

# 基于随差遗忘长短期记忆的风电功率实时预测

李春平<sup>1</sup>, 张沛<sup>1</sup>, 彭春华<sup>1</sup>, 尹瑞<sup>2</sup>, 时珉<sup>2</sup>

(1. 华东交通大学电气与自动化学院, 江西省 南昌市 330013;

2. 国网河北省电力有限公司, 河北省石家庄市 050021)

## Real-time Prediction of Wind Power Based on Error Following Forget Gate-based Long Short-term Memory

LI Chunping<sup>1</sup>, ZHANG Pei<sup>1</sup>, PENG Chunhua<sup>1</sup>, YIN Rui<sup>2</sup>, SHI Min<sup>2</sup>

(1. Electrical and Automation Engineering College of East China Jiaotong University, Nanchang 330013, Jiangxi Province, China;

2. State Grid Hebei Electric Power Company Limited, Shijiazhuang 050021, Hebei Province, China)

**摘要:** 由于标准长短期记忆 (long short-term memory, LSTM) 遗忘门更新方式不能实时反映预测误差对模型预测的修正作用, 提出随差遗忘长短期记忆 (Error Following Forget Gate-based LSTM, EFFG-based LSTM) 的风电功率实时预测模型。用上一时刻的风电功率预测值与实际值的误差来更新遗忘门, 从而降低上一时刻预测误差对此时风电功率预测精度的影响, 提升风电功率滚动预测精度, 并采用某实际风电场的历史风电功率数据和数值预报气象数据进行了验证, 结果表明: 基于 EFFG-based LSTM 网络风电功率实时预测模型预测值的均方根误差小于 3%, 满足系统调度相关要求; 准确率、合格率达到 90% 以上, 比基于支持向量和标准 LSTM 模型具有更高的预测精度。

**关键词:** 风电功率; 实时预测; 时间序列; 随差遗忘长短期记忆

**Abstract:** Because of the fact that the update mode of the forget gate of standard long short-term memory (abbr. LSTM) could not reflect the correction of predicated error to the model based prediction value in real time, a real-time wind power prediction model utilizing error following forget gate (abbr. EFFG)-based LSTM was proposed. The error between the predicted value of wind power and the actual value at the previous moment was used to update the forget gate, thus the influence of the predicted error of the wind power at the previous moment on the prediction accuracy at current moment could be reduced, and the rolling prediction accuracy of wind power could be improved. The historical wind power data of a certain actual wind farm and the numerical forecasted meteorological data were

utilized to verify the proposed model. Verification results show that the root-mean-square error of the value predicted by the proposed real-time wind power prediction model based on EFFG-based LSTM is less than 3%, and both accuracy and acceptability reach more than 90%, thus such results are better than the prediction accuracy by the models based on support vector machine and standard LSTM model.

**Keywords:** wind power; real-time prediction; time series; error following forget gate-based long short-term memory (EFFG-based LSTM)

**DOI:** 10.19725/j.cnki.1007-2322.2020.0200

## 0 引言

由于风电的波动性和间歇性特点, 并网风力发电在提供清洁能源的同时, 给电力系统的安全、稳定运行带来了严峻挑战<sup>[1]</sup>。精确的实时风电功率预测能够帮助调度滚动地修正日出力计划曲线, 在保证电力系统运行的安全性和经济性的同时, 提高风电的消纳水平<sup>[2]</sup>。风电功率预测按预测时间尺度有超短期 (0~4 h 内)、短期 (1~3 天内)、中长期 (数月/年内)<sup>[3]</sup>。而风电功率实时预测是指自预测时刻起对未来 15 min 至 4 h 内风电功率进行预测, 两个预测值之间间隔为 15 min, 实时滚动预测各个时间点的风电功率<sup>[4]</sup>。因此风电功率实时预测为超短期多步预测。

风电功率预测方法可以分为两大类, 即物理方法和统计方法。物理方法一般基于数值天气预报先对风速进行预测, 然后根据风速-功率曲线得到风电功率的预测值。文献<sup>[5]</sup>利用美国航天局

**基金项目:** 河北省重点研发计划项目 (19214310D)

Key Research and Development Project of Hebei Province, China (19214310D)

地球观测系统的全球风速数据,从而得到中国某风电场未来风速,再根据风机的风速-功率特性曲线预测不同时间尺度下的风电功率;文献[6]采用 $K$ 均值聚类方法对预测日前20天的数值天气预报(Numerical Weather Prediction, NWP)数据样本进行聚类,在各类下分别建立模型预测短期风电功率。由于物理方法高度依赖数值天气预报的数据,其精度受数值天气预报精度的影响较大。统计方法则是基于功率、气象历史数据进行预测。目前比较常用的有时间序列法、人工神经网络(Artificial Neural Networks, ANN)法、支持向量机(Support Vector Machine, SVM)法等,以及这些方法的组合方法[7];文献[8]考虑风电功率时间序列波动性特点,建立了多重离群点平滑转换自回归模型进行短期风电功率预测,但未利用NWP时序序列信息会导致其精度随着预测时间增长而降低;文献[9]根据实测功率数据、不同高度的气象数据,建立了基于神经网络的风电功率误差带预测模型,实现了误差带预测,与传统方法相比预测精度有提高;文献[10]根据风速、风向、气温、气压等气象特征,建立了基于SVM的短期风电功率预测,与ANN相比其预测精度有所改善;文献[11]将风速分段后在高、低风速段使用最小二乘支持向量机预测模型,中风速段使用高斯模型预测,预测时间与精度优于单一模型。

