

基于DOCnet的强对流天气分类识别

陈小兰¹, 杨昊¹, 陈敏^{1,2}, 邹茂扬³, 周航¹

(1. 成都信息工程大学计算机学院; 2. 中国科学院成都计算机应用研究所;
3. 成都信息工程大学区块链产业学院, 四川成都610225)

摘要: 强对流天气对人民生命财产有严重威胁, 精确识别强对流天气有益于更好地预测强对流天气。为了解决传统机器学习方法忽视不同强对流天气在雷达图上的不同形状表达和传统机器学习方法计算量大等问题, 提出一种基于DOCnet的多类强对流天气分类识别方法。该网络使用深度倍频卷积分别提取雷达图像的高频特征和低频特征, 在去除低频特征图中冗余空间减少参数量的同时, 增大了提取低频特征图和高频特征图卷积层的感受野, 能充分提取雷达图的图像特征, 提高模型对强对流天气的分类准确度。通过泛洪法训练模型, 提高了模型泛化能力。在风暴事件图像(SEVIR)数据的测试集中, DOCnet模型对强降水、雷暴大风、冰雹、龙卷风4类强对流天气分类的平均命中率为90.54%, 平均临界成功指数为81.2%, 平均空报比率为11.9%。与基线模型相比, DOCnet的命中率提高了15.02个百分点; 与表现最好的MobileNet V2相比, DOCnet的命中率高出5.87%。实验结果表明, DOCnet能够有效提高强对流天气分类效果。

关键词: 分类识别; 强对流天气; 倍频卷积; 深度卷积; 雷达图

DOI: 10.11907/rjtk.232237

中图分类号: TP183

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2024)011-0039-08



Classification of Severe Convective Weather Based on DOCnet

CHEN Xiaolan¹, YANG Hao¹, CHEN Min^{1,2}, ZOU Maoyang³, ZHOU Hang¹

(1. School of Computing Science, Chengdu University of Information Technology; 2. Chengdu Institute of Computer Applications, Chinese Academy of Sciences; 3. School of Blockchain Industry, Chengdu University of Information Technology, Chengdu 610225, China)

Abstract: Severe convective weather will pose a serious threat to people's lives and property, accurate identification of it is beneficial to better forecasting it. In order to solve the problems that traditional machine learning methods ignore the different shape expressions of different severe convective weather on radar and the traditional machine learning methods have a large amount of calculation, a classification and identification method of multi-category severe convective weather based on DOCnet is proposed. This network uses deepwise octave convolution to extract high-frequency features and low-frequency features of radar respectively. This not only removes the redundant space in low-frequency feature maps and reduces the amount of parameters, but also increases the receptive field of the convolution layer for extracting low-frequency feature maps and high-frequency feature maps. which enables the network to fully extract the image features of the radar and improve the model's classification accuracy for severe convective weather. Finally, the model is trained through the flooding method to improve the generalization ability of the model. In the test set of the storm event image (SEVIR) data, the DOCnet model has an average probability of detection of 90.54%, an average critical success index of 81.2% and the average false alarm ration of 11.9% for the four types of severe convective weather.

收稿日期: 2023-12-18

扫描二维码阅读全文:

基金项目: 国家重点研发计划项目(2021YFC3000902); 四川省科技计划项目(2022YFS0542); 四川省自然科学基金项目(2022NSF-SC0964)

作者简介: 陈小兰(1998-), 女, 成都信息工程大学计算机学院硕士研究生, 研究方向为高性能计算和智慧气象; 杨昊(1981-), 男, 博士, CCF会员, 成都信息工程大学计算机学院副教授、硕士生导师, 研究方向为高性能计算和智慧气象; 陈敏(1989-), 女, 中国科学院成都计算机应用研究所博士研究生, 成都信息工程大学计算机学院助教, 研究方向为大数据分析和智慧气象; 邹茂扬(1974-), 博士, 成都信息工程大学区块链产业学院副教授、硕士生导师, 研究方向为基于人工智能的图形图像处理、基于数据挖掘的学习分析; 周航(1991-), 男, 博士, 成都信息工程大学计算机学院讲师, 研究方向为机器学习和高性能计算。
本文通讯作者: 杨昊。



er: heavy precipitation, thunderstorms, hail, and tornadoes. Compared with the baseline model, DOCnet achieves a probability of detection improvement of 15.02 percentage points, and compared with the best performing MobileNet V2, DOCnet achieves a hit rate 5.87% higher than that of MobileNet V2. The experimental results show that DOCnet can effectively improve the classification effect of strong convective weather.

Key Words: classification; severe convective weather; octave convolution; depthwise convolution; radar map

