

# 基于 MFBN-YOLOv5 输电线路绝缘子缺陷检测研究

王凯<sup>1†</sup>, 黄陈蓉<sup>2</sup>, 顾杰<sup>1</sup>, 季星宇<sup>1</sup>

(1. 南京工程学院电力工程学院, 江苏 南京 211100; 2. 南京工程学院计算机工程学院, 江苏 南京 211100)

**摘要:** 针对输电线路绝缘子检测效率低下的问题, 提出了一种绝缘子缺陷检测模型 MFBN-YOLOv5。首先针对骨干网络中特征提取能力不足的问题, 本文设计了 MC3 模块替换骨干网络中的 C3 模块, 在骨干网络尾部引入了 Fenhence 模块, 模块采用卷积与空洞卷积串联的方式, 有效扩大感受野并增强特征提取。其次, 为了改进模型特征融合的能力, 在颈部引入 BiFPN 结构, 提升网络对绝缘子不同缺陷的特征融合能力。最后, 边界回归损失函数使用 NWD(Normalized Wasserstein Distance)度量方式, 提高了在复杂背景条件下模型对绝缘子缺陷的定位精度。实验结果表明, 改进后的 MFBN-YOLOv5 模型可以快速、准确地检测绝缘子的缺陷, 平均精度均值(mAP0.5)达到 95.6%, 比原 YOLOv5s 模型高 3.9%, 能够满足日常电力巡检的需求。

**关键词:** 绝缘子缺陷; MC3; 空洞卷积; 改进特征融合; NWD

**中图分类号:** TP39

**文献标识码:** A

## Research on Defect Detection of Insulators in Transmission Lines Based on MFBN-YOLOv5

WANG Kai<sup>1†</sup>, HUANG Chenrong<sup>2</sup>, GU Jie<sup>1</sup>, JI Xingyu<sup>1</sup>

(1. School of Electric Power Engineering, Nanjing Institute of Technology, Nanjing, Jiangsu 211100, China;  
2. School of Computer Engineering, Nanjing Institute of Technology, Nanjing, Jiangsu 211100, China)

**Abstract:** In order to solve the problem of low efficiency of insulator detection on transmission lines, an insulator defect detection model MFBN-YOLOv5 is proposed. Firstly, in order to solve the problem of insufficient feature extraction ability in the backbone network, the MC3 module is designed to replace the C3 module in the backbone network, and the Fenhence module is introduced at the tail of the backbone network. Secondly, in order to improve the feature fusion ability of the model, the BiFPN structure is introduced into the neck to improve the feature fusion ability of the network to different defects of the insulator. Finally, the boundary regression loss function uses the Normalized Wasserstein Distance (NWD) metric to improve the positioning accuracy of the model for insulator defects under complex background conditions. Experimental results show that the improved MFBN-YOLOv5 model can quickly and accurately detect insulator defects, and the average accuracy (mAP0.5) reaches 95.6%, which is 3.9% higher than that of the original YOLOv5s model (mAP0.5), which can meet the needs of daily power inspection.

**Key words:** insulator defects; MC3; dilated convolution; improved feature fusion; NWD

如今,全国越来越多的电力部门使用智能化巡检作为主流的巡检方式。绝缘子作为输电线路上的基本器件,在电气隔离和机械支撑方面都发挥着重要作用<sup>[1]</sup>。但绝缘子长期暴露在外界,受天气、鸟粪和人为因素影响,可能产生腐蚀、污秽,甚至自爆等缺陷,因此定期巡检绝缘子对防范输电线路事故至关重要<sup>[2-3]</sup>。当前对输电线路巡检方式包括人工巡检<sup>[4]</sup>、直升机巡检、无人机巡检等。在复杂的山区、高海拔地区,人工作业难度较大,采用直升机进行巡检成本又高,而用无人机巡检具有俯瞰视角好、灵活机动、低成本、高分辨率影像、实时传输的特点。其能够从空中全方位捕捉目标区域,实时传输信息,提供高质量影像数据,并可进入危险区域,同时,成本相对较低,对环境友好。这使得无人机成为电力线路巡检的高效、经济、安全的工具。但无人机上传的图像,若采用人工审核的方式对图像进行检查,难免会出现误判、漏判的情况,而如今基于深度学习的目标检测方法为解决这一问题提供了有效途径。当前,基于深度学习的目标检测算法大致分为:以 Fast R-CNN<sup>[5]</sup>、Faster R-CNN<sup>[6]</sup>为代表的双阶段检测网络和以 YOLO<sup>[7]</sup>、SSD<sup>[8]</sup>为代表的单阶段检测网络。

