

DOI: 10.3969/j.issn.1673-6141.2023.05.004

基于 ConvLSTM 和 PredRNN 的大气能见度预报方法

包旭伦¹, 李毅^{2*}, 胡译文^{2,3}, 王阳⁴, 牛丹⁵, 臧增亮², 陈夕松⁵

(1 东南大学软件学院, 江苏 苏州 215123;

2 国防科技大学气象海洋学院, 湖南 长沙 410000;

3 南京信息工程大学大气科学学院, 江苏 南京 210044;

4 北京弘象科技有限公司, 北京 100089;

5 东南大学自动化学院, 江苏 南京 211189)

摘要: 精准的大气能见度预报对空气污染治理、保障公共交通安全等方面具有重要意义。基于2019年12月1日至2020年9月23日国家气象信息中心观测的大气能见度站点数据, 分别采用 ConvLSTM 模型和 PredRNN 模型对中国中东部地区的能见度进行 12 h 预报, 并对这两种模型的预报结果进行评价。试验表明, PredRNN 模型相对于经典的 ConvLSTM 模型在大气能见度预报、图像质量评价指标和预报指标上都有更好的表现。此外, 分析还表明, 相对于 ConvLSTM 模型, PredRNN 模型对 4000 m 中等级别雾区预报效果随时间延长有明显提升。

关键词: 大气能见度预报; 预测递归神经网络; 时空预测; 提高精度

中图分类号: P456.9

文献标识码: A

文章编号: 1673-6141(2023)05-434-011

Atmospheric visibility prediction method based on ConvLSTM and PredRNN

BAO Xulun¹, LI Yi^{2*}, Hu Yiwen^{2,3}, WANG Yang⁴, NIU Dan⁵, ZANG Zengliang², CHEN Xisong⁵

(1 School of Software, Southeast University, Suzhou 215123, China;

2 College of Meteorology and Oceanography, National University of Defense Technology, Changsha 410000, China;

3 College of Atmospheric Sciences, Nanjing University of Information Science & Technology, Nanjing 210044, China;

4 Beijing Hongxiang Technology Co., LTD, Beijing 100089, China;

5 School of Automation, Southeast University, Nanjing 211189, China)

Abstract: Accurate forecast of atmospheric visibility is of great significance to air pollution control and public transportation safety. Based on the atmospheric visibility data observed by the National Meteorological Information Center from December 1, 2019 to September 23, 2020, ConvLSTM model and PredRNN model were used to forecast visibility over central and eastern China for 12 h in this work, and

基金项目: 国家自然科学基金 (41975167, 41775123)

作者简介: 包旭伦(1998-), 内蒙古赤峰人, 硕士研究生, 主要从事深度学习应用气象预测方面的研究。E-mail: 220205610@seu.edu.cn

导师简介: 牛丹(1986-), 江苏徐州人, 博士, 副教授, 博士生导师, 主要从事人工智能与芯片EDA、云边协同系统、气象预报交叉方向的研究。

E-mail: danniu1@163.com

收稿日期: 2022-02-11; 修改日期: 2022-04-26

*通信作者。E-mail: liyiqxy@163.com

the forecast results of the two models were evaluated. The results show that PredRNN model performs better than the traditional ConvLSTM model in atmospheric visibility forecast, image quality evaluation index and forecast index. In addition, it is also found that compared with ConvLSTM model, PredRNN model has improved significantly in forecasting 4000 m medium-level fog area over time.

Key words: prediction of atmospheric visibility; predictive recurrent neural networks; spatiotemporal prediction; improve the accuracy

0 引言

大气能见度是反映大气透明度的重要指标之一,通常定义为具有正常视力的人在当时的天气条件下能够看清楚目标轮廓的最大地面水平距离。低能见度是一种常见的危险性天气,会影响航空、航海、交通运输安全,可能带来重大经济损失。对大气能见度进行准确预报对于支撑政府决策、维护生产生活秩序、保护公民健康安全有着重要意义。能见度是天气预报中最复杂的变量之一,除了受温度、湿度、风影响外,还与气溶胶的浓度、化学成分密切相关。低能见度形成机制比较复杂,既受宏观的天气形势影响,还受局地的地理环境、中小尺度环流以及气溶胶颗粒物分子结构的影响,因此大气能见度是气象预报最难预报的要素之一。

