

基于长短时记忆神经网络的辽东湾海冰 延伸期预报方法研究*

焦艳^{1,2}, 黄菲^{1**}, 高松², 刘清容², 冀承振², 王宁², 曹雅静², 于清溪³

(1. 中国海洋大学物理海洋教育部重点实验室, 山东 青岛 266100; 2. 自然资源部北海预报中心, 山东 青岛 266061;
3. 自然资源部北海信息中心, 山东 青岛 266061)

摘要: 通过合成分析和回归分析,研究了影响辽东湾海冰变化的局地和大尺度环流因子,并基于一种深度学习方法——长短时记忆神经网络(LSTM),建立了辽东湾海冰延伸期预报模型。结果表明,LSTM模型能较好地预报出未来15 d辽东湾海冰的总体发展趋势、浮冰外缘线离岸距离的振荡变化及峰值发生时间等关键特征,1~15 d预报的平均绝对误差为4.1~5.7 n mile^①,均方根误差为5.4~7.5 n mile。LSTM模型的预报时效可达到15 d,较目前海冰数值预报(5~7 d)的时效延长一倍,且运算速度极快,能够节省大量的计算资源和时间成本。该模型的建立为利用深度学习方法开展海洋和气象预报提供了一种新思路。

关键词: 辽东湾海冰;延伸期预报;长短时记忆神经网络;深度学习

中图分类号: P731.15

文献标志码: A

文章编号: 1672-5174(2020)06-001-11

DOI: 10.16441/j.cnki.hdxh.20190179

引用格式: 焦艳,黄菲,高松,等.基于长短时记忆神经网络的辽东湾海冰延伸期预报方法研究[J].中国海洋大学学报(自然科学版),2020,50(6):1-11.

JIAO Yan, HUANG Fei, GAO Song, et al. Research on extended-range forecast model of sea ice in the Liaodong Bay based on long short term memory network[J]. Periodical of Ocean University of China, 2020, 50(6): 1-11.

渤海是北半球纬度最低的结冰海域之一,其冰情变化和严重程度直接影响近海的水产养殖、交通运输、油气开采、海洋生态环境以及沿岸居民的生命财产安全^[1-2]。辽东湾是渤海结冰最早、终冰最晚、冰情最严重的海域,每年冬季冰期达4个月。一般年份,辽东湾浮冰外缘的离岸距离约70 n mile,平整冰厚度约40 cm。冰情严重时,海冰能够延伸至渤海中部,堆积高度达到1~2 m,最大9 m^[3]。根据记载,1968/1969年、1976/1977年、2000/2001年和2009/2010年辽东湾均发生了严重的海冰灾害,给沿岸和海岛居民的生产生活带来了严重影响,并造成了巨大的经济损失^[4]。因此,研究辽东湾海冰变化的影响因子,对冰情做出准确有效的预报,是减轻海冰灾害的重要手段之一。

目前海冰业务化预报主要有数值预报和统计预报两种方法。海冰数值预报是指利用海冰数值模式进行的海冰预报,主要用于海冰短期预报。海冰数值模式可以分为动力学模式、热力学模式和动力-热力耦合模

式。近年来动力-热力耦合模式中的冰-海耦合模式取得了明显进展。王仁树等^[5]建立了第一个模拟渤海海冰生消过程的动力-热力模式,模拟了一般年份的海冰生消情况。吴辉碇^[6]将海冰作为一种粘性-塑性流体,并通过引入热力增长函数和变形函数来表示气-冰-海相互作用的热力学过程和海冰堆积的动力学过程。Su等^[7-8]利用POM和粘-塑性海冰热力-动力模式进行耦合,研发了渤海冰-海洋耦合模式,并对1998/1999年冬季和2000/2001年冬季渤海海冰进行模拟,取得了较好的模拟结果。刘煜^[9]在北极冰-海耦合模式的基础上进行改进,建立了高分辨率局地海冰模式,使其适用于渤、黄海海冰预报,并将预报时效由3~5 d延长到7 d。海冰统计预报是指建立海冰与前期影响因子间的统计关系,并根据影响因子的变化进行海冰预报的方法,多用于月-季时间尺度的冰情预测。研究表明,前期气温(或积温)、西伯利亚高压、西太平洋副热带高压等是影响辽东湾海冰季节内变化的主要因子,而ENSO、北极

* 基金项目:国家重点研发计划项目(2016YFC1402000;2015CB953904);国家自然科学基金项目(U1706216;41575067)资助

Supported by the National Key Research and Development Program(2016YFC1402000;2015CB953904); the National Science Foundation of China(U1706216;41575067)

收稿日期:2019-05-05;修订日期:2019-06-06

作者简介:焦艳(1987-),女,博士生。E-mail:jiaoyan87@163.com

** 通讯作者;E-mail:huangf@mail.ouc.edu.cn

① “n mile”表示“海里”,1 n mile=1.852 km

海冰和北大西洋涛动等主要影响海冰的年际变化^[10-14]。目前的研究中,预报因子的选取方法较为丰富,如主成分分析、逐步回归、遥相关分析法等,但建立预报模型的方法则相对单一,主要为一元一次方程或多元一次方程^[15-16]。

目前的海冰业务化预报从时效上来说,在数值模式中短期预报和统计模型月-季尺度预报之间缺乏有效的延伸期预报方法。延伸期预报是衔接天气预报和气候预测之间的10~30 d时间尺度的“时间缝隙”预报,是中期预报(4~10 d)的延伸^[17],该时间尺度的预报既是技术难点也是海冰防灾减灾工作的关键准备期。海冰的生成和演变是海洋和大气多因子共同作用的复杂的非线性过程。就海冰数值模式而言,受模式本身对海冰演变物理机制的描述以及计算资源的限制,很难在保证误差稳定的情况下继续延长预报时效;而就传统的统计模型而言,线性方程亦不足以描述复杂的非线性过程。因此亟需探究新的海冰预报方法,既能包含冰情及其影响因子间的非线性过程,又不占用太多的计算资源,从而建立起量化的海冰延伸期预报模型。

近年来,随着人工智能浪潮的兴起,深度学习又一次进入了人们的视线。深度学习这一概念最早是由多伦多大学的Hinton等在2006年提出的^[18],是指基于样本数据通过一定的训练方法得到包含多个层级的深度网络结构的学习过程。循环神经网络(Recurrent Neural Network, RNN)是深度学习的代表性网络结构之一,是一种对序列数据建模的神经网络,即一个序列当前的输出与前面的输出有关,主要用于处理时间序列结构。长短时记忆神经网络(Long Short Term Memory Network, LSTM)是在RNN的基础上发展而来的,通过引入“记忆单元”,解决了RNN在处理长时间序列时可能存在的梯度消失或梯度爆炸的问题,更适用于处理长时间序列的预报问题^[19]。目前LSTM已经在气象和海洋预报领域得到了初步应用^[20]。Shi等^[21]利用LSTM方法对降水进行短时预报,其结果优于业务化ROVER临近降水算法预报。Salman等^[22]采用ARIMA与LSTM两种方法分别预报机场能见度,ARIMA模型均方根误差为0.984,而LSTM模型的均方根误差仅为0.0007, LSTM模型预报效果显著。高丽斌等^[23]采用LSTM方法建立波高预报模型,预报结果的平均绝对误差为0.008 m,均方根误差为0.012 m,相关系数达到0.999,说明了LSTM在波高预报中有很好的预报效果。

