

曹华,杜牧云,胡嘉芬,等,2026. 基于语义分割的雷达拼图径向和环状异常回波识别方法[J]. 气象,52(9):1117-1129. Cao H, Du M Y, Hu J F, et al, 2026. Radial and circular abnormal echo recognition in radar mosaic based on semantic segmentation method[J]. Meteor Mon, 52(9):1117-1129(in Chinese).

基于语义分割的雷达拼图径向和环状异常回波识别方法^{*}

曹 华^{1,2,3} 杜牧云^{1,2} 胡嘉芬⁴ 姚 曼⁴ 余 蓉⁵ 刘佩廷⁶

- 1 中国气象局武汉暴雨研究所 全国暴雨研究中心/中国气象局流域强降水重点开放实验室/暴雨监测预警湖北省重点实验室, 武汉 430205
- 2 中国气象局雷达气象重点开放实验室, 南京 210023
- 3 湖北省随州市气象局, 随州 441300
- 4 湖北省气象台, 武汉 430074
- 5 湖北省防雷中心, 武汉 430074
- 6 武汉市气象局, 武汉 430040

提 要: 受设备故障、外界干扰等多种因素影响, 长时间业务运行的天气雷达时常产生异常回波, 制约其在强天气监测预警预报中的应用效果。本研究从历史雷达拼图数据中人工筛选出径向与环状两类异常回波并标注标签, 利用数据增强技术构建了包含 20 000 张图像的雷达拼图异常回波数据集。针对语义分割模型 DeepLabV3+ 进行改进: 使用精简的 ResNet50 结构作为主干网络, 减少了计算量; 主干特征提取层增加了简单注意力机制 SimAM, 使模型更加关注重要回波特征; 在解码器中增加了中层, 可以有效引入更多的细节和背景。试验结果表明, 改进后的模型 DeepLab-ARER 对异常回波的识别效果较好, 其平均像素准确率为 96.75%, 平均交并比为 93.95%, 与 DeepLabV3+ 相比有明显提升, 可为雷达拼图异常回波的自动识别提供有效技术支撑。

关键词: 雷达拼图, 异常回波, 深度学习, 语义分割

中图分类号: P412, TP391

文献标志码: A

DOI: 10.7519/j.issn.1000-0526.2026.052501

Radial and Circular Abnormal Echo Recognition in Radar Mosaic Based on Semantic Segmentation Method

CAO Hua^{1,2,3} DU Muyun^{1,2} HU Jiafen⁴ YAO Man⁴ YU Rong⁵ LIU Peiting⁶

- 1 Heavy Rainfall Research Center of China/ CMA Basin Heavy Rainfall Key Laboratory/ Hubei Key Laboratory for Heavy Rain Monitoring and Warning Research, Institute of Heavy Rain, CMA, Wuhan 430205
- 2 CMA Radar Meteorology Key Laboratory, Nanjing 210023
- 3 Suizhou Meteorological Office of Hubei Province, Suizhou 441300
- 4 Hubei Meteorological Observatory, Wuhan 430074
- 5 Hubei Lightning Protection Center, Wuhan 430074
- 6 Wuhan Meteorological Bureau, Wuhan 430040

^{*} 国家自然科学基金项目(42575172)、湖北省自然科学基金气象联合基金项目(2023AFD095)、全国暴雨研究开放基金项目(BYKJ2024Z08、BYKJ2025M18)、中国气象局创新发展专项(CXFZ2024J015)、中国气象局雷达气象重点开放实验室课题(2023LRM-B07)和武汉市气象科技联合项目(2024020901030452)共同资助

2025 年 6 月 17 日收稿; 2026 年 5 月 25 日收修定稿

第一作者: 曹华, 主要从事气象信息技术研究. E-mail: 468087977@qq.com

通讯作者: 杜牧云, 主要从事雷达数据质量控制与资料同化研究. E-mail: dumy@whihr.com.cn

Abstract: Weather radar systems operating continuously over long periods are often affected by equipment failures, external interference, and other factors, which may lead to abnormal echoes and limit their effectiveness in monitoring, warning, and forecasting severe weather. In this study, two types of abnormal echoes, radial and annular echoes, were manually selected and labeled from historical radar mosaic data. A weather radar abnormal echo dataset for radar mosaics, WRAED, containing 20 000 images, was then constructed using data augmentation techniques. An improved model was developed based on the semantic segmentation model DeepLabV3+. A simplified ResNet50 architecture was adopted as the backbone network to reduce computational cost. A simple attention mechanism, SimAM, was added to the backbone feature extraction layers to help the model focus on important echo features. In addition, an intermediate layer was introduced into the decoder to incorporate more detailed and contextual background information. The improved model, named DeepLab-ARER, was designed for abnormal echo recognition in radar mosaics. Experimental results show that DeepLab-ARER achieves good performance in identifying abnormal echoes, with a mean pixel accuracy of 96.75% and a mean intersection over union of 93.95%, representing a clear improvement over DeepLabV3+. The DeepLab-ARER model provides effective technical support for the automatic identification of abnormal echoes in radar mosaic.

Key words: radar mosaic, abnormal radar echo, deep learning, semantic segmentation

引 言

天气雷达拼图是将某个区域内多部雷达扫描数据拼接在一起形成覆盖该区域的雷达回波图像。雷达拼图能够提升灾害天气预警和防御能力,是预报员高频使用的一种气象资料。然而,天气雷达是由高度复杂的电子系统组成,其运行易受系统内部电子元器件故障、系统机械故障、功能模块工作异常及外部环境干扰等多种因素的影响,导致在长时间业务运行中不可避免地产生异常数据(谢千里,2020)。虽然相关数据质量控制技术已相对成熟,但依然无法完全剔除所有的异常数据,雷达拼图中仍会存在径向、环状等异常回波。径向异常回波是一种沿径向分布的条幅状回波,主要由外部远距离单频点电磁波干扰和内部数据处理异常引起(周红根等,2008)。环状异常回波主要由雷达发射机/接收机故障引起的探测数据强度异常导致,表现为相邻体扫回波强度、范围差别很大,出现环状、饼状回波(赵瑞金等,2015)。这些异常回波不仅直接影响预报员对天气系统的分析判断,还显著削弱了雷达数据的定量应用效果。对于气象业务人员而言,虽然异常回波的人工识别并非难事,但在海量雷达拼图数据中进行人工识别的工作量巨大、效率低下,难以满足数值模式同化系统、强对流天气自动识别系统等业务系统处理效率的要求。因此,实现雷达拼图异常回波的自动有效识别,对于提高数据质量和业务效率