基于深度学习的大气能见度预报方法是近年兴起的新颖方法。常见的深度神经网络包括卷积神经网络、循环神经网络等,目前已广泛应用于温度、降水等气象变量的研究,但对于大气能见度预报方面的研究还比较少。文俊鹏等^[1]提出了基于反向传播(BP)网络的单点能见度预报方法,建立了多元逐步回归和BP神经网络逐3h的客观预报模型,对广州白云机场能见度进行了预报,结果表明,在白云机场能见度下降并到达2km的天气过程中,两种预报模型均能提前24h预报出来;对于白云机场大雾天气的预报,BP神经网络预报与实况相比,预报大雾出现时间与实际时间仅相差1个时次(3h),大雾消失时间一致,最低能见度相差261m。Abdellaoui等^[2]提出了一种基于注意力机制的深度注意力多流单流网络,其在大气能见度的预报上也达到了较好的效果;苏靖晰^[3]等提出了基于GA-BP神经网络模型的大气能见度预报模型,其能够较好地预报成都地区的大气能见度,对于小于5km范围的低能见度预报较为精准。

目前,基于深度学习的大气能见度预测方法只实现了单点预报,没有有效采用空间信息,并且在预报精度和预报细节的呈现方面还需要进一步提高。通过机器学习或深度学习从历史连续帧预报生成未来帧是计算机视觉领域中非常重要的一个研究方向,已应用于降水、交通流等方面的预报^[4-7]。但许多现有的方法一般利用循环神经网络(RNN)^[8]或堆叠的长短时记忆网(LSTM)^[9]来捕获时空数据的时间依赖性,江亮等^[10]提出了基于卷积神经网络(CNN)深度学习模型的机场能见度预测,构建的是一个类似于VGG16的卷积神经网络,将输出层的softmax层替换成MSE层,使其具备了能见度预测能力,模型具有较好的预测能力。邓拓^[11]提出了基于LSTM的机场能见度预报方法,分别建立了1h和3h能见度回归模型,达到了较好的效果。为了能结合时间和空间两种关键的特征,本文基于时空的LSTM递归神经网络(PredRNN)^[12]模型对中国中东部的大气能见度进行了预报,并与经典的卷积LSTM网络(ConvLSTM)^[4]模型进行比较,定量分析两种方法对区域大气能见度的预报效果。

1 模型结构

1.1 时空预测学习

通常来讲,时空序列预测就是向一个系统中输入一段在时间上连续的已有图片,输出另一段在时间上连续的预测图片。本研究所输入和输出的图片是二维能见度场图(RGB图像)。未来场图的推断序列作为大气能见度的预报结果。 t 时刻的观测图像可以表示为一个张量 $X \in R^{(P \times M \times N)}$, R 表示观测的特征域, P 表示特征映射的RGB通道数, M 和 N 分别表示状态张量和输入张量的宽度和高度。从时间的角度来看,对 T 时间步长的观察形成一个张量序列 X_1, X_2, \dots, X_T 。因此,从公式的角度来看,时空序列预测学习是根据给定的历史观测值序列 $X_{t+1}, \dots, X_{t+K} | X_{t-J+1}, \dots, X_t$ (包括当前的观测值)来预测未来最可能的序列 $\hat{X}_{t+1}, \dots, \hat{X}_{t+K}$,其计算公式为

$$\hat{X}_{t+1}, \dots, \hat{X}_{t+K} = A(X_{t+1}, \dots, X_{t+K} | X_{t-J+1}, \dots, X_t), \quad (1)$$

式中 A 代表 argmax 函数,其中 $K=12$,即利用前12h历史能见度场图(连续12帧)来训练神经网络,并预报未来12h能见度场图。

1.2 ConvLSTM

在深度学习领域中涉及到的时空序列问题一般都与循环神经网络(RNN)和卷积神经网络(CNN)^[13]相关。ConvLSTM是以普通的LSTM结合卷积层作为基础构件进行堆叠,最后生成时空记忆流。

LSTM的公式为

$$\begin{cases} f_t = \sigma[W_f \otimes (h_{t-1}, x_t) \oplus b_f] \\ i_t = \sigma[W_i \otimes (h_{t-1}, x_t) \oplus b_i] \\ \tilde{C}_t = H[W_c \otimes (h_{t-1}, x_t) \oplus b_c] \\ C_t = f_t \otimes C_{t-1} \oplus i_t \otimes \tilde{C}_t \\ o_t = \sigma[W_o \otimes (h_{t-1}, x_t) \oplus b_o] \\ h_t = o_t \otimes H(C_t) \end{cases}, \quad (2)$$

