

DOI:10.19651/j.cnki.emt.2212003

GLnet:融合全局和局部信息的短临降雨预报网络

尹传豪 秦华旺 戴跃伟 陈浩然 包顺

(南京信息工程大学电子与信息工程学院 南京 210044)

摘要: 基于雷达回波外推的定量降水预测具有广泛的应用前景。为了提高降水区域和强度的预测准确性,本文提出了一种新的基于 Unet 和 Swin-Transformer 的临近降水预报模型 GLnet。该模型具有非对称双路特征提取结构,通过卷积和窗口自注意力机制分别提取雷达回波图片的局部和全局特征。同时在两类特征融合前引入了 CBAM 注意力机制和 Non-local 非局部注意力机制。本文在公开的荷兰降水地图数据集上分别采样出至少包含 20% 和 50% 降水像素点的子集 NL-20 和 NL-50,并利用结构相似性损失函数进行了实验。结果表明本文模型相比原始的 Unet, MSE 误差分别下降了 14.4% 和 10.6%。

关键词: 降水预报;注意力机制;特征融合;SwinTransformer

中图分类号: P409; TP391.41; TP18 文献标识码: A 国家标准学科分类代码: 520.2040

GLnet: Precipitation nowcasting network combining global and local information

Yin Chuanhao Qin Huawang Dai Yuewei Chen Haoran Bao Shun

(Nanjing University of Information Science and Technology, Electronics and Information Engineering College, Nanjing 210044, China)

Abstract: Quantitative precipitation prediction based on radar echo extrapolation has broad prospects. It's important to get accurate nowcasting. To this end, we propose GLnet, an efficient neural networks-based on Unet and Swin-Transformer architecture equipped with two different attention modules CBAM and Non-local. The model has an asymmetric two-way feature extractor. In this way, the GLnet model extracts local and global features of radar echo images through convolution and windows self-attention mechanisms respectively. We create two datasets, NL-20 and NL-50, in Netherlands Precipitation Dataset by filtering the original precipitation dataset and choosing only the images with at least 20% and 50% of pixels containing any amount of rain respectively. We evaluate our approaches in NL-20 and NL50. The experimental results show that compared with the classical model Unet, the mean square error is reduced by 14.4% and 10.6% respectively.

Keywords: precipitation forecasting; attention mechanism; feature fusion; swin-transformer

0 引言

实时预报天气情况,对工农业生产,交通运输,军事指挥,具有重要的意义。尤其是预报时长在 0~2 h 的是短临降水预报至关重要,传统的短临预报方法主要分为两类数值天气预报^[1](numerical weather forecast, NWP),和雷达回波外推。NWP 通过求解描写天气演变过程的流体力学和热力学的方程组,预测未来一定时段的大气运动状态和天气现象。基于 NWP 的方法需要消耗巨大的算力,无法实现高精度时空分辨率的降水临近预报。基于光流法^[2]的雷达回波外推能够学习连续两帧雷达图片的运动信息,但是无法捕获雷达序列的长时间依赖,同时容易造成误差的

叠加,同样难以获得高精度降水预报。针对以上问题,深度学习技术被应用到雷达回波外推领域中。目前,时空序列预测的神经网络模型主要有两大类:一种是基于卷积神经网络(convolutional neural network, CNN)结构进行序列图像生成;另一种是基于循环神经网络(recurrent neural network, RNN)进行序列图像的预测^[3]。文献[4]将降水预测问题视作时空序列预测问题,首次将卷积与长短期记忆网络(long short-term memory, LSTM)结合,用于学习雷达序列中的时空特征,在此基础上文献[5]创建了一种新的时空 LSTM 块,(Spatiotemporal LSTM, ST-LSTM)在垂直方向增加了内存连接路径,以实现空间信息的高效传递。文献[6]将降水预测视为一个图像到图像的转换问题,