具有重要现实意义。

早期,天气雷达异常回波的检测识别主要依赖传统图像处理和人工特征判别。Haddad et al (2004)利用雷达回波图像的纹理信息,通过灰度直方图以及灰度和差直方图区分降水回波和地物回波,表明纹理统计特征在杂波识别中具有一定判别能力。赵悦等(2007)将中值滤波与小波变换相结合,用于天气雷达回波图像处理,为自动识别回波种类提供了良好的基础。何建新等(2010)采用自适应高斯频域滤波器对天气雷达的地物杂波进行识别与抑制。邵楠等(2013)结合图像处理、特征提取和迭代学习器,实现了异常雷达产品的自动检测。Sadouki and Haddad(2013)则通过灰度共生矩阵进行图像纹理分析,能够有效区分降水回波与杂波。上述基于传统的图像识别技术虽然取得了一定的识别效果,但是严重依赖人工设计特征与固定参数。

随着深度学习方法的应用逐渐成熟,其在气象领域的应用也日益活跃(钱奇峰等,2021;陈鹤等,2022;袁凯等,2022;张雪等,2023;曾小团等,2025)。其中,基于深度学习的图像分类算法已被应用到雷达异常回波识别中。刘昉等(2021)提出了基于卷积神经网络(CNN)的天气雷达异常回波图像识别。Yang et al(2020)基于堆叠自编码器提出了异常天气雷达回波图像识别方法。张林等(2023)基于深度学习研发了天气雷达异常数据识别技术。上述方法对雷达回波图像类别识别时效快、准确率高,较传统识别方法具有显著优势。但是图像分类算法主要识

别一张图片的整体类别,即判断一张回波图像是否包含异常回波,而无法区分包含异常回波图像中的降水回波和异常回波的轮廓、边界及具体的像素位置。

图像分割技术能够将数字图像分割成离散像素类别,通过对每个像素分配一个类别标签实现对图片轮廓的精确描绘。图像分割技术主要分为语义分割、实例分割和全景分割。其中,语义分割是对像素进行语义分类,实例分割是区分同类物体的不同个体,而全景分割结合了两者的优点,实现对图像更全面的分割。语义分割技术的发展经历了三个阶段,第一阶段是基于传统方法的图像语义分割时期,主要依赖图像的低级特征进行分割,但无法实现语义标注的效果;第二阶段是深度学习与传统方法结合的时期,利用卷积神经网络算法实现语义分割(Razavian et al, 2014),但其准确性受到传统方法的限制;第三阶段是基于全卷积神经网络(FCN)时期(Long et al, 2015),FCN通过卷积层提取特征,并利用反卷积层来恢复图像分辨率,实现了像素级别的语义分类(王关茗和胡乃平, 2023; 邝辉宇和吴俊君, 2019)。考虑到雷达异常回波识别的目标是理解回波图像中不同区域的语义信息(正常回波或异常回波),不是简单判断回波图像中是否包含异常回波,也不需要区分同类别的不同个体。因此,本文采用语义分割方法对异常回波进行像素级别的识别,从而提升雷达拼图数据质量和业务应用能力。

1 数据集构建

语义分割的性能在很大程度上依赖于大量、多样且标注准确的图像数据集。构建此类数据集是一项劳动密集型任务,而且标注的质量会直接影响模型的性能。然而,在深度学习语义分割领域,公开的雷达拼图异常回波训练数据集非常匮乏,这也阻碍了准确分割模型的开发。鉴于此,本文基于湖北省

雷达拼图数据构建了异常回波图像分割数据集(WRAED)。该数据集的原始数据来自湖北省气象台业务运行的灾害性天气短时临近预报业务系统(SWAN)生成的组合反射率因子拼图产品。其中,拼图产品源自湖北省9部S波段新一代天气雷达(图1),格点水平分辨率为1 km,时间分辨率为6 min。数据集时间范围为2019—2021年6—9月,涵盖连续三年湖北省主汛期不同天气系统演变下的雷达异常回波特征。

基于收集的SWAN雷达拼图数据,批量绘制雷达组合反射率图像,以此构建VOC格式的雷达拼图回波图像数据集。图2为WRAED的具体流程。首先,从2019—2021年6—9月共77 509张雷达拼图回波图像(即原始图像)中人工筛选出包含异常回波的图像(图3);其中,共有1002张仅含径向异常回波的图像,157张仅含环状异常回波的图像,59张同时包含径向和环状异常回波的图像。

然后,基于Labelme图像标注软件的多边形工具,将上述筛选出的异常回波图像进行标签标注(即人工标签),生成JSON格式的标记数据文件;再使用Python Image Library工具将JSON格式的标记数据文件转换为掩码标注图像(图4)。




图1 湖北省9部S波段天气雷达分布

Fig. 1 Distribution of nine S-band weather radars in Hubei Province




图2 WRAED 流程图

Fig. 2 Workflow of WRAED construction




图 3 (a)径向,(b)环状,(c)径向和环状共存的异常回波图像
Fig. 3 Images of abnormal radar echoes of (a) radial, (b) circular and (c) mixed radial and circular




图 4 (a)异常回波图像及其(b)掩码标注图像
Fig. 4 (a) Abnormal radar echo images and (b) their mask annotation images

由此可知,虽然原始图像有 77 509 张,但最终筛选出来的异常回波图像仅有 1218 张,数据集规模较小且数据分布不均衡,这将会导致训练模型出现严重过拟合现象,泛化能力显著下降。为解决上述问题,康澜和苏志金(2024)提出了图像数据增强技术。这是一种在机器学习、深度学习等领域广泛应用的数据处理技术,旨在通过对现有数据进行一系列变换操作,有效扩充数据集的规模和多样性,同时又能保持数据原本蕴含的关键信息及标签不变,进而提升模型的性能与泛化能力。

