

基于多尺度镶嵌的 Mask R-CNN 台风中心定位

郑宗生, 赵家惠*, 卢鹏, 邹国良, 王振华

上海海洋大学信息学院, 上海 201306

摘要 准确自动检测台风风眼位置可为台风预报与监测研究提供先验信息, 以减少灾害损失。由于台风形态结构的多变性, 其中心自动定位仍存在一定的困难。本研究利用台风卫星云图, 提出一种基于多尺度镶嵌的 R-CNN 台风风眼检测方法。收集日本气象厅发布的 1981—2017 年 5000 多张台风卫星云图, 利用图像数据中风眼眼壁轮廓曲线及内外明暗差别清晰明显的特点对图中风眼进行分割标注。通过台风风眼半径多尺度估算算法, 将原始图像划分为多尺度台风云图, 整合训练集和测试集。借助多尺度图像镶嵌、超参数选择和多条件测试分析, 构建利用多尺度 Mask R-CNN 模型检测分割台风风眼的总体算法框架, 开展多尺度对比实验。在自建标定数据集中, 台风风眼的识别准确率最高达到 92.63%、最低为 88.36%, 平均每张图片的检测时间最少为 0.043 s, 均方误差最小达到 2154, 平均交并比最大为 0.9454。实验结果表明, 所提多尺度镶嵌数据增强方法在大中规模尺度融合时效果最好、中小尺度较差, 与现有主要数据增强方法相比, 能更有效地提升神经网络准确率。整体检测模型在台风中心定位中的综合效率优于其他深度学习定位方法。

关键词 图像处理; 台风风眼; 目标检测; 实例分割; 卫星云图; 数据增强

中图分类号 TP751

文献标志码 A

DOI: 10.3788/LOP213379

Location of Typhoon Center Based on Multi-Scale Mosaic Mask R-CNN

Zheng Zongsheng, Zhao Jiahui*, Lu Peng, Zou Guoliang, Wang Zhenhua

College of Information Technology, Shanghai Ocean University, Shanghai 201306, China

Abstract Accurate automatic detection of typhoon eye position can provide a priori information for typhoon forecast and monitoring research to reduce disaster loss. Due to the variability of typhoon morphology, it is still difficult to locate typhoon center automatically. In this paper, a R-CNN method for typhoon eye detection based on multi-scale mosaic is proposed with typhoon satellite cloud images. More than 5000 typhoon satellite cloud images released by Japan Meteorological Agency from 1981 to 2017 are collected. The typhoon eye in the image based on the contour curves of the eye wall and the clear brightness difference between the inside and outside of the typhoon eye is segmented. The original image is divided into multi-scale typhoon cloud images by multi-scale estimation algorithm of typhoon eye radius, and the training set and test set are integrated. With the help of multi-scale image mosaic, hyperparameter selection and multi-condition test analysis, the overall algorithm framework of detecting and segmental typhoon eye using multi-scale Mask R-CNN model is constructed, and multi-scale comparison experiments are carried out. In the self-built calibration dataset, the identification accuracy of typhoon eye is from 88.36% up to 92.63%. The average detection time of each image is at least 0.043 s, the minimum mean square error is 2154, and the maximum average crossover ratio is 0.9454. The experimental results show that the proposed multi-scale mosaic data augmentation method has the best effect in large and medium scale scale fusion, but is poor in small and medium scale fusion. Compared with the existing main data augmentation methods, it can improve the accuracy of neural network more effectively. The comprehensive efficiency of the whole detection model in typhoon center location is better than other deep learning localization methods.

Key words image processing; typhoon eye; object detection; instance segmentation; satellite cloud imagery; data augmentation

收稿日期: 2021-12-29; 修回日期: 2022-02-09; 录用日期: 2022-02-21; 网络首发日期: 2022-03-01

基金项目: 国家自然科学基金项目(41671431)、上海市科委市地方能力建设项目(19050502100)、国家海洋局数字海洋科学技术重点实验室开放基金项目(B201801034)、上海海洋大学科技发展专项基金(A2-2006-20-200211)

通信作者: *jiahui_zhao@foxmail.com

1 引言

台风突发性强、破坏力大,是世界上最严重的自然灾害之一。利用卫星云图准确自动确定台风中心位置可以减少预报工作量、提高定位精度和自动化程度,具有重要的现实意义^[1]。

目前,国内外传统台风中心定位技术包括以下四种方法:1)模式匹配法,Dvorak^[2]首次提出针对气象卫星云图的台风中心获取方法,通过气象学家经验将台风卫星云图绘制成各种模式,再通过不同模式分别判别云图的台风中心;2)风场分析法,Creasey等^[3]利用Yankee高密度探测系统确定台风的中心位置;3)数学形态学方法,刘正光等^[4]通过数学形态学特征对红外卫星云图进行台风区域分割并提取台风云系,最后求其最大内切圆圆心与半径,在此区域内寻找中心区域;4)跟踪雷达回波算法,鲁转侠等^[5]基于海杂波提取特征参数有效确定台风中心位置,建立基于后向差分法的台风中心识别方法;5)自动云特征跟踪技术,靳少辉^[6]提出基于特征学习和显著区域检测的方法定位无眼台风中心。

随着深度学习的发展,利用神经网络对气象云图进行台风云系识别的方法得到广泛应用。神经网络具有强大的学习能力、记忆能力和联想能力,对于目标监测和目标识别有着十分显著的效果。蒋众名^[7]和王晓霞^[8]利用Faster R-CNN算法进行仿真实验定位台风中心。Wang等^[9]将物联网系统与Fast R-CNN算法结合提出用于台风云识别和台风中心定位的深度学习方法,并设计了通用的算法框架。Tan^[10]提出一种高效的全卷积端到端深度神经网络TCLNet来自动定位台风中心位置,在轻量级架构的基础上获得了较好性能。

