



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于改进YOLOv7的火电厂管道及阀门泄漏分割与检测

彭道刚, 陈晨, 王丹豪, 潘俊臻

引用本文:

彭道刚, 陈晨, 王丹豪, 潘俊臻. 基于改进YOLOv7的火电厂管道及阀门泄漏分割与检测[J]. *控制与决策*, 2024, 39(9): 2977–2986.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.0592>

您可能感兴趣的其他文章

Articles you may be interested in

多目标小尺度车辆目标检测方法

Multi-target and small-scale vehicle target detection method

控制与决策. 2021, 36(11): 2707–2712 <https://doi.org/10.13195/j.kzyjc.2020.0635>

一种基于多层语义特征的图像理解方法

An image understanding method based on multi-level semantic features

控制与决策. 2021, 36(12): 2881–2890 <https://doi.org/10.13195/j.kzyjc.2020.0927>

复杂背景下全景视频运动小目标检测算法

Panoramic video motion small target detection algorithm in complex background

控制与决策. 2021, 36(1): 249–256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

基于MobileNet的多目标跟踪深度学习算法

Deep learning algorithm based on MobileNet for multi-target tracking

控制与决策. 2021, 36(8): 1991–1996 <https://doi.org/10.13195/j.kzyjc.2019.1424>

基于自注意力生成对抗网络的图像超分辨率重建

Image super-resolution reconstruction based on self-attention GAN

控制与决策. 2021, 36(6): 1324–1332 <https://doi.org/10.13195/j.kzyjc.2019.1290>

基于改进YOLOv7的火电厂管道及阀门泄漏分割与检测

彭道刚^{1†}, 陈晨¹, 王丹豪², 潘俊臻¹

(1. 上海电力大学 自动化工程学院, 上海 200090; 2. 上海电力大学 电气工程学院, 上海 200090)

摘要: 火电厂关键区域的管道、阀门等设备时常发生油液、蒸汽等物质的泄漏故障。为了提高火电厂管道及阀门泄漏故障的分割与检测精度, 加快模型推理速度, 提出一种基于改进YOLOv7的火电厂管道及阀门泄漏分割与检测算法, 通过在YOLOv7网络中加入相关实例分割模块, 实现实例分割与目标检测任务的并行; 通过融入极化自注意力机制和可分离的视觉深度自注意力模块(separable vision transformer), 弱化复杂背景的干扰, 强化对泄漏区域的边缘提取; 在后处理阶段运用置信度传播簇机制(confidence propagation cluster, CP-cluster), 提高模型定位的准确性; 在颈部网络使用幽灵卷积降低特征冗余, 并通过通道剪枝技术压缩模型, 实现模型轻量化。实验结果表明, 在加入各项改进后, 算法分割任务与检测任务的mAP@0.5:0.95指标分别达到75.7%、82.2%, 相较于基础模型, 指标分别提高了11.9%、7.1%, 且模型参数量减少了30.3%, 可有效地应用于电厂的实际生产环境中。

关键词: 泄漏检测; 实例分割; 目标检测; 自注意力机制; 置信度传播簇机制; 通道剪枝

中图分类号: TP391

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.0592

引用格式: 彭道刚, 陈晨, 王丹豪, 等. 基于改进YOLOv7的火电厂管道及阀门泄漏分割与检测[J]. 控制与决策, 2024, 39(9): 2977-2986.

Leakage segmentation and detection of pipelines and valves in thermal power plants based on improved YOLOv7

PENG Dao-gang^{1†}, CHEN Chen¹, WANG Dan-hao², PAN Jun-zhen¹

(1. College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China; 2. College of Electrical Power Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: Equipment such as pipelines and valves in key areas of thermal power plants often experience leakage faults of substances such as oil and steam. In order to improve the segmentation and detection accuracy of pipelines and valves leakage faults in thermal power plants and accelerate model inference speed, a pipeline and valve leakage segmentation and detection algorithm in thermal power plants based on the improved YOLOv7 is proposed. By adding relevant instance segmentation modules to the YOLOv7 network, the parallelization of instance segmentation and target detection tasks are achieved. By integrating polarized self-attention mechanism and separated vision transformer modules, the interference of complex backgrounds is weakened, the edge extraction of the leakage area is strengthened. Then, in the post-processing stage, the CP-cluster (confidence propagation cluster) mechanism is applied to improve the accuracy of model localization; Finally, Ghostconv is used in the neck network to reduce feature redundancy, and the model is compressed by channel pruning technology to achieve lightweight model. The experimental results show that after adding various improvements, the mAP@0.5:0.95 of the algorithm's segmentation task and detection task reach 75.7% and 82.2%, respectively, which increase by 11.9% and 7.1% compared to the basic model, and the model parameter decreases by 30.3%. The model can be effectively applied in the actual production environment of power plants.

Keywords: leakage detection; instance segmentation; object detection; self-attention mechanism; CP-cluster mechanism; channel pruning

0 引言

火力发电厂安全、可靠地运行对于国家能源安全和民生保障有着至关重要的意义。火力发电厂生

产工序众多、工艺复杂, 各类管道、阀门等设备在恶劣工况下长期运行, 容易出现油液、蒸汽等工质的跑冒滴漏故障, 此类故障可能导致重大安全事故。因此, 准

收稿日期: 2023-05-05; 录用日期: 2023-09-07.

基金项目: 上海市“科技创新行动计划”高新技术领域项目(21511101800).

责任编委: 赵春晖.

[†]通讯作者. E-mail: pengdaogang@126.com.

确且快速地识别出管道、阀门等关键设备出现的蒸汽、油液等工质泄漏,并分割划定出泄漏的影响范围,对于电厂安全运行具有重大的实际意义.基于此,大量专家学者围绕管道缺陷检测、气体及液体泄漏检测开展了大量研究. Su等^[1]提出了一种基于边缘检测的形态学分割方法,用于提取管道缺陷的特征; Wu等^[2]利用轮廓波变换和最大响应滤波器组来提取管道缺陷的特征,只需少量数据即可完成管道裂缝缺陷的分类;赵苓等^[3]通过红外图像技术来检测气体泄漏,其利用改进的双边滤波算法,结合目标的点源扩散性提取出气体的泄漏位置; Fahimipirehgalin等^[4]提出了一种基于主成分分析法和 K -最邻近法的泄漏液滴的分类方法,可用于提取视频帧内泄漏液滴的特征并完成分类.以上这些基于传统机器视觉的检测模型过度依赖于泄漏特征参数的选择及特征提取器的设计,模型的泛化能力及稳定性较差^[5],难以适应电厂复杂多变的背景信息,检测的准确度及稳定性较低,不利于电厂进行多场景的泄漏检测.

随着深度学习技术的快速发展,部分专家学者将其引入到泄漏检测中. Lyu等^[6]提出了一种基于Vibe算法和EfficientNetB0模型的视觉早期泄漏检测系统,可以对半透明、微小的液体泄漏目标进行较好的判别; Melo等^[7]通过卷积神经网络完成天然气泄漏故障的图像分类工作,并将泄漏区域通过Grad-CAM进行可视化的解释.基于深度学习的检测方法虽然在泛化能力及稳定性上有所提高,但其只能定性地判断出图像中是否存在泄漏异常的发生,无法准确地标记出工质的泄漏位置及泄漏区域的边缘轮廓.另外,上述泄漏识别算法都只能针对某一类物质的泄漏进行识别,无法满足电厂对多种不同工质的泄漏检测需求.

