结合在线注意力网络的变电站绝缘子缺陷识别研究

唐松平[1]， 朱锐锋[1]， 李 冲[1]， 董玉玺[1]， 张 云[1]， 纪 超[2]
（1. 广东电网有限责任公司 惠州供电局，广东 惠州 516000；2. 西安工程大学 电子信息学院，西安 710048）

摘 要：针对因复杂背景干扰而导致的变电站巡检图片中的目标难以识别的问题，提出基于在线注意力网络的变电站绝缘子缺陷识别算法。首先，在YOLOv5网络的基础上引入动态注意力累积机制，获取绝缘子图像中丰富的语境信息，提高检测的精确度。其次，采用PIoU和Focal Loss函数对模型的损失函数进行优化，解决难以准确检测缺陷目标的问题。最后，利用现场绝缘子图像制作数据集并进行训练和测试，比较提出的新算法与当前主流目标检测算法的性能。本文算法对变电站绝缘子缺陷的检测精确率达到96.15%，召回率为91.49%，平均精确率达99.14%。测试结果表明：改进算法的效率有明显提高，对在复杂背景下识别变电站绝缘子缺陷有重要意义。

关键词：绝缘子缺陷检测；深度卷积网络；在线注意力累积机制；自适应注意力网络；损失函数
DOI：10.15938/j.jhust.2026.03.009
中图分类号：TM755 **文献标志码**：A **文章编号**：1007-2683(2026)03-0089-08

Research on Substation Insulator Defect Recognition Combined with Online Attention Network

TANG Songping[1]， ZHU Ruifeng[1]， LI Chong[1]， DONG Yuxi[1]， ZHANG Yun[1]， JI Chao[2]
（1. Huizhou Power Supply Bureau, Guangdong Power Grid Co., Ltd., Huizhou 516000, China;
2. School of Electronics and Information, Xi'An Polytechnic University, Xi'an 710048, China）

Abstract: Addressing the issue of difficulty in recognizing targets in substation inspection images due to interference from complex backgrounds, this paper proposes a substation insulator defect recognition algorithm based on Adaptive attention networks. Firstly, an online attention accumulation mechanism is proposed on the basis of YOLOv5 network to obtain rich contextual information in insulator images and improve the accuracy of detection; then the loss function of the model is improved by using PIoU, Focal Loss function to solve the difficulty of accurately detecting defective targets. Finally, the on-site insulator images are used to produce a dataset and the model is trained and tested to compare the proposed algorithm with the current mainstream target detection algorithms. The algorithm in this paper achieves an accuracy of 96.15%, a recall rate of 91.49% and an AP value of 99.14% for the detection of substation insulator defects. The test results show that the improved algorithm shows significant improvement in efficiency over other algorithms. It is of great significance to be able to identify substation insulator defects in complex backgrounds.

Keywords: insulator defect detection; deep convolutional network; online attention accumulation mechanism; adaptive attention network; loss function

收稿日期：2024-01-08
基金项目：南方电网公司科技项目(031300KK52220012)；陕西省创新人才推进计划-青年科技新星(2022KJXX-41)；国家自然科学基金(52307182).
作者简介：唐松平(1984—)，男，硕士，高级工程师；
朱锐锋(1989—)，男，硕士，高级工程师.
通信作者：纪 超(1987—)，男，副教授，硕士研究生导师，E-mail：dachao9898@163.com.

0 引 言

绝缘子是变电站中常用的绝缘器件[1-3]，由于其长期暴露在复杂环境中，容易受到恶劣天气影响而发生故障。为了保证变电站的安全，必须对绝缘子进行定期巡检[4]。早期大都采用传统图像处理方法对绝缘子图片进行识别，但是恶劣环境和天气可能会导致检测效率低[5]。随着计算能力和深度学习的迅猛发展，利用深度学习算法进行绝缘子工作状态检测已成为目前研究热点。

目前，绝缘子缺陷检测算法多种多样，文[6]利用图像信息融合技术与轮廓分割检测算法进行变电站绝缘子缺陷识别，该算法识别效率较低。文[7]将 YOLOv5 与 VGG-16 融合，用于变电站绝缘子缺陷识别，该算法效率较高。李斌等[8]设计了残差注意力机制和多尺度特征融合网络进行变电站绝缘子缺陷识别，该算法识别精度较高。林倩闽等[9]设计了基于机器视觉的变电站绝缘子识别与定位系统，通过 Vision 模块进行变电站绝缘子缺陷识别。王小玉等[10]对 YOLOv5 的 Neck 部分进行裁剪，显著提高了网络推理速度，降低了系统复杂性。这些算法虽效果较好，但并未考虑恶劣天气对绝缘子检测效果的影响。

