

DOI:10.19651/j.cnki.emt.2211983

# 基于改进 YOLOv5 的输电线路鸟巢缺陷检测方法 \*

赵霖 王素珍 邵明伟 许浩

(青岛理工大学信息与控制工程学院 青岛 266520)

**摘要:** 鸟巢侵占是输电线路经常发生的一个故障情况。鸟类在铁塔上筑巢将会影响铁塔的绝缘性能,造成跳闸事故的发生。传统的输电线路鸟巢识别方法效率低且安全性不足。为此,本文提出了一种改进 YOLOv5 模型的输电线路鸟巢检测算法。通过在主干网络中加入 CBAM 注意力模块,以较小的计算代价提升主干网络的特征提取能力。在颈部网络中引入自适应特征融合模块替换原始结构,加强多尺度特征融合效果。使用更加稳定和平滑的 Mish 激活函数作为激活函数,以提升分类精度和泛化能力。实验结果表明,相较于原始 YOLOv5s 模型,改进方法在召回率以及平均精度均值方面分别提升 4.4% 和 2.3%。对于遮挡目标以及远近距离目标均表现出良好的性能,验证了改进方法的有效性。

**关键词:** 鸟巢缺陷检测;YOLOv5 算法;CBAM;自适应特征融合;Mish

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 510.1050

## Improved YOLOv5-based bird's nest defect detection method for transmission lines

Zhao Lin Wang Suzhen Shao Mingwei Xu Hao

(School of Information and Control Engineering, Qingdao University of Technology, Qingdao 266520, China)

**Abstract:** Bird's nest encroachment is a frequent fault of transmission lines. Birds nesting on the tower will affect the insulation performance of the tower, resulting in tripping accidents. Traditional bird's nest identification methods for transmission lines are inefficient and lack of security. Therefore, this paper proposes a bird's nest detection algorithm for transmission lines based on improved YOLOv5 model. By adding CBAM attention module to the backbone network, the feature extraction ability of the backbone network can be improved with less computational cost. The adaptive feature fusion module is introduced into the neck network to replace the original structure and enhance the multi-scale feature fusion effect. The more stable and smooth Mish activation function is used as the activation function to improve the classification accuracy and generalization ability. Experimental results show that, compared with the original YOLOv5s model, the recall rate and average precision of the improved method are improved by 4.4% and 2.3% respectively. It shows good performance for occlusion targets and near-far targets, which verifies the effectiveness of the improved method.

**Keywords:** bird's nest defect detection; YOLOv5 algorithm; CBAM; adaptive feature fusion; Mish

## 0 引言

随着人们生态保护意识的提高,鸟类的数量也在不断增加,这对输电线路安全造成了很大的威胁。根据国家电网输电线路停电统计数据,造成输电线路停电的原因中,与鸟巢相关的停电事件发生次数仅仅少于雷电事故和外力事故<sup>[1]</sup>。这使得架空线路鸟巢检测成为输电线路巡检中的一个重要课题。

传统的输电线鸟巢检测方法主要是基于图像处理技术对鸟巢目标进行识别,这种方法耗时且费力。徐晶等<sup>[2]</sup>提出了一种输电线路鸟巢识别方法。首先感知铁塔结构特征,以识别出图像中铁塔所在区域。之后基于颜色以及纹理特征相融合以识别出输电线铁塔上的鸟巢目标。Lu 等<sup>[3]</sup>通过设计 4 种特征并其组合以描述鸟巢主干部分特征以及边缘特征,之后使用并行和串行相组合的级联分类器来提高鸟巢分类精度。

收稿日期:2022-11-07

\* 基金项目:山东省自然科学基金(ZR2020QF101)项目资助

与传统的图像处理技术相比,采用卷积神经网络(convolutional neural networks,CNN)算法的深度学习已经成为输电线路缺陷检测领域广泛采用的方法。因为可以从图像中提取目标的多层次特征,并持续更新内部参数以实现自动识别<sup>[4]</sup>。Li 等<sup>[5]</sup>提出了一种改进的 Faster-RCNN 输电线路鸟巢检测方法。使用 K-means 聚类算法得到合适的先验框。此外,采用 focal loss 函数过滤属于背景的 anchor box,降低训练过程中的类不平衡风险。但改进模型对鸟巢缺陷检测精度只有 82.51%。Liu 等<sup>[6]</sup>提出了一种用于绝缘子识别和缺陷检测的 YOLOv3 结构,发现该方法的准确率达到 96.5%。然而,该算法图像处理时间慢。Qiu 等<sup>[7]</sup>提出了一种改进的绝缘子缺陷检测方法。采用 GraphCut 方法对原始数据集进行扩充,并使用拉普拉斯锐化对扩充后的数据集进行预处理。使用 MobileNet 网络作为特征提取网络。实验证明改进方法的可行性。

