

DOI: 10.13382/j.jemi.B2407387

基于 DAMF-NET 的输电线路施工机械智能检测*

张凡^{1,2} 纪超^{1,2} 宋智伟^{1,2} 贾星海^{1,2} 高鸣江^{1,2} 崔奇超^{1,2}

(1. 西安工程大学电子信息学院 西安 710048; 2. 西安市电气设备互联感知与智能诊断重点实验室 西安 710048)

摘要: 输电线路的稳定性是电网正常运行的重要保障,为防止线路施工误碰导线发生事故,针对现有检测方法精度低和可靠性差,提出了一种基于多分支双重注意力的特征提取网络 DAMF-NET。该算法通过构建多分支双重注意力机制使网络更加关注目标信息的局部特征,优化模型特征提取过程;提出多分支轻量特征融合网络,用于强化模型的全局多尺度语义信息和密集任务下的特征显著性,提高图像特征完备性;提出小目标检测网络以缓解网络尺度方差,提高小目标检测敏感性;使用焦点损失函数和 EIoU 优化损失函数,减小正负样本不平衡产生的噪声,加快模型训练收敛速度;最后设计了一种基于风险区域定位的状态识别算法,将其部署至施工机械智能检测系统。实验表明,该方法平均精度优于当前大部分检测模型,在施工机械检测和智能巡检方面具有一定的研究意义。

关键词: 智能检测;双重注意力;轻量特征融合网络;小目标检测网络;状态识别

中图分类号: TN01;TM93 **文献标识码:** A **国家标准学科分类代码:** 470.40

Intelligent detection of transmission line construction machinery based on DAMF-NET

Zhang Fan^{1,2} Ji Chao^{1,2} Song Zhiwei^{1,2} Jia Xinghai^{1,2} Gao Mingjiang^{1,2} Cui Qichao^{1,2}

(1. School of Electronic and Information, Xi'an Polytechnic University, Xi'an 710048, China; 2. Xi'an Key Laboratory of Interconnection Perception and Intelligent Diagnosis of Electrical Equipment, Xi'an 710048, China)

Abstract: The stability of transmission lines is a crucial guarantee for the normal operation of the power grid. To prevent accidents caused by accidental contact with conductors during line construction, this paper proposes a feature extraction network based on a multi-branch dual attention mechanism, DAMF-NET, addressing the low accuracy and poor reliability of existing detection methods. This algorithm enhances the network's focus on local features of target information by constructing a multi-branch dual attention mechanism, optimizing the feature extraction process. A multi-branch lightweight feature fusion network is proposed to reinforce the global multi-scale semantic information and feature significance under dense tasks, thereby improving the completeness of image features. A small object detection network is introduced to mitigate network scale variance and enhance the sensitivity of small object detection. By employing focal loss and EIoU optimized loss functions, the method reduces noise generated by positive and negative sample imbalance, accelerating the convergence speed of model training. Finally, a state recognition algorithm based on risk area localization is designed and deployed in the intelligent detection system of construction machinery. Experiments show that this method has better average precision compared to most current detection models, indicating its research significance in the detection of construction machinery and intelligent inspection.

Keywords: intelligent detection; dual attention; lightweight feature fusion network; small object detection network; state recognition

收稿日期: 2024-03-29 Received Date: 2024-03-29

* 基金项目: 陕西省重点研发计划(2020ZDLGY09-10)、金属挤压与锻造装备技术国家重点实验室开放课题(S2208100.W03)、陕西省创新人才推进计划(2022KJXX-41)、西安市科技计划(22GXFW0041)、西安工程大学研究生创新基金项目(chx2024014)资助

0 引言

输电线路分布在不同的区域,分散性显著,受地形地势等各种因素的影响,维护和管理的难度较大^[1-3]。随着电力系统基建逐年扩张,各类施工机械及机械设备不断增加,若输电线路附近的施工机械对线路误碰,则可能导致线路断线或者短路,严重的威胁电力系统运行稳定性。因此需要对输电线路附近入侵的施工机械设备进行监测,及时采取有效的防护措施,确保电力系统稳定运行^[4]。

传统上开展入侵施工机械监测大多利用人工目视,但输电线路分布广、位置偏僻,使用人工往往存在盲区多、运维范围小等特点^[5]。现阶段,深度学习算法逐渐成熟,利用算法对采集的目标图像进行检测和分类,可以代替传统的人工巡检^[6]。

文献[7]对 Faster R-CNN 进行了改进,通过多尺度特征和 K-均值聚类提高了算法对不同尺度目标的检测效果;文献[8]通过轻量化改进 Faster R-CNN,提高了图像识别精度,但忽略了多尺度特征;文献[9]通过残差网络和多层级特征融合改进了 SSD 网络,提高了对小目标的感知度,但特征提取时存在大量背景噪声;

文献[10]在 YOLOv5 中引入 Transformer 结构进行目标检测,但其对数据要求高,泛化性差;文献[11]对 YOLOv7 进行改进,采用 GAM 注意力机制和 Ghost Net 提升检测精度,但其难以有效捕捉全局特征信息,鲁棒性低。

此外,采用注意力机制或双重注意力机制虽然会强化特征显著性,但也会过于关注局部特征忽略了全局上下文信息^[12]。同时,采用单分支结构的特征融合模块,难以捕捉到数据中复杂的非线性关系,难以提取多样化的特征信息^[13]。

鉴于此,针对以上问题,提出基于多分支双重注意力的特征提取网络(dual attention multi-branch fusion network, DAMF-NET)的输电线路施工机械智能检测算法。通过构建多分支双重注意力机制(multi-head dual attention mechanism, MDAM),使每个分支关注不同的特征子集,保留更多的信息并提高鲁棒性;其次,构建多分支轻量特征融合网络(multi-branch lightweight feature fusion network, MLFN)将特征融合过程分解为多个独立的子任务,捕捉数据中的多样性和非线性关系^[14];同时,通过小目标检测网络,强化小目标检测精度,降低误检、漏检率;使用焦点损失(Focal Loss)函数^[15]和 EIoU^[16]减小样本不平衡带来的负面影响;以及结合算法部署施工机械智能检测系统用于风险管控。

1 DAMF-NET 智能检测算法

当前,施工机械检测具有诸多难点:一是输电线路地处偏僻,环境复杂,现有检测算法难以分辨前景与背景的差异^[17];二是输电线路监测装置常装设在输电杆塔之上,远距离拍摄时,目标过小难以辨别^[18-19]。

因此,本文提出一种输电线路施工机械目标检测算法 DAMF-NET,具体如图 1 所示。

如图 1 所示,DAMF-NET 算法包括图像预处理部分、骨干网络(Backbone)、特征提取网络(Neck)和预测网络(Head)四部分。

其中,多分支双重注意力机制解决特征提取过程目标特征被抑制,背景噪声大的问题;多分支轻量特征融合网络则通过轻量化卷积^[20]提取复杂信息,并以多分支结构获取不同尺度信息,提高图像表征能力;小目标检测网络则能有效提取小目标特征,提高检测精度。

1.1 多分支双重注意力网络

为了提高算法识别施工机械的效率以及准确性,提出基于卷积通道交互的注意力机制(convolutional channel interaction attention mechanism, CCIA)和混合注意力机制(channel and spatial attention module, CBAM)^[21]的多分支双重注意力机制(multi-head dual attention mechanism, MDAM)。其通过快速扫描全局图像来获得需要聚焦的目标区域,从复杂背景信息中选择高价值信息,抑制不必要信息。

