

方巍, 齐媚涵. 基于深度学习的高时空分辨率降水临近预报方法[J]. 地球科学与环境学报, 2023, 45(3): 706-718.

FANG Wei, QI Mei-han. Precipitation Nowcasting Method with High Spatio-temporal Resolution Based on Deep Learning[J]. Journal of Earth Sciences and Environment, 2023, 45(3): 706-718.

DOI: 10.19814/j.jese.2023.01010

·《地球科学与环境学报》更名二十周年纪念专辑·

# 基于深度学习的高时空分辨率降水临近预报方法

方巍<sup>1,2,3</sup>, 齐媚涵<sup>1</sup>

(1. 南京信息工程大学 计算机学院, 江苏 南京 210044;

2. 南京信息工程大学 江苏省大气环境与装备技术协同创新中心, 江苏 南京 210044;

3. 苏州大学 江苏省计算机信息处理技术重点实验室, 江苏 苏州 215006)

**摘要:**降水临近预报在强对流天气监测预警中具有重要地位, 对于防灾减灾至关重要。在气象业务中, 主要采用雷达回波外推方法解决高时空分辨率的临近预报问题。针对传统雷达回波外推方法中普遍存在的资料信息利用率不足和预报准确率较低的问题, 利用上海地区多年的高时空分辨率天气雷达探测资料, 基于数据驱动的深度学习方法进行雷达回波外推, 提出了一种新的降水临近预报模型——SwinAt-UNet 模型。该预报模型通过融合 UNet 模型和 Swin Transformer 结构捕捉历史天气雷达探测资料中的短期和长期动态变化特征, 可以自适应地学习潜在的雷达回波生消演变规律。此外, 为提高模型的泛化能力和预报准确率, 引入深度可分离卷积和卷积块注意力模块。结果表明: 在不同基本反射率阈值下, SwinAt-UNet 模型的预报准确率均高于 UNet、SmaAt-UNet、TransUNet 和 AA-TransUNet 模型; 在 45 dBZ 的基本反射率阈值下, SwinAt-UNet 模型临界成功指数提高了 13%, 同时在预报时效上具有一定的优越性; SwinAt-UNet 模型外推图像具有更加清晰的边缘和细节性纹理, 对降水范围、移动方向和强度变化的预测更为准确。

**关键词:**降水临近预报; 强对流天气; 深度学习; 雷达回波外推; SwinAt-UNet 模型; 时空分辨率; 天气雷达探测

中图分类号: P456.1; X43

文献标志码: A

文章编号: 1672-6561(2023)03-0706-13

## Precipitation Nowcasting Method with High Spatio-temporal Resolution Based on Deep Learning

FANG Wei<sup>1,2,3</sup>, QI Mei-han<sup>1</sup>

(1. School of Computer Science, Nanjing University of Information Science & Technology, Nanjing 210044,

Jiangsu, China; 2. Jiangsu Collaborative Innovation Center of Atmospheric Environment and Equipment

Technology (CICAEET), Nanjing University of Information Science & Technology, Nanjing 210044,

Jiangsu, China; 3. Provincial Key Laboratory for Computer Information Processing Technology,

Soochow University, Suzhou 215006, Jiangsu, China)

**Abstract:** Precipitation nowcasting plays an important role in severe convective weather monitoring and warning, and is very important for disaster prevention and mitigation. In meteorological services, the radar echo extrapolation method is mainly used to solve the

收稿日期: 2023-01-07; 修回日期: 2023-02-23

投稿网址: <http://jese.chd.edu.cn/>

基金项目: 国家自然科学基金项目(42075007); 灾害天气国家重点实验室开放项目(2021LASWB19);

江苏省研究生科研创新计划项目(KYCX22\_1218);

中国气象局交通气象重点开放实验室开放研究基金项目(北极阁基金项目)(BJG202306)

作者简介: 方巍(1975-), 男, 安徽黄山人, 南京信息工程大学教授, 博士研究生导师, 工学博士, 博士后, E-mail: hsfangwei@sina.com.

nowcasting problem with high spatio-temporal resolution. In order to solve the problems of insufficient utilization of data information and low forecast accuracy in traditional radar echo extrapolation method, the high spatio-temporal resolution weather radar detection data in Shanghai area over many years were used to extrapolate radar echo based on data-driven deep learning method, and a new precipitation nowcasting model (SwinAt-UNet) was proposed. By fusing the UNet model and Swin Transformer structure to capture the short-term and long-term dynamic variation characteristics of historical weather radar detection data, the SwinAt-UNet model could adaptively learn the potential radar echo evolution laws of generation, dissipation, accumulation and deformation. In addition, in order to improve the generalization ability and forecast accuracy of the model, the depthwise-separable convolution and convolutional block attention module (CBAM) were introduced. The results show that the forecast accuracy of SwinAt-UNet model is higher than that of UNet, SmaAt-UNet, TransUNet and AA-TransUNet models under different base reflectivity thresholds; the critical success index of SwinAt-UNet model is increased by 13% at the base reflectivity threshold of 45 dBZ, and the period validity is improved; the image extrapolated by SwinAt-UNet model has clearer edge and detailed texture, and the predictions of precipitation range, moving direction and intensity change are more accurate.

**Key words:** precipitation nowcasting; severe convective weather; deep learning; radar echo extrapolation; SwinAt-UNet model; spatio-temporal resolution; weather radar detection

## 0 引 言

降水临近预报旨在未来 2 h 内对局部地区降水进行高时空分辨率的预报<sup>[1]</sup>。相比于短期、中期和长期预报,临近预报重点关注演变速度快、生命周期短的中小尺度天气系统,对预报时效和预报精度的要求更高,预报难度更大<sup>[2]</sup>。在实际业务中,数值预报和雷达回波外推是两种常用的预报方法。数值预报通过求解大气动力学方程组定量预报未来大气的运动状态,包括空气流速、气压和温度等多种不同的物理特性,在短期和中期预报中的表现较为稳定。受次网格过程、初值和边界值等因素的限制,数值预报在 2 h 内存在“模式起转”(Spin-up)问题,预报结果不具备可靠性且计算成本高昂,因此无法直接应用于高分辨率精细化的临近预报<sup>[3]</sup>。目前,最先进的降水临近预报系统通常采用效率更高、预报更准确的雷达回波外推方法<sup>[4]</sup>。

雷达回波外推是指利用历史天气雷达探测资料,确定回波的强度分布及回波体的移动速度和方向,采用线性或者非线性的方法进行回波外推,预测未来一定时间段的雷达回波状态。传统的雷达回波外推方法包括单体质心法<sup>[5]</sup>、交叉相关法<sup>[6]</sup>和光流法<sup>[7]</sup>。单体质心法将目标视为三维单体进行分析,适合对较大目标进行跟踪预报,但对弱回波信息的

预报能力不足,只能应用于对流降水系统<sup>[8]</sup>;交叉相关法通过计算相邻时次雷达回波资料不同区域的最优空间相关系数,确定雷达回波的移动矢量特征,并基于得到的移动矢量进行外推预报,在气象业务部门中得到广泛应用,但在预报演变速度较快的强对流降水过程方面仍存在局限性,预报精度会随预报时效的延长而迅速降低,预报能力明显不足<sup>[9]</sup>;光流法通过计算雷达回波的光流场来获得光流的移动矢量,继而进行雷达回波外推,在移动矢量估计方面具有较好的性能,但由于计算光流矢量和外推两个步骤相分离,所以存在累积误差,不能发挥天气雷达探测资料的优势<sup>[10]</sup>。以上方法均利用若干时刻的雷达回波资料外推下一时刻的回波状态,忽略了中小尺度天气系统中雷达回波的非线性运动特征,在历史雷达资料利用率和预报时效方面仍存在局限性。

人工智能技术的兴起为降水临近预报的发展提供了新途径<sup>[11-14]</sup>。其中,深度学习作为一种数据驱动技术,在挖掘数据内部规律方面具有显著优势,可以自动提取强对流降水演变的非线性特征,在降水临近预报领域已取得初步进展。Shi 等为更好地模拟时空关系,将降水临近预报定义为一种时空序列预测问题,提出了卷积长短时记忆神经网络(Convolutional LSTM Network, ConvLSTM)模型<sup>[15]</sup>;为学习雷达回波的轨迹聚合状态,Shi 等进一步提

