

# 基于语义分割的雷达拼图径向和环状异常回波识别方法研究\*

曹华<sup>1,2,3</sup> 杜牧云<sup>1,2</sup> 胡嘉芬<sup>4</sup> 姚曼<sup>4</sup> 余蓉<sup>5</sup> 刘佩廷<sup>6</sup>

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

**摘要:** 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。本研究基于历史数据对径向与环状两类异常回波进行人工标记, 利用数据增强技术构建了包含 20000 张图像的雷达拼图异常回波数据集; 并针对先进的语义分割模型 DeepLabV3+ 进行优化, 主要包括: 主干网络采用参数更少的简化 ResNet50 结构; 为主干特征提取层引入 SimAM 简单注意力机制, 以关注重要特征; 在解码器路径中添加中间层, 通过合并中间层有效引入额外的细节和背景; 以此构建了雷达拼图异常回波识别模型 DeepLab-ARER。经试验评估, DeepLab-ARER 对两类异常回波均表现出较好的识别性能, 其平均像素准确率(mPA)为 96.75%, 平均交并比(mIoU)为 93.95%, 较原 DeepLabV3+ 均有明显提升。研究成果可为雷达拼图异常回波的自动识别提供有效技术支撑, 为雷达拼图数据在气象业务中的高质量应用奠定基础。

**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 DOI: 10.7519/j.issn.1000-0526.2026.052501

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

CAO Hua<sup>1,2,3</sup> DU Muyun<sup>1,2</sup> HU Jiafen<sup>4</sup> YAO Man<sup>4</sup> YU Rong<sup>5</sup> LIU Peiting<sup>6</sup>

\*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  
2025-06-17. . . . 2026-05-25. . . .

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@whhr.com.cn

27  
28  
29  
30  
31  
32  
33  
34  
35

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

36  
37  
38  
39  
40  
41  
42  
43  
44  
45  
46  
47  
48  
49  
50  
51  
52  
53

**Abstract:** During the prolonged operation of weather radar systems, equipment malfunctions and external interferences often cause abnormal radar echoes. These anomalies impair the radar's effectiveness in the monitoring, warning and forecasting of severe weather events. To address this problem, in this study, we manually labeled radial and circular types of abnormal echoes based on historical data, and used data augmentation techniques to construct a radar mosaic dataset of abnormal echoes consisting of 20,000 images. For the advanced semantic segmentation model DeepLabV3+, we introduced several optimizations, which include, firstly, a streamlined ResNet50 backbone with reduced parameters was adopted; secondly, the SimAM attention mechanism to enhance feature extraction and emphasize critical features was incorporated; and thirdly, intermediate layers were added into the decoder path to integrate additional details and contextual information through layer fusion. Consequently, the DeepLab-ARER model for recognizing abnormal radar echoes in radar mosaic data was developed. Experimental evaluations have demonstrated that DeepLab-ARER achieved superior performance in identifying both types of abnormal echoes, with a mean pixel accuracy (mPA) of 96.75% and a mean intersection-over-union (mIoU) of 93.95%, showing significant improvements over the original DeepLabV3+ model. These research achievements can provide robust technical solutions to the automatic recognition of abnormal echoes in radar mosaic data, laying a solid foundation for enhancing the quality of radar mosaic data in operational applications.

54

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

55

56

## 引言

57  
58  
59  
60  
61  
62  
63  
64  
65  
66  
67

雷达拼图数据是将区域内多部天气雷达相近时间点的观测数据拼接处理形成的覆盖整个区域的雷达回波数据。作为一种预报员高频次使用的数据资源，雷达拼图数据已成为提升灾害天气预警精准性和防御能力的重要支撑。然而，天气雷达是一套高度复杂的电子系统，其运行易受系统故障、模块异常以及外部环境干扰等多种因素的影响，从而在长时间业务运行中不可避免地产生错误数据（谢千里，2020）。虽然雷达数据质量控制技术已相对成熟，但尚无法剔除所有错误信息，雷达拼图数据中仍不时存在径向、环状等异常回波。径向干扰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）。环状或饼状异常回波主要由发射机/接收机故障引起的探测数据强度信息异常所致，在回波上表现为相邻体扫之间的回波强度、范围差异显著（赵瑞金等，2015）。这些异常回波不仅直接干扰预报员对天气系统的分析与判断，还显著削弱雷达数据的定量应用效果。对于气象业务人员而言，虽然异常回波的识别并非难事，但在海量雷

68 达拼图数据中逐一进行人工识别的工作量巨大、效率低，且难以满足数值模式同化系统、强  
69 对流天气自动识别系统等业务系统对数据质量和处理效率的要求。因此，实现雷达拼图数据  
70 中异常回波的自动有效识别，对于提高气象业务效率和数据质量具有重要现实意义。

71 当前，国内外学者在天气雷达异常回波的检测与识别方面已开展了广泛研究，其中许多  
72 研究倾向于采用经典的图像处理方法。例如，Haddad et al (2004) 利用雷达图像的纹理特  
73 征，通过计算灰度直方图或灰度和差的直方图来识别降水和地面回波。赵悦等 (2007) 提出  
74 了一种中值滤波与小波变换相结合的天气雷达回波图像处理方法，为自动识别回波种类提供  
75 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地物杂波进行识别  
76 与抑制。此外，邵楠等 (2013) 提出利用图像模式识别技术提取异常回波特征，并引入迭代  
77 学习器以自动判别异常回波。Sadouki and Haddad (2013) 则通过纹理图像分析中的灰度共  
78 生矩阵，有效区分降水回波与杂波。上述方法虽然取得了一定的识别效果，但算法复杂且效  
79 率较低。而且，传统图像处理方法通常需要人工设置特征以进行图像分割，调参过程对专业  
80 知识要求较高，泛化能力和鲁棒性较差，识别率不高，自动化程度较低，难以满足大规模业  
81 务应用的需求。此外，异常回波细节丰富，目标多呈片状或散落状，轮廓不规则，特征差异  
82 显著，进一步增加了使用传统方法识别异常回波的难度。

83 近年来，随着人工智能和机器学习技术的发展，以深度学习模型为代表的人工智能技术  
84 因其解决复杂问题和非线性建模的突出能力，在气象应用中日益活跃 (钱奇峰等, 2021; 陈  
85 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  
86 像分类算法也被应用到雷达异常回波识别中。邵楠等 (2013) 通过传统的机器学习实现了雷  
87 达回波的自动识别，但其识别效率不够理想。杨宏宇和王峰岩 (2019) 提出一种基于深度卷  
88 积神经网络 (DCNN) 的气象雷达噪声图像语义分割方法，对气象雷达图像中的 4 类噪声回  
89 波具有较好的去噪效果。刘昉等 (2021) 提出了基于卷积神经网络 (Convolutional Neural  
90 Networks, 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  
91 了异常天气雷达回波图像识别新方法。张林等 (2023) 基于深度学习研发了天气雷达异常数  
92 据识别技术。上述方法对雷达回波图像识别率高、时效快，较传统识别方法具有显著优势。  
93 然而，雷达异常回波细节丰富，特征差异明显，图像分类算法识别结果信息丢失严重，往往  
94 只关注图像的整体类别，无法获取图像中具体特征的位置、数量以及轮廓等细节信息。

95 在计算机视觉领域，图像分割技术是实现图像分析和识别的关键环节。它通过将图像中  
96 的每个像素分类为不同的语义类别，精确描绘物体轮廓，从而为后续的分析 and 识别提供基础。

97 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，语义分割侧重于对像素进行  
98 语义分类，实例分割聚焦于区分同类物体的不同个体，而全景分割综合了两者的优点，实现  
99 对图像更全面细致的分割（邝辉宇和吴俊君，2019）。语义分割技术的发展经历了三个阶段。  
100 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  
101 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  
102 （CNN）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  
103 段是基于全卷积神经网络（Fully Convolutional Networks, FCN）时期（Long et al, 2015），  
104 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  
105 类（王关茗和胡乃平，2023）。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  
106 的语义信息（正常回波或异常回波），而无需区分同一类别的不同个体。因此，本研究采用  
107 语义分割技术改善雷达拼图异常回波的自动识别效果，为提升雷达拼图数据的资料质量和业  
108 务应用水平提供技术支持。

