

DOI: 10.13382/j.jemi.B2205769

基于改进 YOLO v5 的电厂管道油液泄漏检测*

彭道刚¹ 潘俊臻¹ 王丹豪¹ 胡捷²
(1. 上海电力大学自动化工程学院 上海 200090; 2. 宝山钢铁股份有限公司电厂 上海 201900)

摘要:针对电厂油库、化水车间等关键区域油液管道时常发生泄漏问题,本文提出了一种基于改进 YOLO v5 的电厂关键区域管道油液泄漏检测方法,通过融入 CBAM 注意力机制模块,加强对管道油液泄漏区域图像的特征学习与特征提取,同时弱化复杂背景对检测结果的影响;在此基础上运用了双向特征金字塔网络进行多尺度特征融合,减少冗余计算,同时提升算法对小目标的检测能力;最后采用 Focal EIoU Loss 作为损失函数,使回归过程更加专注于高质量锚框,加快收敛速度,提高模型的回归精度和鲁棒性。实验结果表明,本文所提出的改进算法在真实样本中表现良好,平均准确率达 79.6%,较原 YOLO v5s 目标检测算法提高了 38.4%,在电厂复杂背景下的误报率和漏报率明显下降,可有效应用于实际生产环境中。

关键词:管道泄漏检测;YOLO v5 算法;CBAM 注意力机制

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Oil leakage detection of pipelines of power plants based on improved YOLO v5

Peng Daogang¹ Pan Junzhen¹ Wang Danhao¹ Hu Jie²
(1. College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;
2. Power plant of Baoshan Iron & Steel Co., Ltd., Shanghai 201900, China)

Abstract: In view of the frequent leakage of oil pipelines in key areas such as power plant oil depots and chemical water workshops, a pipeline leak detection method in key areas of power plants based on improved YOLO v5 is proposed. The improved YOLO v5 detection algorithm first incorporates CBAM module to strengthen the learning of regional features of pipeline oil leakage images. The CBAM makes the model more focused on the extraction of pipeline leakage features, and weakens the influence of complex backgrounds on detection results. Secondly, a bidirectional feature pyramid network is used for multi-scale feature fusion. It also reduces redundant calculation, and improves the detection ability of the algorithm for small targets. Finally, Focal EIoU Loss is used as the loss function to make the regression process more focused on high-quality anchor boxes. It improves the regression accuracy, speeds up the convergence speed, and improve the robustness of the model. The experimental results show that the improved algorithm performs well in real samples, with an average accuracy rate of 79.6%, which is 38.4% higher than the original YOLO v5s algorithm. The false positive rate and the false negative rate in the complex background of the power plant are significantly reduced. It shows that the improved YOLO v5 detection algorithm can be effectively applied in the actual production environment.

Keywords: pipeline leak detection; YOLO v5 algorithm; CBAM attention mechanism

0 引 言

电力生产安全关乎国家能源安全。随着居民用电量与日俱增,电力生产的效率与安全同时也关乎国民生活

质量。电厂中,油库、化水车间等关键区域包含许多重要的充油设备以及输油管道。在氧化老化、受温差胀缩和检修维护不及时等多种因素的影响下,可能会出现油液泄漏的情况。油液泄漏的发生不但会影响生产效益,还可能发生短路放电等情形,从而导致设备毁坏、火灾等严

重后果。不同于高温蒸汽,利用人工巡检或者红外图像识别就能够分辨检测区域内是否发生泄漏。管道油、水等液体的泄漏具有变化细微缓慢、没有固定形状等特点,电厂中管线的分布密集且管道数量众多,泄漏难以检测,因此对管道油液泄漏的及时检测识别与准确定位具有重要的现实意义。

目前,电厂针对关键区域内的跑气、冒水、滴液等跑冒滴漏现象,普遍采用人工巡检的方式。巡检工人一般按照“倒班制”进行巡检,每天最多能对生产现场进行 3 次巡检,每次巡检时间间隔约为 8 h,如果在这 8 h 内发生管道泄漏,就可能未被及时检出而造成严重的后果。此外,人工巡检不仅耗时长、整理和分析历史数据困难,而且实时性较差。

为了及时预防事故发生,减少人工巡检的工作量,同时提升生产现场巡检效率,Nellis 等^[1]首次提出了一种使用红外相机作为外部视觉检测的水渠管道检测系统,通过评估证明了该泄漏检测模型的经济性以及可行性,但并未采用图像处理方法来自动进行自动泄漏检测;Adefila 等^[2]也利用红外相机进行泄漏检测,该研究考虑了管道气体泄漏的情况,并评估了红外相机在获取泄漏气体温度变化方面的灵敏度,但并未提出任何与检测气体泄漏相关的图像处理方法。

后来随着特征提取和图像处理方式的进步,Atef 等^[3]提出了一种基于图像分析的输水管道自动泄漏检测方法,应用聚类分析方法检测图像中存在的泄漏现象,并且将基于区域生长法的分割方法用于泄漏定位;Dai 等^[4]提出了一种基于红外相机和图像处理技术的气体泄漏检测方法,首先利用自适应维纳滤波器进行降噪处理,应用改进的 Surendra 算法和边缘检测来进行变化区域的检测和泄漏区域的定位。

