

DOI: 10.13382/j.jemi.B2407722

面向变电站嵌入式设备的指针式仪表识别方法*

胡欣¹ 刘瑞峰¹ 肖剑² 段承志² 程鸿亮² 罗诗伟³

(1. 长安大学能源与电气工程学院 西安 710064; 2. 长安大学电子与控制工程学院 西安 710064;

3. 中陕核工业集团陕西二一〇研究所有限公司 咸阳 712000)

摘要:针对变电站嵌入式设备在识别指针式仪表时常面临实时性差以及小目标和密集目标场景漏检的问题,提出了一种基于YOLOv5s-BCGS的变电站指针式仪表识别模型。该模型以YOLOv5s为基础网络,首先在其网络颈部引入协调注意力机制,并将路径聚合网络替换为加权双向特征金字塔网络,以更好地融合特征图中的位置和细节信息,从而增强模型对目标位置和尺寸的敏感性。其次,原网络中的传统卷积被轻量化的幽灵卷积替代,既加快了推理速度,又减小了模型体积。最后,将原网络中的CIoU损失函数替换为SIoU损失函数,提高了模型训练速度并改善了远距离小目标的推理精度。实验结果表明,改进后的模型在自制变电站指针仪表数据集上的表现优于YOLOv5s, mAP0.5提高了2.2%, mAP0.75提高了3.8%, mAP0.5~0.95提高了6.7%,同时模型体积减少了34.07%。与常用的Faster R-CNN、YOLOv4-tiny、YOLOv7-tiny和YOLOv8n等模型相比,本模型在精度和速度上均具有明显优势,展现了良好的泛化能力和鲁棒性,且模型体积仅为18.0 MB,实现了轻量化部署。在PC和Jetson Xavier NX开发板上的推理速度分别为154.7 FPS和18.7 FPS,能够满足嵌入式设备在变电站指针仪表巡检中的实际工程需求。

关键词: 变电站;指针式仪表识别;轻量化;协调注意力机制;嵌入式设备

中图分类号: TN98;TH865

文献标识码: A

国家标准学科分类代码: 470.40

Pointer meter identification method for embedded devices in substations

Hu Xin¹ Liu Ruifeng¹ Xiao Jian² Duan Chengzhi² Cheng Hongliang² Luo Shiwei³

(1. School of Energy and Electrical Engineering, Chang'an University, Xi'an 710064, China; 2. School

of Electronic and Control Engineering, Chang'an University, Xi'an 710064, China; 3. Shaanxi 210

Research Institute Co., Ltd of SINO Shaanxi Nuclear Industry Group, Xianyang 712000, China)

Abstract: Embedded devices in substations frequently encounter challenges related to real-time performance and detection accuracy, especially in scenarios involving small targets and densely arranged pointer instruments. This paper proposes an enhanced substation pointer instrument recognition model based on YOLOv5s-BCGS, which improves detection accuracy and efficiency. The model employs YOLOv5s as its backbone network, incorporating a coordinate attention mechanism at the neck to enhance spatial feature extraction. Additionally, the original path aggregation network is replaced with a weighted bidirectional feature pyramid network to better integrate positional and detailed information from the feature maps. This modification increases the model's sensitivity to target location and size, particularly in complex scenarios. To accelerate inference speed and reduce model size, we substitute traditional convolutions with lightweight Ghost Convolutions. Furthermore, the conventional Complete Intersection over Union loss function is replaced by the SCYLLA-Intersection over Union loss function, which improves both the training speed and the inference accuracy for small targets at greater distances. Experimental results show that the proposed model outperforms YOLOv5s on a custom-built substation pointer instrument dataset, with mAP0.5 increasing by 2.2%, mAP0.75 improving by 3.8%, and mAP0.5~0.95 rising by 6.7%.

收稿日期: 2024-07-28 Received Date: 2024-07-28

* 基金项目: 陕西省秦创原“科学家+工程师”队伍建设项目(2024QCY-KXJ-161)、西安市重点产业链项目(23ZDCYJSGG0013-2023)、咸阳市重点研发计划(L2024-ZDYF-ZDYF-GY-0004)项目资助

Additionally, the model size is reduced by 34.07%. When compared to other widely used models such as Faster R-CNN, YOLOv4-tiny, YOLOv7-tiny, and YOLOv8n, our model shows significant improvements in both accuracy and speed. The model, with a size of only 18.0 MB, demonstrates strong generalization and robustness, making it well-suited for lightweight deployment. Inference speeds on a PC and the Jetson Xavier NX development board reach 154.7 FPS and 18.7 FPS, respectively, meeting the performance requirements for embedded devices used in substation pointer instrument inspections.