此外,通过采用“多分支”结构,将特征提取过程分成多个分支,进行不同的特征提取和处理。每个分支可以同时处理不同尺度和分辨率的特征图,从而提高模型对不同大小目标的检测能力。

1) 基于卷积通道交互的注意力机制

卷积通道交互注意力机制是一种优化特征提取过程的方法,通过融合每个特征图的通道和空间权重值来提高图像识别精度和效率。通过采用不同大小的卷积结构捕捉不同尺度下的特征细粒度信息,增强特征图之间的信息传递和相互影响^[22],总体结构如图 2 所示。

卷积通道交互注意力机制模块对输入特征图进行三维度处理,分别通过深度卷积、全局最大池化和全局平均池化,增强特征图空间、通道特征显著性,并降低深度卷积过程中的特征信息丢失。其中,深层卷积模块(deep convolution module, DCM)由多个 DCM Module 构成,通过使用 1×1 的卷积对初始特征图进行变换,提高获取图像特征的泛化能力,减少过拟合的风险,并实现特征图之间的跨通道信息交互。

2) CBAM 混合注意力机制

为避免 CCIA 注意力提取特征单一,采用混合注意

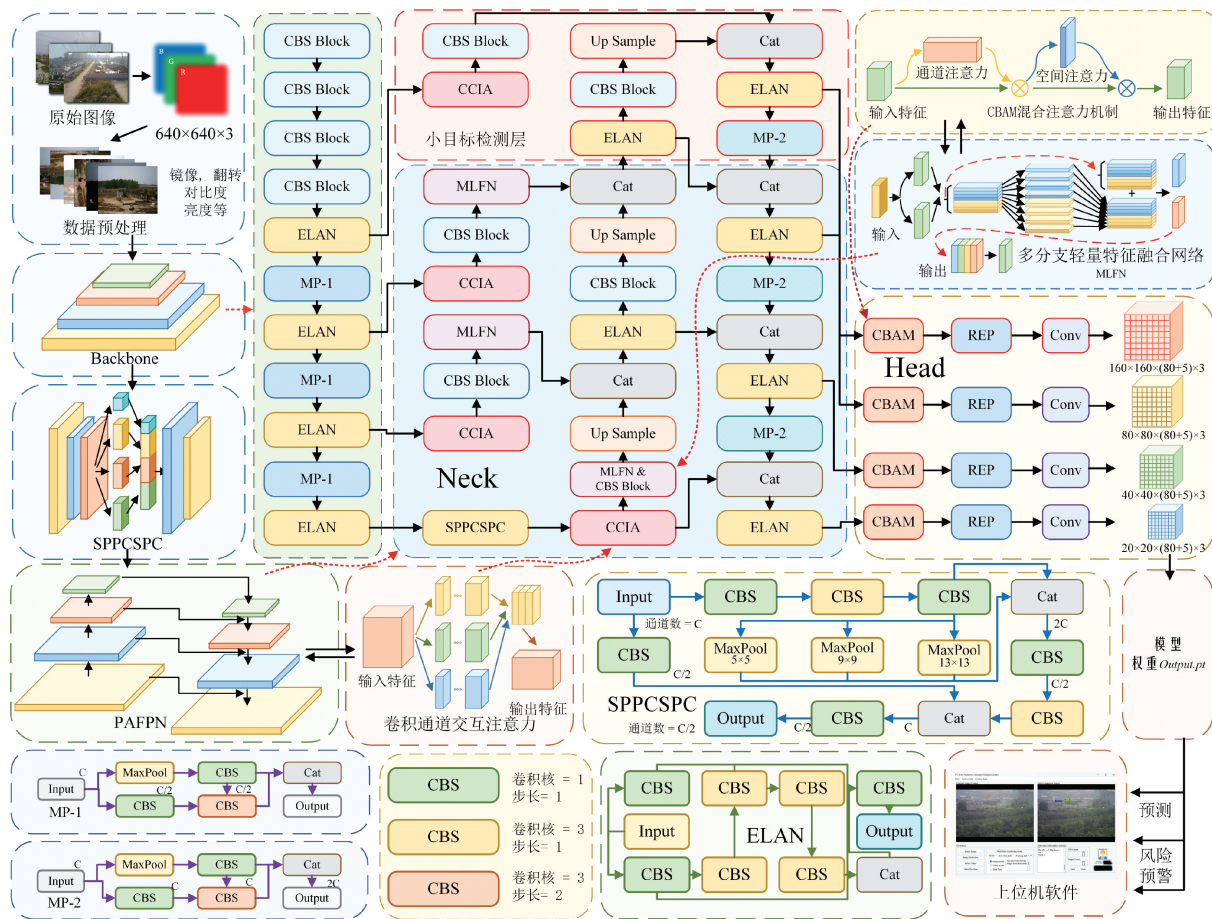


图 1 DAMF-NET 算法结构图

Fig. 1 DAMF-NET algorithm structure diagram

力机制提取后特征。通过 CBAM, 将不同权重分配给不同的卷积通道, 以增强特征显著性; 引入跨信道交互方法来降低模型复杂度, 结构图如图 3 所示。

如图 3 所示, CBAM 混合注意力机制包含两个独立的模块, 空间注意力机制模块和通道注意力机制模块。

(1) 通道注意力

通道注意力是为了突出特征图不同通道之间的相关性, 通过卷积网络的自主学习来获得每个特征通道的重要程度, 并为每个通道给定不同的权重系数, 突出重要的特征, 抑制非重要的特征, 如式(1)所示。

$$F_c(A) = f(MLP(Avg(A)) + MLP(Max(A))) = f(W_1(W_0(A_{avg})) + W_1(W_0(A_{max}))) \quad (1)$$

其中, A_{avg} 和 A_{max} 表示平均池化和最大池化的特征, $f(\cdot)$ 为 Sigmoid 函数。

(2) 空间注意力

空间注意力采用均值和最大池化计算空间注意力, 形成有效的特征图。最后通过卷积操作得到空间注意力权重特征图, 如式(2)所示。

$$F_s(A) = f[Conv(Avg(A); Max(A))] \quad (2)$$

其中, $f[\cdot]$ 为 Sigmoid 函数, $Conv$ 是大小为 7×7 的卷积操作, $Avg(A)$ 代表对特征进行平均池化, $Max(A)$ 代表对特征进行最大池化。

1.2 多分支双重注意力网络

多分支轻量特征融合网络, 旨在提高网络在图像表征和特征提取的能力, 并减轻因加入双重注意力机制而对特征提取造成的影响。其次, 通过卷积网络作为基本卷积模块, 在保持较少参数的同时, 有效地提升特征的表征能力。其网络结构如图 4 所示。

其自上往下具有 4 个分支, 分支一经过 4 次卷积融合, 逐步优化特征的抽象层次和语义信息, 并在 Ghost Block 的卷积模块中, 逐渐丰富和提炼其特征表达能力。同时, 通过捕捉输入数据中的重要特征, 将其转化为更具有区分度和可学习性的表示。

随后, 处理的深度特征被传递到分支 2。通过堆叠深度特征与浅层特征, 强化特征的纹理和细节, 并提炼其特征表达能力。分支 3 则通过浅层信息关注全局语义信息, 分支 4 采用单模块使网络更轻松的学习到恒等映射, 解决训练深度网络时的梯度消失问题, 并为特征提供浅