本文首先利用合成分析和相关分析法,选取并定义影响辽东湾冰情变化的局地和大尺度环流因子,然后基于LSTM方法设计多组试验,进行辽东湾冰情变

化的15 d预报,最后选取最优试验方案,建立辽东湾海冰延伸期预报模型。

1 资料与方法

1.1 数据资料

海冰逐日观测数据 海冰逐日观测数据来源于MODIS遥感监测资料的反演结果,时间段为2005—2018年。该产品由北海预报中心发布,包含海冰面积百分比和浮冰外缘线离岸距离^①(简称“浮冰外缘线”)两个冰情指标。从海冰业务预报的实际需求出发,选取浮冰外缘线作为表征冰情强弱的物理量,并做三日滑动平均处理。

海洋站实测数据 为研究海冰源地的影响因子,选取2004—2018年葫芦岛海洋站的气温、海温、风速风向和气压实测资料,该资料也来源于北海预报中心。

NCEP/NCAR Reanalysis 2 资料 为研究大尺度环流对辽东湾海冰的影响,选用NCEP/NCAR再分析资料,空间分辨率为 $2.5^{\circ} \times 2.5^{\circ}$,时间分辨率为1 d,时间范围为2004—2018年。

GFS 预报数据 Global Forecasting System(GFS)是NCEP/NCAR的全球预报系统,其预报时效为384 h(16 d),每天00和12 h两次滚动预报,其中0~8 d为逐3 h预报,9~16 d为逐12 h预报。本文使用00 h预报结果,并将预报结果处理为日平均数据,用于建立辽东湾海冰延伸期预报模型。

1.2 研究方法

长短时记忆神经网络(Long Short Term Memory Network, LSTM)是一种特殊的循环神经网络(RNN),适用于学习长时间序列信息。图1为RNN与LSTM的结构对比图,其中 x_t 为输入信息,A为神经单元处理部分, h_t 为输出信息。可以看到传统的RNN网络结构已经具备了处理时间序列的能力,前一个时刻的神经单元的处理信息可以传递到当前时刻,当前时刻的信息又能够传递到下一时刻。然而,RNN网络只能接收到相邻序列点的信息,在处理长时序信息时,可能会产生梯度消失或者梯度爆炸的问题。

为解决这一问题,LSTM将RNN中的神经单元替换为“记忆细胞”,每个记忆细胞中包含三个“门”,分别为“输入门”、“输出门”和“遗忘门”。LSTM的关键在于单元状态,即穿过记忆细胞上方的水平线,它类似于一个传送带贯穿整个链条,使信息向下流动。前一个时刻的输出信息和当前时刻的输入信息通过“输入门”、“输出门”和“遗忘门”向单元状态中移除或添加信息,

^① 浮冰外缘线离岸距离是指浮冰外边缘与测量基线交点至湾底的距离。辽东湾的基线为(121°52'E,40°52'N ~ 120°00'E,39°00'N)。

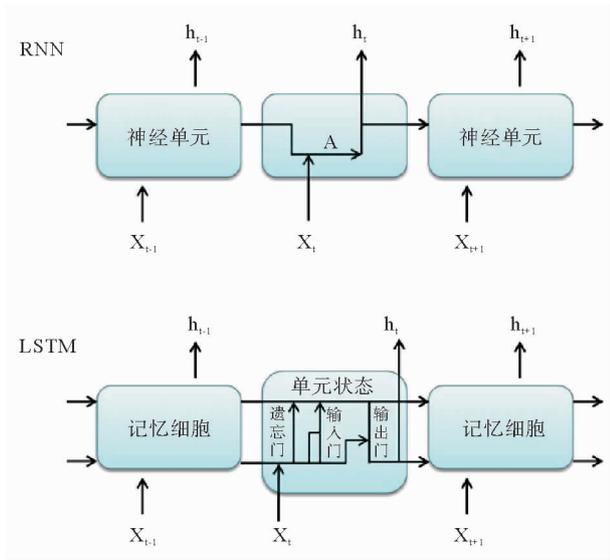


图 1 RNN 与 LSTM 的结构对比

Fig.1 Structure comparison of RNN and LSTM

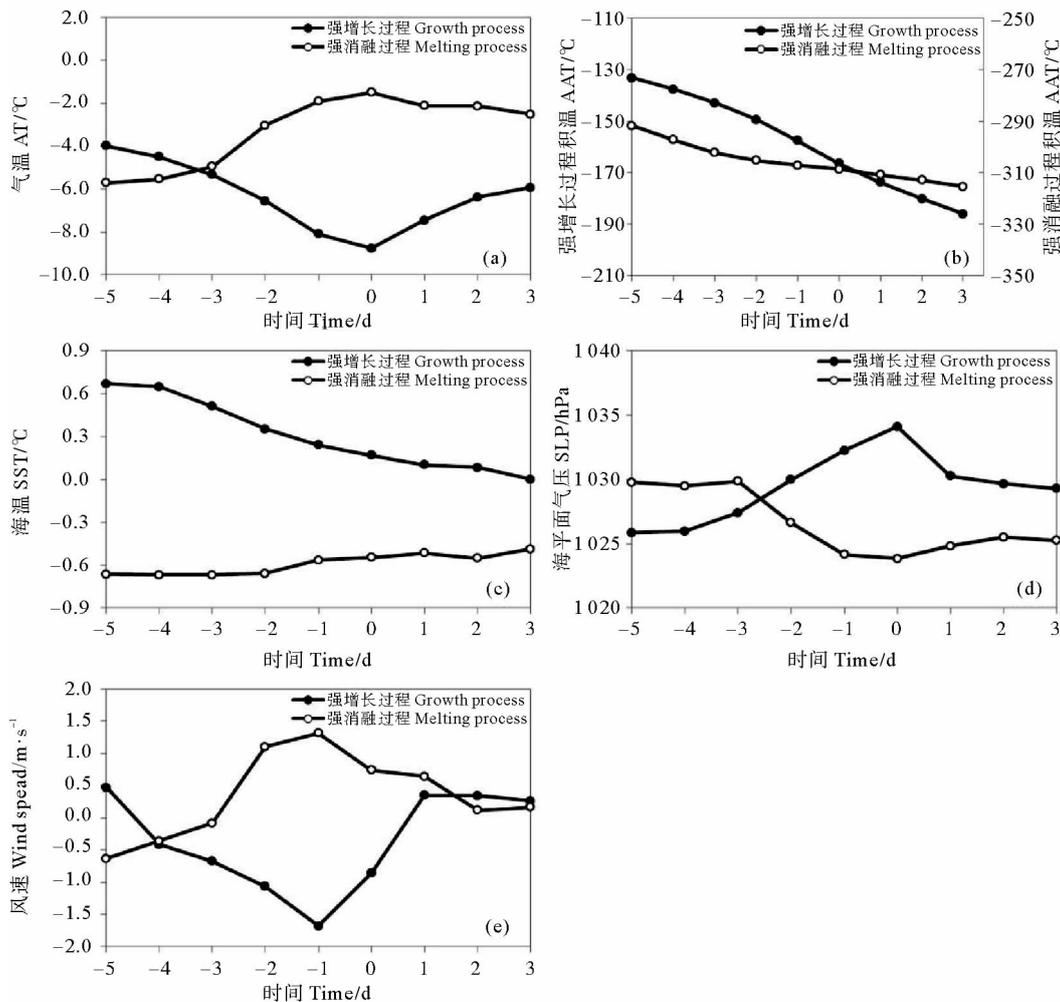
“门”的作用在于有选择的让信息通过,以保护和控制神经元的状态。LSTM 的详细原理见文献[24]。

2 辽东湾浮冰外缘线变化的影响因子分析

2.1 局地影响因子

为研究冰情变化的局地影响因子,对辽东湾海冰强增长和强消融过程前后的气象和海洋环境要素进行合成分析。定义辽东湾浮冰外缘线连续两天平均每天增大(减小)超过 1.5 倍标准差为一次强增长(消融)过程。2005—2018 年间(2005 年指 2004/2005 年冬季,其它年份以此类推),共有强增长过程 41 个,强消融过程 32 个。图 2 为强生消过程前后海冰源地气象和海洋环境要素的变化。

强增长过程中,气温呈先降后升的趋势,强过程前 2 d 至前 1 d 下降幅度最大,当天气温最低。由于气温为负值,积温呈单调下降趋势,但在强过程前 1~0 d 下



((a)气温;(b)积温;(c)海温;(d)海平面气压;(e)10 m 风的东北向分量;时间负值/正值表示环境要素提前/落后于浮冰外缘线变化。(a)Air temperature; (b)Accumulated air temperature; (c)Sea surface temperature; (d)Sea level pressure; (e)NE component of the 10 m wind; Negative/positive value of time indicates the factors change ahead of/behind the SIE.)

