

# 融合双瓶颈结构的轴承外圈缺陷检测算法<sup>\*</sup>

吴飞 范鹏主 马一凡

(武汉理工大学机电工程学院 武汉 430070)

**摘要:** 针对轴承外圈表面缺陷检测中存在的缺陷尺度变化大、纹理相似与分布密集等问题,以及现有检测模型结构复杂、计算量与检测精度差的挑战,提出一种轻量高效的轴承缺陷检测算法 DWA-YOLO。首先,设计了一种即插即用的轻量化双瓶颈结构模块 DBM,以有效降低模型复杂度并强化模型对于不同尺度特征的提取能力。其次,在网络主干中引入多尺度特性的小波卷积 WTConv 作为下采样算子,通过扩大模型的感受野与利用多尺度分析特性来捕捉图像的细节和纹理信息,增强了模型对纹理与噪声的抗干扰能力和上下文信息理解能力,从而提升了整体检测精度。此外,本文设计了联合损失函数 Alpha-MPDIoU,利用幂变换机制提高边界框的定位精度与解决检测多框问题。最后,采用辅助检测头训练策略,加快模型的收敛速度并增强了检测能力。实验结果表明,DWA-YOLO 相比基线模型在 mAP 精度上提升 3.5%,模型参数量为 2.6 M,计算量为 7.4 GFLOPs。改进后的模型不仅提高轴承缺陷识别能力,还降低网络复杂度,更加适用于工业现场对轴承外圈表面缺陷的检测需求。

**关键词:** 缺陷检测;小波卷积;双瓶颈结构;Alpha-MPDIoU

**中图分类号:** TN-9    **文献标识码:** A    **国家标准学科分类代码:** 520.60

## Algorithm for detecting outer ring defects of bearings using a dual bottleneck structure fusion

Wu Fei Fan Pengzhu Ma Yifan

(College of Mechanical and Electrical Engineering, Wuhan University of Technology, Wuhan 430070, China)

**Abstract:** A lightweight and efficient bearing defect detection algorithm DWA-YOLO is proposed to address the challenges of large scale variation, similar texture, and dense distribution of defects in the surface defect detection of bearing outer rings, as well as the complexity of existing detection model structures, poor computational complexity, and detection accuracy. Firstly, a plug and play lightweight dual bottleneck structure module DBM was designed to effectively reduce model complexity and enhance the model's ability to extract features at different scales. Secondly, the wavelet convolution WTConv with multi-scale characteristics is introduced as a downsampling operator in the network backbone. By expanding the receptive field of the model and utilizing the multi-scale analysis characteristics to capture the details and texture information of the image, the model's anti-interference ability against texture and noise and its ability to understand contextual information are enhanced, thereby improving the overall detection accuracy. In addition, this article designs a joint loss function Alpha-MPDIoU, which utilizes power transformation mechanism to improve the localization accuracy of bounding boxes and solve the problem of detecting multiple boxes. Finally, the use of auxiliary detection head training strategy accelerates the convergence speed of the model and enhances its detection capability. The experimental results show that DWA-YOLO improves mAP accuracy by 3.5% compared to the baseline model, with a model parameter size of 2.6 M and a computational complexity of 7.4 GFLOPs. The improved model not only enhances the ability to identify bearing defects, but also reduces network complexity, making it more suitable for the detection needs of bearing outer ring surface defects in industrial sites.

**Keywords:** defect detection; wavelet convolution; dual bottleneck structure; Alpha-MPDIoU

## 0 引言

轴承是工业领域中的关键组件,主要用于支撑旋转机

械部件并减少运动过程中的摩擦。在汽车、航空和风电等领域,轴承发挥着不可或缺的作用。轴承的外圈承受径向和轴向载荷,支撑和固定轴承位置,保证转动精度。然而,

轴承在生产和运输过程中常会出现刮伤、凹槽等缺陷。这些表面质量问题不仅会影响机械设备的正常运转,严重时还可能导致外圈断裂,引发严重的生产事故。目前,用于检测轴承外圈表面的质量的方法有 3 种:人工目测法,是依靠人工进行观察轴承外表面是否存在明显缺陷。该检测效率低、漏检、经验依靠性强、人为因素影响大等诸多缺点。再则是无损检测方法,如:超声检测、磁粉检测等。虽然这种方法检测灵敏度高、检测范围广及结果可靠,但是存在检测速度慢、成本高、无法实现实时在线检测等缺陷。最后,则是通过计算机视觉、图像处理、图像分析等技术对轴承外圈进行检测。该方法的检测速度快、检测精度高、效果稳定、无损伤,是目前最先进的也是使用最广泛的轴承外圈表面缺陷检测方法<sup>[1]</sup>。

近年来,随着人工智能和深度学习的进步,科研人员开始应用这些技术进行工业缺陷检测。当前的目标检测模型主要分为两类:以 Faster R-CNN<sup>[2]</sup> 代表的两阶段和 YOLO<sup>[3]</sup> 代表的单阶段目标检测模型。鉴于工业环境对效率的要求,研究人员更倾向于优化与使用单阶段检测算法。例如,王孟宇等<sup>[4]</sup>提出了一种改进的 YOLOv8 钢材表面缺陷检测算法,引入了自适应下采样权重增强对缺陷信息的关注,并引入可编程梯度信息模块来整合不同尺度特征,提高模型对不同尺度敏感性。赵洋等<sup>[5]</sup>提出一种基于改进 YOLOv8n 的钢材表面缺陷检测算法,通过引入全维动态卷积以增强特征捕捉能力,再使用 APFN 改善特征融合,最后使用动态非单调损失函数优化边界框,以提升模型对于钢材的检测能力。Zhao 等<sup>[6]</sup>提出一种基于 YOLOv5 的轴承缺陷检测算法,通过在特征提取阶段采用 ResC2Net 与模型融合部位采用 PConv 以增加网络提取能力和网络深度以捕获缺陷详细信息。李亚东等<sup>[7]</sup>提出一种基于 YOLOX 网络的轴承缺陷小目标检测算法,首先在骨干网络引入了特征提取更加细粒度的 Res2Block 模块,增加隐性小目标的区域特征。又在后处理阶段使用了 Focal Loss 损失函数,增加模型对于正样本的学习能力。郎德宝等<sup>[8]</sup>提出 MFA-YOLOv8 轴承检测算法,通过引入多尺度特征卷积模块 EMFC 模块以捕获不同尺度的信息特征,又引入焦点调制模块 FM,用于提升模型对于缺陷目标的表征能力与降低模型参数量。姚景丽等<sup>[9]</sup>提出一种改进 YOLOv8 的轻量级轴承缺陷检测算法,首先,通过添加 SimAM 注意力机制以提升模型对于轴承表面缺陷特征提取,接着在颈部网络中嵌入 SCConv 以提升模型小目标检测能力和降低模型参数。

尽管上述研究在一定程度上提升模型检测精度,但仍存在诸多不足。首先,实际的工业生产线对模型的参数量和计算量均有要求,而现有模型虽降低模型参数,但计算量反而增加,没有考虑计算量对于部署与使用的影响。其次,工业轴承的缺陷图像通常具有形状不规则、尺度变化大以及纹理特征相似的特点,使得准确识别缺陷目标变得困难。

虽然上述模型通过多尺度卷积模块等方法提升不同尺度信息捕获能力,但捕获能力提升有限且未能解决缺陷图像纹理与噪声的干扰。此外,上述模型尽管对小目标检测进行了不同程度的改进,比如添加小目标检测头、添加注意力机制模块等,但这些改进不能解决小目标的密集分布与遮挡问题导致漏检和误检,并且小目标检测头和注意力机制会增加模型复杂程度与计算量不利于模型部署使用。最后,工业缺陷中大多数缺陷目标的预测边界框和真实边界框具有相同的纵横比,这削弱了模型的边界框回归能力,从而降低了模型对于缺陷目标的定位精度,并且上述改进后的模型检测时会存在多框与漏检问题。