0 引言

常见的强对流天气主要包括雷暴大风、强降雨、龙卷风、冰雹等,具有很强的随机性和突发性。其发生时间短、破坏力强,严重威胁人民生命财产安全,也会给农业和交通运输造成重大损失。早在20世纪80年代,就有学者开展关于强对流天气的识别研究。1982年,Austin等^[1]基于雷暴单体的空间特征提出一种通过计算雷暴单体三维结构特征的三维矩心技术以识别雷暴大风。随后,Rosenfeld^[2]和Dixon等^[3]对Austin的三维矩心技术加以改进,但对于雷暴单体运动路径不规则或多个雷暴单体相距较为密集时的识别还存在着较大误差。余小鼎等^[4]通过分析指出雷暴大风的主要预警标志之一是对流层中层出现径向辐合,弓形回波是雷暴大风的回波特征,并且较大的垂直累积液态水含量可以作为强冰雹预警的重要指标。同年,Ren等^[5]基于“糖葫芦串”模型,提出一种客观的区域极端事件识别方法,该方法通过提前选择的日指标划分自然日异常带,通过比较相邻日间自然日异常带的空间分布确定事件的时间连续性,进而构建区域事件指标体系,最后根据综合指数的分布将区域性极端事件定义为综合指数值超过一定阈值的事件。因此,该方法充分考虑到了强降雨过程的空间变化特征。2018年,Lu等^[6]基于北京气象台雷达和自动气象站数据,选取9个预报因子,即回波顶高度、最大反照率、最大反射率高度、总垂直液态水含量、总垂直液态水含量随时间变化率、总垂直液态水含量密度、最大反射率高度、风暴移动速度和速度谱宽度,采用支持向量机建立雷暴大风识别模型。然而,有时根据这些预报因子可能会将多个雷暴单体误判为一个雷暴单体,这时需要研究人员结合雷达基地整体反射率和天气情况进行人工干预,以降低雷暴大风误判率。同年,Kim等^[7]基于卷积神经网络对卫星图像中的过冲顶部进行检测以识别雨雪冰冻天气,其在热带地区的检测命中率可达到79.68%,而误报率仅有9.78%。Kurth等^[8]提出了Tiramisu和DeepLabv3+神经网络的变体,对输入管道和网络训练算法作出改进,在CAM5气候数据集上完成了对热带气旋和大气河流的图像分割,CAM5数据集包含的数据有不同海拔高度的温度、风速、气压值和湿度等。随后,Yuan等^[9]为了解决针对单个像素分类提取卫星数据特征的问题,利用U-net架构的编码器—解码器结构对所有像素同时分类,完成了对遥感图像的强对流天气分割任务。2021年,刘新伟等^[10]通过使用机器学习方法LightGBM(Light Gradient Boosting Machine),基于雷达回波产品和观测数据完成对

冰雹、雷暴大风和短时强降水的识别,平均命中率可达到86.4%,平均空报率为29.0%,是首次对3类强对流天气实现自动化预警。

1998年,Lecun等^[11]首次提出卷积神经网络模型LeNet-5并将其用于手写数字分类,此后深度学习得到了更加广泛的关注。AlexNet模型是在LeNet-5的基础上而构建,该神经网络具有6000万个参数和650000个神经元,由5个卷积层组成,其中某些卷积层之后是最大池化层,模型由3个全连接层完成分类,使用Dropout正则化方法以减少全连接层的过度拟合^[12]。AlexNet在ILSVR 2012竞赛中获得冠军后,各种用于自然图像分类的深度学习网络被提出,例如:VGG模型^[13]、Inception系列^[14-17]、MobileNet系列^[18-19]。2015年,卷积神经网络在图像史又迎来了另一个里程碑模型。随着网络深度的增加,准确率达到饱和,然后迅速退化,这种退化不是由过拟合引起。为打破这种“退化”现象,He等^[20]提出深度残差网络ResNet。ResNet不断堆叠最优状态的网络累计多个恒等映射层,达到优化网络模型和提高准确率的效果。ResNet模型的残差块是将浅层特征图和深层特征图相加得到目标特征图,而DenseNet每一层的网络输入是前面所有层的网络输出拼接而成,这样每一层都可以直接访问损失函数和原始输入信号的梯度,从而实现隐式深度监督^[21]。

目前,深度学习方法在自然图像分类研究上已经非常成熟,最新的深度学习方法在10分类任务(CIFAR-10^[22])上准确率已经能达到99.7%^[23],在1000分类任务(ImageNet^[24])上准确率达到91.1%^[25]。但是,深度学习技术和多分类识别技术在强对流天气分类识别上的应用还很少。基于雷达图像的强对流天气分类识别相关研究大部分还是通过传统的机器学习方法完成,且是针对某一类强对流天的识别。基于传统机器学习方法,使用雷达图像研究强对流天气分类任务主要是通过雷达图像的回波顶高、雷达组合反射率因子、垂直液态水含量等特征值与强对流天气之间的关系构建决策树,在大量数据加持下通过复杂的决策方案完成强对流天气分类。基于前人对各类强对流天气的研究和分析可知,强对流天气所在的高亮区域在雷达图上会有不同的图像特征,如雷暴大风在雷达拼图回波图像上的特征包括块状回波、雷暴回波群、爬线回波带、回波短带、絮状回波等;冰雹在雷达回波上表现为钩状、指状、弓状、三体散射、“V”型缺口等回波形态特征^[26-32]。而传统的机器学习方法忽略了不同强对流天气在雷达图上的不同形状表达,因而在强对流天气分类识别研究中,通常一种模型只能针对性地完成某一类强对流天气的分类识别。并且,由于传统机器学习方法要在大量数据基础上构

建雷达特征值和强对流天气的决策树, 计算量非常大、识别耗时长, 导致传统机器学习方法实时性较差。针对以上问题, 本文提出一种深度倍频卷积网络 (Depthwise-Octave Convolution Network, DOCnet), 在使用更少参数和计算的情况下更充分地提取雷达图的图像特征, 从而在耗时更短的情况下提高强对流天气分类任务的分类效果, 并使用 Ishida 等^[33]提出的泛洪法训练模型, 提高模型泛化能力。实验结果表明, DOCnet 模型确实能在更少参数和计算的情况下, 更准确地对强对流天气进行分类, 且与部分经典的纯卷积网络相比, DOCnet 模型效果更好。

1 DOCnet 模型

本文以 ResNet 为基准网络框架, 用深度倍频卷积 (Deepwise Octave Convolution, DOConv) 替换了基准网络的普通卷积层, 从而构建了 DOCnet 模型, 以更好提取雷达图像中的图像特征, 完成强对流天气分类任务。DOCnet 模型在更少参数和计算量的情况下, 通过深度倍频卷积分别提取雷达图的高频特征和低频特征, 通过去除低频特征图