图 2 强生消过程前后气象和海洋环境要素变化

Fig.2 Changes of meteorological and marine factors during strong growth and melting processes

降速率最大。海温也呈单调下降的趋势,在强过程前 2 天至前 1 天下降幅度最大,由于在冰情较为严重时海温维持在冰点附近,因此海温的合成场降温幅度较气温偏小。海平面气压呈现先升后降的趋势,结合气温变化趋势可知,海冰生成源地有冷空气经过,强增长过程当天气压最高。从 10 m 风来看,强增长过程前 4 d 起海冰源地由西南风转为东北风并逐渐增强,前 1 d 风速增至最大,而后风速明显减小,并转为冷空气后部的西南风。

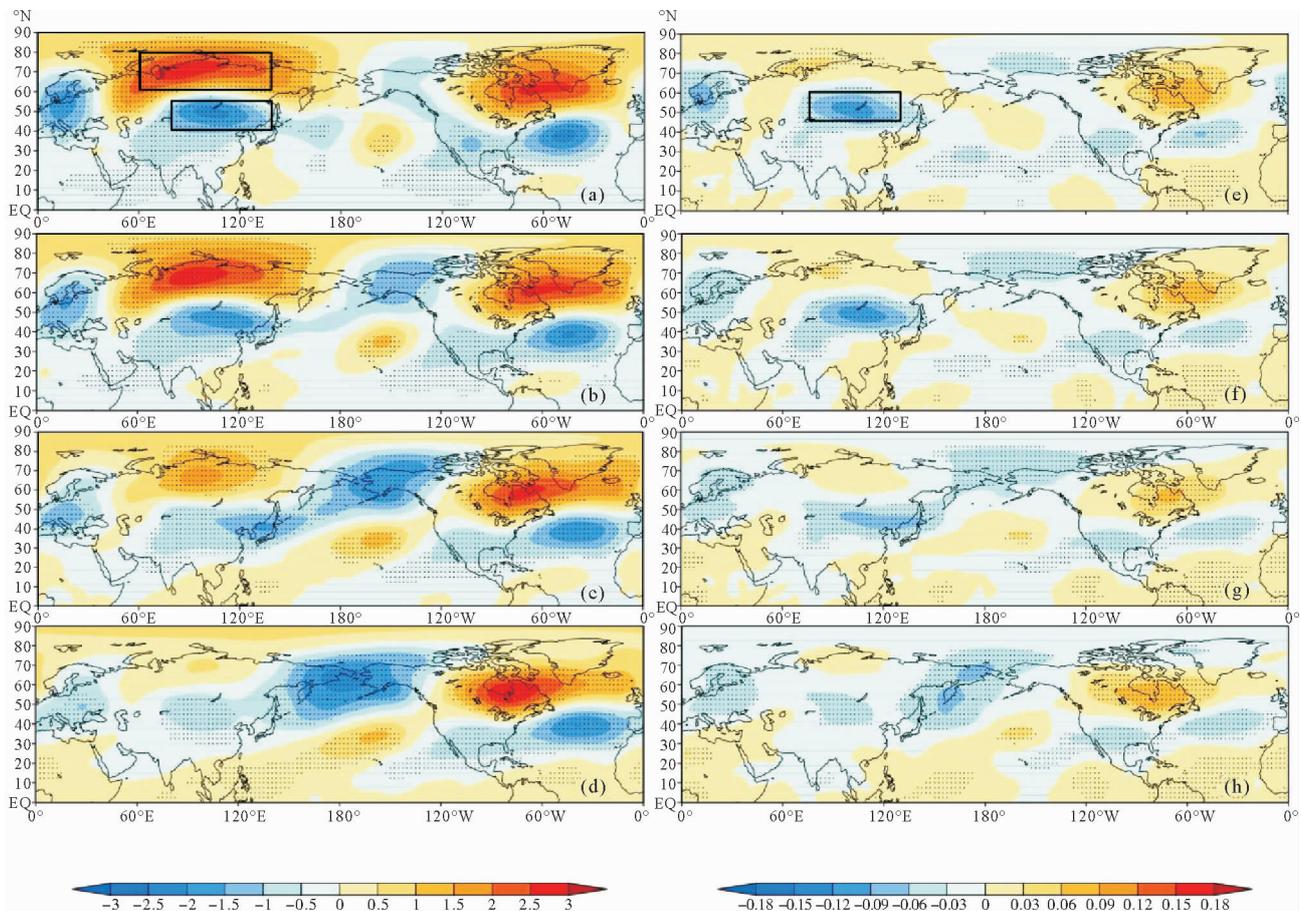
强消融过程中,海冰源地各要素的变化与强增长过程基本相反。气温先升后降,前 2 天至前 1 天升幅最大,当天气温最高。积温在消融过程前变化不大,即气温接近 0°C 。海温前期持平后期略有增长,消融过程的海温低于增长过程是由于消融过程多发生于冰情最严重之后,海温已经降至最低,并开始逐渐上升。海平面气压先降后升,表明强消融过程受地面低压系统的影响。10 m 风以西南风为主,在强过程前 1 d 达到最大值。

通过上述分析可知,局地的气温、积温、海温、气压、海面风等均是辽东湾冰情变化的影响因子。

2.2 大尺度环流影响因子

为研究影响辽东湾浮冰外缘线变化的大尺度环流特征及关键区,对浮冰外缘线与位势高度和气温分别做超前/滞后回归分析。从预报时效性出发,本文重点分析冰情变化前期的环流要素回归场。

图 3 为 500 hPa 位势高度和气温回归场。在浮冰外缘线增长前 6 天,500 hPa 位势高度回归场在欧亚大陆上空呈现出明显的“北正南负”的分布型,正异常中心位于 60°N 以北,西起乌拉尔山,冬至东西伯利亚,负异常中心位于贝加尔湖及蒙古国上空。该分布型对应经向型环流,东亚大槽偏强、偏西。超前 3 天时,正、负异常中心位置基本不变,但强度略有减弱。之后正异常中心逐渐消失,负异常中心东移。从气温回归场来看,超前 6 天贝加尔湖上空有明显的负异常中心,超前 3 天起负异常中心东移、南下,并逐渐减弱。通过上述分析可知,浮冰外缘线变化前 6 天,500 hPa 高空场信号最强,该信号对冰情变化具有较好的预报意义,因此选取 $(60^{\circ}\text{N}\sim 80^{\circ}\text{N}, 60^{\circ}\text{E}\sim 140^{\circ}\text{E})$ 和 $(40^{\circ}\text{N}\sim 55^{\circ}\text{N}, 80^{\circ}\text{E}\sim 140^{\circ}\text{E})$ 两个区域作为 500 hPa 位势高度场关键区,选取 $(45^{\circ}\text{N}\sim 60^{\circ}\text{N}, 80^{\circ}\text{E}\sim 130^{\circ}\text{E})$ 作为 500 hPa 气温场关键区。



((a)~(d)为位势高度回归场;(e)~(h)为气温回归场;(a)和(e)超前 6 天;(b)和(f)超前 3 天;(c)和(g)同期;(d)和(h)滞后 3 天。(a)~(d) potential height; (e)~(h) air temperature; (a) and (e) 6 days ahead; (b) and (f) 3 days ahead; (c) and (g) at the same time; (d) and (h) 3 days behind.)

