

## 基于改进 DETR 的绝缘子缺陷检测算法

欧阳名三, 李 杰

安徽理工大学 电气与信息工程学院, 安徽 淮南 232000

**摘要:**目的 绝缘子缺陷的定期检测与维修对保障输电线路的安全有至关重要的作用,为了解决绝缘子缺陷检测方法存在检测精度不高、泛用性不强等问题,提出了一种基于改进 DETR(Detection Transformer)的绝缘子缺陷检测算法。方法 设计改进编码器,使用 4 个 Transformer stage 来捕捉图像中不同尺度和关系的特征信息。同时,还利用了 ResNet50 的中间输出特征来补充层 Transformer 的输出特征,从而提升目标检测算法的性能。设计改进解码器,采用了三层串联的结构,以确保解码器能够在不同阶段接收并学习不同尺度的特征图,同时特征融合增强模块和查询更新模块使解码器能够更有效地学习图像的特征信息且降低匹配具有相似语义特征区域的难度,进一步提高网络检测的准确率。结果 通过对输电线路绝缘子缺陷航拍图像进行了仿真实验研究,在不同阈值下改进方法识别精度分别达到了 99.5%、80.4%,较原算法分别提升了 3.4%、6.1%,对部分遮挡目标有较好的检测效果,同时与其他算法相比具有更优的检测精度和泛化能力。结论 改进 DETR 具有更高的检测性能,实现对绝缘子缺陷的准确检测,为下一步对于其他输电线路目标,如防震锤、间隔棒等检测提供了保证。

**关键词:**绝缘子缺陷;改进 DETR;空洞卷积;DIUO

**中图分类号:**TP391 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2025.0001.003

### Insulator Defect Detection Algorithm Based on Improved DETR

OUYANG Mingsan, LI Jie

School of Electrical and Information Engineering, Anhui University of Science and Technology, Anhui Huainan 232000, China

**Abstract: Objective** Regular inspection and maintenance of insulator defects play a crucial role in ensuring the safety of transmission lines. In order to address issues such as low detection accuracy and poor universality of existing insulator defect detection methods, an algorithm based on an improved Detection Transformer (DETR) was proposed. **Methods** An improved encoder was designed to use four Transformer stages to capture the feature information of different scales and relationships in the image. At the same time, the intermediate output features of ResNet50 were also used to supplement the output features of the layered Transformer, thereby enhancing the performance of the object detection algorithm. The improved decoder was designed and a three-layer series structure was adopted to ensure that the decoder can receive and learn feature maps of different scales at different stages. Moreover, the feature fusion enhancement module and the query update module can make the decoder learn image feature information more effectively and reduce the difficulty of matching regions with similar semantic features, further improving the accuracy of network detection. **Results** Simulation experiments were conducted on aerial images of insulator defects in transmission lines. The improved method achieved recognition accuracies of 99.5% and 80.4% at different thresholds, respectively, which were 3.4% and 6.1% higher than those of the original algorithm. It exhibited good detection performance for partially occluded targets and demonstrated

**收稿日期:**2023-03-05 **修回日期:**2023-05-18 **文章编号:**1672-058X(2025)01-0020-08

**基金项目:**国家自然科学基金资助项目(51874010);安徽省重点研究发展计划(202004A07020043)。

**作者简介:**欧阳名三(1967—),男,江西萍乡人,教授,博士,从事计算机控制技术研究。

**通讯作者:**李杰(1997—),男,江苏淮安人,硕士生,从事模式识别与目标检测研究。Email:2587049301@qq.com。

**引用格式:**欧阳名三,李杰.基于改进 DETR 的绝缘子缺陷检测算法[J].重庆工商大学学报(自然科学版),2025,42(1):20-27.

OUYANG Mingsan, LI Jie. Insulator defect detection algorithm based on improved DETR[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(1): 20-27.

superior detection accuracy and generalization ability compared with other algorithms. **Conclusion** The improved DETR demonstrates higher detection performance, enabling accurate detection of insulator defects. This provides assurance for the detection of other targets on transmission lines in the future, such as vibration dampers and spacer rods.

