

◆特邀栏目◆

基于 CNN-LSTM-Attention 的短期风向预测研究*

韩星晖¹,何永玲^{1*},蒙古彬¹,胡文睿¹,廖彬杰²

(1. 北部湾大学机械与船舶海洋工程学院,广西钦州 535011;2. 广西电网钦州新区供电局,广西钦州 535011)

摘要:风向预测对提高风能转化率、保障风力发电机偏航系统安全运行及增加风力发电效益具有重要意义。为准确预测风向,提出一种基于 CNN-LSTM-Attention 的短期风向预测模型。首先,利用卷积神经网络(Convolutional Neural Network,CNN)提取风向数据动态变化特征,然后将所提取的特征向量构成时间序列作为长短期记忆(Long Short-Term Memory,LSTM)网络的输入,最后使用注意力机制(Attention mechanism)分配 LSTM 隐含层不同权重,增强重要特征的作用,完成风向预测。采用北部湾海域历史风向数据,通过实验与其他神经网络预测模型进行对比,结果显示,CNN-LSTM-Attention 模型的相对平均误差(MAPE)值为 3.2119%, R^2 为 0.982 6,优于其他对比模型。所得结果为广西北部湾海域海上风电探索发展提供参考。

关键词:偏航系统;风向预测;注意力机制;CNN;LSTM 网络

中图分类号:TP18, TM614 文献标识码:A 文章编号:1002-7378(2023)02-0192-07

DOI:10.13657/j.cnki.gxkxyxb.20230517.009

对于可再生能源——风能,我国正加快海上风电建设,有助于建设清洁低碳、安全高效的能源体系。风力发电技术中的偏航系统是风力发电机组特有的伺服系统,它使风轮稳定跟踪变化的风,保证捕获最大的风能^[1]。目前广西北部湾海域正处于海上风电建设探索阶段,北部湾海域的风速较低,结合历史风向数据对风向进行预测,有助于提高风能利用率,提增风力发电效益。

当前,有不少国内外学者对预测模型、预测方法

进行研究,但是大多是对风速、风功率、负荷等的预测,关于风向预测的研究较少。张东东等^[2]通过误差反向传播(Back Propagation, BP)建立 BP 神经网络模型对风向进行预测,通过预测未来风向,使偏航系统可以提前执行动作。卓泽赢等^[3]将经验小波变换与核极限学习机相结合对风电功率进行预测,使风电功率预测精度得到提高。Lynch 等^[4]使用卡尔曼滤波器(Kalman Filtering, KF)对风速进行预测并与实际风速对比,结果表明该方法具有较好的预测效果。

收稿日期:2022-12-05

修回日期:2023-03-29

* 国家自然科学基金项目(52061001),广西科技重大专项(2021AA08001)和中国华能集团有限公司广西分公司软科学课题“北部湾(广西)海上风电规划发展与探索研究”(2020623)资助。

【第一作者简介】

韩星晖(1997-),男,在读硕士研究生,主要从事海洋工程与技术研究,E-mail:1761491322@qq.com。

【**通信作者】

何永玲(1967-),女,教授,硕士生研究导师,主要从事机电一体化、海洋工程与技术研究,E-mail:1059571537@qq.com。

【引用本文】

韩星晖,何永玲,蒙古彬,等. 基于 CNN-LSTM-Attention 的短期风向预测研究[J]. 广西科学院学报,2023,39(2):192-198.

HAN X H, HE Y L, MENG Z B, et al. Short-Term Wind Direction Prediction Based on CNN-LSTM-Attention [J]. Journal of Guangxi Academy of Sciences, 2023, 39(2): 192-198.

