

DOI:10.13382/j.jemi.B2508233

# 基于改进 YOLOv11n 的微特电机电枢缺陷检测算法\*

吴凡凡<sup>1,2</sup> 张鹏超<sup>1,2</sup> 王磊<sup>1,2</sup> 曾昆峰<sup>1,2</sup> 崔金凯<sup>1,2</sup> 马文星<sup>1,2</sup>

(1. 陕西理工大学机械工程学院 汉中 723001; 2. 陕西省工业自动化重点实验室 汉中 723001)

**摘要:**针对现有微特电机电枢表面缺陷检测方法存在检测精度不高,特别是相似性工件容易误判等问题,结合深度学习的方法,提出了一种基于改进 YOLOv11n 的微特电机电枢外观缺陷检测方法。首先,采用高效部分卷积和残差连接思想,设计一种部分多尺度特征聚合模块(C3K2-multi scale partial feature aggregation, C3K2-MSPFA),显著提高了对不同尺度目标的检测能力,提升了模型的检测精度;其次,引入全维动态卷积(omni-dimensional dynamic convolution, ODConv)和自适应下采样(adaptive downsampling, ADown),设计一种轻量化的全维下采样模块(omni-dimensional adaptive downsampling, OD-ADown),减少了 C3K2-MSPFA 模块的参数数量和计算量;最后,为了弥补完整交并比损失函数(complete-IoU loss, CIoU)在检测任务中泛化性弱和收敛速度慢的问题,使用距离交并比损失函数(distance-IoU loss, DIoU)提高模型精度,加快边界框回归速度。在自建数据集上进行实验对比,实验结果表明,改进后的模型平均精度达到 94.2%,召回率为 90.9%,准确率为 95.9%,参数数量为  $2.15 \times 10^6$ ,模型大小为 4.5 MB。与原 YOLOv11n 网络模型相比,准确率、召回率、平均精度均值分别提高了 1.3%、4.6%、2.7%,参数数量和模型大小相比于原模型分别降低了 16.67% 和 15.09%。能够满足移动端和嵌入式设备的部署要求,为微特电机电枢表面缺陷检测的发展提供了一定有效的技术支持。

**关键词:** 电枢;缺陷检测;YOLOv11n;C3K2-MSPFA;OD-ADown;DIoU 损失函数

**中图分类号:** TN751;TH165 **文献标识码:** A **国家标准学科分类代码:** 520.60

## Improved YOLOv11n-based armature defect detection algorithm for microtome motors

Wu Fanfan<sup>1,2</sup> Zhang Pengchao<sup>1,2</sup> Wang Lei<sup>1,2</sup> Zeng Kunfeng<sup>1,2</sup> Cui Jinkai<sup>1,2</sup> Ma Wenxing<sup>1,2</sup>

(1. School of Mechanical Engineering, Shaanxi University of Technology, Hanzhong 723001, China;

2. Shaanxi Key Laboratory of Industrial Automation, Hanzhong 723001, China)

**Abstract:** To address the issues of low detection accuracy and misclassification of similar components in existing micro-motor armature surface defect detection methods, this study proposes an improved YOLOv11n-based approach for detecting surface defects in micro-motor armatures by integrating deep learning techniques. First, by adopting the concepts of efficient partial convolution and residual connections, we designed a partial multi-scale feature aggregation module named C3K2-multi scale partial feature aggregation (C3K2-MSPFA). This significantly enhances the detection capability for objects at different scales, thereby improving the model's detection accuracy. Second, we introduce omni-dimensional dynamic convolution (ODConv) and adaptive downsampling (ADown) to design a lightweight omni-dimensional adaptive downsampling (OD-ADown) module, reducing the parameter count and computational load of the C3K2-MSPFA module. Finally, to address the weak generalization and slow convergence issues of complete-IoU loss (CIoU) in detection tasks, we employ distance-IoU (DIoU) loss to enhance model accuracy and accelerate bounding box regression speed. Experiments were conducted on a self-built dataset, and the results showed that the improved model achieved an average accuracy of 94.2%, a recall rate of 90.9%, an accuracy rate of 95.9%,  $2.15 \times 10^6$  parameters, and a model size of 4.5 MB. Compared with the original YOLOv11n network model, the accuracy, recall, and average precision have been improved by 1.3%, 4.6%, and 2.7%, respectively. Compared with the original model, the number of parameters and model size were reduced by 16.67% and 15.09%,

收稿日期: 2025-03-11 Received Date: 2025-03-11

\* 基金项目: 国家自然科学基金(62176146)项目资助

respectively. It can meet the deployment requirements of mobile and embedded devices, and provide certain effective technical support for the development of surface defect detection of armatures in micro and special electric machines.

**Keywords:** armature; defect detection; YOLOv11n; C3K2-MSPFA; OD-ADown; DIoU loss function

## 0 引言

微特电机是实现工业自动化、办公自动化、家庭自动化的重要基础部件之一,具有广阔的市场需求。随着新材料、新工艺和新技术的不断涌现,微特电机行业不断进行技术创新和产品升级。当前无刷直流电机因其结构简单、智能控制能力强、噪音低和能效高等特点,成为行业未来发展的趋势。但因有刷直流电机技术成熟且价格相对低廉,传统的有刷直流电机仍占据市场主流。电枢作为微特电机的核心部件,其品质很大程度上影响了电机的性能。因此,对电枢的品控尤为重要。

在电枢缺陷的传统检测中,主要依赖人工操作。上述手段暴露出人为判断偏差明显、用工支出过高及处理速度缓慢等不足,难以适应微特电机领域产能快速扩张的要求。近年来,智能识别技术取得突破性进展,依托神经网络构建的智能检测模型凭借其可靠性强、响应迅速、识别精确及自动化程度高等特点,正逐步成为工业质检领域的研究热点。李勇等<sup>[1]</sup>设计了一种用于增强多尺度特征整合的网络架构,该架构以双向特征金字塔网络(feature pyramid network, FPN)架构的每一个特征融合阶段引入了注意力机制,其目的在于使网络能够依据输入样本的上下文信息,动态地调整不同分辨率特征在融合过程中的权重。陈星寰等<sup>[2]</sup>采用改进丰富卷积特征(rich convolutional features, RCF)模型实现转子表面缺陷检测,其识别准确率达到 94.13%。吴承俊等<sup>[3]</sup>采用改进残差网络(residual network, ResNet)模型对转子进行检测,实验结果显示准确率可达 97.6%。此类方案虽有效,但常伴随高昂的计算与存储成本,具体表现为训练效率低下和参数量膨胀。这些问题使其难以满足众多移动与嵌入式应用场景对资源的严苛约束。特别是巨大的参数量对设备的内存带宽和缓存机制构成了压力,这往往比纯计算开销更影响实时性。