**Keywords:** insulator defect; improved DETR; dilated convolution; DIOU

## 1 引言

高压输电线路通道的检查是保证电网安全的关键措施之一。绝缘子作为输电线路的重要组成部分,受到恶劣的自然条件的影响,容易发生故障<sup>[1]</sup>。绝缘子缺陷的定期检测与维修对保障输电线路的安全有至关重要的作用。然而,高压塔分布广泛,且位于山区和森林地区,使得人工检查困难、危险且效率低下。为了解决这些问题,使用无人图像捕获设备检测传输通道上的关键物体可以大大改善人工检测面临的各种困难<sup>[2]</sup>。因此,在电力线检测中应用目标检测方法处理图像具有重要的研究意义。

目前,运用人工智能技术对输电线路进行巡检目标进行检测的方法已取得较多研究成果。现有的目标检测算法主要分为两大类:一是基于传统深度卷积神经网络的目标检测算法;二是基于 Transformer 架构的目标检测算法。

基于传统深度卷积神经网络的目标检测算法。陈嘉琛等<sup>[3]</sup>基于 YOLO(You Only Look Once)<sup>[4]</sup>模型,提出了基于改进 YOLOv3 的输电线路缺陷识别方法,加入空间金字塔池化模块使得该算法能提取多尺度深度特征,以适应不同尺寸的图片检测。李瑞生等<sup>[5]</sup>基于 SSD(Single Shot Multi Box Detector)模型<sup>[6]</sup>,提出了改进 SSD 的输电线路小目标缺陷检测方法,使用不同大小和角度的默认边框分散到每个特征图中去输出最终的检测框。但传统深度卷积算法,受制于卷积核感受野的大小和锚框的形状,缺乏对全局特征的学习能力,因此对目标的检测精度不高。

随着深度学习不断地发展,基于 Transformer 网络结构的目标检测方法引起了广泛的关注和研究。Transformer 使用注意力机制获得图像特征,通过点积操作自适应调整权重参数,减少模型的学习偏差。因此,Transformer 具有比 CNN 和多层感知机结构拥有更强大的泛化能力。国内外学者也基于 Transformer 提出了不同的目标检测模型,如 CBNET<sup>[7]</sup>、DyHead<sup>[8]</sup>、Swin-transformer<sup>[9]</sup>等。在缺陷检测领域,李刚等<sup>[10]</sup>提出一种 DETR 与先验知识融合的输电线路缺陷检测方法,将先验知识与图像的视觉特征有机融合,增强模型的鉴别能力,但受限于先验知识获取难度高,泛用性不强。张乃雪等<sup>[11]</sup>提出一种基于 Smooth-DETR 的表面小尺寸缺陷检测算法,通过结合 Smooth-L1 损失和 GIOU 损失的优势,进一步提升了小尺寸缺陷的回归精度,从而提

高算法的检测精度,但对网络结构并未做出改进。此类方法依然存在收敛速度慢等缺陷,同时并未对存在遮挡的样本进行实验研究,仍需进一步提高。

为有效解决现有研究的不足,在目标检测模型 DETR<sup>[12]</sup>的基础上进行改进。针对研究对象,即绝缘子缺陷检测,DETR 算法具有以下优势。首先,DETR 算法不依赖于人工设计的锚框,减少了对绝缘子缺陷样本的先验知识需求,提高了模型的泛化能力。其次,DETR 算法利用 Transformer 网络的全局上下文感知能力,可以有效地处理绝缘子缺陷在图像中的复杂背景和尺度变化,提高了检测的准确性。

主要改进方案如下:(1)设计改进编码器,使用分层 Transformer 编码器生成不同尺度特征图并与主干网络中间输出特征进行融合,从而提升目标检测算法的性能;(2)设计改进解码器,能够在不同阶段接收并学习不同尺度的特征图,同时特征融合增强模块和查询更新模块能进一步提高网络检测的准确率。通过对输电线路绝缘子缺陷图像进行实验研究,结果表明改进方法较原算法在检测精度方面有所提升,同时对比其他算法具有更优的检测性能和泛化能力。

## 2 DETR 算法原理

DETR 检测算法主要由 3 部分组成,即主干网络(Backbone)、Transformer 注意力模块和分类预测头(FPN)。首先,该算法利用由残差网络构建的主干网络从输入图像中提取特征图。然后,将提取的特征与位置编码(Positional Encoding)相加,并传递到编码器中。同时,一定数量的对象查询嵌入解码器作为输入。解码器的每个输出被馈送到前馈网络,该网络用于预测目标。最后,使用基于匈牙利算法(Hungarian Algorithm)<sup>[12]</sup>的二分图匹配方法计算检测结果与真实值之间的损失。总体结构如图 1 所示。




图 1 DETR 模型结构

Fig. 1 DETR model structure

DETR 模型是一种基于 Transformer 架构<sup>[13]</sup>的端到端的目标检测模型。核心在于将目标检测建模为一个集合预测问题,并利用 Transformer 的自注意力机制

