

王朋<sup>1</sup> 孙永辉<sup>1</sup> 翟苏巍<sup>1</sup> 侯栋宸<sup>1</sup> 王森<sup>1</sup>

# 基于小波长短期记忆网络的风电功率超短期概率预测

## 摘要

随着大规模的风电并网,风电所具有的间歇性与随机性对电力系统的稳定性产生了很大的影响,风电功率预测成为当前解决该问题重要的方式之一.本文利用长短期记忆(LSTM)网络良好的时序记忆特性,将小波分解技术与LSTM深度网络结合,提出基于小波长短期记忆网络的风电功率超短期概率预测模型.首先通过小波分解技术将原始时间序列进行平稳化处理,再建立各子序列样本的LSTM网络预测模型,借助最大似然估计法估计预测误差的高斯分布函数,最终实现对未来4 h时刻的风电功率概率区间预测.最后,采用中国东北某风电场数据对所提方法进行算例分析,结果表明,将小波分解与深度学习方法结合可以较好地提高预测的精度,提高概率预测的区间可靠性.

## 关键词

小波分解;长短期记忆网络;风电功率;概率预测

中图分类号 O429

文献标志码 A

收稿日期 2019-06-19

资助项目 国家重点研发计划(2018YFB0904200);国家电网有限公司配套科技项目(SGLN DKOOKJJS1800266)

## 作者简介

王朋,男,硕士生,研究方向为新能源发电功率概率预测.18260059528@163.com

孙永辉(通信作者),男,博士,教授,主要研究方向为电力系统分析与控制、负荷预测等.sunyonghui168@gmail.com

## 0 引言

风资源具有强随机性、波动性与间歇性,大规模风电并网给电力系统的稳定性带来了严重的影响,对风电功率进行预测已经成为解决该问题的重要方法<sup>[1]</sup>.因为风资源本身的随机性与预测模型的固有缺陷,风电功率点预测技术无法对风电功率做出准确的预测<sup>[2]</sup>.风电功率概率预测方法考虑到风电功率所具有的不确定性,结合概率统计理论预测出风电功率的概率区间,能够为电网调度部门提供更为可靠的信息,因此,风电功率概率预测成为了风电产业发展的一个关键技术之一<sup>[3-4]</sup>.

依据建模过程中是否使用点预测的结果,风电功率概率预测方法分为两种:一是基于点预测结果,预先假设点预测误差分布的参数化建模;二是以风电功率自身及风电功率点预测的误差作为建模对象的非参数化建模<sup>[5]</sup>.前者对点预测模型的误差进行某种特定的概率分布假设,结合点预测值得到概率预测的结果;后者直接根据实际风电功率历史数据进行建模,计算出风电功率的区间分布<sup>[6-7]</sup>.本文研究的超短期风电功率概率预测时长为4 h,采用基于点预测结果的参数化建模对风电功率进行概率区间预测.

目前,风电功率概率预测已有许多学者在研究,文献[8]通过一种非参数回归模型建立风电功率预测误差的概率分布函数,得到风电功率短期预测值的概率区间;文献[9]通过建立一种联合条件的离散预报误差概率统计模型,修正预报误差的概率分布,与确定性预测值结合得到风速与风电功率概率预测结果;文献[10]对风电功率预测误差数值特性进行分层分析,采用改进后的广义误差分布模型对预测误差概率密度分布进行拟合;文献[11]提出一种基于离散时间Markov链的功率预测模型,将风电功率数据划分为4种状态空间,直接对风电功率数据进行数值分析得到单点预测值和概率分布;文献[12]基于分位点回归分析理论,通过支持向量机选取回归函数,并使用内点法对所建立的风电功率分位点回归模型进行求解,实现对未来时段风电功率的区间预测;文献[13]通过稀疏贝叶斯分类器将SVM预测误差落入预定区间进行概率估计,然后使用D-S证据理论对所有区间的概率估计结果进行整合,得到SVM预测误差的整体概率分布,得到风电功率的概率分布结果.以上文献构建了不同概率预测模型,借助概率统计理论,来研究风电功率的预测误差范围,但由

