

DOI: 10.19650/j.cnki.cjsi.J2513794

# 基于深度学习的工业轴承缺陷检测算法研究

张彪<sup>1,2</sup>, 荀荣科<sup>1,2</sup>, 许家忠<sup>1,2</sup>

(1. 哈尔滨理工大学自动化学院 哈尔滨 150080; 2. 黑龙江省复杂智能系统与集成重点实验室 哈尔滨 150080)

**摘要:**针对现有轴承缺陷检测算法准确率低、存在误检以及漏检现象严重的问题,为了解决这些问题,提出了一种基于YOLOv8n的轴承缺陷检测算法(LASW-YOLOv8)。该算法在YOLOv8n的基础上,引入了轻量化且高效的LiteShiftHead检测头,结合SPConv、REG和CLS模块,提升了特征提取、目标框回归和类别分类的效率与准确性。此外,算法还引入了自适应旋转卷积核模块(ARConv),增强了对多方向缺陷的检测能力;颈部网络优化模块(SAF)进一步提升了特征提取效率;同时采用Inner-WIoU损失函数,通过优化边界框定位精度并增强对小目标及复杂形状缺陷的检测能力。实验结果表明,LASW-YOLOv8算法在多个性能指标上优于其他主流算法。该算法的准确率和召回率分别提升至97.2%和96.6%,相较于YOLOv8n分别提高了3.4%和4.5%。同时,mAP0.5和mAP0.5:0.95分别达到了98.9%和73.3%,并且在运行速度上实现了83 fps。这些结果充分证明了所提改进算法的有效性,不仅能有效减少误检和漏检现象,还满足了工业检测对高准确率和实时性的要求。此外,在东北大学公共数据集(NEU-DET)的实验中,LASW-YOLOv8算法在准确率、召回率、mAP0.5和mAP0.5:0.95这4个关键指标上均表现最佳,分别为79.3%、79.9%、84.1%和49.1%,优于其他主流算法。这一表现证明了LASW-YOLOv8算法具有出色的泛化能力和鲁棒性。

**关键词:** 轴承缺陷检测; LASW-YOLOv8; LiteShiftHead; ARConv; Inner-WIoU 损失函数

中图分类号: TH701 TP391.4 文献标识码: A 国家标准学科分类代码: 520.20

## Research on industrial bearing defect detection algorithm based on deep learning

Zhang Biao<sup>1,2</sup>, Xun Rongke<sup>1,2</sup>, Xu Jiazhong<sup>1,2</sup>

(1. School of Automation, Harbin University of Science and Technology, Harbin 150080, China; 2. Key Laboratory of Complex Intelligent Systems and Integration, Heilongjiang Province, Harbin 150080, China)

**Abstract:** Aiming at the existing bearing defect detection algorithms with low accuracy, misdetection as well as serious leakage, a bearing defect detection algorithm based on YOLOv8n (LASW-YOLOv8) is proposed to solve these problems. Based on YOLOv8n, the algorithm introduces a lightweight and efficient LiteShiftHead detection head, which is combined with SPConv, REG and CLS modules to improve the efficiency and accuracy of feature extraction, target frame regression and category classification. In addition, the algorithm also introduces the Adaptive Rotation Convolutional Kernel module (ARConv), which enhances the detection of multi-directional defects; the Neck Network Optimisation module (SAF), which further improves the efficiency of feature extraction; and the Inner-WIoU loss function, which is used to optimise the bounding box localisation accuracy and to enhance the detection of small targets and complex shape defects. Experimental results show that the LASW-YOLOv8 algorithm outperforms other mainstream algorithms in several performance indicators. The algorithm achieves an accuracy of 97.2% and a recall of 96.6%, representing improvements of 3.4% and 4.5%, respectively, compared to the original YOLOv8n. Meanwhile, mAP0.5 and mAP0.5:0.95 achieved 98.9% and 73.3%, respectively, and ran at 83 fps. These results fully demonstrate the effectiveness of the proposed algorithm, which not only effectively reduces the phenomenon of false detection and missed detection, but also meets the requirements of high accuracy and real-time performance in industrial inspection. In addition, in the experiments on the Northeastern University public dataset (NEU-DET), the LASW-YOLOv8 algorithm outperforms other mainstream algorithms in the four key metrics of accuracy, recall, mAP0.5, and mAP0.5:

0.95, which are 79.3%, 79.9%, 84.1%, and 49.1%, respectively. This performance proves that the LASW-YOLOv8 algorithm has excellent generalisation ability and robustness.

**Keywords:** bearing defect detection; LASW-YOLOv8; LiteShiftHead; ARConv; Inner-WIoU loss function

## 0 引言

轴承是机械设备的重要组成部分,广泛应用于电机、汽车、航空航天等领域,负责提供重量支撑和精确的旋转运动。轴承的性能直接关系到设备的稳定性和寿命,是保障机械系统正常运行的核心要素。但在生产和运输过程中,轴承表面不可避免地产生损伤。这些损伤会直接影响轴承的性能,降低其使用寿命和可靠性,甚至可能导致设备故障<sup>[1]</sup>。如果出现故障,轻则影响机械系统运行,重则引发安全事故,造成人员伤亡<sup>[2]</sup>。因此,对轴承表面缺陷进行检测至关重要,这不仅能确保轴承的质量,还能保障设备的正常运行和可靠性,从而避免潜在的安全风险。

目前,缺陷检测方法主要分为传统的机器视觉技术和基于深度学习的方法。传统方法包括边缘检测技术、模板匹配、局部二值模式算法,以及基于灰度阈值分割和形态学操作的技术<sup>[3-8]</sup>。边缘检测能快速提取缺陷的边缘特征,但对噪声较为敏感;模板匹配依赖预定义模板,适用于规则纹理缺陷,但在应对旋转或尺度变化时效果有限;局部二值模式通过描述纹理特征增强了对复杂背景的鲁棒性,但对噪声干扰仍有不足;灰度阈值分割和形态学操作对明显特征检测较为有效,但在多尺度和复杂形状缺陷下表现较弱。这些方法尽管在特定条件下有效,但依赖人工设计特征,难以覆盖多样化的缺陷类型,且容易出现误检和漏检,限制了其在复杂工业环境中的应用。

与传统方法相比,基于深度学习的检测技术在工业缺陷检测中展现出巨大的潜力。卷积神经网络等技术能够自动提取图像特征,已在印制电路板缺陷、铝表面缺陷、输电线路绝缘子缺陷、钢材表面缺陷、太阳能电池片表面缺陷、芯片缺陷和风力发电机叶片缺陷等多个领域取得了卓越的检测效果<sup>[9-15]</sup>。张莹等<sup>[9]</sup>提出 YOLOPCB 网络,通过删除 YOLOv7 中的混合池化卷积(max-pool convolution, MPCConv)、扩展高效层聚合网络层(extended efficient layer aggregation network layer, E-ELAN)和增强通道单元模块(enhanced channel unit, ECU)和 20×20 预测头,引入跨通道信息连接模块、浅层特征融合模块,采用新的 anchors 匹配策略和自适应加权跳层连接,提升 PCB 小目标缺陷检测能力。苏怡萱等<sup>[11]</sup>针对输电线路绝缘子缺陷检测问题,基于改进 YOLOv8 引入大型选择性卷积核网络(large selective kernel network, LSKNet)和空间金字塔池化快速模块结合大可分离核注意力机制模块(spatial pyramid pooling-fast with large separable kernel

attention, SPPF-LSKA),优化模型结构,增强小目标识别能力。刚帅等<sup>[12]</sup>为解决钢材表面缺陷检测模型复杂问题,采用 ShuffleNetV2 主干层,引入通道注意力机制(channel attention mechanism, CA)和双向特征金字塔网络(bidirectional feature pyramid network, BiFPN),使用轻量级双卷积核(dual convolutional kernel, DualConv)减少参数量,提升检测效率。

目前,基于深度学习的缺陷检测算法主要分为两类:两阶段检测算法(如 R-CNN<sup>[16]</sup>、Fast R-CNN<sup>[17]</sup>、Faster R-CNN<sup>[18]</sup>)和单阶段检测算法(如 SSD<sup>[19]</sup>、RetinaNet<sup>[20]</sup>、YOLO 系列)。两阶段算法通过区域提议网络生成候选区域后再进行分类和定位,精度高但速度慢。单阶段算法直接预测目标位置和类别,无需候选区域,速度更快,适合实时应用。YOLO 系列从 YOLOv5 到 YOLOv11<sup>[21-27]</sup>不断迭代,明显提升了检测速度和精度,逐渐成为工业缺陷检测领域的主流选择。

在 YOLO 系列的最新进展中,YOLOv10 和 YOLOv11 在架构和性能上都有显著改进。YOLOv10<sup>[26]</sup>通过引入指数移动平均注意力模块(exponential moving average attention, EMA)、使用 YOLOv9 的空间金字塔池化增强型局部聚合网络模块(spatial pyramid pooling enhanced local aggregation network, SPPeLAN),并替换 Backbone 为 Fasternet,大幅提升了目标检测算法的精度和效率。YOLOv11<sup>[27]</sup>在 YOLOv8 的基础上进一步优化了网络结构,引入了跨阶段部分卷积块(cross stage partial with kernel size 2, C3k2)和并行空间注意力卷积块(convolutional block with parallel spatial attention, C2PSA),同时在解耦头中增加了深度卷积(depthwise separable convolution, DWConv),以提高特征提取效率和算法的轻量化程度。这些改进使得 YOLOv11 在处理复杂场景和小目标检测时表现更为出色,尽管目前尚未有针对轴承缺陷检测的专门研究,但其在其他领域的应用表明其具有较高的适应性和潜力。