台风卫星图像与自然图像相比有较大区别,由气象卫星上的辐射仪在可见光波段或大气窗区波段通道上感应的图像叠加而成。它具有结构复杂、信息分布不均的特点,并且它的语义信息层次较为丰富。在非卫星图像的自然图像上,为提取更高层的语义信息、减小网络过拟合问题、提高模型的鲁棒性,常采用数据增强策略。例如:Cutout方法^[11]利用一种简单的正则化技术,在训练过程中随机遮盖输入图片的正方形区域,提高卷积神经网络的整体性能;sample pairing方法^[12]从训练数据中随机选择两幅图像对每个像素取两者平均值来合成一个新的样本,显著提高所有测试数据集的分类精度;Mixup方法^[13]混合训练神经网络中样本和标签的凸组合,正则化神经网络,提高了其在ImageNet-2012、CIFAR-10、CIFAR-100等数据集上的泛化性;CutMix方法^[14]在训练图像之间剪切和粘贴补丁,真实标注框也按比例混合到补丁的区域,其在分类任务和定位任务中表现始终优于其他方法,此外在预训练分类器中取得了一定的性能增益;mosaic方法^[15]

将4张样本进行随机裁剪再拼接到一张图上作为训练数据,丰富了图片的背景,变相增加了batch size同时提高了batch normalization效率。

不同台风的风眼尺度差异较大,即使是同一台风,在形成到消亡过程中风眼尺度变化也较大。台风在云图上的表现具有确切的信息及空间结构,由于云系间缝隙和空洞在灰度图片中的特征与风眼类似,样本背景十分复杂。目标检测算法中,常使用目标最小外接垂直矩形框,但这种包围框会存在较大的冗余区域,进而引入背景噪声^[16]。文献[7-9]均采用Faster R-CNN等算法检测台风风眼的大致位置,目前这些目标检测的深度学习方法在识别台风风眼过程中需要学习风眼内、风眼轮廓以及风眼周围云系的相关特征,这就导致风眼的检测结果框不能很好地贴合风眼轮廓,而会将风眼周边的台风云系纳入框内,造成台风中心定位产生较大误差。实例分割算法则可以准确分割出台风风眼的轮廓,从而确定台风中心位置。而文献[15]的随机裁剪方法会造成台风重要结构特征的缺失,同时裁剪尺度的大小跟台风过程、风眼的尺度紧密相关,不同尺度及策略对镶嵌存在重要影响。目前的裁剪方法不能够很好地支持多尺度形态的台风定位。鉴于此情况,本研究在前人研究的基础上,尝试将多尺度镶嵌的目标检测Mask R-CNN算法应用于台风卫星云图的风眼定位检测中,进一步探索提高风眼小目标分割效率以及台风中心定位精度。

2 Mask R-CNN基本模型及改进

2.1 Mask R-CNN模型

Mask R-CNN目标实例分割模型包括两个步骤:1)采用区域生成网络(RPN)提取候选区域;2)生成预测类别和坐标信息的同时,对于每个感兴趣区域(RoI),Mask R-CNN会输出一个二值掩码并将矩形框分类和坐标回归并行处理,大大简化原先R-CNN的流程。在训练阶段,对每个样本的RoI定义多任务损失函数如下:

$$L = L_{\text{cls}} + L_{\text{box}} + L_{\text{mask}}, \quad (1)$$

式中: L_{cls} 、 L_{box} 和 L_{mask} 分别为分类损失、回归框损失和掩码损失。在掩码分支中每个RoI的输出是 Km^2 ,表示 K 个 $m \times m$ 尺寸的二值掩码,其中 K 是物体类别数目。对于每个像素使用Sigmoid函数求得相对熵,而它们的平均值则定义为 L_{mask} 。 K 个掩码相互独立地进行分割,各个分类之间不存在竞争。这种定义 L_{mask} 的方式使得网络在生成每个类别的掩码时不会受类别竞争影响,解耦了掩码和类别预测。

Mask R-CNN通过特征金字塔网络(FPN)合并深层和浅层特征来同时满足分类和检测的需求,在Faster R-CNN的基础上进行扩展,增加了在每个RoI上预测分割掩码的分支,与分类和边框回归任务并行,主要架构如图1所示。

