

DOI: 10.13382/j.jemi.B2508585

# 用于雷暴云识别的大核卷积注意力和 U-Net 算法

王道平<sup>1,2</sup> 韦伟<sup>3</sup> 张光磊<sup>3</sup> 张翠芳<sup>3</sup> 郭新文<sup>1</sup> 田金虎<sup>3</sup> 余铸平<sup>4</sup>

(1. 气象防灾减灾湖南省重点实验室 长沙 410118; 2. 湖南省气象灾害防御技术中心 长沙 410007;

3. 北京华云东方探测技术有限公司 北京 100080; 4. 中国石化销售股份有限公司湖南石油分公司 长沙 410028)

**摘要:**针对当前雷暴云识别命中率不高的问题,通过深度学习技术提高识别的准确性。聚焦于融合大核卷积注意力机制 (large kernel attention, LKA) 和 U-Net 架构,构建了一种新的雷暴云识别模型 LkaUNet,以增强模型对雷暴云整体形态特征和长距离的空间依赖的建模。研究过程中,基于湖南省 2022~2023 年间的 S 波段雷达基数据和闪电资料,进行了多阶段质量控制实现雷达组合反射率与雷电数据的时空匹配与噪声抑制,生成了高质量的雷电概率和雷达组合反射率拼图数据集。在此基础上,构建了以 U-Net 为基础框架,并引入大核注意力模块的深度学习模型。大核卷积注意力机制通过扩大模型的感受野,提高了模型捕获长距离依赖,增强模型对雷暴云特征的感知能力。实验结果表明,采用回归损失函数训练的模型,当阈值大于 0.4 时,LkaUNet 模型的临界成功指数 (critical success index, CSI) 和命中率 (hit rate, HR) 均高于基准 U-Net 模型,同时漏报率 (negative alarm probability, NAP) 更低;采用分类损失函数进行训练,LkaUNet 模型临界成功指数达到 0.730 1,对应的命中率为 86.27%、漏报率为 13.73%、虚报率为 18.45%。研究表明,LkaUNet 能有效建模雷暴云长距离的空间依赖关系,为深度学习在强对流天气的监测提供了有效方案。

**关键词:**深度学习;雷达组合反射率拼图;雷电;雷暴云识别

**中图分类号:** TN95; TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.20

## Deep learning approach for thunderstorm cloud identification by integrating large kernel attention and U-Net

Wang Daoping<sup>1,2</sup> Wei Wei<sup>3</sup> Zhang Guanglei<sup>3</sup> Zhang Cuifang<sup>3</sup> Guo Xinwen<sup>1</sup> Tian Jinhui<sup>3</sup> Yu Zhuping<sup>4</sup>

(1. Hunan Provincial Key Laboratory of Meteorological Disaster Prevention and Mitigation, Changsha 410118, China;

2. Hunan Meteorological Disaster Prevention Technology Center, Changsha 410007, China; 3. Beijing HY Orient

Detection Technology Co., Ltd., Beijing 100080, China; 4. Hunan Petroleum Branch of Sinopec

Marketing Co., Ltd., Changsha 410028, China)

**Abstract:** To address the challenge of low hit rate in thunderstorm cloud identification, deep learning techniques are employed to enhance recognition accuracy. The research focuses on developing a novel thunderstorm cloud identification model, LkaUNet, which integrates a large kernel attention (LKA) mechanism with the U-Net architecture. This design enhances the model's ability to capture global morphological features and long-range spatial dependencies of thunderstorm clouds. The study utilizes S-band radar base data and lightning observation data from Hunan Province (2022~2023), employing multi-stage quality control to synchronize radar composite reflectivity and lightning data while suppressing noise. This process generates high-quality datasets of lightning probability and radar composite reflectivity mosaics as input. The LkaUNet model builds upon the U-Net framework and incorporates large kernel attention modules to expand the receptive field, thereby improving long-range dependency modeling and feature perception. Experimental results demonstrate: When trained with regression loss functions and a threshold exceeding 0.4, the LkaUNet achieves higher critical success index (CSI) and negative alarm probability (NAP), along with a lower false alarm rate (FAR), compared to the baseline U-Net model; Under classification-based loss training, LkaUNet achieved a CSI of 0.730 1, with corresponding detection metrics of 86.27% hit rate, 13.73% miss rate, and 18.45% false alarm rate. The study concludes that LkaUNet effectively models long-range spatial

correlations in thunderstorm clouds, providing a robust deep learning solution for monitoring severe convective weather. The approach highlights the potential of attention mechanisms in meteorological applications.

**Keywords:** deep learning; radar composite reflectivity mosaic; lightning; thunderstorm cloud identification

## 0 引言

雷暴云是产生闪电的对流云,常常伴随强降水、大风、冰雹、龙卷风等灾害性天气过程,是天气监测和预报的重要对象<sup>[1]</sup>。雷电灾害对人民群众的生产生活会造成极大影响,是联合国认定的最严重的 10 种自然灾害之一,全世界平均每分钟会发生 2 000 余次雷暴,每年因此伤亡人数超过万人,造成严重的经济损失<sup>[2-3]</sup>。闪电一般伴随着雷暴云的产生、发展和消亡的过程,是直接判断雷暴云的指标<sup>[4]</sup>。由于大气本身存在一定数量的水分子,当天气雷达发射的脉冲电磁波遇到这些粒子时,大部分能量会继续向前,部分能量则会散射,从而被雷达天线接收到<sup>[5]</sup>。天气雷达是探测降水云团的可靠手段,其强度和结构能够反映雷暴云内部的水凝物含量和分布。因此,通过分析雷达回波数据可以很好的得到雷暴云的分布。

