

基于传统和深度学习技术的黄渤海域大风预报方法研究

刘志杰¹, 刘彬贤², 王锐², 史得道²

(1. 天津市西青区气象局, 天津 300380; 2. 天津海洋中心气象台, 天津 300074)

摘 要: 基于黄渤海域站点风速观测资料以及 TIGGE 资料, 选取欧洲数值预报中心(EC)、中国(CMA)、美国(NCEP)、加拿大(ECCC)4家集合预报产品, 在综合评估各家性能的基础上, 构建、优化和对比了海上大风集成平均(EM)、动态权重(WEM)、变权偏差订正(BCWEM)3类传统集成方法和长短期记忆神经网络(LSTM)方法。结果表明:LSTM在大风集成预报中性能最优。对于黄渤海域 10 m 风速预报, EC 综合表现最好, NCEP 在 6 级及以上大风段优势明显。各家预报误差均具有显著日变化特征, 夜间预报能力弱于白天。优化训练期长度和去除表现较差成员可显著改善 WEM 和 BCWEM 的大风预报能力。相对 EM 的预报结果, WEM 无明显改进, BCWEM 和 LSTM 则有显著提升, 后两者在全风速段和大风风速段上的预报误差均下降 10% 以上, 且在夜间时段更为明显。BCWEM 有效订正了 EM 和 WEM 方法对弱风速的预报偏差, LSTM 则进一步减小了对强风速的预报误差, 并提高了对大风站次的命中数和 ETS 评分。大风个例分析也表明, LSTM 有效弥补了传统方法对低涡东移型大风漏报的问题, 提升了对冷高压型大风的预报能力, 优势明显。

关键词: 海上大风; 集成预报; 动态权重; 偏差订正; 长短期记忆神经网络

中图分类号: P732.4 **文献标识码:** A **文章编号:** 1003-0239(2022)06-0034-10

1 引言

海上大风是黄渤海域常见的灾害性天气, 出现时常引起海浪, 并可能引发风暴潮, 会对渔业生产、海上交通、船舶进出港以及海上石油平台作业等造成严重影响^[1]。在海上大风等灾害性天气预报方面, 以往单一的数值模式产品具有较大的局限性, 为此 LEITH^[2]将 LORENZ^[3]集合预报思想和非线性理论与 EPSTEIN^[4]的动力随机预报理论相结合, 提出了可用于实际集合预报的蒙特卡洛方法, 有效提升了灾害性天气的数值预报能力。

目前多个国家均已建立基于初值扰动和物理过程扰动的集合预报模式^[5]。在此基础上, 利用多家集合预报产品构建多初值、多物理过程和多模式框架的集成预报技术也逐步发展起来。KRISH-

NAMURTI 等^[6]最早提出多模式超级集合预报方法, 即基于最小二乘法在固定训练期内确立最优权重系数, 该方法改进了预报并取得了较好的效果。此后, 各类多模式集成方法被广泛研究, 推动了集成预报技术的发展。

近年来, 针对地面气温^[7-8]、降水^[9-10]以及台风^[11]和海雾^[12]等灾害性天气的集成预报研究不断丰富, 预报方法也得到持续改进。起初, 研究方法多采用线性的加权和偏差订正法, 权重系数由固定转为动态变化^[13], 预报效果获得了一定的提升; 之后, 卡尔曼滤波法^[8, 14]、基于对象的诊断评估法^[15]、贝叶斯概率法^[16]和经典机器学习方法^[17]等均被用于集成预报, 并显示出一定的优势。

随着深度学习技术的发展^[18], 在常规神经网络(Neural Network, NN)的基础上, 卷积神经网络

收稿日期: 2021-11-14; 修回日期: 2022-04-07。

基金项目: 国家重点研发计划(2019YFC1510105); 天津市自然科学基金(19JCYBJC23700); 中国气象局创新发展专项(CXFZ2022J025)。

作者简介: 刘志杰(1990-), 男, 工程师, 硕士, 主要从事客观预报订正方法研究。E-mail: zhijieliu@yeah.net

通信作者: 刘彬贤(1974-), 男, 正研级高工, 学士, 主要从事海上灾害性天气预报研究。E-mail: binxian_l@163.com

(Convolutional Neural Network, CNN)和递归神经网络(Recurrent Neural Network, RNN)方法相继被提出,有效提升了算法性能。深度学习方法开始在气象和海洋领域特别是模式后处理方面得到广泛应用^[19-22],其中长短期记忆(Long Short-Term Memory, LSTM)神经网络算法在气温等要素集成预报和灾害性天气短临预报中体现出较好的性能^[23-24]。受限于海上观测资料的匮乏以及再分析产品在海上存在的显著偏差^[25],深度学习算法在海上大风等要素的预报应用相对较少^[26],特别是缺乏深度学习和集成预报结合方面的研究。

得益于近年来天津市气象局环渤海观测站网的构建^[27],黄渤海域海上大风等灾害性天气得到有效监测,为集成预报研究奠定了基础。本文以黄渤海域海上浮标站、海上平台站以及沿岸地面国家站观测资料为基础,结合多家集合预报产品,在深入分析各家产品差异特征的基础上,构建和优化了成员平均、动态权重、变权订正和深度学习4类集成预报方法,并进行了对比分析。