针对上述问题,结合工业缺陷检测的实时与高精度检测需求,本文基于 YOLOv8 模型提出了一种轴承外圈表面缺陷检测算法 DWA-YOLO,并且从以下方面进行改进:

1) 设计了一种双瓶颈结构模块 (dual bottleneck module, DBM),应用于主干网络的特征提取阶段。该模块不仅有效提升对轴承缺陷图像特征的捕捉能力,解决原有 C2f 模块在此方面的不足,并大幅减少主干网络的参数量和计算复杂度。

2) 在主干网络中引入 WTConv<sup>[10]</sup>,有效扩大模型感受野范围与抑制纹理特征对于缺陷目标识别干扰,提升模型对于多尺度与纹理复杂缺陷的检测能力,同时减少模型的参数。

3) 使用 Alpha-MPDIoU<sup>[11-12]</sup> 作为边界框回归损失函数,有效解决预测框与真实边界框具有相同纵横比时定位问题,并通过引入幂变换机制有效解决高 IOU 时的检测框重复问题。

4) 使用辅助检测头<sup>[13]</sup>策略,在不添加任何参数与计算量的条件下,获得了更多的浅层信息与细粒度特征,加快模型收敛与网络检测能力且利于部署。

## 1 YOLOv8 算法

YOLO<sup>[14]</sup> 系列算法代表了单阶段目标检测技术中最为成熟且广受认可的经典案例。YOLOv8 不仅继承并发扬了前代算法的优点,还扩展了其应用范围,支持多种视觉任务,如目标检测与图像分割。在目标检测方面,YOLOv8 采用了多尺度特征融合的检测方式,以提高检测精度。相较于 YOLOv5, YOLOv8 引入了更为高效的解耦头设计,并将传统的 Anchor-Based 方法替换为 Anchor-Free 方法。此外, YOLOv8 还采用了一种梯度流更丰富的 C2f 模块,以增强特征表达能力。在损失函数的设计上, YOLOv8 实现了动态的正负样本分配机制,即通过分类与回归的加权分数来选择正样本。同时,在损失函数中引入了分布焦点损失 (distribution focal loss),以更好地处理类别不平衡问题,并提升模型的整体性能。

## 2 DWA-YOLO 算法

本文基于 YOLOv8 算法的最小模型 n,提出轴承外圈

缺陷检测算法 DWA-YOLO, 以提升轴承缺陷检测的精度与降低模型复杂度, 其模型结构如图 1 所示。通过在主干网络中引入了 WTConv 模块, 能够在减少参数情况下有效扩大模型感受野, 增强模型对于分布密集的轴承表面缺陷与多尺度的缺陷检测能力。此外, 本文设计了一种轻量化的双瓶颈结构 DBM 模块, 能在提高主干网络对于图像缺

陷的特征提取能力基础上降低模型计算量和参数量。其次, 本文在训练策略中使用了可以提供更丰富梯度信息的辅助检测头, 可以有效提升网络检测能力的同时不增加模型大小和模型复杂度。最后, 使用联合损失函数 Alpha-MPDIoU 来提高边界框的回归能力, 从而提升缺陷目标的定位能力与加快网络收敛。

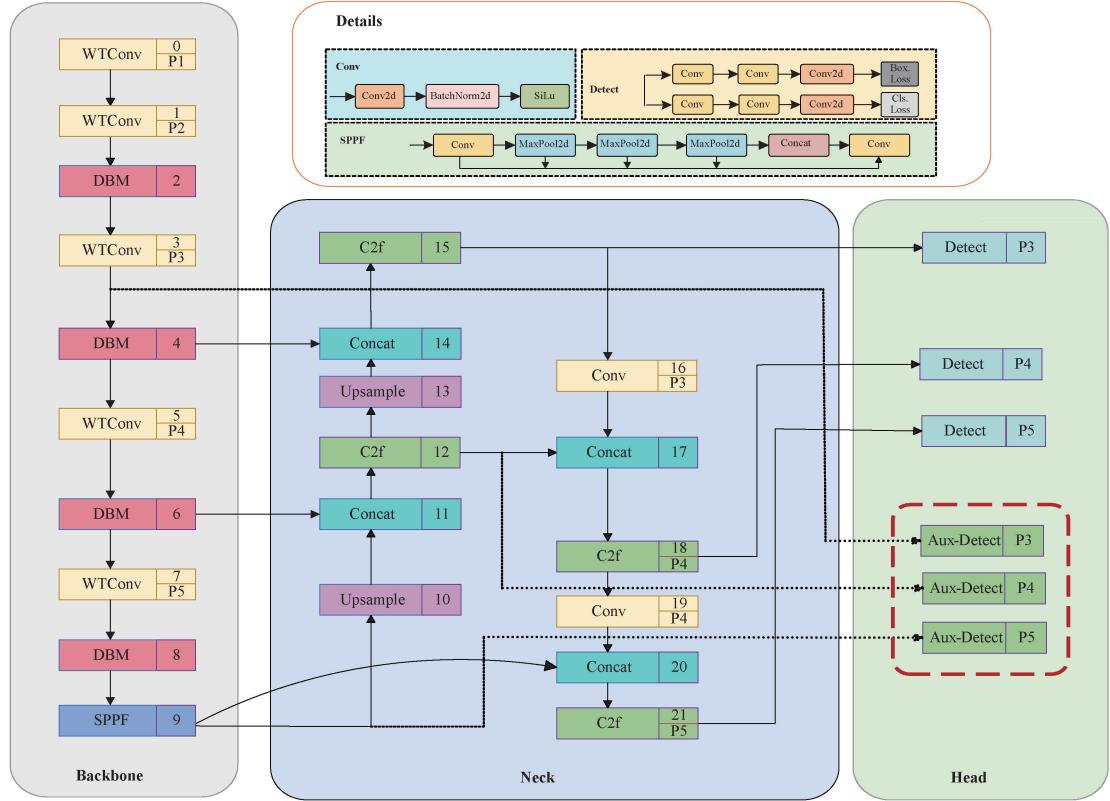


图 1 DWA-YOLO 网络结构

Fig. 1 DWA-YOLO network structure

## 2.1 双瓶颈结构

由于轴承表面的损伤和缺陷图像样式繁杂, 并且往往带有各种复杂的背景与干扰信息。这导致 C2f 模块在提取轴承缺陷能力上表现不足。原有的 C2f 模块仅对经过空间维度拆分后的特征图的一半进行特征学习, 从而限制了模型从完整图像中捕捉信息的能力, 一定程度上减少了卷积神经网络在特征提取上的表征能力。基于此, 本文提出了具有高性能特征提取能力的双瓶颈模块。该模块由两个并行的瓶颈分支组成, 每个分支都包含瓶颈结构。首先, 输入特征图通过一个卷积层后被均分成两部分, 这两部分分别进入两个瓶颈分支进行处理。同时, 经过拆分后的特征会进行融合与池化操作生成用于增强特征的权重因子。最后, 两个分支的结果与初始特征逐元素相加。最后, 通过卷积调整通道数后再与初始输入特征融合, 其结构如图 2(a)所示。

其次, 考虑到 DBM 模块参数过多和提升改进后模型的综合性能, 本文采用了 GhostNet<sup>[15]</sup> 中的 GhostConv 与

GhostBottleneck 模块来减少实际需要训练的参数数量。根据引入 GhostBottleneck 模块数量, 本文提出 3 种方式的双瓶颈结构, 分别如图 2(b)~(d) 所示。图 2(b) 展示了没有使用 Ghostbottleneck 时的双瓶颈结构。图 2(c) 展示了在其中一个分支中使用 Ghostbottleneck 的情况。图 2(d) 展示了在两个分支中均使用 Ghostbottleneck 的结构, 其利用 Ghostbottleneck 的优势, 实现了更高的参数效率。通过对比上述 3 种方式的双瓶颈结构, 本文将研究 Ghostbottleneck 对 DBM 模块的性能影响与挑选出最适合轴承表面缺陷检测的双瓶颈结构。