式中 $f_t, i_t, \tilde{C}_t, C_t, o_t$ 代表门向量, σ, H 分别为sigmoid和tanh激活函数, W_f, W_i, W_c, W_o 代表参数矩阵, h_t 代表隐藏层向量, x_t 代表输入向量, b_f, b_i, b_c, b_o 代表偏差向量, \otimes 代表逐元素相乘, \oplus 代表逐元素相加。在本试验中, x_t 代表能见度场图经过RGB规则和归一化转化后的三通道矩阵变量,门向量、偏差向量、参数矩阵和激活函数均为模型的必要参数,可以有效拟合模型并且防止梯度消失或梯度爆炸。LSTM的结构如图1(a)所示,ConvLSTM模型如图2(a)所示。

1.3 PredRNN

ConvLSTM这种时空序列预测模型去掉了水平方向的时间流,导致时间一致性的降低,并且记忆信息需要流动很长的路径,容易造成梯度消失。而PredRNN中基本建模单元为ST-LSTM,能够解决LSTM存在的问题。

ST-LSTM的公式为

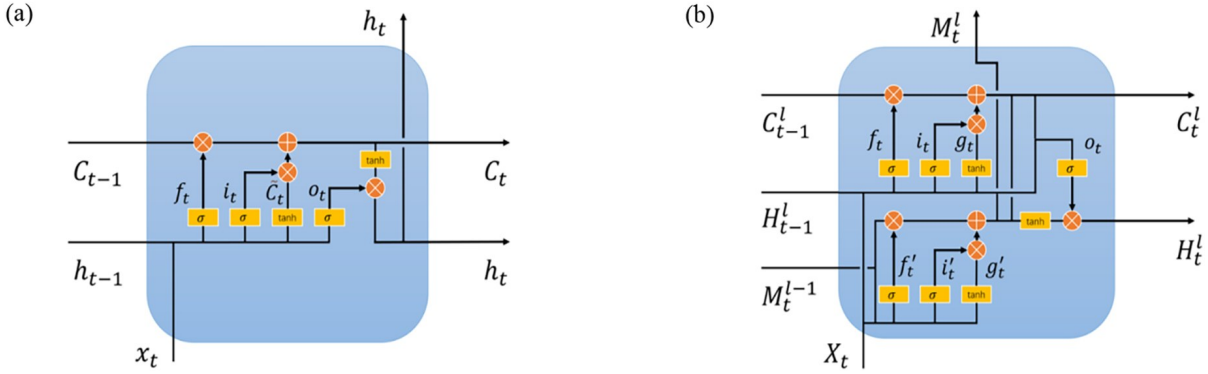


图 1 LSTM (a) 和 ST-LSTM (b) 结构图

Fig. 1 Structure diagram of LSTM (a) and ST-LSTM (b)

$$\begin{cases}
 g_t = H(W_{xg} \otimes X_t \oplus W_{hg} \otimes H_{t-1}^l \oplus b_g) \\
 i_t = \sigma(W_{xi} \otimes X_t \oplus W_{hi} \otimes H_{t-1}^l \oplus b_i) \\
 f_t = \sigma(W_{xf} \otimes X_t \oplus W_{hf} \otimes H_{t-1}^l \oplus b_f) \\
 C_t^l = f_t \odot C_{t-1}^l \oplus i_t \odot g_t \\
 g'_t = H(W_{xg'} \otimes X_t \oplus W_{mg'} \otimes M_{t-1}^{l-1} \oplus b'_g) \\
 i'_t = \sigma(W_{xi'} \otimes X_t \oplus W_{mi'} \otimes M_{t-1}^{l-1} \oplus b'_i) \\
 f'_t = \sigma(W_{xf'} \otimes X_t \oplus W_{mf'} \otimes M_{t-1}^{l-1} \oplus b'_f) \\
 M_t^l = f'_t \odot M_{t-1}^{l-1} \oplus i'_t \odot g'_t \\
 o_t = \sigma(W_{xo} \otimes X_t \oplus W_{ho} \otimes H_{t-1}^l \oplus W_{co} \otimes C_t^l \oplus W_{mo} \otimes M_t^l \oplus b_o) \\
 H_t^l = o_t \odot H[W_{1 \times 1} \otimes (C_t^l, M_t^l)]
 \end{cases} \quad (3)$$