Keywords: substation; pointer instrument recognition; lightweight; coordinate attention mechanism; embedded devices

0 引言

面对新型电力系统数字化智能化转型升级的发展需求,人工智能及数字孪生技术在电网中的应用可以辅助决策和调控,推动电网的数字呈现、智慧运维,提升电力系统多能互补联合调度智能化水平,推进基于数据驱动的电网暂态稳定智能评估与预警,提高电网仿真分析能力,支撑电网安全稳定运行。变电站^[1]作为电网构成中的核心组成部分,扮演着电力行业发展中的关键角色。变电站的智慧运维是新型电力系统转型的关键一步,目前指针式仪表因其结构简单、防寒防水性能卓越以及强大的抗干扰能力等优点,在变电站基础设施中仍然占据着显著的地位。监测变电站内各仪表设备的运行状态^[2]已成为日常变电运维不可或缺的重要组成部分,其在确保变电站安全稳定运行方面具备突出的意义。数字化智能化是电网可以高质量发展的重要保障,对变电站内存在的多种类型仪表的检测,以便后续进行自动读数来实时监测设备状态,对于变电站设备的状态感知和实现变电站智慧巡检有重要意义。

传统识别方法通常依靠操作员去对指针式仪表进行实时监测,同时进行手动记录。人工巡检不仅过程耗时长,还容易造成人为差错,在巡检过程中还具有安全隐患,不能做到自动化和信息化。随着计算机视觉的发展,基于深度学习的目标识别算法迅速发展,如 Single-Shot Detector (SSD)、Region-Convolutional Neural Networks(R-CNN)^[3]及 You Only Look Once(YOLO)等,并在各个领域取得了优异的检测效果。尤其是 YOLO 系列算法^[4-7],因其高速度和较高准确率在指针式仪表目标检测中得到广泛应用。黄杨乐天等^[8]提出了一种指针仪表识别系统,针对仪表区域的识别与定位问题,对 Faster R-CNN 模型进行了池化策略的优化,并采用了更深层的 Residual Neural Network 152(ResNet152)残差网络。经过改进后,模型的识别精度得到了显著提升。赵辉等^[9]提出了一种基于 YOLOv3 的变电站指针式仪表识别算法。引入了 Res2Net 残差模块,采用特征层融合的方法,利用更少的模块和网络层数来获取更高的特征提取效率,增加空间池化金字塔(spatial pyramid pooling, SPP)模块融合多重感受野,使用 Generalized Intersection over Union(GIoU)损失函数代替了原网络的损失函数,提高

了识别精度和速度。金爱萍等^[10]提出了一种结合 YOLOv5 与生物医学图像分割的卷积网络(convolutional networks for biomedical image segmentation, U-net)的仪表读数识别方法。该方法通过使用 YOLOv5 算法对仪表区域进行检测与提取,有效解决了不同背景和距离条件下指针式仪表识别精度较低的问题。陶金等^[11]设计了一种基于深度学习的指针式仪表检测方法,结合 YOLOv4-tiny 网络与残差模块,提升了模型的鲁棒性。该方法不仅降低了电力巡检机器人在识别变电站指针式仪表时的误检率,还提高了仪表读数的识别精度。何敏等^[12]提出了一种基于轻量级 YOLOX 网络的电力仪表图像识别方法。使用深度可分离卷积和参数重组的多尺度特征融合结构来压缩模型大小,在特征融合层中嵌入三维注意力机制无参数注意力机制(a simple, parameter-free attention module, SimAM),设计基于金字塔池化特征编码的 Transformer 结构,提高对不同外形电力仪表的识别精度,加快了模型的推理速度。骆东松等^[13]提出了一种 YOLOv5s-Pointer 网络模型,将 Mixup 数据增强加入 YOLOv5s 网络头部,引入 MobileNetV3 替换原有的 CSPDarkNet53 网络,使用更有利的损失函数 SCYLLA-Intersection over Union(SIoU)替换 Complete Intersection over Union(CIoU),并通过引入动态样本加权思想,降低原有网络的参数量,提升了识别速率。以上方法对距离较远的小仪表、密集仪表识别效果差,同时这些方法计算量仍然较大,识别过程耗时较长,容易受到变电站复杂环境干扰,鲁棒性较差。同时不适合部署在嵌入式设备中,难以适应于实际巡检工作中。

基于 YOLOv5s 模型,旨在应对变电站复杂背景下的挑战,拟对轻量级、高精度仪表目标识别模型进行研究,贡献可以分为以下 4 个方面:

1) 使用工业相机对变电站内以及实验室内 16 种指针式仪表进行远距离拍摄。为了增加数据集的多样性和检测模型的泛化能力,选择在不同的光照条件和角度下拍摄仪表的图像。使用 Labelimg 工具对采集的图像数据进行标注,通过数据增强方法,对图像数据进行处理,构建了一个数据量较为充足、能够全面展现变电站内指针式仪表的数据集。

2) 将协调注意力(coordinate attention, CA)机制引入 YOLOv5s 网络中,增强模型对目标位置和尺寸的敏感性,提高模型对小目标和密集目标场景的识别精度。其次将

加权双向特征金字塔网络 (bidirectional feature pyramid network, BiFPN) 替换原始网络中的路径聚合网络 (path aggregation network, PANet), 融合待识别特征图中更多位置、细节信息, 增强模型对小目标所在区域的关注。

3) 将 SIoU 损失函数替换原始网络中的 CIoU 损失函数, 显著提高了模型训练的速度并增强了对远距离小目标的推理准确性。

4) 最后将轻量化的幽灵卷积 (Ghost) 模块替换传统的卷积模块, 在保持性能的同时显著降低网络参数量, 加快网络推理速度, 适合模型部署资源有限的嵌入式系统。

1 准备工作

仪表图像主要采集于变电站内避雷器、油温表、气压表等 10 类, 指针式仪表、实验室内电压表、电流表等 6 类指针式仪表, 共计 16 类, 如图 1 所示。根据仪表表盘形状以及表盘内象限分布情况将 16 种仪表分为 3 个大类, 分别为圆形仪表 (circular meter)、矩形仪表 (rectangle meter) 和不规则仪表 (irregular meter)。