Ghostconv 是由华为诺亚实验室提出的一种轻量化卷积模块, 能够在保持精度的前提下有效减少特征图的冗余, 从而减少模型计算量和模块的复杂程度。如图 3 所示, GhostConv 模块首先通过一个输出较少的基础卷积层生成一组基础特征图, 利用成本较低的线性变换操作基于这组基础特征图生成额外的“幽灵”特征图。特征图在通道维度上堆叠在一起形成完整的特征图集合。既减少计

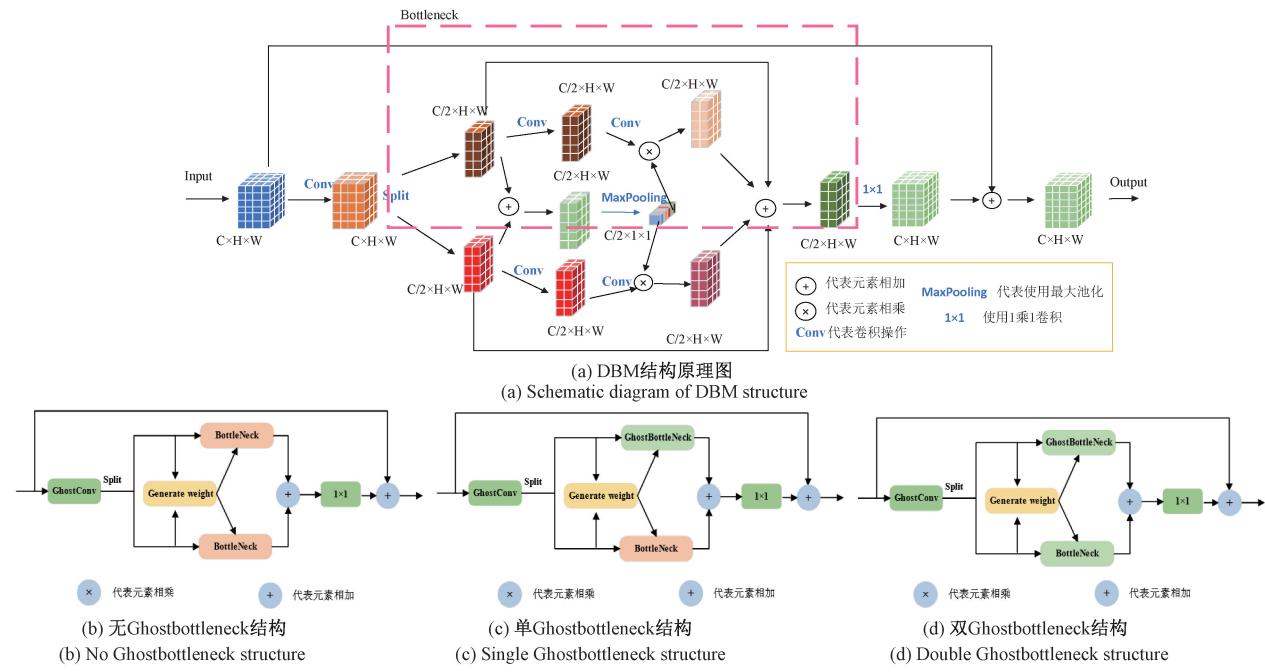


图 2 双瓶颈结构模块结构

Fig. 2 Structure of the double-bottleneck structure module

算量又扩展模型的表达能力,从而有效地解决了特征图冗余问题。Ghostconv 卷积首先通过普通卷积操作生成一部分的本征特征,接着再通过线性变换  $\phi_1 - \phi_n$  生成 Ghost 特征,最终在通道维度进行堆叠生成完整的特征图。如图 4 所示,Ghostbottleneck 模块由两个 Ghostconv 模块堆叠而成。第 1 个 Ghostconv 模块用于扩展通道以增强网络表征能力,而第 2 个则用于减少通道数,以便于残差连接。在第 2 个模块之后不使用激活函数,而在其他层中使用 Batchnorm 和 RELU 激活函数。

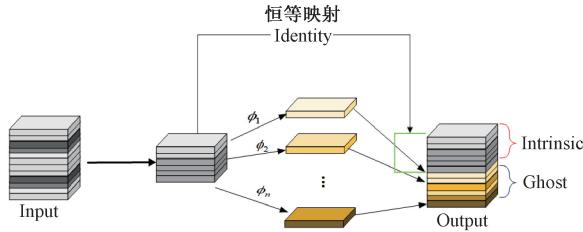


图 3 Ghostconv 结构

Fig. 3 Ghostconv structure

## 2.2 WTConv

在卷积神经网络中,感受野定义为特征图上的某一元素所对应的输入图像区域的大小。扩大感受野能够增强模型的检测能力,特别是在处理复杂场景的任务,如目标定位和像素级分类时,这种增强尤为显著。然而,现有的扩大感受野的方法往往伴随着过度参数化的问题,这不仅增加了模型的复杂度,也提高了计算需求。此外,这些方法在接近全局感受野时容易遭遇性能上限与饱和。

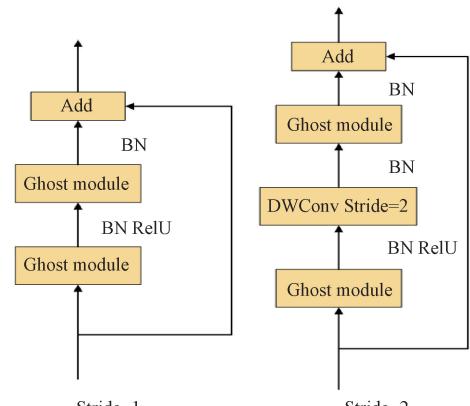


图 4 GhostBottleNeck 结构

Fig. 4 GhostBottleNeck network structure

为了解决上述问题,WTConv 通过小波变换来扩大感受野,与单纯扩大卷积核内核大小来扩大感受野的方式相比,WTConv 使用极少的参数就达到相同的感受野区域,并且避免了全局感受野的上限问题。因此,WTConv 能在有效提升网络拟合与抗干扰能力的同时,减少模型的网络参数与复杂度。如图 5 所示,WTConv 利用小波变换对输入进行滤波和降采样,将输入的低频和高频内容分离,然后在不同频率图上执行小核深度卷积,最后使用逆小波变换(inverse wavelet transform, IWT)构建输出。具体来说,WTConv 对每个输入通道进行二维小波变换,得到高频与低频子带。对于每个高频子带,会在进行一维的小波变换得到低频分量和水平与对角的高频分量。

$$[X_{LL}, X_{LH}, X_{HL}, X_{HH}] = \text{Conv}([f_{LL}, f_{LH}, f_{HL}, f_{HH}], X) \quad (1)$$

其中,  $\text{Conv}$  代表卷积运算,  $f_{LL}$  是低通滤波器,  $f_{LH}, f_{HH}, f_{HL}$  是一组高通滤波器。 $X$  代表输入图像,  $X_{LL}$  则是  $X$  的低频分量,  $X_{LH}, X_{HH}, X_{HL}$  则是水平、垂直和对角的高频分量。这 4 个滤波器形成了一组正交基, 通过小波逆变换, 即转置卷积得到式(2)。接着通过递归分解低频分量来得到级联小波分解, 分解每一级如式(3)所示。其中  $X_{LL}^{(i)} = X$ ,  $i$  表示当前级别。

$$X = \text{Conv} - \text{transposed}([f_{LL}, f_{HL}, f_{LH}, f_{HH}], [X_{LL}, X_{LH}, X_{HL}, X_{HH}]) \quad (2)$$

$$X_{LL}^{(i)}, X_{LH}^{(i)}, X_{HL}^{(i)}, X_{HH}^{(i)} = \text{WT}(X_{LL}^{(i-1)}) \quad (3)$$