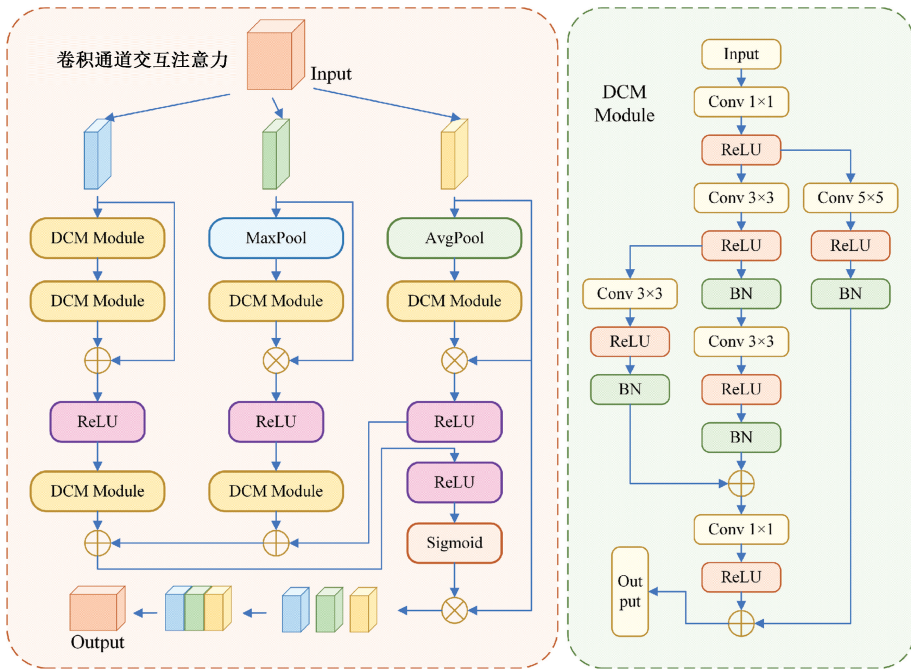


图 2 卷积通道交互注意力
Fig. 2 Convolutional Channel Interaction Attention

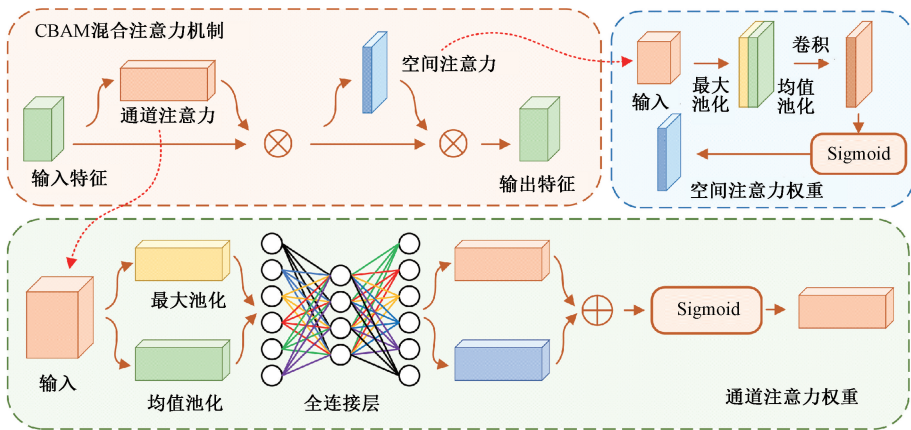


图 3 混合注意力机制结构图
Fig. 3 Structure of the hybrid attention mechanism

层语义信息,强化图像边缘。

而在特征融合阶段,不同分支提取的特征图经过轻量级特征融合,得到更全面和多样化的特征输出,提高模型对复杂任务的解决能力。

此外,Ghost Conv 作为基本卷积模块增加卷积层数,Ghost Block 模块由 Ghost Module 堆叠而成的,其通过较小的滤波器从常规卷积生成少量特征图,然后由一系列线性运算生成与之相似的新特征图,两组特征图的组合即为模型输出的结果。假设输入的特征图尺寸为 $h \times w \times c$,经过一次卷积后的输出为 $h' \times w' \times n$,则普通的卷积与 Ghost 的卷积计算量对比则如下式所示:

$$r_s = \frac{n \cdot h' \cdot w' \cdot c \cdot k \cdot k}{\frac{n}{s} \cdot h' \cdot w' \cdot c \cdot k \cdot k + (s - 1) \cdot \frac{n}{s} \cdot h' \cdot w' \cdot d \cdot d} = \frac{c \cdot k \cdot k}{\frac{1}{s} \cdot c \cdot k \cdot k + \frac{(s - 1)}{s} \cdot d \cdot d} \approx \frac{s \cdot c}{s + c - 1} \approx s \quad (3)$$

式中:分子为普通卷积的复杂度;分母为 Ghost Module 的复杂度,卷积核大小为 k ,线性变换卷积核大小为 d ,经过 s 次变换, n/s 为第一次变换时的输出通道, $s-1$ 为减去了恒等映射的线性变换。

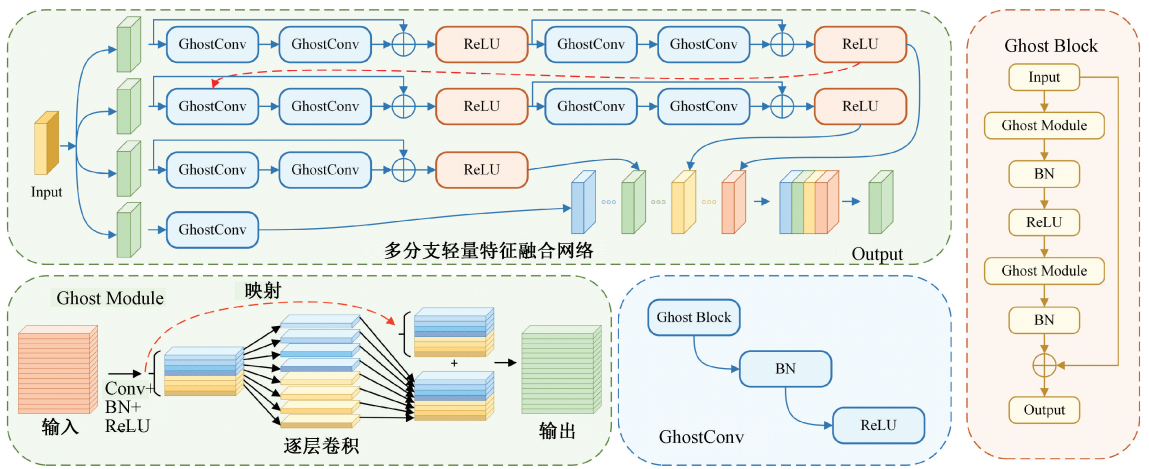


图 4 多分支轻量特征融合网络结构图

Fig. 4 Multi-branch lightweight feature fusion network structure diagram

1.3 小目标检测层

小目标检测是深度学习中一个重要的研究领域,在实际场景中,往往会存在尺寸较小的目标,例如输电塔下较远的施工车辆、遥感图像中的车辆、航拍图像中的人物等。此外,小目标的定义如下:

$$S(x) = \sqrt{\frac{(w_{label} \cdot h_{label})}{(w \cdot h)}} \times 100\% \quad (4)$$

