, & k=0 \\ \prod_{j=1}^k \frac{\partial z^{[l+2j]}}{\partial a^{[l+2(j-1)]}}, & k>0 \end{cases} \quad (6)$$

$\Psi_k$ 是链式法则导数的乘积。对于较深的层, $k$ 较大, $\Psi_k$ 将有许多因子,导致较远的层反向传播的梯度仍然存在一定程度的梯度消失。但是,对于 $k$ 较小的附近输出, $\Psi_k$ 的因子较少,因此出现梯度消失的概率很小。在训练过程中,随着网络有效深度的降低,可以有效改善模型的收敛性。

## 2 模型结构

如图2所示,ForecastNet是一个基本前馈神经网络结构,包括输入层、输出层以及一组顺序连接的隐藏单元,隐藏单元(正方形)包含某种形式的前

馈神经网络。

输入层 ForecastNet模型网络的输入 $x_{t-n+1}$ 是因变量的一组滞后值集合,因变量可以是单变量,也可以是多变量。本文原始数据为单变量,即风电功率历史数据;输入单元连接到网络中的隐藏层(图2)。




图2 时变深度前馈神经网络基本结构

Figure 2 Basic structure of time-varying depth feedforward neural network

隐藏层 ForecastNet隐藏层的单元代表某种形式的前馈神经网络,如全连接神经网络、卷积神经网络或注意力机制等。就架构而言,每个隐藏层的单元可能是异构的,即使每个隐藏单元的架构是相同的(如本文中所使用的),每个单元也都有自己独特的一组参数,这与RNN不同,RNN的单元结构和参数在每个时间步都重复使用。因此,ForecastNet是连续的,但不是周期性的。隐藏单元可以模拟时间序列动态,隐藏单元之间的连接模拟局部动态,单元集合模拟长期动态。

输出层 ForecastNet模型中的每一个输出都提供了对未来的一个预测,模型网络越深,输出的信息就越多,随着预测范围的扩大,模型网络会变得愈加复杂。基于混合密度网络思想,每个输出均建立一个概率分布模型,本文采用正态分布模型。第 $l$ 层输出的正态分布均值 $\mu^{[l]}$ 和标准差 $\sigma^{[l]}$ 分别为

$$\mu^{[l]} = W_{\mu}^{[l]T} a^{[l-1]} + b_{\mu}^{[l]} \quad (7)$$

$$\sigma^{[l]} = \log\left(1 + \exp\left(W_{\sigma}^{[l]T} a^{[l-1]} + b_{\sigma}^{[l]}\right)\right) \quad (8)$$

式(7)、(8)中, $a^{[l-1]}$ 为上一个隐藏单元的输出; $W_{\mu}^{[l]T}$ 、 $b_{\mu}^{[l]}$ 分别为均值层的权重、偏置; $W_{\sigma}^{[l]T}$ 、 $b_{\sigma}^{[l]}$ 分别为标准差层的权重、偏置。

在预测过程中,通过对正态分布 $N(\mu^{[l]}, \sigma^{[l]})$ 进行抽样得到第 $l$ 层的预测结果,采样后得到的预测

信息反馈到下一层。利用极大似然估计作为损失函数( $L$ ),进行反向传播求得网络的权重和偏置,用Adam梯度下降法训练网络以优化正态分布的对数似然函数<sup>[17]</sup>。

$$L = \log \prod_{i=1}^I p(x_i; N(\mu, \sigma)) \quad (9)$$

式中, $x_i$ 为风电功率数据样本; $p(x_i; N(\mu, \sigma))$ 为风电功率数据样本的分布密度。

本文以ForecastNet模型为基础,作为对比在隐藏层中使用了3种神经网络模型。

FN 隐藏层采用全连接网络的ForecastNet,如图3所示, $h$ 表示每层隐藏的神经元数量;每个隐藏单元含2个全连接的隐藏层,每个层具有24个ReLU神经元。




图3 FN 隐含层

Figure 3 FN hidden layer

CFN 隐藏层中采用卷积神经网络的ForecastNet,如图4所示, $f$ 表示卷积核数量, $k$ 表示卷积核大小, $p$ 和 $s$ 分别表示池化层的填充和步幅, $h$ 表示隐藏神经元数量。该模型中每个隐藏单元包括:1个具有24个卷积核的卷积层,每个卷积核的大小为2;平均池化层,其池大小为2、步幅为1;重复的卷积层和池化层;1个由24个ReLU神经元组成的全连接层。