Zhang 等<sup>[8]</sup>使用改进的 YOLOv4 模型进行输电铁塔鸟巢检测。Swin Transformer 模块被添加到骨干网络,提升特征提取能力。Ghost 模块以及解耦检测头被集成到网络中,弥补了速度上的损失。实验结果证明改进模型检测精度提升 1.2%。Ding 等<sup>[9]</sup>提出了一种改进的绝缘子缺陷检测方法。引入了一种新的 anchor 的生成方法-AFK-MC2,并采用 Cluster-NMS 来提高计算速度。但由于数据集中缺陷图片数量不足,模型泛化性能得不到保证。论文中只对训练策略进行改进,并没有对实际检测网络进行改进。Qiu 等<sup>[10]</sup>采用 YOLOv4-Tiny 算法识别输电线路多种鸟害。同 Faster-RCNN、SSD 以及 YOLOv4 等算法比较后,验证了改进方法的有效性。Han 等<sup>[11]</sup>提出了一种改进的 YOLOX 绝缘子及其缺陷检测方法。SIoU 的使用加速了模型收敛速度。ECA 注意力在主干以及颈部被添加,改进方法 mAP 提高了 2.74%。Liu 等<sup>[12]</sup>使用改进的 YOLOv3 模型对复合绝缘子掉串缺陷进行检测。在主干网络中使用 3 个 DenseNets 结合进行特征提取,更好的融合浅层和深层特征。采用 SPP 网络增加特征图所获得的感受野大小,以获得更为丰富的局部特征信息。实验证明了改进方法精度的提升效果,模型大小高达 225 MB,不利于部署到应用端。Xin 等<sup>[13]</sup>提出了一种 FA-SSD 算法用在大雾天气检测绝缘子掉串缺陷。SE 注意力机制被引入到主干网络,原特征提取网络后再增加一个特征融合模块,提升了小目标检测能力。Hao 等<sup>[14]</sup>使用 YOLOv5 对架空线路绝缘子覆冰进行检测。提出的一种弱监督学习图像伪标注方法提高了数据集标注效率。此外,检测模型采用迁移学习和多维特征融合方法来提升目标检测效果。Zhao 等<sup>[15]</sup>提出了一种基于深度学习的绝缘子缺陷检测方法,将训练好的 Faster-RCNN 作为检测模型进行缺陷检测。但检测速度仅为 5 FPS,无法满足实际工程应用的需求。Deng 等<sup>[16]</sup>提出了一种轻量化绝缘子掉串缺陷检测方法。将原始骨干网络替换为 MobileNetv3,减少网络参数量。

使用 PReLU 和 CIoU 改进激活函数和损失函数。根据实验结果,模型检测精度和检测速度分别达到 94.5% 和 58.5 FPS。Chen 等<sup>[17]</sup>设计了一种基于 YOLOv4 的输电线路减振器检测方法。选择更精简的 ResNet101 作为主干网络,加快模型训练速度。并选用 FPN+PAN 网络作为模型特征融合网络。最终减振器检测精度达到 92.62%,相较于原模型提升 4.39%。

为实现输电线路鸟巢目标的精确识别,本文提出了一种基于改进 YOLOv5 深度学习模型的输电线路鸟巢检测方法。本文工作如下,收集并构建了输电线路鸟巢缺陷数据集,并对数据集中鸟巢缺陷目标进行人工标注。针对鸟巢缺陷目标特征信息模糊,特征提取过程中容易出现关键信息丢失的问题,本文在主干网络中引入 CBAM 注意力模块,通过将中间特征图沿空间和通道维度依次推理出注意力权重值,然后将得到的权重与原始特征图相乘,提升网络对原始特征中重要特征信息的关注度,进而提升主干网络的提取能力。引入 ASFF 结构对特征融合网络进行优化,通过自适应的学习在空间上过滤干扰信息以提升颈部网络特征融合效果。Mish 激活函数的引入提高了模型分类精度。最后通过实验验证了改进方法的有效性。

## 1 输电线路鸟巢缺陷检测模型

### 1.1 YOLOv5 网络模型

作为单阶段目标检测模型的代表作,YOLOv5<sup>[18]</sup>提出的多尺度预测方法,可以实现对不同尺寸目标同时进行检测。YOLOv5 模型根据网络深度和特征图宽度的不同分为 4 个型号:YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x。本文选用 YOLOv5s 模块作为基准模型,其模型体积约为 YOLOv4 的 1/10。YOLOv5 模型主要分为骨干网络、颈部网络、预测头输出,其结构如图 1 所示。

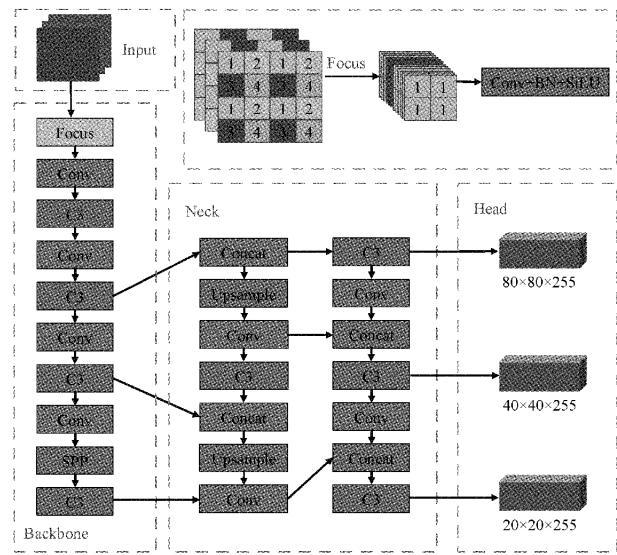


图 1 YOLOv5 网络结构

YOLOv5 骨干网络主要由 C3 模块、Focus 模块以及 SPP 模块组成。相较于早期版本所使用的 CSP 结构,C3 模块降低了参数量,提高了网络的学习能力。Focus 模块通过对图像进行切片操作,压缩模型输入图像的宽度以及高度来扩充通道数,这样的做法可以尽可能的保证没有下采样信息丢失。SPP<sup>[19]</sup>模块使用  $5 \times 5$ 、 $9 \times 9$  和  $13 \times 13$  的最大池化核对同一特征进行不同尺度的特征提取,然后进行融合。

颈部网络采用 FPN+PAN 结构,FPN 从上到下的将深层的语义信息逐步进行传递,从而对整个金字塔进行加强。PAN 在 FPN 后添加一个自下而上的金字塔结构,传递目标的位置信息,对 FPN 进行补充。预测头部分使用

GIOU 作为边界框损失函数,解决了边界框重叠问题。应用非极大值抑制(NMS)对目标进行筛选,得到最优预测权重模型。

整个网络的运行流程可以概括为:图像输入网络后,在骨干网络中对不同细粒度特征进行提取,进一步到颈部网络,对提取到的图像特征进行融合并送到预测头输出部分,通过非极大值抑制等方法,生成边界框并预测出目标类别。

