

基于LSTM的北极海冰范围多步预测策略研究

王漫漫^{1,2,3,4}, 邹斌^{2,3*}, 石立坚^{2,3}, 曾韬^{2,3}, 张颖^{2,3}, 路敦旺^{1,2,3}

(1. 国家海洋环境预报中心, 北京 100081; 2. 国家卫星海洋应用中心, 北京 100081; 3. 自然资源部 空间海洋遥感与应用研究重点实验室, 北京 100081; 4. 国家海洋环境预报中心 自然资源部海洋灾害预报技术重点实验室, 北京 100081)

摘 要: 已有研究对北极海冰范围开展单步预测, 而多步预测及其策略研究有待进一步探索。使用 1979—2022 年的北极月平均海冰范围数据, 采用长短期记忆网络(LSTM)深度学习方法, 结合递归(Recursive)、直接(Direct)、多输入多输出(MIMO)和 Seq2Seq 策略实现对未来 12 个月北极海冰范围的多步预测。结果表明: 24 个月为模型的最佳输入长度; 与另外 3 种基本的多步预测策略相比, Seq2Seq 策略对 12 个月北极海冰范围预测的准确性更好, 均方根误差为 $3.30 \times 10^5 \text{ km}^2$ 。

关键词: 北极海冰范围; 长短期记忆网络; 多步预测策略; Seq2Seq 策略

中图分类号: P731.32 **文献标识码:** A **文章编号:** 1003-0239(2025)01-0011-12

0 引言

过去几十年中, 北极地区温度的上升速度是全球平均速度的近 4 倍^[1], 这种被称为“北极放大”的快速变暖现象已经对北极海冰产生了显著的影响, 具体表现为海冰的退缩和变薄^[2]。海冰密集度(Sea Ice Concentration, SIC)作为描述海冰的主要参数之一, 是指一定区域内海冰面积所占百分比。将 15% 海冰密集度值作为阈值来区分有冰区和无冰区, 有冰区面积之和被定义为海冰范围(Sea Ice Extent, SIE), 它是一个广泛应用于气候变化研究的重要因子^[3]。自 1979 年有卫星观测以来, 北极海冰范围持续下降^[4], 且近 20 年的下降趋势有所增加^[5]。2012 年 9 月 15 日, 北极海冰范围约为 $3.34 \times 10^6 \text{ km}^2$, 达到历史最低水平; 2020 年 9 月 15 日, 北极海冰范围约为 $3.74 \times 10^6 \text{ km}^2$, 为历史第二低值, 比 1980—2010 年的平均值($6.27 \times 10^6 \text{ km}^2$)约小 40%。如果照此下降趋势, 北极可能会在 2020—2030 年的 9 月首次出现无冰现象(指海冰面积低于 $1.00 \times 10^6 \text{ km}^2$), 而到 2035—2067 年, 北极 9 月的无冰情况可能会频繁出

现^[6]。北极海冰损失会影响到天气与气候系统^[7-8]、海洋环流系统^[9]和极地生态系统^[10], 因此预测北极海冰水平对研究气候变化和规划恢复措施至关重要。

北极海冰预测方法主要包括 3 种, 数值模式、统计和机器学习^[11]。海冰数值模式^[12]描述了大气-海冰-海洋的复杂相互作用和冰内物理过程, 可以为北极海冰范围提供合理预测, 但是该方法需要应用复杂的专业物理知识以及大量的计算资源。统计方法则是通过建立北极海冰范围与大气和海洋变量之间的关系来进行预测, 这类方法比海冰数值模式更容易实现, 但是它无法较好地捕捉变量之间的非线性关系^[13]。近年来, 深度学习已经越来越多地被用于北极海冰预测研究。CHI 等^[14]首次使用长短期记忆(Long Short-Term Memory, LSTM)方法构建未来 1 个月的北极 SIC 预测模型, 该模型的唯一输入变量是前 12 个月的 SIC, 利用该方法对 2015 年的月度 SIC 进行预测, 均方根误差(Root Mean Square Error, RMSE)达到 8.89%。之后, 他们使用递归(Recursive)策略实现了对未来 12 个月的北极 SIC

收稿日期: 2023-11-22。

基金项目: 国家重点研发计划项目(2021YFC2803300、2022YFC2807003)。

作者简介: 王漫漫(1999-), 女, 硕士在读, 主要从事深度学习北极海冰参数预测研究。E-mail: manmanwang_ella@163.com

*通信作者: 邹斌(1969-), 男, 研究员, 硕士, 主要从事卫星遥感海洋应用研究。E-mail: zoubin@mail.nsoas.org.cn

以及2015年月度海冰范围的预测,其中预测的2015年9月的海冰范围为 $4.99 \times 10^6 \text{ km}^2$,与观测值的差异为+7.54%。ALI等^[15]比较了不同的基于机器学习和深度学习的海冰范围预测技术,提出了一种多时相集成模型,该模型将日一月的预测网络(d-LSTM)与月一月的预测网络(m-LSTM)集成起来,以此进行未来1个月的海冰范围预测,2014—2018年模型预测结果的平均RMSE为 $5.86 \times 10^5 \text{ km}^2$ 。相较于其他方法,该模型的预测值与观测值最一致,且能更好地预测7—9月融化季节的北极海冰范围。KIM等^[16]基于卷积神经网络(Convolutional Neural Networks, CNN)和卷积LSTM(Convolutional LSTM, ConLSTM)方法并结合自定义损失函数,设计了两种多任务学习模型,同时实现了对未来1个月北极SIE与SIC的预测。该研究使用1979—2012年的数据进行训练,对2014—2020年的数据进行测试,研究提出的多任务CNN与多任务ConLSTM预测海冰范围在测试集上的RMSE分别为 $5.36 \times 10^5 \text{ km}^2$ 与 $3.33 \times 10^5 \text{ km}^2$ 。