## 109 1 数据集构建

110 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  
111 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  
112 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  
113 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  
114 （Weather Radar Abnormal Echo Dataset）。该数据集的原始数据来自湖北省气象台业务运行  
115 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（MCR），拼图产  
116 品由湖北省内 9 部 S 波段新一代天气雷达组网生成（图 1），格点水平分辨率为 1 km，时  
117 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 3 年湖北省主汛期  
118 不同天气系统演变下的雷达异常回波特征。

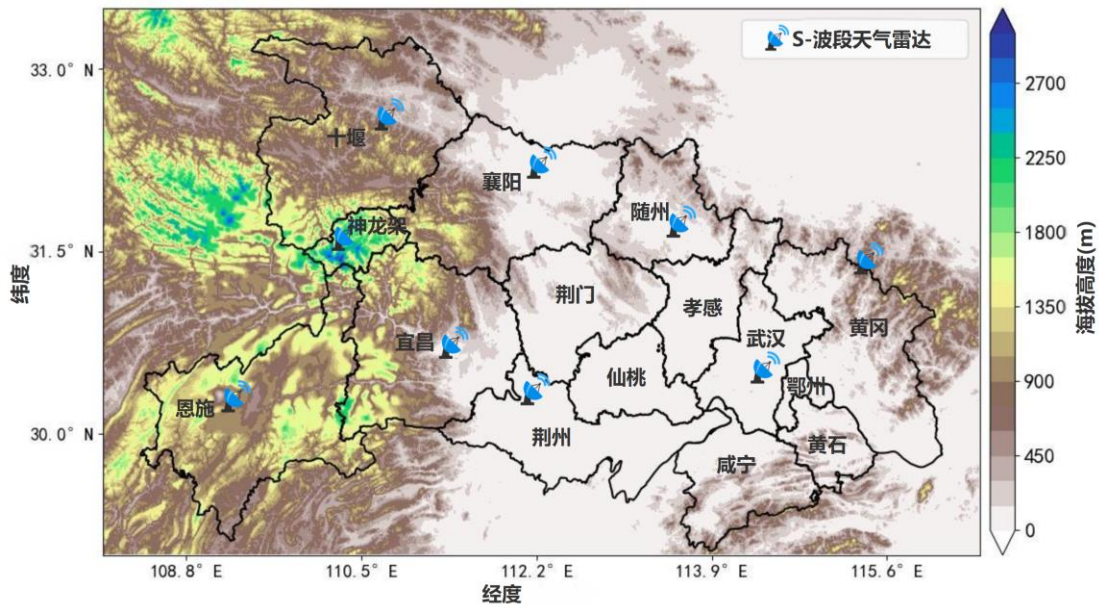


图 1 湖北省 9 部 S 波段天气雷达分布图

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

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 即为自定义图像数据集的具体流程。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图像，157 张仅含环状异常回波图像，59 张同时包含径向和环状异常回波的图像。

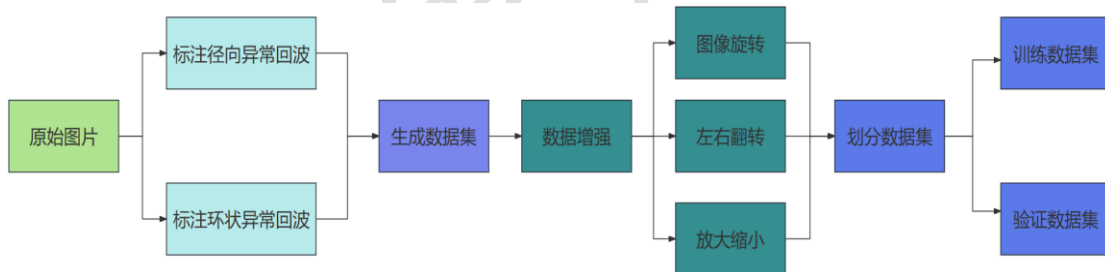


图 2 自定义数据集流程图

Fig.2 Workflow of custom dataset construction

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）。

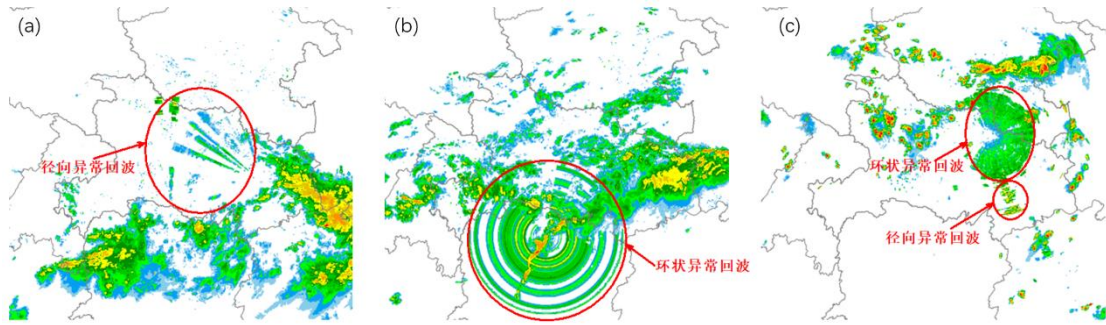


图 3

(a)径向、(b)环状、(c)径向与环状共存异常回波图像

Fig.3 Images of the abnormal radar echoes of (a) radial, (b) ring-shaped and (c) coexistence of radial and ring-shaped abnormal echoes




图 4 (a) 标注后的异常回波图像及其 (b) 掩码标注图像

Fig.4 (a) Annotated 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，可能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，康斓和苏志金（2024）提出了图像数据增强技术。数据增强是一种在机器学习、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（几何变换、颜色变换），有基于多样本图像数据增强方法（SMOTE、SamplePairing、Mixup 等），还有基于生成对抗网络（generative adversarial networks, GAN）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。图像翻转包含水平翻转、垂直翻转等；图像旋转则按照一定角度（30°、60°等）对图像进行旋转操作；图像缩放可对图像进行放大或缩小操作；图像裁剪则通过裁剪出图像的局部区域，改变图像

154 的构图， 可让模型学习到物体的局部特征。

155 综上， 将掩码标注图像及原始图像分别进行旋转、 左右翻转、 放大缩小等操作， 得到雷  
 156 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  
 157 波训练数据集。 由此， 经过数据增强后， 数据集共包含 20000 张图像， 图像大小为 1100×  
 158 800 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  
 159 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  
 160 估。 表 1 所示即为 WRAED 数据集中训练数据集和验证数据集的异常回波分布情况。

161 表 1 数据集异常回波分布情况

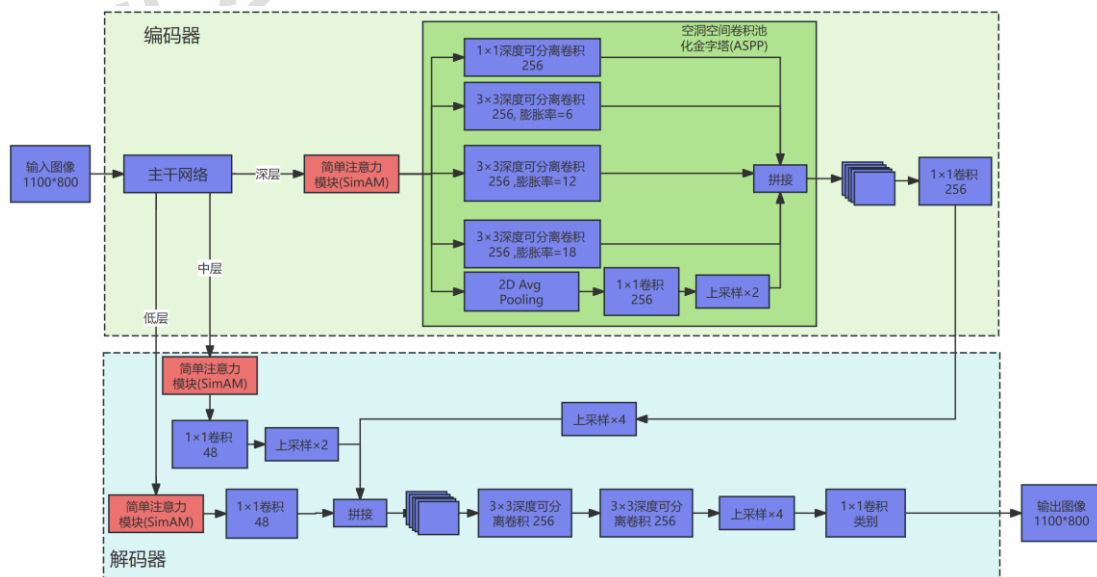
162 Table 1 Distribution of abnormal radar echoes in the dataset

| 数据集   | 径向异常回波 | 环状异常回波 | 径向和环状异常回波 |
|-------|--------|--------|-----------|
| 训练数据集 | 7198   | 7202   | 1600      |
| 验证数据集 | 1801   | 1799   | 400       |