在单阶段检测网络中有以下学者对 YOLO 算法检测绝缘子提出了优化。刘行谋等<sup>[9]</sup>提出一种改进 YOLOv4 的绝缘子缺陷检测方法,通过增加空间金字塔前后的卷积层来加深网络深度,实验证明,此改进方法能够很好地识别绝缘子缺陷。Yao 等<sup>[10]</sup>提出了一种基于 YOLOv3 的绝缘子检测算法,在算法中引入 GIoU 损失函数,在不等增加模型参数的情况下,提高绝缘子的检测精度。霍超等<sup>[11]</sup>在加强特征提取的网络中融合通道注意力机制 SE,使该模型提升了对绝缘子缺陷目标的辨识能力。伍箴燎等<sup>[12]</sup>提出了 YOLOv5-GSEM 的算法,将 GhostNet 结构替换原始 YOLOv5 主干网络 C3 模块,并引入 SimAM 注意力机制,提升了模型的性能。尽管上述方法在一定程度上优化了算法,但当目标置于复杂背景时,它们难以有效提取目标特征。特别是在特征融合方面的能力仍显不足,限制了模型的精度。

针对上述问题,提出了一种基于 MFBN-YOLOv5 的输电线路绝缘子缺陷检测方法。本文的主要改进工作如下:(1)针对绝缘子在复杂背景下缺陷特征很难被提取的情况,在骨干网络中将设计的 MC3 模块替换原本的 C3 模块,并在骨干网络的最后一层添加设计的特征增强模块 Fen-

hence。(2)为了提高模型的特征融合能力,在颈部网络融合 BiFPN 网络,通过其双向跨尺度连接和快速的融合操作,实现对多尺度特征的捕获和融合。(3)最后,边界回归损失函数使用 NWD 度量方式,提高了在复杂背景条件下模型对绝缘子缺陷的定位精度。

## 1 MFBN-YOLOv5 算法介绍

YOLOv5 模型在目标检测领域有着突出的表现,一共有四个主要版本:YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x,模型大小依次增大。本文实验所用的为 YOLOv5s 模型。为了进一步提高模型的检测精度,本文在 YOLOv5s 的基础上,提出了 MFBN-YOLOv5 模型。其模型结构如图 1 所示,实线部分为原 YOLOv5s 模型,虚线部分是改进的部分。MFBN-YOLOv5 模型是由 Input、Backbone、Neck 和 Head 四部分组成。Input 主要是对输入图像的预处理,对图像进行增强、自适应缩放等。Backbone 中主要包含 Conv、MC3、SPPF 和 Fenhence 模块。其中 Conv 模块是卷积层,用于特征提取;MC3 模块使用残差结构来提取图像中的特征信息;SPPF 模块在不改变特征图大小情况下,对于不同尺度特征图进行池化操作;Fenhence 模块采用卷积与空洞卷积串联的方式,有效扩大感受野并增强特征提取。Neck 中采用双向特征金字塔 BiFPN 结构,能够加强网络中的特征融合和信息传输。Head 中包括检测头、NWD 损失函数,最终输出模型的预测结果。

### 1.1 MC3 模块

YOLOv5 的骨干网络中使用了大量的 C3 模块,此模块依靠残差结构来进行提取特征,其结构如图 2 所示,但从上向下传递的过程中,中间信息会存在丢失现象。本文为了防止信息丢失,进一步加强特征信息提取,将 C3 模块结构进行优化,优化后的 MC3 结构如图 3 所示。原 C3 模块中信息传递自上而下,最后将两路的输出进行 Concat,在经过 Bottleneck 这条传输线路时,中间层的信息会产生丢失,这将降低模型的精度。而经过优化后的 MC3 模块,在利用原有的方形卷积提取图像特征的基础上,将 Bottleneck 支路的每层特征信息都进行输出并用于最后的 Concat。与原本的 C3 模块相比,改进后的 MC3 模块可以使得骨干网络获得更加丰富的特征信息,提升模型的精度。