的冗余空间和增大提取高频特征图卷积层的扩张率来达到扩大网络模型感受野和获取更多上下文信息的目的。DOCnet 模型的残差模块使用 Bottleneck 残差模块, DOCnet 模型整体结构如图 1 所示。DOCnet 模型主要包括 3 类基础模块和由其组成的残差模块。第 1 类模块是由倍频卷积和批规范化组成的 OctCB 模块, 如图 2(a) 所示; 第 2 类是在 OctCB 模块后加上 LeakyRelu 激活函数组成的 OctCBL 模块, 如图 2(b) 所示; 第 3 类模块为 DOCBL, 该模块由深度倍频卷积、批规范化和 LeakyRelu 激活函数组成, 如图 2(c) 所示。DOCnet 模型的 DOBottleneck 残差模块是由这 3 类卷积层构成, 如图 2(d) 所示。首先, 雷达图通过卷积核大小为 7×7 的卷积层完成初步数据处理; 其次, 将得到的特征图送入 DOBottleneck 残差模块, 随后特征图通过 5 层 DOBottleneck 残差模块送入最后一个 DOBottleneck 残差模块; 最后, 特征图通过一个普通 Bottleneck 残差模块送入分类器中完成分类。其中, $\alpha_{in}, \alpha_{out} \in [0, 1]$ 表示分配给低频部分的通道比率, 实验中第一个残差模块的 $\alpha_{in} = 0, \alpha_{out} = 0.5$, 最后一个残差模块的 $\alpha_{in} = 0.5, \alpha_{out} = 0$, 中间其余卷积层的 $\alpha_{in} = \alpha_{out} = 0.5$ 。

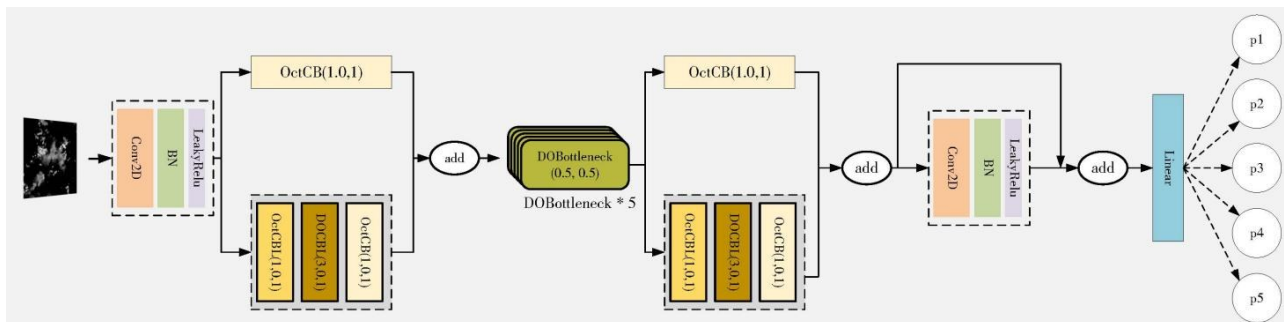


Fig. 1 The overall structure of DOCnet model

图 1 DOCnet 模型整体结构

1.1 DOBottleneck 残差模块

从理论上讲, 随着网络层数增加, 网络可以提取更加复杂的图像特征, 但实验表明当网络深度到达某个临界值时, 再增加网络深度模型反而表现出了更差的性能, 这就是网络退化问题。残差网络提出了恒等映射这一概念, 通过不断堆叠最优状态的网络累计多个恒等映射层, 以打破这种“退化”现象, 达到优化网络模型和提高其准确率的效果, 并通过不断堆叠残差模块加深网络。残差模块将浅层特征和深层特征直接相加的恒等映射思想可以去掉相同的主体部分, 从而突出微小的变化。而不同的强对流天气在雷达图上的高亮区域也会表现出相同的形状特征, 但不同的强对流天气与大气中雨的含量、云的形态和数量关系各不相同。因此, 本文选择使用残差模块捕捉图像上的微小特征, 同时也为了避免后续迭代更新网络时出现网络“退化”现象。

He 等^[20]主要提出了两种残差模块: 一种是 Basic-Block, 这个残差模块是由两个 3×3 的卷积组成, 结构如图 3(a) 所示; 另一种是 Bottleneck, 这个残差模块由两个 1×1 的

卷积层和一个 3×3 的卷积层组成, 结构如图 3(b) 所示。浅层网络如 ResNet 18 和 ResNet 34 一般选择使用 BasicBlock 残差模块提取特征, 深层网络 ResNet 50-152 使用 Bottleneck 残差模块搭建模型。但是, Bottleneck 残差模块整体来看是一种特殊的瓶颈结构, 这样的瓶颈结构可以保留更多的空间信息。本文通过实验对比验证, 使用 Bottleneck 残差模块搭建的 18 层残差模型比使用 BasicBlock 残差模型搭建的 18 层残差模型更适用于强对流天气分类任务, 在强对流天气分类任务上的效果更好。因此, 本文在 Bottleneck 残差模块基础上, 使用深度倍频卷积层替换 Bottleneck 残差模块中的普通卷积层, 构建了 DOBottleneck 残差模块 (DOBottleneck Residual Module), 结构如图 2(d) 所示。

1.2 深度倍频卷积

由于传统的机器学习方法忽略了不同强对流天气在雷达图上的不同图形特征表达和计算量大等问题, 因而在 DOCnet 模型中使用深度倍频卷积提取雷达图像特征并降低模型参数数量和计算量, 深度倍频卷积主要是在倍频卷积