163

## 164 2 DeepLab-ARER 模型

165 本文以 DeepLabV3+模型为基础， 采用简化后的 ResNet50（He et al, 2016; Fakhfakh et  
 166 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  
 167 型的基本结构如图 5 所示。 其中， DeepLabV3+是谷歌（Google） 公司开发的基于编码器-  
 168 解码器（Encoder-Decoder） 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  
 169 的 Xception 主干网络（称为 Aligned Xception）， 可实现高效的特征提取。



170

171

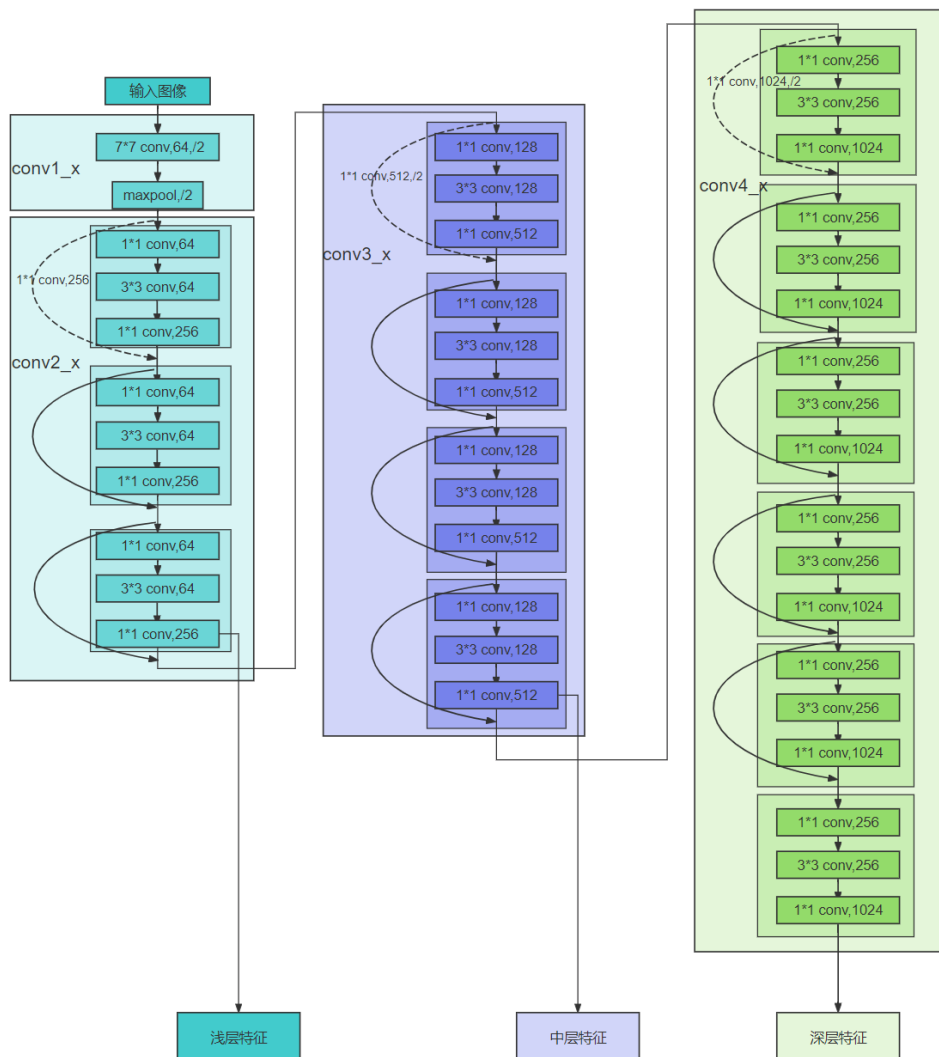
图5 DeepLab-ARER 模型网络结构

172

Fig.5 Architecture of DeepLab-ARER network

173 2.1 主干网络和特征提取

174 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  
 175 法。该方法采用 ResNet50 主干网络，并根据云和雪在天绘一号卫星遥感影像上的特点优化  
 176 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  
 177 （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  
 178 的分割性能最好，ResNet50 次之。为此，DeepLab-ARER 模型采用简化的 ResNet50（删除  
 179 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  
 180 对自定义的异常回波数据集 WRAED 具有更好的分割效果。图 6 即展示了具有不同特征提  
 181 取层的 DeepLab-ARER 模型的主干架构。其中，模型架构的低层、中层和深层的尺寸（像  
 182 素×像素×通道）分别为 128×128×64、64×64×128 和 32×32×256。通过合并中间层，可有  
 183 效引入额外的细节和背景，从而提高模型的分割性能。



184

图 6 DeepLab-ARER 模型主干网络简化的 ResNet50 示意图

Fig. 6 Simplified ResNet50 backbone in DeepLab-ARER model

此外，输出步幅（output stride）表示为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），故本文同样将输出步幅设为 16。

## 2.2 编码器

DeepLab-ARER 模型的编码器路径与 DeepLabV3+保持一致。从主干提取的深度特征层通过空洞空间金字塔池化（ASPP）模块（Chen et al, 2017），结合不同速率的空洞卷积来捕获多尺度信息。ASPP 模块包括一个  $1\times 1$  卷积、三个核大小为  $3\times 3$  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，上述五个分支得到的特征被连接在一起并经过  $1\times 1$  卷积层。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  $3\times 3$  卷积。该技术将标准卷积分解为两个步骤：首先是一个空洞深度卷积（ $3\times 3$  深度卷积，扩张率大于 1），用于对各输入通道独立进行空洞采样；然后是一个逐点卷积（ $1\times 1$  卷积），用于混合通道信息。每个卷积步骤后均紧跟批量标准化和 ReLU 激活函数。这种分解可显著降低计算复杂度，同时保持性能。

## 2.3 解码器

在 DeepLabV3+的解码器组件中，有一种简单且有效的方法来细化分割掩码。首先，从编码器主干提取的低级特征（见图 5 中的低层）经过  $1\times 1$  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连接起来，后者以按 4 倍尺度进行双线性上采样。使用  $3\times 3$  深度可分离卷积层进一步细化连接后的特征。接下来，再次按 4 倍尺度对特征进行双线性上采样。最后，应用  $1\times 1$  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。

然而，基于编码器-解码器的分割模型面临的挑战之一是在编码器的下采样和解码器的上采样过程中，细节特征会丢失。为了解决这个问题，DeepLab-ARER 模型在编码器主干中加入了额外特征提取的中间层（见图 5）。通过特征提取中间层，可在解码器中引入一些编码器路径中可能丢失的一般特征，并增强语义掩码的重建。中间层经过  $1\times 1$  卷积处理，然后以 2 倍系数进行双线性上采样，以匹配解码器其他缩减特征层的大小。随后，将其与模型其他分支的特征连接起来。

## 2.4 注意力模块

注意力机制在计算机视觉领域被证明是有效的，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）。许多研究已表明，加入注意力机制可以提高

215 语义分割模型的性能 (Azad et al, 2020; Zeng et al, 2020; Jia et al, 2023)。其中, 廖艺  
216 齐 (2023) 针对海雾分割任务优化了 DeepLabV3+模型, 在主干网络中引入 ECA 模块, 在  
217 ASPP 模块后加入 CBAM 注意力机制, 提高了海雾分割的精度。吴安坤等 (2024) 分别在  
218 高、低层级特征融合和分割预测之前加入 CBAM 注意力机制, 改善了 DeepLabV3+模型对  
219 雷暴活动的识别精度。贾军营等 (2025) 引入极化自注意力机制 (PSA) 来改进 DeepLabV3+  
220 模型, 有效提升了暴雨过程的道路积水检测性能。同样地, DeepLab-ARER 模型在每个特征  
221 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  
222 力模块, 不引入额外的参数。它不像其他空间和通道注意力机制那样扩展一维或二维 (1D/2D)  
223 权重, 而是直接估计三维 (3D) 权重。将 SimAM 注意力模块添加到低层、中层和深层特征  
224 提取的主干层之后, DeepLab-ARER 模型能够关注重要特征并提高分割性能。