尽管 YOLO 系列在其他领域的应用中表现优异,其在轴承表面缺陷检测中的直接应用仍面临挑战。袁天乐等<sup>[28]</sup>提出了一种改进的 YOLOv5 算法,用于推力球轴承表面缺陷检测。该方法通过引入预处理模块和改进的 Transformer 注意力机制,提升了检测精度和召回率,同时采用实例归一化(instance normalisation, IN)加快了算法收敛速度。改进后的 YOLOv5 在检测数据集上实现了 87.0% 的准确率和 83.0% 的召回率。在复杂背景或光照变化条件下,该方法可能面临准确率和召回率波动、漏检

现象以及实时性能受限等问题。Liu 等<sup>[29]</sup>提出的 CAC-YOLOv8 算法在 YOLOv8 基础上引入通道衰减网络 (channel attenuation network, CAN) 和复合池化金字塔空间金字塔池化快速结构 (compound pooling pyramid spatial pyramid pooling fast structure, CPPSPPF), 提升了轴承缺陷检测的精度和实时性。其召回率达到 90.7%, 准确率为 83.8%。该算法表现出较强的特征提取和多尺度特征捕获能力, 但在复杂背景和光照变化条件下, 其泛化能力可能受限, 且算法复杂度可能影响训练效率。此外, 在复杂背景下的小目标检测中, 仍存在漏检和误检问题, 召回率和准确率有待进一步提高。郎德宝等<sup>[30]</sup>提出了一种改进的 YOLOv8 算法, 即 MFA-YOLOv8, 该算法通过整合轻量化多尺度特征卷积模块 (efficient multi-scale feature convolution, EMFC)、焦点调制模块 (focus modulation, FM) 和注意力尺度序列融合模块 (attention scale fusion, ASF), 在轴承缺陷检测中实现了算法轻量化, 并提高了检测精度, 达到了 89.7% 的准确率和 84.4% 的召回率。尽管性能有所提升, 但在真实应用场景中, 该算法可能仍需进一步优化以减少漏检和误检的情况。盐城工学院团队<sup>[31]</sup>提出了一种改进的 YOLOv10n 算法, 即 FM-NET, 用于轴承表面缺陷检测。该方法通过构建 (free cash flow, FCF) 全尺度连接模块和 (multi-object bi-feature network, MOBFFN) 前向网络架构, 有效提升了检测性能。实验结果表明, 该算法在轴承缺陷数据集上达到了 88.1% 的准确率和 83.1% 的召回率, mAP50 为 88.3%, mAP50:95 为 55.8%。在处理小目标缺陷以及重叠或遮挡的缺陷时, FM-NET 仍可能出现漏检和误检现象, 表明其在复杂场景下的鲁棒性有待进一步提升。

上述研究提出的轴承缺陷检测算法在复杂场景下准确率不足、误检和漏检现象频发的问题。因此, 提出了一种基于 YOLOv8n 的轴承缺陷检测算法 (LASW-YOLOv8)。该算法在 YOLOv8n 架构的基础上, 通过优化检测头和特征提取模块, 提升了对多方向缺陷的检测能力。此外, 通过引入 Inner-WIoU 损失函数, 进一步优化了边界框的定位精度。实验结果表明, LASW-YOLOv8 算法在多个性能指标上优于其他主流算法, 能够有效减少误检和漏检现象, 同时满足工业场景对高精度和实时性的需求。

## 1 YOLOv8n 目标检测算法

YOLOv8 是 YOLOv5 算法的增强版本, 包含 5 种不同复杂度的算法 (n、s、m、l、x), 由骨干网、颈部和检测头 3 部分组成, 其结构如图 1 所示。选择 YOLOv8n 作为基础算法, 而非最新的算法, 是因为它在训练效率、轻量化和计算成本上具有优势。它训练时间短 (0.90 h), 推理速度快 (93 fps), 适合快速迭代和实时检测。尽管参数量

略高于最新的算法, 但其较低的 GFLOPs 使其更适合边缘设备。此外, YOLOv8n 的稳定性和鲁棒性经过验证, 且拥有成熟的社区支持, 有利于算法的长期维护和升级, 因此是理想的研究选择。YOLOv8n 的骨干网由 Conv、C2f 和 SPPF 模块组成。Conv 模块负责基础卷积操作, 为后续处理提供初步特征; C2f 模块用于提取更丰富的特征; SPPF 模块则能够有效检测不同大小的目标。颈部采用 FPN-PAN 结构, FPN 负责合并高低级特征, 而 PAN 则加强了语义连接, 从而提升了特征融合的效率。检测头部分是轻量级的, 它从基于锚点的检测方式过渡到无锚点检测, 通过回归目标的中心点、宽度和高度来实现目标检测, 这种方式不仅处理速度快, 而且分类和定位的准确性也较高。

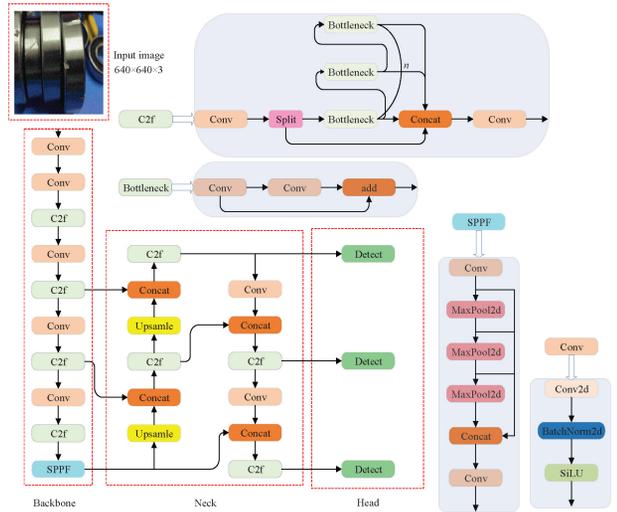


图 1 YOLOv8n 网络架构

Fig. 1 YOLOv8n network architecture diagram

## 2 所提出的改进算法

### 2.1 LASW-YOLOv8 算法

针对现有轴承缺陷检测算法普遍存在的检测精度不足、存在误检以及漏检现象严重的问题, 提出了一种基于改进 YOLOv8n 的轴承缺陷检测算法 (LASW-YOLOv8), 其结构如图 2 所示。该算法通过引入轻量化且高效的 LiteShiftHead 检测头、自适应旋转卷积核模块 (ARConv)、颈部网络优化模块 (SAF) 以及 Inner-WIoU 损失函数, 有效提升了算法对轴承缺陷的检测精度, 并大幅减少了误检和漏检现象。

### 2.2 LiteShiftHead 检测头

该方法提出了一种创新的轻量化检测头 LiteShiftHead, 它融合了 SPCConv、REG 和 CLS 模块, 以提高特征提取、目标框回归和类别分类的效率和准确性, 如

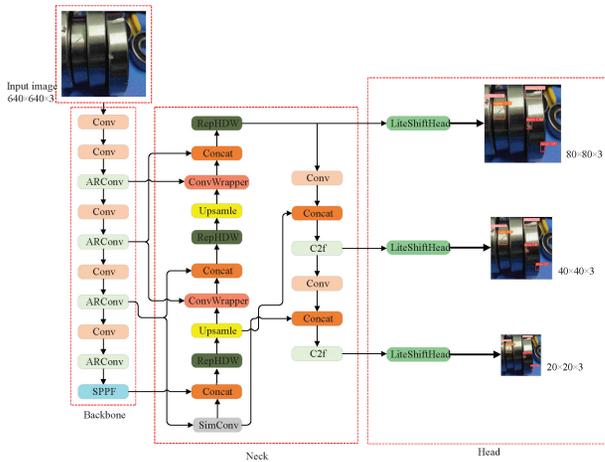


图 2 LASW-YOLOv8 网络架构

Fig. 2 LASW-YOLOv8 network architecture diagram

图 3 所示。SPConv 模块结合 3×3 卷积和 1×1 卷积,增强特征表达同时降低计算量。REG 模块采用多尺度特征回归和动态锚点生成,提高缺陷定位精度。CLS 模块利用深度可分离卷积,实现高效分类。

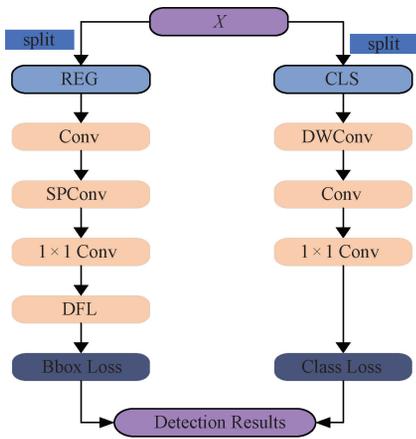


图 3 LiteShiftHead 检测头

Fig. 3 LiteShiftHead detection head

### 1) 可分离逐点卷积模块

可分离逐点卷积模块 (separable pointwise convolution, SPConv) 是一种创新的卷积结构,其结构如图 4 所示,通过将输入特征通道分为两部分,分别采用 3×3 卷积和 1×1 卷积进行操作,从而分别提取局部特征和全局上下文信息。随后,利用自适应平均池化和 Softmax 加权的方式 动态融合这两部分特征,既增强了特征表达能力,提升了对微小缺陷的检测能力,又有效降低了计算复杂度。

