

DOI: 10.19650/j.cnki.cjsi.J2108173

基于模型压缩的 ED-YOLO 电力巡检 无人机避障目标检测算法*

彭继慎¹, 孙礼鑫¹, 王 凯², 宋立业¹

(1. 辽宁工程技术大学电气与控制工程学院 辽宁 125100; 2. 国家电网葫芦岛供电公司 辽宁 125000)

摘 要:针对现有卷积神经网络模型体积大、运算量高,导致电力巡检无人机检测速率与精度无法兼顾的问题,提出一种基于模型压缩的 ED-YOLO 网络实现无人机避障的目标检测算法。该目标检测算法以 YOLOv4 为基础,首先在主干网络中加入通道注意力机制,在不增加计算量前提下提高检测精度;其次在特征金字塔部分运用深度可分离卷积替换传统卷积,减少卷积计算量;最后利用模型压缩策略裁剪网络中冗余通道,减小模型体积并提高模型检测速度。在自主构建的 9 600 张电力巡检无人机飞行障碍的数据集进行测试,ED-YOLO 与 YOLOv4 相比,其障碍物目标检测的平均精度均值只降低了 1.4%,而模型体积减少了 94.9%,浮点运算量减少了 82.1%,预测速度提升了 2.3 倍。实验结果表明,对比多种其他现存方法,本文提出的基于模型压缩的 ED-YOLO 目标检测算法有着精度高、体积小和检测速度快的优势,满足电力巡检无人机避障检测要求。

关键词: 电力巡检无人机;目标检测;注意力机制;深度可分离卷积;模型压缩

中图分类号: TM755 TH39 **文献标识码:** A **国家标准学科分类代码:** 470.4051

ED-YOLO power inspection UAV obstacle avoidance target detection algorithm based on model compression

Peng Jishen¹, Sun Lixin¹, Wang Kai², Song Liye¹

(1. Faculty of Electrical and Control Engineering, Liaoning Technical University, Liaoning 125100, China;

2. Huludao Power Supply Company, State Grid, Liaoning 125000, China)

Abstract: Aiming at the problem that existing convolutional neural network models are large in size and high in computation, which results in not being able to consider both detection rate and accuracy of power inspection UAVs, an ED-YOLO network based on model compression is proposed to achieve the target detection algorithm for UAV obstacle avoidance. The target detection algorithm is based on YOLOv4, which firstly adds a channel attention mechanism to the backbone network to improve detection accuracy without increasing the amount of computation. Secondly, the depth separable convolution is used to replace the traditional convolution in the feature pyramid part to reduce the amount of convolutional computation. Finally, the model compression strategy is used to trim the redundant channels in the network to reduce the model size and improve the model detection speed. Tests were conducted on the dataset independently constructed with 9 600 flight obstacles of power inspection UAV, the obstacle target average detection accuracy for ED-YOLO is reduced only by 1.4% compared with that for YOLOv4, while the model size is reduced by 94.9%, the amount of floating point operations is reduced by 82.1% and the prediction speed is increased by 2.3 times. Experiment results show that compared with various other existing methods, the ED-YOLO target detection algorithm based on model compression proposed in this paper has the advantages of high accuracy, small size and fast detection speed, and meets the requirements of obstacle avoidance detection for power inspection UAVs.

Keywords: power inspection UAV; target detection; attention mechanism; depth separable convolution; model compression

收稿日期:2021-06-29 Received Date: 2021-06-29

* 基金项目:辽宁省教育厅科学技术研究创新团队项目(LT2019007)、辽宁省重点研发计划指导计划项目(2019JH8/10100050)、辽宁省高等学校(境)外培养项目(2019GJWZD002)、辽宁省教育厅科学技术研究服务地方项目(LJ2019FL003)资助

0 引 言

近年来,随着国家电力方面的发展,我国的电力线路越来越长,这对电路的巡检发起了很大的挑战。伴随着无人机(unmanned aerial vehicles, UAV)的异军突起,凭借其体积小、易部署和经济效益高等优势,在电力巡检中具有重要地位^[1]。自此能自主飞行的电力巡检无人机成为了当下发展的新潮流。但电力巡检无人机能自主飞行的最大的困难就是实现自主避障,伴随着深度学习的迅速发展,计算机视觉已经部署在各种应用场景,其中利用目标检测技术^[2-4]可以大幅提高感知能力,这使电力巡检无人机自主飞行成为可能。目前传统无人机避障普遍使用传感器用于障碍物检测,其类型主要有超声波、雷达、激光、红外线等。Meng 等^[5]利用超声波传感器进行检测异物实现了无人机的避障,超声波传感器虽然结构简单,成本低,但是检测目标单一并且容易受到外界环境的影响。2018 年西安电子科技大学的陈洪攀^[6]利用毫米波避障雷达结合单目视觉进行障碍物检测,雷达抗光干扰性强,具有较高的精度和良好的方向性,但经济效益低。现有传统无人机避障方法均存在一定的短板和不足,相比之下相机可以提供丰富的视觉信息,也可以提供低成本的高分辨率图像,本文使用该方法去弥补传统方法的不足,提高经济效益。2020 年杨娟娟等^[7]提出基于目标检测的智能避障系统,使用改进的 YOLOv3 进行目标检测并实现避障,该方法有着高障碍物检测精度与检测速度。随着图像处理和嵌入式设备计算能力的快速发展,搭配卷积神经网络后的摄像机已经成为感知现场环境的流行传感器^[8]。

