

DOI:10.19651/j.cnki.emt.2519589

## 基于改进 YOLOv8 的海上平台管道油液滴漏检测\*

杨金丽<sup>1</sup> 李伟<sup>2</sup> 何晓勇<sup>1</sup> 刘凯书<sup>2</sup> 顾继俊<sup>2</sup>

(1.中海油研究总院有限责任公司 北京 100028; 2.中国石油大学(北京)机械与储运工程学院 北京 102249)

**摘要:** 针对海上平台管道油液滴漏检测中存在的尘雾干扰、目标尺度多变以及复杂背景等挑战,提出了一种基于改进 YOLOv8 模型的海上平台管道油液滴漏检测方法。首先,采用 C2f\_MP 模块替换主干网络中的 C2f 模块,增强了细节特征提取能力。其次,通过在模型颈部引入高效多尺度注意力机制(EMA),提高了模型对复杂场景中多尺度目标的特征关注度,提升模型对于小目标的识别能力。最后,将原有检测头优化为 4 个轻量化小目标检测头,显著改善了小目标检测效果并采用 WIoU 损失函数增强训练效果,提升模型识别准确率。实验结果表明:改进 YOLOv8 模型在保持 118 fps 实时检测速度的同时,精确率较基线模型 YOLOv8s 提升 2.3%,mAP@0.5 提升 2.4%。实际应用测试显示,改进模型在某海上平台管道油液滴漏检测中的平均准确率达到 96.25%,满足工程应用需求,为复杂工业环境背景下的海上平台管道安全监测提供了有效的技术解决方案。

**关键词:** 改进 YOLOv8;管道油液滴漏;小目标检测;多尺度融合;遮挡目标;EMA 注意力机制

**中图分类号:** TP391.41;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Detection of oil drop leakage in pipelines of offshore platforms  
based on improved YOLOv8Yang Jinli<sup>1</sup> Li Wei<sup>2</sup> He Xiaoyong<sup>1</sup> Liu Kaishu<sup>2</sup> Gu Jijun<sup>2</sup>

(1. China National Offshore Oil Corporation Research Institute Co., Ltd., Beijing 100028, China;

2. School of Mechanical and Storage and Transportation Engineering, China University of Petroleum (Beijing), Beijing 102249, China)

**Abstract:** In response to the challenges encountered in the detection of oil leakage from pipelines on offshore platforms, such as dust and fog interference, varying target scales, and complex backgrounds, a detection method for oil leakage from offshore platform pipelines based on an improved YOLOv8 model is herein proposed. Initially, the C2f\_MP module is employed to substitute the C2f module within the backbone network. This substitution effectively enhances the model's capacity to extract detailed features. Subsequently, an efficient multi-scale attention mechanism (EMA) is incorporated into the model's neck structure. This addition significantly improves the model's focus on features of multi-scale targets within complex scenarios, thereby enhancing its ability to recognize small targets. Finally, the original detection head is optimized into four lightweight small target detection heads. This optimization remarkably improves the detection performance for small targets. Moreover, the WIoU loss function is utilized to boost the training effectiveness and enhance the model's recognition accuracy. The experimental results indicate that the improved YOLOv8 model can maintain a real-time detection speed of 118 fps. Simultaneously, compared with the baseline model YOLOv8s, the precision is increased by 2.3%, and the mAP@0.5 is enhanced by 2.4%. The practical application tests demonstrate that the average accuracy of the improved model in detecting oil leakage from pipelines on a particular offshore platform reaches 96.25%. This achievement meets the requirements of engineering applications and offers an effective technical solution for the safety monitoring of offshore platform pipelines under complex industrial environment backgrounds.

**Keywords:** improving YOLOv8; pipeline oil leakage; small object detection; multi-scale fusion; occluded objects; EMA attention mechanism

## 0 引言

随着海洋石油开发的不断深入,海上平台的智能化转

型已成为行业发展的必然趋势。作为平台智能化建设的关键环节,管道系统的安全监测直接关系到整个生产系统的稳定运行。然而,海上平台特殊的工作环境给管道滴漏检

收稿日期:2025-08-13

\*基金项目:海上无人平台智能化提升关键技术研究项目(KJZH-2024-2901)、地球深部探测与矿产资源勘查国家科技重大专项(2024ZD1000800,2024ZD1000806)资助

测带来了严峻挑战:一方面,平台管道系统结构复杂,在设备连接处和阀门接口等关键部位极易发生油液滴漏;另一方面,海洋环境中的尘雾干扰、光照变化以及目标尺度多变等因素,导致传统检测方法难以满足实际需求。

近年来,基于深度学习的目标检测技术在工业检测领域展现出巨大潜力。现有研究主要从以下方面进行改进:

1)网络结构优化方面,采用微型预测头<sup>[1]</sup>和BiFPN<sup>[2]</sup>提升多尺度特征融合能力。

2)轻量化设计方面,基于L-YOLO通过骨干网络替换降低计算复杂度<sup>[3]</sup>。

3)特征提取增强方面,通过协调注意力机制(CA)和CARAFE上采样算子<sup>[4]</sup>,有效提升了复杂背景下的特征提取能力。同时采用部分卷积和NWD损失函数,优化了小目标检测性能<sup>[5]</sup>。

4)在目标检测算法优化方面,改进的IRE-YOLO模型有效提升了小目标检测性能<sup>[6]</sup>;通过BiFPN结构改进特征金字塔网络,则显著增强了密集小目标的检测能力<sup>[7]</sup>。

5)轻量化设计方面,基于小目标检测模块SPD-Conv设计的SGConv模块降低了模型复杂度,还提高了移动端部署的适用性<sup>[8]</sup>。

6)另外,将改进YOLOv8与ByteTrack算法结合,使无人机跟踪精度提升1.6%<sup>[9]</sup>;而通过C2fGhost模块和EMA注意力机制则实现了轻量化火灾高效检测<sup>[10]</sup>。

这些研究为复杂环境下的目标检测提供了重要参考,但这些方法在应对海上平台特殊工业环境时仍存在局限性

及技术瓶颈,难以同时解决特征提取不充分、多尺度融合效果欠佳、小目标检测精度不足等问题。

基于以上调研分析,本文提出一种改进的YOLOv8s管道油液滴漏检测模型,主要创新为设计了C2f\_MP新型模块来强化特征提取;引入高效多尺度注意力机制(EAM)来提升复杂背景下的特征判别能力;通过优化检测头结构并采用WIoU损失函数来增强小目标检测性能和消除数据集难易样本的不均衡。最后通过实验得出:该方法能够有效提升了油液滴漏检测的准确性和鲁棒性,为海上平台智能检测与监测提供了可靠的技术方法。