图像数据增强方法非常多,有基于单样本图像数据增强方法(如几何变换、颜色变换),有基于多样本图像数据增强方法(如 SMOTE、SamplePairing 和 Mixup 等),还有基于生成对抗网络数据生成的

数据增强。本文主要采用基本的几何变换类数据增强以增加样本的多样性,具体包括:翻转、旋转、缩放及裁剪。翻转包含水平翻转、垂直翻转等;旋转则按照一定角度对图像进行旋转操作;缩放可对图像进行放大或缩小操作;裁剪则通过裁剪出图像的局部区域,改变图像的构图,可使模型学习到物体的局部特征。

综上,将可视化标注图像以及原始图像分别进行旋转、翻转、缩放等操作,得到雷达拼图回波图像扩充增强数据集;同时,进行训练集和验证集的划分,获得雷达拼图异常回波训练数据集。由此,经过数据增强后,数据集共包含 20 000 张图像,图像大小为 1100 像素×800 像素,涵盖了径向和环状两类异常回波。其中,80%的图像被划分为训练数据集,

用于模型的训练阶段;20%的图像则被划分为验证数据集,以便对训练得到的模型进行验证和评估。

表1所示为WRAED中训练数据集和验证数据集的异常回波分布情况。

表1 WRAED异常回波分布(单位:张)

Table 1 Distribution of abnormal radar echoes in the WRAED dataset (unit: sheet)			
数据集	径向异常回波	环状异常回波	径向+环状异常回波
训练数据集	7198	7202	1600
验证数据集	1801	1799	400

2 DeepLab-ARER 模型

本文以DeepLabV3+模型为基础,采用简化后的ResNet50(He et al, 2016; Fakhfakh et al, 2020)为主干网络,构建了面向雷达拼图异常回波精准识别的DeepLab-ARER模型,模型的基本结构如图5所示。其中,DeepLabV3+是谷歌公司开发的基于编码器-解码器结构的语义分割网络,其采用了针对语义分割任务进行适配改进的Xception主干网络,可实现高效的特征提取。

2.1 主干网络和特征提取

郑凯等(2020)提出了一种结合ResNet和DeepLabV3+的全卷积神经网络云、雪检测方法。该方法采用ResNet50主干网络,并根据云和雪在卫星遥感影像上的特点优化DeepLabV3+网络模型,从而得到比传统方法更高的检测精度和更好的稳健性。吴安坤等(2024)基于DeepLabV3+开展气象卫星影像雷暴识别研究时发现,主干网络采用ResNet101的分割性能最好,ResNet50次之。为此,DeepLab-ARER模型采用简化的ResNet50(删除了ResNet50的第四模块)作为主干网络进行特征提取。经评估,使用深度较小的主干模型对WRAED具有更好的分割效果。

此外,输出步幅表示输入图像空间分辨率与最终输出分辨率(最后一个特征层)的比率。对于图像语义分割任务,输出步幅通常取8或16。有研究表明,16是速度和精度之间的最佳折衷(Chen et al, 2018),故本文将输出步幅设为16。

2.2 编码器

DeepLab-ARER模型的编码器路径与DeepLabV3+相同。通过空洞空间金字塔池化(ASPP)模块从主干提取的深层特征(Chen et al, 2017),结合不同膨胀率的空洞深度可分离卷积来捕获多尺度

信息。ASPP模块包括一个 1×1 卷积、三个核大小为 3×3 的卷积(膨胀率分别为6、12、18)和平均池化的图像级特征。如图5所示,将五个分支提取的特征进行拼接并输入到 1×1 卷积层中。与DeepLabV3+类似,本模型在编码器和解码器路径中使用空洞深度可分离卷积代替传统的 3×3 卷积。这项技术将标准卷积分解为深度卷积和点卷积(即 1×1 卷积),在保持性能的同时大大降低了计算复杂度。

2.3 解码器

DeepLabV3+的解码器首先从编码器主干提取的浅层特征(见图5中的低层)经过 1×1 卷积以减少通道数量。然后,将这些减少后的特征与编码器输出拼接,其中编码器输出进行了4倍双线性上采样。使用 3×3 空洞深度可分离卷积层进一步细化拼接后的特征。接下来,再次进行4倍双线性上采样。最后,应用 1×1 卷积来生成分割结果,其中卷积核的数量与类别的数量匹配。

在雷达拼图异常回波识别任务中,径向异常回波通常表现为细长条带状结构,环状异常回波则具有较明显的闭合或半闭合边界。这类目标对空间细节和边界信息较为敏感。如果采用DeepLabV3+原有的特征融合方式,部分中尺度结构信息可能在编码器连续下采样的过程中被削弱。为此,本文在DeepLab-ARER模型的解码器主干中增加了特征提取的中层(图5)。中层先经过 1×1 卷积处理,再通过2倍双线性上采样,以匹配其他缩减特征层的大小。最后,将其与模型其他分支的特征进行拼接。通过中层的特征提取,可以将一些可能在编码器路径中丢失的通用特征引入解码器,从而增强异常回波区域的分割完整性。

2.4 注意力模块

注意力机制通过为不同区域分配不同的权重,允许模型关注输入的相关部分(Guo et al, 2022)。已




图 5 DeepLab-ARER 模型网络结构

Fig. 5 Architecture of DeepLab-ARER network

有研究表明,在 DeepLabV3+或其他分割网络中引入注意力模块,有助于改善复杂背景下的目标分割效果(Azad et al, 2020; Zeng et al, 2020; Jia et al, 2023)。其中,廖艺齐(2023)针对海雾分割任务优化了 DeepLabV3+,在主干网络中引入 ECA 模块,在 ASPP 模块后加入卷积模块注意力机制(CBAM),提高了海雾分割精度。吴安坤等(2024)分别在深、低层级特征融合和分割预测之前加入 CBAM,改善了 DeepLabV3+对雷暴活动的识别精度。贾军营等(2025)引入极化自注意力机制来改进 DeepLabV3+,有效提升了暴雨过程的道路积水检测性能。如图 5 所示,DeepLab-ARER 模型在每个特征提取层之后添加简单注意力机制 SimAM(Yang et al, 2021)。SimAM 是一个轻量级的注意力机制,不引入额外的参数,直接估算三维权重,而不是像其他空间和通道注意力机制那样扩展一维或二维权重。将 SimAM 分别加入浅层、中层和深层特征提取之后,模型可以在不同语义层级上增强对异常回波相关特征的关注,提高了 DeepLab-ARER 对径向和环状异常回波的特征分割能力。