图4 CFN 隐含层

Figure 4 CFN hidden layer

CAFN 在ForecastNet的隐藏层中采用基于注意力机制的卷积网络,其结构如图5所示。




图5 CAFN 隐含层

Figure 5 CAFN hidden layer

## 3 算例仿真

### 3.1 数据预处理

以美国PJM网上MIDATL地区2014—2015年的风电功率数据作为研究数据进行仿真(<http://www.pjm.com/markets-and-operations/ops-analysis.aspx>)。2014年1月7—13日的风电功率如图6所示,采样间隔为1h。




图6 原始数据

Figure 6 The original data

由图6可知,风电功率序列波动大,出现带有峰值的局部最大点或最小点,这是由极端天气期间气象因素突然变化等因素引起的,可直观地看出风电功率的波动和随机性十分明显但呈现出一定的规律性。

本文利用开源的Python发行版本Anaconda进行程序编写,考虑到该仿真训练神经网络模型所用的原始数据量和网络参数数量众多,仅仅依靠计算机CPU进行训练,效率是低下的。针对上述问题,仿真时应用美国NVIDIA公司旗下的统一计算设备框架CUDA,充分利用GPU的显存资源,同时应用针对神经网络的GPU加速库cuDNN,使CUDA更加契合深度神经网络的使用,大大减少了仿真所需时间。

本文利用拉格朗日插值法仅对预测精度影响较大的缺失数据进行处理,提高数据的连续性,进而提高模型的预测精度,拉格朗日插值多项式为

$$L(x) = \sum_{i=0}^n y_i \prod_{j=0, j \neq i}^n \frac{x - x_j}{x_i - x_j} \quad (10)$$

其中,  $y = L(x)$  为若干个二维坐标点  $(x_i, y_i)$  确定的多项式函数。

采用最大最小标准化(min-max normalization)方法对原始风电功率数据进行归一化处理,将其转换为  $[0, 1]$  之间的数据,即

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (11)$$

式中,  $x'$  为归一化后的风电功率值;  $\max(x)$ 、 $\min(x)$  分别为原始风电功率数据中的最大、最小值;  $x$  为实际风电功率值。

### 3.2 评价指标

风电功率点预测模型常用的评价指标有平均绝对误差(MAE)、均方误差(MSE)、均方根误差(RMSE)。上述评价指标只能用于评价确定性预测的结果,并不能用来评价不确定性预测的结果。为了衡量风电功率预测值与实际值的概率性误差,本文选择区间覆盖率和区间平均宽度共同衡量风电功率预测结果的不确定性误差<sup>[18-20]</sup>。

#### 1) 区间覆盖率。

在置信度  $1 - \alpha$  下,预测区间数量为  $N_{\text{interval}}$ , 区间覆盖率表示为

$$\begin{cases} I_i^\alpha = [L_i^\alpha, U_i^\alpha] \\ \xi_i^\alpha = \begin{cases} 0, & P^i \notin I_i^\alpha \\ 1, & P^i \in I_i^\alpha \end{cases}, i = 1, 2, \dots, N \\ R_{\text{cover}} = \frac{1}{N_{\text{interval}}} \sum_{i=1}^N \xi_i^\alpha \end{cases} \quad (12)$$

式中,  $L_i^\alpha$  为  $1 - \alpha$  置信度下第  $i$  个预测区间的下界;  $U_i^\alpha$  为对应的上界;  $I_i^\alpha$  为对应区间;  $P^i$  为对应实际点的值;  $R_{\text{cover}}$  为可靠性指标;  $\xi_i^\alpha$  表示第  $i$  个真实值是否落在预测区间内,即风电功率预测区间对真实值的覆盖率。

区间覆盖率表示预测区间包含风电功率实际值的比例,即风电功率预测区间对实际值的覆盖率,区间覆盖率的值越大说明预测区间的可信度越高。在事先给定置信度时,区间覆盖率应该不小于