YOLO 系列算法在目标检测任务中具有检测实时性强、效果好的优点[11]，故本文在 YOLOv5 算法的基础上进行改进，提出在线注意力网络，用于变电站绝缘子缺陷识别，实现对变电站中绝缘子状态的检测。

1 基于在线注意力网络的绝缘子缺陷检测

针对巡检绝缘子因受恶劣天气而导致的传统算法检测准确性较低的问题[12]，本文引入了在线注意力网络模型，用于变电站绝缘子缺陷的检测。在线注意力网络首先使用在线注意力累积机制，提高数据集中感兴趣区域的显著性，获取绝缘子图像中丰富的语境信息。而后，利用 PIoU 和 Focal Loss 函数对模型的损失函数进行改良，以此提高检测精度。算法的检测过程如图 1 所示。

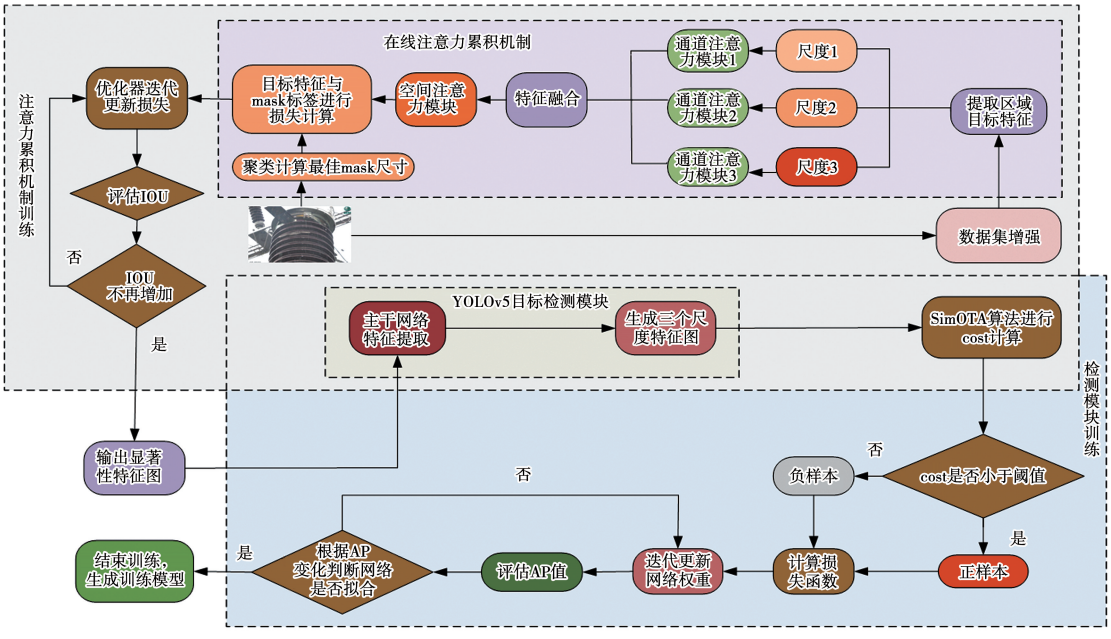

图 1 自适应在线注意力算法模型检测流程图

Fig. 1 Flowchart of the adaptive online attention algorithm model detection process

首先，对获得的图像进行预处理并通过不同尺度的卷积提取目标特征，将特征图分别输入至通道注意力模块，突出图像重点区域的通道特征信息。其次，将重点区域的通道特征信息图通过卷积和上采样操作统一大小后进行拼接，利用输入空间的注意力模块来提取目标的位置信息，增强目标显著度。然后，将显著性增强后的特征图输入至 YOLOv5 主干网络中进行训练，通过迭代不断更新网络权重，保存效果最优的网络参数，得到测试集的基准网络。最后，将测试集输入至基准网络中进行测试，获得最

终结果。

1.1　在线注意力累积机制

为了获得绝缘子图像中的丰富语义信息,使图像中感兴趣的特征位置能得到重点关注,本文融合了注意力机制和多尺度特征提取的思想,提出在线注意力累积机制,可学习并实时更新网络权重。在线注意力累积机制分别从 3 个不同尺寸的特征图中提取感兴趣区域并进行融合,提升目标区域的显著度。