2.5 损失函数

本文所提出 DeepLab-ARER 语义分割模型实现对径向、环状异常雷达回波及背景的识别,本质上是图像像素级别的三分类问题,所以采用标准的交

叉熵作为损失函数。交叉熵损失函数定义如下:

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \ln(p_{i,c}) \quad (1)$$

式中: N 为一张雷达回波图像像素的总数; C 为类别数量,此处为 3; $y_{i,c}$ 表示第 i 个像素点在第 c 个类别上的 one-hot 编码的真实语义标签, $p_{i,c}$ 表示 DeepLab-ARER 模型预测的第 i 个像素点属于第 c 个类别的概率。

通过在输出层添加 Softmax 函数将 DeepLab-ARER 模型输出值映射到 $[0, 1]$ 区间且满足输出值之和为 1。Softmax 函数的定义如下:

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (2)$$

式中: x_i 为向量的第 i 个元素, n 为向量的维度。为了数值计算的稳定性,在深度学习框架中同时实现了 Softmax 函数与交叉熵损失函数,避免分开使用带来的数值溢出等异常现象。

3 模型评估

3.1 评估方法

为进一步评估模型分割效果,基于构建的雷达拼图异常回波分割数据集(WRAED),对 DeepLab-

ARER 模型与其他主流的 CNN 语义图像分割基准模型,如 DeepLabV3+ (Chen et al, 2018)、FCN (Long et al, 2015)、ResUnet (Zhang et al, 2018) 与 UNet (Ronneberger et al, 2015) 进行性能对比。其中,考虑到 DeepLab-ARER 模型是基于 DeepLabV3+ 改进而来,因此将其与采用 Xception、ResNet50 及 ResNet101 三种不同主干网络的 DeepLabV3+ 进行同步对比。

3.2 评估指标

DeepLab-ARER 模型不仅需要判断异常回波像素级类别,还需要尽可能准确地给出异常回波的空间范围。因此,本文在评价模型时同时考虑像素分类精度和区域重合程度,选用像素准确率(PA)、平均像素准确率(mPA)、交并比(IoU)和平均交并比(mIoU)作为主要评价指标。为进一步分析模型对各类回波的识别能力,借鉴气象检验中常用的三个辅助指标:命中率(POD)、误报率(FAR)与偏差(Bias)。

3.2.1 PA 与 mPA

PA 用于统计预测结果中被正确分类的像素占全部像素的比例。对于雷达拼图异常回波识别任务而言,PA 可以反映模型在整幅图像上的总体像素分类情况,其计算公式为:

$$PA = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

式中:TP、TN、FP、FN 分别是某类异常回波的真实例、真负例、假正例、假负例像素的总数。真正例像素表示已正确预测给定类别的像素,真负例像素表示已正确识别非给定类别的像素,假正例像素表示错误预测为给定类别的像素,假负例像素表示错误预测非给定类别的像素。

mPA 定义为每个类别正确预测像素与该类别真实像素总数比值的平均值,类似于平均召回率。与 PA 相比,mPA 能够减弱样本类别像素数量差异对评价结果的影响,更适合用于分析模型对背景和异常回波等不同类别的识别能力。其计算公式为:

$$mPA = \frac{1}{N} \sum_{i=1}^N \frac{TP}{TP + FN} \quad (4)$$

式中: N 为异常回波的类别总数(含背景类),取值为 3。

3.2.2 IoU 与 mIoU

IoU 用于衡量某一类别预测区域与真实标注区

域之间的重合程度。该指标不仅考虑正确预测的像素数量,也同时受到漏分和误分像素的影响,因此能够较好地反映异常回波区域的空间匹配程度。其计算公式为:

$$IoU = \frac{TP}{TP + FP + FN} \quad (5)$$

mIoU 则是计算所有类别 IoU 的平均值,用于评价模型在多类别像素分割任务中的整体表现。

上述指标经过归一化,取值范围均为 $[0, 1]$,其中 0 表示性能不佳,取值越接近 1 则表示性能越好。

3.3 试验环境与参数设置

本文试验在配备 NVIDIA GeForce GTX 1080 Ti GPU 的计算节点上进行,模型构建与训练基于 PyTorch 深度学习框架完成。训练阶段输入图像尺寸为 1100 像素 $\times$ 800 像素,优化器采用 Adam,损失函数选用多类别交叉熵损失。主要训练参数设置如下:初始学习率为 0.007,批量大小为 100。训练过程中使用 GPU 加速模型计算,并保存每轮训练的损失值和验证集评价指标。

3.4 评估结果

3.4.1 DeepLab-ARER 性能分析

使用简化 ResNet50 主干的 DeepLabV3+ 为基准模型,通过在基准模型的不同位置交替或同时添加简单注意力机制和中层进行对比试验,评估 DeepLab-ARER 模型性能。表 2 显示,当只加入 SimAM,mPA 提高了 1.50 个百分点,mIoU 提高了 1.67 个百分点;当只加入中层,mPA 提高了 1.61 个百分点,mIoU 提高了 4.71 个百分点;当 SimAM 和中层同时加入时,mPA 提高了 5.88 个百分点,mIoU 提高了 9.49 个百分点。在所有模型变体中,同时引入 SimAM 注意力机制和中层的 DeepLab-ARER 表现最好,mPA 和 mIoU 分别达到 96.75% 和 93.95%。这一结果说明,中层主要增强了模型对异常回波空间结构的表达能力,而 SimAM 注意力机制能够在特征提取过程中更加关注异常回波特征。二者结合后,模型对异常回波区域的识别能力进一步提高。从类别识别角度来看,DeepLab-ARER 模型表现最优,对两类异常回波的识别均取得最高的 POD 和最低的 FAR,Bias 也更加接近 1。值得注意的是,在所有模型变体中,环状异常回波的识别性能始终优于径向异常回波,表现出更高的 POD 与更低的 FAR,这也反映出其形态结构更易于被模型捕捉与识别。