## 225 2.5 损失函数

226 交叉熵损失函数 (Cross Entropy Loss) 在多分类任务中已被广泛验证具有良好的性能。  
227 为此, 本研究采用标准交叉熵损失函数对径向异常回波、环状异常回波及背景的三分类语义  
228 分割任务进行优化。在语义分割任务中, 每个像素被视为一个独立的多分类问题。给定一个  
229 包含  $N$  个像素的训练批次, 交叉熵损失函数定义如下:

$$230 \quad L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(p_{i,c}) \quad (1)$$

231 式中:  $C = 3$  为类别数量,  $y_{i,c}$  表示第  $i$  个像素点在第  $c$  个类别上的真实标签 (one-hot 编码),  
232  $p_{i,c}$  表示模型预测的第  $i$  个像素点属于第  $c$  个类别的概率。

233 DeepLab-ARER 模型的最后一层为  $1 \times 1$  卷积层, 其输出通道数等于语义分割类别数 (即  
234 为 3)。经过该卷积层后, 网络直接输出三通道特征图, 分别对应三个类别的未归一化得分。  
235 网络输出层未使用 Softmax 激活函数, 而是将原始得分直接输入交叉熵损失函数。在现代深  
236 度学习框架中, 标准交叉熵损失函数内部会自动对类别得分执行 Softmax 归一化处理。  
237 Softmax 函数的定义如下:

$$238 \quad \text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (2)$$

239 式中:  $x_i$  为输入向量的第  $i$  个元素,  $n$  为向量维度,  $e$  为自然对数的底数。

## 240 3 模型评估

### 241 3.1 评估方法

242 为进一步评估模型的分割效果，基于构建的雷达拼图异常回波数据集 WRAED，对  
243 DeepLab-ARER 模型与其他主流的 CNN 语义分割基准模型，如 DeepLabV3+ (Chen et al,  
244 2018)、FCN (Long et al, 2015)、ResUnet (Zhang et al, 2018) 与 U-Net (Ronneberger et  
245 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，  
246 因此将其与采用 Xception、ResNet50 及 ResNet101 三种不同主干网络的 DeepLabV3+进行同  
247 步对比。

### 248 3.2 评估指标

249 语义分割模型旨在预测图像中每个像素的类别。模型可能在一个指标下表现良好，但在  
250 另一个指标下表现不佳。为此，本文在评估分割模型时，选用像素准确率 (Pixel Accuracy,  
251 PA)、平均像素准确率 (mean Pixel Accuracy, mPA)、交并比 (Intersection over Union, IoU)  
252 和平均交并比 (mean Intersection over Union, mIoU) 作为主要评价指标。同时，为进一步  
253 分析模型对各类别的识别能力，借鉴气象检验中常用的的三个辅助指标：命中率 (Probability  
254 of Detection, POD)、误报率 (False Alarm Ratio, FAR) 与偏差 (Bias)。

#### 255 3.2.1 像素准确率 (PA)

256 PA 是语义分割中最直观的评估指标，它衡量了模型在所有像素上的整体分类准确度，  
257 反映了模型正确标记图像中每个像素的能力。

$$258 \quad PA = \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i} \quad (3)$$

#### 259 3.2.2 平均像素准确率 (mPA)

260 在语义分割领域，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  
261 均值，类似于平均召回率，但它忽略了误报像素，可衡量模型在每个类别上正确识别像素的  
262 能力。

$$263 \quad mPA = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FN_i} \quad (4)$$

#### 264 3.2.3 交并比 (IoU) 与平均交并比 (mIoU)

265 IoU 与 mIoU 是语义分割模型最核心、最通用的评估指标。它们通过计算预测区域与真  
266 实区域之间的重叠程度，直接量化分割结果的空间精度。其中，IoU 用于衡量针对单个类别

267 的分割精度，它是该类别预测结果与真实标签之间重叠面积（交集）与覆盖总面积（并集）  
268 的比值；mIoU 则是计算所有类别 IoU 的平均值，以提供对模型整体分割性能的宏观度量。

$$269 \quad IoU = \frac{TP_i}{TP_i + FP_i + FN_i} \quad (5)$$

$$270 \quad mIoU = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i + FN_i} \quad (6)$$

### 271 3.2.4 命中率（POD）

272 POD 表征模型检测出真实存在的正类目标的能力，其值域为[0, 1]。其值越高，说明模  
273 型的漏检率越低。

$$274 \quad POD = \frac{TP_i}{TP_i + FN_i} \quad (7)$$

### 275 3.2.5 误报率（FAR）

276 FAR 衡量在所有被模型预测为正类的像素中出现错误预测的比例，其值域为[0, 1]。其  
277 值越高，说明模型的误检率越高。

$$278 \quad FAR = \frac{FP_i}{TP_i + FP_i} \quad (8)$$

### 279 3.2.6 偏差（Bias）

280 Bias 表示模型预测的正类数量与真实的正类数量之间的比例关系。Bias>1 表示模型高  
281 估了该类别，预测的正类像素过多（可能 FP 过高）；Bias<1 表示模型低估了该类别，预测  
282 的正类像素不足（可能 FN 过高）；Bias=1 则表示预测与真实完美匹配。

$$283 \quad BIAS = \frac{TP_i + FP_i}{TP_i + FN_i} \quad (9)$$

284 式（3）~（9）中： $N$  是异常回波类别总数（含背景类），取值为 3； $TP_i$ 、 $TN_i$ 、 $FP_i$ 、 $FN_i$   
285 分别是第  $i$  类异常回波的真实例、真负例、假正例、假负例像素的总数。需要注意的是，真  
286 正例像素表示已正确预测给定类别的像素，而真负例像素表示已正确识别非给定类别的像素。

## 287 3.3 评估环境

288 文中使用配备 GeForce GTX1080Ti 和 PyTorch 深度学习框架的计算节点进行评估。在模  
289 型训练阶段，输入原始图像大小为 1100×800 像素，使用标准 Adam 优化器和分类交叉熵损  
290 失，且设置合适的超参数（学习率初始化为 0.007、批量大小为 100 等）。采用 GPU 加速训

291 练，提高计算效率，通过可视化技术观察模型的训练过程和效果，及时调整超参数和优化策  
292 略。

### 293 3.4 评估结果

#### 294 3.4.1 DeepLab-ARER 性能分析

295 将使用简化 ResNet50（见图 6）主干的 DeepLabV3+视为基准模型（Baseline），通过  
296 在基准模型的不同位置交替或同时添加简单注意力机制（SimAM）和中间层（M-Layer）来  
297 评估 DeepLab-ARER 模型的性能。表 2 展示了基准模型及其不同改进策略下的评估指标。  
298 由表 2 可见，基准模型的整体性能较好，而注意力机制和中间层都能进一步改进模型。但相  
299 较而言，中间层的引入对提高模型性能起主要作用，它使模型能够捕获额外的上下文信息并  
300 优化分割结果，其 mIoU 和 mPA 分别提升了 4.71%和 1.61%。此外，注意力机制同样有助于  
301 合理地改进模型。试验结果表明，联合注意力机制和中间层的效果最优，其 mIoU 为 93.95%，  
302 改进最为明显（提高了 9.49%）；mPA 也得到明显提升（提高了 5.88%），达到了 96.75%。  
303 从类别识别角度来看，在基准模型上添加注意力机制和中间层的配置同样表现最优，对两类  
304 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  
305 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，表现出更高的命中率与  
306 更低的误报率，这也反映出其形态结构更易于模型捕捉与判别。