## 1 系统整体结构

海上平台管道油液滴漏智能巡检系统主要由视频图像处理、油液滴漏检测及判别3大功能模块组成,其系统架构如图1所示。首先,视频图像处理模块通过平台上各点位摄像头获取目标巡检区域的实时视频数据,若出现者尘雾情况,该模块就会基于非线性上下文正则化的方法<sup>[11]</sup>对视频图像进行除尘去雾增强处理;然后,油液滴漏检测模块对目标区域滴漏特征进行在线智能识别,实时保存目标区域滴漏锚框关键点信息并读取,实现对目标区域的管道滴漏进行实时检测;最后,滴漏判别模块根据检测的结果来判断是否发生油液滴漏事件,若判定为油液滴漏,该系统则会在系统前端界面弹窗警告和发送警报信号,并将油液滴漏相关信息以字段的形式存入数据库相应表格集中管理。

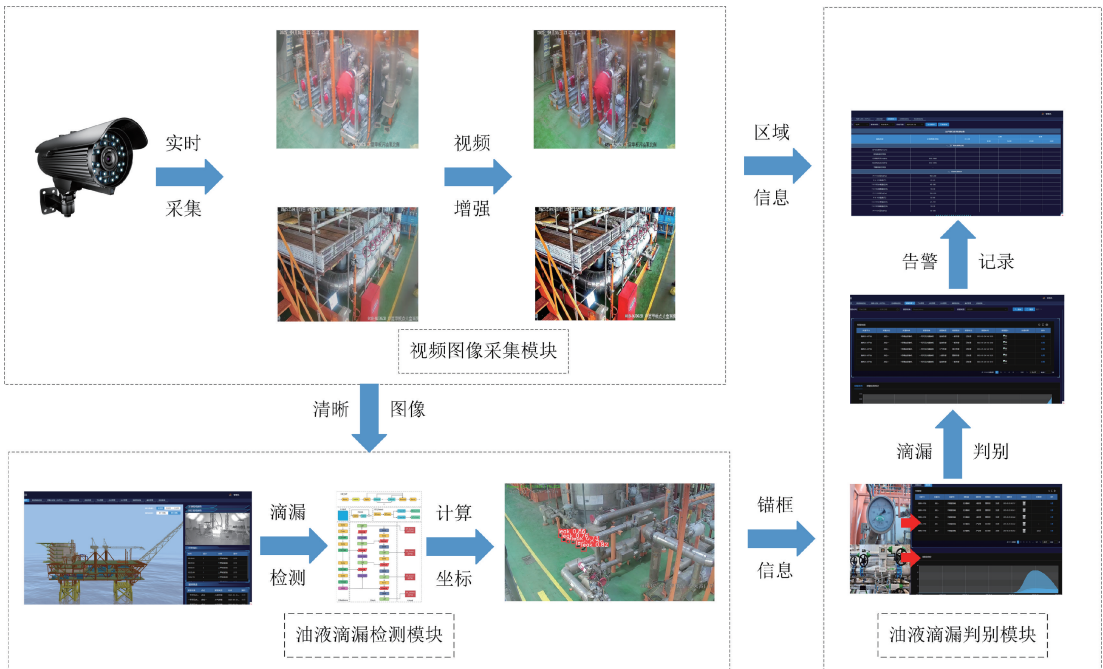


图1 海上平台智能视频巡检系统架构示意图

Fig. 1 Schematic diagram of the architecture of the intelligent video inspection system for offshore platforms

## 2 改进的 YOLOv8 目标检测算法

### 2.1 改进 YOLOv8 的网络结构设计

YOLOv8<sup>[12]</sup> 优势在于处理速度快且具有良好的泛化性,但海上平台管道错综交错,存在设备遮挡等情况,且油液滴漏姿态多样、尺度不一。此外,海上平台因所处环境复杂,管道油液滴漏检测难以避免出现尘雾和光照不均的影响,导致油液滴漏的识别效果不佳。

本文以 YOLOv8s 网络为基础,采用以下几种方法来提高模型的检测精度和抗干扰能力,其网络结构如图 2 所示,具体包括:

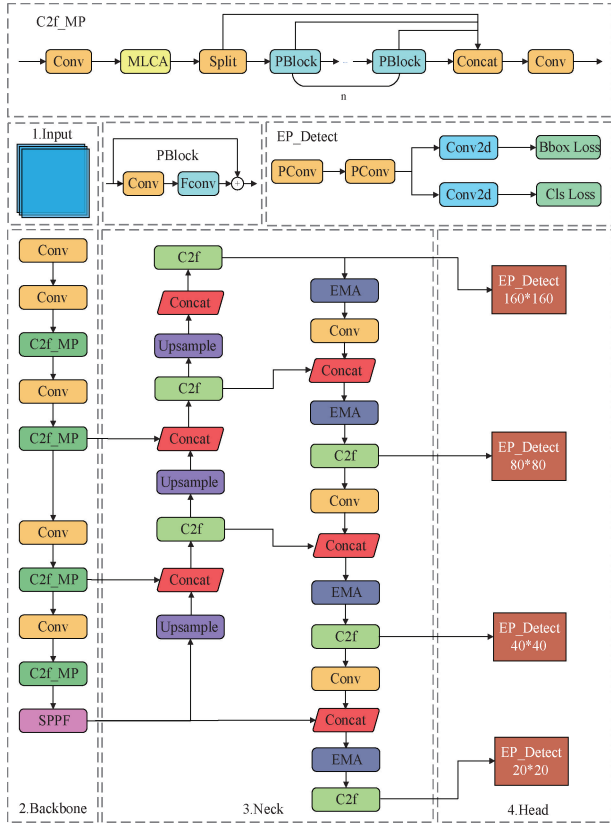


图 2 改进 YOLOv8 模型结构

Fig. 2 Improves the structure of the YOLOv8 model

1) 针对小目标提取特征能力和提取效率较低的问题,在主干网络中嵌入 C2f\_MP 模块,增强了提取管道滴漏的细节特征的能力,降低了计算的复杂性;

2) 针对油液滴漏位置被其他设备部分遮挡导致识别效果不佳的问题,通过在颈部网络结构中加入 EMA 注意力机制,采用跨空间学习机制增强遮挡滴漏可见区域特征表征,抑制背景噪声干扰,提高遮挡滴漏目标的检测精度;