其中, w_{label} 和 h_{label} 分别表示标记框的宽度和长度, w

和 h 分别表示整个图像的宽度和高度。将标记框的长宽乘积除以图像的长宽乘积,并取平方根,当结果小于 5% 时,统称为小目标对象。

为应对检测需求,提出小目标检测网络 (small object detection network, SODN)。通过结合原预测头生成 4 个不同大小的预测结构,使网络更适应不同目标大小,有效提取目标特征,降低误检和漏检率。详细结构如图 5 所示。




图 5 小目标检测网络结构图

Fig. 5 Structure of small target detection layer

如图所示,通过大小、深度不同的卷积和堆叠,提取更高分辨率的特征图像,并使用 CCIA 的结构强化其特征提取能力,并提升网络对密集目标的识别能力。

1.4 损失函数

在实际的网络训练过程中,由于负样本的数量远远大于正样本的数量,所以网络会包含着大量简单负样本权重,并且目标类别分类的难易程度也各不相同,提取特征的过程相对复杂。因此在基线模型的基础上,增加 Focal Loss 损失函数;同时,为解决基线模型的完全交并比 (complete-IoU, CIoU) 忽略了真实框与预测框的重叠面积、高宽比等问题,改进 IoU 交并比。

1) 焦点损失函数 (Focal Loss)

基线模型在处理正负样本不均衡问题时,会因为负

样本过于庞大,丧失正样本权重,使网络模型的效果难以达到预期。因此,采用 Focal Loss 函数可以解决训练过程中正负样本不平衡,以及对于样本难易程度不同而关注度却相同的问题。具体公式如下所示:

$$a_i = \begin{cases} \alpha, & a = 1 \\ 1 - \alpha, & \text{其他} \end{cases} \quad (5)$$

$$x_i = \begin{cases} x, & a = 1 \\ 1 - x, & \text{其他} \end{cases} \quad (6)$$

$$Loss_{focal} = -a_i \cdot (1 - x_i)^\beta \cdot \log(x_i) \quad (7)$$

其中, a_i 权重系数用于平衡正负样本, $1 - x_i$ 权重因子用于平衡样本的难易程度, β 为调制系数。

2) EIoU

基线模型的 CIoU 交并比函数在边界框回归指标的

聚合方面存在缺陷。其没有考虑真实框与预测框的重叠面积、中心点的偏差以及高宽比等因素,因此预测框在训练过程中可能无法快速准确地定位,导致收敛速度较慢且效率较低。

因此,采用高效交并比 (efficient-IoU, EIoU) 损失函数将纵横比的损失项拆分为预测的宽高与最小外接框宽高的差值,加快模型收敛速度并提高回归精度。具体如图 6 所示。




图 6 EIoU 原理图

Fig. 6 EIoU schematic

其中, b 是边界框的中心点, w, h 为边界框的宽度及高度, w^c 和 h^c 是预测边界框与真实边界框的最小外接矩形的宽度和高度。EIoU Loss 包括 3 个部分: IoU 损失、距离损失、高宽损失,其具体公式如下所示:

$$L_{EIoU} = L_{IoU} + L_{dis} + L_{asp} \quad (8)$$

$$L_{IoU} = 1 - IoU \quad (9)$$

$$L_{dis} = \frac{\rho^2(b, b^{gt})}{(w^c)^2 + (h^c)^2} \quad (10)$$

$$L_{asp} = \frac{\rho^2(w, w^{gt})}{(w^c)^2} + \frac{\rho^2(h, h^{gt})}{(h^c)^2} \quad (11)$$

其中, b 为预测框的中心点坐标, b^{gt} 为实际框的中心点坐标, $\rho^2(w, w^{gt})$ 表示预测边界框与实际边界框宽度的差值。

2 基于 5G 通信和光纤环网的施工机械智能检测系统

2.1 硬件部署

输电线路施工机械智能检测系统部署方案如图 7 所示。

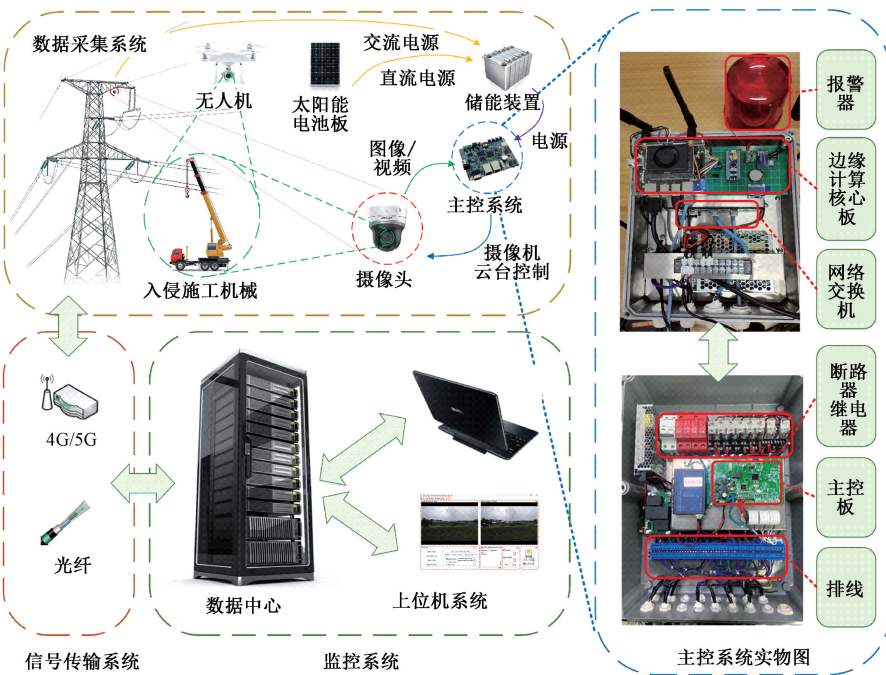


图 7 输电线路施工机械检测系统部署方案

Fig. 7 Deployment plan for transmission line construction machinery inspection system

如图所示,通过图像采集装置获取输电线路施工机械入侵检测的实时状态信息,利用无线 5G 通信网络^[23]和光纤环网传输信息至地面设备监测终端。采集的图像

信息经过服务器进行数据预处理,通过相关算法进行图像分析和目标检测的数据训练与测试。最终,由智能监测终端实时传输数据状态信息。

2.2 风险预警

为了评估输电线路现场施工机械的入侵级别,以进行风险预警,提出基于预选框定位和输电线路风险区域的状态识别算法,如图 8 所示。

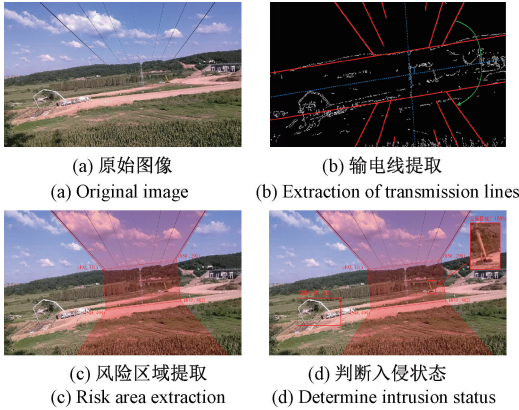


图 8 基于预选框定位和风险区域状态识别
Fig. 8 Based on pre selection box positioning and risk area status recognition

如图 8 所示,首先通过边缘检测算法(Canny 边缘检测)获取地平线和输电线路的轮廓;而后利用霍夫变换(Hough Transform)从边缘轮廓中检测出直线等几何形状,帮助确定输电线路的位置和方向。

