第 36 卷 第 5 期 中 国 机 械 工 程 Vol.36 No.5
2025 年 5 月 CHINA MECHANICAL ENGINEERING pp.1054-1064

# 一种基于改进 YOLOv8n 的气缸套缺陷检测方法

罗 亮[1,2] 郎 霄[1] 祖国庆[2*] 张 农[1] 杨 林[3] 沈雄伟[4]
1.合肥工业大学机械工程学院,合肥,230009
2.先进结构材料教育部重点实验室,长春,130012
3.赛德动力科技(广东)有限公司,广州,511458
4.欧冶工业品股份有限公司,上海,201900

**摘要**:珩磨网纹缺陷是气缸套质量的重要指标,广泛采用的人工质检方法存在检测精度与效率低及人工误差等问题,且相关自动化检测方法不能区分缺陷类别,因此,提出一种基于改进 YOLOv8n 模型的气缸套缺陷检测方法,可细致识别 7 类珩磨网纹缺陷。首先基于几何特征参数定义 7 类珩磨网纹缺陷;然后基于轻量化卷积设计 SC-C3 模块以减少模型计算参数;同时,引入通道优先注意力机制提高网络的特征提取能力;最后,采用 Wise-IoU 损失函数减小低质量样本的负面影响。研究结果表明,所提检测方法可以在复杂网纹背景下较好地识别区分复合缺陷,且检测模型的 mAP@0.5(交并比为 0.5 时的平均精度均值)达到 96.7%,帧率达 476 帧/s,较 YOLOv8n 模型时提高了 2%识别精度并降低了 0.7 GFLOPs(每秒十亿次浮点运算次数)。该研究为气缸套内表面缺陷检测提供了高速自动化高精解决方案。

**关键词**:气缸套;缺陷检测;珩磨网纹;网络优化
**中图分类号**:TP391.4
DOI:10.3969/j.issn.1004-132X.2025.05.017 **开放科学(资源服务)标识码(OSID)**:

# A Cylinder Liner Defect Detection Method Based on Improved YOLOv8n

LUO Liang[1,2] LANG Xiao[1] ZU Guoqing[2*] ZHANG Nong[1] YANG Lin[3] SHEN Xiongwei[4]
1.School of Mechanical Engineering, Hefei University of Technology, Hefei, 230009
2.Key Laboratory of Advanced Structural Materials of the Ministry of Education, Changchun, 130012
3.SYTECH Powertrain Technologies Co., Ltd.(Guangdong), Guangzhou, 511458
4.OBEI Co., Ltd., Shanghai, 201900

**Abstract**: Honing texture defects of the cylinder liners were the important quality indicator of an engine. Widely used manual quality inspection, however, owned problems of low detection accuracy, low efficiency, and manual uncertainty, as well as manual errors, and related automation detection research mightn not identify different types of defects. Therefore, a cylinder liner defect detection method was proposed based on an improved YOLOv8n model, which might accurately identify seven types of honing mesh defects. Firstly, the seven types of honing defects were defined based on geometric feature parameters.Then, the SC-C3 module was designed based on lightweight convolutional SCConv to reduce computational parameters of the model. Simultaneously, the channel prior convolutional attention(CPCA) mechanism was introduced to enhance the feature extraction ability of network. Finally, the Wise-IoU loss function was used to lower negative impacts of low-quality samples. The results show that the proposed detection method may effectively identify and distinguish composite defects under complex mesh backgrounds. The detection model's mAP@0.5(mean of average precision of IoU is as 0.5) reaches 96.7%, and frame per second(FPS) approaches 476 frames/s. Moreover, the proposed model improves recognition accuracy by 2% and reduces computational load of 0.7 GFLOPs (Giga floating-point operations per second) compared to those of the YOLOv8n model. The paper provides an automated high-speed high-precision solution for detecting surface defects on cylinder liners.

**Key words**: cylinder liner; defect detection; honing texture; network optimization

## 0 引言

金属切削加工会在产品表面产生规则纹理,该表面纹理质量可反映加工质量并极大地影响产品摩擦特性[1],因此金属表面纹理缺陷检测必不

**收稿日期**:2023-12-14
**基金项目**:长春工业大学先进结构材料教育部重点实验室开放课题(ASM-202204)

可少，且基于检测结果可调控加工工艺参数有助于提高工业产品质量[2]。珩磨加工是气缸套关键加工工序，珩磨加工在气缸套内表面形成的纵横交错的网纹结构可改善缸套内表面的油膜分布，减少缸套磨损，延长缸套使用寿命，提高发动机的燃油经济性和热效率[3]。由于存在刀具磨损等因素，气缸套网纹沟槽难免会出现边缘破损、沟槽中断、裂纹、划痕等缺陷，从而极大影响缸套表面润滑、油膜分布和使用寿命。气缸套作为汽车发动机的核心部件，其表面质量直接影响发动机效率及寿命，因此发动机制造厂均对气缸套内表面进行缺陷检测以控制缸套产品质量。