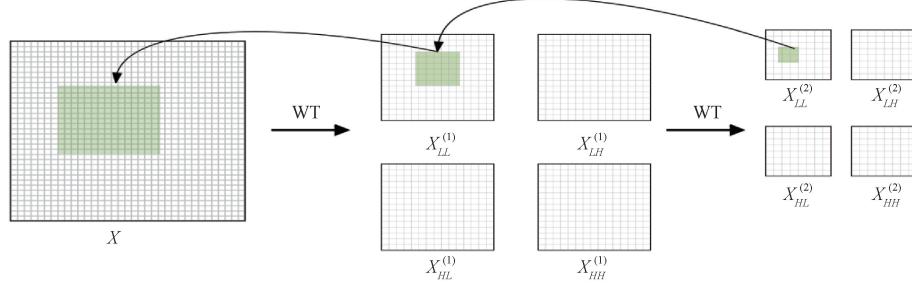


图 5 小波卷积原理图

Fig. 5 Schematic diagram of wavelet convolution

### 2.3 联合损失函数

在轴承表面缺陷识别中, 经常出现预测框与边界框具有相同的纵横比, 但宽度和高度值完全不同的情况, 基线模型的损失函数 ClIoU 无法对这种情况进行优化, 导致模型的泛化性和鲁棒性降低。而 MPDIoU 损失函数通过最小化预测真实边界框之间的左上和右下点距离, 能够有效解决这一问题。

$$\begin{cases} d_1^2 = (x_1^{prd} - x_1^{gt})^2 + (y_1^{prd} - y_1^{gt})^2 \\ d_2^2 = (x_2^{prd} - x_2^{gt})^2 + (y_2^{prd} - y_2^{gt})^2 \end{cases} \quad (4)$$

$$IoU = \frac{I}{U} \quad (5)$$

$$MPDIoU = IoU - \frac{d_1^2}{h^2 + w^2} - \frac{d_2^2}{h^2 + w^2} \quad (6)$$

其中,  $d_1^2, d_2^2$  分别为预测框与真实框左上角和右下角距离平方。 $I$  为边界框的交集,  $U$  为边界框的并集。 $h, w$  分别为检测图像的高度和宽度。

$\text{Alpha} - \text{IoU}$  是一种改进的  $\text{IoU}$  损失函数方法, 通过引入幂变换(如  $\text{IoU}^\alpha$ )来优化边界框回归精度。其中  $\alpha$  为可调参数, 能够灵活调整不同  $\text{IoU}$  值的权重, 从而更有效地处理高交并比与低交并比样本。这种方法增强了对非重叠或部分重叠边界框的梯度信息, 提升了模型在各种场景下的回归准确性。通过调整  $\alpha$  值,  $\text{Alpha} - \text{IoU}$  能够在特定应用中进一步优化边界框预测性能。本文在  $\text{MPDiou}$  损失基础上引入了  $\text{Alpha} - \text{IoU}$  的方法, 并且幂

这一过程将卷积操作与频率分量分离, 再用小卷积核在原始更大的区域中操作, 使感受野实现指数级别的增长, 且无需显著增加参数量。通过分离高频和低频信息, 使小核卷积在各自频率分量上更加高效。特别对低频分量的强化响应, 使得模型对形状等低频信息的捕捉能力增强。并且, 得益于低频信息的捕捉能力, 其在处理低频噪声和分布外数据(如模糊、像素化等腐蚀性干扰)时表现出更好的鲁棒性。这些特点使得小波卷积在处理低频噪声、纹理复杂以及多尺度目标变换的场景表现优异。因此, WTConv 能有效忽视图像纹理带来的干扰, 更加关注于检测对象的形状特征, 有助于提高模型的泛化能力。

变换系数  $\alpha = 3$ 。故本文边界框回归损失函数  $\text{Alpha} - \text{MPDIoU}$  如下:

$$\begin{aligned} L_{IoU} &= 1 - IoU \\ L_{\alpha-IoU} &= 1 - IoU^\alpha \end{aligned} \quad (7)$$

$$L_{\alpha-MPDIoU} = 1 - MPDIoU^\alpha = 1 - \left( IoU - \left( \frac{d_1^2}{h^2 + w^2} \right) - \left( \frac{d_2^2}{h^2 + w^2} \right) \right)^\alpha \quad (8)$$

### 2.4 辅助检测头

在轴承表面缺陷中存在着小目标缺陷, 如凹槽等。然而, 由于下采样操作会导致特征图的尺寸和分辨率降低, 从而丢失了一些重要的细微信息。为了解决这个问题, 本文引入辅助检测头(Auxiliary Head)的策略。在训练过程中, 辅助检测头可以提取更多浅层信息, 得到细粒度的特征图, 加速模型收敛和提高小目标的检测能力。同时, 辅助分支与主分支合并计算模型损失, 利用更丰富的梯度信息提升网络检测能力, 同时降低过拟合风险。其次, 辅助检测头只在训练过程中使用, 训练结束后会删除辅助检测头的分支, 因此在模型之后的推理过程中不会增加任何额外的计算负担或部署压力。假设  $\alpha$  为辅助检测头计算损失比例, 则带有辅助检测头的总损失如式(9)所示。

$$LOSS_{total} = \alpha LOSS_{Aux-head} + (1 - \alpha) LOSS_{Main} \quad (9)$$

### 3 实验

#### 3.1 实验环境与数据集

本文的实验配置环境如表 1 所示,所采用的基础模型为 YOLOv8n, 优化器选用随机梯度下降法(stochastic gradient descent, SGD), 初始学习率设为 0.000 1, 动量系数为 0.937, L2 正则化系数为 0.000 5, 训练图像的尺寸设定为  $640 \times 640$  像素, 总训练轮次为 300 个周期(epochs), 批处理大小(batch size)设置为 16; 为了定量评估改进后的 YOLOv8n 模型的综合性能, 本研究采用了以下评价<sup>[16]</sup>指标: 通过精确率(precision, P)、召回率(recall, R)、平均精度(average precision, AP)以及平均精度均值(mean average precision, mAP)来衡量检测精度, 具体地, mAP50(即 IoU 阈值为 0.5 时各类别 AP 的均值)和 mAP50:95(即 IoU 阈值从 0.50~0.95 每隔 0.05 取值所对应的 mAP 的平均值)被选作主要的平均精度衡量指标, 而通过参数量(Parameters)、每秒帧数(frames per second, FPS)以及模型的浮点运算次数(gflops)来评估模型的速度和复杂度, 上述 AP 与 mAP 的计算公式分别如式(10)和(11)所示。

$$AP = \int_0^1 P(R) dR \quad (10)$$

$$mAP = \frac{\sum_{i=0}^n AP(i)}{n} \quad (11)$$

表 1 实验环境

Table 1 Experimental environment

实验环境	配置
操作系统	Ubuntu20.04
GPU 型号	NVIDIA GeForce RTX 4090(24 GB)
CPU 型号	12 vCPU Intel(R) Xeon(R) Platinum 8352V CPU @ 2.10 GHz
深度学习框架	CUDA11.8+Pytorch1.12.0

本文所使用数据集来源于工业现场采集的真实轴承缺陷图像, 缺陷种类分为: 擦伤、凹槽、划痕 3 个类别。原始

数据集中包含 1 350 张图片。为了提升模型的鲁棒性和泛化能力, 本文采用了多种数据增强方法来模拟实际工业环境中的光照变化、图像采集角度和背景噪声等因素, 将数据集扩充至 4 050 张图像。具体的数据增强方法包括: 图像旋转(0°、90°、180°、270°), 以增加模型对不同视角下缺陷的识别能力; 随机亮度调整(亮度调整范围为 0.5~1.2), 以模拟不同光照条件下的图像效果; 椒盐噪声添加(噪声比例范围为 0.01~0.05), 以模拟实际工业环境中可能存在的背景噪声; 随机裁剪(裁剪后的图像面积保持在原图的 80%~100%), 以增加模型对局部特征的敏感性。数据集按照 8:1:1 的比例划分为训练集、验证集和测试集, 分别包含 3 240、405 和 405 张图像。轴承缺陷及其数据集的抽样图像如图 6 所示。