### 2) 目标框回归模块

目标框回归模块 (regression module, REG) 用于目标框回归,其结构如图 5 所示。REG 模块通过标准卷积和 SPConv 模块的组合,高效提取特征并回归目标框坐标。其中,标准卷积利用 3×3 卷积捕捉局部特征,为回归任务提

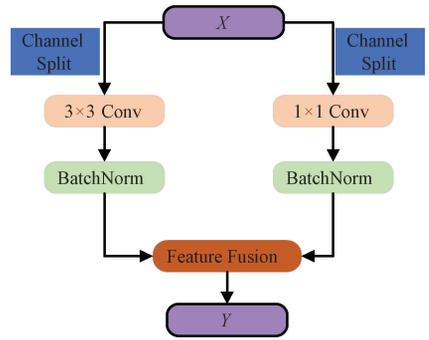


图 4 SPConv 模块

Fig. 4 SPConv module

供基础特征表示。SPConv 模块则通过 3×3 卷积和 1×1 卷积的结合,进一步增强特征表达能力,同时降低计算复杂度。最后,通过 1×1 卷积将特征映射到目标框的坐标分布。REG 模块支持多尺度特征回归,能够精确定位不规则形状的缺陷。结合动态锚点生成技术,它能够灵活适应不同尺寸的缺陷,从而实现高效、精准的目标框定位。



图 5 REG 模块

Fig. 5 REG module

### 3) 目标类别分类模块

目标类别分类模块 (classification module, CLS) 则用于目标类别分类,其结构如图 6 所示。CLS 模块通过深度可分离卷积和标准卷积的结合,高效提取特征并输出类别概率。深度可分离卷积将标准卷积分解为深度卷积和逐点卷积,减少了参数量和计算量,同时保留了强大的特征提取能力。标准卷积进一步增强特征表达能力,能够提取更丰富的语义信息和空间关系,从而有效区分不同类型的缺陷。

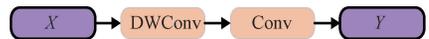


图 6 CLS 模块

Fig. 6 CLS module

## 2.3 自适应旋转卷积核模块

为了增强对不同方向缺陷的检测精度和效率,提出了一种自适应旋转卷积核模块 (adaptive rotation convolution kernel, ARConv)。该模块利用卷积核旋转机制、路由函数以及条件计算机制,动态调整卷积核的方向以适应目标缺陷的任意方向。这种设计让算法能够更准确地捕捉特征,提升对多方向缺陷的识别效果,并提升检测的准确性与计算效率。

### 1) 卷积核旋转机制

由于缺陷可能以任意方向出现,准确捕捉这些多变

的缺陷方向特征是至关重要的。为了解决这一问题, ARConv 采用自适应旋转卷积核来动态调整卷积核的方向, 以更有效地适应目标的方向变化。这个过程首先将卷积核的权重值看作是二维空间中的采样点, 并通过双线性插值技术将这些权重值扩展到一个连续的卷积核空间。随后, 根据预测得到的旋转角度  $\theta$ , 对原始坐标进行旋转, 从而获得新的采样坐标。新的采样坐标  $(x', y')$  可以通过以下旋转公式计算得出, 如式(1)所示。

$$\begin{cases} x' = x \cos \theta - y \sin \theta \\ y' = x \sin \theta + y \cos \theta \end{cases} \quad (1)$$

通过这种方式, 能够从卷积核空间中采样新的权重值, 得到旋转后的卷积核, 卷积核旋转过程如图7所示。这种动态调整卷积核方向的机制, 使得算法能够根据缺陷的实际方向进行自适应调整。

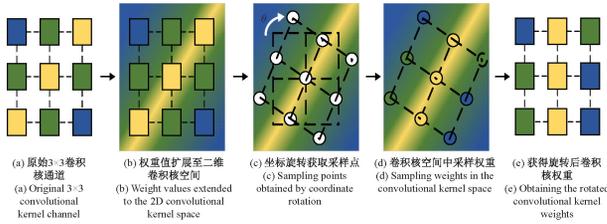


图7 3×3卷积核的旋转过程

Fig.7 The rotation process of 3×3 convolution kernels

## 2) 路由函数

路由函数是 ARConv 的关键部分, 负责根据输入特征动态预测卷积核的旋转角度和组合权重。输入特征可能包含缺陷的方向和形状信息, 路由函数能够根据这些信息预测出最适合的旋转角度和权重。输入特征首先通过一个轻量级的深度可分离卷积和平均池化层进行编码, 得到全局特征  $f_{\text{encoded}}$ , 即:

$$f_{\text{encoded}} = \text{AvgPool}(\text{ReLU}(\text{DWConv}(x))) \quad (2)$$

随后, 通过一个线性层和 Softsign 激活函数预测旋转角度  $\theta$ , 以及通过另一个线性层和 Sigmoid 激活函数预测组合权重  $\lambda$ , 即:

$$\theta = \text{Softsign}(\mathbf{W}_\theta f_{\text{encoded}} + \mathbf{b}_\theta) \quad (3)$$

$$\lambda = \text{Sigmoid}(\mathbf{W}_\lambda f_{\text{encoded}} + \mathbf{b}_\lambda) \quad (4)$$

这种动态预测机制能够根据缺陷的方向和形状信息自适应调整卷积核的方向和权重, 从而提高算法对不同方向缺陷的检测能力。

## 3) 条件计算机制

条件计算机制处理图像中可能存在的多个方向的缺陷。模块中包含多个卷积核  $\{\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_n\}$ , 每个卷积核根据预测的角度  $\{\theta_1, \theta_2, \dots, \theta_n\}$  独立旋转, 得到旋转后的卷积核, 如式(5)所示。

$$\mathbf{W}'_i = \text{Rotate}(\mathbf{W}_i; \theta_i), i = 1, 2, \dots, n \quad (5)$$

式中:  $\text{Rotate}(\mathbf{W}_i; \theta_i)$  表示对第  $i$  个卷积核  $\mathbf{W}_i$  进行旋转操

作的函数;  $\theta_i$  表示该卷积核的旋转角度。

随后, 这些旋转后的卷积核通过路由函数预测的组合权重  $\lambda = [\lambda_1, \lambda_2, \dots, \lambda_n]$  加权求和, 形成一个综合的卷积核:

$$\tilde{\mathbf{W}} = \sum_{i=1}^n \lambda_i \mathbf{W}'_i \quad (6)$$

最后, 使用综合的卷积核对输入特征  $\mathbf{x}$  进行卷积操作, 得到输出特征图  $y$ , 具体操作如式(7)所示。

$$y = \tilde{\mathbf{W}} * \mathbf{x} = \left( \sum_{i=1}^n \lambda_i \mathbf{W}'_i \right) * \mathbf{x} \quad (7)$$

式中:  $*$  表示卷积操作;  $y$  是综合的输出特征图。

## 2.4 颈部网络优化模块

为了进一步提升特征提取的效率和质量, 提出了颈部网络优化模块 (superficial assisted fusion, SAF), 并详细介绍了其中的3个关键模块: ConvWrapper、SimConv 和 RepHDW。ConvWrapper 模块通过 3×3 卷积层和 SiLU 激活函数, 高效地捕捉图像的局部特征并引入非线性特性。SimConv 模块则利用 ReLU 激活函数和批量归一化技术, 快速提取特征并减少训练过程中的协变量偏移。RepHDW 模块通过 DBU 模块和多路径特征融合, 进一步增强了算法对复杂特征的提取能力。

### 1) 卷积封装模块

卷积封装模块 (convolution wrapper module, ConvWrapper) 的核心设计是高效地进行特征提取, 如图8所示。该模块通过一个 3×3 的卷积层来捕捉图像中的局部特征, 并结合批量归一化技术以稳定训练过程并加速算法收敛。此外, 模块还采用了 SiLU 激活函数, 这种激活函数能够为网络引入非线性特性, 从而增强算法对复杂模式的学习能力。

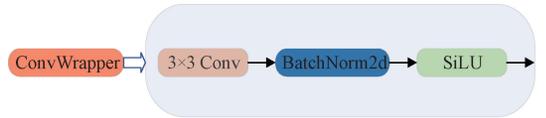


图8 ConvWrapper 模块

Fig.8 ConvWrapper module

### 2) 简化卷积模块

简化卷积模块 (simplified convolution module, SimConv) 的设计侧重于通过 ReLU 激活函数实现快速的特征提取, 如图9所示。该模块包含一个 3×3 卷积层, 用于提取输入图像的局部特征。在卷积操作之后, 模块通过批量归一化技术对数据进行规范化, 以减少训练过程中的内部协变量偏移。ReLU 激活函数的引入为网络提供了非线性处理能力, 从而提升了算法对复杂图像特征的学习能力。