目前气缸套质量检测大多采用人工检测，效率低下，精度不高。由于检测人员主观性因素，容易导致评价结果不统一，出现漏检、误检。此外，其检测内容多数以网纹夹角和表面粗糙度等结构参数为主，并未对缺陷进行细致分类与测算。研究结果表明，不同类型、尺寸的珩磨网纹缺陷会反映出不同的加工问题，因此高速精确的缺陷检测有助于调控加工工艺，进而改善产品生产效率与质量。张农等[4]提出一种基于机器视觉的珩磨角测量方法以代替人工检测，利用 Gabor 滤波器增强网纹图像，然后进行傅里叶变换，并在频域内进行网纹夹角测量，测量误差控制在 0.33%。吕延军等[5]对缸套表面的 3D 粗糙度图像运用灰度共生矩阵提取纹理特征，再用广义回归神经网络建立 3D 粗糙度检测模型，与实测粗糙度之间的误差均值达到 7.9%，可作为代替粗糙度检测的方法之一。BEYERER 等[6]提出对网纹沟槽和背景分离后再进行特征提取的方法，即通过离散傅里叶变换将各向异性的网纹在频域内实现分离，所得的背景图片存留各种形式的缺陷，再用 LOG 滤波器进行局部缺陷检测，最终通过拉东变换实现全局缺陷检测。WANG[7]对气缸套表面网纹质量检测提出了两种评价方法，一种是利用 Gabor 滤波器和梯度振幅设计一组双边滤波器来识别粗糙的槽边缘缺陷，并用缺陷的加权空间密度作为评价指标；另一种则是对光学显微镜下气缸套内表面的石墨颗粒进行检测，用形态学顶帽和黑帽的方法计算石墨颗粒的空间自相关性，并作为衡量石墨空间均匀性的质量指标。目前有关气缸套质量自动化检测方法的研究中多数是以传统机器视觉的方法对气缸套的结构参数或是构造一个综合评价指标进行检测评价，并不能实现对不同种类缺陷的准确定位和识别，且泛用性较低。

为解决上述问题，本文提出了一种高速高精的自动化检测方案，可实现多种珩磨加工表面缺陷的细致识别和精确定位，用以代替人工检测。首先，对珩磨加工表面常见的缺陷进行归纳总结并进行数据集制作，缺陷包括沟槽破损、沟槽中断、错切槽、划痕、孔洞、裂纹、异物七类；其次，设计 SC-C3 轻量化模块和 SC-Block 瓶颈结构，该模块可即插即用，方便部署，可平衡计算量和检测精度；然后，在 YOLOv8n 骨干网络末端引入通道优先卷积注意力(channel prior convolutional attention，CPCA)机制，以提高模型定位能力；最后，使用 Wise-IoU 损失函数进行边界框回归损失计算，以降低低质量样本的影响、提高模型检测精度。

## 1　YOLOv8n 模型介绍

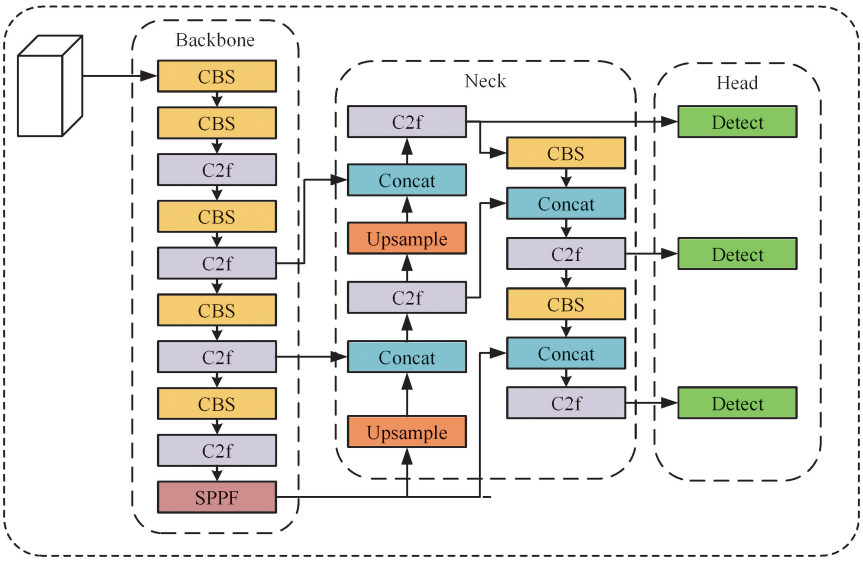
YOLOv8 通过宽度因子和深度因子控制模型的尺寸规模，共有 n、s、m、l、x 五种尺寸模型，YOLOv8n 为最小尺寸模型，具有检测速度快的优点，考虑到数据集规模，本文选用 YOLOv8n 网络作为研究对象，模型网络结构如图 1 所示。

YOLOv8n 主要由 Backbone、Neck、Head 三部分组成。Backbone 由 CBS、C2f、SPPF 三个模块堆叠组成，CBS 和 C2f 模块主要用于提取特征，捕捉物体形状、纹理以及深层次的语义信息，C2f 模块还可增强并行的梯度流信息，图 1b 中 $n$ 为 Bottleneck 层重复的次数，SPPF 模块的作用是将不同尺寸输入的特征图放缩成相同尺寸输出。Neck 部分采用 PAN-FPN 结构实现浅层信息和深层特征聚合，并穿插 C2f 模块，增加检测器感受野，能更充分地捕捉不同尺度的目标。Head 参考了主流的解耦头，将分类和检测头分离。损失函数使用 VFL Loss 作为分类损失，考虑了正负样本不平衡的问题。使用 DFL Loss 和 CIoU Loss 作为回归损失，使网络快速聚焦于目标位置，并进一步精确定位。