电厂生产现场的管道泄漏主要分为气体泄漏和液体泄漏两种。气体泄漏特征比较明显,高温蒸汽泄漏时,温度特征较为明显,且颜色方便分辨,利用红外相机配合图像处理算法就能够进行检测,其他气体的检测也能够找到对应的检测方法。如 Kroll 等^[5]利用典型气体泄漏的温度廓线的二维高斯分布模拟热成像图像中的泄漏区域,通过图像与温度廓线的相关性来进行泄漏检测。该方法需要事先掌握有关泄漏的温度廓线的信息;Wang 等^[6]采用卷积神经网络(convolutional neural networks, CNN)对红外图像进行气体泄漏检测,并根据不同泄漏率对图像进行分类。为降低噪声水平,研究人员对背景图像进行减影处理以降低环境影响;Araujo 等^[7]提出了一种利用热像仪和红-绿-蓝(RGB)三基色相机进行泄漏检测的图像分析技术,将得到的图像合成为一幅图像作为 CNN 分类器识别泄漏的输入。图像分析需要获得更多的参数,诸如相机与管道之间的距离以及相机的视角。

电厂管道液体泄漏场景的检测比较复杂,一方面电厂背景复杂,另一方面液体泄漏特征不明显,肉眼也很难观察到,因此针对电厂油液泄漏进行检测的难度可想而知。在利用热成像视频数据进行泄漏检测方面,Fahimipirehgalin 等^[8]提出了一种基于主成分分析(principal component analysis, PCA)和 k-最近邻(k-nearest neighbor, KNN)分类的方法,来获得帧内泄漏液滴的特征,并对正常和异常(包括泄漏)视频进行分类,但该方法无法对泄漏液滴进行定位。

随着人工智能的不断发展,深度学习的应用不仅局限于通过分析管道各项数据检测是否存在泄漏,尤其是机器视觉的应用降低了工业现场检测仪器的部署难度。通过安装摄像头等影像采集设备、部署服务器就能实现对工业现场设备以及管道状态的检测,包括油液泄漏检测、安全帽检测、气体泄漏检测等。基于机器视觉的管道泄漏检测的优点主要有:

- 1) 实时、快速、精准检测电厂设备或者管道特定部位故障^[9];

- 2) 随着使用时间的增长,生产现场采集的数据集不断增加,检测方法的准确性会越来越高;

- 3) 传统算法利用特征工程对对象进行特征分析与建模,但受到手工特征设计质量高低以及机器学习方法自身缺陷影响^[10],导致传统算法泛化能力弱且鲁棒性差^[11]。基于机器视觉的检测方法可以针对某一特定种类的泄漏场景进行模型设计,通过训练后具有很强的泛化性能,可以在某一类场景下广泛使用。

现有的一些研究方法,也有利用图像数据结合图像处理方法进行管道泄漏的相关研究,但目前尚未有将基于深度学习的目标检测技术与电厂关键区域管道油液泄漏检测场景相结合的实例。本文从实际应用场景出发,根据油库、化水车间等电厂关键区域管道油液泄漏特征和生产现场检测需求,旨在提出一种基于机器视觉的管道油液泄漏检测算法,以智能巡检机器人的机载可见光、红外摄像头和生产现场安装的固定点摄像头或者双视云台作为影像采集设备,实现对电厂关键区域管道油液泄漏现象的有效检测。本文针对原始 YOLO v5 算法在电厂复杂背景环境下定位不准确的问题,结合智能巡检机器人自身特点,在 YOLO v5 的网络架构基础上进行了深度优化,提出了一种基于改进 YOLO v5 的电厂管道油液泄漏图像检测算法,主要改进如下:

- 1) 通过智能巡检机器人的机载可见光、红外摄像头和生产现场的固定摄像头或者双视云台所获取的影像数据,作为泄漏检测模型的输入,实现对油库、化水车间等电厂关键区域内管道油液泄漏现象的检测。

- 2) 针对电厂关键区域油液管道分布密集、生产现场环境复杂的特征,本算法通过融入注意力机制模块

(convolutional block attention moudule,CBAM),弱化复杂背景对检测结果的影响,使得模型更加专注于对管道泄漏特征的提取,加强对管道油液泄漏图像区域特征的学习。

3) 针对电厂管道油液泄漏现象存在被检测目标尺度较小的特征,本算法采用双向特征金字塔网络(Bi-directional feature pyramid network,BiFPN)进行多尺度特征融合,以提升算法对小目标的检测能力,解决 YOLO 算法定位不准确的问题^[12]。

4) 针对原始 YOLO v5 算法 Bounding Box 回归中样本不平衡问题,本文所提出的改进算法采用 Focal EIoU Loss 作为损失函数,更加明确地测量边界框回归中重叠面积、中心点和边长的差异,提升回归过程对高质量锚框的关注度,加快收敛速度,提高模型的回归精度和鲁

