

基于 LSTM 的海洋表面短期风速预测研究

李亚蒙^{1,2}, 孙宝楠^{2,3,4,5}, 丁军航^{1,6,7}, 官 晟^{2,3,4,5}

(1. 青岛大学自动化学院, 山东 青岛 266071; 2. 自然资源部第一海洋研究所, 山东 青岛 266061; 3. 自然资源部海洋环境科学与数值模拟重点实验室, 山东 青岛 266061; 4. 山东省海洋环境科学与数值模拟重点实验室, 山东 青岛 266061; 5. 青岛海洋科学与技术试点国家实验室区域海洋动力学与数值模拟功能实验室, 山东 青岛 266237; 6. 山东省工业控制技术重点实验室, 山东 青岛 266071; 7. 青岛大学山东省生态纺织协同创新中心, 山东 青岛 266071)

摘要: 为实现对海面风速精确的短期预测, 提出了一种基于长短期记忆(LSTM, long short-term memory)神经网络的短期风速预测模型, 选取 OceanSITES 数据库中单个浮标站点采集的风速历史数据作为模型输入, 经过训练设置最佳参数等步骤, 实现了以 LSTM 方法, 对该站点所在海区海面风速在各季节性代表月份海面风速的 24 h 短期预测。同时通过不同预测时长的实验以及与 BP(back propagation)神经网络神经网络和径向基函数神经网络(radial basis function neural network, RBF)的预测效果对比实验, 证明了 LSTM 预测方法相比上述两种神经网络预测方法, 在海表面风速预测应用中的优越性。最后通过多个海域对应的站点风速数据预测实验, 证明了 LSTM 神经网络模型的普遍适用性, 由相关系数和预测误差的分析可知该方法具备应对急剧变化数据的预测稳定性, 可以作为海洋表面风速短期预测的一种可靠方法。

关键词: 神经网络; 长短期记忆网络模型; 海面风速; 短期预测

中图分类号: P714.1 文献标识码: A 文章编号: 1000-3096(2022)11-0055-12

DOI: 10.11759/hyxx20211116001

20 世纪以来, 全球气候变暖加剧, 世界各地的自然灾害事件频繁发生, 其中海洋灾害造成的损失迅速增长^[1]。20 世纪 90 年代末, 中国海洋灾害年经济损失高达 100 亿元, 其中由于风暴潮灾害造成的损失占 80%以上, 并且在 2017 年中, 风暴潮灾害造成的直接经济损失在全部海洋灾害直接经济损失中占比突破 90%^[2]。此外, 随着人类海上活动增多, 对海洋环境及相互作用的观测需求更为迫切。例如, 近年发展的海上航天发射活动, 对包括风速等要素的观测提出更高需求; 风力发电要实现并网调配, 保障安全运行, 也需要具备对风速的预报、预警能力。因此针对海面 10 m 高度风速(以下统称海面风速)的预测研究, 对于海上作业、海洋环境安全预警、海洋观测环境预报等应用领域有重要的意义。

目前常用的风速预报研究方法包括: 经验预报、数值预报、统计预报和神经网络预报^[3]等。其中, 神经网络和深度学习在风速预报中的应用成为近年研究热点。包括误差法反向传播(back propagation, BP)神经网络、多层感知机器(multilayer perceptron, MLP)、

循环神经网络(recurrent neural network, RNN)、自适应神经模糊推断系统(adaptive network-based fuzzy inference system, ANFIS)、支持向量机(support vector machine, SVM)、卡尔曼滤波器等。

长短期记忆(long short-term memory, LSTM)神经网络是一种基于 RNN 的改进算法, 作为非线性模型, LSTM 可以用于构造更大型的深度神经网络^[4]。熊一橙等^[5]基于 LSTM 构建多输入-多输出智能网络, 利用 SWAT(soil and water assessment tool)模型对 4 个水文站点的径流过程进行了模拟研究。针对河流水质的变化趋势^[6-7]和海洋水质预测^[8]问题, 建立 LSTM 预测模型或基于 LSTM 的组合预测模型均具有良好的预测效果。武双新^[9]利用 LSTM 气温预测

收稿日期: 2021-11-16; 修回日期: 2022-01-23

基金项目: 科技部重大科学仪器专项项目(2018YFF01014100)

[Foundation: Major Scientific Instrument Project of Ministry of Science and Technology, No. 2018YFF01014100]

作者简介: 李亚蒙(1996—), 女, 山东烟台人, 硕士研究生, 主要从事智能控制与数据资料预测分析研究, E-mail: 516553884@qq.com; 官晟(1972—), 通信作者, 男, 山东青岛人, 研究员, 博士, 主要从事海洋环境观测技术与智能控制研究, E-mail: gsh30@163.com

模型对每日最高气温进行预测并与其他模型对比,实验证明了该模型预测效果的优越性。在河流水温预测^[10]以及沿海异常高水温预测^[11]方面, LSTM 预测模型均体现出了优质的潜力。Liu 等^[12]提出了一种基于 LSTM 的城市内、外河短期水位实时滚动预测方法,并以福州市为研究区域,证实了 LSTM 在水位实时滚动预报中的可行性。Yan 等^[13]设计了一种基于深度学习的海杂波信号检测方法,利用 LSTM 的优点对预测误差进行频域转换,提高了检测性能。Jrges 等^[14]开发了一种基于 LSTM 神经网络的机器学习模型,用于预测近岸海水的的海有效波高,实验证明 LSTM 的性能优于深度前馈神经网络和其他先进的机器学习算法。

在风速预测领域, LSTM 模型能成功学习不同方向风速预报特点,对于不同方向风速预报误差结果相近,具有一定的抗干扰能力,可以忽略掉部分相关性和质量差的变量^[15]。魏昱洲等^[16]设计了一种双层网络结构的 LSTM 预测模型,通过实验证明了预测模型的高精度性。李冰等^[17]以风机历史数据为输入,建立了基于 LSTM 深度神经网络的短期风速预测模型,预测误差与其他预测方法相比更小。王俊等^[18]提出一种基于变分模态分解(variational mode decomposition, VMD)和 LSTM 的超短期预测算法,对比分析证明该模型在超短期风速预测上精度较高。

在风速预测问题上,目前已经有了大量的研究,然而大部分均聚焦在城市、风场和铁路附近等陆上领域,对于海面风速研究极为匮乏。原因在于海洋气象环境多变并且风速变化幅度强烈。此外由于海洋环境复杂,对于海面风速的数据采集相较于陆地更为困难,导致数据的连续性和代表性也因此降低。

