

DOI: 10.13382/j.jemi.B2205638

# 改进 YOLOv5 算法下的输电线路外破隐患 目标检测研究\*

龙乐云<sup>1</sup> 周腊吾<sup>1</sup> 刘淑琴<sup>2</sup> 黄彪<sup>1</sup> 范凯<sup>1</sup>

(1. 长沙理工大学电气与信息工程学院 长沙 410114; 2. 广东电网有限责任公司电力科学研究院 广州 510080)

**摘要:**采用图像视频技术对输电线路通道实时监控,通过智能目标检测算法实现外力破坏隐患目标的识别并预警的方法精确率高,近年来被逐渐普及。但在实际环境中,由于图片背景复杂、天气变化(如雾、雨等)等因素,训练数据无法涵盖所有条件,目标识别算法泛化能力较弱,实际应用中常出现漏报和误报。基于这些问题,采用 YOLOv5 作为本文算法基础,通过数据扩增模拟不同天气,引用自注意力机制(CBAM)增强模型的特征提取能力,并加入多尺度域自适应网络对训练集进行对抗训练,增强模型对不同天气、不同场景的泛化能力。经实验证明,本文所用算法得到的召回率(Recall)达到了 86.9%,较原算法有明显提升,平均准确率(MAP)高于原 YOLOv5 算法,达到了 92.2%,能准确的检测出待检外破目标,减少漏检、误检。

**关键词:**外力破坏;目标检测;天气变化;注意力机制;多尺度域自适应;YOLOv5

**中图分类号:** TM769; TN919.8 **文献标识码:** A **国家标准学科分类代码:** 470.4054

## Identification of hidden damage targets by external forces based on domain adaptation and attention mechanism

Long Leyun<sup>1</sup> Zhou Lawu<sup>1</sup> Liu Shuqin<sup>2</sup> Huang Biao<sup>1</sup> Fan Kai<sup>1</sup>

(1. School of Electrical &amp; Information Engineering, Changsha University of Science and Technology, Changsha 410114, China; 2. Electric Power Research Institute Guangdong Power Grid, Guangzhou 510080, China)

**Abstract:** The method of using image and video technology to monitor the transmission channel in real time and using intelligent target detection algorithm to realize the identification and early warning of potential damage caused by external force with high accuracy and has been gradually popularized in recent years. However, in the real conditions, due to the scene change, weather change (such as fog, rain, etc.) and other factors, training data cannot cover all conditions, and the algorithm model generalization ability is weak, and there are often missed and false positives in the practical application. Based on these problems, we use the YOLOv5 as based algorithm. This article through the data amplification to simulate different weather, with the domain adaptive network to combat training of the training set, strengthen model generalization ability of the different weather, different scene, citing the attention mechanism (CBAM) at the same time, strengthen model's ability to extract features from data. Experiments prove that the Recall obtained by the algorithm in this paper reaches 86.9%, which is significantly improved compared with the original algorithm, and the average accuracy (MAP) is 92.2% higher than that of the original YOLOv5 algorithm, which can accurately detect the target to be detected and reduce missed and false detection.

**Keywords:** external force damage; target detection; the weather changes; attentional mechanism; multiscale domain adaptive; YOLOv5

## 0 引言

架空输电线路是维持电能传输的重要通道,保证其安全稳定运行对整个电力系统至关重要<sup>[1]</sup>。引发输电线

路故障的原因有很多,如有因雷击<sup>[2]</sup>、冰灾<sup>[3]</sup>、山火<sup>[4]</sup>等自然因素引起的输电线路跳闸,也有因外力破坏、设备故障等非自然因素引起的跳闸。而其中,外力破坏故障主要表现为违规施工机械碰线、异物挂线等情况导致的输电线路跳闸。此类故障偶发性大,且一旦发生,线路重

合闸动作成功率较低<sup>[5]</sup>。近年来,由于我国城镇化建设加快,输电走廊面积逐渐被建筑施工压缩,输电线路的外破故障发生率大幅升高,严重影响着电力系统的安全稳定运行。目前针对输电线路外力破坏故障的措施主要有人工巡线、无人机巡检及图像视频监控等。人工巡线成本高、工作周期长,效率不高,无人机巡检可无视复杂的地形条件开展巡视任务<sup>[6]</sup>,但是其飞行受天气、空域限制等影响,无法随时随地开展巡检任务。图像视频监控与传统人工巡方式相比,成本更低,能够实时监控输电线路的运行状态,更适用于外破故障的巡视。但是该方法需要通过将图像视频装置定时拍摄的图片传送到后台,后台工作人员对图片进行筛查,遴选出具有外破隐患的图片后进行告警,仍需耗费一定的人力物力,且与现场情况还是具有滞后性,因此实现外破隐患实时自动识别报警是当前亟待解决的问题。

对具有外破威胁的目标进行准确无误的识别是实现精准自动报警的重要前提,是至关重要的一步。在外力破坏隐患的目标识别方面已有一定研究。赵庆杭等<sup>[7]</sup>结合吊车自身特点进行“形状-纹理-颜色”特征融合,并采用随机森林分类器进行目标识别,但识别类别单一,难以满足外破隐患检测要求。深度学习采用卷积神经网络(convolutional neural network, CNN)对目标进行特征提取,在图像处理和目标检测方面应用广泛,近年来发展迅速,在输电线路故障检测方面已有一定应用,郝帅等<sup>[8]</sup>针对输电线路待检测目标易受复杂背景和部分遮挡影响问题,提出一种基于卷积块注意力模型的 YOLOv3 输电线路故障检测方法;魏贤哲等<sup>[9]</sup>采用部分边界框标注的实例分割神经网络算法,将检测分支的特征迁移到掩膜分支,对常见外破类别的平均识别准确率高于 91%。但实际应用环境复杂,场景变换、天气变化、光线的影响、检测目标相互遮挡等各种因素对外破隐患目标检测影响较大。