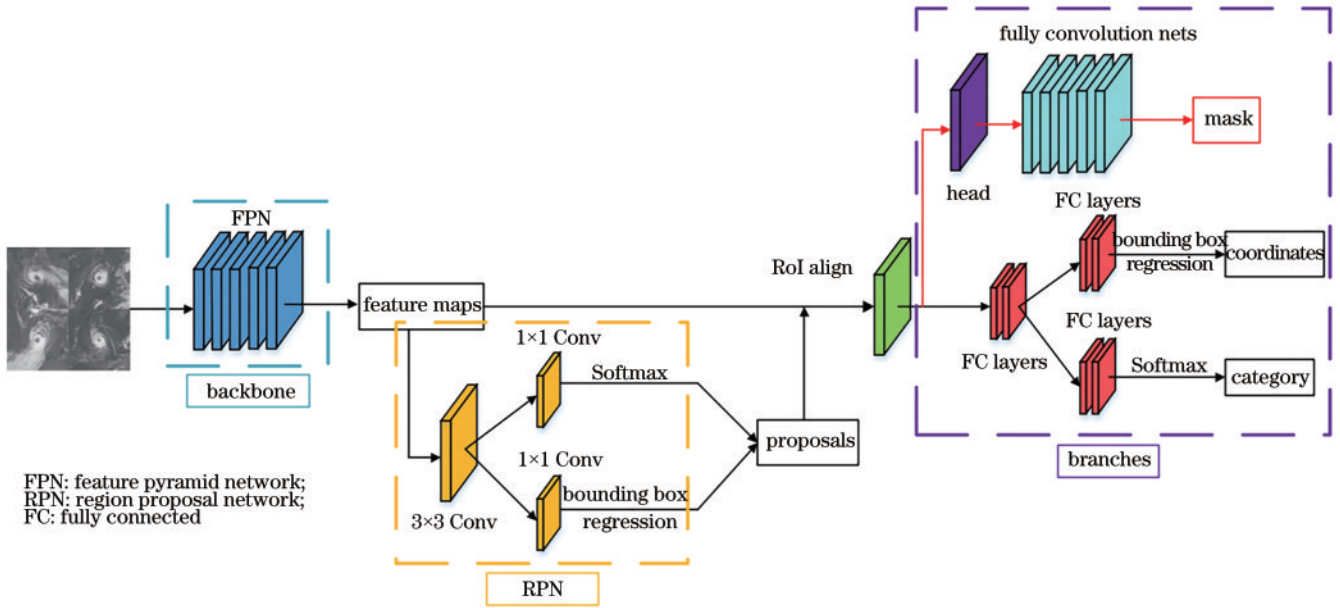


图 1 模型架构图

Fig. 1 Model architecture diagram

2.2 台风风眼半径多尺度估算方法

自 1981 年日本气象厅开始记录发布台风卫星云图数据以来,历年平均生成台风 26.2 个,而每个台风从生成到消亡公布的图片数据不超过 10 张,可见气象云图数据之匮乏。将获取到的所有 5500 张卫星云图分为 4400 张训练数据和 1100 张测试数据。首先对其进行风眼标注,之后在生成的标注文件里记录标注圆心坐标 (x_1, y_1) 和圆上一点坐标 (x_2, y_2) 。根据这两个坐标,计算出每张台风云图风眼半径的像素值大小 $r = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$ 。接着,根据半径大小 r 将训练数据等分为 3 份,如表 1 所示。

所多尺度镶嵌方法,是在原有 mosaic 数据增强方法的基础上提出的新方法。mosaic 数据增强方式利用 4 张图片通过随机缩放、随机裁减、随机排布的方

表 1 台风风眼尺度划分

Table 1 Scale division of typhoon eye

Level of scale	Radius size	Number of pictures
Small	$r < 1.43$	1467
Middle	$1.43 \leq r < 1.90$	1467
Large	$r \geq 1.90$	1466

式进行拼接,但是所提多尺度镶嵌方法则将 4 张图片(如图 2 所示)通过 50% 缩小、随机旋转、随机排布组合成 1 张新的 128 pixel × 128 pixel 图片,组合后的数据如图 3 所示。其优点是丰富了检测物体的背景和小目标,并且在计算 batch normalization 的时候 1 次会计算 4 张图片的数据,使得 mini-batch 不需要很大,1 个 GPU 就可以达到比较好的效果,契合本实验的硬件环境。

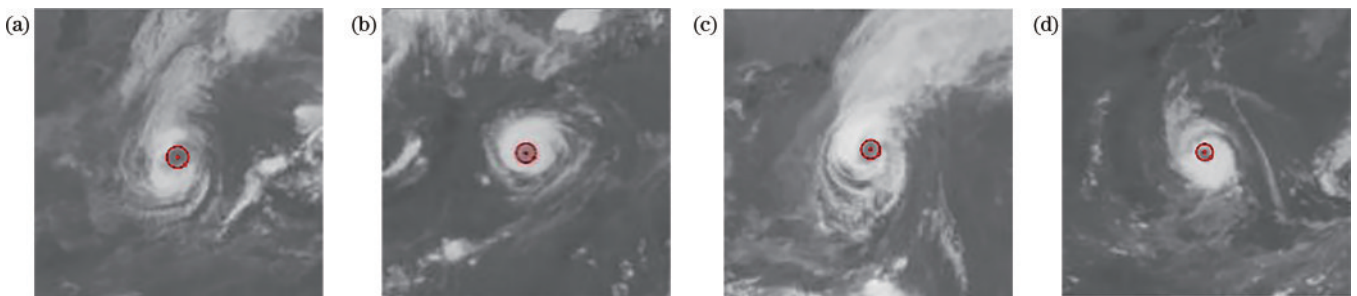


图 2 原标注数据。(a)样本 1;(b)样本 2;(c)样本 3;(d)样本 4

Fig. 2 Original labeled data. (a) Sample 1; (b) sample 2; (c) sample 3; (d) sample 4

在本实验中,选取大型和中等、大型和小型、中等和小型以及大中小融合等 4 组尺度数据进行多尺度镶嵌数据增强,通过对比实验来寻找对模型提升最大的镶嵌组合。

3 多尺度镶嵌

传统数据增强技术主要可分为 3 类:几何变化、色彩变换和混合变换。前两者由于手段单一、变换简单,




图3 融合后数据
Fig. 3 Fused data

对于模型性能的提升往往是有限的。在以往的混合变换数据增强技术的基础上改进图像与标注的拼接方式和融合标准,提出多尺度镶嵌数据增强方法。在多尺度镶嵌中,首先利用卫星云图风眼轮廓标注中的圆心和圆上一点的坐标信息计算出每张台风云图风眼半径的像素值大小,同时根据半径大小的不同将它们分为大、中、小等3种尺寸的台风数据。接着,每次从数据集中挑选4张卫星云图通过50%缩小、随机旋转、随机排布组合成1张新的128 pixel×128 pixel图片,通过这种方式完成数据增强。而面对实验中不同的尺度组合,数据增强时会在组合中各尺度数据内随机选取图片,具体算法如下。

设 $x \in \mathbb{R}^{W \times H \times C}$ 和 y 分别表示训练图像及其标签,其中 W 表示图像的宽度, H 表示图像的高度, C 表示图像的通道数,在本研究中固定为3。所提多尺度镶嵌方法则通过结合 (x_A, y_A) 、 (x_B, y_B) 、 (x_C, y_C) 和 (x_D, y_D) 这4个训练样本来生成1个新的训练样本 (\tilde{x}, \tilde{y}) 。而模型仍然使用原来的损失函数去训练生成的新样本 (\tilde{x}, \tilde{y}) 。结合的过程用以下公式表示:

$$\begin{cases} \tilde{x} = M_1 \odot x_A T_A + M_2 \odot x_B T_B + M_3 \odot x_C T_C + M_4 \odot x_D T_D \\ \tilde{y} = \lambda_1 y_A + \lambda_2 y_B + \lambda_3 y_C + \lambda_4 y_D \end{cases}, \quad (2)$$