### 3) 可重组混合深度卷积模块

可重组混合深度卷积模块 (reparameterizable hybrid

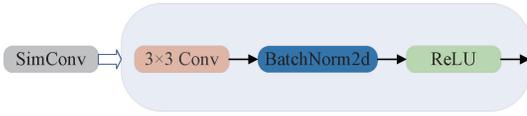


图9 SimConv 模块

Fig. 9 SimConv module

depthwise module, RepHDW)通过双分支单元模块(dual branch unit module, DBU)来增强网络的特征提取能力。在 RepHDW 中,输入特征图首先通过一个  $1 \times 1$  的卷积层进行通道数的调整,随后特征图被分割为两部分,其中一部分通过一个 DBU 模块进行处理。DBU 模块由多个卷积层组成,包括  $1 \times 1$  卷积层、 $3 \times 3$  卷积层,以及 SiLU 激活函数,这些操作协同工作以提取更深层次的特征。处理后的特征图与未处理的部分在通道维度上进行拼接,整合来自不同处理路径的特征信息。最后,拼接后的特征图通过另一个  $1 \times 1$  卷积层进行特征整合,直接输出结果,如图 10 所示。通过这种方式,RepHDW 模块能够有效地提取和融合特征,从而增强算法的表达力。

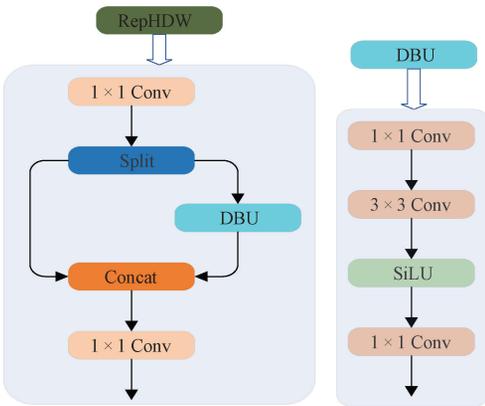


图10 RepHDW 模块

Fig. 10 RepHDW module

## 2.5 Inner-WIoU 损失函数

由于传统的损失函数往往难以有效处理预测框与真实框高度重合时的优化问题。这种情况下,算法可能会对距离度量施加过多的惩罚,从而影响检测精度和泛化能力。为了解决这一问题,提出了 Inner-WIoU 损失函数,旨在通过引入内部辅助框精准评估重合度,动态减小对距离度量的惩罚,进而提升小目标检测的精度。

Inner-WIoU 的提出受到了 WIoU 系列损失函数的启发。WIoUv1 首次提出了解决低质量样本和几何因素影响泛化能力的问题。通过引入距离注意力机制,WIoUv1 能在预测框和真实框重合度较高时,动态减轻几何因素(如距离、长宽比)的惩罚,从而提高算法在这些情况下的准确度和稳定性。该机制会随着重合度的提高减弱对

边界的关注,集中优化那些高质量的样本。WIoUv1 的公式如式(8)所示。

$$L_{WIoUv1} = R_{WIoU} L_{IoU} \quad (8)$$

$$R_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^{\sim}}\right) \quad (9)$$

式中: $x$ 和 $y$ 为包围框的中心坐标; $x_{gt}$ 和 $y_{gt}$ 为目标框的特征; $W_g$ 和 $H_g$ 是最小封闭盒的尺寸。为了防止 $R_{WIoU}$ 产生阻碍收敛的梯度,将 $W_g$ 和 $H_g$ 从计算图中分离出来,上标“ $\sim$ ”表示分离操作。

在 WIoUv1 的基础上,WIoUv3 引入了双层注意力机制,通过进一步动态调整损失函数的权重,使其能够更灵活地适应不同场景,特别是对小目标检测有了明显提升。WIoUv3 通过定义离群度 $\beta$ ,根据边界框与真实框的重合情况动态分配梯度增益。对低质量样本赋予较小的梯度增益,从而避免低质量的检测框产生有害的梯度反向传播,最终优化边界框的质量。WIoUv3 损失函数通过引入动态调整因子 $r$ 来增强 WIoUv1 在目标检测任务中的性能,其基本公式,如式(10)所示。

$$L_{WIoUv3} = r L_{WIoUv1} \quad (10)$$

式(10)用于动态调整锚框的学习权重,它通过为高质量的锚框(低离群度)分配较大的梯度增益,使算法能够更有效地学习并优化这些锚框的预测。对于低质量的锚框(高离群度),分配较小的梯度增益可以减少它们对算法训练的负面影响,防止不良的梯度反向传播。在这个过程中, $r$ 作为一个动态调整因子,它基于锚框的离群度 $\beta$ 来计算。 $\beta$ 用于量化锚框与真实边界框之间的匹配程度。 $r$ 的计算公式如式(11)所示。

$$r = \frac{\beta}{\delta \alpha^{\beta - \delta}} \quad (11)$$

$$\beta = \frac{L_{IoU}^r}{L_{IoU}} \in [0, +\infty) \quad (12)$$

式中: $L_{IoU}^r$ 表示优化后的交并比(IoU)值; $L_{IoU}$ 为动量 $m$ 的运行平均值; $\alpha$ 和 $\delta$ 为超参数。

尽管如此,WIoUv3 在处理高度重合的框时存在一定的局限,可能会对这些框产生过度惩罚。Inner-IoU 则通过引入辅助边界框和比例因子,动态调整边界框的尺寸比例,能够更加精准地评估框的重合度,有效减少了距离度量的过度惩罚。Inner-IoU 的公式如式(16)所示。

$$inter = (\min(b_x^g, b_x) - \max(b_x^t, b_x)) \times (\min(b_y^g, b_y) - \max(b_y^t, b_y)) \quad (13)$$

$$union = (w^g \times h^g) \times (ratio)^2 + (w \times h) \times (ratio)^2 - inter \quad (14)$$

$$IoU^{inner} = \frac{inter}{union} \quad (15)$$

$$L_{Inner-IoU} = 1 - IoU^{inner} \quad (16)$$

式中:  $b_r^{gt}$  和  $b_r$  分别表示目标框右边界和预测框右边界的坐标;  $b_l^{gt}$  和  $b_l$  表示目标框左边界和预测框的左边界的坐标;  $b_b$  和  $b_b^{gt}$  分别表示预测框的底部边界和目标框底部边界的坐标;  $b_t$  和  $b_t^{gt}$  分别表示预测框的顶部边界和目标框顶部边界的坐标; 目标框的宽度和高度分别表示为  $w_{gt}$  和  $h_{gt}$ , 而锚框的宽度和高度由  $w$  和  $h$  表示。“ratio” 对应于比例因子, 通常在值范围  $[0.5, 1.5]$  内。

因此, Inner-WIoU 结合了两者的优点, 如图 11 所示。这种结合提升了算法的检测精度、鲁棒性, 并进一步优化了小目标检测的性能。Inner-WIoU 的计算公式如式 (17) 所示。

$$L_{Inner-WIoU} = L_{WIoUv3} + IoU - IoU^{inner} \quad (17)$$

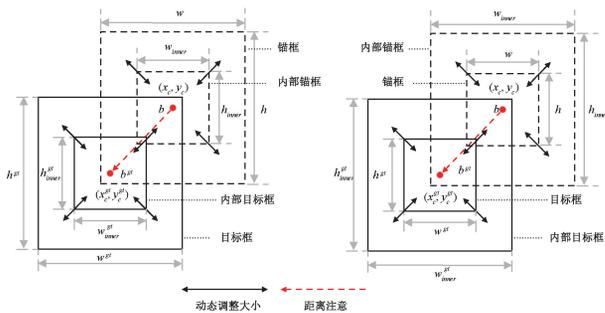


图 11 Inner-WIoU 损失函数  
Fig. 11 Inner-WIoU loss function

### 3 实验与结果分析

#### 3.1 图像采集与数据集构建

在研究中, 图像采集硬件由 USB 500 万像素高清相机、180 倍变焦镜头和 144 颗可调光源组成。相机通过 USB 接口与计算机连接, 确保数据传输的稳定性与实时性。工作台提供稳定的支撑平台, 并配备了 10 A 大支架以保证设备的稳定性。光源的亮度可以通过调整光盘控制, 进一步优化拍摄过程中的光照条件, 以提高图像质量, 整体硬件布局如图 12 所示。

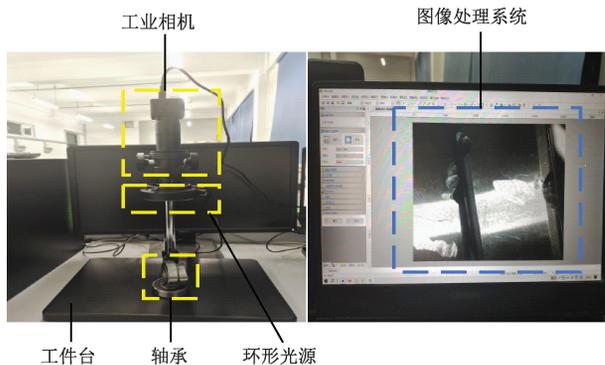


图 12 轴承表面缺陷检测系统

Fig. 12 Bearing surface defect detection system

在实验中, 通过在工作台上直接拍摄轴承表面的缺陷图像来构建数据集。轴承表面缺陷主要分为 3 种类型: 凹槽、擦伤和划痕。凹槽是指轴承表面出现的凹槽状损伤; 擦伤是由于摩擦导致材料损耗或磨蚀; 划痕则是轴承表面出现的较浅的划痕或线状损伤。为了确保算法能够全面学习这 3 种不同类型的小目标缺陷特征, 采集了每种缺陷类型的图像各 700 张, 并且还采集了包含这 3 种缺陷的复合图像共 1 600 张, 总计 3 700 张图像, 图 13 展示了这些缺陷图像的示例。