针对以上问题,本文提出一种改进 YOLOv5 目标检测算法。本文的主要工作如下:1)在一阶段目标检测算法 YOLOv5 的基础上,采用多尺度领域自适应网络,对提取到的特征进行对抗训练,增强整体模型的泛化能力。2)通过模拟天气变化、亮度变换以及添加噪声等方式对数据集进行扩充,以满足本文的研究要求。3)在主干网络中增加一个自注意力机制(convolutional block attention module, CBAM)层,增强网络特征提取能力。4)采用 DIOU-NMS 非极大值抑制方法减小在同类目标遮挡时的漏检率。

## 1 智能图像视频外破监测技术

当大型施工机械等外破隐患物体与架空输电线路的

距离小于安全距离时就可能导致放电,进而引起输电线路接地短路故障。而放电距离受到温度、气压、湿度、电压等级、电流大小等多种因素影响,所以施工的安全距离往往无法准确界定。

智能图像视频外破监测技术是利用深度学习算法对摄像头捕捉到的外破隐患图像进行处理和识别,并实现自主告警的一种技术,其工作示意图如图 1 所示。当输电线路存在外破隐患,通过摄像头捕捉到图像,然后经 4G 网络传输到后台服务器中进行算法识别并告警。通过深度学习算法的应用,本文基本上已实现了外力破坏的实时监控与告警。但是大型施工机械作业的背景环境较为复杂,并且户外天气、光照等因素时常变化,导致对图像的处理难度大,增加了外破隐患目标的误判率与漏判率,是当下急需解决的一个难点。

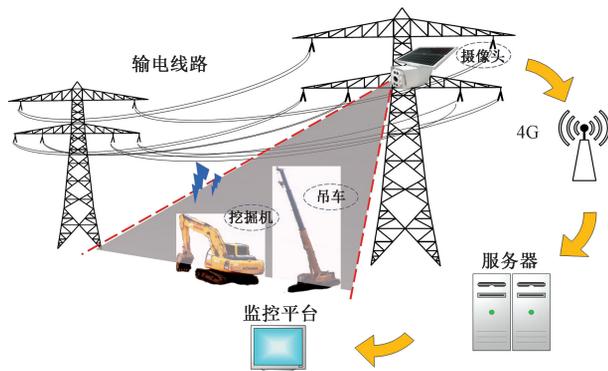


图 1 智能图像视频外破监测示意图

Fig. 1 Schematic diagram of intelligent image and video outbreking monitoring

## 2 基于改进 YOLOv5 的外破目标检测算法

### 2.1 YOLOv5 算法的目标检测原理

YOLOv5<sup>[10]</sup>结构如图 2 所示,输入端采用 Mosaic 数据增强,在初始锚框的基础上基于训练数据输出预测框,并和真实框 groundtruth 进行比对,计算两者差距,再反向更新,同时对原始图片自适应填充黑边并缩放至统一大小,然后再送入 Backbone,提高算法速度。

主干网络(Backbone)部分主要由 Focus<sup>[11]</sup>结构和 CSP 结构组成。Focus 模块在图片进入 Backbone 前,对图片进行切片操作,将  $640 \times 640 \times 3$  的图像先变成  $320 \times 12$  的特征图,如图 3 所示。再经过  $3 \times 3$  的卷积操作,形成  $320 \times 320 \times 64$  的特征图,在下采样的同时最大限度的保留了原图的特征信息。CSP 模块将基础层的特征映射划分为两部分,然后通过跨阶段层次结构将它们合并,减少了计算量,提高了算法准确率。

