

DOI:10.11737/j.issn.1003-0239.2024.06.003

基于深度学习的大风订正预报研究

杨凡¹, 刘志丰^{2*}, 任兆鹏¹, 崔天伦³, 于洋³

(1. 青岛市气象服务中心, 山东青岛 266003; 2. 青岛市黄岛区气象局, 山东青岛 266400; 3. 青岛天洋气象科技有限公司, 山东青岛 266400)

摘要: 基于数值预报模式产品的风速预报集成学习误差订正方法, 通过长短期记忆网络(LSTM)和残差神经网络(ResNet)构建新的风速预测混合模型 ResNet-LSTM。采用 2019—2020 年欧洲中期天气预报中心 39 种数值天气预报模式产品训练深度学习模型, 对格点预报产品插值到站点后的预报结果进行订正。结果表明: 与 ECMWF 的原始预报相比, ResNet-LSTM 模型在预测 6 级以上阵风时的 TS 评分整体可以提高 50% 以上, 预报精度提升。寒潮大风和台风大风的个例分析也表明, ResNet-LSTM 可以有效解决大风漏报问题, 对站点风速的预报订正效果显著。

关键词: 残差神经网络; 长短期记忆网络; 风速; 预报; 订正

中图分类号: P457.5 **文献标识码:** A **文章编号:** 1003-0239(2024)06-0023-09

0 引言

灾害性天气对人民生活有较大影响。海上大风是黄渤海域常见的灾害性天气之一, 出现时常引起海浪、风暴潮等, 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会造成严重影响。因此, 提高海上大风尤其是风速的预报能力对气象防灾减灾具有重要的现实意义^[1]。

目前风速预报常使用区域或全球尺度数值天气预报模式, 但由于模式初始场、动力和物理过程的不确定性, 可能导致预报结果与实况存在较大偏差^[2-3]。随着科技不断发展, 人们开始采用多种误差订正方法对单一数值预报结果进行订正。传统的订正方法大多为线性模式, 难以捕捉到风速变化中的非线性特征; 而人工智能方法则在捕捉风速的非线性变化方面显现出良好的应用效果^[4-5]。孔令彬等^[6]利用支持向量机(Support Vector Machine, SVM)算法建立了风速订正模型, 将人工观测的风速数据向自动观测数据订正。张颖超等^[7]利用极

学习机(Extreme Learning Machine, ELM)算法对 WRF(Weather Research and Forecasting)模式预报的风速进行订正, 减小了风速预报误差。邓华等^[8]利用主成分分析(Principal Component Analysis, PCA)和径向基函数(Radial Basis Function, RBF)网络相结合的 PCA-RBF 算法, 利用 WRF 模式预报的风向、气温、气压等气象要素对预报风速进一步订正, 与反向传播(Back Propagation, BP)神经网络、最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)算法相比, PCA-RBF 算法有较好的订正效果。

随着人工智能技术的不断发展, 深度学习方法展现了较好的优势。循环神经网络(Recurrent Neural Network, RNN)中的 LSTM 方法在风速预报中体现出较好的性能^[9]。王国松等^[10]利用观测数据和再分析数据建立了 LSTM 网络并对沿海风速进行预测。刘志杰等^[11]选取了 4 家集合预报产品, 对比了 3 类传统集成方法和 LSTM 方法, 结果表明 LSTM 在大风集成预报中性能最优。

收稿日期: 2023-09-19。

基金项目: 青岛市气象局课题(2021qdxz02、2019qdxz01); 山东省气象局项目(2022SDQN06)。

作者简介: 杨凡(1981-), 男, 高级工程师, 硕士, 主要从事气象服务技术研究。E-mail: yangfan317@126.com

*通信作者: 刘志丰(1995-), 女, 工程师, 硕士, 主要从事海洋人工智能研究。E-mail: lzflyjk@163.com

但是仅仅考虑风速的时序特征是不完善的,为了更准确地获取风速数据在多因素影响下的深层次特征, HUANG等^[11]将卷积神经网络(Convolutional Neural Networks, CNN)和LSTM结合,提出混合深度学习模型APNet,利用CNN的特性自动提取特征,完成对单个站点多个特征序列的逐层提取。但是随着模型层数的增加,深层CNN又存在着梯度消失或者爆炸的问题,这导致深度卷积神经网络在训练阶段难以得到收敛,并且随着网络深度的不断增加,网络的退化问题愈加严重,而残差网络(Residual Network, ResNet)则可以解决退化问题^[12]。

