

中文引用格式:姜垣良,任庆滢,任远,等. 基于改进 YOLO 模型的中缅油气管道遥感图像高后果区识别方法[J]. 中国安全科学学报,2025,35(1):103-111.

英文引用格式:JIANG Yuanliang, REN Qingying, REN Yuan, et al. High-consequence area indentation of remote sensing images of China-Myanmar oil and gas pipeline based on improved YOLO model [J]. China Safety Science Journal, 2025, 35(1): 103-111.

基于改进 YOLO 模型的中缅油气管道遥感图像 高后果区识别方法*

姜垣良^{1,2,3} 高级工程师,任庆滢^{3,4},任远² 高级工程师,
刘海鹏^{1,2,3} 高级工程师,董绍华^{**1,3} 教授

(1 中国石油大学(北京)安全与海洋工程学院,北京 102249;2 中国石油集团 中油国际管道公司,北京 102206;3 中国石油大学(北京)油气生产安全与应急技术应急管理部重点实验室,北京 102249;4 中国石油大学(北京)人工智能学院,北京 102249)

中图分类号:X924.2 文献标志码:A DOI: 10.16265/j.cnki.issn1003-3033.2025.01.0632

资助项目:中国石油天然气集团有限公司-中国石油大学(北京)战略合作科技专项(ZLZX2020-05)。

【摘要】 为解决中缅油气管道国外段外界环境敏感且复杂多变、人工巡检难度大、危险系数高的问题,提出一种改进的高后果区目标检测算法。首先通过引入卷积注意力模块(CBAM)自适应地学习通道和空间注意力,以增强网络的感知能力和泛化能力;然后使用精确边界框回归的高效交并比(Focal-EIoU)损失全面考虑目标特征和相互关系,处理类别不平衡问题,减少易分类样本的干扰,增强模型鲁棒性;最后将改进模型应用至中缅油气管线遥感图像地区属性化智能识别,并进行相关消融试验,以验证改进 YOLO 模型的有效性。结果表明:采用所提方法识别中缅油气管线遥感图像特征,田地、绿地、居住地、河流 4 类地区检测的平均精度均值(mAP)达 68.2%;相比于 YOLOv5、YOLOx 及 YOLOv8 分别提高 29%、21.6%、10.7%。

【关键词】 YOLO; 中缅油气管道; 遥感图像; 高后果区; 目标检测; 智能识别

High-consequence area indentation of remote sensing images of China-Myanmar oil and gas pipeline based on improved YOLO model

JIANG Yuanliang^{1,2,3}, REN Qingying^{3,4}, REN Yuan², LIU Haipeng^{1,2,3}, DONG Shaohua^{1,3}
(1 College of Safety and Ocean Engineering, China University of Petroleum (Beijing), Beijing 102249, China; 2 CNPC International Pipeline Company, Beijing 102206, China; 3 Key Laboratory of Oil and Gas Safety and Emergency Technology, Ministry of Emergency Management, China University of Petroleum (Beijing), Beijing 102249, China; 4 College of Artificial Intelligence, China University of Petroleum (Beijing), Beijing 102249, China)

Abstract: An improved object detection algorithm for high-consequence areas was proposed to solve the problems of the sensitive and complex external environment of the overseas section of the China-Myanmar

* 文章编号:1003-3033(2025)01-0103-09; 收稿日期:2024-08-16;; 修稿日期:2024-10-21

** 通信作者:董绍华(1972—),男,山东寿光人,博士,二级教授,博士生导师,主要从事安全工程、管道完整性管理技术、管道运行维护技术、管道安全评价技术、管道信息工程技术等方面的研究。E-mail:shdong@cup.edu.cn。

oil and gas pipeline, difficulty in manual inspection, and high-risk factors. Firstly, a convolutional block attention module was used to adaptively learn channel and spatial attention to enhance the network's perception and generalization capabilities. Then, focal and efficient intersection over union (Focal-EIoU) loss was used to comprehensively consider the target features and their associations to deal with the issues of class imbalance, reduce the interference of easy-to-classify samples, and enhance the robustness of the model. Finally, the improved model was used to intelligently recognize regional attributes of China-Myanmar oil and gas pipeline remote sensing images. Furthermore, the proposed YOLO model was validated against related ablation experiments. The results showed that for the feature recognition of remote sensing images of the China-Myanmar oil and gas pipeline, the proposed model reached a mean average precision (mAP) of 68.2% for the field, green space, settlement, and river. The model performance was improved by 29%, 21.6%, and 10.7% compared with YOLOv5, YOLOx, and YOLOv8, respectively.