事先给定的置信度,区间覆盖率越大,表示越多的风电功率真实值落在对应的区间范围内,即预测效果越好<sup>[14,21]</sup>。

#### 2) 区间平均宽度。

区间覆盖率指标不能全面真实地体现区间预测结果的优劣,因为当预测模型给出的区间过于宽泛时,区间覆盖率通常会更高。过于宽泛的区间宽度会导致预测结果能提供的有用信息较少,这样的预测区间范围也丧失了实际意义,所以还需要结合区间平均宽度来共同判断区间预测结果的优劣。区间平均宽度表示为

$$\begin{cases} \delta_i^\alpha = U_i^\alpha - L_i^\alpha \\ \delta_{\text{mean}}^\alpha = \frac{1}{N} \sum_{i=1}^N \delta_i^\alpha \end{cases} \quad (13)$$

式中,  $\delta_i^\alpha$  为第  $i$  个预测区间的宽度;  $\delta_{\text{mean}}^\alpha$  为区间平均宽度。

给出的预测风电功率区间平均宽度越小代表得到的功率区间越小,给出的有用信息越多。区间覆盖率、区间平均宽度这2个指标能够充分反映风电功率不确定性预测结果的优劣。

### 3.3 仿真分析

根据上述内容,基于3种不同的隐含层神经网络建立 ForecastNet 预测模型,每次多步预测可得到未来 12 h 的风电功率,如图 7 所示,在一次多步预测中,每一时刻的预测结果不仅与输入的风电功率真实值有关,还需充分考虑前面时刻的风电功率预测值对当前预测结果的影响。




图7 多步预测

Figure 7 Multi-step prediction

ForecastNet 模型的程序流程如图 8 所示,在一次多步预测中,当对大于等于 2 时刻进行预测时,历

史风电数据与前一时刻的预测结果共同构成训练数据,训练当前时刻的模型参数。该模型能够精确地追踪数据变化规律,可充分学习输入和输出之间以及输出与输出之间的依存关系,然后滚动预测500次,共得到未来500 h的风电功率预测结果。

在80%、85%和90%置信度下, FN、CFN和CAFN这3种模型的2组预测结果区间范围如图9所示,其中图9(a)~(c)为一组,9(d)~(f)为一组,可知真实值大部分都落在3种模型的预测区间范围内。CAFN模型在跟踪风电功率变化趋势方面表现最为优异,风电功率的实际值更多的落在高置信度下的预测区间。对比3种模型给出的区间范围,明显看出,CAFN和CFN模型在同置信度下得到的预测区间宽度远小于FN模型得到的预测区间宽度。