因此,本文将ResNet残差结构和LSTM相结合,提出了一种风速预测多任务学习模型ResNet-LSTM。模型以ResNet作为特征提取单元,利用LSTM结构进行时间序列特征的学习。ResNet和LSTM网络共同构成模型共享层,可以取得更强更稳定的性能,并可以建立更深层的网络结构。该方法的优点在于可以通过ResNet层获取到更直接的特征信息,同时也保持了一定的时间序列信息,再通过LSTM网络可以进一步学习时间序列特征。本文利用ECMWF的39个气象要素场作为输入数据,使用ResNet-LSTM模型对青岛地区的风速进行订正预报。

1 数据

本文采用欧洲中期天气预报中心(The European Centre for Medium-Range Weather Forecasts, ECMWF)大气模型高分辨10 d预报产品(Atmospheric Model high resolution 10-day forecast (Set I - HRES)),时间为2019年1月—2020年12月,空间分辨率为 $0.125 \times 0.125^\circ$ 。ECMWF模式每日00时(世界时,下同)起报。本文选择了每日3~24 h预报(时间间隔为3 h)共7个预报时效的ECMWF预报产品,实现了24 h内逐3 h的短期预报。ECMWF模式数据共有39个气象要素场,包括29个地面层要素(SFC),7个压力层要素(PL)和3个模式层要素(ML)(见表1)。

根据风要素相关影响因子经验,将相关纬向风分量(U)和经向风分量(V)(地面层10u、10v、100u、

100v;压力层950u、950v、1000u、1000v)合成为风速(W)。合成公式为:

$$W = \sqrt{U^2 + V^2} \quad (1)$$

对地面层温度露点差进行特征处理(2mt-2md),将温度相关数据由原始的开尔文温度转换为摄氏度(2d、2t、skt等),将表面压力sp由Pa转换为hPa,对部分压力层数据(r 、 q)做同一要素不同压力层相减($r1\ 000-r950$ 、 $q1\ 000-q950$)。

本文将时段内模式在0时刻的10 m风速分析场作为模型标签(深度学习算法中的真值),将ECMWF预测的与标签对应时刻的所有气象要素作为深度学习算法的输入特征,构建ResNet-LSTM风速订正模型。

2 方法

2.1 长短期记忆网络

LSTM是RNN模型的变体,是为了克服RNN的长期依赖问题而引入的。风速时间序列具有长期和短期依赖性,LSTM能够通过学习长期依赖关系,更好地对具有长期和短期依赖的时间数据进行顺序处理。因此,本文以LSTM模型为主框架对风速进行预测。

在LSTM中,存储单元是处理长期依赖性的核心,单元状态可以通过输入门、遗忘门和输出门进行控制和更新。标准的LSTM计算定义如下:

$$\begin{cases} f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \\ i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \\ g_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + W_{cc}c_{t-1} + b_c) \\ c_t = f_t * c_{t-1} + i_t * g_t \\ o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_{t-1} + b_o) \\ h_t = o_t + \tanh(c_t) \end{cases} \quad (2)$$

式中: $x = (x_1, x_2, \dots, x_n)$ 为扁平化的数据层; f_t 、 i_t 、 c_t 、 o_t 分别为遗忘门、输入门、记忆细胞矢量门和输出门; W 、 b 、 $*$ 分别代表每个记忆细胞的权重矩阵、偏置矢量和标量乘积; $\sigma(\cdot)$ 和 $\tanh(\cdot)$ 是两个激活函数,定义为:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