1.1.1　通道注意力累积机制

为了增强目标区域显著性,进而提升算法精确度,本文通过通道注意力累积机制赋予每个通道不同的权重。首先,对输入图像进行不同大小的卷积操作,分别提取不同尺度的特征图,通过通道注意力累积模块,学习每个特征通道的重要性。然后,将生成的通道注意力图调整大小后进行逐像素累加,完成通道重标定。通过不断突出目标通道特征,尽可能完整地挖掘目标区域特征。图 2 为通道注意力机制的原理图。

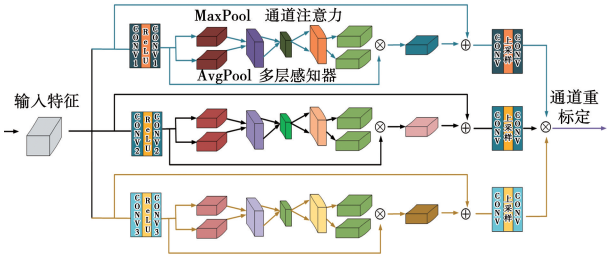

图 2　通道注意力累积原理图

Fig. 2　Principle diagram of channel attention accumulation

设 F_{in} 为输入通道注意力累积机制的初始特征图,首先利用带有 ReLU 激活函数的卷积层提取特征得到特征图 F_r,然后将 F_r 分别经过最大池化和平均池化后,送入多层感知器进一步完成特征提取。将提取出的通道特征经 Sigmoid 激活函数处理后,与通道统计系数相乘得到 $F_r^{'}$。最后与输入特征 F_{in} 进行逐元素相加得到每个分支的输出 F_b。

经过 2 个卷积层和 ReLU 激活函数的处理,对输入特征图进行特征提取。

$$F_r = f_1(F_{in}) \tag{1}$$

式中:公式 $f_1(\cdot)$ 为执行第 1 阶段的特征提取步骤,包括 2 次卷积运算和 ReLU 激活操作;F_{in} 为通道注意力累积机制的输入特征图;F_r 为经过第 1 步特征提取后得到的特征图。

将得到的特征图像 F_r 输入至通道注意力模块深化特征提取,通道注意力模块第 2 步特征提取包括最大池化与平均池化层,2 层全连接层及 Sigmoid 激活函数。

$$f(F_r) = \sigma(M_{LP}(P_{Avg}(F_r)) + M_{LP}(P_{Max}(F_r))) \tag{2}$$

$$C_{eff} = f(F_r) \tag{3}$$

$$F_r^{'} = C_{eff} F_r \tag{4}$$

式中:$\sigma(\cdot)$ 为 Sigmoid 激活函数;$f(\cdot)$ 为由通道注意力机制执行的操作;C_{eff} 为通道统计系数;$F_r^{'}$ 为通道注意力机制首次提取的特征,在经过 Sigmoid 激活函数后与通道统计系数相乘后的结果;M_{LP} 为多层感知器;$P_{Avg}(\cdot)$ 为平均池化;$P_{Max}(\cdot)$ 为最大池化。每个通道注意力累积模块的最终输出,可用 F_b 来表示:

$$F_b = F_{in} + F_r^{'} \tag{5}$$

通道注意力累积机制包含 3 个结构相同但卷积核大小不同的分支,分别为 Conv1、Conv2、Conv3,其卷积核大小分别为 3×3,5×5,7×7。因此,通道注意力机制能够从 3 个不同尺度分别提取特征信息。在获得特征图 F_1、F_2、F_3 后,通道注意力累积模块使用的卷积和上采样操作对这些特征图进行融合。