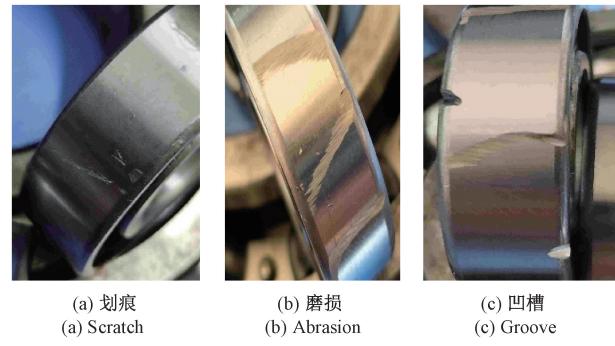


图 6 数据集抽样图

Fig. 6 Sampling plot of the dataset

#### 3.2 双瓶颈结构实验

作为模型特征提取的核心部分, 网络骨干对于提升整体性能至关重要。为了研究不同模式下 DBM 模块对模型表现的影响, 本实验将经过改进的 DBM 模块集成到了原有的骨干网络中。根据所采用 Ghostbottleneck 的数量差异, 本文定义了 3 种变体: YOLOv8-D0、YOLOv8-D1 和 YOLOv8-D2。实验结果如表 2 所示, 当使用双 Ghostbottleneck 结构时, DBM 能够显著降低模型的复杂度及计算需求; 其中, YOLOv8-D2 相比基准 YOLOv8n 减少了 23.3% 的参数量。然而, 由于这种过度轻量化设计弱化了骨干网的特征表示能力, 导致 mAP 仅微升 0.1%。

表 2 不同模式下 DBM 模块对比

Table 2 Comparison of DBM modules in different modes

模型	mAP@0.5/%	AP@0.5/%			Params/M	GFLOPS
		Grooves	Abrasions	Scratches		
YOLOv8n	86.2	87.1	88.3	83.1	3.0	8.1
YOLOv8n-D0	88.8	89.9	89.0	87.4	3.3	9.4
YOLOv8n-D1	87.8	89.7	88.6	85.2	2.7	7.7
YOLOv8n-D2	86.3	88.1	88.0	83.3	2.3	6.8

另一方面, YOLOv8-D0 通过引入双瓶颈架构大幅增

强了特征捕捉效率, 实现了 2.6% 的 mAP 增长。不过, 这

也带来了负面效应,即模型尺寸膨胀了16%,增加了额外的冗余参数,从而不利于实际部署。相比之下,YOLOv8-D1在mAP提升了1.6%的同时,还减少了9.8%的计算负担以及6.6%的参数规模。

综上所述,考虑到模型综合性能,本文最终选取了YOLOv8-D1方案来优化原始模型。此方法不仅提高了识别准确性,而且通过减少模型参数有效地提升了整体效率。

### 3.3 不同位置的感受野对比实验

本小节将探究在模型不同部位引入WTConv对模型感受野大小的影响。本实验分别对基础网络的整体部分、骨干网络以及颈部网络的下采样卷积模块进行替换,对应的模型依次命名为YOLOv8-A、YOLOv8-B、YOLOv8-N,实验结果如表3所示。同时,为了更清晰地展示感受野对模型检测精度的影响,本节将采用RepLKNet<sup>[17]</sup>的感受野

可视化方法,生成不同模型的感受野的可视化图像,可视化结果如图7所示。整体网络得到替换之后,得益于WTConv的少参数,模型参数相比于基线模型降低了20%,但过度的轻量化破坏了原有网络的结构特征融合能力,相比于只在骨干部分和颈部部分引入WTConv,mAP分别降低了0.8%和0.6%,模型的表征能力表现更差。感受野可视化图也印证了这一结果,颈部部分和骨干引入WTConv的感受野明显大于基础模型和整个网络都引入WTConv的感受野。其次,通过对比在颈部和骨干部分引入WTConv实验结果,前者虽然能扩大感受野大小,但是WTConv的少参数弱化了模型的特征融合与上下文信息整合能力,导致凹槽这类数量多,目标小的缺陷识别能力变差。因此,本文选择在网络骨干部分引入WTConv,大幅提升模型的特征提取和特征融合能力,同时还最大程度降低了模型的参数。

表3 不同位置下感受野对比实验

Table 3 Comparative experiments of receptive fields at different locations

模型	mAP@0.5/%	AP@0.5/%			Params/M	GFLOPS
		Grooves	Abrasions	Scratches		
Baseline	86.2	87.1	88.3	83.1	3.0	8.1
YOLOv8-A	87.2	89.5	87.5	84.7	2.4	7.1
YOLOv8-B	88.0	89.6	90.1	84.4	2.6	7.4
YOLOv8-N	87.8	89.4	88.0	86.0	2.8	7.9

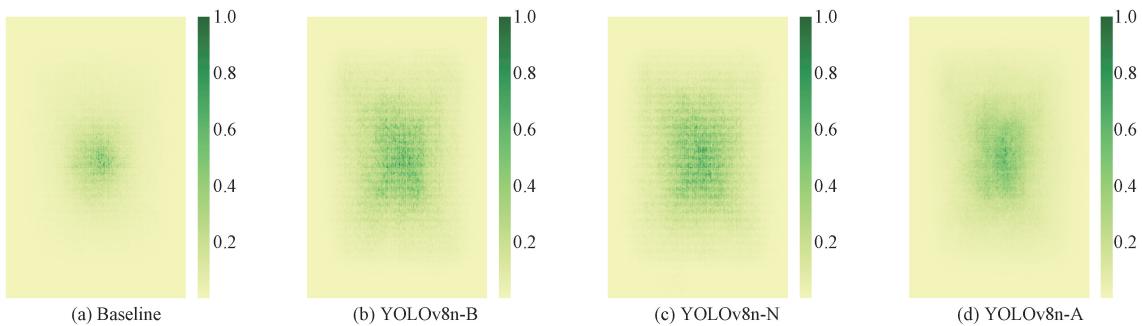


图7 有效感受野对比图

Fig. 7 Comparison of effective receptive fields

### 3.4 损失函数对比实验

为了探究本文提出的边界框回归损失函数的有效性,本小节将CIoU(基线)与Alpha-MPDIoU、SIoU<sup>[18]</sup>、DIoU<sup>[19]</sup>、MPDIoU及EIoU<sup>[20]</sup>进行了对比分析,实验结果如表4所示。在6组对照实验中,为确保损失函数是唯一变量,所有训练参数均保持一致。实验结果显示,相对于原始模型,使用SIoU、DIoU、MPDIoU和Alpha-MPDIoU后,mAP分别提升了0.2%、0.3%、0.9%以及1.7%,而使用EIoU则降低了1.4%。分析表明,MPDIoU能够显著改善轴承表面缺陷检测过程中,当预测框与真实边界框具有相同纵横比时定位能力不足的问题;例如,在处理划痕

和凹槽这类缺陷时,其识别精度相比原模型分别提高了2.1%和0.3%。此外,通过向MPDIoU引入幂变换机制,整体模型的平均精度达到87.9%。这6组实验的mAP@50曲线图如图8所示,根据曲线结果分析,改进后的损失函数所对应的精度曲线不仅高于其他情况,而且上升趋势更为平稳,这证明了改进后的模型具有更强的鲁棒性和更快的收敛速度。因此,采用Alpha-MPDIoU不仅可以提升边界框定位准确性,还能有效加快模型收敛。

### 3.5 消融实验

为了验证本文算法所提出改进点的有效性,本文结合不同改进策略设计了8组消融实验。实验结果如表5所

表 4 损失函数对比实验

Table 4 Comparative experiments of loss functions

损失函数	Precision/%	Recall/%	mAP@0.5/%	AP@0.5/%		
				Grooves	Abrasions	Scratches
Baseline	92.2	78.2	86.2	87.1	88.3	83.1
SIoU <sup>[18]</sup>	92.1	79.0	86.4	87.2	87.8	84.1
DIoU <sup>[19]</sup>	91.0	80.6	86.5	87.9	88.0	83.6
EIoU <sup>[20]</sup>	91.0	77.6	84.8	86.9	86.6	80.9
MPDIoU	91.6	80.6	87.1	89.1	88.6	83.6
Alpha-MPDIoU	90.6	82.9	87.9	89.0	89.4	85.3