随着计算机视觉技术的迭代升级,智能视觉系统的研发与应用边界持续拓展。工业制品外观质量智能检测系统凭借其非接触式优势,逐渐成为智能制造领域的关键支撑技术。在缺陷检测领域,这些算法主要以卷积神经网络(convolutional neural network, CNN)为基础<sup>[4-5]</sup>,根据单阶段检测和双阶段检测两种类型展开研究,两类技术在缺陷检测速度方面均取得了良好效果。区域卷积神

经网络(region-based convolutional neural networks, R-CNN)系列算法<sup>[6-9]</sup>是双阶段检测的典型实现。该方案将检测流程解耦为区域提议与区域识别两个串行阶段。虽然此范式有助于提升精度,但其结构也导致了模型复杂度高、计算负载大的问题,主要表现为参数量大和推理速度慢。这种串行瓶颈使其难以在注重效率的工业应用(如在线质检)中实现高推理吞吐量。鉴于上述对实时性的迫切需求,检测流程更为简洁的单阶段方法自然展现出其独特优势。这类方法通常能实现更快的推理速度,并拥有更优的架构可扩展性,因而在工业场景中得到了广泛青睐。在该技术路线中,YOLO 系列算法<sup>[10-16]</sup>,无疑是近年来发展最为迅速、影响最为深远的主流方案之一,并已在工业质检、安防监控等多个实际领域取得了成功的应用实践。刘祉桑等<sup>[17]</sup>提出一种 YOLOv5s-ADW 算法,针对钢材表面缺陷检测中存在的小目标检测效果差、特征提取不充分问题进行改进,性能评估显示,与基准模型 YOLOv5 相比,其在平均精度均值上达到 14.4%。杜佳奇等<sup>[18]</sup>提出基于 YOLOv6s 模型的微特电机电枢缺陷检测模型,通过引入简单注意力模块(simple attention module, SimAM)、使用分组稀疏卷积(grouped sparse convolution, GSConv)和替换损失函数优化模型结构,实验结果表明,该模型平均精度均值达到 50.6%,较 YOLOv6 基准模型提高了 4.7%。王天洋等<sup>[19]</sup>基于改进 YOLOv8s 的轻量级印制电路板(PCB)缺陷检测算法,针对印刷电路板小目标缺陷检测任务的问题进行改进,参数量降低 81.5%,计算量降低 21.3%,模型大小降低 72.3%,平均精度均值提升 3.0%。金莉莉等<sup>[20]</sup>提出了一种改进的 YOLOv10n 模型,并将其应用于太阳能电池板的缺陷识别。该模型在平均精度均值、精确率和召回率上均优于原基准模型。这些成功的应用案例,彰显了基于现有检测器进行针对性优化以适应特定工业场景的有效性,为技术发展奠定了坚实基础。但必须指出的是,尽管该领域已不乏大量研究,但在微特电机电枢表面缺陷检测中处理细微瑕疵样本时,易引发关键属性遗漏及特征学习不足的问题。为此,优化缺陷辨识度成为技术突破的关键方向。综上所述,实时检测速率低、模型计算复杂且参数规模庞大等挑战,仍是阻碍其实际部署的关键瓶颈。

为应对上述挑战,本文构建了一种基于 YOLOv11n 的改进型网络模型,以期在保证精度的同时,显著提升检测效率并压缩模型体积。

### 1 YOLOv11 网络模型

YOLOv11 网络模型作为目标检测领域的重要迭代,在模型架构和训练范式上进行了全面升级。相较于前代 YOLOv8 模型<sup>[21]</sup>,YOLOv11 在检测精度与推理速度两方面均实现了显著进步。这一提升主要源于其采取的一系列架构改进,包含一个经过重参数化优化的骨干网络、一条增强的多尺度特征融合路径、一个计算效率更高的检测头,以及针对小目标检测的专项策略。尤为关键的是在分类检测头中嵌入了两个深度可分离卷积(depthwise convolution, DWConv)层,该设计在不牺牲精度的前提下,有效降低了模型的计算复杂度和内存访问开销,从而对减少延迟与功耗起到了积极作用。YOLOv11 提供了共 5 种配置,这些版本通过系统地增加网络的深度与宽度,逐步提升模型的复杂度和表征能力。其中,YOLOv11n 作为复杂度最低的版本,凭借其极快的推理速度,非常适合对实时性要求极高的边缘计算场景,但其检测精度相对有限。反之,从 YOLOv11s 到 YOLOv11x,随着模型容量的增大,其精度虽有显著改善,但随之增长的计算负担也导致了更长的检测周期。因此,在真实的工业实时监测系统中,必须在模型的精度与速度之间进行审慎的权衡,过大的模型所引入的时间延迟可能会直接影响整个系统的响应能力与实际效用。

### 2 YOLOv11n 网络模型改进

鉴于上述分析,YOLOv11n 在速度上的优势与精度上的不足并存。因此,本文的核心目标是针对 YOLOv11n 模型进行针对性优化,以期在尽量保留其高速特性的前提下,有效提升检测精度,从而更好地满足工业实时检测场景下对性能均衡的苛刻要求。本文所提出的改进模型结构如图 1 所示。

#### 1) 多尺度特征聚合模块设计

采用高效部分卷积与残差连接思想,设计了部分多尺度特征聚合模块(C3K2-multi scale partial feature aggregation, C3K2-MSPFA)。该模块通过融合多尺度局部特征与全局语义信息,显著提升了对微小缺陷目标的检测精度与多尺度适应性。

#### 2) 轻量化全维下采样模块设计

引入全维动态卷积(omni-dimensional dynamic convolution, ODConv)和自适应下采样(adaptive downsampling, ADown),设计一种轻量化的全维下采样模块(omni-dimensional adaptive downsampling, OD-ADown),以此来减少 C3K2-MSPFA 模块导致的模型参数量和计算量增大问题。

#### 3) 损失函数优化

采用距离交并比损失函数(distance-IoU loss, DIoU)替代原有方案,以此来解决完整交并比损失函数(complete-IoU loss, CIoU)泛化性弱与收敛速度慢问题。