并利用优秀的图像分割网络 Unet^[7]进行降水雷达图片的生成。文献[8]在 Unet 的基础上增加了深度可分离卷积在减少网络参数量的同时取得了与 Unet 近似的性能。另外,本文注意到注意力机制可以有效提升卷积神经网络的性能。文献[9]为 Unet 配备了通道注意力机制有效提升了网络的云图分割性能。

尽管基于卷积的 Unet 及其变体在降水预测领域取得了巨大的成功,但是卷积仅依靠固定大小为 $n \times n$ 的窗口提取雷达图片的局部特征,无法建模整张雷达图片的全局依赖。基于窗口自注意力的 SwinTransformer^[10]具有强大的全局信息提取能力,结合卷积神经网络和

SwinTransformer 各自的优点,本文提出了一种新的神经网络 GLnet,其遵循 Unet 的设计原则,包含上采样,下采样,和跳连接,以及并行的卷积和 SwinTransformer 的特征提取框架,以获得不同尺度的雷达降水图的全局语义表示和局部特征信息。

1 模型方法

1.1 模型概述

本文提出的模型 GLnet,旨在获得不同尺度降水图片下的局部空间信息和全局语义表示,通过融合不同层次的特征最终得到降水预测图片。模型的整体架构如图 1 所示。

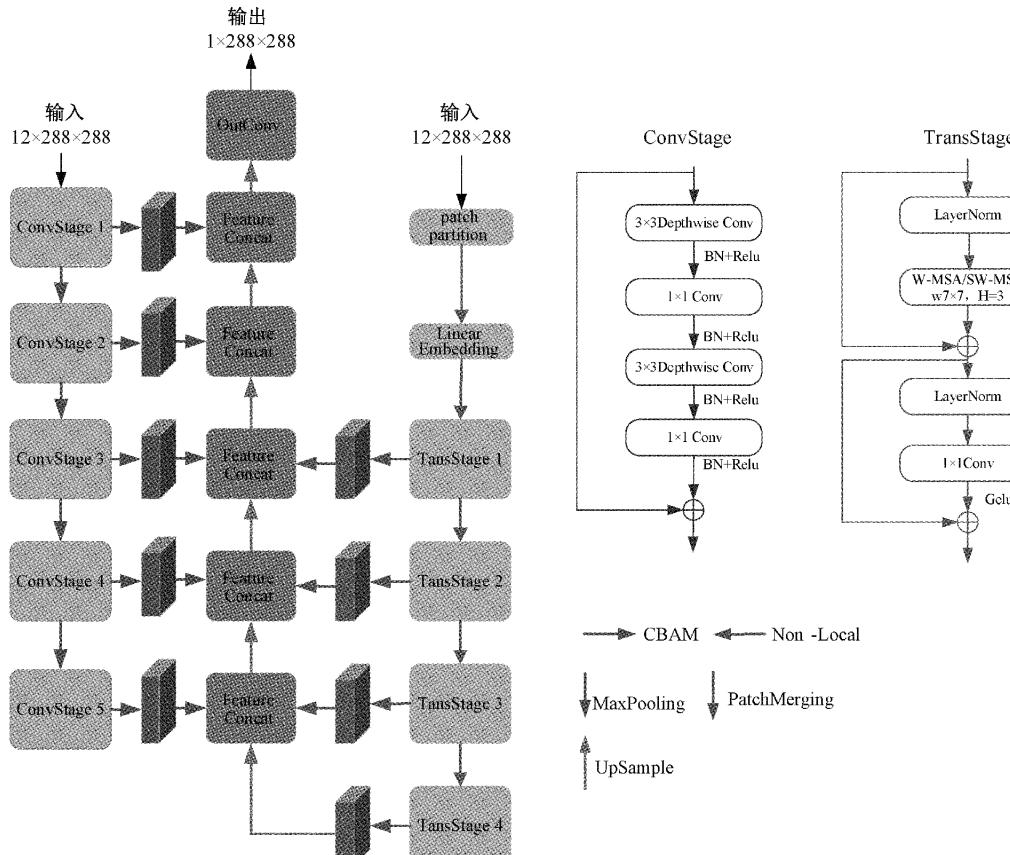


图 1 GLnet 的整体模型架构

GLnet 包含两个并行的非对称的特征提取分支,和一条特征融合路径。局部特征提取分支包含 5 阶段卷积,和最大池化下采样,全局特征提取分支包含 4 阶段的 SwinTransfoemer 块,和 PatchMerging 下采样,特征融合路径包含卷积块注意力模块^[11](convolutional block attention module, CBAM),用于抑制卷积特征图中空间和通道中的不相关信息,以及非局部模块^[12](nonlocal block),进一步捕获 SwinTransformer 提取出的全局信息中的长程像素依赖。通过将底层上采样得到的特征与上层的局部空间信息,全局语义表示融合,不断上采样最后恢复得到与原始降水图片大小相同的降水预测雷达图。

本文的 GLnet 具有以下优点:1)结合了卷积神经网络和 Transformer 的优点,设计了并行的全局和局部特征提取框架,CNN 具有平移不变性,偏置归纳,等优点同时能够补充局部空间细节。Transformer 捕获降水图片中长程依赖,这种依赖既包括时间也包括空间上的像素依赖。2)GLnet 的特征融合路径,包含了 CBAM 注意力机制和 Non-local 注意力机制,可自适应融合不同尺度下各分支提取的语义信息。GLnet 每阶段的特征图大小如表 1 所示。