文献[7]虽然实现避障,但网络模型较大限制了其实时检测。由于卷积神经网络参数量大而且模型深,例如 VGG-16 模型^[9]的规模已经超过 500 M,导致难以部署在无人机等移动设备中。基于移动设备的部署有助于边缘计算和实时检测,但是巨大的存储成本限制了神经网络模型在移动端的集成^[10]。因此,研究轻量级模型和模型压缩对于减轻模型权重和加快模型推理非常重要的意义^[11-12]。

目前,卷积神经网络的压缩方法与轻量化模型的发展日新月异。模型压缩的方法主要有知识蒸馏,低秩分解,量化和通道剪枝。Chen 等^[13]在卷积神经网络中引入知识蒸馏实现模型压缩,将大型网络模型蒸馏提取到小型简单模型上;Denton 等^[14]利用近似矩阵乘积来代替卷积神经网络的权值矩阵,将卷积神经网络进行低秩分解,从而降低参数减少运算。Liu 等^[15]提出通道剪枝算法,针对卷积层结构冗余结点进行剪枝,并

且保证卷积神经网络完整性的情况下有效减少参数量和计算量。针对轻量化模型,2017 年,Howard 等^[16]提出轻量化骨干网络 MobileNets,引入深度可分离卷积模块,减少了大量的卷积运算与浮点运算,但网络本身参数少,提取特征能力不足,且识别精度较低。后续在其基础上改进的 MobileNets V2^[17]和 MobileNets V3^[18]网络解决了识别精度问题并且得到大幅提升。模型轻量化的方法有很多,思想与模型压缩类似,均是利用不同方法对不重要的权重或卷积核进行处理,然后训练去恢复模型的精度。本文提出一种基于模型压缩的 ED-YOLO(efficient-depthwise YOLO)网络模型,该模型利用深度可分离卷积替换传统卷积,再加入通道注意力机制,最后采用通道剪枝去除一定数量的通道和层使模型参数更少,实现推理时间更短。

1 YOLOv4 目标检测算法

YOLOv4 网络^[19]由 Bochkovskiy 等在 2020 年提出,该网络在 YOLOv3 网络的基础上添加多种插件模块从而大幅提升性能,其网络结构图如图 1 所示。YOLOv4 在 YOLOv3 的基础上分别在输入端、特征提取骨干网络、特征融合颈部、检测头 4 个方面进行了优化,其各模块的主要优化功能如下:

1) 输入端:与传统 CNN 网络不同,YOLOv4 网络在训练时加入数据增强,生成对抗训练等进行图片预处理,从而丰富了目标数据集。

2) 特征提取骨干:YOLOv4 的特征提取网络(CSPDarkNet53),采用 CBM(由卷积、批归一化和 MISH 激活函数组成)模块和 CBL(由卷积、批归一化和 Leaky-ReLU 激活函数组成)进行特征提取。激活函数由 Leaky-ReLU 更换成 MISH,函数更加光滑检测精度更高。

3) 特征融合颈部:在特征提取骨干和最后的输出层之间加入空间金字塔池化模块(spatial pyramid pooling, SPP)与特征金字塔(feature pyramid networks, FPN)+路径聚合网络结构(path aggregation network, PAN)。SPP 空间金字塔池主要利用不同大小的池化核增加感受野从而将上下文特征进行明显区分。而为了实现更好的小目标识别效果在 YOLOv3 的 FPN 层基础上,自底向上添加了一个包含两个 PAN 结构的特征金字塔。该结构可以传达强语义特征,更好加强特征提取能力。

4) 检测头:在 YOLOv3 网络的基础上将原训练损失 DIOU_Loss 更换成 CIOU_Loss,采用 CIOU_Loss 后的预测速度回归速度与精度都得到提升。