目前,已有的北极海冰范围深度学习研究都是针对月度开展预测,其往往局限于单步的中短期预测,缺乏中长期研究;并且都是先进行SIC预测,在此基础上计算海冰范围,这种预测模型的建立需要较大的计算量。此外,在未来中长期海冰预测研究中,选择预测策略需要更加深入详细。针对上述问题,本文在LSTM方法的基础上,采用4种多步预测策略对1979—2022年北极月度海冰范围构建预测模型,尝试预测未来12个月的月平均海冰范围。本研究可为北极海冰范围变化和全球气候变化预测提供参考。本文结构如下:第1节介绍使用的数据以及研究方法,第2节描述实验方案,第3节比较不同的预测策略和不同时间序列的输入数据对预测结果的影响,以确定较优的预测模型并进一步评价分析。

1 数据与研究方法

1.1 数据及预处理

1.1.1 海冰密集度产品

美国国家冰雪数据中心(National Snow and Ice Data Center, NSIDC)发布的SIC数据集是在

Nimbus-7扫描多通道微波辐射计(Scanning Multifrequency Microwave Radiometer, SMMR)、国防气象卫星计划(Defense Meteorological Satellite Program, DMSP)-F8/-F11/F13专用传感器微波成像仪和DMSP-f17专用传感器微波成像仪/探测仪获取的亮温数据的基础上,由NASA Goddard太空飞行中心冰冻圈科学实验室开发的NASA Team(NT)算法反演得到^[17]。该数据集涵盖了1978年10月26日至今的日平均和月平均SIC,数据投影方式为NSIDC极地立体投影,空间分辨率为 $25 \text{ km} \times 25 \text{ km}$ 。季节与海冰状态等因素会影响NT算法反演海冰密集度的准确性,冬季反演值与真实值相差 $\pm 5\%$,而夏季由于海冰表面融池的影响,误差可达 $\pm 15\%$ 。本文使用的月平均海冰范围数据由月平均SIC网格单元数据计算得到,公式为:

$$Y_E = \sum_i \sum_j \begin{cases} A[i, j], & \text{if } Y_c[i, j] \geq 15\% \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

式中: $A[i, j]$ 为像素在 $[i, j]$ 处的面积,若该处的SIC值 $\geq 15\%$,则记录该处面积,否则不记录;遍历所有网格单元,将所有 $SIC \geq 15\%$ 的面积求和得到海冰范围。

1987年12月与1988年1月时间序列的海冰范围数据存在缺失,为了保证数据的连续性,需要对缺失数据进行插值。本文采用1986年12月与1988年12月平均海冰范围作为1987年12月海冰范围数据,1987年1月与1989年1月平均海冰范围作为1988年1月海冰范围数据。此外,北极海水的冰冻和融化存在季节性特征,海冰范围在3月达到顶峰,9月处于低谷;1979年3月海冰范围最大,为 $16.34 \times 10^6 \text{ km}^2$,2012年9月最小,为 $3.57 \times 10^6 \text{ km}^2$,可见不同时段的海冰范围存在数量级差异。为了取消数据间的数量级差别,提高模型训练效果,需要对海冰范围的时间序列数据进行归一化预处理。本文使用最大值最小值归一化方法,归一化后的数据范围为0~1。归一化公式为:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

式中: x 为海冰范围; x_{\min} 为最小海冰范围; x_{\max} 为最大海冰范围; x^* 为归一化后的海冰范围。

1.1.2 数值模式海冰预报产品

为了对深度学习预测结果进行评价,本研究还

使用了基于数值模式的海冰密集度预报产品^[18],该产品来自哥白尼气候变化服务季节性预报数据库,由欧洲中期天气预报中心(European Centre for Medium-Range Weather Forecasts, ECMWF)最新一代季节性预报系统 SEAS5 产生(以下用 SEAS5 表示海冰密集度预报产品)。SEAS5 系统中的海冰模型采用欧洲海洋核心模式 NEMO (Nucleus for European Modeling of the Ocean)框架中的 Louvain-la-Neuve 海冰版本 2 (LIM2)。研究选取预测年份(2019—2022年)的数值模式月度预测 SIC 产品,该产品的经纬度网格为 $0.25^\circ \times 0.25^\circ$ 。首先将模式预报产品从经纬度网格重新网格化到 NSIDC 极地立体投影,使其分辨率和范围与 NSIDC 海冰密集度数据相同,然后根据式(1)计算海冰范围,并与深度学习预测结果进行比较。

1.2 LSTM

LSTM 是循环神经网络 (Recurrent Neural Networks, RNN) 的优化算法^[19]。它通过向 RNN 中引入门控制结构来控制历史信息的传播,避免了 RNN 算法中存在的梯度消失和梯度爆炸问题,解决了长序列数据的依赖问题,提高了数据预测的精度。北极海冰范围变化具有明显的周期性,而 LSTM 能够捕捉时序数据中的长期依赖关系,因此适用于北极海冰范围预测。

LSTM 的核心内容是 3 个门与两条更新路线,原理为:

门控结构通过将元素与门的输出向量相乘来实现对信息的控制,其中遗忘门(f_t)选择性遗忘上一时刻不重要的信息,输入门(i_t)选择性记忆当前位置的重要信息,输出门(o_t)用于调整短期记忆的

权重。公式为:

$$f_t = \sigma(W_f \cdot [C_{t-1}, h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i \cdot [C_{t-1}, h_{t-1}, x_t] + b_i) \quad (4)$$

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

式中: C_{t-1} 、 C_t 为分别为上一时刻与当前时刻的细胞状态; h_{t-1} 为上一时刻细胞状态的输出值; x_t 为当前时刻的输入值; W 为待训练的权重; b 为偏置; σ 为激活函数。

细胞状态 C_t 的更新是通过对上一时刻细胞状态 C_{t-1} 的选择性遗忘与当前时刻候选态 \tilde{C}_t 的选择性记忆共同组成。更新公式为:

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (7)$$

式中: \tanh 为激活函数; \tilde{C}_t 为候选态,即当前时刻的信息。

隐藏状态的更新,是通过对更新后的细胞状态 \tilde{C}_t 特征进行提取和保留的结果,更新公式为:

$$h_t = o_t * \tanh(C_t) \quad (8)$$

1.3 时间序列多步预测策略

多步预测是使用历史时间序列数据对未来一段时间的值进行预测。以北极月平均海冰范围预测为例,单步预测是将 N 时刻前 d 个历史北极月平均海冰范围作为输入值,预测 $N+1$ 时刻月平均海冰范围;多步预测则是输入值不变,但要实现对未来 H 步的月平均海冰范围预测,其原理见图 2。输入序列记为 $[x_{N-d+1}, \dots, x_{N-1}, x_N]$, 输出序列记为 $[y'_{N+1}, \dots, y'_{N+H}]$, 输入数据与输出数据之间的依赖关系记为 f , 因此预测未来 H 个北极月平均海冰范围值为:

$$[y'_{N+1}, \dots, y'_{N+H}] = f(x_{N-d+1}, \dots, x_{N-1}, x_N) \quad (9)$$




图1 LSTM原理^[20]

Fig.1 Structure of the LSTM^[20]




图2 海冰范围多步预测原理

Fig.2 Multi-step prediction principle of SIE

多步预测可通过不同的策略实现,这些策略在误差积累或对时间依赖性等方面存在不同优势。目前常用的多步预测策略包括递归(Recursive)、直接(Direct)和多输入多输出(Multi-input Multi-

$$\hat{y}_{N+h} = \begin{cases} \hat{f}(x_N, \dots, x_{N-d+1}), & \text{if } h = 1 \\ \hat{f}(\hat{y}_{N+h-1}, \dots, \hat{y}_{N+1}, x_N, \dots, x_{N-d+h}), & \text{if } h \in \{2, \dots, d\} \\ \hat{f}(\hat{y}_{N+h-1}, \dots, \hat{y}_{N-h-d}), & \text{if } h \in \{d+1, \dots, H\} \end{cases} \quad (11)$$

为了实现 Recursive 多步预测,需要不断加入单步预测结果作为输入,而为了保持输入数据维度的一致性,还需要不断舍弃真实值。这种操作使得输入数据中的真实值越来越少,而存在误差的预测值占比增加,且误差还会在预测过程中积累,因此,递归策略不适合用于较长期的多步预测。

1.3.2 直接(Direct)策略

Direct 多步预测^[22-23]是在单步预测的基础上,通过多次单步预测来实现多步预测(见图 3b)。输出

output, MIMO)^[21]。

1.3.1 递归(Recursive)策略

Recursive 多步预测^[22-23]是在单步预测模型的基础上,通过迭代实现多步预测(见图 3a)。在这个策略中,需要训练一步预测模型 f 并完成模型学习。步骤为:

$$y_{t+1} = f(x_t, \dots, x_{t-d+1}) + w \quad t \in \{d, \dots, N-1\} \quad (10)$$

进行 H 步预测时,首先用已知数据进行单步预测并得到结果,将其作为下一步预测输入变量的一部分,以此类推,直到 H 步预测完成。 H 预测步长内各步预测值为:

模型 f_h 为:

$$y_{t+h} = f_h(x_t, \dots, x_{t-d+1}) + w \quad t \in \{d, \dots, N-1\}, h \in \{1, \dots, H\} \quad (12)$$

进行 H 步预测时,使用相同的输入构建 H 个模型,每个模型预测 H 步中的一步,例如模型 1 实现提前第一步预测,模型 2 实现提前第二步预测,以此类推, H 个模型就能够实现 H 步预测。 H 预测步长内各步预测值为:

$$\hat{y}_{t+h} = \hat{f}_h(x_N, \dots, x_{N-d+1}) \quad (13)$$

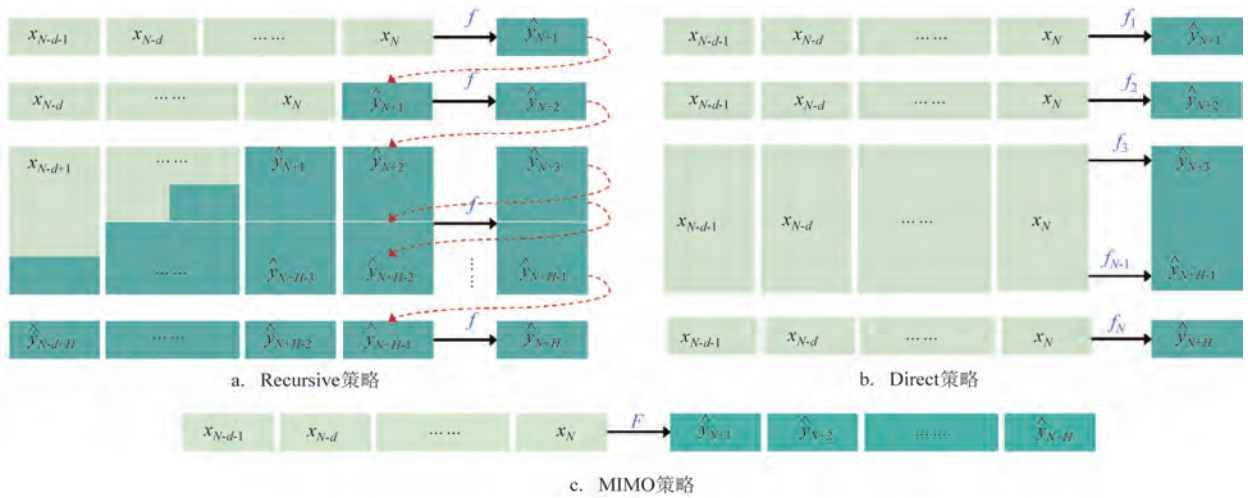


图3 Recursive策略、Direct策略与MIMO策略

Fig.3 Recursive, Direct, and MIMO strategies

Direct 多步预测对每个预测值单独建立模型,输入数据都是真实值,不存在预测值作为输入所带来的误差累积。然而,它将 H 个模型进行独立训练,忽略了 H 个预测值之间的时间依赖关系。