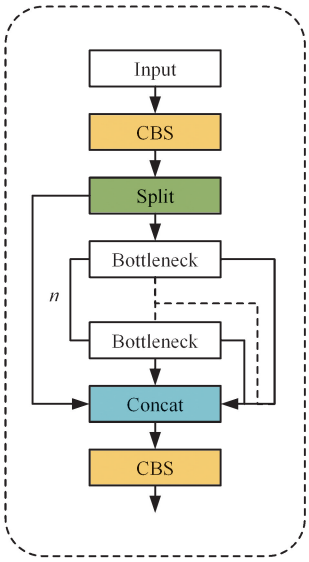
## 2　改进的 YOLOv8n 模型

### 2.1　SC-C3 模块

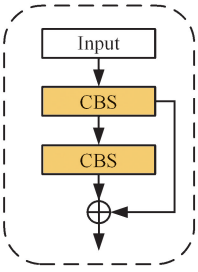
卷积运算提取特征存在空间维度和通道维度的冗余，同深度的特征图存在相似性，从而造成计算资源浪费。空间和通道重构卷积(spatial and channel reconstruction convolution，SCConv)模块是一种高效的卷积模块，通过对空间与通道维度进行分离重构以实现轻量化运算[8]。SCConv 模块包括空间重组单元(spatial reconstruction unit，SRU)和通道重建单元(channel reconstruction unit，CRU)两个组件，如图 2 所示。



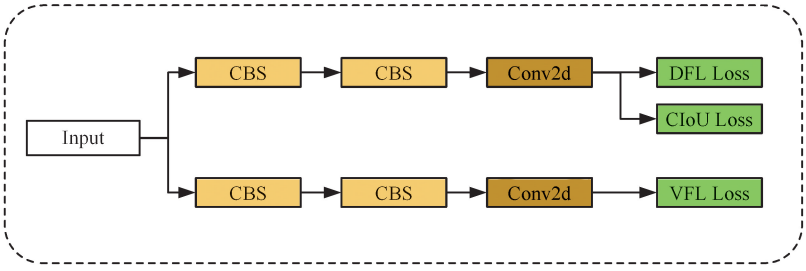

(a) YOLOv8n



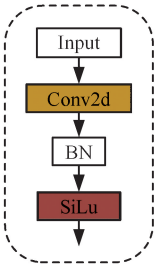

(b) C2f 模块




(c) Bottleneck



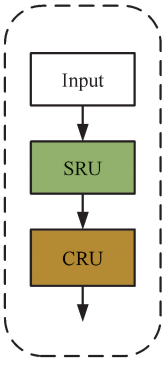

(d) Detect 模块



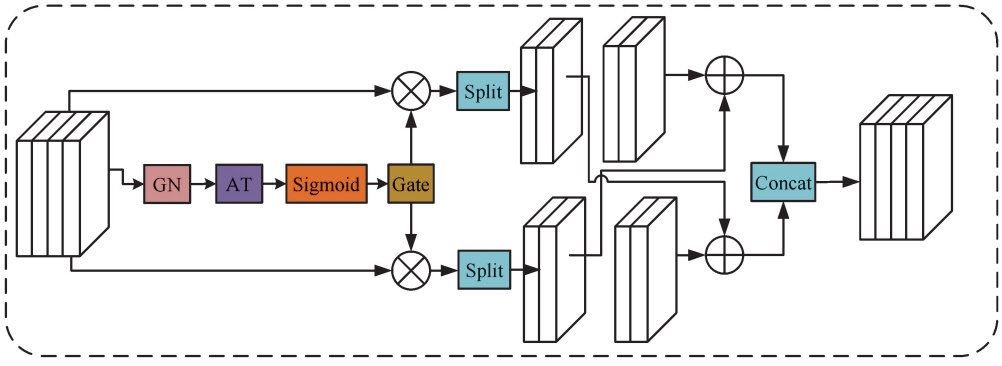

(e) CBS 模块

**图 1　YOLOv8n 模型结构**

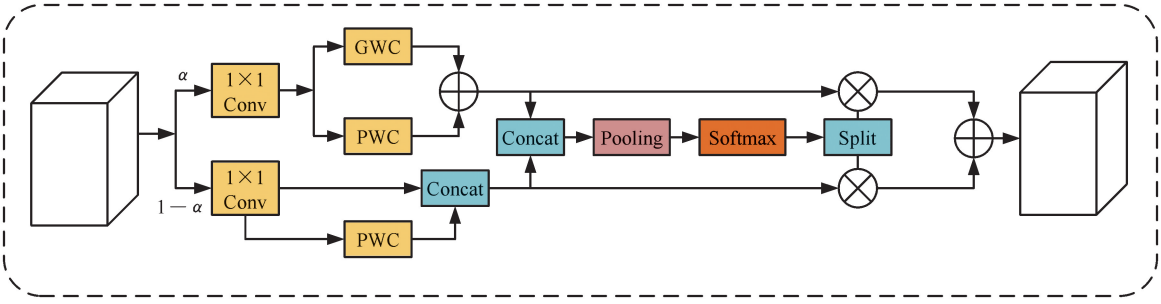
**Fig.1　YOLOv8n model structure**




(a) SCConv




(b) 空间重组单元




(c) 通道重组单元

**图 2　SCConv 模块**

**Fig.2　SCConv module**

SRU 采用分离和重构的方法，分离的目的是将信息丰富的特征图与信息较少的特征图分离出来。首先将输入特征进行标准化(GN)，再进行仿射变换(AT)，标准化及仿射变换如下式所示：

$$X_{\text{out}} = \gamma \frac{X-\mu}{\sqrt{\sigma^2+\varepsilon}} + \beta \tag{1}$$