表1 ECMWF数值预报39个气象要素场

Tab.1 39 Kinds of meteorological variables of the ECMWF numerical prediction

要素类型	序号	气象要素场
地面层(SFC)	1	10 m 纬向风(10 metre U wind component)
	2	10 m 经向风(10 metre V wind component)
	3	表面压力(Surface pressure)
	4	柱状水总量(Total column water)
	5	2 m 温度(2 metre temperature)
	6	2 m 露点温度(2 metre dewpoint temperature)
	7	总降水量(Total precipitation)
	8	对流可用势能(Convective available potential energy)
	9	总云量(Total cloud cover)
	10	平均海平面气压(Mean sea level pressure)
	11	对流降水(Convective precipitation)
	12	低云量(Low cloud cover)
	13	100 m 纬向风(100 metre U wind component)
	14	100 m 经向风(100 metre V wind component)
	15	水蒸气柱总量(Total column water vapour)
	16	表面温度(Skin temperature)
	17	预测反照率(Forecast albedo)
	18	过去 3 h 10 m 阵风(10 metre wind gust in the last 3 hours)
	19	过去 3 h 2 m 的最低温度(Minimum temperature at 2 metres in the last 3 hours)
	20	过去 3 h 2 m 处的最高温度(Maximum temperature at 2 metres in the last 3 hours)
	21	积雪深度(Snow depth)
	22	能见度(Visibility)
	23	0 摄氏度等温面高度(0 degree isothermal level (atm))
	24	累积冻雨(Accumulated freezing rain)
	25	大范围降水(Large-scale precipitation)
	26	降水类型(Precipitation type)
	27	雪密度(Snow density)
	28	降雪量(Snowfall)
	29	海面温度(Sea surface temperature)
压力层(PL)	30	相对湿度(1000 hpa 和 950 hpa)(Relative humidity)
	31	温度(1000 hpa 和 950 hpa)(Temperature)
	32	风纬向速度(1000 hpa 和 950 hpa)(V velocity)
	33	风经向速度(1000 hpa 和 950 hpa)(U velocity)
	34	垂直速度(1000 hpa 和 950 hpa)(Vertical velocity)
	35	比湿(1000 hpa 和 950 hpa)(Specific humidity)
	c	位涡(1000 hpa 和 950 hpa)(Potential vorticity)
模式层(ML)	37	云冰量(Specific cloud ice water content)
	38	云液态水含量(Specific cloud liquid water content)
	39	云量分数(Fraction of cloud cover)

2.2 加入 ResNet 的集成方法

深度卷积神经网络(Deep Convolutional Neural Networks, DCNN)由于具有局部区域感知、时空域上采样和权重共享的优点,在数据分类领域应用广泛并且取得了巨大的突破。但是 DCNN 也存在一些问题,如随着网络层数的加深会出现梯度消失问题;层数较浅的网络难以显著提升识别效果;网络的识别效果并不会随着层数的增加变得更好等。

为了解决上述问题,HE 等^[13]提出了残差网络 ResNet,即引入残差块(Residual Block)构建深层网络。残差块结构见图 1,其中 x 为输入, $H(x)$ 为输出, $F(x)$ 为残差映射函数。

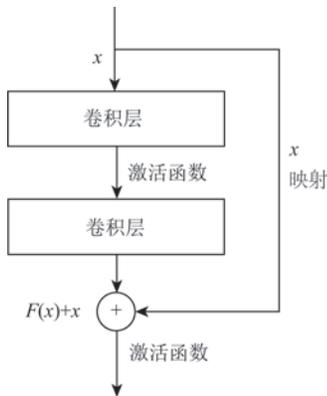


图 1 ResNet 残差块结构

Fig.1 Residual Block Structure of the ResNet model

ResNet-LSTM 模型是将 ResNet 的思想应用于 LSTM 网络,以解决 LSTM 深层网络训练困难的问题。ResNet-LSTM 模型的基本结构包括输入层、LSTM 层、残差连接层和输出层。输入层用于接收序列输入;LSTM 层为典型的 LSTM 层,包含输入门、遗忘门、输出门等;残差连接层为在 LSTM 层后添加残差连接,实现 $h(t) = h(t-1) + F(h(t-1), x(t))$, 其中 F 表示 LSTM 层, $h(t-1)$ 表示上一层的输出, $x(t)$ 表示当前输入;输出层为输出序列的预测结果。

ResNet-LSTM 模型的工作原理为:

- ① 输入序列经过输入层进入 LSTM 层;
- ② LSTM 层按时间步计算每个时间步的输出,但并不直接输出,而是进入残差连接;
- ③ 残差连接中的 $h(t-1)$ 取上一时间步 LSTM

层的输出,与 $F(h(t-1), x(t))$ 相加,得到当前时间步的输出 $h(t)$;

④ 将 $h(t)$ 作为下一时间步 LSTM 层的输入和下一残差连接中的 $h(t-1)$,重复此步骤;

⑤ 重复步骤②-④,最终由输出层给出序列的预测结果;

⑥ 进行反向传播,以更新网络参数。

由于梯度消失问题,普通的深层 LSTM 网络很难训练,残差连接则可以有效解决这个问题,使得网络更容易优化;另外,残差连接允许网络继续加深,并建立更深的 LSTM 网络;同时,它还可以减少梯度计算次数,使得训练速度更快。综上所述,ResNet-LSTM 的主要优点在于更容易训练和优化,能取得更强更稳定的性能,并建立更深层的网络结构。这些优点来源于残差连接,它巧妙地改善和补充了 LSTM 网络。