出了卷积核可变形门控循环单元(Trajectory Gated Recurrent Unit, TrajGRU)模型,利用光流的思想主动学习循环连接的位置变化<sup>[16]</sup>。Wang 等提出了预测循环神经网络(Predictive Recurrent Neural Network, PredRNN)模型,该模型可以同时提取和记忆时间、空间信息<sup>[17]</sup>;Wang 等还提出了时空预测循环神经网络(Recurrent Network for Spatiotemporal Predictive, PredRNN++)模型,该模型可以自适应地学习时空序列中的短期和长期特征信息<sup>[18]</sup>;此外,Wang 等提出了 Memory in Memory 模型,利用差分思想提取高阶非平稳特征信息<sup>[19]</sup>。Wu 等提出了 MotionRNN 模型,用于提高对复杂时空运动的适应能力<sup>[20]</sup>。Ravuri 等提出了一种基于条件生成对抗网络的深度生成模型 DGMR,通过判别器与生成器之间的博弈训练解决外推图像的模糊问题<sup>[21]</sup>。Luo 等提出了 PredRANN 预报模型,增强了对时间和空间信息的特征提取能力<sup>[22]</sup>。Ehsani 等提出了 NowCasting-Nets 预报模型,提高了降水临近预报的时效性<sup>[23]</sup>。方巍等提出了一种基于对抗型光流长短期记忆网络模型 DCF-LSTM,该模型具有较好的抗畸变性<sup>[24]</sup>。

尽管前人已经提出了很多基于循环神经网络(Recurrent Neural Networks, RNN)的模型,但是受限于循环结构的连续性特征,无法实现并行化操作,在反向传播过程中非常消耗时间。随后,研究者将最初应用于医学图像分割领域的基于卷积神经网络的 UNet 模型<sup>[25]</sup>引入降水临近预报领域,验证其适用性,取得了良好的效果<sup>[4]</sup>。Trnbing 等提出了 SmaAt-UNet 模型,仅使用 25% 的可训练参数就得到了与 UNet 模型相近的预报性能<sup>[26]</sup>。但是受限于卷积运算固有的局部性特征,基于卷积神经网络(Convolutional Neural Networks, CNN)的模型在学习全局特征和长期信息方面表现出很大的局限性。Transformer 结构最初是在自然语言处理(Natural Language Processing, NLP)领域中提出来的<sup>[27]</sup>,由于其在提取长期信息方面的突出表现,且具有良好的并行性,已成功应用于很多领域。其中,Vision Transformer 结构<sup>[28]</sup>和 Swin Transformer 结构<sup>[29]</sup>在计算机视觉领域都取得了广泛成功,但基于 Transformer 结构的方法空间复杂度较高,无法直接应用于高时空分辨率的降水临近预报任务<sup>[30]</sup>。针对以上问题,Chen 等提出了 TransUNet 模型,通过融合卷积神经网络和 Transformer 结构学习数据中的全局和局部特征<sup>[31]</sup>。Yang 等提出了

AA-TransUNet 模型,缩减了 TransUNet 模型的可训练参数,提高了模型的预报性能<sup>[32]</sup>。

针对传统雷达回波外推方法中存在的资料信息利用率不足和预报准确率随时效的增加而下降快等问题,本文将 UNet 模型和 Swin Transformer 结构进行有效融合,构造了 SwinAt-UNet 模型,以自适应地学习雷达回波资料中的短期和长期动态变化信息;同时,为提高模型的泛化能力和预报准确率,引入了深度可分离卷积<sup>[33]</sup>和卷积块注意力模块(Convolutional Block Attention Module, CBAM)<sup>[34]</sup>,并利用上海市多年的高时空分辨率天气雷达探测资料构造数据集,通过多重反射率评估试验对该模型的预报效果进行检验评估,以探讨基于数据驱动的深度学习方法在降水临近预报任务中的可行性和适用性;最后,为了验证 SwinAt-UNet 模型改进的有效性,本文还设计了消融试验,尝试为降水临近预报提供一种基于气象大数据和深度学习的研究思路和方法。

## 1 资料来源与分析方法

### 1.1 资料来源

本文使用的雷达探测资料是由上海市两部同步的新一代 S 波段多普勒天气雷达(南汇、青浦)拼图和计算得到的。该雷达的有效探测距离为 230 km,时间分辨率为 6 min,空间分辨率为 1 km,雷达数据的中心地理坐标为(31°0′25″N, 121°52′55″E)。为了确保样本数据的质量,首先通过相关系数(CC)方法对体扫反射率因子数据进行质量控制,这样可以有效抑制地物杂波等非降水回波的影响<sup>[35]</sup>。此外,由于基数据是采用极坐标格式进行存储的,为了方便后续的计算,采用最邻近插值法将其插值到三维笛卡尔坐标系中,网格的水平分辨率为 0.01°,生成的等高平面位置显示(Constant Altitude Plan Position Indicator, CAPPI)图像分辨率为 460×460。考虑到对流层中代表性平均引导气流的高度,选取垂直高度为 3 km 的等高平面位置显示图像作为样本数据<sup>[13]</sup>。每个网格点的数值代表基本反射率的大小,数值越大表示该网格点的雷达回波强度越强,降水的可能性越高。降水回波的基本反射率通常在 10 dBZ 以上,因此,本文将缺省值和基本反射率小于 10 dBZ 的数值均设置为 0,将基本反射率大于 70 dBZ 的数值均设置为 70,这样数据范围为 0~70 dBZ。

为了提高训练效率,本文将等高平面位置显示

图像进一步转换为 PNG 格式存储的灰度图像。雷达探测资料的覆盖时间为 2017~2020 年的 6 月至 9 月,共包含 243 个降水过程。为了提高训练效率,本文选取部分有雨天气子集构成数据集,共包含 40 000 个样本数据。为了得到用于训练、验证和测试的不相交子集,本文将数据划分成 400 个不重叠的帧块,并顺序选取 320 个帧块用于训练,40 个帧块用于验证,40 个帧块用于测试。因此,试验数据包含 32 000 个训练序列,4 000 个验证序列和 4 000 个测试序列,序列长度为 20 帧,沿通道维度进行叠加。前 10 帧用于模型的输入,时间间隔为 6 min,后 10 帧用于预测,时间间隔为 12 min,相当于用过去 1 h 的天气情况预测未来 2 h 内雷达回波图像中每个像素点的降水强度。为提高不同强度雷达回波区域的可辨识度,通常会将雷达回波图像转换为伪彩色图像。图 1 为 2019 年 8 月 10 日 12 时 30 分上海地区雷达回波图像伪彩色转换过程。图 2 为数据集中一组样本(2019 年 9 月 1 日 10 时至 13 时)的可视化图像。

## 1.2 分析方法

### 1.2.1 Swin Transformer 结构

Swin Transformer 结构克服了循环神经网络模型中存在的记忆长度有限和无法并行化的问题,能够有效捕捉雷达回波资料中的长期动态变化信息。图 3 为本文采用的 Swin Transformer 结构,其由补丁分割模块以及窗口多头自注意力(Windows Multi-head Self-attention, W-MSA)和移动窗口多头自注意力(Shifted Windows Multi-head Self-at-

tention, SW-MSA)模块两部分组成。首先通过补丁分割模块将输入的特征图切分为不重叠的补丁(Patches),然后通过线性映射模块将每个补丁线性映射为一维向量,用于 W-MSA 和 SW-MSA 模块的输入。W-MSA 模块通过将特征图划分成多个不相交的子窗口,在每个子窗口中独立进行自注意力计算来减少计算量。SW-MSA 模块通过使用移动窗口策略让信息可以在相邻窗口之间进行传递。W-MSA 和 SW-MSA 模块的计算过程为

$$\hat{A}_l = \text{W-MSA}(\text{LN}(A_{l-1})) + A_{l-1} \quad (1)$$

$$A_l = \text{MLP}(\text{LN}(\hat{A}_l)) + \hat{A}_l \quad (2)$$

$$\hat{A}_{l+1} = \text{SW-MSA}(\text{LN}(A_l)) + A_l \quad (3)$$

$$A_{l+1} = \text{MLP}(\text{LN}(\hat{A}_{l+1})) + \hat{A}_{l+1} \quad (4)$$

式中:MLP 表示多层感知机;LN 表示层归一化;W-MSA 表示窗口多头自注意力;SW-MSA 表示移动窗口多头自注意力; $\hat{A}_l$  和  $A_l$  分别表示第  $l$  层中 W-MSA 和 SW-MSA 模块及多层感知机的输出特征。