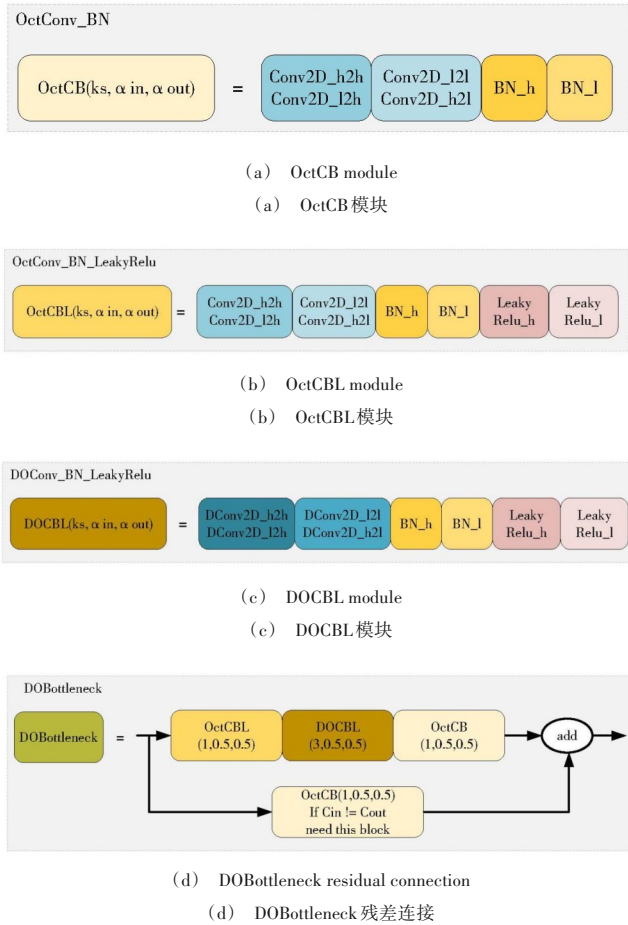


Fig. 2 DOCnet module design
图2 DOCnet 模块设计

中引入深度卷积。

视觉空间频率模型表明自然图像可以分为低空间频率部分和高空间频率部分,即图像包括高频信号和低频信号,又称高频分量和低频分量。高频信号是指图像强度变化剧烈的像素点,例如轮廓、图像细节处、噪声等,低频信号是指图像强度变化平缓的像素点。在雷达图中强对流天气发生区域多出现于雷达图上的高亮部分,与周围非强对流天气相比有明显的颜色变化。图像高频部分数据相关性强,低频部分图片结构变化平稳,强对流天气在雷达图上表现出不同的形状和更多语义特征,可认为强对流天气的重要信息主要集中在雷达图形的高频部分。因此,本文使用深度倍频卷积分别对图像高频部分和低频部分进行不同的信息提取操作,降低低频特征图的空间分辨率,增加提取高频特征图卷积层的感受野以获取更多高频特征部分的形状、语义等特征,提高模型对雷达中图形边缘信息的提取,以达到增强模型对强对流天气的分类效果。深度倍频卷积通过去除低频特征图中的冗余空间降低了低频特征图的空间分辨率,进而扩大了模型在提取低频特征时的感受野。为了平衡低频特征部分和高频特征部分的感受野差,让模型更多关注高频特征图,本文通过增大提取高频特征卷积层的扩张率以扩大提取高频特征卷积

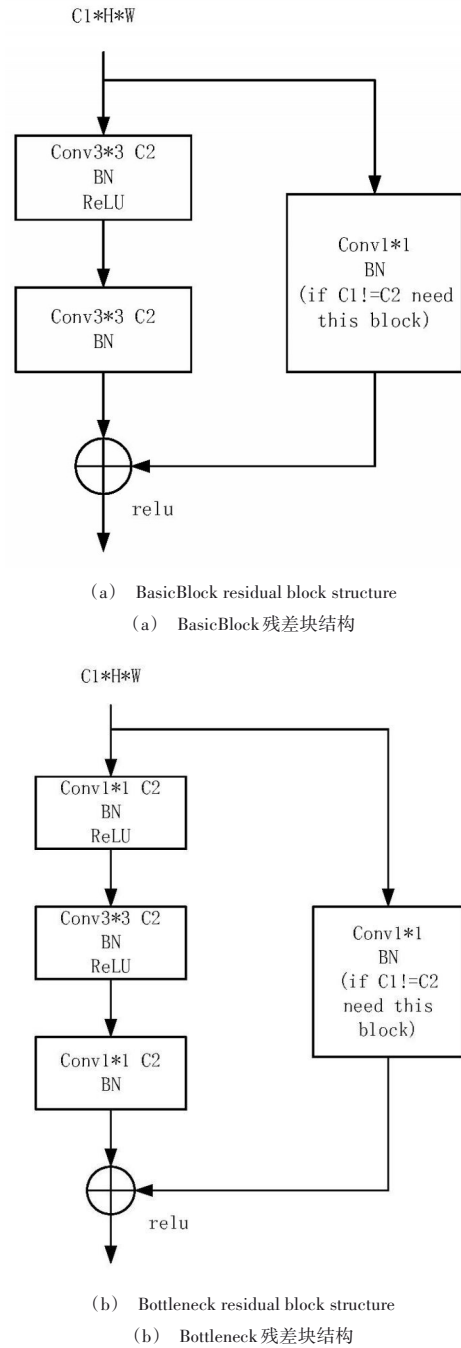


Fig. 3 Two structures of residual blocks
图3 残差块的两结构

层的感受野,从而捕获更多高频特征图的上下文信息,提高模型分类效果。

为了进一步降低模型参数量和计算量,在倍频卷积中引入逐通道卷积,使用逐通道卷积替换倍频卷积层中卷积核大小为3×3的普通卷积。因为ResNet模型中Bottleneck残差模块结构非常特殊,Bottleneck残差模块中间3×3卷积层的输入通道数等于输出通道数,这满足了使用逐通道卷积替换普通卷积的策略。普通卷积层中卷积核数量等于卷积层输出通道数,每个卷积核的通道数等于输入特征图

的通道数。因此,普通 3×3 卷积的参数数量等于 $3\times 3\times$ 输入通道数 \times 输出通道数。而逐通道卷积的一个卷积核负责一个通道,一个通道只被一个卷积核卷积,该过程产生的特征图通道数和输入的通道数一样, 3×3 逐通道卷积的参数数量等于 $3\times 3\times$ 输入通道数。由此可见,这样的修改极大降低了模型参数数量和计算量。