对于如何提高风电功率实时预测精度,大量文献提出了许多实时预测模型。基本路线是利用历史实际风电功率(Real Wind Power, RWP)时间序列和历史风速、风向等数据对模型进行训练,然后以此模型进行功率预测。文献[12]利用灰色关联关系和标准风速功率曲线建立了基于灰色关联决策的风电功率实时预测模型,相较于完全基于历史风速或者完全基于历史功率的模型,该方法提高了预测精度;文献[13]利用数据挖掘和模糊聚类技术将不同的机组进行分类,并分别进行实时预测,将预测结果进行累加得到最终的预测结果;文献[14]利用经验模态分解算法将风电功率时间序列分解为若干子序列,以及值点划分法将若干子序列重构为3个分量,再在每个分量上建立基于集对分析的实时预测模型,最后将各个分量预测结果叠加;文献[15]采用集合经验模态分解算法将风电功率时间序列分解为各个子序列,对各子序列建立相关向量机预测模型,最后将得到的各子序列预测结果叠加得到最终功率预测值。

然而这类方法的不足在于:①因为其输入特征只单纯利用历史风电功率时间序列以及历史气象数据预测未来风电功率,而不考虑未来预测时段的NWP数据,然而NWP对风电功率的影响是根本性的和趋势性的,所以其预测精度会随着预测时间尺度的增长而快速下降;②风电功率时间序列具有动态特性<sup>[16]</sup>,即系统的输出不仅与当前时刻的输入有关,而且与过去的输入有关,但现有时间序列模型(如Auto Regression Moving Average, ARMA)、常用的神经网络(ANN、SVM等)结构决定了其并不能学习到风电功率、风速、风向等时间序列间的关联性,因此风电功率预测的精度难于再提高。

文献[17]提出一种基于长短期记忆(long short-term memory, LSTM)网络的超短期风电功率预测模型,因LSTM网络有短期记忆能力,即能反映前面时刻输出值对当前时刻值的影响,与ARMA、ANN、SVM等模型相比其预测精度有显著提高。但其不足在于:①其输入特征只单纯利用历史风电功率时间序列以及历史气象数据预测未来风电功率,而不考虑未来预测时段的NWP数据。所以其难以预测由于气象突变造成的功率突变时的功率值,且随着预测时间尺度的增长这种问题越严重;②其对如何选定LSTM的输入时间步长,即使用多少个历史时刻来预测下一时刻的输出值未给出依据与方法,而输入步长会直接影响LSTM预测性能;③所用的LSTM模型为标准的LSTM,未对其为适合风电功率预测进行优化改进。而气象因素或风电功率的随机性、波动性极强且数值尺度相差极大,因此有必要为风电功率预测对标准LSTM进行优化改进。

因此,本文提出考虑数值天气预报和风电功率时序间关联关系的随差遗忘长短期记忆风电功率滚动预测方法。首先,采用斯皮尔曼相关性分析方法,对预测时刻的风电功率与历史时刻的风电功率,以及预测时刻的风电功率与预测时刻的NWP数据(如风速,风向等)进行相关性分析。筛选出相关性强的历史时刻风电功率与数值天气预报的气象信息,作为每步随差遗忘长短期记忆(Error Following Forget Gate-based LSTM, EFFG-based LSTM)预测模型的多变量输入特征序列。当预测 $t$ 时刻时,利用 $t-1$ 时刻风电功率预测值和实际值的差值作为EFFG-based LSTM模型遗忘门的输入来调整遗忘门的输出,以降低 $t-1$ 时刻

预测误差对  $t$  时刻风电功率预测精度的影响，从而提高滚动预测精度。

### 1 相关性分析与输入特征序列构建

气象数据与风电功率都具有时序相关性，即当前时刻气象数据和风电功率与历史时刻风电功率有关。因此需要量化评估当前  $t$  时刻风电功率与历史 ( $t-1$ 、 $t-2$  等) 时刻气象数据和风电功率的相关性，以确定 EFFG-based LSTM 的输入变量。

由于气象因素和风电功率不服从某种特定概率分布，因此宜采用斯皮尔曼相关系数法来分析风电功率与 NWP 特征之间以及风电功率时间序列自相关性。斯皮尔曼相关性系数，也即斯皮尔曼秩相关系数。“秩”可以理解成一种顺序或者排序，它根据原始数据的排序位置进行求解：