随着气象观测系统和计算机技术的迅速发展,学者基于卫星观测资料、大气电场数据、雷达数据等进行雷暴云的识别研究。周康辉等<sup>[6]</sup>基于闪电数据进行雷暴的识别和追踪。周鑫等<sup>[7]</sup>基于 2010~2018 年 WWLLN 闪电数据和闪电密度的空间聚类算法,构建西北太平洋地区雷暴数据集,并进行时空分布特征分析。沈岳峰等<sup>[8]</sup>提出融合大气电场数据、闪电定位数据和雷达数据,使用深度学习和光流法进行雷电预警。

上述方法对雷暴云进行了较全面的识别和分析,密度极大值快速搜索聚类算法等机器学习方法和常规卷积神经网络能有效识别闪电密集的强对流雷暴区域,但对弱对流雷暴区域的识别不够精准,雷暴云整体识别效果有待进一步提升。雷暴云区域识别不精准对各行业会产生不同程度的影响,农业易导致作物减产、设施损毁;电力通信行业可能引发设备故障、供电通信中断;交通领域会增加航空、陆地及水运事故风险;工业尤其是易燃易爆行业,可能诱发爆炸泄漏等安全事故;同时威胁公众安全,导致应急响应滞后、次生灾害加剧。本研究基于雷达回波数据,通过深度学习强大的特征提取和识别能进行雷暴云识别,使用雷电信息进行模型训练的指导,结合 U-Net 网络<sup>[9-10]</sup>和大核注意力(large kernel attention, LKA)<sup>[11]</sup>提高模型捕获长距离依赖,增强对多尺度特征的感知能力,降低漏报率。主要包括以下内容:1)通过闪电数据和雷达回波数据构建的雷暴云数据集,减少人工标注成本;2)基于 U-Net 网络架构和大核注意力提出 LkaUNet 网络架构,大核注意力机制能捕获长距离依赖,

增强模型对多尺度特征的感知能力,降低漏报率,雷暴云识别效果优于基础模型;3)使用回归方法进行模型训练,通过迁移学习进行分类模型的训练,很好的提高了网络的性能。

## 1 构建 LkaUNet 模型

雷暴云具有复杂的多尺度空间结构,传统神经网络的感受野有限,难以有效捕捉雷暴云中大范围多尺度的动态结构和长距离的依赖关系,而常规注意力往往侧重于局部或通道层面,应对大范围、多尺度的空间模式捕捉时存在局限性。本研究引入大核卷积注意力机制,通过扩大卷积核的尺寸,扩大有效感受野,使模型能捕获雷暴云整体的结构核长距离的依赖关系,对雷暴云识别具有至关重要的作用。

### 1.1 模型结构

本文提出 LkaUNet (large kernel attention U-Net), 基于经典 U-Net 架构进行改进,通过引入大核卷积注意力模块增强模型对多尺度特征的感知能力。模型结构如图 1 所示,采用对称的网络结构,在跳跃连接中嵌入 LKA 模块,通过大核卷积捕获长程依赖关系,并利用注意力机制动态优化特征响应,抑制冗余特征,突出关键信息,有效解决了传统 U-Net 在强对流天气目标分割中存在的局部特征关联性不足、细节信息丢失等问题。

编码器部分由 4 级下采样单元构成,每级包含两个 3×3 卷积层、批归一化与 ReLU 激活函数,后接 2×2 最大池化层。随着网络深度增加,特征图的空间分辨率逐级减半,通道数倍增,形成多尺度特征。编码器部分提取雷达组合反射率拼图不同层次特征,从低级的反射率强度信息、降水区域的形状和轮廓特征、纹理特征到高级的语义和上下文信息特征,为后续的处理提供丰富的特征表示。

大核卷积注意力模块,在跳跃连接路径中,原始的编码器特征图与解码器特征融合前,经过 LKA 模块处理,抑制噪声并强化有效信息、捕获长程依赖关系。计算公式如式(1)~(2)所示。

$$O = A \otimes F \quad (1)$$

$$A = C_{\text{conv}1 \times 1}(D_{\text{WDConv}}(D_{\text{WConv}}(F))) \quad (2)$$

其中,  $A \in R^{C \times H \times W}$  是注意力特征图,  $F \in R^{C \times H \times W}$  是输入特征图,  $C_{\text{conv}1 \times 1}$  为通道卷积,  $D_{\text{WDConv}}$  为空间长程卷积(depth-wise dilation convolution),  $D_{\text{WConv}}$  为局部空间卷积(depth-wise convolution)。