于传统预测模型的固有缺陷,使得模型对预测误差的影响程度偏大,降低了概率预测结果的可靠度。

长短期记忆网络是一种带有记忆与遗忘模式的特殊递归神经网络,解决了传统的递归神经网络在BPTT训练过程中出现的梯度消失与梯度爆炸的问题<sup>[14]</sup>。该模型可以记忆长时间的信息,对历史数据进行深度学习,构建出的风电功率超短期概率预测模型更能够提高历史数据的利用率,使得所构建的风电功率概率预测模型更加逼近数据模型,减小模型的误差对预测精度的影响。使用长短时记忆(Long Short-Term Memory,LSTM)网络建立的预测模型具有良好的预测性能,提高了概率预测的精度。

基于上述讨论,本文提出基于小波长短期记忆网络的风电功率超短期概率预测模型,能够实现对风电功率未来4h的概率区间预测。单独的LSTM网络对于非平稳信号概率预测的区间可靠性低,综合质量差。通过LSTM深度网络对分频信号单独的确定性预测,能提高确定性预测结果的精度,使得风电功率概率预测的区间质量更高。某风电场真实风电功率的算例分析表明:本文所提出的基于小波分解技术与LSTM网络相结合的风电功率超短期概率预测方法,具有较好的预测精度和泛化能力。

## 1 长短期记忆网络原理

传统的递归神经网络(Recurrent Neural Networks,RNNs)利用隐含层能够跨越时间点保留历史状态,推导出未来的状态信息,但是当面临长时间段的信息时,传统的RNNs在BPTT训练过程中会出现梯度消失与梯度爆炸的问题。长短期记忆(LSTM)网络用存储单元代替了常规的神经元,并且每个存储单元由输入门、输出门、自由状态组成,实现了对于数据长时间度的学习,该方法已经在很多领域得到了广泛的应用<sup>[15-20]</sup>。

LSTM存储单元中设有遗忘门、输入门、输出门,管理着存储单元的移除或添加,3种门限由sigmoid激活函数和逐点乘法运算组成。前一个时间步骤的隐藏状态,一个送到遗忘门(输入节点),一个送到输入门,一个送到输出门。各门限负责学习何时将隐藏状态流入流出存储单元。

图1为从 $t-1$ 状态到 $t$ 状态的LSTM工作原理。首先,在正向传递过程中,遗忘门层抛弃通过遗忘门的一些历史状态信息,得到需要的历史状态信息 $f_t$ 输入单元内:

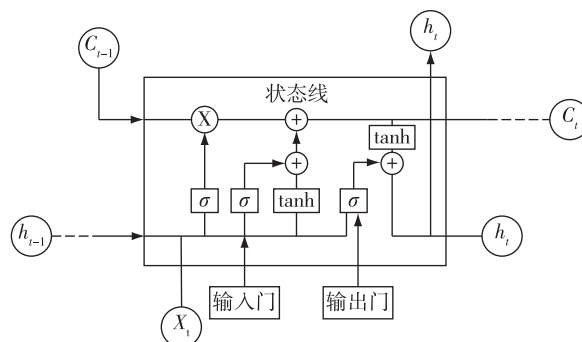


图1 LSTM存储单位工作流程

Fig. 1 LSTM stores unit workflow

$$f_t = \sigma(W_f[h_{t-1}, X_t] + b_f). \quad (1)$$

接着,根据当前时刻的信息生成临时新的状态 $\tilde{C}_t$ ,更新旧状态 $C_{t-1}$ ,将临时的新状态值与遗忘之后的旧状态值相加,得到新的状态值:

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i), \quad (2)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, X_t] + b_c), \quad (3)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t. \quad (4)$$

最后,将通过sigmoid函数的输出信息与经过tanh函数转化的单元状态值相乘,得到最终的输出:

$$o_t = \sigma(W_o[h_{t-1}, X_t] + b_o), \quad (5)$$

$$h_t = o_t \tanh(C_t). \quad (6)$$

式中, $f_t$ 为经遗忘门处理之后的历史状态信息, $\sigma$ 为sigmoid函数, $W_f$ 为遗忘门连接的权重矩阵, $h_{t-1}$ 是隐含层上一个时间节点的输出, $X_t$ 是 $t$ 时刻输入层的输出, $b_f$ 是遗忘门的偏移值, $i_t$ 为 $t$ 时刻输入门的输出, $W_i$ 为输入门连接的权重矩阵, $b_i$ 为输入门的偏移值, $\tilde{C}_t$ 为临时新状态值, $W_c$ 为 $t$ 时刻计算单元新状态的连接权重矩阵, $b_c$ 为 $t$ 时刻计算单元新状态的偏移值, $C_{t-1}$ 为旧状态, $C_t$ 为 $t$ 时刻新的状态, $W_o$ 为输出门的连接权重, $b_o$ 为输出门的偏移值, $h_t$ 为输出门的值。