其次,由人工根据获取的几何形状坐标选择实际的输电线路和地平线,再选择外围线路绘制风险区域,用于标识可能存在风险的区域。而后,通过状态识别算法判断检测框与风险区域之间重叠程度的大小,确定相应的预警状态,积极提醒相关人员注意可能存在的风险。

设检测框的左上角顶点为 (x_1, y_1) , 右下角顶点 (x_2, y_2) , 则检测框面积 D_{area} 为:

$$D_{area} = |x_2 - x_1| \times |y_2 - y_1| \quad (12)$$

设检测框(矩形)和风险区域(多边形)的交集区域为 *Intersection Region*, 面积为 U 。首先计算交集区域,假设风险区域由一系列顶点组成,对于风险区域的每一条边 (L_i, L_{i+1}) , 计算其与检测框的 4 条边相交的线段,并求交点。

而对于每个交点,如果在检测框内部,即将其加入交集区域。根据交集区域的点,构建一个新的多边形,即交集区域:

$$Intersection\ Region = \{(x_i, y_i)\}, \quad i = 1, 2, \dots, n \quad (13)$$

最后,计算预选框和风险区域的交集面积 U_{area} 时,设交集区域是由顶点 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ 组成的不规则多边形,将其分成若干个三角形后,计算每个三角形的面积。此外,如果该多边形是逆时针方向,则为正

面积;如果是顺时针方向,则为负面积,公式如下:

$$A_{signed\ area} = \frac{1}{2} \sum_{i=1}^{n-1} (x_i y_{i+1} - x_{i+1} y_i) + \frac{1}{2} (x_n y_1 - x_1 y_n) \quad (14)$$

$$U_{area} = |A_{signed\ area}| \quad (15)$$

其中, (x_i, y_i) 表示交集区域的第 i 个顶点, n 表示顶点的数量, $A_{signed\ area}$ 为交集区域有向面积, U_{area} 为交集区域面积。

检测目标框与风险区域之间重叠程度 U_{area} 与检测框 D_{area} 比值为 R , 其公式如下:

$$R = \frac{U_{area}}{D_{area}} \times 100\% \quad (16)$$

R 的大小可以实时反映施工机械侵入输电线路风险区域的严重程度,当 R 越大,表示侵入风险高,需要引起高度警惕。

3 实验及结果分析

3.1 实验数据采集

实验所使用的数据均来源于青海某 750 kV 输电线路。通过利用塔上摄像机、无人机等设备拍摄多种复杂环境下的现场图像,如小目标、背景杂、多目标、遮挡等场景。具体如图 9 所示。

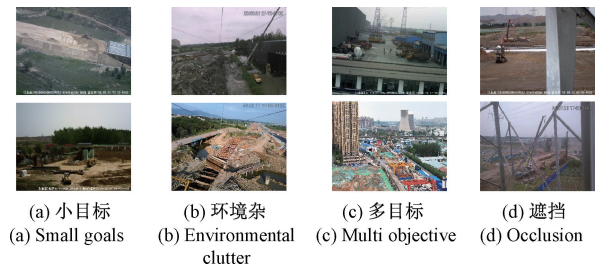


图 9 数据集示例图

Fig. 9 Diagram example diagram of a dataset

此外,本文通过该数据源制作了全新的输电线路施工机械入侵数据集(transmission line construction machinery intrusion dataset, TLCMID),共计 2 406 张图像。检测 8 种不同类型的目标,包括铲车(TS)、吊车(CR)、水泥泵车(CP)、挖掘机(EX)、压路机(RO)、卡车(TR)、打桩机(PD)和塔吊(TC)。同时,鉴于模型对数据样本数量的依赖性,将原始图像通过翻转、旋转、剪切等方法进行增强,增强后有 12 030 张图像。

3.2 实验环境配置

本实验在 Ubuntu18.04 系统环境下进行,处理器型号为 Intel i9-11900K, 64 G 内存,采用一张 NVIDIA RTX3090。在 Python3.8 的环境下使用 PyTorch 深度学

习框架实现整个算法。实验 Batch Size 设置为 8, 动量大小 0.9, 权重衰减设置为 0.0005, 学习率设置为 0.001。

3.3 实验结果评价指标

为客观评价 DAMF-NET 算法的优势, 选取全类平均精度 (mean average precision, mAP)、召回率 (recall, R)、准确率 (precision, P)、十亿次浮点运算量 (GFLOPs), 参数量 (Parameters), 每秒处理帧数 (frames per second,

FPS), 延时 (Latency) 作为评价指标^[24]。此外, $mAP_{0.5}$ 代表置信度为 50% 时的全类平均精度。

3.4 实验结果分析

1) 结果数据对比

为了验证 DAMF-NET 所采取的不同机制对基线模型的改进效果, 实验将所有改进依次嵌入至基线模型中, 结果如表 1 所示。

表 1 消融实验结果

Table 1 Results of ablation experiments

Base	CCIA	CBAM	MLFN	SODN	LOSS	GFLOPs/G	Params/M	FPS	Latency/ms	P/%	R/%	F1	$mAP_{0.5}/%$
✓	×	×	×	×	×	106.472	37.623	59.189	16.895 1	80.54	71.25	0.76	80.12
✓	✓	×	×	×	×	650.831	65.674	19.346	51.690 3	80.81	72.40	0.78	81.23
✓	×	✓	×	×	×	106.474	37.706	55.651	17.969 1	80.96	72.56	0.75	81.54
✓	×	×	✓	×	×	107.725	37.761	44.706	22.368 4	81.23	72.44	0.76	81.59
✓	×	×	×	✓	×	196.735	47.732	34.648	28.861 7	81.16	74.08	0.79	82.82
✓	×	×	×	×	✓	196.748	47.732	34.665	28.847 5	80.82	71.87	0.76	80.33
✓	✓	✓	×	×	×	650.836	65.760	19.047	52.501 7	81.60	75.23	0.80	82.40
✓	✓	✓	✓	×	×	652.088	65.900	18.709	53.450 2	82.37	76.21	0.80	83.62
✓	✓	✓	✓	✓	×	845.891	75.953	15.421	64.846 6	83.61	77.54	0.81	85.39
✓	✓	✓	✓	✓	✓	845.914	75.953	15.416	64.867 7	83.42	77.65	0.81	85.87

表中基线模型为 YOLOv7-L 算法, 多种改进模块对其结果有显著影响。CCIA 机制通过融合通道和空间权重值优化特征提取, 相较基线模型提升了 1.11% 的 $mAP_{0.5}$ 。CBAM 注意力模块分配不同权重给卷积通道, 提高了 $mAP_{0.5}$ 值 1.42%。多分支轻量特征融合网络强化图像表征, 提升了 $mAP_{0.5}$ 值 1.47%。

此外, 在基线模型上引入大小、深度不同的卷积及其堆叠, 添加额外检测头可使 $mAP_{0.5}$ 提升约 2.7%。改进的损失函数平衡了正负样本不平衡和难易不均问题, 虽然降低了 Precision, 但提升了 Recall, 降低了漏检率,

$mAP_{0.5}$ 提升了 0.21%。

最后, 融合网络的 $mAP_{0.5}$ 精度较基线模型提升了 5.75%, 验证了改进方案的有效性。尽管改进使模型参数和浮点运算效率增加, 但其精度提升十分可观。