棒性。

1 电厂关键区域管道油液泄漏检测算法

1.1 YOLO v5 网络结构

YOLO v5 和 YOLO v4 作为 YOLO v3 的社区改进版,它们在整体的网络结构上是相似的,算法结构如图 1 所示。与之前 YOLO 版本不同的是,YOLO v5 算法通过调节深度倍数(depth multiple)和宽度倍数(width multiple)这两个参数,实现了 YOLO v5s、YOLO v5m、YOLO v5l 和 YOLO v5x 四种结构。这 4 种结构网络逐渐加深加宽,泛化能力、特征提取能力、特征融合能力以及模型精度不断提升,但模型的训练速度会随着模型复杂度的增加逐渐减慢。




图 1 YOLO v5 目标检测算法结构

Fig. 1 Structure of YOLO v5 target detection algorithm

YOLO v5 的网络架构从结构上可以分为输入端、骨干段、颈部段和头部输出端四部分,使用 YOLO v5 目标检测算法对电厂关键区域管道油液泄漏进行检测的整体流程如下:

1) 输入端:加载自建的电厂关键区域管道油液泄漏图像数据集,并对输入的图像进行 Mosaic 数据增强、自适应锚框计算、自适应的缩放等预处理操作。

2) 骨干段:采用 Focus 操作对管道油液泄漏图片进行切片,整个切片过程中将高度、宽度信息集中到了通道空间,并对输入通道进行了扩充。同时还采用了跨阶段局部网络(cross stage partial networks),将梯度变化集成到特征图中,最后得到不同分辨率下的图像特征。

3) 颈部段:通过路径聚合网络(path-aggregation

network,PANet)^[13]对获得的管道油液泄漏图像特征进行混合和组合,改善低层特征的传播,使得低层的定位信息能够增强到整个特征提取网络。

4) 头部端:对管道油液泄漏图像特征进行预测,生成边界框并预测类别。

1.2 改进的 YOLO v5 网络结构

1) 融入 CBAM 注意力机制^[14]

近年来注意力机制被越来越多地应用于图像领域,在此之前注意力机制已经在自然语言领域中取得了突出的成果^[15]。

对于 YOLO v5 算法,虽然在取得不同分辨率下检测物体特征信息的基础上,能够通过网络结构的设计进行特征融合提升模型的性能,但是在电厂复杂的背

景以及变化的环境中,容易出现管道泄漏定位不准确的情形。

通过融入 CBAM 注意力机制能够弱化背景变化对检测结果的影响,使模型更加专注于对管道油液泄漏的特

征学习与特征提取,同时在已经能够获取不同分辨率下油液泄漏特征信息的基础上,兼顾不同像素类别、通道特征和上下文关联之间存在的差异。CBAM 结构示意图如图 2 所示。




图 2 CBAM 结构

Fig. 2 Structure of CBAM

CBAM 包含了通道注意力模块和空间注意力模块这两个独立的子模块,分别进行通道和空间上的注意力操作。

在通道注意力模块中,通过重新分配特征图之间的权重,加大对关键特征图的关注,弱化冗余特征图对识别结果的影响^[16]。首先将输入的特征图复制成两份,它们分别经过基于宽度和高度的全局最大池化和全局平均池化,得到两个特征图,再将它们分别送入到一个两层的多层感知机 (multi-layer perceptron, MLP),这个两层的神经网络由两个特征图共享,最终将生成的特征传入空间注意力模块。

在空间注意力模块中,将通道注意力模块的输出特征图作为空间注意力模块的输入特征图,首先进行基于通道的全局最大池化和全局平均池化,得到两个特征图,再将这两个特征图基于通道进行拼接操作 (concat),接着经过卷积操作降维为 1 个通道,最后经过 sigmoid 激活函数生成空间注意力特征,再将空间注意力模块最终输出的特征与输入特征做乘法得到最终 CBAM 注意力机制所输出的特征图。

针对电厂关键区域管道分布密集且环境复杂的特征,通过引入注意力机制模块,不仅能够增强对管道油液泄漏图像区域特征的学习,还能够降低模型大小,减少算力开销,便于集成到现有的网络架构中。对比表 1 中的实验数据,通过引入 CBAM 注意力机制,算法检测性能确实取得了很大的提升。

表 1 引入 CBAM 注意力机制的性能评估实验

Table 1 Performance evaluation experiment with CBAM

算法	Recall	Precision	mAP/%
YOLO v5	0.542	0.566	0.575
YOLO v5+CBAM	0.596	0.645	0.656

2) 基于 BiFPN 的多尺度特征融合网络

随着 YOLO 架构的创新,网络逐渐加深,模型复杂度越来越高,模型所提取的特征复杂度也越来越高,就会造成一定的特征损失。在模型中,浅层网络较深层网络拥有更高的分辨率,涵盖了更准确的位置信息;而深层网络较浅层网络拥有更大的感受野,能够涵盖更多的高维语义信息,利于对检测目标进行分类。因此,采取更好的特征融合方法对不同尺度的特征信息进行融合,对于提升目标检测模型的性能至关重要。