基于深度学习的分割网络相较于分类和目标检测网络,需要对图像进行像素级别的对象分离,其在缺陷信息特征提取上有一定的优势,因此将实例分割的思想引入电厂多种工质的泄漏检测可以取得较高的定位精度、检测准确性、稳定性和泛化能力. YOLACT^[8]是首个具备实时实例分割能力的单阶段实例分割模型,后续又有SOLOv2^[9]、BlendMask^[10]等实例分割算法被相继提出.目前,尚未有将实例分割算法应用于火电厂管道及阀门的油液、水滴和蒸汽泄漏检测场景的例子.

本文从电厂的实际需求出发,针对现有泄漏检测方法对复杂背景适应能力差、泄漏区域定位不准确、无法准确分割出具体的泄漏区域以及无法同时分割与检测多种不同泄漏物质的问题,提出一种基于改进

YOLOv7的火电厂关键区域管道及阀门泄漏分割与检测算法.该算法可在电厂多种复杂背景环境下同时完成对油液、水滴及蒸汽泄漏故障的高精度分割与检测,不但检测出泄漏的具体类型,还可以将泄漏区域的边缘轮廓也反映出来,直观地反应出泄漏的影响范围及严重程度.算法的主要改进如下:

1) 在YOLOv7^[11]模型的基础之上加入相关实例分割模块,实现实例分割与目标检测任务的并行处理.

2) 针对背景干扰大的问题,在算法中融入极化自注意力机制 polarized self-attention (PSA 机制)^[12],以弱化背景信息的干扰,加强模型对泄漏故障特征的学习能力.

3) 为了更好地表达出网络的全局信息,在网络中加入 separable vision transformer 模块 (SepViT 模块)^[13],强化泄漏区域的边缘提取.

4) 引入 confidence propagation cluster 机制 (CP-Cluster 机制)^[14],提高后处理的精度及效率.

5) 在颈部网络引入 Ghostconv^[15],减弱特征冗余,同时使用通道剪枝技术^[16]对模型进行压缩,使模型能兼顾速度与准确性.

1 火电厂管道及阀门泄漏分割与检测算法

1.1 模型总体结构与系统概述

YOLOv7 目标检测算法引入了可拓展的高效层聚合网络 E-ELAN^[11]、MP 结构等策略,使其在精度与检测速度上均优于当前主流的目标检测模型,可在一定程度上减少检测器出现检测及分类错误,因此将其改造成实例分割模型可以保证较高的泄漏故障分割精度.虽然 YOLOv7 算法处理一些常见的任务场景时有出色的表现,但由于油液、蒸汽等泄漏工质存在目标特征不清晰、目标尺寸小等问题,需要对 YOLOv7 基础网络进行改进,以适应电厂对泄漏工质分割与检测的实际需求.

本文以 YOLOv7 目标检测网络为基础,参考 YOLACT 实时实例分割模型的思想,在颈部网络及预测头中分别加入 ProtoNet 模块^[8]、Mask 分支,并行地实现泄漏故障的分割与检测.同时在 YOLOv7 主干及颈部网络的 E-ELAN、BConv 模块后融合了 PSA 模块,并在颈部网络的最前端加入 3 层 SepViT 模块,该改进有效地提高了模型对泄漏特征及隐含信息的提取能力,弱化了复杂背景的干扰.在后处理阶段使用 CP-Cluster 机制替换 NMS 方法,有效地提升了模型对泄漏区域定位的准确性.最后,为了弥补模型改进后参数量增加、模型复杂度变大的不利影响,

将颈部网络中E-ELAN、MP模块的普通卷积更换成Ghostconv,有效地去除了网络的特征冗余,同时使

用通道剪枝技术压缩模型结构,使得模型更加轻量化.改进后的网络结构如图1所示.