本文利用浮标测量风速数据,将 LSTM 预测模型应用到海面风速的短期预测中。首先研究了 LSTM 算法对于季节性海面风速的预测效果,并与 BP 神经网络和径向基函数(radial basis function, RBF)神经网络预测方法进行对比,证明了该方法的预测准确性。然后通过多个浮标站点采集的数据进行预测实验,验证了 LSTM 预测方法对于不同海域的普遍适用性。为海面风速的短期预测研究提供了一种思考路线。

1 相关理论和数据来源

1.1 LSTM 网络结构

LSTM 网络是一种时间循环神经网络,用于消除 RNN 在处理长期依赖问题时产生的梯度消失或梯度爆炸现象^[19]。相比普通 RNN 的简单重复模块链结构, LSTM 拥有 4 层以特殊形式交互的重复模块结构,因此在长序列训练过程中, LSTM 表现更好。

LSTM 具有删除或添加信息到细胞状态的能力,该能力由一种名为“门”的可选式信息通过方式赋予,“门”的结构由 sigmoid 神经网络层和点乘法运算组成。相较于 RNN 的隐藏层中只有单个传递状态, LSTM 网络增加了一个状态单元 c_t ,并由 LSTM 中的 3 个“门”:输入门 i_t 、输出门 o_t 和遗忘门 f_t 进行保护和控制。LSTM 单元在当前时刻有 3 个控制输入:输入值 x_t 、上一时刻输出值 h_{t-1} 和上一时刻状态值 c_{t-1} , 2 个输出:输出值 h_t 和状态值 c_t 。输入门控制即时输入信息送入状态单元;输出门控制状态单元中部分信息输出并继续自循环迭代;遗忘门控制信息的删除与保留,并重置状态单元。LSTM 网络结构如图 1 所示。

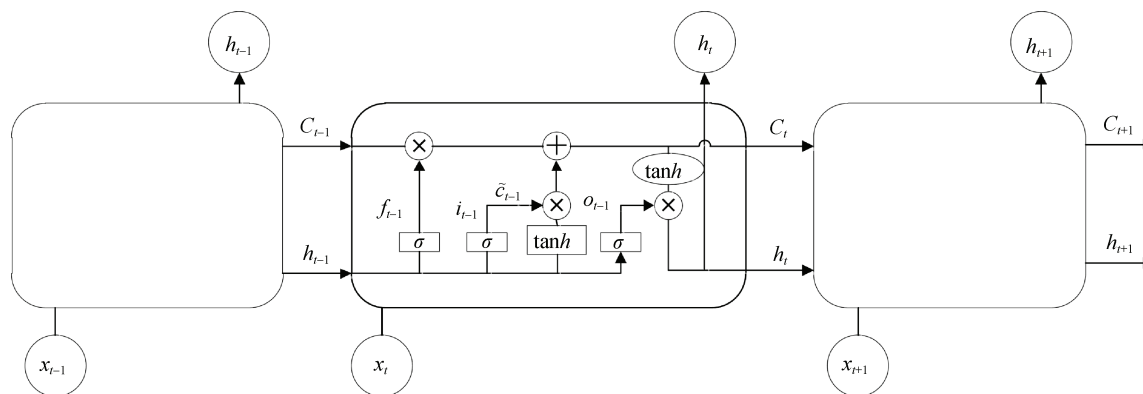


图 1 LSTM 网络结构图
Fig. 1 LSTM network structure

单个 LSTM 主要分为以下 4 个步骤:

(1) 确定要从状态单元中删除哪些信息。这项工作由“遗忘门”中的 sigmoid 神经网络层实现,它基于前一时刻输出 h_{t-1} 和当前时刻输入 x_t , 为上个时刻状态值 c_{t-1} 中每个值输出 0 到 1 之间的数字, 1 表示全部保留, 0 表示彻底遗忘。

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

其中, f_t 是遗忘门激活函数, σ 是 sigmoid 函数, W_f 是遗忘门权重矩阵, b_f 是遗忘门偏置向量。

(2) 确定要在状态单元中存储哪些信息。该步骤分为两部分, 首先利用“输入门”的 sigmoid 层决定更新值, 其次使用 tanh 层计算候选向量 \tilde{c}_t 加入状态单元中。

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

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

其中, i_t 是输入门激活函数, W_i 、 W_c 是输入门、状态单元权重矩阵, b_i 、 b_c 是输入门、状态单元偏置向量。

(3) 更新上一时刻状态值 c_{t-1} , 得到当前时刻状态值 c_t 。

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t, \quad (4)$$

其中, “ \cdot ” 指按元素相乘符号。

(4) 确定输出信息。首先运行 sigmoid 层决定要输出哪些部分, 其次将状态值通过 tanh 层, 并结合 sigmoid 层输出决定信息输出的程度。

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

$$h_t = o_t \cdot \tanh(c_t), \quad (6)$$

其中, o_t 是输出门激活函数, W_o 是输出门权重矩阵, b_o 是输出门偏置向量。

1.2 数据来源

本文采用的海面风速数据是 OceanSITES 数据库 (OceanSITES 是一个全球范围的, 长期、开放的海洋观测站系统, 每个站位可以测量获取从海气界面到海底, 全海深的数十个海洋环境变量。https://dods.ndbc.noaa.gov/oceansites/) 中, 位于各个海域, 靠近海岸线的浮标站点实时监测的现场数据。包括东太平洋 T8S165E 站(8°S, 165°E)、西太平洋 T2S95W 站(2°S, 95°W)、北大西洋 PIRATA 站(21°N, 23°W)、南大西洋 PIRATA 站(14°S, 32°W)和北印度洋 RAMA 站(15°N, 90°E)。上述站位, 分布在主要大洋, 且位置相对较远, 测试结果具有较强的独立性, 因而研究结果的普适性更有说服力。

本文下载使用的 NC(Net Common Data Format, NetCDF)数据包中, 包含了近年来对应站点的风速、气温、相对湿度和大气压等气象观测数据。浮标风速传感器每 10 min 启动一次用时 2 min 的检测, 共采样 240 次, 以 240 次采样平均值作为这 10 min 的风速值。这种检测方法将浮标运动及传感器随机误差对风速测量造成的影响大大降低, 测量值基本反映了风速本身的变化规律, 更有利于开展预测方法的研究。本文采用 Matlab 软件及其机器学习工具箱进行短期风速预测。首先对获取的数据进行数据集划分和标准化, 将处理后的数据输入构建的 LSTM 网络进行训练, 通过重复训练计算出损失函数和模型误差, 从而调整网络参数得到基于 LSTM 的短期风速预测模型。