图 1 YOLOv4 网络结构图

Fig. 1 The network structure diagram of YOLOv4

2 ED-YOLO 目标检测算法

2.1 添加通道注意力机制

由于无人机飞行时,背景经常会出现障碍物单一但是背景复杂的情况。通过加入注意力机制,可以解决环境带来的干扰从而提高检测精确率。目前大多数现有注意力机制虽然提高了精度但同时也增加了计算量。为了同时兼顾二者,本文引用高效通道注意模块 (efficient channel attention, ECA),该模块几乎不增加计算量,却能明显提升各方面性能。所以本文在每个 CSPX 的残差模块 (CSP_unit) 后添加一个 ECA 模块去计算特征图在通道位置上的权重信息,根据权重分配提高网络区分目标和背景的能力而几乎并不增加的计算开销。ECA 通道注意力机制模块不仅可以通过学习来获得每个特征通道的重要性,增强更有用的特征通道并抑制不重要的通道,同时通过执行该模块,重要信息可以从融合的特征中被过滤和增强,而无用的特征将被抑制^[20]。

ECA 模块在保持通道维度的前提下,对特征通道进行全局平均池化,执行一维卷积来产生通道权重。其中卷积核大小 (k) 可以自适应确定,即交互的覆盖范围 (即内核大小 k) 与通道维数成正比。所以,如果已知通道维数 C ,那么卷积核大小 (k) 可由式 (1) 计算得:

$$k = \Psi(C) = \left\lfloor \frac{\log(C)}{a} + \frac{b}{a} \right\rfloor_{\text{odd}} \quad (1)$$

其中, k 是通过信道维数 C 的映射自适应确定的; $\lfloor \cdot \rfloor_{\text{odd}}$ 表示最近的奇数; a 与 b 为线性函数系数,本文将 a 设置为 2, b 设置为 1。在 CSPX 模块中的 CSP_unit 后添加一个 ECA 模块如图 2 所示。




图 2 CSPX 的改进

Fig. 2 Improvement of CSPX

2.2 PANet 中引入深度可分离卷积

将 PANet 中的 CBL 块连续卷积“ $\times 5$ ”用深度可分离卷积代替,可以克服由于传统卷积带来的高额计算量而无法提高运行速度的问题,同时减少参数,降低模型体积。

深度可分离卷积 (depth separable convolution) 是 2017 年谷歌团队提出的轻量化网络 MobileNet 的核心,它由深度卷积 (depthwise convolution) 和点卷积 (pointwise convolution) 两部分组成,深度可分离卷积可以达到与传统卷积相同的效果。传统卷积:对于 7×7 像素,三通道 (大小为 $7 \times 7 \times 3$),经过通道数为 4 具有 3×3 卷积核的卷积层 (大小为 $3 \times 3 \times 3 \times 4$),输出结果为 4 个特征图。其卷

积层的参数数量为:

$$3 \times 3 \times 3 \times 4 = 108$$

深度可分离卷积中的第一部分是深度卷积。深度卷积是在一个二维平面上执行,卷积核的数量与上一层的通道数量相同。可以计算出卷积层的参数数量是:

$$3 \times 3 \times 3 = 27$$

因此,三通道图像在计算后生成三个特征图。另一部分是点卷积过程,它类似于传统的卷积。其卷积核的大小为 $1 \times 1 \times 3$, 3 是上层的通道数。因此,点卷积与上一步的深度卷积相结合,生成新的特征图。卷积核的数量与生成的特征图的数量相同为:

$$1 \times 1 \times 3 \times 4 = 12$$

综上,进行对比:传统卷积的参数个数为 108;深度可分离卷积的参数个数为 39。可以看出,深度可分离的卷积可以使用大约 1/3 的计算量来产生与传统卷积相同的效果。本文将利用深度可分离卷积来代替 CBL 块连续卷积“ $\times 5$ ”中的传统卷积,以减少计算量,提高模型识别速度。改进前后的卷积块模型如图 3 所示。




图3 连续 CBL 块改进

Fig. 3 Continuous CBL block improvement

YOLOv4 中 PANet 模块含有“CBL $\times 5$ ”单元,其中 5 次传统卷积的卷积核分别为 1×1 、 3×3 、 1×1 、 3×3 、 1×1 。本文将原“CBL $\times 5$ ”单元中的 5 个卷积核分别改为 3×3 (depthwise)、 1×1 (reduction)、 1×1 (expansion)、 3×3 (depthwise)、 1×1 (reduction),实现深度可分离卷积代替传统卷积。

