

基于W-BiLSTM的可再生能源超短期发电功率预测方法

谢小瑜¹, 周俊煌², 张勇军¹, 王 奖¹, 苏洁莹¹

(1. 智慧能源工程技术研究中心, 华南理工大学电力学院, 广东省广州市 510640;

2. 广州市奔流电力科技有限公司, 广东省广州市 510700)

摘要: 针对现有新能源超短期预测方法难以有效挖掘和分析数据的固有波动规律,且当时序过长时易丢失重要信息等问题,提出了一种基于注意力(Attention)机制的小波分解-双向长短时记忆网络(W-BiLSTM)超短期风、光发电功率预测方法。首先,利用小波分解提取输入时间序列的时域信息和频域信息。随后,考虑双向信息流,采用双向长短时记忆网络(BiLSTM)进行预测,引入注意力机制,通过映射加权和参数矩阵赋予BiLSTM隐含状态不同的权重,有选择性地获取更多有效信息。最后,通过实际数据进行仿真验证。仿真结果表明,所提模型与现有模型相比,具有良好的预测性能。

关键词: 可再生能源; 风力发电; 光伏发电; 功率预测; 小波分解; 深度学习; 注意力机制

0 引言

在电网规模不断增长的背景下,能源与环境问题同日益增长的用电需求之间的矛盾不断凸显,清洁能源发电的比例逐步提高^[1]。合理改善能源结构,促进新能源消纳,将是电力系统研究的重要方向。然而,以风力发电、光伏阵列为首的清洁能源发电具有高随机性与波动性,并且电能难以大规模存储,同时考虑到源网规划不协调等因素,对电力系统调峰^[2]和调度^[3]提出了新的挑战,也在很大程度上限制了可再生能源的消纳^[4]。因此,新能源出力的精准预测是维护电网运营供需平衡及安全稳定的重要手段。

现有风光发电功率预测方法主要包括物理建模方法^[5-6]和统计方法^[7-9]。其中,物理建模方法主要通过建立数学模型以研究气象演变过程,并根据光电、风电转换物理模型等进行预测,其不需要大量的样本数据,但模型复杂、计算量大、抗干扰能力较差。统计方法,诸如时间序列模型^[10]、回归分析模型^[11]以及卡尔曼滤波模型^[12]等,使用历史测量数据间的统计关系对功率进行预测,可以有效解决预测延迟的问题,然而其对原始数据的处理和时序序列的稳定性要求较高,难以反映非线性因素的影响;而诸如人工神经网络^[13]、支持向量机^[9]等,可以拟合复杂的

非线性关系,然而现有方法多为浅层神经网络,对输入数据的深层特征挖掘不够,泛化能力有待提高。

深度学习技术具有受噪声干扰小、能充分挖掘数据间的关联性等优点,为可再生能源发电功率预测提供了强大支撑^[14]。文献[15]提出了基于多对多映射网络和堆栈降噪自编码器的多尺度风电功率预测方法,实现对风力发电复杂的空间相关性和相互依赖性的挖掘。文献[16]提出了基于传统门控循环单元神经网络和卷积神经网络(convolutional neural network, CNN)相融合的风电功率预测方法,提高了对变长度时序信息的信息利用和预测能力。文献[17]提出了基于长短时记忆网络(long-short term memory network, LSTM)和深度递归神经网络(recurrent neural network, RNN)模型,对社区微网的光伏输出进行了预测。文献[18]比较了基于CNN, LSTM以及CNN-LSTM混合模型的3种光伏功率预测方法,结果表明后者的预测效果最好,同时输入时序数据的序列长短对预测精度也有一定的影响。文献[19-20]对光伏、风电功率变量进行相关程度评估,基于此对数据进行筛选,降低了数据的大小以及复杂程度。然而上述预测方法只考虑了单向的数据信息流,忽视了反向数据序列变换规律对短时预测的影响,同时对数据的时间相关性以及周期性考虑不足,当输入的时间序列较长时,易丢失序列信息,模型的预测精度不高。

基于此,本文提出了基于注意力(Attention)机制的小波分解-双向长短时记忆网络(W-BiLSTM)

收稿日期: 2020-07-18; 修回日期: 2020-09-08。

上网日期: 2020-10-30。

国家自然科学基金资助项目(51777077)。

的风电、光伏发电功率预测方法,引入小波分解全面地考虑了数据的波动性、非线性特性和时间相关性,并且将LSTM拆分为2个方向,充分学习时序数据的正反向特征,采用注意力机制,赋予网络隐藏层单元不同的权重,加强了重要信息的影响。最后,通过实际数据验证了所提方法的有效性。

1 基于注意力机制的W-BiLSTM模型原理

1.1 小波分解

新能源出力的随机性、波动性较强,同时具有一定的周期性,时间相关性较高。而小波分解^[21]将传统傅里叶变换的基函数替换成了有限长会衰减的小波基,可以实现给定时间序列中的时域信息与频域信息的提取,在低频具有较高的频率分辨率和较低的时间分辨率,在高频有较低的频率分辨率和较高的时间分辨率,具有强信号表征能力^[22],解决了傅里叶变换时间信息丢失及非平稳信号分析困难等问题。