(self-attention) 对目标和全局图像上下文之间的关系进行推理<sup>[9]</sup>, 因此 DETR 模型具有强大的全局特征学习能力。Transformer 的自注意力机制可以描述为公式:

$$Q = XW^Q \quad (1)$$

$$K = XW^K \quad (2)$$

$$V = XW^V \quad (3)$$

$$\text{attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V \quad (4)$$

式(1)~式(4)中,  $X$  是由主干网络提取的特征向量,  $W^Q$ 、 $W^K$  和  $W^V$  是变换矩阵, 通过随机初始化并随训练过程进行优化,  $Q$ 、 $K$  和  $V$  分别是查询向量、键向量和值向量,  $\sqrt{d}$  为缩放因子, 最后通过式(4)计算出输出权重矩阵, 其中的每个元素代表了注意力权重值。

### 3 改进 DETR 算法

#### 3.1 改进编码器

在原始的 DETR 模型中, 编码器接收来自 ResNet 网络的输出, 对图像特征进行学习。然而, 由于输入图像经过了 32 倍的下采样, 导致丢失了很多特征信息。并且由于输电线图像采集设备拍摄距离和角度不同导致目标尺寸大小差异明显<sup>[14]</sup>。

为了有效地利用特征信息进行目标识别和定位, 引入了基于金字塔多尺度注意力机制作为解码器的一部分。这种金字塔多尺度注意力机制是一种新颖的分层 Transformer 编码器, 能够生成高分辨率的细粒度特征和低分辨率的粗略特征。同时, 它与主干网络的中间特征图进行融合, 从而提供解码器所需的图像局部细节特征和完整全局特征。改进编码器如图 2 所示。

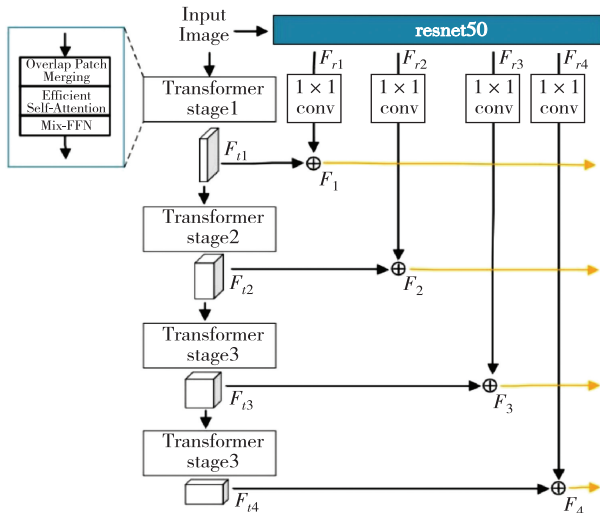


图 2 改进编码器结构  
Fig. 2 Improved encoder structure

Transformer stage 结构由高效自注意力 (Efficient Self-Attention) 层、混合前馈网络 (Mix Feed forward Network, Mix-FFN) 层和重叠压缩合并层 (Overlapped Patch Merging, OPM) 构成。改进编码器中共包含 4 个

Transformer stage, 这些阶段能够通过自注意力机制来捕捉图像中不同尺度和关系的特征信息。使用多层 Transformer 处理图像过程中会进行大量的自我注意力操作。图像在大量的自我注意力操作后, 通常会导致特征注意力分散<sup>[15]</sup>。因此, 利用 ResNet50 的中间输出特征来补充分层 Transformer 的输出特征从而减少注意力分散。具体过程如图 2 所示, 将产生的特征  $\{F_{i1} | i \in (1, 2, 3, 4)\}$  和 Resnet18 的输出特征  $\{F_{ri} | i \in (1, 2, 3, 4)\}$  一一对应聚合, 计算过程用公式表示为

$$F_i = F_{ri} \oplus \int^{1 \times 1} F_{i1} \quad (5)$$

式(5)中,  $\int^{1 \times 1}$  表示  $1 \times 1$  的卷积操作,  $\oplus$  表示对应像素点相加。  $F_{ri}$  的维度为  $(2^{i+5}, \frac{w}{2^{i+1}}, \frac{h}{2^{i+1}})$ ,  $F_{i1}$  的维度为  $(2^{i+7}, \frac{w}{2^{i+1}}, \frac{h}{2^{i+1}})$ 。

通过将中间输出特征与分层 Transformer 的输出特征进行融合, 能够在保留全局上下文信息的同时, 注入更加丰富和细致的局部特征, 从而提升目标检测算法的性能。这种改进的编码器结构能够充分利用 Transformer 和卷积操作的优势, 提取多尺度和多层次的图像特征, 从而更好地捕捉目标的语义信息和上下文关系。