2 资料

2.1 站点观测资料

为获得更为精准的预报模型,本文以站点观测资料为基础构建集成方法^[28-29]。通过查阅黄渤海域内现有站点分布,综合考虑站点位置和观测资料质量等因素,选取了52个代表性站点(见图1)。这些站点包括黄渤海沿岸36个地面国家站、渤海海域内10个海上平台站以及黄渤海域6个近海浮标站。使用前对各站点风速数据进行了质量控制和高度订正^[27]。

2.2 集合预报产品

本文采用欧洲数值预报中心(European Centre for Medium-range Weather Forecast, ECMWF)全球交互式大集合系统(THORPEX(The Observing System Research and Predictability Experiment) Interactive Grand Global Ensemble, TIGGE)中的10 m风场产品^[5],选取了包括ECMWF(以下简称EC)51个成员、中国气象局(China Meteorological Administration, CMA)15个成员、美国国家环境预报中心(Na-




图1 观测站点分布(●地面国家站,△浮标站,+海上平台站,数字为对应站号)

Fig.1 Distribution of observation stations (● national ground stations, △ buoy stations, + offshore platform stations, the numbers correspond to the station IDs)

tional Centers for Environmental Prediction, NCEP) 21个成员和加拿大环境与气候变化部(Environment and Climate Change Canada, ECCC)21个成员共108个成员的集合产品,其中各机构均包含一个控制预报结果,其余为扰动预报成员。考虑到资料的完整度,本文选取黄渤海域(35°~42°N, 117°~125°E)2018年1月—2019年12月的数据。预报产品起报时刻为每日20时(北京时,下同),预报时长为168 h,空间分辨率为0.5°×0.5°,时间步长为6 h。采用双线性方法将上述4个机构集成员的格点数据统一插值到站点位置上,缺失或质控不合格的观测及预报数据统一按缺测处理。

3 方法

3.1 传统集成方法

对任意站点,令 t 时刻第 i 个成员的预报结果为 $F_{i,t}$,则全部 n 个成员集合平均(Ensemble Mean, EM)的预报结果 S_{EM} 为:

$$S_{EM} = \frac{1}{n} \sum_{i=1}^n F_{i,t} \quad (1)$$

此时,若观测值为 Q_t ,则各成员对应的预报绝对偏差 $R_{i,t}$ 为:

$$R_{i,t} = |F_{i,t} - Q_t| \quad (2)$$

定义过度因子 $V_{i,t}$ 和动态权重因子 $a_{i,t}$, 有:

$$V_{i,t} = 1 - R_{i,t} / \sum_{i=1}^n R_{i,t} \quad (3)$$

$$a_{i,t} = V_{i,t} / \sum_{i=1}^n V_{i,t} \quad (4)$$

式中:权重系数 $a_{i,t}$ 根据各成员的预报绝对偏差计算得到,偏差越小,权重系数越大。动态权重 (Weighted Ensemble Mean, WEM) 的集合预报结果 S_{WEM} 可表示为:

$$S_{\text{WEM}} = \sum_{i=1}^n a_{i,t} F_{i,t} \quad (5)$$

对时刻 t , 确定动态训练周期 m 和权重系数 $a_{i,t}$, 则该时刻前期相对预报偏差 $B_{m,t}$ 有:

$$B_{m,t} = \frac{1}{m} \sum_{j=1}^m \left(\sum_{i=1}^n a_{i,t-j} F_{i,t-j} - Q_{t-j} \right) \quad (6)$$

考虑成员动态权重分配和整体预报偏差, 则变权订正 (Bias Correction Weighted Ensemble Mean, BCWEM) 算法结果 S_{BCWEM} 可表示为:

$$S_{\text{BCWEM}} = \sum_{i=1}^n a_{i,t} F_{i,t} - B_{m,t} \quad (7)$$

文中 EM 方法采用 4 个机构 108 个集合成员的数据, WEM 和 BCWEM 方法则使用 4 个机构的集合平均值。

3.2 长短期记忆神经网络算法

LSTM 神经网络算法^[30]是一种改进的 RNN 算法, 由于其添加输入、输出和遗忘 3 个门控制单元, 并加入细胞状态这一长期状态参数, 有效遏制了 RNN 算法在长序列训练中梯度爆炸或消失等问题, 使得预报性能有所提升。不考虑偏置项, LSTM 神经网络算法公式如下^[23-24]:

首先引入 3 个门控制单元, 有:

$$\begin{cases} z^i = \sigma(w^i[h_{t-1}, x_t]) \\ z^o = \sigma(w^o[h_{t-1}, x_t]) \\ z^f = \sigma(w^f[h_{t-1}, x_t]) \end{cases} \quad (8)$$

式中: w^i 、 w^o 、 w^f 分别为输入门 z^i 、输出门 z^o 、遗忘门 z^f 的对应权重; x_t 和 h_{t-1} 分别为输入项和上一时刻隐藏层结果; 激活函数 σ 将计算结果转换为 0~1 之间

的数值作为门控状态。基于上述 3 个门控状态有:

$$\begin{cases} z = \sigma(w^h[h_{t-1}, x_t]) \\ c_t = z^f \odot c_{t-1} \oplus z^i \odot z \\ h_t = z \odot \tanh(ct) \\ y_t = \sigma(w^y[h_t]) \end{cases} \quad (9)$$