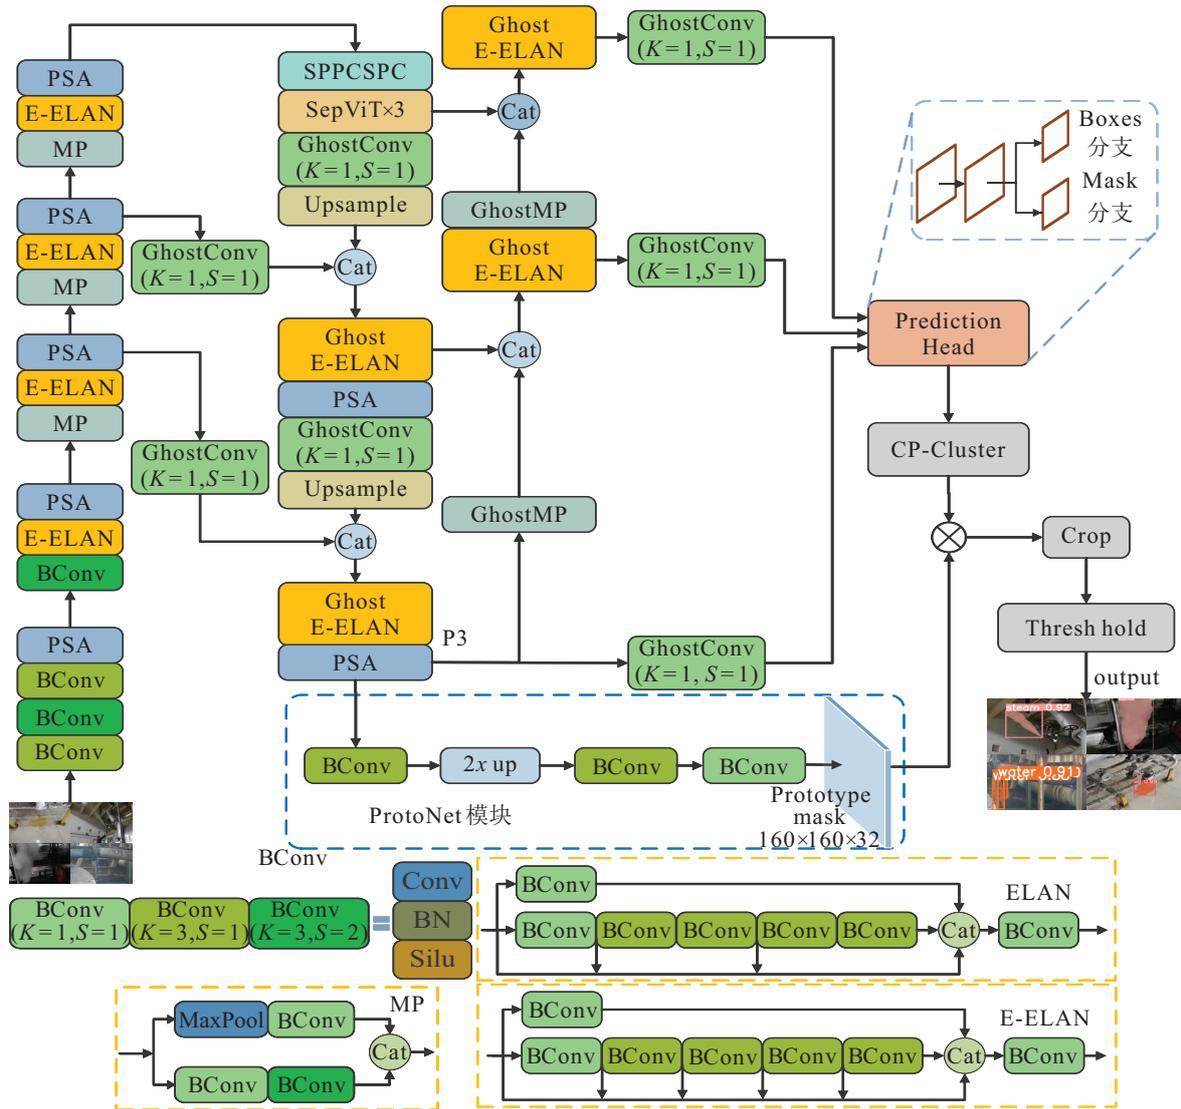


图1 基于改进YOLOv7的电厂泄漏分割与检测网络结构

1.2 基于YOLOv7的分割与检测并行方案

在检测蒸汽、油液等工质泄漏时仅仅通过一个方框标记出故障的大概位置,无法在电厂监控系统的界面中直观地反应出泄漏量的大小,因此引入实例分割算法的思想,不但检测出泄漏的具体类型,还可以将泄漏的边缘轮廓也反映出来,从而在监控系统中根据图中分割出的故障区域的大小,直观地判断出泄漏的严重程度.

使用YOLOv7来实现对泄漏故障的分割任务,主要参考了YOLACT算法的思想,将分割任务分成两个并行的子任务(ProtoNet模块、Mask分支)来实现. ProtoNet模块的输入取自YOLOv7颈部网络的P3特征层,模块通过一个全卷积网络生成32个“原型掩码(Prototype Masks)”. 这些原型掩码不依赖于任何一个特定泄漏故障实例,而是在不同泄漏故障类别

之间共享,每一个泄漏故障实例都由多个原型掩码组合而成. Mask分支是在原有YOLO预测头的基础上添加的一个并行分支,以预测每个Anchor的原型掩码系数. 预测头预测出每个Anchor的Box、Class、原型掩码系数后,经过后处理步骤的过滤,得到最终的预测结果. 最后将Mask分支预测的原型掩码系数和ProtoNet模块预测的原型掩码进行线性组合,得到每一个泄漏故障的实例Mask,对该Mask进行实例框截取和二值化操作后,得到最终的目标分割结果,具体结构如图1所示.

ProtoNet模块和Mask分支不会影响网络原有的目标检测任务,从而实现分割任务与检测任务的并行处理. 检测任务的目标置信度损失和分类损失采用Focal Loss^[17],坐标框损失采用CIoU损失^[18],分割任务的掩码损失采用二值交叉熵损失,模型的最终损失

由这4部分的损失相加,从而保证两个任务都能取得较好的精度. 本文将加入实例分割分支的模型取名为YOLOv7-seg.

1.3 融入高效注意力机制

1.3.1 融合 polarized self-attention (PSA) 机制

由于电厂设备密集、背景信息杂乱,且泄漏的油液、水滴等工质具有目标小、质地透明的特性,使用前文提出的原始YOLOv7-seg算法进行泄漏分割与检测时,复杂的背景信息对泄漏故障的分割与检测有较大干扰,易出现错分割、漏分割等问题. 注意力机制可以通过动态调整网络权重参数,使得模型能够抑制无效特征^[9],为了弱化背景信息的干扰使模型专注于泄漏工质的特征提取,在原有网络的E-ELAN模块后融合了PSA机制,其结构如图2所示. PSA机制分别针对通道及空间维度应用自注意力机制,模块的最终输出特征图与原始输入特征图在结构尺寸上完全一致,不会影响网络后续的处理步骤,对原始网络的梯度路径影响较小,而且PSA模块可与网络一起进行端到端的训练,因此PSA机制可以与YOLOv7的网络架构进行良好的融合.

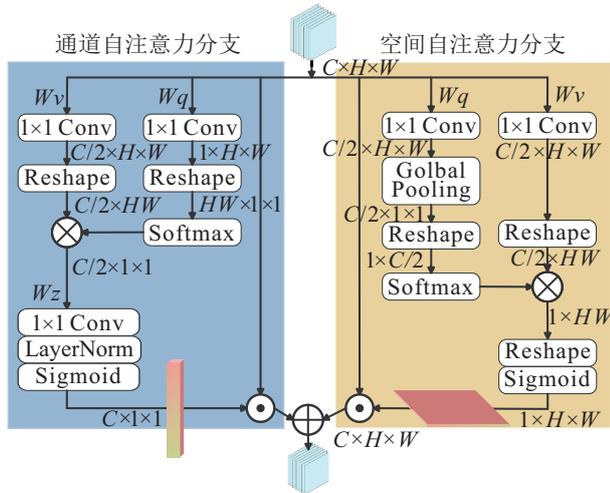


图2 极化自注意力机制结构

通道及空间自注意力分支的处理过程相似,都分别通过 1×1 卷积将输入的泄漏特征转换成各自的特征 Q 和特征 V ,通道分支将特征 Q 的通道维度完全压缩并将维度变换至 $HW \times 1 \times 1$,空间分支通过Global Pooling将特征 Q 压缩到 $C/2 \times 1 \times 1$ 大小,两分支特征 V 的维度均未进行较大的压缩都保持为 $C/2 \times HW$,特征信息损失较小,使得PSA模块能够在像素级任务上保持较好的性能. 然后,两个分支都通过Softmax对各自压缩后的特征 Q 进行增强,并通过矩阵乘法分别对各自的特征 V 和特征 Q 进行融合得到空间及通道注意力参数. 之后,通过维度变换、层归一化将空间、通道注意力参数的维度分别调整为 $1 \times H \times W$ 、

$C \times 1 \times 1$,并通过Sigmoid将空间、通道注意力参数映射到 $0 \sim 1$ 之间. 最后,原始的输入泄漏特征分别与通道、空间注意力参数相乘,并将两个分支的结果相加,得到最终的输出泄漏特征图.

PSA的通道注意力分支可以自适应地调整每个通道的重要性,突出与泄漏油液、水滴相关的特征,同时空间注意力分支则能够动态地调整不同空间位置的注意力权重,提高对泄漏区域的建模能力,弱化背景区域的权重. 因此,PSA可以帮助YOLOv7更好地捕捉和利用泄漏油液、水滴的关键特征,抑制无关区域的影响,较大程度地提高模型的分割与检测性能.