式中 $g_t, i_t, f_t, g'_t, i'_t, f'_t, o_t$ 代表门向量, H, σ 分别为 sigmoid 和 tanh 激活函数 $W_{xg}, W_{xg'}, W_{xi}, W_{xi'}, W_{xf}, W_{xf'}, W_{xo}, W_{co}, W_{mo}$ 代表参数矩阵, X_t 代表输入向量, $H_t^l, H_{t-1}^l, C_t^l, C_{t-1}^l, M_t^l, M_{t-1}^{l-1}$ 代表隐藏层向量, $b_g, b_i, b_f, b'_g, b'_i, b'_f, b_o$ 代表偏差向量, \odot 表示 hadmard 乘积。在本试验中, 模型的必要参数包括门向量、偏差向量、参数矩阵和激活函数, 它们用于对经过 RGB 规则和归一化转化后的三通道矩阵变量 X_t 进行建模, 借助这些参数, 模型能够有效地拟合数据, 并且能够避免梯度消失或梯度爆炸的问题。ST-LSTM 的结构如图 1 (b) 所示, 其可以看作由上下两个 LSTM 连接构成, 其中上半部分 LSTM 称为标准时序记忆, 这部分为普通 LSTM, 下部分称为时空记忆, 这部分把普通 LSTM 的 h_t, C_t 结合成 M_t^l (时空记忆状态)。它可以同时提取和记忆时空特征, 并垂直地跨层传递记忆和水平地跨状态传递记忆。PredRNN 模型如图 2 (b) 所示, 相比基于 ConvLSTM 的时空记忆流, 所增加的水平状态, 可以水平传递记忆信息。

2 试验数据

2.1 数据来源介绍

采用国家气象信息中心观测的大气能见度站点数据开展研究, 该数据来源于中国气象数据网, 时间范围是北京时间 2019 年 12 月 1 日至 2020 年 9 月 23 日的每 1 h 间隔数据。区域范围覆盖中国中东部区域 (100° E~120° E, 20° N~40° N), 共选取 2428 个观测站点。

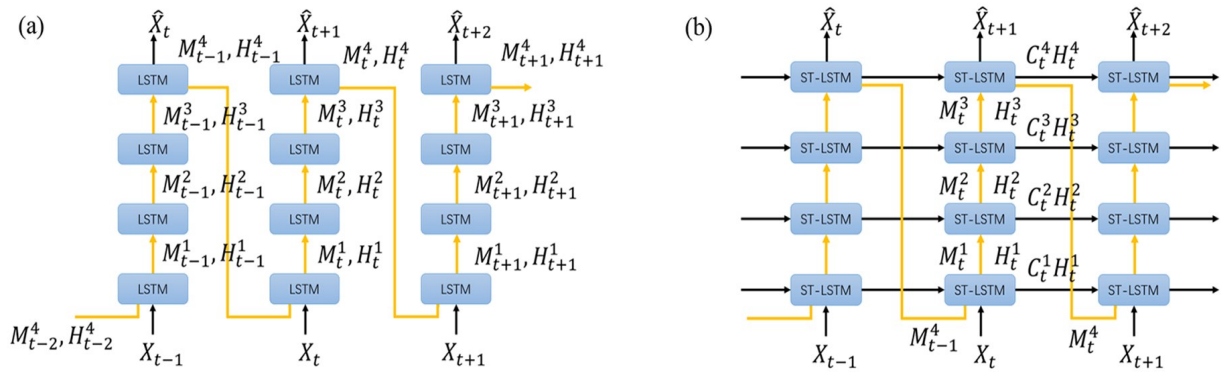


图2 ConvLSTM (a) 和 PredRNN (b) 模型

Fig. 2 Structure diagram of ConvLSTM (a) and PredRNN (b)

2.2 数据集制作

由于原始的观测数据有异常值和缺损值,所以在训练模型之前要对这些损坏的数据进行数据清洗,包括异常值删除和缺损值填充这两个步骤。对于站点数据中多次连续出现例如999999的异常值,处理时直接将异常值删除。采取两种措施对缺损值进行填充:1)若连续缺损值不超过1个,采用前后两个非缺损值进行均值填充;2)若连续缺损值超过1个,采用前后非缺损值进行线性插值填充。