1.3.3 多输入多输出(MIMO)策略

Recursive 和 Direct 多步预测都属于单输出^[24],即每次输出一个预测值,通过多次使用模型或者多次迭代模型实现多步预测输出。MIMO 多步预测^[25]是构建一个模型,实现一次预测输出未来多个预测值,此时的预测值是包含多个输出的向量(见图 3c)。MIMO 策略模型 F 为:

$$[y_{t+H}, \dots, y_{t+1}] = F(x_N, \dots, x_{N-d+1}) + w \quad (14)$$

$$t \in \{d, \dots, N-1\}$$

进行 H 步预测时,使用一组历史数据构建 1 个模型 F ,输出值为模型 F 预测 H 步中的每一步。 H 预测步长内各步预测值为:

$$[\hat{y}_{t+H}, \dots, \hat{y}_{t+1}] = \hat{F}(x_N, \dots, x_{N-d+1}) \quad (15)$$

MIMO 的基本原理是在预测值之间保持表征时间序列的随机依赖性。这种策略避免了 Direct 策略做出的条件独立假设,也避免了 Recursive 策略中由于迭代所产生的预测误差积累。

1.3.4 Seq2Seq 策略

Seq2Seq^[26]即序列到序列,是一个编码器到解码器(Encoder-Decoder)结构的网络。Seq2Seq 诞生之初主要是为解决 RNN 无法处理不定长配对的问题,其结构可以很好地处理时间序列多步预测问题。从输入序列到输出序列的角度来看,Seq2Seq 策略也属于 MIMO 策略的一种,Seq2Seq 策略模型 F 同式(14), H 预测步长内各步预测值同式(15)。

图 4 为 Seq2Seq 网络结构,输入值为前 d 个月的海冰范围数据, $h(x)$ 和 $g(x)$ 分别表示 LSTM 层中的隐藏单元。编码器将输入序列转化为上下文向量 C ,解码器将 C 转化为输出序列。相比于其他策略强调模型结构的深度,Seq2Seq 策略的多步预测模型更突

出特征学习的重要性。Seq2Seq 策略通过逐层特征变换,将样本在原空间的特征表示变换到新空间,并将时间和外部特征进行编码、解码的高维度映射,强调了输出序列之间的依赖性^[27],预测结果更准确。

2 实验方案设计

2.1 多步预测方案

2.1.1 模型构建

深度学习模型是为了挖掘输入数据与输出数据之间的关系,所以在本研究中需要将时间序列海冰范围数据转化为有监督的数据对,并且需要满足模型输入数据的条件;以 MIMO 策略为例,使用 LSTM 模型进行多步预测,需要构建输入数据的形状为 (Batch_size, Timesteps_in, Features),输出数据的形状为 (Batch_size, Timesteps_out, Features),其中 Batch_size 是指每次输入模型的个数, Timesteps_in 和 Timesteps_out 分别指输入和输出步长, Features 指特征数。若输入长度与输出长度均为 12 个月,则输入数据形状 (32, 12, 1),输出数据形状 (32, 12, 1)。

LSTM 框架包括数据输入层、LSTM 层、全连接层和输出层。本研究使用两层 LSTM 隐藏层,每层各有 256 个 LSTM 单元,单输出多步预测时全连接层输出为 1,多输出多步预测时全连接输出层为 12。损失函数使用均方误差 (Mean Square Error, MSE),学习率为 0.000 3,批量大小为 32,使用 Adam 优化器,对模型进行 500 次 epoch 的训练,直到模型收敛。

2.1.2 模型训练

完成样本数据的处理与模型结构的搭建后,就可以将数据输入模型进行训练,经过多次训练可以确定权重的最优解,其反映了输入与输出数据之间的对应关系。训练效果可以通过训练集损失 (train_loss) 与验证集损失 (val_loss) 确定,当两者都逐渐减小说明训练正常,当损失趋于平稳说明模型




图4 Seq2Seq 网络结构

Fig.4 Seq2Seq network structure

收敛,可结束训练。

由于近年来北极海冰范围正在急剧下降,许多研究认为相较历史序列数据,较近的数据会为未来一段时间的预测提供更多有用的特征信息^[14,28-29],这些研究从整个数据集中划分了尽可能多的数据用于训练。因此,本文将预测年份之前的所有历史序列数据全部进行训练和验证,例如针对2019年的预测,训练数据为1979—2015年,验证数据为2016—2018年,其余3个年份数据集的划分类似,具体设置见表1。由于模型训练具有不确定性,本文对每一组实验均进行10次训练。

表1 数据集划分

Tab.1 Dataset split

模型	训练年份	验证年份	预测年份
Model2019	1979—2015	2016—2018	2019年
Model2020	1979—2016	2017—2019	2020年
Model2021	1979—2017	2018—2020	2021年
Model2022	1979—2018	2019—2021	2022年

2.2 模型评估

本文采用几种常见的统计指标,即RMSE、平均

绝对误差(Mean Absolute Error, MAE)和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)来评价模型的预测性能,它们均能反应预测值与真实值的偏差。

3 结果与分析

本节首先比较不同的多步预测策略并选择出最优策略,在此基础上探讨输入长度对预测结果的影响,确定最佳输入长度,最后使用最优策略和最佳输入长度构建多步预测模型,并对2019—2022年北极月度海冰范围进行多步预测,探讨模型的预测能力以及预测误差产生的原因。

3.1 多步预测策略比较

为了探索最优的多步预测策略,本文使用LSTM结合1.3节的4种多步预测策略对未来12个月的北极月平均海冰范围进行预测(输入长度为前12个月的数据)。表2为采用不同策略实现的多步预测在2019—2022年的评估情况。从整体上看,Recursive、Direct、MIMO和Seq2Seq策略的预测效果依次升高,其中Direct与MIMO策略的预测能力