(a) 矩形仪表
(a) Rectangle meter



(b) 圆形仪表
(b) Circular meter



(c) 不规则仪表
(c) Irregular meter

图 1 部分仪表图像

Fig. 1 Partial instrument panel imagery

考虑到变电站内仪表附近铺设了大量碎石或鹅卵石, 智能巡检往往无法对仪表进行近距离拍摄。数据集中图像拍摄位置位于巡检路径上, 使用工业相机对指针仪表进行远距离拍摄。由于变电站环境的复杂性, 指针仪表往往与背景相似, 特征不明显。为了增加数据集的多样性和检测模型的泛化能力, 选择在不同的光照条件和角度下拍摄指针仪表的图像。

使用工业相机拍摄 16 类指针式仪表图像, 共采集得到 1 385 张图像, 分辨率均为 $4\,000 \times 5\,000$ 。使用 Labeling 工具对采集的图像数据进行标注, 通过数据增强方法, 对图像数据进行翻转、旋转、比例缩放、裁剪、添加噪声等, 将数据集扩充至 6 500 张。将数据集按照 8 : 1 : 1 划分, 其中训练集 5 200 张, 验证集与测试集均为 650 张。

2 指针仪表检测模型设计

由于 YOLOv5s 模型参数量大, 部署在嵌入式设备当中推理速度较慢^[14], 无法满足智能巡检的实时性需求, 所以需要 YOLOv5s 模型的网络结构进行改进, 降低模型的参数量, 加快模型的推理速度, 同时提高目标的识别精度。

2.1 网络模型结构设计

改进后 YOLOv5s 模型命名为 YOLOv5s-BCGS, 如图 2 所示, 该网络结构主要由 Backbone、Neck、Head 三部分组成。Backbone 是模型的主干特征提取网络, 对输入的指针仪表图像进行特征提取, 获得 3 个有效特征层进行下一步网络的构建。Neck 是模型的加强特征提取网络, 通过上采样与下采样将 3 个有效特征层中不同尺度的特征信息进行特征融合。Head 是模型的分类器与回归器, 对 3 个加强过的有效特征层上的特征点进行判断, 得到预测结果。

YOLOv5s-BCGS 相较于未改进的 YOLOv5s 主要差别在于使用了轻量化的 C3Ghost 模块替代了主干特征提取网络中的 C3 模块, 压缩模型参数量, 降低计算成本, 提高模型的推理速度; 在加强特征提取网络融入 CA 注意力机制, 提高模型对目标尤其是小目标的识别精度; 将加强特征提取网络原先的 PANet 替换为加权双向特征金字塔网络 BiFPN, 通过带权重的特征融合机制可以加强对检测贡献大的特征层的比重, 提高检测的性能; 使用 SIoU 作为模型的损失函数, 使得模型能够更快地更准确地收敛。

2.2 C3Ghost 模块

传统的深度学习模型在保持准确性的同时, 常常需要庞大的参数和高昂的计算开销, 难以在资源受限的环

境中高效运行。GhostNet^[15]的引入为这一问题提供了一种切实可行的策略。Ghost Module 是 GhostNet 的核心,功能是代替普通卷积,用更低的计算成本去获取相似的特征层。Ghost Module 模块分为常规卷积、Ghost 生成和特征图拼接 3 步。

首先利用 1×1 卷积获得本征特征图,计算方式为:

$$Y' = X \times f' \quad (1)$$

其中, $X \in R^{h \times w \times c}$ 表示输入特征图, h, w 分别表示输入特征图的高和宽, c 表示通道数, $f' \in R^{m \times k \times k \times c}$ 表示 m 个 c 通道大小为 $k \times k$ 的卷积核, $Y' \in R^{m \times h' \times w'}$ 表示经过卷积运算后得到的通道数为 m , 高宽为 w', h' 的输出特征图。

然后利用深度可分离卷积获得本征特征图的相似特征图 Ghost 特征图, 计算方式为:




图 2 YOLOv5s-BCGS 网络结构

Fig. 2 YOLOv5s-BCGS network architecture

$$y_{ij} = \Phi_{i,j}(y'_i) \quad \forall i = 1, \dots, m, j = 1, \dots, s \quad (2)$$

其中, y'_i 表示 $Y' \in R^{m \times h' \times w'}$ 第 i 个通道特征图, $\Phi_{i,j}$ 表示对 y'_i 进行第 j 个线性运算, 得到第 j 个 Ghost 特征图 y_{ij} 。

最后将第 1 步得到的本征特征图和第 2 步得到的 Ghost 特征图拼接 (identity 连接) 得到 $m \times s$ 通道的输出结果。将瓶颈中的正常卷积替换为两个堆叠的 Ghost 模块, 以获得 Ghost Bottleneck。将原本 C3 模块中原始瓶颈替换为 Ghost Bottleneck 堆栈以获得 C3Ghost 模块。

如图 3 所示, 改进后的 Ghost Bottleneck 模块通过两个 GhostConv 层进行通道数的减半和恢复, 然后将其与

经过 3×3 深度卷积的残差边相加以融合特征。这种改造后的 Ghost Bottleneck 模块取代了原有的 Bottleneck 模块, 形成了 C3Ghost 模块。这一改变减少了原有结构中大部分的 3×3 传统卷积操作, 从而使模型拥有更低的参数和计算量, 进一步提高了推理速度。