Keywords: YOLO; China-Myanmar oil and gas pipeline; remote sensing images; high consequence areas; object detection; intelligent identification

0 引言

中缅油气管道由原油管道与天然气管道组成,约 771 km 管线位于缅甸境内,1 631 km 原油管道及 1 727 km 天然气管道位于中国境内,其跨度大,途经外界环境复杂多变。为保证管道正常工作及能源安全运输,及时准确地掌握沿线高后果区^[1],对管道周边情况的定时监测必不可少。人工沿线勘察费时费力,难顾全大局且危险系数高;卫星遥感技术在一定程度上减小了人力损耗,通过目标的位置坐标信息,可获取相应地区卫星遥感影像。然而,目前采用人工查看管道沿线遥感图像方式费时费力,工作量且主观性强。因此,本研究选择目标检测法智能识别中缅管线沿线地区的区域特性,可重点关注沿线高后果区的情况。

遥感图像的目标检测可分为传统方法与深度学习 2 大类^[2]。传统遥感图像目标检测算法包括模板匹配和机器学习^[3]。自 2012 年深度卷积神经网络 AlexNet^[4]在图像分类领域获得很大成功并证明了深度学习模型的可行性以来,越来越多的深度学习模型被应用至光学遥感图像的目标检测。在单目标检测方面,多名学者针对遥感图像中单一目标,如飞机、船舶、车辆等的检测展开过研究,如基于马尔可夫随机场全卷积网络^[5]和利用迁移学习的端到端飞机检测框架^[6];使用全卷积网络^[7]、引入传统恒虚警率的快速区域卷积网络^[8](Faster Region-based Convolutional Network, Faster R-CNN)和利用图像空间信息的级联耦合卷积神经网络^[9]的船舶检测框架;可进行任意方向检测的端到端单卷积神经网络^[10]、基于超特征图的精确车辆候选网络及耦合 R-

CNN 方法^[11],具有循环特征感知可视化技术^[12]的车辆检测框架;以及 CAI Bowen 等^[13]提出的一种难例挖掘和权重均衡策略的端到端机场检测网络。多目标检测主要是针对飞机、船舶、储罐、球场、田径场、港口、桥梁等多个目标同时进行检测,如 HAN Xiaobing 等^[14]提出的高分辨率空间遥感图像综合地理空间目标检测框架,LI Ke 等^[15]提出了旋转不敏感和上下文增强网络等。还有学者采用贝叶斯的观点展开研究^[16],引入注意力机制^[17]等方法进行遥感图像的目标检测。对于一些特定场景,有学者将 YOLOv3 应用于震后遥感图像倒塌建筑物的定位^[18],HAN Yanling 等^[19]基于挤压激励网络、卷积神经网络和支持向量机检测遥感图像中的海冰;ZENG Kan 等^[20]提出一种深度卷积神经网络应用于遥感影像的溢油检测。长期以来,多项研究均针对遥感图像中单一目标进行识别,多目标识别通常针对储罐、球场、桥梁等城市中的个体物,但面对中缅油气管道,对其沿线遥感图像识别存在以下问题:管道通常埋于地下,难以捕获管线精确地理位置;中缅油气管道沿线具有自身独特性,如沿线途经山区、植被茂密地带、不发达城镇地区等,其遥感图像形貌特征与一般城市有较大差别,且标注难度较大。

鉴于此,笔者拟建立中缅油气管道木姐段遥感图像数据集,通过添加卷积注意力模块(Convolutional Block Attention Module, CBAM)、引入用于精确边界框回归的高效交并比(Focal and Efficient Intersection over Union, Focal-EIoU)损失来改进 YOLOv8 模型,智能识别中缅油气管道遥感图像高后果区的地区属性,以期为相关领域的研究提供参考和借鉴。

1 中缅油气管道遥感图像数据

中缅油气管道沿线遥感图像高后果区地区属性识别所用数据为通过指定管道沿线经纬度信息,从谷歌地球获取的中缅油气管道缅甸境内木姐县区域管段沿线两侧约 3km 的缓冲区遥感图像,选区如图 1 所示。其中,黑粗线为管道所在位置,灰白色区域为待分析区域,即管道两侧约 3 km 的缓冲区。高后果区是管道泄漏后可能对公众和环境造成较大不良影响的区域,通过处理获得 800 张 512×512 遥感图像,标注图像中的田地、绿地、河流、居住地及道路,其中田地 1 128 处、绿地 3 411 处、居住地 2 929 处、河流 240 处,总计 7 708 处实例,并按 8 : 1 : 1 比例划分出训练、验证、测试集。中缅管线遥感图像数据如图 2 所示。