式中：$X_{\text{out}}$ 为输出特征图；$X$ 为输入特征图；$\mu$、$\sigma$ 分别为 $X$ 的均值和方差；$\varepsilon$ 为极小常量；$\beta$、$\gamma$ 为仿射变换系数。

将归一化后的结果作为权重，可反映不同特征映射的重要程度，由下式计算得到：

$$W_\gamma = \{w_i\} = \frac{\gamma_i}{\sum_{i=1}^{C}\gamma_i} \qquad i = 1,2,\cdots,C \tag{2}$$

式中：$W_\gamma$ 为仿射变换系数 $\gamma$ 下一组归一化后的权重；$w_i$ 为第 $i$ 个通道的权重；$\gamma_i$ 为第 $i$ 通道下训练的仿射变换系数值；$C$ 为通道数。

对输入特征图依次进行组归一化、仿射变换、系数归一化后，将权重值通过 Sigmoid 函数映射到(0,1)范围内，使用阈值分割函数 $Gate(\cdot)$，设置该函数的阈值 $T=0.5$ 进行分离操作，则整个分离过程可表示为

$$W = Gate(\text{Sigmoid}(W_\gamma(AT(GN(X))))) \tag{3}$$

式中：$AT(\cdot)$ 表示仿射变换操作；$GN(\cdot)$ 表示标准化操作；$W_\gamma(\cdot)$ 表示系数归一化操作。

为进一步减少空间冗余，采用交叉重构的方法，将分离的特征图进行交叉元素相加再进行拼接，从而得到空间细化的特征图。

CRU 包括分割、转换、融合三个步骤。首先将输入特征按比例 $\alpha$ 在通道维度进行 Split 操作，分割为两部分。然后对两组特征进行 $1\times1$ 卷积压缩特征操作，其中第一组特征图分别进行分组卷积(groupwise convolution，GWC)和逐点卷积(pointwise convolution，PWC)，将结果进行元素相加；第二组只进行逐点卷积，并进行 Concat 操作。最后，将两组输出分别进行全局平均池化(Pooling)和 Softmax 操作，得到两组能够衡量输出重要程度的特征向量，并与输入进行乘积运算，以实现通道维度的去冗余。

本文基于 SCConv 模块轻量化卷积设计了 SC-C3 模块，如图 3a 所示。SC-C3 模块由 3 个 1×1的 CBS 模块和 $m$ 个 SC-Block 模块组成，其中 SC-Block 是针对 Bottleneck 结构的改进，可以在减少计算量的同时维持网络特征提取能力，如图 3b 所示。SC-Block 模块首先经过步长为 1 的 3×3 卷积来扩展通道数，再通过 SCConv 模块对卷积得到的特征进行精炼，最后进行拼接操作，将输出与输入拼接进行特征融合，得到类似残差模块的瓶颈结构，避免出现梯度消失问题，SC-Block 模块通过多次堆叠是特征提取的主要手段，综合考虑计算量和检测精度，本文中 $m$ 取值为 2。通过对 3 个 CBS 模块进行特征图维度升降控制来保证输入维度与输出维度相同。相较于 C2f 模块，SC-C3 模块减少了梯度流信息，但是精简了分支结构，达到了轻量化的目的。