## 2 基于小波变换的风电功率概率预测方法

小波变换是一种针对信号的时间-频率上的局部分析方法,是经传统的傅里叶变换改进而来的。将傅里叶变换的基函数换成了有限长会衰减的小波基,因此小波变换可以对细微的信号进行分析研究,提供了一种非平稳信号的时间尺度分析手段<sup>[7]</sup>。小波变换含有的变量为尺度 $a$ (scale)和平移量 $t$ (translation),尺度 $a$ 控制小波函数的伸缩,平移量 $t$ 控制小波函数的平移。两个变量对应于频率与时间。小波变换如下:

在连续小波变换中,设  $\phi(t) \in L^2(\mathbf{R})$ ,  $\phi^*(w)$  为  $\phi(t)$  的傅里叶变换结果,  $\phi^*(w)$  满足:

$$\int_{-\infty}^{+\infty} \frac{|\phi^*(w)|^2}{|w|} dw < \infty, \quad (7)$$

则  $\phi(t)$  为一个母小波函数.

同时,  $\phi(t)$  经伸缩和平移后可得:

$$\phi_{a,\tau}(t) = \frac{1}{\sqrt{|a|}} \phi\left(\frac{t-\tau}{a}\right), a, \tau \in \mathbf{R}; a \neq 0, \quad (8)$$

其中,  $a$  为伸缩变量,  $\tau$  为平移变量.

对于平方积函数  $f(t) \in L^2(\mathbf{R})$  的连续小波变换为

$$WT(a, \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \Psi\left(\frac{t-\tau}{a}\right) dt, \quad (9)$$

将  $a$  与  $\tau$  进行离散化, 分别取  $a = a_0^j$ ,  $\tau = ka_0^j \tau_0$  ( $j, k \in \mathbf{Z}$ ), 其中步长  $a_{10}$  是固定值, 离散化小波变换公式为

$$\phi_{j,k}(t) = a_0^{-\frac{j}{2}} \phi\left(\frac{t - ka_0^j \tau_0}{a_0^j}\right) = a_0^{-\frac{j}{2}} \phi(a_0^{-j} t - k\tau_0), \quad (10)$$

离散化系数为

$$c_{j,k} = \int_{-\infty}^{+\infty} f(t) \phi_{j,k}^*(t) dt. \quad (11)$$

为了提高小波变换之后重构的信号精度, 对于尺度与平移量的选择应该尽量小一点. 风电功率的时间序列是一种非平稳信号, 本文采用小波变换的方法, 首先将采集到的样本进行分析处理, 得到输入输出模型, 通过小波变换将每一列的数据进行分解. 考虑到小波变换之后信号重组的精度, 依据信号的平稳性对样本进行小波分解. 本文选用的东北某风电场的功率序列平稳性较差. 针对平稳性较差的东北风电场样本采用三级小波分解, 再将已经得到的小波信号进行预测研究, 对信号的平稳性进行判断.

在已经得到各分解信号的基础上, 再对小波样本进行 LSTM 网络训练, 得到风电功率小波样本的预测模型, 进而对预测模型误差进行分析, 进行风电功率小波样本的概率预测. 小波变换下的风电功率概率预测模型的结构如图 2 所示.