图 3 辽东湾浮冰外缘线与 500 hPa 位势高度和气温超前/滞后回归分析场

Fig.3 Lead/lag regression coefficients of SIE and potential height and air temperature at 500 hPa

图 4 为 850 hPa 位势高度和气温回归场。位势高度回归场显示, 浮冰外缘线增长前 6 天, 乌拉尔山及其东侧有明显的正异常中心, 超前 3 天时略有减弱, 当浮冰外缘线开始发生变化时, 该异常中心已明显减弱并逐渐消失。对应 850 hPa 温度回归场超前 6 天时贝加尔湖上空负异常中心最强。随着时间推移, 该异常中心逐渐东移南下, 经过渤海海域并逐渐消失。可以看出, 850 hPa 层的信号也是超前浮冰外缘线变化 6 天时

信号最强, 且与 500 hPa 基本呈正压结构。由此选取的关键区为位势高度场(60°N~80°N, 60°E~120°E)和气温场(40°N~60°N, 80°E~140°E)。地面层的气压和气温回归场与 850 hPa 回归场的分布型相似(图略), 浮冰外缘线增长对应冷高压的发展、东移和南下, 地面层选取的关键区为海平面气压场(55°N~75°N, 60°E~120°E)和气温场(40°N~65°N, 80°E~140°E)。

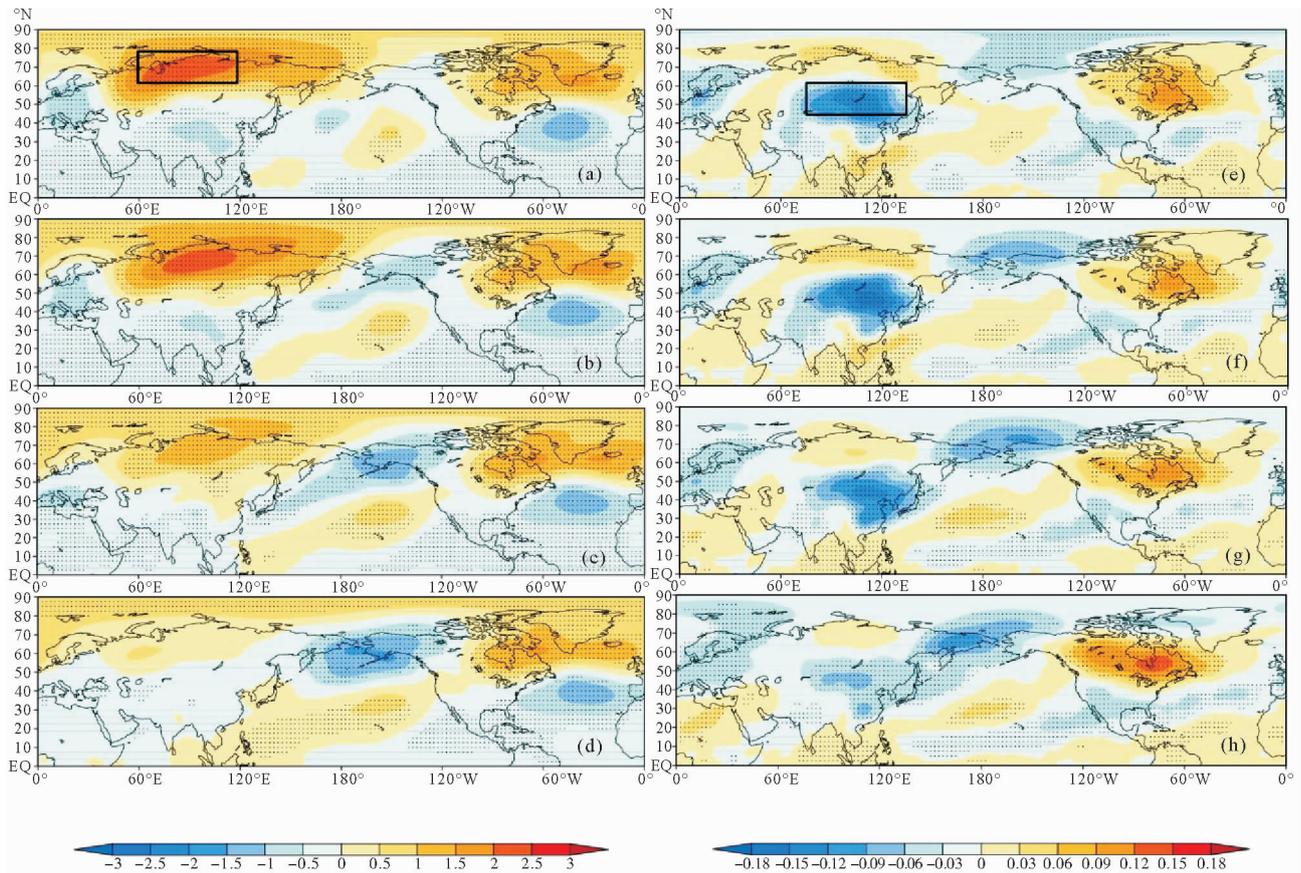


图 4 辽东湾浮冰外缘线与 850 hPa 位势高度和气温超前/滞后回归分析场((a)~(h)同图 3)

Fig.4 Lead/lag regression coefficients of SIE and potential height and air temperature at 850 hPa ((a)~(h) the same as Fig.3)

3 辽东湾浮冰外缘线延伸期预报模型的建立

辽东湾海冰的变化并非受单一因素的影响, 它既是局地海洋和大气要素相互作用的产物, 又受前期大尺度环流形势的影响, 因而用简单的线性方程难以对浮冰外缘线进行较好的拟合, 也难以排除各因子之间的相关性。本文基于 LSTM 方法, 建立各因子与辽东湾浮冰外缘线之间的非线性关系, 力求突破数值模式的预报时效, 建立辽东湾浮冰外缘线的延伸期预报模型。

3.1 试验设置及流程

在本试验中, 预报目标是辽东湾浮冰外缘线未来 15 d 的逐日变化(用“Y”表示), 预报因子是与外缘线变化相关的大气和海洋要素(用“X”表示)。通过上一节

的分析, 将预报因子分为局地因子和大尺度环流因子两大类。局地因子包括辽东湾海域的气温、积温、海温、气压和 10 m 风东北向分量。大尺度环流因子为 2.2 节定义的对流层中层、低层和底层的 6 个关键区指数。此外, 将预报日期、起报前浮冰外缘线的实测值设定为预报的基础信息。LSTM 模型的参数设置见表 1, 各类预报因子及来源见表 2。

试验所用数据为 2005—2018 年, 将其分为两个时段, 2005—2016 年共 12 年作为训练集 (TRAIN), 2017—2018 年共 2 年作为验证集 (TEST)。

图 5 为 LSTM 方法建立预报模型流程图, 具体步骤为: ①用 LSTM 对训练集中的预报因子 (XTRAIN) 与预报目标 (YTRAIN) 进行训练, 将训练得到的结果存储为“NET”; ②调用“NET”, 输入测试集中的预报因

子(XTEST),计算得到预报目标(YPRED);③用测试集中的 YTEST 对计算得出的 YPRED 进行预报结果检验;④若通过检验,则保存 NET,在日常业务化预报时,只需调取 NET 并输入预报因子的值,即可得到预报值;若没有通过检验,则需返回第①步,调整预报因子和训练参数,重新训练模型。