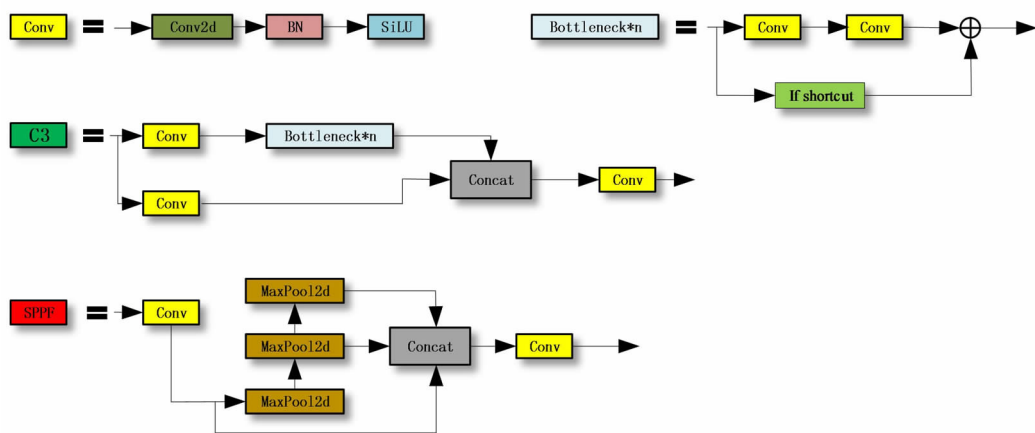
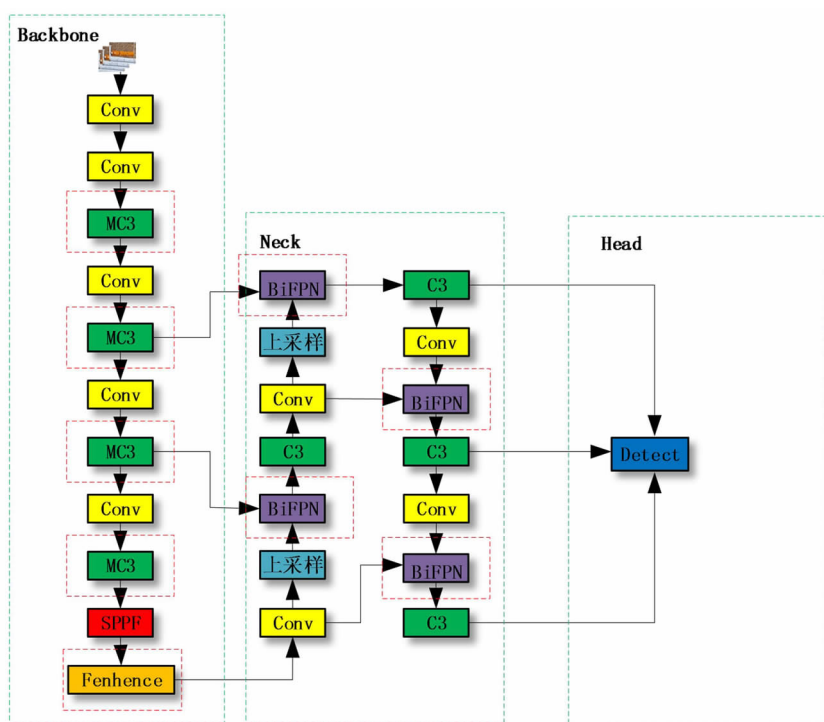