$$\rho_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (1)$$

式中： $n$  为样本数量； $d_i$  为两列第  $i$  个样本数列重

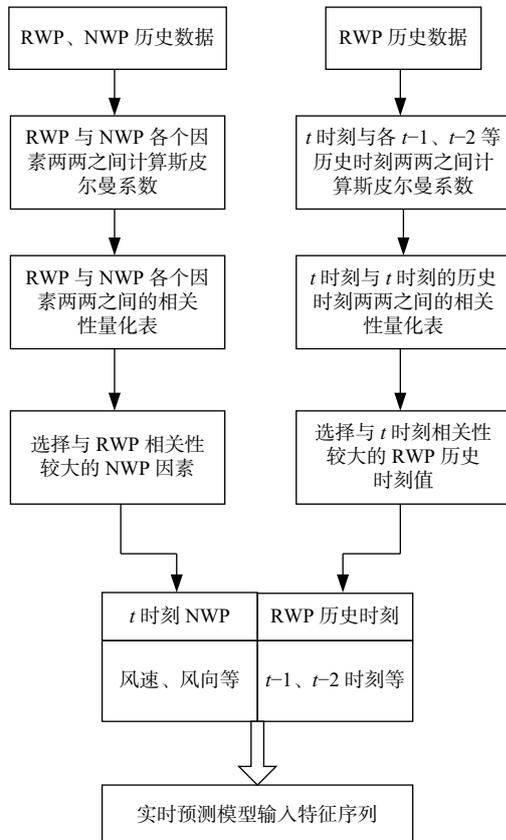


图 1 实时预测输入特征序列数据的构建

Fig. 1 Construction of input feature sequence data for real time prediction

新按降序排列后的序号差。

如图 1 所示，以斯皮尔曼相关性方法进行风电功率与各 NWP 特征相关性量化分析、风电功率时间序列自相关性量化分析后，重新构建了一个包含历史时刻 RWP 与预测时刻 NWP 的特征序列输入，以此时间序列作为每步预测的输入进行实时滚动的风电功率预测。

### 2 随差遗忘长短期记忆网络

在任意时刻 (如  $t$  时刻) 每个 LSTM 单元 (cell) 输入有 3 个： $t$  时刻 LSTM cell 的输入变量  $x(t)$ 、 $t-1$  时刻 LSTM cell 的输出量  $h(t-1)$ 、以及  $t-1$  时刻 LSTM cell 的状态量  $c(t-1)$ 。在本文中， $x(t)$  为  $t$  时刻输入到 LSTM 单元中的历史风电功率与  $t$  时刻的预报气象； $h(t-1)$  为  $t-1$  时刻 LSTM 单元输出的风电功率预测值； $c(t-1)$  为保存或遗忘了的前  $t-1$  时刻 LSTM 单元的历史输出值。输出有 2 个： $t$  时刻 LSTM 输出值  $h(t)$  和  $t$  时刻 LSTM 单元状态  $c(t)$ ，即  $t$  时刻的风电功率预测值和历史风电功率预测值的保存或遗忘状态。在任意时刻每个 LSTM 都拥有 3 个门，来保护和控制 LSTM cell 状态，分别为：输入门、输出门和遗忘门<sup>[18]</sup>。图 2 展示了 LSTM 时序预测模型及其内部结构。

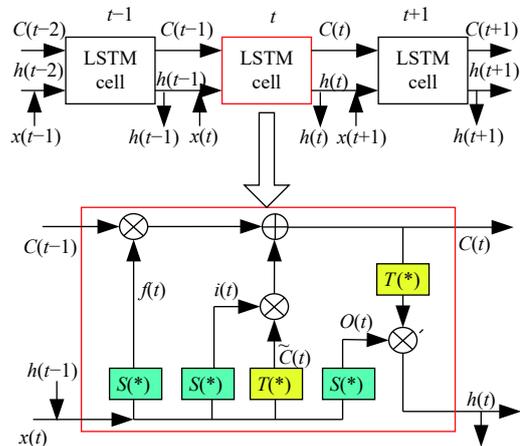


图 2 LSTM 时序模式及其内部结构

Fig. 2 LSTM timing mode and its internal structure

遗忘门  $f(t)$ ：根据  $t-1$  时刻输出  $h(t-1)$  和  $t$  时的输入  $x(t)$ ，确定了  $t-1$  时刻  $c(t-1)$  信息有多少保存到  $t$  时刻的单元状态  $c(t)$  中。因此，遗忘门的数学表达式：

$$f_t = s(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

式中： $s$  为 sigmoid 激活函数； $W_f$  为遗忘门的权

重矩阵； $b_f$ 为遗忘门的偏置项。

在风电功率实时滚动预测模式下进行  $t$  时刻预测时， $t-1$  时刻模型的预测值与测量的实际值是已经可以得到，所以就得到了实际值与预测值的偏差（误差）。此时的偏差不仅反映了  $t-1$  时刻模型的预测能力也包含了历史时刻信息对预测值到底还能有多少积极的作用。如果计算后发现偏差巨大，那就说明历史时刻值对  $t$  时刻预测已无太大的支持作用了进而要减小历史时刻值对预测输出值的影响。在 LSTM 单元中，减小历史时刻信息对当前预测的作用也即减小  $t-1$  时刻的 LSTM 单元状态  $c(t-1)$ ，是通过遗忘门来实现的。因此，遗忘门要根据  $t-1$  时刻预测值与实际值偏差情况调整遗忘门大小，即进行随差遗忘。但是从式 (2) 可知标准 LSTM 的遗忘门是由  $t-1$  时刻输出  $h(t-1)$  和  $t$  时刻的输入  $x(t)$  来确定的，这种更新方式不能计及  $t-1$  时刻预测值与实际值的偏差对  $t$  时刻遗忘门的调整作用。为此，把  $t-1$  时刻预测值与实际值两者的绝对误差来作为遗忘门更新的输入量如：

$$f_t = s(W_f \cdot K + b_f) \quad (3)$$

式中： $K = h'_{t-1} - h_{t-1}$ ； $h'_{t-1}$  为  $t-1$  时刻实际值； $h_{t-1}$  为  $t-1$  时刻的预测值。

根据式 (3)，遗忘门根据  $t-1$  时刻预测值与实际值的误差反馈来调整  $t$  时刻遗忘门的大小，即实现了对历史信息的随差遗忘。在风电功率实时预测模式下，改进后的更新规则更适合于实时功率预测。