### 3 考虑误差分布的风电功率超短期概率预测

由中心极限定理可知, 大量统计独立的随机变量的和的分布近似服从一个数学期望为  $\mu$ , 方差为  $\sigma^2$  的高斯分布, 记为  $N(\mu, \sigma^2)$ , 其中  $\mu, \sigma^2$  分别决定着该分布的位置与幅度<sup>[21]</sup>. 通常进行概率统计分布参数估计的方法为贝叶斯估计方法<sup>[22]</sup>、最大似然估

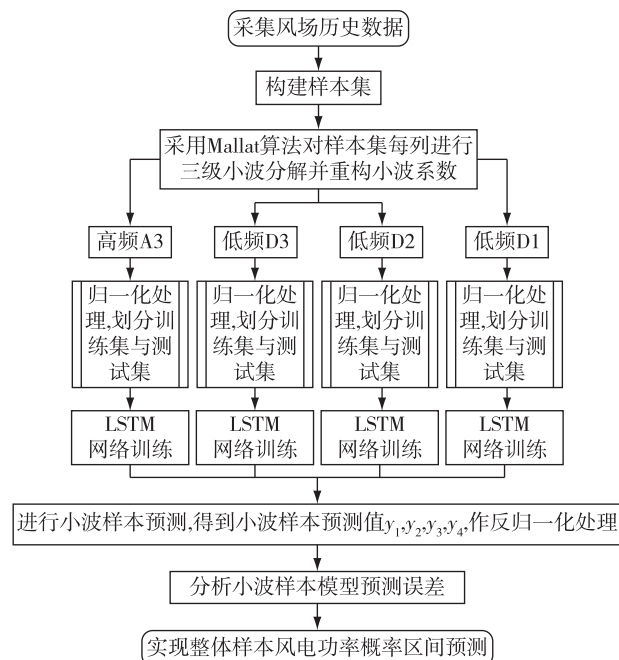


图 2 小波变换下的风电功率概率预测模型结构

Fig. 2 Wind power probability prediction model structure under wavelet transform

计方法<sup>[23]</sup>、无偏估计方法等.

风电功率时间序列在建立预测模型的过程中会不可避免地产生模型误差<sup>[24]</sup>. 通常情况下, 若以所建的模型进行风电功率预测, 预测的结果与实际值之间都会存在此模型误差. 根据高斯分布的定义, 在大量的误差统计下, 风电功率的预测误差近似服从高斯分布<sup>[25]</sup>. 本文采用最大似然估计的方法对预测模型的误差进行高斯分布参数估计.

假设  $d_1, d_2, d_3, \dots, d_n$  是已知风电功率模型训练的误差向量, 则在高斯分布下均值与方差的最大似然估计分别为

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n d_i, \quad (12)$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n d_i^2 - \left(\frac{1}{n} \sum_{i=1}^n d_i\right)^2. \quad (13)$$

长短期记忆网络对于时间叙述模型的求解具有天然的优势, LSTM 是一种带有“注意力”的神经网络<sup>[22]</sup>. LSTM 不仅可以过去时刻的信息带进现在时刻来计算, 而且还带有遗忘的模式, 将过去无关的状态舍弃, 从而充分挖掘数据的有用信息<sup>[26]</sup>, 提高预测的准确度.

LSTM 网络对状态信息有记忆功能, 因此为了尽量降低预测模型的复杂度与保证预测精度, 本文的

数据输入为 100 维, 输出为 1 维, 输入向量为当前时刻之前的 100 个历史风功率值, 输出点为当前时刻未来的第 16 个点, 其中功率值点间隔为 5 min, 因此本文实现的为对未来 4 h 的超短期风电功率概率预测. 建立的预测模型为

$$y = f(x_1, x_2, \dots, x_{100}), \quad (14)$$

式中:  $y$  为未来 4 h 时刻的风功率值,  $x_1, x_2, \dots, x_{100}$  为当前时刻之前的 100 个风功率值.

首先采用小波分解的方法对样本时间序列进行列向三级小波分解, 得到 4 个小波样本分别为高频样本 A3, 低频样本 D3、D2、D1.

基于小波 LSTM 网络的风功率超短期概率预测算法步骤如下:

1) 采集分析风电场历史数据, 将当前时刻之前的 100 个风功率值  $x_1, x_2, \dots, x_{100}$  作为输入向量, 未来 4 h 时刻的风功率值  $y$  作为输出向量, 构建训练样本集.

2) 对训练样本采用 Mallat 算法进行三级小波分解得到 4 个小波训练样本集.

3) 对小波训练样本进行归一化处理. 归一化的处理方式为将每一维的特征标准化为 0 均值单位标准差, 并且选取模型训练集与验证集.

4) 建立 LSTM 网络模型对每一个小波样本进行训练得到每一个小波样本的预测值与模型的预测误差.