307 表 2 基于 WRAED 数据集的消融实验结果

308 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         |
| Baseline                      | 84.46        | 90.87        | 0.85        | 0.11        | 0.955        | 0.87        | 0.10        | 0.967        |
| Baseline+SimAM                | 86.13        | 92.37        | 0.88        | 0.09        | 0.967        | 0.90        | 0.08        | 0.978        |
| Baseline+M-Layer              | 89.17        | 92.48        | 0.89        | 0.07        | 0.957        | 0.90        | 0.05        | 0.947        |
| <b>Baseline+M-Layer+SimAM</b> | <b>93.95</b> | <b>96.75</b> | <b>0.93</b> | <b>0.06</b> | <b>0.989</b> | <b>0.95</b> | <b>0.03</b> | <b>0.979</b> |

309 注：粗体为本文提出的 DeepLab-ARER 模型性能指标，下同。

#### 310 3.4.2 不同的注意力机制

311 本评估实验中，基于 DeepLab-ARER 模型测试了不同注意力机制，如：简单注意力  
312 SimAM（Yang et al, 2021）、挤压和激励 SE（Hu et al, 2018）、卷积块注意力 CBAM（Woo  
313 et al, 2018）、瓶颈注意力 BAM（Park et al, 2018）、高效通道注意力 ECA（Wang et al,  
314 2020）、三重注意力 TripletAtt（Misra et al, 2021）和协调注意力 CoordAtt（Hou et al, 2021）  
315 的性能表现。表 3 给出了不同注意力机制下模型的综合评估结果。从整体分割精度来看，

316 SimAM 与 SE 模块表现最为突出，其 mIoU 分别为 93.95%和 93.08%，高于其他对比机制。  
 317 然而，在参数量方面，SimAM 展现出独特优势，其无参设计使其成为所有方案中最高效的  
 318 选择。相比之下，SE 模块虽性能接近，但引入了超过一万的额外参数。在类别识别能力上，  
 319 SimAM 同样表现稳健，在径向与环状异常回波识别上均实现了高命中率（POD 分别为 0.93  
 320 和 0.95）与低误报率（FAR 分别为 0.06 和 0.03）；其 Bias 值最接近 1，表明预测偏差最小。  
 321 尽管 ECA、CoordAtt 等机制对环状异常回波的识别命中率略高（POD=0.96），但其误报率  
 322 （FAR $\geq$ 0.06）也相应增加，并显示出一定的过检倾向（Bias>1）。综合各项指标可知，SimAM  
 323 凭借其无参的三维权重重建模能力，在保持最高分割精度的同时，实现了效率与性能的最佳平  
 324 衡，充分证明了其与本任务特性的高度契合。

表 3 基于 WRAED 数据集的不同注意力机制实验结果

Table 3 Performance comparison of attention mechanisms based on WRAED dataset

| 注意力机制                         | mIoU/%       | mPA/%        | 参数量/<br>个         | 径向异常回波      |             |              | 环状异常回波      |             |              |
|-------------------------------|--------------|--------------|-------------------|-------------|-------------|--------------|-------------|-------------|--------------|
|                               |              |              |                   | POD         | FAR         | Bias         | POD         | FAR         | Bias         |
| <b>Baseline+M-Layer+SimAM</b> | <b>93.95</b> | <b>96.75</b> | <b>10,406,762</b> | <b>0.93</b> | <b>0.06</b> | <b>0.989</b> | <b>0.95</b> | <b>0.03</b> | <b>0.979</b> |
| ECA                           | 91.35        | 96.07        | +2,100            | 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        | +11,800           | 0.92        | 0.10        | 1.022        | 0.96        | 0.08        | 1.043        |
| SE                            | 93.08        | 96.55        | +11,200           | 0.93        | 0.06        | 0.989        | 0.95        | 0.04        | 0.990        |
| BAM                           | 92.53        | 96.31        | +33,200           | 0.93        | 0.09        | 1.022        | 0.94        | 0.07        | 1.011        |
| CBAM                          | 89.54        | 95.39        | +11,500           | 0.92        | 0.11        | 1.034        | 0.94        | 0.09        | 1.033        |

327 注：参数量列的+表示新增数量。3.4.3 与其他模型的对比

328 进一步对比 DeepLab-ARER 模型与其他主流图像分割模型，如：DeepLabV3+（Chen et  
 329 al, 2018）、FCN（Long et al, 2015）、ResUnet（Zhang et al, 2018）与 U-Net（Ronneberger  
 330 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  
 331 （Xception、ResNet101 和 ResNet50），且各模型均以 output\_stride=16 进行构建。图 7 给出  
 332 了表现较好的几个分割模型的识别结果对比。从图中可以直观看出，DeepLab-ARER 模型识  
 333 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。

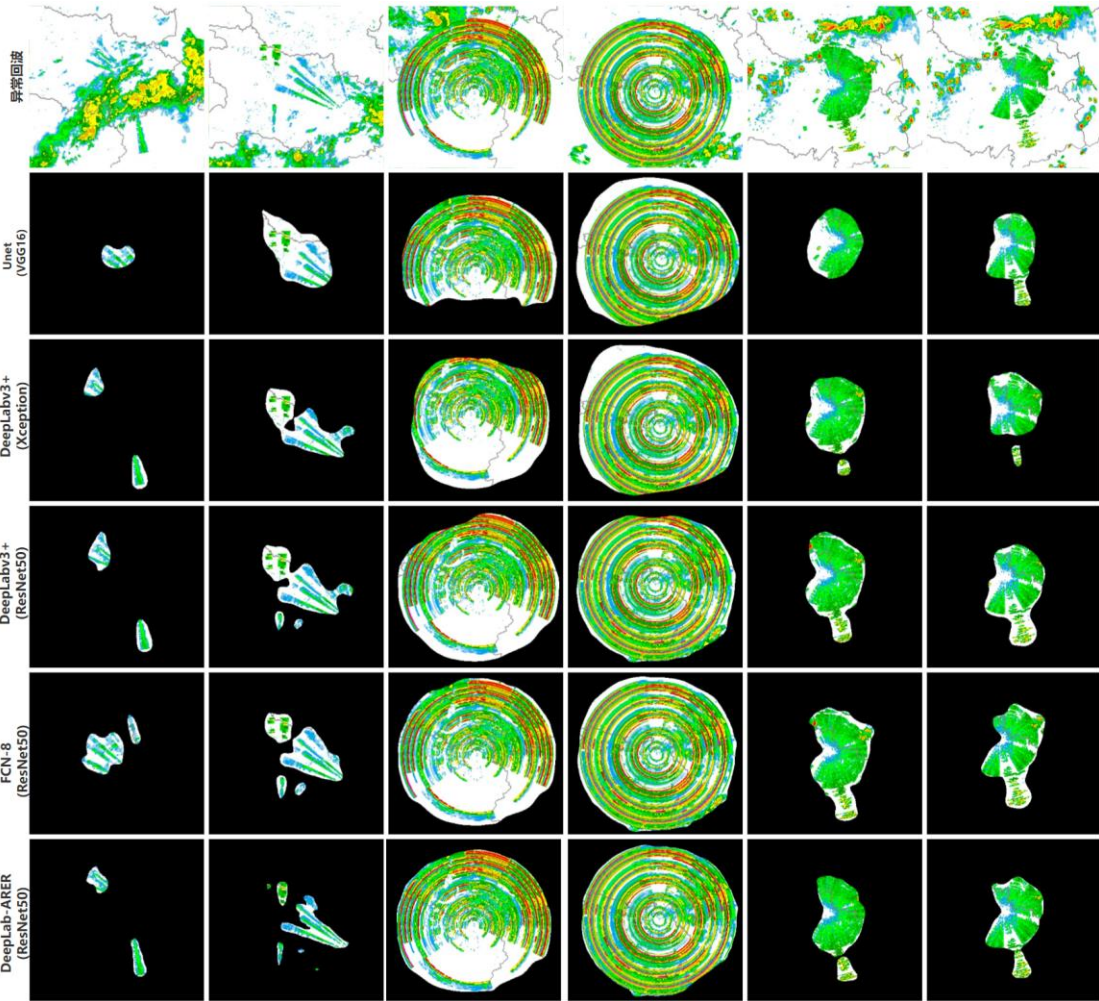


图 7 不同模型对各类异常回波的识别结果对比

Fig. 7 Comparison of recognition results of various abnormal echoes by different models