解码器部分采用转置卷积实现上采样,每级包含  $2 \times 2$  反卷积层、特征拼接(与 LKA 模块输出的特征图进行

拼接)及两个  $3 \times 3$  卷积层。最终输出层使用  $1 \times 1$  卷积生成雷暴云团分割概率图。

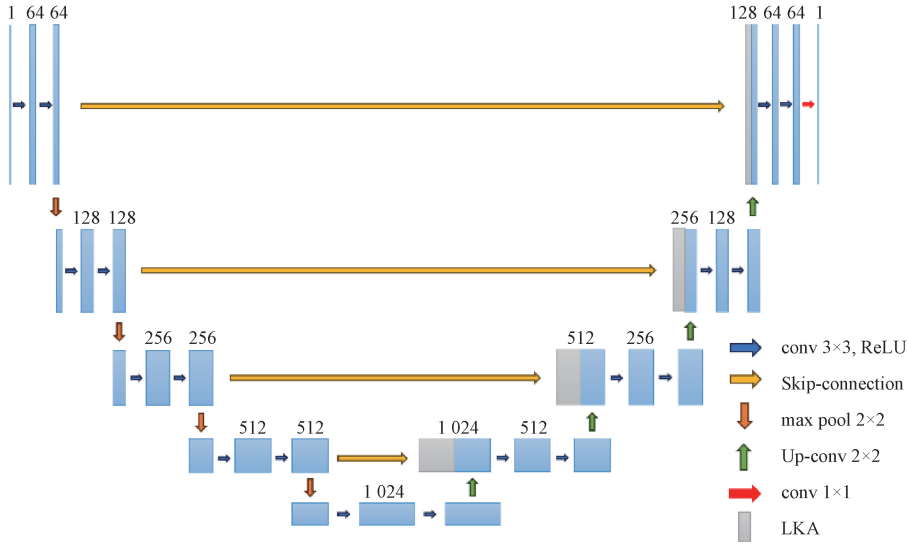


图 1 LkaUNet 网络结构  
Fig. 1 LkaUNet network structure

### 1.2 模型训练

本文采用分阶段训练与迁移学习策略,系统评估 LkaUNet 对雷暴云区域的分割性能。模型的输入数据为雷达组合反射率拼图数据,采用随机旋转、水平/垂直反转对数据进行增强,扩充数据的多样性。在模型训练的初始阶段,标签为 0-1 的数据集使用回归的方法进行训练,考虑雷暴云区域的空间分布不均衡性,LkaUNet 和 U-Net 模型均采用基于权重的均方差损失函数 (weighted MSE loss) 作为优化目标,模型输出雷暴云概率图,通过反向传播算法不断调整模型的权重参数,最小化损失函数,从而使得模型的预测结果尽可能接近实际的雷暴云分布。基于权重的均方差损失函数如式(3)所示。

$$L_{WMSE} = \frac{1}{N} \sum_{i=1}^N w_i \cdot (y_i - \hat{y}_i)^2 \quad (3)$$

其中,  $N$  为像素总数,  $w_i$  为权重系数,  $y_i$  为第  $i$  个像素的真实标签,  $\hat{y}_i$  为模型预测的第  $i$  个像素的雷暴云概率。

基于均方差损失的训练完成后,将这两个训练好的模型进行迁移学习,应用于标签为 0 和 1 的数据集,使用分类的方法进行模型的训练。在分类模型中,分割结果的像素预测值为二值类别(0 和 1),以此对图像中的不同像素点是否属于雷暴云进行分类判断,模型采用二元交叉熵损失函数(binary cross-entropy loss)和 Dice 相似系数损失函数(dice loss)<sup>[12-13]</sup>,交叉熵损失函数可以很好的衡量模型预测概率分布和实际标签分布之间的相似度,Dice 相似系数损失函数关注预测区域和真实区域之间的

重叠面积,有助于提高边界位置预测的准确性。损失函数如式(4)所示。

$$L = \alpha L_{BCE} + (1 - \alpha) L_{Dice} \quad (4)$$

式中:二元交叉熵损失函数和 Dice 相似系数损失函数如式(5)、(6)所示。

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N y_i \log \hat{y}_i + (1 - y_i) \log(1 - \hat{y}_i) \quad (5)$$

$$L_{Dice} = 1 - \frac{2 \sum_{i=1}^N y_i \hat{y}_i}{\sum_{i=1}^N y_i + \sum_{i=1}^N \hat{y}_i} \quad (6)$$

其中,  $\alpha$  为权重系数,  $L_{BCE}$  为二元交叉熵损失函数,  $L_{Dice}$  为 Dice 相似系数损失函数,  $N$  为像素总数,  $y_i$  为第  $i$  个像素的真实标签,  $\hat{y}_i$  为模型预测的第  $i$  个像素的雷暴云概率。

## 2 结果与分析

### 2.1 资料与方法

#### 1) 数据来源

研究选取湖南省 2022 年和 2023 年的雷达组合反射率拼图和雷电数据作为数据源。雷达数据由湖南省布网的天气雷达采集,通过对不同位置、不同角度的雷达反射率数据进行处理,生成了能够全面反映湖南省上空降水粒子分布、强度以及降水系统结构等信息的雷达组合反射率拼图,时间分辨率为 6 min,空间分辨率为  $0.01^\circ \times 0.01^\circ$  的网格化拼图。闪电定位仪和大气电场仪作为获

取雷电数据的重要工具,在湖南省组成了一套完整的闪电监测网络,能够精准记录闪电发生的时间、经纬度位置、闪电类型(云闪或地闪)以及闪电强度等关键参数,大气电场仪和闪电定位仪的主要性能指标如表 1 和 2 所示。

表 1 大气电场仪主要性能指标

Table 1 Key technical specifications of the atmospheric electric field instrument

性能属性	性能指标
测量范围	-100~+100 kV/m
分辨率	10 V/m
灵敏度	≤20 V/m
测量误差	≤5%
响应时间	≤50 ms
预警时间	>0.5 h

表 2 闪电定位仪主要性能指标

Table 2 Key technical specifications of the lightning locator

性能属性	性能指标
观测频段	1~400 kHz
单站探测范围	300 km
地闪探测效率	90%
定位精度	500 m
时间接收源精度	0.1 μs

## 2) 数据预处理

通过多阶段质量控制实现雷达组合反射率与雷电数据的时空匹配与噪声抑制,达到对资料的初步质控。在时间维度上,以雷达扫描周期 6 min 为基准,聚合前后 15 min 窗内的闪电事件,并通过 DBSCAN 算法(邻域半径 0.02°,最小样本数 3)剔除孤立闪电点<sup>[14]</sup>。空间维度上,使用核密度估计方法,将离散闪电点转换为网格的雷电概率图<sup>[8]</sup>,其核函数定义如式(7)所示。

$$V_{ijk} = \begin{cases} 1 - (1 - e^{-\frac{4L_{ijk}}{r^2}})(1 - V_{ij(k-1)}), & k > 0, \frac{L_{ijk}}{r^2} \leq 1 \\ V_{ij(k-1)}, & k > 0, \frac{L_{ijk}}{r^2} \geq 1 \\ 0, & k > 0 \end{cases} \quad (7)$$