3) 针对小目标检测精度较低问题,通过增加小目标检测头并改进为 EP\_Detect 检测头的方式,提高了检测小尺寸管道油液滴漏目标的准确性;

4) 针对油液滴漏训练数据集标注质量具有波动性且

样本自身难易存在差异性,WIoU 损失函数通过均衡油液滴漏样本难度分布,优化模型训练效果。

### 2.2 C2f\_MP 模块

YOLOv8 中的 C2f 模块计算复杂度高、推理速度慢,制约了模型对复杂目标的特征提取能力与效率。基于部分卷积(partial convolution, PConv)<sup>[13]</sup>,本文重构了 C2f 模块的 Bottleneck,构建出 PBlock 结构,如图 3 所示。PConv 只在少数几个输入通道上应用过滤器,而对其余通道不做处理,与传统卷积相比,减少了冗余计算和内存访问次数<sup>[14]</sup>。PBlock 结构较原 Bottleneck 在特征提取能力上更优,计算成本更低且能降低计算资源的消耗,同时还能更好地利用设备的计算性能。同时 PConv 能够处理提取特征时可能存在的遮挡部分,能够保证输入不完整情况下模型的鲁棒性,更适合在海上平台复杂场景下快速提取特征,从而提高 C2f 模块对管道滴漏特征提取的性能和效率。




图 3 PBlock 结构

Fig. 3 Structure of PBlock

在海上平台复杂环境下提取特征难以获取所有重要的细节信息,即使采用一些方法获取所有重要特征细节也会使得结构变得复杂,不利于检测性能和效率的提升。传统的注意力机制大多只考虑通道整体关系而忽略单一通道的空间信息,这会导致一部分的重要特征丢失。本文采用混合局部通道注意力机制(mixed local channel attention, MLCA)<sup>[15]</sup>,它能够克服传统注意力机制的局限性,通过融入关键的空间信息使得模型的复杂性和性能增益达到平衡,大大提升检测的准确性和性能。

MLCA 注意力机制的结构及原理如图 4 所示<sup>[16]</sup>。首先,输入的特征图(C, W, H)会经过局部平均池化 LAP (local average pooling) 和全局平均池化 GAP (global average pooling) 处理。LAP 主要捕捉局部区域的特征,GAP 主要关注整个特征图的统计信息。对于 LAP 的特征,会先经过重新排列(Reshape)、1D 卷积(Conv1d)以及重新排列(Reshape)的流程;对于 GAP 的特征,同样会先经过重新排列(Reshape)和 1D 卷积(Conv1d),只不过 GAP 的特征不再做重新排列而是做反池化(UNAP)操作。其次,经过上述流程 GAP 的特征和 LAP 的特征会进行“加法”操作,实现全局特征融合。最后,融合特征再次进行反池化操作后与原始输入的特征进行“乘法”运算,将空间维度恢复至原始状态。1D 卷积核的大小 k 与特征通道数 C 成正比,其计算公式为:

$$k = \left\lfloor \frac{\log_2 C}{\gamma} + \frac{b}{\gamma} \right\rfloor_{odd} \quad (1)$$

式中:γ 和 b 都是线性参数,odd 表示 k 只能是奇数(倘若 k

为偶数,就在  $k$  现有值的基础上加 1)。

基于前述思路,本文创新性地设计了 C2f\_MP 模块,其详细结构如图 5 所示。其核心改进在于:在 C2f 模块的首个卷积层(Conv)后嵌入 MLCA 模块。该模块通过整合输入特征图的通道维度、空间上下文、局部通道关系及全局通道依赖,显著强化了管道油液滴漏的细微特征表达能力,降低了计算的复杂性;采用 PBlock 结构替代原生 Bottleneck 模块,再次引入 PConv 模块克服参数共享机制的特征提取局限,显著增强管道油液滴漏目标的特征提取能力,尤其优化了其小尺度特征的代表效能。该设计同步降低了计算复杂度与内存访问量,有效提升了网络运行效率,更加适合实际工程应用的部署。

### 2.3 引入 EMA 注意力机制模块

海上平台管道油液滴漏呈现非刚性特质,其形态、亮




图 5 C2f\_MP 结构

Fig. 5 Structure of C2f\_MP

度及尺度存在显著不确定性,并蕴含丰富细节特征。此类特性对目标检测模型的特征提取、融合与分类等过程构成严峻挑战。除此之外,海上平台周围环境复杂,工业相机拍摄的视频图像可能存在尘雾干扰、强光干扰以及分辨率低等问题。引入注意力机制可强化算法对管道滴漏关键区域的聚焦能力,通过动态权重分配来抑制背景带来的干扰,显著提升算法的检测精度与鲁棒性。

高效多尺度注意力机制 (efficient multi-scale attention module, EMA)<sup>[17]</sup> 是一个高效、可推广的注意模块,与 CBAM、NAM、SA、ECA 以及 CA 等注意力机制模块相比,EMA 不仅取得了更好的结果,而且在所需参数方面更高效。应用于海上平台管道油液滴漏场景中,模型可以通过 EMA 可以在复杂背景下准确区分和识别目标,充分挖掘小尺寸或受遮挡检测目标的丰富特征,能够显著提升模型在特征提取方面的能力,进而提高了整体的检测性能。

EMA 的结构如图 6 所示。2 条  $1 \times 1$  分支同时处理输入特征图,分别对输入特征图的  $X$  和  $Y$  通道执行一维全局平均池化编码,然后将编码结果拼接后送入同一个的  $1 \times 1$  卷积层。该层会先保持通道维度不变,其输出也会被拆分为两个向量,再经过 Sigmoid 函数对这两向量做非线性映射处理,它们就会生成线性卷积所对应二维 2 进制分布。最终,融合  $X$  和  $Y$  两个通道的注意力图,由于  $3 \times 3$  分支具有  $3 \times 3$  卷积核,使得其能够进一步提取特征图里面的多尺度特征,扩展了特征图的特征空间。