对于单阶段目标检测算法,只有一个阶段对图像特征进行抽取,因此无法得到不同尺度的特征信息。在骨干段抽取生成的特征,按照阶段 (Stage) 进行划分,记作 $C_1, C_2, \dots, C_7$,其中数字代表图像分辨率减半的次数,例如 C_1 表示第 1 阶段,输出为原图像 1/2 尺寸的特征图 (图像分辨率减半了 1 次)。之后自上向下逐层进行特征融合,设输出为 P ,整个过程可以用公式表示为:

$$P_i, P_{i+1}, \dots, P_{i+n} = f(C_i, C_{i+1}, \dots, C_{i+n}) \tag{1}$$

其中, $C_i, C_{i+1}, \dots, C_{i+n}$ 表示第 i 个阶段所抽取的生成的特征, $P_i, P_{i+1}, \dots, P_{i+n}$ 表示第 i 个阶段的输出, f 表示输入到输出的转变过程 (包括上下层之间的特征融合)。

YOLO v5 算法在颈部段延续了 YOLO v4 中的路径聚合网络 (PANet) 来进行特征融合。它基于 Mask R-CNN 和 FPN 架构,同时加强了信息传播,在网络提取器中采用了自下而上增强的 FPN 结构进行低层特征传播的改善,同时使用自适应特征池化 (adaptive feature pooling) 对每个候选区域和所有特征层次之间被破坏的信息路径进行恢复,聚合每个特征层次上的每个候选区域,避免被任意分配。

由 Google Brain 团队在 2020 年提出的 EfficientDet 目标检测网络中首次应用了 BiFPN^[17] 多尺度特征融合, BiFPN 整体结构如图 3 所示,较之前广泛使用的 PANet,其主要改进在于:

- 1) 减少入度为 1 的节点,由于其较前一节点没有额外信息,因此可以减少冗余计算。
- 2) 增加跳跃链接,使得输出层不仅能得到自下而上已经参与特征融合的信息,而且保留了原始节点未经融合的信息。
- 3) 模块化,整体可以继续参与堆叠,进一步做融合,各层关系如式 (2) 所示。

$$\begin{cases} P_7^{out} = \text{Conv}(P_7^{in}) \\ P_6^{out} = \text{Conv}(P_6^{in} + \text{Resize}(P_7^{out})) \\ P_5^{out} = \text{Conv}(P_5^{in} + \text{Resize}(P_6^{out})) \\ P_4^{out} = \text{Conv}(P_4^{in} + \text{Resize}(P_5^{out})) \\ P_3^{out} = \text{Conv}(P_3^{in} + \text{Resize}(P_4^{out})) \end{cases} \quad (2)$$

其中, P^{in} 表示所在层的输入特征, P^{out} 表示所在层的输出特征, Resize 表示用于上采样或者下采样的分辨率匹配操作, Conv 表示用于特征处理的卷积操作。




图 3 BiFPN 整体结构
Fig. 3 Structure of BiFPN

通过将原始 YOLO v5 算法中的路径聚合网络替换成为双向特征金字塔网络,通过多尺度的特征融合,不仅可以提升检测算法对于小目标的检测能力,还能够大幅度降低模型的运算量,对于工业现场运算能力并不突出

的设备、现场的实际部署以及后续模型的更新都具有很大的现实意义。

针对电厂管道泄漏存在被检测的目标尺度较小的特征,本文通过运用双向特征金字塔网络进行多尺度特征融合,使算法更好地识别管道油液泄漏的特征,同时提升算法对小目标的检测能力,解决 YOLO 定位不准确的问题。在工程应用方面,双向特征金字塔网络的引入也能够减少冗余计算,降低模型大小,使得检测算法更容易在生产现场实施部署。通过对比引入 BiFPN 前后模型检测性能,如表 2 所示,算法的平均检测精度有了明显的提高,召回率等其他性能指标也相应提高了,算法改进效果明显。

表 2 引入 BiFPN 的性能评估实验

算法	Recall	Precision	mAP/%
YOLO v5	0.542	0.566	0.575
YOLO v5+BiFPN	0.614	0.640	0.672

3) Focal EIoU Loss 损失函数

在头部端,最重要的是损失函数的选取。目标检测算法中的损失函数一般由边界框回归损失和分类损失两部分构成,以此来度量神经网络预测信息与期望信息之间的距离。预测信息越接近期望信息,损失函数的值就越小。YOLO v5 将完全交并比损失函数^[18] (complete intersection over union loss, CIoU Loss) 作为损失函数,在 DIoU Loss 的基础上增加了一个影响因子,通过考虑引入中心点距离和高宽比,将完全交并比损失函数 (complete intersection over union loss, CIoU Loss) 作为损失函数,具体计算方法如下:

$$CIoU_{LOSS} = 1 - CIoU \quad (3)$$

$$CIoU = IoU - \frac{Distance_2^2}{Distance_c^2} - \frac{v^2}{(1 - IoU) + v} \quad (4)$$

$$v = \frac{4}{\pi^2} \left(\tan^{-1} \frac{w^{gt}}{h^{gt}} - \tan^{-1} \frac{w^p}{h^p} \right)^2 \quad (5)$$