式中: $M \in \{0, 1\}^{W \times H}$ 是二进制掩码,表示从4幅图像中裁剪和填充的位置, M 满足 $M_1 + M_2 + M_3 + M_4 = 1$, 1是指填满1的二进制码; \odot 为元素对应相乘; λ 表示4个数据的组合比率,取自beta分布 $\text{Be}(\alpha, \alpha)$ 。本研究中,取 α 为1,即 λ 从均匀分布 $(0, 1)$ 中采样,且 λ 满足 $\lambda_1 + \lambda_2 + \lambda_3 + \lambda_4 = 1$ 。同时为了保证在裁剪拼接的过程中能过够保留完整的风眼数据同时丰富样本背景,引入了平移缩放和随机旋转作为 T 变换。

为采样二进制掩码 M ,先采样边界框坐标 $B = (r_x, r_y, r_w, r_h)$ 表示 x_A, x_B, x_C 和 x_D 上的裁剪区域,4张图

片从区域 B 中裁剪出来的补丁互相填充拼接形成1张完整的新图片。

在实验中选择采样矩形掩码 M ,其长宽比与原始图像成比例。根据以下公式均匀采样框坐标:

$$\begin{cases} r_x \sim \text{Unif}(0, W), r_w = W \sqrt{1 - \lambda} \\ r_y \sim \text{Unif}(0, H), r_h = H \sqrt{1 - \lambda} \end{cases}, \quad (3)$$

式中:裁切面积的比例满足 $\frac{r_w r_h}{WH} = 1 - \lambda$ 。对于裁剪区域的判定由二进制掩码 $M \in \{0, 1\}^{W \times H}$ 判定,在边界框 B 内 M 填充为0,其他区域则填充1。

4 实验与分析

4.1 实验环境

实验环境为Ubuntu操作系统,CPU为Intel® Core™ i7-9700 CPU@3.00 GHz×8,内存为8 GB,双显卡为NVIDIA GeForce RTX 2060。软件使用Python 3.6版本,实验基于TensorFlow框架。主要超参数的设置如表2所示。

表2 通用超参数设置
Table 2 Universal hyperparameter settings

Hyperparameter	Value
NMS-thresh	0.45
Score-thresh	0.5
Maximum iterations	40000
Model checkpoint	2
Learning rate	$10^{-4} - 10^{-6}$
Weight decay	5×10^{-4}
GPU number	1
Input size	128×128

4.2 评价指标

为了定量分析实验结果,采用均方误差(MSE)、平均交并比(MIoU)、平均像素精度(MPA)和检测速度(FPS)等4个评价指标对模型能力进行多方位评价。

1) MSE评价的是边界框的偏离程度,计算的是模型预测边界框和标注边界框之差平方的期望值,是反映它们之间差异程度的一种度量。MSE的值越小,表示模型预测的边界框越准确。公式如下:

$$M_{\text{MSE}} = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n (\hat{y}_{ij} - y_{ij})^2, \quad (4)$$

式中: \hat{y}_{ij} 和 y_{ij} 分别代表模型得到的预测框和真实框中第 i 行第 j 列像素的位置; m 代表边界框的宽度; n 代表边界框的长度。

2) MIoU评价的是边界框的重叠情况,计算的是真实框与预测框的交集和并集比值的平均值,用来衡量模型的框回归能力。MIoU越大,代表真实框与预测框越接近。公式如下:

$$M_{\text{MIoU}} = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k (p_{ji} - p_{ii})}, \quad (5)$$

式中: p_{ij} 表示本属于类 i 但被预测为类 j 的像素数量; p_{ii} 表示真正例的数量; p_{ij} 和 p_{ji} 分别表示被预测为假正例和假负例的像素数量; k 代表类别, 另有一个背景类共 $k+1$ 类目标。

3) MPA 是指平均每个类别内被正确分类像素数占真实图像总像素数的比例。MPA 值越大, 代表预测区域越贴近真实区域。公式如下:

$$M_{\text{MPA}} = \frac{1}{k+1} \cdot \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{TN}} + N_{\text{FP}} + N_{\text{FN}}}, \quad (6)$$

式中: N_{TP} 表示预测正确像素数; N_{TN} 表示预测为背景的像素数; N_{FP} 表示预测错误像素数; N_{FN} 表示没有预测到的像素数。

4) FPS 为一秒钟处理图片的数量。一秒钟内模型对图片操作的数量越多, 它的运算能力越强, 体现了模型的运算能力。




图 4 卫星云图数据。(a) 样本 1; (b) 样本 2; (c) 样本 3; (d) 样本 4

Fig. 4 Satellite cloud image data. (a) Sample 1; (b) sample 2; (c) sample 3; (d) sample 4

由于有眼热带气旋的眼壁轮廓通常是一条不规则的闭合曲线, 同时在图像中风眼位置较暗, 并且在边缘位置风速不连续, 因此可根据这两个成像特点借助 Labelme 工具对处理好的台风云图源数据进行风眼标注。标注后的对应数据如图 4(c)、(d) 所示。

4.4 对比实验

4.4.1 尺度镶嵌对比

实验将大+中、大+小、中+小和大+中+小风眼构成的 4 组多尺度镶嵌数据送入 Mask R-CNN 模型进行 3 次训练, 得到结果后在测试集上验证 MSE、MIoU、MPA 和 FPS, 结果如表 3 所示。其中, 1、2、3 代表训练序号。