Swin Transformer 结构的优势在于计算复杂度与图像大小成线性关系,在处理高时空分辨率的雷达回波资料时计算效率得到了显著提升。具体而言,W-MSA 和 SW-MSA 模块是在不重叠的局部窗口中而非整张雷达回波特征图像中进行自注意力计算,同时允许跨窗口连接,将计算复杂度从图像大小的二次方减小为线性关系,极大地提高了计算效率。自注意力计算公式为

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}(\mathbf{Q}\mathbf{K}^T / \sqrt{d_k} + B)\mathbf{V} \quad (5)$$

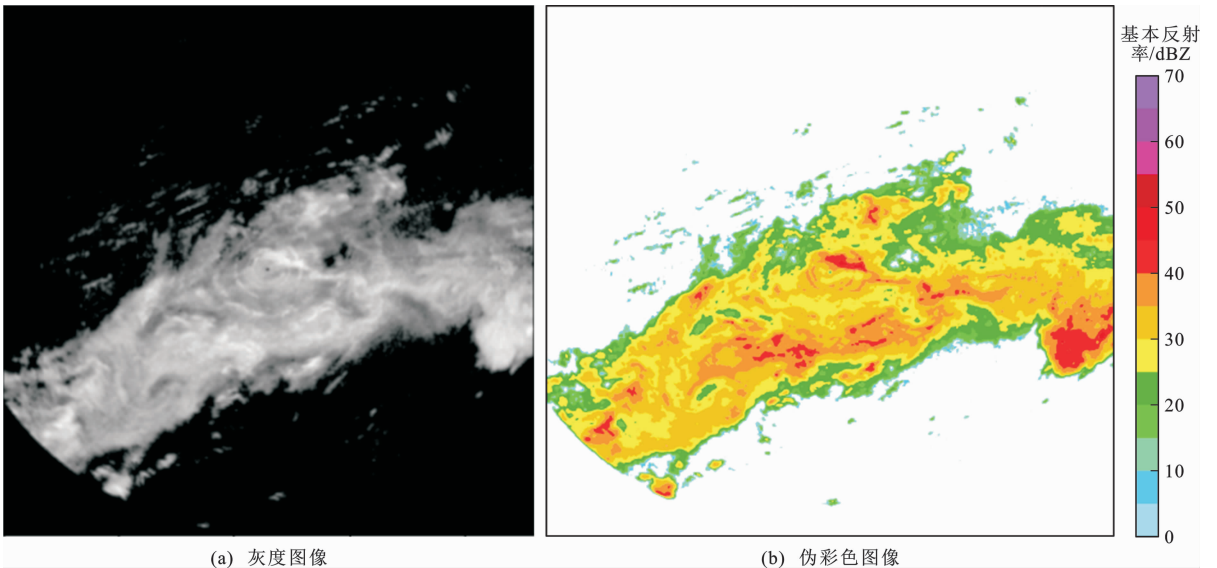
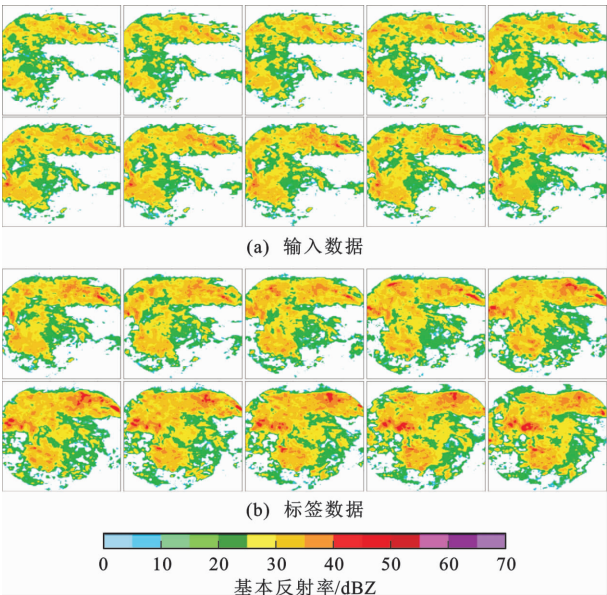


图 1 2019 年 8 月 10 日 12 时 30 分上海地区雷达回波图像伪彩色转换过程

Fig. 1 Pseudo-color Transformation Processing of Radar Echo Image in Shanghai Area at 12:30 on August 10, 2019



第一帧输入时间为 2019 年 9 月 1 日 10 时 06 分

图 2 2019 年 9 月 1 日 10 时至 13 时上海地区雷达回波图像序列可视化结果

Fig. 2 Visualization Results of Radar Echo Image Sequence in Shanghai Area from 10:00 to 13:00 on September 1, 2019

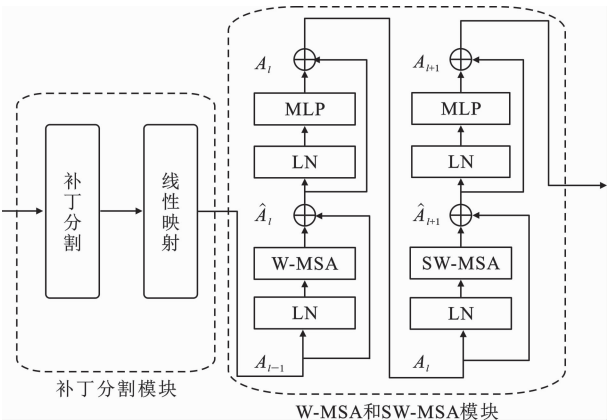


图 3 Swin Transformer 结构示意图

Fig. 3 View of Swin Transformer Structure

$$\text{head}_k = \text{Attention}(\mathbf{Q}\mathbf{W}_k^Q, \mathbf{K}\mathbf{W}_k^K, \mathbf{V}\mathbf{W}_k^V) \quad (6)$$
$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{head}_1, \dots, \text{head}_h) \mathbf{W}^O \quad (7)$$

式中： $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$  分别表示查询向量、键向量和值向量； $\mathbf{W}_k^Q$ 、 $\mathbf{W}_k^K$ 、 $\mathbf{W}_k^V$ 、 $\mathbf{W}^O$  表示可训练的卷积核； $\text{head}_k$  表示第  $k$  个注意力头， $k=1, 2, \dots, h$ ； $h$  为注意力头数量； $\sqrt{d_k}$  表示键向量的维度； $B$  表示相对位置偏置，用于提升网络模型的性能； $\text{softmax}$  表示激活函数； $\text{Concat}$  表示拼接函数； $\text{Attention}$  表示自注意力； $\text{MultiHead}$  表示多头自注意力。

针对 W-MSA 模块中存在的相邻窗口之间无法

进行信息传递的问题，SW-MSA 模块通过移动窗口策略实现了相邻窗口之间的信息交互，并通过循环移位和窗口合并解决移动窗口导致的窗口增多和计算量增大的问题。循环移位后一个窗口可能由几个不相邻的子窗口组成，合并不同子窗口时可能会导致信息发生混乱，本文采用掩码机制将自注意力计算限制在每个子窗口中，以有效解决信息混乱的问题。图 4 为 SW-MSA 模块的整体计算过程，A、B、C 为循环移位过程中需要移动的区域。

1. 2. 2 SwinAt-UNet 预报网络

图 5 给出了 SwinAt-UNet 模型的网络结构。该模型将 UNet 模型和 Swin Transformer 结构进行了有效融合，可以自适应地捕捉雷达回波资料中的短期和长期动态变化信息。为提高模型的泛化能力和预报精度，本文还引入了深度可分离卷积和卷积块注意力模块。具体而言，深度可分离卷积将标准卷积分解为逐通道卷积和逐点卷积，可以显著减少模型的可训练参数。卷积块注意力模块是一种简单有效的前馈卷积神经网络注意力模块，由空间注意力模块和通道注意力模块两个互补模块组成，两者顺序排列，可以帮助模型关注空间维度和通道维度上的重要特征，并抑制对当前任务不重要的特征。