然而,浅层神经算法在对输入数据特征信息提取挖掘上,能力略显不足,从而影响了建立预测模型的精度。为提高网络模型性能,深度学习算法受到广泛应用。Wang等^[5]利用卷积神经网络(Convolutional Neural Network, CNN)模型对输入数据进行特征提取,对负荷进行预测,发现模型在非线性序列上有较高的准确率。李亚蒙等^[6]利用长短期记忆(Long Short-Term Memory, LSTM)深度神经网络在处理时序数据上的优异性能,对未来的短期风速进行预测,通过实验对比分析表明, LSTM 预测方法具有较好的预测效果。但在时间序列输入过长时, LSTM 网络容易丢失时序的信息,会使模型的精确度降低^[7,8]。陆继翔等^[9]使用 CNN 和 LSTM 混合网络模型进行短期负荷预测,将具有高效提取数据特征能力的 CNN 和处理时间序列表现优异的 LSTM 网络结合,有效避免了因输入序列过长造成的精度低的问题。但 CNN 只能对输入的时序数据提取局部信息,无法选择性地关注输入中对结果影响最大的部分,从而影响了模型的精确度。为有效增强主要特征的作用,提高模型精确度,本文引入注意力机制(Attention mechanism)^[10]。注意力机制是一种资源分配机制,通过给输入的特征分配权重,增强重要特征的作用,使模型更容易处理时间序列的依赖关系。

基于此,本文将注意力机制应用在风向预测领域,提出基于 CNN-LSTM-Attention 的风向预测模型,将具有高效提取数据特征能力的 CNN 和在处理时间序列方面表现优异的 LSTM 网络相结合,并且通过注意力机制的分配概率权重补足 CNN 只能捕捉局部信息的短板。通过实验对比分析其他的预测模型,验证所提出的方法在风向预测方向的可行性,为后续广西北部湾海域海上风电的探索建设提供参考。

1 CNN-LSTM-Attention 模型原理

1.1 CNN

CNN 是一种具有卷积架构的深度学习神经网络,在语音识别、人脸识别、自然语言处理等领域都有着广泛的应用。由于 CNN 同时具备共享权重及局部连接的功能,因而在降低模型的复杂度、减少建模参数的同时,还可以更高效地提取特征信息^[11]。

CNN 相对于普通的神经网络,区别主要在于卷积层和池化层,结构如图 1 所示。卷积层对所有输入信息进行卷积计算,同时对数据特征进行有效提取,

通过池化层对输入特征进行压缩,简化网络计算复杂度,提取主要特征。卷积层与池化层共同组成的特征提取器,既能够最大限度地对输入值的潜在信息加以合理提取,又能降低人为抽取数据时产生的偏差。因此,本文先采用 CNN 对归一化后的数据进行特征提取,然后通过 LSTM 网络进行分析预测。

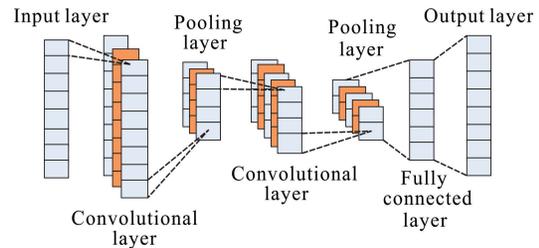


图 1 CNN 结构

Fig. 1 Structure of CNN

1.2 LSTM 网络

由于循环神经网络(RNN)存在较为严重的问题,即梯度消失、梯度爆炸的问题^[12], LSTM 网络算法在 RNN 的基础上进行了一些改进,通过特殊的方式存储“记忆”,从而解决 RNN 存在的问题。图 2 为 LSTM 网络记忆单元结构图。与 RNN 结构不同的是, LSTM 通过特殊的方式存储“记忆”,即设置“门”结构,达到对“细胞状态”信息的舍弃和增添,代替了 RNN 中的隐含层,实现记忆中的信息取舍。“门”结构将 sigmoid 函数作为激活函数, sigmoid 层输出的元素都是(0,1)之间的实数。3 个门分别是输入门、输出门和遗忘门。通过对历史输入、当前输入和历史输出进行加权学习,进而实现对历史输入、历史输出的记忆功能^[13]。