式中:格点与闪电位置的距离定义如式(8)所示。

$$L_{ijk} = (i - I(x_k))^2 + (j - J(y_k))^2 \quad (8)$$

式中: $V_{ijk}$  表示格点  $(i, j)$  经过  $k$  次闪电后的闪电概率密度值; $i$  为格点行号; $j$  为格点列号; $x_k$  表示第  $k$  个闪电的经度; $y_k$  表示第  $k$  个闪电的纬度; $I(x_k)$  为经度索引; $J(y_k)$  为纬度索引值。

基于阈值筛选,保留闪电密度图连续区域面积

≥50 km<sup>2</sup> 的雷暴云团,同时匹配雷达回波强度 ≥40 dBZ 以保障电活动与对流强度的物理一致性<sup>[15-16]</sup>。经质控后共生成有效样本 3 609 组,样本季节分布为春季 1 047 例(29.0%)、夏季 2 387 例(66.1%)、秋季 166 例(4.6%)及冬季 9 例(0.3%)。

## 3) 评估指标

为了全面评估 LkaUNet 和 U-Net 迁移后的性能优势,选取未使用迁移学习的全卷积网络(fully convolutional network, FCN)<sup>[17-18]</sup>和 Deeplabv3+模型<sup>[19]</sup>作为对比对象。所有模型统一使用 AdamW 优化器<sup>[20]</sup>进行权重的更新,学习率为  $1 \times 10^{-4}$ ,权重衰减为  $1 \times 10^{-4}$ ,epoch 设置为 500。利用临界成功指数(critical success index, CSI)、命中率(hit rate, HR)、虚报率(false alarm rate, FAR)和漏报率(no alarm probability, NAP)对模型效果进行评估。评价指标定义如式(9)~(12)所示。

$$CSI = \frac{T_p}{T_p + F_p + F_N} \quad (9)$$

$$HR = \frac{T_p}{T_p + F_N} \quad (10)$$

$$FAR = \frac{F_p}{T_p + F_p} \quad (11)$$

$$NAP = \frac{F_N}{T_p + F_N} \quad (12)$$

式中: $T_p$  为实际为正预测为正的样本(prediction = 1, target = 1); $F_p$  为实际为负预测为正的样本(prediction = 1, target = 0); $F_N$  为实际为正预测为负的样本(prediction = 0, target = 1)。

## 2.2 回归方法性能分析

基于构建的回归数据集和带权重的 MSE 损失函数进行 U-Net 和 LkaUNet 模型的训练,模型输出为每个像素点雷暴云的概率,取值为 0~1,表示该位置发生雷暴云的概率,通过设定不同阈值识别雷暴云区域,实验结果如图 2 所示。

CSI 是评估模型综合性能的指标,同时兼顾正确预测、漏报和误报的情况。阈值设定从 0.1 到 0.9, LkaUNet 和 U-Net 均呈现近似平稳的趋势,整体水平较为接近, LkaUNet 在阈值为 0.5 时取得最大值, U-Net 在阈值为 0.4 时取得最大值。但阈值在区间 [0.4, 0.9] 时, LkaUNet 的 CSI 值高于 U-Net,表明在常用阈值上 LkaUNet 效果较好,通过引入大核卷积注意力模块,提高了模型在不同场景下的稳定性。

HR 反映模型正确识别样本的能力。U-Net 和 LkaUNet 模型的 HR 均随阈值的增大不断减小,但 LkaUNet 的 HR 全程均高于 U-Net,即在相同的阈值下, LkaUNet 具有更高的命中率。表明 LkaUNet 结构的改进使其对目标特征的捕获更精准,显著提升了模型对目标

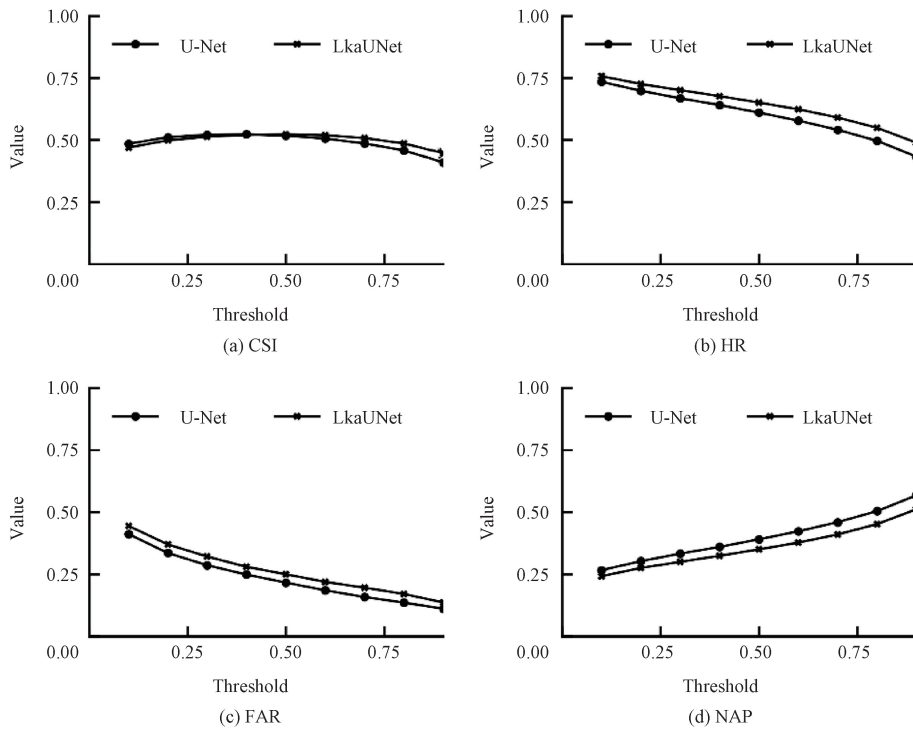


图 2 LkaUNet 和 U-Net 不同阈值下的结果对比

Fig. 2 Comparative analysis of LkaUNet and U-Net performance across threshold variations