表 2 基于 WRAED 的消融试验结果

Table 2 Results of ablation experiments based on WRAED dataset

模型架构	mIoU/%	mPA/%	径向异常回波			环状异常回波		
			POD	FAR	Bias	POD	FAR	Bias
基准模型	84.46	90.87	0.85	0.11	0.955	0.87	0.10	0.967
基准模型+SimAM	86.13	92.37	0.88	0.09	0.967	0.90	0.08	0.978
基准模型+中层	89.17	92.48	0.89	0.07	0.957	0.90	0.05	0.947
DeepLab-ARER 模型	93.95	96.75	0.93	0.06	0.989	0.95	0.03	0.979

3.4.2 不同注意力机制对比

本评估试验中,基于 DeepLab-ARER 模型测试了不同注意力机制,如简单注意力(SimAM; Yang et al, 2021)、挤压和激励(SE; Hu et al, 2018)、卷积块注意力(CBAM; Woo et al, 2018)、瓶颈注意力(BAM; Park et al, 2018)、高效通道注意力(ECA; Wang et al, 2020)、三重注意力(TripletAtt; Misra et al, 2021)和协调注意力(CoordAtt; Hou et al, 2021)的性能,结果见表 3。从整体分割指标看,采用 SimAM 的模型 mIoU 为 93.95%,采用 SE 的模型 mIoU 为 93.08%,相对于基准模型性能提升明显。SE 模块虽性能接近,但引入较多的额外参数,而 SimAM 无参数设计使其成为所有方案中的最优选择。从类别识别结果看,SimAM 在径向与环状异常回波识别表现较好,其径向异常回波 POD 为 0.93, FAR 为 0.06;环状异常回波 POD 为 0.95, FAR 为 0.03,说明模型在保持较高命中率的同时,误报率相对较低。对应的 Bias 分别为 0.989 和 0.979,非常接近 1,表明预测结果与真实样本数量之间的偏差较小。相比之下,ECA、CoordAtt 等对环状异常回波的 POD 为 0.96,略高于 SimAM,但其 FAR 也有所增加且 Bias 大于 1,说明在提高命中率的同时可能引入了更多误检像素,存在一定过检倾向。因此,本文最终选用 SimAM 作为 DeepLab-ARER 的注意力模块。

3.4.3 与不同图像分割模型的对比

进一步对比不同图像分割模型,如:DeepLabV3+ (Chen et al, 2018)、FCN (Long et al, 2015)、Res-

UNet (Zhang et al, 2018) 与 UNet (Ronneberger et al, 2015)在 WRAED 数据集上的性能表现。其中,DeepLabV3+ 包括了不同的主干网络(Xception、ResNet101 和 ResNet50),且各模型均以输出步幅为 16 进行构建。图 6 给出了表现较好的几个分割模型识别结果对比。从图中可直观看出,DeepLab-ARER 模型识别结果轮廓清晰,范围合理,更加接近真实的异常回波,其整体效果最优。

表 4 为不同模型识别性能的定量评估结果。从整体性能来看,DeepLab-ARER 在 mIoU(93.95%)和 mPA(96.75%)两项核心分割指标上均优于所有对比模型;同时,其参数量(10.41×10^6)也显著低于大多数模型,仅为标准 DeepLabV3+(ResNet50 主干网络)的约 37.30%,但 mIoU 提升了 6.32 个百分点。尽管其每秒浮点运算次数(FLOPS)(1465.92×10^6)略高于部分模型,但仍处于合理范围,表现出良好的计算效率。在类别识别能力上,DeepLab-ARER 在径向异常回波识别方面表现良好(POD=0.93、FAR=0.06、Bias=0.989),在环状异常回波识别上则更加优异(POD=0.95、FAR=0.03、Bias=0.979),且两者均为所有模型中最优或接近最优。相比之下,其他模型虽在某些单项指标上表现尚可,但均未能在整体精度、效率和类别识别稳定性上实现全面优势。例如,FCN-8(ResNet50 主干网络)识别环状异常回波的 POD 略高(0.96),但其参数量高达 451.51×10^6 ,推理开销巨大;而 Res-UNet 的参数量虽然最少(8.23×10^6),但其各项识别指标都显著偏低。

表 3 基于 WRAED 的不同注意力机制下模型试验结果

Table 3 Performance comparison of attention mechanisms based on WRAED dataset

注意力机制	mIoU/%	mPA/%	新增参数/个	径向异常回波			环状异常回波		
				POD	FAR	Bias	POD	FAR	Bias
ECA	91.35	96.07	2100	0.91	0.07	0.978	0.96	0.06	1.021
CoordAtt	91.16	96.11	900	0.92	0.09	1.011	0.96	0.07	1.032
TripletAtt	90.95	96.16	11800	0.92	0.10	1.022	0.96	0.08	1.043
SE	93.08	96.55	11200	0.93	0.06	0.989	0.95	0.04	0.990
BAM	92.53	96.31	33200	0.93	0.09	1.022	0.94	0.07	1.011
CBAM	89.54	95.39	11500	0.92	0.11	1.034	0.94	0.09	1.033




图 6 雷达拼图原始图像与不同模型对各类异常回波的识别结果

Fig. 6 The original radar mosaic images and the recognition results of various abnormal echoes by different models

表 4 基于 WRAED 的不同模型性能对比结果

Table 4 Results of performance comparison of different models based on WRAED dataset