图 3 为标签分布情况,图 3a 为每个标签的中心点 (x, y) 在整幅图像中的位置,通过图像信息看出,标签位置较为均匀地分布在一张图像中的各个位置。图 3b 展示了不同尺寸标签的数量关系,通过图像信息看出,小目标居多,但仍均匀存在着大目标。图 3c 直观展示了数据中所有标签框的位置与形态。

训练过程中进行数据增强往往会使训练结果更好,使用 Mosaic^[21] 数据增强方法,该方法每次涉及 4 张图像,思路如下:①每次读取 4 张图片;②分别缩放、反转 4 张图片等,摆放在 4 个方向位置;③组合 4 张图片,得到一张新图像,再将图像投入训练。

2 管道沿线高后果区识别方法

2.1 管道沿线高后果区识别网络整体架构

管道沿线高后果区地区属性识别网络整体结构如图 4 所示,主要由卷积(Conv)-批量归一化-激活函数组合模块(Conv-Batch normal-SiLU, CBS)、C2f




图 1 管道位置分布

Fig. 1 Pipeline location distribution




图 2 中缅管线遥感图像数据

Fig. 2 Remote sensing image data of China-Myanmar pipeline

模块、CBAM^[22] 模块、快速空间金字塔池化(Spatial Pyramid Pooling Fast, SPPF)^[23] 模块和检测头等组成。C2f 模块主要由 CBS、瓶颈模块与合并拼接操作组成,C2f_M 中 M 表示瓶颈模块个数。瓶颈模块由 2 个 CBS 和特征图相加操作组成,并可通过参数来控制是否进行直连操作。SPPF 由一个 CBS 模