经过各参数结果对比发现, 所有镶嵌方法在 MIoU 和 MPA 这两个指标上均优于原模型, 像素级识别预测较为精准。大+中的镶嵌组合明显优于其他所有组合, 同时对比原模型在 4 个指标上都获得了比较明显的提升; 大+中+小的镶嵌组合模型效果逊色于前者, 偶有数据结果略差于原模型的情况; 大+小的镶嵌组合在 MPA 指标上的表现较为羸弱; 中+小的镶嵌组合在 MSE 和 MPA 指标上都明显差于原模型。综合分析可

4.3 实验数据

气象云图数据取自 Himawari-1-8 号 (H-8) 气象卫星, 时间分辨率为 10 min。H-8 搭载的高级成像仪 (AHI) 有 16 个可见光和红外通道, 可见光和红外图像的空间分辨率分别可达到 0.5~1 km 和 1~2 km。自建台风数据由日本国立情报学研究所 (NII) 提供, 该机构整理采用了 H-8 中的 1 个 0.64 μm 波段、0.5 km 空间分辨率和 11 bit 位深的可见光传感器以及 4 个红外传感器数据, 这 4 个红外传感器的空间分辨率均为 2 km, 波段分别为 10.4 μm 、12.4 μm 、6.2 μm 和 3.9 μm , 位深分别为 12 bit、12 bit、11 bit 和 14 bit。本研究选取近四十年来台风云图数据最为丰富的 10.4 μm 红外遥感图像作为数据样本。为避免域样本数量及内容上差异引发的过拟合问题, 采取以下方式: 首先, 对图像进行增强和归一化处理; 其次, 由于模型输入为三通道彩色图像, 将卫星云图的单通道灰度图像进行通道扩增, 形成 RGB 三通道图像; 最后, 将图片重采样为 128 pixel \times 128 pixel, 如图 4(a)、(b) 所示。

以判断, 台风云图中部分风眼占据像素面积过小, 缩小组合后会使得标注框模糊甚至重叠, 不利于模型训练。

确定大+中的镶嵌组合对模型性能提升明显之后, 对这种尺度组合镶嵌的 Mask R-CNN 算法在大、中、小这 3 种不同尺度台风风眼分割中的表现进行进一步研究。对大、中、小这 3 种尺度的测试数据分别计算改进多尺度镶嵌方法前后的 MIoU 和 MPA, 结果如表 4 所示。其中, MIoU^{S} 、 MIoU^{M} 和 MIoU^{L} 分别表示小、中、大尺度风眼数据的平均交并比, MPA^{S} 、 MPA^{M} 和 MPA^{L} 分别表示小、中、大尺度风眼数据的平均像素精度。从表 4 可以看出, 经过所提多尺度镶嵌方法数据增强后的模型在中、小尺度风眼上分割效果提升明显, MIoU 分别提高 3.24 个百分点和 3.25 个百分点, MPA 分别提高 3.66 个百分点和 2.6 个百分点。由此可见, 大+中尺度风眼图像的缩小组合, 使得模型对中小尺度风眼的特征学习和分割鉴别能力得到加强。

综合以上实验得出, 大尺度和中尺度风眼的卫星云图组合镶嵌送入网络训练可以显著提高模型对中、小尺度风眼分割的准确率, 使台风风眼得到有效识别定位, 同时 4 模块融合的数据也在一定程度上加快了

表 3 多尺度实验结果
Table 3 Results of multi-scale experiments

Scale combination	Number	MSE	Mean MSE	MIoU	Mean MIoU	MPA	Mean MPA	FPS	Mean FPS
Master model	1	3802		0.9086		0.8959		20.4	
	1	2154		0.9454		0.9263		17.1	
Large+Middle	2	2981	2554	0.9384	0.9421	0.9170	0.9218	23.3	20.6
	3	2527		0.9426		0.9221		21.5	
Large+Small	1	3290		0.9322		0.9098		19.4	
	2	3747	3415	0.9270	0.9313	0.9061	0.9115	22.7	21.4
	3	3208		0.9348		0.9186		22.2	
Middle+Small	1	3685		0.9259		0.8836		20.8	
	2	4761	4176	0.9151	0.9151	0.8908	0.8896	19.8	20.7
	3	4082		0.9044		0.8944		21.5	
Large+Middle+Small	1	3125		0.9187		0.8968		22.1	
	2	3588	3355	0.9221	0.9222	0.9047	0.9043	18.7	20
	3	3351		0.9258		0.9113		19.2	

表 4 各尺度风眼分割结果对比
Table 4 Comparison of wind eye segmentation results at different scales

Model	MIoU ^S	MIoU ^M	MIoU ^L	MPA ^S	MPA ^M	MPA ^L
Mask R-CNN	0.8880	0.9145	0.9233	0.8830	0.8831	0.9216
Mask R-CNN+Proposed multi-scale mosaic	0.9305	0.9469	0.9489	0.9090	0.9197	0.9367

训练速度。图 5(a)、(b)、(c)、(d)分别展示了模型对台风西马仑(2018年第 20 号台风)在 8 月 21 日 6、9、12、15 时卫星图像的风眼识别结果。在自建标定数据集中,台风风眼的识别准确率最高达到 92.63%,平均每