SwinAt-UNet 模型是一种编码器-解码器结构，其输入是由  $T$  张雷达回波图像组成的序列，将其沿通道维度进行堆叠以生成三维张量，最后两个维度是雷达回波图像的高度和宽度。编码器部分用于提取数据特征并逐步缩小空间分辨率，解码器部分用于将提取到的特征逐步放大到更高的空间分辨率并生成最终的预测。

编码器部分由 4 个下采样模块和 1 个 Swin Transformer 模块组成。下采样模块用于学习输入数据中的短期动态变化；Swin Transformer 模块作为下采样模块的补充，用于捕捉长期动态变化。每个下采样模块依次通过双卷积操作、卷积块注意力模块和最大池化操作提取数据特征，并逐步缩小空间分辨率。双卷积操作中统一使用卷积核为  $3 \times 3$  的深度可分离卷积，该操作使得特征通道数增加为原来的一倍。卷积块注意力模块是为了放大当前特征图比例上的重要特征，并抑制不必要的特征。最大池化操作中应用  $2 \times 2$  的最大池化运算，步长设置为 2，该操作使得特征图的空间大小减小为原来的一半。需要注意的是，每个下采样模块都是以应用卷积块注意力模块之前的特征图作为输入，从而可以将输入数据的特征一直保留到最后一个下采样模




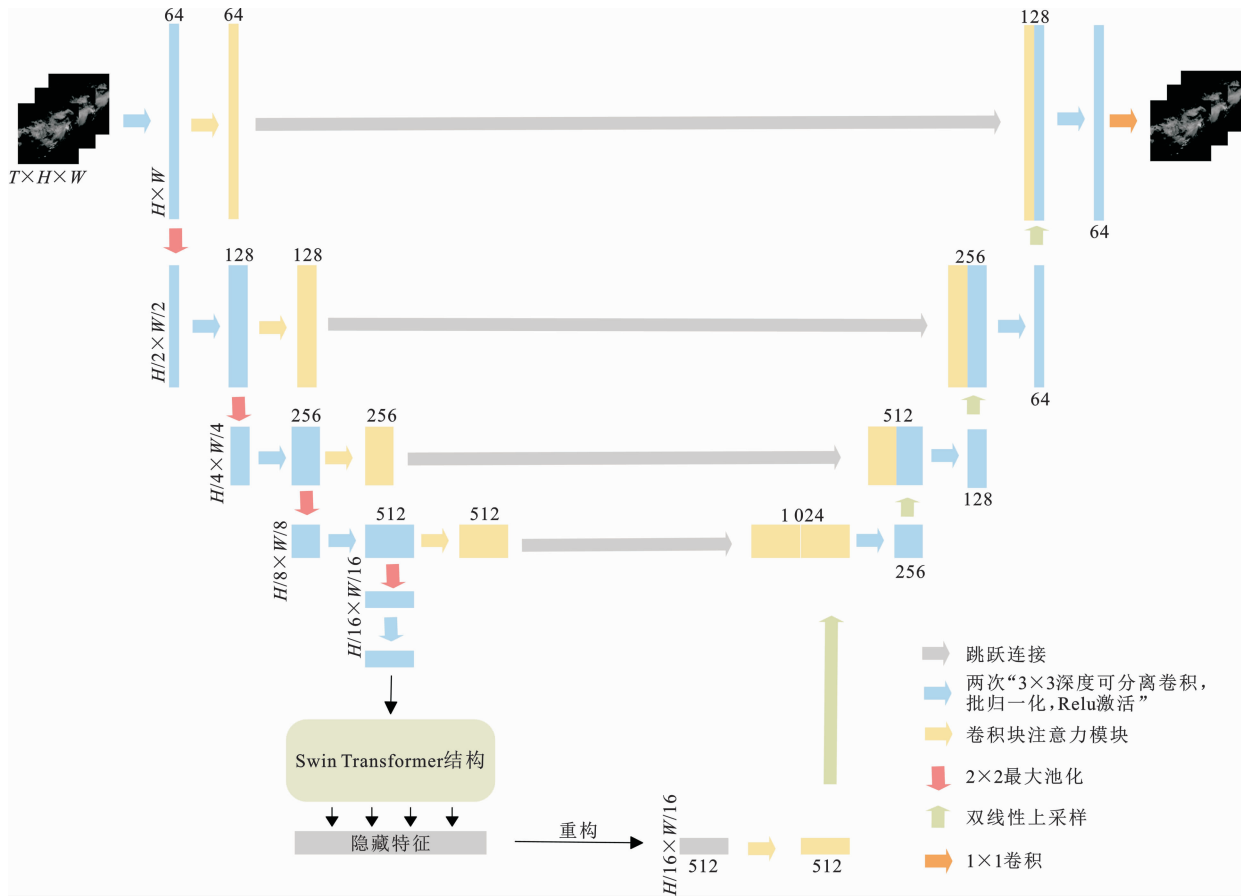


图 4 SW-MSA 模块的整体计算过程

Fig. 4 Overall Calculation Process for SW-MSA Module



$T$  为雷达回波图像序列长度;  $H$  为雷达回波图像高度;  $W$  为雷达回波图像宽度

图 5 SwinAt-UNet 模型的网络结构

Fig. 5 Network Structure of SwinAt-UNET Model

块。Swin Transformer 模块以最后一个下采样模块的输出作为输入,将生成的特征图输入到补丁分割模块中进行分块以得到不重叠的补丁,并将每个补丁线性映射为一维向量用于 W-MSA 和 SW-MSA 模块的输入。W-MSA 和 SW-MSA 模块使用多头注意力机制捕捉特征图中的长期动态变化,输出的隐藏特征重新映射为原始的维度用于解码器的输入。

解码器部分由 4 个上采样模块组成。每个上采样模块首先通过双线性上采样操作将学到的特征放大到更高的空间分辨率,然后通过跳跃连接将生成的特征图与相同比例的编码器输出进行合并,使得

模型能够使用输入的多个比例来生成输出,以捕获大小不同的对象,最后通过基于深度可分离卷积的双卷积结构将特征图的通道数量减半。4 次上采样操作后,采用  $1 \times 1$  卷积生成最终的预测结果。

在模型训练过程中,初始学习率 (Learning Rate) 设置为 0.001,时期 (Epoch) 的最大值设置为 500,批量大小 (Batch-size) 设置为 20,损失函数采用均方误差 (Mean Square Error, MSE),并使用 Adam 优化器对模型进行优化。为了使模型尽快收敛到较优值,使用学习率调整策略,当验证损失在 10 个时期内没有升高时,将学习率调整为当前学习率的 1/10。模型使用 Pytorch 开源神经网络框架进行

实现,在 NVIDIA Tesla P100 上进行训练。

### 1.3 模型评价指标

试验采用气象业务中常用的临界成功指数 (Critical Success Index, CSI)、命中率 (Probability of Detection, POD)、空报率 (False Alarm Rate, FAR)和均方误差作为评价指标<sup>[15]</sup>。由于天气雷达探测资料的真实观测值和模型进行雷达回波外推得到的预测值均为像素值,所以需要先 将像素值转换成基本反射率。为了全面评估模型的预报能力,本文设置了 15、25、35 和 45 dBZ 等 4 个阈值进行综合判别。计算不同基本反射率阈值下的临界成功指数、命中率和空报率需要根据指定阈值将预测值和真实观测值进行 0/1 二值化处理,并进行逐像素对比。4 个评价指标的计算公式分别为

$$I_{\text{CSI}} = \frac{n_{\text{hits}}}{n_{\text{hits}} + n_{\text{misses}} + n_{\text{false alarms}}} \tag{8}$$

$$R_{\text{POD}} = \frac{n_{\text{hits}}}{n_{\text{hits}} + n_{\text{misses}}} \tag{9}$$

$$R_{\text{FAR}} = \frac{n_{\text{false alarms}}}{n_{\text{hits}} + n_{\text{false alarms}}} \tag{10}$$

$$E_{\text{MSE}} = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W (y_{\text{obs}}^{(i,j)} - y_{\text{pre}}^{(i,j)})^2 \tag{11}$$