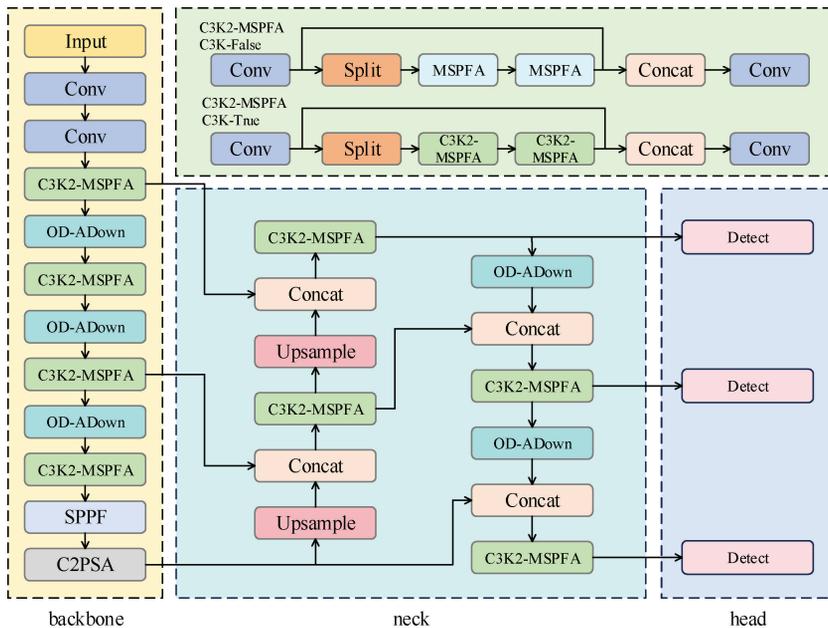


图 1 改进后的 YOLOv11n 网络结构

Fig. 1 Structure diagram of the improved YOLOv11n network

### 2.1 C3K2-MSPFA 模块

在计算机视觉任务中,利用不同尺度卷积核对图片进行特征捕获以获取多尺度信息具有良好效果。针对不同尺度特征间的上下文信息丢失以及电极缺陷图像小目标特征难以提取的问题,本研究参考 CVPR2020-GhostNet<sup>[22]</sup>与 CVPR2024-FasterNet<sup>[23]</sup>思想,提出了一种基于高效部分卷积的改进方案。通过设计 C3K2-MSPFA 模块,替换原模型中的 C3K2 模块,并将其命名为 C3K2-MSPFA。该模块结构如图 2 所示。

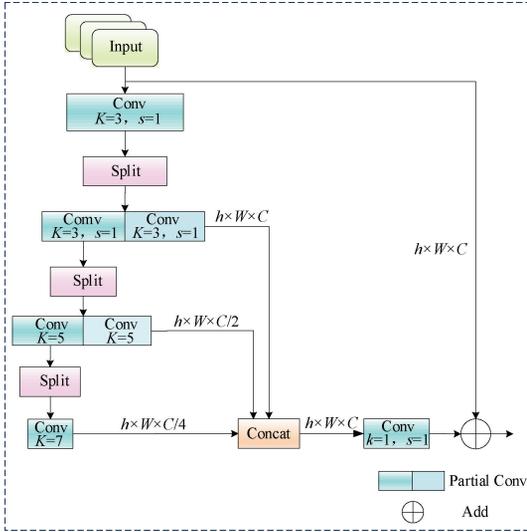


图 2 C3K2-MSPFA 模块  
Fig. 2 C3K2-MSPFA module

C3K2-MSPFA 模块通过对不同尺寸卷积核进行显著性特征信息提取,但其关键创新在于仅对输入通道的一部分(而非全部)执行卷积操作,这种部分卷积机制,在保证多尺度信息融合效果的同时,有效降低了模块的计算复杂度和参数量。既先通过通道分割(Split)操作将卷积沿通道维度平均拆分为两部分。继而,这两个部分并行地经由不同尺度的卷积核进行处理,所得到的多尺度特征图被立即送入拼接(concatenation, Concat)层进行融合,该并行化设计是提升计算效率的关键。为进一步增强特征整合能力,模块末端引入了一个 1x1 的卷积层,用于对融合后的多尺度特征进行跨通道信息交互与降维。最终,通过一条残差连接,将模块的原始输入与前述处理结果进行逐元素相加。这种残差机制不仅解决了梯度消失和梯度爆炸问题,还通过融合原始输入与处理特征有效提升了模型的表达能力,表达式为:

$$C_{i \times i}(P_{im}) = [C_{3 \times 3}(P_{im}), C_{5 \times 5}(C_{3 \times 3}(P_{im})), C_{7 \times 7}(C_{5 \times 5}(C_{3 \times 3}(P_{im})))]$$

(1)

$$M_{out} = C_{1 \times 1}(Cat[P_{im}, C_{i \times i}(P_{im})])$$

(2)

式中: $P_{im}$  表示多尺度特征融合模块的输入; $C_{3 \times 3}$  表示卷积核尺寸为 3x3 的卷积操作; $C_{5 \times 5}$  表示卷积核尺寸为 5x5 的卷积操作; $C_{7 \times 7}$  表示卷积核尺寸为 7x7 的卷积操作; $M_{out}$  表示多尺度特征聚合模块的输出。

### 2.2 轻量化全维下采样模块

在深度学习特征提取过程中,ADown<sup>[24]</sup>下采样模块首先通过平均池化压缩特征图尺寸,从而减少后续卷积的计算量。在通道处理方面,该模块创新性地结合两种并行路径:一路先进行最大池化再卷积,另一路仅执行卷积,并通过参数共享机制高效学习模型参数,显著减少了参数量并提高了计算效率。本文引入 ADown 模块替代传统的下采样卷积,并创新性地将原 ADown 模块中的普通卷积替换成全维动态卷积 ODConv<sup>[25-26]</sup>,设计一种轻量化的 OD-ADown 下采样模块,以实现更好的检测效果和轻量化,对比如图 3 所示。

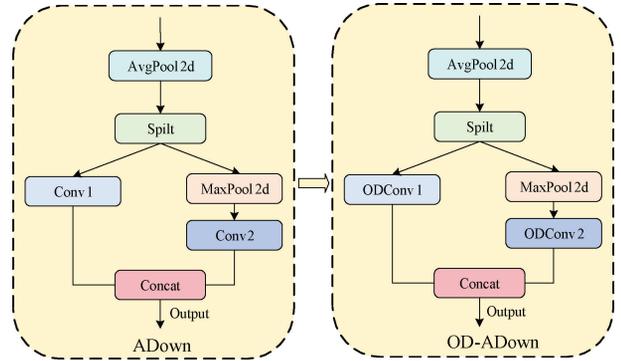


图 3 ADown 与 OD-ADown 下采样对比

Fig. 3 Comparison of ADown and OD-ADown downsampling

ODConv 的核心创新在于其卷积核权重可在 4 个维度上实现动态调整,这 4 个维度包括空间尺度、卷积核自身、输入通道以及输出通道。ODConv 采用并行策略,通过多个轻量级网络来协同生成这 4 个维度上的自适应权重。与传统静态卷积相比,ODConv 实现了真正意义上的多维度动态适应性。这意味着卷积操作能够更灵活地响应输入特征在空间、通道等不同层面的变化,从而具备更强大的特征提取能力,尤其适用于从复杂的工业图像中捕捉鉴别性信息。ODConv 结构如图 4 所示。