为了得到更加优良的特征聚合效果,EMA 通过引入  $1 \times 1$  支路和  $3 \times 3$  支路的输出信息以达到更好的融合效

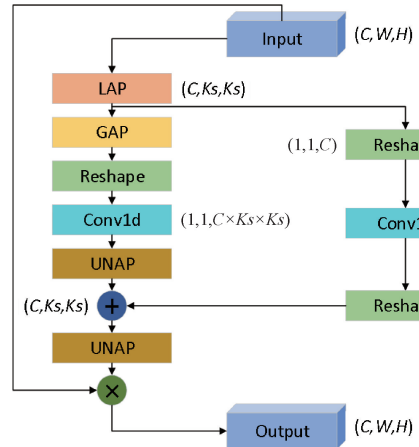


图 4 MLCA 结构

Fig. 4 Structure of MLCA

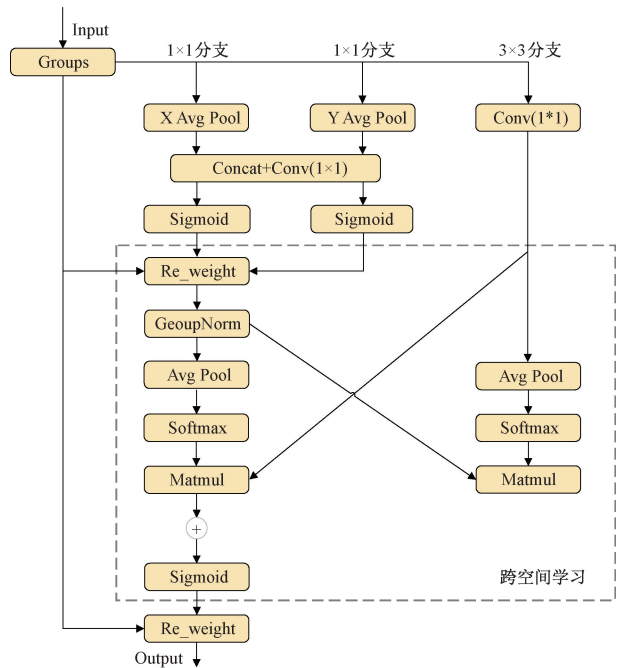


图 6 EMA 结构

Fig. 6 Structure of EMA

果。该算法在  $1 \times 1$  分支中执行 2D 全局平均池化,编码特征图的空间全局信息,同时将最小分支输出直接投影至目标维度。池化操作计算如式(2)所示。

$$z_c = \frac{1}{h \times w} \sum_i^h \sum_j^w x_c(i, j) \quad (2)$$

式中:  $Z_c$  是输出特征图在通道  $c$ 、坐标点为  $(i, j)$  处的值;  $x_c(i, j)$  是输入特征图在通道  $c$ 、坐标点为  $(i, j)$  处的值。

综上, EMA 模块具有并行的卷积核结构和跨空间学习的机制, 使其能够有效解决神经网络计算时的短时相关性与长时依赖性, 还能显著提升神经网络的表征力与泛化性。将该模块引入本文改进 YOLOv8 模型, 可增强管道油液滴漏特征的识别精度。

### 2.4 EP\_Detect 检测头模块

检测头是 YOLOv8 模型的核心组件之一, 它具有高效的多尺度解耦结构和深入的空间特征提取能力, 并且这部分的总浮点运算量较大, 占据了模型的 41.0%。此检测头为了针对不同分辨率的特征图, 设计了 3 个独立的检测头, 从而实现了对大、中、小目标的精确检测, 其检测头结构如图 7 所示。每个检测头都利用两个  $3 \times 3$  卷积层和后续的  $1 \times 1$  卷积层, 这使得检测头的特征表征和检测精度都得到了优化。但是, 这也增加了此模型参数量和计算量, 不利于轻量化部署。




图 7 Detect 结构

Fig. 7 Structure of Detect

为了提高检测头特征融合网络中的特征提取能力和检测速度, 与此同时降低模型计算量并实现轻量化<sup>[18]</sup>。本文在原有结构的基础上, 提出了一种新的检测头结构 EP\_Detect, 通过参数共享的方法, 将原本两个分支上的 4 个普通卷积整合到单分支中, 这样处理后单分支只需两个普通卷积, 最后将这两个普通卷积替换成 PConv。改进后的检测头结构如图 8 所示, 它预测以及分类的状态仍然是解耦的, 能够有效提升算法精度同时降低网络结构冗余, 实现轻量且高效的检测网络<sup>[19]</sup>。




图 8 EP\_Detect 结构

Fig. 8 Structure of EP\_Detect

### 2.5 增加小目标检测层

YOLOv8 的小目标检测层是为了解决检测小目标时可能出现的识别精度低的问题。小目标是指检测目标中低分辨率和小尺寸的部分, 基本的 YOLOv8 的 Head 部分一共有 3 个检测头, 它们分别负责检测目标小、中、大尺度的部分, 其对应的颈部特征图大小依次是  $80 \times 80$ 、 $40 \times 40$ 、

$20 \times 20$ 。在海上平台管道滴漏场景中, YOLOv8 对较小的油液滴漏的检测依然存在着漏检误检的情况。除此之外, YOLOv8 Neck 的浅层特征蕴含丰富的小目标信息, 其利用尚不充分, 为了解决这一问题, 我们在原始网络的基础上引入了一个由上采样与特征拼接操作生成的  $160 \times 160$  融合特征图, 用来提取分辨率在  $8 \times 8$  以下的图像, 提高了检测小目标油液滴漏的准确性。

### 2.6 改进损失函数

海上平台管道油液滴漏检测环境复杂性导致自制数据集呈现样本难度分布波动性大, 且非刚性目标特性致使标注框质量存在固有不确定性。YOLOv8 的边界框回归默认基于 CIoU 损失函数进行优化, 但 CIoU 训练模型识别此场景却存在以下问题: 一方面, 针对普通油液滴漏和小目标油液滴漏, 难以兼顾样本数目的均衡问题, 导致小目标油液滴漏样本的识别效果不如普通油液滴漏; 另一方面, 针对标注质量低的样本有一定的局限性, 使得训练的模型效果不佳。因此, 该文将 CIoU 替换为 WIoU 损失函数<sup>[20]</sup>, WIoU 自身具有权重因子这一参数, 可以将油液滴漏特征差别大的数据集样本赋予更为适合的权重, 从而抑制了一部分低质量样本的不良梯度影响, 使得海上平台智能巡检场景下管道油液滴漏目标预测框高效精准的回归, 实现模型的训练效果大幅提升。WIoU 损失函数通过动态聚焦机制自适应调整锚框梯度分布, 均衡不同质量数据集样本的损失权重, 显著抑制小目标管道油液滴漏数据带来的干扰影响。

$$L_{wIoU} = rR_{wIoU}L_{IoU} \quad (3)$$

$$r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \quad (4)$$

式中:  $r$  为非单调焦点因子;  $L_{wIoU}$  为动态损失函数;  $L_{IoU}$  为边界框损失;  $\delta$  和  $\alpha$  分别为梯度增益因子和学习系数;  $\beta$  为离群度;  $R_{wIoU}$  为权重系数惩罚项。

$$R_{wIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \quad (5)$$

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \quad (6)$$

式中: 真实矩形框的中心位置坐标是  $(x_{gt}, y_{gt})$ ; 预测矩形框的中心位置坐标是  $(x, y)$ ;  $H_g$  和  $W_g$  分别为由预测框和真实框围成的矩形框的高度和宽度;  $L_{IoU}^*$  为预测框和真实框之间的交并比阈值;  $\overline{L_{IoU}}$  为边界框损失的均值。