2) 3D 可视化特征对比

此外, 为更深入地理解模型的内部工作机制, 引入 3D 可视化工具, 用于详细分析特征图的生成过程, 并筛选最具代表性的特征通道进行深入研究, 具体如图 10 所示。

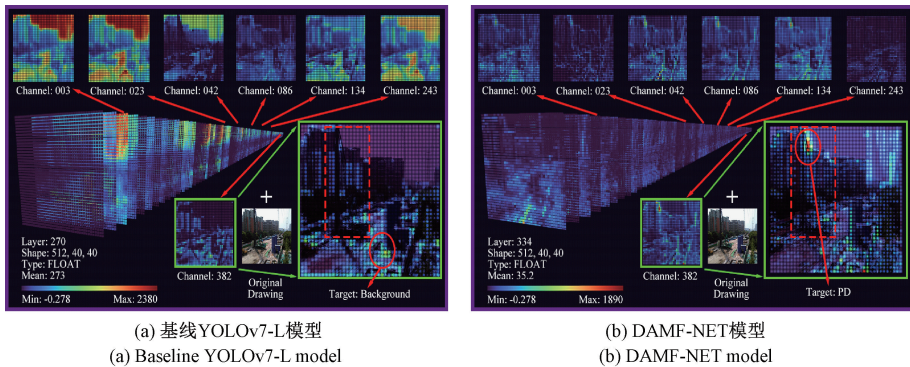


图 10 3D 可视化特征通道图对比

Fig. 10 Comparison of 3D visualization feature channel maps

如图可知, 本研究的模型在增强特征细节、强化小目标提取和抑制背景噪声等方面展现出了显著的优势。

相比之下, 基线模型的前景和背景之间的区分度较

低, 网络误将天空等背景要素视为主要特征, 网络关注的重点不在目标上, 而在背景上, 这必然导致目标受到噪声干扰, 从而引发漏检问题。

3.5 数据对比实验

1) 结果数据对比

为了验证 DAMF-NET 相较于于基线模型以及其他各类先进算法(state of the art, SOTA)算法优劣,本实验使用相同的训练集对每个不同类型的 SOTA 算法进行训练,其中包括两阶段检测网络 Faster R-CNN、单阶段检测

网络 RetinaNet^[25]、SSD、YOLOv4^[26]、YOLOv5^[27]、YOLOv8^[28],单阶段无锚框网络 CenterNet^[29]、端到端检测网络 DETR^[30]、单阶段轻量型检测网络 EfficientDet D0^[31]、单阶段 Anchor-Free 网络 FCOS^[32]等。训练迭代次数为 200 次,使用相同的测试集进行验证,结果如表 2 所示。

表 2 SOTA 算法结果对比

Table 2 Comparison of SOTA algorithm results

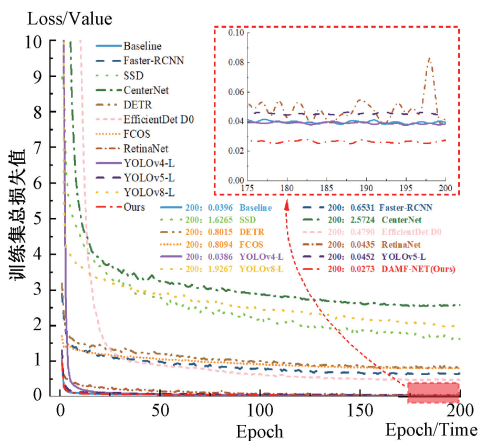
Method	Backbone	Size	P/%	R/%	AP _{max} /%	mAP _{0.5} /%	Params/M	FPS	Latency/ms
Baseline	CSPDarkNet-53	[640,640]	80.54	71.25	96.01	80.12	37.623	59.189	16.895
Faster R-CNN	ResNet50	[600,600]	48.16	71.74	82.15	65.77	137.099	25.364	39.425
SSD	VGG	[640,640]	84.85	75.22	94.32	78.55	26.285	53.483	18.697
CenterNet	ResNet50	[512,512]	12.50	0.19	18.25	2.81	32.665	107.747	9.281
DETR	ResNet50	[800,800]	53.03	59.73	69.78	52.58	36.762	37.582	26.608
EfficientDet D0	EfficientNet	[512,512]	28.47	4.95	50.91	23.04	3.874	26.354	37.944
FCOS	ResNet50	[640,640]	72.20	73.50	96.25	77.42	32.155	48.067	20.804
RetinaNet	ResNet50	[600,600]	88.22	63.50	86.99	76.76	37.969	49.880	20.048
YOLOv4-L	CSPDarkNet	[640,640]	82.37	72.20	91.63	78.40	64.363	46.291	21.602
YOLOv5-L	CSPDarkNet	[640,640]	87.15	62.64	91.27	76.67	47.057	49.048	20.388
YOLOv8-L	DarkNet-53	[640,640]	88.32	74.25	92.31	81.64	43.692	59.316	16.858
Ours	DAMF-NET	[640,640]	83.42	77.65	99.05	85.87	75.953	15.416	64.868

分析对比结果可知,DAMF-NET 的 mAP_{0.5} 达到了 85.87%,明显高于各类 SOTA 算法,具有显著的精度优势。Faster R-CNN 的 mAP_{0.5} 为 65.77%,参数量高达 137.099 M,其特征提取阶段仅提取单层特征图,难以解决背景复杂度高和小目标特征的难点。

RetinaNet、SSD、YOLOv4、YOLOv5、YOLOv8 以及 DAMF-NET 均为单阶段检测网络,参数量相对较低。虽然 DAMF-NET 算法的 Precision 较低,但 Recall 和 AP_{max} 均最高,分别达到了 77.65%和 99.05%。改进提高了模型对复杂背景和小目标的精度,降低了误检和漏检率,使得 mAP_{0.5} 表现较好。

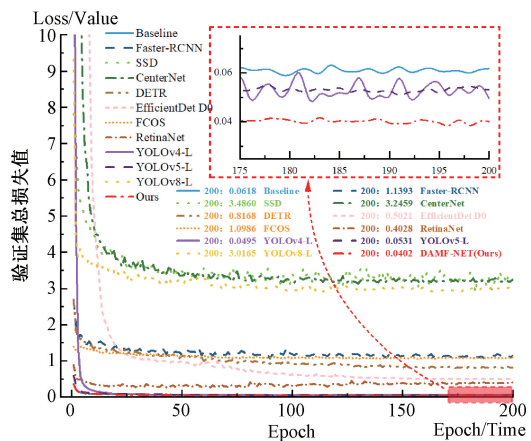
CenterNet 的 mAP_{0.5} 仅为 2.81%,虽然其 FPS 达到 107 帧,但其精度低,难以在工程实践中应用。与 DETR 相比,本文算法的 mAP_{0.5} 领先了约 33.29%。EfficientDet D0 模型参数量虽小,但计算复杂,FPS 值仅为 26.354 5,且识别精度不及其他单阶段算法。FCOS 的 mAP_{0.5} 达到了 77.42%,但仍不及 DAMF-NET 算法。

此外,为了清晰地描述模型迭代过程中损失函数的变化趋势,绘制基线模型与前述 SOTA 算法的训练以及验证的损失值变化曲线,整体迭代轮数为 200 轮,如图 12 所示。