因此,ResNet-LSTM 已成为目前较先进和有效的时序学习框架之一,在许多任务上都显示出较强的性能,成为序列学习领域的重要研究内容和发展方向。因此,本文使用 ResNet-LSTM 模型对青岛地区风速进行订正预报。

3 模型订正效果及订正个例

3.1 模型性能评估

本文构建模型的输入数据为台站历史观测资料。以 2019—2020 年 ECMWF 预报数据作为数据集,用于模型训练,前 80% 长度的时间序列作为训练集、10% 作为验证集、剩余 10% 作为测试集,用于检验模型性能。本文的预报时效为 3~12 h(预报间隔为 3 h)。基于测试集部分,将数据特征处理后的 ECMWF 预报因子输入训练好的模型网络中,得到测试集风力预测结果;对比风力预测结果和实际风力观测数据,以特定风力等级综合准确率评分(Threat Score, TS)作为检验标准,验证模型合理性。模型优化器选择 Adam 优化算法,损失函数采用均方损失函数进行梯度下降迭代训练。

为了比较不同的风速时间序列预测方法的有效性,常利用 4 种气象评价指标来计算预测值与真实值的误差情况。定义如下:

均方根误差(Root Mean Square Error, RMSE):

$$E_{\text{RMS}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_i)^2} \quad (5)$$

平均绝对误差 (Mean Absolute Error, MAE):

$$E_{\text{MA}} = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}_i| \quad (6)$$

相关系数 (Correlation Coefficients, CC):

$$r = \frac{\text{Cov}(x_i, \bar{x}_i)}{\sqrt{\text{Var}(x_i) \text{Var}(\bar{x}_i)}} \quad (7)$$

式中: x_i 为观测值; \bar{x}_i 为模型预测值; n 为统计对象总体数目。衡量风速预报性能时, RMSE、MSE 和 MAE 数值越低, 模型表现越好, CC 的数值越趋于 1, 模型表现越好。

以时间段内 6 级以上阵风为标准, 风速预报综合准确率 (TS) 计算方法为:

$$\text{TS} = \frac{N_r}{(N_a + N_t - N_r)} \times 100\% \quad (8)$$

式中: N_r 是同一时刻预测值和观测值都在阵风 6 级以上的预测值数量; N_a 是观测值在阵风 6 级以上的数量; N_t 是预测值在阵风 6 级以上的数量。

3.2 模型订正效果

选取每日 3~24 h 预报 (时间间隔为 3 h) 共 7 个预报时效的 ECMWF 预报产品, 使用双线性插值方法将其插值到站点来训练 ResNet-LSTM 模型, 得到站点的风速预报订正结果并进行评估。青岛站数据共选取 5 086 个样本, 每个样本有 39 个特征; 由于海岛站缺乏及时的维护, 大公岛站观测数据缺失较多, 共选取 4 043 个样本, 每个样本有 39 个特征。模型性能的评估标准包括模型风速预报综合准确率以及模型订正值与观测值的均方根误差。选取不同季节 (夏季和冬季) 分别对模型效果进行验证 (见图 2)。

以典型临海站点青岛国家气象观测站 2020 年 6—7 月 (夏季) 和 11—12 月 (冬季) 每日未来 24 h 逐 3 h 6 级以上阵风预报数据进行对比, 结果见表 2。相较 ECMWF, 夏季 ResNet-LSTM 的 RMSE 降低了 37.8%, TS 评分提升了 30.5%; 冬季 ResNet-LSTM 的 RMSE 降低了 34.6%, TS 评分提升了 22.7%。7 月 23 日 02 时 (见图 2b 的 168 时刻), 青岛站实际风速为 17.3 m/s, 而 ECMWF 的预报结果为 31.8 m/s, 预报值比实际值大 14.5 m/s, 严重高估了阵风风速, 而