时空序列预测所需要的数据集是一组连续的二维图片,因此,将每小时的站点数据在经纬度上进行了自定义色彩映射,最后生成RGB格式的图片。由于地面观测站点的数量有限,无法覆盖所有网格点,因此利用线性插值来填充没有数据的网格点的数值,最后生成的能见度场图如图3所示。

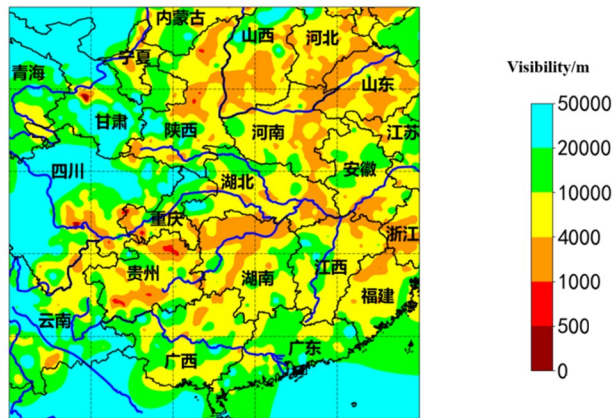


图3 2020年9月14日00:00能见度场图

Fig. 3 Visibility field map at 00:00, September 14, 2020

整理图片时,发现有些图片是全蓝或全绿(表示能见度较高),但是其前后时刻的图片并不是全蓝或全绿且有明显的低能见度,故推测这些全蓝或全绿图片是因采集数据缺漏而导致,所以要删除这些全蓝或全绿图片,然后将相邻前后的图片复制到缺省位置,以免它们对以后的模型训练过程产生负面影响。在以后的时刻片段抽取函数中,选取时刻连续且对应图片都存在的时刻片段间的图片,放入训练集、验证集或测试集中。如果遍历到的时刻片段不满足上述条件,便不考虑该片段。

考虑到深度学习训练时间成本和空间成本,将图片压缩至128 pixel × 128 pixel, 96 dpi,最后得到一组数据集,其中2019年12月1日至2020年5月31日的数据为训练集,包括4392张图片;2020年6月1日至2020年7月31日的数据为验证集,包括1464张图片;2020年8月1日至2020年9月23日的数据为测试集,包括1296张图片。

3 试验设计与结果分析

3.1 试验设计

分别采用ConvLSTM模型和PredRNN模型对上述的数据集进行训练。ConvLSTM模型的编码器和预测器都由LSTM堆叠组成,每个layer都有128个隐藏状态。LSTM内部的卷积滤波器设置为5 × 5。此外每个序列包含24帧(24个连续时刻的能见度场图),前12帧为输入序列,后12帧为预报序列,预报完成后,将得到的三通道矩阵数据再转化为能见度场图。PredRNN模型的编码器和预测器都由ST-LSTM组成,其余参数与ConvLSTM模型设置相同。

3.2 检验指标

使用多种参数来量化模型的预测效果,包括均方误差(MSE, E_{MS})、结构相似性(SSIM, S)、图像感知度相似指标(LPIPS)以及临界成功指数(CSI),其中MSE可以验证模型的拟合效果,SSIM和LPIPS用来在图像学的角度上量化预测效果,而CSI是气象领域常用的检验指标,表示预报的成功率。

MSE是深度学习常用的回归评价指标,其计算公式为

$$E_{MS} = \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{m}, \quad (4)$$

式中 y_i 代表真实值, \hat{y}_i 代表预报值, m 代表样本数量。

SSIM^[14]是一种衡量两幅图像相似度的指标。给定两个图像 x 和 y ,两张图像的结构相似性的表达式为

$$S = \frac{(2\mu_x \mu_y + c_1)(\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (5)$$

式中 μ_x 、 μ_y 分别是 x 、 y 的平均值; σ_x^2 、 σ_y^2 分别是 x 、 y 的方差; σ_{xy} 是 x 和 y 的协方差; $c_1=(k_1 L)^2$, $c_2=(k_2 L)^2$,二者是用来维持稳定的常数,其中 L 是像素值的动态范围, $k_1=0.01$, $k_2=0.03$ 。