张图片的检测时间最快达到 0.043 s。即改进网络模型的检测准确率已得到较好的提升,能准确快速地检测、分割出风眼目标。

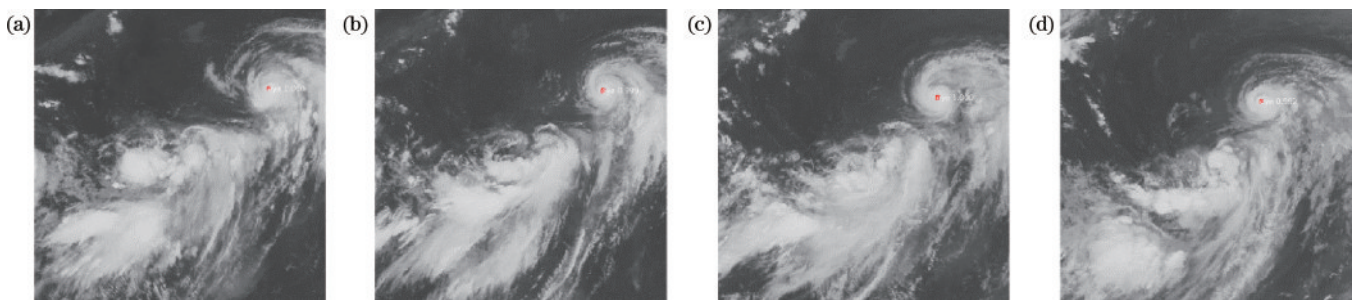


图 5 检测结果样图。(a)样本 1;(b)样本 2;(c)样本 3;(d)样本 4

Fig. 5 Sample drawing of detect results. (a) Sample 1; (b) sample 2; (c) sample 3; (d) sample 4

4.4.2 数据增强对比

将 Cutout、CutMix 和 mosaic 等 3 种使用广泛的主流数据增强方法分别与 Mask R-CNN 相结合进行训练,结果如表 5 所示。

从表 5 数据可以看出,所提多尺度镶嵌方法在边界框 MSE、MIoU 和 MPA 这 3 个评价指标上取得了所有实验中最好的结果。其对比 Mask R-CNN 原模型, MSE 明显下降,准确率则得到显著提高: MIoU 和 MPA 分别提升 3.35 个百分点和 2.59 个百分点。在检测速度方面,所提多尺度镶嵌方法增强后的模型每秒

表 5 各数据增强实验结果

Table 5 Experimental results of each data augmentation

Model	Data augmentation method	MSE	MIoU	MPA	FPS
Mask R-CNN		3802	0.9086	0.8959	20.4
	Proposed multi-scale mosaic	2554	0.9421	0.9218	20.6
	Cutout	5373	0.8569	0.8247	22.8
	CutMix	4006	0.9135	0.9061	17.0
	mosaic	3249	0.9207	0.9074	15.4

处理图片数量与原模型基本持平。考虑到多尺度镶嵌图像背景复杂并且特征广泛, FPS 没有明显增加的结果可以接受。Cutout 方法在前 3 个评价指标中均得到了最差的结果, 只有 FPS 有提升。分析可得, 这是由于 Cutout 特殊的裁剪方式容易遗漏图像中的重要背景特征或风眼信息, 不适用于台风风眼的识别分割, 但正由于图像中信息的缺失导致了空白比例的增加, 减少了模型处理图像的时间。CutMix 则在 MIoU 和 MPA 指标中获得了一定提升, 但 FPS 值明显下降, 这是由于 CutMix 按一定比例将两张图片融合, 丰富了图像内容。mosaic 作为最新流行的数据增强方法, 将 4 张图片合成为 1 张, 在前 3 个指标均有提升, 但是 FPS 在所有对比组中最低。将所提多尺度镶嵌方法与其他数据增强方法的训练结果对比发现, 大、中尺度镶嵌的数据增强方法对 Mask R-CNN 分割准确率提升最大。实验结果表明, 所提多尺度镶嵌方法加持的 Mask R-CNN 在自建台风卫星云图数据集上执行风眼识别分割任务具有可行性和优越性。

图 6 是不使用数据增强方法的 Mask R-CNN 模型训练损失函数图, 图 7 是分别使用 4 种数据增强方法的 Mask R-CNN 模型训练损失函数图。

对比观察数据增强后的损失图和原模型损失图可发现: Cutout 和 CutMix 模型损失函数在前期急速下降之后会有一小段小幅度上升波动, 原因是这两种方法对图片进行了随机裁剪或融合, 导致前期特征缺失、网




图 6 Mask R-CNN 模型损失函数图

Fig. 6 Loss function figure of Mask R-CNN model

络学习效率较低, 损失函数较难收敛; 在后 4 种模型中, mosaic、Cutout 和 CutMix 的损失函数均在训练 20000 轮左右收敛, 这与原模型保持一致, 而所提多尺度镶嵌数据增强方法在 10000 轮左右就实现了模型损失函数收敛。可见, 多尺度镶嵌的方法在一定程度上提升了网络的学习效率。

4.4.3 台风中心定位对比

目前, 深度学习目标检测领域最具代表性的方法有 Faster R-CNN 和 YOLOv3 等。Faster R-CNN 首先通过卷积池化提取图像的特征图, 接着通过 RPN 和 RoI 池化生成推荐特征, 最后计算归类并回归边界框得到检测框位置。YOLOv3 借鉴 FPN 的思想, 从不同尺度提取特征, 将小特征图上采样到