2.3 损失函数

YOLOv4 进行预测时,会在不同尺度下分为 3 类网格,每个区域由其适应的网格大小进行检测。预测时每个网格产生 9 个候选框,预测框则由候选框对应形成,真

实框为人工标注的目标框。损失函数则由预测框和真实框差异决定,YOLOv4 检测模型训练中使用的损失函数主要包括定位损失 ($Loss_{Ciou}$)、置信度损失 ($Loss_{conf}$) 和分类损失 ($Loss_{class}$),总体损失如式(2)所示。

$$Loss = Loss_{Ciou} + Loss_{conf} + Loss_{class} \quad (2)$$

定位损失 ($Loss_{Ciou}$) 公式如下:

$$Loss_{Ciou} = 1 - IoU + \frac{d^2}{c^2} + \alpha V \quad (3)$$

$$\alpha = \frac{V}{(1 - IoU) + V} \quad (4)$$

$$V = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (5)$$

其中, IoU 表示预测框与真实框的相交和并集之比, c 和 d 分别表示两个边界框的中心之间的距离和对角距离。 w^{gt} 和 h^{gt} 是真实框的宽度和高度,而 w 和 h 表示预测框的宽度和高度, α 是一个正的权衡参数。置信度损失 ($Loss_{conf}$) 公式如下:

$$Loss_{conf} = \sum_{i=0}^{S^2} \sum_{j=0}^B K [-\log(p) + BCE(\hat{n}, n)] \quad (6)$$

$$BCE(\hat{n}, n) = -\hat{n} \log(n) - (1 - \hat{n}) \log(1 - n) \quad (7)$$

$$K = I_{i,j}^{obj} \quad (8)$$

其中, S 表示网格的数量, B 是每个网格对应的候选框个数。 K 表示权重, I 表示第 i 个网格第 j 个先验框含有目标的概率,如果概率存在其值为 1,0 否则为 0,1;而 n 与 $\hat{n}$ 则表示预测框和真实框的置信度, p 是预测对象的概率。分类损失 ($Loss_{class}$) 公式如下:

$$Loss_{class} = \sum_{i=0}^{S^2} I_{i,j}^{obj} \sum_{c \in D} [\hat{m} \log(m) + (1 - \hat{m}) \log(1 - m)] \quad (9)$$

其中, m 表示单元格中目标实际概率; $\hat{m}$ 表示预测概率。

2.4 模型压缩

由于目前卷积神经网络模型体积大,致使在许多实际应用中受到了高算力成本阻碍^[21]。利用模型压缩,可以在训练过程中将大型网络中冗余部分去除,把不重要的通道通过一些手段将其自动识别并修剪,从而得到具有高精度的微型和紧凑型模型。

1) 稀疏训练

稀疏训练的目的在于区分重要通道与非重要通道,为剪枝非重要通道进行准备。针对通道的重要性需要一个指标进行评判,由于批量归一化 (batch normalization, BN) 层具有信道级缩放与移动参数的作用,所以大多数卷积神经网络选择在卷积层后加入归一化处理通道数据,所以可以利用 BN 层中参数作为评判指标。

算法 1 稀疏训练阶段的批归一化算法流程^[22]

输入: 一个 batch: $B = \{x_1, x_2, x_3, \dots, x_{\text{batch_size}}\}$
 输出: $\{y_i = BN_{\gamma, \beta}(x_i)\}$

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad // \text{计算批处理均值}$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad // \text{计算批处理数据方差}$$

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \quad // \text{规范化}$$

$$y_i = \gamma \hat{x}_i + \beta \equiv BN_{\gamma, \beta}(x_i) \quad // \text{尺度变换和偏移}$$

BN 层的做法是先将一批图片进行归一化处理得到输入 x_i , 然后通过数据集训练输入 x_i 与输出 y_i 实现参数 γ 与 β 的更新。从“尺度变换和偏移”中可以得出 γ 参数直接影响输出 y_i , γ 数值越小该通道信息越不重要。因此, 将 γ 参数作为通道重要性的量化指标并将其称为通道的缩放因子。




图 4 通道剪枝策略

Fig. 4 Channel pruning strategy

在缩放因子 γ 进行升序排列后, 需要给定剪枝率进行剪枝, 剪枝率越高, 得到模型体积越小。但是当设定的修剪率过高时, 修剪后的精度会有大幅度的降低, 但这可以利用微调使修剪后的网络进行精度恢复。在模型压缩中的许多情况下, 经过微调的狭窄网络甚至可以获得比原始未修剪网络更高的准确性。

3 实验与分析

3.1 实验平台

实验的算法训练环境为 Ubuntu18.04.3 LTS 系统的服务器, 搭载 Intel® Xeon(R) Gold 6230 CPU@ 2.10 GHz×80, 256 GB RAM 和 4 块 8 GB 显存的 NVIDIA GeForce RTX2080Ti GDDR6 GPU, 项目代码基于 Pytorch 深度学习框架开发。