$$F_{out} = [f_{fuse}(F_1), f_{fuse}(F_2), f_{fuse}(F_3)] \tag{6}$$

式中:$f_{fuse}(\cdot)$ 为融合操作;$[\cdot]$ 为连接操作;F_{out} 为通道注意力累积机制的输出。

1.1.2　空间注意力机制

空间注意力机制有助于关注显著特征的位置信息。通道注意力累积机制在输出通道特征图后,将其传递至空间注意力机制,以便提取位置特征。图 3 为空间注意力机制的原理图。

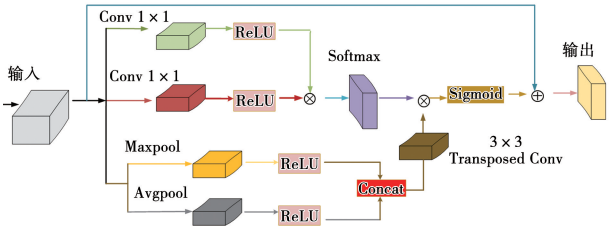

图 3　空间注意力机制原理图

Fig. 3　Principle of spatial attention mechanism

空间注意力机制中的每个卷积层都配备 1 个卷积核,用于学习局部空间特征。首先,通道注意力机制的输出特征图 F_{out} 通过 2 个大小相同的降维卷积层进行降维,利用矩阵乘法和 Softmax 计算得到空间注意力图 F_{so};其次,F_{out} 分别由卷积和平均池化拼接,经过转置卷积得到特征图 F_{co};最后,将特征图

F_{sp}与F_{co}在经过 Sigmoid 激活操作之后相乘,再与F_{out}相加得到输出特征图,如式(7)所示。

$$\left.\begin{aligned} F_{so} &= \mathrm{Softmax}\{\mathrm{RE}[f^{1\times1}(F_{out})]\times\mathrm{RE}[f^{1\times1}(F_{out})]\} \\ F_{co} &= f_{3\times3}\{\mathrm{RE}[f^{3\times3}(F_{out})]+\mathrm{RE}[P_{Avg}(F_{out})]\} \\ F_{sp} &= \sigma\{[F_{so}\times F_{co}]F_{out}\} \end{aligned}\right\} \tag{7}$$

式中:Softmax(·)为使用 Softmax 的计算操作;F_{so}为 Softmax 计算后得到的特征图;RE[·]为 ReLU 激活函数;$\sigma(\cdot)$为 Sigmoid 激活函数;$f_{k\times k}$为转置卷积操作,卷积核大小为 $k\times k$;$f^{k\times k}$为卷积操作,卷积核大小为 $k\times k$;F_{co}为最大池化和平均池化操作后得到的特征图;F_{sp}为经过空间注意机制后得到的特征图。

1.2 损失函数的改进

自适应注意力网络模型将原损失函数分为L_{IoU}、L_{conf}和L_{cls},如式(8)所示。

$$L = L_{cls} + L_{IoU} + L_{conf} \tag{8}$$

均衡交叉熵损失函数如式(9)所示。

$$f_{BCE}(\alpha,\gamma) = \begin{cases} -\beta\log(\alpha), & y=1 \\ -(1-\beta)\log(1-\alpha), & y=0 \end{cases} \tag{9}$$

式中:α 为模型的预测概率;β 为正样本的权重系数,用于平衡正负样本。

Focal Loss 损失函数[13]引入权重因子 λ 和$(1-\alpha)^{\delta}$ 调节不均衡,如式(10)所示。

$$F_{FL} = \begin{cases} -\lambda(1-\alpha)^{\delta}\log(\alpha), & y=1 \\ -(1-\lambda)\alpha^{\delta}\log(1-\alpha), & y=0 \end{cases} \tag{10}$$

式中:λ 为用于平衡正负样本数量的值;δ 为 1 个调制因子,用来平衡简单样本与复杂样本。一般情况下,当 δ 增大时,λ 应适当减小。实验中,δ 取 2,λ 取 0.25 效果最佳。

采用 PIoU 损失函数[14]作为自适应注意力网络模型的预测框回归损失函数,PIoU 函数及其损失L_{PIoU}计算公式如式(11)~(12)所示:

$$F_{PIoU}(b,b') = \frac{S_{b\cap b'}}{S_{b\cup b'}} \tag{11}$$

$$L_{PIoU} = \frac{-\sum_{(b,b')\in M}\ln F_{PIoU}(b,b')}{|M|} \tag{12}$$

式中:M 为所有的正样本;$|M|$为正样本的数量;b 为真实目标所在位置;b'为目标框;$b\cap b'$为两者之间并集的区域;$S_{b\cup b'}$、$S_{b\cap b'}$分别为真实目标与目标框的并集与交集所含的像素数。自适应注意力网络模型中的 L_{conf}、L_{cls}和 L_{IoU}如式(13)~(15)所示:

$$\begin{aligned} L_{conf} = &\sum_{i=0}^{s^2}\sum_{j=0}^{B} I_o[\hat{C}\log(C_i)+(1-\hat{C})\log(1-C_i)] - \\ &\kappa\sum_{i=0}^{s^2}\sum_{j=0}^{B} I_n[\hat{C}\lambda(1-\hat{C})^{\delta}\log(C_i)+ \\ &(1-\hat{C})(1-\lambda)\hat{C}^{\delta}\log(1-C_i)] \end{aligned} \tag{13}$$