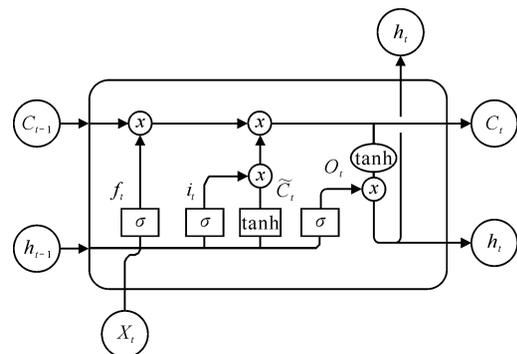


图 2 LSTM 网络记忆单元结构

Fig. 2 Structure of LSTM network memory cell

当输入时刻为 t 时, LSTM 单元的计算过程如下。

遗忘门的值为

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

输入门的值为

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

候选记忆单元状态值为

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

当前记忆单元状态值为

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

输出门的值为

$$O_t = \sigma(W_O \cdot [h_{t-1}, x_t] + b_O) \quad (5)$$

最终得到输入时刻为 t 时, LSTM 单元格的输出:

$$h_t = O_t \times \tanh(C_t) \quad (6)$$

上式中, W 和 b 分别表示权重矩阵以及偏置量, (W_f, b_f) 、 (W_i, b_i) 、 (W_C, b_C) 、 (W_O, b_O) 分别对应遗忘门、输入门、状态单元以及输出门的权重矩阵和偏置量, σ 表示 sigmoid 函数, f_t 、 i_t 和 O_t 为对应门输出的激活函数, \tilde{C}_t 和 C_t 分别表示即时状态和状态单元的向量, h_t 表示当前时刻 LSTM 单元格的输出^[14]。

1.3 注意力机制

注意力机制是机器学习中的一种数据处理方法, 广泛应用在自然语言处理、图像识别及语音识别等各种类型的机器学习任务中^[15]。注意力机制本质上与人类对外界事物的观察机制相似。通常来说, 人们在观察外界事物的时候, 首先会比较倾向于观察事物某些重要的局部信息, 然后再把不同区域的信息组合起来, 从而形成一个对被观察事物的整体印象。在神经网络中引入注意力机制, 可以在众多输入信息中关注对当前任务更重要的信息特征, 降低对其他信息的关注度, 甚至过滤掉无关信息, 解决信息过载问题, 并提高任务处理的效率和准确性。注意力机制模型结构如图 3 所示。其中, $X_1, X_2, \dots, X_{t-1}, X_t$ 表示风向数据的输入特征; $h_1, h_2, \dots, h_{t-1}, h_t$ 表示 LSTM 的隐藏层状态的输出值; $a_1, a_2, \dots, a_{t-1}, a_t$ 表示 Attention 机制对 LSTM 隐藏层输出的注意力权重值。

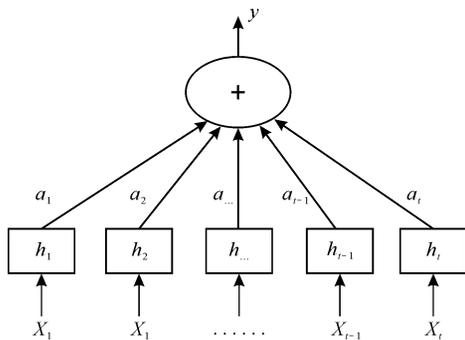


图 3 注意力机制模型结构

Fig. 3 Structure of attention mechanism model

2 基于 CNN-LSTM-Attention 的网络风向预测

2.1 CNN-LSTM-Attention 风向预测网络模型结构

本文建立的 CNN-LSTM-Attention 风向预测网络模型如图 4 所示。此模型将具有高效提取特征能力的 CNN 与处理时间序列能力优异的 LSTM 网络相结合, 并且使用注意力机制进行优化, 通过概率分配权重, 增强关键特征的作用, 进一步提高风向预测的准确性。此模型主要分为 5 层: 输入层、CNN 层、LSTM 层、注意力(Attention)层和输出层。