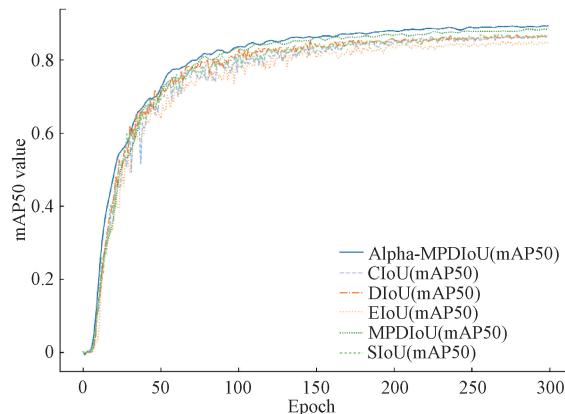


图 8 损失函数 mAP 对比曲线

Fig. 8 Comparison curve of the loss function mAP

示, DBM、WTConv 的模块结构和位置为双瓶颈结构实验和感受野可视化实验最优结果。

由结果分析可得, 使用本文提出的 DBM 来替代主干网络的 C2f 模块, 能够有效增强模型的特征提取能力和减少模型参数与计算量, mAP 增加 1.6%, 参数量降低 0.3 M, 计算量降低 0.4 GFLOPS。通过使用 WTConv 来扩大模型的感受野, 能使模型获得更强的特征融合能力和上下文分析能力, 有效识别出大的缺陷目标和多尺度的缺陷目标。另外, 采用 Alpha-MPDIoU 损失函数能削弱预测与真实框相似纵横比对边界框回归影响, 从而加强模型鲁棒性和边界框定位能力。最后, 通过使用辅助检测头训练策略, 可以获得更加浅层的特征信息与梯度回传, 加速模型收敛和提高模型缺陷识别能力。与基准模型相比, YOLO-DWA 的 mAP 提升了 3.5%, 参数量减少了 13.3%, 计算

表 5 消融实验

Table 5 Ablation experiments

DBM	WTConv	Aux-Head	Alpha-MPDIoU	P/%	R/%	mAP@0.5/%	Params/M	FPS	GFLOPS
✓				92.5	78.1	86.2	3.0	153	8.1
	✓			89.8	83.5	87.8	2.7	135	7.7
		✓		90.6	83.1	88.0	2.6	140	7.4
			✓	93.1	78.8	86.8	3.0	145	8.1
✓	✓			90.6	82.9	87.9	3.0	150	8.1
✓				92.2	82.4	88.4	2.6	135	7.4
✓			✓	90.8	83.5	88.1	2.7	139	7.7
✓	✓	✓	✓	92.8	83.7	89.7	2.6	130	7.4

量减少了 8.6%。上述实验结果说明本文在降低模型参数基础上提升了网络精度, 进一步证实改进方法的有效性。

### 3.6 主流算法对比实验

为验证本文提出算法有效性, 本节将选取工业上常用高效的单阶段目标检测算法与 DWA-YOLO 算法进行对比实验, 如: SSD<sup>[21]</sup>、YOLOv3<sup>[22]</sup>、YOLOv5、YOLOv7、YOLOv10<sup>[23]</sup>、RT-DETR<sup>[24]</sup>以及轴承领域目前最新的改进 YOLO 算法, 如: GRP-YOLOv5、MFA-YOLOv8、YOLO-SSW。

实验结果如表 6 所示, 本文提出的算法在平均精度、模型参数量、计算量以及检测速度方面均优于经典的单阶段目标检测算法 SSD。与 YOLOv3-tiny、YOLOv5n、YOLOv7-tiny、YOLOv10n 及 RT-DETR 等通用目标检测算法相比, 在有效降低参数和计算量的前提下, 本文算法的 mAP 分别提升了 9.4%、7.3%、5.6%、4.0% 和 3.7%。特别是对于划痕类别的检测, 改进后的算法相比于基线模型精度大幅提升 6%, 有效改善了这一类别检测精度低的难题。结合实验, 例如, 划痕类别在损失函数对比实验中

相比于基线模型,精度提升2.2%,在双瓶颈结构实验中精度提升为2.1%等,证明划痕类别的提升主要归功于Alpha-MPDIoU机制解决了预测框与实际边界框比例一

致时的定位问题,以及DBM双瓶颈结构增加了特征提取的深度和广度,从而增强对这种多尺度与细长型缺陷的检测能力。

表6 不同算法对比实验

Table 6 Comparative experiments of different algorithms

模型	mAP@0.5/%	AP@0.5/%			FPS	Params/M	GFLOPS
		Grooves	Abrasions	Scratches			
SSD <sup>[21]</sup>	77.5	78.9	79.5	74.1	67	26.3	62.7
YOLOv3-tiny <sup>[22]</sup>	80.3	82.2	79.6	79.1	97	12.2	19.4
YOLOv5n	83.4	84.5	84.3	81.4	141	2.5	7.1
YOLOv7-tiny	84.1	86.7	84.1	84.5	135	6.1	13.2
YOLOv8n	86.2	87.1	88.3	83.1	153	3.0	8.1
YOLOv10n <sup>[23]</sup>	85.7	87.3	87.1	82.7	165	2.2	6.5
RT-DETR <sup>[24]</sup>	87.0	86.9	89.1	85.0	67	32.1	110.1
YOLO-SSW <sup>[9]</sup>	87.6	88.3	88.7	85.8	110	2.8	11.8
GRP-YOLOv5 <sup>[6]</sup>	87.1	88.5	87.9	84.9	91	7.3	16.2
MFA-YOLO <sup>[8]</sup>	86.7	89.3	89.0	81.8	81	2.8	8.0
Ours	89.7	90.1	89.9	89.1	126	2.6	7.4

相较于当前先进轴承检测算法YOLO-SSW、GRP-YOLOv5、MFA-YOLOv8,本文算法不仅在mAP上分别高出2.1%、2.6%和3.0%,还实现最低的参数量2.6M和计算成本7.4GFLOPs。YOLO-SSW和GRP-YOLOv5通过引入注意力机制与特征融合模块提升了对凹槽缺陷的检测精度,但在处理密集分布的凹槽缺陷和纹理相似的划痕缺陷时表现乏力。MFA-YOLO虽然降低了模型的参数量和计算成本,但其EFMC和FM模块主要针对凹槽等小目标检测问题,但未能有效应对多尺度分布和复杂纹理特征的划痕缺陷,导致模型综合检测能力不足。

通过11组对比实验证,所提DWA-YOLO算法展现了卓越的性能。本文算法针对轴承缺陷的多尺度变化、密集分布特性及复杂的纹理特征进行了优化,同时实现了

参数量与计算量的全面轻量化。这不仅保证了高效的检测性能,还在保持低参数量和计算成本的前提下,大幅提升对各种类型缺陷的检测精度,使其更适用于实际工业应用中的部署和使用。

本文采用可视化手段对检测结果进行分析,旨在更直观地展示改进后算法在实际应用中的性能提升。如图9所示,与YOLOv3-tiny相比,YOLOv5n、YOLOv8n算法能够检测到大部分缺陷目标。然而,这些算法在处理凹槽等密集小目标时会出现漏检现象,并在划痕缺陷检测中会出现多框问题。相比于YOLO-SSW和MFA-YOLO,本文模型能够有效解决密集分布缺陷的漏检问题,尤其是对于划痕这种纹理复杂且尺度变化大的检测目标,本文模型表现出最好的检测结果。