YOLOv5 的 Neck 结构采取多尺度特征金字塔 FPN+ PANet 的结构。如图 4 所示,FPN 自顶向下将深层特征

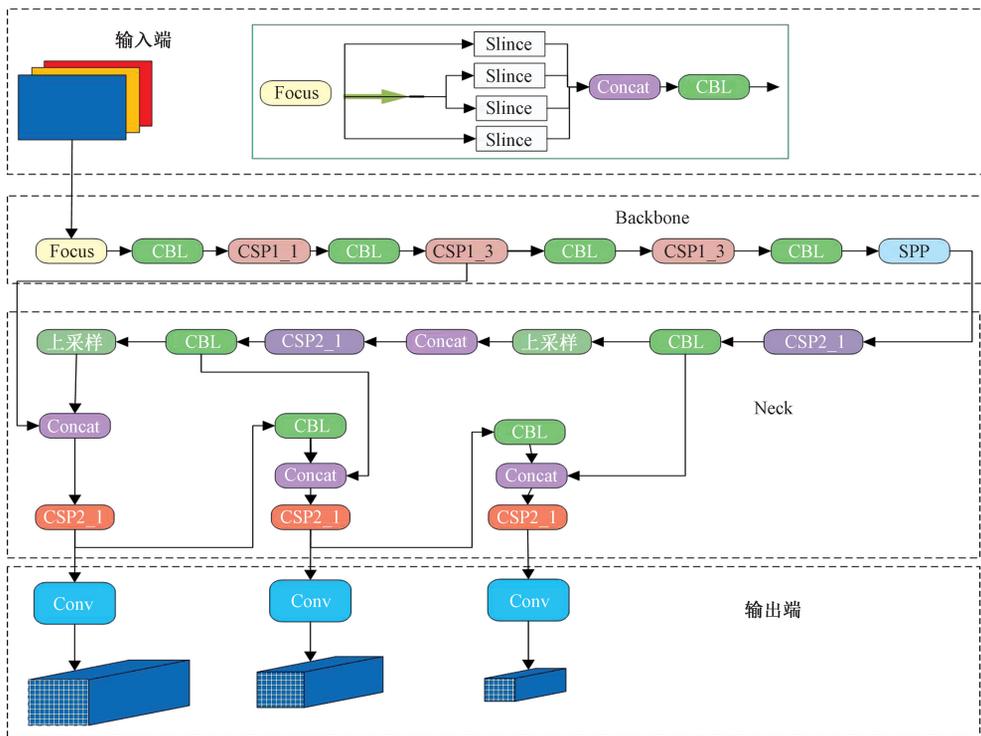


图 2 YOLOv5 结构图

Fig. 2 Structure chart of YOLOv5

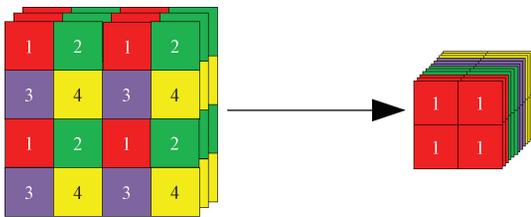


图 3 Focus 结构图

Fig. 3 Structure chart of Focus

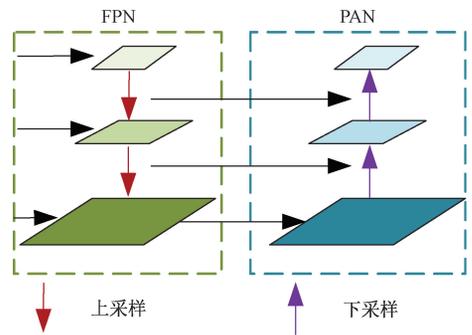


图 4 FPN+PAN 结构图

Fig. 4 Structure chart of FPN+PAN

图通过上采样和浅层特征融合,增强特征图的语义信息,而 PANet 自底向上将带有强位置信息的浅层特征图下采样与深层特征图再融合,以增强 Neck 网络的特征融合能力<sup>[12-13]</sup>。

最后在输出端, YOLOv5 以  $GIOU\_Loss^{[14]}$  作为边界框回归的损失函数。其定义如下:

$$F_{Loss} = 1 - IOU + \frac{|C/(A \cup B)|}{|C|} \quad (1)$$

式中:  $F_{Loss}$  表示损失函数,  $IOU$  表示交并比,  $A$  表示标注框,  $B$  表示预测框,  $C$  表示预测框与标注框的最小外接矩形面积,  $A \cup B$  表示预测框与标注框的并集。

## 2.2 改进方法

本文为改善自身因素的影响, 提出基于领域自适应和注意力机制的改进 YOLOv5 输电线外破隐患目标检

测算法。算法的具体结构如图 5 所示。

### 1) CBAM 自注意力模块

在输电线外破隐患监测中, 拍摄图片背景有时较为复杂, 无关车辆、建筑物等会对外破目标的检测造成干扰, 降低识别准确率。为降低干扰, 本文通过在 YOLOv5 算法的 Backbone 结构中加入注意力机制模块 (convolutional block attention module, CBAM)<sup>[15]</sup>, 以提升算法模型的特征提取能力, 其结构如图 6 所示。

CBAM 将通道注意力与空间注意力相结合, 以中间特征图  $F = \mathbb{R}^{H \times W \times C}$  为输入, 沿着两个独立的维度 (通道和空间), 依次计算出注意力图, 然后将注意力图乘以输入特征图进行自适应特征细化。在特征图信息提取时同时使用