图 3 标签分布情况

Fig. 3 Label distribution

块、3个最大池化层、合并拼接操作和一个 CBS 模块串联而成,其中,前3步操作会直接将参数传入合并拼接操作中,再共同传入最后一个 CBS 模块。检测

头由2个分支组成,每个分支都由2个 CBS 模块和一个卷积组成,其中,一个分支得到边界框回归损失,另一个分支得到分类损失。

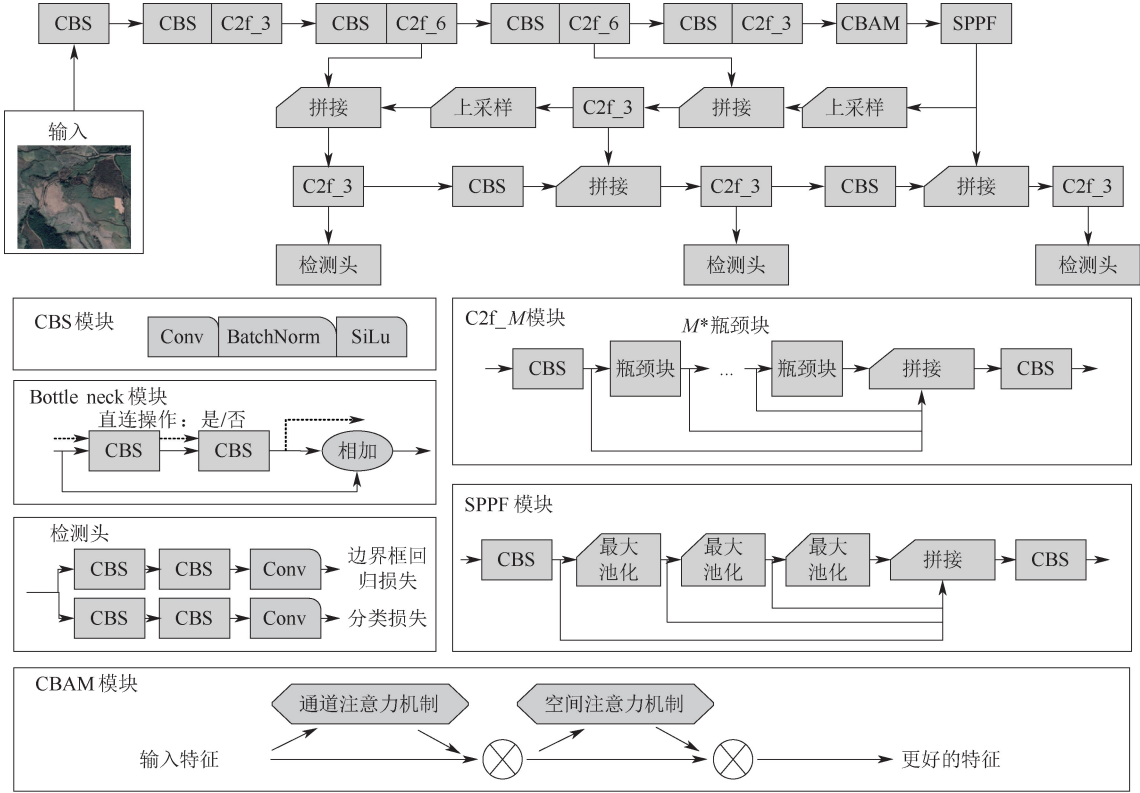


图4 网络结构

Fig. 4 Network structure

2.2 CBAM

CBAM 是一种用于前馈卷积神经网络的简单而有效的注意力模块。给定一个中间特征图, CBAM 模块会沿着 2 个独立的维度(通道和空间)依次推断注意力图,然后将注意力图与输入特征图相乘以进行自适应特征优化。其整体结构如图 5 所示。可以看出, CBAM 包含 2 个子模块,通道注意力模块(Channel Attention Module, CAM)和空间注意力模块(Spatial Attention Module, SAM)。




图5 CBAM 整体结构

Fig. 5 CBAM overall structure

CAM 结构如图 6 所示,首先将输入的高设为 H 、宽设为 W 、通道数设为 C 的特征图 $F(H \times W \times C)$ 分别经过基于宽和高的全局最大池化和全局平均池

化,计算每个通道上的最大特征值和平均特征值,得到 2 个 $1 \times 1 \times C$ 的特征图,再将它们输入到一个共享全连接层中。




图6 CAM 结构

Fig. 6 CAM structure

这个全连接层用于学习每个通道的注意力权重,通过学习网络可以自适应地决定哪些通道对于当前任务更加重要。将全局最大特征向量和平均特征向相交,得到最终注意力权重向量。之后将共享全连接层输出的特征进行基于逐元素的加和操作,再经过 Sigmoid 激活函数,生成最终通道注意力权重 M_c 。最后,将 M_c 和输入特征图 F 作逐元素乘法操作,生成 SAM 模块需要的输入特征。该通道注意力机制见下式:

$$M_c(F) = \text{sigmoid}(\text{MLP}(\text{AvgPool}(F))) +$$

$$\text{MLP}(\text{MaxPool}(F)) =$$

$$\text{sigmoid}(W_1(W_0(F_{\text{avg}}^C)) + W_1(W_0(F_{\text{max}}^C))) \quad (1)$$

$$W_0 \in \mathbb{R}^{C/r \times C}, W_1 \in \mathbb{R}^{C \times C/r} \quad (2)$$

式中: AvgPool 和 MaxPool 分别为平均池化和最大池化; MLP (Multi-Layer Perceptron) 为多层感知机; W_0 和 W_1 分别为池化层和共享 MLP 的权重。输入的 F 经过平均池化和最大池化分别得到特征图 AvgPool(F) 和 MaxPool(F), 同时, 2 条池化路径共享一个全连接层, 2 特征图分别经过共享 MLP 处理后得到 MLP (AvgPool(F)) 与 MLP (MaxPool(F)), 之后经过激活函数得到最终输出 $M_c(F)$ 。

SAM 结构如图 7 所示, 首先将 CAM 输出的特征作为输入特征, 分别沿通道维度执行最大池化和平均池化操作, 生成不同上下文尺度的特征, 将最大池化和平均池化后的特征沿着通道维度进行拼接操作, 得到一个具有不同尺度上下文信息的特征图。然后通过 7×7 的卷积层处理这个特征图, 以生成空间注意力权重, 再经过 Sigmoid 激活函数生成空间注意力权值 M_s , 最后将得到的空间注意力权重应用于原始特征图, 对每个空间位置的特征加权, 以突出重要的图像区域, 并减少不重要区域的影响。该通道注意力机制可表达见下式:




图 7 SAM 结构

Fig. 7 SAM structure

$$M_s(F) = \text{sigmoid}(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) = \text{sigmoid}(f^{7 \times 7}([F_{\text{avg}}^s; F_{\text{max}}^s])) \quad (3)$$

式中 $f^{7 \times 7}$ 表示 7×7 的卷积操作。

在 YOLOv8 中加入 CBAM 能够自适应地学习输入特征图中的通道和空间注意力, 从而增强网络对目标的感知能力和泛化能力, 其通过引入更多的上下文信息并对每个通道的特征图加权, 提升模型的检测性能, 减少假阳性和漏检情况。同时, CBAM 模块只引入少量额外参数, 能够在不增加太多参数和计算量情况下获得更好的性能表现。

2.3 损失函数

高效交并比^[24] (Efficient Intersection over Union, EIoU) 主要由交并比 (Intersection over Union, IoU) 损失 L_{IoU} 、距离损失 L_d 、边长损失 L_a 3 个部分组