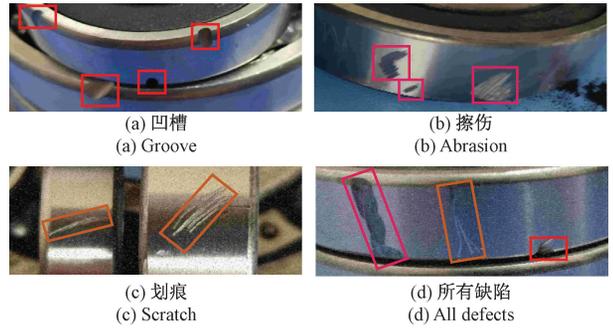


图 13 各类别缺陷和含所有缺陷示意图

Fig. 13 Schematic diagram of various types of defects and all defects included

为了提高算法的鲁棒性和泛化能力, 采用了多种数据增强技术, 包括随机旋转、缩放和翻转等。这些增强方法使得数据量扩展至 6 216 张。随后, 使用 LabelImg 标注工具对图像中的凹槽、擦伤和划痕进行精确标记, 标注文件以“.txt”格式保存, 并采用不同大小的矩形框来标注各缺陷的位置。由于工业场景中单个部件常存在多种缺陷, 在 6 216 张图像中共标注了 18 537 个缺陷实例, 平均每张图像包含约 3 个缺陷, 这种多缺陷标注策略不仅真实反映了工业检测的实际情况, 也为算法训练提供了更丰富的特征学习样本, 从而有效提升了算法的检测精度。

为了有效训练算法, 增强后的 6 216 张图像按 8:1:1 的比例随机划分为训练集 (4 973 张图像, 含 14 802 个缺陷实例)、验证集 (622 张图像, 含 1 896 个缺陷实例) 和测试集 (621 张图像, 含 1 839 个缺陷实例)。表 1 展示了 3 类缺陷在数据集中的实例分布情况。

表 1 训练集、验证集和测试集中轴承缺陷实例的分布  
Table 1 Distribution of bearing defect instances in the training set, validation set, and test set

数据集	缺陷类别数量			总缺陷数量
	凹槽	擦伤	划痕	
训练集	5 573	4 858	4 371	14 802
验证集	756	625	515	1 896
测试集	642	615	582	1 839
总计	6 971	6 098	5 468	18 537

### 3.2 实验环境与参数配置

在研究中,所有实验均在相同条件下进行,以确保实验结果的一致性和可重复性。实验过程中,所有算法的训练均从头开始,并采用 GPU 加速来提高训练效率。同时,对环境条件进行了严格的控制,以确保结果的可靠性。实验环境和参数配置如下:操作系统为 Ubuntu 20.04,使用 RTX 3090 作为 GPU,以及 Intel Core i9-10900K 作为 CPU。编程语言采用 Python 3.8,深度学习框架为 Pytorch 2.0,CUDA 版本为 11.8。训练图像的尺寸设置为 640 pixels×640 pixels,批量大小为 32。优化器选用随机梯度下降算法(stochastic gradient descent,SGD),学习率为 0.01,动量参数设置为 0.937,权重衰减系数为 0.0005,迭代次数设定为 200 次。

### 3.3 算法性能评估指标

在目标检测领域,准确评估算法性能是至关重要的,其中检测准确性是核心考量因素之一。采用多个关键指标来全面评估算法的性能,包括平均准确率均值(mean average precision, mAP)、准确率(Precision)、召回率(Recall)、计算量(GFLOPs)、参数量(Parameters)、帧率(FPS),这些指标帮助全面评估算法在不同场景下的表现。mAP 特别关注各类缺陷的平均检测精度,是衡量不同目标检测算法总体性能的关键指标。mAP<sub>0.5</sub> 代表将 IoU 阈值取为 0.50 时的 mAP 值。mAP<sub>0.5:0.95</sub> 代表 IoU 阈值在 0.50 到 0.95 之间变化时的 mAP 值。Precision、Recall、AP、mAP 的公式,如式(18)~(21)所示。

$$Precision = \frac{TP}{TP + FP} \quad (18)$$

$$Recall = \frac{TP}{TP + FN} \quad (19)$$

$$AP = \int_0^1 p(r) dr \quad (20)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (21)$$

式中:TP(真阳性)表示算法正确识别的缺陷数;TN(真阴性)表示正确识别的非缺陷数;FP(假阳性)和 FN(假阴性)分别指误判为缺陷的非缺陷数和漏检的缺陷数。准确率(Precision)和召回率(Recall)均在 0~1,反映算法的识别准确性和完整性。平均准确率(AP)由准确率和召回率的关系曲线与坐标轴围成的面积计算得出。平均准确率均值表示多个类别的平均准确率的平均值。N 代表类别的总数,AP<sub>i</sub> 表示第 i 个类别的平均准确率。该公式通过对所有类别的 AP 值求和,然后除以类别数 N 来计算出 mAP。

### 3.4 YOLOv8n 与 LASW-YOLOv8 性能对比

在研究中,对 LASW-YOLOv8 算法和 YOLOv8n 算法在轴承表面缺陷检测中的性能进行了全面的评估和对比

分析。轴承表面常见缺陷包括凹槽、擦伤和划痕。图 14 展示了两种算法在训练和验证过程中的损失曲线,包括边界框损失(box\_loss)、目标损失(df1\_loss)和分类损失(cls\_loss)。从图中可以明显看出,LASW-YOLOv8 算法在所有这些关键指标上的损失均低于 YOLOv8n 算法。随着训练轮数的增加,LASW-YOLOv8 不仅下降速度更快,而且最终达到的损失值也更低,这反映出其具有更快的学习速度和更佳的收敛效果。此外,LASW-YOLOv8 在验证集上的损失表现同样出色,这进一步证明了它具有更好的泛化能力。损失曲线的平滑性也表明 LASW-YOLOv8 的训练过程更加稳定,波动较小。

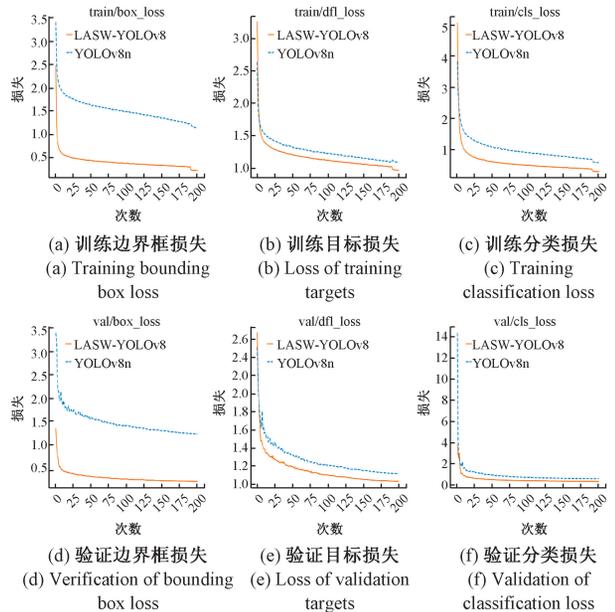


图 14 LASW-YOLOv8 和 YOLOv8n 算法的训练损失曲线和验证损失曲线

Fig. 14 Training loss curve and validation loss curve of LASW-YOLOv8 and YOLOv8n algorithms

表 2 进一步对比了两种算法在不同缺陷类型上的检测性能。LASW-YOLOv8 在所有缺陷类型上的检测性能均优于 YOLOv8n。在凹槽缺陷检测中,LASW-YOLOv8 的准确率和召回率分别提高了 3.4% 和 3.6%,mAP<sub>0.5</sub> 和 mAP<sub>0.5:0.95</sub> 分别提升了 2.5% 和 7.9%;在擦伤缺陷检测中,准确率和召回率分别提升了 2.5% 和 2.2%,mAP<sub>0.5</sub> 和 mAP<sub>0.5:0.95</sub> 分别提升了 0.5% 和 8.3%;在划痕缺陷检测中,准确率和召回率分别提高了 4.1% 和 7.5%,mAP<sub>0.5</sub> 和 mAP<sub>0.5:0.95</sub> 分别提升了 4.0% 和 12.3%。这些结果表明,LASW-YOLOv8 在复杂缺陷的检测和定位方面具有明显优势,进一步验证了其在工业轴承缺陷检测任务中的可靠性和有效性。