图 3 C3Ghost 模块

Fig. 3 C3Ghost module

2.3 协调注意力机制

在深度学习领域, 注意力机制作为一种重要的技术手段, 近年来受到了广泛的关注和应用。注意力机制^[16]通过赋予模型在处理数据时的“注意力”, 使其能够自动地关注和强化重要信息, 从而在各种任务中取得显著的性能提升。

CA 注意力机制^[17]基于对特征图坐标的建模, 它通过将坐标信息作为注意力的一部分来引导特征图的学习。这种注意力机制能够有效地在不引入额外计算复杂度的情况下, 提升模型的性能。CA 注意力机制与其他常用的注意力机制如压缩和激励网络^[18] (squeeze-and-excitation networks, SEnet)、卷积块的注意力模块^[19] (convolutional block attention module, CBAM) 相比, 更加轻量级且具有更好的适应性, 尤其在处理大尺寸特征图时表现更为出色。如图 4 为 CA 注意力机制的实现过程。




图 4 CA 注意力机制模块

Fig. 4 CA mechanism module

为了获取图像宽度和高度上的注意力并对精确位置信息进行编码,CA 首先将输入特征图分为宽度和高度两个方向分别进行全局平均池化,得到宽度和高度方向的特征图,如式(3)和(4)所示。

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, j) \quad (3)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (4)$$

将获得全局感受野的宽度和高度两个方向的特征图合并,并送入共享的 1×1 卷积核模块,将维度减少至原来的 C/r 。然后,将经过批量归一化处理的特征图 F_1 输入 *Sigmoid* 激活函数,得到形如 $1 \times (W + H) \times C/r$ 的特征图 f ,如式(5)所示。

$$f = \delta(F_1([z^h, z^w])) \quad (5)$$

将特征图 f 分别按照原高度和宽度进行 1×1 卷积,得到通道数与原特征图一致的 F_h 和 F_w 。经过 *Sigmoid* 激活函数后,分别获得高度方向的注意力权重 g^h 和宽度方向的注意力权重 g^w ,如式(6)和(7)所示。

$$g^h = \sigma(F_h(f^h)) \quad (6)$$

$$g^w = \sigma(F_w(f^w)) \quad (7)$$

经过上述计算,将获得输入特征图在高度方向的注意力权重 g^h 和在宽度方向的注意力权重 g^w 。最终,通过在原始特征图上进行乘法加权计算,得到在宽度和高度方向上带有注意力权重的最终特征图,得到式(8)。

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (8)$$

2.4 加权双向特征金字塔网络

加权双向特征金字塔网络由 Google Brain 团队在 2020 年提出,实现在 EfficientDet^[20] (scalable and efficient object detection) 中进行多尺度特征融合。

BiFPN 的结构如图 5 所示,与传统特征金字塔^[21] (feature pyramid network, FPN) 不同, BiFPN 在特征金字塔相邻级别之间引入了双向连接,信息可以在不同层级的特征之间双向流动:既可以从高层级特征向低层级特征传递(自顶向下的路径),也可以从低层级特征向高层级特征传递(自底向上的路径)。

BiFPN^[22] 在同一尺度的输入节点到输出节点之间加一个跳跃连接,由于输入输出处于相同层,可以在不增加太多计算成本的同时,融合更多的特征。

考虑到不同分辨率的特征图对融合输入的特征图的贡献不同, BiFPN 采用一种简单而高效的加权特征融合的方法,方法如式(9)所示。

$$O = \sum_i \frac{\omega_i}{\epsilon + \sum_j \omega_j} \cdot I_i \quad (9)$$

其中, I_i 是输入特征层, ω_i, ω_j 是可学习的权重, ϵ 是学习率,设置为小值,避免数值不稳定, O 为输出的特征




图5 BiFPN 结构图

Fig. 5 BiFPN structural diagram

融合结果。

这种方法可以将所有权重都被归一化为一个值范围为 0~1 的概率,表示每个输入的重要性,训练稳定而且训练速度快。以 P5 层的输出为例,特征层的加权特征融合计算如式(10)和(11)所示。

$$P_5^{td} = \text{Conv} \left(\frac{\omega_1 \cdot P_5^{in} + \omega_2 \cdot \text{Resize}(P_6^{td})}{\omega_1 + \omega_2 + \epsilon} \right) \quad (10)$$

$$P_5^{out} = \text{Conv} \left(\frac{\omega_1' \cdot P_5^{in} + \omega_2' \cdot P_5^{td} + \omega_3' \cdot \text{Resize}(P_4^{out})}{\omega_1' + \omega_2' + \omega_3' + \epsilon} \right) \quad (11)$$

其中, P_5^{td} 是自顶向下路径中第 5 层的中间特征, P_5^{out} 是自底向上路径中第 5 层的输出特性, *Resize* 是常规的上采样或下采样操作,将不同分辨率的特征层规整为同一分辨率方便特征融合, ω 是学习中不断更新的参数,用于区分特征融合过程中不同特征的重要程度。

2.5 SIoU 损失函数

目标检测的有效性是计算机视觉任务中的一个核心问题,极大地依赖于损失函数能够准确预测期望结果。传统的目标检测损失函数例如 *GIoU*^[23]、*CIoU*^[24] 等通常与预测框和真实框的距离、重叠区域和长宽比相关,没有考虑预测框与真实框在方向上的不匹配。