局部特征提取分支每阶段包含两次的深度可分离卷积,一次深度可分离卷积先利用不同的核大小为 3 的逐通道卷积,对不同的通道进行单独卷积,其次利用卷积核大

表 1 GLnet 特征提取分支每阶段特征图大小

局部特征提取分支		全局特征提取分支	
输入	$12 \times 288 \times 288$	输入	$12 \times 288 \times 288$
ConvStage1	$32 \times 288 \times 288$	PatchEmbed	$192 \times 72 \times 72$
ConvStage2	$64 \times 144 \times 144$	TransStage1	$96 \times 72 \times 72$
ConvStage3	$128 \times 72 \times 72$	TransStage2	$192 \times 36 \times 36$
ConvStage4	$256 \times 36 \times 36$	TransStage3	$384 \times 18 \times 18$
ConvStage5	$256 \times 18 \times 18$	TransStage4	$768 \times 9 \times 9$

小为 1 的点卷积, 进行通道内信息的融合, 并将卷积得到的特征图通道映射到指定大小。全局特征提取分支每阶段堆叠两次 TransformerBlock, 雷达图片以分块的形式进

入 TransformerBlock, 首先经过层归一化后进入窗口多头自注意力模块 (windows multi-head self-attention, SW-MSA), 再通过带有 Gelu 激活函数的线性层, 并在下一个 Block 中引入移动窗口多头自注意力模块 (shifted windows multi-head self-attention, SW-MSA)。

1.2 模型细节

1) CBAM 注意力机制

注意力机制是一种加强有用信息, 抑制无关信息的机制。CBAM 包含两种不同的注意力机制, 空间注意力机制, 关注同一通道空间内不同位置像素对预测的重要性。通道注意力机制关注不同通道信息对预测的重要性。CBAM 的整体结构如图 2 所示。

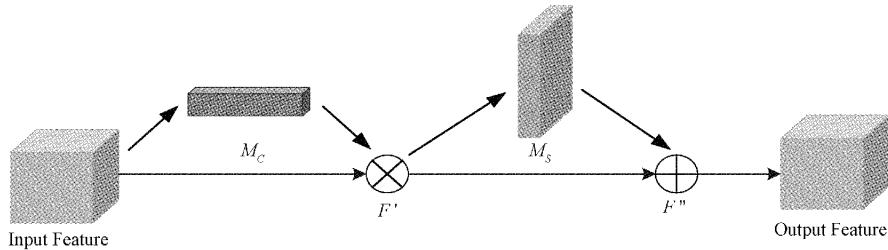


图 2 CBAM 注意力机制

CBAM 依次生成一维通道注意力 $M_C \in R^{C \times 1 \times 1}$, 和二维空间注意力 $M_S \in R^{1 \times H \times W}$, CBAM 注意力机制生成特征图的过程可以描述为下式。其结果是一个加权的特征图。