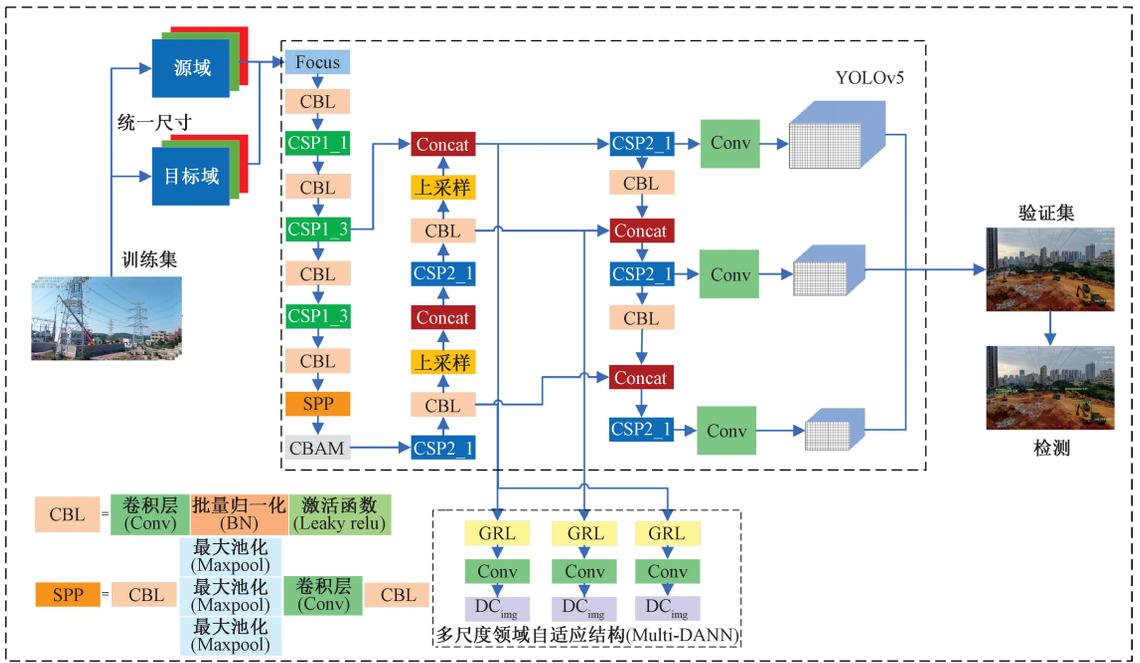


图 5 算法总框图

Fig. 5 Block diagram of the algorithm

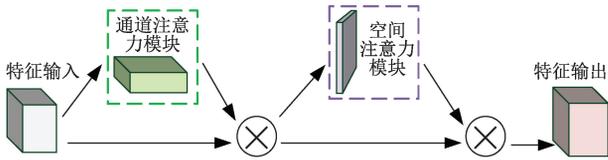


图 6 自注意力机制 CBAM 结构图

Fig. 6 Structure diagram of self-attentional mechanism CBAM

全局平均池化和最大池化,减少信息丢失。

通道注意力模块利用特征图通道间的关系,采用全局平均池化和最大池化聚合特征图空间信息,再经过多层感知器 MLP、Sigmoid 激活函数处理,生成通道注意力图,侧重于提取检测目标的轮廓信息特征,通道注意力图  $M_c$ 。计算公式如下:

$$M_c = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) = \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \quad (2)$$

式中:  $\sigma$  表示 Hard Sigmoid 激活函数,  $F_{avg}^c$ 、 $F_{max}^c$  分别表示利用平均池化和最大池化在空间上生成的特征映射,  $MLP$  表示 CBAM 中的共享网络,  $W_1$ 、 $W_0$  分别表示 MLP 中多层感知器中的隐藏层权重和输出层权重。

通道注意力模块之后,再引入空间注意力模块,提取目标特征图的空间位置信息作为通道注意特征图的补充。将上述  $M_c$  与初始输入  $F$  相乘得到  $F'$  作为空间注意力模块的输入,通过卷积操作,并同样使用两种池化方法聚合位置信息,拼接之后再利用卷积及 Sigmoid 激活函数

得到一个具有空间注意力的空间矩阵,最后与  $F'$  相乘得到新的特征图。其计算公式为:

$$M_s = \sigma(f^{7 \times 7}([\text{AvgPool}(F'), \text{MaxPool}(F')])) = \sigma(f^{7 \times 7}([F'_{avg}, F'_{max}])) \quad (3)$$

本文在 YOLOv5 模型的 Backbone 中引入自注意力模型 CBAM。利用 Grad-CAM<sup>[16]</sup>进行引入 CBAM 前后的效果可视化,前后对比如图 7 所示(图中中间深色部分表示算法模型对物体的注意力程度较高)。从图中明显可见,在引入 CBAM 后,特征覆盖到了待识别物体的更多部位,有效提升了算法模型的特征提取能力。

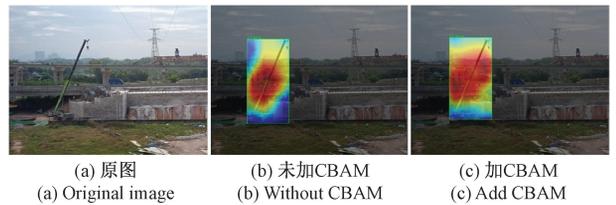


图 7 CBAM 效果可视化图

Fig. 7 Effect visualization of CBAM

2) 基于 YOLOv5 的多尺度特征域自适应

为尽可能解决在户外由于天气、光照等因素的变化而引起的输电线路外破隐患误检与漏检,本文提出一种多尺度特征域自适应模型。

域自适应网络<sup>[17]</sup>(domain adaptation neural network, DANN)属于迁移学习的一种。在域自适应中,将数据集分为源域以及目标域两部分,源域含有数据标签,目标域

不含数据标签。域自适应的任务是通过源域数据集特征提取并实现精确分类,将特征分布不同的源域和目标域数据映射到一个特征空间中,并进行特征对齐,以此将源域数据集训练好的分类器迁移至目标域集上,实现跨域检测,因此属于无监督学习。如图 8 所示,DANN 的结构主要可分为特征提取器、分类器以及域判别器 3 个部分。

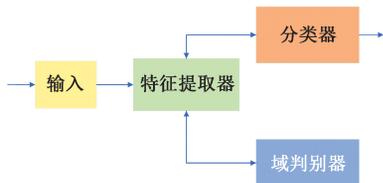


图 8 域自适应网络结构示意图

Fig. 8 Schematic diagram of domain adaptive network structure

特征提取器提取源域和目标域数据集的特征信息,分类器对源域数据集的特征信息进行分析并计算出数据集的类别损失,同时通过反向传播不断更新优化。目标域数据集和源域数据集特征输入到域判别器中,判别输入特征属于目标域还是源域,计算域分类损失,并也采用反向传播方式对域分类损失不断更新优化。

本文将 Backbone 结构作为域自适应网络的特征提取器,分别使用第 1 次上采样前、第 2 次上采样前及即将输入至 Neck 结构时的 3 处不同尺度的特征作为 DANN 的输入(如图 4)。采用不同尺度特征作为域自适应网络的输入能够充分利用图片的特征信息,避免在不断地卷积操作中造成梯度消失,提高域自适应网络的分类效率。源域数据集图片输入至 YOLOv5 的 Neck 模块中进行标签分类,计算标签分类损失,同时将源域数据集和目标域数据集特征输入域判别器(domain classifier,  $DC_{img}$ )中,通过多个卷积层结构进行域分类,并使用二元交叉熵分别计算不同尺度的域分类损失(domain classification loss,  $Loss_{DC}$ ),计算公式如下:

$$Loss_{DC} = - \sum_{i,u,v} [D_i \ln P_i^{(u,v)} + (1 - D_i) \ln(1 - P_i^{(u,v)})] \quad (4)$$