SIoU 提出了一种新的损失函数,重新定义了惩罚度量,考虑了期望回归之间的向量夹角。SIoU 损失函数由 4 个损失函数构成^[25]: *Angle cost*、*Distance cost*、*Shape cost*、*IoU cost*。

假设 B 是真实框, B^{GT} 是预测框, σ 是 B 与 B^{GT} 中心点间的直线距离, C_w 和 C_h 分别是中心点水平和竖直方向上的距离,如图 6 所示为损失函数检测示意图。

Angle cost 的损失函数公式为:

$$\Lambda = 1 - 2 \times \sin^2 \left(\arcsin(x) - \frac{\pi}{4} \right) \quad (12)$$




图 6 损失函数检测示意图

Fig. 6 Loss function detection schematic diagram

其中, $x = \frac{C_h}{\sigma} = \sin(\alpha)$, 当 $\alpha < \frac{\pi}{4}$ 时, 检测框向水平方向回归, 当 $\alpha > \frac{\pi}{4}$, 检测框向竖直方向回归。

Distance cost 的损失函数公式为:

$$\Delta = \sum_{l=x,y} (1 - e^{-\rho_l}) \tag{13}$$

其中, $\rho_x = \left(\frac{b_{C_x}^{gt} - b_{C_x}}{C_w} \right)^2, \rho_y = \left(\frac{b_{C_y}^{gt} - b_{C_y}}{C_h} \right)^2, \gamma = 2 -$

A 。当 $\alpha \rightarrow \frac{\pi}{4}$ 时, $\gamma \rightarrow 1$, 角度损失增大, 当 $\alpha = 0$ 时, $\gamma = 2$, 退化为距离损失。

Shape cost 的损失函数公式为:

$$\Omega = \sum_{l=w,h} (1 - e^{-\omega_l})^\theta \tag{14}$$

其中, $\omega_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})}, \omega_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})}$ 。

IoU cost 的损失函数公式为:

$$IoU = \frac{|B \cap B^{GT}|}{|B \cup B^{GT}|} \tag{15}$$

综合以上 4 个部分可以得到 SIoU 的损失函数为:

$$L = 1 - IoU + \frac{\Delta + \Omega}{2} \tag{16}$$

3 实验与结果分析

3.1 实验环境

所有模型的训练均在实验室的 PC 上完成, PC 的硬件配置为 CPU: Intel Core i7-9700K、GPU: NVIDIA RTX 3050(6 G), 将训练好的模型分别部署在 PC 和 Jetson xavier nx 开发板上进行测试。

3.2 网络训练参数

单次训练共 300 轮次, Batch-size 为 16, 图像的输入大小为 640×640 , 最大学习率为 0.01, 最小学习率为 0.000 1, 学习率下降方式为 cos(余弦退火), 使用 SGD 优化器, 使用 YOLOv5s 模型为预训练的模型。

3.3 识别结果


使用本研究设计的检测模型 YOLOv5s-BCGS 对测试集中的 650 张图片进行检测, 部分检测结果如图 7 所示。



(a) 一般情况下仪表检测
(a) Meter detection in general



(b) 小型仪表检测
(b) Small meter detection



(c) 密集仪表检测
(c) Intensive meter detection

图 7 部分仪表检测结果

Fig. 7 Partial meter detection results

从图 7(a) 可以看出,改进后的 YOLOv5s-BCGS 检测算法在复杂环境下表现出良好的鲁棒性,即便在阳光反射、阴影遮挡等不利条件下,该模型仍能准确检测到仪表。此外,如图 7(b)、(c) 所示针对多类型仪表、密集排列的仪表以及远距离的小型仪表,YOLOv5s-BCGS 模型均能精确识别,证明其在复杂场景中的强大适应能力。

3.4 模型有效性分析

全类平均精度 (mean average precision, mAP) 是一种用于评估目标检测模型性能的指标,它考虑了模型在不同 IoU 阈值下的精度。mAP0.5、mAP0.75 分别表示在 IoU 阈值为 0.5、0.75 时的平均精度,mAP0.5~0.95 表示在 IoU 阈值从 0.5~0.95 的范围内的平均精度。采用 mAP0.5、mAP0.75、mAP0.5~0.95 作为模型检测精度的评价指标,分别对应采用 mAP0.5、mAP0.75、mAP0.5~0.95 作为模型检测精度的评价指标,分别对应相对较宽松的匹配条件下的性能、比较严格的匹配条件下的性能、不同匹配要求下的整体性能。考虑到模型需要部署到嵌入式设备,需要对模型的推理运行速度进行评估分析。模型的体积表示模型的大小,较小的体积能够在资源受限环境中的部署效率。Frames Per Second (FPS) 是模型每秒处理的帧数,FPS1 与 FPS2 分别表示模型在 PC