2 风速预测的具体实现

2.1 预测模型构建

本文采用的短期风速预测模型, 隐含层由一个 LSTM 层、一个 Dropout 层和一个 Dense 层构成。Dropout 方法能够有效解决神经网络在训练过程中, 训练结果较好而测试效果较差的过拟合问题。Dense 层中每个神经元与上一层全部神经元输出相连^[20], 因此 LSTM 的输出不仅包含预测所需信息, 还能反映出特征信息与预测结果之间的函数关系。

LSTM 模型具体实现风速预测由 3 个步骤构成。首先, 对采集到的数据进行划分和标准化处理; 其次, 在训练过程中, 确定网络模型训练和预测所需具体参数如隐藏层神经元个数、学习率、训练迭代次数等, 完成模型的构建; 最后, 通过去标准化的数据进行测试集预测, 完成对模型的检验。预测模型框架如图 2 所示。

2.2 数据处理和模型参数

本文数据来源于实时监测采集海面风速的太平洋浮标站点, 选取其中一定序列长度的数据, 按一定比例划分训练集和测试集。考虑到神经网络中神经元的饱和特性, 以及激活函数的输入输出数值范围, 数据划分完毕后需要进行标准化处理, 标准化公式为:

$$s_t = \frac{d_t - \mu_{tra}}{\sigma_{tra}}, \quad (7)$$

其中, s_t 是标准化后的数值, d_t 是训练集中每个时刻的数据值, μ_{tra} 是训练数据的均值, σ_{tra} 是训练数据的标准差。

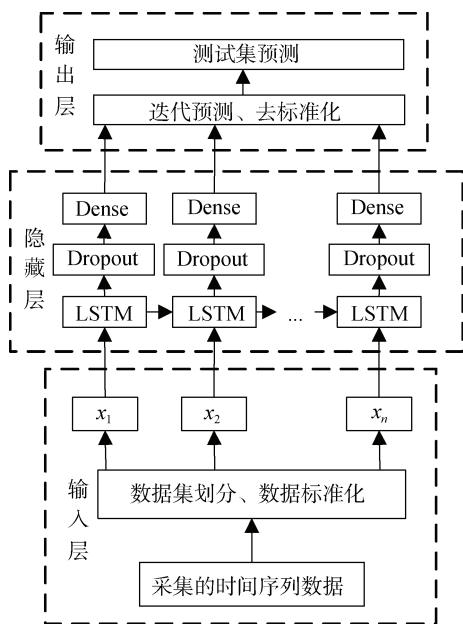


图 2 LSTM 预测网络模型框架

Fig. 2 LSTM prediction network model framework

构建基于 LSTM 网络的海表短期风速预测模型需要确定部分特征参数。本文建立的预测模型只考虑到海面风速数据，因此输入层维数设为 1。隐藏层维数代表了隐藏层神经元的个数，当时间序列数据较为复杂时，神经元个数设置越多模拟效果越好，但同时也带来了训练时间过长以及过拟合的缺点，在训练过程中需要折衷考虑模拟效果和训练时间长短问题，因此在隐藏层中，选取 LSTM 层神经元个数为 144，Dropout 层舍弃神经元比例为 0.2，Dense layer 层输出向量为 1 维。同时可知输出层维数为 1。训练天数即训练数据的序列长度，选择时需要充分考虑模型进行网络训练时的实际情况，当序列长度太短时，模型训练程度不足以模拟出数据变化的规律，预测性能较差；当序列长度太长时，会导致训练时间过长，且有概率因为突兀数据造成预测性能恶化，本文在实验过程中，通过设置不同的训练天数来确定最佳的序列长度。训练迭代次数 epoch 与训练天数类似，选择的大小会影响模型生成时间和预测准确率，因此同样通过实验设置不同的迭代次数进行对比，从而选择出最佳次数。

LSTM 网络的训练采用的是反向传播算法 (back-propagation through time, BPTT)，首先前向计算出每个神经元的输出值，其次反向计算出每个神经元的误差项，最后通过误差项计算出权重梯度值。本文实验中在每一步的预测完成后，利用

该时刻的风速预测值计算误差项，进而预测出下一步的风速值。其他的网络参数设置如下：损失函数采用均方根误差函数、优化算法使用学习率自适应 (adaptive moment estimation, Adam) 算法、初始学习率设置为 0.005。

2.3 预测效果评价指标

在短期风速预测中，一般选取平均绝对误差 (mean absolute error, E_{MA}) 和均方根误差 (root mean squared error, E_{RMS}) 对预测结果进行评价，两者的计算公式如下：

$$E_{MA} = \frac{1}{N} \sum_{t=1}^N (|f_t - y_t|), \quad (8)$$

$$E_{RMS} = \sqrt{\frac{1}{N} \sum_{t=1}^N (f_t - y_t)^2}, \quad (9)$$

其中， N 表示模型样本数， f_t 表示 t 时刻风速实际值， y_t 表示 t 时刻风速预测值。

同时，利用皮尔逊相关系数 r (Pearson correlation coefficient) 作为反映预测值与实际值之间相关性程度的统计指标。计算公式为：

$$r = \frac{\sum_{t=1}^N (f_t - \bar{f})(y_t - \bar{y})}{\sqrt{\sum_{t=1}^N (f_t - \bar{f})^2 \sum_{t=1}^N (y_t - \bar{y})^2}}, \quad (10)$$

其中， \bar{f} 表示风速实际值均值， \bar{y} 表示风速预测值均值。可知 r 的绝对值处于 0~1， r 越接近 1，则预测值与实际值之间相关性程度越高。

3 实验结果与分析

3.1 样本选择

首先从 T8S165E 站提供的海洋数据中，筛选出对应位置 2021 年各季节代表月份中 16 d 的实时数据，进行海面风速的季节性预测研究讨论，分别为 1 月、4 月、7 月和 10 月，每天数据的采样周期为 10 min。在实验过程中，通过设定 LSTM 模型中不同的训练天数对应的样本数据和训练迭代次数，来实现对各月份后 144 个样本数据的预测。同时与 BP 神经网络模型和 RBF 神经网络模型的季节性风速预测结果进行对比。考虑到缺损值和突兀点对神经网络模型训练的影响，首先需要对采集到的数据进行预处理。剔除野点后，T8S165E 站各月份选取的 16 d 海面风速变化曲线如图 3 所示。