深度倍频卷积过程如图 4 所示。深度倍频卷积将输入的特征图按其空间频率进行因式分解和分组,沿通道维度分解为高频特征图和低频特征图,其中高频特征图 $X^H \in R^{(1-\alpha_{in})c \times h \times w}$ 捕获精细节,低频特征图 $X^L \in R^{\alpha_{in}c \times \frac{h}{2} \times \frac{w}{2}}$ 捕获全局结构。由于输入的高频特征和低频特征存在空间分辨率差异,将卷积核也分成两个组件 $W=[W^H, W^L]$,分别负责与高频特征图和低频特征图进行卷积,实现高效的异频通信。 $f(X; W)$ 表示参数为 W 的卷积, $\alpha \in [0, 1]$ 表示分配给低频部分的通道比率。模型中第一个深度倍频卷积的 $\alpha_{in} = 0, \alpha_{out} = \alpha$,最后一个深度倍频卷积的 $\alpha_{in} = \alpha, \alpha_{out} = 0$,其余倍频卷积的 $\alpha_{in} = \alpha_{out} = \alpha$ 。 Y^H 表示高频特征图, Y^L 表示低频特征图,具体定义如式(1)和式(2)所示。

$$Y_{p,q}^H = Y_{p,q}^{H \rightarrow H} + Y_{p,q}^{L \rightarrow H} = \sum_{i,j \in N_k} W_{i+\frac{k-1}{2}, j+\frac{k-1}{2}}^{H \rightarrow H} X_{p+i, q+i}^H + \sum_{i,j \in N_k} W_{i+\frac{k-1}{2}, j+\frac{k-1}{2}}^{L \rightarrow H} X_{\lfloor \frac{p}{2} \rfloor + i, \lfloor \frac{q}{2} \rfloor + j}^L \quad (1)$$

$$Y_{p,q}^L = Y_{p,q}^{L \rightarrow L} + Y_{p,q}^{H \rightarrow L} = \sum_{i,j \in N_k} W_{i+\frac{k-1}{2}, j+\frac{k-1}{2}}^{L \rightarrow L} X_{2p+0.5+i, 2q+0.5+j}^L + \sum_{i,j \in N_k} W_{i+\frac{k-1}{2}, j+\frac{k-1}{2}}^{H \rightarrow L} X_{2p+0.5+i, 2q+0.5+j}^H \quad (2)$$

其中, (p, q) 指特征图上的某一位置, N_k 是一个集合, $Y^A \rightarrow B$ 表示特征的卷积更新将 A 组映射到 B 组。高频特征图中 p 和 q 除以二表示池化操作,而低频特征图中 p 和 q 乘以二表示上采样操作。

2 数据集及其处理

2.1 SEVIR 数据集

风暴事件图像(The Storm EVent ImagRy, SEVIR)数据集采用美国国家海洋和大气管理局(National Oceanic and Atmospheric Administration, NOAA)发布的公开可用数据集创建的时间和空间对齐的图像集合。图像来自 5 种不同

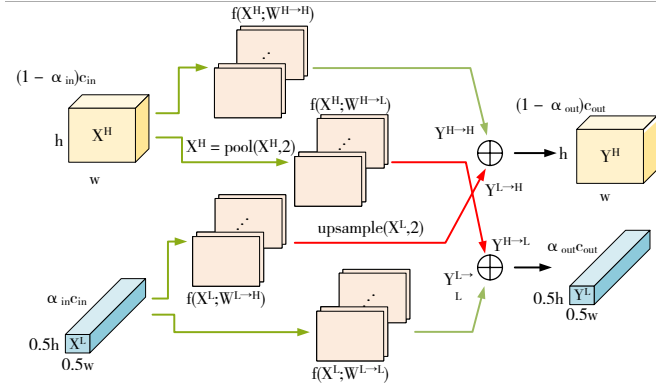


Fig. 4 Flow of deepwise octave convolution

图 4 深度倍频卷积流程

的传感模式,其中包括 GOES-16 对地静止卫星 3 个通道采集的 vis、ir069、ir107 共 3 种数据、从 NEXRAD 天气雷达派生的垂直液态水含量 vil 数据和 GOES-16 同步闪电测绘仪(Geostationary Lightning Mapper, GLM)记录的闪烁数据。如表 1 所示,5 类传感器中 vis、ir069、ir107、vil 是网格类型,它们的数据都是单通道图像,lght 是离散事件的集合事件的闪电数据,由 $N \times 5$ 的矩阵表示,包括闪电时间和位置信息。

Table 1 SEVIR dataset sensor types

表 1 SEVIR 数据集传感器类型

传感器	key	空间分辨率/km	图片大小	时间步长/min
GOES-16 C02 0.64 μm	vis	0.5	768 \times 768	5
GOES-16 C09 6.9 μm	ir069	2	192 \times 192	5
GOES-16 C13 10.7 μm	ir107	2	192 \times 192	5
Vertically Integrated Liquid (VIL)	vil	1	384 \times 384	5
GOES-16 GLM flashes	lght	8	N/A	持续

图 5 是通过将离散事件插值成 48×48 的网格数据后的可视化结果。

SEVIR 数据集采样地区为美国某 $384 \text{ km} \times 384 \text{ km}$ 的区域,时间范围为 2017 年 6 月 13 日—2019 年 11 月 30 日,包含卫星和雷达捕获的 10 000 个天气事件的图像序列,每个事件以 5 min 为时间增量采集 4 h 数据,共有 8 类灾害性天气和非灾害性天气,灾害性天气分别为:暴洪、洪水、强降雨、漏斗云、闪电、雷暴大风、龙卷风、冰雹。SEVIR 数据集的事件是根据美国国家气象局(National Weather Service, NWS)的记录标记为“风暴事件”。