1.3.2 融合 separable vision transformer 模块

由于蒸汽这类气态泄漏物会发生快速的扩散,呈现出半透明的状态,在电厂复杂的光照条件下泄漏区域的边缘极为模糊,与背景的区别度较小,如果只在某个局部去提取特征信息,极易出现泄漏区域分割不全、误将背景分割成泄漏区域等问题. 为了解决上述问题,需要模型有极强的全局建模能力,提取出更多泄漏特征所隐含的特有信息,从而较好地地区别背景与泄漏边缘. 因此,本文在模型颈部网络的前端加入SepViT模块,加强泄漏区域的边缘轮廓提取. SepViT引入了深度可分离卷积的设计思想,并遵循基于窗口的自注意力机制,具有很强的灵活性,其可以根据实际需要设置不同的模型深度与输出尺寸,做到即插即用,且其参数可以与模型同步进行端到端的训练,因此可与YOLO算法相互配合提高模型的远距离建模能力. SepViT主要由depthwise self-attention (DWA)模块和pointwise self-attention (PWA)模块组成,结构如图3所示.

SepViT模块首先对输入特征图进行窗口划分,每个窗口可视为一个特征映射的输入通道,包含不同的泄漏特征信息. 为了表征窗口间的注意力关系,每个窗口都创建了对应的window token,以封装各窗口的全局表示信息. 将各窗口的所有像素及对应的window token送入DWA模块,执行自注意力计算,实现窗口内不同通道、不同位置间的特征信息融合以及窗口内像素与window token的信息交互.

PWA部分主要进行跨窗口的信息融合,实现各窗口间的特征信息交互. 首先从DWA的输出中分别提取出窗口像素信息的特征映射和window token,然后利用包含全局信息的window token对窗口间的注意力关系进行建模并生成各窗口的注意力参数. 之后,window token生成的注意力参数与DWA输出的泄漏故障特征映射进行窗口间的注意力计算,从而建立多个窗口间的连接,实现全局信息的交互.

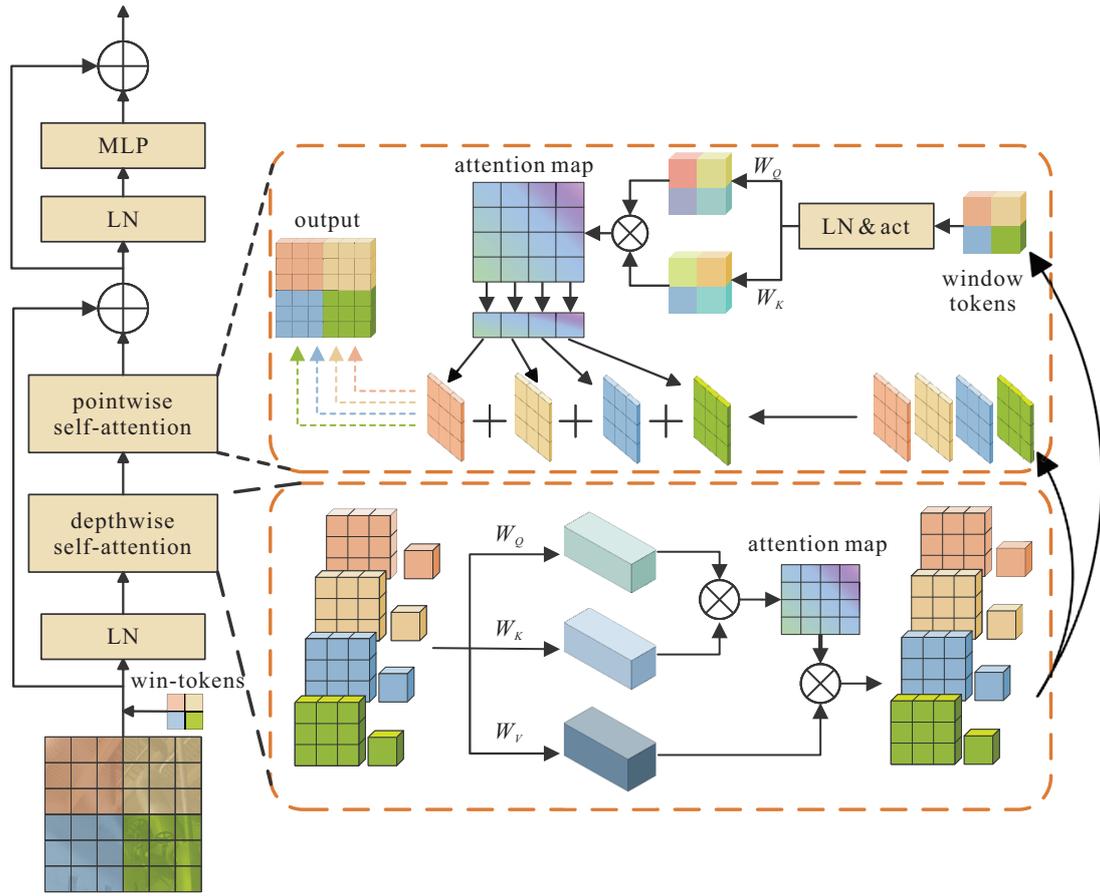


图3 SepViT模块结构

SepViT 模块会对划分出的各个窗口及与其对应的 window token 进行多次的自注意力计算, 使得模型能够在输入特征图的每个位置、每个通道上对其他位置进行加权关注, 捕捉到更多的长距离依赖关系. 通过对目标的全局上下文进行建模, 模型能够更准确地理解图像中的全局结构, 这使得网络可以从全局范围内来归纳蒸汽的总体特征, 避免了在局部小范围内无法较好提取蒸汽边缘特征的问题.

1.4 引入 confidence propagation cluster 机制

YOLOv7-seg 算法在输出最终分割结果前, 会对泄漏故障的实例 mask 进行实例框截取和二值化操作. 如果算法出现较大的泄漏区域定位误差, 将导致泄漏区域边缘出现分割不全的问题, 直接影响最终的分割性能, 因此提高定位精度至关重要. 传统的基于 NMS 的后处理方法存在一些固有的问题, 且仅单纯去重, 未考虑加强那些重要的预测框^[14]. 为了提高模型对泄漏区域的定位准确性, 引入 CP-Cluster 方法来代替 NMS, 在后处理阶段增强某些重要候选框的置信度. CP-Cluster 机制不会影响模型的前向、后向传播过程, 有较高的灵活性, 不依赖于具体的网络架构和训练方法, 因此可以无缝地融入 YOLOv7 网络.

CP-Cluster 机制的总体思路是首先根据预测边

界框间的 IoU 关系建立边界框间的连接, 并将其推广成无向图的集合; 然后在每个无向图中, 节点之间相互同时传递正面消息和负面消息; 最后在重复的预测边界框被消除掉的同时, 那些被选出的预测边界框的置信度也得到了加强.