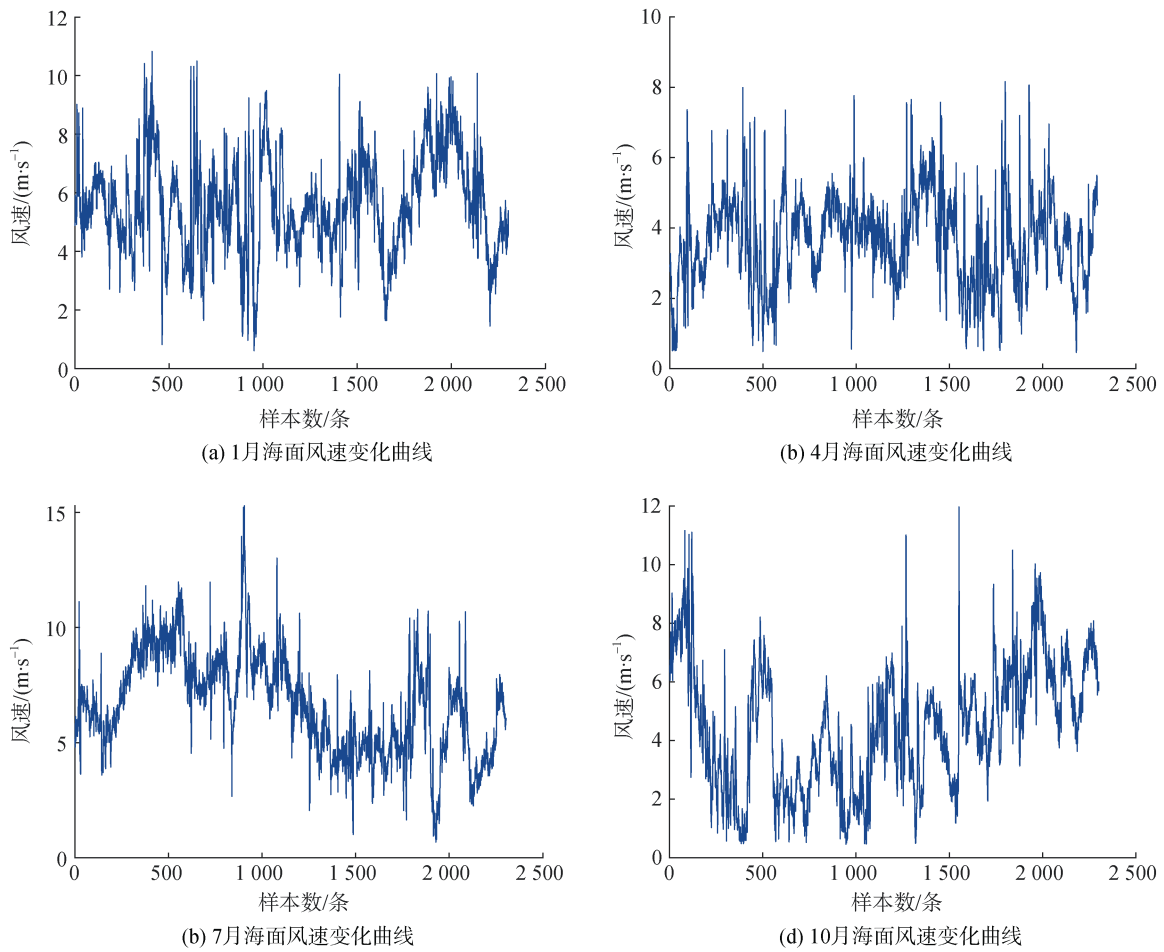


图 3 T8S165E 站各季节海面风速变化曲线

Fig. 3 Sea surface wind speed variation curve of T8S165E station in different seasons

3.2 预测结果及性能分析

通常情况下，随着训练天数和训练迭代次数的增加，LSTM 模型的预测效果越理想，但同时训练时间也随之增加。当参数选择过小时，模型无法完成收敛，预测精度较低；当参数选择过大时，模型的误差和损失函数等下降幅度会减弱，此时参数中过多的无用信息以及增加的训练时间则拉低了预测模型的整体性能。因此综合考虑到训练天数和训练迭代次数对模型预测精准度和训练时间的影响，将 T8S165E 站 2021 年各月份数据对应的训练时间分别设置为 15 d、10 d、5 d 和 3 d，即对应的训练数据样本个数为 2 160、1 440、720 和 432。训练迭代次数分别设置为 40、60 和 80，形成的参数组合如表 1 所示。

根据不同的参数组合，绘出对应的模型平均绝对误差和均方根误差如图 4 所示。

表 1 训练时间和训练迭代次数参数选取

Tab. 1 Parameter selection of training time (d) and training iterations

编号	训练时间/d	训练迭代次数
1	15	40
2	15	60
3	15	80
4	10	40
5	10	60
6	10	80
7	5	40
8	5	60
9	5	80
10	3	40
11	3	60
12	3	80