$$F' = M_C(F) \times F \quad (1)$$

$$F'' = M_S(F') \times F \quad (2)$$

对于卷积生成的特征图 $F \in R^{C \times H \times W}$, 式中 C 表示通道数, H 表示特征图的长, W 表示特征图的宽。通道注意力机制通过对原特征图通道维度上的最大池化和平均池化, 生成两个压缩了空间信息的一维特征 F_{avg}^c , 和 F_{max}^c , 将其输入多层感知器 MLP 中运算并相加后经过 Sigmoid 函数得到通道注意力 M_C , 如图 3 所示。

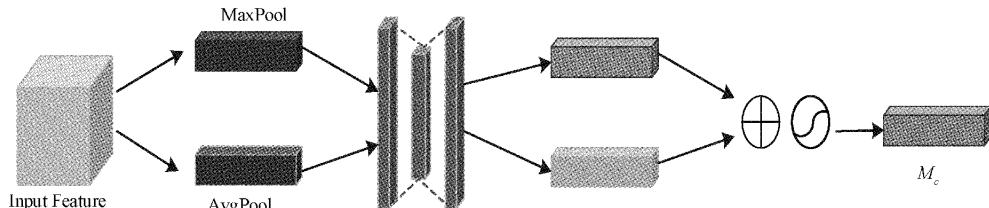


图 3 通道注意力机制

通道注意力的生成过程可描述为:

$$M_c = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \quad (3)$$

$$M_C = \sigma(W_1(W_0(F_{\text{Avg}}^c) + W_0(F_{\text{Max}}^c))) \quad (4)$$

其中, σ 是 sigmoid 函数, W_1 和 W_0 是 MLP 的权重。

空间注意力机制对特征图进行空间维度上的最大池化和平均池化生成两个压缩了通道信息的二维特征 F_{Avg}^s 和 F_{Max}^s , 并将其沿着通道维度拼接, 卷积并经过 Sigmoid 运算得到空间注意力 M_s , 如图 4 所示。

空间注意力的生成过程可描述为:

$$M_s(F) = \sigma(f^{7 \times 7}[\text{AvgPool}(F) + \text{MaxPool}(F)]) \quad (5)$$

$$M_S(F) = \sigma(f^{7 \times 7}[F_{\text{Avg}}^s + F_{\text{Max}}^s]) \quad (6)$$

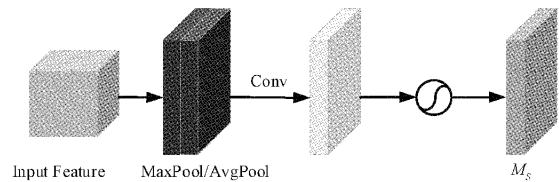


图 4 空间注意力机制

2) Nonlocal 注意力机制

非局部注意力机制通过直接计算当前像素点与特征图内所有像素点之间相似度值, 然后对相似性值进行加权求和以表示当前像素点的特征信息。非局部注意力机制的具体操作如下式所示:

$$y_i = \frac{1}{C(x)} \sum_{\forall j} f(x_i, x_j) g(x_j) \quad (7)$$

其中, x 表示输入特征图, y 表示输出特征图, x 与 y 尺寸相同, i 代表输出特征位置的索引, j 代表特征图中所有其他可能位置的索引。二元函数 $f(x_i, x_j)$ 计算 x_i, x_j 的相似度, 一元函数 $g(x_j)$ 计算输入特征在位置 j 的特征表示。 $C(x) = N, N$ 指所有 x 位置的数量。