## 3 实验结果与分析

### 3.1 实验平台与环境配置

实验计算机的操作系统是 Windows11, GPU 型号是 NVIDIA GeForce RTX 4060Ti, CPU 的型号是 i5-12600KF, 依托的深度学习框架是 PyTorch, 依托的编译器版本是 Python3.11, 搭配的 CUDA 版本是 11.8。改进模型训练的参数设置如表 1 所示。

表1 改进模型训练的参数

Table 1 Parameters for improving model training

参数名称	数值
训练轮次 (epochs)	200
批次 (batch)	16
学习率 (lr)	0.01
优化器 (optimizer)	SGD
正则化系数 (weight_decay)	0.0005

### 3.2 数据集与评价指标

从某两个海上平台选取多角度、不同光照条件下的管道附近进行油液滴漏模拟,通过视频图像采集模块将现场的监控视频进行预处理并制作数据集,一共得到了7000余张图片,然后按7:1.5:1.5的比例划分为训练集、测试集和验证集。该数据集主要针对油液滴漏的形态尺度多样、遮挡、光照不均以及小目标等场景,最终得到了海上平台管道油液滴漏检测专有的数据集,数据集部分样本如图9所示。




图9 数据集部分样本展示

Fig. 9 Sample display of some datasets

该模型以精度  $P$  (precision)、召回率  $R$  (recall)、IoU 为 0.5 时的平均精度  $mAP@0.5$  (mean average precision) 以及 IoU 从 0.5 到 0.95, 步长为 0.05 上的平均精度  $mAP@$

0.5:0.95 作为评价模型性能的指标, $P$ 、 $R$  以及  $mAP@0.5$  表达式如式(7)~(9)所示。

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

式中: $P$  表示正确检测的阳性样本占有所有预测为阳性样本的比例。 $TP$  (true positive) 是指正确识别到的阳性样本数量; $FP$  (false positive) 是指将阴性样本误判为阳性的数量。

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

式中: $R$  表示正确检测的阳性样本占有所有真正为阳性样本的比例。 $FN$  (ture negative) 是指错误把阳性样本标记为阴性样本的数量, $TP$  与式(7)相同。

$$\begin{cases} AP = \int_0^1 PR dR \\ mAP = \frac{1}{n} \sum_{i=1}^n AP_i \end{cases} \quad (9)$$

式中: $mAP$  是指在所有类别上计算的  $AP$  的平均值, $AP$  为单个类比的平均检测精度。该指标越高,表明模型检测的效果越好。

### 3.3 消融实验

本研究采用消融实验评估 YOLOv8s 基线模型上各改进模块的有效性。在统一数据集和软硬件配置下,依次引入各模块并评估性能,如表2所示。结果显示,单独加入任一模块均能提升  $mAP@0.5$  以及  $mAP@0.5:0.95$ ,证实了各模块添加的有效性。C2f\_MP 模块将检测精度较基线模型提升了 2.0%,提升效果显著,验证了融合了 MLCA 注意力机制 Pconv 的 C2f 结构可以更好提取海上平台场景下管道滴漏目标的微小特征,同时也能有效抑制由光照、尘雾等背景因素造成的干扰。EMA 模块的加入,精度显著提升 1.8%、 $mAP@0.5$  提升 1.6%、 $mAP@0.5:0.95$  也提升了 1.5%,主要是因为 EMA 可以在复杂背景下准确区分和识别目标,使模型更好解决目标遮挡问题。EP\_Detect 有明显效果,改进后的  $mAP@0.5$ 、 $mAP@0.5:0.95$  和召回率相较于基线模型精度分别提高了 1.8%、1.9% 和 2.0%,说明了增加小目标检测头能够显著增强模

表2 改进YOLOv8模型消融实验结果

Table 2 Results of ablation experiments of improved YOLOv8 model

C2f_MP	EMA	EP_Detect	WIoU	P/%	R/%	$mAP@0.5$ /%	$mAP@0.5:0.95$ /%
×	×	×	×	95.6	92.3	96.4	67.6
√	×	×	×	97.6	94.5	98.1	69.3
×	√	×	×	97.4	94.7	98.0	69.1
×	×	√	×	97.3	94.3	98.2	69.5
×	×	×	√	97.2	94.6	98.1	69.2
√	√	×	×	<b>98.1</b>	94.8	98.3	70.5
√	√	√	×	97.7	95.1	98.5	71.6
√	√	√	√	97.9	<b>95.4</b>	<b>98.8</b>	<b>72.1</b>

型对特征的特征能力,提高检测小目标的精度。引入 WIoU 损失函数后,模型性能得到均衡改善,精度得到了 1.6% 的增长,召回率实现 2.3% 的提升,mAP@0.5 则提高了 1.7%。

尽管组合引入模块时它们间存在干扰现象,但改进模型 YOLOv8 在精度、召回率以及平均检测精度等方面都有显著的提升。C2f\_MP 模块加入 YOLOv8s 增强了对油液滴漏细节特征的提取能力,精度、召回率、mAP@0.5 以及 mAP@0.5:0.95 都得到了显著的提升。EMA 模块的加入增强了模型在复杂背景下对油液滴漏目标的检测,同时也提升了对小目标油液滴漏特征的关注度,精度和召回率均实现 2.5% 的增长、mAP@0.5 获得 1.9% 的提升,mAP@0.5:0.95 也得到了 2.9% 的提升。引入 EP\_Detect 结构有效改善了模型对于油液滴漏小目标检测的精度,结合 C2f\_MP 模块,模型对于小目标油液滴漏的表征能力再次显著提升,相较于 YOLOv8s 基线模型,精度得到了 2.1% 的增长,召回率提升 2.8%,mAP@0.5 提高 2.1%,且 mAP@0.5:0.95 也提升 4.0%。WIoU 能够有效处理难易样本和样本数量的不平衡问题,抑制其极端影响,模