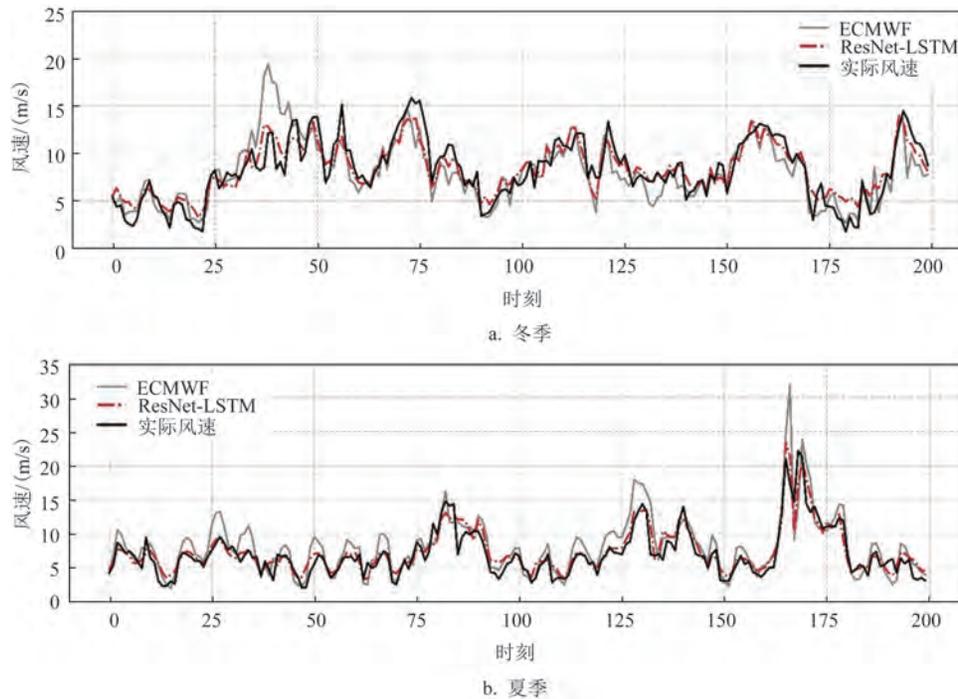


图2 青岛站夏季和冬季 3 h 阵风观测值、ResNet-LSTM 预测值和 ECMWF 预报结果对比

Fig.2 Comparison of 3-hour gust observations, the ResNet-LSTM predictions, and the ECMWF predictions at Qingdao Station in summer and winter in 2020

表2 2020年夏季和冬季青岛站6级以上阵风预测结果对比
Tab.2 Comparison of forecast results for gusts above level 6 at Qingdao Station in summer and winter in 2020

季节	模式	TS	RMSE	MAE	CC
夏季	ResNet-LSTM	0.55	1.42	1.06	0.87
	ECMWF	0.42	2.29	1.77	0.82
冬季	ResNet-LSTM	0.72	1.49	1.18	0.93
	ECMWF	0.58	1.93	1.42	0.87

ResNet-LSTM的订正结果为21.3 m/s,与实际值非常接近。11月18日05时(见图2a的39时刻),青岛站实际风速为8.5 m/s,ECMWF的预报结果为18.1 m/s,比实际值大9.6 m/s,而ResNet-LSTM的订正结果为12.9 m/s。这显示出ResNet-LSTM模型对风速预报具有较好的订正效果。由图2b也可以看出,多数时刻ECMWF对风速的预报都存在高估现象,而ResNet-LSTM模型均进行了良好的订正。

大公岛是青岛市第二高岛,距大陆最近点为14.8 km。大公岛站作为青岛近海的海岛站,常年风速较大,其对青岛近海阵风预报有很好的参考意义和代表性。本文选取大公岛站作为海岛站的代表性站点,选取2020年6—7月(夏季)和11—12月(冬季)每日未来24 h逐3 h阵风6级以上预报数据进行对比,结果见表3。相较ECMWF的预报结果,夏季ResNet-LSTM模型的TS评分提升了22.6%,RMSE降低了9.8%,而冬季的TS评分提升了88.9%,RMSE降低了14.4%。这表明ResNet-LSTM模型可以很好地提取到数据之间的相关特性,有效减小ECMWF模式的预报误差,提高风速预测准确率。

以上结果表明,对青岛站而言,ECMWF预报的整体结果偏高,而对于大公岛站,ECMWF的预报结果忽高忽低,而ResNet-LSTM模型可以有效订正

表3 2020年夏季和冬季大公岛站6级以上阵风预测结果对比
Tab.3 Comparison of forecast results for gusts above level 6 at Dagongdao Station in summer and winter in 2020

季节	模式	TS	RMSE	MAE	CC
夏季	ResNet-LSTM	0.57	3.28	1.99	0.81
	ECMWF	0.47	3.64	2.32	0.78
冬季	ResNet-LSTM	0.34	3.26	2.68	0.64
	ECMWF	0.18	3.81	2.93	0.43

表4 2020年夏季和冬季青岛站不同预报时效6级以上阵风预测结果RMSE对比

Tab.4 Comparison of RMSE prediction results for gusts above level 6 at Qingdao Station in summer and winter in 2020 with different forecast time limits