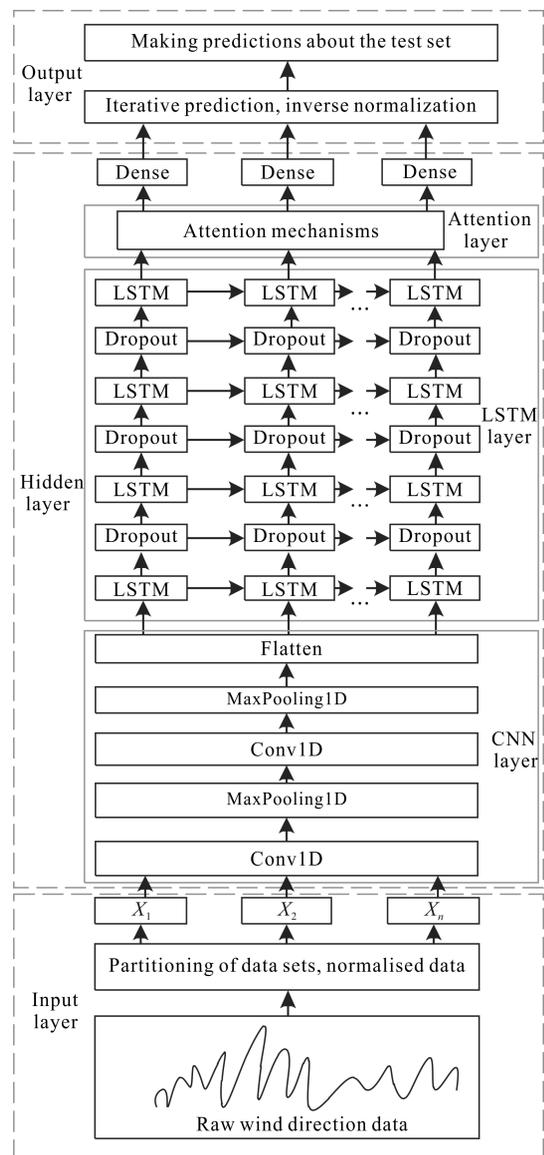


图 4 CNN-LSTM-Attention 风向预测网络模型

Fig. 4 CNN-LSTM-Attention wind direction prediction network model

模型中的每层具体叙述如下。

①输入层。对长度为 n 的历史风向数据进行预处理, 将其作为该模型的输入时间序列, 表示为

$$X = [x_1 \cdots x_{t-1}, x_t \cdots x_n]^T. \quad (7)$$

②CNN层。该层主要对输入的序列数据进行特征提取。该模型设置2个卷积层, 2个最大池化层。卷积层的激活函数为 ReLU 函数, 填充设置为 same。数据经过卷积层以及池化层提取, 输入 LSTM 神经网络。

③LSTM层。该层主要是对 CNN 层提取的特征进行学习。该模型搭建了4层 LSTM 网络层, 对提取的特征进行充分学习, 并且设置3层 Dropout, 防止在训练过程中出现过拟合现象。

④Attention层。该层的输入是 LSTM 层的输出, 使用概率分配权重的方式计算权重矩阵, 计算公式如下所示:

$$e_t = u \tanh(\omega h_t + b), \quad (8)$$

$$a_t = \text{softmax}(e_t), \quad (9)$$

$$C_t = \sum_{i=1}^i a_i h_i, \quad (10)$$

式中, e_t 、 a_t 分别表示在 t 时刻风向数据不同特征所对应的注意力分数和权重, h_t 表示 LSTM 层在 t 时刻的输出, b 是偏置系数, u 与 ω 是权重系数, C_t 表示 Attention 层在 t 时刻的输出。

⑤输出层。该层的输入是 Attention 层的输出。输出层的计算公式如下所示:

$$y_t = \text{sigmoid}(\omega_o C_t + b_o), \quad (11)$$

式中, y_t 表示在 t 时刻的输出, ω_o 表示权重系数, b_o 表示偏置项。

2.2 Dropout

神经网络的训练容易出现过拟合现象, 当出现过拟合现象时, 得到的模型几乎不可用, 因为该模型虽然在训练集上损失函数(loss)值小, 准确率高, 但是应用在测试集上, 不仅 loss 值大, 而且预测的准确率低, 模型没有实际的意义。为解决该问题, 在网络中加入 Dropout 层, 通过阻止特征检测器的共同作用进而提高神经网络的性能, 即在进行前向传播时, 让某一个神经元的激活值以一定概率 p 停止工作, 并让其他神经元以概率 $q = 1 - p$ 保留, 每个神经元被关闭的概率相同^[16]。这样可以提高模型的性能, 使模型具有更好的鲁棒性, 通过减少隐藏节点间的相互作用, 降低对局部特征的依赖性。图5为 Dropout 在神经网络中的应用。