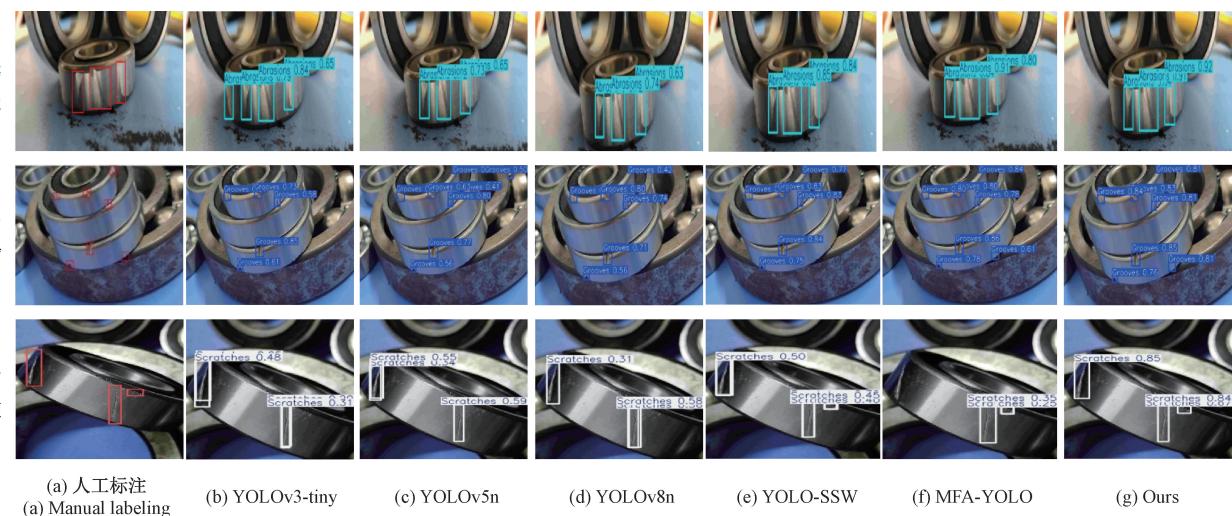


图9 检测效果对比

Fig. 9 Comparison of detection effects

综上,本文提出算法不仅检测出所有的小目标缺陷,还有效解决了划痕检测中的多框问题。此外,DWA-YOLO 算法在检测目标时的置信度分数更高,表明其分类任务执行得更好,结果更具可靠性。

为了进一步分析改进后模型在轴承缺陷检测上的性能,本文采用了 Grad-CAM 热力图可视化方法<sup>[25]</sup>。如图 10 所示,与原有算法相比,DWA-YOLO 在划痕检测方面表现得更为出色:不仅能够更完整地识别出划痕,而且

热力图中的高亮区域与实际缺陷位置的匹配度显著提高。对于数量较多且细微的凹槽类缺陷,DWA-YOLO 展现出了更强的捕捉能力,成功定位到了更多微小的缺陷点。此外,在处理磨损类缺陷时,该模型表现出更优秀的聚焦能力,有效抑制了背景噪声干扰,确保了对缺陷位置的精准识别,从而避免了误检情况的发生。这些结果共同证明了 DWA-YOLO 在提升轴承缺陷检测准确性方面的优越性。

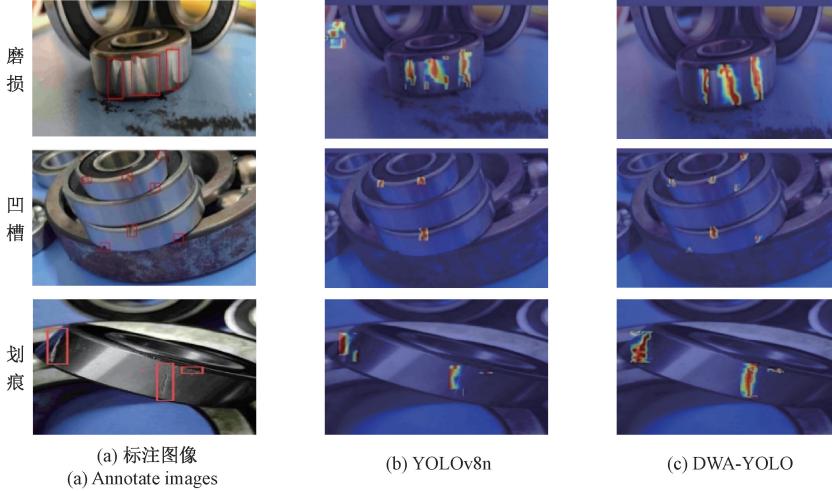


图 10 热力图可视化

Fig. 10 Figure 10 Visualization of Heat Map

### 3.7 泛化性实验

为验证 DWA-YOLO 的泛化能力,本节将采用公开的钢板缺陷数据集 NEU-DET<sup>[26]</sup>与北京大学 PCB 缺陷数据集进行验证。NEU-DET 数据集是由东北大学公开的表面缺陷数据集,包含 1 800 张图片,涵盖 6 类常见钢材损伤:裂纹、夹杂、斑块、划痕、氧化和点蚀。北京大学 PCB 数据集包含 693 张图像,涵盖 6 类缺陷:缺孔、鼠咬、开路、短路、毛刺和余铜。上述数据集均按照 8:1:1 的比例划分为训练集、验证集和测试集。本节使用当前先进的目标检测模型 YOLOv8n、YOLOv10n 及轴承缺陷检测算法 YOLO-SSW、MAF-YOLO 与本文算法进行对比,结果如表 7 和 8 所示。

表 7 NEU-DET 缺陷数据集的对比结果

Table 7 Comparison results of NEU-DET defect dataset

模型	mAP	AP@0.5/%					
		点蚀	划痕	裂纹	夹杂	氧化	斑块
YOLOv8	77.5	87.3	89.3	54.1	82.1	58.8	93.4
文献[23]	77.3	87.1	88.6	55.1	81.9	57.9	93.2
文献[9]	78.4	87.0	93.3	57.5	81.1	59.3	92.2
文献[8]	77.9	86.3	92.0	57.6	81.2	58.0	92.0
Ours	80.6	91.7	95.6	59.4	83.2	59.1	94.6

表 8 PCB 缺陷数据集的对比结果

Table 8 Comparison results of PCB defect datasets

模型	mAP	AP@0.5/%					
		缺孔	鼠咬	开路	短路	毛刺	余铜
YOLOv8	90.0	97.3	89.0	87	93.4	84.3	89.0
文献[23]	89.7	96.5	87.8	86.5	94.1	83.6	89.7
文献[9]	89.6	97.0	87.3	85.0	93.7	84.1	90.5
文献[8]	90.8	98.2	90.0	87.2	94.4	85.3	89.7
Ours	93.3	99.3	95.6	90.4	96.4	86.3	91.8

在 NEU-DET 数据集上,DWA-YOLO 的精度达到 80.6%,与 YOLOv8n、YOLOv10n、YOLO-SSW 与 MAF-YOLO 相比,mAP 提升 3.1%、3.3%、2.2% 与 2.7%。特别是对于点蚀、划痕、裂纹等小目标和多尺度缺陷类别,DWA-YOLO 的单个类别检测精度相比于基线模型分别提升了 4.4%、6.3% 和 5.3%。在 PCB 缺陷数据集上,本文模型精度达到 93.3%,相比于 YOLOv8n、YOLOv10n、YOLO-SSW 与 MAF-YOLO, mAP 提升 3.3%、3.6%、3.7% 与 2.5%。其中,与本文基线模型相比在缺孔、鼠咬、开路、短路等小目标与多尺度缺陷类别的单个类别检测精度分别提升 2%、6.6%、3.4%、3%。根据两个数据集的对比实验,YOLO-SSW 和 MAF-YOLO 的泛化能力表现不稳定。在钢材缺陷检测中,MAF-YOLO 应对噪声干扰的