图1 MFBN-YOLOv5 结构




图2 C3 结构

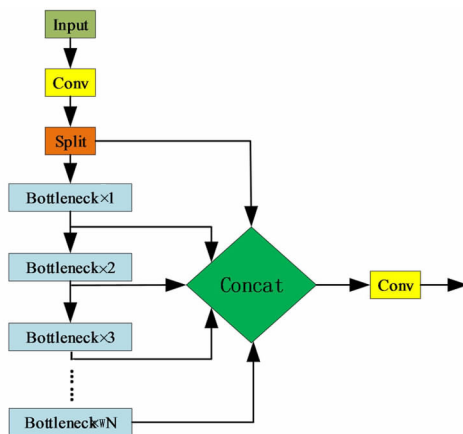


图3 MC3 结构

### 1.2 Fenhence 模块

为了进一步增强骨干网络中对绝缘子缺陷特征信息的提取能力,本文在骨干网络最后一层引入设计的 Fenhence 模块,其结构如图 4 所示。其中 Input 为特征输入,经过 Layer 模块传递后,会出现三个输出,将三个输出与原本的输入进行一个相加求和,传递经过 BN(Batch Normalization)模块和激活函数 SiLU 模块后进行最终的输出。




图 4 Fenhence 结构

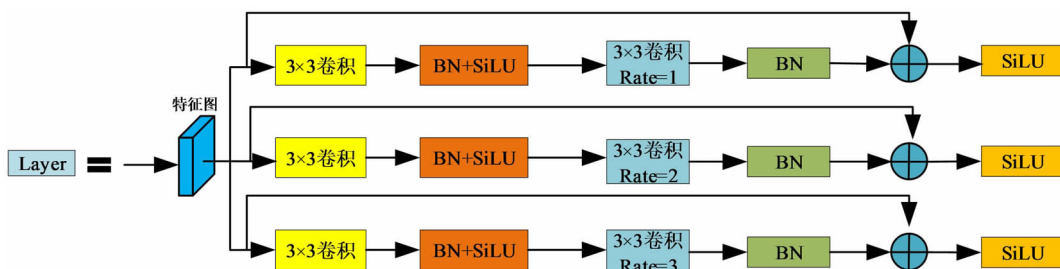


图 5 Layer 结构




图 6 不同 r 下的感受野

### 1.3 加权双向特征金字塔网络 (BiFPN)

原 YOLOv5 的特征融合网络采用 FPN + PAN 结构。FPN 网络自顶向下融合,通过上采样传递强语义特征,如图 7(a)所示;PAN 实现自底向上融合,传递强定位特征,如图 7(b)所示。然而,由于输入特征信息的尺度大小不同,因此融合输出中忽略了重要特征。为了提高特征融合的效果,本文将加权双向特征金字塔网络 (BiFPN) 作为新网络替换原本的 PAN 结构。

BiFPN 网络如图 7(c)所示,网络精简了 PAN 中低贡献结构节点,同时引入跃级连接以在同一尺度的输入节点和输出节点之间增加特征融合。此外,BiFPN 网络构建了自学习权重的特征融合模块,包括自顶向下和自底向上的双向路径,通过不

在 Fenhence 的顶部是一个 Layer 模块,其结构如图 5 所示。为了让后续 Neck 网络更好地进行特征融合,在 Layer 模块内部引入不同扩张率的空洞卷积,扩大网络的感受野,增强提取不同尺度特征信息的能力。在空洞卷积中,空洞扩张率是一个重要参数,它可以控制网络感受野的范围。空洞卷积感受野与扩张率的关系如式(1)所示。

$$k' = k + (k - 1) \times (r - 1) \tag{1}$$

式(1)中,  $k'$  为空洞卷积感受野的大小,  $k$  为原始卷积核大小,  $r$  为空洞扩张率。根据式(1),当原卷积核大小为  $3 \times 3$  时,空洞扩张率  $r$  分别为 1, 2, 3 时,所获得的空洞卷积感受野分别为  $3 \times 3$ 、 $5 \times 5$ 、 $7 \times 7$ ,如图 6 所示。因此,使用空洞卷积的优点是可以在不增加额外参数的情况下扩大感受野,捕获不同层次的特征信息,增强模型精度。

断堆叠重复块实现更高级别的特征融合。BiFPN 中使用快速归一化的方法来进行加权特征融合,如下式:

$$O = \sum_i \frac{\omega_i}{\epsilon + \sum_j \omega_j} \cdot I_i \tag{2}$$

式中:每一个权重  $\omega_i$  后面都添加了 ReLU 函数,以保证  $\omega_i \geq 0$ ,  $\epsilon = 0.0001$ ,避免数值的不稳定。 $I_i$  表示归一化后再输入的特征, $O$  表示额外的权重。