首先通过全局平均池化层(global average pooling, GAP)对输入特征进行空间维度压缩,生成维度为  $c_{in}$  的特征向量,随后通过由全连接层(fully connected, FC)和 ReLU(rectified linear unit)激活函数构成的降维模块,其中 FC 层以 1/16 的压缩比将特征投影至低维空间,从而有效降低动态卷积的计算复杂度,而 ReLU 函数在此过程中执行非线性变换,来消除特征向量中的负值响应。为进一步增强特征表达能力,网络架构设计了 4 个并行预测分支,每个分支均由全连接层和两种激活函数组成,

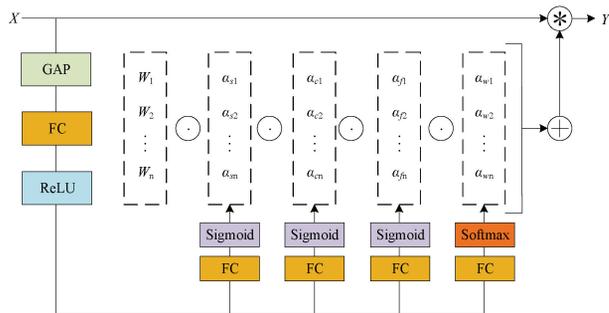


图 4 ODCConv 卷积结构

Fig. 4 ODCConv convolution structure

分别用于生成 ODCConv 模块的 4 类注意力权重。这种多维度注意力协同机制能够从不同特征空间捕获电枢缺陷的显著性特征和上下文关联信息,通过多维度的特征交互显著提升模型的代表能力和泛化性能。

为提升 ADown 模块的效率与性能,本文对其结构进行了两项关键优化。首先,使用 ODCConv 替代原有的标准卷积堆叠。这一替换显著降低了该模块的参数量,加快了模型训练收敛速度;同时,ODCConv 的动态特性有助于改善深层网络中的梯度流动,有效缓解了梯度消失与模型退化问题。其次,在部分关键卷积层中增大了卷积核尺寸,以此扩大网络的感受野,增强其对图像全局上下文信息与复杂特征的捕捉能力。

### 2.3 损失函数优化

核心评估指标用于衡量模型稳定性,显著影响检测精度与训练效率,对目标检测性能的提升具有决定性作用。其中,边界框损失函数作为检测模型的关键组成部分,在电枢缺陷检测中面临复杂工况挑战——生产线环境存在机械振动和噪声污染等问题,严重制约自动化检测的准确性。基于此,本研究提出采用 DIoU<sup>[27]</sup> 替代 YOLOv11n 中原有的 CIoU<sup>[28]</sup> 损失函数,以优化边界框回归速度。值得注意的是,传统 CIoU 仅关注形状相似性,当检测框与标注框的高宽比一致时,其退化特性会导致损失函数等同于交并比(intersection over union, IoU) 损失函数。

为克服 CIoU 损失函数在目标检测任务中存在的泛化能力不足与收敛速度较慢的局限性,研究者提出了 DIoU 损失函数。该函数在 IoU 基础之上引入了一个针对边界框中心点距离的惩罚项,通过直接最小化并归一化预测框与真实框中心点之间的欧氏距离,有效加速了模型的收敛过程。因此,DIoU 被视为对 CIoU 的一项重要优化,其在保持高定位精度的同时,显著提升了回归效率。其作用原理如图 5 所示。

在特征学习过程中,若电枢缺陷样本中心与预测框重合而尺寸发生变化时,DIoU 损失函数的数值表现保持

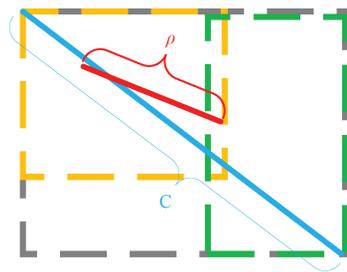


图 5 DIoU 计算原理

Fig. 5 Schematic diagram of DIoU calculations

恒定。对于包含、平行及垂直排列的目标框结构,该指标通过引入中心点距离约束项,有效提升边界框的快速收敛能力。其数学表达式如下:

$$L_{DIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} \quad (3)$$

式中: $\rho$  表示检测框中心与标注框中心的直线距离; $c$  为两框最小包围矩形的空间对角线长度; $b$  和  $b^{gt}$  分别代表了锚框和目标框的中心点。该损失函数通过融合区域交叠度与几何中心偏移量双维度信息,在目标框完全包含且存在交叠时,基于中心点间距的约束机制可显著提升参数收敛效率。

## 3 实验数据与评价指标

### 3.1 数据集制作

数据集来源于某标准大型电机厂。在工厂流水线上的图像采集设备完成原始图像采集后,将图像送至质量检测部门。经验丰富的质检员对图片进行筛选,来区分良品与不良品。随后由质量工程师进行复检以确保分类准确性,最终获得电枢缺陷图像 1 846 张。获取的图像为 1 440 pixel×1 080 pixel 的 JPG 格式文件。通过筛选去除模糊、重复等无效图像后,保留的电枢缺陷图像共 698 张,分类如下:点焊不良 (poor spot welding) 95 张,断线 (breaking) 68 张,浮线 (float line) 258 张,抛线 (throwing line) 92 张,勾角线 (hook lines) 98 张,换向器伤 (commutator injury) 87 张。图 6 所示为电枢缺陷样本。

为提升模型的泛化能力并增加训练数据的多样性,本研究对原始电枢缺陷图像集进行了系统的数据增强处理。增强手段涵盖像素级变换(如添加噪声、调整亮度)与空间几何变换(如平移、旋转及镜像翻转等)。经过此系列扩充操作后,有效图像样本总量达到 3 490 张。随后,使用 LabelImg 工具对所有图像中的缺陷目标进行人工精确标注,标注信息统一保存为标准的 YOLO 格式。为保障模型训练与评估的科学性,将完整数据集按 7 : 2 : 1 的比例随机划分为 3 个互斥子集,分别为训练集