表2 2019—2022年4种策略海冰范围预测结果的评估情况

Tab.2 Assessment of SIE predictions for four strategies from 2019 to 2022

年份	误差类别	策略			
		Recursive	Direct	MIMO	Seq2Seq
2019	RMSE/($\times 10^5 \text{ km}^2$)	5.53	4.87	4.55	3.68
	MAE/($\times 10^5 \text{ km}^2$)	4.38	3.63	3.65	3.02
	MAPE/%	6.09	5.35	5.08	3.70
2020	RMSE/($\times 10^5 \text{ km}^2$)	7.40	4.42	4.10	5.20
	MAE/($\times 10^5 \text{ km}^2$)	5.79	3.31	3.08	3.67
	MAPE/%	8.54	4.73	4.18	5.29
2021	RMSE/($\times 10^5 \text{ km}^2$)	6.26	5.75	5.42	3.08
	MAE/($\times 10^5 \text{ km}^2$)	5.14	4.61	4.56	2.54
	MAPE/%	6.13	6.11	5.75	3.30
2022	RMSE/($\times 10^5 \text{ km}^2$)	3.59	2.94	2.87	2.84
	MAE/($\times 10^5 \text{ km}^2$)	2.95	2.46	2.41	2.36
	MAPE/%	3.40	2.74	2.71	2.81
平均	RMSE/($\times 10^5 \text{ km}^2$)	5.70	4.49	4.24	3.70
	MAE/($\times 10^5 \text{ km}^2$)	4.57	3.50	3.42	2.90
	MAPE/%	6.04	4.73	4.42	3.77

相近,且较Recursive策略有较大提升,而Seq2Seq策略总体预测效果最佳, RMSE、MAE、MAPE分别为 $3.70 \times 10^5 \text{ km}^2$ 、 $2.90 \times 10^5 \text{ km}^2$ 、3.77%。从各个年份上看,Recursive策略的预测能力与总体结果相似,远低于其他3种策略,这可能是由于随着迭代步数的增加,预测误差不断积累,导致整体预测精度下降。Direct策略仅有2019年的MAE略低于MIMO策略,其余年份的评价指标均高于MIMO策略,这可能是由于Direct策略忽略了月度北极海冰范围数据之间的时间相关性,因此影响了预测精度。MIMO策略由于一次输出所有预测值,避免了

Direct策略做出的条件独立假设,也避免了Recursive策略中由于迭代所产生的预测误差积累,因此预测精度较高。Seq2Seq策略是对MIMO策略的改进,即在一次输出所有值的基础上,将序列数据进行编码器到解码器的高维度映射,它强调了输出序列之间的序列依赖性,预测结果更准确。尽管Seq2Seq策略在2020年的预测性能略低于MIMO策略,但是从整体上看,Seq2Seq策略的预测精度较其他3种策略更高,说明其预测性能更稳定,因此可用于月平均北极海冰范围多步预测。

3.2 输入长度对预测结果的影响

在不同预测策略评估结果的基础上,利用Seq2Seq策略研究输入长度对预测能力的影响,输入长度分别设置为6、12、18、24、30、36个月。2022年不同输入长度预测10次平均结果的相对误差见图5, RMSE统计结果见表3。从结果来看,6、30、36个月作为输入长度得到的预测结果的平均相对误差大都高于12、18、24个月的预测结果,10次平均的RMSE标准差较大,分别为 $3.75 \pm 1.05 \times 10^5 \text{ km}^2$ 、 $3.89 \pm 1.16 \times 10^5 \text{ km}^2$ 、 $4.10 \pm 1.30 \times 10^5 \text{ km}^2$ 。这可能是由于6个月的输入长度太短,无法同时包括海冰变化周期中的峰值与谷值,导致模型无法学习到极




图5 不同输入长度预测结果的平均相对误差(2022年)

Fig.5 Average relative error of predictions for different input lengths (2022)

表3 2022年10次预测结果的RMSE(单位: $\times 10^5 \text{ km}^2$)

Tab.3 RMSE for 10 predictions in 2022 (unit: $\times 10^5 \text{ km}^2$)

误差类别	输入长度					
	6个月	12个月	18个月	24个月	30个月	36个月
RMSE ₁	3.11	3.38	2.61	2.30	3.71	2.99
RMSE ₂	3.37	2.96	2.61	3.81	4.90	3.61
RMSE ₃	3.11	3.56	2.55	2.52	3.37	3.64
RMSE ₄	3.36	2.88	4.69	2.46	3.78	3.53
RMSE ₅	3.10	2.36	2.59	2.23	3.81	4.19
RMSE ₆	6.51	2.11	3.17	2.64	2.11	2.10
RMSE ₇	3.16	3.43	2.61	2.35	6.54	4.91
RMSE ₈	3.61	2.68	2.45	2.37	3.52	4.87
RMSE ₉	3.84	3.32	2.64	2.49	3.96	6.90
RMSE ₁₀	4.39	1.69	1.99	2.29	3.23	4.23
$\overline{\text{RMSE}}$	3.75	2.84	2.79	2.55	3.89	4.10
标准差	1.05	0.44	0.72	0.46	1.16	1.30

值特征,增加了极值预测的不确定性。与30个月的输入长度相比,36个月的预测效果更差,这可能因为预测时间过长,会削弱近期历史海冰范围序列与未来海冰范围序列的相关性,同时导致输入信息冗余,训练时间增加。在大部分月份中,12、18、24个月输入长度的预测误差相当,平均RMSE分别为 $2.84 \times 10^5 \text{ km}^2$ 、 $2.79 \times 10^5 \text{ km}^2$ 、 $2.55 \times 10^5 \text{ km}^2$;18、24个月的输入长度中所有月份的相对误差均小于6%,而12个月的输入长度在8、9月的相对误差超出6%,且远高于另外两种输入长度;18个月作为输入长度的RMSE标准差为 $0.72 \times 10^5 \text{ km}^2$,高于24个月的 $0.42 \times 10^5 \text{ km}^2$ 。综上,使用24个月作为输入长度得到的预测结果误差较小,且多次预测结果的差异较小,模型相对更加稳定。因此,对于未来12个月北极月度海冰范围预测,本文合理选择24个月的历史海冰范围序列数据作为输入长度构建预测模型。