5) 假设模型的预测误差在服从高斯分布的情况下, 利用最大似然估计方法求出小波样本的误差分布函数的参数, 对小波样本的预测结果以及误差结果重新整合, 得到整体样本的预测值与高斯分布下的模型预测误差均值和标准差:

$$\text{预测值: } \hat{y} = \sum_{i=1}^j y_i,$$

$$\text{模型预测误差均值: } \tilde{\mu} = \sum_{i=1}^j \hat{\mu}_i,$$

$$\text{模型预测误差标准差: } \sqrt{\hat{\sigma}^2} = \sqrt{\sum_{i=1}^j \hat{\sigma}_i^2},$$

式中,  $y_i$  为第  $i$  个小波分量的预测值,  $\hat{\mu}_i$  为第  $i$  个小波分量的预测误差均值,  $\hat{\sigma}_i^2$  为第  $i$  个小波分量的预测误差方差,  $j$  为小波样本数.

6) 求出在不同置信度  $\alpha$  下, 风电功率整体样本的超短期概率预测区间.

## 4 仿真结果与性能比较

为了验证本文所提超短期概率预测方法的正确

性与可行性, 选择中国东北某风电场进行仿真测试, 实现对该风电场功率未来 4 h 的超短期概率预测.

### 4.1 概率预测评估指标

本文采用平均绝对百分比误差作为对点预测结果的评价指标, 灵敏度、可信度以及二者综合指标对概率预测区间进行评估.

1) 平均绝对百分比误差  $e$ :

$$e = \frac{1}{N} \sum_{i=1}^N \left| \frac{\text{ttest}(i) - \text{ytest}(i)}{y_{\max}} \right| \times 100\%, \quad (15)$$

式中,  $N$  为验证样本个数,  $\text{ttest}(i)$  和  $\text{ytest}(i)$  分别为第  $i$  个验证样本的点预测值与实际值,  $y_{\max}$  为验证样本中最大的功率值.

2) 灵敏度  $L$ :

$$L = \frac{1}{N} \sum_{i=1}^N \frac{\text{up}(i) - \text{low}(i)}{y_i} \times 100\%, \quad (16)$$

式中,  $\text{up}(i)$  和  $\text{low}(i)$  分别为第  $i$  个验证样本概率预测的上限与下限,  $y_i$  为第  $i$  个验证样本的功率值.

3) 可信度  $R$ :

$$R^{1-\alpha} = [\lambda - (1 - \alpha)] \times 100\%, \quad (17)$$

式中,  $R^{1-\alpha}$  为在置信度  $1 - \alpha$  下的可靠度值,  $\lambda$  为在置信度  $1 - \alpha$  下实际值落入预测置信区间的个数与总验证样本个数的比值.

4) 综合得分 (score):

$$\delta_i^\alpha(i) = \text{up}(i) - \text{low}(i), \quad (18)$$

$$\text{sc}(i) = \begin{cases} -2\alpha\delta_i^\alpha(i) - 4[\text{low}(i) - \text{yt}(i)], & \text{yt}(i) < \text{low}(i), \\ -2\alpha\delta_i^\alpha(i), & \text{yt}(i) \in [\text{low}(i), \text{up}(i)], \\ -2\alpha\delta_i^\alpha(i) - 4[\text{yt}(i) - \text{up}(i)], & \text{yt}(i) > \text{up}(i), \end{cases} \quad (19)$$

$$\text{综合得分} = \frac{1}{N} \sum_{i=1}^N \text{sc}(i), \quad (20)$$

式中,  $\delta_i^\alpha(i)$  为在置信度  $1 - \alpha$  下第  $i$  个点处的区间宽度,  $\text{up}(i)$  和  $\text{low}(i)$  分别为第  $i$  个验证样本概率预测的上限与下限,  $\text{yt}(i)$  为验证样本中第  $i$  个功率值,  $N$  为验证样本个数,  $\text{sc}(i)$  为第  $i$  个点处的区间得分.

实际进行风电功率预测时, 灵敏度  $L$  评价概率预测结果区间的平均宽度对随机变化范围的灵敏区域, 其绝对值越小表示灵敏度越高; 可信度  $R$  评价概率预测置信区间的可信程度, 其绝对值越小表示可信度越高; 综合得分  $\text{score}$  评价概率预测区间的综合质量, 并且综合指标绝对值越小区间质量越高; 平均绝对百分比误差  $e$  评价点预测结果的误差大小, 其值越小结果越准确.