设任意函数 $g(t)$, $\psi(t)$ 是平方可积函数,即 $g(t) \in L^2(R)$, $\psi(t) \in L^2(R)$,且 $\psi(t)$ 满足允许条件:

$$C_\psi = \int_{-\infty}^{+\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty \quad (1)$$

式中: $\hat{\psi}(\omega)$ 为 $\psi(t)$ 的傅里叶变换。

则连续小波变换定义为:

$$W_g(p, q) = \int_{-\infty}^{+\infty} g(t) \psi\left(\frac{t-q}{p}\right) dt \quad p \neq 0 \quad (2)$$

$$\psi_{p,q}(t) = \frac{1}{\sqrt{p}} \psi\left(\frac{t-q}{p}\right) \quad (3)$$

通常称满足式(1)的可积函数 $\psi(t)$ 为一基本小波或小波母函数, $\psi_{p,q}(t)$ 是由母小波经伸缩变量 p 和平移变量 q 变换后生成的连续小波, t 为时间索引。

小波变换的重构公式为:

$$g(t) = C_\psi^{-1} \int_{-\infty}^{+\infty} W_g(p, q) \psi_{p,q}(t) \frac{dp}{|p|^2} dq \quad (4)$$

常使用离散小波变换(discrete wavelet transform, DWT)处理离散信号。 p 和 q 的离散化公式分别取作 $p=p_0^j$ 和 $q=kp_0^j q_0$ 。这样,对应的离散小波 $\psi_{j,k}(t)$ 可写做:

$$\psi_{j,k}(t) = p_0^{-\frac{j}{2}} \psi(p_0^{-j} t - k q_0) \quad (5)$$

实际中常用二进制动态采样网络,取离散化参数 $p_0=2, q_0=1$ 。

DWT为:

$$G(j, k) = \sum_{t=-\infty}^{\infty} g(t) \psi_{j,k}(t) \quad (6)$$

实际上,DWT是使用滤波器组方法实现的,其中输入信号通过低通滤波器 $L(e)$ 和高通滤波器 $H(e)$,然后减少2倍以确定其近似值和详细成分。

采用Mallat算法^[23],分解后的低频信号序列和高频信号序列可表示为:

$$\begin{cases} a_j = a_{j+1} h_1 \\ d_j = d_{j+1} l_1 \end{cases} \quad j = 0, 1, \dots, n-1 \quad (7)$$

式中: h_1 和 l_1 分别为低通滤波系数和高通滤波系数; n 为小波分解层数。

重建算法描述如下:

$$a_j = a_{j+1} h_2 + d_{j+1} l_2 \quad j = n-1, \dots, 1, 0 \quad (8)$$

式中: h_2 和 l_2 分别为 h_1 和 l_1 的对偶算子。

小波变换的过程如图1所示。




图1 小波变换过程
Fig. 1 Wavelet transform process

1.2 BiLSTM原理结构

LSTM^[24]从RNN发展而来。针对序列信息,传统神经网络很难利用前序信息对后续事件进行分类,而RNN是多层感知机的进化,可以有效保留前一步的数据信息,不断将信息进行循环操作,从而更好地处理序列类型数据。然而,在对较长序列进行预测的过程中,其性能往往不尽如人意。受限于RNN结构的局限性,在反向传播计算过程中会出现梯度消失问题,RNN只能学习过去短时间间隔的记忆^[25]。基于此,LSTM的提出一定程度上解决了学习序列长期依赖的问题^[26]。典型的LSTM结构如图2所示。




图2 典型LSTM结构

Fig. 2 Typical structure of LSTM

图2中: x 为输入; h 为赋予网络记忆能力的隐藏状态;下标 $t-1, t$ 和 $t+1$ 代表不同的时间步长;

W, U, V 是不同层的超参数。其节点之间的连接形成沿着序列的有向图, h_t 是基于前一层隐状态的输出和当前时刻的输入计算得到的。

典型的 LSTM 重复单元主要由记忆存储单元状态(C_t)、遗忘门(f_t)、输入门(i_t)以及输出门(o_t)构成。单元状态是 LSTM 的核心,即贯穿图 2 顶部的水平线,其少分支的传送带结构设计使得信息易以不变的方式流过整个细胞单元。遗忘门、输入门以及输出门实现对单元状态的控制,选择性地向单元状态添加或移除信息。

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (9)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (10)$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (11)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes \tilde{C}_t \quad (12)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (13)$$

$$h_t = o_t \otimes \tanh(C_t) \quad (14)$$

式中: W 为隐藏单元的输入权重矩阵; U 为输出权重矩阵; b 为偏置向量; $\tilde{C}_t$ 为候选单元状态; 下标 c、f、i、o 代表记忆存储单元状态、遗忘门、输入门和输出门; $\otimes$ 表示逐点求积运算; $\sigma(\cdot)$ 为激活函数。

为增强网络的非线性, 2 个激活函数的函数表示如下:

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (15)$$

$$\tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (16)$$

在时间序列预测中, 充分考虑时序数据的正反向信息规律, 可以有效提高预测精度。BiLSTM 由正向、逆向 2 个 LSTM 构成, 相比于标准 LSTM 中状态传输单向的从前往后, BiLSTM 同时考虑前后数据的变化规律, 展现出了更加优越的性能。BiLSTM 结构示意图见附录 A 图 A1。

可以看出, BiLSTM 由前向计算与后向计算构成。图中水平方向的指示箭头表示模型中时间序列信息的双向流动, 同时数据信息在输入层到隐藏层到输出层垂直单向流动。

1.3 注意力机制

注意力机制模拟了人脑注意力在特定时刻对特定区域集中的情况, 从而有选择性地获取更多有效信息, 忽略无用信息^[27]。它通过对神经网络隐藏层单元分配不同的概率权重, 以突出关键信息的影响, 增强模型判断的准确性。将注意力机制引入本文方法中, 可以有效解决由于输入长时间序列所导致的模型难以学到合理的向量表示的情况; 同时针对风电与光伏功率特性, 突出二者由于数据特性差异所造成的对不同时间点位置的注意力分布的不同, 捕

捉数据间的时间相关性并选择相应的驱动数据来进行预测。注意力结构如图 3 所示, 其中, a_t 为注意力机制对神经网络隐藏层输出的注意力概率分布值; y 为引入注意力机制后的模型输出值。




图3 注意力机制结构示意图
Fig.3 Schematic diagram of Attention mechanism structure

注意力机制层的权重系数计算公式可表示为:

$$e_t = u \tanh(w h_t + b) \quad (17)$$

$$a_t = \frac{\exp(e_t)}{\sum_{j=1}^T \exp(e_j)} \quad (18)$$

$$s_t = \sum_{i=1}^T a_i h_i \quad (19)$$

式中: e_t 为第 t 时刻由神经网络隐藏层输出向量 h_t 所决定的注意力概率分布值; u 和 w 为权重系数; b 为偏置系数; s_t 为注意力机制在 t 时刻的输出; T 为输入序列维度。

2 超短期发电功率预测

风电、光伏等清洁能源受其所处的地理位置、环境天气条件等因素的影响严重。天气参数本身具有强随机性, 因而以风电、光伏为代表的可再生能源本质上也具有高度的不确定性以及时间相关性。本文提出了基于注意力机制的 W-BiLSTM 模型, 实现对风力机组、光伏阵列发电量的超短期预测。

2.1 发电功率与输入气象信息关系

根据文献[28], 风电、光伏的出力直接受风速和光照强度影响。

风电机组的有功功率 P_{WTG} 与风机参数(额定容量、切入风速 V_{ci} 、额定风速 V_r 和切出风速 V_{co})和风速 V_h 有关, 可以用式(20)近似表示风电的有功出力:

$$P_{WTG} = \begin{cases} 0 & 0 \leq V_h \leq V_{ci} \text{ 或 } V_{co} < V_h \\ P_{WTG}^r \frac{V_h - V_{ci}}{V_r - V_{ci}} & V_{ci} < V_h \leq V_r \\ P_{WTG}^r & V_r < V_h \leq V \end{cases} \quad (20)$$

式中: P_{PVG}^r 为光伏额定容量。

光伏输出的有功功率 P_{PVG} 与光照强度之间的关系可近似表示为:

$$P_{\text{PVG}} = \begin{cases} P_{\text{PVG}}^r \frac{I}{I_m} & I \leq I_r \\ P_{\text{PVG}}^r & I > I_r \end{cases} \quad (21)$$

式中: I 为光照强度; I_m 为光照强度的最大值; I_r 为额定光照强度。

2.2 预测算法流程

所提算法的整体框架见附录 B 图 B1。具体步骤如下。

1) 对所得输入数据进行预处理, 同时根据 2.1 节所述风速-风电功率、光强-光伏功率关系, 进行数据转换, 输出风电、光伏功率。

为了消除维数的影响, 消除量纲误差, 加速训练过程, 将输入训练数据进行归一化, 转换成标量值, 如式(22)所示。

$$w' = \frac{w - w_{\min}}{w_{\max} - w_{\min}} \quad (22)$$

式中: w' 为经过归一化之后的值; w 为样本数据实际值; $w_{\max}$ 和 $w_{\min}$ 分别为所选数据所在列的最大值和最小值。

2) 使用小波分解方法对输入时间序列数据进行小波分解和单支重构, 实现趋势信息的优化提取, 过滤波动信息, 分离噪声, 得到模型的最终输入序列。

3) 初始化基于注意力机制的 BiLSTM 网络, 将分解后的数据集训练数据分别输入网络中, 利用训练样本对网络进行训练。以均方误差作为损失函数, 网络训练采用 Adam 优化算法, 对权重进行更新, 得到预测模型。