3.3 LSTM+Seq2Seq策略预测表现

根据上述结果,本文选用的模型输入长度为24个月,且使用Seq2Seq策略进行未来12个月的月度北极海冰范围预测。本文对每一组数据集进行10次训练,得到平均预测结果和最佳预测结果,前者代表模型的整体预测性能,后者代表模型捕获月度海冰范围特征的能力。此外,本文还使用了预测年份的数值模式海冰预报产品SEAS5来对LSTM+Seq2Seq的预测结果进行评价。从表4可知,2019年和2020年LSTM+Seq2Seq的平均RMSE高于SEAS5,原因可能是这两年融冰期(7—11月)的海冰范围较往年大幅度降低,本文使用的深度学习模型是没有加入物理参量的纯数据驱动模型,因此对海冰范围极端变化预测的准确度有待提升。SEAS5预报产品在测试年份的误差平稳,平均RMSE为 $3.34 \times 10^5 \text{ km}^2$,LSTM+Seq2Seq模型预测的平均

RMSE相近,为 $3.30 \times 10^5 \text{ km}^2$,最佳RMSE为 $2.67 \times 10^5 \text{ km}^2$,这表明经过多次训练,LSTM+Seq2Seq模型能够在某些年份获得较好的预测结果,整体预测能力与数值模式预报相当。


自2008年以来,海冰预测网络(Sea Ice Prediction Network, SIPN)每年都会在6—8月征集海冰展望(Sea Ice Outlook, SIO)^[30],收集来自全球研究人员对9月北极海冰范围的预测。为了进一步评估LSTM+Seq2Seq的性能,本文与SIO收集的9月海冰范围预测结果(提前期为1个月)进行比较。2022年、2021年SIO分别收到22份与36份提交报告(见图6),这些预测基于动力学(基于物理的)模型、统计方法、机器学习以及启发式方法。2022年9月海冰范围观测值为 $4.90 \times 10^6 \text{ km}^2$,LSTM+Seq2Seq的预测值为 $4.89 \times 10^6 \text{ km}^2$,误差仅为 $0.10 \times 10^5 \text{ km}^2$,在SIO的22个预测值中处于第二位。2021年9月海冰范围观测值为 $4.95 \times 10^6 \text{ km}^2$,LSTM+Seq2Seq的预测值为 $4.66 \times 10^6 \text{ km}^2$,误差为 $2.9 \times 10^5 \text{ km}^2$,在SIO的36个预测值中处于前1/3位置,再次说明了LSTM+Seq2Seq预测结果的合理性以及在月度海冰预测中的潜力。

图7的折线为2019—2022年各年海冰范围观测值与对应的预测结果,柱状图为月海冰范围观测值与预测结果的绝对误差,正值代表观测值高于预测值,为低估,反之则为高估。从图7可以看出,2019年大多数月份表现为高估,2020年上半年表现为低估,下半年为高估,而2021年与2022年几乎所有月份都表现为低估,这与2019年、2020年北极海冰异常减少、2021年和2022年海冰范围有所恢复的现实相符合。从预测误差的正负上来看,除少数几个月份(如2019年9月,2020年4月、8月、12月以及2021年4月),其余月份的最佳预测结果与平均预测结果的高估或低估情况一致;从预测误差的数值上看,大多数月份表现出平均预测误差大、最佳预测

表4 2019—2022年预测结果的最佳与平均RMSE(单位: $\times 10^5 \text{ km}^2$)

Tab.4 Best and mean RMSE of predictions from 2019 to 2022 (unit: $\times 10^5 \text{ km}^2$)

模型	误差类别	2019年	2020年	2021年	2022年	平均
SEAS5	RMSE	3.55	3.10	3.43	3.26	3.34
LSTM+Seq2Seq	平均RMSE	3.85	3.93	2.85	2.55	3.30
	最佳RMSE	3.16	3.51	1.77	2.23	2.67

图6 北极海冰范围分布(改编自 SIPN 9月报告^[30])Fig.6 Arctic sea ice extent distribution (September report, adapted from SIPN^[30])