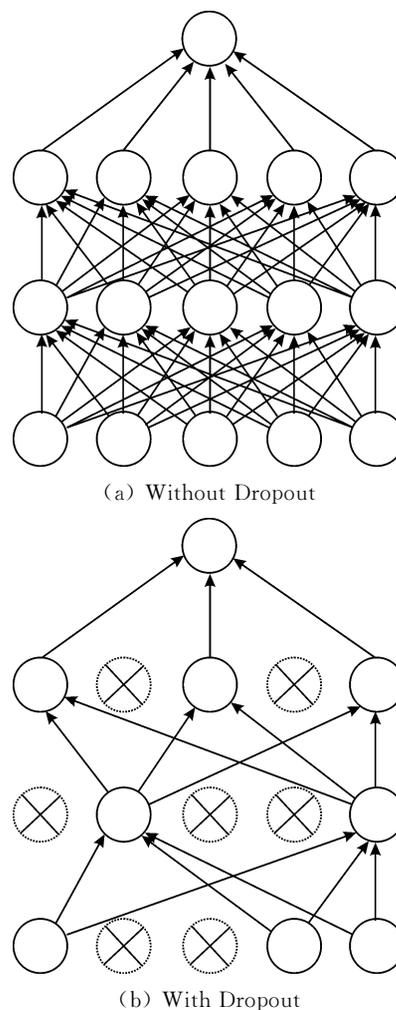


图5 有无 Dropout 的神经网络模型

Fig. 5 Neural network model with or without Dropout

3 实验验证与结果分析

3.1 样本处理

本文使用北部湾海域的原始风向数据, 所收集到的风向数据间隔为 10 min。考虑到不同指标之间存在量纲影响, 为了消除影响, 对数据进行归一化处理。归一化后可以加快模型的收敛速度, 并且在一定程度上提升预测模型的精度。本模型使用 MinMaxScaler 函数进行输入数据归一化, 区间为 $[0, 1]$ 。时间序列原始风向数据与归一化后的数据如图6所示。

本次实验所使用的设备均在带有 Windows 10 64 位操作系统的个人计算机(PC)上进行, 设备主要参数为 CPU i7-10750H (2.60 GHz), 六核十二线程的处理器, 运行内存为 16 GB。

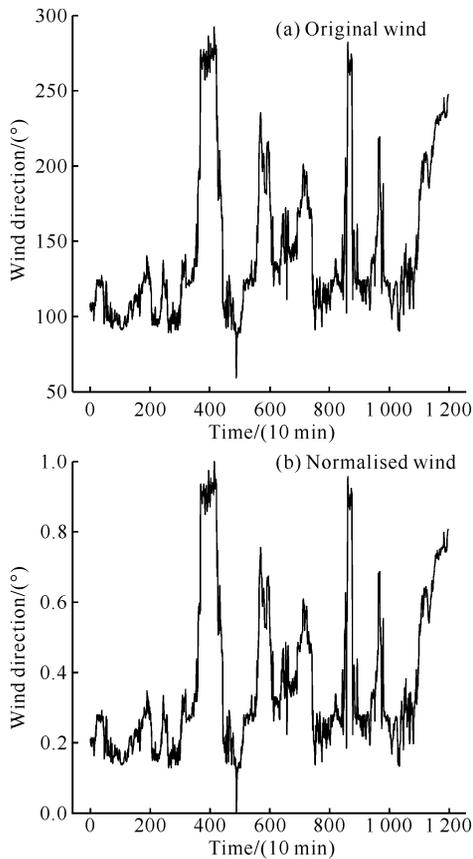


图6 风向序列曲线

Fig. 6 Wind direction sequence curve

3.2 模型参数设置

为了验证本文的 CNN-LSTM-Attention 模型的相关性能,分别使用卷积-长短时记忆网络(CNN-LSTM)^[17]、长短时记忆(LSTM)网络^[18]、卷积神经网络(CNN)^[19]和 BP 神经网络^[20],在相同历史数据下进行风向预测,并与本文的预测模型进行对比分析。CNN-LSTM-Attention 预测模型时间步长为 5,即将 5 个历史风向数据作为输入,预测出后一位风向数据。该模型参数依靠经验进行设置,并根据所得结果不断调整参数。具体参数设置:设置 2 层卷积层,激活函数使用 ReLU 函数,第 1 层和第 2 层卷积层的卷积核均有 64 个,大小设置均为 5×5 ;设置 2 层最大池化层,其 pool_size 设置均为 1;设置 1 层 flatten 层;设置 4 层 LSTM 网络层,其单元数分别为 100、110、90 和 90;设置 3 层 Dropout 函数, p 均为 0.1,加入注意力层,最后连接全连接层作为输出, batch_size 设置为 16, each_epoch 设置为 200 次,使用均方误差作为目标函数,优化算法采用学习率自适应的 Adam 算法。