$$\begin{aligned} L_{cls} = -&\sum_{i=0}^{s^2} I_o\sum[\hat{\alpha}_i(c)\beta\log(\alpha_i(c))+ \\ &(1-\hat{\alpha}_i(c))(1-\beta)\log(1-\alpha_i(c))] \end{aligned} \tag{14}$$

$$L_{IoU} = \sum_{i=0}^{s^2}\sum_{j=0}^{B} I_o(C_i-\hat{C}_i)^2 + \mu_n\sum_{i=0}^{s^2}\sum_{j=0}^{B} I_n(C_i-\hat{C}_i)^2 \tag{15}$$

式中:s^2 为网格数;B 为每个单元预测框的数量;λ 为权重因子,用来改善正负样本不平衡;β 为用来平衡正负样本的权重因子;μ_n 为滑动窗口与真实目标所在区域重叠面积的损失权重;I_n 和 I_o 用于检测目标是否在滑动窗口 j 中的第 i 个单元格内,若有物体两者分别取 0 和 1,若没有物体两者分别取 1 和 0;κ 为不包含目标时置信度惩罚的权重;C_i 和$\hat{C}_i$ 分别为单元格 i 中真实目标的置信度与预测框的置信度;$\hat{C}$ 为置信度的真实标签(目标存在时为 1,背景时为 0);$\alpha(c)$与 $\alpha_i(\hat{c})$则分别为真实框与预测框的类别概率值。

2 实验及结果分析

2.1 实验环境及参数配置

本文实验配置条件:i7-9700 处理器、NVDIA TITANX 显卡、64 G 内存,在 Python3.7 环境下用 Pytorch 框架实现整个算法。参数配置如表 1 所示。

表 1 实验参数配置

Tab.1 Experimental parameter configuration

参数	数值
批大小	64
动量大小	0.9
权重衰减	0.000 5
初始学习率	0.01
后 200 轮中学习率	0.001

2.2 数据采集与处理

本文实验数据采用现场采集及国网开放的 1 200张变电站绝缘子数据集图片。通过对数据集进行旋转、翻转、缩放,实现了数据增强,可减少模型过拟合的风险,提升了模型的鲁棒性。增强后的数据集共2 426张图片,主要检测变电站绝缘子破损缺陷。使用 LabelImg 软件进行标注,并将缺陷定义为

breakage,选用其中的 80% 作为训练集,剩余 20% 作为测试集。

2.3　实验结果评价标准

精确度[15]反映了模型判断为正例且实际为正例的比重,如下:

$$P = \frac{\mathrm{TP}}{\mathrm{TP} + \mathrm{FP}} \tag{16}$$

式中:P 为精确度;TP 为检测到的正例;FP 为检测到的反例。

召回率[16]反映了模型判断出的正样本占所有测试图片中正样本的比重,如下:

$$R = \frac{\mathrm{TP}}{\mathrm{TP} + \mathrm{FN}} \tag{17}$$

式中:R 为召回率;TP 为检测到的正例;FN 为未检测到的正例。

平均精确率[17]表示某一类别的平均精度,即:

$$\alpha_{\mathrm{AP}} = \frac{1}{n}\sum_{i=1}^{n}\int_{0}^{1} P(R)\,\mathrm{d}R \tag{18}$$

式中:α_{AP} 为平均精确率;P 为精确度;R 为召回率;n 为样本数。

2.4　实验结果分析

本文选取处于复杂背景下的变电站绝缘子破损缺陷样本,并利用自适应注意力网络进行实验,实验结果如图 4 所示。



(a) 雨天破损绝缘子



(b) 强光照射破损绝缘子

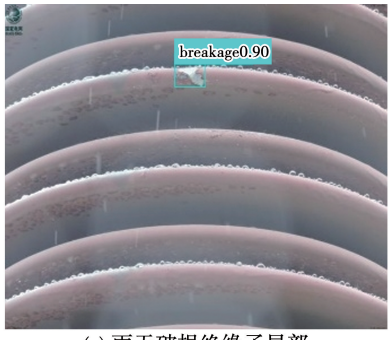

(c) 雨天破损绝缘子局部



(d) 雾天绝缘子

图 4　自适应注意力算法检测结果图

Fig. 4　Detection result graph of adaptive attention algorithm

由图可见,本文算法可准确识别处于恶劣天气环境下变电站中的绝缘子,且具有较高的置信度。

本文提出的自适应注意力网络与传统的 YOLOv5 网络模型的 $P-R$ 变化曲线如图 5 所示。由图可见,YOLOv5 模型的精确率为 97.45%,自适应注意力网络对破损检测的平均精确率为 99.14%,相较于 YOLOv5 算法提升了 1.69%,自适应注意力网络模型的精确度较高。平均精确率随训练轮数的变化如图 6 所示。