## 1.2 CBAM 注意力模块

为提升主干网络的特征提取能力,在原始 YOLOv5 骨干网络中引入 CBAM (convolutional block attention module)模块。CBAM<sup>[20]</sup>由通道注意力模块和空间注意力模块组成,其结构如图 2 所示。

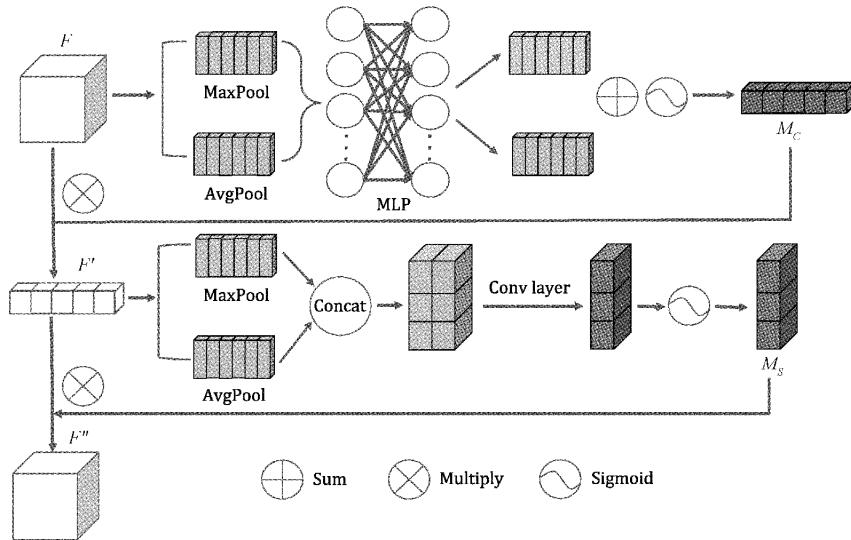


图 2 CBAM 注意力模块

在 CBAM 模块中,通道注意力部分的计算如式(1)所示。输入特征图  $F \in R^{H \times W \times C}$  同时进行全局平均池化操作(AvgPool)和最大值池化操作(MaxPool)。之后将输出发送到具有共享功能的多层感知器(MLP)中。最后将 MLP 的输出经过逐元素求和操作合并特征,再经过 Sigmoid 激活操作,生成通道特征  $M_c(F)$ 。

$$M_c(F) = \text{Sigmoid}[\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))] \quad (1)$$

式中:AvgPool( $F$ )和 MaxPool( $F$ )是对输入进行的全局平均池化操作与最大池化操作。MLP 代表多层感知器。

空间注意力部分的计算如式(2)所示。将通道特征  $M_c(F)$  乘以原始输入  $F$  得到的特征图  $F'$  作为空间注意力模块的输入。 $F'$  沿通道维度进行全局平均池化与最大池化操作,之后进行通道维度的拼接(Concat)。接着经过一层卷积操作,最后经过 Sigmoid 激活函数生成空间特征  $M_s(F')$ 。最后将生成的空间特征乘以  $F'$  得到 CBAM 模块最终生成的特征图。

$$M_s(F') = \text{Sigmoid}[f^{7 \times 7}[(\text{AvgPool}(F)); (\text{MaxPool}(F))]] \quad (2)$$

式中:  $f^{7 \times 7}$  表示使用卷积核大小为  $7 \times 7$ 。

由于本文数据集中的鸟巢缺陷目标存在目标较小且特征信息模糊的特点,这些都将影响网络的特征提取效果。此外,数据集中复杂的背景信息也会增加原始目标特征的提取难度。为解决上述问题,本文在检测模型骨干网络第 3、6、9 以及 13 层添加 CBAM 模块,通过对不同特征分配不同的权重,使网络专注于更关键的特征信息。

## 1.3 自适应特征融合模块

在卷积神经网络当中,深层特征的语义信息强,但位置信息弱;浅层特征的语义信息弱,但具有丰富的位置信息。目标检测中往往因语义信息或位置信息的丢失而影响检测效果。原始 YOLOv5 网络使用特征金字塔方法进行特征融合。在特征金字塔方法中,当某一特征图匹配到目标时,其他层的特征图信息将被忽略,这将导致不同尺度的特征之间存在不一致性,影响特征融合效果。

本文引入自适应特征融合( adaptively spatial feature fusion, ASFF)<sup>[21]</sup>方法,通过自适应学习在空间上过滤干扰信息以抑制梯度反传时不一致的情况,将深层网络特征与浅层网络特征赋予不同权重,然后进行特征融合,从而提

升目标检测效果。自适应特征融合主要分为两步操作：统一不同特征层的形状和自适应融合。

### 1) 尺度统一

自适应特征融合网络结构如图 3 所示。以 ASFF-3 为

例， $X_1$ 、 $X_2$  和  $X_3$  是来自不同层拥有不同分辨率和不同通道数的特征图，使用上采样/下采样操作将  $X_1$  和  $X_2$  调整到与  $X_3$  相同的形状，之后采用  $1 \times 1$  卷积将  $X_1$  和  $X_2$  调整到与  $X_3$  相同的通道数，得到特征图  $X^{1 \rightarrow 3}$ 、 $X^{2 \rightarrow 3}$ 。