(a) 训练集损失值变换曲线

(a) Training set loss value transformation curve



(b) 验证集损失值变换曲线

(b) Validation set loss value transformation curve

图 11 训练集损失值变换曲线

Fig. 11 Training set loss value transformation curves

根据图中数据可知,各 SOTA 算法和基线模型的损失函数变化曲线呈逐渐下降并趋于稳定的趋势。其中,CenterNet、YOLOv8-L、SSD 收敛阈值相对较宽,表现不佳;EfficientDet D0 网络收敛最慢,需要大约 100 个 Epoch 才能稳定。DETR、FCOS 和 Faster R-CNN 的收敛区间较大,反映了在训练过程中反向传播不够稳定。

相比之下,DAMF-NET 的训练集损失函数从 0.99 下降至约 0.03,验证集损失函数收敛至 0.04 左右,表现出

最小和最为平缓的变化。

2) 可视化检测结果对比

为了更进一步验证 DAMF-NET 网络的识别精度,同时结合对比数据结果,选择具有代表性的算法进行对比,包括两阶段检测网络 Faster R-CNN、单阶段检测网络 SSD、YOLOv5-L 和本文算法,分析测试集数据的可视化检测结果,如图 12 所示。



图 12 可视化结果对比

Fig. 12 Comparison of visualization results

在 4 个实验组(A、B、C、D)中,DAMF-NET 的置信度最高,预测框更精确,综合性能卓越。

A 组实验中,DAMF-NET 在小目标检测上表现显著优越,基线模型和 Faster R-CNN 存在误检和漏检问题;B 组实验中,SSD 和 Faster R-CNN 存在大量误检。例如,Faster R-CNN 将右下角的叉车错误地识别为压路机 RO

类;SSD 算法则在图像的左侧检测到大量错误的目标。相比之下,DAMF-NET 表现出最佳的目标识别精度,能够准确地识别出复杂背景中的 CR 类目标。

C 组实验中,基线模型、Faster R-CNN、SSD 以及 YOLOv5-L 模型都存在不同程度的漏检问题,其中以 Faster R-CNN 表现最为严重;D 组实验中,被检测的目标

均被杆塔等遮挡物所遮挡。Faster R-CNN 算法错误地将遮挡物杆塔识别为 PD 类目标;SSD 算法的性能表现最差,大量将遮挡物错误地识别为 PD 类目标,并错误地将被遮挡的目标 EX 类目标识别为 TS 类目标。DAMF-NET 则具有最高的识别置信度,在目标识别和定位性能方面表现更为卓越。

4 结 论

为针对现有监测方法对输电线路场景下的复杂背景和小目标检测精度低、可靠性差的问题,提出了一种基于 DAMF-NET 的施工机械智能检测算法与图像处理系统。

通过构建多分支双重注意力机制优化模型特征提取过程;提出多分支轻量特征融合网络得到更好的图像表征能力;增加小目标检测头强化模型提取特征的敏感性;使用焦点损失函数和 EIOU 加快模型训练收敛速度;最后结合算法开发施工机械智能检测系统。算法平均精度 $mAP_{0.5}$ 达到 85.87%,优于当前大部分 SOTA 模型,对复杂环境下的施工机械智能监测具有一定的现实意义。但该算法仍在每秒帧处理速度上有一定提升空间,下一步工作将重点处理轻量化模型上。


参考文献

- [1] DU X K, QU W J, YU X, et al. Research on online monitoring system of fusion transmission line based on multi-source data [J]. Journal of Physics: Conference Series, 2022, 2360(1): 012021.
- [2] LANINGA J, ESFAHANI A N, KORDI B. Monitoring technologies for HVDC transmission lines [J]. Energies, 2023, DOI:10.3390/en16135085.
- [3] 刘传洋,吴一全. 基于深度学习的输电线路视觉检测方法研究进展 [J]. 中国电机工程学报, 2023, 43(19): 7423-7446.
LIU CH Y, WU Y Q. Research progress of vision detection methods based on deep learning for transmission lines [J]. Proceedings of the CSEE, 2023, 43 (19): 7423-7446.
- [4] 曾繁祎,陈太艺,周川. 基于光纤传感技术的输电线路在线监测技术 [J]. 电力与能源, 2022, 43(4): 322-325,347.
ZENG F W, CHEN T Y, ZHOU CH. Online monitoring technology of transmission line based on optical fiber sensing technology [J]. Power & Energy, 2022, 43(4): 322-325,347.
- [5] 李斌,屈璐瑶,朱新山,等. 基于多尺度特征融合的绝缘子缺陷检测 [J]. 电工技术学报, 2023, 38 (1): 60-70.
LI B, QU L Y, ZHU X SH, et al. Insulator defect detection based on multi-scale feature fusion [J]. Transactions of China Electrotechnical Society, 2023, 38(1): 60-70.
- [6] 李帷韬,侯建平,张倩,等. 基于强化学习和 Transformer 的输电线路缺陷智能检测方法研究 [J]. 高电压技术, 2023, 49(8): 3373-3384.
LI W T, HOU J P, ZHANG Q, et al. Research on intelligent detection method of transmission line defects based on reinforcement learning and transformer [J]. High Voltage Engineering, 2023, 49(8): 3373-3384.
- [7] 蔡文彪,李永锋,吴怀诚,等. 基于改进 Faster RCNN 模型的输电线路缺陷检测方法 [J]. 信息技术, 2023, 47(1): 148-153.
CAI W B, LI Y F, WU H CH, et al. Transmission line defect detection method based on improved fast RCNN model [J]. Information Technology, 2023, 47 (1): 148-153.
- [8] 魏业文,李梅,解园琳,等. 基于改进 Faster-RCNN 的输电线路巡检图像检测 [J]. 电力工程技术, 2022, 41(2): 171-178.
WEI Y W, LI M, XIE Y L, et al. Transmission line inspection image detection based on improved Faster-RCNN [J]. Electric Power Engineering Technology, 2022, 41(2): 171-178.
- [9] 李瑞生,张彦龙,翟登辉,等. 基于改进 SSD 的输电线路销钉缺陷检测 [J]. 高电压技术, 2021, 47(11): 3795-3802.
LI R SH, ZHANG Y L, ZHAI D H, et al. Pin defect detection of transmission line based on improved SSD [J]. High Voltage Engineering, 2021, 47(11): 3795-3802.
- [10] 郝帅,赵新生,马旭,等. 基于 TR-YOLOv5 的输电线路多类缺陷目标检测方法 [J]. 图学学报, 2023, 44(4): 667-676.
HAO SH, ZHAO X SH, MA X, et al. Multi-class defect target detection method for transmission lines based on TR-YOLOv5 [J]. Journal of Graphics, 2023, 44(4): 667-676.
- [11] 宋智伟,黄新波,纪超,等. 基于 Flexible YOLOv7 的输电线路绝缘子缺陷检测和故障预警方法 [J]. 高电压技术, 2023, 49(12): 5084-5094.
SONG ZH W, HUANG X B, JI CH, et al. Insulator defect detection and fault warning method for transmission line based on flexible YOLOv7 [J]. High Voltage