利用训练好的神经网络模型对待预测时段的分解出来的每个子序列分别进行预测, 将预测后的子序列相加, 验证预测精度, 得到最终预测的风电、光伏功率数据。

考虑到连续多步预测的误差积累问题, 导致预测的精度随着预测步数的增加而不断地降低^[29], 文章采用单点预测方式, 利用前 m 个时间采样点的输入数据, 对下一个时间采样点进行预测; 对于当前预测时刻 t , 将 $t-m$ 至 $t-1$ 时刻的数据作为模型的输入序列 X , 当前时刻的数据作为输出 y 。不断使用获得的实际数据值对输入样本序列进行更新, 从而达到滚动预测的目的, 为电网的实时优化调度与控制等方面提供可靠的发电功率预测信息。

基于注意力机制的 BiLSTM 网络见附录 B 图 B2。模型包括输入层、BiLSTM 隐藏层、注意力层、全连接层以及输出层。BiLSTM 层实现双向特征学习, 充分利用序列的时间关联特性; 注意力层突出关键信息的影响, 增强模型判断的准确性; 全连接层进行局部特征整合。模型具有良好的特征提取和建模能力。

1) 输入层

经标准化处理后的风光功率数据, 经过小波分解与重构后, 分别作为神经网络模型的输入, 其维度为 1 维, 考虑到风光功率序列具有明显的周期性, 选取输入序列时间步长为 24。

2) BiLSTM 隐藏层

BiLSTM 隐藏层可以充分学习数据之间的前向与反向信息: 按照时间步的先后关系, 前向计算由 $t=1$ 至 $t=T$ 的时间顺序, 计算并保存每个时刻向前隐含层的输出, 后向计算由时间 $t=T$ 至 $t=1$ 的时间顺序, 计算并保存每个时刻向后隐含层的输出; 随后, 在每个时刻结合前后向的相应单元状态得到各个时间步的最终输出值。

3) 注意力层

对隐藏层单元进行选择性的学习, 风、光功率由于数据特性差异会造成对不同时间点位置的注意力分布的不同, 捕捉数据间的时间相关性进行预测。

4) 输出层

使用全连接层对结果进行降维, 选取非饱和激活函数 ReLU 函数作为 Dense 层的激活函数, 对输出数据进行非线性映射, 使得网络可以自行引入稀疏性, 提高了训练速度, 得到最终的输出结果。

2.3 评估指标

平均绝对百分比误差 (MAPE) 与均方根误差 (RMSE)^[22] 的数量级会根据功率值的数量级变化, 考虑到不同文献方法之间, 由于机组额定功率等的差异, 造成评估指标值的对比难以直接反映预测精度, 为量化分析比较预测精度, 消除量纲对评估指标值的影响, 选取标准化评估指标 k_{NMAE} , k_{NMAPE} , k_{NRMSE} 对本文所提模型性能进行评价。其中 y_{true} 为经过归一化处理之后的样本实际测量值; y_{pred} 为样本的标准化功率预测值; N 为测试样本个数。由于是对标准化的数据进行评估, 各项指标的数值没有单位。

标准化绝对平均误差 (normalized mean absolute error, NMAE) 的表达式为:

$$k_{\text{NMAE}} = \frac{1}{N} \sum_{i=1}^N |y_{\text{true}} - y_{\text{pred}}| \quad (23)$$

标准化平均绝对百分比误差(normalized mean absolute percentage error, NMAPE)的表达式为:

$$k_{\text{NMAPE}} = \frac{1}{N} \sum_{i=1}^N \frac{|y_{\text{true}} - y_{\text{pred}}|}{y_{\text{true}}} \quad (24)$$

标准化均方根误差(normalized root mean squared error, NRMSE)的表达式为:

$$k_{\text{NRMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{\text{true}} - y_{\text{pred}})^2} \quad (25)$$

3 算例仿真

3.1 实验设计

为了验证本文所提方法的有效性,选取了HOMER (hybrid optimization model for electric renewable)软件^[30]自带的“Interior China”某地区光照强度全年数据以及风速全年数据进行实验,并与其他常用算法的建模结果进行对比分析,数据采样间隔为15 min。为了验证本文所提方法的普遍适用性,取该地区4个季度每季度的首月风速数据以及光照强度数据,记为风速数据集A,B,C,D,以及光照强度数据集E,F,G,H。为了验证本文所提方法在数据缺失、获取困难情况下的适用性,选取数据集A和F为半月数据,以测试有限数据条件下的预测精度。数据集具体信息如表1所示。考虑到篇幅限制,本文在3.2节实验结果分析中,仅附上数据集B的风电功率预测以及数据集E的光伏功率预测的详细预测结果图。所有实验在i7-7700HQ(2.8 GHz), Windows10 64位操作系统的PC上进行。

表1 数据集信息
Table 1 Data set information

数据集	训练数据	测试数据	采样时间
A	1 344	288	1月15日00:00—1月31日23:45
B	2 688	288	4月1日00:00—5月1日23:45
C	2 688	288	6月1日00:00—7月1日23:45
D	2 688	288	10月1日00:00—10月31日23:45
E	2 688	288	1月1日00:00—1月31日23:45
F	1 344	288	4月15日00:00—5月1日23:45
G	2 688	288	6月1日00:00—7月1日23:45
H	2 688	288	10月1日00:00—10月31日23:45