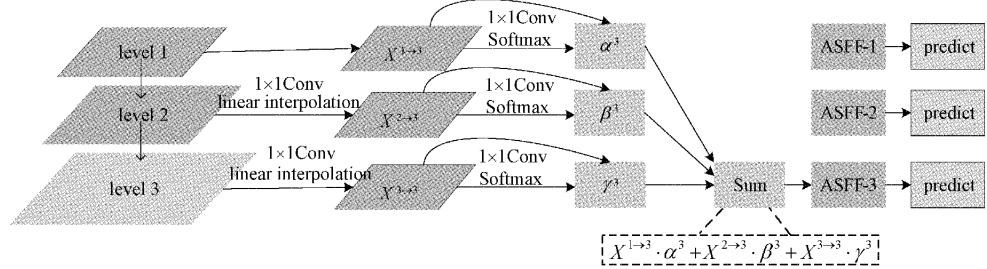


图 3 改进的特征融合模块示意图

### 2) 自适应融合

将上一步中得到的特征图  $X^{1 \rightarrow 3}$ 、 $X^{2 \rightarrow 3}$  以及  $X^{3 \rightarrow 3}$  使用 Concat 操作进行通道维度的拼接，然后采用  $1 \times 1$  卷积进行降维，最后经过 Softmax 函数得到来自不同层的重要性权重  $\alpha^3$ 、 $\beta^3$  以及  $\gamma^3$ 。将得到的权重分别对应乘以  $X^{1 \rightarrow 3}$ 、 $X^{2 \rightarrow 3}$ 、 $X^{3 \rightarrow 3}$  再求和得到融合后的新特征 ASFF-3。

$$y_{ij}^3 = \alpha_{ij}^3 \cdot x_{ij}^{1 \rightarrow 3} + \beta_{ij}^3 \cdot x_{ij}^{2 \rightarrow 3} + \gamma_{ij}^3 \cdot x_{ij}^{3 \rightarrow 3} \quad (3)$$

式中： $\alpha_{ij}^3$ 、 $\beta_{ij}^3$  和  $\gamma_{ij}^3$  分别代表空间重要性权重，通过  $1 \times 1$  卷积学习得到。另外， $\alpha_{ij}^3$ 、 $\beta_{ij}^3$  和  $\gamma_{ij}^3$  最终是通过 Softmax 函数计算获得，分别用  $\lambda_{\alpha_{ij}}^l$ 、 $\lambda_{\beta_{ij}}^l$  和  $\lambda_{\gamma_{ij}}^l$  参数进行控制。

$$\alpha_{ij}^l = \frac{e^{\lambda_{\alpha_{ij}}^l}}{e^{\lambda_{\alpha_{ij}}^l} + e^{\lambda_{\beta_{ij}}^l} + e^{\lambda_{\gamma_{ij}}^l}} \quad (4)$$

式中： $\alpha_{ij}^l + \beta_{ij}^l + \gamma_{ij}^l = 1$ ，且  $\alpha_{ij}^l, \beta_{ij}^l, \gamma_{ij}^l \in [0, 1]$ 。

### 1.4 改进激活函数

在卷积神经网络中，激活函数的使用可以使网络中增加非线性因素，提升模型表达能力。原始 YOLOv5 网络中使用 Swish 激活函数，但 Swish 激活函数存在计算量大、网络性能不稳定的问题。针对这个问题，本文使用 Mish 激活函数替换掉主干网络中的 Swish 激活函数，Mish 激活函数<sup>[22]</sup> 的数学表达式如式(5)所示。

$$f(x) = x \cdot \tanh(\text{softplus}(x)) = x \cdot \tanh(\ln(1+e^x)) \quad (5)$$

与 Swish 激活函数相同，Mish 激活函数没有上限，这个特点能够避免由于梯度接近零值导致训练速度下降，进而带来的梯度饱和问题。并且，Mish 函数的光滑性使得其在求解和模型泛化能力方面表现出更优良的性能。

通过结合 CBAM 注意力模块、自适应特征融合模块，构建了整个改进网络框架，如图 4 所示。

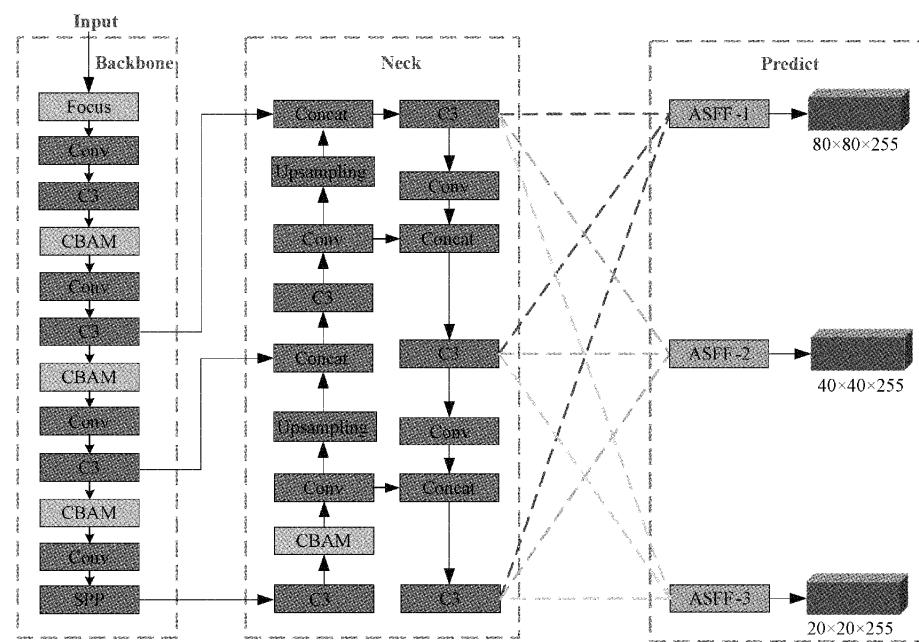


图 4 本文改进模型结构

## 2 实验

### 2.1 数据集和实验环境

本文所使用的输电线路数据集如下:1)自主收集得到的背景为农田、山林、民居、天空且包含鸟巢的输电线路图像。2)公开的中国电力线绝缘子数据集(CPLID)<sup>[23]</sup>成为本文数据集的一部分。数据集中部分样本如图 5 所示。由于数据集中存在大量难以检测的小目标,故本文在收集得到的 781 张原始输电线路图像的基础上,采用上下翻转、高斯模糊、随机裁剪的方式对数据集进行扩充,以提升模型的泛化能力,最终得到 2 747 张包含不同尺度、不同背景的输电线路鸟巢缺陷图像组成本文实验数据集。