其中, $Distance_2$ 是预测框与目标框的中心点距离, $Distance_c$ 是最小外接矩形对角线长度, $\frac{w^{gt}}{h^{gt}}$ 和 $\frac{w^p}{h^p}$ 分别是预测框和目标框的高宽比。

相较于 DIoU Loss,尽管 CIoU Loss 增加了一个影响因子来考虑引入中心点距离和高宽比,但是仍然无法有效地描述边界框回归的目标,可能会导致收敛缓慢而且回归不准确。因此本算法在原有的 CIoU Loss 损失函数 (如式 (3) 所示) 的基础上进行改进,引入了 Focal EIoU Loss 作为损失函数,如式 (6) 所示。

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

其中, γ 是一个用于控制曲线弧度的超参数。

$$L_{EIoU} = L_{IoU} + L_{dis} + L_{asp} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \frac{\rho^2(w, w^{gt})}{c_w^2} + \frac{\rho^2(h, h^{gt})}{c_h^2} \quad (7)$$

EIoU 将损失函数分为了 IoU 损失、距离损失和边长损失 3 个部分, L_{IoU} 是 IoU 损失, L_{dis} 是距离损失, L_{asp} 是边长损失。其中, C_w 和分别是 C_h 分别是覆盖预测框和目标框的最小外接框的宽度和高度。

Focal EIoU Loss 损失函数中的 Focal 与传统的 Focal Loss^[19] 有一定的区别, 传统的 Focal Loss 针对越困难的样本损失越大, 以挖掘困难样本; 而在 Focal EIoU Loss 损失函数中, IoU 越高损失越大, 相当于加权作用, 回归目标越好则损失越大, 因此有助于提高回归精度。

相较于 CIoU Loss 损失函数, Focal EIoU Loss 损失函数不仅将纵横比的损失项拆分成预测的宽高分别与最小外接框宽高的差值, 提高了模型的收敛速度和回归精度, 而且引入 Focal Loss 能够解决优化边界框回归任务中的样本不平衡问题, 减少与目标框重叠较少的大量锚框对边界框回归的贡献, 使得整个回归过程更加专注于高质量锚框。

本文通过采用 Focal EIoU Loss 作为损失函数, 解决了边界框回归中的样本不平衡问题, 使回归过程更加专注于高质量锚框, 加快收敛速度, 并提高模型的回归精度和鲁棒性。通过引入 Focal EIoU Loss 的性能评估实验, 实验结果如表 3 所示, 证明使用 Focal EIoU Loss 作为损失函数对模型的性能有较大幅度的提升。

表 3 引入 Focal EIoU Loss 的性能评估实验

Table 3 Performance evaluation with Focal EIoU Loss

算法	Recall	Precision	mAP/%
YOLO v5	0.542	0.566	0.575
YOLO v5+Focal Loss	0.664	0.655	0.688

2 电厂关键区域管道油液泄漏设计方案

2.1 总体网络结构

电厂生产现场服务器算力有限。出于对模型运算开销的考虑, 本文提出了基于改进 YOLO v5 算法的电厂关键区域管道油液泄漏检测算法, 选取 YOLO v5s 为基础进行算法改进, 如图 4 所示。

改进后的算法在网络中引入了 CBAM, 加强对管道油液泄漏图像区域特征的学习, 使得模型更加专注于对管道泄漏特征的提取, 弱化复杂背景对检测结果的影响; 同时针对电厂管道油液泄漏存在被检测目标尺度较小的




图 4 CBAM-YOLO v5 算法整体结构
Fig. 4 Structure of CBAM-YOLO v5

特征, 通过引入双向特征金字塔网络进行多尺度特征融合, 减少冗余计算, 提升算法对小目标的检测能力; 为了进一步提高管道泄漏检测的精度, 采用 Focal EIoU Loss 作为损失函数, 使回归过程更加专注于高质量锚框, 提高模型的收敛速度、回归精度和鲁棒性。

本文所提出的电厂关键区域管道油液泄漏检测整体流程如图 5 所示。




图 5 电厂关键区域管道油液泄漏检测整体流程
Fig. 5 The overall process of pipeline oil leakage detection algorithm detection in key areas of power plants

通过联合电厂中油库、化水车间等关键区域各处的高清摄像头或双视云台,以及智能巡检机器人的机载可见光、红外摄像头,对电厂关键区域内的设备以及管道进行影像采集;然后通过无线 AP 或者有线网络在存储服务器与机器人服务器和算法服务器之间建立通信连接,实现图像数据的转储,用于算法服务器中的管道油液泄漏检测算法进行实时检测。最后通过前端可视化界面进行检测结果的展示,实现电厂关键区域管道油液泄漏图像数据的实时查验和自动识别预警。

2.2 电厂关键区域管道油液泄漏检测数据集

虽然目前目标检测技术相关的研究颇多,但是更多地专注于算法本身性能的提升,缺乏实际应用场景的技术落地。现有的很多目标检测算法都是通过特定的数据集进行训练,在电厂复杂且特殊的环境下,并不能达到很高的检测精度。电厂管道泄漏图像目前尚无权威公开数据集,并且实际电厂管道发生油液泄漏的影像数据难以收集,所以并没有可以直接利用的管道油液泄漏图像数据集。