LPIPS^[15]采用的是一种学习生成图像到地表实况的学习生成器方法,通过反向映射强制生成器从假图像中重构真实图像,并优先处理它们之间的感知相似性,它更符合人类的感知情况,LPIPS的值越低,表示两张图像越相似,其中 D 代表 x 与 x_0 的距离,其计算公式为

$$D = \sum_l \frac{\sum_{(h,w)} \|w_l \odot (y_{hw}^{\hat{}} - y_{0,hw}^{\hat{}})\|_2^2}{(H_l W_l)}, \quad (6)$$

式中向量 w_l 用于放出活动通道的数量, \odot 代表 w_l 和 $(y_{hw}^{\hat{}} - y_{0,hw}^{\hat{}})$ 的乘法, $y_{hw}^{\hat{}}$ 和 $y_{0,hw}^{\hat{}}$ 是每个卷积层的输出在激活后归一化的结果, H_l 和 W_l 分别代表卷积层 l 中图像的高度和宽度。

由于本预报任务是在像素级完成的,因此需要将处理后的数据投影回大气能见度,并计算网格每个单

元的大气能见度。这个指标与分类指标相似,主要关注预报的定位点是否在一定阈值范围内命中。例如,如果阈值为1000 m,那么经过二值化后,999 m将被转换为0,1001 m将被转换为1。将预报值和真实值中的每个像素值转换为0或1后,计算 H_{hits} (真阳性,预报值=1,真实值=1)、 M_{misses} (假阳性,预报值=1,真实值=0)和 $F_{\text{false_alarms}}$ (假阴性,预报值=0,真实值=0)。为了充分评价算法的性能,计算了对应于不同大气能见度的三个阈值下的技能得分,最终选择1000、4000、10000 m作为阈值来评价预报性能。临界成功指数 C_{CSI} 的计算公式为

$$C_{\text{CSI}} = \frac{H_{\text{hits}}}{H_{\text{hits}} + M_{\text{misses}} + F_{\text{false_alarms}}} \quad (7)$$

3.3 结果分析

为了更直观地分析预报效果,从测试集中选出了一组个例进行分析。图4为2020年9月14日12:00—17:00观测与ConvLSTM和PredRNN预报的大气能见度空间分布,图中1 h至6 h对应的图像分别表示从12:00开始往后每小时的预测图。由图可以看出,ConvLSTM和PredRNN预报的大气能见度在空间分布上与观测结果有较好的一致性,都能预报出华北地区和华中地区两个较大的低能见度区,并且对于一些精细的局地性特征,如天津、石家庄、武汉等地区的低能见度也能较好地预报,但预报结果在强度上总体比观测结果略小,在后几小时均低估了河南地区的低能见度;相对于ConvLSTM模型,PredRNN模型预报的能见度分布与实况结果更接近。图5为2020年9月14日18:00—23:00的预报结果对比图,图中7 h至12 h对应的图像分别表示从18:00开始往后每小时的预测图。由图可以看出,在后6 h的预测结果中,PredRNN的优势更为明显,相对于ConvLSTM模型,在低能见度预报方面,PredRNN模型在华中和贵州地区的预报区域偏大,而在苏北、皖北、河南地区等地的预报区域偏小,这都更接近况。




图4 2020年9月14日12:00—17:00预报示例。(a) 真实值;(b) ConvLSTM 预报图;(c) PredRNN 预报图

Fig. 4 Example of weather forecast from 12:00 to 17:00, September 14, 2020. (a) True value; (b) ConvLSTM forecast map; (c) PredRNN forecast map




图 5 2020年9月14日 18:00—23:00 预报示例。(a) 真实值; (b) ConvLSTM 预报图; (c) PredRNN 预报图

Fig. 5 Example of weather forecast from 18:00 to 23:00, September 14, 2020. (a) True value; (b) ConvLSTM forecast map; (c) PredRNN forecast map

表 1 为 2020 年 8 月 1 日至 9 月 23 日测试集 ConvLSTM 和 PredRNN 预报的大气能见度 6 h 的平均定量结果, 其中, “↑”表示值越高越好, “↓”表示值越低越好。由表可以看出, PredRNN 模型预报的大气能见度的 6 个指标均优于 ConvLSTM 模型。其中预测能见度 1000 m 临界成功指数 (CSI-1000)、4000 m 临界成功指数 (CSI-4000) 和 10000 m 临界成功指数 (CSI-10000) 分别提升了 11.59%、5.46% 和 3.16%, 这说明 PredRNN 对于低能见度的预报效果更好, 这是由于 PredRNN 的模型结构能够学习数据集中一些复杂的时空模式, 更有利于区域大气能见度的预报。