式中: $D_i$  表示第  $i$  个图像的域标签,图像属于源域时为 1,属于目标域时为 0,  $P_i^{(u,v)}$  表示域分类器在特征图位置  $(u,v)$  的域类概率输出。

此外,将对抗思想引入域自适应网络中。通过最大化域分类损失来混淆源域数据集与目标域数据集,最小化标签分类损失达到图片精确分类,两者相互作用,最终达到平衡,得到域不变特征。但两者在反向梯度更新参数时特征提取处的梯度方向上相反。为了解决最大化-最小化矛盾,在特征提取器与域判别器之间加入梯度反转层(gradient reversal layer, GRL)<sup>[18]</sup>。域分类损失进行反向传播时自动对梯度方向取反,在前向传播时作恒等

变换,实现 DANN 网络端到端的训练。

### 3) DIOU-NMS 非极大值抑制

YOLOv5 源码中使用 NMS 非极大值抑制方法对图片中生成的边界框进行后处理,进行筛选和删除。但在多类别检测中,使用 NMS 易造成距离很近的同类目标漏选<sup>[19]</sup>。

本文对 NMS 进行改进,不仅考虑 bounding box 与 ground truth 的重叠问题,还考虑两个 box 之间的中心点距离,其公式为:

$$S_i = \begin{cases} S_i, IoU - R_{DIOU}(M, b_i) < \zeta \\ 0, IoU - R_{DIOU}(M, b_i) \geq \zeta \end{cases} \quad (5)$$

$$R_{DIOU} = \frac{\rho^2(\alpha_1, \alpha_2)}{d^2} \quad (6)$$

式中: $\alpha_1, \alpha_2$  分别表示两个检测框的中心点,  $\rho$  表示两中心点的欧氏距离,  $d$  表示覆盖两个检测框的最小封闭矩形的对角线长度。如图 9 所示,假设 box1 为最大得分框 M,  $R_{DIOU}$  作为惩罚项加入 IoU 中,当 box2 与它的中心点距离  $\rho$  较大时,便认为二者有可能分别对应不同目标,则将 box2 进行保留处理。

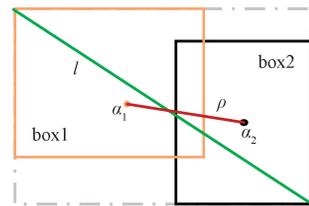


图 9 DIOU-NMS 示意图

Fig. 9 Schematic diagram of DIOU-NMS

## 3 实验结果与分析

### 3.1 数据集收集与处理

本文算法所使用的原始图像数据集均由某电网的视频智能巡检装置所拍摄。初始数据集较为杂乱,经过整理后将具有外破隐患的图片进行分类整合,最终的外破数据集中包含了吊车、挖掘机、塔吊、泵车、线路异物这 5 种常见的外破隐患。本文针对外破目标检测应用下场景多变、天气变换等难点提出多尺度域自适应方法,将相似场景、天气晴朗、光照适中的外破图片作为源域数据集,而以不同场景下,雨天、雾天等条件下的外破图片作为目标域数据集,两者共同作为本文算法模型的训练数据集,取与目标域情况类似的复杂天气外破图片作为验证集用于验证算法效果。

由于原始数据集中雨天、雾天等复杂天气下的图片较为稀少。于是本文对原始数据集采取图像变换手段模拟上述天气情况,并进行亮度变化,增加图片的复杂性。

对数据量较少的线路异物数据集图片进行水平翻转、旋转、添加高斯噪声等处理,增加样本数量,既改善了不同类型外破隐患样本之间的平衡性,又增加样本多样性。经处理后的部分样本集如图 10 所示。

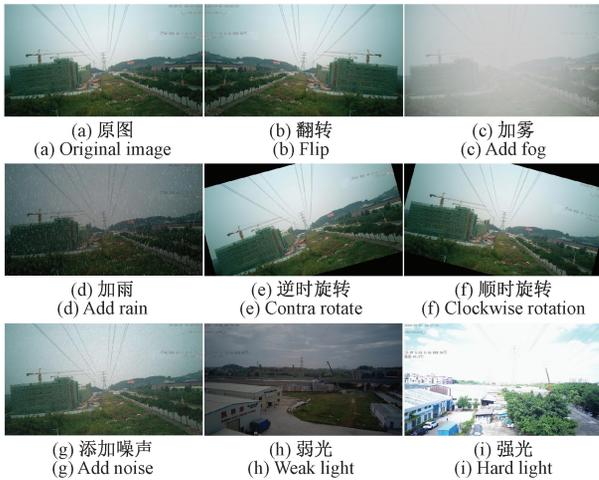


图 10 部分数据集变换与扩增结果

Fig. 10 Results of partial data set transformation and amplification

经上述方法处理后,最终得到源域数据集 1 500 张,目标域数据集 2 250 张,在目标域中随机选出 750 张作为验证集用户来检验算法的效果,其余的相同数量的源域数据集和目标数据集共同作为训练集,得到训练集与验证集的比例为 8 : 2。数据集中各种类型的外破隐患样本数量如表 1 所示,对原数据集中泵车、线路异物样本数较少的两类进行扩充,使样本均衡,提高模型的鲁棒性。随后,根据 YOLO 数据集格式,使用专门的数据集标签制作软件 Labelimg 将源域数据打上标签。

表 1 各种外破类型的样本数

Table 1 Sample numbers of various external rupture types

	吊车	挖掘机	泵车	塔吊	线路异物	
训练集	源域	429	687	452	451	533
	目标域	537	591	306	518	270
	验证集	278	421	310	274	159