成, 定义见下式:

$$L_{\text{EIoU}} = L_{\text{IoU}} + L_d + L_a = 1 - \text{IoU} + \frac{\rho^2(b, b')}{c^2} + \frac{\rho^2(w, w')}{C_w^2} + \frac{\rho^2(h, h')}{C_h^2} \quad (4)$$

式中: b 为预测框; b' 为真实框; w 为预测框宽; w' 为真实框宽; h 为预测框高; h' 为真实框高; c 为最小包围框的对角线距离; C_w 和 C_h 分别为 2 个矩形闭包的宽和高, 这些数值均基于像素计算。

IoU 可体现预测框与真实框的检测效果, 具体表达见下式及图 8。

$$\text{IoU} = \frac{|b \cap b'|}{|b \cup b'|} \quad (5)$$




图 8 IoU 计算

Fig. 8 IoU calculation

在 EIoU 的基础上通过分析有效示例挖掘问题, 将 EIoU 损失和 FocalL1 损失相结合得到 Focal-EIoU^[24] 损失见下式, 其中, γ 为一个用于控制曲线弧度的超参数。

$$L_{\text{Focal-EIoU}} = \text{IoU}^\gamma L_{\text{EIoU}} \quad (6)$$

3 管道沿线高后果区识别结果讨论

试验使用 Python 版本 3.9, Pytorch 版本 1.12.0, CUDA 版本 11.6, 批处理大小为 16, 初始学习率为 0.005, 动量参数为 0.937, 权重衰减系数为 0.0005, 训练迭代次数为 450。

3.1 管道沿线高后果区识别结果评价指标

对于一个目标检测模型, 通常使用精度 P 、召回率 R 、平均精度 (Average Precision, AP) 以及平均精度均值 (mean Average Precision, mAP) 等指标来评价模型。 P 、 R 计算见下式:

$$P = \text{TP} / (\text{TP} + \text{FP}) \quad (7)$$

$$R = \text{TP} / (\text{TP} + \text{FN}) \quad (8)$$

式中: TP 为真阳性, 表示预测为正且实际为正; FP 为假阳性, 表示预测为正且实际为负; TN 为真阴性, 表示预测为负且实际为负; FN 为假阴性, 表示预测为负且实际为正。

以 R 、 P 分别为坐标轴的横、纵坐标画一条曲线, 称该曲线为 PR 曲线, PR 曲线与坐标轴围成的面积为 AP 值, AP 值越大则说明平均准确率越高, AP 值的计算见下式:

$$AP = \sum_{i=1}^{n-1} (r_{i+1} - r_i) P_1(r_i + 1) \quad (9)$$

$$P_1(r_i + 1) = \max_{\tilde{r}: \tilde{r} \geq r_{i+1}} P(\tilde{r}) \quad (10)$$

式中: r_1, r_2, \dots, r_i 是按升序排列的 P 插值段第一个插值处对应的 R 值; i 为插值的点数; n 为插值总点数; P_1 为 P 的插值计算; $\max_{\tilde{r}: \tilde{r} \geq r_{i+1}}$ 表示在约束条件 $\tilde{r} \geq r_{i+1}$ 下, 对 \tilde{r} 进行最大化选择; $P(\tilde{r})$ 为在召回率 \tilde{r} 处的测量精度。

mAP 值即为所有类别 AP 值的一个平均, 是目标检测中最重要的衡量指标之一, 计算见下式:

$$mAP = \sum_{i=1}^k AP_i / k \quad (11)$$

式中 k 为类别数量。

mAP@0.5 为在 IoU 阈值为 0.5 的情况下计算的 mAP, mAP@0.5:0.95 表示 IoU 阈值从 0.5 ~ 0.95 变化的情况下计算的 mAP。

3.2 管道沿线高后果区识别模型结果对比

为验证模型有效性, 将改进的模型与 YOLOv5、YOLOx 以及 YOLOv8 对比, 评估其检测性能, 试验结果见表 1。改进模型对于 4 类中缅管线遥感图像

高后果区属性检测 mAP@0.5 达 68.2%, 相比 YOLOv5、YOLOx 及 YOLOv8 分别提高 29%、21.6%、10.7%。

图 9—图 13 为各模型的试验结果对比, 其中, 图 9 为 4 张测试数据原图, 图 10 为针对图 9a 的检测结果, 其中 YOLOv5 仅检测出图中一处绿地, YOLOx 和 YOLOv8 均检测出图中的绿地和田地部分, 改进模型额外识别出图中一处不明显的居住地。图 11 为针对图 9b 的检测结果, 其中 YOLOv5 未识别出大部分地区属性, YOLOx 和 YOLOv8 检测遗漏之处较多, 改进模型几乎正确识别出图中所有地区属性。图 12 为针对图 9c 的检测结果, 其中 YOLOv5、YOLOx 和 YOLOv8 均未检测出图像上方河流, 改进模型则将图像上的绿地、居住地以及河流均识别出来。图 13 为针对图 9d 的检测结果, 其中 YOLOv5 未检测出图中地区属性, YOLOx 检测出图像右下角部分住所, YOLOv8 检测出图像中间大面积的田地区域以及周边部分住所和绿地, 改进模型在其基础上检测出了一些遗漏的房屋住所。