图 7 FPN、PAN、BiFPN 结构

### 1.4 损失函数 NWD

由于本文所检测的数据集中存在大量复杂背

景下的小目标,故本文引入适用于检测小目标的 NWD(Normalized Wasserstein Distance) 损失函数。NWD 采用一种新的度量方法来计算框与框之间的相似度。先把框建模为高斯分布,然后使用 Wasserstein 距离度量这两个分布之间的相似度,并替代 IoU。对于水平的标注框  $R = (c_x, c_y, w, h)$ ,  $(c_x, c_y)$  为标注框的中心坐标,  $w$  为宽,  $h$  为高,将标注框  $R$  建模为二维高斯函数  $N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  如式(3)所示:

$$\boldsymbol{\mu} = \begin{bmatrix} c_x \\ c_y \end{bmatrix}, \boldsymbol{\Sigma} = \begin{bmatrix} \frac{w^2}{4} & 0 \\ 0 & \frac{h^2}{4} \end{bmatrix} \quad (3)$$

下面继续归一化高斯 Wasserstein 距离。使用 Wasserstein 距离来计算标注框  $R_1 = (c_{x1}, c_{y1}, w_1, h_1), R_2 = (c_{x2}, c_{y2}, w_2, h_2)$  之间的高斯分布距离,如式(4)所示:

$$W_2^2(N_1, N_2) = \left\| \left( \begin{bmatrix} c_{x1}, c_{y1}, \frac{w_1}{2}, \frac{h_1}{2} \end{bmatrix}^T, \begin{bmatrix} c_{x2}, c_{y2}, \frac{w_2}{2}, \frac{h_2}{2} \end{bmatrix}^T \right) \right\|_2^2 \quad (4)$$

因  $W_2^2(N_1, N_2)$  是距离度量,故不能直接用来衡量标注框  $R_1$  和  $R_2$  之间的相似度,利用指数将 Wasserstein 距离归一化,获得新的度量 NWD,如式(5)所示:

$$NWD(N_a, N_b) = \exp\left(-\frac{\sqrt{W_2^2(N_a, N_b)}}{C}\right) \quad (5)$$

其中  $C$  为常数,大小由数据集决定。

相比原 YOLOv5 中的 IoU 度量方式,用 NWD 度量可以更加准确地评估绝缘子的小目标缺陷结果之间的相似性,加快网络训练收敛的速度,提高模型的精度和鲁棒性。

## 2 实验结果与分析

### 2.1 数据集的构建

本文原数据集 422 张,但原始数据集相对不足,故通过旋转、翻折的方式进一步扩充数据集,扩充后共计 1688 张数据集,数据集样本如图 8 所示。使用 LabImg 工具对图片进行标注,标签标注分为三类:正常绝缘子(Insulator)、破损绝缘子(Damaged)、闪络绝缘子(Flashover)。最后按 8:2 的比例将数据集划分为 Train 和 Val,其中 Train 有 1350 张,Val 有 338 张。




图 8 数据集样本

### 2.2 实验环境配置

本实验采用 Python 3.8.5 作为编程语言,使用 Pytorch 作为深度学习框架,GPU 为 NVIDIA GeForce RTX3060。相关实验参数如表 1 所示。

表 1 实验参数设置

参数名称	参数值
图片尺寸	640 像素×640 像素
批量处理大小	16
初始学习率	0.01
动量	0.937
训练轮数	120

### 2.3 评价指标

为了客观评价 MFBN-YOLOv5 算法的优越性,将使用全类平均精度均值(mAP0.5)、精确率  $P$ (Precision)、召回率  $R$ (Recall) 等指标来判别模型的性能。具体公式如下:

$$mAP = \frac{\sum_{i=0}^N AP_i}{N} \quad (6)$$

$$P = \frac{TP}{TP + FP} \times 100\% \quad (7)$$

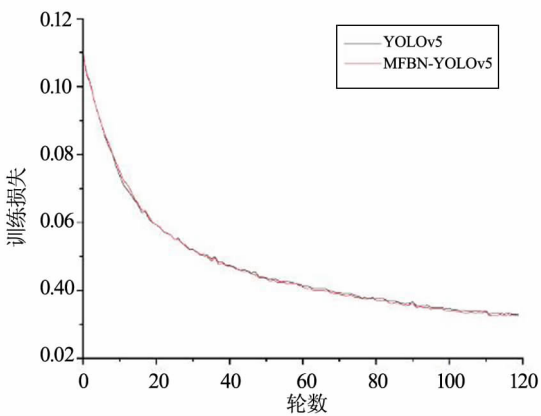
$$R = \frac{TP}{TP + FN} \times 100\% \quad (8)$$