对比算法有基于注意力机制的BiLSTM、基于注意力机制的LSTM、门控循环神经网络(gated recurrent unit, GRU)、RNN以及CNN。通过对比不同算法在不同气候条件以及不同数据集大小下的精度,以验证本文算法有效性。

模型参数如附录C表C1所示,小波分解选取

Daubechies(db)小波基函数进行特征提取,其具有低通、高通滤波性质以及内在正交性,在时序数据分析中表现良好。

3.2 实验结果分析

3.2.1 注意力机制分析

为了充分说明注意力机制对模型预测的影响及有效性,对10月份的风电及光伏功率预测(数据集D和H)的不同时间步长的注意力权重分布结果进行展示,如图4所示。




图4 不同时间步长的注意力权重分布结果
Fig. 4 Attention weight distribution results of different time steps

由图4可得出如下结论。

1)对于风电与光伏功率预测,不同输入的时间步长对其影响力不同,由图可见,对于风功率预测,第20~23个时间步长对预测产生的影响较大,而对于光伏预测,注意力层主要关注第1~5和18~24个时间步长而对其他时间步长的关注度较低。注意力机制可以关注重要时段对目标预测产生的影响,从而提升模型对关键特征信息的提取能力。

2)对比风电与光伏功率预测的注意力权重分布,二者之间存在一定的差异。由于风电的时序特性存在较大的不确定性,对于长时间尺度下的历史数据关注度不高,其注意力主要集中在距离预测点较近的时间步上,而光伏发电的时序性更为明确,在模型预测过程中,会更多地考虑长时间步内的数据信息,其权重分布较风电预测更为均匀。

3.2.2 风电预测

风电数据集B的测试序列数据的小波分解及单支重构结果,以及各子序列的预测结果对比图见附录C图C1。所得子序列包括低频信号序列 a_4 以及高频信号序列 d_1, d_2, d_3, d_4 ,每个子序列的长度都与原始序列相同,低频信号的峰谷变化反映了风功率变化的趋势,而高频信号序列波动性较强,反映了气候等因素的干扰。可以看出,风功率受气候影响严重,具有高波动性、随机性及高环境因素依赖性。

图5为所提算法以及其他对比方法的预测结果与输入风功率数据的对比图。为评价模型与真实值的拟合程度,对模型的预测结果与实际数据值进行

误差估计,得到本文所提方法与对比方法的评估指标值对比结果如表2所示。由表2可知,所提方法的各误差评价指标值均显著优于对比算法,并且算法对数据集A,B,C,D有优越的拟合预测能力。由基于注意力机制的W-BiLSTM的NMAPE可以看出,相较于其他对比算法,其预测值偏离真实值的程

度最小,从而预测的效果最优。数据集A,B中的各项评估指标相较于数据集C,D有所上升,说明在春季、冬季的风速波动较夏季、秋季更为明显。同时,数据集A的样本数量相对较小,因而预测模型的评估指标略有上升,但依然维持较低水平。




图5 B组测试集预测结果对比
Fig. 5 Forecasting result comparison of test set B

表2 风功率预测评估指标值对比
Table 2 Evaluation index value comparison of wind power prediction

方法	性能指标	不同数据集下的指标值			
		A	B	C	D
基于注意力机制的W-BiLSTM	NMAE	0.039 5*	0.028 3*	0.017 1*	0.024 6*
	NMAPE	0.822 4*	0.164 1*	0.326 4*	0.307 5*
	NRMSE	0.050 7*	0.037 4*	0.022 6*	0.050 8*
基于注意力机制的BiLSTM	NMAE	0.090 4	0.104 1	0.054 4	0.071 1
	NMAPE	1.308 4	0.583 4	1.500 7	1.411 9
	NRMSE	0.120 0	0.131 8	0.081 7	0.100 9
基于注意力机制的LSTM	NMAE	0.092 2	0.105 6	0.058 4	0.073 0
	NMAPE	1.372 5	0.587 1	1.761 5	1.483 9
	NRMSE	0.121 0	0.132 7	0.081 9	0.109 0
GRU	NMAE	0.0944	0.106 2	0.060 1	0.074 5
	NMAPE	1.984 0	0.616 7	1.605 7	1.629 2
	NRMSE	0.123 0	0.136 8	0.088 1	0.108 0
RNN	NMAE	0.113 3	0.119 1	0.066 5	0.074 0
	NMAPE	1.336 0	0.595 2	1.454 9	1.458 9
	NRMSE	0.150 5	0.152 0	0.097 9	0.103 8
CNN	NMAE	0.097 1	0.104 0	0.059 5	0.072 0
	NMAPE	1.440 4	0.590 5	1.561 1	1.462 6
	NRMSE	0.127 3	0.132 5	0.087 2	0.101 6

注:*表示实验评价指标结果显著优于其他算法。

总而言之,相较于文中涉及其他算法,本文所提出方法在不同季度下的风速预测拟合效果更好,同

时在样本数据有限情况下仍保持高精度预测。

3.2.3 光伏预测

由于光伏阵列只能在有光照的时候发电,光伏发电输出更容易受到时段的影响,因而光伏发电的功率输出受光照强度的影响具有一定的线性和周期性。通常情况下,在20:00到次日05:00之间,光照强度为0,因而光伏功率输出为0,在午间时段,光伏功率输出随光照强度的增加而达到顶峰。