季节	模型	预报时效/h			
		3	6	9	12
夏季	ResNet-LSTM	1.54	1.35	1.30	1.43
	ECMWF	2.36	2.70	2.72	2.40
冬季	ResNet-LSTM	1.25	1.42	1.71	1.71
	ECMWF	1.60	1.96	2.08	2.83

ECMWF的预报结果,丰富模型中的有效信息量,提高短期风速预测精度。

将青岛站和大公岛站3~12 h预报时效的结果进行对比,计算每个预测时效的RMSE。从表4和表5可以看出,ResNet-LSTM模型的RMSE低于ECMWF,前者在青岛站夏季平均降低35.4%,冬季平均降低21.3%,在大公岛站夏季平均降低12.2%,冬季平均降低8.3%。这说明深度学习方法对不同时效的ECMWF风速预报进行了不同的订正,并且该方法对数据量比较敏感,数据量越大(如青岛站),订正效果越好。

表5 2020年夏季和冬季大公岛站不同预报时效6级以上阵风预测结果RMSE对比

Tab.5 Comparison of RMSE prediction results for gusts above level 6 at Dagongdao Station in summer and winter in 2020 with different forecast time limits

季节	模型	预报时效/h			
		3	6	9	12
夏季	ResNet-LSTM	2.54	2.57	2.64	2.97
	ECMWF	3.24	2.82	3.10	3.54
冬季	ResNet-LSTM	3.43	2.85	2.36	3.48
	ECMWF	3.91	3.07	2.73	3.82

3.3 站点风速预报个例订正

数值天气预报模式常出现极值预报偏低^[14],因此它还有很大提升空间。本文选取两种不同类型的大风天气(台风大风和寒潮大风),分析并对比模型的预报性能。

2022年第12号台风“梅花”给青岛地区和近海海域带来大风影响。台风“梅花”可按影响天气系统分为两个阶段。第一阶段受台风北部倒槽影响,主要影响时间为9月14日凌晨一白天,区域为青岛近海海域。9月14日14时3h大公岛观测阵风风速达24.7 m/s,而ECMWF的预报结果只有16.6 m/s,与实际值相差8.1 m/s,而ResNet-LSTM模型的订正结果为24.4 m/s(见图3a)。第二阶段为台风本体环流影响,时间为15日下午—16日,主要影响区域为青岛全境及近海海域。此阶段最大阵风风力出现在大公岛,为12级(风速为33.0 m/s),ECMWF的风速预报结果只有23.1 m/s,与实际值相差9.1 m/s,而ResNet-LSTM模型的订正结果为29.4 m/s。对于6级以上阵风,ResNet-LSTM模型的RMSE为3.76 m/s,ECMWF为5.9 m/s,ResNet-LSTM的订正效果更佳。

对台风“梅花”过程按照阵风风力为6级以上、8级以上和10级以上进行预报结果检验,结果见表6。与ECMWF相比,ResNet-LSTM模型的6级以上阵风的TS评分提升53.33%,8级以上阵风提升76.47%,10级以上阵风提升66.67%。

十一期间青岛经历了典型的寒潮天气过程,出

表6 台风“梅花”期间ResNet-LSTM模型与ECMWF预测结果对比

Tab.6 Comparison of the ResNet-LSTM and ECMWF prediction results during Typhoon "Meihua"

模式	TS	RMSE	MAE	CC
ResNet-LSTM(6级以上)	1.00	3.76	2.84	0.67
ECMWF(6级以上)	0.65	5.91	5.17	0.73
ResNet-LSTM(8级以上)	0.82	4.24	3.09	0.55
ECMWF(8级以上)	0.46	6.58	5.76	0.42
ResNet-LSTM(10级以上)	0.33	3.76	3.07	0.64
ECMWF(10级以上)	0.20	7.03	6.56	0.46

现寒潮大风(见图3b)。对此过程按照阵风风力6级以上和7级以上进行预报结果检验,结果表明,ResNet-LSTM模型6级和7级以上阵风的TS评分均提升50%(见表7)。

各类方法的预报结果表明,ResNet-LSTM模型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TS评分均优于ECMWF的预报结果。由此可以看出,ResNet-LSTM模型通过充分挖掘观测数据之间的时序关系,在一定程度上弥补了数值天气预报的不足,对