的识别能力。

FAR 用于衡量模型将非目标样本误判为目标的概率。U-Net 和 LkaUNet 模型的 FAR 均随阈值的增加不断减小,且 U-Net 的 FAR 值始终低于 LkaUNet,即相同阈值下,U-Net 的虚报率更低。

NAP 评估模型将目标误判为非目标的概率。U-Net 和 LkaUNet 模型的 FAR 均随阈值的增大不断增加,且 LkaUNet 的 NAP 值始终低于 U-Net,即相同阈值下,LkaUNet 的漏报率更低。表明 LkaUNet 能更精准的识别真是目标和噪声信息,识别结果更可靠。

综上所述,本研究通过调整阈值,系统评估了基于回归损失函数训练模型的识别效果。结果表明,改变阈值可以调整模型的识别效果,阈值越大临界成功指数先增加后减小,HR 和 FAR 随着阈值的增加不断减小,阈值越大 NAP 越大。当阈值大于 0.4 时,LkaUNet 的 CSI 和 HR 均高于 U-Net,在常用阈值下 LkaUNet 可有效提升 CSI 和 HR。

### 2.3 分类方法模型性能分析

基于构建的分类数据集和二元交叉熵损失函数及 Dice Loss 进行 LkaUNet、U-Net、DeepLabv3+和 FCN 模型的训练,模型的输出为像素点是否为雷暴云,取值为 0 和 1,0 表示非雷暴云区域,1 表示雷暴云区域。基于迁移学习的方法,使用 LkaUNet 和 U-Net 回归模型的参数对相应的分类模型进行初始化。在测试集进行模型效果的评

估,测试效果随 epoch 的变化如图 3 所示(每 20 个 epoch 取一个点)。

LkaUNet 模型的 CSI 和 HR 随着训练次数的增加呈现上升趋势。CSI 在训练初期即超过了 0.6,最终稳定在 0.73 左右。HR 在训练初期虽有波动,但后期逐渐稳定在 0.85 左右,表明 LkaUNet 模型在雷暴云识别任务中的稳定性和可靠性。FAR 在训练初期迅速下降,并在 0.2 左右稳定下来。NAP 指标在模型训练初期波动较大,随着训练的推进逐渐趋于稳定。这两项指标的稳定性表明 LkaUNet 在减少误报和漏报方面具有有效的控制能力。

U-Net 模型在 CSI 和 HR 指标上前期上升比较明显,后期逐渐趋于稳定,最终 CSI 稳定在 0.73 左右,HR 稳定在 0.84 左右。U-Net 的 FAR 和 NAP 指标在初期有较大波动,随后趋于稳定,表明模型在训练过程中逐渐优化了对误报和漏报的控制,但模型整体效果不如 LkaUNet。

DeepLabV3+模型在 CSI 和 HR 指标上表现出快速提升并迅速稳定的趋势。其 FAR 一直稳定在 0.2 以下,而 NAP 指标在初期有较大波动,随后趋于稳定,但整体处于较高水平,对漏报的控制能力较差。模型优化效果不突出,整体效果不如 LkaUNet 和 U-Net。

FCN 模型在训练初期的指标波动较大,后期 HR 虽有提升但幅度有限,CSI 始终处于降低水平,FAR 和 NAP 始终处于较高水平。模型目标关联性提升不明显,对目