#### 3.2 改进解码器

解码器在目标检测任务中扮演着至关重要的角色, 其主要任务是接收来自编码器的特征输出, 并基于特征图中的信息生成包含位置和类别信息的查询对象。为有效地实现这一目标, 提出了一种创新的改进解码器, 采用了 3 层串联的结构, 以确保解码器能够在不同阶段接收并学习不同尺度的特征图 (图 3)。

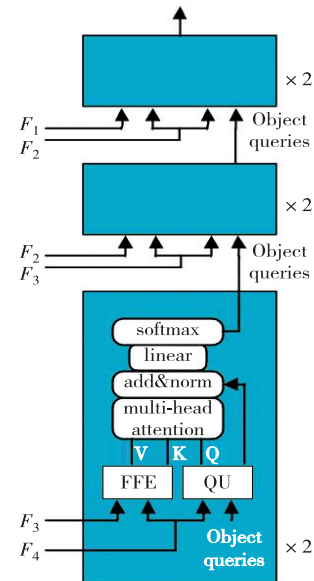


图 3 改进解码器结构

Fig. 3 Improved decoder structure

改进的解码器结构具有一定的层次性,共分为 3 层,每个解码器层负责处理特定的尺度特征图,并接收来自上一层的查询对象输出。改进的解码器由 6 个结构相同的解码器模块组成,解码器模块包含特征融合增强 (Feature Fusion Enhancement Module, FFE) 模块和查询更新 (Query Update module, QU) 模块。

### 3.2.1 FFE 模块

特征融合增强模块,旨在高效地增强特征信息,使得解码器能够更有效地学习图像的特征信息。诸多研究显示添加注意力机制可以提升网络模型对小目标的检测效果<sup>[16]</sup>。该增强模块通过一系列操作对特征图进行处理,以实现特征的融合和权重调整 (图 4)。




图 4 FFE 模块

Fig. 4 FFE model

首先,特征图经过上采样操作与高维特征图进行拼接融合,使用一个 1 维卷积对通道数进行调整。随后,采用了最大池化和平均池化操作,用于从特征图中提取关键特征。最大池化能够捕捉特征图中最显著的特征值,而平均池化则能够融合特征图中的整体信息。利用一个多层感知机 (MLP) 对特征向量进行学习和映射,以提高特征的表达能力和区分度。MLP 通过多个全连接层的组合,能够学习非线性映射,从而捕捉特征之间的复杂关系和高阶特征。最后,将经过 MLP 映射得到的两个特征向量相加,并通过 ReLU 函数进行激活,得到特征权重。最后,将特征权重与特征图相乘得到特征增强的特征图。计算过程用公式表示为

$$F_{di} = \int^{1 \times 1} \text{Concat}(F_n, \text{Up}(F_m)) \quad (6)$$

$$Mc(F_{di}) = \sigma(\text{MLP}(\text{maxpool}(F_{di})) + \text{MLP}(\text{avgpool}(F_{di}))) \quad (7)$$

$$F = Mc(F_{di}) \otimes F_{di} \quad (8)$$

式(6)中,  $\int^{1 \times 1}$  表示  $1 \times 1$  的卷积操作参数分别为  $(3 \times 2^{i+4}, 256, 1, 1)$ , Up 是上采样操作,Concat 是通道维度上的串联操作。式(7)中,  $\sigma$  表示 ReLU 激活。式(8)中,  $\otimes$  表示对应像素点相乘。

### 3.2.2 QU 模块

查询更新模块,旨在确保在输入自注意处理之前将编码图像特征纳入对象查询中,以降低匹配具有相似语义特征区域的难度。QU 模块如图 5 所示。




图 5 QU 模块

Fig. 5 QU module

首先,将编码图像特征从一维序列  $F \in \mathbf{R}^{h \times d}$  恢复到二维特征图  $F_R \in \mathbf{R}^{h \times w \times d}$ ,  $d$  表示对象查询的个数。使用 MLP 来预测每个对象查询的  $M$  个关键点的空间位置  $R_{SP}$ ,  $M$  一般取 8。然后,通过双线性插值从  $F_R$  中采样这些代表性关键点。最后将  $M$  个具有代表性的关键点对应的采样特征向量串联起来作为新的对象查询  $Q^{new'}$ 。同时,接收先前的查询  $Q$ ,通过“线性投影+ReLU 激活”与新的查询相乘得到最终的查询  $Q^{new}$ ,输入到后续的多头自注意中。计算过程用公式表示为

$$R_{SP} = \text{MLP}(F_R) \quad (9)$$

$$Q^{new'} = \text{concat}[F_R(x, y) \text{ for } x, y \in R_{SP}] \quad (10)$$

$$Q^{new} = Q^{new'} \otimes \sigma(QW_R) \quad (11)$$

式(9)中,  $R_{SP} \in \mathbf{R}^{2 \times M \times d}$  代表  $d$  个查询中每个关键点坐标。式(11)中,  $W_R$  表示线性投影的可学习参数,  $\sigma$  表示 ReLU 激活,  $\otimes$  表示对应像素点相乘。