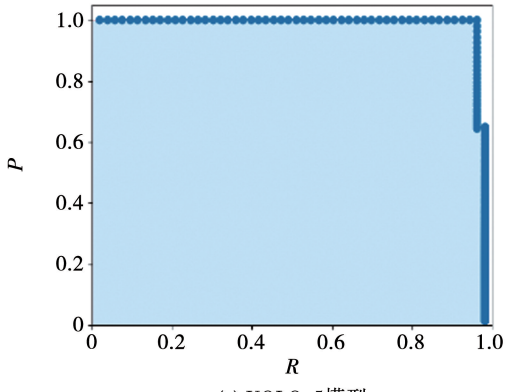

(a) YOLOv5模型

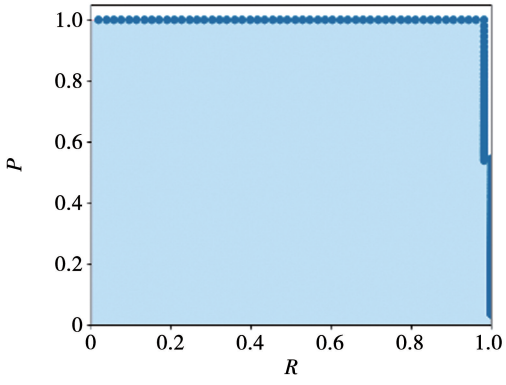

(b) 自适应注意力模型

图 5 不同阈值下的精确率与召回率变化曲线

Fig. 5 Curve of accuracy and recall rate changes at different thresholds

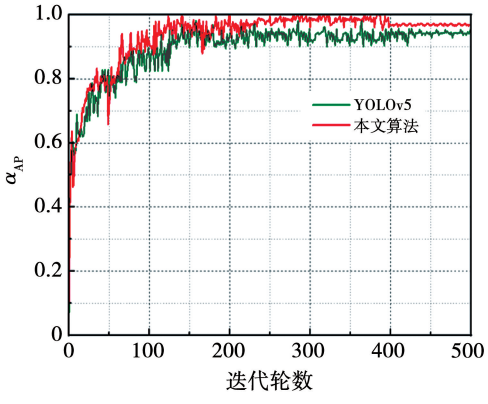

图 6 α_{AP} 变化曲线

Fig. 6 Curve of α_{AP} variation

由图可见,伴随迭代次数的上升,α_{AP} 也在不断升高。本文算法在迭代 400 轮后,α_{AP} 逐渐趋于稳定,传统 YOLOv5 算法在迭代 430 轮后逐渐趋于稳定。相比于本文算法,传统 YOLOv5 算法收敛速度较慢且收敛后的 α_{AP} 低于本文算法。

图 7 为损失函数变化曲线。由图可见,随迭代轮数的不断增加,损失函数趋于收敛;相比于 YOLOv5 算法,本文算法表现出更快的收敛速度和更低的损失值[18]。本文对 YOLOv5 网络模型采取 2 种不同的策略进行改进,提出自适应注意力网络模型。为了说明各个模块的有效性,本文将各个模块依次嵌入模型中,实验结果如表 2 所示。

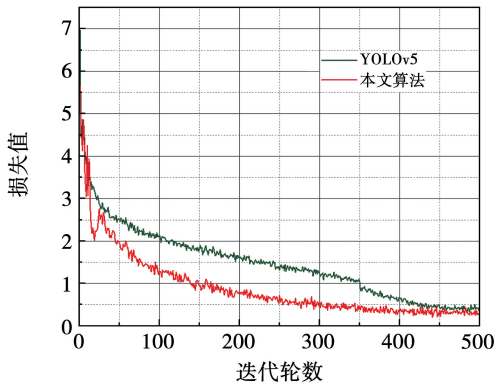

图 7 损失函数变化曲线

Fig. 7 Curve of loss function changes

表 2 消融实验结果

Tab. 2 Ablation experiment results

在线注意力累积机制	损失函数改进	α_{AP}/%
		97.45
√		98.42
	√	97.86
√	√	99.14

注:“√”表示使用该模块

由表可知,不同改进方式给网络性能带来了不同程度的提升。其中,在线注意力累积机制将原始的 YOLOv5 网络模型的 α_{AP} 提高 0.97%;改进 YOLOv5 网络模型的损失函数将模型的 α_{AP} 提高了 0.41%。为了进一步说明实验结果的可靠性,将本文算法与 3 种流行算法进行对比[19],实验结果如表 3 所示。