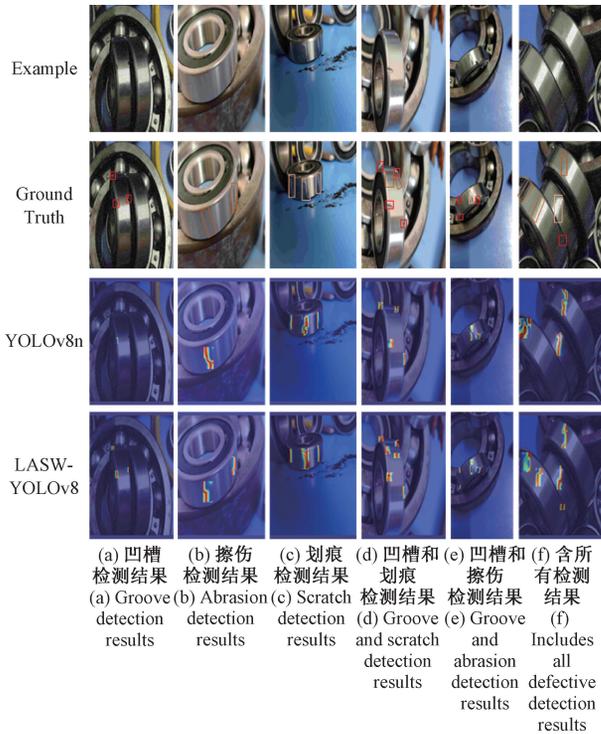
由图 15 直观地展示了轴承缺陷检测的结果,包括原始图像(Example)、真实标注(ground truth)、YOLOv8n 算

表2 轴承缺陷类别检测性能对比

Table 2 Comparison of detection performance for bearing defect categories

(%)

算法	类别	P	R	mAP0.5	mAP0.5:0.95
YOLOv8n	凹槽	93.6	92.2	96.3	59.0
	擦伤	96.2	95.4	98.9	69.3
	划痕	91.7	88.6	93.9	62.5
本文	凹槽	97.0(+3.4)	95.8(+3.6)	98.8(+2.5)	66.9(+7.9)
	擦伤	98.7(+2.5)	97.6(+2.2)	99.4(+0.5)	77.6(+8.3)
	划痕	95.8(+4.1)	96.1(+7.5)	97.9(+4.0)	74.8(+12.3)



自适应旋转卷积核模块(ARConv, A)和颈部网络优化模块(SAF, S)。实验以 YOLOv8n 为基线算法,该算法的初始性能指标为:准确率 93.8%,召回率 92.1%,mAP0.5 为 96.1%,以及 mAP0.5:0.95 为 65.1%。随着实验的进行,通过逐步引入 LiteShiftHead、ARConv 和 SAF 等模块,算法的性能得到了有效增强。

表3 消融实验结果

Table 3 Results of ablation experiment (%)

算法	L	A	S	P	R	mAP0.5	mAP0.5:0.95
YOLOv8n				93.8	92.1	96.1	65.1
YOLOv8n+L	✓			93.8	95.6	97.3	66.7
YOLOv8n+A		✓		94.8	94.7	97.5	68.5
YOLOv8n+S			✓	95.8	95.6	97.8	69.1
YOLOv8n+L+A	✓	✓		95.5	95.7	97.9	69.5
YOLOv8n+L+S	✓		✓	95.4	95.6	98.2	70.5
YOLOv8n+A+S		✓	✓	96.3	95.7	98.4	71.3
本文	✓	✓	✓	<b>97.2</b>	<b>96.6</b>	<b>98.9</b>	<b>73.3</b>

当单独添加每个模块时,召回率、准确率以及 mAP 值均有所提高。引入 LiteShiftHead 模块使召回率提升了 3.5%,而 ARConv 和 SAF 模块的加入则分别使准确率提升了 1.0%和 2.0%。这些改进表明,每个模块都对算法的检测性能有所提升。

当模块组合使用时,性能提升更为明显。特别是当 LiteShiftHead 与(ARConv 和 SAF)模块结合时,mAP0.5:0.95 分别提升了 4.4%和 5.4%。而 ARConv 与 SAF 模块的结合则使准确率提升了 2.5%,召回率提升了 3.6%,mAP0.5 提升了 2.3%,mAP0.5:0.95 提升了 6.2%。

最终,将所有模块 LiteShiftHead、ARConv 和 SAF 集成在一起时,算法实现了最佳性能提升。准确率提升了 3.4%,召回率提升了 4.5%,mAP0.5 提升了 2.8%,mAP0.5:0.95 提升了 8.2%。这些结果不仅验证了各个模块的有效性,还在缺陷检测任务中实现了整体性能的明显提升。

图15 LASW-YOLOv8 与 YOLOv8n 检测结果对比

Fig. 15 Comparison of LASW-YOLOv8 and YOLOv8n detection results

法和 LASW-YOLOv8 算法的检测效果。可以看出, LASW-YOLOv8 在缺陷检测方面的表现明显优于 YOLOv8n 算法。LASW-YOLOv8 的检测结果与真实标注更为接近,能够更准确地识别出轴承上的缺陷区域,显示出更高的精度和召回率。相比之下, YOLOv8n 出现漏检的情况。这些结果表明, LASW-YOLOv8 在处理复杂背景和不同缺陷类型时具有更强的适应性和鲁棒性,能够提供更可靠的检测结果,进一步验证了其在轴承缺陷检测任务中的优越性。

3.5 消融实验

表3的消融实验结果展示了对 YOLOv8n 算法进行不同模块优化后的性能提升情况。实验中,“✓”符号表示该模块被加入到算法中。这些模块包括 LiteShiftHead(L)、

图 16 进一步直观地展示了随着 LiteShiftHead、ARConv 和 SAF 模块的逐步集成,逐步改进的 YOLOv8n 算法在准确率、召回率、mAP0.5 和 mAP0.5:0.95 等关键性能指标上的明显提升。最终,当所有模块集成到本文算法中时,其在所有性能指标上均达到了最佳表现。

### 3.6 不同算法的性能对比

为了验证所提算法性能的优越性,选取了 YOLOv5s、YOLOv7-tiny、基准算法 YOLOv8n 以及 YOLOv9t、YOLOv10n、YOLOv11n 作为比较对象进行对比分析。对这些算法在参数量、准确率、召回率、平均精度(mAP0.5 和 mAP0.5:0.95)、计算量(GFLOPs)和帧率(FPS)等关键性能指标上的表现进行了详细分析,实验结果如表 4 所示。

在准确率和召回率方面,LASW-YOLOv8 的准确率达到到了 97.2%,这不仅比 YOLOv8n(93.8%)提高了 3.4%,还比 YOLOv9t(94.3%)、YOLOv10n(95.2%)和

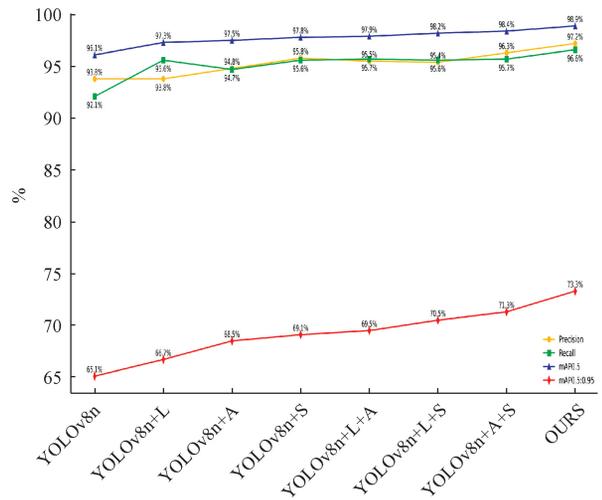


图 16 消融实验结果曲线

Fig. 16 Curve of ablation experiment results

表 4 不同算法的性能结果对比

Table 4 Comparison of performance results of different algorithms

算法	参数量/M	P/%	R/%	mAP0.5/%	mAP0.5:0.95/%	GFLOPs/G	FPS/P
YOLOv5s	7.03	96.0	95.5	98.1	64.7	16.0	91
YOLOv7-tiny	6.02	94.6	91.4	95.9	59.6	13.2	87
YOLOv8n	3.02	93.8	92.1	96.1	65.1	8.2	93
YOLOv9t	2.66	94.3	90.2	95.2	60.5	11.0	73
YOLOv10n	2.71	95.2	94.4	97.7	68.2	6.7	96
YOLOv11n	2.61	95.9	95.4	97.9	71.0	6.3	99
本文	3.82	97.2	96.6	98.9	73.3	12.4	83

YOLOv11n(95.9%)分别高出 2.9%、2.0%和 1.3%。与 YOLOv5s(96.0%)和 YOLOv7-tiny(94.6%)相比,LASW-YOLOv8 的准确率也更具优势。同时,其召回率为 96.6%,相比于 YOLOv8n(92.1%)提高了 4.5%,还比 YOLOv9t(90.2%)、YOLOv10n(94.4%)和 YOLOv11n(95.4%)分别提高了 6.4%、2.2%和 1.2%,同时相比 YOLOv5s(95.5%)和 YOLOv7-tiny(91.4%)也有所提升,这表明 LASW-YOLOv8 在识别更多真实样本方面具有较好的性能。

在 mAP0.5 和 mAP0.5:0.95 这两个关键指标上,LASW-YOLOv8 同样表现优异。其 mAP0.5 达到了 98.9%,不仅比 YOLOv8n(96.1%)提升了 2.8%,还比 YOLOv9t(95.2%)、YOLOv10n(97.7%)和 YOLOv11n(97.9%)分别高出 3.7%、1.2%和 1.0%,并且优于 YOLOv5s(98.1%)和 YOLOv7-tiny(95.9%)。在 mAP0.5:0.95 上,LASW-YOLOv8 的表现 73.3%,远高于 YOLOv5s(64.7%)和 YOLOv7-tiny(68.0%)、YOLOv8n(65.1%)、YOLOv9t(60.5%),还比 YOLOv10n(68.2%)