式(6)、(7)中 TP 为预测正确的正样本个数, FN 为预测错误的负样本个数, FP 为预测错误的正样本个数。式(6)中 mAP 为所有对象的平均检测精度。


### 2.4 模型的训练

分别使用 MFBN-YOLOv5 和 YOLOv5 网络模型对绝缘子数据集进行训练,其模型训练损失前后对比如图 9 所示。可以看出 MFBN-YOLOv5

在训练集和验证集的损失函数收敛性都要优于原模型。



(a) 训练损失




(b) 验证损失

图 9 模型损失曲线对比


改进前后模型的评价指标对比如图 10 所示,随着训练次数的增多,精确率( $P$ )和召回率( $R$ )都呈现上升的趋势,且根据红、黑两曲线的对比走势,当训练次数到达 120 轮时,本文优化的模型要比原模型更好,最终本次优化模型的准确率( $P$ )和召回率( $R$ )分别达到了 95.1%、91.4%。mAP0.5 曲线也随着训练轮次的增加而上升,最终各类型的目标检测平均精度均值(mAP0.5)达到了 95.6%,比原模型高出 3.9%。上述所有评价指标证明了本文算法的优越性。

### 2.5 模型消融实验


为了进一步验证本文的 MFBN-YOLOv5 模型的性能,使用 MC3-YOLOv5、Fenhence-YOLOv5、BiFPN-YOLOv5 及 NWD-YOLOv5 进行对比消融实验。上述模型均是在 YOLOv5s 模型的基础上添加改进的模块,以准确率、召回率和 mAP0.5 为客观评价指标进行消融对比试验,实验结果如表 2 所示。



(a) 准确率曲线对比



(b) 召回率曲线对比



(c) 平均精度均值对比

图 10 评价指标对比

从表 2 结果可以看出,实验 1 的准确率较原模型提升了 2.9%,召回率下降了 0.9%,mAP0.5 提升了 2.5%,平均检测速度 FPS 下降了 1.01 帧/s;实验 2 的准确率较原模型提升了 2.5%,召回率提升了 1.4%,mAP 0.5 提升 3%,参数量上升了 0.29MiB,平均检测速度 FPS 下降了 1.72 帧/s;实验

3的准确率较原模型提升了2.4%，召回率上升了0.3%，mAP 0.5提升了2.8%，平均检测速度FPS下降了3.93帧/s；最后实验4(MFBN-YOLOv5)准确率为95.1%，较原模型提升了2.8%，召回率为91.4%，较原模型提升2.4%，mAP0.5为95.6%，较原模型提升3.9%，参数量较原模型增加了

1.32MiB，平均检测速度FPS下降了2.92帧/s，仍然满足日常电力巡检的需求。

综上所述，本文的MFBN-YOLOv5模型在绝缘子缺陷检测效果上远远优于YOLOv5模型，本次消融实验也证明了该方法对于绝缘子目标检测的有效性。

表2 模型对比消融实验

模型类型	MC3	Fenhence	BiFPN	NWD	准确率/ %	召回率/ %	mAP0.5/ %	参数量/ MiB	FPS/ (帧·s <sup>-1</sup> )
原模型					92.3	89	91.7	7.03	78.26
实验1	✓				95.2	88.1	94.2	7.13	77.25
实验2	✓	✓			94.8	90.4	94.7	7.32	76.54
实验3	✓	✓	✓		94.7	89.3	94.5	8.35	74.33
实验4	✓	✓	✓	✓	95.1	91.4	95.6	8.35	75.34

## 2.6 不同算法对比实验

为了更加全面地验证本文优化后模型的优越性，将本文算法MFBN-YOLOv5与YOLOv5、YOLOv4、YOLOv3及SSD等模型进行对比实验，性能对比如表3所示。