表 3 各种算法的检测结果对比

Tab. 3 Comparison of detection results of various algorithms

方法	α_{AP}/%	参数量/M	P/%	R/%
Faster R-CNN	97.12	137.099	94.25	90.72
YOLOv3	91.84	61.949	93.64	89.65
YOLOv5	97.45	7.377	94.44	91.07
本文算法	99.14	7.946	96.15	91.49

由表可见,Faster R-CNN 的 α_{AP} 达到 97.12%,平均准确率相对较高,但模型参数量很大,实用性不强。YOLOv3 算法的 α_{AP} 比 Faster R-CNN 低 5.28%,召回率为 89.65%,相较于其他 3 种算法略低,说明

YOLOv3 算法出现的漏检现象较其他算法更为严重。YOLOv5 算法的 α_{AP} 为 97.45%,召回率为 91.07%。本文算法的 α_{AP} 可达到 99.14%,在对比算法中检测效果最准确,且模型参数量较小,仅为 7.946 MB,召回率和精确度均高于其他 3 种算法,相较于其他算法漏检情况和精确性均有所改善,实用性更强。因此,本文算法可在保证模型大小的同时满足精确度要求,更适合恶劣天气条件下变电站的绝缘子缺陷检测。

3　结　语

针对航拍巡检图像中待检测目标检测准确率较低的问题,本文提出了用于识别绝缘子缺陷的自适应注意力网络模型。实验结果表明:自适应注意力网络模型对变电站绝缘子缺陷检测的 α_{AP} 为 99.14%,精确度为 96.15%,召回率为 91.49%,相较于传统的 YOLOv5 模型 α_{AP} 提升了 1.69%,精确度提升了 1.71%,召回率提升了 0.42%,表明本文算法检测精确度相对较高,漏检率较低。

由于绝缘子缺陷类型众多,本文收集的破损与自爆数据集具有局限性,下一步应将算法应用于其余缺陷类型检测中。

参 考 文 献:

[1] 冯晗, 姜勇. 使用改进 Yolov5 的变电站绝缘子串检测方法[J]. 智能系统学报, 2023, 18(2): 325.
FENG Han, JIANG Yong. A Substation Insulator String Detection Method Based on an Improved Yolov5 [J]. CAAI Transactions on Intelligent Systems, 2023, 18(2): 325.

[2] 邱刚, 陈杰, 张廼龙, 等. 基于 YOLOv3 和 HSV 颜色空间的绝缘子低/零值故障诊断研究[J]. 高压电器, 2023, 59(1): 148.
QIU Gang, CHEN Jie, ZHANG Nailong, et al. Research of Low/Zero Defect Diagnosis of Porcelain Insulator Based on YOLOv3 and HSV Color Space Image Processing Technology[J]. High Voltage Apparatus, 2023, 59(1): 148.

[3] 陈赟, 张英, 李端姣, 等. 相近色干扰下大型变电站玻璃绝缘子目标识别算法[J]. 沈阳工业大学学报, 2025, 47(4): 478.
CHEN Yun, ZHANG Ying, LI Duanjiao, et al. Target Recognition Algorithm for Glass Insulators in Large Substations under Similar Color Interference[J]. Journal of Shenyang University of Technology, 2025, 47(4): 478.

[4] 管文瑞, 姜文刚, 王平心, 等. 基于图像处理的三支聚类[J]. 南京理工大学学报, 2023, 47(5): 643.
GUAN Wenrui, JIANG Wengang, WANG Pingxin, et al. Three Branch Clustering Based on Digital Image Processing[J]. Journal of Nanjing University of Science and Technology, 2023, 47 (5): 643.

[5] 刘行谋, 田浩, 杨永明, 等. 复杂环境背景下绝缘子缺陷图像检测方法研究[J]. 电子测量与仪器学报, 2022, 36(2): 57.
LIU Xingmou, TIAN Hao, YANG Yongming, et al. Research on Image Detection Method of Insulator Defects in Complex Environmental Background [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (2): 57.