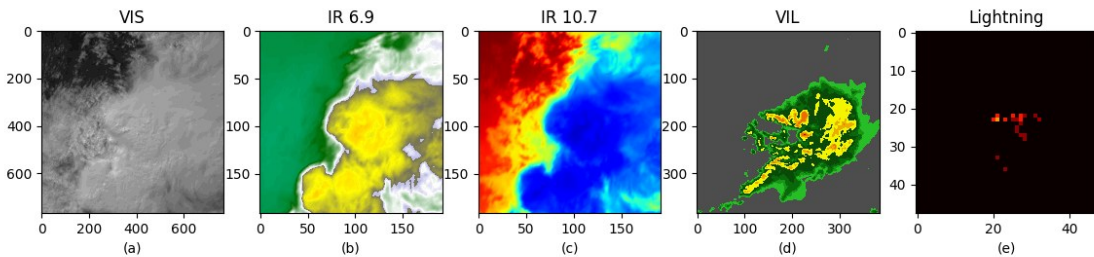


Fig. 5 Visualization sample images of 5 types of images in the SEVIR dataset

图 5 SEVIR 数据集 5 类图像可视化样例图

2.2 数据处理

本文基于雷达图实现强对流天气的分类识别,需要对SEVIR数据集进行筛选和数据标准化等数据预处理操作。由于SEVIR数据集中8类强对流天气样本数严重失衡,因而选择了样本数较为均匀且常见的强降水、冰雹、雷暴大风、龙卷风4类强对流天气制作单雷达要素数据集(VIL-SEVIR)。通过访问NWS的灾害性天气记录,将洪水引发原因为强降水的洪水事件发生时间前的数据集归类为强降水。筛选出所有事件的vil图,使用双三次插值方法将图片大小缩放为192×192,然后对数据集进行Z-Score标准化。最后得到的数据集共有17 017个样本,其中强降水有3 456个样本、冰雹有3 385个样本、雷暴大风有3 576个样本、龙卷风有3 400个样本,非强对流天气有3 200个样本。数据集中样本被打乱顺序,其中80%用于训练模型,15%用于验证模型,5%用作测试集。

3 实验与结果分析

为了验证DOCnet模型对强对流天气分类识别的有效性,本文基于VIL-SEVIR数据集将DOCnet模型与部分经典的纯卷积模型(如ResNet18、MobilenetV2、ConvNext等)进行了对比。

3.1 实验设置

本文使用SGD优化算法进行网络训练,激活函数选择LeakyReLU,初始学习率为0.05,动量为0.9,衰减率为0.000 1,训练周期为500轮。为了提高模型泛化性,使用泛洪方法进行训练。泛洪法是指人为设置一个泛洪阈值,当训练损失小于该阈值时,仿照批量梯度下降方法,进行梯度上升,有意阻止训练损失的进一步减小,使训练损失值在阈值附近浮动,从而使模型表现出更好的分类识别能力。

3.2 检验指标

本文不仅使用了气象领域常用的检验指标,还采用了分类任务通用的检验指标以判断强对流天气分类识别效果。检验指标具体包括:命中率(Probability of Detection, POD)、临界成功指数(Critical Success Index, CSI)、空报比率(False Alarm Ratio, FAR)、准确率(Accuracy)、精确率(Precision)和召回率(Recall)。各检验指标定义如下:

命中率:

$$POD = \frac{\text{正确识别的样本数}}{\text{强对流天气总样本数}} \times 100\% \quad (3)$$

临界成功指数:

$$CSI = \frac{\text{正确识别的样本数}}{\text{强对流天气总样本数} + \text{空报样本数}} \times 100\% \quad (4)$$

空报比率:

$$FAR = \frac{\text{空报样本数}}{\text{正确识别的样本数} + \text{空报样本数}} \times 100\% \quad (5)$$

其中,模型预测的分类结果和数据对应的标签相同即

为正确识别,反之为错误识别,如图6所示。

		Expert judgments	
		True	False
Classifier judgments	Positive	TP	FP
	Negative	FN	TN

Fig. 6 The adjacency list of prediction result

图6 预测结果邻接表

准确率:

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \times 100\% \quad (6)$$

精确率:

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% \quad (7)$$

召回率:

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (8)$$

3.3 实验结果

表2分别展示了DOCnet模型和不同经典纯卷积模型在VIL-SEVIR数据集上各指标的平均值。DOCnet对4类强对流天气分类的命中率平均值达到了90.54%,临界成功指数平均值为81.20%,空报比率的平均值只有11.90%。与基线方法相比,DOCnet在VIL-SEVIR数据集上的命中率提高了15.02个百分点,与表现最好的MobileNet V2相比,DOCnet的命中率比MobileNet V2的命中率高出5.87%。

Table 2 Classification results of different models for severe convective weather

表2 不同模型对强对流天气的分类结果

模型	POD ↑	CSI ↑	FAR ↓	Accuracy ↑	Precision ↑	Recall ↑
ResNet18	75.52	59.74	27.04	74.20	73.72	73.64
ConvNeXt	72.43	54.02	33.89	71.31	71.21	71.33
Senet	82.58	70.08	18.88	80.41	80.13	79.98
MobileNet V2	84.67	74.42	15.01	83.76	83.51	83.39
DOCnet	90.54	81.20	11.90	88.38	88.28	87.91

表3展示了DOCnet模型在VIL-SEVIR数据集上对每类强对流天气的分类结果。可以看出,DOCnet对4类强对流天气的分类效果各不相同,其中龙卷风的分类效果最好,命中率可达到96.90%,对雷暴大风的分类效果最差,仅有78.99%。

VIL-SEVIR数据集使用的是垂直液态水含量雷达图,垂直液态水含量雷达图反映的是某个区域的含水量情况。

Table 3 Classification results of DOCnet model for each type of strong convective weather

表3 DOCnet模型对每类强对流天气的分类结果

强对流天气	POD	CSI	FAR
Heavy Rain	90.70	85.40	6.40
Hail	95.59	84.42	12.16
Thunderstorm Wind	78.99	64.38	22.31
Tornado	96.90	90.58	6.72
Mean	90.54	81.20	11.90