表3 不同算法的对比结果

模型	准确率/ %	召回率/ %	mAP0.5/ %	参数规模
YOLOv5	92.3	89	91.7	7.03
YOLOv4	90.2	87.6	89.7	12.31
YOLOv3	82.1	82.4	84.3	9.31
SSD	85.7	84.6	87.9	16.04
MFBN-YOLOv5	95.1	91.4	95.6	8.35

从表3中的数据可以看出，首先，本文算法MFBN-YOLOv5和原YOLOv5模型是检测绝缘子缺陷准确率最高的两个算法，分别达到了95.1%和92.3%，YOLOv3算法识别准确率和mAP0.5最低，仅为82.1%和84.3%。其次，本文算法在召回率方面的表现也是最好的，达到了91.4%。最后，本文在参数规模上仅次于YOLOv5和YOLOv3，但精度上的提升明显要高。综上分析，本文改进的网络在骨干网络中引入MC3和Fenhence模块，在颈部网络中替换原特征提取网络，最后引入NWD损失函数的方式，使得模型能够满足电力巡检的要求。图11左图为原YOLOv5算法检测的结果，右图为MFBN-YOLOv5算法检测的结果，从图中可以清晰看出，原算法和改进的算法都能进行绝缘子缺陷识别，但本算法的检测精度更高。可见本文的MFBN-YOLOv5算法在绝缘子缺陷检测任务中表现更胜一筹。




图11 绝缘子检测结果对比

## 3 结论

(1)针对绝缘子缺陷检测精度不足的问题，设计了MC3和Fenhence模块，将其部署到骨干网络中，提升了网络检测的精度。

(2)针对特征融合不足的问题，在颈部网络引入加权双向特征金字塔网络(BiFPN)，以一种加权融合的方式，提高网络对于多尺度特征的融合能力。

(3)针对原损失函数收敛慢的问题,将原IoU度量方式替换为NWD度量方式,提高网络收敛速度的同时,也增强了网络在复杂背景下对绝缘子缺陷特征的检测能力。实验结果表明,相较于YOLOv5,本文的MFBN-YOLOv5模型的准确率可以达到95.1%,平均精度均值(mAP0.5)达到95.6%,相较于原YOLOv5s模型准确率和平均精度均值(mAP0.5)分别提升了2.8%和3.9%。综上,本文提出的MFBN-YOLOv5模型可以快速、准确地识别航拍图像中绝缘子的缺陷问题,满足日常电力巡检的需求。