## 4.2 算例测试

该东北风电场每 5 min 采集一个风功率值,选取风电场某段时间内 5 000 个功率值作为样本,对风电功率原始样本进行三级小波分解,得到 4 个小波样本信号.取当前时刻前 110 个风功率值作为预测模型的输入向量,取未来 4 h 时刻的值作为预测模型的输出向量,构建 3 000 个训练样本集,并划分模型训练集与验证集比值为 4:1,风电场的装机容量为 148.4 MW.以此建立风电功率超短期预测模型,实现对该风电场功率未来 4 h 时刻的超短期预测.

本文在建立 LSTM 网络时,隐含 LSTM 网络层数为 10 层时,所取得的预测效果最佳,网络所采用的误差训练函数为均方误差函数,目标优化器为 adam 函数,Dropout 层设为 0.5,输出层激活函数选 linear 函数,网络训练迭代次数设为 2 000.采用本文的预测模型在不同置信度的条件下,对该东北风电场风电功率进行超短期概率预测整体仿真的结果分别如图 3、4 所示.




图 3 4 h 时刻的风电功率预测结果

Fig. 3 Wind power prediction result at 4 h time




图 4 置信度为 95% 的风电功率概率预测区间

Fig. 4 The wind power prediction intervals at 95% confidence

## 4.3 预测结果评估

风电功率超前 4 h 预测结果平均绝对百分比误差  $e$ , 及与现有方法对比结果如表 1 所示.

表 1 预测结果平均绝对百分比误差

Table 1 Mean absolute percentage error of prediction results

方法	$e$
LSTM 方法 <sup>[27]</sup>	0.018 6
DWT-BP 方法 <sup>[7]</sup>	0.029 7
本文方法	0.016 6

选取的东北某风电场的数据在单独 LSTM 方法下预测精度较普通 BP 网络精度要高,较本文预测模型下的精度要低,因此采用本文的预测模型,预测精度得到了提升.

计算东北某风电场在 95% 置信度下概率预测结果的各项指标,并且分别与现有的方法进行对比,结果如表 2 所示,本文方法取得较好结果.

表 2 95% 置信度下风电功率概率预测指标

Table 2 Prediction index of wind power probability under 95% confidence

方法	R(可信度)	L(灵敏度)	综合得分(score)
LSTM 方法 <sup>[27]</sup>	-0.379 9	0.046 4	-7.145 8
DWT-BP 方法 <sup>[7]</sup>	-0.050 0	0.127 3	-3.698 0
本文方法	0.003 3	0.086 1	-2.903 9

## 5 结束语

本文将深度学习技术与小波分解技术相结合用于风电功率超短期概率预测,并且使用最大似然估计的方法来处理预测模型的误差,将模型的误差分布近似为高斯分布,提出了风电功率超短期 4 h 概率预测方法.通过对东北某风电场风功率进行超短期概率区间预测仿真并与其他方法比较,得出以下结论:

1) 将 LSTM 网络与小波分解方法结合对非平稳数据进行概率预测具有很好的效果,能改进区间预测的效果,增强模型的泛化能力.

2) 本文方法没有考虑更多资源之间的关联特性.影响预测误差的因素是多方面的,需要对资源之间潜在的关系进行深度挖掘.高斯分布只能近似代表预测误差的分布情况,对于误差关联特性有待进一步挖掘.

## 参考文献

### References

- [1] 叶林,赵永宁.基于空间相关性的风电功率预测研究综述[J].电力系统自动化,2014,38(14):126-135  
YE Lin,ZHAO Yonning.A review on wind power predic-