3.2 数据集构建

1) 数据集类型

由于无人机避障目标检测模型训练效果对数据集的

针对引进缩放因子 γ 的通道剪枝算法中的总损失函数如式 (10) 所示。

$$L = \sum_{(x,y)} l(f(x,W), y) + s \sum_{\gamma \in \Gamma} g(\gamma) \quad (10)$$

其中第一项为网络的训练损失, x 和 y 分别为训练的输入与输出, W 为网络中的训练参数; 第二项为 BN 层系 γ 数的 L1 正则约束项, $g(\gamma)$ 是对缩放因子的稀疏性引起的惩罚, 而 s 平衡了这两个项。本文在稀疏训练中选择了 $g(\gamma) = |\gamma|$, 该等式被广泛用于实现稀疏性, s 为本文实验时设置的惩罚因子。

2) 通道剪枝与微调

在通道级稀疏性引起的正则化条件下进行训练之后, 获得了一个其中许多缩放因子都接近于零模型, 模型如图 4 所示。然后, 将稀疏好的缩放因子 γ 进行升序排列, 缩放因子越接近 0 的通道越不重要, 将不重要的通道进行去除可以很好的降低网络模型体积, 所以将缩放因子接近 0 的通道的输入和输出连接以及相应的权重进行剪枝。

质量有着很高的要求, 并且为了保障无人机实时避障的准确性与数据集样本的多样性, 本文实验数据集采用电网巡线照片、人工飞行障碍物拍摄、百度图库以及 COCO 数据集这 4 种方式去获取无人机巡线避障数据集, 障碍物示例如图 5 所示。



图 5 原始数据

Fig. 5 Raw data

该数据集主要从电力巡检无人机工作环境的角度出发收集人(电网检修工作人员)、风筝(空中飞行的风筝)、建筑物(电线周围建筑物)、鸟类、树木、电线杆、电力高架桥和无人机(电力巡检)构的多样性数据集共 8 类,每一类 200 张,最后选出 1 600 张图片。

2) 数据集增强

由于原始数据集数量较少,为了进一步增加数据集的数量与多样性,本文采用增加高斯噪声、水平翻转、改变亮度、Mosaic 数据增强以及雾化 5 种方式随机组合对数据标注后的 1 600 幅图像进行数据增强。最终得到电力巡检无人机避障数据集共 9 600 幅,数据增强效果如图 6 所示。




图 6 数据增强

Fig. 6 Data enhancement

3.3 模型性能的评价指标

为了验证模型的性能,本研究采用预测精度(mAP)、浮点型运算量(BFLOPS)、模型参数量(parameters)模型体积(model volume)、预测时间(inference time)4 个指标进行评价。其中 mAP 的计算公式如式(11)所示。

$$mAP = \frac{\sum_{C=1}^C AP(C)}{C} \quad (11)$$

式中: C 是检测的类别数,本文使用了 $C=8$; mAP 是检测到障碍物时平均精度(AP)的平均值,该值越高,障碍物的检测结果就越好。AP 是以召回率(recall)为横轴,准确率(precision)为纵轴形成的 PR 曲线下的面积。 $precision, recall$ 的计算公式为:

$$precision = \frac{TP}{(TP + FP)} \times 100\% \quad (12)$$

$$recall = \frac{TP}{(TP + FN)} \times 100\% \quad (13)$$

其中, TP, FP, FN 的意义分别为真阳性、假阳性、假阴性数。预测时间是指单张图片预测时间。

3.4 验证模型改进有效性

表 1 中对比了 YOLOv4 (baseline)、添加注意力机制 ECA 模块网络模型 E-YOLOv4、PANet 中引入深度可分离卷积模块的 D-YOLOv4 以及二者都引入的 ED-YOLOv4。将 4 个模型对比的目的是为了验证改进有效性,本文网络输入图片尺寸均为 608×608 ,对比参数如表 1 所示。

表 1 改进模型参数对比

Table 1 Comparison of improved model parameters

模型名称	$mAP/\%$	BFLOPS	预测时间/ms	模型体积/MB
YOLOv4	92.45	121.3	45.1	245
E-YOLOv4	93.24	121.3	47.3	245
D-YOLOv4	92.90	92.7	38.5	227
ED-YOLOv4	93.42	105.1	41.8	238

从表 1 中可清晰的看出,增加注意力机制 ECA 模块的 E-YOLOv4 模型在浮点运算量和模型体积方面没有改变,但预测时间增加而 mAP 有了小幅度提升。引入深度可分离卷积模块的 D-YOLOv4,各参数均有明显提升。在将两者均引入后,运算量减少至传统 YOLOv4 模型的 86.64%,模型体积减小了 7 MB,速度在 RTX2080Ti 上提升了 3.3 ms,精度提升了 1.27%。