模型	主干网络	mIoU/%	mPA/%	参数量/ 10^6	FLOPS/ 10^6	径向异常回波			环状异常回波		
						POD	FAR	Bias	POD	FAR	Bias
DeepLabV3+	ResNet50	87.63	95.01	27.91	1397.47	0.91	0.07	0.978	0.94	0.04	0.979
DeepLabV3+	ResNet101	80.32	92.76	46.98	1785.36	0.86	0.12	0.977	0.93	0.11	1.045
DeepLabV3+	Xception	86.90	94.55	42.19	755.45	0.88	0.09	0.967	0.95	0.04	0.990
UNet	VGG16	78.49	94.14	25.86	4372.14	0.89	0.14	1.035	0.93	0.08	1.011
FCN-8	ResNet50	90.63	95.95	451.51	2756.86	0.91	0.11	1.023	0.96	0.07	1.032
FCN-8	VGG16	77.93	91.29	134.35	790.44	0.83	0.12	0.943	0.91	0.08	0.989
ResUNet	—	72.54	91.51	8.23	3621.53	0.84	0.13	0.966	0.89	0.09	0.978
DeepLab-ARER	ResNet50	93.95	96.75	10.41	1465.92	0.93	0.06	0.989	0.95	0.03	0.979

注:“—”表示 ResUNet 未使用特征提取标准主干构建模型。

3.4.4 DeepLab-ARER 模型类别识别性能分析

环状异常回波的 IoU 为 95.27%, PA 为 97.00%; 径向异常回波的 IoU 为 88.13%, PA 为

93.00%(表略)。IoU 差异表明,模型对环状异常回波区域的预测与人工标注结果重合度更高,而对径向异常回波在边界和局部细节处仍存在一定偏差。

环状异常回波的 POD 为 0.95, FAR 为 0.03, 径向异常回波的 POD 为 0.93, FAR 为 0.06(表 4), 说明模型对环状异常回波的漏检和误检相对较少。DeepLab-ARER 模型对环状异常回波的识别优于径向异常回波, 这主要与回波的空间形态有关。环状异常回波多呈闭合或半闭合结构, 边界连续性较强, 且主体区域相对集中, 模型较容易学习其形态特征。径向异常回波通常表现为沿雷达径向延伸的条带状结构, 宽度较窄, 空间跨度较大, 在有降水回波覆盖时容易发生混合。两类异常回波的 Bias 分别为 0.989 和 0.979, 均接近 1, 说明模型总体上没有明显的过检或漏检倾向。

3.4.5 实例分析

利用雷达拼图实例数据分析 DeepLab-ARER 模型的识别效果。图 7a 为 2020 年 8 月 8 日 04:54 (世界时, 下同) 的雷达拼图原始图像与异常回波识别结果。从图 7a₁ 可以看出, 在图右下方出现了明显的异常回波, 整体呈现多层环状分布特征, 强度跨度较大, 数值在 20~65 dBz。这种异常回波会导致出现大面积的虚假回波及强降水的误判。图 7a₂ 则为异常回波识别结果, 从图中可以清晰地看到, 异常回波的完整轮廓得到了有效识别。

图 7b 为 2020 年 7 月 7 日 18:42 的雷达拼图原始图像与异常回波识别结果。由图 7b₁ 可以清楚地看到, 图中部出现了多条径向异常回波, 且异常回波主要表现为连续的或断续的径向辐散分布特征, 回波强度集中在 20~40 dBz。这种异常回波使得雷达拼图在多个径向方向上出现虚假回波。从图 7b₂ 的异常回波识别结果可以明显看出, 多个径向异常回波都被完整识别, 识别效果良好。

图 7c 为 2021 年 7 月 15 日 06:18 的雷达拼图原始图像与异常回波识别结果。由图 7c₁ 可以看到近似半圆状的环状异常回波, 且同时存在一条径向异常回波, 回波强度集中在 20~40 dBz。对于这种环状和径向共存的异常回波, 一般的算法难以同时有效识别。从图 7c₂ 的异常回波识别结果可以明显看出, 环状和径向异常回波被同时且完整地识别。

然而, DeepLab-ARER 模型同样存在误识别的情况。图 7d 为 2021 年 6 月 1 日 11:00 的雷达拼图原始图像与模型错误识别结果。导致错误识别的主要原因有数据标注错误和相似特征易造成混淆。训练数据集的标注不可能绝对完美, 存在标注错误(标

错类别、边界不精确、遗漏小物体)时, 模型会学习到这些错误模式。不同类别回波在颜色、纹理、形状上可能非常相似, 模型依赖的特征不足以可靠地区分它们, 导致产生误识别。环状回波特征清晰, 不易误识别; 径向回波复杂多变, 部分径向回波特征与降水回波外观相似, 从而导致模型识别错误。


4 结论与讨论

面向雷达拼图数据业务应用中异常回波识别的实际问题和客观需求, 本文开展了基于计算机视觉领域语义分割技术的雷达拼图异常回波识别模型的构建与改进, 得到如下结论:

(1) 针对公开的分割数据集稀缺的问题, 本文利用湖北雷达拼图数据构建了雷达拼图异常回波图像分割数据集(WRAED)。该数据集为分割模型的训练与评估奠定良好的数据基础, 可作为雷达异常回波自动识别与评估研究的有益资源。

(2) 基于经典的 DeepLabV3+ 模型, 通过使用简化的 ResNet50 作为主干网络使其具有更少参数和轻量化的特点, 在主干特征提取后引入简单注意力机制 SimAM, 并在解码器路径中结合新的中层, 构建了面向天气雷达拼图异常回波识别的 DeepLab-ARER 模型。经 WRAED 评估, 在雷达异常回波的图像分割方面优于部分主流的 CNN 语义分割基准模型, 其 mIoU 和 mPA 分别达 93.95% 和 96.75%。此外, 与具有相同主干网络的 DeepLabV3+ 相比, DeepLab-ARER 的 mIoU 提高了 6.32 个百分点, 而参数量却减少了约 62.70%。雷达拼图实例数据评估结果表明, DeepLab-ARER 模型能有效识别出环状和径向两类异常回波, 整体效果较好。

尽管 DeepLab-ARER 在 WRAED 上取得了较好的分割结果, 但本文工作仍存在一定不足。WRAED 主要来自湖北区域雷达拼图资料, 异常回波样本的区域代表性和类型丰富度有待扩展。DeepLab-ARER 模型仍以 CNN 卷积结构为主要特征提取方式, 对大范围雷达拼图中的全局空间关系理解不够充分。径向异常回波因形态细长、边界变化大、易与正常降水回波重叠, 仍然较难识别。为此, 未来将进一步扩展 WRAED 的样本数量, 并探索使用 Transformer 或 CNN-Transformer 混合架构方法以获得更优的识别效果。