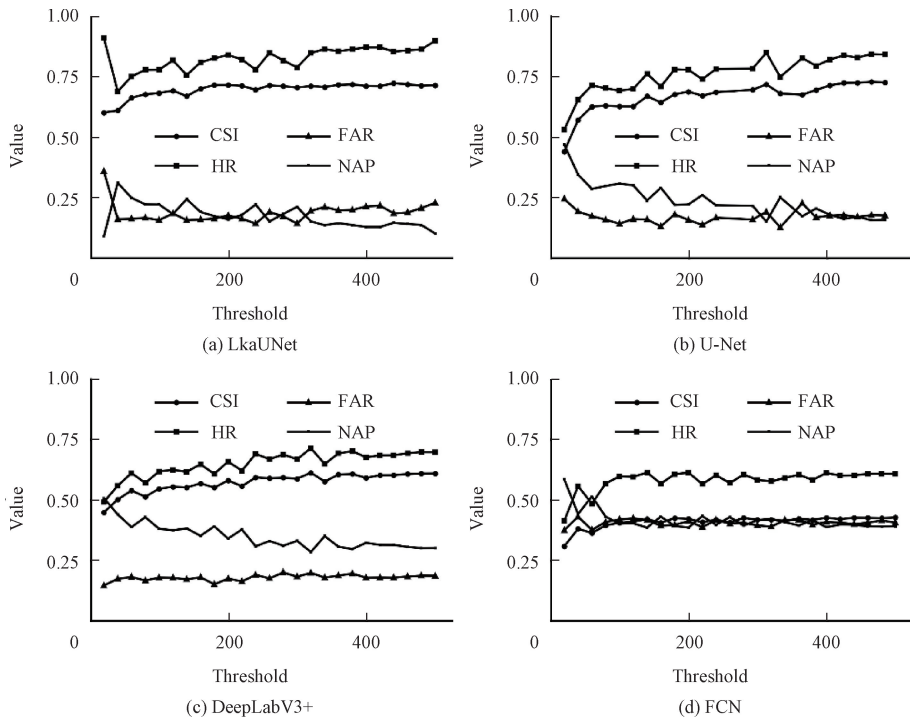


图 3 模型评估结果

Fig. 3 Model performance evaluation metrics

标区域的判别能力不足,整体表现不及 LkaUNet、U-Net 和 Deeplabv3+。

综上所述,LkaUNet 和 U-Net 使用回归进行参数初始化的模型效果明显好于 DeepLabV3+和 FCN,验证了迁移学习的有效性。LkaUNet 的 CSI 和 HR 提升显著且收敛性好,FAR 和 NAP 处于较低水平,体现其在训练过程中对目标识别、误报及漏报抑制的综合优势。相比之下,U-Net、DeepLabV3+和 FCN 在各指标上的优化效率与最终性能均弱于 LkaUNet。结果验证了 LkaUNet 模型结构在训练稳定性与性能提升上的优越性,为雷暴云识别任务提供了更高效的模型选择。模型最优结果如表 3 所示,LkaUNet 模型的整体效果最好,在 CSI 相当的情况下,LkaUNet 的 HR 比 U-Net 高 1.95%,虚报率仅差 0.93%。

表 3 模型效果对比

Table 3 Comparative evaluation of model performance

模型	HR/%	FAR/%	NAP/%	CSI
LkaUNet	86.27	18.45	13.73	0.730 1
U-Net	84.32	17.52	15.68	0.730 4
DeepLabv3+	68.79	18.84	31.21	0.599 1
FCN	60.84	40.67	39.15	0.428 3

87.53%、FAR 为 14.66% 和 6.61%、NAP 为 7.00% 和 12.47%、CSI 为 0.801 8 和 0.824 3,U-Net(图 4(c))HR 为 91.79% 和 85.98%、FAR 为 12.22% 和 5.56%、NAP 为 8.21% 和 14.02%、CSI 为 0.813 9 和 0.818 4,DeepLabV3+(图 4(d))HR 为 82.70% 和 72.09%、FAR 为 15.61% 和 7.86%、NAP 为 17.30% 和 27.91%、CSI 为 0.717 2 和 0.679 1,FCN(图 4(e))HR 为 77.84% 和 65.02%、FAR 为 23.82% 和 25.47%、NAP 为 22.16 和 34.98%、CSI 为 0.626 0 和 0.532 0,LkaUNet 的整体效果最好。

由图 4 可知,模型对大面积雷暴云区域具有较好的识别效果,能够精准捕捉明显的气象特征和空间分布模式,在区域分割和边界定位上均呈现较高精度,实现对大规模雷暴云区域的完整定位和准确识别,在处理显著气象现象方面具有较高的鲁棒性和精准性。对较小区域或分布比较零散的区域识别精度有待进一步提升,部分零散小区域雷暴云存在漏检或误检的情况,已识别的小区域也可能出现边界定位偏差,导致分割结果在完整性与准确性上有所欠缺。从技术层面剖析,该现象或与模型对小目标特征的提取能力不足、上下文信息融合机制不完善相关。后续研究可围绕优化特征融合结构,引入小目标增强检测模块等方向展开,以提升模型对复杂场景中尺度目标的识别能力。此外,训练数据中这类区域的样本数量可能相对较少,导致模型在该分布的数据上泛化能力受到限制。