通过 QU 模块,使得解码器能够更好地利用编码图像特征中的语义信息,并更精确地定位与对象查询相关的特征区域,进一步改善 Transformer 在目标检测任务中的表现。

### 3.3 改进 DETR 整体架构

改进后的模型整体架构如图 6 所示,主要由以下多个部分,分别是特征提取的主干网络模块 (Backbone)、改进的编码器 (Transformer encoder)、改进的解码器 (Transformer decoder) 和前馈神经网络预测模块 (FFN)。

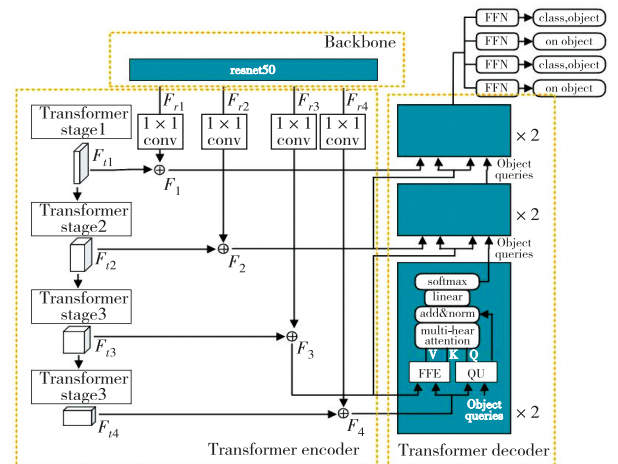


图 6 改进 DETR 模型结构

Fig. 6 Improved DETR model structure

首先,利用主干网络 ResNet50 对输入的绝缘子图像进行特征提取,并获得对应视觉特征。其次,使用分层 Transformer 编码器生成不同尺度和关系的特征信息。将 ResNet50 的中间输出特征与编码器输出特征融合后输入到不同解码器层中。最后,将解码器输出向量输入至前馈神经网络预测模块获得目标类别和预测框信息。

## 4 实验与结果分析

### 4.1 数据集与实验平台

研究所使用的模型主要是针对高压输电线通道存在的绝缘子及其缺陷进行检测。通过无人机、相机等不同设备所拍摄采集图像,通过像素变换将数据集图像尺寸统一缩减为  $416 \times 416$  像素的大小。通过对图像进行翻转、剪裁和平移等操作增加样本多样性,扩充数据集到 5 475 张,其中包含正常绝缘子图像约 3 100 张,缺陷图像约 2 300 张。按照 8 : 2 的比例划分训练集与测试集。

在 TeslaV100 上进行训练和测试模型。操作系统是 Ubuntu18.04,开发语言是 Python,框架是 Pytorch。在训练时使用迁移学习加载预训练模型。训练网络时,Batch\_size 为 4,初始学习率为 0.000 1,迭代总批次为 300,权重衰减设置为 0.000 01,学习率每 50 轮进行一次衰减来保证模型更好地收敛。

### 4.2 运行结果

在相同配置环境下,对改进算法和原始算法进行了 300 轮的训练,并在不同 IOU 阈值下比较它们的平均精度,实验结果如图 7、图 8 所示。通过观察实验结果可得,改进算法相较于原始算法在训练过程中表现出更快的收敛速度。此外,在检测精度方面,改进算法相对于原始算法也有所提升。在不同 IOU 阈值下,改进算法的精度分别达到了 99.5% 和 80.4%。




图 7 平均精度变化曲线 (IOU 为 0.5)

Fig. 7 Average accuracy variation curve (IOU=0.5)

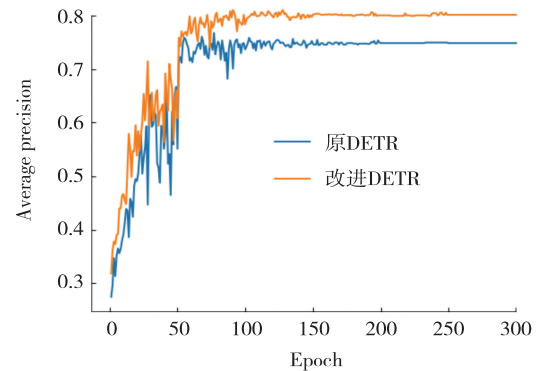



图 8 平均精度变化曲线 (IOU 为 0.5 : 0.95)