注:图 d 中椭圆为误识别的范围。

图 7 (a_1, b_1, c_1, d_1) 雷达拼图原始图像与 (a_2, b_2, c_2, d_2) DeepLab-ARER 模型异常回波识别结果
(a) 2020 年 8 月 8 日 04:54, (b) 2020 年 7 月 7 日 18:42, (c) 2021 年 7 月 15 日 06:18, (d) 2021 年 6 月 1 日 11:00

Fig. 7 (a_1, b_1, c_1, d_1) The original radar mosaic images and (a_2, b_2, c_2, d_2) the abnormal echo recognition results of DeepLab-ARER model

(a) 04:54 UTC 8 August 2020, (b) 18:42 UTC 7 July 2020, (c) 06:18 UTC 15 July 2021, (d) 11:00 UTC 1 June 2021

参考文献

- 陈鹤,蔡荣辉,陈静静,等,2022. 基于深度学习方法的气温预报技术应用与评估[J]. 气象,48(11):1373-1383. Chen H, Cai R H, Chen J J, et al, 2022. Application and evaluation of temperature forecast based on deep learning method[J]. Meteor Mon, 48(11):1373-1383(in Chinese).
- 何建新,王旭,刘艳,2010. 自适应高斯频域滤波器在天气雷达中的应用[J]. 气象,36(6):117-121. He J X, Wang X, Liu Y, 2010. Application of adaptive Gaussian frequency filter to weather radar[J]. Meteor Mon, 36(6):117-121(in Chinese).
- 贾军营,吴兴宇,杨海波,2025. 基于改进 DeepLabv3+ 的道路积水检测[J]. 计算机系统应用,34(4):175-183. Jia J Y, Wu X Y, Yang H B, 2025. Road water accumulation detection based on improved DeepLabv3+[J]. Comput Syst Appl, 34(4):175-183(in Chinese).
- 康澜,苏志金,2024. 图像数据增强技术原理与发展综述[J]. 信息技术, (9):176-185. Kang L, Su Z J, 2024. Principle and prospect of image data enhancement technology[J]. Inform Technol, (9):176-185(in Chinese).
- 邱辉宇,吴俊君,2019. 基于深度学习的图像语义分割技术研究综述[J]. 计算机工程与应用,55(19):12-21,42. Kuang H Y, Wu J J, 2019. Survey of image semantic segmentation based on deep learning[J]. Comput Eng Appl, 55(19):12-21,42(in Chinese).
- 廖艺齐,2023. 结合注意力机制与 Deeplabv3+ 的海雾分割模型[D]. 南昌:南昌大学. Liao Y Q, 2023. Daytime sea fog recognition by combining attention mechanism with Deeplabv3+ [D]. Nanchang: Nanchang University(in Chinese).
- 刘昉,李奇临,蒋涌,等,2021. 基于 CNN 的天气雷达异常回波图像识别算法研究[J]. 电子设计工程,29(6):74-78,87. Liu F, Li Q L, Jiang Y, et al, 2021. Study on recognition algorithm of abnormal radar echo image based on CNN[J]. Electron Design Eng, 29(6):74-78,87(in Chinese).
- 钱奇峰,王川,徐雅静,等,2021. 一种基于深度学习的台风强度估测技术[J]. 气象,47(5):601-608. Qian Q F, Wang C, Xu Y J, et al, 2021. A deep learning technique of typhoon intensity estimation[J]. Meteor Mon, 47(5):601-608(in Chinese).
- 邵楠,裴翀,刘传才,等,2013. 基于图像处理技术自动判别雷达异常产品[J]. 气象科技,41(6):993-997. Shao N, Pei C, Liu C C, et al, 2013. Automatic identification system of abnormal radar echoes based on image processing technology[J]. Meteor Sci Technol, 41(6):993-997(in Chinese).
- 王关茗,胡乃平,2023. 基于深度学习的自然灾害遥感影像语义分割[J]. 计算机系统应用,32(2):322-328. Wang G M, Hu N P, 2023. Semantic segmentation of natural disaster remote sensing image based on deep learning[J]. Comput Syst Appl, 32(2):322-328(in Chinese).
- 吴安坤,郭军成,王强,等,2024. 基于改进 DeepLabv3+ 网络的气象卫星影像雷暴识别[J]. 气象科技,52(6):775-786. Wu A K, Guo J C, Wang Q, et al, 2024. Thunderstorm identification in meteorological satellite images based on an improved DeepLabv3+ network[J]. Meteor Sci Technol, 52(6):775-786(in Chinese).
- 谢千里,2020. 基于基数据的天气雷达异常回波识别[J]. 信息与电脑,32(15):63-66. Xie Q L, 2020. Abnormal echo recognition of weather radar based on raw data[J]. China Comput Commun, 32(15):63-66(in Chinese).
- 袁凯,李武阶,李明,等,2022. 四种机器深度学习算法对武汉地区雷达回波临近预报的检验和评估[J]. 气象,48(4):428-441. Yuan K, Li W J, Li M, et al, 2022. Examination and evaluation of four machine deep learning algorithms for radar echo nowcasting in Wuhan Region[J]. Meteor Mon, 48(4):428-441(in Chinese).
- 曾小团,谭肇,沈玉伟,等,2025. CastNet:深度学习定量降水临近预报模型[J]. 气象,51(4):400-416. Zeng X T, Tan Z, Shen Y W, et al, 2025. CastNet: deep-learning-based model for quantitative precipitation nowcasting[J]. Meteor Mon, 51(4):400-416(in Chinese).
- 张林,吴蕾,李峰,等,2023. 基于深度学习的天气雷达异常数据识别技术[J]. 应用气象学报,34(6):694-705. Zhang L, Wu L, Li F, et al, 2023. Identification of weather radar abnormal data based on deep learning[J]. J Appl Meteor Sci, 34(6):694-705(in Chinese).
- 张雪,贾克斌,刘钧,等,2023. 基于多任务学习的地基云图识别与分割技术[J]. 气象,49(4):454-466. Zhang X, Jia K B, Liu J, et al, 2023. Ground cloud image recognition and segmentation technology based on multi-task learning[J]. Meteor Mon, 49(4):454-466(in Chinese).
- 赵瑞金,刘黎平,张进,2015. 硬件故障导致雷达回波错误数据质量控制方法[J]. 应用气象学报,26(5):578-589. Zhao R J, Liu L P, Zhang J, 2015. The quality control method of erroneous radar echo data generated by hardware fault[J]. J Appl Meteor Sci, 26(5):578-589(in Chinese).
- 赵悦,陈家华,章建军,等,2007. 基于中值滤波和小波变换的天气雷达回波图像处理[J]. 气象科学,27(1):63-68. Zhao Y, Chen J H, Zhang J J, et al, 2007. Weather radar echo image processing based on median filter and wavelet transform[J]. Sci Meteor Sin, 27(1):63-68(in Chinese).
- 郑凯,李建胜,杨骥峰,等,2020. 天绘一号卫星遥感影像云雪检测的 ResNet 与 DeepLabV3+ 综合法[J]. 测绘学报,49(10):1343-1353. Zheng K, Li J S, Yang J F, et al, 2020. A cloud and snow detection method of TH-1 image based on combined ResNet and DeepLabV3+[J]. Acta Geod Cartogr Sin, 49(10):1343-1353(in Chinese).
- 周红根,柴秀梅,胡帆,等,2008. 新一代天气雷达回波异常情况分析[J]. 气象,34(6):112-115. Zhou H G, Chai X M, Hu F, et al, 2008. Analysis of abnormal echoes of new generation weather radar[J]. Meteor Mon, 34(6):112-115(in Chinese).
- Azad R, Asadi-Aghbolaghi M, Fathy M, et al, 2020. Attention DeepLabv3+: multi-level context attention mechanism for skin lesion segmentation[M] // Computer Vision - ECCV 2020 Workshops. Glasgow, UK: Springer.
- Chen L C, Papandreou G, Schroff F, et al, 2017. Rethinking atrous convolution for semantic image segmentation[PP/OL]. arXiv.