随差遗忘长短期记忆网络在  $t$  时刻结构如图 3 所示。随差遗忘长短期记忆网络与标准的长短期记忆网络相比，除了遗忘门输入改进为预测值  $h_{t-1}$  与实际值  $h'_{t-1}$  外，其它门的更新方式与标准的长短期记忆一样。随差遗忘长短期记忆网络输

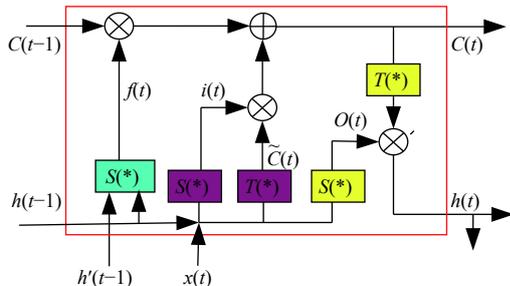


图 3 随差遗忘 LSTM 单元内部结构

Fig. 3 Unit internal structure of Error Following Forget Gate-based LSTM

入门与输出门的更新方式如下：

输入门  $i(t)$ ：根据  $t-1$  时刻输出  $h(t-1)$  和  $t$  时刻的输入  $x(t)$  来决定将当前的信息量保存到  $t$  时刻单元状态  $c(t)$  中，也可以避免将当前无关紧要的信息进入到  $c(t)$  中。因此，输入门的数学表达式为：

$$i_t = s(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

式中： $W_i$  为遗忘门的权重矩阵； $b_i$  为遗忘门的偏置项。

当前时刻记忆  $\tilde{c}(t)$ ：当前时刻的记忆根据  $t-1$  时刻输出  $h(t-1)$  和  $t$  时刻的输入  $x(t)$  来确定，即  $\tilde{c}(t)$  中保存的是  $t$  时刻的输入信息。因此， $t$  时刻记忆  $\tilde{c}(t)$  的数学表达式为：

$$\tilde{c}_t = T(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

式中： $T$  为  $\tanh$  激活函数； $W_c$  为输入门的权重矩阵； $b_c$  为输入门的偏置项。

新单元状态  $C(t)$ ：由  $t-1$  时刻的单元状态  $c(t-1)$  乘以遗忘门  $f(t)$ ，再用当前输入的单元状态  $\tilde{c}(t)$  乘以输入门  $i(t)$ ，后将两个积相加。把当前  $t$  时刻的记忆  $\tilde{c}(t)$  和长期的记忆  $c(t-1)$  组合在一起，形成了新的单元状态  $c(t)$ 。因此，新单元状态  $C(t)$  的数学表达式为：

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (6)$$

根据式 (6) 新单元状态， $C(t)$  由于遗忘门的控制，可以保存很久之前的信息，由于输入门的控制，又可以避免当前无关紧要的内容进入记忆。

输出门  $O(t)$ ：根据上个时刻输出  $h(t-1)$  和当前的输入  $x(t)$  来控制最终单元状态  $c(t)$  有多少输出到 LSTM 最终输出  $h(t)$  中。因此，输出门  $O(t)$  的数学表达式为：

$$o_t = s(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

式中： $W_o$  为输入门的权重矩阵； $b_o$  为输入门的偏置项。

最后，随差遗忘长短期记忆模块的最终输出  $h(t)$  为：

$$h_t = o_t \cdot \tanh(c_t) \quad (8)$$

至此，由公式 (3)~(8) 构成一个完整 EFFG-based LSTM 单元。

### 3 基于随差遗忘长短期记忆的风电功率实时预测模型

基于 EFFG-based LSTM 的风电功率实时预测

模型动态结构如图4所示,假设历史的RWP取 $t-1, t-2, t-3$ 时刻功率;NWP特征取风速与风向。在预测 $t$ 时刻功率时,将由RWP( $t-1$ 时刻功率; $t-2$ 时刻功率; $t-3$ 时刻功率)与NWP( $t$ 时刻风速; $t$ 时刻风向)构成的时间序列输入数据输入到EFFG-based LSTM网络中。然后EFFG-based LSTM网络模型预测出 $t$ 时刻的风电功率。在进行 $t+1$ 时刻预测时,把 $t$ 时刻实测功率与 $t-1, t-2$ 时刻功率和 $t+1$ 时刻风速、 $t+1$ 时刻风向作为输入数据;同时用 $t$ 时刻的预测值和功率实际值作为EFFG-based LSTM模型遗忘门的输入来更新遗忘门的大小,再预测输出 $t+1$ 时刻的风电功率。如此滚动预测出未来每个时刻的风电功率。

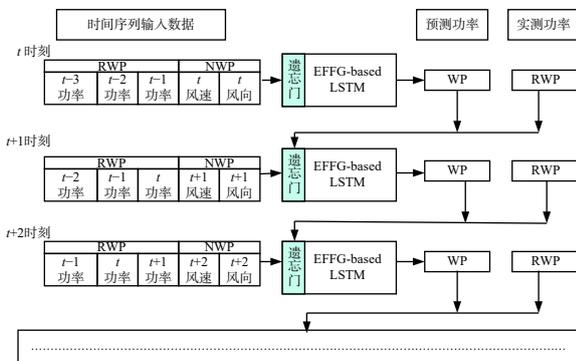


图4 基于随差遗忘长短期记忆风电功率预测流程图  
Fig. 4 Flow chart of wind power prediction based on EFFG-based LSTM