3.5 模型压缩实验

1) 稀疏化训练

实验设置不同的惩罚项 s ,通过过稀疏化训练过程中的损失 Loss 与稀疏化效果来选择惩罚因子。对稀疏训练设置惩罚因子 s 分别等于 0.0001、0.001、0.005、0.01,学习率与初始训练相同。图 7 和 8 分别为不同稀疏因子对应的稀疏训练 Loss 图与稀疏情况图。

对稀疏训练的模型的通道均进行 80% 剪枝率,比较剪枝后的 mAP 、模型参数量、推理时间和模型体积如表 2 所示。从图 7 和 8 中可以看出当 $s=0.005$ 时,在训练 100 个 epoch 后,训练损失 Loss 与稀疏化程度分别达到最低和最佳。虽然图 7 中显示 $s=0.0001$ 与 $s=0.001$ 的 Loss 值更低,但从表 2 得出这两者经过稀疏训练后剪枝会完全丢失精度。

秉持着低模型大小高剪枝率的前提将从 $s=0.005$ 和 $s=0.01$ 中选择。从图 8 中得出 $s=0.01$ 时稀疏效果最好,但剪枝后网络 mAP 值过低且微调后效果并不理想,故本文选取 0.005 作为最终通道稀疏化训练的惩罚因子。




图 7 稀疏训练 Loss 图

Fig. 7 Sparse training Loss graph




图 8 不同惩罚因子的稀疏情况

Fig. 8 The sparseness of different penalty factors

表 2 不同惩罚因子参数对比

Table 2 Parameter comparison of different penalty factors

s	$mAP/\%$	参数量/M	预测时间/ms	模型体积/MB
0.0001	0	4.522	40.1	245
0.001	0	4.03	37.3	176
0.005	63.9	3.31	34.5	128
0.01	22.7	2.82	31.8	82

2) 模型裁剪对比

在惩罚因子 $s=0.005$ 确定后,为了验证模型剪枝的有效性,本文对模型 ED-YOLOv4 进行比例为 0.5、0.6、0.7 以及 0.9 的剪枝。表 3 为不同剪枝率参数对比,通过参数表现比较来选择最好的剪枝比例。

剪枝后的模型命名为 ED-YOLO-剪枝率。进行剪枝时为稀疏模型裁剪 16 个 shortcut,并以不同的剪枝率修剪所获得的模型。将修剪的 3 个全局阈值设置为 50%、60%、70% 和 80%。

表 3 不同剪枝率参数对比

Table 3 Parameter comparison of different pruning rates

模型名称	$mAP/\%$	BFLOPS	预测时间/ms	模型体积/MB
YOLOv4	92.5	121.3	45.1	245
ED-YOLO-0.5	92.12	51.5	31.4	51.8
ED-YOLO-0.6	90.3	44.1	27.2	37.5
ED-YOLO-0.7	82.8	33.2	23.9	24.2
ED-YOLO-0.8	63.9	21.7	19.6	12.5

将不同剪枝率模型的参数进行比较。从表 3 中得出,4 种进行不同通道剪枝率的模型体积、推理时间和浮点型运算量都被降低了。同时,修剪后的 mAP 值分别为 92.12%、90.3%、82.8% 和 63.9%。经过微调后, mAP 被恢复到 93.04%、92.6%、91.8% 和 91.2%。由于微调后的平均精度差别不大,因此在模型的大小、参数的数量和推理时间上都有明显的差异。因此,选择 80% 的通道剪枝率可以使模型在较小的精度损失下获得更好的模型压缩效果。

在构建的无人机电力巡检障碍数据集的基础上,使用通道剪枝算法修剪冗余部分的 ED-YOLO 目标检测模型,实验结果表明,ED-YOLO-0.8 电力巡检无人机避障的目标检测模型的浮点运算量为 21.7,模型体积为 12.5 MB,障碍物检测的 mAP 为 91.2%,预测时间为 19.6 ms。

3.6 模型对比实验

表 4 中对比了 FasterR-CNN, Efficientdet-D0, YOLOv3, YOLOv4, ED-YOLOv4, ED-YOLO-0.8 分别从各个模型的 mAP 、BFLOPS、模型体积以及在 RTX2080Ti 预测时间进行对比。对比结果如表 4 所示。

表 4 不同模型参数对比

Table 4 Comparison of different model parameters

模型名称	$mAP/\%$	BFLOPS	预测时间/ms	模型体积/MB
YOLOv4	92.5	121.3	45.1	245
FasterR-CNN	94.4	531.2	186	1 034.2
Efficientdet-D0	88.2	52.6	55	11.9
YOLOv3	89.4	151.72	59	234
ED-YOLOv4	93.42	63.1	32	238
ED-YOLO-0.8	91.2	21.7	19.6	12.5