表 1 能见度场图数据集的平均定量结果 (6 h)

Table1 Average quantitative results of visibility field map data set (6 h)

模型	MSE (↓)	SSIM (↑)	LPIPS (↓)	CSI-1000 m (↑)	CSI-4000 m (↑)	CSI-10000 m (↑)
ConvLSTM	33.21	0.487	0.327	0.233	0.476	0.569
PredRNN	31.65	0.511	0.270	0.260	0.502	0.587

表 2 为 ConvLSTM 和 PredRNN 预报的大气能见度 12 h 能见度场图数据集的平均定量结果。由可以看出, 与 ConvLSTM 模型相比, PredRNN 模型 12 h 预报的 6 个指标仍然均优于 ConvLSTM 模型, 其中 CSI-1000、CSI-4000 和 CSI-10000 相对于 ConvLSTM 模型分别提高了 7.42%、5.50% 和 5.87%, 比表 1 中 6 个小时预报提高的更为明显, 说明 PredRNN 对能见度的预报有较好的持续性。

图 6 为 2020 年 9 月 14 日预报示例检验指标图。由图可以看出, PredRNN 的 6 个指标均高于 ConvLSTM 模型, 这说明 PredRNN 模型相对来说更能够学习到能见度场图数据集中有效的演变时空特征, 其中图 6 (a)

表 2 能见度场图数据集的平均定量结果 (12 h)

Table 2 Average quantitative results of visibility field map data set (12 h)

模型	MSE (\downarrow)	SSIM (\uparrow)	LPIPS (\downarrow)	CSI-1000 m (\uparrow)	CSI-4000 m (\uparrow)	CSI-10000 m (\uparrow)
ConvLSTM	70.32	0.381	0.373	0.175	0.418	0.511
PredRNN	58.73	0.410	0.325	0.188	0.441	0.541

和图 6 (b) 中曲线的差别随时间增大, 特别图 6 (a) 中的差别增大明显, 说明 PredRNN 模型对中等低能见度的预报效果更好。




图 6 2020年9月14日预报示例检验指标。(a) 图像评价指标; (b) CSI评价指标

Fig. 6 Sample test indexes were predicted on September 14, 2020. (a) Image evaluation indicators; (b) CSI evaluation indicators

4 结 论

提出了利用 ConvLSTM 模型和 PredRNN 模型进行大气能见度预报的方法, 并基于中国气象数据网的站点观测数据对中国中东部地区的大气能见度进行了预报。相较于以往的单点预报, 本研究实现了对能见度时间和空间的同时预报, 提高了大气能见度预报的图像细节和预报精度。将 PredRNN 模型对大气能见度的预报结果与经典的 ConvLSTM 模型进行对比, 结果表明 PredRNN 模型在图像质量评价和预报评价指标上均优于经典的 ConvLSTM 模型。与 ConvLSTM 模型相比, PredRNN 模型 6 h 预报的 CSI-1000、CSI-4000 和 CSI-10000 分别提升了 11.59%、5.46% 和 3.16%, 12 h 预报的 CSI-1000、CSI-4000 和 CSI-10000 分别提升了 7.42%、5.50% 和 5.87%。PredRNN 模型相对于 ConvLSTM 模型对中等低能见度预报效果随时间的延长的提升效果更明显, 预报的能见度场图更加详细, 预报精度更高。

采用 ConvLSTM 和 PredRNN 模型分别对能见度进行了时空预报, 但是两种方法都没能够预报出安徽地区的低能见度, 并且误判了陕西和河南地区的低能见度。目前深度学习在气象领域的应用仍旧处于探索阶段, 尚有较大的改进空间。例如, ConvLSTM 和 PredRNN 预测出的图像都较为模糊, 这对其最后的检验评分有一定的积极影响, 如何在不损失模型检验评分的情况下, 尽可能地让模型也产出“锐利”的预测图, 是接下来研究的重点。图 6 的曲线变化趋势和走向都表现出预报的效果随着时间的推移而变差, 在日后的研