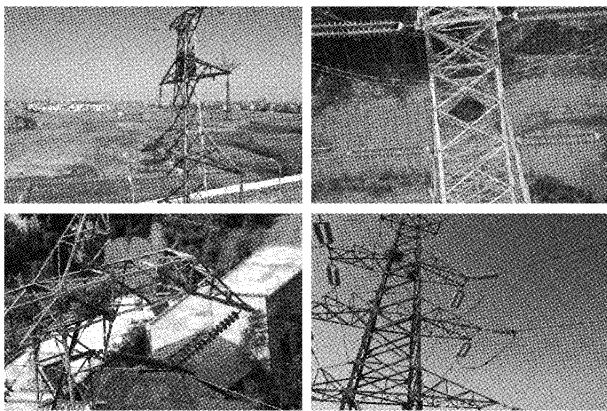


图 5 数据集中部分样本图

实验部分采用 YOLOv5 模型当中体积最少的 YOLOv5s 进行基础训练。实验超参数设定如下:初始学习率为 0.01,终止学习率为 0.2,学习率的动态量设置为 0.937,每次训练的 batch 设置为 16,使用 8 个数据加载器来加快图像读取速度,训练轮数为 200 轮,训练部分和验证部分图像尺寸统一为 640×640 pixels。

本文在配备处理器为 Intel(R) Xeon(R) E5-2683 v4、显卡为 NVIDIA GeForce RTX 2080Ti 的实验平台上进行实验。软件环境为 CUDA11.0.3 和 Python3.8,实验框架选用 Pytorch,具体配置如表 1 所示。

表 1 实验环境设置

硬件或软件	参数
显卡(GPU)	NVIDIA GeForce RTX2080Ti (11 GB)
处理器(CPU)	Intel(R) Xeon(R) E5-2683 v4
深度学习框架	Pytorch 1.7.1
GPU 加速环境	CUDA 11.0.3
编程语言	Python3.8

### 2.2 实验过程

对收集的输电线路鸟巢样本采用上下翻转、高斯模糊等方式扩充数据集,以减少网络训练过程中的过拟合现

象,提高改进模型的泛化能力。本文数据集统一采用 LabelImg 工具进行人工标注,格式为 VOC。数据集按照 8 : 1 : 1 的比例划分为训练集 2 198 张、验证集 276 张以及测试集 273 张。之后使用训练集分别在原始网络和改进网络上进行训练,训练轮次为 200 轮,每次训练传入网络的图像数据为 16 张。训练过程中采用随机梯度下降算法和余弦退火学习率衰减方法进行优化以得到最优的网络权重。最后,使用训练得到的最优模型在测试集上进行模型改进效果的验证,并与原始网络和其他目前流行的目标检测网络进行对比。整个流程如图 6 所示。

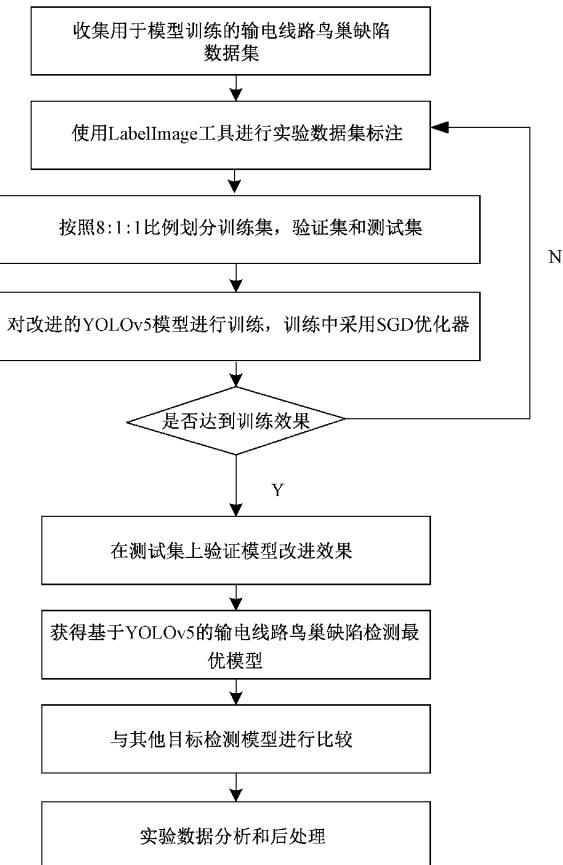


图 6 实验整体流程

### 2.3 评价指标

由于电力巡检任务的特殊性,本文使用召回率 Recall、平均精度均值 mAP@0.5 (mean average precision) 和每秒检测速率帧 FPS (frame per second) 来评估检测模型的性能。召回率反映了模型正确判定的正样本占总的正样本的比重,又称为查全率;mAP@0.5 是指以 IOU = 0.5 时所计算的 mAP 值,其中 IOU 为交并比。FPS 指标作用是衡量模型每秒处理图像数量的能力;上述评价指标计算公式如下:

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

式中:分母  $TP + FN$  是正样本预测出正样本数量加上负

样本预测出正样本数量。

$$AP = \int_0^1 P_{smooth}(r) dr \quad (7)$$

式中： $P_{smooth}(r)$  表示将 PR 曲线经过平滑处理，再对其进行积分即曲线所围成的面积。

$$mAP = \frac{\sum_{i=1}^C AP_i}{C} \quad (8)$$

式中：C 为类别数， $P_i$  为第  $i$  个类别的精确率，本文类别数 C 为 1。

### 3 实验结果分析

#### 3.1 网络模型的收敛结果

损失函数曲线能够反映出深度学习模型的学习质量，对损失曲线的收敛情况进行分析，可以更好地评估模型性能。将本文数据集送入基础模型和改进模型中进行训练，经过 200 个轮次后，得到验证集损失函数曲线如图 7 所示。

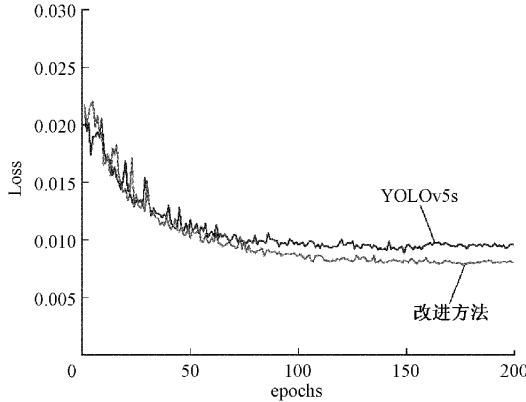


图 7 验证集损失函数收敛情况

#### 3.2 网络模型性能验证

为评估改进后模型的性能，本文基于 YOLOv5s 基础模型与本文改进模型进行实验。将改进模型与原始模型在同一实验环境下，分别使用本文数据集进行训练，训练轮数为 200 轮，平均精度均值以及召回率的对比结果如图 8 所示。从图 8 中可以清楚看出两模型训练效果良好，本文改进模型相较于原始模型在平均精度均值以及召回率方面均有明显提升，验证了改进方法的有效性。

#### 3.3 模型对训练数据集大小的敏感度测试

为了进一步测试改进模型的性能，使用 3.1 节中的训练数据集按照不同比例（60%~90%）取出数据分别进行模型训练，验证集以及测试集大小不变。结果如表 2 所示。

由表 2 可以得出如下结论，随着训练数据集规模的增大，实验模型（包括基础模型和改进模型）的性能均在提升，这说明训练数据集的大小对深度学习模型性能有很大影响。当只取出 60% 的数据进行训练时，基础模型与改进模型的召回率指标均不高。其中，基础模型的召回率只有

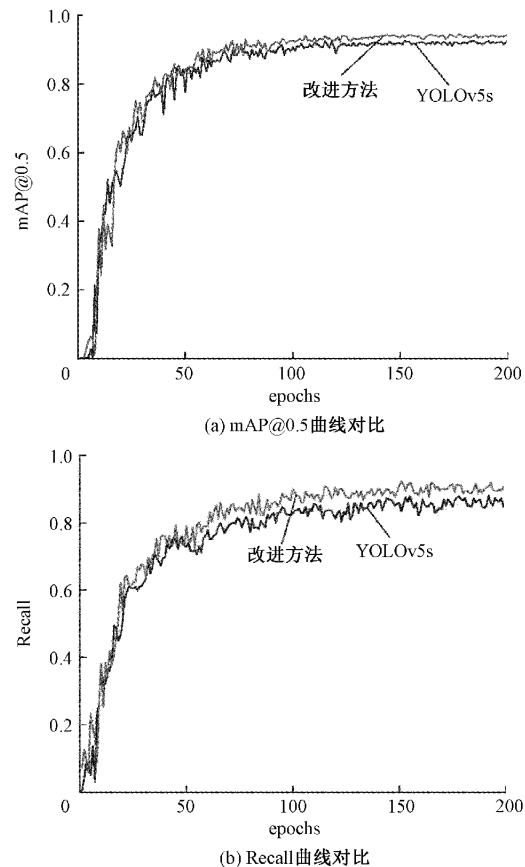


图 8 网络模型的性能对比

表 2 不同规模训练数据的验证结果

训练数据集	模型	Precision / %	Recall / %	mAP @ 0.5 / %
60%	YOLOv5s	90.4	77.5	86.0
70%		91.6	82.3	88.9
80%		93.3	85.1	90.7
90%		95.0	86.6	91.5
60%	改进方法	91.0	81.2	88.5
70%		91.3	87.2	90.1
80%		93.8	89.9	91.8
90%		94.7	90.9	93.2

77.5%，这说明数据量的不足使得模型无法学习到更多更丰富的目标特征，不利于深度学习网络的记忆和学习。当使用 70% 或更多的训练数据，各性能指标均出现平稳的提升。当训练数据集达到实验数据集的 90% 时，训练效果良好，基础模型和改进模型性能均基本达到了本文最优模型的水平。对于不同规模的训练数据，改进方法都表现出比基础模型更优秀的性能，体现在各项性能指标均高于基础模型，说明改进方法具有良好的鲁棒性。

#### 3.4 与其他目标检测算法比较

为进一步验证本文改进方法的有效性，使用

YOLOv3<sup>[24]</sup>、YOLOv4<sup>[25]</sup>以及 SSD<sup>[26]</sup>模型进行对比实验, 实验结果如表 3 所示。

表 3 不同目标检测模型性能对比

方法	Precision / Recall / mAP@0.5 /			FPS
	%	%	%	
YOLOv3	93.1	85.9	90.4	16.5
YOLOv4	95.9	88.2	92.5	13.7
SSD-VGG16	92.6	75.1	86.8	76.1
文献[8]	92.1	83.7	88.6	—
YOLOv5s	95.2	87.3	92.3	58.0
改进方法	95.4	91.7	94.6	37.5