Fig. 8 Average accuracy variation curve (IOU=0.5 : 0.95)

为了直观地比较改进前后算法的检测效果,在测试集上使用训练出的最优网络进行了测试,并选取了部分图像进行可视化对比,如图 9 所示。在图中,第一列展示了原始 DETR 算法的检测结果,而第二列展示了改进后的 DETR 算法的检测结果。实验结果表明:改进后的检测算法能够在不同复杂度的背景下更准确地检测出所有目标,并且对目标类别的置信度高于原算法。特别是在小尺寸目标上,改进后的算法的性能提升明显。此外,通过在图像中加入黑框来模拟遮挡情况,并发现改进算法仍能更准确地识别目标,并且相较于原算法,改进算法的置信度也有显著提升。这些结果进一步验证了改进算法在绝缘子缺陷检测任务中的优越性。



(a) 原 DETR



(b) 改进 DETR

图 9 算法检测结果可视化对比

Fig. 9 Visual comparison of algorithm detection results

### 4.3 消融实验

将 DETR 作为基线模型,参考 mAP 和参数量等指标,对比分析各项改进策略对模型检测性能的影响,实验结果见表 1。

表 1 综合使用不同改进策略检测效果对比

Table 1 Comprehensive use of different improvement strategies to compare the detection effects

组别	改进编码器	改进解码器	参数量 /M	mAP <sub>(IOU=0.5)</sub>	mAP <sub>(IOU=0.95:0.5)</sub>
1			129	0.961	0.743
2	✓		145	0.974	0.776
3		✓	137	0.982	0.773
4	✓	✓	149	0.995	0.804

根据表 1 的结果显示,各种改进方案对于整体模型的检测性能都起到了积极的作用。原始 DETR 算法在未经过任何改进的情况下,mAP<sub>(IOU=0.5)</sub>为 96.1%,mAP<sub>(IOU=0.95:0.5)</sub>为 74.3%。然而,在这些基础上,通过改进编码器,mAP 得到了显著提升,分别达到了 97.4%和 77.6%。其次,使用改进解码器也使 mAP 提升较为明显,分别为 98.2%和 77.3%。最终,综合运用了所有提出的改进方法,虽然参数量相较原始算法有所增加,

但整体检测准确率分别达到了 99.5%和 80.4%,较原始 DETR 算法提高了 3.4%和 6.1%。这些研究结果明确表明,通过综合利用上述改进策略,能够显著提高 DETR 模型在输电线路绝缘子和缺陷检测任务中的检测精度。

### 4.4 与同类改进算法比较

为验证所提方法的有效性,在相同实验环境下,将改进方法与 Conditional DETR<sup>[17]</sup>、Dynamic DETR<sup>[18]</sup>、Anchor DETR<sup>[19]</sup> 3 种同类基于 DETR 的改进目标检测模型进行对比实验。3 种模型都是基于原始 DETR 模型架构进行改进的,它们在编码器和解码器方面采用了不同的改进策略。通过与这些同类基于 DETR 的改进目标检测模型进行对比,能够全面展示本文改进方法的有效性和优势。实验结果见表 2。

表 2 同类模型的对比结果

Table 2 Comparison results of similar models

算法	mAP <sub>(IOU=0.5)</sub>	mAP <sub>(IOU=0.95:0.5)</sub>	AR	参数量/M
DETR	0.961	0.743	0.805	129
Conditional DETR	0.963	0.751	0.803	121
Dynamic DETR	0.971	0.757	0.819	138
Anchor DETR	0.979	0.765	0.832	133
改进算法	0.995	0.804	0.830	149

由表 2 与 3 种同类最新基于 DETR 的改进目标检测模型对比结果可知,本文改进模型在 mAP (IOU = 0.5) 和召回率 AR 方面取得最优结果,分别达到了 99.5%和 83%。一方面,Deformable DETR 对原始模型的编码器和解码器做出一定优化,准确率达到 97.1%,召回率方面也有所上升,但仍低于本文改进算法。Conditional DETR 在参数量方面为最优,但准确率和召回率方面没有优势。同样 Anchor DETR 虽然召回率较优,为 83.2%,但准确率方面略低于本文算法。