通过到电厂实地考察并进行管道泄漏场景模拟实验,以及综合电厂已有的泄漏图像和视频数据,构建了涵盖室内外管道、阀门等多个场景的电厂关键区域管道泄漏检测数据集。通过视频、图片的形式采集了大量的数据,最终通过数据清洗,保留了 3 000 张管道油液泄漏图像用于构建数据集,并使用 Python 脚本文件将全部图像按照 70%,20%,10%的比例随机划分为训练集、验证集、测试集,数据集部分样本如图 6 所示。



图 6 数据集部分样本
Fig. 6 Some samples

经统计,共标注带有管道油液泄漏现象的图像 2 836 幅,数据集格式采用 YOLO 格式,使用开源标注工具 labeling 对电厂关键区域管道油液泄漏数据集集中的样本进行手工标注,并填写对应的油液泄漏标签,数据集标注

样例如图 7 所示。



图 7 标注样例
Fig. 7 Annotation examples

3 实验结果与分析

3.1 实验环境

本文在 Windows 10 操作系统上进行实验环境配置,采用 Pytorch 作为深度学习算法框架,具体实验环境配置如表 4 所示。

表 4 实验环境配置

Table 4 Experimental environment	
操作系统	Windows 10
CPU	I9 12900k
GPU	NVIDIA RTX 3090
内存	32 G
GPU 显存	24 G
Python 版本	3. 8
算法框架	Pytorch 1. 11. 0

3.2 模型训练参数

YOLO v5 具有 4 种不同的模型,根据复杂度由低到高排序依次为 YOLO v5s、YOLO v5m、YOLO v5l、YOLO v5x。由于电厂中现有服务器设备较老,出于现场服务器实际情况和检测成本的考虑,因此 YOLO v5s 算法更适用于电厂关键区域管道油液泄漏检测^[20],它在兼顾了模型检测精度与模型训练难易程度的前提下,可以使用较少的成本对现场中服务器进行改进升级,从而满足算法的运行环境。

主要训练参数如下:训练周期(epochs)为 300,批处理量(batchsize)为 4,图片尺寸为 640×640,采用 Adam 一阶优化算法,初始学习率为 0. 001、动量初始值为 0. 9、权重衰减率为 0. 000 5。

3.3 评价指标

采用混淆矩阵中的查准率和召回率作为识别精度的基本指标:查准率主要用于评估模型预测的准确性;召回率主要用于评估查找的全面性。根据查准率和召回率计算得到平均精度(mean average precision, mAP),作为最终的精度评价指标,以此来衡量训练所得到的模型的综

合性能,并将交并比为 0.5 作为判别检测成功与否的阈值。

采用每秒传输帧数 (frames per second, FPS) 来评估算法在运算速度上的性能。本文所提出的改进算法的最终目的是为了与电厂监控系统结合,搭建电厂在线实时管道油液泄漏检测系统,因此需要具有一定的实时性,因此使用此项指标来评估算法动态实时检测识别的性能。

电厂中环境复杂多变,为了检测光照强度对模型检测精度的影响,本文采用两组不同光照强度、不同角度的油液漏液图片对原 YOLO v5s 模型和改进后的模型进行对比测试。

3.4 实验结果分析

将改进后的电厂关键区域管道油液泄漏检测算法在训练集上进行多轮训练,得到权重文件,并选出表现最好的权重文件作为模型的权重,对测试集中的图像进行检测,结果如图 8 所示。

图 8(a) 列为待检测的输入图像,图 8(b) 列为输出的检测结果,检测结果中准确地检测出了阀门油液泄漏的位置。此外,算法对于同一个场景中存在多处泄漏的情形,也能够准确地检测出来。




图 8 CBAM-YOLO v5s 检测结果示例

Fig. 8 Examples of experimental results

图 9 是基于同一场景不同图像曝光度、不同角度下的检测识别结果。从实验结果可以看出,改进后的电厂关键区域管道泄漏检测算法在不同角度或者光照强度下的检测效果都比较稳定,能够准确地检测出漏液的水柱或者是地上的油渍。原 YOLO v5s 模型在俯视角度或者

存在阴影遮挡的情况下,出现了明显的漏检情况,说明算法经过改进之后,模型的稳定性有所提高,对于电厂中生产现场复杂的环境以及光照的变化有了更好的适应能力。




图 9 YOLO v5s 和 CBAM-YOLO v5s 算法检测结果对比

Fig. 9 Comparison of detection results of YOLO v5s and CBAM-YOLO v5s algorithms

实验结果表明,改进后的算法能够更加准确地检测出管道油液泄漏,即使是在复杂的室外场景也能有很好的检测效果,具有检测精度高、鲁棒性等优点,同时降低了模型误检的几率。

为了更加客观地验证算法性能,通过在同一自建管道油液泄漏检测数据集下进行检测,对比主流的几种目标检测算法,最终得到的性能测试结果如表 5 所示。

表 5 基于同一自建数据集的不同算法性能对比

Table 5 Performance comparison of different algorithms based on the same self-built dataset