LkaUNet、U-Net、DeepLabV3+ 和 FCN 模型预测结果如图 4 所示,LkaUNet(图 4(b))的 HR 为 93.00% 和

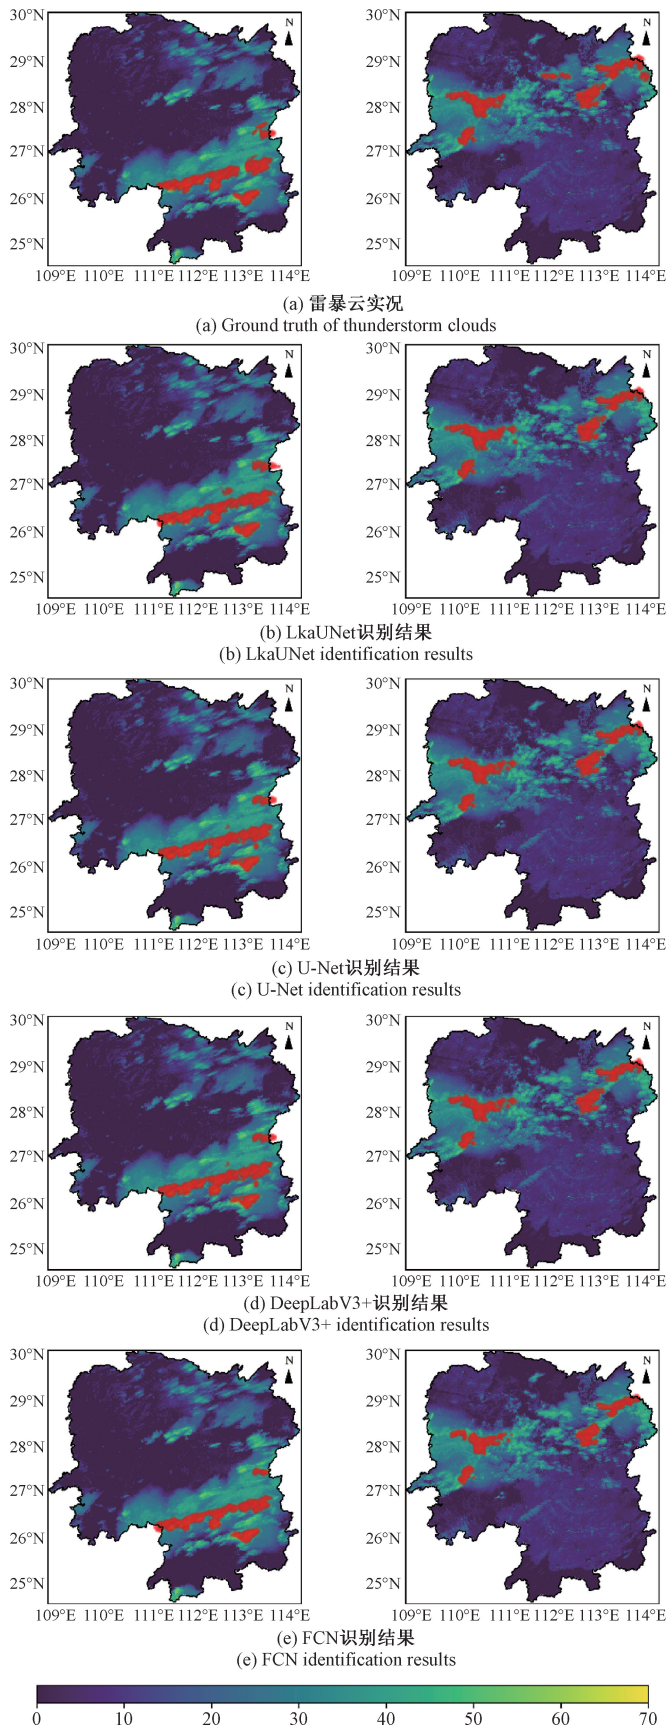


图 4 模型预测效果

Fig. 4 Predictive performance evaluation of the model

### 3 结 论

本文针对雷暴云多尺度空间结构特征,以及传统神经网络在捕捉其大范围信息和长距离依赖方面存在的不足,提出一种融合大核注意力机制与 U-Net 架构的深度学习模型 LkaUNet,以提升雷暴云识别的命中率。研究基于湖南省 2022 年至 2023 年的 S 波段雷达组合反射率拼图数据和雷电数据,构建了高质量的雷暴云数据集,系统对比了 LkaUNet 与基线模型(U-Net、DeepLab、FCN)的识别性能,并对识别结果进行了对比分析。主要结论如下:1)在数据集构建和预处理方面,使用 DBSCAN 算法对原始雷电数据进行清洗和去噪,有效消除了离散噪声。通过概率计算生成雷电概率图,并结合雷达回波的强度信息,构建 0-1 连续概率标签与二值化标签(0/1)的雷暴云数据集,通过数据特征构建符合实际分布的雷暴云数据集,为模型训练提供了有效、可靠的数据基础。2)在模型架构和回归训练方面,LkaUNet 网络在 U-Net 架构中引入大核卷积注意力机制,显著扩大了模型的感受野,增强了模型对雷暴云大尺度形态特征和长距离信息的捕捉。使用 MSE 损失函数在 0-1 雷暴云数据集上进行 LkaUNet 和 U-Net 模型的训练,实验结果表明,在常用阈值上,LkaUNet 识别效果由于传统 U-Net,验证了大核卷积注意力机制在雷暴云识别中的有效性。3)在分类模型训练方面,使用迁移学习方法,以回归模型的参数对 LkaUNet 和 U-Net 进行初始化,显著提升了模型性能。对比试验表明,经过迁移学习的 LkaUNet 和 U-Net 网络的性能明显优于不使用该策略的 DeepLabv3+ 和 FCN。进一步分析发现,模型对大面积、成片分布的雷暴云区域具有好的识别效果,对较小区域或分布比较零散的区存在漏检或误检的情况,识别精度有待进一步提升。4)在综合性能评估方面,本文提出的 LkaUNet 模型综合效果最好,其 CSI 达到 0.730 1,相应的 HR 为 86.27%、NAP 为 13.73%、FAR 为 18.45%。各项指标均表明,LkaUNet 以较高的精度和可靠性实现了雷暴云的像素级识别。

研究仍存在一定的局限性,主要体现在对于小目标雷暴云识别的精度仍有不足,后续将持续对模型结构、训练方法和数据集进行优化,进一步提升模型的性能。


### 参考文献

[ 1 ] 马瑞阳,郑栋,姚雯,等. 雷暴云特征数据集及我国雷暴活动特征[J]. 应用气象学报, 2021, 32(3): 358-369.  
MA R Y, ZHENG D, YAO W, et al. Thunderstorm feature dataset and characteristics of thunderstorm activities in China[J]. Journal of Applied Meteorological Science, 2021, 32(3): 358-369.