## 参考文献

- [1] PARK K C, MOTAI Y, YOON J R. Acoustic fault detection technique for high-power insulators[J]. IEEE Transactions on Industrial Electronics, 2017, 64(12): 9699-9708.
- [2] WANG J, LIANG X, GAO Y. Failure analysis of decay-like fracture of composite insulator[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2014, 21(6): 2503-2511.
- [3] HAN G, HE M, ZHAO F, et al. Insulator detection and damage identification based on improved lightweight YOLOv4 network[J]. Energy Reports, 2021, 7: 187-197.
- [4] JENSSEN R, ROVERSO D. Automatic autonomous vision-based power line inspection: A review of current status and the potential role of deep learning[J]. International Journal of Electrical Power & Energy Systems, 2018, 99: 107-120.
- [5] GIRSHICK R. Fast r-cnn[C]//Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [6] REN S, HE K, GIRSHICK R, et al. Faster r-cnn: towards real-time object detection with region proposal networks[J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(6): 1137-1149.
- [7] 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, 2016: 779-788.
- [8] LIU W, ANGUÉLOV D, ERHAN D, et al. Ssd: single shot multibox detector [C]//Computer Vision - ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, Proceedings, Part I 14. Springer International Publishing, 2016: 21-37.
- [9] 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(02):57-67.
- [10] YAO L, YAOYAO Q. Insulator detection based on GIOU-YOLOv3[C]//2020 Chinese Automation Congress (CAC). IEEE, 2020: 5066-5071.
- [11] 霍超,谷晓钢,黄玲琴,等.基于YOLO v4优化的航拍绝缘子缺陷图像检测模型[J].电子测量技术,2023,46(9):175-181.
- [12] 伍箴燎,吴正平,孙水发.基于改进YOLOv5算法的绝缘子多缺陷检测[J].高压电器,2024(12):95-102+112.
- [1] PARK K C, MOTAI Y, YOON J R. Acoustic fault detection technique for high-power insulators[J]. IEEE Transactions on Industrial Electronics, 2017, 64(12): 9699-9708.
- [2] WANG J, LIANG X, GAO Y. Failure analysis of decay-like fracture of composite insulator[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2014, 21(6): 2503-2511.
- [3] HAN G, HE M, ZHAO F, et al. Insulator detection and damage identification based on improved lightweight YOLOv4 network[J]. Energy Reports, 2021, 7: 187-197.
- [4] JENSSEN R, ROVERSO D. Automatic autonomous vision-based power line inspection: A review of current status and the potential role of deep learning[J]. International Journal of Electrical Power & Energy Systems, 2018, 99: 107-120.
- [5] GIRSHICK R. Fast r-cnn[C]//Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [6] REN S, HE K, GIRSHICK R, et al. Faster r-cnn: towards real-time object detection with region proposal networks[J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(6): 1137-1149.
- [7] 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, 2016: 779-788.
- [8] LIU W, ANGUÉLOV D, ERHAN D, et al. Ssd: single shot multibox detector [C]//Computer Vision - ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, Proceedings, Part I 14. Springer International Publishing, 2016: 21-37.
- [9] 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(02):57-67.
- [10] YAO L, YAOYAO Q. Insulator detection based on GIOU-YOLOv3[C]//2020 Chinese Automation Congress (CAC). IEEE, 2020: 5066-5071.
- [11] 霍超,谷晓钢,黄玲琴,等.基于YOLO v4优化的航拍绝缘子缺陷图像检测模型[J].电子测量技术,2023,46(9):175-181.
- [12] 伍箴燎,吴正平,孙水发.基于改进YOLOv5算法的绝缘子多缺陷检测[J].高压电器,2024(12):95-102+112.

## (上接第63页)

- [4] ZHOOU J, KOGE H, MAKI T. Automation of MBES noise reduction: an approach based on seafloor bathymetry features derived from manual editing procedures[J]. Ocean Engineering, 2024, 299: 117397.
- [5] LUONG T T, NGUYEN D A, NGUYEN H D. Reference the seabed topographic depth observations based on the national mean dynamic topography model [J]. MethodsX, 2024, 12: 102624.
- [6] 董聚兵,刘晓东.基于四阶累积量的测深侧扫声纳波达方向估计方法研究[J].仪器仪表学报,2022(8):235-244.
- [7] 张宏鸣,樊世豪,陈茹雪,等.基于数字高程模型的淤地坝地区河网提取方法[J].农业机械学报,2023,54(9):246-253.
- [8] SHI B, CAO T, GE Q. Sonar image intelligent processing in seabed pipeline detection: review and application [J]. Measurement Science and Technology, 2024, 35(4).
- [9] 金绍华,章宁,边刚.多波束与侧扫声纳图像的多尺度迭代自适应配准方法[J].测绘学报,2022,51(9):8.
- [10] HOLLAND W C, PINSON S. Erratum: sediment interval velocities from a monostatic multibeam sonar[J]. The Journal of the Acoustical Society of America, 2024, 155(1): 380.
- [11] 徐博阳,王方旗,丁继胜.侧扫声纳图像增益补偿判断模型建模方法研究[J].海洋测绘,2023,43(2):15-19.
- [12] 黄志豪,袁希平,甘淑.复杂条带状沟谷地形点云抽稀与内插算法对数字高程模型构建的精度影响[J].兰州大学学报(自然科学版),2023,59(4):460-467.
- [13] 刘宇晨,高永年.Sentinel时序影像的长江流域地表水体提取[J].遥感学报,2022(2):26.
- [14] 周毅阳,代文,王春,等.数字高程模型空间分辨率对精细尺度地形变化检测的影响[J].山地学报,2023,41(3):446-458.
- [15] 范承成,德晓薇,郭金家.基于三角位姿姿态矫正的激光线扫描海底地形三维测绘[J].光学精密工程,2022,30(10):11.