基于EFFG-based LSTM的风电功率实时预测模型在 $t$ 时刻的静态网络结构如图5所示,包含一层输入层(历史RWP与未来NWP数据及上一时刻模型预测与功率实际值)、一层隐含层(EFFG-based LSTM网络层)、一层输出层。

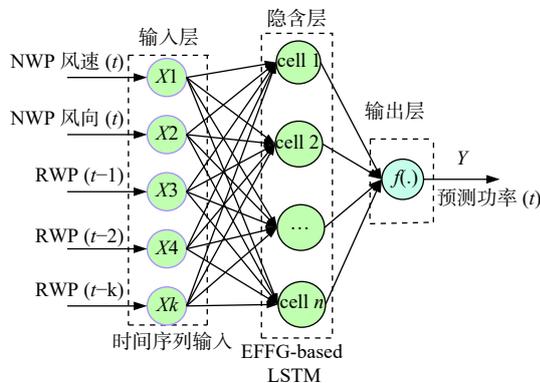


图5 基于随差遗忘长短期记忆风电功率预测模型网络结构图  
Fig. 5 Network structure diagram of wind power prediction model based on EFFG-based LSTM

输入层:输入层即时间序列模式的输入特征量,其中 $X$ 为当前 $t$ 时刻的过去时刻( $t-1, t-2, t-3$ 等)RWP与 $t$ 时刻NWP(风速、风向等)组成一组时间序列及上一时刻模型预测与功率实际值,输入层首先把输入数据根据式(9)进行归一化处理。

$$X' = \frac{x - (x_{\max} - x_{\min})/2}{(x_{\max} - x_{\min})/2} \quad (9)$$

式中: $x_{\max}$ 为该变量的极大值; $x_{\min}$ 为该变量的极小值。

再把归一化的数据转化为EFFG-based LSTM神经元(cell)输入数据的格式,最后数据进入到隐含层,即EFFG-based LSTM网络中。

隐含层:隐含层即EFFG-based LSTM网络,一层隐含层既能保证预测模型较快的预测计算速度;另外不需要考虑由于隐含层过多致使网络过深而可能出现的过拟合现象。隐含层的神经元(cell)即为如图3所示的EFFG-based LSTM单元。

输出层: $f(\cdot)$ 为输出层激活函数, $Y$ 为下一时刻 $t$ 风电功率预测值。输出层把隐含层的输出进行加权与偏置后,输出一维的预测风电功率。因输入层已经把数据归一化,所以在输出层需要按式(10)进行反归一化计算。最后得到实际的风电功率预测值:

$$Y = \frac{1}{2} [y'(y_{\max} - y_{\min}) + (y_{\max} + y_{\min})] \quad (10)$$

## 4 算例分析

### 4.1 数据说明与试验设计

本文样本数据来自中国西北某实际风电场的历史数据,即2017年7月1日至7月21日的NWP数据与历史实际风电功率。此期间风电场的装机容量为90 MW,风电功率采样时间间隔为15 min,NWP预报间隔为15 min。NWP包含有170 m、100 m、30 m处的风速与风向。

首先利用斯皮尔曼相关系数法进行风电功率与NWP各特征相关性系数的计算、当前风电功率与历史风电功率相关性系数的计算,以此筛选出预测模型输入特征变量。

表1中数值为风电功率与NWP各特征量的斯皮尔曼相关系数,数值大小反映了风电功率与NWP各特征量相关性的强弱。从表1中可知:此

风电场当前  $t$  时刻风电功率与当前  $t$  时刻 100 m、30 m 处的风速与风向最相关。因此，此风电场要预测  $t$  时刻的风电功率时需将  $t$  时刻 100 m、30 m 处的风速与风向计入到新构建的时间序列中。

表 1 风电功率与各个 NWP 特征量之间的斯皮尔曼相关系数分析结果

Table 1 Analysis results of wind power and Spearman correlation coefficients among NWP characteristic quantities

位置	NWP特征量	斯皮尔曼相关系数
170 m	风速	0.45
170 m	风向	0.41
100 m	风速	0.85
100 m	风向	0.79
30 m	风速	0.64
30 m	风向	0.56
—	气压	0.40
—	温度	0.21
—	湿度	0.07

表 2 中数值为当前 ( $t$  时刻) 风电功率与历史 ( $t-1$ 、 $t-2$ 、 $t-3$  等时刻) 风电功率的斯皮尔曼相关系数，数值大小反映了当前时刻风电功率与各历史时刻风电功率相关性的强弱。从表 2 中可知：此风电场当前  $t$  时刻功率与  $t-1$ 、 $t-2$ 、 $t-3$  历史时刻功率的相关性较强。因此，要预测此风电场  $t$  时刻的功率时需将  $t$  时刻前 3 个时刻功率放入到新构建的时间序列中。

表 2  $t$  时刻与前  $t$  各时刻风电功率之间的斯皮尔曼相关系数分析结果

Table 2 Spearman correlation coefficient between real wind power at  $t$  time and at time  $t$  before

前 $t$ 时刻风电功率	斯皮尔曼相关系数
$t-1$ 时刻风电功率	0.87
$t-2$ 时刻风电功率	0.75
$t-3$ 时刻风电功率	0.53
$t-4$ 时刻风电功率	0.42
$t-5$ 时刻风电功率	0.21
$t-6$ 时刻风电功率	0.19