和 YOLOv11n(71.0%)分别提高了 5.1%和 2.3%。这表明 LASW-YOLOv8 在不同 IoU 阈值下的综合检测性能优于其他算法,能够更准确地识别和定位目标。

综上所述,LASW-YOLOv8 算法在准确率、召回率和 mAP 等关键指标上优于其他主流目标检测算法。其能够更准确地识别轴承表面的多种缺陷,同时减少误检和漏检的情况。LASW-YOLOv8 适用于对高精度和高可靠性要求较高的工业应用场景,能够有效满足实际工业检测的需求。

从表 5 的轴承缺陷检测对比中可以看出,改进的算法在凹槽、擦伤和划痕 3 个类别中均表现出色。在凹槽类别中,LASW-YOLOv8 的 mAP0.5 达到了 98.8%,mAP0.5:0.95 达到了 66.9%,优于其他主流目标检测算法。在擦伤类别中,LASW-YOLOv8 的 mAP0.5:0.95 更是高达 77.6%,远超其他算法。而在划痕类别中,LASW-YOLOv8 的 mAP0.5:0.95 也达到了 74.8%,同样领先其他算法。这些结果表明,LASW-YOLOv8 在检测精度和鲁棒性上都有明显提升,证明了改进算法的有效性。

表5 不同算法的轴承缺陷类别检测性能对比

Table 5 Comparison of bearing defect category detection performance of different algorithms (%)

缺陷类别	算法	<i>P</i>	<i>R</i>	<i>mAP</i> 0.5	<i>mAP</i> 0.5:0.95
	YOLOv5s	96.0	95.8	98.3	59.6
	YOLOv7-tiny	93.2	92.9	95.7	53.0
	YOLOv8n	93.6	92.2	96.3	59.0
凹槽	YOLOv9t	93.2	91.0	95.2	54.2
	YOLOv10n	95.3	95.3	98.1	64.2
	YOLOv11n	96.2	95.0	97.5	64.8
	LASW-YOLOv8	<b>97.0</b>	<b>95.8</b>	<b>98.8</b>	<b>66.9</b>
	YOLOv5s	98.1	97.6	99.3	69.4
	YOLOv7-tiny	96.8	94.1	97.8	65.5
	YOLOv8n	96.2	95.4	98.9	69.3
擦伤	YOLOv9t	97.4	93.0	97.8	66.7
	YOLOv10n	96.7	96.1	99.0	71.9
	YOLOv11n	98.1	<b>97.7</b>	99.3	74.0
	LASW-YOLOv8	<b>98.7</b>	97.6	<b>99.4</b>	<b>77.6</b>
	YOLOv5s	93.9	93.0	96.8	65.0
	YOLOv7-tiny	93.7	87.0	94.1	60.2
	YOLOv8n	91.7	88.6	93.9	62.5
划痕	YOLOv9t	92.1	86.7	93.9	60.6
	YOLOv10n	93.7	91.9	96.2	68.6
	YOLOv11n	93.1	93.4	96.6	70.5
	LASW-YOLOv8	<b>95.8</b>	<b>96.1</b>	<b>97.9</b>	<b>74.8</b>

图 17 中的曲线清楚地表明,改进后的算法在准确率、召回率、*mAP*0.5 和 *mAP*0.5:0.95 这 4 个关键指标上优于其他主流目标检测算法。LASW-YOLOv8 不仅在训练初期迅速达到高性能,而且在整个训练过程中保持了稳定且优异的表现,进一步证明了 LASW-YOLOv8 在轴承缺陷检测任务中具有明显的性能提升和更快的收敛速度。

图 18 直观地展示了不同算法在轴承缺陷检测上的效果。LASW-YOLOv8 算法表现最为出色,能够准确识别出所有缺陷,漏检和误检的情况最少,检测框与真实缺陷标注最为接近。相比之下,其他主流目标检测算法虽然也能识别大部分缺陷,但存在漏检和误检的情况,整体检测精度和鲁棒性均不如 LASW-YOLOv8。这些结果充分证明了改进算法在轴承缺陷检测任务中的优越性和有效性。

3.7 NEU-DET 实验对比

为了进一步增强算法的鲁棒性和泛化能力,采用了广泛使用的钢材表面缺陷检测数据集 NEU-DET 进行验证。该数据集涵盖了多种类型的缺陷。表 6 展示了在

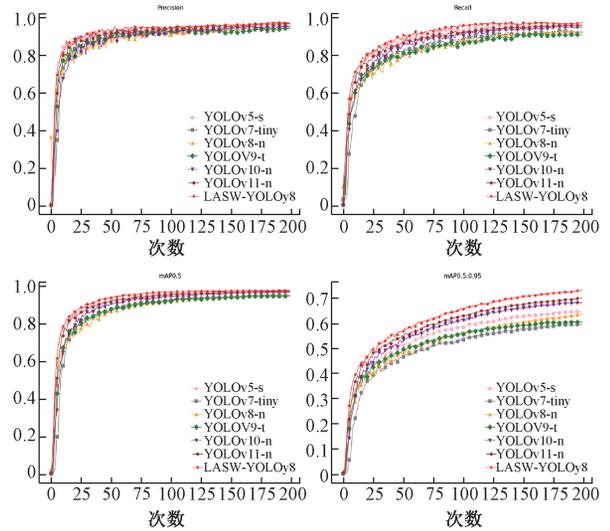


图 17 不同算法的准确率、召回率和 *mAP* 曲线

Fig. 17 Precision, recall, and *mAP* curves of different algorithms



图 18 不同算法的缺陷检测结果

Fig. 18 Defect detection results of different algorithms

NEU-DET 数据集上不同算法的性能对比。LASW-YOLOv8 算法在准确率、召回率、*mAP*0.5 和 *mAP*0.5:0.95 这 4 个性能指标上均表现最佳,分别达到了 79.3%、79.9%、84.1% 和 49.1%。相比之下,其他主流目标检测算法虽然在某些指标上表现良好,但整体性能均不如 LASW-YOLOv8 算法。

**表 6 不同算法在 NEU-DET 数据集的性能结果对比**  
**Table 6 Performance comparison of different algorithms on NEU-DET dataset** (%)

算法	<i>P</i>	<i>R</i>	<i>mAP</i> 0.5	<i>mAP</i> 0.5:0.95
YOLOv5s	66.6	77.0	82.2	43.1
YOLOv7-tiny	56.7	75.7	72.0	33.4
YOLOv8n	73.2	76.5	81.2	46.2
YOLOv9t	67.1	74.4	80.2	47.9
YOLOv10n	71.2	72.8	71.6	44.5
YOLOv11n	73.8	79.5	82.6	47.9
本文	79.3	79.9	84.1	49.1

表 7 则进一步比较了不同算法在钢材表面缺陷类别检测上的性能,LASW-YOLOv8 算法在裂纹、斑块、点蚀等 6 个缺陷类别的检测精度上整体表现最佳,这不仅证明了它在自建的轴承缺陷数据集上的良好表现,同时也表现出它在钢材表面缺陷数据集上的良好性能。这些实验结果结果表明该算法具备出色的泛化能力和鲁棒性。

**表 7 不同算法的钢材表面缺陷类别检测性能对比**  
**Table 7 Comparison of detection performance of steel surface defect categories by different algorithms**

算法	裂纹	内含物	斑块	点蚀	氧化皮	划痕
YOLOv5s	76.9	54.6	83.9	80.9	54.4	49.0
YOLOv7-tiny	74.9	44.0	66.5	86.6	42.9	45.7
YOLOv8n	70.4	51.2	70.3	88.7	67.6	70.1
YOLOv9t	87.3	58.3	68.5	77.9	52.5	57.2
YOLOv10n	65.2	<b>65.4</b>	87.6	84.3	<b>76.8</b>	78.4
YOLOv11n	78.4	58.9	67.9	92.4	67.6	<b>89.7</b>
本文	96.7	54.5	<b>89.4</b>	<b>97.2</b>	74.5	86.3

## 4 结 论

针对工业轴承缺陷检测中现有算法存在的准确率、误检和漏检现象严重的问题,提出了一种基于 YOLOv8n 的轴承缺陷检测算法(LASW-YOLOv8)。该算法通过引入轻量化的 LiteShiftHead 检测头、自适应旋转卷积核模块(ARConv)、颈部网络优化模块(SAF)以及 Inner-WIoU 损失函数,显著提升了轴承缺陷检测的精度和效率。其中,LiteShiftHead 检测头结合 SPConv、REG 和 CLS 模块,增强了特征提取、目标框回归和类别分类的能力;ARConv 通过动态调整卷积核方向,提高了对多方向缺陷的检测精度;SAF 模块进一步优化了特征提取效率;Inner-WIoU 损失函数则通过优化边界框定位精度,增强

了对小目标及复杂形状缺陷的检测能力。实验结果表明,LASW-YOLOv8 算法在多个性能指标上优于其他主流目标检测算法,有效减少了误检和漏检现象,同时满足了工业检测对高准确率和实时性的要求,验证了该算法在轴承缺陷检测中的有效性。此外,在 NEU-DET 公共数据集上的钢材缺陷检测任务中,相较于其他主流目标检测算法,展现出了更高的检测精度,这表明该算法具备出色的鲁棒性和泛化能力。当前研究虽然取得了一定的成果,但仍存在一些局限性。首先,算法较高的计算复杂度和参数量限制了其在资源受限设备上的部署能力;其次,虽然现有推理速度能满足常规工业检测需求,但在高速生产场景下的实时性能仍有待提升。针对这些问题,后续研究将重点在保持检测精度的前提下,通过算法轻量化设计和计算效率优化,进一步提升检测速度,以更好地适应资源受限设备和高速生产线的实际应用需求。

## 参考文献

[ 1 ] XU F N, DING N, LI N, et al. A review of bearing failure modes, mechanisms and causes[J]. Engineering Failure Analysis, 2023, 152: 107518.