式中: z 为过渡状态; c_t 和 h_t 为隐藏层状态, 分别对应长期变化和短期变化, c_t 变化相对缓慢; y_t 为输出层结果; w^h 和 w 分别为过渡状态和输出层权重; \tanh 为激活函数, 可以将数值转换为 0~1 之间; \odot 和 \oplus 为矩阵对应元素相乘和相加。

基于以上集成方法构建黄渤海风速预报模型, 将 4 个机构的预报结果作为输入量, 同时刻站点实况作为输出量, 将 2018 年 1—12 月数据作为训练集, 2019 年 1—6 月作为验证集, 7—12 月作为测试集。对以上 3 类方法在测试时段 (2019 年 7—12 月) 的性能, 除采用均方根误差 (Root Mean Square Error, RMSE) 作为判断依据外, 也采用了公平技巧评分 (Equitable Threat Score, ETS) 以及命中数 N_A 、空报数 N_B 和漏报数 N_C 来检验各类方法对大风站次 (6 级及以上) 的预报效果^[31]。

4 结果分析

4.1 4 家产品性能评估

选取 2018 年 1 月—2019 年 12 月 EC、NCEP、CMA 和 ECCO 在黄渤海 10 m 风速预报的集合平均产品, 以及与站点实测资料的 RMSE (见图 2)。在全风速段 (整个风速段) 内, EC 产品体现出显著优势, 其 RMSE 平均可达 2.06 m/s, 平均相关系数为 57%; NCEP 产品的 RMSE 最大, 达到 2.43 m/s, 但相关系数较好, 为 52%, 仅次于 EC; CMA 产品的 RMSE 低于 ECCO, 但相关性偏差, 两者产品的性能相近 (见图 2a 和 2b)。在大风风速段, NCEP 的预报误差优于 EC, 达到 5.38 m/s, 但相关性偏低 (见图 2c 和 2d)。

综合上述分析可知, EC 预报的综合性能最优, 其对风速的预报优势主要体现在弱风速区间, 而 NCEP 在大风预报中的性能更好。此外, 各机构产品的预报误差随预报时长的增加表现出一定的日变化特征。在全风速段 (见图 2a), 各成员误差均在 02 时最大, 14 时最小; 在大风风速段 (见图 2c), 各成

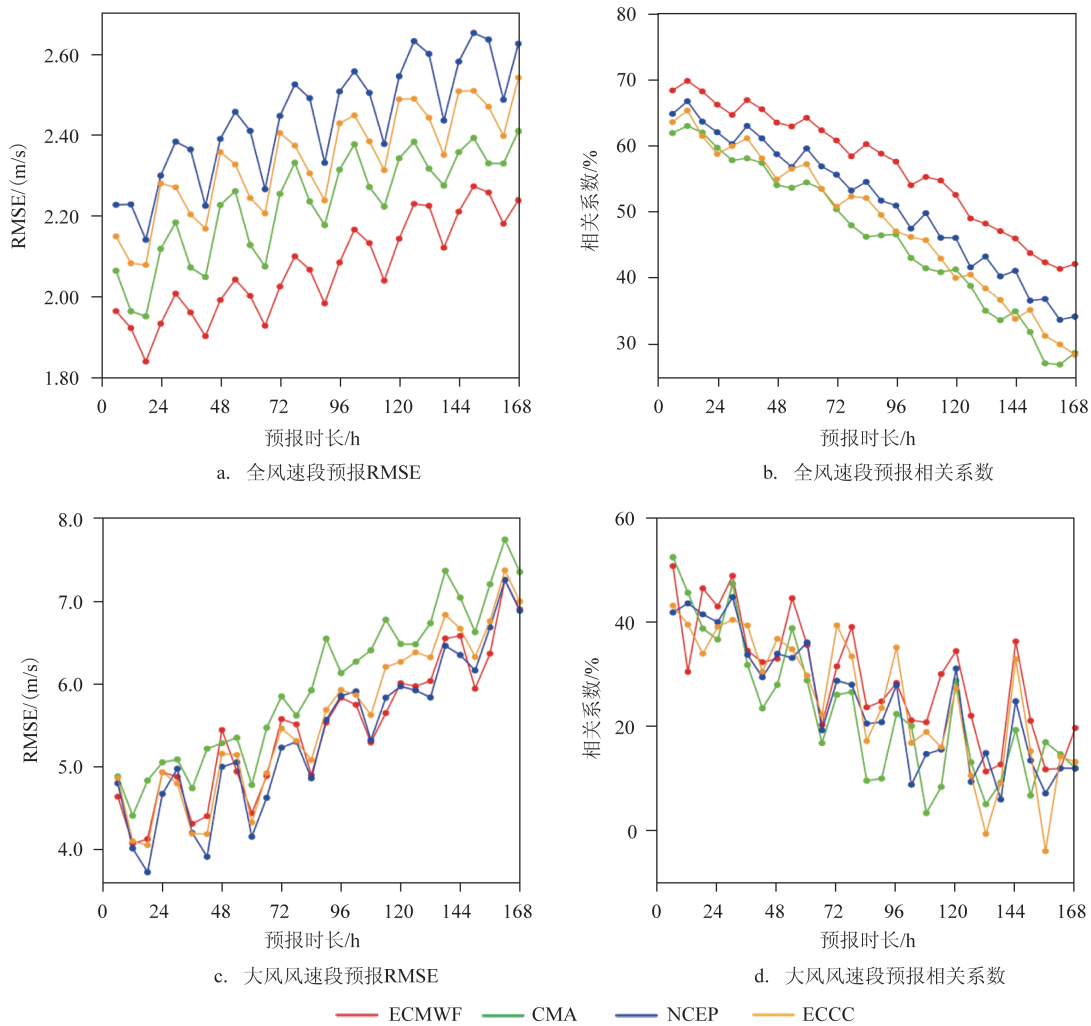


图2 4家中心集合平均在黄渤海域风速预报性能

Fig.2 Wind speed prediction performance of the ensemble average of four centers in the Yellow Sea and Bohai Sea