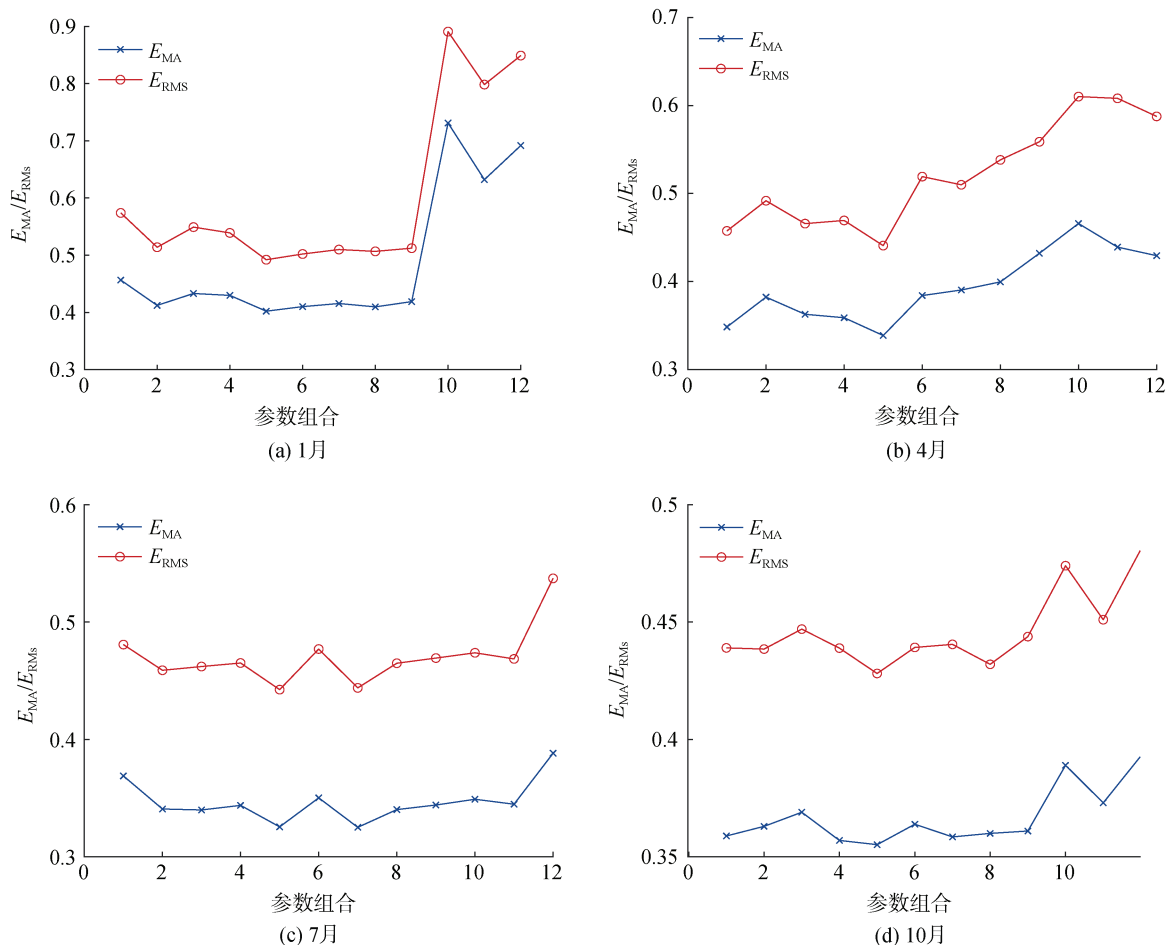


图4 各月份不同参数组合下的 MAE/RMSE

Fig. 4 MAE/RMSE under different parameter combinations in each month

结合训练误差对各季节的 LSTM 风速预测模型参数进行如下设置: 1月, 4月, 7月, 10月训练时间均为 10 d, 迭代次数均为 60。BP 神经网络预测模型输入层维数为 1, 中间层神经元数通过训练得出最佳值 7, 输出层维数为 1, 各月份训练时间通过实验, 同样选择为 10 d。RBF 神经网络预测模型参数选择与 BP 模型基本相同。利用设置的参数代入各模型对各月份后 144 个样本数据进行预测, 如图 5 所示为各季节海面风速预测效果的对比情况。

各模型预测结果的平均绝对误差和均方根误差如表 2 所示。

通过预测结果和误差分析可知, 对于不同季节的数据, 各神经网络预测模型都可以有效模拟出海面风速的变化趋势, 体现出在不同季节的海洋环境影响下, 预测模型均具备一定的适应性, 可以全方位地预测出整年的海面风速数据。

根据浮标实际检测值可知, 海面风速的随机性较强, 变化幅度较大, 当各月份出现急剧变化的风速值时, LSTM 神经网络的预测效率更强, 对于风速的拟合度相较另外两种神经网络更高。对于整体预测效果而言, LSTM 的预测最小 E_{MA} 和 E_{RMS} 达到 0.328 和 0.445, RBF 预测的最小 E_{MA} 和 E_{RMS} 分别为 0.334 和 0.463, BP 预测的最小 E_{MA} 和 E_{RMS} 分别为 0.373 和 0.476, 因此 LSTM 神经网络模型的预测更精准有效。

各种神经网络模型对于海面风速的预测可以进一步讨论, 通过调整不同的测试集长度, 验证出神经网络模型的最佳预测周期。设置预测时长为 6、12、18 和 24 h, 利用 3 种神经网络模型对各季节海面风速预测进行对比, 选择出预测的最佳测试集长度, 预测值的平均绝对误差如下图 6 所示。

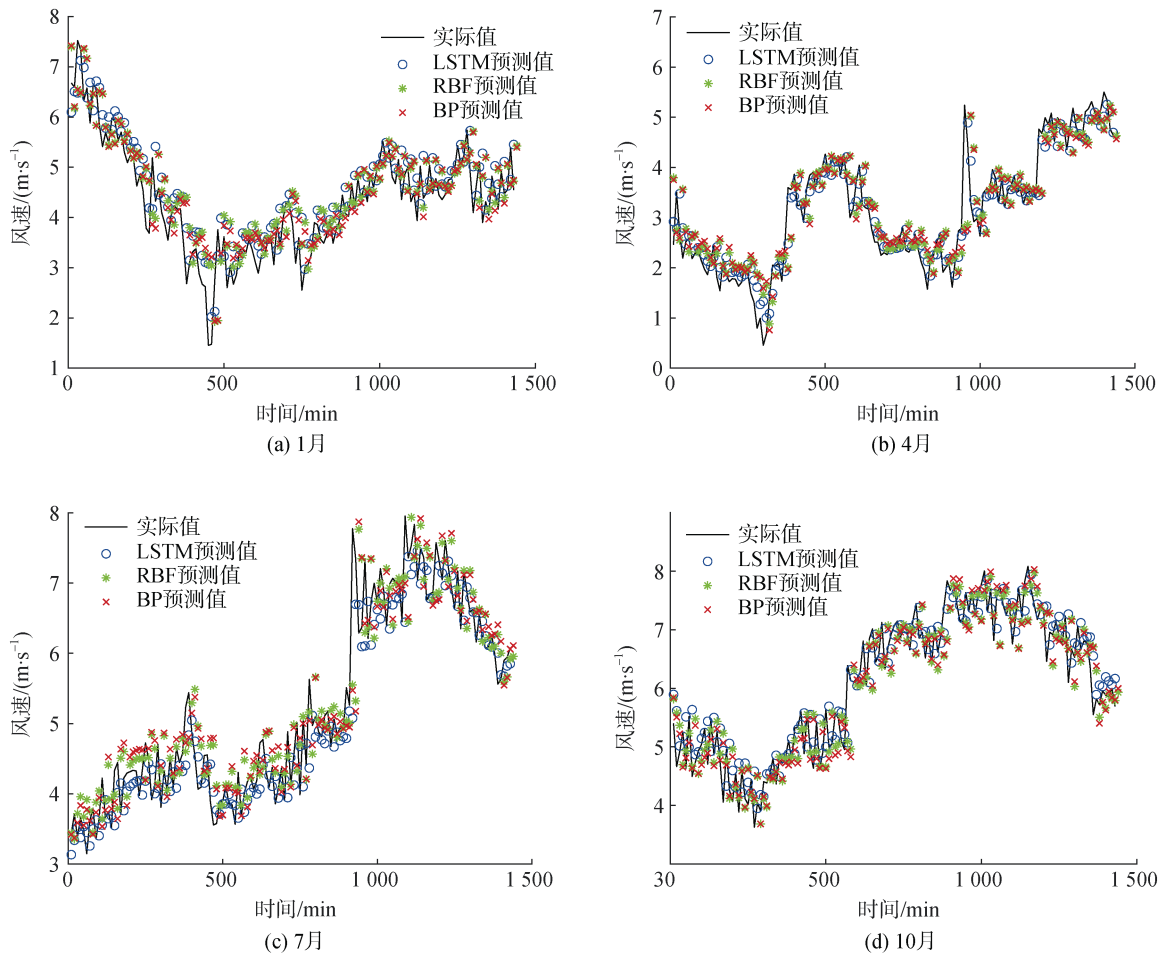


图 5 海面风速预测结果与实测对比

Fig. 5 Comparison between predicted and measured sea surface wind speed

表 2 各模型预测结果的 MAE 和 RMSE

Tab. 2 MAE and RMSE of predicted results of each model

预测方法	误差	1月	4月	7月	10月
LSTM	E_{MA}	0.400	0.328	0.328	0.354
	E_{RMS}	0.496	0.446	0.445	0.428
RBF	E_{MA}	0.435	0.334	0.380	0.393
	E_{RMS}	0.541	0.463	0.507	0.471
BP	E_{MA}	0.440	0.373	0.384	0.404
	E_{RMS}	0.541	0.476	0.509	0.481