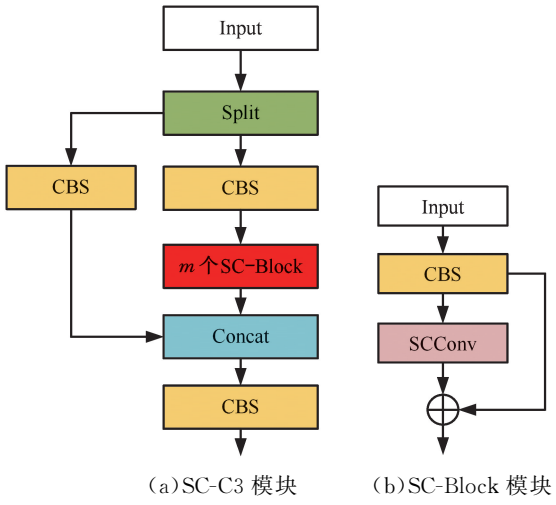



**图 3　轻量化模块**

**Fig.3　Lightweight module**

## 2.2　CPCA 机制

通道优先卷积注意力(channel prior convolutional attention，CPCA)[9]机制是一种结合了通道注意力和空间注意力的模块，可以在通道和空间维度动态分配权重，能够快速聚焦重要信息通道和重要空间区域，从而提高网络定位能力。CPCA 机制先执行通道注意力再执行空间注意力，如图 4 所示，在通道注意力部分，首先对输入图像分别采用最大池化(Max Pooling)和平均池化(Avg Pooling)，学习图像的显著性特征和整体程度信息，将输入特征图和池化后的特征图通过一组权重相同的多层感知机(multilayer perception，MLP)后进行元素相加，通过 Sigmoid 函数放缩到[0,1]范围内，得到代表通道注意力的权重向量，最后将权重向量与输入特征进行元素相乘，得到通道先验的特征；在空间注意力部分，首先采用图 5 所示的多尺度深度可分离卷积(depthwise separable convolution，DWC)，充分学习了空间维度的显著性特征，也降低了模型计算量，再使用 1×1 卷积进行通道混合，以增强特征提取能力，最后与通道先验的特征逐元素相乘，得到细化的特征作为输出。

## 2.3　Wise-IoU 损失函数

数据集制作过程中，标注框过大会导致学习过多的背景信息，标注框过小会导致特征学习不完全，错误标注则会导致学习错误特征。数据集

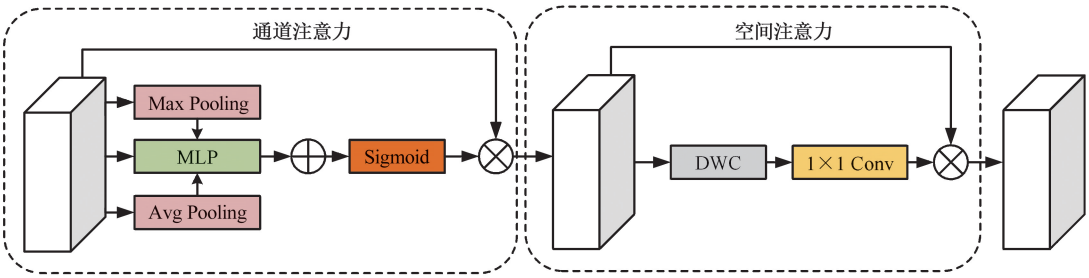



图 4 CPCA 结构

Fig.4 Channel prior convolutional attention structure

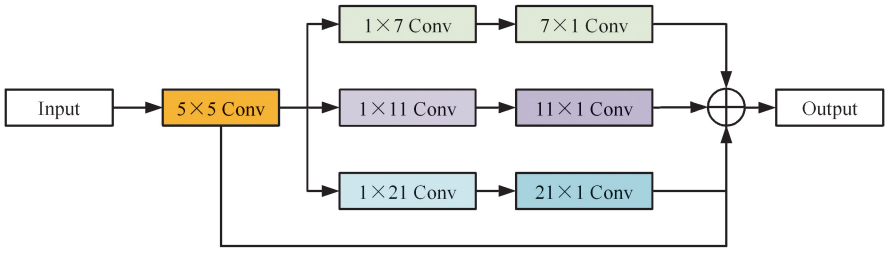



图 5 深度可分离卷积结构

Fig.5 Depthwise separable convolution structure

难以避免存在一些低质量示例，如果强化对低质量边界框的回归，则会危害模型的检测性能，因此，本文采用具有动态聚焦机制的 Wise-IoU[10] 作为回归损失，以代替原本的 CIoU 损失。

CIoU 损失既考虑了预测框与真实框之间的中心点距离，也加入了对高宽比的惩罚项，但没有考虑高质量标注示例与低质量标注示例之间的平衡。CIoU 损失的计算表达式如下：

$$L_{\mathrm{CIoU}}=L_{\mathrm{IoU}}+\frac{\rho^2(b,b^{\mathrm{gt}})}{c^2}+\alpha v=1-R_{\mathrm{IoU}}+\frac{\rho^2(b,b^{\mathrm{gt}})}{c^2}+\alpha v \tag{4}$$

$$v=\frac{4}{\pi^2}\left(\arctan\frac{w^{\mathrm{gt}}}{h^{\mathrm{gt}}}-\arctan\frac{w}{h}\right)^2$$

$$\alpha=\frac{v}{(1-R_{\mathrm{IoU}})+v}$$

式中：$b$、$w$、$h$ 分别为预测框的中心点位置、宽度和高度；$b^{\mathrm{gt}}$、$w^{\mathrm{gt}}$、$h^{\mathrm{gt}}$ 分别为真实框的中心点位置、宽度和高度；$\rho(\cdot)$ 表示对 $b$ 和 $b^{\mathrm{gt}}$ 求取距离值；$c$ 为预测框和真实框最小外接矩形的对角线长度；$v$ 为衡量高宽比相似性的参数，$v$ 越小表明预测框和真实框的高宽比越近似；$\alpha$ 为用于平衡交并比(intersection over union，IoU) 和高宽比的权重参数，预测框和真实框的重合度高则 $\alpha$ 趋近于 1，重合度低则 $\alpha$ 趋近于 0，$R_{\mathrm{IoU}}$ 为 IoU，表示预测框和真实框的交集与并集的比值；$L_{\mathrm{IoU}}$ 为 IoU 损失。