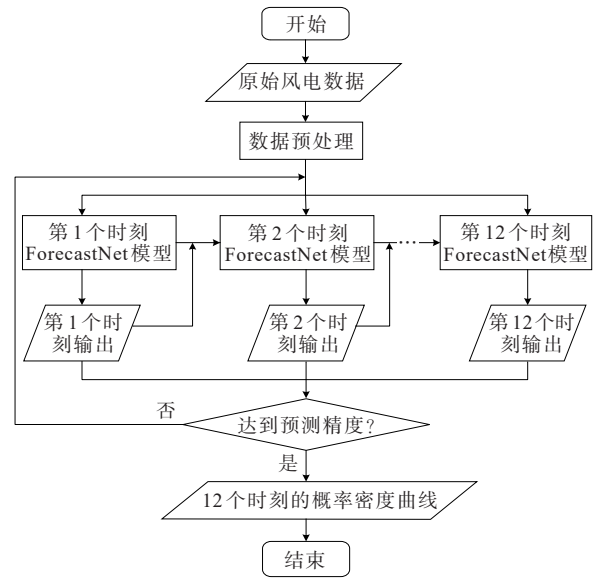


图8 流程

Figure 8 The flow chart

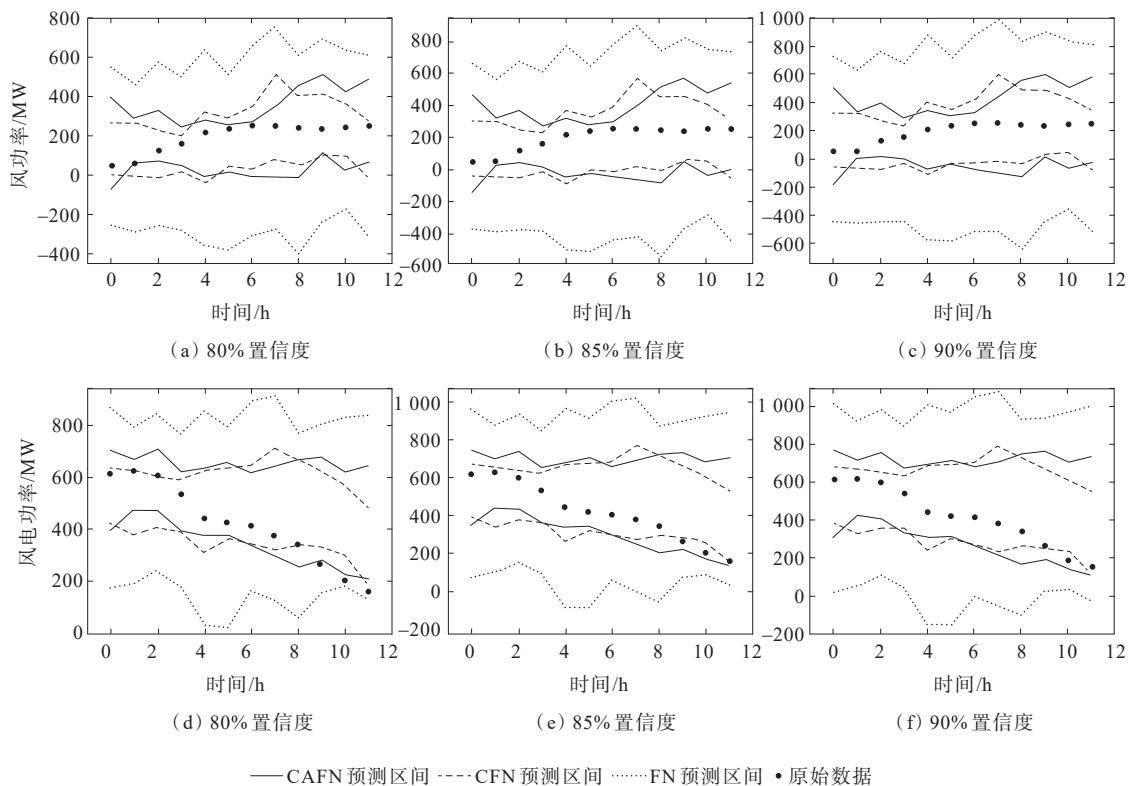


图9 预测区间

Figure 9 Prediction interval

为进一步考察本文所述 ForecastNet模型短期风电功率不确定性预测的效果,在保证训练集、测试集、参数设置以及训练轮数相同的条件下,分别采用QRLSTM<sup>[2]</sup>和分位数回归时间卷积网络<sup>[20]</sup>(quantile regression of time convolutional network,

QRTC�)模型同样预测未来12 h的风电功率。在连续滚动预测500个时刻后,计算其区间覆盖率和区间平均宽度,所得结果与本文所提3种模型(FN、CFN和CAFN)的预测结果作对比,如表1所示。

表 1 预测指标对比

Table 1 Comparison of Forecast Indicators

置信度%	模型	区间覆盖率/%	区间平均宽度/MW
80	QRTCN	68.68	356.52
	QRLSTM	75.26	400.93
	FN	99.32	785.57
	CFN	82.26	302.41
	CAFN	85.67	355.98
85	QRTCN	75.21	420.32
	QRLSTM	79.31	498.36
	FN	99.95	1 005.53
	CFN	86.61	387.08
	CAFN	89.43	430.05
90	QRTCN	84.26	470.36
	QRLSTM	88.37	523.51
	FN	100.00	1 131.22
	CFN	93.26	435.46
	CAFN	95.89	483.80

由表 1 可知,在 80%、85% 和 90% 置信度下, FN 模型的区间覆盖率均为最高,分别为 99.32%、99.95%、100%,但是其得到的区间平均宽度过于宽泛,是 CFN、CAFN 模型的 2 倍多;CFN、CAFN 模型的区间覆盖率均超过了事先给定的置信度, CAFN 模型的区间覆盖率相对于 CFN 模型分别提

高了 4.14%、3.23%、2.79%,但同时,CAFN 模型得到的区间平均宽度也相应增加,相比于 CFN 模型,在不同置信度下分别增加了 17.71%、11.08%、11.10%;QRLSTM、QRDCC 模型与 CFN、CAFN 模型得到的区间平均宽度结果相差并不大,但是 QRLSTM、QRDCC 模型的区间覆盖率未达到给定的置信度,预测效果并不理想。