强降水和冰雹发生区域的空气含水量都非常高, 龙卷风形成区域通常会出现漏斗云等现象, 而云中含水量也较高, 因而强降水、冰雹和龙卷风发生区域都表明该区域空气中含水量较高, 与垂直液态水含量雷达图有直接联系。但是在雷暴大风发生天气, 空气快速流动, 很可能导致周围区域没有云或者天气较为干燥, 因而雷暴大风天气与垂直液态水含量雷达图的关联较弱, 通过垂直液态水含量雷达图识别雷暴大风天气的准确度较强降水、冰雹和龙卷风等强对流天气更低。

表 4 和表 5 中, ResNet18 是使用 BasicBlock 作为残差模块的基线模型, OCnet 模型是使用 Bottleneck 残差模块和倍频卷积搭建的深度学习网络模型。为了平衡高频部分和低频部分的感受野差, OACnet 模型在 OCnet 模型的基础上引入了空洞卷积以增大提取高频特征部分卷积层的感受野。DOCnet 是本文提出的模型, DOCnet+Flooding 则使用泛洪法训练模型。

表 4 展示的是 DOCnet 模型在 VIL-SEVIR 数据集上的消融实验结果, 其中各检验指标的结果均为 4 类强对流天气分类结果的平均值。可以看出, 与基线模型相比, DOCnet 模型使用深度倍频卷积, 通过降低低频特征图的空间分辨率, 增大高频特征部分的感受野, 提取了更多上下文信息, 关注到更多图形边缘语义信息, 提高了模型分类效果。

Table 4 Ablation experiment results of DOCnet on the VIL-SEVIR dataset

model	POD ↑	CSI ↑	FAR ↓	Accuracy ↑	Precision ↑	Recall ↑
ResNet18	75.52	59.74	27.04	74.20	73.72	73.64
OCnet(OctConv)	89.13	78.28	14.01	86.94	86.92	86.43
OACnet(OctConv+AtrConv)	90.12	80.25%	12.73	87.74	87.57	87.23
DOCnet(DOConv)	88.63	78.45	13.12	86.94	86.95	86.38
DOCnet+Flooding	90.54	81.20	11.90	88.38	88.28	87.91

表 5 展示了 DOCnet 模型引入各模块后参数数量和计算量的变化过程。可以看出, 引入深度倍频卷积可以在牺牲较小命中率的情况下大幅度减少模型参数数量和计算量。

Table 5 The amount of parameters and calculations after DOCnet introduces each module

model	参数数量(M)	计算量(M)
ResNet18	11.175 813	1 281.414 144
OCnet(OctConv)	13.950 149	1 045.438 464
OACnet(OctConv+AtrConv)	13.950 149	1 045.438 464
DOCnet(DOConv)	7.708 613	625.534 464
DOCnet+Flooding	7.718 021	712.238 592

表 6 展示了引入泛洪方法前后 DOCnet 模型在验证集和测试集上各指标的结果对比。本文引入泛洪法, 将泛洪阈值设置为 0.000 1, 重新训练模型, 这不仅弥补了降低参数数量和计算量而损失的命中率, 还提高了模型泛化能力。

Table 6 Comparison of the results (average) of DOCnet on the verification set and test set before and after the introduction of flooding

model	验证集结果(mean)			测试集结果(mean)		
	POD	CSI	FAR	POD	CSI	FAR
DOCnet	89.70	80.90	11.33	88.63	78.45	13.12
DOCnet+Flooding	90.17	81.30	11.29	90.54	81.20	11.90

综合上述实验结果可知, 本文模型在 VIL-SEVIR 数据集上的 4 类强对流天气分类任务中取得了优于所有对比模型的综合表现。并且, 在极大降低模型参数数量和计算量的情况下, 使用泛洪法训练模型后, 分类效果依然表现最好。因此, 相较于其他深度学习模型, DOCnet 模型在完成强对流天气分类任务方面更有优势。

4 结语

强对流天气因其突发性强很难准确识别预警, 因而强对流天气总会对人类生活带来巨大损失, 如何更准确地识别、预报、预警强对流天气具有重要意义。本文提出了 DOCnet 深度学习模型, 基于由 NOAA 发布的公开数据集创建的 SEVIR 数据集, 研究强降水、冰雹、雷暴大风、龙卷风 4 类强对流天气的分类识别。通过使用倍频卷积和空洞卷积分别扩大模型提取低频特征图和高频特征图部分的感受野, 提高模型获取上下文信息的能力, 提出深度倍频卷积以进一步降低模型参数数量和计算量。与基线模型和部分经典纯卷积模型相比, 本文提出的模型相对较小, 且对 4 类强对流天气的分类识别效果更好。

但同时, DOCnet 模型也存在一些不足, 比如: 目前 DOCnet 仅能完成强降水、雷暴大风、冰雹和龙卷风 4 类强对流天气的分类识别; 并且, 在这 4 类强对流天气中, DOCnet 对雷暴大风的分类命中率仅有 78.99%。这些问题都有待对模型和数据集作进一步完善和修改。

未来, 将结合 NOAA 上的记录对应标出强对流天气发生的具体位置以便于识别。并且, 还将引入 SEVIR 数据集中 vis、ir069、ir107 这 3 类数据集或地形数据制作多模态数据集, 并充分考虑到其他气象要素和地形与强对流天气的相关性, 以达到更好的识别效果。

参考文献:

[1] AUSTIN G L, BELLON A. Very-short-range forecasting of precipitation by the objective extrapolation of radar and satellite data[M]. London: Academic Press, 1982: 177-190.

[2] ROSENFELD D. Objective method for analysis and tracking of convective cells as seen by radar[J]. Journal of Atmospheric and Oceanic Technology, 1987, 4(3): 422-434.

[3] DIXON M, WIENER G. TITAN: thunderstorm identification, tracking, analysis, and nowcasting—a radar-based methodology[J]. Journal of Atmospheric and Oceanic Technology, 1993, 10(6): 785-797.