Wise-IoU 的核心点是在 IoU 损失的基础上结合注意力函数和非单调动态聚焦系数，其表达式如下：

$$R_{\mathrm{WIoU}}=\exp\left(\frac{\rho^2(b,b^{\mathrm{gt}})}{W_{\mathrm{g}}^2+H_{\mathrm{g}}^2}\right) \tag{5}$$

$$\beta_0=\frac{L_{\mathrm{IoU}}^*}{\bar{L}_{\mathrm{IoU}}}\qquad \gamma_0=\frac{\beta_0}{\delta\theta^{\beta_0-\delta}}\qquad L_{\mathrm{WIoU}}=\gamma_0 R_{\mathrm{WIoU}}L_{\mathrm{IoU}}$$

式中：$R_{\mathrm{WIoU}}$ 为注意力函数；$W_{\mathrm{g}}$、$H_{\mathrm{g}}$ 分别为真实框和预测框最小外接矩形的高和宽；$\beta_0$ 为离群度；$L_{\mathrm{IoU}}^*$ 为 IoU 损失的梯度增益；$\bar{L}_{\mathrm{IoU}}$ 为 IoU 损失的滑动平均；$\theta$、$\delta$ 为用于构造系数非单调性的超参数；$\gamma_0$ 为非单调动态聚焦系数；$L_{\mathrm{WIoU}}$ 为 Wise-IoU 损失。

注意力函数由真实框中心点位置以及外接框高、宽两个方面的距离度量构造而成，考虑了预测框和真实框中心点位置的度量。非单调动态聚焦系数用离群度衡量标注框的质量，质量较高的标注框示例具有较小的离群度，匹配的梯度增益较小，这使得 Wise-IOU 在每个时刻都能做出符合当前情况的最优梯度增益分配策略。

## 3 数据采集与处理

本文数据集采用的是潍柴 WP10 发动机缸套，型号为 612630010015A，图像获取设备为 Hisometunion DHⅡ显微镜，物镜放大倍数为 20，显示屏放大倍数为 25。为采集内表面缺陷图片，对气缸套进行线切割加工，最终采集到 1500 张图像，图像格式为 JPG 格式，图像分辨率为 600 pixel×800 pixel。实验器材和气缸套原图见图 6。

为确保采集到的图片质量完好，对采集到的气缸套图片进行预处理。因气缸套内表面为曲面，采集到的图片边缘会产生失真，因此为保留中间清晰度较高的部分图像，将原始图像进行裁剪，如图 7 所示，裁剪后图片尺寸为 400 pixel×400 pixel。

受采集环境限制，图像整体亮度偏暗，对图像进行直方图均衡化处理，如图 8 所示。



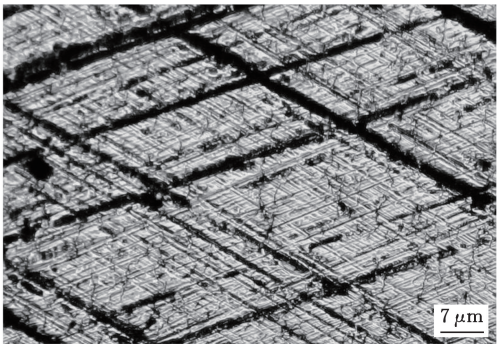
(a)数据采集设备



(b)气缸套切片



(c)气缸套




(d)气缸套表面纹理原图

**图 6　实验设备及气缸套试样**

**Fig.6　Experimental equipment and cylinder linear samples**

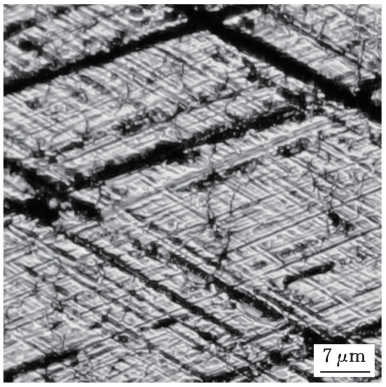



**图 7　一次裁剪图片**

**Fig.7　Firstly cropped image**

为扩充数据集和方便标注，对图像再次裁剪，将一张分辨率为 400 pixel×400 pixel 的图片裁剪为四张分辨率为 250 pixel×250 pixel 的图片，如图 9 所示。通过图像预处理，可以提高模型的鲁棒性。