给定一个预测边界框 $b_i \in B$, B 是后处理前模型输出的原始预测边界框集合. 在 CP-Cluster 中将 b_i 的置信度值定义成 $\hat{P}(b_i) = \hat{P}(b_i | N_{b_i}, \bar{b}_i)$, N_{b_i} 表示 b_i 在无向图中的相邻节点集, \bar{b}_i 是网络预测的 b_i 置信度. 对于边界框 b_i , 其相邻节点会生成正面消息来增加 $\hat{P}(b_i)$. 正面消息 $M_p(i)$ 的传递过程如下所示:

$$M_p(i) \leftarrow \frac{Q}{Q+1} \times (1 - \hat{P}(b_i)) \times \max_{\hat{b} \in W_{b_i}} \hat{P}(\hat{b}). \quad (1)$$

其中: W_{b_i} 是 b_i 弱样本集合, 其是 N_{b_i} 的一个子集, 对于任意的 $b_j \in W_{b_i}$, 都存在 $\hat{P}(b_j) < \hat{P}(b_i)$ 、 $\text{IoU}(b_j, b_i) > \theta_n$ 的关系; Q 是 W_{b_i} 的样本数. 正面消息对预测框的增强效果与该框周围的低置信度预测框数量紧密相关, 低置信度框越多, 增强效果越明显. CP-Cluster 的另一个目标是通过负面信息来抑制冗余的低质量预测框. 如果一个预测框周围的高置信度预测框越多, 则负面消息对该框的抑制效果也越强. 负面消息 $M_n(i)$ 的传递过程如下所示:

$$\begin{aligned}
& T(b_j, b_i) \leftarrow \\
& \alpha \times \hat{P}(b_j) / \hat{P}(b_i) + (1 - \alpha) \times \text{IoU}(b_j, b_i) / \theta, \\
& M_n(i) \leftarrow \hat{P}(b_i) \times \text{IoU}(b_i, \underset{b_j \in N_{b_i}, \text{SUP}_{j,i} \leq \zeta}{\arg \max} T(b_j, b_i)).
\end{aligned} \quad (2)$$

其中: $T(b_j, b_i)$ 是 b_j 对 b_i 的负影响因子; SUP 是抑制计数矩阵, 用来计算 b_j 抑制 b_i 的次数, 防止一个预测框反复地被另一个预测框抑制; ζ 是个超参数, 用于限制抑制的最大次数.

CP-Cluster 迭代时按 $\hat{P}(b_i) + M_p(i) - M_n(i)$ 的形式来更新 $\hat{P}(b_i)$, 一般执行 2 轮即可收敛到最优解. 通过使用 CP-Cluster 替代 NMS 方法, 在去除那些重复的低质量预测框的同时不断加强和修正那些置信度较高的预测框, 从而提高模型对泄漏区域的定位准确性, 使模型的分割与检测效果进一步提高.

2 模型轻量化设计

2.1 网络融入 Ghostconv

CNN 网络所生成的中间特征图存在较多的冗余特征, 为了减轻网络的特征冗余问题, 减少网络的参数规模和计算复杂度, 本文将模型颈部网络中的普通卷积替换为 Ghostconv. 该模块将传统卷积拆分成了两步, 第 1 步使用少量的卷积核生成原始特征图, 第 2 步使用线性变换生成更多的 Ghost 特征图, 最后对两部分特征进行拼接, 组成新的输出.

标准卷积运算的 FLOPS^[20] 如下所示:

$$\text{FLOPS}_C = c \times k^2 \times n \times h' \times w'. \quad (3)$$

其中: c 表示输入泄漏特征图的通道数, n, h', w' 表示输出泄漏特征图的通道数、高度、宽度, k 表示卷积核的尺寸. Ghostconv 的 FLOPS^[20] 可表示为如下形式:

$$\text{FLOPS}_G = c \times k^2 \times n/s \times h' \times w' + n/s \times d^2 \times (s-1) \times h' \times w'. \quad (4)$$

其中: d 为线性操作的内核大小, s 为 $m (m \leq n)$ 个原始泄漏特征图线性变换生成的相似特征图个数.

对比式 (3) 和 (4), 可知 Ghostconv 对普通卷积的压缩比可近似为 s , 模型参数量可极大地减少.

2.2 模型通道剪枝

本文提出的改进算法能够实现对多种泄漏工质的高效分割与检测, 为了降低网络参数量, 提高模型的实用性, 方便后期在电厂实际应用, 本文通过通道剪枝技术对模型进行压缩. 通道剪枝实现简单, 不会改变原有网络结构, 也不需要特别的硬件支持.

整体思路是利用批归一化层 (BN 层) 的缩放因子 γ 作为通道选择的标准来评定通道的重要程度, 通过在损失函数中引入正则化项来惩罚因子 γ , 使得在稀疏训练后大多数因子 γ 能靠近于 0. 训练结束后, 将因

子 γ 接近于 0 的通道裁减掉, 最后微调剪枝后的模型, 实现网络模型的轻量化. 缩放因子 γ 利用 L_1 正则化进行稀疏, 迫使其向 0 靠近, 稀疏训练的损失函数如下所示:

$$L = \sum_{(x,z)} l(f(x,W), z) + \lambda \sum_{\gamma \in T} |\gamma|. \quad (5)$$

式 (5) 的第 1 项为正常训练时的损失函数, x 和 z 代表输入和输出, W 为模型的训练权重; 第 2 项为稀疏训练的正则项, λ 用于平衡两项损失. 当剪枝比例过高时, 模型精度会急剧下降, 本文将按 50% 的比例来裁剪网络.

3 实验过程及结果分析

3.1 构建电厂泄漏图像实例分割数据集

目前, 实例分割技术还未在电厂中有实际的落地应用, 其中一个原因是现有的公开分割数据集中没有电厂设备泄漏的相关数据, 无法满足对电厂关键设备泄漏故障进行高精度分割与检测的实际需求. 因此, 本文综合电厂近些年的监控数据以及在电厂实际环境下进行的泄漏模拟实验, 构建一个涵盖电厂管道、阀门等多种设备、多种工质类别的电厂泄漏图像分割数据集, 用于训练本文改进的分割与检测模型. 不同工质的泄漏样本如图 4 所示.

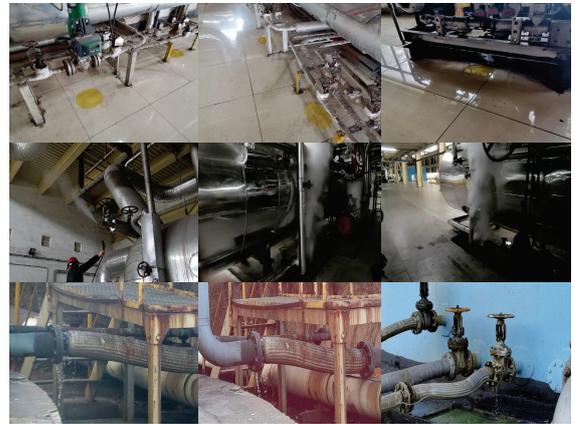


图 4 数据集样本

本文构建的电厂多场景多类别泄漏图像数据集中主要包含油滴、蒸汽和水滴这几种工质的泄漏图像, 通过对原始图像数据进行数据清洗, 最终保留了 2264 张泄漏图像, 并按照 70%、20%、10% 的比例随机抽取出训练集、验证集、测试集. 数据集的标注使用 Labelme 工具描画泄漏工质的具体泄漏区域, 填写泄漏类型标签.

3.2 实验配置及模型训练参数

本文使用的计算机硬件平台 CPU 为 Intel(R) Core(TM) i7-9700, GPU 为 NVIDIA RTX2080, 操作系统为 Window10, 采用 PyTorch1.10.2 深度学习框架及

CUDA11.3,编程语言Python3.8.