### 4.5 与其他主流最新算法比较

为了进一步验证所提方法的先进性,在相同的实验环境下,将改进方法与多种经典和同类最新的目标检测模型进行了对比实验。这些模型包括 Faster-RCNN<sup>[20]</sup>、SSD<sup>[6]</sup>作为经典目标检测模型,YOLOv7<sup>[21]</sup>、R-YOLO<sup>[22]</sup>为最新目标检测模型,以及 CBNET<sup>[7]</sup>、DyHead<sup>[8]</sup>、Swin-transformer<sup>[9]</sup>作为同类最新基于 Transformer 架构的目标检测模型。这些模型被广泛应用于目标检测任务,并在各自的研究领域取得了显著的成果。通过与这些模型进行对比实验,能够全面评估所提方法的有效性,并展示改进算法在性能指标上

的优势。进一步证明所提方法在绝缘子缺陷检测领域的应用潜力和研究意义。

通过与 Faster-RCNN、SSD 等模型的对比,能够评估所提方法在目标检测任务中的创新性和改进效果。同时,与 CBNET、DyHead、Swin-transformer 同类最新基于 Transformer 架构的目标检测模型的对比,能够展示改进方法在同类模型中的先进性和竞争力。表 3 给出了以上模型在数据集上的性能指标。

表 3 不同模型的对比结果

Table 3 Comparison results of different models

算 法	mAP <sub>(IOU=0.5)</sub>	参数量/M	AR	FPS
Faster-RCNN	0.725	114	0.729	18.1
SSD	0.876	98	0.583	34.1
YOLOv5s	0.716	26	0.707	24.5
YOLOv7	0.758	45	0.747	32.4
R-YOLO	0.789	59	0.752	36.8
BEIT	0.973	137	0.807	14.1
DyHead	0.971	131	0.809	13.7
Swin-transformer	0.977	139	0.812	12.9
改进算法	0.995	149	0.830	15.2

由表 3 可知,改进 DETR 模型 mAP 指标达到 99.5%,同时召回率 AR 也达到了 83%。一方面,SSD 和 R-YOLO 有着较高的检测速率,精度可以达到 80% 左右,但是召回率较低。另一方面,YOLOv7、YOLOv5s 和 Faster-RCNN 的召回率在 70% 左右,但检测精度较改进算法偏低。相比之下改进 DETR 模型虽然在参数量指标上略逊于其他模型,检测速率能与其他模型保持在同一数量级,同时在检测精度 mAP 和召回率 AR 评价指标明显优于其他 4 个参照模型。

通过与 4 种同类最新基于 Transformer 架构的目标检测模型的对比,本文改进模型在 mAP<sub>(IOU=0.5)</sub> 和 mAP<sub>(IOU=0.95:0.5)</sub> 方面取得最优结果,分别达到了 99.5% 和 80.4%。一方面,CBNET 对 Transformer 的编码器和解码器做出一定优化,准确率达到 97.3% 和 75.8%,召回率方面也有所上升,但仍低于本文改进算法。DyHead 的参数量为对比模型中最优,准确率达到 97.7% 和 76.1%,较本文算法仍有一定差距。同样 Swin-transformer 虽然召回率较优,为 81.2%,但准确率方面低于本文算法。相比之下改进 DETR 模型虽然在参数量指标上略高于其他模型,但综合考量准确率和召回率等指标,改进算法明显优于其他模型。

综上所述,改进措施有效地提高了模型的检测精

度,在不同 IOU 阈值下都取得了显著的性能提升。研究结果进一步证明了采用这些改进策略的重要性,以实现更准确、可靠的输电线路绝缘子和缺陷检测。

## 5 结 论

绝缘子缺陷严重影响输电线路的安全,针对输电线路中绝缘子识别精度低且泛化能力不强等问题,提出了一种基于改进 DETR 的绝缘子缺陷检测算法。改进编码器,使用分层 Transformer 编码器生成不同尺度特征图并与主干网络中间输出特征进行融合,从而提升目标检测算法的性能。改进解码器,在不同阶段接收并学习不同尺度的特征图,同时特征融合增强模块和查询更新模块能进一步提高网络检测的准确率。

通过实验表明改进算法在绝缘子缺陷数据集上, mAP<sub>(IOU=0.5)</sub> 和 mAP<sub>(IOU=0.95:0.5)</sub> 分别达到了 99.5%、80.4%,较原算法分别提升了 3.4%、6.1%,对部分遮挡目标有较好的检测效果,具有更高的检测性能,同时对比其他目标检测模型也具有一定优势,实现对绝缘子缺陷的准确检测。为下一步对于其他输电线路目标,如防震锤、间隔棒等检测提供了保证。