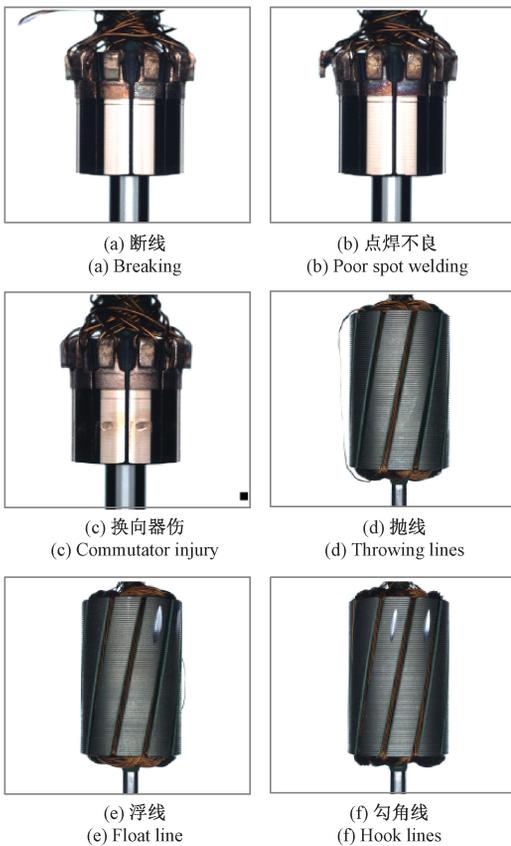


图 6 电枢缺陷样本

Fig. 6 Armature defect samples

(2 443 张)、验证集(698 张)和测试集(349 张)。

### 3.2 试验环境配置与网络参数设置

本文实验环境统一配置为 Ubuntu18.04.6 LTS 操作系统, 配备 62.5GB 的充足运行内存, 以及高性能的 NVIDIA GeForce RTX 3080GPU。在构建深度学习模型时, pytorch 框架版本为 2.2.2 + cu121, python 版本为 3.10.14。实验过程中, 模型的迭代训练被设定为 550 次循环, 每次迭代处理的批量数据大小为 32。

为了优化训练效果, 初始学习率被设定为 0.01, 并应用了 0.0005 的权重衰减策略。优化算法方面, 采用

经典的随机度下降(SGD)方法。此外, 为了进一步提升模型的泛化能力和识别精度, 在训练过程中集成了 Mosaic 数据增强技术。

### 3.3 性能评价指标

本文采用目标检测中常用的性能评价指标, 即召回率(recall, R)、平均精度均值(mean average precision, mAP)、模型参数量(parameter)、浮点数计算量(giga floating-point operations per second, GFLOPs)、模型大小(module size), 对本文所提模型进行有效评价。将 IoU 阈值为 0.5~0.95 之间, 步长为 0.05, 取 10 个阈值, 对分别得到的 10 个平均精度均值进行平均, 得到 mAP@0.5:0.95。对交并比阈值为 0.5 时得到的精度进行平均, 得到 mAP@0.5。计算如式(4)~(6)所示。

$$P = \frac{T_p}{T_p + F_p} \tag{4}$$

$$R = \frac{T_p}{T_p + F_n} \tag{5}$$

$$mAP = \frac{\sum_{i=1}^n AP_i}{n} \tag{6}$$

式中:  $F_p$  为错误预测的正样本数;  $F_n$  表示错误预测的负样本数;  $T_p$  表示正确预测的正样本数。AP 是针对单个类别计算的, 而 mAP 是在所有类别中计算的, 利用该指数对各个类别的整体探测效果进行了评价。

## 4 结果和分析

### 4.1 不同位置替换 C3K2-MSPFA 对模型的影响

为了筛选出最佳的 C3K2 模块改进方案, 分别使用 C3K2-MSPFA 模块对 3 个不同网络结构部分的 C3K2 模块进行替换, 表 1 为 4 组不同的对比试验, 分别是替换主干网络(Backbone)部分的 C3K2 模块、头部网络(Head)部分的 C3K2 模块、主干网络部分和头部网络部分的 C3K2 模块以及原始 YOLOv11n 网络模型。结果如表 1 所示。

表 1 C3K2-MSPFA 不同位置替换方案结果对比

Table 1 Comparison of the results of the C3K2-MSPFA replacement program at different locations

试验编号	网络结构	参数量/( $\times 10^6$ )	模型大小/MB	准确率/%	召回率/%	mAP@0.5/%
①	YOLOv11n	2.58	5.3	94.6	86.3	91.5
②	Backbone	2.61	5.3	92.4	88.5	93.0
③	Head	2.58	5.4	95.2	85.7	91.0
④	Backbone+Head	2.63	5.4	96.6	88.8	93.4

根据表 1 的数据, 在替换主干网络和头部网络中的 C3K2 模块后, 模型在电枢外观缺陷识别方面的平均精度

均值相比其他两种方案分别提高了 0.4% 和 2.4%。与此同时, 准确率分别提高了 4.2% 和 1.4%, 召回率分别提高

了 0.3% 和 3.1%。这一性能提升主要得益于 C3K2-MSPFA 模块末端的  $1 \times 1$  卷积层设计。该层通过整合来自不同尺度的特征信息,并借助残差连接将原始输入特征与经过处理的特征进行融合,既保留了底层的细节信息,又引入了增强的语义表征,从而显著提升了模型对多尺度特征的表达能力。因此,基于试验④的结果对 C3K2 模块进行结构优化,该改进使模型在保留底层特征完整性的同时,能够有效融合多尺度上下文信息。这种双重保障机制显著增强了网络的特征表征能力,为后续检测

任务提供了更丰富的语义基础。与原始 YOLOv11n 网络模型相比,尽管该改进方案使平均精度均值提升了 1.9%,但却让参数量和模型大小增加了  $0.05 \times 10^6$  和 0.1 MB。

#### 4.2 不同位置替换 OD-ADown 对模型的影响

为验证本文所改进的 OD-ADown 模块在降低原网络模型参数量方面的有效性,分别对主干网络、头部网络以及主干和头部网络整体进行了验证,并与原始 YOLOv11n 和 ADown 模型进行对比,结果如表 2 所示。

表 2 OD-ADown 不同位置替换方案结果对比

Table 2 Comparison of the results of OD-ADown replacement program at different locations