检验时选用平均绝对误差(MAE)和均方根误差(RMSE)两个物理量作为衡量模型优劣的标准,其表达式如(1)和(2)所示。

$$MAE = \frac{1}{m} \sum_{i=1}^m |YPRED_i - YTEST_i|, \quad (1)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (YPRED_i - YTEST_i)^2}。 \quad (2)$$

表2 预报因子分类、名称及来源

Table 2 Classification, name and data source of forecast factors

	简称 Abbreviation	全称 Full name	数据来源 Data resource	备注 Remark
局地因子 Local factors	AT	气温	海洋站、GFS	/
	AAT	积温		前一年11月1日起日均气温的累积值
	NE-WND	东北风		海面10m风的东北向分量
	PRESS	气压		/
	SST	海温		海洋站
环流因子 Circulation factors	HGT500	500 hPa 位势高度关键区指数	NCEP Reanalysis 2, GFS	(60°N~80°N,60°E~140°E)~ (40°N~55°N,80°E~140°E)
	HGT850	850 hPa 位势高度关键区指数		(60°N~80°N,60°E~120°E)
	MSLP	平均海平面气压关键区指数		(55°N~75°N,60°E~120°E)
	AT500	500 hPa 气温关键区指数		(45°N~60°N,80°E~130°E)
	AT850	850 hPa 气温关键区指数		(40°N~60°N,80°E~140°E)
AT1 000	1 000 hPa 气温关键区指数	(40°N~65°N,80°E~140°E)		

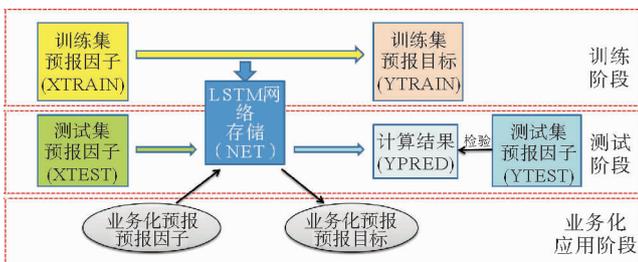


图5 LSTM方法建立预报模型流程图

Fig.5 Flow chart of LSTM for establishing forecast model

3.2 试验方案及结果检验

根据影响因子与预报目标的时间关系,本节共设计了5组试验,每组试验中由于所选因子类别不同,又

表1 LSTM模型参数设置

Table 1 Parameter settings of LSTM model

训练参数 Parameters	数值 Value
训练集 Training set/%	85
测试集 Test set/%	15
预测时长 Forecast time/d	15
历史时长 Historical time/d	15
训练周期数 Epoch	50
学习速率 Learning rate/s	0.005
集合预报成员 Ensemble members	10
误差检验 Error test	MAE、RMSE

包含4个分试验(见表3),每个分试验重复训练10次,求集合平均作为预报结果。下面介绍各试验的方案设计及预报检验情况。

试验1利用(t-15,t-14,...,t-1)共15天的预报因子观测值,对(t,t+1,...,t+14)共15天辽东湾浮冰外缘线建立预报模型。图6为试验1各分试验的预报检验结果,从左至右分别为单次预报(黑线)和集合预报(红线)的MAE、RMSE,以及2017、2018年预报值(黑线)与实测值(红线)的对比图。

从各试验MAE和RMSE结果可以看出,集合预报能够保证预报结果的稳定性,其误差低于单次训练误差,因而在建立模型和误差分析时,均采用集合预报

方法。首先分析试验 1-1 的预报结果,该模型的短期预报误差较小,随着预报时效增长误差增大,6 d 起误差基本保持不变,MAE 在 4.2~6.5 n mile 之间, RMSE 在 5.5~9.0 n mile 之间。从 2017 和 2018 年预报的外缘线变化与实测值对比来看(黑线为每日起报的 15 d 预报曲线,红线为浮冰外缘线的实测值),该模型总体上能够预报出浮冰外缘线的年循环趋势,但对于强生消过程,尤其是消融过程的模拟效果欠佳。该结果说明前期局地因子所含有的信息对 5 d 内的冰情变化具有较大影响,对 5 d 以上的冰情变化影响减弱。

试验 1-2 选用大尺度环流因子作为预报因子。与试验 1-1 相比,其 MAE 和 RMSE 在 1~15 d 预报中总体保持不变,但误差值明显偏大,MAE 在 7.0~8.0 n mile 之间, RMSE 在 10.0~11.0 n mile 之间。从逐日预报曲线也可以直观看出,该模型的预报效果次于试验 1-1,尤其是在海冰的生成阶段,但其对于海冰振荡过程的预报略好于试验 1-1。这是因为在只考虑大尺度环流,不考虑局地要素的情况下,模型无法获取海冰生成源地气温或海温等热力因子的信息,因而无法

模拟出海冰的生成时间以及高频变化。但大尺度环流中包含有未来一段时间海冰所在区域的天气形势变化信号,因此对海冰振荡过程的模拟效果有所好转。

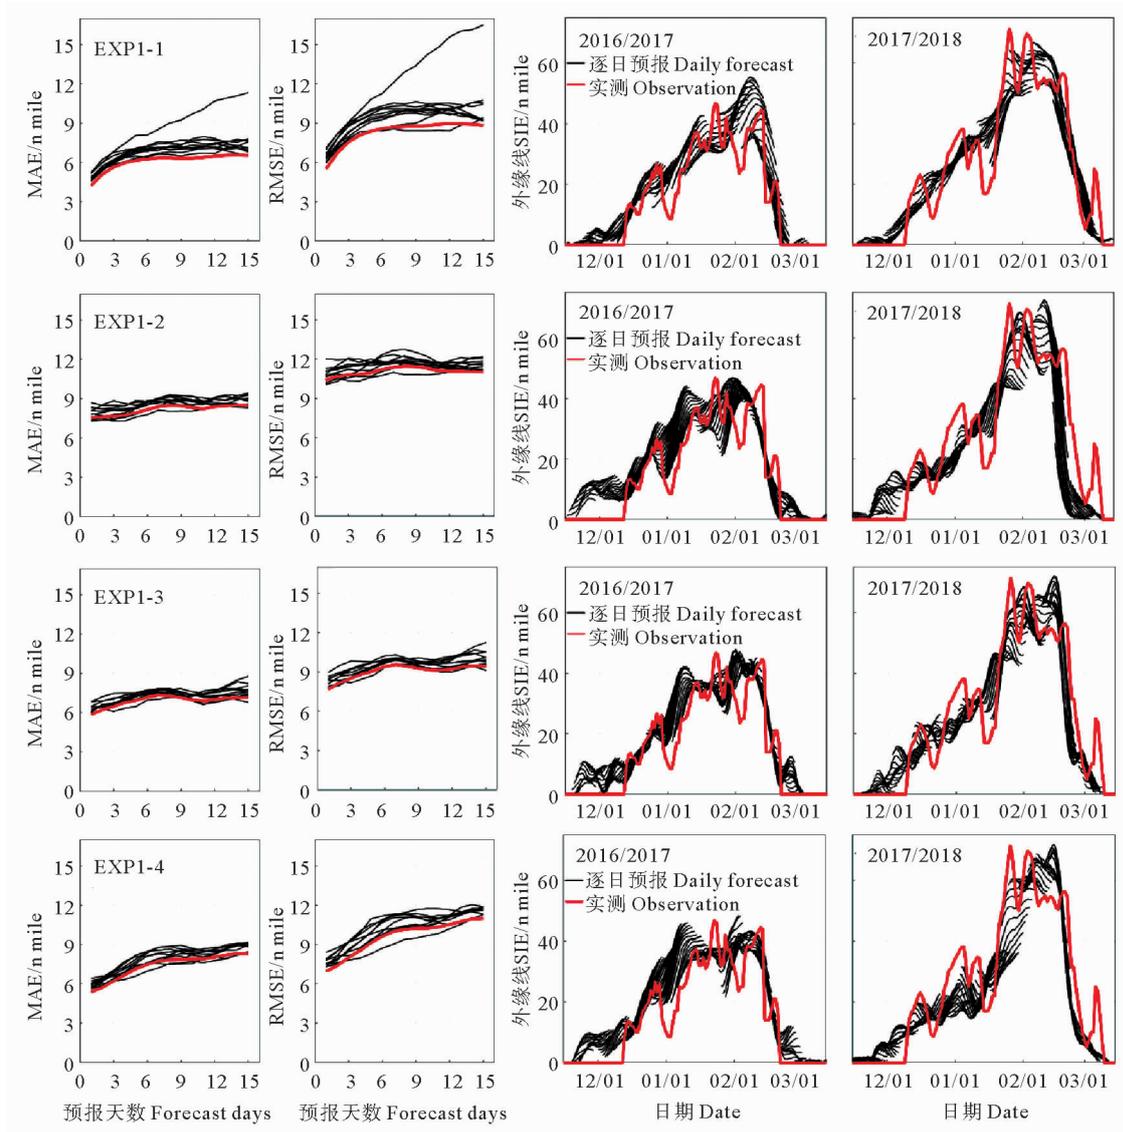
试验 1-3 选取了所有局地因子和大尺度环流因子作为预报因子来训练模型,结果表明,试验 1-3 的 MAE 和 RMSE 与试验 1-2 的分布型基本相同,但误差值比试验 1-2 减小 1.5~2.0 n mile,表明在环流因子的基础上增加局地因子,对提升模型预报效果有明显作用。但与试验 1-1 相比,试验 1-3 误差偏大 1.0 n mile 左右,说明局地因子是影响海冰变化的主要因子,在局地因子的基础上增加环流因子并不能提升预报效果,反而引入干扰信息,影响模型的准确性。试验 1-4 从局地因子和环流因子中选取部分与冰情变化相关性较高的因子(AT、NE-WND、PRESS、HGT500、HGT850、AT1000)进行试验,其预报效果并未较试验 1-3 有明显改进。