研究中,可以使用ConvTransformer^[16]模型并采取Muti-attention机制来尝试使模型输出精细的预报结果并且使预报效果随着时间的推移不断改善。在大气能见度预报方面,如何有效使用雷达、地面、卫星等多源数据进行融合预报,不断将新生成的观测数据纳入神经网络模型训练中,使得预报效果随着时间的推移不断改善。另外,如何将气象上的物理概念模型与深度学习算法有机结合,也值得深入研究。

参考文献:

- [1] Wen J P, Lan J, Liu F. Experiment on objective forecast methods for the low visibility of Guangzhou Baiyun Airport [J]. *Advances in Meteorological Science and Technology*, 2021, 11(2): 176-180.
文俊鹏, 蓝静, 刘峰. 广州白云机场低能见度客观预报方法试验 [J]. *气象科技进展*, 2021, 11(2): 176-180.
- [2] Abdellaoui I A, Mehrkanoon S. Deep multi-stations weather forecasting: Explainable recurrent convolutional neural networks [EB/OL]. <https://arxiv.org/abs/2009.11239>.
- [3] Su J X, Wang S T, Chen H M, et al. Atmospheric visibility forecast based on GA-BP neural network model [J]. *Computer Knowledge and Technology*, 2020, 16(18): 19-21.
苏靖晰, 王圣堂, 陈红敏, 等. 基于GA-BP神经网络模型的大气能见度预测 [J]. *电脑知识与技术*, 2020, 16(18): 19-21.
- [4] Shi X J, Chen Z R, Wang H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [C]. *Proceedings of the 28th International Conference on Neural Information Processing Systems*, December 7, 2015, Montreal, Canada. MIT Press, 2015: 802-810.
- [5] Guo H Y, Chen M X, Han L, et al. High resolution nowcasting experiment of severe convection based on deep learning [J]. *Acta Meteorologica Sinica*, 2019, 77(4): 715-727.
郭瀚阳, 陈明轩, 韩雷, 等. 基于深度学习的强对流高分辨率临近预报试验 [J]. *气象学报*, 2019, 77(4): 715-727.
- [6] Niu D, Huang J H, Zang Z L, et al. Two-stage spatiotemporal context refinement network for precipitation nowcasting [J]. *Remote Sensing*, 2021, 13(21): 4285.
- [7] Xu Z R, Wang Y B, Long M S, et al. PredCNN: Predictive learning with cascade convolutions [C]. *Proceedings of the 27th International Joint Conference on Artificial Intelligence*. July 13-19, 2018, Stockholm, Sweden. AAAI Press, 2018: 2940-2947.
- [8] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors [J]. *Nature*, 1986, 323(6088): 533-536.
- [9] Hochreiter S, Schmidhuber J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [10] Jiang L, Wang B S, Hong L, et al. Airport visibility prediction based on CNN deep learning model [J]. *China Computer & Communication*, 2020, 32(23): 43-46.
江亮, 王保升, 洪磊, 等. 基于CNN深度学习模型的机场能见度预测 [J]. *信息与电脑*, 2020, 32(23): 43-46.
- [11] Deng T. *Airport Visibility Prediction Based on LSTM Neural Network* [D]. Jinan: Shandong University, 2019.
邓拓. 基于LSTM神经网络的机场能见度预测 [D]. 济南: 山东大学, 2019.
- [12] Wang Y B, Long M S, Wang J M, et al. PredRNN: Recurrent neural networks for predictive learning using spatiotemporal LSTMs [C]. *Proceedings of the 31st International Conference on Neural Information Processing Systems*. December 4-9, 2017, Long Beach, California, USA. New York: ACM, 2017: 879-888.
- [13] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [14] Oh J, Guo X, Lee H, et al. Action-conditional video prediction using deep networks in Atari Games [C]. *Proceedings of the*

-
- 28th International Conference on Neural Information Processing Systems*. December 7, 2015, Montreal, Canada, MIT Press, 2015: 2863-2871.
- [15] Wang Z, Bovik A C, Sheikh H R, *et al*. Image quality assessment: From error visibility to structural similarity [J]. *IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society*, 2004, 13(4): 600-612.
- [16] Zhang R, Isola P, Efros A A, *et al*. The unreasonable effectiveness of deep features as a perceptual metric [C]. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. June 18-23, 2018, Salt Lake City, UT, USA. IEEE, 2018: 586-595.