由于实验设备的限制,训练图像统一尺寸为 640×640 ,批处理量 `batchsize` 设置为 4,训练周期 `epoch` 设为 150,训练过程中使用 AdamW 优化器快速逼近最优解,实验显示迭代超过 115 次以后模型各项指标趋于稳定,模型总损失下降到 0.027 左右. 初始学习率设为 0.001,动量设为 0.92,权重衰减为 0.0005,在训练的前 3 个 `epoch` 使用 `warmup` 策略,之后通过余弦退火算法调整学习率.

3.3 实验评价指标

本文采用 $mAP@0.5:0.95$ 作为主要评价指标. 通过真正例 TP、假正例 FP、真负例 TN、假负例 FN 这 4 类可以计算出精确度 P 和召回率 R 如下:

$$P = \frac{TP}{TP + FP}, R = \frac{TP}{TP + FN}. \quad (6)$$

通过计算每个类别的 P-R 曲线下方的面积可以确定每个类的精度值 (AP),进而对每个类别的 AP 值求平均即可确定 mAP 指标,如下所示:

$$AP = \sum_{i=1}^N P_i / N, mAP = \sum_{j=1}^M AP_j / M. \quad (7)$$

其中: N 表示测试的图像数量, M 表示检测的类别总

数. $mAP@0.5:0.95$ 表示以 0.05 为步进的单位, IoU 阈值从 0.5 到 0.95 的平均精度的平均值,如下所示:

$$mAP@0.5:0.95 = \frac{\sum_{k=0}^9 mAP@(0.5 + 0.05k)}{10}. \quad (8)$$

该值越高代表模型预测区域与标注区域的拟合度越高,模型综合性能越强.

3.4 消融实验

本文针对 YOLOv7-seg 模型的多个环节进行改进,为了评估 PSA、SepViT、CP-Cluster 模块对于模型分割与检测精度的影响,在自构建的多场景多类别泄漏数据集上对不同的模块组合方式进行消融对比实验. 不同改进对模型分割性能、检测性能的影响如表 1 和表 2 所示. 在模型中引入 Ghostconv 和通道剪枝是为了弥补模型改进后参数量增加的不利影响,因此针对 Ghostconv 和剪枝的实验将在模型完整加入各项改进后进行. 针对融合 Ghostconv 的实验分成两部分进行,分别验证在全网络范围内以及仅在颈部网络中使用 Ghostconv 替换普通卷积的性能差异. 通道剪枝主要考察剪枝率为 25% 和 50% 时,剪枝对模型参数量 `params` 和模型精度的影响.

表 1 各项改进对分割性能影响的消融实验结果

模型	v7-seg	PSA	SepViT	CP-Cluster	Ghost		剪枝		mAP@0.5:0.95 ^{Mask} / %				params/M
					neck	all	25%	50%	oil	steam	water	all	
1	✓								85.4	69.2	36.8	63.8	37.9
2	✓	✓							87.0	81.7	46.1	71.5	42.8
3	✓		✓						87.8	81.8	46.0	71.9	49.2
4	✓			✓					87.6	72.8	40.6	67.1	37.8
5	✓	✓	✓						89.2	84.6	50.5	74.8	54.2
6	✓	✓		✓					89.4	82.6	51.0	74.3	42.9
7	✓		✓	✓					90.0	84.4	49.4	74.6	49.2
8	✓	✓	✓	✓					89.6	83.8	52.6	75.3	54.2
9	✓	✓	✓	✓	✓				90.0	83.9	51.8	75.3	46.6
10	✓	✓	✓	✓		✓			89.2	82.5	51.8	74.5	40.0
11	✓	✓	✓	✓	✓		✓		89.0	85.0	54.5	76.2	34.5
ours	✓	✓	✓	✓	✓		✓		90.5	85.1	51.3	75.7	26.4

表 2 各项改进对检测性能影响的消融实验结果

模型	v7-seg	PSA	SepViT	CP-Cluster	Ghost		剪枝		mAP@0.5:0.95 ^{Box} / %				params/M
					neck	all	25%	50%	oil	steam	water	all	
1	✓								93.4	83.9	47.9	75.1	37.9
2	✓	✓							97.2	89.0	54.6	80.2	42.8
3	✓		✓						95.8	88.7	53.4	79.3	49.2
4	✓			✓					95.7	86.7	51.4	78.0	37.8
5	✓	✓	✓						97.7	91.3	57.2	82.1	54.2
6	✓	✓		✓					97.6	90.0	59.3	82.3	42.9
7	✓		✓	✓					96.8	90.4	56.7	81.3	49.2
8	✓	✓	✓	✓					98.0	90.7	59.5	82.7	54.2
9	✓	✓	✓	✓	✓				98.0	90.5	59.7	82.8	46.6
10	✓	✓	✓	✓		✓			97.4	88.9	57.7	81.3	40.0
11	✓	✓	✓	✓	✓		✓		97.8	91.3	60.0	83.0	34.5
ours	✓	✓	✓	✓	✓		✓		97.9	90.1	58.6	82.2	26.4

表1的实验结果表明,单独应用各模块时均能对模型的分割性能产生正向优化.当仅在模型各处增加PSA模块时,模型可以在不同层次的特征图上自适应地调整不同通道和不同位置的权重,更好地聚焦于各类泄漏物的特征信息,因此模型的mAP指标提升了7.7%,参数量小幅增加.当仅在颈部网络头部增加SepViT模块时,会在深层特征图上使用大量的多头注意力机制来捕获更丰富长距离依赖关系,使得模型能从全局范围内来归纳泄漏工质的总体特征,避免在局部小范围内背景噪声对泄漏特征的干扰,因此模型的分割mAP指标提高了8.1%,但大量地使用多头注意力机制需要进行大规模的矩阵运算导致模型的参数量大幅增加,参数量上升了11.7M.当单独加入CP-Cluster机制时,模型通过正面及负面消息的传播,不断增强高置信度预测框,使模型的定位准确性得到提高,分割mAP指标提高了3.3%.

不同模块的组合对分割性能也都产生了较大的提升.对比模型6(同时添加PSA和CP-Cluster)和模型7(同时添加Sepvit和CP-Cluster)发现两者在总体分割精度相差不大的情况下,模型6对泄漏水滴的分割精度比模型7要高出1.6%,比分别单独使用PSA、CP-Cluster模块时高出4.9%和10.4%.同时,模型7对泄漏蒸汽的分割精度比模型6要高出1.8%,比分别单独使用Sepvit、CP-Cluster模块时高出2.6%、11.6%,表明在使用CP-Cluster机制保证了模型有较高定位精度的前提下,PSA模块可以较好地弱化背景权重,减少背景信息对泄漏水滴、油液这类小目标的干扰;SepViT模块则能通过大量多头注意力机制,更好地提取出泄漏蒸汽这类边缘模糊、半透明目标的全局隐含特征,使得模型能较好地地区分背景与泄漏边缘,达到了引入各模块的目的.当模型同时应用所有模块(模型8)时,分割mAP指标达到75.3%,较原始模型提高了11.5%,但模型的参数量较原始模型增大了43%.为了降低模型参数量与特征冗余,本文在模型8的基础上分别在颈部和全网络使用Ghostconv代替普通卷积,通过对比模型9、模型10可以发现,仅在颈部网络引入Ghostconv可以在不降低模型分割精度的前提下,有效地对传统卷积操作进行参数分解,参数量相较模型8减少14%.作为对比,在全网络使用Ghostconv代替传统卷积虽然可以进一步降低参数量,但引入了过多的信息损失,使得模型的特征映射不完整,模型的分割mAP指标下降了0.8%,因此仅在颈部使用Ghostconv代替普通卷积能较好地平衡模型的参数量和分割性能.为了能进一步降低模