[6] 华泽玺, 施会斌, 罗彦, 等. 基于轻量级 YOLO-v4 模型的变电站数字仪表检测识别[J]. 西南交通大学学报, 2024, 59(1): 70.
HUA Zexi, SHI Huibin, LUO Yan, et al. Digital Instruments Detection and Recognition of Substations Based on Lightweight YOLO-v4 Model at Substations[J]. Journal of Southwest Jiaotong University, 2024, 59(1): 70.

[7] 刘芳, 刘玉坤, 林森, 等. 基于改进型 YOLO 的复杂环境下番茄果实快速识别方法[J]. 农业机械学报, 2020, 51(6): 229.
LIU Fang, LIU Yukun, LIN Sen, et al. Fast Recognition Method for Tomatoes under Complex Environments Based on Improved YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51 (6): 229.

[8] 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.
LI Bin, QU Luyao, ZHU Xinshan, et al. Insulator Defect Detection Based on Multi-scale Feature Fusion [J]. Transactions of China Electrotechnical Society, 2023, 38 (1): 60.

[9] 林倩闽. 一种 CCA – 层次聚类的基因聚类算法[J]. 哈尔滨理工大学学报, 2023, 28(5): 85.
LIN Qianmin. A Gene Clustering Algorithm Based on the CCA-Hierarchical Clustering[J]. Journal of Harbin University of Science and Technology, 2023, 28(5): 85.

[10] 王小玉,林鹏. 空间通道双重注意力道路场景语义分割[J]. 哈尔滨理工大学学报,2023,28(5):103.
WANG Xiaoyu, LIN Peng. Semantic Segmentation of Unmanned Driving Scene Based on Spatial Channel Dual Attention[J]. Journal of Harbin University of Science and Technology,2023,28(5):103.

[11] 颜宏文, 陈金鑫. 基于改进 YOLOv3 的绝缘子串定位与状态识别方法[J]. 高电压技术, 2020, 46(2): 423.
YAN Hongwen, CHEN Jinxin. Insulator String Positioning and State Recognition Method Based on Improved YOLOv3 Algorithm [J]. High Voltage Engineering, 2020, 46(2): 423.

[12] 王艳辉,张福泉,邹静,等. 基于改进卷积神经网络的遥感图像目标检测方法[J]. 南京理工大学学报, 2023,47(3):330.
WANG Yanhui, ZHANG Fuquan, ZOU Jing, et al. Remote Sensing Image Object Detection Method Based on Improved Convolutional Neural Network [J]. Journal of Nanjing University of Science and Technology, 2023,47(3): 330.

[13] 许逵, 李鑫卓, 张历, 等. 自然场景下配电线网施工安全帽佩戴检测算法[J]. 计算机工程与应用, 2024, 60(8): 320.
XU Kui, LI Xinzhuo, ZHANG Li, et al. Safety Helmet Wearing Detection Algorithm for Distribution Network Construction in Natural Scenarios [J]. Computer Engineering and Applications, 2024, 60(8): 320.

[14] 冯万兴, 范鹏, 姚翔宇, 等. 基于深度学习的输电线路绝缘子缺陷识别[J]. 水电能源科学, 2021, 39(1): 176.
FENG Wanxing, FAN Peng, YAO Xiangyu, et al. Defect Identification Detection for Insulator of Transmission Line Based on Deep Learning[J]. Water Resources and Power, 2021, 39(1): 176.

[15] WEN G, LI S, LIU F, et al. YOLOv5s-CA: A Modified YOLOv5s Network with Coordinate Attention for Underwater Target Detection[J]. Sensors, 2023, 23(7): 3367.

[16] ZHANG Y, FENG W, WU Z, et al. Deep-learning Model of ResNet Combined with CBAM for Malignant-Benign Pulmonary Nodules Classification on Computed Tomography Images[J]. Medicina, 2023, 59(6): 1088.

[17] CHANG R, ZHOU S, ZHANG Y, et al. Research on Insulator Defect Detection Based on Improved YOLOv7 and Multi-UAV Cooperative System[J]. Coatings, 2023, 13(5): 880.

[18] HAO Shuai, AN Beiyi, MA Xu, 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, 38(5): 3387.

[19] ZHAI Y J, YANG X, WANG Q, et al. Hybrid Knowledge R-CNN for Transmission Line Multifitting Detection [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1.

(编辑:温泽宇)