- <https://arxiv.org/abs/1706.05587>.
- Chen L C, Zhu Y K, Papandreou G, et al, 2018. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]//15th European Conference on Computer Vision (ECCV). Munich, Germany: Springer; 801-818.
- Fakhfakh M, Bouaziz B, Gargouri F, et al, 2020. ProgNet: COVID-19 prognosis using recurrent and convolutional neural networks [J]. *Open Med Imaging J*, 12(1): 11-12.
- Guo M H, Xu T X, Liu J J, et al, 2022. Attention mechanisms in computer vision: a survey [J]. *Comput Vis Media*, 8(3): 331-368.
- Haddad B, Adane A, Sauvageot H, et al, 2004. Identification and filtering of rainfall and ground radar echoes using textural features [J]. *Int J Remote Sens*, 25(21): 4641-4656.
- He K M, Zhang X Y, Ren S Q, et al, 2016. Deep residual learning for image recognition [C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA; IEEE: 770-778.
- Hou Q B, Zhou D Q, Feng J S, et al, 2021. Coordinate attention for efficient mobile network design [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, TN, USA; IEEE: 13708-13717.
- Hu J, Shen L, Sun G, 2018. Squeeze-and-excitation networks [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA; IEEE: 7132-7141.
- Jia J T, Song J R, Kong Q Q, et al, 2023. Multi-attention-based semantic segmentation network for land cover remote sensing images [J]. *Electronics*, 12(6): 1347.
- Long J, Shelhamer E, Darrell T, 2015. Fully convolutional networks for semantic segmentation [C]//IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA; IEEE: 3431-3440.
- Misra D, Nalamada T, Arasanipalai A U, et al, 2021. Rotate to attend: convolutional triplet attention module [C]//IEEE Winter Conference on Applications of Computer Vision. Waikoloa, HI, USA; IEEE: 3138-3147.
- Park J, Woo S, Lee J Y, et al, 2018. BAM: Bottleneck attention module [PP/OL]. arXiv: 1807. 06514. <https://arxiv.org/abs/1807.06514>.
- Razavian A S, Azizpour H, Sullivan J, et al, 2014. CNN features off-the-shelf: an astounding baseline for recognition [C]//IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA; IEEE: 512-519.
- Ronneberger O, Fischer P, Brox T, 2015. U-Net: convolutional networks for biomedical image segmentation [C]//18th International Conference on Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Munich, Germany; Springer.
- Sadouki L, Haddad B, 2013. Classification of radar echoes with a textural-fuzzy approach: an application for the removal of ground clutter observed in Sétif (Algeria) and Bordeaux (France) sites [J]. *Int J Remote Sens*, 34(21): 7447-7463.
- Wang Q L, Wu B G, Zhu P F, et al, 2020. ECA-Net: efficient channel attention for deep convolutional neural networks [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA; IEEE: 11531-11539.
- Woo S, Park J, Lee J Y, et al, 2018. CBAM: convolutional block attention module [C]//15th European Conference on Computer Vision (ECCV). Munich, Germany; Springer: 3-19.
- Yang L, Wang Y, Wang Z K, et al, 2020. A new method based on stacked auto-encoders to identify abnormal weather radar echo images [J]. *J Wireless Commun Netw*, 2020(1): 177.
- Yang L X, Zhang R Y, Li L D, et al, 2021. SimAM: a simple, parameter-free attention module for convolutional neural networks [C]//Proceedings of the 38th International Conference on Machine Learning. PMLR 139: 11863-11874.
- Zeng H B, Peng S Q, Li D X, 2020. DeepLabv3+ semantic segmentation model based on feature cross attention mechanism [J]. *J Phys Conf Ser*, 1678(1): 012106.
- Zhang Z X, Liu Q J, Wang Y H, 2018. Road extraction by deep residual U-Net [J]. *IEEE Geosci Remote Sens Lett*, 15(5): 749-753.

(本文责编:王婷波)