从表 3 中可以看出, 在模型检测速度方面, SSD-VGG16 模型的检测速度最快, 可以达到 76.1 FPS, 高于 YOLOv3、YOLOv4、YOLOv5s 以及本文改进模型。但是 SSD-VGG16 模型对于鸟巢缺陷目标的平均精度均值只有 86.8%, 召回率更是只有 75.1%。这是因为 SSD 模型使用浅层特征来检测鸟巢缺陷目标, 而浅层特征由于卷积层数少, 存在特征提取不充分的问题。与之相比, 本文改进的模型虽然检测速度不及基础模型以及 SSD 模型, 但是速度也达到 37.5 FPS, 满足工程应用的需求。此外, 在召回率以及平均精度均值方面, 本文改进方法均表现出比 YOLOv3、YOLOv4 以及 SSD 模型更好的性能, 识别精确度、召回率以及平均精度均值分别达到 95.4%、91.7% 和 94.6%。

将本文算法与文献[8]所提方法进行比较, 可以看出本文算法在各主要评价指标上都表现出了更好的性能, 由于实验所使用的设备不同, 故模型检测速度方面不进行比较。以上的实验与对比结果均验证了本文改进模型的可靠性。

### 3.5 不同模型检测效果

本节实验对改进方法在测试集上的表现给出说明。将基础模型和本文改进模型训练得到的最优网络用于模型测试效果的验证。图 9 所示为部分测试样本的可视化结果, 左边为基础模型, 右边为本文改进方法。图 9(a)为正常的输电线路鸟巢缺陷目标, 图 9(b)为存在遮挡的目标, 图 9(c)、(d)分别为近距离和远距离的鸟巢缺陷目标的检测图像。

从图 9(a)中可以看出, 基础模型和改进模型都表现出了良好的性能, 但是在图像亮度不足时, 基础模型出现了误检情况, 具体表现为将防振锤误识别为鸟巢缺陷目标。在图 9(b)中, 对于存在遮挡的鸟巢目标, 改进方法表现出了更好的性能, 具体表现为更高的置信度分值。在图 9(c)中, 对于左下角近距离的鸟巢缺陷目标, 原始模型与改进模型都准确的识别出了目标, 改进方法的识别准确率更高。在图 9(d)中, 对于远距离的鸟巢缺陷目标, 基础模型

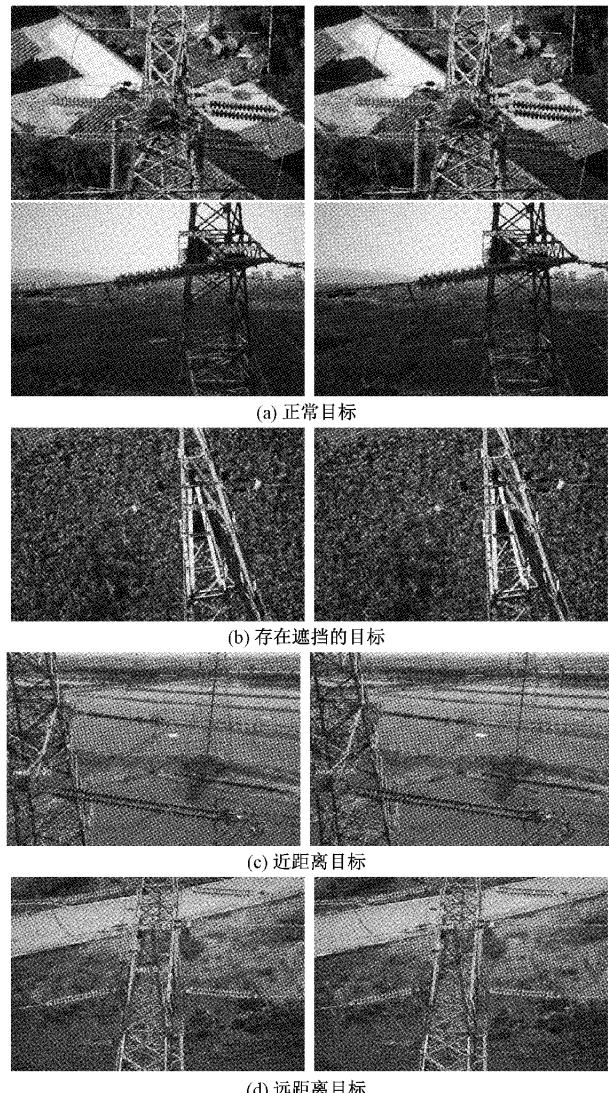


图 9 模型测试结果(左图为 YOLOv5 模型, 右图为本文改进模型)

出现了误检情况, 误将绝缘子目标识别为鸟巢, 原因是远距离的鸟巢缺陷目标在图像中有效像素占比低, 关键信息模糊。改进方法通过对不同特征分配不同的权重, 使网络对关键的特征信息更加关注, 有效改善了小尺度鸟巢目标的特征提取效果, 使得改进方法准确的识别出了该目标。测试实验说明, 与原始 YOLOv5 模型相比, 改进方法的缺陷识别准确率更高, 同时误检情况也更少。

## 4 结 论

针对输电线路鸟巢缺陷识别精度低、易出现误检情况的问题, 提出了一种改进 YOLOv5 模型的输电线路鸟巢缺陷检测方法。通过在主干网络中引入 CBAM 通道注意力机制, 在空间和通道维度上对特征进行加权处理以获得细粒度的特征。自适应特征融合机制的引入代替原始特征金字塔结构。与传统的特征图进行逐元素的堆叠来融合

多尺度特征不同,自适应融合使网络自主的学习每个尺度融合的权重,解决了特征融合过程中尺度不一致的问题,进一步提升模型检测精度。使用更加平滑的 Mish 函数作为改进方法的激活函数,提升模型性能。实验结果表明,改进后的模型优于基础模型和其他目标检测模型,在召回率和平均精度均值方面分别高于基础模型 4.4% 和 2.3%,检测速度满足电力巡检缺陷检测应用的要求。