对于函数 g 本文使用的是一个线性嵌入函数 $g(x_j) = w_g x_j$, 其中 w_g 是一个可学习的权重矩阵, 在实验中使用 1×1 的卷积实现。函数 f 使用的是点积实现 $f(x_i, x_j) = \theta(x_i)^T \phi(x_j), \theta(x_i) = w_\theta x_i, \phi(x_j) = w_\phi x_j$ 是两个嵌入函数, 实验中同样用 1×1 卷积层实现。非局部注意力机制的具体的实现流程如图 5 所示。

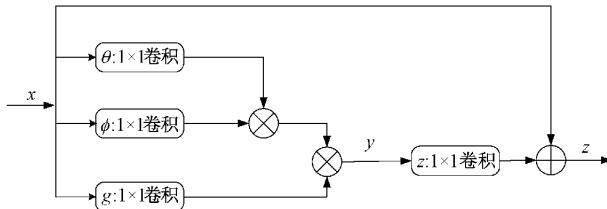


图 5 Non-local 注意力模块

非局部注意力的计算公式为:

$$\mathbf{Z} = \mathbf{W}_z \mathbf{Y} + \mathbf{X} \quad (8)$$

其中, \mathbf{W}_z 是可学习的参数矩阵“ $+ \mathbf{X}$ ”表示残差连接^[13], \mathbf{Y} 为非局部算子的计算结果, \mathbf{Z} 为非局部注意力机制的输出。

3) SwinTransformer

随着 Transformer 模型在 NLP 领域取得巨大成功, 各种应用于视觉领域的 Transformer 架构也层出不穷, SwinTransformer 是一种在移位窗口上计算自注意力的新型 Transformer 视觉模型, 通过在划分好的不重叠窗口上计算自注意力, 在同时通过移动窗口, 实现不同窗口内的信息交互, 达到全局建模的目的。SwinTransformer 包含 patch partition 层将图片以分块的形式送入网络中, 通常使用卷积核大小等于步长的卷积实现。Linear Embedding 层, 将特征图通道数映射到指定大小。Patch Merging 层应用于下采样, SwinTransformerBlock 进行窗口自注意力的计算, 多头注意力的每个头的注意力计算如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{SoftMax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}} + \mathbf{B}\right)\mathbf{V} \quad (9)$$

式中: $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别为查询, 键, 值矩阵, d 为向量维度, \mathbf{B} 为偏置矩阵, SoftMax 为多分类激活函数。与 Transformer 中的多头注意力机制相比 SwinTransformer 引入的窗口多头注意力机制有效的减少了计算量。计算复杂度如下:

$$\Omega(\text{MSA}) = 4hwC^2 + 2(hw)^2C \quad (10)$$

$$\Omega(W - \text{MSA}) = 4hwC^2 + 2M^2hwC \quad (11)$$

其中, h 表示特征图的高度, w 表示特征图的深度, M 表示每个窗口的大小。

2 实验与分析

2.1 降水数据集

本文使用公开的荷兰皇家气象研究所的降水数据, 该数据包含 2016~2019 年荷兰和周边国家的降雨地图, 时间间隔为 5 min, 空间分辨率为 1 km, 该数据总共包含 42 000 张降水图。原始图片大小 765×700 , 一个像素对应 1 km 范围内过去 5 min 内的累计降水量, 将降水雷达图中心裁剪到 288×288 的大小, 同时由于降水天数明显少于非降水天数, 模型会倾向于预测无雨, 本文选择保证每张降水图至少有 50% 的像素点有雨, 从原始数据集中采样出子集 NL-50, 选择保证每张降水图至少有 20% 的像素点有雨采样出子集 NL-20 以训练本文的模型更多关注雷达图上的降雨区域。本文选择沿着通道方向堆叠 12 张连续的降水图作为模型的输入即相当于过去 1 h 的降水数据, 模型输出第 30 min 的降水图。选取 2016~2018 年的数据作为训练集, 2019 年的数据作为测试集数据, 随机从训练集中抽取 10% 的数据作为验证集, 用于提示模型何时停止训练。数据集的具体描述如表 2。随后在测试集上验证模型的泛化性能。处理后空间范围为 $288 \text{ km} \times 288 \text{ km}$ 的雷达降水图片如图 6 所示。