员误差均在20时一次日02时最大,08时最小,表明各机构风速预报产品的夜间预报能力弱于白天。

4.2 算法优化

鉴于各机构集合产品间存在显著差异,本文在构建4类算法时,逐站、逐预报时长来计算模型参数,还充分考虑了成员组合方式和训练期长度对模型性能的影响。鉴于EC和NCEP产品的预报优势,本文分别构建了EC+NCEP以及全部4个机构成员这两种组合形式,以及10 d、20 d和30 d动态训练期长度,以探究两者与WEM和BCWEM算法性能的关系。

结果表明,成员组合方式和训练期长度均对

WEM和BCWEM的预报效果有显著影响。随着训练期长度的增加,不同组合的两类算法均呈现出大风风速段预报误差升高而全风速段预报误差降低的特征,其中大风风速段预报误差对训练期长度更加敏感(见图3)。同一训练期长度下,BCWEM的预报结果显著优于WEM。EC+NCEP组合相对全部成员组合在大风风速段的预报更好,但由于NCEP在全风速段预报上的劣势,两者组合在全风速段的预报误差略高于全体成员组合。选择适宜的训练期长度以及剔除性能较差的成员,均可显著提升WEM和BCWEM方法的大风预测能力,因此优化后的3类传统集成方法均选择EC+NCEP的最优组合方式,WEM和BCWEM采用10 d训练期长度。




图3 不同组合和训练期长度在WEM及BCWEM中的7 d平均预报误差

Fig.3 The 7-day average forecast errors of different combinations and training period lengths in WEM and BCWEM

对于LSTM算法,由于训练样本偏少,为避免过拟合现象,需适当减少模型层数、每层神经元个数以及训练次数等并加入随机丢弃机制。经多次调整优化,模型最终确定为双层LSTM结构,各层均设定为100个神经网络节点,每两层之间加入比例为0.2的随机丢弃层(见图4)。LSTM层均采用修正线性单元(Rectified Linear Units, ReLU)激活函数以提升模型的非线性拟合能力,共训练100次,优化器选用均方根传递(Root Mean Square Prop, RMSProp),学习率为0.001,损失函数为均方误差(Mean Square Error, MSE)。运行前,我们对训练数据集进行了均

值-方差归一化处理,并对各风速段样本比例予以优化,同时根据实况分布限定模型预报风速的上下限为0~20.8 m/s(9级风)。

4.3 方法对比

4.3.1 整体性能比较

基于测试数据集,我们对比了优化后的4类算法的预报能力。从整体上看,WEM和EM的预报能力无明显差异,而BCWEM和LSTM的改进效果明显,两者在全风速段的预报误差相对EM分别下降了13%和15%,在大风风速段分别下降了11%和21%(见表1)。与BCWEM方法相比,LSTM的性能更优,其在全风速段和大风风速段的预报误差分别减小到1.61 m/s和4.07 m/s。在大风风速段,采用LSTM方法后大风站次的命中数进一步增加,尽管空报数量也明显增多,但ETS评分仍提升到0.3以

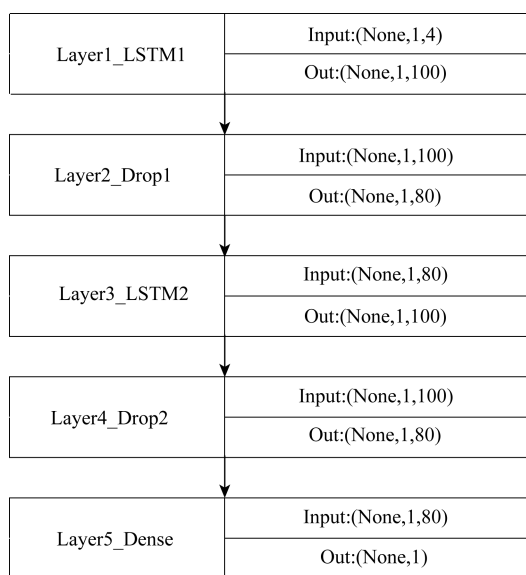


图4 LSTM预报模型结构

Fig.4 Structure of LSTM prediction model

表1 不同方法在全风速段和大风风速段预报性能

Tab.1 Prediction performance of different methods in full wind speed and gale wind speed

方案	全风速段	大风风速	ETS	N_A	N_B	N_C
	RMSE/ (m/s)	段RMSE/ (m/s)				
EM	1.90	5.17	0.11	78	42	580
WEM	1.92	5.12	0.12	87	47	571
BCWEM	1.65	4.59	0.19	132	24	526
LSTM	1.61	4.07	0.31	243	136	415

上,改进效果明显。

从预报时长来看,WEM相对EM在大风风速段的预报上有微弱优势,而在全风速段的预报误差略偏大,在20时和02时的全风速段预报上,BCWEM和LSTM相对EM和WEM的改进效果最为明显(见图5)。在大部分预报时长内,LSTM的预报误差均低于BCWEM;在全风速段内,LSTM的预报优势随