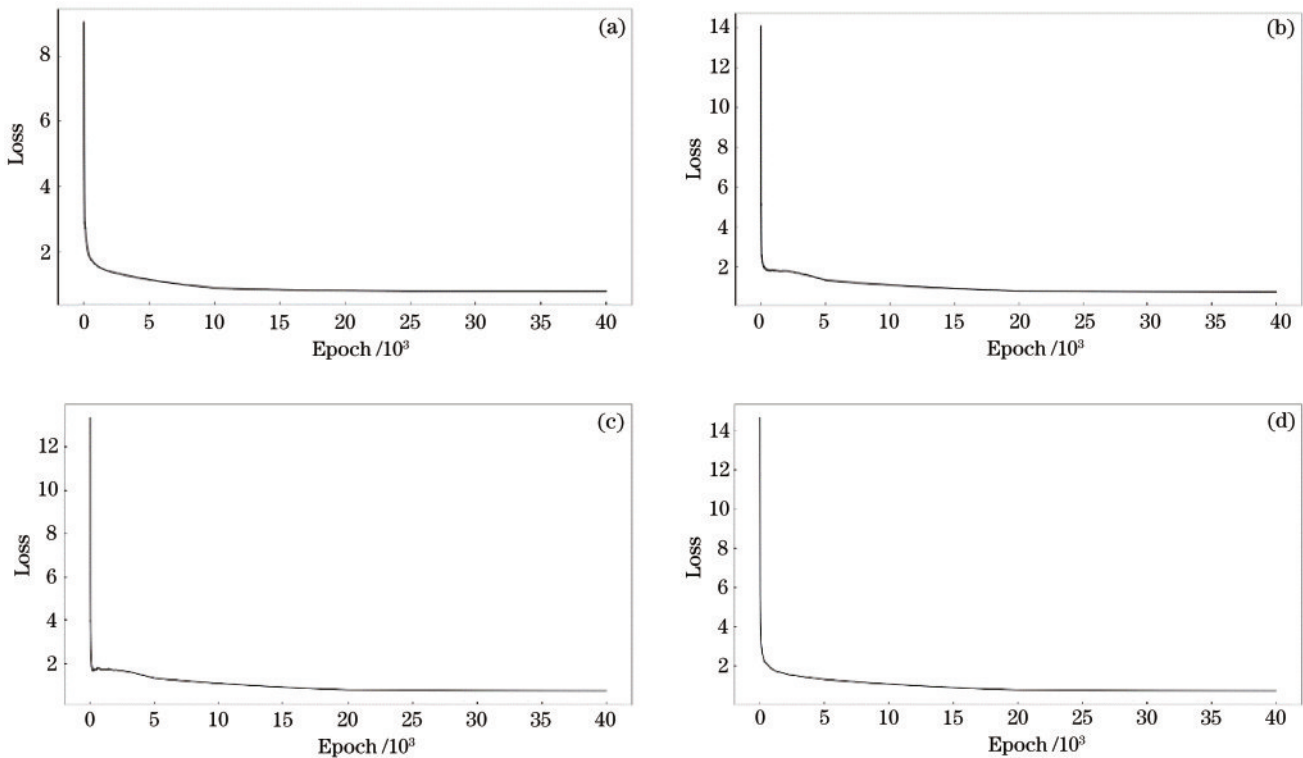


图 7 结合数据增强的 Mask R-CNN 模型损失函数图。(a) 所提多尺度镶嵌; (b) Cutout; (c) CutMix; (d) mosaic

Fig. 7 Loss function figures of Mask R-CNN model combined with data augmentation. (a) Proposed multi-scale mosaic; (b) Cutout; (c) CutMix; (d) mosaic

与大的特征图相同大小,然后与大的特征图拼接进一步预测,最后聚类出锚框预测目标坐标和目标分类。

为了验证所提模型的可行性,分别进行 3 组实验对 Faster R-CNN、YOLOv3 和结合所提多尺度镶嵌的

Mask R-CNN 这 3 个模型进行比较。

图 8 为两个目标检测模型和所提分割模型对台风中心定位的效果演示图,其中目标检测模型将矩形检测框的中心作为台风中心,分割模型则通过分割出风眼的完整轮廓将轮廓图形中心作为台风中心。




图 8 深度学习定位台风中心方法。(a) Faster R-CNN; (b) YOLOv3; (c) Mask R-CNN

Fig. 8 Deep learning method for locating typhoon center. (a) Faster R-CNN; (b) YOLOv3; (c) Mask R-CNN

实验利用在相同训练集上训练至收敛的 3 种模型对相同测试集进行检测分割,通过计算图形几何中心的方法输出台风中心的定位结果。将这些自动定位结果与 NII 给出的台风中心经纬度信息进行比较,得出精度误差,如表 6 所示。

从表中数据可以发现:所提分割算法相比较经典目标检测算法在经纬度平均误差上分别至少有 0.11 和 0.06 的减少,精度提升比例最高达到 39%;而在经纬度平均方差中分别至少有 0.015 和 0.014 的减少,精度提升比例最高达 35%。这说明所提模型的台风中心定位算法优势明显、效果显著。

所提台风定位算法的精确性也在具体的台风序列上进行了测试。选取 2020 年北太平洋的两个超强台风:第 10 号台风海神(HAISHEN)和第 22 号台风环高(VAMCO)。分别节选它们在 9 月 5 日 3 点—9 月 6 日 21 点和 11 月 14 日 3 点—11 月 15 日 21 点的台风中心地理位置数据与所提模型提取的台风中心经纬度信息进行对比,拟合结果如图 9 所示。图 9(a)为台风海神坐标,图 9(b)为台风环高坐标。其中,圈点表示所提算法的台风中心定位结果,星点表示 NII 公开的台风中心最佳路径,每个中心点的时间间隔为 6 h。

表 6 台风中心定位精度对比

Table 6 Comparison of location accuracy of typhoon center

Model	Mean error		Mean variance	
	Longitude	Latitude	Longitude	Latitude
Faster R-CNN	0.31	0.26	0.055	0.046
YOLOv3	0.28	0.25	0.043	0.039
Mask R-CNN+Proposed multi-scale mosaic	0.17	0.19	0.028	0.025

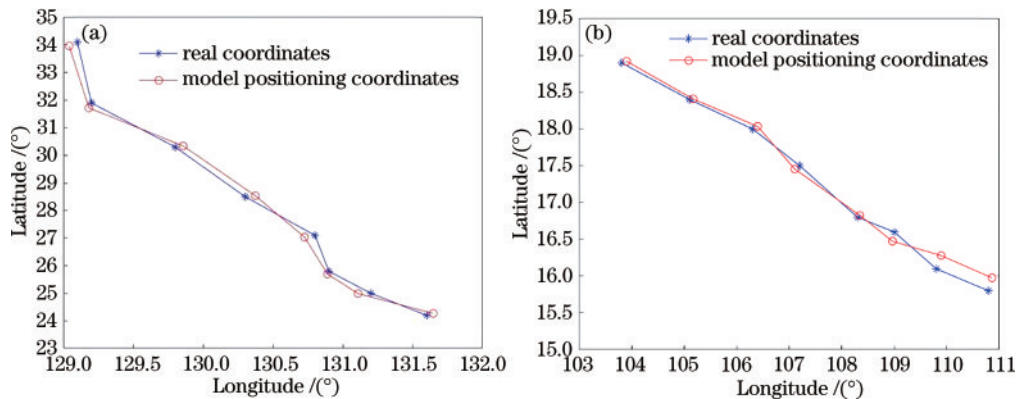


图 9 模型分割定位坐标与真实坐标拟合图。(a)海神;(b)环高

Fig. 9 Fitting diagrams of real coordinates and segmented coordinates of model. (a) HAISHEN; (b) VAMCO