和 Jetson xavier nx 开发板运行时每秒的处理帧数。在相同的数据集,相同的初始模型下,对改进的模块进行消融实验。消融实验的结果如表 1 所示,在主干特征提取网络输出的 3 个有效特征层加入 CA 注意力机制,mAP0.5 提升 0.1%,mAP0.75 提升 1.7%,mAP0.5~0.95 提升 6.4%,模型 2 在检测指标 mAP0.5~0.95 提升尤为明显,说明 CA 注意力机制通过获得特征图在不同位置上的注意力权重,使得模型能够更加关注目标的位置信息,从而提升了模型的精度。将主干特征提取网络中的 C3 模块换为 C3Ghost 模块,模型 3 体积减少 9.5 MB,每秒检测帧数 FPS1、FPS2 分别提升 56.1、7.2,说明采用 C3Ghost 替换掉 C3 模块,能够减少生成冗余的特征图,从而加速。将加强特征提取网络替换为 BiFPN,mAP0.5 降低 0.1%,mAP0.75 提升 3.3%,mAP0.5~0.95 提升 5.9%,模型 4 在较为严格的匹配条件下平均检测精度 mAP0.75 取得了优异的提升,说明加权双向特征金字塔网络 BiFPN 很好地将浅层网络的位置信息保留并与高层次的语义信息融合。加入 SIoU 损失函数,mAP0.5 提升 1.8%,mAP0.75 提升 2.5%,mAP0.5~0.95 降低 0.4%,模型 5 在 mAP0.5 指标上是 4 个改进模型中的最佳,在相对较宽松的匹配条件下具有优异的性能,说明加入 SIoU 损失函数使得模型能够更快更准确的收敛。

表 1 消融实验结果
Table 1 Ablation experiment results

网络模型	CA	Ghost	BiFPN	SIoU	mAP0.5	mAP0.75	mAP0.5~0.95	模型体积/MB	FPS1	FPS2
模型 1					97.0	88.5	54.7	27.3	92.7	11.1
模型 2	✓				97.1	90.2	61.1	27.6	90.4	10.9
模型 3		✓			97.2	87.3	54.1	17.8	148.8	18.3
模型 4			✓		96.9	91.8	60.6	27.3	84.2	10.2
模型 5				✓	98.8	91.0	54.3	27.3	100.3	14.5
模型 6	✓	✓	✓	✓	99.2	92.3	61.4	18.0	154.7	18.7

模型 2~5 的各项检测指标表明加入不同的模块对仪表检测模型均有一定的效果,同时加入 4 个模块可以使模型的检测精度和速度方面都得到提升。其中 mAP0.5 提升 2.2%,mAP0.75 提升 3.8%,mAP0.5~0.95 提升 6.7%,模型体积减小了 9.3 MB,每秒检测帧数 FPS1、FPS2 分别提升了 62、7.6。除了模型体积略逊于模型 3,YOLOv5s-BCGS 在不同匹配条件下的检测性能和检测速度均为改进模型中的最佳。改进后的 YOLOv5s-BCGS 模型与 YOLOv5s 模型的检测结果如图 8 所示。在密集目标检测方面,YOLOv5s 模型在第 1 幅和第 2 幅图像中均出现漏检现象,而改进后的 YOLOv5s-BCGS 模型能够准确识别所有目标。在检测远距离小目标时,第 3 幅图像的结果表明,YOLOv5s-BCGS 模型在小目标的识别精度上优于 YOLOv5s 模型。

3.5 综合性能分析

为了验证改进 YOLOv5s-BCGS 算法的优势,使用相同的数据集在不同的目标检测模型中训练,选择常用的检测模型 Faster R-CNN、YOLO^[26] 系列的 YOLOv4-tiny^[27]、YOLOv5s、YOLOv7-tiny^[28]、YOLOv8n^[29] 进行比较,不同网络性能对比如表 2 所示。实验结果表明,改进后的 YOLOv5s-BCGS 算法各项评价指标优于 Faster R-CNN、YOLOv4-tiny、YOLOv5s、YOLOv7-tiny 等网络,mAP0.5 分别高 28.5%、2.7%、2.2%、2.5%,mAP0.75 分别高 24.2%、9.3%、3.8%、4%,mAP0.5~0.95 分别高 20.6%、17.3%、6.7%、5%,每秒检测帧数 FPS1、FPS2 分别高 96.1、13.3、17.4、2.8、62、7.6、38.8、6.3,检测精度和速度均优于上述模型。相较于 YOLO 系列 YOLOv8 中最轻量的模型 YOLOv8n,YOLOv5s-BCGS 虽然在模型体积大了 5.1 MB,但在 mAP0.5 高了 0.3%,mAP0.75 高了

1.7%,mAP0.5~0.95 高了 2.2%,每秒检测帧数 FPS1、FPS2 分别提升了 11.9、4.1。检测精度方面 YOLOv5s-BCGS 在 mAP0.5、mAP0.75、mAP0.5~0.95 上均有提升,意味着模型在不同匹配条件下均能更准确地识别和定位目标;检测速度方面 YOLOv5s-BCGS 虽然模型体积

大于 YOLOv8n,但在更具实际工程意义的评级指标 FPS 上更具优势,使得 YOLOv5s-BCGS 在巡检识别上更具实时性。综合来看,YOLOv5s-BCGS 相较于 YOLOv8n 更有优势。