式中: $I_{\text{CSI}}$ 为临界成功指数; $R_{\text{POD}}$ 为命中率; $R_{\text{FAR}}$ 为空报率; $E_{\text{MSE}}$ 为均方误差; $n_{\text{hits}}$ 、 $n_{\text{misses}}$ 、 $n_{\text{false alarms}}$ 分别表示命中点(预测值为 1,真实观测值为 1)、漏报点(预测值为 0,真实观测值为 1)和空报点(预测值为 1,真实观测值为 0)的数量; $y_{\text{obs}}^{(i,j)}$ 表示像素点 $(i,j)$ 的真实观测值; $y_{\text{pre}}^{(i,j)}$ 表示像素点 $(i,j)$ 的预测值。

临界成功指数和命中率越大,空报率和均方误差越小,则模型的表现越好。均方误差为雷达回波图像的预测值与真实观测值逐像素误差的平方和,是最直接的误差来源。

## 2 结果分析

### 2.1 多重反射率对比评估试验

为了全面评估 SwinAt-UNet 模型在不同降水强度下的综合表现,本文选取了 4 个不同降水强度对应的基本反射率作为阈值,分别为 15、25、35 和 45 dBZ。在多重反射率对比评估试验中,本文考虑了 4 个基准模型,分别为 UNet 模型<sup>[25]</sup>、SmaAt-UNet 模型<sup>[26]</sup>、TransUNet 模型<sup>[31]</sup>和 AA-TransUNet 模型<sup>[32]</sup>。所有模型均在相同的数据集和环境下进行训练、验证和测试,外推时长为 2 h,试验结果如表 1 所示。

表 1 5 个模型在不同基本反射率阈值下的评价结果

Table 1 Evaluation Results of Five Models Under Different Base Reflectivity Thresholds

基本反射率阈值	模型名称	临界成功指数	命中率	空报率	均方误差/10 <sup>6</sup>
15 dBZ	UNet	0.685	0.738	0.098	9.319
	SmaAt-UNet	0.687	0.753	0.115	9.582
	TransUNet	0.681	0.741	0.108	9.614
	AA-TransUNet	0.677	0.734	0.103	15.761
	SwinAt-UNet	0.699	0.776	0.125	9.169
25 dBZ	UNet	0.597	0.651	0.123	9.319
	SmaAt-UNet	0.608	0.670	0.135	9.582
	TransUNet	0.599	0.661	0.138	9.614
	AA-TransUNet	0.576	0.624	0.117	15.761
	SwinAt-UNet	0.628	0.713	0.161	9.169
35 dBZ	UNet	0.392	0.452	0.270	9.319
	SmaAt-UNet	0.392	0.446	0.231	9.582
	TransUNet	0.392	0.462	0.280	9.614
	AA-TransUNet	0.335	0.364	0.182	15.761
	SwinAt-UNet	0.422	0.517	0.309	9.169
45 dBZ	UNet	0.207	0.218	0.178	9.319
	SmaAt-UNet	0.121	0.128	0.232	9.582
	TransUNet	0.170	0.180	0.182	9.614
	AA-TransUNet	0.043	0.046	0.088	15.761
	SwinAt-UNet	0.233	0.255	0.247	9.169

注:表中数据为测试集中 100 组数据样本在 2 h 内各个评价指标的平均值。

从表 1 可以看出,相较于 4 个基准模型,SwinAt-UNet 模型在不同基本反射率阈值下临界成功指数、命中率和均方误差均获得了最优表现。相比之下,TransUNet 模型和 AA-TransUNet 模型在低基本反射率的情况下表现欠佳;主要原因在于其修改了 UNet 模型中对称的双卷积操作,造成模型特征提取和反向重构的效果有所影响。当基本反射率较高时,TransUNet 模型的预报能力有所提高;主要原因在于该模型融合了 Transformer 结构,能够捕捉雷达回波资料中的长期动态变化;基本反射率越高,被过滤掉的信息越多,从而使得模型捕捉长期动态变化的能力得以体现。SwinAt-UNet 模型并没有破坏 UNet 模型中对称的双卷积结构,而是在此基础上融合了 Swin Transformer 结构,结合了两者的优点,从而获得了较好的预报性能。UNet 模型和 SmaAt-UNet 模型的预报性能相近,但始终低于 SwinAt-UNet 模型,尤其在高基本反射率的情况下;主要原因在于其无法自适应地学习雷达回波资料中的短期和长期动态变化,使得资料利用率不足,

预报准确率较低。

为了能够更加直观地观察各模型的表现及数据变化情况,本文绘制了在不同基本反射率阈值下外推 2 h 内临界成功指数的整体变化过程,时间步长间隔为 12 min,结果如图 6 所示。从图 6 可以看出,随着预报时效的延长,所有模型的临界成功指数均呈下降趋势,预报能力逐渐减弱。相比其他基准模型, SwinAt-UNet 模型在所有基本反射率阈值下临界成功指数均获得了最优表现,下降趋势更加平缓。在 45 dBZ 的基本反射率阈值下,随着预报时效的延长, SmaAt-UNet 模型和 AA-TransUNet 模型已逐渐失去预报能力;而 SwinAt-UNet 模型的预报能力较为稳定且始终优于其他基准模型,说明在基本反射率不低于 45 dBZ 的情况下,该模型的表现更为平

稳,预报更为准确。

## 2.2 消融试验

UNet 模型在处理时空序列问题方面已初见成效,但受限与卷积运算固有的局部性特征,在捕捉雷达回波资料中的长期动态变化信息方面存在局限性。针对以上问题,本文提出了 SwinAt-UNet 模型,其可以自适应地学习雷达回波资料中的短期和长期动态变化,以非自回归的方式生成预测,在预报时效和预报准确率上具有一定的优越性。

本文在 UNet 模型的基础上提出了 3 项改进措施:首先,为了学习雷达回波资料中的长期动态变化信息以提高资料利用率, SwinAt-UNet 模型将 UNet 模型和 Swin Transformer 结构进行了有效融合;其次,为了提高模型的泛化能力,减少模型的可训练