型参数量,在模型9的基础上进行通道剪枝,当剪枝率为25%时,模型在经过微调后分割的mAP指标进一步增大0.9%,达到76.2%,这主要是因为剪枝操作减少了一些可能干扰模型学习的冗余参数,同时一定程度上减轻了模型的过拟合,提高了模型的泛化能力,参数量相较原始模型1减少了8.9%.当剪枝率为50%时,模型微调后的最终分割精度可以达到75.7%,比25%剪枝率时下降了0.5%,但仍比模型9高0.4%,且相较于原始模型1性能提高了11.9%,参数量仅为26.4M,相较于原始模型1减少了30.3%.通过对比25%和50%剪枝率的结果可知,如果进一步加大剪枝率会造成模型分割精度的下降,因此50%剪枝率是相对最优的选择.

检测性能随各项改进的变化趋势总体上与分割性能的变化趋势相近.表2的实验结果表明,在模型中单独应用各项改动时均能对模型的检测性能产生正向的优化,但模型的参数量也有较大增加.不同改动的组合对模型的检测性能也都产生了较大的提高.当模型同时应用PSA、SepViT、CP-Cluster三个模块(模型8)时,模型能同时在3类泄漏故障检测中取得较高的精度,其中对蒸汽和油液泄漏的检测精度都能达到90%以上,总体检测精度可以达到82.7%,较原始模型指标提高了7.6%,但模型的参数量相较于原始模型增加43%,模型复杂度变大.通过对比模型9、模型10可以发现,仅在颈部网络引入Ghostconv,可以在不降低模型检测精度的前提下,参数量相较未引入Ghostconv时减少14%.在模型9的基础上进行通道剪枝,当剪枝率为25%时,模型微调后的检测mAP指标小幅提高,达到83.0%,参数量相较于原始模型1减少了8.9%.当剪枝率为50%时,模型的最终检测指标可以达到82.2%,比采用25%剪枝时,精度下降了0.8%,但相较于原始模型1性能提高了7.1%,且参数量相较于原始模型1减少了30.3%.

3.5 对比实验

为了评估本文算法的有效性,将几种典型的实例分割算法应用于电厂管道阀门的泄漏分割与检测,并进行对比.对比算法包括YOLACT^[8]、SOLOv2^[9]、BlendMask^[10]、MaskRCNN^[21]、基于YOLOv5^[22]的实例分割算法和YOLOv7-seg.基于YOLOv5的实例分割算法是在YOLOv5目标检测算法的基础上通过本文第1.2节的并行方案改进而来,主要目的是验证本文以YOLOv7为基础网络的有效性.为了保证结果的公平性,所有的算法均采用相同的实验配置,在本文自构建的多场景多类别电厂泄漏数据集上进行性

能对比,实验结果如表3所示。

表3 不同算法性能对比

算法模型	mAP _{0.5:0.95} ^{Mask} / %	mAP _{0.5:0.95} ^{Box} / %	FPS/(帧/s)
YOLOv7 ^[10]	43.4	54.8	18.4
MaskRCNN ^[21]	67.2	68.4	8.5
BlendMask ^[13]	57.3	67.2	16.7
SOLOv2 ^[12]	53.9	\	17.6
YOLOv7-seg	61.4	66.9	23.8
YOLOv7-seg	63.8	75.1	28.4
本文算法	75.7	82.2	29.5

通过对比可以发现,MaskRCNN的分割与检测指标分别为67.2%、68.4%,明显优于大部分对比算法,但由于候选区域生成网络在生成大量候选框时会增加模型的计算时间,导致处理速度较低,无法满足实时性的需求。YOLOv7算法虽然处理速度变快,但精度较低。BlendMask采用了更精细化的特征融合策略,使得模型的分割与检测精度大幅提高,分别达到57.3%、67.2%,且处理速度未大幅下降。SOLOv2与BlendMask的总体性能相近,SOLOv2精度略低但速度更快。基于YOLO的分割模型得益于更强的特征提取与特征融合能力,使得模型精度与处理速度相比于其他实时分割模型有明显的提高。同时,YOLOv7-seg在分割、检测精度及检测速度上分别比YOLOv5l-seg高出2.4%、8.2%、4.6帧/s,因此以YOLOv7作为基线模型可以获得更高的综合性能。本文提出的改进算法在精度及检测速度方面都有大幅的提升,分割精度可以达到75.7%,检测精度可达到82.2%,FPS达到29.5帧/s,表明改进后的算法能够

在复杂环境下对各种工质的泄漏特征进行更加准确的提取和学习。

为了直观地显示本文算法的有效性,分别用基础的YOLOv7-seg算法和加入了各项改进的最终算法对不同场景、不同曝光度、不同角度的测试图像进行分割与检测,具体效果如图5所示。图5(a)第1个图片中,设备壳体呈现银色并伴有强烈反光,而泄漏蒸汽相对稀薄且特征与后方设备高度相识,YOLOv7-seg网络出现了泄漏区域分割不全的问题;第2个图片中,高压管道出现了蒸汽喷射故障,由于喷射蒸汽量很小且快速发生扩散,泄漏区域的边缘模糊,基线模型将部分背景误分割成了泄漏区域;第3个图片中管道发生油液泄漏,但由于油液质地透明且与地面颜色相似,基线网络发生了漏分割;第4个图片中管道出现液体泄漏,由于泄漏的水滴目标极小且背景信息杂乱,基线网络出现了漏检与漏分割。

与之形成对比的是,改进后的算法能够准确地分割并检测出泄漏的水滴、油渍及蒸汽,未出现明显的漏分割、错分割等问题。表明本文所提改进算法对电厂的复杂环境及光照变化有更强的适应能力,具有分割精度高、稳定性强等优点。经过在测试数据集上的实验统计,改进后模型的平均分割准确率达到90.1%,平均检测准确率达到94.3%,故障的漏检率仅为4.8%,本文提出的改进算法无论在精度、模型复杂度及实时性上都有较大的提升,能够满足电厂对泄漏故障进行实时分割与检测的实际需求。