### 3.2 模型训练

本文算法基于 Pytorch1. 6. 0 框架搭建,设备的 CPU 处理器采用 Intel Xeon E5-2678 v3,显卡型号为 NVIDIA GeForce RTX 2080Ti,操作环境为 Ubuntu。

将训练集(带标签的源域数据集及目标域数据集)输入本文模型,经过 Mosaic 数据增强、自适应填充和缩放等操作,将所有图片统一为 640×640 尺寸。算法初始学习率设置为 0. 01,迭代 200 轮之后改为 0. 002,总共训练 300 轮。Batch\_size 设置为 16,即一批输入 16 张图片

数据,数据加载线程数设置为 8。

### 3.3 训练结果分析与讨论

本文采用精度、召回率和均值平均精度等指标来综合评估模型的效果,各指标的具体计算公式如下:

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

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

$$MAP = \frac{\sum_{i=1}^k AP_i}{k} \quad (9)$$

式中:Pre 表示精度,Re 表示召回率,MAP 表示均值平均精确率,本文使用置信度阈值为 0. 5 时的平均精确率作为衡量标准,AP<sub>i</sub> 表示第 i 种类别的平均精度,TP 表示正样本预测出正样本数量,FP 表示负样本预测出正样本数量,FN 表示正样本预测出负样本数量,k 表示本文检测目标的类别数。

与原 YOLOv5 算法的训练数据曲线对比结果如图 11 所示。可以看出本文算法在 MAP、精度、召回率 3 个指标上均有一定提高:精度达到 92. 7%,YOLOv5 为 86. 7%,提高了 6%。图中平均精确率 MAP 值为 92. 2%,最终召回率由 82. 7%提升至 86. 9%,提高了 3. 8%。各指标收敛速度明显优于 YOLOv5 算法,本文算法在迭代至约 40 轮时,图 10 中指标均基本达到了收敛。从各指标中的提高证明了本文算法的有效性,实现了跨域准确识别,DANN 增强了模型的泛化能力。

为了进一步研究本文算法中提出的改进措施对模型的影响。本文进行了消融实验,其结果如表 2 所示。

表 2 不同方法组合对模型的影响

Table 2 The influence of different methods combination on the model

CBAM	DIOU-NMS	DANN	YOLOv5	MAP@ 0. 5/%	召回 率/%	精度/%	时间/s
			√	<b>90. 0</b>	<b>82. 7</b>	<b>86. 7</b>	<b>0. 007 5</b>
√			√	88. 5	84. 3	90. 4	0. 007 3
		√	√	90. 6	85. 2	89. 7	0. 008 2
	√		√	88. 9	84. 6	90. 3	0. 007 5
√		√	√	89. 6	85. 0	90. 4	0. 007 9
	√	√	√	<b>91. 1</b>	86. 4	<b>91. 2</b>	0. 008 2
√	√		√	88. 7	85. 9	90. 3	0. 007 3
√	√	√	√	<b>92. 2</b>	<b>86. 9</b>	<b>91. 7</b>	<b>0. 008 2</b>

表中“√”表示在训练时加入了此改进方法,从表 2 中可以看到,本文算法的精度为 91. 7%,相较于原 YOLOv5 算法训练下的 86. 7%有明显提升。且可以看出,在应用领域自适应网络与 DIOU-NMS 后,算法召回率较 YOLOv5 同样有明显的提高。将增加 CBAM 后的算法与原 YOLOv5 对比,可看到在加入 CBAM 后算法准确率