[ 2 ] 薛源, 陈志刚, 王衍学, 等. 基于合成谱峭度优化 VMD 的滚动轴承故障特征提取[J]. 电子测量技术, 2024, 47(9): 1-7.

XUE Y, CHEN ZH G, WANG Y X, et al. Fault feature extraction of rolling bearing based on synthetic spectrum kurtosis optimized VMD [J]. Electronic Measurement Technology, 2024, 47(9):1-7.

[ 3 ] MEI H W, JIANG H Y, YIN F H, et al. Terahertz imaging method for composite insulator defects based on edge detection algorithm [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.

[ 4 ] KONG Q M, WU ZH H, SONG Y T. Online detection of external thread surface defects based on an improved template matching algorithm[J]. Measurement, 2022, 195: 111087.

[ 5 ] SONG K CH, YAN Y H. A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects[J]. Applied Surface Science, 2013, 285: 858-864.

[ 6 ] ZHANG G, TANG Z, FAN Y, et al. Steel wire rope surface defect detection based on segmentation template and spatiotemporal gray sample set[J]. Sensors, 2021, 21(16): 5401.

[ 7 ] WIN M, BUSHROA A R, HASSAN M A, et al. A contrast adjustment thresholding method for surface defect detection based on mesoscopy[J]. IEEE Transactions on Industrial Informatics, 2015, 11(3): 642-649.

[ 8 ] TRUONG M T N, KIM S. Automatic image thresholding

- using Otsu's method and entropy weighting scheme for surface defect detection[J]. *Soft Computing*, 2018, 22: 4197-4203.
- [9] 张莹, 邓华宣, 王耀南, 等. 基于多通道特征融合学习的印制电路板小目标缺陷检测[J]. *仪器仪表学报*, 2024, 45(5): 10-19.
- ZHANG Y, DENG H X, WANG Y N, et al. Small defects detection of PCB based on multi-channel feature fusion learning [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(5): 10-19.
- [10] SUI T T, WANG J W. An efficient multiscale enhancement network with attention mechanism for aluminium defect detection [J]. *Nondestructive Testing and Evaluation*, 2024: 1-18.
- [11] 苏怡萱, 李智, 盘书宝. 基于改进 YOLOv8 的输电线路绝缘子缺陷检测方法[J]. *电子测量与仪器学报*, 2025, 39(1): 14-23.
- SU Y X, LI ZH, PAN SH B. Insulator defect detection method for transmission lines based on improved YOLOv8[J]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(1): 14-23.
- [12] 刚帅, 刘培胜, 郭希旺. 改进基于 YOLOv8n 的轻量化钢材表面缺陷检测算法[J]. *电子测量技术*, 2025, 48(3): 74-82.
- GANG SH, LIU P SH, GUO X W. Lightweight improved YOLOv8 algorithm for steel surface defect detection[J]. *Electronic Measurement Technology*, 2025, 48(3): 74-82.
- [13] ZHU J H, ZHOU D Q, LU R SH, et al. C2DEM-YOLO: Improved YOLOv8 for defect detection of photovoltaic cell modules in electroluminescence image[J]. *Nondestructive Testing and Evaluation*, 2025, 40(1): 309-331.
- [14] 姜也, 黄一凡, 熊美明, 等. PCBA 板载 DDR 芯片焊点缺陷检测研究[J]. *仪器仪表学报*, 2023, 44(2): 129-137.
- JIANG Y, HUANG Y F, XIONG M M, et al. Research on solder bump defect detection of DDR chip on PCBA[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(2): 129-137.
- [15] 曾勇杰, 范必双, 杨涯文, 等. 改进 YOLOv8 算法在风机叶片缺陷检测上的应用[J]. *电子测量与仪器学报*, 2024, 38(8): 26-35.
- ZENG Y J, FAN B SH, YANG Y W, et al. Application of improved YOLOv8 algorithm in wind turbine blade defect detection [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(8): 26-35.
- [16] 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.
- [17] GIRSHICK R. Fast R-CNN [C]. 2015 IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [18] REN SH Q, HE K M, 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*, 2017, 39(6): 1137-1149.
- [19] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. *Computer Vision-ECCV 2016*, 2016: 21-37.
- [20] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]. 2017 IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [21] XUE D, ZHAO Y, ZHANG W, et al. A lightweight Mini-YOLOv5s algorithm for small target crack detection in tunnels [J]. *Nondestructive Testing and Evaluation*, 2024, 1-19.
- [22] BIST R B, SUBEDI S, YANG X, et al. A novel YOLOv6 object detector for monitoring piling behavior of cage-free laying hens [J]. *AgriEngineering*, 2023, 5(2): 905-923.
- [23] 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. 2023: 7464-7475.
- [24] WANG ZH, HUA ZH X, WEN Y CH, et al. E-YOLO: Recognition of estrus cow based on improved YOLOv8n model [J]. *Expert Systems with Applications*, 2024, 238: 122212.
- [25] WANG C Y, YE H I, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information [C]. *Computer Vision-ECCV 2024*, 2024: 1-21.
- [26] WANG AO, CHEN H, LIU L H, et al. YOLOv10: Real-time end-to-end object detection [J]. *Advances in Neural Information Processing Systems*, 2024, 37: 107984-108011.
- [27] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements [J]. *ArXiv preprint arXiv:2410.17725*, 2024.
- [28] 袁天乐, 袁巨龙, 朱勇建, 等. 基于改进 YOLOv5 的推力球轴承表面缺陷检测算法 [J]. *浙江大学学报*

(工学版), 2022, 56(12): 2349-2357.

YUAN T L, YUAN J L, ZHU Y J, et al. Surface defect detection algorithm for thrust ball bearing based on improved YOLOv5 [J]. Journal of Zhejiang University (Engineering Science), 2022, 56(12): 2349-2357.

- [29] LIU B SH, ZHAO Y, CHEN B L, et al. CAC-YOLOv8: Real-time bearing defect detection based on channel attenuation and expanded receptive field strategy [J]. Measurement Science and Technology, 2024, 35(9): 096004.
- [30] 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. Lightweight bearing defect detection algorithm based on improved YOLOv8 [J]. Modern Electronics Technology, 2024, 47(19): 115-122.
- [31] 盐城工学院, 盐城工学院技术转移中心有限公司. 基于改进 YOLOv10 的轻量级轴承表面缺陷检测方法及其系统: 中国, 202411682346. 4[P]. 2025-03-14.
- Yancheng Institute of Technology, Yancheng Institute of Technology Technology Transfer Center Co., Ltd. Lightweight bearing surface defect detection method and system based on improved YOLOv10: China, 202411682346. 4[P]. 2025-03-14.

## 作者简介



**张彪** (通信作者), 2009 年于哈尔滨理工大学获得学士学位, 2011 年于哈尔滨工程大学获得硕士学位, 2020 年于哈尔滨工程大学获得博士学位, 现为哈尔滨理工大学自动化学院副教授, 主要研究方向为船舶运动预测与控制、数字图像处理和深度学习算法方面的研究。

面的研究。

E-mail: zhangbiao@hrbust.edu.cn

**Zhang Biao** (Corresponding author) received his B. Sc. degree from Harbin University of Science and Technology in

2009, received his M. Sc. degree from Harbin Engineering University in 2011, and received his Ph. D. degree from Harbin Engineering University in 2020. He is currently an associate professor at Harbin University of Science and Technology. His main research interests include ship motion prediction and control, digital image processing, and deep-learning algorithms.



**荀荣科**, 2023 年于辽宁科技大学取得学士学位, 现为哈尔滨理工大学控制工程专业硕士研究生, 主要研究方向为图像处理、目标检测。

E-mail: 2320510082@stu.hrbust.edu.cn

**Xun Rongke** received his B. Sc. degree from Liaoning University of Science and Technology in 2023. He is currently a master's degree candidate in Control Engineering at Harbin Institute of Technology, with main research interests in image processing and target detection.



**许家忠**, 1999 年于东北农业大学获得学士学位, 2002 年于东北农业大学获得硕士学位, 2007 年于哈尔滨理工大学获得博士学位, 现为哈尔滨理工大学教授, 主要研究方向为农业机械工程、机械制造及其自动化、仪器科学与技术。

E-mail: xujiazhong@hrbust.edu.cn

**Xu Jiazhong** received his B. Sc. degree from Northeast Agricultural University in 1999, M. Sc. degree from Northeast Agricultural University in 2002, and Ph. D. degree from Harbin Institute of Technology (HIT) in 2007. Now he is a professor at HIT, with main research interests in agricultural machinery engineering, machinery manufacturing and automation, and instrument science and technology.