能力较弱;而在 PCB 纹理相似的缺陷检测中, YOLO-SSW 则未考虑到纹理与噪声对工业缺陷检测的影响,其表现甚至不及基线模型 YOLOv8n。

以上实验结果证明,DWA-YOLO 不仅在轴承表面缺陷检测中表现出良好的检测能力,也在其他不同类型的工业数据集中展现了显著的提升的检测效果,进一步验证了本文所设计算法的有效性和泛化性。

## 4 结 论

本文针对轴承外圈缺陷检测中存在的目标尺度变化大、目标尺寸小、分布密集、纹理复杂以及现有模型计算量大等问题,提出了轴承缺陷检测算法 DWA-YOLO。首先,在网络骨干中设计一种轻量化的双瓶颈模块 DBM,不同于现有模型仅考虑模块的特征融合能力,DBM 结合 GhostConv 少参数特性大幅降低参数量与计算量。其次,通过引入小波卷积来扩大模型的有效感受野来,并且解决了目前改进模型对缺陷图像纹理与噪声抗干扰能力弱问题,使模型能整合更多视觉信息。此外,本文设计了联合损失函数 Alpha-MPDIoU 来解决定位能力不足的问题,并通过引入幂变换机制解决不同尺度目标的适应性与检测时的多框问题。最后,使用辅助检测头的训练策略,以提取更多浅层信息与细粒度的特征图,并且解决了现有改进策略增加模型计算复杂度和参数量的问题。实验结果表明本文改进算法较原算法与其他先进目标检测算法精度明显提升,并且参数量与计算量均大幅降低,对于轴承缺陷检测与其他场景的工业缺陷检测均有良好效果。但本文也存在一定不足:模块改进并未提升模型的推理速度。在未来研究中,考虑对模型进行剪枝,以提升模型的推理速度和大幅压缩模型权重大小。使其能够运用于更加苛刻的工业环境中。

## 参考文献

- [1] 张明辉,王建武,张文,等.机器视觉在轴承检测中的研究现状及发展趋势[J].机床与液压,2019,47(23):183-189.  
ZHANG M H, WANG J W, ZHANG W, et al. The research status and development trends of machine vision in bearing inspection [J]. Machine Tool and Hydraulic, 2019,47(23): 183-189.
- [2] 罗仁泽,唐祥,余泓,等.基于改进 Faster RCNN 的射线图像焊缝缺陷检测方法[J].电子测量技术,2023,46(22):160-168.  
LUO R Z, TANG X, YU H, et al. Radiographic image weld defect detection method based on improved Faster RCNN [ J ]. Electronic Measurement Technology, 2023, 46(22): 160-168.
- [3] 李忠科,刘小芳.基于轻量级 YOLOv8n 网络的 PCB 缺陷检测算法[J].电子测量技术,2024,47(4):120-126.  
LI ZH K, LIU X F. PCB defect detection algorithm based on lightweight YOLOv8n network [ J ]. Electronic Measurement Technology, 2024, 47(4): 120-126.
- [4] 王孟宇,刘志强.改进 YOLOv8 算法的钢材表面缺陷检测[J/OL].机械科学与技术,1-11 [2025-01-20].  
[https://doi.org/10.13433/j.cnki.1003-8728.20240113.](https://doi.org/10.13433/j.cnki.1003-8728.20240113)  
WANG M Y, LIU ZH Q. Improved YOLOv8 algorithm for steel surface defect detection [J/OL] Mechanical Science and Technology, 1-11 [2025-01-20].  
[https://doi.org/10.13433/j.cnki.1003-8728.20240113.](https://doi.org/10.13433/j.cnki.1003-8728.20240113)
- [5] 赵洋,王军凯,林志毅,等.基于改进 YOLOv8n 的钢材表面缺陷检测[J].电子测量技术,2024,47(13):191-198.  
ZHAO Y, WANG J K, LIN ZH Y, et al. Steel surface defect detection based on improved YOLOv8n [J]. Electronic Measurement Technology, 2024, 47(13): 191-198.
- [6] 赵洋,陈宝玲,刘斌,等.改进 YOLOv5 的轴承缺陷检测算法[J].Sensors,2023,23(17):7437.  
ZHAO Y, CHEN B L, LIU B, et al. GRP-YOLOv5: An improved bearing defect detection algorithm based on YOLOv5[J]. Sensors, 2023, 23(17): 7437.
- [7] 李亚东,马行,穆春阳,等.改进 YOLOX 网络的轴承缺陷小目标检测方法[J].计算机工程与应用,2023,59(1):100-107.  
LI Y D, MA X, MU CH Y, et al. Improved small object detection method for bearing defects in YOLOX network[J] Computer Engineering and Applications, 2023, 59(1): 100-107.
- [8] 郎德宝,周凯红.改进 YOLOv8 的轻量化轴承缺陷检测算法[J].现代电子技术,2024,47(19):115-122.  
LANG D B, ZHOU K H. Improved YOLOv8 lightweight bearing defect detection algorithm [J]. Modern Electronic Technology, 2024, 47 ( 19 ): 115-122.
- [9] 姚景丽,程光,万飞,等.改进 YOLOv8 的轻量化轴承缺陷检测算法[J].计算机工程与应用,2024,60(21):205-214.  
YAO J L, CHENG G, WAN F, et al. Improved YOLOv8 lightweight bearing defect detection algorithm [ J ]. Computer Engineering and Applications, 2024, 60(21): 205-214.
- [10] FINDER S E, AMOYAL R, TREISTER E, et al. Wavelet convolutions for large receptive fields [J]. ArXiv preprint arXiv:2407.05848, 2024.  
FINDER S E, AMOYAL R, TREISTER E, et al. Wavelet convolutions for large receptive fields [J]. ArXiv preprint arXiv:2407.05848, 2024.
- [11] 马思,徐勇. MPDIoU: A loss for efficient and accurate bounding box regression[J]. ArXiv preprint arXiv:2307.07662, 2023.  
MA S, XU Y. MPDIoU: A loss for efficient and accurate bounding box regression[J]. ArXiv preprint arXiv:2307.07662, 2023.

- [12] HE J, ERFANI S, MA X, et al. Alpha -IoU: A family of power intersection over union losses for bounding box regression [J]. Advances in Neural Information Processing Systems, 2021, 34: 20230-20242.
- [13] 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]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [14] REDMON J. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [15] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations [C]. IEEE/CVF conference on computer vision and pattern recognition, 2020: 1580-1589.
- [16] JIANG B R, LUO R X, MAO J Y, et al. Acquisition of localization confidence for accurate object detection[C]. European Conference on Computer Vision (ECCV), 2018: 816-832.
- [17] DING X, ZHANG X, HAN J, et al. Scaling up your kernels to  $31 \times 31$ : Revisiting large kernel design in cnns[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11963-11975.
- [18] GEVORGYAN Z. SIoU loss: More powerful learning for bounding box regression [J]. ArXiv preprint arXiv:2205.12740, 2022.
- [19] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]. AAAI Conference on Artificial Intelligence. 2020, 34(7): 12993-13000.
- [20] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-157.
- [21] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multi box detector[C]. Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part I 14. Springer International Publishing, 2016: 21-37.
- [22] FARHADI A, REDMON J. YOLOv3: An incremental improvement [C]. Computer Vision and Pattern Recognition, Berlin/Heidelberg, Germany: Springer, 2018.
- [23] WANG AO, CHEN H, LIU L H, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv:2405.14458, 2024.
- [24] LYU W, XU S, ZHAO Y, et al. Detrs beat yolos on real-time object detection[J]. ArXiv preprint arXiv: 2304.08069, 2023.
- [25] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization[C]. IEEE International Conference on Computer Vision, IEEE, 2017.
- [26] 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 detecting surface defects in steel[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 108-116.

### 作者简介

吴飞(通信作者),博士,教授,主要研究方向为故障诊断、图像处理、缺陷检测等。

E-mail: wufei@whut.edu.cn

范鹏主,硕士研究生,主要研究方向为目标检测、图像融合、计算机视觉。

马一凡,硕士研究生,主要研究方向为机器视觉与图像处理。