综合分析试验 1 中的 4 个分试验,使用局地因子预报的效果最好,其次是局地和环流因子的组合,只使用环流因子的预报效果不佳。然而,试验 1-1 对海冰生消过程的预报并不理想,因此考虑优化试验方案,寻求更好的预报效果。

表 3 试验设计方案

Table 3 Experimental design scheme

试验名称 Experiment	时间 Period	因子选取 Factor selection	数据来源 Data resource
Exp1-1	(t-15, t-14, ..., t-1)	局地	局地因子来源于葫芦岛海洋站观测,环流因子来源于 NCEP Reanalysis 2
Exp1-2		环流	
Exp1-3		局地+环流	
Exp1-4		部分局地+部分环流	
Exp2-1	(t, t+1, ..., t+14)	局地	局地和环流因子均来源于 GFS 预报数据
Exp2-2		环流	
Exp2-3		局地+环流	
Exp2-4		部分局地+部分环流	
Exp3-1	(t, t+1, ..., t+14)	局地	训练集采用实测数据,其中局地因子来源于海洋站观测,环流因子来源于 NCEP Reanalysis 2; 测试集来源于 GFS 预报数据
Exp3-2		环流	
Exp3-3		局地+环流	
Exp3-4		部分局地+部分环流	
Exp4-1	(t-15, t-14, ..., t+14)	局地	(t-15, t-14, ..., t-1)时段同试验 1; (t, t+1, ..., t+14)时段同试验 2
Exp4-2		环流	
Exp4-3		局地+环流	
Exp4-4		部分局地+部分环流	
Exp5-1	(t-15, t-14, ..., t+14)	局地	(t-15, t-14, ..., t-1)时段同试验 1; (t, t+1, ..., t+14)时段同试验 3
Exp5-2		环流	
Exp5-3		局地+环流	
Exp5-4		部分局地+部分环流	



(MAE 和 RMSE 的黑线为单次预报, 红线为集合预报; 浮冰外缘线变化的黑线为逐日预报, 红线为实测值。The red line of MAE and RMSE represents ensemble forecast and the black lines are 10 forecast members; the red line of SIE is observation value and the black lines are daily forecast results.)

图6 试验1各分试验预报结果及检验

Fig.6 Prediction results and tests of Experiment 1

试验2选取与海冰变化同期的预报因子进行模型训练。为保证业务化应用的可行性,本组试验所用的预报因子均从GFS数值模式的15d预报数据中提取(由于GFS无SST预报,在局地因子中去掉SST)。类比试验1,试验2也设计了4个分试验(见表3)。

由于篇幅所限,试验2至试验5不再给出每个分试验的预报值与实测值对比图,而是通过比较RMSE(见图7),选取最优方案后,再分析其预报结果。

试验2的RMSE整体较试验1偏低,表明使用与浮冰外缘线变化同期的海洋和大气要素作为预报因子,比选用前期因子的预报效果更佳。各分试验RMSE随预报时效增长的变化趋势基本一致,呈现出“短期持平,后期增长”的特征,其主要原因是GFS模式在短期内预报效果较好,6d以后预报误差逐渐增大,

使得LSTM模型在训练和测试中引入了不确定因素。

为优化试验2中GFS预报误差随时间增大给模型训练带来误差的问题,设计试验3。试验3在预报时间上与试验2相同,均采用同时刻预报,不同之处在于训练集采用历史观测数据,测试集仍采用GFS预报数据。本试验的目的是评估在训练关系准确,但测试集发生改变的情况下,与试验2训练集和测试集一致但均有误差的情况下,哪一种方案预报效果更优。从图7可知,除试验3-2外,试验3-1、3-3和3-4的预报误差基本相当,MAE在4.2~7.1n mile之间,RMSE在5.8~9.6n mile之间。与试验2相比,8~12d的预报结果有一定改善。

由前三组试验可以得出,使用同期预报因子比使用前期预报因子建模得到的预报效果更好。在此基础

上,为进一步提高预报准确率,减小试验误差,设计试验 4 和 5,尝试利用前期和同期预报因子共同建立模型,进行辽东湾浮冰外缘线预报。试验 4 为试验 1 和 2 的组合,试验 5 为试验 1 和 3 的组合。从预报结果看,试验 4-1 和试验 5-1 的误差较其它试验明显减小,尤其

是试验 4-1, RMSE 仅在 5.5~7.5 n mile 之间,且预报误差随着预报时效的增长并没有明显增长。该结果表明,将外缘线变化前期和同期的局地海洋和大气要素共同作为影响因子,训练得到的模型预报效果最优。