表 2 3 个降水数据集的大小

数据集名称	降水像素点 要求/%	训练集	验证集	测试集
原始数据	0	314 940	31 494	105 003
NL-20	20	31 674	3 167	11 276
NL-50	50	5 734	573	1 557

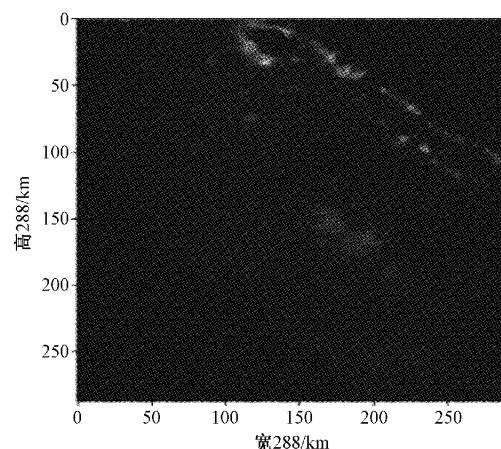


图 6 处理后的雷达降水图片(288,288)

2.2 实验环境与训练参数配置:

实验环境硬件配置: 处理器 Intel(R) Xeon(R) Silver 4216 CPU @ 2.10 GHz, 运行内存 384 GB, 显卡: Tesla V100(32 GB) 实验环境软件配置, 操作系统 Windows10, 深度学习框架 pytorch1.10, cuda 版本 11.1, python 版本 3.7。

网络采用 Adam 优化器训练,参数默认,同时采用动态学习率调节器,当验证集损失连续 4 个轮次没有下降,学习率缩减为原来的 1/10,初始学习率为 0.001。同时训练设置了最大训练轮次为 200,当验证集损失连续 15 个轮次没有下降训练停止。本实验采用的损失函数基于图像质量评估指标。相比 MSE 损失,其能生成更高质量的图像^[14]。结构相似性指标(structural similarity index,SSIM index),其公式如下:

$$1 - SSIM(x, y) = 1 - \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (12)$$

式中: $SSIM(x, y)$ 为网络输出值 x 和真实值 y 的结构相似性,取值范围为 0~1,值越大说明图像失真越小,两幅图像越相似。 μ_x, μ_y 分别为 x 和 y 的平均值 σ_x^2, σ_y^2 分别为 x 和 y 的方差, σ_{xy} 为 x 和 y 的协方差。 $C_1 = (k_1 L)^2, C_2 = (k_2 L)^2, L$ 为图像的灰度级数 k_1, k_2 的默认值分别为 0.01, 和 0.03, 网络训练通过最小化 $1 - SSIM(x, y)$ 以获得更高的结构相似性。

2.3 评价指标

通过计算真实值和预测值的均方误差(mean squared error,MSE),评判降水强度的预测的准确性,MSE 的计算公式如下:

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (13)$$

其中, n 为一张降水图上的像素个数 y_i 为真实值, \hat{y}_i 为预测值。除了 MSE 还计算了多种气象二分类指标,用于评判 GLnet 对降水区域的预测准确性,如精确率(Precision)召回率(Recall)正确率(Accuracy)F-1 指数以及关键成功指数(critical success index,CSI)。所有的指标在降雨量大于 0.5 mm/h 的阈值下计算。使用这个阈值,将预测降水图片和真实降水图片转换为二值图片,降雨量大于阈值的像素点为 1,小于阈值的点为 0。从而对二值化