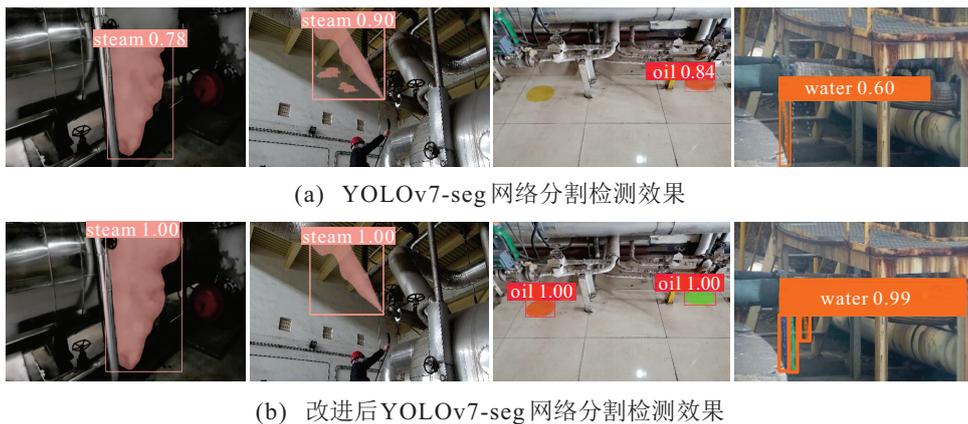


图5 算法效果对比

4 结论

本文根据电厂的实际需求,针对现有泄漏检测方法对复杂背景适应能力差、泄漏区域定位不准确、无法准确分割出具体的泄漏区域以及无法同时检测分割多种泄漏工质的问题,提出了一种基于改进YOLOv7的火电厂关键区域管道及阀门泄漏分割

与检测算法。首先,在YOLOv7模型的基础之上加入ProtoNet模块及Mask分支,同时实现对泄漏故障的分割与检测;其次,在网络中融入PSA机制和SepViT模块,弱化背景对泄漏特征的干扰,强化网络的特征学习能力;同时,在后处理阶段使用CP-Cluster机制加强模型对泄漏区域的定位能力;最后,在模型的颈

部网络中使用 Ghostconv 代替普通卷积,并对模型按 50% 的比例进行通道剪枝,使模型能同时兼顾速度与准确性.实验结果表明,本文提出的算法在面对电厂多场景、多工质泄漏故障时,分割精度、检测精度都有大幅的提高,较好地平衡了精度与速度.

参考文献(References)

- [1] Su T C, Yang M D, Wu T C, et al. Morphological segmentation based on edge detection for sewer pipe defects on CCTV images[J]. *Expert Systems with Applications*, 2011, 38(10): 13094-13114.
- [2] Wu W, Liu Z, He Y. Classification of defects with ensemble methods in the automated visual inspection of sewer pipes[J]. *Pattern Analysis and Applications*, 2015, 18(2): 263-276.
- [3] 赵苓, 郭召阳, 任仲超. 基于改进双边滤波的气体泄漏检测[J]. *液压与气动*, 2019(3): 49-53.
(Zhao L, Guo Z Y, Ren Z C. Air leak detection based on bilateral filter of infrared image[J]. *Chinese Hydraulics & Pneumatics*, 2019(3): 49-53.)
- [4] Fahimipirehgalin M, Trunzer E, Odenweller M, et al. Automatic visual leakage inspection by using thermographic video and image analysis[C]. 2019 IEEE 15th International Conference on Automation Science and Engineering. Vancouver, 2019: 1282-1288.
- [5] 王红梅, 王晓鸽, 王晓燕. 基于深度学习的复杂背景下目标检测[J]. *控制与决策*, 2022, 37(12): 3115-3121.
(Wang H M, Wang X G, Wang X Y. Target detection under complex background based on deep learning[J]. *Control and Decision*, 2022, 37(12): 3115-3121.)
- [6] Lyu C G, Liu Y G, Wang X K, et al. Visual early leakage detection for industrial surveillance environments[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(6): 3670-3680.
- [7] Melo R O, Costa M G F, Filho C F F C. Applying convolutional neural networks to detect natural gas leaks in wellhead images[J]. *IEEE Access*, 2020, 8: 191775-191784.
- [8] Bolya D, Zhou C, Xiao F Y, et al. YOLACT: Real-time instance segmentation[C]. 2019 IEEE/CVF International Conference on Computer Vision. Seoul, 2020: 9156-9165.
- [9] Wang X L, Zhang R F, Kong T, et al. Solov2: Dynamic and fast instance segmentation[C]. *Proceedings of the 34th International Conference on Neural Information Processing Systems*. Vancouver, 2020: 17721-17732.
- [10] Chen H, Sun K Y, Tian Z, et al. BlendMask: top-down meets bottom-up for instance segmentation[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 8570-8578.
- [11] Wang C Y, Bochkovskiy A, Liao H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, 2023: 7464-7475.
- [12] Liu H J, Liu F Q, Fan X Y, et al. Polarized self-attention: Towards high-quality pixel-wise mapping[J]. *Neurocomputing*, 2022, 506: 158-167.
- [13] Li W, Wang X, Xia X, et al. SepViT: Separable vision transformer[J/OL]. 2022, arXiv: 2203.15380.
- [14] Shen Y C, Jiang W L, Xu Z, et al. Confidence propagation cluster: Unleash full potential of object detectors[C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, 2022: 1141-1151.
- [15] Han K, Wang Y H, Tian Q, et al. GhostNet: More features from cheap operations[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 1577-1586.
- [16] Liu Z, Li J G, Shen Z Q, et al. Learning efficient convolutional networks through network slimming[C]. 2017 IEEE International Conference on Computer Vision. Venice, 2017: 2755-2763.
- [17] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]. 2017 IEEE International Conference on Computer Vision. Venice, 2017: 2999-3007.
- [18] Zheng Z H, Wang P, Liu W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(7): 12993-13000.
- [19] 陈文玉, 赵怀慈, 刘鹏飞, 等. 基于改进YOLOv3的车辆检测算法[J]. *控制与决策*, 2024, 39(4): 1151-1159.
(Chen W Y, Zhao H C, Liu P F, et al. Vehicle detection algorithm based on improved YOLOv3 [J]. *Control and Decision*, 2024, 39(4): 1151-1159.)
- [20] 叶卓勋, 刘妹琴, 张森林. 基于轻量化深度学习网络的工业环境小目标缺陷检测[J]. *控制与决策*, 2023, 38(5): 1231-1238.
(Ye Z X, Liu M Q, Zhang S L. Small-scale defect detection in industrial environment based on lightweight deep learning network[J]. *Control and Decision*, 2023, 38(5): 1231-1238.)
- [21] He K M, Gkioxari G, Dollár P, et al. Mask R-CNN[C]. 2017 IEEE International Conference on Computer Vision. Venice, 2017: 2980-2988.
- [22] Jocher G. Yolov5[EB/OL]. (2020-08-10)[2023-04-10]. <https://github.com/ultralytics/yolo-v5>.

作者简介

彭道刚(1977—), 男, 教授, 博士生导师, 从事低碳智能发电、综合智慧能源、电力巡检智能机器人等研究, E-mail: pengdaogang@126.com;

陈晨(1998—), 男, 硕士生, 从事电力巡检智能机器人、机器视觉等研究, E-mail: cc15295088557@169.com;

王丹豪(1992—), 男, 博士生, 从事综合能源系统、能源互联网等研究, E-mail: damhao.wang@qq.com;

潘俊臻(2000—), 男, 博士生, 从事电力巡检智能机器人、机器视觉等研究, E-mail: pan_junzhen@163.com.