由实验结果可知, 随着测试集预测时长的变化, LSTM 神经网络模型的预测误差始终低于其他神经网络模型。由于海面风速的变化幅度较大且随机性较强, 因此随着预测时长的变化, 预测的误差变化较小。在实际工程中进行测试集的选择时还需综合考虑预测成本与准确性, 因此在保证风速预测的时效性前提下, 可以选择 24 h 作为测试集最佳预测周期。

3.3 多站点预测验证实验

基于对比实验的研究分析, 为了验证 LSTM 神经网络预测模型的普遍适用性, 选择 4 个站点的海面风速数据进行预测验证, 由于数据较多, 选取各站点在 2021 年中单季节的预测结果进行展示, 分别为 RAMA 站(15°N, 90°E)1 月数据、PIRATA 站(14°S, 32°W)4 月数据、PIRATA 站(21°N, 23°W)7 月份数据和 T2S95W 站(2°S, 95°W)10 月数据。模型参数通过上述实验后均选取最佳值, 各站点数据采样周期仍为 10 min, 预测时长为 24 h。通过各海域浮标站点的代表性海面风速数据验证 LSTM 神经网络模型的预测普遍适用性。预测结果如图 7 所示。

利用相关系数 r (Pearson correlation coefficient) 作为反映预测值与实际值之间相关性程度的统计指标, r 越接近 1, 则预测值与实际值之间相关性程度越高。相关性曲线如图 8 所示。




图 6 各季节代表月份海面风速预测平均绝对误差

Fig. 6 Mean absolute error of sea surface wind speed prediction in representative months of each season