光伏数据集E的测试序列数据的小波分解及单支重构结果,以及各子序列的预测结果对比图见附

录C图C2。其中低频信号 a_4 的峰谷变化反映了光伏功率变化的趋势,而高频信号序列反映了云层等气候因素的干扰,光伏发电具有波动性。相比于直接利用原始数据进行预测,小波分解可以充分提取给定时间序列中的时域信息与频域信息,具有强信号表征能力,从而提升了预测算法的精度。

图6为所提算法以及其他对比方法的预测结果与输入光伏功率数据的对比图。表3为不同预测模型所得的误差评估指标的对比结果。




图6 E组测试集预测结果对比
Fig. 6 Forecasting result comparison of test set E

表3 光伏功率预测评估指标值对比
Table 3 Evaluation index value comparison of photovoltaic power prediction

方法	性能指标	不同数据集下的指标值			
		A	B	C	D
基于注意力机制的W-BiLSTM	NMAE	0.008 6*	0.018 9*	0.011 3*	0.013 7*
	NMAPE	0.909 9	0.303 3	0.305 1*	0.312 5*
	NRMSE	0.012 7*	0.026 7*	0.015 4*	0.015 6*
基于注意力机制的BiLSTM	NMAE	0.018 9	0.024 5	0.023 3	0.014 5
	NMAPE	0.433 0	1.313 3	0.699 1	0.360 4
	NRMSE	0.034 3	0.040 3	0.039 6	0.022 2
基于注意力机制的LSTM	NMAE	0.019 0	0.023 0	0.024 0	0.016 9
	NMAPE	0.597 0	0.311 5	0.334 0	0.450 1
	NRMSE	0.035 0	0.042 7	0.043 7	0.025 7
GRU	NMAE	0.020 9	0.024 9	0.025 3	0.017 8
	NMAPE	0.852 8	0.255 3	0.668 1	0.672 6
	NRMSE	0.037 0	0.043 9	0.043 1	0.030 0
RNN	NMAE	0.022 1	0.029 1	0.027 5	0.021 9
	NMAPE	1.058 2	0.318 8	1.908 0	0.861 3
	NRMSE	0.040 7	0.046 5	0.043 6	0.033 3
CNN	NMAE	0.022 9	0.026 9	0.028 4	0.019 4
	NMAPE	1.061 4	0.267 2	0.978 5	0.654 9
	NRMSE	0.036 7	0.042 4	0.043 0	0.027 6

注:*表示实验评价指标结果显著优于其他算法。

可以看出,所提方法的各评价指标值均优于对比算法,在不同季节下均具有良好的预测效果。其

中,数据集F中的各项评估指标数值均高于其他数据集,表明数据集F的预测结果较其他数据集稍劣,

这是由于数据集 F 样本数量少于其他数据集, 预测精度略有下降。此外, 数据集 E 的 MAPE 指标及数据集 G 中 RNN 和 CNN 方法的 MAPE 指标等, 明显高于其他数据集, 究其原因在于 MAPE 为相对平均误差, 不同于风力发电, 光伏实际数据中有一些属于夜间零出力数据。而数据集中有部分处于交界处的时刻的非零光强数据取值极小, 造成这一时刻的预测误差绝对值与实际值的比值很大, 然而其对应平均绝对误差 (MAE) 的指标仍处于较低水平, 说明预测数值与实际数值偏离程度很小, 模型预测效果仍然显著。

为评价不同天气情况下模型的预测效果, 表 4 给出了 1 月 29 日至 1 月 31 日的每日基于注意力机制的 W-BiLSTM 方法光伏功率预测误差对比结果。

表 4 3 日模型预测评估指标对比
Table 4 Comparison of model forecasting evaluation indices for 3 days

时间	NMAE	NMAPE	NRMSE
1 月 29 日	0.005 4	0.309 6	0.008 0
1 月 30 日	0.012 7	1.557 2	0.016 7
1 月 31 日	0.007 6	0.863 3	0.011 7

由表 4 及图 6 可见, 1 月 29 日为阴天天气, 光照强度较弱, 对应光伏发电功率整体偏低, 波动性不高, 1 月 30 日、31 日的光伏功率较 29 日具有显著的波动性。30 日上午为晴朗天气, 日照充足, 下午受云层等影响, 光照强度波动强烈; 31 日为多云天气, 全天光伏功率波动较前一天稍低。对应表 4 中的各项评价指标排序为: 29 日 < 31 日 < 30 日, 可见, 对于光照波动较弱的天气, 模型的预测效果相对较好。

4 结语

本文提出了一种基于注意力机制的 W-BiLSTM 的超短期可再生能源功率预测方法, 提高了预测模型精度。对原始数据进行小波分解可以有效提高建模精度, 实现给定时间序列中的时域信息与频域信息的提取, 具有强信号表征能力。BiLSTM 适用于风速、光强的建模问题, 充分挖掘数据的时序信息, 注意力机制可以加强重要信息对预测结果的影响。实验结果表明, 在不同季节以及气象条件下, 本文算法对风电、光伏出力的预测精确性与适用性均高于文中其他对比算法。