EFFG-based LSTM 网络参数设置：由前面的斯皮尔曼相关性计算可知输入步长为 4，即前三个历史时刻 RWP 与预测时刻 NWP。隐含层神经元即 EFFG-based LSTM 单元 (cell) 个数与预测精度 (如 RMSE) 并不是线性关系，即达到一定数目后再增加 cell 个数预测精度反而会减小。所

以，隐含层神经元数目要根据时间序列中输入特征量的多少、模型训练精度高低来确定，经反复试验验证其设置为 12 时预测精度最好。EFFG-based LSTM 各个门激活函数保持为默认值。

最后以 2017 年 7 月 1 日至 7 月 19 日的数据作为模型训练样本数据，进行两种时间尺度的实时预测。一是预测未来 4 h 内，即从 7 月 20 日 10:00 至 14:45 的风电功率；二是预测未来 24 h 内，即 7 月 21 日一天内的风电功率。

## 4.2 预测效果评估

因为实际风电功率值存在零值，预测效果评估指标中常用的平均绝对百分比误差 (mean absolute percentage error, MAPE) 将失去意义<sup>[19]</sup>，所以本文采用均方根误差 (root mean square error, RMSE) 和文献 [4] 中的准确率 AR、合格率 QR 指标对预测结果进行评价。

均方根误差 RMSE 计算公式：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - P'_i)^2} \quad (11)$$

式中： $n$  为预测结果个数； $P$  为目标数据的实际值； $P'$  为目标数据的预测值； $i$  为实际值、预测值序列编号。

准确率 AR 计算公式：

$$AR = \left[ 1 - \sqrt{\frac{1}{N} \sum_{K=1}^N \left( \frac{P_{MK} - P_{PK}}{P_{cap}} \right)^2} \right] \times 100\% \quad (12)$$

式中： $P_{MK}$  为  $K$  时间段的实际功率平均值； $P_{PK}$  为  $K$  时间段的预测功率平均值； $P_{cap}$  为风电场对应时段的开机容量； $N$  为预测总时段数。

合格率 QR 计算公式：

$$QR = \frac{1}{N} \sum_{K=1}^N B_K \times 100\% \quad (13)$$

$$\left( 1 - \frac{P_{MK} - P_{PK}}{P_{cap}} \right) \times 100\% \geq 75\% \quad B_K = 1 \quad (14)$$

$$\left( 1 - \frac{P_{MK} - P_{PK}}{P_{cap}} \right) \times 100\% < 75\% \quad B_K = 0 \quad (15)$$

## 4.3 预测结果比较

为验证和比较本文预测模型的预测性能，本文采用基于 SVM 和标准的 LSTM 风电功率实时预测模型作为对比模型进行预测结果对比分析。对比模型同样以 2017 年 7 月 1 日至 7 月 19 日的

数据作为训练数据,进行两种时间尺度的实时预测,即7月20日10:00至14:45的风电功率以及7月21日一天内的风电功率。各模型预测结果如图6、7所示。

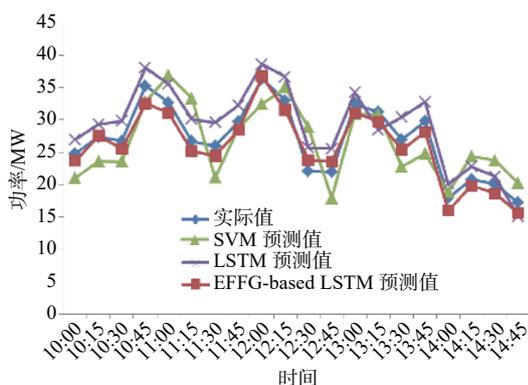


图6 3种模型实时预测4h内的风电功率

Fig. 6 Predicted wind power within 4 hours by three models

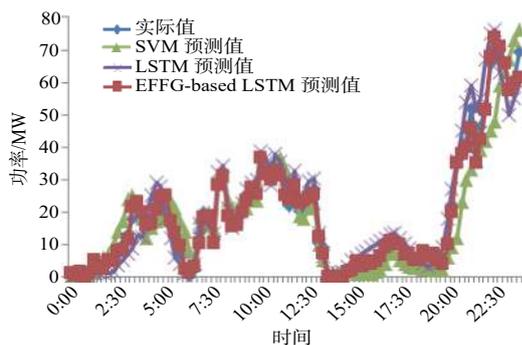


图7 3种模型实时预测24h内的风电功率

Fig. 7 Predicted wind power within 24 hours by three models

从图6、7可知:无论是在4h还是24h时间段上的预测,SVM预测模型是3个模型中表现最差的,其大致能预测出风电功率的变化趋势,但是具体到单一时间点时,预测值与实际值的绝对误差较大。原因在于SVM不是适合时间序列预测的模型,无法处理时间序列间关联信息和时间相关性。而且SVM也不是基于深度学习技术的模型,对大量样本的特征学习能力有限;LSTM与EFFG-based LSTM预测模型无论是4h还是24h时间段上的预测结果都优于SVM预测模型,因为其首先利用了深度学习技术来优化网络里的各个参数以达到最优,其次LSTM与EFFG-based LSTM网络为一种时间序列网络模型,能较好地处理风电功率时间序列间关联信息和时间相关性,