- tion based on spatial correlation approach[J].Automation of Electric Power Systems,2014,38(14):126-135
- [2] Teng Q,Wang C,Jun L,et al.Modeling the temporal correlation of ultra-short term wind power forecast error based on copula theory[C]//Proceedings of IEEE Conference on Energy Internet and Energy System Integration,2017:1-4
- [3] 吴向足,乔颖,鲁宗相,等.风电功率概率预测方法及展望[J].电力系统自动化,2017(18):167-175  
WU Wenzu,QIAO Ying,LU Zongxiang,et al.Methods and prospects for probabilistic forecasting of wind power[J].Automation of Electric Power Systems,2017,41(18):167-175
- [4] 薛禹胜,郁琛,赵俊华,等.关于短期及超短期风电功率预测的评述[J].电力系统自动化,2015,39(6):141-151  
XUE Yusheng,YU Chen,ZHAO Junhua,et al.A review on short-term and ultra-short-term wind power prediction[J].Automation of Electric Power Systems,2015,39(6):141-151
- [5] Kong W,Dong Z,Jia Y,et al.Short-term residential load forecasting based on LSTM recurrent neural network[J].IEEE Transactions on Smart Grid,2019,10(1):841-851
- [6] 黄志刚,刘虹,刘娟,等.基于C5.0算法的胃癌生存预测模型研究[J].南京信息工程大学学报(自然科学版),2017,9(4):406-410  
HUANG Zhigang,LIU Hong,LIU Juan,et al.Gastric cancer prediction model based on C5.0 classification algorithm[J].Journal of Nanjing University of Information Science & Technology(Natural Science Edition),2017,9(4):406-410
- [7] 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
- [8] 王彩霞,鲁宗相,乔颖,等.基于非参数回归模型的短期风电功率预测[J].电力系统自动化,2010,34(16):78-82  
WANG Caixia,LU Zongxiang,QIAO Ying,et al.Short-term wind power forecast based on non-parametric regression model[J].Automation of Electric Power Systems,2010,34(16):78-82
- [9] 王松岩,于继来.风速与风电功率的联合条件概率预测方法[J].中国电机工程学报,2011(7):7-15  
WANG Songyan,YU Jilai.Joint conditions probability forecast method for wind speed and wind power[J].Proceedings of the CSEE,2011,31(7):7-15
- [10] 叶林,任成,赵永宁,等.超短期风电功率预测误差数值特性分层分析方法[J].中国电机工程学报,2016,36(3):692-700  
YE Lin,REN Cheng,ZHAO Yonning,et al.Stratification analysis approach of numerical characteristics for ultra-short-term wind power forecasting error[J].Proceedings of the CSEE,2016,36(3):692-700
- [11] 周封,金丽斯,刘健,等.基于多状态空间混合 Markov 链的风电功率概率预测[J].电力系统自动化,2012,36(6):29-33  
ZHOU Feng,JIN Lisi,LIU Jian,et al.Probabilistic wind power forecasting based on multi-state space and hybrid markov chain models[J].Automation of Electric Power Systems,2012,36(6):29-33
- [12] 李智,韩学山,杨明,等.基于分位点回归的风电功率波动区间分析[J].电力系统自动化,2011,35(3):83-87  
LI Zhi,HAN Xueshan,YANG Ming,et al.Wind power fluctuation interval analysis based on quantile regression[J].Automation of Electric Power Systems,2011,35(3):83-87
- [13] 林优,杨明,韩学山,等.基于条件分类与证据理论的短期风电功率非参数概率预测方法[J].电网技术,2016,40(4):1113-1119  
LING You,YANG Ming,HAN Xueshan,et al.Nonparametric approach for short-term probabilistic wind generation forecast based on conditional classification and evidence theory[J].Power System Technology,2016,40(4):1113-1119
- [14] Tian Y,Pan L.Predicting short-term traffic flow by long short-term memory recurrent neural network[C]//Proceedings on IEEE International Conference on Smart City Socialcom Sustaincom,2015:153-158
- [15] Hochreiter S,Schmidhuber J.Long short-term memory[J].Neural Computation,1997,9(8):1735-1780
- [16] 陈龙龙,王波,袁玲.一种电力变压器神经网络故障诊断方法[J].南京信息工程大学学报(自然科学版),2018,10(2):199-202  
CHEN Longlong,WANG Bo,YUAN Ling.A neural network-based method for fault diagnosis of power transformer[J].Journal of Nanjing University of Information Science & Technology(Natural Science Edition),2018,10(2):199-202
- [17] 林增贤,刘肖凡.追踪比特币新币走向:一种基于交易网络结构特征识别矿工的方案[J].南京信息工程大学学报(自然科学版),2018,10(4):450-455  
LIN Zengxian,LIU Xiaofan.Tracking the circulation routes of fresh coins in Bitcoin;a way to identify coinminers based on transaction network structural properties[J].Journal of Nanjing University of Information Science & Technology(Natural Science Edition),2018,10(4):450-455
- [18] Gao L,Guo Z,Zhang H W,et al.Video captioning with attention-based LSTM and semantic consistency[J].IEEE Transactions on Multimedia,2017,19(9):2045-2055
- [19] 卢剑权,李海涛,刘洋,等.矩阵半张量积方法在逻辑网络和相关系统中的应用综述[J].南京信息工程大学学报(自然科学版),2017,9(4):341-364  
LU Jianquan,LI Haitao,LIU Yang,et al.A survey on the applications of semi-tensor product of matrices on logical networks and other related systems[J].Journal of Nanjing University of Information Science & Technology(Natural Science Edition),2017,9(4):341-364
- [20] 俞祝良.人工智能技术发展概述[J].南京信息工程大学学报(自然科学版),2017,9(3):297-304