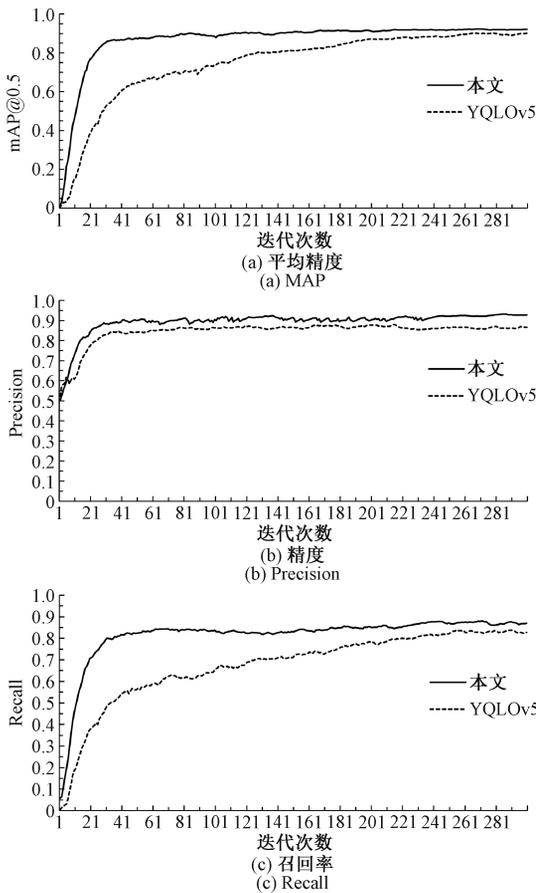


图 11 MAP、精度、召回率对比

Fig. 11 MAP, precision and recall ratio comparison diagram

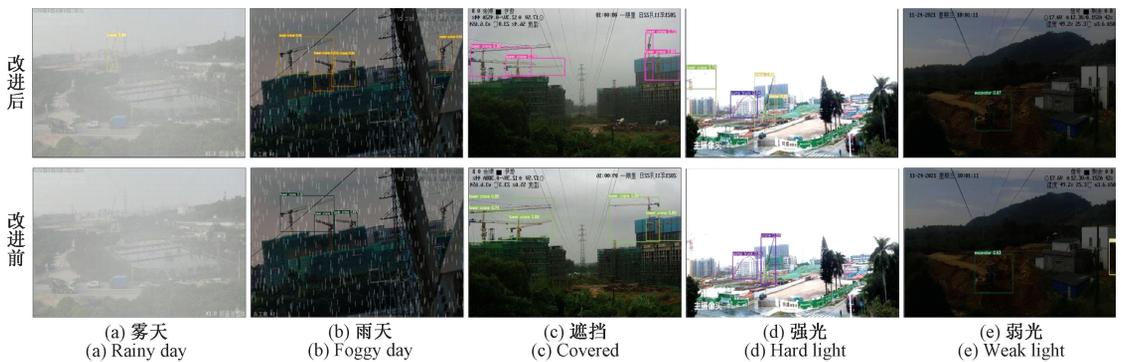


图 12 本文算法检测结果

Fig. 12 Detection results of this algorithm

### 3.5 不同算法比较

为了说明本文算法相较于其他目标检测算法的优越性,使用与本文相同的数据集,分别在 YOLOv4、Faster-RCNN、SSD 等其他常用于目标检测的算法模型上进行训练。最后将它们的结果汇总比较,具体数据如表 3 所示。本文算法的平均精确度和召回率远比 SSD 算法高。

有明显提升,提高了 3.7%,召回率同样提高了 1.6%,证明了自注意力机制的有效性。检测速度上,由于在模型中增加了注意力机制与域自适应网络,因此略有所变慢。

### 3.4 检测结果分析

将本文训练之后的权重文件用于图像视频检测装置所拍摄图片的外破隐患目标检测。为检验算法在实际情况下的泛化能力,检测所用图片均采用训练时未使用的图片。同样,所测试图片也经过模拟各种天气与光照等处理,检测结果如图 12 所示。

图 11 所示图片分别为原 YOLOv5 算法的检测结果与本文算法的检测结果对照。在雾天情况下,视野能见度大大降低,同时图中吊车目标较小,目标特征很不明显,在使用改进前的原 YOLOv5 算法后未能检测到图中的吊车目标,而使用本文改进后的算法能成功识别出目标。在雨天情况下使用改进前的 YOLOv5 算法存在漏检,采用改进后算法,漏检的塔吊目标可成功检测出来。存在遮挡,导致原 YOLOv5 算法漏检,本文算法同样能够识别出来。图 12(c) 中背景较为复杂,且多个塔吊目标相互存在遮挡,改进前虽基本也都能识别出目标,但可以看出仍存在漏检,改进后的算法改善了这一情况,准确并完整的将隐患目标检测出来。同样在图 12(d) 强光的对比中,在有遮挡情况下,本文算法仍能原 YOLOv5 算法中无法识别的吊车目标检测出来,弱光时并未有明显区别,两者表现均良好,置信度得分上本文算法稍高。

Faster-RCNN 模型虽然精度与召回率均表现不俗,但检测时间过长,在外破隐患目标检测中不适用。YOLOv4 算法表现同样不如于 YOLOv5 与本文改进后的算法。再结合前文与原 YOLOv5 算法的比较,可以看出本文算法在外破目标检测总体上还是明显优于其他算法的。

表 3 不同算法训练结果

Table 3 Training results of different algorithms

算法	MAP	召回率/%	时间/s
SSD	87.5	78.5	0.051 4
Faster-RCNN	<b>90.4</b>	<b>84.2</b>	3.071 5
YOLOv4	89.3	83.8	0.012 0
YOLOv5	<b>90.0</b>	82.7	0.007 5
本文算法	<b>92.2</b>	<b>86.9</b>	<b>0.008 2</b>

## 4 结 论

本文针对视频监控装置在外力破坏目标检测应用中由于场景、天气、遮挡等外界因素影响导致的漏检与误检情况,提出基于领域自适应与注意力机制的 YOLOv5 改进算法。结合本文实验结果,得出如下结论:

1) 在 Backbone 结构中引入 CBAM 自注意力结构,增强了模型在复杂背景下对目标检测物的特征提取能力,提高了模型的检测精度。

2) 通过在原模型中引入多尺度域自适应网络,将训练集分为源域与目标域两个数据集,两者进行对抗训练学习域不变特征,提高模型的泛化能力,减少了在雾天、雨天、强光及弱光等因素影响下外力破坏目标的漏检与误检。

3) 采用改进的 DIUO-NMS 非极大值抑制方法对检测框筛选,减少了同类目标遮挡情况下的漏检情况。

综上所述,本文算法在复杂的图片场景下准确率高、具有较好的抗干扰性,对后续外力破坏的告警研究具有一定的参考价值。

## 参考文献

- [ 1 ] 宋耐超,王瑞琦,李明明,等. 多自然灾害下的架空输电线路运行风险评估[J]. 电力系统保护与控制, 2021, 49(19): 65-71.
- SONG N CH, WANG R Q, LI M M, et al. Risk assessment of overhead transmission lines under multiple natural disasters[J]. Power System Protection and Control, 2021, 49(19): 65-71.
- [ 2 ] 冯瑞发,蔡汉生,廖民传,等. 基于改进跳闸率计算方法的输电线路雷击风险评估及防雷配置研究[J]. 电瓷避雷器, 2022(1): 75-81.
- FENG R F, CAI H SH, LIAO M CH, et al. Risk assessment and lightning protection measures configuration of transmission line based on the improved calculation method of trip rate[J]. Insulators and Surge Arresters, 2022(1): 75-81.
- [ 3 ] 陈勇,李鹏,张忠军,等. 基于 PCA-GA-LSSVM 的输电线路覆冰负荷在线预测模型[J]. 电力系统保护与

控制, 2019(10): 110-119.