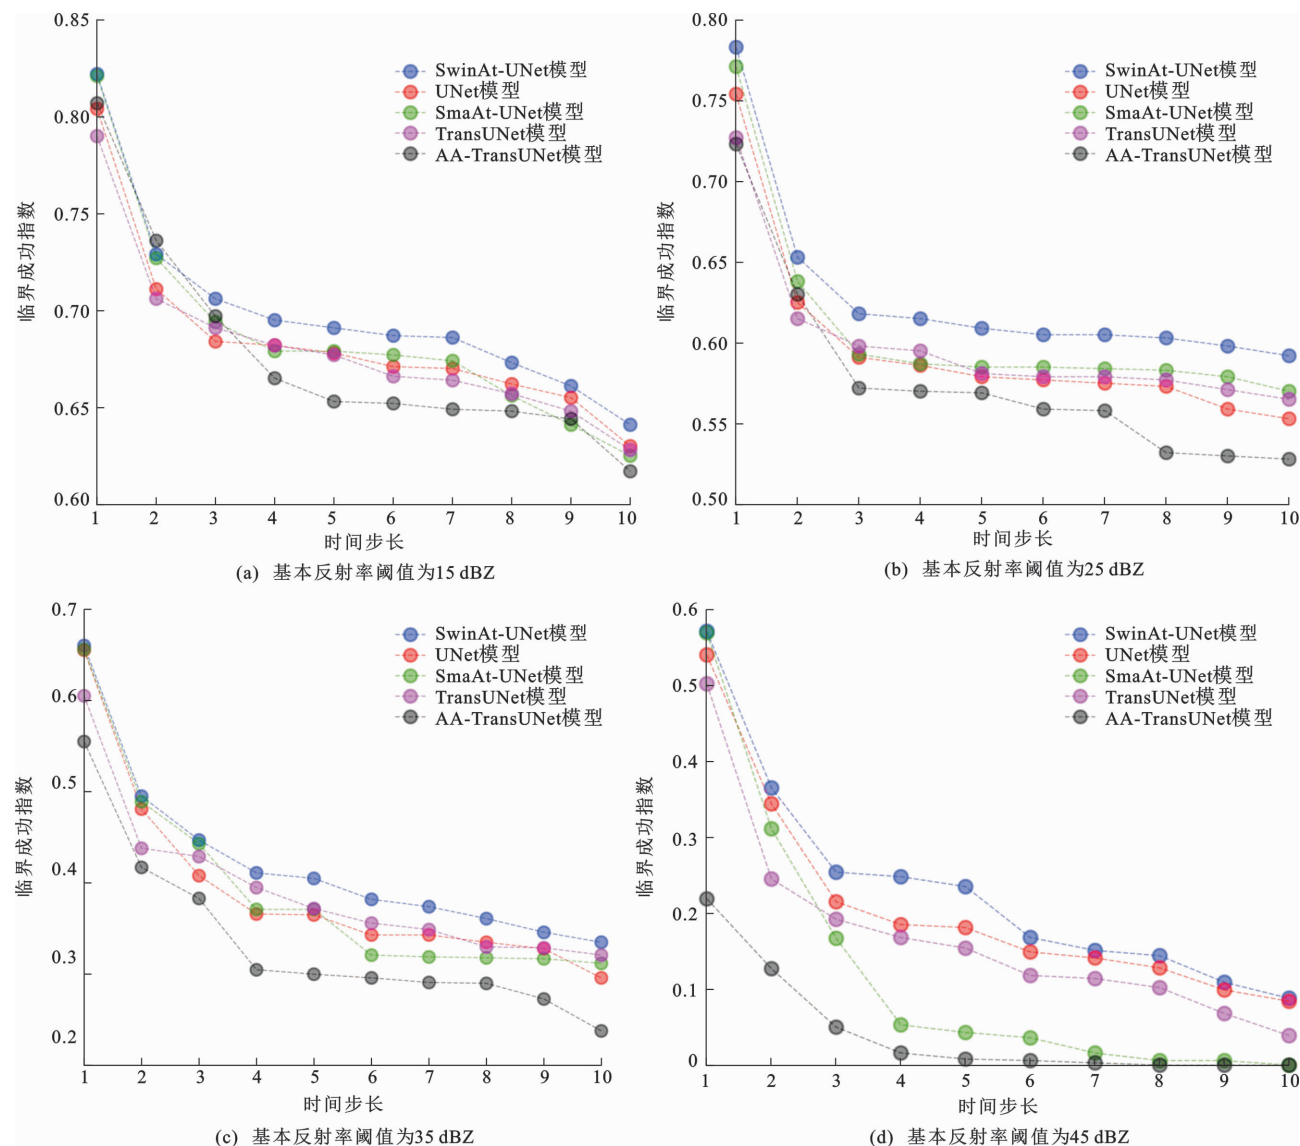


图 6 10 个时间步长上不同基本反射率阈值下 5 个模型的临界成功指数整体变化

Fig. 6 Overall Variations of CSI of Five Models Under Different Base Reflectivity Thresholds over Ten Time Steps



参数,引入了深度可分离卷积;最后,为了进一步提高模型的预报准确率,引入了卷积块注意力模块,以关注空间维度和通道维度上的重要特征。为了测试各个模块的综合改进效果,本文在 4 个不同降水强度对应的基本反射率阈值(15、25、35 和 45 dBZ)上设计了消融试验,外推时长为 2 h,试验结果如表 2 所示。

表 2 SwinAt-UNet 模型在不同基本反射率阈值下的评价结果

Table 2 Evaluation Results of SwinAt-UNet Model Under Different Base Reflectivity Thresholds					
基本反射率阈值	模型情况	临界成功指数	命中率	空报率	均方误差/ $10^6$
15 dBZ	SwinAt-UNet 模型去掉 Swin Transformer 模块	0.687	0.753	0.115	9.582
	SwinAt-UNet 模型去掉卷积块注意力模块	0.678	0.740	0.112	9.862
	SwinAt-UNet 模型去掉深度可分离卷积模块	0.694	0.757	0.109	9.266
	SwinAt-UNet 模型	0.699	0.776	0.125	9.169
25 dBZ	SwinAt-UNet 模型去掉 Swin Transformer 模块	0.608	0.670	0.135	9.582
	SwinAt-UNet 模型去掉卷积块注意力模块	0.596	0.660	0.142	9.862
	SwinAt-UNet 模型去掉深度可分离卷积模块	0.609	0.674	0.141	9.266
	SwinAt-UNet 模型	0.628	0.713	0.161	9.169
35 dBZ	SwinAt-UNet 模型去掉 Swin Transformer 模块	0.392	0.446	0.231	9.582
	SwinAt-UNet 模型去掉卷积块注意力模块	0.398	0.465	0.276	9.862
	SwinAt-UNet 模型去掉深度可分离卷积模块	0.422	0.502	0.286	9.266
	SwinAt-UNet 模型	0.422	0.517	0.309	9.169
45 dBZ	SwinAt-UNet 模型去掉 Swin Transformer 模块	0.121	0.128	0.232	9.582
	SwinAt-UNet 模型去掉卷积块注意力模块	0.150	0.156	0.145	9.862
	SwinAt-UNet 模型去掉深度可分离卷积模块	0.177	0.187	0.182	9.266
	SwinAt-UNet 模型	0.233	0.255	0.247	9.169

注:表中数据为测试集中 100 组数据样本在 2 h 内各个评价指标的平均值。

试验结果表明,以上 3 项改进措施均会影响模型的预报性能,去掉任意模块都会降低模型的预报准确率。SwinAt-UNet 模型同时进行了以上 3 项修改,其性能优于任何只进行两项修改的模型以及

未经修改的 UNet 模型。由表 2 可知,当基本反射率较低时,去掉卷积块注意力模块后的模型各项评价指标变化最为明显,说明在低基本反射率的情况下,模型中卷积块注意力模块的作用更大。具体而言,去掉卷积块注意力模块使得模型临界成功指数平均下降 0.027,命中率平均下降 0.045,均方误差平均提高 0.693。当基本反射率较高时,去掉 Swin Transformer 模块的影响更为显著;主要原因在于分辨率越高,模型过滤掉的信息越多,模型中 Swin Transformer 模块捕捉雷达回波资料中的长期动态变化的优越性得以体现。相比之下,去掉深度可分离卷积模块对模型的性能影响相对不显著,但是其可以极大地减少模型的可训练参数并提高模型的泛化能力,因此引入深度可分离卷积是必要且有效的。

图 7 给出了在 25 和 45 dBZ 的基本反射率阈值下外推 2 h 内临界成功指数的整体变化过程,时间步长间隔为 12 min。由图 7 可以发现,去掉任意一个模块都会影响模型的整体预报性能。在 25 dBZ 的基本反射率阈值下,去掉卷积块注意力模块后的模型临界成功指数下降速度最快,说明在基本反射率较低时引入卷积块注意力模块的作用更为显著。在 45 dBZ 的基本反射率阈值下,去掉 Swin Transformer 模块后的模型临界成功指数下降速度最快,说明在基本反射率较高时融合 Swin Transformer 结构的作用更为显著。总之,模块完整的 SwinAt-UNet 模型临界成功指数下降趋势更加平缓,预报准确率更高。

### 3 对流云降水外推结果对比

为了进一步验证 SwinAt-UNet 模型的优越性,本文选取 2020 年 7 月 6 日 10 时至 13 时发生在上海市的一次对流云降水过程进行分析。该降水过程的最强雷达回波强度超过 50 dBZ,利用前 1 h 的雷达回波图像外推后 2 h 的降水情况,时间分辨率为 6 min。输入的时间间隔为 6 min,外推的时间间隔为 12 min。为清晰观察降水云团不同强度雷达回波区域的整体演变过程,基本反射率阈值设置为 15 dBZ。

图 8 给出了 5 个模型在该降水过程上的外推结果。从地面实况图像可以看出,强回波区域分布较为集中且始终保持一定的大小[图 8(b)]。上方降水云团中的强回波区域始终处于不断变化的状态,只有 SwinAt-UNet 模型能够较为准确地预测该演变过程。相比于其他 4 个基准模型,SwinAt-UNet