表 1 管道沿线高后果区识别模型对比结果

Table 1 Results of model tests for identification of high consequence areas along pipelines

模型	AP/%				mAP@0.5/%	mAP@0.5:0.95/%
	田地	绿地	居住地	河流		
YOLOv5	49.2	52.1	54.5	1.0	39.2	22.8
YOLOx	59.8	59.1	49.5	17.8	46.6	21.5
YOLOv8	53.5	59.3	58.3	59.1	57.5	24.4
改进模型	62.7	57.8	52.8	99.5	68.2	30.0

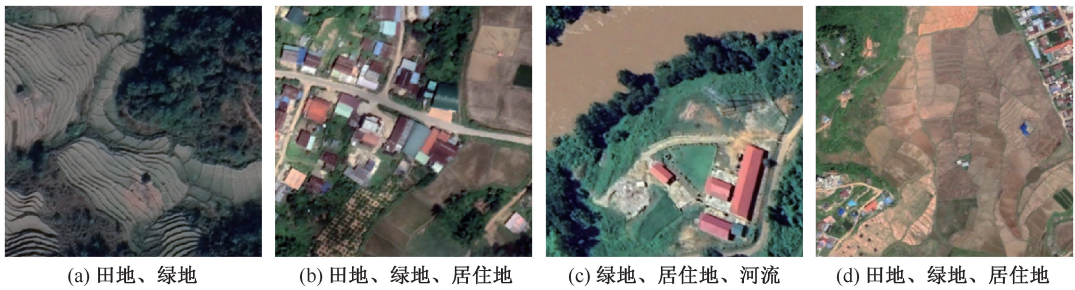


图 9 原始测试图像

Fig. 9 Original test image

3.3 消融试验

为验证模型的有效性, 进行消融试验, 主要对比点包括注意力机制的添加以及损失函数的修改。具体对比结果见表 2, 其中“√”表示使用某结构, “—”表示未使用某结构。图 14 为在原始网络结构以及添加 CBAM 机制网络结构 2 种情况下使用不

同损失函数的结果。

从图 14 看出, 无论是否添加注意力机制, 使用 EIou 与 Focal 结合的损失函数结果最好, 这是由于 EIou 更好地处理了目标框之间的间隙问题, 使得智能识别模型更加关注目标的整体形状而不是简单地考虑目标框的重叠程度, Focal 损失一定程度上解决

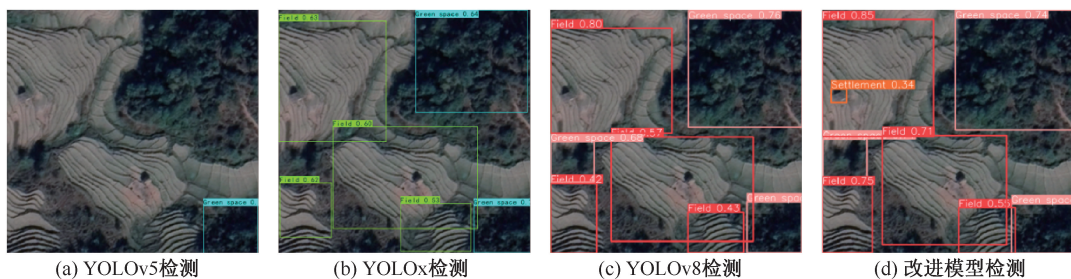


图 10 各模型检测结果对比 (针对图 9a)

Fig. 10 Comparisons between model detection (for Figure 9a)

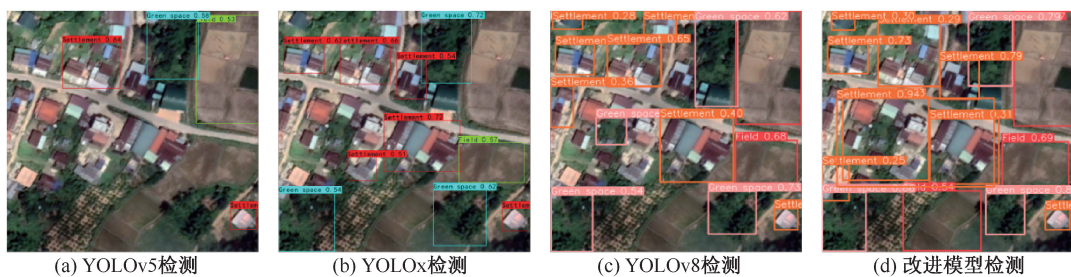


图 11 各模型检测结果对比图 (针对图 9b)