后的降水图片的每一个像素点进行判断,分别计算出 TP(真阳性,真实为 1,预测为 1),FP(假阳性,实际为 0,预测为 1),TN(真阴性,实际为 0,预测为 0),FN(假阴性,实际为 1,预测为 0)的总个数。即 TP 和 TN 分别表示预测正确的有雨和无雨的像素点总个数,FP 和 FN 分别表示错误将无雨预测成有雨和错误将有雨预测成无雨的像素点总个数。各项评价指标的计算公式如下:

$$precision = \frac{TP}{TP + FP} \quad (14)$$

$$recall = \frac{TP}{TP + FN} \quad (15)$$

$$accuracy = \frac{TP + TN}{TN + FP + FN + TP} \quad (16)$$

$$csi = \frac{TP}{TP + FN + FP} \quad (17)$$

$$far = \frac{FP}{TP + FP} \quad (18)$$

$$F1 = 2 \frac{precision \times recall}{precision + recall} \quad (19)$$

3 结果与分析

GLnet 在降水数据集上(NL-50)的训练结果如表 3 所示,各项指标最好的结果以粗体显示,↑ 表示该指标数值越高,模型性能越优秀,↓ 表示该指标数值越小,模型性能越优秀。其中 MSE 指标是将预测降水图片反归一化到原始降水强度计算得出。特别是在临近预报中天气条件通常保持不变^[15],因此使用输入图像序列的最后一个作为预测图像的持久性模型(persisitence)往往难以超越,本文选择持久性模型作为基线,结果表明本文的 GLnet 性能不仅大幅超越了基线,同时对比其他神经网络模型也拥有最低的 MSE 得分,相比于最原始的 Unet,MSE 误差下降了 10.6%,除 MSE 外的评价指标,均在 0.5 mm/h 的阈值下计算得到,所有指标对比 Unet 提升 0.4%~1.9%。

表 3 GLnet 在 NL-50 上的测试结果

模型	MSE ↑	Accuracy ↑	Precision ↑	Recall ↑	F1 ↑	CSI ↑	FAR ↓
Persisitence	0.024 8	0.756	0.678	0.643	0.660	0.493	0.320
Unet	0.012 2	0.836	0.740	0.855	0.794	0.658	0.259
SmaAtUnet	0.012 2	0.829	0.730	0.850	0.786	0.647	0.270
GLnet	0.010 9	0.847	0.759	0.859	0.806	0.675	0.241

同时测试了 GLnet 在另一个降水数据集 NL-20 上的能力,结果如表 4 所示,最好的指标以粗体显示,可以注意到无论是基线模型还是其余的神经网络模型在该降水数据集上都具有更小的 MSE 误差,造成这种现象的原因是 NL-20 上有更少的降水像素点,和更弱的降水强度,因此模型预测的值也更加偏向于 0。相比于最原始的 Unet,本文提出的 GLne,MSE 误差下降了 14.4%,其余在 0.5 mm/h 的降水阈

值下计算得到的评价指标上升了 2%~6.1%。

Glnet 在 NL-20 和 NL-50 两个降水数据上的预测效果分别图 7 和 8 所示,左侧为真实图像,右侧为预测图像,图片上每一个像素点的大小为 1 km 范围内,过去 5 分钟的累计降水量。可以看出 GLnet 能够较好的捕捉降水区域的轮廓,同时对地图上的强降水区域,即高亮部分可以实现良好的预测。

表 4 GLnet 在 NL-20 上的测试结果

模型	MSE ↑	Accuracy ↑	Precision ↑	Recall ↑	F1 ↑	CSI ↑	FAR ↓
Persistence	0.022 7	0.827	0.559	0.543	0.551	0.380	0.441
Unet	0.011 1	0.880	0.666	0.782	0.719	0.562	0.334
SmaAtUnet	0.011 1	0.867	0.626	0.801	0.703	0.516	0.395
GLnet	0.009 5	0.902	0.727	0.802	0.762	0.616	0.273