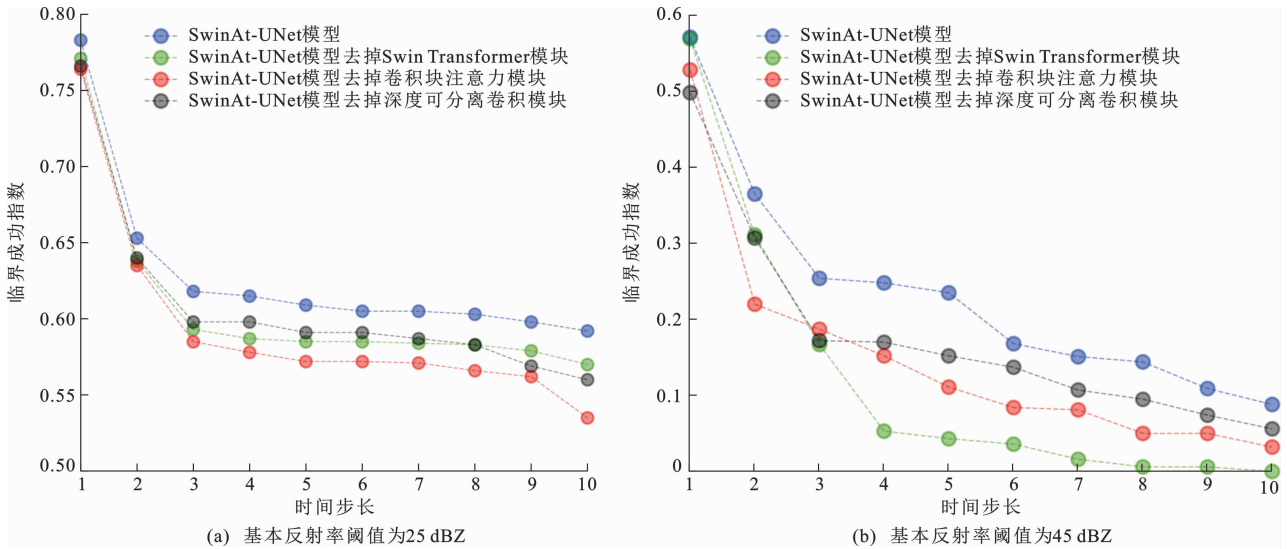


图 7 10 个时间步长上不同基本反射率阈值下 SwinAt-UNet 模型去掉各模块后的临界成功指数整体变化

Fig. 7 Overall Variations of CSI of SwinAt-UNet Model Removing Each Module Under Different Base Reflectivity Thresholds over Ten Time Steps

模型的外推图像具有更加清晰的边缘和细节性纹理,可以更好地预测降水云团的生消演变规律,对强回波区域的预测更为准确。相比之下,UNet 模型和 SmaAt-UNet 模型对降水区域的预测范围过大,TransUNet 模型和 AA-TransUNet 模型对强回波区域的预测能力较弱,预测值过于保守。

为了量化各模型在该降水过程中的表现,表 3 给出了 15 dBZ 的基本反射率阈值下各模型在临界成功指数、命中率、空报率和均方误差上的评估结果。从表 3 可以看出,相较于其他 4 个基准模型, SwinAt-UNet 模型得到了最高的临界成功指数和命中率,预报准确率更高。

表 3 5 个模型在基本反射率阈值为 15 dBZ 时的评价结果

Table 3 Evaluation Results of Five Models Under Base Reflectivity Threshold of 15 dBZ

模型名称	临界成功指数	命中率	空报率	均方误差/ $10^6$
UNet	0.715	0.762	0.079	1.202
SmaAt-UNet	0.718	0.778	0.096	1.181
TransUNet	0.699	0.747	0.083	1.285
AA-TransUNet	0.630	0.661	0.065	1.278
SwinAt-UNet	0.722	0.787	0.103	1.205

## 4 结 语

本文介绍了基于数据驱动的深度学习方法在降水临近预报中的应用,并通过融合 UNet 模型和 Swin Transformer 结构提出了 SwinAt-UNet 模型,以自适应地学习雷达回波资料中的短期和长期动态变化,然后引入了深度可分离卷积和卷积块注意力

模块以提高模型的泛化能力和预报准确率,最后在此基础上与其他深度学习模型的预报结果进行对比。

(1)深度学习作为一种数据驱动技术,具有强大的非线性映射能力,可以充分利用大量历史数据对雷达回波进行非线性外推。深度学习模型 SwinAt-UNet 可以自适应地学习雷达回波资料中的短期和长期动态变化,提高了资料信息利用率和预报准确率,并且克服了循环神经网络模型中存在的记忆长度有限和无法并行化的问题,在预报时效上具有一定的优越性。

(2)在气象业务中,不同降水强度给予的关注度不同,对人类活动影响较大的强降水往往被赋予更多的关注。多重反射率评估试验结果表明, SwinAt-UNet 模型在 15、25、35 和 45 dBZ 的基本反射率阈值下均取得了最高的临界成功指数。在 45 dBZ 的强回波阈值下,临界成功指数相较于其他基准模型提高了 13%,能够更好地预报未来 2 h 的雷达回波变化。

(3)消融试验结果表明, SwinAt-UNet 模型的 3 个改进措施——融合 Swin Transformer 结构、采用深度可分离卷积和引入卷积块注意力模块,均会影响模型的预报能力。在基本反射率较低时,引入卷积块注意力模块的作用更为显著;在基本反射率较高时,融合 Swin Transformer 结构的重要性得以体现。

(4)对流云降水外推对比试验结果表明,相较于其他基准模型, SwinAt-UNet 模型能够更好地预测




图 8 5 个模型在 2020 年 7 月 6 日 10 时至 13 时上海地区对流云降水过程上的外推结果对比

Fig. 8 Comparisons of Extrapolation Results of Five Models on Convective Cloud Precipitation Process in Shanghai Area from 10:00 to 13:00 on July 6, 2020

降水范围、移动方向和强度变化,外推图像具有更加清晰的边缘和细节性纹理,对强回波区域的预测更为准确。

(5)本文提出的 SwinAt-UNet 模型存在深度学习方法普遍存在的不足和局限性。基于深度学习的降水临近预报模型仅使用雷达回波图像序列作为模型的输入数据,缺乏对温度、风场等其他气象特征的综合观测,预测结果具有不确定性,并且随着预报时效的延长,外推图像趋向于模糊。在未来的研究中,有必要尝试输入多源融合气象数据,并使用生成对抗网络增强雷达图像的生成质量,在保证现有预报准确率的前提下解决预报模型外推模糊的问题。

《地球科学与环境学报》编辑部在主编彭建兵院士的领导下,聚焦国内外地学领域的重要基础和前沿问题,精心策划出版了很多非常有学术影响力的专刊,如“纪念刘国昌先生诞辰 110 周年专辑”“庆祝长安大学建校七十周年专辑”等! 2023 年,《地球科学与环境学报》将迎来更名二十周年,期待贵刊学术影响力再上新台阶!

参 考 文 献 :

References :

[1] 湛 芸,曹 勇,孙 健,等.中央气象台精细化网格降水预报技术的发展和思考[J]. 气象,2021,47(6):