Fig. 11 Comparisons between model detection (for Figure 9b)



图 12 各模型检测结果对比图 (针对图 9c)

Fig. 12 Comparisons between model detection (for Figure 9c)

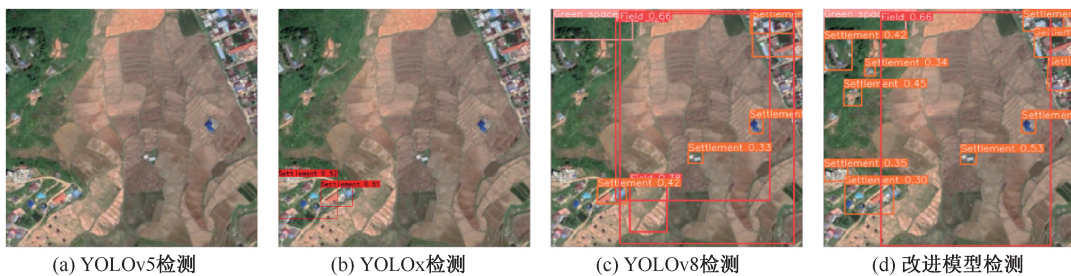


图 13 各模型检测结果对比图 (针对图 9d)

Fig. 13 Comparisons between model detection (for Figure 9d)

了文中河流类型数量较少、类别不平衡对试验结果影响较大的问题。图 15 为在使用 CIoU、EIoU、Focal-EIoU 3 种不同损失函数的情况下,是否对网络结构进行改进所带来的影响。

图 15 中浅灰色表示原始网络结构,深灰色为添

加了 CBAM 的网络结构。通过图像可以看出,添加 CBAM 模块都会获得一个更好的结果,这是由于 CBAM 模块通过自适应学习了特征图中的通道和空间注意力,增强了特征的表达能力,提高了模型的鲁棒性和泛化能力。




图 14 不同损失函数结果对比

Fig. 14 Comparison of results with different loss functions




图 15 添加 CBAM 结果对比

Fig. 15 Comparison of results of adding CBAM

表 2 消融试验结果对比

Table 2 Comparison of ablation experiment results

序号	注意力机制	损失函数			mAP/%
		CloU	EIoU	Focal	
1	未添加 CBAM	√	—	—	57.5
2		—	√	—	58.7
3		—	√	√	61.2
4	添加 CBAM	√	—	—	59.7
5		—	√	—	67.1
6		—	√	√	68.2

4 结 论

1) 中缅油气管道沿线遥感图像智能识别存在的问题主要包括管道通常埋于地下,难以精确捕获具体地理位置;沿线具有途经山区、植被茂密地带、不发达城镇等自身独特性,地形地貌特征与一般城市有较大差别,标注难度较大。

2) 采用精确经纬度信息获取的中缅管道木姐段沿线遥感图像为数据集,以 YOLOv8 为基础网络,通过添加 CBAM 并引入用于精确边界框回归的高效交并比损失对模型进行改进,在中缅油气管道沿线田地、绿地、居住地、河流 4 类地区的 mAP 达 68.2%。

3) 与 YOLOv5、YOLOx 以及 YOLOv8 等标检测网络相比,其平均精度的平均值分别提高 29%、21.6%、10.7%,通过多组消融试验验证了模型所做改进的有效性。

参 考 文 献

- [1] 王晓霖, 帅健, 宋红波, 等. 输油管道高后果区识别与分级管理[J]. 中国安全科学学报, 2015, 25(6): 149-154.
WANG Xiaolin, SHUAI Jian, SONG Hongbo, et al. Identification and hierarchical management of high consequence areas for oil pipeline[J]. China Safety Science Journal, 2015, 25(6): 149-154.
- [2] 刘天颖, 李文根, 关佳红. 基于深度学习的光学遥感图像目标检测方法综述[J]. 无线电通信技术, 2020, 46(6): 624-634.
LIU Tianying, LI Wengen, GUAN Jihong. Deep learning based object detection in optical remote sensing images: a survey[J]. Radio Communications Technology, 2020, 46(6): 624-634.
- [3] 冯长峰, 王春平, 付强, 等. 基于深度学习的光学遥感图像目标检测综述[J]. 激光与红外, 2023, 53(9): 1309-1319.
FENG Changfeng, WANG Chunping, FU Qiang, et al. Survey of object detection in optical remote sensing images based on deep learning[J]. Laser & Infrared, 2023, 53(9): 1309-1319.
- [4] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25(2): DOI:10.1145/3065386.
- [5] YANG Yiding, ZHUANG Yin, BI Fukun, et al. M-FCN: effective fully convolutional network-based airplane detection framework[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(8): 1293-1297.