由于卫星红外传感器的空间分辨率大多在 1~2 km, 卫星云图中只是几个像素的差别就会导致 10 km 左右的差距, 进而会造成较多的经纬度误差。一般的目标检测算法对风眼识别不够精细, 中心定位误差较大。而从拟合结果图来看, 结合所提多尺度镶嵌的 Mask R-CNN 在台风中心定位上误差较小, 贴合公开数据, 能够对卫星云图中的台风中心进行有效识别和精准定位, 取得很好的效果。

5 结 论

为充分利用深度学习中目标检测算法快速自动提取特征、检测定位高效准确的优势, 解决目前台风风眼检测定位不便的问题, 将多尺度镶嵌方法应用于卫星云图中台风风眼的深度学习检测方法中定位台风中心。对台风风眼检测定位方法进行深入的调研, 分析传统的台风风眼检测方法并进行模拟实验, 将卫星云图数据转化并处理生成实验所需的数据集, 应用建立好的数据集, 设计一种新的数据增强方案展开台风风眼的识别对比工作。根据方案利用历史数据结合 Mask R-CNN 并对网络模型进行修改, 对风眼分割定位进行仿真实验, 实验结果在各评价指标中都获得令人满意的结果, 最终验证了总体方案的可行性。

参 考 文 献

- [1] 张军, 刘正光, 吴冰, 刘还珠. 基于单幅红外云图的有眼台风自动定位算法[J]. 天津大学学报, 2005, 38(5): 437-442.
Zhang J, Liu Z G, Wu B, et al. Algorithm of eyed typhoon locating based on single infrared image[J]. Journal of Tianjin University, 2005, 38(5): 437-442.
- [2] Dvorak V F. Tropical cyclone intensity analysis and forecasting from satellite imagery[J]. Monthly Weather Review, 1975, 103(5): 420-430.
- [3] Creasey R L, Elsberry R L. Tropical cyclone center positions from sequences of HDSS sondes deployed along high-altitude overpasses[J]. Weather and Forecasting, 2017, 32(1): 317-325.
- [4] 刘正光, 邱海明, 吴冰, 等. 基于卫星云图的无眼台风中心定位算法[J]. 天津大学学报, 2003, 36(6): 668-672.
Liu Z G, Qiu H M, Wu B, et al. Center locating of non-eye typhoon based on satellite cloud image[J]. Journal of Tianjin University, 2003, 36(6): 668-672.
- [5] 鲁转侠, 李雪, 李吉宁, 等. 利用高频天波返回散射反演台风中心和风速[J]. 空间科学学报, 2018, 38(4): 508-516.
Lu Z X, Li X, Li J N, et al. Reconstruction of the typhoon center and wind speed distribution using HF sky-wave backscatter spectrum[J]. Chinese Journal of Space Science, 2018, 38(4): 508-516.
- [6] 靳少辉. 基于视觉显著性和特征学习的 SAR 影像台风中心定位研究[D]. 西安: 西安电子科技大学, 2016.
Jin S H. Center location of typhoons in SAR images based on visual saliency and feature learning[D]. Xi'an: Xidian University, 2016.
- [7] 蒋众名. 基于遥感数据的台风识别与中心定位方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2018.
Jiang Z M. Research on typhoon recognition and centering based on remote sensing data[D]. Harbin: Harbin Institute of Technology, 2018.
- [8] 王晓霞. 基于多源卫星数据的台风定位方法比较研究[D]. 北京: 国家海洋环境预报中心, 2020.
Wang X X. Comparative analysis on typhoon center location methods based on multi-source satellite data[D]. Beijing: National Marine Environment Prediction Center, 2020.
- [9] Wang E K, Wang F, Kumari S, et al. Intelligent monitor for typhoon in IoT system of smart city[J]. The Journal of Supercomputing, 2021, 77(3): 3024-3043.
- [10] Tan C. TCLNet: learning to locate typhoon center using deep neural network[C]//2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS, July 11-16, 2021, Brussels, Belgium. New York: IEEE Press, 2021: 4600-4603.
- [11] DeVries T, Taylor G W. Improved regularization of convolutional neural networks with cutout[EB/OL]. (2017-08-15)[2022-01-05]. <https://arxiv.org/abs/1708.04552>.
- [12] Inoue H. Data augmentation by pairing samples for images classification[EB/OL]. (2018-01-09) [2022-02-05]. <https://arxiv.org/abs/1801.02929>.
- [13] Zhang H Y, Cisse M, Dauphin Y N, et al. Mixup: beyond empirical risk minimization[EB/OL]. (2017-10-25)[2022-02-05]. <https://arxiv.org/abs/1710.09412>.
- [14] Yun S, Han D, Chun S, et al. CutMix: regularization strategy to train strong classifiers with localizable features [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 6022-6031.
- [15] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. (2020-04-23)[2022-02-04]. <https://arxiv.org/abs/2004.10934>.
- [16] 侯笑晗, 金国栋, 谭力宁. 基于深度学习的 SAR 图像舰船目标检测综述[J]. 激光与光电子学进展, 2021, 58(4): 0400005.
Hou X H, Jin G D, Tan L N. Survey of ship detection in SAR images based on deep learning[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0400005.