型的训练效果因此得到了提升。如表 2 所示,加入改进的损失函数 WIoU 后,精度、召回率、mAP@0.5 以及 mAP@0.5:0.95 都得到了显著提升,分别提高 2.3%、3.1%、2.4% 以及 4.5%。总之,改进 YOLOv8 模型有效地提升了核心性能指标,且整体融合后油液滴漏检测效果最优,验证了其对于海上平台管道油液滴漏目标识别检测能力的显著提升,能够满足海上平台管道油液滴漏目标实时检测识别的要求。

为了进一步验证改进 YOLOv8 模型的效果,本文用基线模型 YOLOv8s 与改进模型进行热力图对比分析,其对比结果如图 10 所示。热力图的对比场景选自海上某平台管道周围容易发生油液滴漏的位置,其中场景 1 代表视角良好无遮挡油液滴漏场景,场景 2 代表小目标油液滴漏场景,场景 3 代表多尺度油液滴漏场景,场景 4 代表尘雾干扰油液滴漏场景,场景 5 代表光照不均油液滴漏场景。由场景 1 热力对比图可以看出:在摄像头视角良好,背景对比鲜明,油液尺度差异小且无遮挡的场景下,本文改进模型相比于基线模型对油液滴漏特征的关注度更优;由场景 2 的热力对比图可以得出,基线模型对于小目标油液滴漏出

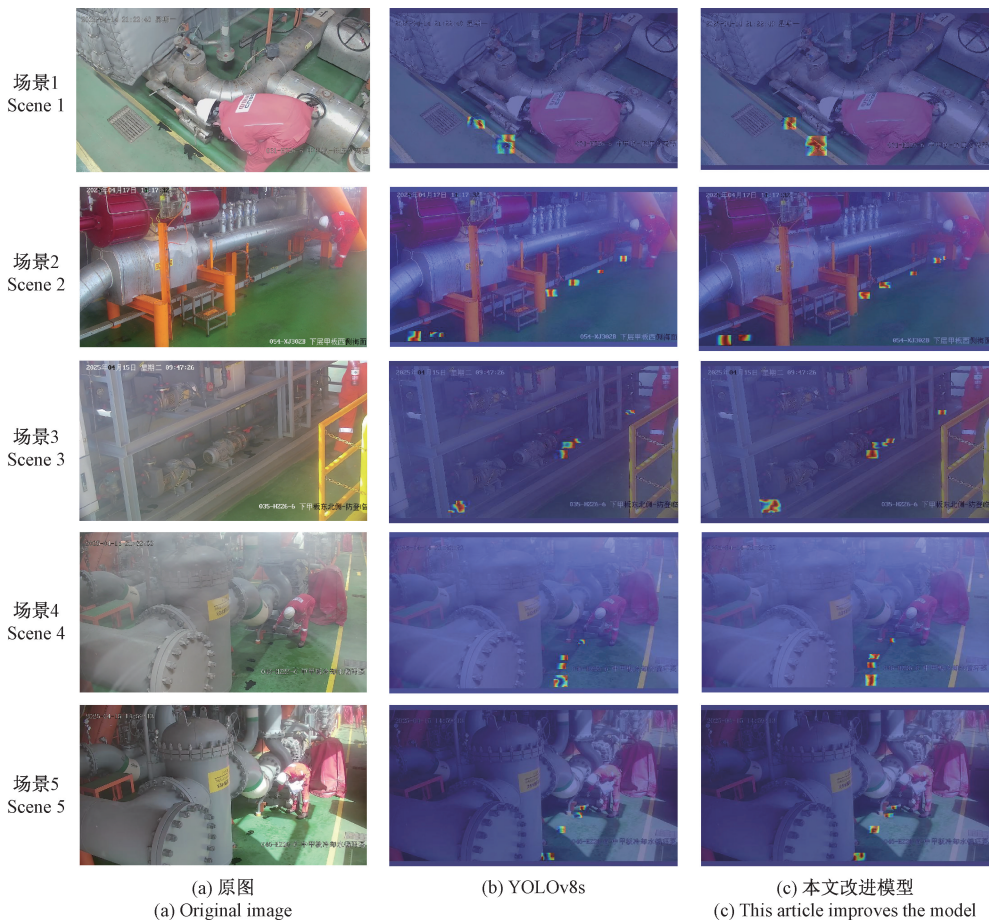


图 10 改进 YOLOv8 热力图对比

Fig. 10 Comparison of improved YOLOv8 heat maps

现漏检,原因是基线模型缺乏对小目标油液滴漏的关注度,改进模型避免了此类问题,能够精准识别到小目标油液滴漏。由场景 3 的热力对比图可以看出,对于多尺度油液滴漏,改进模型相比于基线模型对于油液滴漏特征的关注度更加均衡,抗干扰能力也更强。由场景 4 和 5 中的热力对比图可以看出,无论是在尘雾干扰背景下,还是在光照不均背景下,改进模型对于油液滴漏特征的提取更充分,油液滴漏特征整体的关注度也更高,具有更优良的检测效果。

### 3.4 对比实验

实验设计包含改进 YOLOv8 与 YOLOv5m、YOLOv8n、YOLOv8s-SPDCConv、YOLOv10s 的对比,旨在验证前者的优越性,结果如表 3 所示。其中 YOLOv8s-SPDCConv 是通过将 YOLOv8s 的普通卷积替换为 SPDCConv 实现改进,其针对小

目标的优异性能已获广泛验证<sup>[21]</sup>。如表 3 所示,改进 YOLOv8 模型的精度、召回率、mAP@0.5 以及 mAP@0.5:0.95 在所有对比模型中均领先。具体而言:改进 YOLOv8 模型精度达到了 97.9%,较 YOLOv5m、YOLOv8n、YOLOv8s-SPDCConv 和 YOLOv10s 分别提升 3.5%、3.4%、1.8% 和 1.7%;召回率较对比模型分别提高 4.2%、3.7%、2.3% 和 1.1%;mAP@0.5 较相同对比模型分别提升 3.4%、2.9%、2.0% 和 2.3%;mAP@0.5:0.95 较相同对比模型分别提高 5.4%、4.8%、2.9% 和 1.3%。检测速度为 118 帧/s,较 YOLOv5m、YOLOv8n、YOLOv8s-SPDCConv 和 YOLOv10s 分别降低 28、80、66 和 9 帧/s,表明其速度表现有待优化,其主要原因是改进模型增加了小目标检测头导致颈部网络层数增加,进而 FPS 有所下降,但是并不影响海上平台管道油液滴漏检测的实时性。