- [6] CHEN Zhong, ZHANG Ting, OUYANG Chao. End-to-end airplane detection using transfer learning in remote sensing images[J]. *Remote Sensing*, 2018, 10(1): DOI:10.3390/rs10010139.
- [7] LIN Haoning, SHI Zhenwei, ZOU Zhengxia. Fully convolutional network with task partitioning for inshore ship detection in optical remote sensing images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(10): 1 665–1 669.
- [8] KANG Miao, LENG Xiangguang, LIN Zhao, et al. A modified faster R-CNN based on CFAR algorithm for SAR ship detection[C]. *Proceedings of the 2017 International Workshop on Remote Sensing with Intelligent Processing (RSIP)*, 2017: DOI:10.1109/RSIP.2017.7958815.
- [9] ZHAO Juanping, ZHANG Zenghui, YU Wenxian, et al. A cascade coupled convolutional neural network guided visual attention method for ship detection from sar images[J]. *IEEE Access*, 2018, 6: 50 693–50 708.
- [10] TANG Tianyu, ZHOU Shilin, DENG Zhipeng, et al. Arbitrary-oriented vehicle detection in aerial imagery with single convolutional neural networks[J]. *Remote Sensing*, 2017, 9(11): DOI:10.3390/rs9111170.
- [11] DENG Zhipeng, SUN Hao, ZHOU Shilin, et al. Toward fast and accurate vehicle detection in aerial images using coupled region-based convolutional neural networks[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(8): 3 652–3 664.
- [12] MANDAL M, SHAH M, MEENA P, et al. AVDNet: a small-sized vehicle detection network for aerial visual data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(3): 494–498.
- [13] CAI Bowen, JIANG Zhiguo, ZHANG Haopeng, et al. Airport detection using end-to-end convolutional neural network with hard example mining[J]. *Remote Sensing*, 2017, 9(11): DOI:10.3390/rs9111198.
- [14] HAN Xiaobing, ZHONG Yanfei, ZHANG Liangpei. An efficient and robust integrated geospatial object detection framework for high spatial resolution remote sensing imagery[J]. *Remote Sensing*, 2017, 9(7): DOI:10.3390/rs9070666.
- [15] LI Ke, CHENG Gong, BU Shuhui, et al. Rotation-insensitive and context-augmented object detection in remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(4): 2 337–2 348.
- [16] ZOU Zhenxia, SHI Zhenwei. Random access memories: a new paradigm for target detection in high resolution aerial remote sensing images[J]. *IEEE Transactions on Image Processing*, 2018, 27: 1 100–1 111.
- [17] ZHANG Gongjie, LU Shijian, ZHANG Wei. CAD-net: a context-aware detection network for objects in remote sensing imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(12): 10 015–10 024.
- [18] MA Haojie, LIU Yalan, REN Yuhuan, et al. Detection of collapsed buildings in post-earthquake remote sensing images based on the improved YOLOv3[J]. *Remote Sensing*, 2019, 12(1): DOI:10.3390/rs12010044.
- [19] HAN Yanling, WEI Cong, ZHOU Ruyan, et al. Combining 3D-CNN and squeeze-and-excitation networks for remote sensing sea ice image classification[J]. *Mathematical Problems in Engineering*, 2020, 2020(1): 1–15.
- [20] ZENG Kan, WANG Yixiao. A deep convolutional neural network for oil spill detection from spaceborne sar images[J]. *Remote Sensing*, 2020, 12(6): DOI:10.3390/rs12061015.
- [21] BOCHKOVSKIY A, WANG Chienyao, LIAO Hongyuanmark. YOLOv4: optimal speed and accuracy of object detection[J]. *ArXiv Preprint*, 2020: DOI:10.48550/arXiv.2004.10934.
- [22] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]. *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018: 3–19.
- [23] HE Kaiming, ZHANG Xiangyu, REN Shaoping, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1 904–1 916.
- [24] ZHANG Yifan, REN Weiqiang, ZHANG Zhang, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. *Neurocomputing*, 2022, 506: 146–157.

作者简介: 姜垣良 (1986—),男,吉林松原人,博士研究生,高级工程师,主要从事资源与环境、管道运输安全等方面的研究。E-mail:yuanliang.jiang@cnpc.com.cn。