- 655-670.
- CHEN Yun, CAO Yong, SUN Jian, et al. Progress of Fine Gridded Quantitative Precipitation Forecast Technology of National Meteorological Centre[J]. Meteorological Monthly, 2021, 47(6): 655-670.
- [2] 肖 蕾, 杜小玲, 武正敏, 等. 贵州省短时强降水时空分布特征分析[J]. 暴雨灾害, 2021, 40(4): 383-392.
- XIAO Lei, DU Xiao-ling, WU Zheng-min, et al. Temporal and Spatial Distribution Characteristics of Short-time Heavy Rainfall in Guizhou Province[J]. Torrential Rain and Disasters, 2021, 40(4): 383-392.
- [3] 程丛兰, 陈 敏, 陈明轩, 等. 临近预报的两种高时空分辨率定量降水预报融合算法的对比试验[J]. 气象学报, 2019, 77(4): 701-714.
- CHENG Cong-lan, CHEN Min, CHEN Ming-xuan, et al. Comparative Experiments on Two High Spatio-temporal Resolution Blending Algorithms for Quantitative Precipitation Nowcasting[J]. Acta Meteorologica Sinica, 2019, 77(4): 701-714.
- [4] LIANG H, CHEN H N, ZHANG W, et al. Convective Precipitation Nowcasting Using U-Net Model [C]// IEEE. 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS. Brussels: IEEE, 2021: 7134-7137.
- [5] CRANE R K. Automatic Cell Detection and Tracking [J]. IEEE Transactions on Geoscience Electronics, 1979, 17(4): 250-262.
- [6] AUSTIN G L, BELLON A. The Use of Digital Weather Radar Records for Short-term Precipitation Forecasting[J]. Quarterly Journal of the Royal Meteorological Society, 1974, 100: 658-664.
- [7] GIBSON J J. The Ecological Approach to Visual Perception: Classic Edition[M]. London: Psychology Press, 2014.
- [8] 王 芬, 李腹广, 张 辉. 风暴单体识别与跟踪(SCIT)算法评估[J]. 气象, 2010, 36(12): 128-133.
- WANG Fen, LI Fu-guang, ZHANG Hui. Storm Cell Identification and Tracking Algorithm for Assessment of SCIT[J]. Meteorological Monthly, 2010, 36(12): 128-133.
- [9] 俞小鼎, 周小刚, 王秀明. 雷暴与强对流临近天气预报技术进展[J]. 气象学报, 2012, 70(3): 311-337.
- YU Xiao-ding, ZHOU Xiao-gang, WANG Xiu-ming. The Advances in the Nowcasting Techniques on Thunderstorms and Severe Convection[J]. Acta Meteorologica Sinica, 2012, 70(3): 311-337.
- [10] 田 刚, 陈良华, 魏 凡, 等. 基于光流法雷达外推的2020年长江致洪降水临近预报检验评估[J]. 暴雨灾害, 2021, 40(3): 316-325.
- TIAN Gang, CHEN Liang-hua, WEI Fan, et al. Evaluation of Flood-producing Rainfall Nowcasting Based on Radar Extrapolation with the Variational Optical Flow Method in the Yangtze River Basin in 2020[J]. Torrential Rain and Disasters, 2021, 40(3): 316-325.
- [11] 张梦涵, 魏 进, 卞海丁. 基于机器学习的边坡稳定性分析方法: 以国内618个边坡为例[J]. 地球科学与环境学报, 2022, 44(6): 1083-1095.
- ZHANG Meng-han, WEI Jin, BIAN Hai-ding. Slope Stability Analysis Method Based on Machine Learning: Taking 618 Slopes in China as Examples [J]. Journal of Earth Sciences and Environment, 2022, 44(6): 1083-1095.
- [12] 杨 玲, 魏 静, 许子伏. 基于平滑先验法-麻雀搜索算法-支持向量机回归模型的滑坡位移预测: 以三峡库区八字门和白水河滑坡为例[J]. 地球科学与环境学报, 2022, 44(6): 1096-1110.
- YANG Ling, WEI Jing, XU Zi-fu. Displacement Prediction of Landslide Based on SPA-SSA-SVR Model: Taking Bazimen and Baishuihe Landslides in Three Gorges Reservoir Area, China as Examples [J]. Journal of Earth Sciences and Environment, 2022, 44(6): 1096-1110.
- [13] 黄兴友, 马玉蓉, 胡苏蔓. 基于深度学习的天气雷达回波序列外推及效果分析[J]. 气象学报, 2021, 79(5): 817-827.
- HUANG Xing-you, MA Yu-rong, HU Su-man. Extrapolation and Effect Analysis of Weather Radar Echo Sequence Based on Deep Learning[J]. Acta Meteorologica Sinica, 2021, 79(5): 817-827.
- [14] FANG W, PANG L, YI W N, et al. AttEF: Convolutional LSTM Encoder-forecaster with Attention Module for Precipitation Nowcasting[J]. Intelligent Automation & Soft Computing, 2021, 29(3): 453-466.
- [15] SHI X J, CHEN Z R, WANG H, et al. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting [C]// CORTES C, LEE D D, SUGIYAMA M, et al. Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal: ACM, 2015: 802-810.
- [16] SHI X J, GAO Z H, LAUSEN L, et al. Deep Learning for Precipitation Nowcasting: A Benchmark and a New Model [C]// VON LUXBURG U, GUYON I. Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM, 2017: 5622-5632.
- [17] WANG Y B, WU H X, ZHANG J J, et al. PredRNN:

- A Recurrent Neural Network for Spatiotemporal Predictive Learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(2): 2208-2225.
- [18] WANG Y B, GAO Z F, LONG M S, et al. PredRNN++: Towards a Resolution of the Deep-in-time Dilemma in Spatiotemporal Predictive Learning[C]// PMLR. Proceedings of the 35th International Conference on Machine Learning. Stockholm: PMLR, 2018: 5123-5132.
- [19] WANG Y B, ZHANG J J, ZHU H Y, et al. Memory in Memory: A Predictive Neural Network for Learning Higher-order Non-stationarity from Spatiotemporal Dynamics[C]// IEEE. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 9154-9162.
- [20] WU H X, YAO Z Y, WANG J M, et al. MotionRNN: A Flexible Model for Video Prediction with Space-time-varying Motions[C]// IEEE. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021: 15435-15444.
- [21] RAVURI S, LENC K, WILLSON M, et al. Skilful Precipitation Nowcasting Using Deep Generative Models of Radar[J]. Nature, 2021, 597: 672-677.
- [22] LUO C Y, ZHAO X Y, SUN Y X, et al. PredRANN: The Spatiotemporal Attention Convolution Recurrent Neural Network for Precipitation Nowcasting [J]. Knowledge-based Systems, 2022, 239: 107900.
- [23] EHSANI M R, ZAREI A, GUPTA H V, et al. Nowcasting-Nets: Representation Learning to Mitigate Latency Gap of Satellite Precipitation Products Using Convolutional and Recurrent Neural Networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 4706021.
- [24] 方 巍, 庞 林, 张飞鸿, 等. 对抗型长短期记忆网络的雷达回波外推算法[J]. 中国图象图形学报, 2021, 26(5): 1067-1080.  
FANG Wei, PANG Lin, ZHANG Fei-hong, et al. Radar Echo Extrapolation Algorithm Based on Adversarial Long Short-term Memory Network[J]. Journal of Image and Graphics, 2021, 26(5): 1067-1080.
- [25] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation [C] // NAVAB N, HORNEGGER J, WELLS W M, et al. International Conference on Medical Image Computing and Computer-assisted Intervention; MICCAI 2015. Munich: Springer, 2015: 234-241.
- [26] TRNBING K, STANCZYK T, MEHRKANOON S. SmaAt-UNet: Precipitation Nowcasting Using a Small Attention-UNet Architecture[J]. Pattern Recognition Letters, 2021, 145: 178-186.
- [27] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is All You Need[C]// VON LUXBURG U, GUYON I. Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM, 2017: 6000-6010.
- [28] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An Image Is Worth  $16 \times 16$  Words; Transformers for Image Recognition at Scale[EB/OL]. (2020-10-22) [2022-12-20]. <https://arxiv.org/abs/2010.11929>.
- [29] LIU Z, LIN Y T, CAO Y, et al. Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows[C]// IEEE. Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021: 9992-10002.
- [30] NOGUEIRA R, JIANG Z, LIN J. Investigating the Limitations of Transformers with Simple Arithmetic Tasks[EB/OL]. (2021-02-25) [2022-12-20]. <https://arxiv.org/abs/2102.13019>.
- [31] CHEN J, LU Y, YU Q, et al. TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation[EB/OL]. (2021-02-08) [2022-12-20]. <https://arxiv.org/abs/2102.04306>.
- [32] YANG Y M, MEHRKANOON S. AA-TransUNet: Attention Augmented TransUNet for Nowcasting Tasks[C]// IEEE. 2022 International Joint Conference on Neural Networks (IJCNN). Padua: IEEE, 2022: 1-8.
- [33] CHOLLET F. Xception: Deep Learning with Depth-wise Separable Convolutions[C]// IEEE. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 1800-1807.
- [34] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module[C]// FERRARI V, HEBERT M, SMINCHISDESCU C, et al. Computer Vision-ECCV 2018. Munich: Springer, 2018: 3-19.
- [35] 张 林, 李 峰, 吴 蕾, 等. CINRAD/SAD 双偏振雷达非降水回波识别技术[J]. 应用气象学报, 2022, 33(6): 724-735.  
ZHANG Lin, LI Feng, WU Lei, et al. Non-precipitation Identification Technique for CINRAD/SAD Dual Polarimetric Weather Radar[J]. Journal of Applied Meteorological Science, 2022, 33(6): 724-735.