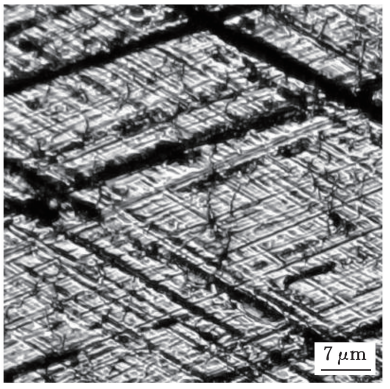



**图 8　直方图均衡化**

**Fig.8　Histogram equalization**

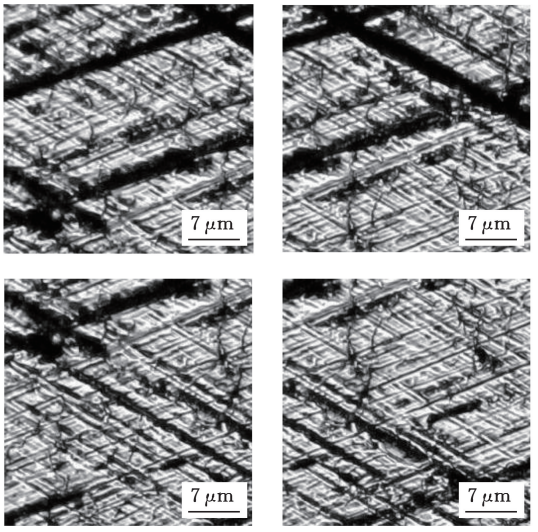
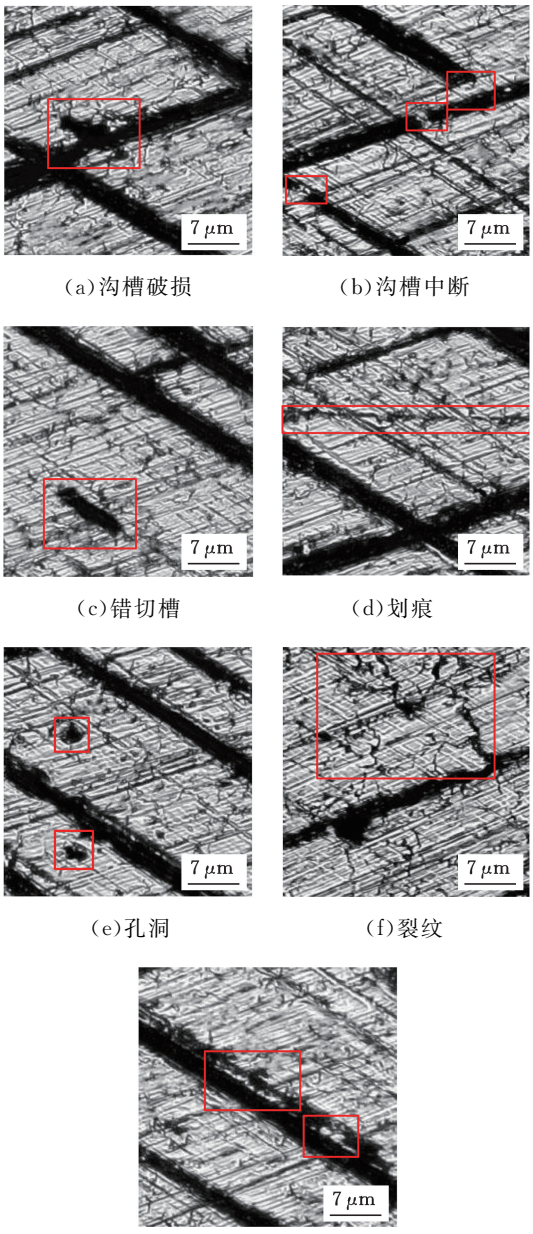



**图 9　二次裁剪图片**

**Fig.9　Secondarily cropped images**

然后将数据集按 7∶3 比例划分为训练集、测试集。同时，使用 labelme 标注工具对图像进行标注。在图像标注时，采用矩形框进行标注。缸套加工工艺包括铸造、切削加工、珩磨加工等多道工序，将工序中常见缺陷考虑在内，选择 7 类缺陷作为标注类别，如图 10 所示，图 10a～图 10g 分别为沟槽破损、沟槽中断、错切槽、划痕、孔洞、裂纹、异物，其中沟槽破损、沟槽中断、错切槽为珩磨加工表面特有缺陷。

气缸套珩磨表面具有复杂的网纹结构，一类缺陷产生往往伴随多类缺陷特征，小区域内多个缺陷共存，为人工缺陷标注带来困难，因此人工标注结果极易存在漏标、错标等现象，产生低质量样本。本文对缺陷类别制定的标注标准如下：①深沟槽边缘破损超过沟槽宽度二分之一时认定为沟槽破损；②深沟槽之间连通中断认定为沟槽中断；③所切沟槽与任何其他沟槽均不相连认定为错切槽；④与沟槽纹理方向不一致的沟槽认定为划痕；⑤沟槽中存在未切除彻底的金属残留物认定为沟槽异物；⑥金属表面孔洞直径大于 10 μm 时认定




(a)沟槽破损　(b)沟槽中断

(c)错切槽　(d)划痕

(e)孔洞　(f)裂纹

(g)异物

**图 10　珩磨表面常见缺陷**

**Fig.10　Defects on the honing surfaces**

为孔洞缺陷；⑦金属表面裂纹长度大于 100 μm 时认定为裂纹缺陷。

按照上述标准进行标注后，最终数据集图像数量分布如表 1 所示。

**表 1　缺陷类别统计**

**Tab.1　Defect category statistics**

| 缺陷类别 | 数量 |
|---|---|
| 错切槽 | 384 |
| 裂纹 | 980 |
| 沟槽中断 | 745 |
| 异物 | 444 |
| 沟槽破损 | 505 |
| 划痕 | 349 |
| 孔洞 | 1132 |

## 4　结果分析

### 4.1　实验环境和参数配置

本实验在 Win11 操作系统下进行，GPU 为 NVIDIA GeForce RTX 3060，内存为 6 GB，编程语言采用 python 3.9.16 版本，使用 Pytorch 1.13.1 进行训练。