CHEN Y, LI P, ZHANG ZH J, et al. Online prediction model for power transmission line icing load based on PCA-GA-LSSVM [J]. Transactions of China Electrotechnical Society, 2019(10): 110-119.

- [ 4 ] 黎鹏,阮江军,黄道春,等. 模拟山火条件下导线-板间隙击穿特性影响因素分析[J]. 电工技术学报, 2018, 33(1): 195-201.

LI P, RUAN J J, HUANG D CH, et al. Influence factors analysis of the conductor-plane gap breakdown characteristic under simulation forest fire condition[J]. Transactions of China Electrotechnical Society, 2018, 33(1): 195-201.

- [ 5 ] 陆佳政,周特军,吴传平,等. 某省级电网 220 kV 及以上输电线路故障统计与分析[J]. 高电压技术, 2016, 42(1): 200-207.

LU J ZH, ZHOU T J, WU CH P, et al. Fault statistics and analysis of 220 kV and above power transmission line in province-level power grid [J]. High Voltage Engineering, 2016, 42(1): 200-207.

- [ 6 ] 顾晓东,唐丹宏,黄晓华. 基于深度学习的电网巡检图像缺陷检测与识别[J]. 电力系统保护与控制, 2021, 49(5): 91-97.

GU X D, TANG D H, HUANG X H, et al. Deep learning-based defect detection and recognition of a power grid inspection image[J]. Power System Protection and Control, 2021, 49(5): 91-97.

- [ 7 ] 赵庆杭,王昕,郑益慧,等. 基于特征融合与随机森林的吊车碰线预警算法[J]. 高电压技术, 2020, 46(2): 471-479.

ZHAO Q H, WANG X, ZHI Y H, et al. Forewarning algorithm of crane collision with transmission lines based on feature fusion and random forest [J]. High Voltage Engineering, 2020, 46(2): 471-479.

- [ 8 ] 郝帅,马瑞泽,赵新生,等. 基于卷积块注意模型的 YOLOv3 输电线路故障检测方法[J]. 电网技术, 2021, 45(8): 2979-2987.

HAO SH, MA R Z, ZHAO X SH, et al. Fault detection of YOLOv3 transmission line based on convolutional block attention model [J]. Power System Technology, 2021, 45(8): 2979-2987.

- [ 9 ] 魏贤哲,卢武,赵文彬,等. 基于改进 Mask R-CNN 的输电线路防外破目标检测方法研究[J]. 电力系统保护与控制, 2021, 49(23): 155-162.

WEI X ZH, LU W, ZHAO W B, et al. Target detection method for external damage of a transmission line based on an improved Mask R-CNN algorithm [J]. Power System Protection and Control. 2021, 49(23):

- 155-162.
- [10] 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.
- [11] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection [J]. Computer Vision and Pattern Recognition, 2020.
- [12] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [J]. IEEE Computer Society, ArXiv Preprint, arXiv: 1612. 03144, 2017.
- [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 (CVPR), 2018: 8759-8768.
- [14] REDMON J, FARHADI A. YOLOv3: An incremental improvement[J]. ArXiv Preprint, arXiv:1804.02767, 2018.
- [15] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [J]. Springer, 2018: 1-17.
- [16] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization [J]. International Journal of Computer Vision, 2020, 128(2): 336-359.
- [17] HUO Y, ZHANG Q, JIA Y, et al. A deep separable convolutional neural network for multiscale image-based smoke detection[J]. Fire Technology, 2022: 1-24.
- [18] CHEN Y H, LI W, CHRISTOS S, et al. Domain adaptive faster R-CNN for object detection in the wild[J]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 3339-3348.
- [19] 王凤随, 王启胜, 陈金刚, 等. 基于注意力机制和 Soft-NMS 的改进 Faster R-CNN 目标检测算法[J]. 激光与光电子学进展, 2021, 58(24): 405-416.  
WANG F S, WANG Q SH, CHEN J G, et al. Improved faster R-CNN target detection algorithm based on

attention mechanism and soft-NMS [J]. Laser & Optoelectronics Progress, 2021(24):405-416.

## 作者简介



**龙乐云**, 2019 年于南昌大学科学技术学院获学士学位, 现为长沙理工大学硕士研究生, 主要研究方向为输电线路在线监测、图像处理技术。

E-mail: 1011992184@qq.com

**Long Leyun** received his B. Sc. degree from Nanchang University, College of Science and Technology in 2019. Now he is a M. Sc. candidate in Changsha University of Science & Technology. His main research interests include transmission line online monitoring and image processing technology.



**周腊吾** (通信作者), 1983 年于湖南大学获学士学位, 1993 年于湖南大学获得硕士学位, 2008 年于湖南大学获得博士学位, 现为长沙理工大学教授, 主要研究方向为新型电机电器设计及其控制、新能源发电技术。

E-mail: 1021853001@qq.com

**Zhou Lawu** (Corresponding author) received his B. Sc. degree from Hunan University in 1983, M. Sc. degree from Hunan University in 1993 and Ph. D. degree from Hunan University in 2008, respectively. Now he is a professor in Changsha University of Science & Technology. His main research interests include design and control of new electrical machinery, and new energy generation technology.



**刘淑琴**, 2016 年于南昌大学获得学士学位, 2019 年于宁夏大学获得硕士学位, 现为广东电网有限责任公司电力科学研究院工程师, 主要研究方向为输电线路监测。

E-mail: 508064710@qq.com

**Liu Shuqin** received her B. Sc. degree from Nanchang University in 2016, M. Sc. degree from Ningxia University in 2019, respectively. Now she is an engineer in Electric Power Research Institute Guangdong Power Grid. Her main research interest includes transmission line online monitoring.