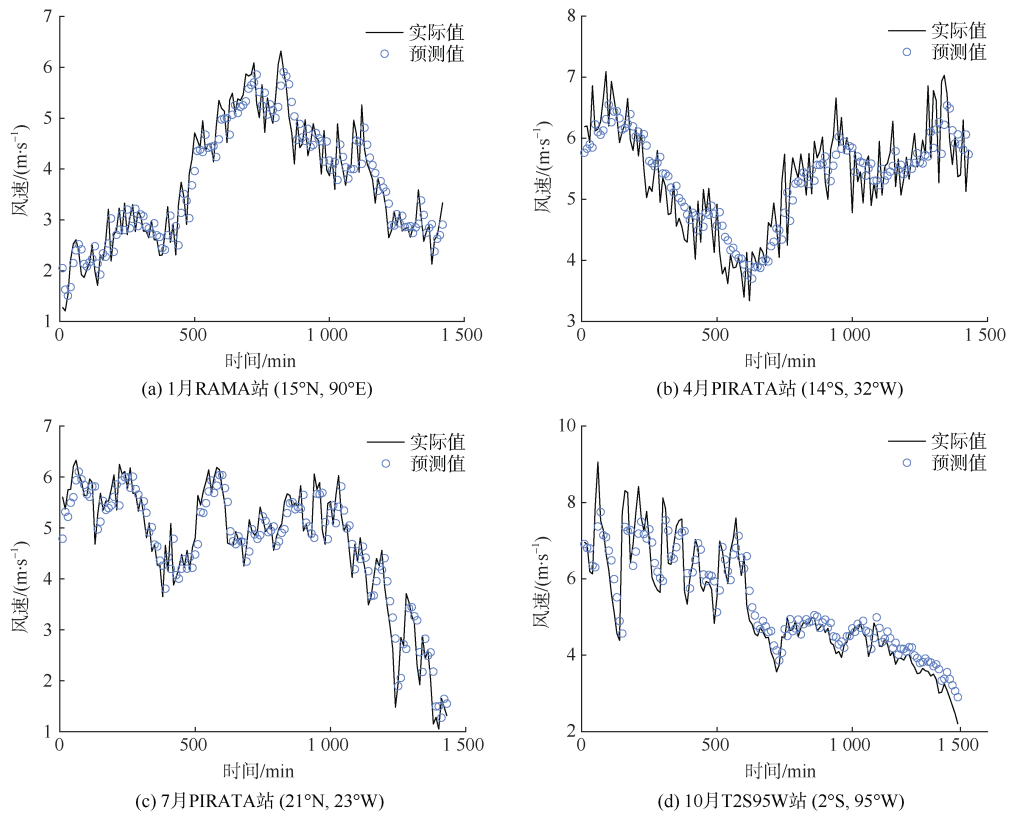


图 7 各站点海面风速预测结果

Fig. 7 Forecast results of sea surface wind speed at each station

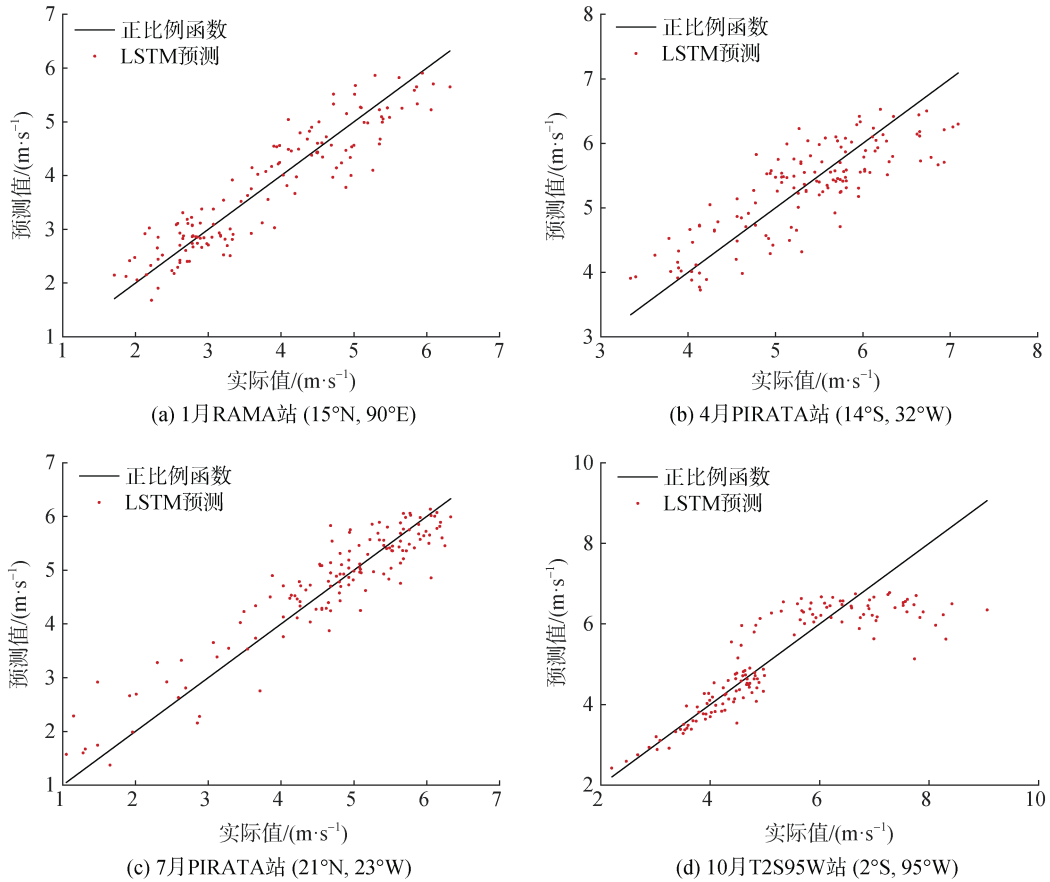


图 8 各站点海面风速预测相关性曲线

Fig. 8 Correlation curve of sea surface wind speed prediction at each station

预测结果指标如表 3 所示。

表 3 各站点预测性能指标和相关系数
Tab. 3 Predicted performance indicators and correlation coefficients of each site

站点	E_{MA}	E_{RMS}	相关系数 r
RAMA 站(15°N, 90°E)	0.369	0.445	0.930
PIRATA 站(14°S, 32°W)	0.394	0.474	0.830
PIRATA 站(21°N, 23°W)	0.389	0.495	0.926
T2S95W 站(2°S, 95°W)	0.416	0.590	0.909

通过多站点预测实验结果的预测误差分析和相关系数可知, LSTM 神经网络模型对于海面风速的预测具备多海域普遍适用性, 能够精确拟合出各海域及各季节海洋数据的变化趋势。当某季节风速变化频率较快且幅度较大时, 模型预测效果仍然可以保证一定的相关程度, 这表明尽管海面风速等海洋数据受诸多不稳定因素影响, 而具备随机性、高非线性的特点, 但使用 LSTM 神经网络能够进行高精度预测, 并且具备应对急剧变化数据的预测稳定性。

4 结论

针对海洋领域中气象环境复杂多变、海面风速随机性强而导致的难以精准预测的问题, 本文提出了一种基于 LSTM 神经网络的短期风速预测方法。在 Matlab 环境下搭建了基于 LSTM 神经网络的预测模型, 同时搭建了 BP 神经网络和 RBF 神经网络模型用作预测性能对比。

首先考虑到海面风速受季节性影响较大, 选取东太平洋单浮标站点各季节代表月份的海面风速历史数据作为模型输入, 通过训练选取最佳模型参数, 对固定测试集海面风速数据进行了预测。结果证明, 3 种神经网络模型均能模拟出海面风速的变化趋势, 对季节性变化均可进行一定时间范围内有效的预测; 但相比之下, LSTM 神经网络拥有更高的精准性能。

其次基于 3 种神经网络预测模型对测试集预测时长进行扩展讨论, 对各模型不同预测时长下的预测值平均绝对误差进行比较, 得出海面风速的最佳

预测周期为 24 h。证明了 LSTM 神经网络整体预测效果始终优于 BP 神经网络和 RBF 神经网络。

最后利用 LSTM 神经网络对不同海域中多个站点进行预测验证,通过选取靠近海岸线的海洋浮标站点,以及各浮标季节性相关的海面风速进行预测实验,验证了本文提出的 LSTM 神经网络模型的普遍适用性。通过相关系数的计算,证明了当数据波动较为频繁时,模型预测结果保持了较强的一致性。

在以后的研究方向中可以进一步考虑优化模型参数的设置,如增加输入维数(包括添加海面海温、湿度、风向等海洋数据作为输入),这些变量可以看作海面风速影响因子。因此可以探讨增加的输入参数与需要预测的参数之间的相关性,并且对比出不同程度相关性数据输入时对于预测精度的影响,进而使得神经网络对于海洋数据的预测达到更高的精确度。

参考文献:

- [1] 许飞琼. 灾害损失评估及其系统结构[J]. 灾害学, 1998, 13(3): 80-83.
XU Feiqiong. Disaster loss assessment and its system structure[J]. Disaster Science, 1998, 13(3): 80-83.
- [2] 肖茹水, 郭佩芳, 解晓茹. 风暴潮灾害损失评估研究综述[J]. 海洋湖沼通报, 2021, 43(2): 67-73.
XIAO Rushui, GUO Peifang, XIE Xiaoru. Overview of the study on the assessment of storm surge disaster losses[J]. Bulletin of Oceans and Lakes, 2021, 43(2): 67-73.
- [3] 耿道懿, 郝坤, 史振威. 一种基于深度学习的热带气旋路径集成预报方法[J]. 海洋科学, 2022, 46(2): 74-86.
GENG Xiaoyi, HAO Kun, SHI Zhenwei. An Integrated prediction method of tropical cyclone paths based on depth learning[J]. Marine Sciences, 2022, 46(2): 74-86.
- [4] 陈亮, 王震, 王刚. 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用[J]. 电力信息与通信技术, 2017, 15(5): 8-11.
CHEN Liang, WANG Zhen, WANG Gang. Application of LSTM network in short-term power load forecasting under the framework of deep learning[J]. Power Information and Communication Technology, 2017, 15(5): 8-11.
- [5] 熊一橙, 徐炜, 张锐, 等. 基于 LSTM 网络的长江上游流域径流模拟研究[J]. 水电能源科学, 2021, 39(9): 22-24, 40.
XIONG Yicheng, XU Wei, ZHANG Rui, et al. Study on runoff simulation of the upper reaches of the Yangtze River based on LSTM network[J]. Hydropower and Energy Science, 2021, 39(9): 22-24, 40.
- [6] 张贻婷, 李天宏. 基于长短时记忆神经网络的河流水质预测研究[J]. 环境科学与技术, 2021, 44(8): 163-169.
ZHANG Yiting, LI Tianhong. Research on prediction of river water quality based on Long-term and Short-term Memory neural network[J]. Environmental Science and Technology, 2021, 44(8): 163-169.
- [7] 胡衍坤, 王宁, 刘枢, 等. 时间序列模型和 LSTM 模型在水质预测中的应用研究[J]. 小型微型计算机系统, 2021, 42(8): 1569-1573.
HU Yankun, WANG Ning, LIU Shu, et al. Research on the application of time series model and LSTM model in water quality prediction[J]. Minicomputer System, 2021, 42(8): 1569-1573.
- [8] 李彦杰, 贺鹏飞, 冯巍巍, 等. 基于 LSTM 模型的海面水质预测[J]. 计算机与数字工程, 2020, 48(2): 437-441.
LI Yanjie, HE Pengfei, FENG Weiwei, et al. Marine water quality prediction based on LSTM model[J]. Computer and Digital Engineering, 2020, 48(2): 437-441.
- [9] 武双新. 基于 LSTM 的气温数据建模研究[J]. 数据通信, 2021(2): 47-51.
WU Shuangxin. Research on temperature data modeling based on LSTM[J]. Data Communication, 2021(2): 47-51.
- [10] QIU R J, WANG Y K, RHOADS B, et al. River water temperature forecasting using a deep learning method[J]. Journal of Hydrology, 2021, 595: 126016.
- [11] CHOI H M, KIM M K, YANG H. Abnormally high water temperature prediction using LSTM deep learning model[J]. Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology, 2021, 40(4): 8013-8020.
- [12] LIU Y, WANG H, FENG W W, HUANG H C, et al. Short term real-time rolling forecast of urban river water levels based on LSTM: a case study in Fuzhou city, China[J]. International Journal of Environmental Research and Public Health, 2021, 18(17): 9287.
- [13] YAN Y, XING H Y. A sea clutter detection method based on LSTM error frequency domain conversion[J]. Alexandria Engineering Journal, 2022, 61(1): 883-891.
- [14] JRGES C, BERKENBEINK C, STUMPE B. Prediction and reconstruction of ocean wave heights based on bathymetric data using LSTM neural networks[J]. Ocean Engineering, 2021, 232: 109046.
- [15] 王国松, 王喜冬, 侯敏, 等. 基于观测和再分析数据的 LSTM 深度神经网络沿海风速预报应用研究[J]. 海洋学报, 2020, 42(1): 67-77.
WANG Guosong, WANG Xidong, HOU Min, et al.

- Study on the application of LSTM depth neural network to coastal wind speed prediction based on observation and reanalysis data[J]. Haiyang Xuebao, 2020, 42(1): 67-77.
- [16] 魏昱洲, 许西宁. 基于 LSTM 长短期记忆网络的超短期风速预测[J]. 电子测量与仪器学报, 2019, 33(2): 64-71.
WEI Yuzhou, XU Xining. Ultra short term wind speed prediction based on LSTM long-term and short-term memory network[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 64-71.
- [17] 李冰, 张妍, 刘石. 基于 LSTM 的短期风速预测研究[J]. 计算机仿真, 2018, 35(11): 456-461.
LI Bing, ZHANG Yan, LIU Shi. Research on short-term wind speed prediction based on LSTM[J]. Computer Simulation, 2018, 35(11): 456-461.
- [18] 王俊, 李霞, 周昔东, 等. 基于 VMD 和 LSTM 的超短期风速预测[J]. 电力系统保护与控制, 2020, 48(11): 45-52.
WANG Jun, LI Xia, ZHOU Xidong, et al. Ultra short term wind speed prediction based on VMD and LSTM[J]. Power System Protection and Control, 2020, 48(11): 45-52.
- [19] 张博一, 胡雄, 唐刚, 等. 基于二元 LSTM 神经网络的船舶运动预测算法研究[J]. 海洋科学, 2021, 45(9): 69-74.
ZHANG Boyi, HU Xiong, TANG Gang, et al. Research on ship motion prediction algorithm based on binary LSTM neural network[J]. Marine Sciences, 2021, 45(9): 69-74.
- [20] WANG Q L, GUO Y F, YU L X, et al. Earthquake prediction based on spatio-temporal data mining: an LSTM network approach[J]. IEEE Transactions on Emerging Topics in Computing, 2017, 8(1): 148-158.

Short-term wind-speed prediction of ocean surface based on LSTM

LI Ya-meng¹, SUN Bao-nan^{2, 3, 4, 5}, DING Jun-hang^{1, 6, 7}, GUAN Sheng^{2, 3, 4, 5}

(1. School of Automation, Qingdao University, Qingdao 266071, China; 2. First Institute of Oceanography, Ministry of Natural Resources, Qingdao 266061, China; 3. Key Laboratory of Marine Science and Numerical Modeling, Ministry of Natural Resources, Qingdao 266061, China; 4. Shandong Key Laboratory of Marine Science and Numerical Modeling, Qingdao 266061, China; 5. Laboratory for Regional Oceanography and Numerical Modeling, Pilot National Laboratory for Marine Science and Technology (Qingdao), Qingdao 266237, China; 6. Shandong Key Laboratory of Industrial Control Technology, Qingdao 266071, China; 7. Collaborative Innovation Center for Eco-Textiles of Shandong Province, Qingdao University, Qingdao 266071, China)

Received: Nov. 16, 2021

Key words: neural network; LSTM network model; sea surface wind speed; short-term prediction

Abstract: Sea surface wind speed plays a critical role in production and operation activities such as marine space launches and wind power deployment. However, because sea surface wind speed is highly nonlinear and stochastic, it is relatively challenging to estimate precisely. A short-term wind-speed prediction model based on long short-term memory (LSTM) neural network is suggested to accomplish reliable short-term prediction of sea surface wind speed. The historical wind speed data gathered by a single buoy station in the OceanSITES database is chosen as the model input, and the LSTM techniques are implemented by training the best parameters. Using this LSTM method, a 24-hour short-term forecast of the sea surface wind speed where the station is located in each seasonal representative month is realized. Simultaneously, through experiments involving various prediction durations and comparison experiments of prediction effects with back propagation neural network and radial basis function neural network, it is demonstrated that the LSTM prediction approach is superior to the above two neural network prediction methods in the application of sea surface wind-speed prediction. Finally, the LSTM neural network model is demonstrated to be globally applicable to wind speed prediction experiment data at stations representing diverse marine areas. The analysis of correlation coefficient and prediction error reveals that this method has the prediction stability to deal with quickly changing data and can be employed as a reliable method for short-term prediction of ocean surface wind speed.

(本文编辑: 丛培秀)