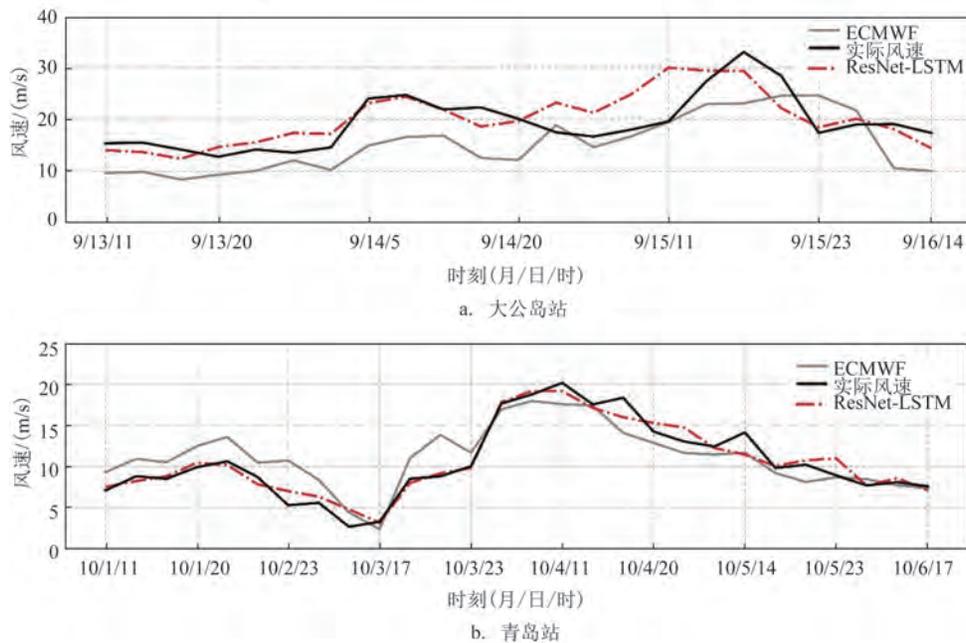


图3 不同站点天气过程观测值、ResNet-LSTM预测值和ECMWF预报结果对比

Fig.3 Comparison of observed values, the ResNet-LSTM predicted values, and the ECMWF forecast results for weather processes at different stations

表 7 十一寒潮期间 ResNet-LSTM 模型与 ECMWF 预测结果对比

Tab.7 Comparison of the ResNet-LSTM and ECMWF prediction results during cold wave

模式	TS	RMSE	MAE	CC
ResNet-LSTM(6级以上)	0.90	1.41	1.10	0.89
ECMWF(6级以上)	0.60	2.01	1.62	0.86
ResNet-LSTM(7级以上)	0.75	1.47	1.15	0.83
ECMWF(7级以上)	0.50	2.19	1.75	0.85

于极端天气预报可能具有较强的订正潜力。

4 结论与讨论

本文基于混合深度学习模型 ResNet-LSTM 对 ECMWF 模式产品的风速预报结果进行订正,验证了该模型在风速订正方面的优越性和可行性,证明了深度学习与数值天气预报模式相结合有广阔的应用前景。主要结论如下:

①利用 ECMWF 的 39 种气象要素构建时序观测特征数据集,使用 ResNet-LSTM 模型对站点风速预报进行订正,结果表明该模型可有效改善风速预报结果。

②相较于数值预报,ResNet-LSTM 模型对 6 级以上阵风预报的 TS 评分整体可以提高 50% 以上,预报精度提升。大风个例验证表明,ResNet-LSTM 可以有效弥补大风漏报问题,对站点风速预报订正效果显著。

但是,模型也存在一定的局限性。今后可以尝试利用深度学习方法进行更长时间尺度(如 48~72 h)的风速预测。另外,将模式格点预报产品插值到站点必然会带来误差,尤其在地形复杂区域,插值时未考虑地形地貌对气温变化的影响,这一误差会被引入到深度学习模型中。

总的来说,ResNet-LSTM 模型是一种强大的深度学习模型,但也存在上述局限性,需要针对具体任务和数据选择合适的模型,并采取相应的技术手段来克服这些局限。

参考文献:

[1] 刘志杰,刘彬贤,王锐,等.基于传统和深度学习技术的黄渤海域大风预报方法研究[J].海洋预报,2022,39(6):34-43.

LIU Z J, LIU X B, WANG R, et al. Research on the gale prediction methods in the Yellow Sea and Bohai Sea based on traditional and deep learning technologies[J]. Marine forecasts, 2022,39(6):34-43.

[2] 陈静,陈德辉,颜宏.集合数值预报发展与研究进展[J].应用气象学报,2002(4):497-507.

CHEN J, CHEN D H, YAN H. A brief review on the development of ensemble prediction system[J]. Journal of Applied Meteorological Science, 2002, 13(4): 497-507.