- Engineering, 2023, 49(12): 5084-5094.
- [12] 王山豹, 梁栋, 沈玲. 利用多模态注意力机制生成网络的图像修复[J]. 计算机辅助设计与图形学学报, 2023, 35(7): 1109-1121.
WANG SH B, LIANG D, SHEN L. Image inpainting with multi-modal attention mechanism generative networks[J]. Journal of Computer-Aided Design & Computer Graphics, 2023, 35(7): 1109-1121.
- [13] 林梦翔, 林志玮, 黄秀萍, 等. 融合全局与随机局部特征的鸟类姿态识别模型[J]. 计算机辅助设计与图形学学报, 2022, 34(4): 581-591.
LIN M X, LIN ZH W, HUANG X P, et al. Bird postures recognition model fusing global and random local features [J]. Journal of Computer-Aided Design & Computer Graphics, 2022, 34(4): 581-591.
- [14] 黄港, 郑元林, 廖开阳, 等. 互补注意多样性特征融合网络的细粒度分类[J]. 中国图象图形学报, 2023, 28(8): 2420-2431.
HUANG G, ZHENG Y L, LIAO K Y, et al. Mutual attention diversity feature fusion network-relevant fine-grained classification [J]. Journal of Image and Graphics, 2023, 28(8): 2420-2431.
- [15] 李季, 刘乐, 牛雨潇, 等. 融入注意力的 YOLOv3 绝缘子串识别方法[J]. 高压电器, 2022, 58(11): 67-74.
LI J, LIU L, NIU Y X, et al. YOLOv3 identification method incorporating attention for insulator string [J]. High Voltage Apparatus, 2022, 58(11): 67-74.
- [16] YANG Z M, WANG X L, LI J. EIoU: An improved vehicle detection algorithm based on VehicleNet neural network [J]. Journal of Physics: Conference Series. 2021, 1924(1): 012001.
- [17] 裴少通, 张行远, 胡晨龙, 等. 基于 ER-YOLO 算法的跨环境输电线路缺陷识别方法[J]. 电工技术学报, 2024, 39(9): 2825-2840.
PEI SH T, ZHANG X Y, HU CH L, et al. The defect detection method for cross-environment power transmission line based on ER-YOLO algorithm [J]. Transactions of China Electrotechnical Society, 2024, 39(9): 2825-2840.
- [18] CHENG Q Y, YUAN G D, CHEN D, et al. Transmission lines small-target detection algorithm research based on YOLOv5 [J]. Applied Sciences, 2023, 13(16): 9386.
- [19] 吴军, 白梁军, 董晓虎, 等. 基于 Cascade R-CNN 算法的输电线路小目标缺陷检测方法[J]. 电网与清洁能源, 2022, 38(4): 19-27, 36.
WU J, BAI L J, DONG X H, et al. Transmission line small target defect detection method based on cascade R-CNN algorithm [J]. Power System and Clean Energy, 2022, 38(4): 19-27, 36.
- [20] 林德钰, 周卓彤, 过斌, 等. 高斯混合模型与 GhostNet 结合的 YOLO-G 遗留物检测方法[J]. 计算机辅助设计与图形学学报, 2023, 35(1): 99-107.
LIN D Y, ZHOU ZH T, GUO B, et al. YOLO-G abandoned object detection method combined with gaussian mixture model and GhostNet [J]. Journal of Computer-Aided Design & Computer Graphics, 2023, 35(1): 99-107.
- [21] 刘志远, 于晓军, 罗美玲, 等. 基于 CBAM-FCN 的高压输电线路发展性故障识别方法[J]. 电网与清洁能源, 2022, 38(9): 25-33, 44.
LIU ZH Y, YU X J, LUO M L, et al. An evolved faults identification method of HV transmission lines based on CBAM-FCN [J]. Power System and Clean Energy, 2022, 38(9): 25-33, 44.
- [22] HAO SH, AN B Y, MA X, et al. PKAMNet: A transmission line insulator parallel-gap fault detection network based on prior knowledge transfer and attention mechanism [J]. IEEE Transactions on Power Delivery, 2023, PP(99): 1-11.
- [23] 李文君, 段登伟, 朱雨, 等. 基于 5G 通信模式下的配电网自愈保护应用[J]. 电力系统保护与控制, 2022, 50(24): 152-159.
LI W J, DUAN D W, ZHU Y, et al. Application of distribution network protection based on a 5G end-to-end communication mode [J]. Power System Protection and Control, 2022, 50(24): 152-159.
- [24] 蒋兴群, 刘波, 宋力, 等. 基于改进 YOLO-v3 的风力机叶片表面损伤检测识别[J]. 太阳能学报, 2023, 44(3): 212-217.
JIANG X Q, LIU B, SONG L, et al. Surface damage detection and recognition of wind turbine blade based on improved YOLO-v3 [J]. Acta Energiæ Solaris Sinica, 2023, 44(3): 212-217.
- [25] LIU Y H, LIU X CH, ZHANG B. RetinaNet-vline: A flexible small target detection algorithm for efficient aggregation of information [J]. Cluster Computing, 2023, 27(3): 1-13.
- [26] ABDULLAH B, VEYSEL G. YOLOv4 and tiny YOLOv4 based forage crop detection with an artificial intelligence board [J]. Brazilian Archives of Biology and Technology, 2023, 66(14): 1-15.

- [27] DIAO ZH, HUANG X F, LIU H, et al. LE-YOLOv5: A lightweight and efficient road damage detection algorithm based on improved YOLOv5 [J]. *International Journal of Intelligent Systems*, 2023, 2023: 1-17.
- [28] HAN L, MA CH H, LIU Y, et al. SC-YOLOv8: A security check model for the inspection of prohibited items in X-ray images[J]. *Electronics*, 2023, 12(20): 4208.
- [29] WANG H, XU Y S, WANG Z N, et al. CenterNet-Auto: A multi-object visual detection algorithm for autonomous driving scenes based on improved CenterNet [J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2023, 99: 1-11.
- [30] HUANG Y M, YUAN G W. AD-DETR: DETR with asymmetrical relation and decoupled attention in crowded scenes[J]. *Mathematical Biosciences and Engineering*, 2023, 20(8): 14158-14179.
- [31] WANG Y F, WANG T, ZHOU X, et al. TransEffiDet: Aircraft detection and classification in aerial images based on EfficientDet and transformer [J]. *Computational Intelligence and Neuroscience*, 2022, 2022: 1-10.
- [32] ZHANG ZH Q, LIU Y, ZHU X CH, et al. DSE-FCOS: Dilated and SE block-reinforced FCOS for detection of marine benthos [J]. *The Visual Computer*, 2023, 40(4): 1-15.

作者简介



张凡(通信作者),2022年于西安工程大学获得学士学位,现为西安工程大学硕士研究生,主要研究方向为输电线路状态智能检测、图像处理、人工智能与计算机视觉。

E-mail: zhangspace2023@163.com

Zhang Fan (Corresponding Author)

received his B. Sc. degree from Xi'an Engineering University in 2022 and is currently a M. Sc. candidate at Xi'an Engineering University. His main research interests include intelligent detection of the state of transmission lines, image processing, artificial intelligence, and computer vision.



纪超,2009年于西安工程大学获得学士学位,2012年于西北工业大学获得硕士学位,2015年于西北工业大学获得博士学位,现为西安工程大学副教授,主要研究方向为输电线路状态智能检测、图像处理与人工智能。

E-mail: dachao9898@163.com

Ji Chao received his B. Sc. degree from Xi'an Polytechnic University in 2009, M. Sc. degree from Northwestern Polytechnical University in 2012 and Ph. D. degree from Northwestern Polytechnical University in 2015, respectively. Now he is an associate professor in Xi'an Polytechnic University. His main research interests include intelligent detection of transmission line status and image processing and artificial intelligence.