从表 4 中分析出 ED-YOLO-0.8 与其他 5 种模型相比,其 mAP 分别高于 2 种模型 (EfficientDet-D0 和 YOLOv3) 的 88.2% 和 89.4%;检测速度分别高于其他 5 种模型 (FasterR-CNN、EfficientDet-D0、YOLOv3、YOLOv4 和 ED-YOLOv4) 的 186、55、59、45.1 和 32 ms。

在浮点型运算量与模型体积方面,ED-YOLO-0.8 均比其他网络更加小。实验表明,ED-YOLO 在精度与其他模型接近的情况下,展现出了在模型体积、浮点运算量和预测时间等方面的优势。与 YOLOv4 相比其 mAP 只降低了 1.4%,但模型体积减少了 94.9%,预测速度提升了 2.3 倍。综合各个方面,证明该目标检测算法检测效果有效可行。ED-YOLO-0.8 的部分识别结果如图 9 所示。




图9 部分识别结果图

Fig.9 Partial identification result diagram

4 结 论

本文提出一种基于模型压缩的 ED-YOLO 电力巡检无人机避障的目标检测算法,实现在移动端的障碍物实时检测。算法在 CSP 残差模块中加入 ECA 注意力机制,在保证检测精度前提下增强通道中有用的信息,抑制不重要的信息。其次,引用深度可分离卷积模块替换 PANet 中多层卷积模块从而使得网络整体计算量下降。将整个网络运用通道剪枝策略进行模型压缩化,利用该方法显著提高网络检测速度,大大减小网络模型体积。结合上述改进,在自主构建的无人机障碍物数据集测试中与现有的 YOLOv3、YOLOv4、FasterRCNN、EfficientDet-D0 等网络对比结果表明,经过模型压缩后的 ED-YOLO 在模型体积、检测精度与速度方面均展现出了明显的优势,易部署在嵌入式设备端进行检测与计算,更适用于无人机电力巡检中的障碍物目标检测任务。

参考文献

- [1] 隋宇, 宁平凡, 牛萍娟, 等. 面向架空输电线路的挂载无人机电力巡检技术研究综述[J]. 电网技术, 2021, 45(9): 3636-3648.
- [2] 李晖晖, 周康鹏, 韩太初. 基于 CReLU 和 FPN 改进的 SSD 舰船目标检测[J]. 仪器仪表学报, 2020, 41(4): 183-190.
- [3] 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.
- [4] 刘芳, 韩笑. 基于多尺度深度学习的自适应航拍目标检测[J/OL]. 航空学报: 1-13 [2021-05-14]. <http://kns.cnki.net/kcms/detail/11.1929.V.20210301.1047.018.html>.
- [5] MENG G L, PAN H B. The application of ultrasonic sensor in the obstacle avoidance of quad-rotor UAV[C]. 2016 IEEE Chinese Guidance, Navigation and Control Conference (CGNCC). IEEE, 2016: 976-981.
- [6] 陈洪攀. 基于毫米波雷达与单目视觉融合的无人机自主避障系统[D]. 西安: 西安电子科技大学, 2018.
- [7] 杨娟娟, 高晓阳, 李红岭, 等. 基于机器视觉的无人机避障系统研究[J]. 中国农机化学报, 2020, 41(2): 155-160.
- [8] 张伟, 庄幸涛, 王雪力, 等. DS-YOLO: 一种部署在无人机终端上的小目标实时检测算法[J]. 南京邮电大学学报(自然科学版), 2021, 41(1): 86-98.
- [9] SUI Y, NING P F, NIU P J, et al. Overview of research on power inspection technology of mounted drones for overhead transmission lines [J]. Power Grid Technology, 2021, 45(9): 3636-3648.
- [10] LI H H, ZHOU K P, HAN T CH. Improved SSD ship target detection based on clelu and FPN [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 183-190.
- [11] CAO H Y, SHEN X L, LIU CH M, et al. Improved YOLOv3 infrared target detection algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(8): 188-194.
- [12] LIU F, HAN X. Adaptive aerial target detection based on multi-scale deep learning [J/OL]. Journal of Aeronautics: 1-13 [2021-05-14]. <http://kns.cnki.net/kcms/detail/11.1929.V.20210301.1047.018.html>.