着时间的增加而逐步减小,6~7 d的预报误差甚至略大于BCWEM,而大风风速段中LSTM在整个预报时长内均具有明显优势。

选取72 h和168 h预报时长作为短期和中期预报代表,对比4类算法的站点风速预报能力(见图6)。在中短期预报上,EM和WEM预测的站点风速均存在弱风速段偏高、强风速段偏低的特征,拟合

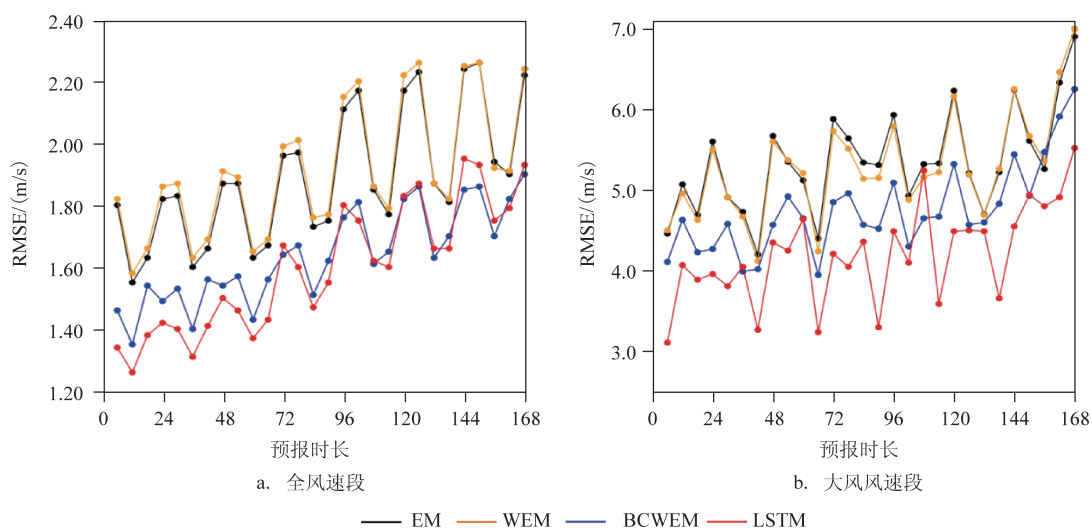


图5 不同方法风速预报误差随预报时长变化

Fig.5 Variation of wind speed prediction error of different methods with prediction duration

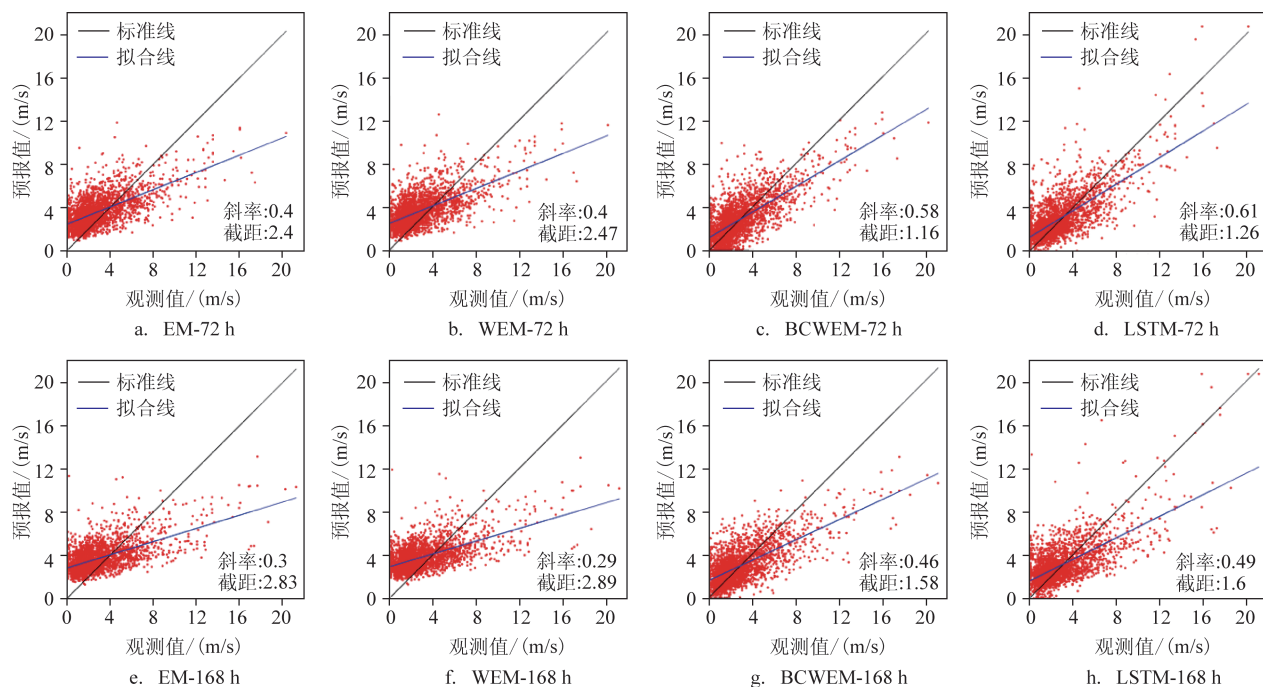


图6 不同预报方法在短期72 h和中期168 h的站点风速观测值和预报值

Fig.6 Wind speed observation and prediction of stations in different prediction methods at short-term 72 hour and medium-term 168 hour