3.3 评价指标

在各模型性能评比上,本文使用常用的评价函数

进行评价。 y_{true} 表示测试集,即该时刻输出的实际值; y_{pre} 表示通过模型预测出的预测值; n 为测试集的测试样本数; \bar{y} 表示样本均值。

绝对平均误差(MAE):

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_{\text{true}} - y_{\text{pre}}|。 \quad (12)$$

相对平均误差(MAPE):

$$\text{MAPE} = \left(\frac{1}{n} \sum_{i=1}^n |y_{\text{true}} - y_{\text{pre}}| \right) \times 100\% / \bar{y}_{\text{true}}。 \quad (13)$$

均方根误差(RMSE):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{\text{true}} - y_{\text{pre}})^2}。 \quad (14)$$

相关系数(R^2):

$$R^2 = 1 - \sum_{i=1}^N \frac{(y_{\text{true}} - y_{\text{pre}})^2}{(y_{\text{true}} - \bar{y})^2}。 \quad (15)$$

其中,MAE、MAPE、RMSE 越小,说明模型的精确度越高; R^2 的取值范围为(0,1), R^2 越大表示模型的拟合效果越好。

3.4 实验结果分析

将 BP 模型、CNN 模型、LSTM 模型、CNN-LSTM 模型和 CNN-LSTM-Attention 模型的预测结果和实际值进行对比,其结果如图 7 所示。

通过图 7 可以看出,本文提出的 CNN-LSTM-Attention 模型比 CNN-LSTM 模型、LSTM 模型、CNN 模型以及 BP 模型预测效果更优。其中,BP 神经网络预测结果与真实值有明显差异,效果并不理想[图 7(a)];相对于 BP 模型,CNN 模型提高了预测精度,但是在风向变化较大的位置误差较大[图 7(b)];在风向变化较大的位置,LSTM 模型相对于 CNN 模型误差变小,预测效果提高[图 7(c)];相对于 LSTM 预测值分布于真实值下方,CNN-LSTM 模型的预测值比 LSTM 更接近于真实值[图 7(d)];相对于 CNN-LSTM 模型,CNN-LSTM-Attention 模型的预测值曲线拟合程度更为理想,预测精度提高[图 7(e)]。

5 种预测模型的评价结果如表 1 所示。通过对 5 种模型预测结果的误差对比分析可知,在北部湾海域的风况下,本文提出的 CNN-LSTM-Attention 模型的 MAPE、RMSE 以及 MAE 都是最小的, R^2 值最大,预测效果最好。其中,CNN-LSTM-Attention 预测模型的 MAPE 为 3.2119%,相对于 BP、CNN、