表 3 改进 YOLOv8 模型与其他模型对比实验结果

Table 3 Experimental results of the improved YOLOv8 model compared with other models

模型	P/%	R/%	mAP@0.5%	mAP@0.5:0.95%	FPS
YOLOv5m	94.4	91.2	95.4	66.7	146
YOLOv8n	94.5	91.7	95.9	67.3	<b>198</b>
YOLOv8s-SPDCConv	96.1	93.1	96.8	69.2	184
YOLOv10s	96.2	94.3	96.5	70.8	127
改进 YOLOv8	<b>97.9</b>	<b>95.4</b>	<b>98.8</b>	<b>72.1</b>	118

为了更加直观的验证改进 YOLOv8 油液滴漏的检测效果,该对比试验采用同一数据集,对比了 YOLOv5m、YOLOv8n、YOLOv10s、YOLOv8s-SPDCConv 及改进 YOLOv8 油液滴漏检测的效果,实验结果如图 11 所示。该对比实验选取了某海上平台管道油液滴漏比较经典的 6 个场景:场景 1 为密集油液滴漏目标检测识别场景,场景 2 为油液滴漏遮挡目标检测识别场景,场景 3 为油液滴漏小目标识别场景,场景 4 为背景偏暗下油液滴漏多尺度目标检测识别场景,场景 5 为尘雾干扰下油液滴漏目标检测识别场景,场景 6 为光照不均条件下油液滴漏目标检测识别场景。由场景 1 可以看出:尽管所有模型均为出现油液滴漏目标漏检误检情况,但改进 YOLOv8 模型相比于其他模型在密集油液滴漏目标的检测中整体置信度高很多;由场景 2 可以看出:YOLOv5m、YOLOv8n 以及 YOLOv8s-SPDCConv 出现了遮挡油液滴漏目标漏检的情况;由场景 3 可以看出:YOLOv5m、YOLOv8n 以及 YOLOv10s 出现了小目标油液滴漏漏检的情况;由场景 4 可以看出:YOLOv5m 以及 YOLOv10s 出现了多尺度油液滴漏目标漏检的情况;由场景 5 可以看出:在尘雾干扰下,出改进 YOLOv8 模型外,其他模型均出现误检情况;由场景 6 可以看出:在光照不均的情况下,YOLOv5m、YOLOv8n 以及 YOLOv10s 均出现将场景中阴影误检为油液滴漏目标,而改进 YOLOv8 模型并未出现误检问题。

总而言之,改进 YOLOv8 模型在处理油液滴漏位置角度欠佳、小目标油液滴漏以及油液滴漏部分被遮挡等情况效果更好,在各个场景的多视角油液滴漏检测下无误检和漏检的情况发生,整体的检测置信度更高,可有效应对海上平台管道油液滴漏检测复杂多变的环境,检测速度也能够达标。

### 3.5 海上某平台管道油液滴漏识别实验

为分析基于改进 YOLOv8 的海上平台智能视频巡检系统的有效性,现选用某海上平台实际的管道附近监控视频进行油液滴漏识别实验。首选在该平台上容易发生管道油液滴漏的地方进行人为模拟并进行实时监控,然后从多个视角下的实时监控视频中选取素材,划分为 3 个实验组(帧数分别为 2 648、1 639 和 867 帧)。表 4 详细展示了各组油液滴漏的检测结果,经综合计算,得到系统平均识别准确率达到 96.25%。3 组油液滴漏检测实验的结果如图 12 所示,从中可以得到油液大小、背景复杂程度以及摄像头角度等因素是影响油液滴漏识别检测效果优劣的关键。实验组 1 区域摄像头位置良好、油液滴漏与背景对比鲜明,所以其油液滴漏识别的准确率是 3 组中最高的。实验组 2 场景中存在遮挡和光照不均等现象,加之摄像头角度欠佳,油液滴漏识别效果相对较差,所以检测的准确率相比于实验组 1 与实验组 3 较低一些。





图 11 各模型油液滴漏识别结果对比

Fig. 11 Comparison of oil drip identification results of each model


表 4 油液滴漏检测结果统计

Table 4 Statistics of oil drip detection results

组别	油液滴漏数量	识别滴漏数量	准确率/%
1 组	2 648	2 588	97.73
2 组	1 639	1 556	94.94
3 组	867	833	96.08



(a) 1组检测结果  
(a) Group 1 test results



(b) 2组检测结果  
(b) Group 2 test results



(c) 3组检测结果  
(c) Group 3 test results

图 12 油液滴漏检测结果

Fig. 12 Oil drip detection results

## 4 结 论

基于消融实验证明了各个模块的改进效果:C2f\_MP模块、EMA模块、WiO函数、EP\_Detect检测头以及小目标检测头的添加对海上平台管道油液滴漏检测的mAP@0.5分别提高了1.7%,1.6%,1.8%,1.7%。通过组合各个模块并融入基线模型形成改进YOLOv8模型,相比于基线模型YOLOv8s,其对油液滴漏特征的提取能力得到了提升,精度得到了2.3%的提升,帧率实现118帧/s,虽相比于基线模型帧率有所下降,但仍能够满足实时检测的要求;基于对比实验的结果表明:改进YOLOv8模型对于油液滴漏检测识别的整体效果最好,对海上平台管道油液滴漏多个场景都有很好的识别效果,没有出现漏检误检的情况,识别精度达97.9%;海上某平台管道油液滴漏识别实验结果表明:基于改进YOLOv8模型的油液滴漏识别方法实现了海上平台管道油液滴漏的准确判别,平均识别准确率为96.25%。