适合于有时序关联性的时间序列的预测。但是在风电功率波动性大的时段,即功率时增时减时段EFFG-based LSTM预测模型要明显优于LSTM预测模型。原因在于LSTM遗忘门的更新仅仅是通过上一时刻输出值与当前的所有输入量,因此不能反映上一时刻模型预测值与功率实际值之间的误差对遗忘门的影响。而EFFG-based LSTM遗忘门的更新是通过上一时刻模型预测值与功率实际值之间的误差来更新的。所以当误差较大时遗忘门也增大,也即模型的遗忘系数大了,历史输出值将遗忘更多,历史值对模型的作用就更小了。在风电功率突变的时段,下一时刻的功率与上几个时刻功率没有历史关联性,即预测下一时刻功率时其历史值没有支持作用了,所以要减小历史值的作用。EFFG-based LSTM遗忘门的更新正是契合此种情况,所以EFFG-based LSTM预测模型在风电功率波动性大的时段的预测效果是最好的。

表3、4分别为3个预测模型4h和24h预测结果的RMSE、准确率AR、合格率QR。

由表3、4可知:EFFG-based LSTM预测模型无论是在4h还是24h预测值的均方根误差RMSE、准确率AR、合格率QR相比于SVM和LSTM预测模型都是最优的。其RMSE虽然在24h时段预测时有所增大,但仅仅增大了0.65;在4h时段和24h时段的准确率、合格率都在90%以上。但是SVM和LSTM预测模型由4h时段到24h时段的准确率、合格率都出现了显著下降。特别

表3 各预测模型预测4h风电功率结果的评价指标

Table 3 Evaluation indices of predicted results within 4 hours by different prediction models

评价指标	预测模型		
	SVM	LSTM	EFFG-based LSTM
RMSE	8.47	3.48	2.32
AR	77.93	85.41	92.07
QR	76.56	84.25	91.46

表4 各预测模型预测24h风电功率结果的评价指标

Table 4 Evaluation indices of predicted results within 24 hours by different prediction models

评价指标	预测模型		
	SVM	LSTM	EFFG-based LSTM
RMSE	12.45	5.95	2.97
AR	70.38	80.94	91.34
QR	71.24	80.12	90.82

是 RMSE 分别增大了 3.98 与 2.47。表现较好的 LSTM 预测模型准确率、合格率也仅能达到 80% 左右。因为随着预测时段的增长, 包含了更多的风电功率剧烈波动情况, 而 SVM 与标准 LSTM 模型都无法有效应对功率剧烈变化的时段的预测。对此问题 EFFG-based LSTM 通过改进后的遗忘门得到比较有效的解决, 所以无论在短时间段还是长时间段 EFFG-based LSTM 预测模型各方面性能都优于 SVM 与标准 LSTM 模型。

## 5 结论

本文提出的基于 EFFG-based LSTM 风电功率实时预测方法。算例结果表明:

1) 采用斯皮尔曼法计算分析不同气象输入变量与风电功率之间的相关性以及各个历史时刻风电功率序列间的自相关性, 据此为预测模型输入变量的筛选提供依据, 进而构建了包含历史实际功率和预测时刻 NWP 的输入时间序列、为后续的 EFFG-based LSTM 输入时间步长的确定提供依据, 进而为 EFFG-based LSTM 的训练与预测设置合理的输入时间步长。

2) 有别于现有的仅利用历史功率进行风电功率预测, 本文方法在输入特征上除了利用历史功率外还计及了 NWP 数据, 即有效利用了多变量信息; 其次 NWP 数据的加入一定程度上可以使预测模型提高在气象突变引起的风电功率突变时段的预测精度。

3) 基于标准 LSTM 建立的风电功率预测模型, 由于其遗忘门的更新输入会让其有较大历史惯性, 导致在风电功率变化剧烈时段的预测精度大大下降。本文对标准 LSTM 的遗忘门进行了改进, 建立的 EFFG-based LSTM 模型优于 LSTM 预测模型, 特别是在风电功率变化剧烈时段的预测精度。

历史实测气象数据中包含了风电场局部性的气象信息, 如何把 NWP 与实测气象进行有效结合, 以改善 NWP 预报的精度从而提高风电功率实时预测精度是有待下一步研究的问题。

## 参考文献

[1] 贺益康, 胡家兵. 双馈异步风力发电机并网运行中的几个热点问题 [J]. 中国电机工程学报, 2012, 32(27): 1-15.

HE Yikang, HU Jiabing. Several hot-spot issues associated with the grid-connected operations of wind-turbine driven doubly fed induction generators [J]. Proceedings of the CSEE, 2012, 32(27): 1-15 (in Chinese).