能力较差;BCWEM采用偏差订正的方式,较好地纠正了EM和WEM中存在的弱风速预报偏高的问题,拟合系数有所提升;LSTM则进一步提高了强风速下的预报准确率,改善了整体预报效果,拟合系数达到最优。这也与LSTM提升大风站次命中数的结论相一致。

4.3.2 大风个例分析

选取黄渤海域2019年7月5日和12月17日两次不同类型的大风天气,对比分析了各类集成方法的预报性能。7月5日前后,华北地区有低涡东移,黄渤海位于低涡前部,等压线密集,部分站点出现6级及以上偏南大风;12月17日前后,冷高压南下,冷空气入侵黄渤海地区,部分站点出现6级及以上偏北大风。各类方法提前72 h的预报结果表明,LSTM对不同类型大风天气的预报均体现出显著优势,其在大风风速段预报的RMSE和ETS评分均优于其他方法;其次为BCWEM,在风速预报中相对EM和WEM有一定改进(见表2)。

具体来看,低涡系统东移带来了偏南大风,渤海区域共有5站出现6级及以上大风。受限于各家模式的预报值偏低,EM和WEM均未能预报出大风;经过订正,BCWEM整体的预报误差明显减小,并预报出1个站点大风;LSTM则更进一步减小大风站点的预报误差,提高了大风站次命中数(命中2个站次大风)。冷高压系统下的偏北大风造成黄渤海域7站出现大风,LSTM在大风风速段的预报性能最佳,大风站次命中数为6个,优于BCWEM预报的4个。但相对BCWEM,LSTM在部分非大风站点的预报偏差较大,尤其是对金县一号(54560)海上平台站及东港站(54590)的预报偏大,导致出现大风空报现象,这也是LSTM在全风速段的预报误差高于BCWEM的主要原因(见表2)。

5 结论

本文基于黄渤海域的站点观测资料,在对比分析4家中心风速集合预报产品的基础上,构建、优化并对比分析了集成平均(EM)、动态权重(WEM)、变权订正(BCWEM)和长短期记忆神经网络(LSTM)4类集成预报方法。结论如下:

(1)在传统集成方法中,WEM和BCWEM性能对成员组合和滑动训练期长度较为敏感,剔除性能较差的成员并选择较短训练期长度均可提升两种方法的大风预报效果。基于EC+NCEP最优组合的WEM相比EM无明显改进。考虑误差日变化的BCWEM在20时和02时的预报改进效果明显,显著提高了6级及以上大风的预报能力,在减小空报数的同时增加了命中数量,从而提升了ETS评分。

(2)相对BCWEM,LSTM表现出更好的预报性能,在保持全风速段较低的预报误差的基础上,显著提升了大风风速段的预报能力,提高了命中数和ETS评分。在中短期站点的风速预报中,BCWEM主要解决了EM和WEM对弱风速预报偏高的问题,而LSTM在此基础上进一步减小了强风速段的预报偏差,改善了拟合效果。

(3)在黄渤海域的大风个例分析中,LSTM有效弥补了BCWEM等传统方法对低涡东移型偏南大风漏报的问题;对冷高压型大风,LSTM则在BCWEM的基础上进一步提高了对大风站点的预报能力,改进了ETS评分。

本研究仅采用LSTM一种深度学习技术开展研究。鉴于深度学习方法在海上大风集成预报中表现出的优势,今后工作中将尝试更多最新的深度学习算法,利用不断丰富的相关数据集,提升海上大风的预报能力。此外,随着多源观测资料的丰富和

表2 不同方法在两类大风个例中的预报偏差和评分情况

Tab.2 Forecast errors and scores of different methods in two types of gale cases

集成预报方法	偏南大风				偏北大风			
	EM	WEM	BCWEM	LSTM	EM	WEM	BCWEM	LSTM
全风速段 RMSE	3.08	3.12	2.81	2.60	3.00	3.09	2.32	2.70
大风风速段 RMSE	5.23	5.16	4.68	3.78	4.15	4.09	3.20	3.08
大风命中站次	0	0	1	2	1	1	4	6
ETS	0	0	0.21	0.42	0.15	0.15	0.63	0.77

融合算法的提升,生成了更多更高精度的格点分析产品,将之与适配的深度学习算法结合得到格点订正产品,可更好地应用于业务和服务。

参考文献:

- [1] 傅赐福,李涛,刘仕潮,等. 1909号台风“利奇马”引发渤海湾风暴潮特征及无人机灾害调查[J]. 海洋预报, 2021, 38(5): 17-23.
FU C F, LI T, LIU S C, et al. Characteristics of the storm surge and UAV disaster investigation caused by the typhoon Lekima (No. 1909) in the Bohai Bay[J]. Marine Forecasts, 2021, 38(5): 17-23.
- [2] LEITH C E. Theoretical skill of Monte Carlo forecasts[J]. Monthly Weather Review, 1974, 102(6): 409-418.
- [3] LORENZ E N. Atmospheric predictability as revealed by naturally occurring analogues[J]. Journal of the Atmospheric Sciences, 1969, 26(4): 636-646.
- [4] EPSTEIN E S. A scoring system for probability forecasts of ranked categories[J]. Journal of Applied Meteorology, 1969, 8(6): 985-987.
- [5] PARK Y Y, BUIZZA R, LEUTBECHER M. TIGGE: preliminary results on comparing and combining ensembles[J]. Quarterly Journal of the Royal Meteorological Society, 2008, 134(637): 2029-2050.
- [6] KRISHNAMURTI T N, KISHTAWAL C M, LAROW T E, et al. Improved weather and seasonal climate forecasts from multimodel superensemble[J]. Science, 1999, 285(5433): 1548-1550.
- [7] 智协飞,黄闻. 基于卡尔曼滤波的中国区域气温和降水的多模式集成预报[J]. 大气科学学报, 2019, 42(2): 197-206.
ZHI X F, HUANG W. Multimodel ensemble forecasts of surface air temperature and precipitation over China by using Kalman filter [J]. Transactions of Atmospheric Sciences, 2019, 42(2): 197-206.
- [8] ZHU S P, ZHI X F, GE F, et al. Subseasonal forecast of surface air temperature using superensemble approaches: experiments over Northeast Asia for 2018[J]. Weather and Forecasting, 2021, 36(1): 39-51.
- [9] 危国飞,刘会军,吴启树,等. 多模式降水分级最优权重集成预报技术[J]. 应用气象学报, 2020, 31(6): 668-680.
WEI G F, LIU H J, WU Q S, et al. Multi-model consensus forecasting technology with optimal weight for precipitation intensity levels[J]. Journal of Applied Meteorological Science, 2020, 31(6): 668-680.
- [10] 智协飞,赵忱. 基于集合成员订正的强降水多模式集成预报[J]. 应用气象学报, 2020, 31(3): 303-314.
ZHI X F, ZHAO C. Heavy precipitation forecasts based on multi-model ensemble members[J]. Journal of Applied Meteorological Science, 2020, 31(3): 303-314.
- [11] 郭蓉,余晖,漆梁波,等. 台风路径多模式集成预报技术研究[J]. 气象科学, 2019, 39(6): 839-846.
GUO R, YU H, QI L B, et al. A study on multi-model ensemble forecast technique for Typhoon track[J]. Journal of the Meteorological Sciences, 2019, 39(6): 839-846.
- [12] 高松,徐江玲,刘桂艳,等. 基于机器学习的青岛市区近岸海雾集成预报方法[J]. 海洋科学, 2021, 45(3): 33-42.
GAO S, XU J L, LIU G Y, et al. Ensemble forecast of sea fog in Qingdao coastal area based on machine learning[J]. Marine Sciences, 2021, 45(3): 33-42.
- [13] 智协飞,林春泽,白永清,等. 北半球中纬度地区地面气温的超级集合预报[J]. 气象科学, 2009, 29(5): 569-574.
ZHI X F, LIN C Z, BAI Y Q, et al. Superensemble forecasts of the surface temperature in Northern Hemisphere middle latitudes [J]. Scientia Meteorologica Sinica, 2009, 29(5): 569-574.
- [14] 张玉涛,佟华,孙健. 一种偏差订正方法在平昌冬奥会气象预报的应用[J]. 应用气象学报, 2020, 31(1): 27-41.
ZHANG Y T, TONG H, SUN J. Application of a bias correction method to meteorological forecast for the Pyeongchang Winter Olympic Games[J]. Journal of Applied Meteorological Science, 2020, 31(1): 27-41.
- [15] JI L Y, ZHI X F, SIMMER C, et al. Multimodel ensemble forecasts of Precipitation based on an object-based diagnostic evaluation[J]. Monthly Weather Review, 2020, 148(6): 2591-2606.
- [16] 祁海霞,彭涛,林春泽,等. 清江流域降水的多模式BMA概率预报试验[J]. 气象, 2020, 46(1): 108-118.
QI H X, PENG T, LIN C Z, et al. Probabilistic forecasting of precipitation over the Qingjiang River basin using BMA multimodel ensemble technique[J]. Meteorological Monthly, 2020, 46(1): 108-118.
- [17] 门晓磊,焦瑞莉,王鼎,等. 基于机器学习的华北气温多模式集合预报的订正方法[J]. 气候与环境研究, 2019, 24(1): 116-124.
MEN X L, JIAO R L, WANG D, et al. A temperature correction method for multi-model ensemble forecast in North China based on machine learning[J]. Climatic and Environmental Research, 2019, 24(1): 116-124.
- [18] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [19] CHENG L L, ZANG H X, DING T, et al. Ensemble recurrent neural network based probabilistic wind speed forecasting approach[J]. Energies, 2018, 11(8): 1958.
- [20] LI H C, YU C, XIA J J, et al. A model output machine learning method for grid temperature forecasts in the Beijing area[J]. Advances in Atmospheric Sciences, 2019, 36(10): 1156-1170.
- [21] 刘岳明,杨晓梅,王志华,等. 基于深度学习RCF模型的三都澳筏式养殖区提取研究[J]. 海洋学报, 2019, 41(4): 119-130.
LIU Y M, YANG X M, WANG Z H, et al. Extracting raft aquaculture areas in Sanduao from high-resolution remote sensing images using RCF[J]. Haiyang Xuebao, 2019, 41(4): 119-130.
- [22] 孙健,曹卓,李恒,等. 人工智能技术在数值天气预报中的应用