[ 2 ] HOLLE R L. A year of global lightning deaths and injuries [ C ]. 2023 12th Asia-Pacific International Conference on Lightning ( APL ), Langkawi, Malaysia, 2023: 1-6.  
[ 3 ] YIN Q Y, LIU H Y, FAN X P, et al. Lightning fatalities in China, 2009-2018 [ J ]. Journal of Agricultural Meteorology, 2021, 77(2): 150-159.  
[ 4 ] 谢晓林,胡迪,罗宇昂,等. 成都“8·11”强对流天气多普勒雷达与闪电特征分析[J]. 成都信息工程大学学报, 2022, 37(6): 701-708.  
XIE X L, HU D, LUO Y ANG, et al. Analysis of doppler radar and lightning characteristics in “8·11” severe convective weather in chengdu [ J ]. Journal of Chengdu University of Information Technology, 2022, 37(6): 701-708.  
[ 5 ] 唐顺仙,吕达仁,何建新,等. 天气雷达技术研究进展及其在我国天气探测中的应用[J]. 遥感技术与应用, 2017, 32(1): 1-13.  
TANG SH X, LYU D R, HE J X, et al. Research of weather radar technology and application on Chinese weather observation[J]. Remote Sensing Technology and Application, 2017, 32(1): 1-13.  
[ 6 ] 周康辉,郑永光,蓝渝. 基于闪电数据的雷暴识别、追踪与外推方法[J]. 应用气象学报, 2016, 27(2): 173-181.  
ZHOU K H, ZHENG Y G, LAN Y. Flash cell identification, tracking and nowcasting with lightning data [ J ]. Journal of Applied Meteorological Science, 2016, 27 ( 2 ): 173-181.  
[ 7 ] 周鑫,张文娟,张义军,等. 基于闪电聚类方法的西北太平洋区域雷暴活动特征[J]. 热带气象学报, 2021, 37(3): 490-501.  
ZHOU X, ZHANG W J, ZHANG Y J, et al. Characteristics of thunderstorm activity in the northwest pacific based on lightning clustering method [ J ]. Journal of Tropical Meteorology, 2021, 37(3): 490-501.  
[ 8 ] 沈岳峰,刘冬,刘银锋,等. 基于深度学习的雷电预警算法[J]. 自动化与仪表, 2022, 37(10): 1-7, 13.  
SHEN Y F, LIU D, LIU Y F, et al. Lightning warning algorithms based on deep learning [ J ]. Automation and Instrumentation, 2022, 37(10): 1-7, 13.  
[ 9 ] RONNEBERGE O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [ C ]. International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer International Publishing, 2015: 234-241.  
[ 10 ] 张平,佟昆宏,王学珍. 基于改进 U-net 网络的液压管路分割方法 [ J ]. 电子测量与仪器学报, 2023,

- 37(1): 123-129.
- ZHANG P, TONG K H, WANG X ZH. Hydraulic pipeline segmentation method based on improved U-net network [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(1): 123-129.
- [11] GUO M H, LU C Z, LIU Z N, et al. Visual attention network [J]. *Computational Visual Media*, 2023, 9(4): 733-752.
- [12] MILLETARI F, NAVAB N, AHMADI S A. V-Net: Fully convolutional neural networks for volumetric medical image segmentation [C]. 2016 Fourth International Conference on 3D Vision (3DV). IEEE, 2016: 565-571.
- [13] SUDRE C H, LI W, VERCAUTEREN T, et al. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations [C]. *International Workshop on Deep Learning in Medical Image Analysis*. Cham; Springer International Publishing, 2017: 240-248.
- [14] ZHAO Z, ZHOU W L, LIANG D H, et al. Denoising method based on improved DBSCAN for lidar point cloud [J]. *IEEE Access*, 2024, 12(000): 137656-137666.
- [15] HUANG Y J, WANG J G, CAI L, et al. Relationship between radar reflectivity thresholds and very low frequency/low frequency total lightning for thunderstorm identification [J]. *High Voltage*, 2024, 9(5): 1068-1080.
- [16] 师正, 吴子珉, 孙京, 等. 基于三种聚类算法的雷暴系统识别效果对比研究 [J]. *暴雨灾害*, 2023, 42(3): 334-345.
- SHI ZH, WU Z M, SUN J, et al. Comparative research on thunderstorms identification based on three clustering methods [J]. *Torrential Rain and Disasters*, 2023, 42(3): 334-345.
- [17] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 3431-3440.
- [18] 金玉, 袁和金. 基于改进 FCN 双路径特征融合的局部放电图谱识别 [J]. *电子测量技术*, 2022, 45(24): 132-136.
- JIN Y, YUAN H J. Partial discharge pattern recognition based on improved FCN dual path feature fusion [J]. *Electronic Measurement Technology*, 2022, 45(24): 132-136.
- [19] CHEN L C, ZHU Y K, PAPANDEOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]. *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018: 801-818.
- [20] 蔡玉芳, 王涵, 李琦, 等. 联合自然梯度和 AdamW 算法的 RSF 图像分割模型 [J]. *仪器仪表学报*, 2023, 44(3): 261-270.
- CAI Y F, WANG H, LI Q, et al. RSF image segmentation model joint natural gradient and AdamW algorithm [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(3): 261-270.

### 作者简介



王道平, 2002 年于成都信息工程学院获得学士学位, 2014 于成都信息工程学院获得硕士学位, 现为湖南省气象灾害防御技术中心高级工程师, 主要研究方向是雷电灾害防御等工作。

E-mail: 836460717@qq.com

**Wang Daoping** received his B. Sc. degree from Chengdu University of Information Technology in 2002 and M. Sc. degree from Chengdu University of Information Technology in 2014. He is now a senior engineer at the Hunan Provincial Meteorological Disaster Prevention Technology Center. His main research interests include lightning disaster prevention and related research.



韦伟(通信作者), 2007 年于北京印刷学院获得学士学位, 现为北京华云东方探测技术有限公司副总经理, 主要负责技术研发、供应链保障及党政管理等相关工作。

E-mail: 15749006@qq.com

**Wei Wei** (Corresponding author) received his B. Sc. degree from Beijing Institute of Graphic Communication in 2007. He is now the deputy general manager of Beijing Huayun Oriental Detection Technology Co., Ltd. He is primarily responsible for technology research and development, supply chain support, as well as party affairs and administrative management.