算法	mAP/%	FPS
SSD	52.5	29
Mask R-CNN	59.1	15
CenterNet	52.6	26
YOLO v2	53.1	24
YOLO v4	54.2	25
YOLO v5s	57.5	26
本文算法	76.9	28

通过对比可以发现,本文所提出的改进算法相较于其他目标检测算法,具有最高的检测精度 76.9%,说明经过改进之后,算法能够对管道油液泄漏的特征进行更加准确的提取和学习。并且改进后的算法在速度上也有提升,对比其他 YOLO 系列的目标检测算法有 2~4 帧的提升,对比其他算法速度提升更加明显。

为了进一步验证实验效果,利用改进后的算法对现场实际模拟管道油液泄漏场景进行了视频检测实验,发现改进后的算法在训练之后能够准确地识别管道油液泄漏情况,并能够稳定、流畅地在视频中对泄漏位置进行框选标注。

3.5 消融实验

本文针对原 YOLO v5s 模型的主干网络、特征融合和损失函数等进行了改进,为了评估各项改动和各项改动组合对于算法性能优化的程度,本文进行了消融实验,实验结果如表 6 所示。

表 6 消融实验数据
Table 6 Ablation data

算法	Recall	Precision	mAP/%
YOLO v5	0.542	0.566	0.575
YOLO v5+CBAM	0.596	0.645	0.656
YOLO v5+BiFPN	0.614	0.640	0.672
YOLO v5+Focal Loss	0.664	0.655	0.688
YOLO v5+CBAM+BiFPN	0.673	0.688	0.755
YOLO v5+BiFPN+FocalLoss	0.732	0.745	0.762
YOLO v5+CBAM+Focal Loss	0.746	0.758	0.771
本文算法	0.782	0.793	0.796

实验结果表明,各项改动单独应用均能够对最终的结果产生正向优化,其中 Focal EIoU Loss 对于识别准确率的贡献相对较为明显。不同改动之间的组合对整体的表现也都产生了正向优化,3 项改动组合起来同时应用对于最终的识别精度优化效果最好,达到了 79.6% 的平均准确率,取得了所有算法中最好的检测效果。通过现场场景的模拟测试,能够对现场中的油液滴漏现象进行准确检测,且误检率低,通过与视频监控软件的结合就能够构成电厂管道油液泄漏检测系统,实现实时检测,具有很高的实际应用价值。

4 结 论

通过对比原 YOLO v5s 目标检测算法,本文针对复杂的电厂关键区域管道油液泄漏场景,提出基于改进 YOLO v5s 的管道油液泄漏检测算法,通过融入 CBAM 注意力机制模块,弱化复杂背景对检测结果的影响,加强对管道油液泄漏图像区域特征的学习,使得模型更加专注于对管道泄漏特征的提取;运用双向特征金字塔网络进行多尺度特征融合,减少冗余计算,同时提升算法对小目标的检测能力;采用 Focal EIoU Loss 作为损失函数,使回归过程更加专注于高质量锚框,加快收敛速度,并提高模型的回归精度和鲁棒性。

目前,电厂这类复杂场景下的管道泄漏检测仍然面临诸多问题,比如生产现场现有摄像头像素不高,导致所采集的影像数据不够清晰;生产现场照明条件较差,管道密集且交错分布,导致油液泄漏检测较为困难。在不改变生产现场现有检测设备的前提下,上述问题可能需要对采集到的图片进行超分辨率重建,或者拍摄红外图像进行图像融合来进行解决。实验测试中还发现,在管道

油液泄漏特征并不明显,尤其是油液滴落频率不高的情况下,仍然容易出现漏检,说明算法对于轻微滴漏情形的检测能力还有待提升,以上问题将是后续工作的重点研究方向。

参考文献

[1] NELLIS M D. Application of thermal infrared imagery to canal leakage detection [J]. Remote Sensing of Environment, 1982, 12(3): 229-234.

[2] ADEFILA K, YAN Y, WANG T. Leakage detection of gaseous CO₂ through thermal imaging [C]. 2015 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) Proceedings. IEEE, 2015: 261-265.

[3] ATEF A, ZAYED T, HAWARI A, et al. Multi-tier method using infrared photography and GPR to detect and locate water leaks [J]. Automation in Construction, 2016, 61: 162-170.

[4] DAI D, WANG X, ZHANG Y, et al. Leakage region detection of gas insulated equipment by applying infrared image processing technique [C]. 2017 9th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA). IEEE, 2017: 94-98.

[5] KROLL A, BAETZ W, PERETZKI D. On autonomous detection of pressured air and gas leaks using passive IR-thermography for mobile robot application [C]. 2009 IEEE International Conference on Robotics and Automation. IEEE, 2009: 921-926.

[6] WANG J, TCHAPMI L P, RAVIKUMAR A P, et al. Machine vision for natural gas methane emissions detection using an infrared camera [J]. Applied Energy, 2020, 257: 113998.

[7] ARAUJO M S, BLAISDELL S G, DAVILA D S, et al. Detection of hazardous leaks from pipelines using optical imaging and neural network: U. S. Patent 10, 657, 443 [P]. 2020-5-19.