- [4] YU X D, ZHOU X G, WANG X M. The advances in the nowcasting techniques on thunderstorms and severe convection[J]. *Acta Meteorologica Sinica*, 2012, 70(3): 311-337.
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.
- [5] REN F, CUI D, GONG Z, et al. An objective identification technique for regional extreme events[J]. *Journal of Climate*, 2012, 25(20): 7015-7027.
- [6] YANG L, HAN F, CHEN M X, et al. Thunderstorm gale identification method based on support vector machine[J]. *Journal of Applied Meteorology*, 2018, 29(6): 680-689.
- [7] KIM M, LEE J, IM J. Deep learning-based monitoring of overshooting cloud tops from geostationary satellite data[J]. *GIScience & Remote Sensing*, 2018, 55(5): 763-792.
- [8] KURTH T, TREICHLER S, ROMERO J, et al. Exascale deep learning for climate analytics[C]// SC18: International Conference for High Performance Computing, Networking, Storage and Analysis, 2018: 649-660.
- [9] YUAN M, CHAI Z, ZHAO W. Severe convective weather classification in remote sensing images by semantic segmentation[C]// ICANN 2019: 28th International Conference on Artificial Neural Networks, 2019: 143-156.
- [10] LIU X W, HUANG W B, JIANG Y S, et al. Study of the classified identification of the strong convective weathers based on the LightGBM algorithm[J]. *Plateau Meteorology*, 2021, 40(4): 909-918.
刘新伟, 黄武斌, 蒋盈沙, 等. 基于LightGBM算法的强对流天气分类识别研究[J]. *高原气象*, 2021, 40(4): 909-918.
- [11] 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.
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [13] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[DB/OL]. <https://arxiv.org/abs/1409.1556>, 2014.
- [14] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// Boston: the IEEE Conference on Computer Vision and Pattern Recognition, 2015.
- [15] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]// International Conference on Machine Learning, 2015: 448-456.
- [16] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]// Proceedings of the IEEE Conference on Computer vision and Pattern Recognition, 2016: 2818-2826.
- [17] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning[C]// AAAI'17: Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, 2017: 4278-4284.
- [18] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications[DB/OL]. <https://arxiv.org/abs/1704.04861>, 2017.
- [19] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 4510-4520.
- [20] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [21] HUANG G, LIU Z, VAN DER M L, et al. Densely connected convolutional networks[C]// Honolulu: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2261-2269.
- [22] KRIZHEVSKY A, HINTON G. Learning multiple layers of features from tiny images[D]. Toronto: University of Toronto, 2009.
- [23] KABIR H M. Reduction of class activation uncertainty with background information[DB/OL]. <https://arxiv.org/abs/2305.03238>, 2023.
- [24] DENG J, DONG W, SOCHER R, et al. Imagenet: a large-scale hierarchical image database[C]// 2009 IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248-255.
- [25] CHEN X N, LIANG C, HUANG D, et al. Symbolic discovery of optimization algorithms[C]// Proceedings of the 37th International Conference on Neural Information Processing Systems, 2023: 49205-49233.
- [26] CHEN L M. Application of satellite cloud analysis chart to analyze the weather process of strong wind and hail on April 28[J]. *Scientia Meteorologica Sinica*, 1985(1): 77-79.
陈榴美. 应用卫星云分析图浅析4月28日大风冰雹天气过程[J]. *气象科学*, 1985(1): 77-79.
- [27] WANG J. Research on the approach of hail detection and nowcasting in Guizhou region based on storm numerical model[D]. Beijing: Chinese Academy of Meteorological Sciences, 2008.
王瑾. 基于强对流数值模拟的贵州冰雹识别及临近预报方法研究[D]. 北京: 中国气象科学研究院, 2008.
- [28] HU Y L, KANG J P, XIE Y M, et al. Preliminary analysis on the cause of tornadoe on July 3rd, 2007[J]. *Journal of Anhui Agricultural Sciences*, 2008, 36(27): 11936-11939.
胡玉玲, 康健鹏, 谢义明, 等. 2007年7月3日苏皖龙卷风成因初步分析[J]. *安徽农业科学*, 2008, 36(27): 11936-11939.
- [29] WANG X, LIAO R, LI J, et al. Thunderstorm identification research based on simulated airborne weather radar reflectivity data[J]. *EURASIP Journal on Wireless Communications and Networking*, 2020, 2020(1): 37.
- [30] ZHANG X F, MA Z Y, WANG H G, et al. Classification and feature analysis of radar mosaic echo of thunderstorm gale in Wuyuan[J]. *Meteorological, Hydrological and Marine Instruments*, 2021, 38(2): 20-24.
张晓芳, 马中元, 王汉根, 等. 婺源雷暴大风雷达成因回波分类与特征分析[J]. *气象水文海洋仪器*, 2021, 38(2): 20-24.
- [31] QIN H, NONG M S, LAI Z Q, et al. Analysis of large scale hail weather process in Guangxi on January 24, 2020[J]. *Journal of Meteorological Research and Application*, 2021, 42(1): 107-112.
覃皓, 农孟松, 赖珍权, 等. 2020年“1·24”广西大范围冰雹天气过程分析[J]. *气象研究与应用*, 2021, 42(1): 107-112.
- [32] ZHENG Z W, MA Z Y, CHEN B F, et al. Classification and characteristic analysis of radar echo of Fuliang thunderstorm and gale[J]. *Meteorological, Hydrological and Marine Instruments*, 2022, 39(4): 32-35.
郑志文, 马中元, 陈鲍发, 等. 浮梁雷暴大风雷达成因回波分类与特征分析[J]. *气象水文海洋仪器*, 2022, 39(4): 32-35.
- [33] ISHIDA T, YAMANE I, SAKAI T, et al. Do we need zero training loss after achieving zero training error?[C]// ICML'20: Proceedings of the 37th International Conference on Machine Learning, 2020: 4604-4614.
- [34] CHEN Y, FAN H, XU B, et al. Drop an octave: reducing spatial redundancy in convolutional neural networks with octave convolution[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 3434-3443.

(责任编辑: 孙娟)