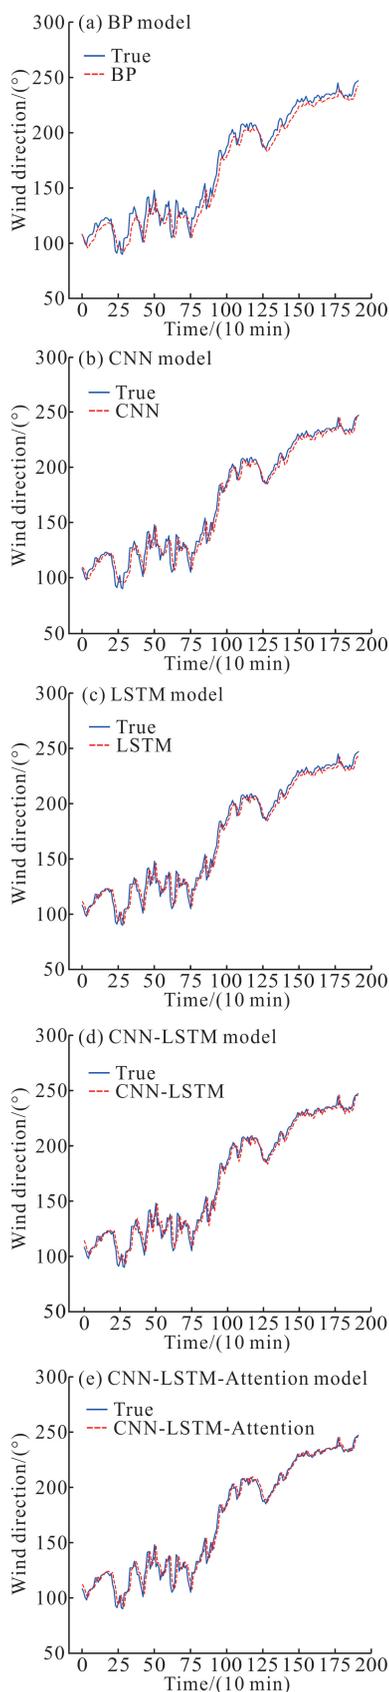


图7 各模型预测结果

Fig. 7 Prediction results of each model

LSTM、CNN - LSTM 模型分别减少 1.4741%、0.5700%、0.2928%、0.2096%；RMSE 为 6.496 9，相对于 BP、CNN、LSTM、CNN-LSTM 模型分别减少 2.116 6、0.768 4、0.285 6、0.183 5；MAE 为 4.470 5°，相对于 BP、CNN、LSTM、CNN-LSTM 模型分别减少 2.652 2°、1.203 2°、0.624 2°、0.408 1°； R^2 为 0.982 6，相对于 BP、CNN、LSTM、CNN - LSTM 模型分别提高 0.012 5、0.003 9、0.002 3、0.001 5。因此本文模型预测性能优于其他 4 种模型。

表1 风向预测性能对比

Table 1 Comparison of wind direction prediction performance

模型 Model	MAPE/(%)	RMSE	MAE/(°)	R^2
BP	4.686 0	8.613 5	7.122 7	0.970 1
CNN	3.781 9	7.265 3	5.673 7	0.978 7
LSTM	3.504 7	6.782 5	5.094 7	0.980 3
CNN-LSTM	3.421 5	6.680 4	4.878 6	0.981 1
CNN-LSTM-Attention	3.211 9	6.496 9	4.470 5	0.982 6

4 结论

针对我国广西北部湾海域处于海上风电建设探索阶段,北部湾海域风速较低的现象,准确预测风向,有助于优化偏航控制系统,提高风资源利用率,提增风力发电的经济效益。本文提出基于 CNN-LSTM-Attention 的深度学习神经网络模型,结合北部湾海域的风况条件,对未来风向进行预测。通过设置对比分析实验可知:

①结合北部湾海域历史风向数据,本文提出的 CNN - LSTM - Attention 预测模型相对于 CNN - LSTM、LSTM、CNN 以及 BP 网络模型具有更高的预测精度,与实际风向具有较好的拟合性,从而验证了所提出的方法在风向预测方面的有效性,可为广西北部湾海域海上风电建设探索发展提供参考决策。

②由于风的随机性,在风向变化幅度较大时,预测精度会有些许降低。后续进一步研究可以考虑添加一些影响风向变化的数据,如温度、湿度等,以提高波动点的预测精度。

参考文献

- [1] 张磊,李继影,李钦伟,等. 风力机偏航系统控制策略研究现状及进展[J]. 发电技术, 2021, 42(3): 306-312.
- [2] 张东东,崔新维. BP 神经网络在风力发电机风向预测中的应用[J]. 太阳能, 2015(3): 47-49.