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 M) 也显著低于大多数模型，仅为标准 DeepLabV3+ (ResNet50 主干) 的约三分之一，但 mIoU 提升了 6.32%。尽管其每秒浮点运算次数 (FLOPS) (1465.92 M) 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=0.98)，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的水平。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) 识别环状异常回波的 POD 略高 (0.96)，但其参数量高达 451.51 M，推理开销巨大；而 ResUnet 的参数量虽然最少 (8.23 M)，但其各项识别指标都显著偏低。

表 4 基于 WRAED 数据集的不同模型性能对比结果

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

| Model                    | Backbone        | mIoU/%       | mPA/%        | Params/M     | FLOPS/M        | 径向异常回波      |             |              | 环状异常回波      |             |
|--------------------------|-----------------|--------------|--------------|--------------|----------------|-------------|-------------|--------------|-------------|-------------|
|                          |                 |              |              |              |                | POD         | FAR         | Bias         | POD         | FAR         |
| DeepLabV3+               | ResNet50        | 87.63        | 95.01        | 27.91        | 1397.47        | 0.91        | 0.07        | 0.978        | 0.94        | 0.04        |
| DeepLabV3+               | ResNet101       | 80.32        | 92.76        | 46.98        | 1785.36        | 0.86        | 0.12        | 0.977        | 0.93        | 0.11        |
| DeepLabV3+               | Xception        | 86.90        | 94.55        | 42.19        | 755.45         | 0.88        | 0.09        | 0.967        | 0.95        | 0.04        |
| Unet                     | VGG16           | 78.49        | 94.14        | 25.86        | 4372.14        | 0.89        | 0.14        | 1.035        | 0.93        | 0.08        |
| FCN-8                    | ResNet50        | 90.63        | 95.95        | 451.51       | 2756.86        | 0.91        | 0.11        | 1.023        | 0.96        | 0.07        |
| FCN-8                    | VGG16           | 77.93        | 91.29        | 134.35       | 790.44         | 0.83        | 0.12        | 0.943        | 0.91        | 0.08        |
| ResUnet                  | -               | 72.54        | 91.51        | 8.23         | 3621.53        | 0.84        | 0.13        | 0.966        | 0.89        | 0.09        |
| <b>DeepLab-A<br/>RER</b> | <b>ResNet50</b> | <b>93.95</b> | <b>96.75</b> | <b>10.41</b> | <b>1465.92</b> | <b>0.93</b> | <b>0.06</b> | <b>0.989</b> | <b>0.95</b> | <b>0.03</b> |

351

352 3.4.4 模型类别性能分析

353 为深入阐释 DeepLab-ARER 模型识别两类异常回波的性能差异，这里结合各类别评估  
 354 指标做进一步分析。由表 5 可见，模型识别环状异常回波的 IoU 与 PA 分别达 95.27% 与 0.97，  
 355 明显高于径向异常回波的 88.13% 与 0.93。其中，IoU 的较大差距反映出环状异常回波具有  
 356 的清晰、闭合边界更利于模型实现空间上的精确拟合，而 PA 的领先则说明其整体结构一致  
 357 性更高，从而在像素级分类任务中具备固有优势。在检测性能方面，模型不仅对环状异常回  
 358 波具有更高的命中率 (POD=0.95)，其误报率 (FAR=0.03) 也低于径向异常回波 (POD=0.93，  
 359 FAR=0.06)。总体而言，模型对两类异常回波均表现出良好的识别能力，但对环状异常回  
 360 波的识别效果更佳。这种性能差异主要源于两类异常回波在形态结构上的本质区别。环状异  
 361 常回波多呈现为规则、闭合的环状或弧状形态，结构稳定、特征鲜明，有利于模型进行精确  
 362 分割。相比之下，径向异常回波形态复杂多变，常呈放射状分布，其条纹结构在某些情况下  
 363 与降水回波的纹理特征相近，导致模型在判别边界与细微结构时更容易产生混淆，故其 IoU  
 364 相对较低，误报率也略高。此外，径向异常回波与环状异常回波的 Bias 值分别为 0.989 和  
 365 0.979，均非常接近 1，这也说明模型对这两类目标的预测不存在明显的系统性偏差。

366

表 5 基于 WRAED 数据集的 DeepLab-ARER 模型识别性能评估结果

367

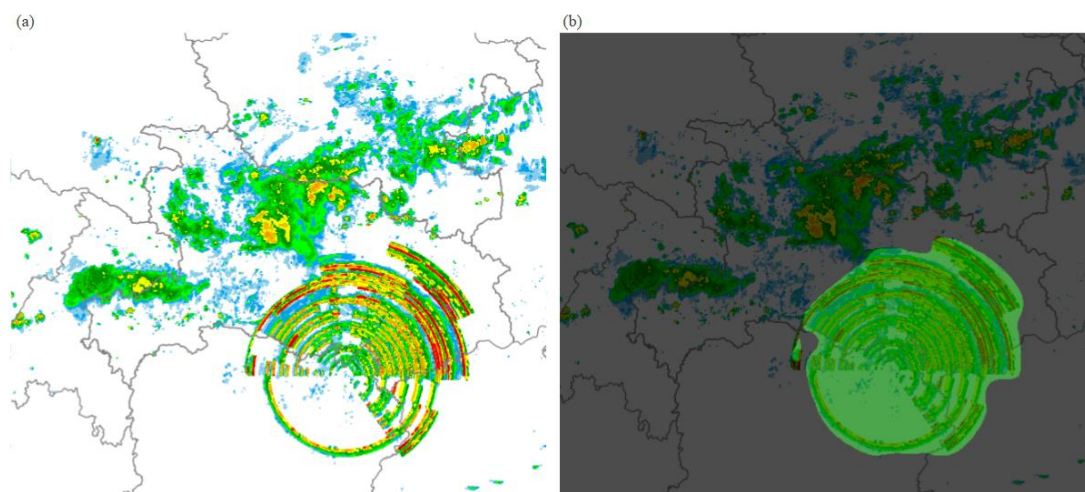
Table 5 Evaluation results of the recognition performance of DeepLab-ARER model based on WRAED dataset

| 类别     | IoU/% | PA   | POD  | FAR  | Bias  |
|--------|-------|------|------|------|-------|
| 径向异常回波 | 88.13 | 0.93 | 0.93 | 0.06 | 0.989 |
| 环状异常回波 | 95.27 | 0.97 | 0.95 | 0.03 | 0.979 |

368

### 369 3.4.5 实例分析

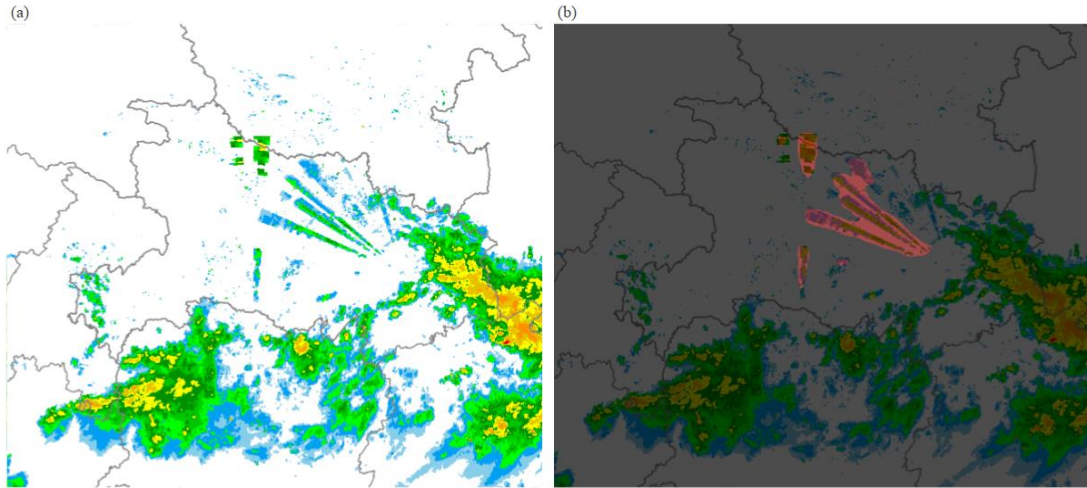
370 利用雷达拼图实例数据分析 DeepLab-ARER 模型的识别效果。图 8 即为 2020 年 8 月 8  
 371 日 04:54（世界时，下同）的雷达拼图原始图像（图 8a）与异常回波识别结果（图 8b）。从  
 372 图 8a 可以看出，在湖北省与湖南省的交界处出现了明显的异常回波，异常回波整体呈现多  
 373 层环状分布特征，强度值跨度较大，取值在 20~65 dBz。这种异常回波不仅严重干扰预报员  
 374 对天气系统的分析判断，在雷达数据定量应用时也会产生明显的偏差，即出现大面积的虚假  
 375 回波，以及强降水的误判。图 8b 则为 DeepLab-ARER 模型异常回波识别结果，从图中可以  
 376 清晰地看到，异常回波的完整轮廓得到了有效识别。