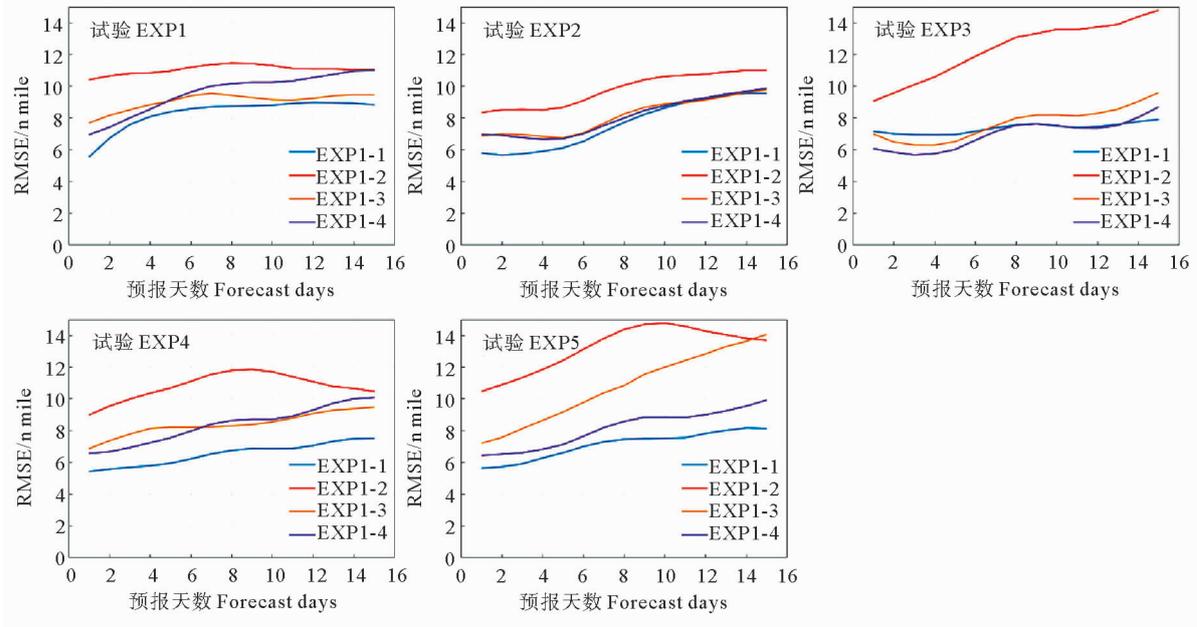


图 7 试验 1 至试验 5 的 RMSE 对比图
Fig.7 RMSE comparison of Experiment 1 to 5

3.3 最优模型选取

通过上一节各试验的 RMSE 对比分析,选取试验 4-1 为最优预报模型,图 8 给出了试验 4-1 的预报结果。该模型 1~15 d 预报的 MAE 仅为 4.1~5.7 n mile, RMSE 仅为 5.4~7.5 n mile。从预报值和实测值对比

可以直观地看出,无论是海冰的总体发展趋势、海冰的生消振荡过程,还是浮冰外缘线的峰值模拟方面,该模型均较之前建立的模型有明显提升。

因此本文选取试验 4-1 建立的 LSTM 模型,作为辽东湾浮冰外缘线延伸期预报模型。

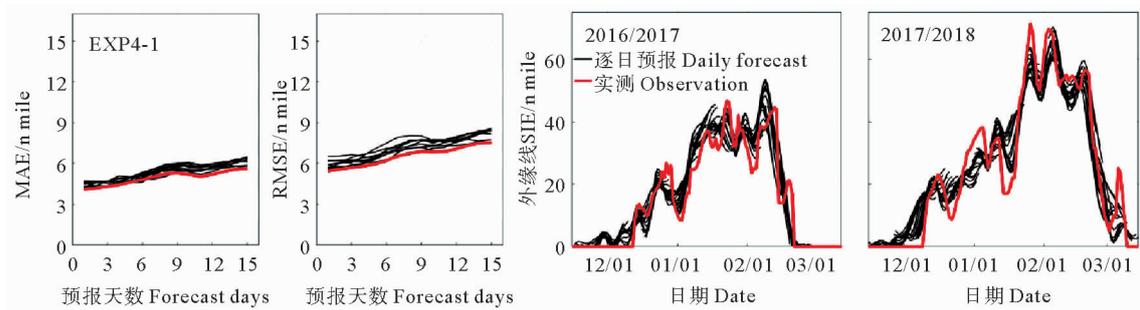


图 8 试验 4-1 预报结果及检验
Fig.8 Prediction result and test of Experiment 4-1

4 总结与讨论

本文首先分析了影响辽东湾浮冰外缘线变化的局地因子和大尺度环流因子,然后基于 LSTM 方法建立

了辽东湾浮冰外缘线的延伸期预报模型。在模型建立时,分别考虑了预报因子类别、来源及时间的不同,共设计了 5 组试验、20 个分试验。通过误差分析,选取出的最优预报模型能很好地模拟出未来 15 d 辽东湾浮冰

外缘线的总体发展趋势、生消振荡过程和峰值等关键特征,1~15 d 预报的 MAE 在 4.1~5.7 n mile 之间, RMSE 在 5.4~7.5 n mile 之间。

从空间上来看,局地影响因子建立的模型预报效果最好,说明海冰 15 d 以内的季节内变化主要受局地海洋和大气要素的影响;从时间上来看,选取浮冰外缘线变化前期和同期的影响因子共同建立模型,预报效果最好,说明海冰变化不仅受同期海洋和大气环境的影响,还受前期海洋和大气信号累积的影响。

将 LSTM 建立的最优预报模型与北海预报中心业务化运行的冰-海洋耦合数值预报模式(Couple Ice-Ocean Model, CIOM)的预报结果进行对比(见图 9),计算 1~6 d 误差平均值, LSTM 的 MAE 和 RMSE 分别为 4.4 和 5.7 n mile, CIOM 的 MAE 和 RMSE 分别为 4.4 和 5.5 n mile,表明二者在 1~6 d 的预报效果相当。与数值模式相比, LSTM 的运算速度极快,能够节省大量的计算资源,在浮冰外缘线预报中具有明显的优势。然而目前 LSTM 模型还不能完全取代数模式,因为该模型主要适用于时间序列的预报,尚不能进行海冰空间范围变化的预报。

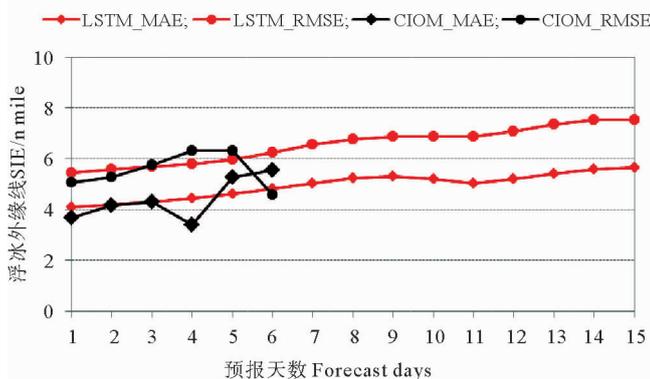


图 9 LSTM 模型与 CIOM 模式预报误差对比图

Fig.9 Comparison of errors between LSTM and CIOM model

LSTM 辽东湾海冰延伸期预报模型的建立,弥补了海冰数值模式和统计模式预报时效之间的“空白”,将海冰逐日定量化预报由 5~7 d 延长至 15 d,且该模型的运算成本低,在海冰业务化预报中具有广泛的应用前景。同时该模型的建立也为其它海洋、气象要素的预测预报提供了一种新的思路和方法。

参考文献:

[1] 张方俭. 我国的海冰[J]. 中国航海, 1982(2): 63-72.
Zhang F. Sea ice in our country[J]. Navigation of China, 1982(2): 63-72.

[2] Zhang J, Gao X. Heavy metals in surface sediments of the intertidal Laizhou Bay, Bohai Sea, China: Distributions, sources and contamina-

tion assessment[J]. Marine Pollution Bulletin, 2015, 98(1-2): 320-327.