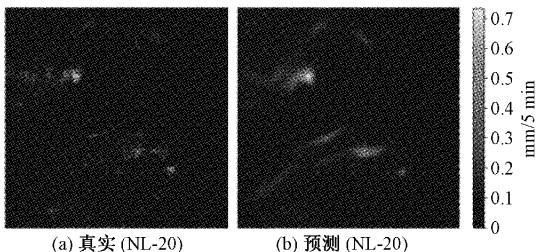


图 7 NL-20 预测效果

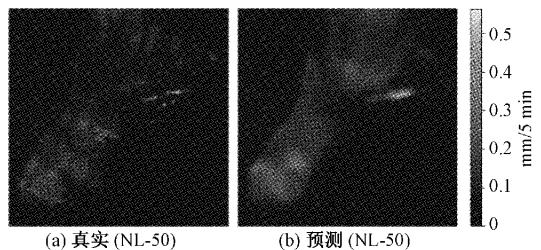


图 8 NL-50 预测效果

4 结 论

降水短临预报和人们的日常生活、工业生产和科学等领域休戚相关,对人们的生活规划具有指导意义。本文提出了一种用于降水临近预报的神经网络模型 GLnet,其包含一条使用深度可分离卷积的局部特征提取分支,在保留卷积强大特征提取能力的同时,大幅减少了模型的参数量,一条使用 SwinTransformer 的全局特征提取分支,同时采用 CBAM 和 Non-local 注意力机制,自适应融合不同尺度下各分支提取的语义信息。GLnet 有效融合了不同尺度下雷达降水图片的局部特征和全局特征,实验结果表明 GLnet 对降水强度的预测具有更小的误差,对降水区域范围的预测具有更高的准确性。

参考文献

- [1] SUN J, XUE M, WILSON J W, et al. Use of NWP for nowcasting convective precipitation: Recent progress and challenges[J]. Bulletin of the American Meteorological Society, 2014, 95(3): 409-426.
- [2] WOO W, WONG W. Operational application of optical flow techniques to radar-based rainfall nowcasting[J]. Atmosphere, 2017, 8(3): 48.
- [3] 黄俊豪. 基于深度学习的短临降水预测方法研究[D]. 南京:东南大学.
- [4] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [J]. Advances in Neural Information Processing Systems, 2015, 28.
- [5] WANG Y, LONG M, WANG J, et al. Predrnn: Recurrent neural networks for predictive learning using spatiotemporal lstms [J]. Advances in Neural Information Processing Systems, 2017, 30.
- [6] AGRAWAL S, BARRINGTON L, BROMBERG C, et al. Machine learning for precipitation nowcasting from radar images [J]. ArXiv Preprint, 2019, ArXiv:1912.12132.
- [7] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham, 2015: 234-241.
- [8] TREBING K, STAŃCZYK T, MEHRKANOON S. SmaAt-UNet: Precipitation nowcasting using a small attention-UNet architecture[J]. Pattern Recognition Letters, 2021, 145: 178-186.
- [9] 崔志强,单慧琳,张银胜,等. 基于改进型 U-Net 的遥感云图分割方法[J]. 电子测量技术,2022,45(12): 127-132.
- [10] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012-10022.
- [11] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018: 3-19.
- [12] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7794-7803.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [14] SARA U, AKTER M, UDDIN M S. Image quality

assessment through FSIM, SSIM, MSE and PSNR—A comparative study[J]. Journal of Computer and Communications, 2019, 7(3): 8-18.

- [15] SOMAN S S, ZAREIPOUR H, MALIK O, et al. A review of wind power and wind speed forecasting methods with different time horizons [C]. North American Power Symposium 2010, IEEE, 2010: 1-8.

作者简介

尹传豪,硕士研究生,主要研究方向为基于深度学习的短临预报。

E-mail:2374015242@qq.com

秦华旺(通信作者),博士,教授,博导,主要研究方向为基

于 ARM、DSP、FPGA、单片机的嵌入式系统软硬件设计;深度学习;信息系统开发;复杂系统测控信息安全。

E-mail:qin_h_w@163.com

戴跃伟,博士,教授,主要研究方向为复杂系统建模与控制、网络与多媒体信息安全。

E-mail:dyw@nust.edu.cn

陈浩然,硕士研究生,主要研究方向为基于深度学习的气象数据降尺度。

E-mail:781241941@qq.com

包顺,硕士研究生,主要研究方向为基于深度学习的短临预报。

E-mail:1907007685@qq.com