综合以上分析,CFN、CAFN 模型均取得了较好的预测效果,CAFN 模型通过引入注意力机制,在增加较小区间宽度的情况下,一定程度上增加了模型的区间覆盖率,提高了模型的可靠性,同时,也能更好地追踪风电功率变化趋势。

本文从未来 500 个预测时间中随机抽取了 6 个时间点,展示其概率密度分布,CAFN、CFN 和 FN 这 3 种模型的概率密度分布曲线如图 10 所示,可以看出,风电功率的真实值落在 3 条曲线的中间区域,表明 3 种算法均能够较好地预测未来时刻的风电功率概率密度分布;真实值落在 3 条曲线的波峰附近,表明预测曲线给出的高概率区间与风电功率真实值相符合。但 CFN、CAFN 模型在展现曲线波峰的细节方面更加细致、灵敏,而 FN 模型更显迟钝,只展现出大体轮廓。

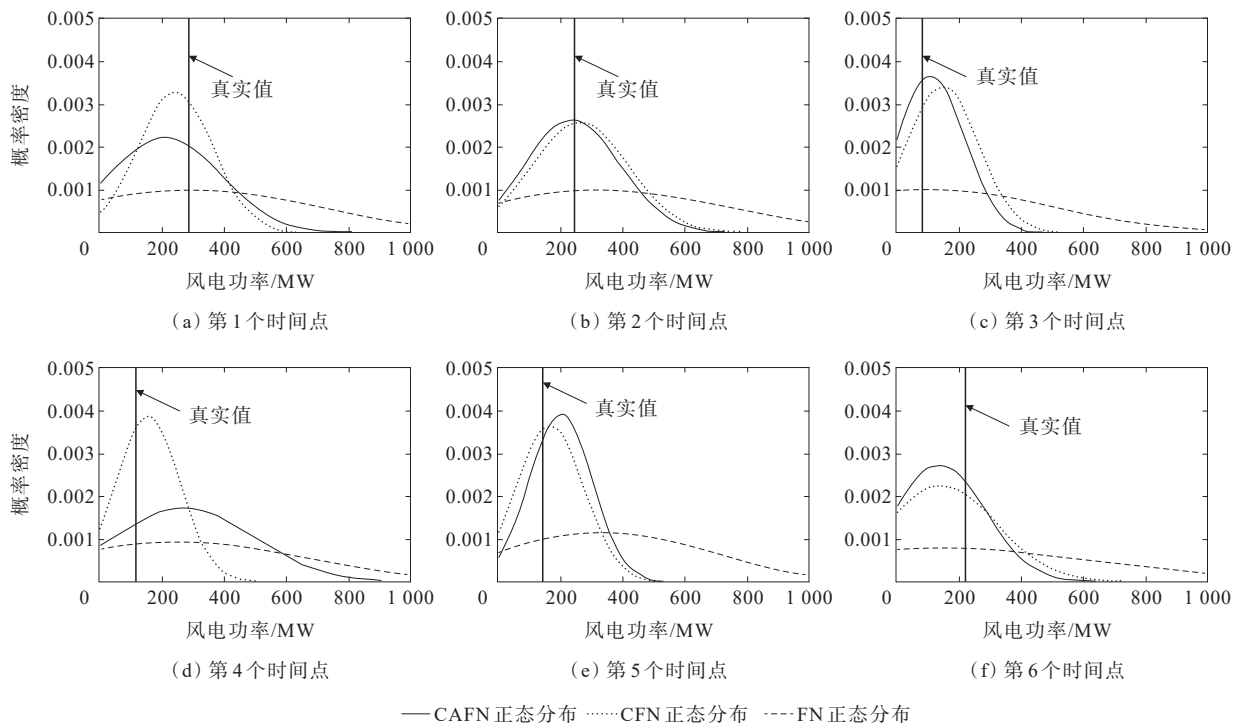


图 10 概率密度

Figure 10 The probability density



## 4 结语

本文应用时变深度前馈神经网络风电功率短期区间预测模型,解决了以RNN或CNN为基础框架构建模型的时不变问题。提出了模型的3个变体用于风电功率短期不确定性预测,该方法不仅在预测精度上有提高,而且能获得风电功率概率密度函数,可以为电力系统制定机组组合、鲁棒调度计划时提供准确的风电功率波动范围,提高风电功率预测在调度策略优化中的支撑价值,提升功率预测的实用化水平。