在后续研究中, 针对风、光功率预测, 可以充分考虑不同特征特点, 研究在考虑多种影响因素下复

杂环境的可再生能源发电功率预测问题; 针对不同预测步数对所提方法的影响进行实验分析, 为提前预警、宏观决策和电能调度计划等方面提供指导; 同时, 也可以考虑对所得数据进行预处理, 改善数据质量 (如完整性、准确性、一致性等), 消除数据噪声, 开展自适应误差修正等方面研究, 进一步提升模型预测效果, 提高预测模型的普适性。

附录见本刊网络版 (<http://www.aeps-info.com/aeps/ch/index.aspx>), 扫英文摘要后二维码可以阅读网络全文。

参 考 文 献

- [1] PILLOT B, MUSELLI M, POGGI P, et al. Historical trends in global energy policy and renewable power system issues in Sub-Saharan Africa: the case of solar PV[J]. Energy Policy, 2019, 127: 113-124.
- [2] 胡殿刚, 潘正婕, 徐昊亮, 等. 大规模可再生能源并网条件下天然气机组调峰空间估算[J]. 电力系统保护与控制, 2017, 45(3): 87-93.
HU Diangang, PAN Zhengjie, XU Haoliang, et al. Peaking capacity estimation of natural gas unit under the condition of large-scale renewable energy connecting with power grid[J]. Power System Protection and Control, 2017, 45(3): 87-93.
- [3] 区允杰, 孙景涛, 陈刚. 一种含抽水蓄能电站的可再生能源系统综合优化调度方法[J]. 广东电力, 2019, 32(10): 79-88.
OU Yunjie, SUN Jingtao, CHEN Gang. Integrated optimization scheduling method for renewable energy system with pumped storage power station[J]. Guangdong Electric Power, 2019, 32(10): 79-88.
- [4] 张振宇, 王文倬, 张钢, 等. 基于非时序模型的新能源消纳能力评估方法[J]. 电力系统自动化, 2019, 43(20): 24-32.
ZHANG Zhenyu, WANG Wenzhuo, ZHANG Gang, et al. Assessment method of accommodation capacity of renewable energy based on non-time-series model[J]. Automation of Electric Power Systems, 2019, 43(20): 24-32.
- [5] CHENG W Y Y, LIU Yubao, BOURGEOIS A J, et al. Short-term wind forecast of a data assimilation/weather forecasting system with wind turbine anemometer measurement assimilation[J]. Renewable Energy, 2017, 107: 340-351.
- [6] MA Tao, YANG Hongxing, LU Lin. Solar photovoltaic system modeling and performance prediction[J]. Renewable and Sustainable Energy Reviews, 2014, 36: 304-315.
- [7] MASSERAN N, RAZALI A M, IBRAHIM K, et al. Fitting a mixture of von Mises distributions in order to model data on wind direction in Peninsular Malaysia[J]. Energy Conversion and Management, 2013, 72: 94-102.
- [8] 管霖, 赵琦, 周保荣, 等. 基于多尺度聚类分析的光伏功率特性建模及预测应用[J]. 电力系统自动化, 2018, 42(15): 24-30.
GUAN Lin, ZHAO Qi, ZHOU Baorong, et al. Multi-scale