试验编号	网络结构	参数量/ $(\times 10^6)$	模型大小/MB	准确率/%	召回率/%	mAP@0.5/%
①	YOLOv11n	2.58	5.3	94.6	86.3	91.5
②	ADown	2.18	4.8	95.2	88.9	92.2
③	Backbone	2.24	4.6	95.8	87.4	92.5
④	Head	2.45	5.0	95.8	87.3	91.8
⑤	Backbone+Head	2.10	4.4	96.1	88.0	92.0

根据表 2 的数据,替换主干网络和头部网络中的模块后,模型在电枢外观缺陷识别方面的参数量相比其他两种方案分别降低了  $0.14 \times 10^6$  和  $0.35 \times 10^6$ 。同时,该方案下的模型大小相比其余两种方案分别降低了 0.2 和 0.6 MB。这是因为 OD-ADown 模块通过减少参数量来降低模型的复杂度,同时优化下采样过程。这不仅提高了模型的运行效率,还在减少参数量的同时提升了检测性能。与原始 YOLOv11n 网络模型相比,采用试验⑤的改进方案不仅让平均精度均值提升了 0.5%,还使模型的参数量降低了  $0.48 \times 10^6$ 。与原始 ADown 网络模型相比,采

用试验⑤的改进方法虽然使平均精度均值降低了 0.2%,但是准确率增加了 0.9%,参数量和模型大小降低了  $0.08 \times 10^6$ 、0.4 MB。

#### 4.3 不同位置替换 C3K2-MSPFA+OD-ADown 的影响

为降低因 C3K2-MSPFA 模块引起的参数量和模型大小增加等问题,在表 1 试验④的基础上引入 OD-ADown 模块,并分别针对主干网络、头部网络以及主干和头部网络整体进行验证,以探索降低参数量和模型大小的可能性,结果如表 3 所示。

表 3 C3K2-MSPFA+OD-ADown 不同位置替换方案对比

Table 3 Comparison of the results of C3K2-MSPFA+OD-ADown replacement programs at different locations

试验编号	网络结构	参数量/ $(\times 10^6)$	模型大小/MB	准确率/%	召回率/%	mAP@0.5/%
①	YOLOv11n	2.58	5.3	94.6	86.3	91.5
②	Backbone	2.39	6.8	95.4	88.7	92.6
③	Head	2.28	6.7	95.2	87.6	92.9
④	Backbone+Head	2.15	4.5	96.8	88.1	93.7

根据表 3 试验④的数据,采用 OD-ADown 模型在电枢外观缺陷识别方面的平均精度均值相比其他两种方案分别提高了 1.1% 和 0.8%。与此同时,该方案下的网络结构相比其它两种方案分别减少了  $0.24 \times 10^6$  和  $0.13 \times 10^6$  的参数量。与原始 YOLOv11n 网络模型相比,采用试验④的改进方案使平均精度均值提升了 2.2%,模型的参数量和模型大小降低了  $0.43 \times 10^6$  和 0.8 MB。因此,与表 1 试验④相比,采用表 3 试验④的方案不仅让平均精度均值提升了 0.3%,还使模型参数量和模型大小降低了  $0.48 \times 10^6$  和 0.9 MB。该试验验证了在 C3K2-MSPFA 模块基础上引入改进后的轻量化 OD-ADown 下采样模块以

降低参数量和模型大小的可行性,有效减少了因引入 C3K2-MSPFA 模块导致的模型参数量和模型大小增加问题。

#### 4.4 不同损失函数对模型的影响

为了弥补 Ciou 损失函数在检测任务中泛化性弱和收敛速度慢的问题,在表 3 试验④的基础上引入 Diou 损失函数,以提高模型精度并加快边界框回归速度。通过对比试验,结果如表 4 所示。

根据试验结果,Diou 损失函数的表现优于基础的 Ciou 损失函数。因在工业检测领域,召回率和平均精度均值是评估检测系统性能的关键指标,这类场景通常采

用“宁可错检,不可漏检”的严格检测策略,以确保潜在缺陷能够被有效识别和捕捉。与 CIoU 相比,DIoU 在召回率和平均精度均值上分别提升了 2.8% 和 0.5%,有效提升了模型的检测能力。

表 4 不同损失函数结果对比

Table 4 Comparison of the results of different loss functions

试验编号	网络模型	准确率/%	召回率/%	mAP@0.5/%
①	CIoU	96.8	88.1	93.7
②	EIoU	94.8	88.3	91.5
③	Inner-MDPIoU	95.8	90.2	92.5
④	ShapeIoU	96.4	85.4	92.6
⑤	DIoU	95.9	90.9	94.2

#### 4.5 消融试验

为验证各改进模块的有效性,本文设计了系统的

表 5 消融试验结果

Table 5 Result of ablation experiment

模型	C3K2-MSPFA	OD-ADown	DIoU	参数量/ $(\times 10^6)$	模型大小/MB	准确率/%	召回率/%	mAP@0.5/%
A	×	×	×	2.58	5.3	94.6	86.3	91.5
B	√	×	×	2.63	5.4	96.6	88.8	93.4
C	×	√	×	2.10	4.4	96.1	88.0	92.0
D	×	×	√	2.58	5.3	94.6	86.3	91.7
E	√	√	×	2.15	4.5	96.8	88.1	93.7
F	√	×	√	2.63	5.4	96.3	87.2	91.7
G	×	√	√	2.10	4.4	93.6	88.6	92.2
H	√	√	√	2.15	4.5	95.9	90.9	94.2

在模型 B 的基础上引入轻量化 OD-ADown 下采样模块得到模型 E,旨在解决因 C3K2-MSPFA 模块导致的参数量和模型大小增加问题。与模型 A 相比,模型 E 的参数量和模型大小分别降低了  $0.43 \times 10^6$  和 0.8 MB,同时平均精度均值提升了 2.2%。在此基础上,将原网络的损失函数替换为 DIoU 损失函数,得到模型 H。试验结果表明,采用 DIoU 损失函数在未引入任何额外参数、保持模型体积不变的条件下,有效提升了目标检测的整体精度。这证明了该改进在提升模型性能方面具有较高的参数效率。最终,通过模型 H 与模型 A 的对比结果表明,改进后的网络模型在识别准确率、召回率和平均精度均值上

消融实验,其结果如表 5 所示。所有实验均在相同的自建数据集上进行,以原始 YOLOv11n 模型作为性能基准(模型 A),模型 B、C、D 依次使用单个模块 C3K2-MSPFA、轻量化 OD-ADown 下采样模块和引入 DIoU 损失函数对网络进行重构及改进,以评估其渐进式贡献与最终的综合性能。试验结果表明,与原始算法相比,3 种改进方法均能在一定程度上提高模型的平均精度均值。其中,C3K2-MSPFA 模块的效果最为显著,尽管参数量和模型大小分别增加了  $0.05 \times 10^6$  和 0.1 MB,但平均精度均值提升了 1.9%。这证明了在特征提取阶段采用高效部分卷积和残差连接,即将输入特征与处理后的特征相加的改进方法能够有效保留原始信息并引入新的多尺度信息,从而提高模型的检测精度的方法是有效的。