- [3] 张方俭, 费立淑. 我国的海冰灾害及其防御[J]. 海洋通报, 1994(5): 75-83.
Zhang F J, Fei L S. Sea ice disasters and defence measures taken in China[J]. Marine Science Bulletin, 1994(5): 75-83.
- [4] 孙劭, 苏洁, 史培军. 2010 年渤海海冰灾害特征分析[J]. 自然灾害学报, 2011, 20(6): 087-93.
Sun S, Su J, Shi P-J. Features of sea ice disaster in the Bohai Sea in 2010[J]. Journal of Natural Disasters, 2011, 20(6): 087-93.
- [5] 王仁树, 刘旭世, 张立锟. 渤海海冰的数值试验[J]. 海洋学报, 1984, 6(5): 572-580.
Wang R S, Liu S X, Zhang L K. Numerical test of the sea ice in the Bohai Sea[J]. Haiyang Xuebao, 1984, 6(5): 572-580.
- [6] 吴辉斌. 海冰的动力-热力过程的数学处理[J]. 海洋与湖沼, 1991, 22(4): 321-328.
Wu H D. Dynamic-thermodynamic process of mathematical treatment of the sea ice[J]. Oceanologia Et Limnologia Sinica, 1991, 22(4): 321-328.
- [7] Su J, Wu H, Zhang Y, et al. A coupled ice-ocean model for the Bohai Sea I. Study on model and parameter[J]. Acta Oceanologica Sinica, 2004, 23(4): 597-608.
- [8] SU J, Wu H, Zhang Y, et al. A coupled ice-ocean model for the Bohai Sea II. Case study[J]. Acta Oceanologica Sinica, 2005, 24(3): 54-67.
- [9] 刘焯. 渤海海冰数值预报关键技术研究及应用[D]. 青岛: 中国海洋大学, 2013.
Liu Y. Key Technologies Research and Application of Sea Ice Numerical Forecast in the Bohai Sea[D]. Qingdao: Ocean University of China, 2013.
- [10] 王萌, 武胜利, 郑伟, 等. 长时间序列卫星遥感渤海海冰时空分布特征及与气温关系分析[J]. 气象, 2016, 42(10): 1237-1244.
Wang M, Wu S L, Zheng W, et al. Temporal spatial distribution of Bohai Sea sea ice in long time series and its correlation with air temperature[J]. Meteorological Monthly, 2016, 42(10): 1237-1244.
- [11] 李春花, 白珊, 刘钦政, 等. 渤海冰面积与营口气温的关系[J]. 海洋预报, 2008, 25(1): 1-4.
Li C H, Bai S, Liu Q Z et al. Correlativity between ice area at the bohai sea and air temperature of yingkou[J]. Marine Forecast, 2008, 25(1): 1-4.
- [12] 李彦青, 苏洁, 汪洋, 等. 渤海海冰外缘线候平均离岸距离的变化及其关键影响因子[J]. 中国海洋大学学报(自然科学版), 2013, 43(7): 7-16.
Li Y Q, Su J, Wang Y, et al. Variability of the pentadly average distance between the sea ice edge and the coast in the Bohai Sea and its key impact factors[J]. Periodical of Ocean University of China, 2013, 43(7): 7-16.
- [13] 药蕾, 苏洁. 渤海海冰与西伯利亚高压之间的关系及与北大西洋涛动之间的可能联系[J]. 中国海洋大学学报(自然科学版), 2018, 48(6): 1-12.
Yao L, Su J. Relationships Between Bohai sea ice and Siberian high and possible connections between Bohai sea ice and North Atlantic oscillation[J]. Periodical of Ocean University of China, 2018, 48(6): 1-12.

- [14] 唐茂宁, 洪洁莉, 刘煜, 等. 气候因子对渤海冰情影响的统计分析[J]. 海洋通报, 2015, 34(2): 152-157.
Tang M N, Hong J L, Liu Y, et al. Statistical analysis of climatic factors impacting on the Bohai Sea ice[J]. Marine Science Bulletin, 2015, 34(2): 152-157.
- [15] 周须文, 史印山, 井元元, 等. 基于逐旬滚动主成分回归分析的渤海海冰预测方法研究[J]. 海洋预报, 2015, 32(6): 74-79.
Zhou X W, Shi Y S, Jing Y Y et al. Research on prediction method of the sea ice in the Bohai Sea based on ten-days rolling principal component regression analysis[J]. Marine Forecast, 2015, 32(6): 74-79.
- [16] 焦艳, 曹丛华, 黎舸, 等. 基于海温遥相关的渤海冬季气温与海冰预测方法[J]. 海洋预报, 2017, 34(1): 19-24.
Jiao Y, Cao C H, Li G, et al. Prediction method of air temperature and sea ice in winter in the Bohai Sea and the Yellow Sea based on teleconnection[J]. Marine Forecast, 2017, 34(1): 19-24.
- [17] 孙国武, 冯建英, 陈伯民, 等. 大气低频振荡在延伸期预报中的应用进展[J]. 气象科技进展, 2012, 2(1): 12-18.
Sun G W, Feng J Y, Chen B M, et al. Advances in the application of atmospheric low-frequency oscillation on extended range forecast[J]. Advances in Meteorological Science and Technology, 2012, 2(1): 12-18.
- [18] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18: 1527-1554.
- [19] 杨函. 基于深度学习的气象预测研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
Yang H. Research on Weather Forecasting Based on Deep Learning[D]. Harbin: Harbin Institute of Technology, 2017.
- [20] Gao S, Zhao P, Pan B, et al. A nowcasting model for the prediction of typhoon tracks based on a long short term memory neural network[J]. Acta Oceanologica Sinica, 2018, 37(5): 8-12.
- [21] Shi X, Chen Z, Hao W, et al. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting [C]. Istanbul Turkey: International Conference on Neural Information Processing Systems, 2015.
- [22] Salman A G, Heryadi Y, Abdurahman E, et al. Weather forecasting using merged long short-term memory model (LSTM) and autoregressive integrated moving average (ARIMA) model[J]. Journal of Computer Science, 2018, 14(7): 930-938.
- [23] 高丽斌, 郭民权, 张少涵, 等. 基于长短期记忆网络的波高预报[J]. 福建电脑, 2018, 34(8): 109-111.
Gao L B, Guo M Q, Zhang S H et al. Wave height forecast based on LSTM[J]. Fujian Computer, 2018, 34(8): 109-111.
- [24] Christopher. Understanding LSTM Networks[J]. <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>, 2015.

Research on Extended-Range Forecast Model of Sea Ice in the Liaodong Bay Based on Long Short Term Memory Network

JIAO Yan^{1,2}, HUANG Fei¹, GAO Song², LIU Qing-Rong², JI Cheng-Zhen²,
WANG Ning², CAO Ya-Jing², YU Qing-Xi³

(1. The Key Laboratory of Physical Oceanography, Ocean University of China, Qingdao 266100, China; 2. North China Sea Marine Forecast Center, Qingdao 266061, China; 3. North China Sea Data & Information Service, Qingdao 266061, China)

Abstract: In this paper, the local and large-scale circulation factors affecting the variation of sea ice in the Liaodong Bay are studied by composite analysis and regress analysis, and then an extended-range forecast model of sea ice edge (SIE) in the Liaodong Bay is established based on a deep learning method—Long Short Term Memory Network (LSTM). The results show that the LSTM model can well predict the variation trend, generation and dissipation oscillation, peak and other key characteristics of the SIE in the Liaodong Bay in the next 15 days. The MAE varies from 4.1 to 5.7 n miles, and RMSE varies from 5.4 to 7.5 n miles, which is consistent to the sea ice numerical forecasting model. But the LSTM model extends the period of validity to 15 days, as twice as that of the numerical forecast (5~7). Besides, the operation speed is extremely fast, which can save a lot of computing resources and time cost. The establishment of this model provides a new idea for forecasting other marine and meteorological variables with deep learning method.

Key words: sea ice in the Liaodong Bay; extended-range forecasting; LSTM; deep learning