[8] 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 (CASE). IEEE, 2019: 1282-1288.

[9] LI R, HUANG H, XIN K, et al. A review of methods for burst/leakage detection and location in water distribution systems [J]. Water Science and Technology: Water Supply, 2015, 15(3): 429-441.

[10] 李章维,胡安顺,王晓飞.基于视觉的目标检测方法综述 [J]. 计算机工程与应用, 2020, 56(8): 1-9.

LI ZH W, HU AN SH, WANG X F. Survey of vision based object detection methods [J]. Computer

- Engineering and Applications, 2020, 56(8): 1-9.
- [11] 化嫣然, 张卓, 龙赛, 等. 基于改进 YOLO 算法的遥感图像目标检测[J]. 电子测量技术, 2020, 43(24): 87-92.
HUA Y R, ZHANG ZH, LONG S, et al. Remote sensing image target detection based on improved YOLO algorithm [J]. Electronic Measurement Technology, 2020, 43(24): 87-92.
- [12] 徐晓光, 李海. 多尺度特征在 YOLO 算法中的应用研究[J]. 电子测量与仪器学报, 2021, 35(6): 96-101.
XU X G, LI H. Research on the application of multi-scale features in YOLO algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(6): 96-101.
- [13] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [14] 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.
- [15] 郭璠, 张泳祥, 唐璁, 等. YOLOv3-A: 基于注意力机制的交通标志检测网络[J]. 通信学报, 2021, 42(1): 87-99.
GUO F, ZHANG Y X, TANG J, et al. YOLOv3-A: A traffic sign detection network based on attention mechanism [J]. Journal on Communications, 2021, 42(1): 87-99.
- [16] 张海超, 张闯. 融合注意力的轻量级行为识别网络研究[J]. 电子测量与仪器学报, 2022, 36(5): 173-179.
ZHANG H CH, ZHANG CH. Research on lightweight action recognition networks with fusion attention [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(5): 173-179.
- [17] TAN M, PANG R, LE Q V. Efficient det: Scalable and efficient object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [18] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression [J]. arXiv preprint arXiv:2101.08158, 2021.
- [19] 陶晓天, 何博侠, 张鹏辉, 等. 基于深度学习的航天密封圈表面缺陷检测[J]. 仪器仪表学报, 2021, 42(1): 199-206.
TAO X T, HE B X, ZHANG P H, et al. Surface defect detection of aerospace sealing rings based on deep learning [J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 199-206.
- [20] 吕禾丰, 陆华才. 基于 YOLOv5 算法的交通标志识别

技术研究[J]. 电子测量与仪器学报, 2021, 35(10): 137-144.

LYU H F, LU H C. Research on traffic sign recognition technology based on YOLOv5 algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 137-144.

作者简介



E-mail: pengdaogang@126.com

Peng Daogang (Corresponding author), received his Ph. D. from Tongji University in 2009. Now he is a professor in the Faculty of Automation Engineering of Shanghai University of Electric Power. His main research interests include intelligent power generation, integrated intelligent energy, intelligent robots for power inspection, information security of power control systems, power equipment condition monitoring and fault warning, etc.



Pan Junzhen, received his B. Sc. degree from Shanghai University of Electric Power in 2020. Now he is a M. Sc. candidate at Shanghai University of Electric Power. His main research interests include deep learning and object detection.



Wang Danhao, Ph. D. candidate in electrical engineering at Shanghai University of Electric Power. His main research interests include the development of intelligent inspection robots and related software for smart power plants.



Hu Jie, M. Sc. degree. Now he is a senior engineer of the Energy and Environmental Protection of Baoshan Iron and Steel Co., Ltd. His main research interest includes power plant production management.

彭道刚 (通信作者), 2009 年于同济大学获博士学位。现为上海电力大学自动化工程学院教授, 主要研究方向为智能发电、综合智慧能源、电力巡检智能机器人、电力控制系统信息安全、电力设备状态监测与故障预警等。

潘俊臻, 2020 年于上海电力大学获得学士学位, 现为上海电力大学硕士研究生, 主要研究方向为深度学习和目标检测。

E-mail: pan_junzhen@163.com

潘俊臻, received his B. Sc. degree from Shanghai University of Electric Power in 2020. Now he is a M. Sc. candidate at Shanghai University of Electric Power. His main research interests include deep learning and object detection.

王丹豪, 上海电力大学电气专业在读博士, 主要研究方向为智能巡检机器人以及智慧电厂相关软件的开发。

E-mail: danhao.wang@qq.com

Wang Danhao, Ph. D. candidate in electrical engineering at Shanghai University of Electric Power. His main research interests include the development of intelligent inspection robots and related software for smart power plants.

胡捷, 硕士, 现为宝山钢铁股份有限公司能源环保部高级工程师, 主要研究方向为发电厂生产管理。

E-mail: hujie@baosteel.com

Hu Jie, M. Sc. degree. Now he is a senior engineer of the Energy and Environmental Protection of Baoshan Iron and Steel Co., Ltd. His main research interest includes power plant production management.