- [2] Carta J A, Velazquez S, Cabrera P. A review of measure-correlate-prediction (MCP) methods used to estimate long-term wind characteristics at a target site [J]. Renewable and Sustainable Energy Reviews, 2013(4): 362-400.
- [3] 国家电网公司. 风电功率预测功能规范: Q/GDW 588-2011 [S]. 北京: 中国电力出版社, 2011.
- [4] 国家能源局. 风电厂功率预测预报管理暂行办法 [S]. 北京: 国家能源局, 2011.
- [5] 于大洋, 韩学山, 梁军, 等. 基于 NASA 地球观测数据库的区域风电功率波动特性分析 [J]. 电力系统自动化, 2011, 35(5): 77-81.
- YU Dayang, HAN Xueshan, LIANG Jun, *et al.* Study on the profiling of China's regional wind power fluctuation using GEOS-5 data assimilation system of national aeronautics and space administration of America [J]. Automation of Electric Power Systems, 2011, 35(5): 77-81 (in Chinese).
- [6] 王丽婕, 冬雷, 高爽. 基于多位置 NWP 与主成分分析的风电功率短期预测 [J]. 电工技术学报, 2015, 30(5): 79-84.
- WANG Lijie, DONG Lei, GAO Shuang. Wind power short-term prediction based on principal component analysis of NWP of multiple locations [J]. Transactions of China Electrotechnical Society, 2015, 30(5): 79-84 (in Chinese).
- [7] 史洁, 刘晓飞. 新能源功率预测算法优化研究 [J]. 发电技术, 2019, 40(01): 78-82.
- SHI Jie, LIU Xiaofei. The optimization research approaches for renewable energy output forecasting [J]. Power Generation Technology, 2019, 40(1): 78-82. (in Chinese)
- [8] 陈昊, 张建忠, 许超, 等. 基于多重离群点平滑转换自回归模型的短期风电功率预测 [J]. 电力系统保护与控制, 2019, 47(1): 73-79.
- CHEN Hao, ZHANG Jianzhong, XU Chao, *et al.* Short-term wind power forecast based on MOSTAR model [J]. Power System Protection and Control, 2019, 47(1): 73-79 (in Chinese).
- [9] 范高峰, 王伟胜, 刘纯, 等. 基于人工神经网络的风电功率预测 [J]. 中国电机工程学报, 2008, 28(34): 118-123.

- FAN Gaofeng, WANG Weisheng, LIU Chun, *et al.* Wind power prediction based on artificial neural network [J]. *Proceedings of the CSEE*, 2008, 28(34): 118 – 123(in Chinese).
- [10] ZENG J, QIAO W. Short-term wind power prediction using support vector machine. *IEEE Trans. Sustain. Energy* 3(2) (2012)
- [11] 张颖超, 郭晓杰, 叶小岭, 等. 一种短期风电功率集成预测方法 [J]. *电力系统保护与控制*, 2016, 44(7): 90 – 95.  
ZHANG Yingchao, GUO Xiaojie, YE Xiaoling, *et al.* An integrated forecasting method of short-term wind power [J]. *Power System Protection and Control*, 2016, 44(7): 90 – 95(in Chinese).
- [12] 杨茂, 黄宾阳, 江博. 基于概率分布量化指标和灰色关联决策的风电功率实时预测研究 [J]. *中国电机工程学报*, 2017, 37(24): 7099 – 7107+7424.  
YANG Mao, HUANG Binyang, JIANG Bo. Real-time wind power prediction based on probability distribution and gray relational decision-making [J]. *Proceedings of the CSEE*, 2017, 37(24): 7099 – 7107+7424(in Chinese).
- [13] 杨茂, 熊昊, 严干贵, 等. 基于数据挖掘和模糊聚类的风电功率实时预测研究 [J]. *电力系统保护与控制*, 2013, 41(1): 1 – 6.  
YANG Mao, XIONG Hao, YAN Gangui, *et al.* Real-time prediction of wind power based on data mining and fuzzy clustering [J]. *Power System Protection and Control*, 2013, 41(1): 1 – 6(in Chinese).
- [14] 杨茂, 陈郁林. 基于EMD分解和集对分析的风电功率实时预测 [J]. *电工技术学报*, 2016, 31(21): 86 – 93.  
YANG Mao, CHENG Yulin. Real-time prediction for wind power based on EMD and set pair analysis [J]. *Transactions of China Electrotechnical Society*, 2016, 31(21): 86 – 93(in Chinese).
- [15] 杨茂, 张强. 基于集合经验模态分解和相关向量机的风电功率实时预测研究 [J]. *太阳能学报*, 2016, 37(5): 1093 – 1099.  
YANG Mao, ZHANG Qiang. Real-time prediction of wind power based on ensemble empirical mode decomposition and correlation vector machine [J]. *Acta Energiae Solaris Sinica*, 2016, 37(5): 1093 – 1099(in Chinese).
- [16] 王羽. 风电出力时序特性及其对省级电网的影响 [J]. *发电技术*, 2018, 39(5): 475–482.  
WANG Yu. Analysis on the characteristics of wind power time series and its impact on provincial power grid [J]. *Power Generation Technology*, 2018, 39(5): 475–482. (in Chinese)
- [17] 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(in Chinese).
- [18] Sepp Hochreiter, Jürgen Schmidhuber. Long Short-Term Memory [J]. *Neural Computation*, 1997(8).
- [19] Sreelakshmi K, Ramakanth Kumar, P. Performance evaluation of short term wind speed prediction techniques [J]. *IJCSNS Int. Comput. Sci. Netw. Secur*, 2008, 8(8).

收稿日期: 2020-05-11

作者简介:

李春平 (1991), 男, 硕士研究生, 研究方向为新能源预测及并网优化调度, E-mail: 1042438602@qq.com;

张沛 (1972), 男, 教授, 博士生导师, 通信作者, 研究方向为电力系统调度运行, 电力信息化; 新能源发电预测和运行消纳等, E-mail: peizhang166@qq.com;

彭春华 (1979), 男, 教授, 博士生导师, 研究方向为电力系统优化调度与运行电力市场等, E-mail: 23248008@qq.com

尹瑞 (1990), 男, 博士, 工程师, 研究方向为柔性直流输电技术、新能源发电技术, E-mail: 1021207298@zju.edu.cn

时珉 (1976), 男, 高级工程师, 研究方向为电网调度计划、水电及新能源, E-mail: 774524019@qq.com。