## 参考文献(References):

- [1] 李唯韬, 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 Wei-tao, HOU Jian-ping, ZHANG Qian, 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.
- [2] 罗鹏, 王波, 马恒瑞, 等. 基于组合式目标检测框架的低漏报率缺陷识别方法[J]. 高电压技术, 2021, 47(2): 454-464.  
LUO Peng, WANG Bo, MA Heng-rui, et al. Defect recognition method with low false negative rate based on combined target detection framework [J]. High Voltage Engineering, 2021, 47(2): 454-464.
- [3] 陈嘉琛, 俞曜辰, 陈中, 等. 基于改进 YOLOv3 的输电线路缺陷识别方法[J]. 南方电网技术, 2021, 15(1): 114-120.  
CHEN Jia-chen, YU Yao-chen, CHEN Zhong, et al. An improved method for defect identification of transmission lines based on YOLOv3[J]. Southern Power System Technology, 2021, 15(1): 114-120.
- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 779-788.
- [5] 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 Rui-sheng, ZHANG Yan-long, ZHAI Deng-hui, et al. Pin defect detection of transmission line based on improved SSD[J]. High Voltage Engineering, 2021, 47(11): 3795-3802.
- [6] LIU W, ANGUELOV D, et al. SSD: single shot multibox detector[J]. International Journal of Engineering Intelligent Systems for Electrical and Communications, 2016: 21-37.
- [7] LIANG T, CHU X, LIU Y, et al. CBNNet: A composite backbone network architecture for object detection[J]. IEEE Transactions on Image Processing, 2022, 31: 6893-6906.
- [8] DAI X, CHEN Y, XIAO B, et al. Dynamic head: Unifying object detection heads with attentions[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2021: 7369-7378.
- [9] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2021: 9992-10002.
- [10] 李刚, 张运涛, 汪文凯, 等. 采用 DETR 与先验知识融合的输电线路螺栓缺陷检测方法[J]. 图学学报, 2023, 44(3): 438-447.
- LI Gang, ZHANG Yun-tao, WANG Wen-kai, et al. Defect detection method of transmission line bolts based on DETR and prior knowledge fusion [J]. Journal of Graphics, 2023, 44(3): 438-447.
- [11] 张乃雪, 钟羽中, 赵涛, 等. 基于 Smooth-DETR 的产品表面小尺寸缺陷检测算法[J]. 计算机应用研究, 2022, 39(8): 2520-2525.
- ZHANG Nai-xue, ZHONG Yu-zhong, ZHAO Tao, et al. Detection method for small-size surface defects based on Smooth-DETR[J]. Application Research of Computers, 2022, 39(8): 2520-2525.
- [12] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2020: 213-229.
- [13] ASHISH V, NOAM S, NIKI P. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30(5): 6000-6010.
- [14] 张焕龙, 齐企业, 张杰, 等. 基于改进 YOLOv5 的输电线路鸟巢检测方法研究[J]. 电力系统保护与控制, 2023, 51(2): 151-159.
- ZHANG Huan-long, QI Qi-ye, ZHANG Jie, et al. Bird nest detection method for transmission lines based on improved YOLOv5[J]. Power System Protection and Control, 2023, 51(2): 151-159.
- [15] SILVA J, HISTACE A, ROMAIN O, et al. Toward embedded detection of polyps in WCE images for early diagnosis of colorectal cancer[J]. International Journal of Computer Assisted Radiology and Surgery, 2014, 9(2): 283-293.
- [16] 张学锋, 王子琦, 汤亚玲. 基于 YOLO-CDF 神经网络的安全帽检测[J]. 重庆工商大学学报(自然科学版), 2022, 39(4): 32-41.
- ZHANG Xue-feng, WANG Zi-qi, TANG Ya-ling. Helmet detection based on YOLO-CDF neural network[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2022, 39(4): 32-41.
- [17] MENG D, CHEN X, FAN Z, et al. Conditional DETR for fast training convergence[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2021: 3651-3660.
- [18] DAI X, CHEN Y, YANG J, et al. Dynamic DETR: end-to-end object detection with dynamic attention[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2021: 2968-2977.
- [19] WANG Y, ZHANG X, YANG T, et al. Anchor DETR: query design for transformer-based detector[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(3): 2567-2575.
- [20] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [21] 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]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2023: 7464-7475.
- [22] HOU Y, SHI G, ZHAO Y, et al. R-YOLO: a YOLO-based method for arbitrary-oriented target detection in high-resolution remote sensing images[J]. Sensors, 2022, 22(15): 5716.

责任编辑:陈 芳