分别提升了 1.3%、4.6% 和 2.7%。同时,模型参数量和模型大小分别降低了  $0.43 \times 10^6$  和 0.8 MB。此改进方案有效提升了微特机电枢表面缺陷的检测能力,并为满足移动端和嵌入式设备的部署需求提供了有效的技术支持。

#### 4.6 不同模型性能对比试验

为验证本文算法对微特机电枢缺陷检测的有效性,在自建的电枢缺陷数据集上,将本文算法与 Faster R-CNN、YOLOv5s、YOLOv8n、YOLOv10n、YOLOv11n、YOLOv12n、YOLOv13n 等模型进行了性能对比,实验结果如表 6 所示。

表 6 不同模型的性能对比

Table 6 Performance comparison of model

模型	参数量/ $(\times 10^6)$	浮点计算量/GFLOPs	模型大小/MB	准确率/%	召回率/%	mAP@0.5/%
Faster R-CNN	186.4	427.6	114.3	94.8	87.2	88.7
YOLOv5s	7.03	15.8	14.5	90.2	84.5	90.2
YOLOv8n	3.00	8.1	6.3	96.5	86.1	92.5
YOLOv10n	2.70	6.7	5.6	96.5	86.1	92.8
YOLOv11n	2.58	6.3	5.3	94.6	86.3	91.5
YOLOv12n	2.51	6.2	5.2	94.5	85.1	89.7
YOLOv13n	2.45	5.8	5.0	96.7	84.6	91.6
本文	2.15	6.6	4.5	95.9	90.9	94.2

可以看出,与 Faster R-CNN 相比较,本文提出的算法在准确率、召回率和平均精度均值上提升了 1.1%、3.7% 和 5.5%、但模型大小仅为 Faster R-CNN 的 3.94%。相比 YOLOv5s、YOLOv8n、YOLOv10n、YOLOv12n、YOLOv13n 轻量级网络,参数量分别降低了  $4.88 \times 10^6$ 、 $0.85 \times 10^6$ 、 $0.55 \times 10^6$ 、 $0.36 \times 10^6$  和  $0.30 \times 10^6$ ,模型大小降低了 10、1.8、1.1、0.7 和 0.5 MB,平均精度均值分别提高了 4.0%、1.7%、1.4%、4.5% 和 2.6%。改进算法相较于 YOLOv11n 算法,虽然增加了 0.3 GFLOPs 的计算量上,但准确率、召回率、平均精度均值分别提高了 1.3%、

4.6%、2.7%,模型大小和参数量相比于原模型分别降低了和 16.67% 和 15.09%。试验结果表明,与其他主流目标检测算法比较,本文提出的改进算法以最小的模型体积实现了较高的检测精度,准确率最高、参数量更低,更加方便移植应用,更适合微特电机电枢缺陷的实时目标监测。

图 7 所示为本文所改进的算法与原始 YOLOv11n 算法对微特电机电枢缺陷检测结果的对比。与原始 YOLOv11n 网络模型相比,本文所改进的 YOLOv11n 算法在检测效果上表现更佳。



图 7 模型检测效果对比

Fig. 7 Comparison of model detection result

## 4 结 论

为实现微特电机电枢表面缺陷的快速准确检测,本研究基于 YOLOv11n 模型进行改进,旨在提升微特电机电枢表面缺陷的检测精度,并寻求检测性能与模型复杂度之间的更优平衡。基于系统的数据集构建、算法设计与实验验证,得到如下结论。

1) 本文提出了一种基于 YOLOv11n 的微特电机电枢表面缺陷检测方法。通过设计基于高效的部分卷积和残差连接思想的 C3K2-MSPFA 模块,对原始 C3K2 模块进行重构;同时引入 OD-Conv 和 ADown 下采样,设计一种轻量化的 OD-ADown 下采样模块,有效减少了 C3K2-MSPFA 模块造成的参数冗余和计算复杂度。此外,将原损失函数替换为 DIoU,进一步提高了检测精度,且未额外增加参数量和计算复杂度。

2) 在自建数据集上进行消融试验和对比试验后,验证了改进后的算法能够在提升检测精度的同时降低参数量。本文算法在电枢外观缺陷数据集上实现了平均精度均值 94.2%、准确率 95.9%、召回率 90.9% 的检测性能,

同时参数量仅为  $2.15 \times 10^6$ ,模型权重大小仅为 4.5 MB。

3) 本文提出的模型也存在一定局限性。在恶劣的自动化生产环境中,其他设备的振动或灰尘导致镜头脏污,可能会使图像质量下降,从而引发漏检问题。针对这一问题,后续研究将考虑引入图像增强技术提升图像质量,降低漏检率。此外,未来将采集更多复杂生产场景下的图像数据,来扩充数据并优化训练,为微特电机电枢外观缺陷的快速精准检测提供更有力的支持。

## 参 考 文 献

- [1] 李勇,王杨,方夏,等. 基于改进 BiFPN 的微特电机电枢表面缺陷检测方法[J]. 机床与液压,2022,50(6): 1-8.  
LI Y, WANG Y, FANG X, et al. Micro-motor armature surface defect detection method based on improved BiFPN [J]. Industrial Control Computer, 2022, 50(6): 1-8.
- [2] 陈星寰,吴静静,安伟. 基于改进 RCF 模型的转子表面缺陷检测[J]. 传感技术学报,2023,36(4): 575-582.  
CHEN X H, WU J J, AN W. Defect detection using rotor image with improved RCF model [J]. Chinese