- YU Zhuliang. Review of progress on artificial intelligence [J]. *Journal of Nanjing University of Information Science & Technology (Natural Science Edition)*, 2017, 9(3): 297-304
- [21] Tzikas D, Likas A, Galatsanos N. The variational approximation for Bayesian inference [J]. *IEEE Signal Processing Magazine*, 2008, 25(6): 131-146
- [22] 陈昊, 高山, 王玉荣, 等. 基于广义自回归条件异方差偏度峰度模型的风电功率预测方法[J]. *中国电机工程学报*, 2017, 37(12): 3456-3461  
CHEN Hao, GAO Shan, WANG Yurong, et al. Wind power forecasting method based on generalized autoregressive conditional heteroskedasticity with skewness and kurtosis model [J]. *Proceedings of the CSEE*, 2017, 37(12): 3456-3461
- [23] Haque A U, Nehrir M H, Mandal P. A hybrid intelligent model for deterministic and quantile regression approach for probabilistic wind power forecasting [J]. *IEEE Transactions on Power Systems*, 2014, 29(4): 1663-1672
- [24] 丁华杰, 宋永华, 胡泽春, 等. 基于风电场功率特性的日前风电预测误差概率分布研究[J]. *中国电机工程学报*, 2013, 33(34): 136-144  
DING Huajie, SONG Yonhua, HU Zechun, et al. Probability density function of day-ahead wind power forecast errors based on power curves of wind farms [J]. *Proceedings of the Chinese Society of Electrical Engineering*, 2013, 33(34): 136-144
- [25] Glazebrook J, Rogers T, McClelland J. Review of semantic cognition: a parallel distributed processing approach [J]. *Cognitive Systems Research*, 2010, 11(2): 204-207
- [26] Chen K, Huo Q. Training deep bidirectional LSTM acoustic model for LVCSR by a context-sensitive-chunk BPTT approach [J]. *ACM Transactions on Audio, Speech, and Language Processing*, 2016, 24(7): 1185-1193
- [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

## Ultra-short-term probability prediction of wind power based on wavelet decomposition and long short-term memory network

WANG Peng<sup>1</sup> SUN Yonghui<sup>1</sup> ZHAI Suwei<sup>1</sup> HOU Dongchen<sup>1</sup> WANG Sen<sup>1</sup>

<sup>1</sup> College of Energy and Electrical Engineering, Hohai University, Nanjing 210098

**Abstract** With the large-scale wind power connected into the power systems, the intermittency and randomness of wind power have a great impact on the stability of the power systems. Therefore, the accurate prediction of wind power has become one of the most important ways to solve this problem. In this paper, considering the timing memory characteristics of long short-term memory (LSTM) network, by combining wavelet decomposition and LSTM network, an ultra-short-term probability prediction model for wind power based on wavelet-LSTM network is proposed. Firstly, wavelet decomposition is used to smooth the sequence of the original time sequence. Then the LSTM network prediction model for the sequence samples is developed. By using the maximum likelihood estimate method, the Gaussian distribution function of prediction error can be estimated. Thus the probability prediction of wind power in the future 4 hours could be realized. Finally, based on the wind farm data in Northeast China, simulation results show that wavelet decomposition with deep learning method can improve the accuracy of prediction. The interval reliability of probability prediction is also improved.

**Key words** wavelet decomposition; long short-term memory network; wind power; probability prediction