- [J]. 应用气象学报, 2021, 32(1): 1-11.
- SUN J, CAO Z, LI H, et al. Application of artificial intelligence technology to numerical weather prediction[J]. Journal of Applied Meteorological Science, 2021, 32(1): 1-11.
- [23] 智协飞, 王田, 季焱. 基于深度学习的中国地面气温的多模式集成预报研究[J]. 大气科学学报, 2020, 43(3): 435-446.
- ZHI X F, WANG T, JI Y. Multimodel ensemble forecasts of surface air temperature over China based on deep learning approach[J]. Transactions of Atmospheric Sciences, 2020, 43(3): 435-446.
- [24] 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 G S, WANG X D, HOU M, et al. Research on application of LSTM deep neural network on historical observation data and reanalysis data for sea surface wind speed forecasting[J]. Haiyang Xuebao, 2020, 42(1): 67-77.
- [25] 范书鸣, 储鹰, 蒋勤. 再分析风场修正及其在渤海湾典型温带风暴潮模拟中的应用[J]. 海洋预报, 2021, 38(4): 61-68.
- FAN S M, CHU A, JIANG Q. Optimization of reanalysis wind field and its application in the simulation of extratropical storm surge in the Bohai Bay[J]. Marine Forecasts, 2021, 38(4): 61-68.
- [26] 许立兵, 王安喜, 汪纯阳, 等. 基于机器学习的海洋环境预报订正方法研究[J]. 海洋通报, 2020, 39(6): 695-704.
- XU L B, WANG A X, WANG C Y, et al. Research on correction method of marine environment prediction based on machine learning[J]. Marine Science Bulletin, 2020, 39(6): 695-704.
- [27] 司鹏, 梁冬坡, 朱男男, 等. 黄渤海海域16个石油平台站风速资料的初步质量检测[J]. 海洋预报, 2020, 37(1): 43-49.
- SI P, LIANG D P, ZHU N N, et al. Preliminary quality verification of wind speed data observed by 16 oil platform monitoring stations in the Yellow Sea and Bohai Sea[J]. Marine Forecasts, 2020, 37(1): 43-49.
- [28] 严明良, 缪启龙, 沈树勤. 基于超级集合思想的数值预报产品变权集成方法探讨[J]. 气象, 2009, 35(6): 19-25, 129-130.
- YAN M L, MIAO Q L, SHEN S Q. Exploration on ensemble model of numerical forecasting based on variable-weight super-ensemble method[J]. Meteorological Monthly, 2009, 35(6): 19-25, 129-130.
- [29] 智协飞, 李刚, 彭婷. 基于贝叶斯理论的单站地面气温的概率预报研究[J]. 大气科学学报, 2014, 37(6): 740-748.
- ZHI X F, LI G, PENG T. On the probabilistic forecast of 2 meter temperature of a single station based on Bayesian theory[J]. Transactions of Atmospheric Sciences, 2014, 37(6): 740-748.
- [30] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [31] 陈圣劫, 刘梅, 张涵斌, 等. 集合预报产品在江苏省暴雨预报中的应用评估[J]. 气象, 2019, 45(7): 893-907.
- CHEN S J, LIU M, ZHANG H B, et al. Evaluation on forecasting heavy rainfall over Jiangsu region using ensemble forecast techniques and products[J]. Meteorological Monthly, 2019, 45(7): 893-907.

Research on the gale prediction methods in the Yellow Sea and Bohai Sea based on traditional and deep learning technologies

LIU Zhijie¹, LIU Binxian², WANG Rui², SHI Dedao²

(1. Xiqing Meteorological Bureau, Tianjin 300380, China; 2. Tianjin Marine Meteorological Center, Tianjin 300074, China)

Abstract: Based on the wind speed observation data of stations in the Yellow Sea and Bohai Sea and the ensemble forecast products of the European Centre for Medium-Range Weather Forecasts (EC), China (CMA), the United States (NCEP) and Canada (ECCC) in the THORPEX Interactive Grand Global Ensemble (TIGGE) data, three traditional integration methods, including ensemble mean (EM), dynamic weight ensemble mean (WEM), bias correction weighted ensemble mean (BCWEM), and the long short-term memory neural network (LSTM) methods are constructed, optimized, and compared on the basis of comprehensive evaluation of the performance of the ensemble forecast products. The results show that LSTM has the best performance in sea gale integrated prediction. For the 10-m wind speed forecast in the Yellow Sea and Bohai Sea, EC has the best comprehensive performance, while NCEP has significant advantages in the gale prediction that is equal or greater than level 6. The diurnal variations of the forecast errors in four products are significant, and the prediction

abilities of all products at nighttime are weaker than that at daytime. In the traditional methods, the gale prediction ability of WEM and BCWEM can be significantly improved by optimizing the length of training period and removing the members with poor performance. Compared with EM, WEM shows no significant improvement, while BCWEM and LSTM shows a significant improvement with a decrease in forecast error by more than 10% for both full wind speed and strong wind speed, which is more remarkable at nighttime. BCWEM effectively corrects the prediction bias of the EM and WEM methods for moderate and weak wind speed, while LSTM further reduces the prediction error for strong wind speed and improved the hit number of gale stations and *ETS* score. The cases analysis of gale also shows that LSTM effectively compensates for the missing report problem of gale in low vortex eastward type by traditional methods, and improves the prediction ability of gale in cold and high pressure type with significant advantage.

Key words: sea gale; integrated prediction; dynamic weight; bias correction; long short-term memory neural network