- clustering analysis based modeling of photovoltaic power characteristics and its application in prediction[J]. Automation of Electric Power Systems, 2018, 42(15): 24-30.
- [9] ZHOU Junyi, SHI Jing, LI Gong. Fine tuning support vector machines for short-term wind speed forecasting [J]. Energy Conversion and Management, 2011, 52(4): 1990-1998.
- [10] KAVASSERI R G, SEETHARAMAN K. Day-ahead wind speed forecasting using f-ARIMA models [J]. Renewable Energy, 2009, 34(5): 1388-1393.
- [11] 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.
- [12] GUAN C, LUH P B, MICHEL L D, et al. Hybrid Kalman filters for very short-term load forecasting and prediction interval estimation[J]. IEEE Transactions on Power Systems, 2013, 28(4): 3806-3817.
- [13] HERNÁNDEZ L, BALADRÓN C, AGUIAR J M, et al. Artificial neural network for short-term load forecasting in distribution systems[J]. Energies, 2014, 7(3): 1576-1598.
- [14] 谢小瑜,周俊煌,张勇军.深度学习在泛在电力物联网中的应用与挑战[J].电力自动化设备,2020,40(4):77-87.
- XIE Xiaoyu, ZHOU Junhuang, ZHANG Yongjun. Application and challenge of deep learning in Ubiquitous Power Internet of Things [J]. Electric Power Automation Equipment, 2020, 40(4): 77-87.
- [15] YAN Jie, ZHANG Hao, LIU Yongqian, et al. Forecasting the high penetration of wind power on multiple scales using multi-to-multi mapping [J]. IEEE Transactions on Power Systems, 2018, 33(3): 3276-3284.
- [16] 牛哲文,余泽远,李波,等.基于深度门控循环单元神经网络的短期风功率预测模型[J].电力自动化设备,2018,38(5):36-42.
- NIU Zhewen, YU Zeyuan, LI Bo, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network [J]. Electric Power Automation Equipment, 2018, 38(5): 36-42.
- [17] WEN Lulu, ZHOU Kaile, YANG Shanlin, et al. Optimal load dispatch of community microgrid with deep learning based solar power and load forecasting[J]. Energy, 2019, 171: 1053-1065.
- [18] WANG K, QI X, LIU H. A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network[J]. Applied Energy, 2019, 251: 113315.
- [19] ZENG Jiawu, QIAO Wei. Short-term solar power prediction using an RBF neural network[C]// IEEE Power & Energy Society General Meeting, July 24-28, 2011, Detroit, USA.
- [20] 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.
- [21] YU Chuanjin, LI Yongle, ZHANG Mingjin. An improved wavelet transform using singular spectrum analysis for wind speed forecasting based on Elman neural network [J]. Energy Conversion and Management, 2017, 148: 895-904.
- [22] 唐振浩,赵赓楠,曹生现,等.基于SWLSTM算法的超短期风向预测[J].中国电机工程学报,2019,39(15):4459-4468.
- TANG Zhenhao, ZHAO Gengnan, CAO Shengxian, et al. Very short-term wind direction prediction via self-tuning wavelet long-short term memory neural network [J]. Proceedings of the CSEE, 2019, 39(15): 4459-4468.
- [23] 李长庆,魏云冰,郭元战,等.含分布式电源的配电网电能质量扰动源定位研究[J].电力系统保护与控制,2020,48(9): 104-111.
- LI Changqing, WEI Yunbing, GUO Yuanzhan, et al. Research on power quality disturbance source location of a distribution network with distributed power supply [J]. Power System Protection and Control, 2020, 48(9): 104-111.
- [24] SONG Xuanyi, LIU Yuetian, XUE Liang, et al. Time-series well performance prediction based on long short-term memory (LSTM) neural network model [J]. Journal of Petroleum Science and Engineering, 2020, 186: 106682.
- [25] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult [J]. IEEE Transactions on Neural Networks, 1994, 5(2): 157-166.
- [26] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [27] ZHOU Heng, FANG Zhijun, GAO Yongbin, et al. Feature fusion network based on attention mechanism for 3D semantic segmentation of point clouds[J]. Pattern Recognition Letters, 2020, 133: 327-333.
- [28] ZHANG Chunyu, DING Yi, WANG Qi, et al. Uncertainty-averse TRANSCO planning for accommodating renewable energy in CO₂ reduction environment [J]. Journal of Modern Power Systems and Clean Energy, 2015, 3(1): 24-32.
- [29] LI Y, SHI H, HAN F, et al. Smart wind speed forecasting approach using various boosting algorithms, big multi-step forecasting strategy [J]. Renewable Energy, 2019, 135: 540-553.
- [30] FARRET F A, SIMÕES M G. Integration of alternative sources of energy[M]. USA: Wiley-IEEE Press, 2006.

谢小瑜(1996—),女,硕士研究生,主要研究方向:人工智能技术在电力系统中的应用。E-mail:1943294998@qq.com

周俊煌(1993—),男,硕士研究生,主要研究方向:人工智能技术在电力系统中的应用。E-mail:272757783@qq.com

张勇军(1973—),男,通信作者,博士,教授,博士生导师,主要研究方向:智能电网与能源互联网的规划、运行与控制等。E-mail:zhangjun@scut.edu.cn

(编辑 孔丽蓓)

W-BiLSTM Based Ultra-short-term Generation Power Prediction Method of Renewable Energy

XIE Xiaoyu¹, ZHOU Junhuang², ZHANG Yongjun¹, WANG Jiang¹, SU Jiying¹

(1. Research Center of Smart Energy Technology, School of Electric Power,

South China University of Technology, Guangzhou 510640, China;

2. Guangzhou Power Electrical Technology Co., Ltd., Guangzhou 510700, China)

Abstract: The existing ultra-short-term prediction methods for renewable energy are difficult to effectively mine and analyze the inherent fluctuation rules of data. Important information is easy to be lost when the time sequence is too long. Therefore, a power prediction method of wind power and photovoltaic based on the wavelet bidirectional long-short term memory network (W-BiLSTM) with Attention mechanism is proposed. Firstly, wavelet decomposition is used to extract the time domain information and frequency domain information of the input time series. Then, considering the bi-directional information flow, the bidirectional long-short term memory (BiLSTM) network is used for prediction. Attention mechanism is introduced, and different weights are given to the hidden state of BiLSTM through mapping weighting and learning parameter matrix, so as to selectively obtain the more effective information. Finally, the experiment is carried out using actual data, and the results show that the proposed model has better prediction performance compared with the existing models.

This work is supported by National Natural Science Foundation of China (No. 51777077).

Key words: renewable energy; wind power generation; photovoltaic; power prediction; wavelet decomposition; deep learning; Attention mechanism