- Journal of Sensors and Actuators, 2023, 36 ( 4 ): 575-582.
- [ 3 ] 吴承俊,方夏,王杰,等.基于改进 ResNet 两阶段训练模型的转子焊锡缺陷检测[J].工业控制计算机,2023,36(4):115-116,119.  
WU CH J, FANG X, WANG J, et al. Rotor solder defect detection based on improved ResNet two stage training model[J]. Industrial Control Computer, 2023, 36(4):115-116,119.
- [ 4 ] FUKUSHIMA K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position [ J ]. Biological Cybernetics, 1980, 36(4):193-202.
- [ 5 ] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [ J ]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [ 6 ] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [ C ]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [ 7 ] GIRSHICK R. Fast R-CNN [ C ]. 2015 IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [ 8 ] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6):1137-1149.
- [ 9 ] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]. 2017 IEEE International Conference on Computer Vision, 2017:2961-2969.
- [ 10 ] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [ EB/OL ]. 2015-06-08 [ 2023-12-01 ]. [https:// doi. org/ 10. 48550/arXiv. 1506. 02640](https://doi.org/10.48550/arXiv.1506.02640).
- [ 11 ] REDMON J, FARHADI A. YOLOv3: An incremental improvement [ EB/OL ]. 2018-04-08 [ 2023-12-01 ]. [https:// doi. org/10. 48550/arXiv. 1804. 02767](https://doi.org/10.48550/arXiv.1804.02767).
- [ 12 ] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [ EB/OL ]. 2020-04-23 [ 2023-12-01 ]. [https:// doi. org/ 10. 48550/arXiv. 2004. 10934](https://doi.org/10.48550/arXiv.2004.10934).
- [ 13 ] JOCHER G. YOLOv5 by ultralytics [ EB/OL ]. 2020-06-19 [ 2023-12-01 ]. [https:// github. com/ultralytics/ yolov5](https://github.com/ultralytics/yolov5).
- [ 14 ] LI C, LI L, JIANG H, et al. YOLOv6: A single-stage object detection framework for industrial applications [ EB/OL ]. 2022-09-07 [ 2023-12-01 ]. [https:// doi. org/ 10. 48550/arXiv. 2209. 02976](https://doi.org/10.48550/arXiv.2209.02976).
- [ 15 ] 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 Conference on Computer Vision and Pattern Recognition, 2023:7464-7475.
- [ 16 ] 刘博文,徐卫平,徐钦,等.基于改进 YOLOX 的猕猴桃分类识别与空间定位[J].国外电子测量技术,2024,43(4):133-142.  
LIU B W, XU W P, WU Q, et al. Classification identification and spatial localization of kiwifruit based on the improved YOLOX [ J ]. Foreign Electronic Measurement Technology, 2024,43(4):133-142.
- [ 17 ] 刘祉桑,张晓玲,刘珂宇,等.基于改进 YOLOv5 的钢材表面缺陷检测[J].兵工自动化,2024,43(12):30-34.  
LIU ZH SH, ZHANG X L, LIU K Y, et al. Steel surface defect detection based on improved YOLOv5 [ J ]. Ordnance Industry Automation, 2024, 43(12):30-34.
- [ 18 ] 杜佳奇,肖杰,朱高义,等.基于改进 YOLOv6 模型的微特电机电枢表面缺陷检测[J].组合机床与自动化加工技术,2024(9):108-112,117.  
DU J Q, XIAO J, ZHU G Y, et al. Modular machine tool & automatic manufacturing technique [ J ]. 2024 ( 9 ):108-112,117.
- [ 19 ] 王天洋,刘路,王太勇,等.基于改进 YOLOv8s 的轻量级 PCB 缺陷检测算法[J].电子测量与仪器学报,2025,39(3):44-52.  
WANG T Y, LIU L, WANG T Y, et al. Light weight PCB defect detection algorithm based on improved YOLOv8s [ J ]. Journal of Electronic Measurement and Instrumentation, 2025,39(3):44-52.
- [ 20 ] 金莉莉,魏利胜.基于改进 YOLOv10n 的太阳能电池板缺陷检测方法[J/OL].重庆工商大学学报(自然科学版),1-9 [ 2025-03-01 ]. [http://kns. cnki. net/kcms/ detail/50. 1155. N. 20241018. 1447. 006. html](http://kns.cnki.net/kcms/detail/50.1155.N.20241018.1447.006.html).
- JIN L L, WEI L SH. Solar panel defect detection method based on improved YOLOv10n [ J/OL ]. Journal of Chongqing Technology and Business University ( Natural Science Edition ), 1-9 [ 2025-03-01 ]. [http://kns. cnki. net/kcms/ detail/50. 1155. N. 20241018. 1447. 006. html](http://kns.cnki.net/kcms/detail/50.1155.N.20241018.1447.006.html).
- [ 21 ] 李春晖,吕岩,孟祥来,等.基于 YOLOv8 的油气管道漏磁检测缺陷智能识别技术研究[J].仪器仪表学报,2025,46(2):247-254.  
LI CH H, LYU Y, MENG X L, et al. Research on intelligent defect recognition in oil and gas pipeline magnetic flux leakage detection based on YOLOv8 [ J ].

- Chinese Journal of Scientific Instrument, 2025, 46(2): 247-254.
- [22] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020:1580-1589.
- [23] CHEN J, KAO S, HE H, et al. Run don't walk: Chasing higher FLOPS for faster neural networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023:12021-12031.
- [24] WANG C Y, YE H I, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information [C]. European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2024:1-21.
- [25] LI CH, ZHOU AO J, YAO AN B. Omni-dimensional dynamic convolution [J]. ArXiv preprint arXiv: 2209.07947, 2022.
- [26] 伍锡如, 梁诗意. 改进 YOLOv8 的密集人群口罩检测算法 [J]. 电子测量技术, 2025, 48(1): 55-63.  
WU X R, LIANG SH Y, et al. Improved YOLOv8 for mask detection in dense [J]. Electronic Measurement Technology, 2025, 48(1): 55-63.
- [27] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [28] LI J, LIU S, CHEN D, et al. APD-YOLOv7: Enhancing sustainable farming through precise identification of agricultural pests and diseases using a novel diagonal difference ratio IOU loss [J]. Sustainability, 2024, 16(20): 8855.

### 作者简介



**吴凡凡**, 2023 年于西安汽车职业大学获得学士学位, 现为陕西理工大学硕士研究生, 主要研究方向为计算机视觉。  
E-mail: 2728242761@qq.com

**Wu Fanfan** received his B. Sc. degree from Xi'an Automotive Vocational University in 2023. He is now a M. Sc. candidate at Shaanxi University of Technology. His main research interest includes computer vision.



**张鹏超** (通信作者), 1999 年于陕西工学院获得学士学位, 2005 年于西北工业大学获得硕士学位, 现为陕西理工大学教授, 主要研究方向为智能控制理论与应用、计算机视觉。  
E-mail: snutzpc@126.com

**Zhang Pengchao** (Corresponding author) received his B. Sc. degree from Shaanxi Institute of Technology in 1999, and M. Sc. degree from Northwestern Polytechnical University in 2005. He is now a professor at Shaanxi University of Technology. His main research interests include intelligent control theory and applications, as well as computer vision.