377

378 图 8 2020 年 8 月 8 日 04:54 (a) 雷达拼图原始图像与 (b) DeepLab-ARER 模型异常回波识别结果  
 379 Fig.8 (a) The original radar mosaic image and (b) the abnormal echo recognition result of DeepLab-ARER model  
 380 at 04:54 UTC 8 August 2020

381 图 9 为 2020 年 7 月 7 日 18:42 的雷达拼图原始图像（图 9a）与异常回波识别结果（图  
 382 9b）。由图 9a 可以清楚地看到，湖北省境内出现了多条径向异常回波，且异常回波主要表  
 383 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。这种异常回波使雷达  
 384 拼图数据在多个径向方向上出现虚假回波，明显干扰了雷达拼图数据在多个地区的业务应用。  
 385 从图 9b 的 DeepLab-ARER 模型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  
 386 整识别出来，识别效果良好。



387

388 图9 2020年7月7日18:42 (a) 雷达拼图原始图像与 (b) DeepLab-ARER 模型异常回波识别结果

389 Fig.9 (a) The original radar mosaic image and (b) the abnormal echo recognition result of DeepLab-ARER

390

model at 18:42 UTC 7 July 2020

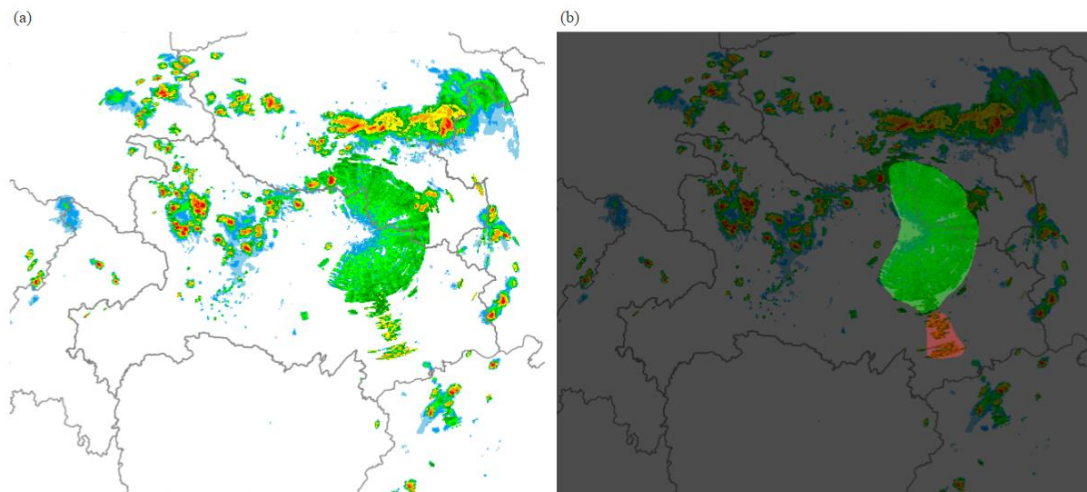
391 图10为2021年7月15日06:18的雷达拼图原始图像(图10a)与异常回波识别结果(图

392 10b)。由图10a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

393 波强度集中在20~40 dBz。这种环状和径向共存的异常回波同样干扰了雷达拼图数据的业务

394 应用,而且一般的算法难以同时有效识别。从图10b的DeepLab-ARER模型异常回波识别

395 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出来。



396

397 图10 2021年7月15日06:18 (a) 雷达拼图原始图像与 (b) DeepLab-ARER 模型异常回波识别结果

398 Fig.10 (a) The original radar mosaic image and (b) the abnormal echo recognition results of DeepLab-ARER

399

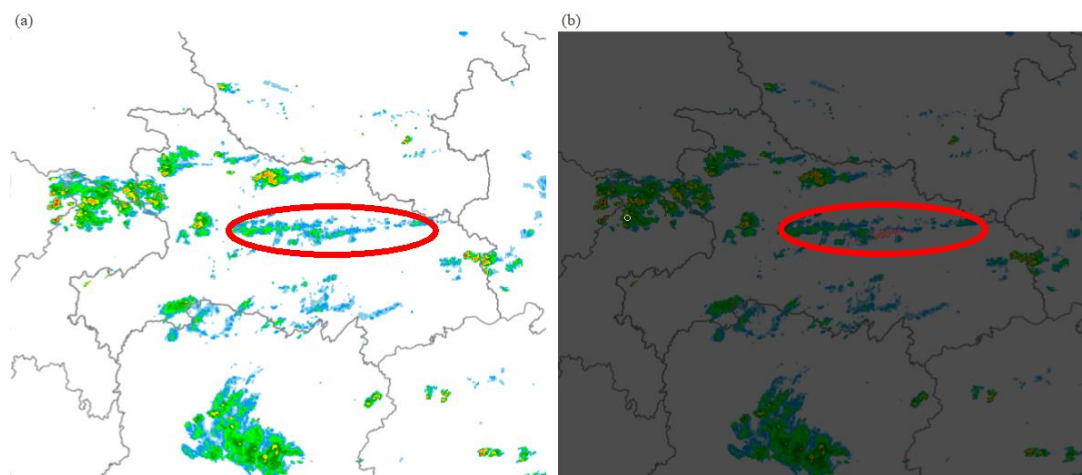
model at 06:18 UTC 15 July 2021

400 然而,DeepLab-ARER模型同样存在误识别的情况。图11即为2021年6月1日11:00

401 的雷达拼图原始图像(图11a)与模型异常回波识别结果(图11b)。导致DeepLab-ARER

402 模型产生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

403 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  
404 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  
405 靠地区分它们, 导致模型产生误识别。环状回波特征清晰, 不易误识别; 对于径向回波, 其  
406 特征复杂多变, 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。



407  
408 图 11 2021 年 6 月 1 日 11:00 (a) 雷达拼图原始图像与 (b) DeepLab-ARER 模型异常回波识别结果

409 Fig.11 (a) The original radar mosaic image and (b) the abnormal echo recognition result of DeepLab-ARER  
410 model at 11:00 UTC 1 June 2021

## 411 4 结论与讨论

412 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  
413 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:

414 (1) 针对公开的雷达拼图异常回波分割数据集稀缺的问题, 本文利用湖北雷达拼图数  
415 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  
416 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。

417 (2) 基于经典的 DeepLabV3+ 模型, 通过使用简化的 ResNet50 主干网络, 在主干特征  
418 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间层, 构建了面向雷  
419 达拼图异常回波识别的 DeepLab-ARER 模型。经 WRAED 数据集评估, DeepLab-ARER 不  
420 仅具有更少的参数和轻量化特点, 在雷达异常回波的图像分割方面优于其他主流的 CNN 语义  
421 分割基准模型, 其 mIoU 和 mPA 值分别达 93.95% 和 96.75%。此外, 与相同主干的  
422 DeepLabV3+ 相比, DeepLab-ARER 在参数减少约三分之二的情况下实现了 mIoU 提高 6.32%。  
423 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  
424 波, 整体效果良好。

425 虽然 DeepLab-ARER 等 CNN 分割模型表现较好, 但仍然存在一些局限性。CNN 需要

426 大量标记数据进行训练,尤其是在雷达异常回波图像分割这类需要学习复杂特征的任务中。  
427 此外, CNN 受局部感受野限制,可能无法有效捕捉全局背景,这种限制会影响模型对全局  
428 背景的感知能力。Transformer 等新型计算机视觉技术使用自注意力机制来捕捉长距离依赖  
429 关系并能更加有效地捕捉整体背景。为此,未来将进一步扩展 WRAED 数据集的样本数量,  
430 研究使用完整或混合的基于 Transformer 模型的方法以获得更优的识别效果。