- [3] 卓泽赢,曹茜,李青. 基于 EWT-KELM 方法的短期风电功率组合预测[J]. 电测与仪表,2019,56(2):83-89.
- [4] LYNCH C, OMAHONY M J, SCULLY T. Simplified method to derive the Kalman Filter covariance matrices to predict wind speeds from a NWP model [J]. Energy Procedia,2014,62:676-685.
- [5] WANG Y, CHEN Q X, GAN D H, et al. Deep learning-based socio-demographic information identification from smart meter data [J]. IEEE Transactions on Smart Grid,2019,10(3):2593-2602.
- [6] 李亚蒙,孙宝楠,丁军航,等. 基于 LSTM 的海洋表面短期风速预测研究[J]. 海洋科学,2022,46(11):55-66.
- [7] CINAR Y G, MIRISAEE H, GOSWAMI P, et al. Period-aware content attention RNNs for time series forecasting with missing values [J]. Neurocomputing, 2018,312:177-186.
- [8] MEDENNIKOV I, BULUSHEVA A. LSTM-based language models for spontaneous speech recognition [C]// International Conference on Speech and Computer, Switzerland:Springer, Cham,2016:469-475.
- [9] 陆继翔,张琪培,杨志宏,等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019,43(8):131-137.
- [10] 苏雅茜,崔超然,曲浩. 基于自注意力移动平均线的时间序列预测[J]. 南京大学学报(自然科学版),2022, 58(4):649-657.
- [11] 简定辉,李萍,黄宇航,等. 基于 CNN-LSTM 网络的短期电力负荷预测[J]. 电工电气,2022(9):1-6.
- [12] 赵兵,王增平,纪维佳,等. 基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J]. 电网技术,2019, 43(12):4370-4376.
- [13] 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.
- [14] 陈海鹏,周越豪,王趁录,等. 基于改进的 CNN-LSTM 短期风功率预测的系统旋转备用经济性分析[J]. 高电压技术,2022,48(2):439-448.
- [15] 刘柏霆,管卫利,李陶深. 基于 XLNet + BiGRU + Att (Label)的文本分类模型[J]. 广西科学院学报,2022, 38(4):412-419.
- [16] 王宇辉,帖云,王峰,等. 基于希尔伯特曲线-卷积神经网络的肿瘤类型预测[J]. 郑州大学学报(理学版), 2021,53(4):89-94.
- [17] 王朝阳,李丽敏,温宗周,等. 基于时间序列和 CNN-LSTM 的滑坡位移动态预测[J]. 国外电子测量技术, 2022,41(3):1-8.
- [18] 叶峻峒,苏敬勇,王耀威,等. 基于 LSTM 的语言学习长期记忆预测模型[J]. 中文信息学报,2022,36(12): 133-138,148.
- [19] LIU T Y, HUANG Z K, TIAN L, et al. Enhancing wind turbine power forecast via convolutional neural network [J]. Electronics,2021,10(3):261.
- [20] HUANG Y, XIANG Y X, ZHAO R X, et al. Air quality prediction using improved PSO-BP neural network [J]. IEEE Access,2020,8:99346-99353.

Short-Term Wind Direction Prediction Based on CNN-LSTM-Attention

HAN Xinghui¹, HE Yongling^{1*}, MENG Zhanbin¹, HU Wenrui¹, LIAO Binjie²

(1. College of Mechanical and Marine Ocean Engineering, Beibu Gulf University, Qinzhou, Guangxi, 535011, China; 2. Guangxi Power Grid Qinzhou New District Power Supply Bureau, Qinzhou, Guangxi, 535011, China)

Abstract: Wind direction prediction is of great importance to improve the conversion rate of wind energy, ensure the safe operation of wind turbine yaw system and increase the benefits of wind power generation. In order to accurately predict wind direction, a short-term wind direction prediction model based on CNN-LSTM-Attention is proposed. Firstly, the Convolutional Neural Network (CNN) is used to extract the dynamic change features of wind direction data. Then, the extracted feature vectors are used to form a time series as the input of the Long Short-Term Memory (LSTM) network. Finally, attention mechanism is used to allocate different weights of the LSTM hidden layer to enhance the role of important features and complete the wind direction prediction. The historical wind direction data of Beibu Gulf waters are used to compare with other neural network prediction models through experiments. The results show that the MAPE value of CNN-LSTM-Attention model is 3.2119%, and R^2 is 0.9826, which is better than other comparison models. The results provide a reference for the exploration and development of offshore wind power in Beibu Gulf of Guangxi.

Key words: yaw system; wind direction prediction; attention mechanism; CNN; LSTM network

责任编辑:梁晓