[3] 韩念菲,杨璐,陈明轩,等.京津冀站点风温湿要素的机器学习订正方法[J].应用气象学报,2022, 33(4):489-500.

HAN N F, YANG L, CHEN M X, et al. Machine learning correction of wind, temperature and humidity elements in Beijing-Tianjin-Hebei Region. Journal of Applied Meteorological Science, 2022, 33(4): 489-500.

[4] 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. Journal of Applied Meteorological Science, 2021, 32(1): 1-11.

[5] 孙全德,焦瑞莉,夏江江,等.基于机器学习的数值天气预报风速订正研究[J].气象,2019, 45(3):426-436.

SUN Q D, JIAO R L, XIA J J, et al. Adjusting Wind Speed Prediction of Numerical Weather Forecast Model Based on Machine Learning Methods[J]. Meteorological Monthly, 2019, 45(3):426-436.

[6] 孔令彬,赵艳茹,王聚杰,等.基于支持向量机风速订正方法的研究[J].西南大学学报(自然科学版),2014, 36(5):194-200.

KONG L B, ZHAO Y R, WANG J J, et al. Modification of Wind Speed Based on SVM[J]. Journal of Southwest University (Natural Science Edition), 2014, 36(5):194-200.

[7] 张颖超,肖寅,邓华.基于 ELM 的风电场短期风速订正技术研究[J].气象,2016, 42(4):466-471.

ZHANG Y C, XIAO Y, DENG H. Modification Technology Research of Short Term Wind Speed in Wind Farm Based on ELM Method[J]. Journal of Applied Meteorological Science, 2016, 42(4):466-471.

[8] 邓华,张颖超,顾荣,等.基于 PCA-RBF 的风电场短期风速订正方法研究[J].气象科技,2018, 46(01):10-15.

DENG H, ZHANG Y C, GU R, et al. Correction Method of Short Term Wind Speed in Wind Farm Research Based on PCA and RBF Neural Network[J]. Meteorological Science and Technology, 2018, 46(01):10-15.

[9] 刘志丰,丁锋.基于人工神经网络的沿海风速多步预测研究[J].气象科技,2022, 50(6):851-858.

LIU Z F, DING F. Research on Application of Artificial Neural Network for Sea Surface Wind Speed Forecasting[J]. Meteorological Science and Technology, 2022,50(6):851-858.

[10] 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.
- [11] HUANG C J, KUO P H. A Deep CNN-LSTM Model for Particulate Matter (PM_{2.5}) Forecasting in Smart Cities[J]. Sensors, 2018, 18(7):2220.
- [12] 王琛, 王颖, 郑涛, 等. 基于 ResNet-LSTM 网络和注意力机制的综合能源系统多元负荷预测[J]. 电工技术学报, 2022, 37(7): 1789-1799.
- WANG C, WANG Y, DENG T, et al. Multi-Energy Load Forecasting in Integrated Energy System Based on ResNet-LSTM Network and Attention Mechanism[J]. Transactions of China Electrotechnical Society, 2022, 37(7):1789-1799.
- [13] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition. Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA. 2015. 770-778.
- [14] 陈昱文, 黄小猛, 李熠, 等. 基于 ECMWF 产品的站点气温预报集成学习误差订正[J]. 应用气象学报, 2020, 31(4):494-503.
- CHEN Y W, HUANG X M, LI Y, et al. Ensemble learning for bias correction of station temperature forecast based on ECMWF products[J]. Journal of Applied Meteorological Science, 2020, 31(4): 494-503.

Research on wind speed forecasting correction based on deep learning

YANG Fan¹, LIU Zhifeng^{2*}, REN Zhaopeng¹, CUI Tianlun³, YU Yang³

(1. Qingdao Meteorological Service Center, Qingdao 266003, China; 2 Huangdao Meteorological Bureau, Qingdao 266400, China; 3 Qingdao Tianyang Meteorological Technology Co., Ltd., Qingdao 266400, China)

Abstract: A novel wind speed prediction model, the ResNet-LSTM model, is proposed combining the Long Short-Term Memory (LSTM) model and Residual Network (ResNet) model. By using 39 kinds of numerical weather forecasting products from the European Center for Medium Range Weather Forecasting (ECMWF), a deep learning model is trained to correct wind speed forecasts. The results show that compared with the ECMWF results, the TS score of the ResNet-LSTM model for gusts above level 6 has been increased by over 50%. Further analysis shows that the ResNet-LSTM model can effectively solve the fail report problem and improve wind speed forecasting corrections.

Key words: ResNet model; Long Short Term Memory neural network, wind speed; forecasting, correction