误差也大的现象,这在一定程度上说明模型的单次预测与平均预测能力一致。从平均预测的表现来

看,大多数月份的绝对预测误差低于 $3.00 \times 10^5 \text{ km}^2$,再一次说明本文使用 Seq2Seq 策略、24 个月作为输

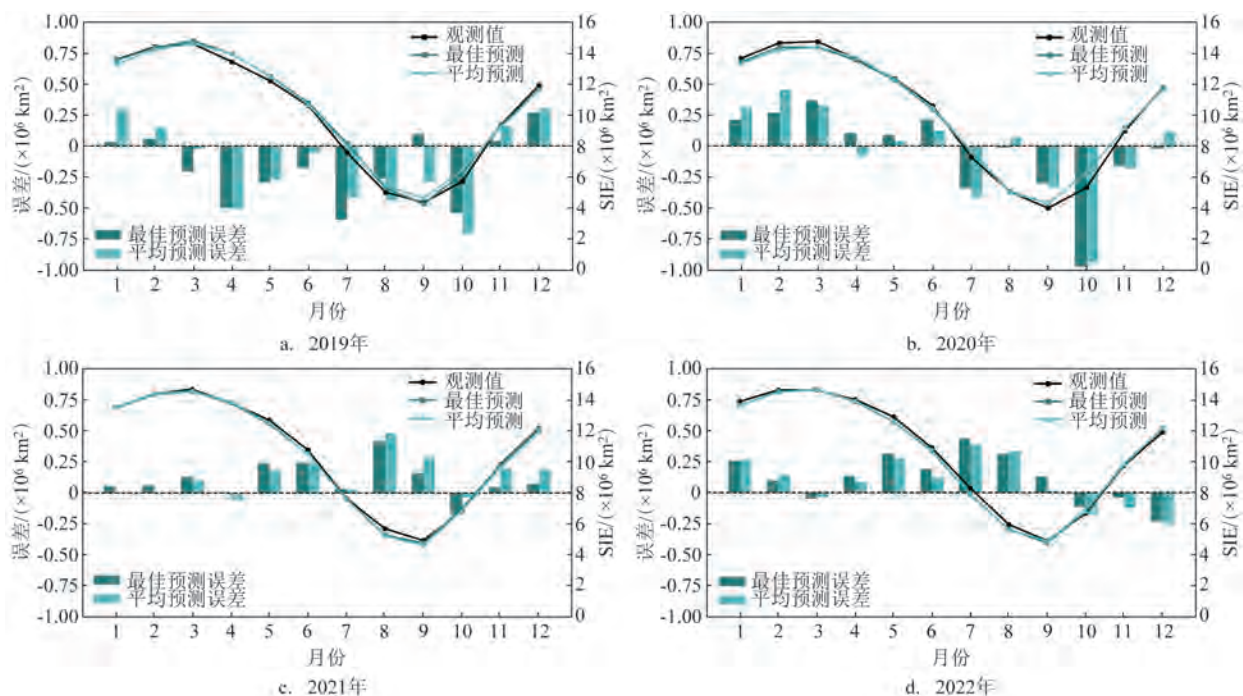


图7 2019—2022年预测结果与误差

Fig.7 Predictions and errors from 2019 to 2022

入长度构建的LSTM多步预测方法能够对未来12个月的北极月度海冰范围做出合理预测。

海冰范围绝对预测误差在 $3.00 \times 10^5 \sim 5.00 \times 10^5 \text{ km}^2$ 的有2019年4月、7月、8月,2020年1月、2月、3月、7月、9月,2021年8月与2022年7月;误差超过 $5.00 \times 10^5 \text{ km}^2$ 的有2019年10月、2020年10月,尤其是2022年10月的平均绝对误差达到了 $9.30 \times 10^5 \text{ km}^2$,这与KIM等^[16]使用深度学习方法所得到的结果一致。预测误差较大的月份大都集中在7—10月,由此可以看出北极夏季与秋季的海冰范围较难预测。夏季北极海冰融化,9月达到最低值,随后开始进入冻结期,7—10月处于低谷区,温度异常或其他气候影响都会对该时期的海冰产生剧烈影响,造成该时期北极海冰年际变化幅度大,预测难度大,相对来说春季与冬季北极海冰范围的预测误差较小。

4 结论与展望

本文针对12个月的北极海冰范围预测目标,对LSTM深度学习方法的不同预测策略进行对比研究。

研究表明,相对于Recursive、Direct、MIMO策略,Seq2Seq策略的多步预测效果最佳,2019—2022年预测结果的平均RMSE为 $3.7 \times 10^5 \text{ km}^2$;使用Seq2Seq策略对未来12个月进行多步预测时,24个月输入长度的平均RMSE为 $3.3 \times 10^5 \text{ km}^2$,比6、18、30、36个月的预测误差更小,多次预测结果更稳定,预测效果更好;预测结果中,夏秋季海冰范围的预测误差比冬春季大,更难预测。

本文建立的深度学习模型仅使用海冰范围历史数据对未来海冰变化区域进行预测,随着近年北极海冰持续减少和变化异常加剧,这种由纯数据驱动模型在准确捕获这种异常变化趋势上有一定难度。后续可以基于北极海冰的物理机制,考虑将各种海洋大气物理变量添加到深度学习模型中,并且量化变量因子对北极海冰范围预测的作用,构建“可解释”的深度学习模型。此外,本研究的预测结果仅仅局限于一维的数值预测,而北极海冰范围的空间分布预测也是一个极具挑战性的研究课题。

参考文献:

- [1] RANTANEN M, KARPECHKO A Y, LIPPONEN A, et al. The

- Arctic has warmed nearly four times faster than the globe since 1979[J]. *Communications Earth & Environment*, 2022, 3(1): 168.
- [2] DAVY R, GRIEWANK P. Arctic amplification has already peaked[J]. *Environmental Research Letters*, 2023, 18(8): 084003.
- [3] DELHAYE S, MASSONNET F, FICHEFET T, et al. Dominant role of early winter Barents-Kara sea ice extent anomalies in subsequent atmospheric circulation changes in CMIP6 models[J]. *Climate Dynamics*, 2024, 62(4): 2755-2778.
- [4] 孙晓宇, 孙启振, 沈辉, 等. 1979—2022年北极海冰范围变化特征及趋势分析[J]. *海洋预报*, 2023, 40(5): 49-55.
- SUN X Y, SUN Q Z, SHEN H, et al. Analysis of characteristics and trends of Arctic sea ice extent changes from 1979 to 2022[J]. *Marine Forecasts*, 2023, 40(5): 49-55.
- [5] SUN X Y, LV T T, SUN Q Z, et al. Analysis of spatiotemporal variations and influencing factors of sea ice extent in the Arctic and Antarctic[J]. *Remote Sensing*, 2023, 15(23): 5563.
- [6] JAHN A, HOLLAND M M, KAY J E. Projections of an ice-free Arctic Ocean[J]. *Nature Reviews Earth & Environment*, 2024, 5(3): 164-176.
- [7] GAO Y Q, SUN J Q, LI F, et al. Arctic sea ice and Eurasian climate: a review[J]. *Advances in Atmospheric Sciences*, 2015, 32(1): 92-114.
- [8] CHRIPKO S, MSADEK R, SANCHEZ-GOMEZ E, et al. Impact of reduced Arctic sea ice on Northern Hemisphere climate and weather in autumn and winter[J]. *Journal of Climate*, 2021, 34(14): 5847-5867.
- [9] SÉVELLEC F, FEDOROV A V, LIU W. Arctic sea-ice decline weakens the Atlantic Meridional Overturning Circulation[J]. *Nature Climate Change*, 2017, 7(8): 604-610.
- [10] ESAU I, PETTERSSON L H, CANCELT M, et al. The Arctic amplification and its impact: a synthesis through satellite observations[J]. *Remote Sensing*, 2023, 15(5): 1354.
- [11] 刘泉宏, 张韧, 汪杨骏, 等. 深度学习方法在北极海冰预报中的应用[J]. *大气科学学报*, 2022, 45(1): 14-21.
- LIU Q H, ZHANG R, WANG Y J, et al. Application of deep learning methods to Arctic sea ice prediction[J]. *Transactions of Atmospheric Sciences*, 2022, 45(1): 14-21.
- [12] 刘骥平, 雷瑞波, 宋米荣, 等. 适应极地快速变化海冰模式的研究与挑战[J]. *大气科学学报*, 2021, 44(1): 12-25.
- LIU J P, LEI R B, SONG M R, et al. Development and challenge of sea ice model adapting to rapid polar sea ice changes[J]. *Transactions of Atmospheric Sciences*, 2021, 44(1): 12-25.
- [13] WANG L, YUAN X J, TING M F, et al. Predicting summer Arctic sea ice concentration intraseasonal variability using a vector autoregressive model[J]. *Journal of Climate*, 2016, 29(4): 1529-1543.
- [14] CHI J, KIM H C. Prediction of Arctic sea ice concentration using a fully data driven deep neural network[J]. *Remote Sensing*, 2017, 9(12): 1305.
- [15] ALI S, HUANG Y Y, HUANG X, et al. Sea ice forecasting using attention-based ensemble LSTM[EB / OL]. arXiv: 2108.00853, (2022-02-08)[2023-10-11]. <http://arxiv.org/abs/2108.00853>.
- [16] KIM E, KRUSE P, LAMA S, et al. Multi-task deep learning based spatiotemporal Arctic sea ice forecasting[C]//2021 IEEE International Conference on Big Data (Big Data). Orlando: IEEE, 2021: 1847-1857.
- [17] National Snow and Ice Data Center. Sea ice concentrations from nimbus-7 SMMR and DMSP SSM/I-SSMIS passive microwave data, Version 2[DS / OL]. [2023-10-25]. <https://nsidc.org/data/nsidc-0051/versions/2>.
- [18] Climate Data Store. Seasonal forecast monthly statistics on single levels[DS/OL]. 2018[2024-03-26]. <https://cds.climate.copernicus.eu/doi/10.24381/cds.68dd14c3>.
- [19] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [20] Understanding LSTM networks[EB / OL]. Colah's Blog, 2015 [2024-12-26]. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- [21] TAIEB S B, BONTEMPI G, ATIYA A F, et al. A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition[J]. *Expert Systems with Applications*, 2012, 39(8): 7067-7083.
- [22] SORJAMAA A, HAO J, REYHANI N, et al. Methodology for long-term prediction of time series[J]. *Neurocomputing*, 2007, 70(16-18): 2861-2869.
- [23] HAMZAÇEBİ C, AKAY D, KUTAY F. Comparison of direct and iterative artificial neural network forecast approaches in multi-periodic time series forecasting[J]. *Expert Systems with Applications*, 2009, 36(2): 3839-3844.
- [24] TAIEB S B, SORJAMAA A, BONTEMPI G. Multiple-output modeling for multi-step-ahead time series forecasting[J]. *Neurocomputing*, 2010, 73(10-12): 1950-1957.
- [25] BONTEMPI G. Long term time series prediction with multi-input multi-output local learning[C]//Proceedings of the 2nd European Symposium on Time Series Prediction (TSP). Helsinki: Helsinki University of Technology, Department of Information and Computer Science, 2008: 145-154.
- [26] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks[EB/OL]. arXiv: 1409.3215, (2014-12-14)[2023-10-11]. <http://arxiv.org/abs/1409.3215>.
- [27] 王涛, 张伟, 贾宇欣, 等. 基于Seq2Seq模型的港口进出口货物量预测[J]. *计算机系统应用*, 2020, 29(3): 132-139.
- WANG T, ZHANG W, JIA Y X, et al. Prediction on import and export goods volume of ports based on Seq2Seq model[J]. *Computer Systems & Applications*, 2020, 29(3): 132-139.
- [28] KIM Y J, KIM H C, HAN D, et al. Prediction of monthly Arctic sea ice concentrations using satellite and reanalysis data based on

- convolutional neural networks[J]. The Cryosphere, 2020, 14(3): 1083-1104.
- [29] CHI J, BAE J, KWON Y J. Two-stream convolutional long- and short-term memory model using perceptual loss for sequence-to-sequence Arctic sea ice prediction[J]. Remote Sensing, 2021, 13(17): 3413.
- [30] Sea Ice Prediction Network. Sea ice outlook[EB/OL]. [2024-12-26]. <https://www.arcus.org/sipn/sea-ice-outlook>.

Research on multi-step prediction strategies of Arctic sea ice extent based on Long Short-Term Memory

WANG Manman^{1,2,3,4}, ZOU Bin^{2,3*}, SHI Lijian^{2,3}, ZENG Tao^{2,3}, ZHANG Ying^{2,3}, LU Dunwang^{1,2,3}

(1. National Marine Environmental Forecasting Center, Beijing 100081, China; 2. National Satellite Ocean Application Service, Beijing 100081, China; 3. Key Laboratory of Space Ocean Remote Sensing and Application, Ministry of Natural Resources, Beijing 100081, China; 4. Key Laboratory of Marine Hazards Forecasting, National Marine Environmental Forecasting Center, Ministry of Natural Resources, Beijing 100081, China)

Abstract: While previous researches have primarily focused on single-step prediction of Arctic sea ice extent, multi-step prediction and strategy are yet to be explored. This study utilizes monthly average Arctic sea ice extent data spanning from 1978 to 2022 and employs Long Short-Term Memory to implement multi-step predictions of Arctic sea ice extent for the next 12 months using four strategies: Recursive, Direct, Multi-input Multi-output, and Seq2Seq. The results show that a model input length of 24 months performs optimally. When compared to the other three basic multi-step prediction strategies, the Seq2Seq strategy demonstrates superior accuracy in forecasting Arctic sea ice extent over the next 12 months, with an root mean square error of 0.33 million square kilometers.

Key words: Arctic sea ice extent; Long Short-Term Memory; multi-step prediction strategies; Seq2Seq