图 8 改进算法检测结果对比

Fig. 8 Comparative analysis of detection results for improved algorithms

表 2 不同模型性能对比

Table 2 Performance comparison of different models

网络模型	mAP0.5	mAP0.75	mAP0.5~0.95	模型体积/MB	FPS1	FPS2
Faster-RCNN	70.7	68.1	40.8	108.8	58.6	1.4
YOLOv4-tiny	96.5	83.0	47.1	22.6	137.3	15.9
YOLOv5s	97.0	88.5	54.7	27.3	92.7	11.1
YOLOv7-tiny	96.7	88.3	56.4	23.3	115.9	12.4
YOLOv8n	98.9	90.6	59.2	12.9	142.8	14.6
YOLOv5s-BCGS	99.2	92.3	61.4	18.0	154.7	18.7

4 结 论

针对变电站嵌入式设备的指针式仪表识别存在实时

性差、小目标和密集目标识别漏检等问题,提出了一种改进的 YOLOv5s 模型。该模型在 YOLOv5s 网络的颈部引入 CA 注意力机制并替换 PANet 为 BiFPN,将原始网络背部和颈部的传统卷积替换为轻量化的 Ghost 模块,优

化了网络的结构,增强了小目标和密集目标的检测能力;为了提高定位精度,将原始网路中的目标检测损失函数CIOU替换为SIOU,进一步提升了模型的检测性能。改进后的YOLOv5s-BCGS模型展现了卓越的性能,在PC和嵌入式设备上均表现出了良好的实时性和高精度,能够满足变电站指针仪表巡检的实际需求。本研究的核心贡献在于提出了一种针对嵌入式设备优化的目标检测模型,突破了传统模型在小目标和密集目标检测中的局限。通过网络结构中引入新的注意力机制与轻量化设计,本研究不仅提高了检测精度,还保证了模型在资源受限环境中的高效运行。此外,本研究的创新技术能够为智能化变电站的巡检系统提供技术支持,并为嵌入式设备上的高效目标检测提供了新的思路。未来的工作将聚焦于进一步优化模型结构,探索更高效的算法,提升在更复杂环境中的适应能力,并推动其在更广泛的工业应用中的落地与实践。

参考文献

- [1] 杨楠,刘钊,鄢晶,等.考虑主变调整利用和安全效能成本的变电站规划方法[J].中国电机工程学报,2020,40(13):4187-4200.
- YANG N, LIU ZH, YAN J, et al. Planning method of substation considering main transformer adjustment utilization and safety efficiency cost[J]. Proceedings of the CSEE, 2020, 40(13): 4187-4200.
- [2] 张瑶,王傲寒,张宏.中国智能电网发展综述[J].电力系统保护与控制,2021,49(5):180-187.
- ZHANG Y, WANG AO H, ZHANG H. Overview of smart grid development in China[J]. Power System Protection and Control, 2021, 49(5): 180-187.
- [3] 关忠榜,杨颜博,李敏超.基于改进Mask R-CNN的牛脸目标检测算法[J].电子测量技术,2023,46(24):133-138.
- GUAN ZH B, YANG Y B, LI M CH. Bull face target detection algorithm based on improved mask R-CNN[J]. Electronic Measurement Technology, 2023, 46(24): 133-138.
- [4] 赵佰亭,张晨,贾晓芬.ECC-YOLO:一种改进的钢材表面缺陷检测方法[J].电子测量与仪器学报,2024,38(4):108-116.
- ZHAO B T, ZHANG CH, JIA X F. ECC-YOLO: An improved method for surface defect detection of steel[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 108-116.
- [5] 胡欣,周运强,肖剑,等.基于改进YOLOv5的螺纹钢表面缺陷检测[J].图学学报,2023,44(3):427-437.
- HU X, ZHOU Y Q, XIAO J, et al. Surface defect detection of rebar based on improved YOLOv5[J]. Journal of Graphics, 2023, 44(3): 427-437.
- [6] 陈娟,李燕,阚希,等.基于EfficientNet的轻量化行人检测算法[J].国外电子测量技术,2023,42(6):1-9.
- CHEN J, LI Y, KAN X, et al. Lightweight pedestrian detection algorithm based on EfficientNet[J]. Foreign Electronic Measurement Technology, 2023, 42(6): 1-9.
- [7] 张堃,刘志诚,刘纪元,等.面向人机协作系统的上肢姿态精准识别算法研究[J].仪器仪表学报,2023,44(1):275-282.
- ZHANG K, LIU ZH CH, LIU J Y, et al. Research on upper limb posture accurate recognition algorithm for human-computer collaboration system[J]. Journal of Instrumentation, 2023, 44(1): 275-282.
- [8] 黄杨乐天,刘宜胜,陈铤,等.基于深度学习的指针仪表识别系统[J].自动化与仪表,2023,38(11):100-104,108.
- HUANG Y L T, LIU Y SH, CHEN Y, et al. Indicator instrument recognition system based on deep learning[J]. Automation and Instrumentation, 2023, 38(11): 100-104,108.
- [9] 赵辉,姜立锋,王红君,等.基于机器视觉的指针式仪表检测[J].科学技术与工程,2021,21(34):14665-14672.
- ZHAO H, JIANG L F, WANG H J, et al. Pointer instrument detection based on machine vision[J]. Science Technology and Engineering, 2021, 21(34): 14665-14672.
- [10] 金爱萍,袁亮,周德勤,等.基于YOLOv5和U-net的指针式仪表读数识别方法[J].仪表技术与传感器,2022(11):29-33.
- JIN AI P, YUAN L, ZHOU D Q, et al. A method for reading indicator dial readings based on YOLOv5 and U-net[J]. Instrument Technology and Sensors, 2022, (11): 29-33.
- [11] 陶金,林文伟,曾亮,等.基于YOLOv4-tiny和Hourglass的指针式仪表读数识别[J].电子测量与仪器学报,2023,37(5):1-10.
- TAO J, LIN W W, ZENG L, et al. Recognition of pointer instrument readings based on YOLOv4-tiny and Hourglass[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(5): 1-10.
- [12] 何敏,秦亮,刘开培,等.变电站电力仪表智能检测