未来的工作将主要从两个方面开展。首先,由于输电线路缺陷数据集的保密性,使得数据集的样本收集受到限制。接下来将继续收集不同尺度、不同背景的输电线路鸟巢缺陷样本来扩充实验数据集,以提升检测模型的泛化能力。此外,将进一步优化网络结构,以轻量化模块来优化主干网络结构,并应用部署到移动端,实现实时、高效的输电线路缺陷检测。

## 参考文献

- [1] WEN X, WU Q, WANG Y, et al. High-risk region of bird streamer flashover in 110 kV composite insulators and design for bird-preventing shield [J]. International Journal of Electrical Power & Energy Systems, 2021, 131: 107010.
- [2] 徐晶, 韩军, 童志刚, 等. 一种无人机图像的铁塔上鸟巢检测方法 [J]. 计算机工程与应用, 2017, 53(6): 231-235.
- [3] LU J, XU X, LI X, et al. Detection of bird's nest in high power lines in the vicinity of remote campus based on combination features and cascade classifier [J]. IEEE Access, 2018, 6: 39063-39071.
- [4] SIDDIQUI Z A, PARK U. A drone based transmission line components inspection system with deep learning technique [J]. Energies, 2020, 13(13): 3348.
- [5] LI J, YAN D, LUAN K, et al. Deep learning-based bird's nest detection on transmission lines using UAV imagery[J]. Applied Sciences, 2020, 10(18): 6147.
- [6] LIU Z, WU G, HE W, et al. Key target and defect detection of high-voltage power transmission lines with deep learning [J]. International Journal of Electrical Power & Energy Systems, 2022, 142: 108277.
- [7] QIU Z, ZHU X, LIAO C, et al. Detection of transmission line insulator defects based on an improved lightweight YOLOv4 model [J]. Applied Sciences, 2022, 12(3): 1207.
- [8] ZHANG Z, HE G. Recognition of bird nests on power transmission lines in aerial images based on improved YOLOv4[J]. Frontiers in Energy Research, 2022, 10: 870253.
- [9] DING J, CAO H, DING X, et al. High accuracy real time insulator string defect detection method based on improved YOLOv5[J]. Frontiers in Energy Research, 2022, 10: 928164.
- [10] QIU Z, ZHU X, LIAO C, et al. Detection of bird species related to transmission line faults based on lightweight convolutional neural network [J]. IET Generation, Transmission & Distribution, 2022, 16(5): 869-881.
- [11] HAN G, LI T, LI Q, et al. Improved algorithm for insulator and its defect detection based on YOLOX[J]. Sensors, 2022, 22(16): 6186.
- [12] LIU J, LIU C, WU Y, et al. An improved method based on deep learning for insulator fault detection in diverse aerial images[J]. Energies, 2021, 14(14): 4365.
- [13] XIN R, CHEN X, WU J, et al. Insulator umbrella disc shedding detection in foggy weather[J]. Sensors, 2022, 22(13): 4871.
- [14] HAO Y, LIANG W, YANG L, et al. Methods of image recognition of overhead power line insulators and ice types based on deep weakly-supervised and transfer learning [J]. IET Generation, Transmission & Distribution, 2022, 16(11): 2140-2153.
- [15] ZHAO W, XU M, CHENG X, et al. An insulator in transmission lines recognition and fault detection model based on improved faster R-CNN [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-8.
- [16] DENG F, XIE Z, MAO W, et al. Research on edge intelligent recognition method oriented to transmission line insulator fault detection[J]. International Journal of Electrical Power & Energy Systems, 2022, 139: 108054.
- [17] CHEN W, LI Y, ZHAO Z. Transmission line vibration damper detection using deep neural networks based on UAV remote sensing image[J]. Sensors, 2022, 22(5): 1892.
- [18] 王雪, 程换新, 骆晓玲, 等. 基于改进的 YOLOv5 网络的异常行为检测算法研究 [J]. 电子测量技术, 2022, 45(16): 137-141.
- [19] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37 (9): 1904-1916.
- [20] 孙丰刚, 王云露, 兰鹏, 等. 基于改进 YOLOv5s 和迁移学习的苹果果实病害识别方法 [J]. 农业工程学报, 2022, 38(11): 171-179.
- [21] 马燕婷, 赵红东, 阎超, 等. 改进 YOLOv5 网络的带钢

- 表面缺陷检测方法[J]. 电子测量与仪器学报, 2022, 36(8):150-157.
- [22] 王宸, 张秀峰, 刘超, 等. 改进 YOLOv3 的轮毂焊缝缺陷检测[J]. 光学精密工程, 2021, 29(8):1942-1954.
- [23] TAO X, ZHANG D, WANG Z, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018, 50(4):1486-1498.
- [24] 曹红燕, 沈小林, 刘长明, 等. 改进的 YOLOv3 的红外目标检测算法[J]. 电子测量与仪器学报, 2020, 34(8): 188-194.
- [25] YU Z, LIU Y, YU S, et al. Teat detection of dairy cows based on deep learning neural network FS-YOLOv4 model [J]. Computers and Electronics in Agriculture, 2022, 200: 107224.
- [26] 薛俊达, 朱家佳, 张静, 等. 基于 FFC-SSD 模型的光学遥感图像目标检测[J]. 光学学报, 2022, 42(12): 138-148.

### 作者简介

赵霖, 硕士研究生, 主要研究方向为人工智能与图像处理。

E-mail: zhaolin28328@163.com

王素珍(通信作者), 博士, 副教授, 主要研究方向为计算机应用技术。

E-mail: 417322899@qq.com

邵明伟, 博士, 讲师, 主要研究方向为计算机视觉。

E-mail: 373851680@qq.com

许浩, 硕士研究生, 主要研究方向为图像处理。

E-mail: xh809472942@163.com