## 参考文献

- [1] BAI C, ZHANG K, JIN H, et al. SFFEF-YOLO: Small object detection network based on fine-grained feature extraction and fusion for unmanned aerial images [J]. *Image and Vision Computing*, 2025, 156, 105469.
- [2] HONG J, YE K, QIU S. Study on lightweight strategies for L-YOLO algorithm in road object detection[J]. *Scientific Reports*, 2025, 15(1):7649.
- [3] ZHANG H, LIANG M, WANG Y. YOLO-BS: A traffic sign detection algorithm based on YOLOv8[J]. *Scientific Reports*, 2025, 15(1):7558.
- [4] MA Q, FAN X, CHEN H, et al. IRE-YOLO: Infrared weak target detection algorithm based on the fusion of multi-scale receptive fields and efficient convolution[J]. *The Journal of Supercomputing*, 2025, 81(4): 558.
- [5] 王浚银,文斌,沈艳军,等.基于改进YOLOv7-tiny的铝型材表面缺陷检测方法[J]. *浙江大学学报(工学版)*, 2025, 59(3):523-534.  
WANG J Y, WEN B, SHEN Y J, et al. Surface defect detection method for aluminum profiles based on improved YOLOv7-tiny [J]. *Journal of Zhejiang University (Engineering and Technology Edition)*, 2025, 59(3):523-534.
- [6] 张弛,游浩,高谦,等.基于改进YOLOv8算法的密集型小目标检测[J]. *软件导刊*, 2025, 24(8):196-200.  
ZHANG CH, YOU H, GAO Q, et al. Intensive small object detection based on improved YOLOv8 algorithm[J]. *Software Guide*, 2025, 24(8):196-200.
- [7] 方伟,张亚.基于改进YOLOv8s的无人机航拍图像小目标检测算法[J]. *兰州工业学院学报*, 2025, 32(1): 82-88.
- [8] FANG W, ZHANG Y. Small object detection algorithm for UAV aerial images based on improved YOLOv8s [J]. *Journal of Lanzhou Institute of Technology*, 2025, 32(1):82-88.
- [8] 冯茂胜,付明雨,姚泽圆,等.基于改进YOLOv8的轨道小尺度异物入侵算法研究[J]. *现代电子技术*, 2025, 48(11):174-179.  
FENG Q SH, FU M Y, YAO Z Y, et al. Research on orbital small-scale foreign object invasion algorithm based on improved YOLOv8[J]. *Modern Electronics Technology*, 2025, 48(11):174-179.
- [9] 程鲲,雷洪涛,吕志轩.改进YOLOv8轻量级网络的无人机跟踪方法[J/OL]. *系统工程与电子技术*, 1-15 [2025-06-06]. <https://link.cnki.net/urlid/11.2422.TN.20250521.1742.009>.  
CHENG K, LEI H G, LYU ZH X. Improving the UAV tracking method of YOLOv8 lightweight network[J/OL]. *Systems Engineering and Electronic Technology*, 1-15 [2025-06-06]. <https://link.cnki.net/urlid/11.2422.TN.20250521.1742.009>.
- [10] 苗作华,周浩,王巧稚,等.改进YOLOv8n的矿井火灾检测算法[J]. *矿业研究与开发*, 2025, 45(5):200-206.  
MIAO Z H, ZHOU H, WANG Q ZH, et al. Mine fire detection algorithm for improving YOLOv8n[J]. *Mining Research and Development*, 2025, 45(5): 200-206.
- [11] 毛清华,苏毅楠,贺高峰,等.基于改进YOLOv8模型的井下人员入侵带式输送机危险区域智能识别[J]. *工矿自动化*, 2025, 51(1):11-20,103.  
MAO Q H, SU Y N, HE G F, et al. Intelligent identification of dangerous areas of underground personnel invasion belt conveyor based on improved YOLOv8 model [J]. *Journal of Mine Automation*, 2025, 51(1):11-20,103.
- [12] VARGHESE R, SAMBATH M. YOLOv8: A novel object detection algorithm with enhanced performance and robustness[C]. *2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS)*. IEEE, 2024: 1-6.
- [13] CHEN J, KAO S H, HE H, et al. Run, don't walk: Chasing higher FLOPs for faster neural networks[C]. *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE, 2023: 12021-12031.
- [14] 景会成,鲍成明.基于改进YOLOv12的铝型材工件缺陷检测技术研究[J]. *电子测量技术*, 2026, 49(1):

- 216-225.
- JING H CH, BAO CH M. Research on defect detection technology for aluminum profile workpieces based on improved YOLOv12[J]. Electronic Measurement Technology, 2026, 49(1): 216-225.
- [15] SU Q, MU J. Complex scene occluded object detection with fusion of mixed local channel attention and multi-detection layer anchor-free optimization[J]. Automation, 2024, 5(2): 176-189.
- [16] 费春国, 陈世洪. 融合先验掩膜与 YOLOv8 的 FOD 检测方法研究[J]. 电子测量技术, 2026, 49(2): 65-78.
- FEI CH G, CHEN SH H. Research on FOD detection method integrating prior masks and YOLOv8 [J]. Electronic Measurement Technology, 2026, 49(2): 65-78.
- [17] OUYANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning[C]. 2023 IEEE International Conference on Acoustics, Speech and Signal Processing. Rhodes Island, Greece: IEEE, 2023: 1-5.
- [18] 胥姜苗, 曹爽, 管海燕. 基于改进 YOLOv8 的轻量化钢材表面缺陷检测方法[J]. 电子测量技术, 2025, 48(24): 138-147.
- XU J M, CAO SH, GUAN H Y. A lightweight steel surface defect detection method based on improved YOLOv8 [J]. Electronic Measurement Technology, 2025, 48(24): 138-147.
- [19] 贾亮, 陈茂辉, 王琪, 等. 改进 YOLOv8n 的航拍多尺度目标检测模型[J]. 电子测量技术, 2026, 49(1): 237-246.
- JIA L, CHEN M H, WANG Q, et al. An aerial multi-scale object detection model based on improved YOLOv8n[J]. Electronic Measurement Technology, 2026, 49(1): 237-246.
- [20] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[J]. ArXiv preprint arXiv:2301.10051, 2023.
- [21] 谢莉, 耿俊杰, 兰倩, 等. 面向寄生虫卵显微图像的轻量化目标检测模型 [J]. 计算机应用, 2025, 45(S2): 270-277.
- XIE L, GENG J J, LAN Q, et al. Lightweight target detection model for parasitic egg microscopic images[J]. Computer Applications, 2025, 45(S2): 270-277.

### 作者简介

**杨金丽**, 高级工程师, 主要研究方向为海上油气田通信与智能化设计。

E-mail: yangjl4@cnooc.com.cn

**李伟**, 硕士研究生, 主要研究方向为机器视觉、海上平台目标检测、深度学习。

E-mail: 2098716007@qq.com

**顾继俊**(通信作者), 教授, 博士研究生, 主要研究方向为高端油气装备智能设计与检测监测技术。

E-mail: gu@cup.edu.cn