- 算法研究[J]. 高电压技术, 2024, 50(7): 2942-2954.
- HE M, QIN L, LIU K P, et al. Research on intelligent detection algorithm for substation power instruments[J]. High Voltage Technology, 2024, 50(7): 2942-2954.
- [13] 骆东松, 张杰峰, 魏義民. 基于轻量化的指针仪表检测算法研究[J]. 工业仪表与自动化装置, 2024(1): 98-103.
- LUO D S, ZHANG J F, WEI Y M. Research on pointer instrument detection algorithm based on lightweight[J]. Industrial Instrumentation and Automation Devices, 2024(1): 98-103.
- [14] LI ZH G, WANG J T. An improved algorithm for deep learning YOLO network based on xilinx ZYNQ FPGA[J]. International Conference on Culture-oriented Science & Technology (ICCST), 2020: 447-451. DOI: 10.1109/ICCST50977.2020.00092.
- [15] HAN K, WANG Y H, TIAN Q, et al. GhostNet: More features from cheap operations[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020:1577-1586.
- [16] 李文举, 张干, 崔柳, 等. 基于坐标注意力的轻量级交通标志识别模型[J]. 计算机应用, 2023, 43(2): 608-614.
- LI W J, ZHANG G, CUI L, et al. Lightweight traffic sign recognition model based on coordinate attention[J]. Journal of Computer Applications, 2023, 43(2): 608-614.
- [17] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [18] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018:7132-7141.
- [19] WOO S, PARK J, LEE J, et al. CBAM: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3-19.
- [20] TAN M X, PANG R M, LE Q V. EfficientDet: Scalable and efficient object detection[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020:10778-10787.
- [21] LIN T, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017:936-944.
- [22] GUO Y, CHEN SH Q, ZHAN R H, et al. SAR ship detection based on YOLOv5 using CBAM and BiFPN[C]. IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium, Kuala Lumpur, Malaysia, 2022:2147-2150.
- [23] REZATOFIGHI H, TSOI N, SADEGHIAN A, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019:658-666.
- [24] ZHENG ZH H, WANG P, REN D W, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[C]. IEEE Transactions on Cybernetics, 2021, 52(8): 8574-8586.
- [25] GEVORGYAN Z. SiLU Loss: More powerful learning for bounding box regression[J]. ArXiv preprint arXiv: 2205.12740, 2022.
- [26] 邵延华, 张铎, 楚红雨, 等. 基于深度学习的YOLO目标检测综述[J]. 电子与信息学报, 2022, 44(10): 3697-3708.
- SHAO Y H, ZHANG D, CHU H Y, et al. A review of yolo object detection based on deep learning[J]. Journal of Electronics & Information Technology, 2022, 44(10): 3697-3708.
- [27] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv preprint arXiv:2004.10934, 2020.
- [28] 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]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022:7464-7475.
- [29] REIS D, KUPEC J, HONG J, et al. Real-time flying object detection with YOLOv8[J]. ArXiv preprint arXiv: 2305.09972, 2023.

作者简介



胡欣, 2008 年于西北工业大学获得博士学位, 现为长安大学教授, 主要研究方向为智慧巡检及大数据处理、人工智能及机器人和多模态数据融合。

E-mail: huxin@chd.edu.cn

Hu Xin received her Ph. D. degree from Northwestern Polytechnical University in 2008. Now she is a professor at Chang'an University. Her main research interests include intelligent patrol inspection and big data processing,

artificial intelligence and robots, and multimodal data fusion.



刘瑞峰, 2022 年于西北农林科技大学获得学士学位, 现为长安大学研究生, 主要研究方向为智慧巡检和图像处理。

E-mail: 441725753@qq.com

Liu Ruifeng received his B. Sc. degree from Northwest A&F University in 2022. Now he is a graduate student at Chang'an University. His main research interests include intelligent patrol inspection and image processing.



肖剑 (通信作者), 2008 年于兰州大学获得博士学位, 现为长安大学副教授, 主要研究方向为智能感知与计算、机器视觉和图像处理。

E-mail: xiaojian@chd.edu.cn

Xiao Jian (Corresponding author) received his Ph. D. degree from Lanzhou University in 2008. Now he is an associate professor at Chang'an University. His main research interests include intelligent perception and


computing, machine vision, and image processing.



段承志, 2024 年于长安大学获得硕士学位, 主要研究方向为机器视觉、深度学习和图像处理。

E-mail: 1346854749@qq.com

Duan Chengzhi received his M. Sc. degree from Chang'an University in 2024. His main research interests include machine vision, deep learning and image processing.



程鸿亮, 2009 年于长安大学获得硕士学位, 现为长安大学讲师, 主要研究方向为嵌入式系统和深度学习。

E-mail: hlcheng@chd.edu.cn

Cheng Hongliang received his M. Sc. degree from Chang'an University in 2009. Now he is a lecturer at Chang'an University. His main research interests include embedded systems and deep learning.