在本文研究的基础上仍可进行以下深入研究: ForecastNet在隐藏层中应用了3种神经网络,后续工作中可以针对研究隐藏单元内部之间的连接展开更为详细的研究,应用更多的神经网络模型以提高其预测能力;ForecastNet模型通过避免参数共享来实现时变模型,这需要占用较多的内存,未来可以展开探索使用内存优化技术的研究。

### 参考文献:

- [1] 朱抗,杨洪明,孟科.基于极限学习机的短期风力发电预测[J].电力科学与技术学报,2019,34(2):106-111.  
ZHU Kang, YANG Hongming, MENG Ke. Short-term wind power forecast using extreme learning machine[J]. Journal of Electric Power Science and Technology, 2019, 34(2): 106-111.
- [2] 李彬,彭曙蓉,彭君哲,等.基于深度学习分位数回归模型的风电功率概率密度预测[J].电力自动化设备,2018,38(9):15-20.  
LI Bin, PENG Shurong, PENG Junzhe, et al. Wind power probability density prediction based on model of quantile regression deep learning[J]. Electric Power Automation Equipment, 2018, 38(9): 15-20.
- [3] JU Y, SUN G, CHEN Q, et al. A model combining convolutional neural network and light GBM algorithm for ultra-short-term wind power forecasting[J]. IEEE Access, 2019, 7: 28309-28318.
- [4] LIU Y, YAN J, HAN S, et al. Uncertainty analysis of wind power prediction based on quantile regression[C]// Asia-Pacific Power and Energy Engineering Conference, Shanghai, China, 2012.
- [5] 何俊强,师长立,韦统振.基于马尔科夫链的自适应储能需求功率预测模型[J].电工技术学报,2021,36(S2):563-571.  
HE Junqiang, SHI Changli, WEI Tongzhen. Adaptive power demand prediction model of energy storage based on Markov chain[J]. Transactions of China Electrotechnical Society, 2021, 36(S2): 563-571.
- [6] ZHANG Y, WANG J, WANG X. Review on probabilistic forecasting of wind power generation[J]. Renewable & Sustainable Energy Reviews, 2014, 32: 255-270.
- [7] 庞传军,尚学伟,张波,等.基于改进梯度提升算法的短期风电功率概率预测[J].电力系统自动化,2022,46(16):198-206.  
PANG Chuanjun, SHANG Xuewei, ZHANG Bo, et al. Short-term wind power probability prediction based on improved gradient boosting machine algorithm[J]. Automation of Electric Power Systems, 2022, 46(16): 198-206.
- [8] 夏洪伟,李坤,韩丽.考虑风电预测误差的电-热系统混合时间尺度调度[J].电力系统保护与控制,2022,50(17):86-96.  
XIA Hongwei, LI Kun, HAN Li. Hybrid time-scale dispatch of an electric-heating system considering wind power forecast error[J]. Power System Protection and Control, 2022, 50(17): 86-96.
- [9] 孙川永,彭友兵,刘志亮,等.梯度提升树算法在陕北风电场短期风电功率预测中的应用[J].电网与清洁能源,2022,38(4):124-128+134.  
SUN Chuanyong, PENG Youbing, LIU Zhiliang, et al. Short-term wind power prediction of the wind farm in Northern Shaanxi based on gradient boosting decision tree [J]. Power System and Clean Energy, 2022, 38(4): 124-128+134.
- [10] 高鹭,孔繁苗,张飞,等.基于IPSO-BiLSTM-AM模型的超短期风电功率预测方法[J].智慧电力,2022,50(4):27-34.  
GAO Lu, KONG Fanmiao, ZHANG Fei, et al. Ultra short-term wind power prediction method based on IPSO-BiLSTM-AM model[J]. Smart Power, 2022, 50(4): 27-34.
- [11] 朱显辉,于越,师楠,等.BP神经网络的分层优化研究及其在风电功率预测中的应用[J].高压电器,2022,58(2):158-163.  
ZHU Xianhui, YU Yue, SHI Nan, et al. Research on hierarchical optimization of BP neural network and its application in wind power prediction[J]. High Voltage Apparatus, 2022, 58(2): 158-163.
- [12] 杨玉,牛洪海,李兵,等.基于集成学习的风电功率概率