- DS-YOLO: A real-time detection algorithm for small targets deployed on UAV terminals [J]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 2021, 41(1): 86-98.
- [9] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. ArXiv Preprint 2014, ArXiv:1409.1556.
- [10] HUANG L L, LI Q, HE X ZH, et al. Research on pruning algorithm of target detection model with YOLOv4 [C]. 2020 Chinese Automation Congress (CAC). IEEE, 2020: 3283-3287.
- [11] 黄靖淞, 左颢睿, 张建林. 轻量化目标检测算法研究及应用 [J/OL]. 计算机工程: 1-8 [2021-05-14]. <https://doi.org/10.19678/j.issn.1000-3428.0059168>. HUANG J S, ZUO H R, ZHANG J L. Research and application of lightweight target detection algorithm [J/OL]. Computer Engineering: 1-8 [2021-05-14]. <https://doi.org/10.19678/j.issn.1000-3428.0059168>.
- [12] 孔维刚, 李文婧, 王秋艳, 等. 基于改进 YOLOv4 算法的轻量化网络设计与实现 [J/OL]. 计算机工程: 1-10 [2021-05-14]. <https://doi.org/10.19678/j.issn.1000-3428.0060948>. KONG W G, LI W J, WANG Q Y, et al. Design and implementation of lightweight network based on improved YOLOv4 algorithm [J/OL]. Computer Engineering: 1-10 [2021-05-14]. <https://doi.org/10.19678/j.issn.1000-3428.0060948>.
- [13] CHEN G, CHOI W, YU X, et al. Learning efficient object detection models with knowledge distillation [C]. Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017: 742-751.
- [14] DENTON E, ZAREMBA W, BRUNA J, et al. Exploiting linear structure within convolutional networks for efficient evaluation [J]. ArXiv Preprint, 2014, ArXiv:1404.0736.
- [15] LIU Z, LI J, SHEN Z, et al. Learning efficient convolutional networks through network slimming [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2736-2744.
- [16] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [J]. ArXiv preprint, 2017, ArXiv: 1704.04861.
- [17] SANDLER M, HOWARD A, ZHU M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [18] HOWARD A, SANDLER M, CHU G, et al. Searching for mobilenetv3 [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019: 1314-1324.
- [19] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [J]. ArXiv Preprint, 2020, ArXiv: 2004.10934.
- [20] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2020.
- [21] 符惠桐, 王鹏, 李晓艳, 等. 面向移动目标识别的轻量化网络模型 [J]. 西安交通大学学报, 2021, 55(7): 124-131. FU H T, WANG P, LI X Y, et al. Lightweight network model for mobile target recognition [J]. Journal of Xi'an Jiaotong University, 2021, 55(7): 124-131.
- [22] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [C]. International Conference on Machine Learning. PMLR, 2015: 448-456.

作者简介



彭继慎, 1991 年于西安交通大学获得学士学位, 1998 年于辽宁工程技术大学获得硕士学位, 现为辽宁工程技术大学教授, 博士生导师, 主要研究方向为工业过程控制与优化等。

E-mail: pengjishen@163.com

Peng Jishen received a bachelor degree from Xi'an Jiaotong University in 1991 and a master degree from Liaoning Technical University in 1998. He is currently a professor and doctoral supervisor at Liaoning Technical University. His main research direction is industrial process control and optimization.



孙礼鑫(通信作者),2019 年于辽宁工程技术大学获得学士学位,现为辽宁工程技术大学硕士研究生,主要研究方向为机器视觉与深度学习。

E-mail:1125646980@qq. om

Sun Lixin (Corresponding author) received a bachelor degree from Liaoning Technical University in 2019 and is currently a master student at Liaoning Technical University. His main research direction is machine vision and deep learning.



王凯,2001 年于辽宁工程技术大学获得学士学位,2015 年于辽宁工程技术大学获得硕士学位,现为国家电网葫芦岛供电公司高级工程师,从事电力系统继电保护、智能电网理论与技术等研究工作。

E-mail:28935200@qq. com

Wang Kai received a bachelor degree in 2001 and master degree in 2015 both from Liaoning Technical University. He is

currently a senior engineer in Huludao Power Supply Company, State Grid and is engaged in the research work of power system relay protection and smart grid theory and technology.



宋立业,1994 年于阜新矿业学院获得学士学位,2001 年和 2018 年于西安交通大学和辽宁工程技术大学分别获得硕士学位和博士学位,现为辽宁工程技术大学副教授,硕士生导师,主要研究方向为智能电网新技术,电力系统数字化监控技术。

E-mail:372492761@qq. com

Song Liye received a bachelor degree from Fuxin Institute of Mining and Technology in 1994, master degree in 2001 from Xi'an Jiaotong University and doctorate degree in 2018 from Liaoning Technical University. He is currently an associate professor and master student supervisor in Liaoning Technical University, his main research direction includes smart grid new technology and power system digitized monitoring technology.