431

## 432 参考文献

- 433 陈鹤,蔡荣辉,陈静静,等,2022.基于深度学习方法的温度预报技术应用与评估[J].气象,48(11):1373-1383. Chen H, Cai R H,  
434 Chen J J, et al, 2022. Application and evaluation of temperature forecast based on deep learning method[J]. Meteor Mon, 48(11):  
435 1373-1383 (in Chinese).
- 436 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.  
437 Application of adaptive Gaussian frequency filter to weather radar[J]. Meteor Mon, 36(6): 117-121 (in Chinese).
- 438 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  
439 H B, 2025. Road water accumulation detection based on improved DeepLabv3+[J]. Comput Syst Appl, 34(4): 175-183 (in Chinese).
- 440 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  
441 image data enhancement technology[J]. Inform Technol, (9): 176-185 (in Chinese).
- 442 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  
443 combining attention mechanism with Deeplabv3+[D]. Nanchang: Nanchang University (in Chinese).
- 444 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  
445 L, Jiang Y, et al, 2021. Study on recognition algorithm of abnormal radar echo image based on CNN[J]. Electron Design Eng, 29(6):  
446 74-78, 87 (in Chinese).
- 447 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,  
448 2021. A deep learning technique of typhoon intensity estimation[J]. Meteor Mon, 47(5): 601-608 (in Chinese).
- 449 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  
450 al, 2013. Automatic identification system of abnormal radar echoes based on image processing technology[J]. Meteor Sci Technol,  
451 41(6): 993-997 (in Chinese).
- 452 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.  
453 Semantic segmentation of natural disaster remote sensing image based on deep learning[J]. Comput Syst Appl, 32(2): 322-328 (in  
454 Chinese).
- 455 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  
456 J C, Wang Q, et al, 2024. Thunderstorm identification in meteorological satellite images based on an improved DeepLabv3+  
457 network[J]. Meteor Sci Technol, 52(6): 775-786 (in Chinese).
- 458 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  
459 weather radar based on raw data[J]. China Comput Commun, 32(15): 63-66 (in Chinese).
- 460 杨宏宇,王峰岩,2019.基于深度卷积神经网络的气象雷达噪声图像语义分割方法[J].电子与信息学报,41(10):2373-2381. Yang H  
461 Y, Wang F Y, 2019. Meteorological radar noise image semantic segmentation method based on deep convolutional neural network[J].

462 J Electron Inform Technol, 41(10): 2373-2381 (in Chinese).

463 袁凯, 李武阶, 李明, 等, 2022. 四种机器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

464 K, Li W J, Li M, et al, 2022. Examination and evaluation of four machine deep learning algorithms for radar echo nowcasting in

465 Wuhan region[J]. Meteor Mon, 48(4): 428-441 (in Chinese).

466 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,

467 et al, 2025. CastNet: deep-learning-based model for quantitative precipitation nowcasting[J]. Meteor Mon, 51(4): 400-416 (in

468 Chinese).

469 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,

470 et al, 2023. Identification of weather radar abnormal data based on deep learning[J]. J Appl Meteor Sci, 34(6): 694-705 (in Chinese).

471 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,

472 2023. Ground cloud image recognition and segmentation technology based on multi-task learning[J]. Meteor Mon, 49(4): 454-466

473 (in Chinese).

474 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,

475 Zhang J, 2015. The quality control method of erroneous radar echo data generated by hardware fault[J]. J Appl Meteor Sci, 26(5):

476 578-589 (in Chinese).

477 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

478 H, Zhang J J, et al, 2007. Weather radar echo image processing based on median filter and wavelet transform[J]. Sci Meteor Sin,

479 27(1): 63-68 (in Chinese).

480 郑凯, 李建胜, 杨戩峰, 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):

481 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

482 and DeepLabV3+[J]. Acta Geod Cartogr Sin, 49(10): 1343-1353 (in Chinese).

483 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,

484 2008. Analysis of abnormal echoes of new generation weather radar[J]. Meteor Mon, 34(6): 112-115 (in Chinese).

485 邝辉宇, 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,

486 2019. Survey of image semantic segmentation based on deep learning[J]. Comput Eng Appl, 55(19): 12-21, 42 (in Chinese).

487 Azad R, Asadi-Aghbolaghi M, Fathy M, et al, 2020. Attention deeplabv3+: multi-level context attention mechanism for skin lesion

488 segmentation[M]//Bartoli A, Fusiello A. Computer Vision—ECCV 2020 Workshops. Glasgow, UK: Springer.

489 Chen L C, Papandreou G, Schroff F, et al, 2017. Rethinking atrous convolution for semantic image segmentation[J/OL]. arXiv:

490 1706.05587. <https://arxiv.org/abs/1706.05587>.

491 Chen L C, Zhu Y K, Papandreou G, et al, 2018. Encoder-decoder with atrous separable convolution for semantic image

492 segmentation[C]//15th European Conference on Computer Vision (ECCV). Munich, Germany: Springer: 801-818.

493 Fakhfakh M, Bouaziz B, Gargouri F, et al, 2020. ProgNet: COVID-19 prognosis using recurrent and convolutional neural networks[J].

494 Open Med Imaging J, 12(1): 11-12.

495 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.

496 Haddad B, Adane A, Sauvageot H, et al, 2004. Identification and filtering of rainfall and ground radar echoes using textural features[J].

497 Int J Remote Sens, 25(21): 4641-4656.

498 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

499 Pattern Recognition. Las Vegas, NV, USA: IEEE: 770-778.

500 Hou Q B, Zhou D Q, Feng J S, et al, 2021. Coordinate attention for efficient mobile network design[C]//IEEE/CVF Conference on

501 Computer Vision and Pattern Recognition. Nashville, TN, USA: IEEE: 13708-13717.

502 Hu J, Shen L, Sun G, 2018. Squeeze-and-excitation networks[C]/IEEE/CVF Conference on Computer Vision and Pattern Recognition.  
503 Salt Lake City, UT, USA: IEEE: 7132-7141.

504 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].  
505 Electronics, 12(6): 1347.

506 Long J, Shelhamer E, Darrell T, 2015. Fully convolutional networks for semantic segmentation[C]/IEEE Conference on Computer Vision  
507 and Pattern Recognition. Boston, MA, USA: IEEE: 3431-3440.

508 Misra D, Nalamada T, Arasanipalai A U, et al, 2021. Rotate to attend: convolutional triplet attention module[C]/IEEE Winter Conference  
509 on Applications of Computer Vision. Waikoloa, HI, USA: IEEE: 3138-3147.

510 Park J, Woo S, Lee J Y, et al, 2018. BAM: Bottleneck attention module[J/OL]. arXiv: 1807.06514. <https://arxiv.org/abs/1807.06514>.

511 Razavian A S, Azizpour H, Sullivan J, et al, 2014. CNN features off-the-shelf: an astounding baseline for recognition[C]/IEEE  
512 Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA: IEEE: 512-519.

513 Ronneberger O, Fischer P, Brox T, 2015. U-Net: convolutional networks for biomedical image segmentation[C]/18th International  
514 Conference on Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015. Munich, Germany: Springer.

515 Sadouki L, Haddad B, 2013. Classification of radar echoes with a textural–fuzzy approach: an application for the removal of ground  
516 clutter observed in S tíf (Algeria) and Bordeaux (France) sites[J]. Int J Remote Sens, 34(21): 7447-7463.

517 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  
518 Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA: IEEE: 11531-11539.

519 Woo S, Park J, Lee J Y, et al, 2018. CBAM: convolutional block attention module[C]/15th European Conference on Computer Vision  
520 (ECCV). Munich, Germany: Springer: 3-19.

521 Yang L, Wang Y, Wang Z K, et al, 2020. A new method based on stacked auto-encoders to identify abnormal weather radar echo  
522 images[J]. J Wireless Commun Netw, 2020(1): 177.

523 **Yang L X, Zhang R Y, Li L D, et al, 2021. SimAM: a simple, parameter-free attention module for convolutional neural  
524 networks[C]/Proceedings of the 38th International Conference on Machine Learning, PMLR 139: 11863-11874.**

525 Zeng H B, Peng S Q, Li D X, 2020. Deeplabv3+ semantic segmentation model based on feature cross attention mechanism[J]. J Phys  
526 Conf Ser, 1678(1): 012106.

527 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.