- 预测方法研究[J]. 自动化仪表,2022,43(4):86-91+96.
- YANG Yu, NIU Honghai, LI Bing, et al. Research on probabilistic prediction method for wind power based on integrated learning[J]. Process Automation Instrumentation, 2022,43(4):86-91+96.
- [13] 徐鹏超,李琰,赵艳雷. 基于自适应变异蝙蝠优化BP神经网络的短期风电功率预测[J]. 电测与仪表,2021,58(4):121-127.
- XU Pengchao, LI Yan, ZHAO Yanlei. Short-term wind power prediction based on BP neural network with adaptive mutation bat optimization algorithm[J]. Electrical Measurement & Instrumentation, 2021,58(4): 121-127.
- [14] YANG X, MA X, KANG N, et al. Probability interval prediction of wind power based on KDE method with rough sets and weighted Markov chain[J]. IEEE Access, 2018,6:51556-51565.
- [15] JÜRGEN S. Deep learning in neural networks: an overview [J]. Neural Netw, 2015,61: 85-117.
- [16] DABROWSKI J J, ZHANG Y F, RAHMAN A. ForecastNet: a time-variant deep feed-forward neural network architecture for multi-step-ahead time-series forecasting [C]//The 27th International Conference on Neural Information Processing(ICONIP), Bangkok, Thailand, 2020.
- [17] 叶瑞丽,郭志忠,刘瑞叶,等. 基于置信区间估计及储能装置优化配置的风电场可靠出力研究[J]. 电力自动化设备,2017,37(5):85-91.
- YE Ruili, GUO Zhizhong, LIU Ruiye, et al. Reliable power output based on confidence interval estimation and optimal ESS configuration of wind farm[J]. Electric Power Automation Equipment, 2017,37(5):85-91.
- [18] 庞昊,高金峰,杜耀恒. 基于时间卷积网络分位数回归的短期负荷概率密度预测方法[J]. 电网技术,2020,44(4):1343-1350.
- PANG Hao, GAO Jinfeng, DU Yaoheng. A short-term load probability density prediction based on quantile regression of time convolution network[J]. Power System Technology, 2020,44(4):1343-1350.
- [19] 谢俊,王璐,傅旭华,等. 考虑风电功率概率分布不确定性的含风电配电网无功规划方法[J]. 电力自动化设备, 2016,36(6):40-47.
- XIE Jun, WANG Lu, FU Xuhua, et al. Reactive power planning with consideration of wind power probability distribution uncertainty for distribution network[J]. Electric Power Automation Equipment, 2016,36(6):40-47.
- [20] WAN C, XU Z, PINSON P. Probabilistic forecasting of wind power generation using extreme learning machine[J]. IEEE Transactions Power Systems, 2014,29(3):1033-1044.
- [21] 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.
- 
- (上接第75页 = Continued from page 75)
- [19] 刘迪,张强,吕干云. 量子粒子群算法在配电网重构中的改进和应用[J]. 电测与仪表,2022,59(3):58-65.
- LIU Di, ZHANG Qiang, LÜ Ganyun. Improvement and application of quantum particle swarm optimization in distribution network reconfiguration[J]. Electrical Measurement & Instrumentation, 2022,59(3):58-65.
- [20] 滕志军,吕金玲,郭力文,等. 基于动态加速因子的粒子群优化算法研究[J]. 微电子学与计算机,2017,34(12): 125-129.
- TENG Zhijun, LÜ Jinling, GUO Liwen, et al. Research on particle swarm optimization based on dynamic acceleration coefficients[J]. Microelectronics & Computer, 2017,34(12):125-129.
- [21] 邵凡,张艳,鲁燕. 中央空调冷水机组群控优化方法研究 [J]. 电力需求侧管理,2016,18(4):6-10.
- SHAO Fan, ZHANG Yan, LU Yan. Study on optimal group control of chillers for central air conditioner[J]. Power Demand Side Management, 2016,18(4):6-10.
- [22] 王晨旭,唐飞,刘涤尘,等. 基于双层代理模型的概率-区间潮流计算及灵敏度分析[J]. 电工技术学报,2022,37(5):1181-1193.
- WANG Chenxu, TANG Fei, LIU Dichen, et al. Probabilistic-interval power flow and sensitivity analysis using double layer surrogate method[J]. Transactions of China Electrotechnical Society, 2022,37(5):1181-1193.