参数设置如下：训练轮数（epochs）为 300，批处理大小（batchsize）为 8，输入图像尺寸（Img_size）256 pixel×256 pixel，线程数（workers）设置为 8，优化器（optimizer）为随机梯度下降（stochastic gradient descent，SGD）优化器，初始学习率（lr0）为 0.01，周期学习率（lrf）为 0.01。

### 4.2　评价指标

本文采用的评价指标是目标检测任务最常用的评价指标，包括精确率（Precision）、召回率（Recall）、平均精度均值（mean average precision，mAP）、计算参数量（Parameters）、每秒十亿次浮点计算量（giga floating-point operations per second，GFLOPs）、帧率即每秒帧数（frames per second，FPS）。准确率、召回率和 mAP 的计算公式如下：

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \tag{6}$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \tag{7}$$

$$P_A = \int_0^1 P(R)\mathrm{d}R \tag{8}$$

$$P_{mA} = \frac{1}{J}\sum_{j=1}^{J} P_{Aj} \tag{9}$$

其中，$N_{TP}$ 表示为预测正确的正样本数量（true positive，TP），$N_{FP}$ 表示预测错误的正样本数量（false positive，FP），$N_{FN}$ 表示预测错误的负样本数量（false negative，FN）；$P$ 为准确率，表示预测为正例的样本数据中预测正确的比例；$R$ 为召回率，表示在所有正样本中，模型找回的正样本比例；$P_A$ 为平均精度（average precision，AP），是以 $R$ 为横坐标、$P$ 为纵坐标的曲线在（0，1）上的积分，是两者的融合指标，反映了模型的性能，积分值越大，表明模型性能越好；$P_{mA}$ 为平均精度均值（mAP），表示对所有类别 $J$ 的平均精度求均值，mAP 常用 mAP@0.5 和 mAP@0.5:0.95 两个指标来衡量，前者表示 IoU 阈值取 0.5 时的平均精度均值，后者表示对 IoU 阈值从 0.5 到 0.95、步长为 0.05 的 10 组 mAP 求均值的结果。

准确率、召回率和 mAP 用于表述模型的检测精度，计算参数量（即模型需要训练时的参数量大

小）和 GFLOPs 用于表述模型的参数规模，FPS 用于表征模型的检测速度。

### 4.3　对比实验

损失函数作为一种惩罚项，需要在训练期间最小化以实现预测框与真实框的最优匹配。为验证损失函数 Wise-IoU 的有效性，在原 YOLOv8n 模型基础上，采用相同超参数的情况下，运用 EIoU 和 SIoU 进行对比[11-12]。EIoU 和 SIoU 的表达式分别如下：

$$L_{\mathrm{EIoU}}=1-R_{\mathrm{IoU}}+\frac{\rho^2(b,b^{\mathrm{gt}})}{c^2}+\frac{\rho^2(w,w^{\mathrm{gt}})}{W_{\mathrm{g}}}+\frac{\rho^2(h,h^{\mathrm{gt}})}{H_{\mathrm{g}}} \tag{10}$$

$$L_{\mathrm{SIoU}}=1-R_{\mathrm{IoU}}+\frac{\Delta+\Omega}{2} \tag{11}$$

$$\Delta=\sum_{t=x,y}(1-\exp((2-\Lambda)\rho_t))$$

$$\Lambda=1-2\sin^2(\arcsin t-\frac{\pi}{4})$$

$$t=\frac{\max(b_t^{\mathrm{gt}},b_t)-\min(b_t^{\mathrm{gt}},b_t)}{\rho(b,b^{\mathrm{gt}})}$$

$$\rho_x=(\frac{b_x^{\mathrm{gt}}-b_x}{W_{\mathrm{g}}})^2 \qquad \rho_y=(\frac{b_y^{\mathrm{gt}}-b_y}{H_{\mathrm{g}}})^2$$

$$\Omega=(1-\exp(-l_w))^{\vartheta}+(1-\exp(-l_h))^{\vartheta}$$

$$l_w=\frac{|w-w^{\mathrm{gt}}|}{\max(w,w^{\mathrm{gt}})} \qquad l_h=\frac{|h-h^{\mathrm{gt}}|}{\max(h,h^{\mathrm{gt}})}$$

式中：$\Delta$ 为损失函数的角度成本；$\Omega$ 为形状成本；$\vartheta$ 为超参数，表示对 $\Omega$ 的关注度；下标 $x$、$y$ 分别表示各类框的横坐标和纵坐标；$l_w$、$l_h$ 分别为方形预测框在宽度和高度上的损失程度。

各损失函数的检测结果如表 2 所示，相较于 CIoU，EIoU 将高宽比例损失改为高宽值损失，SIoU 则多考虑了边界框的角度因素和预测框的形状成本，理应具有更优的定位效果，但是由于低质量示例的存在，采用 SIoU 和 EIoU 损失函数的模型的 mAP@0.5 相较于采用 CIoU 损失的原模型反而下降 1 个百分点。Wise-IoU 则针对这个问题表现优秀，其 mAP@0.5 相较于采用 CIoU 损失的原模型的 mAP@0.5 提高 1.7 个百分点。

**表 2　各损失函数比较**

**Tab.2　Comparison of various loss functions**

| 损失函数 | *P* | *R* | mAP@0.5 | mAP@0.5:0.95 |
|---|---|---|---|---|
| CIoU | 0.909 | 0.883 | 0.947 | 0.605 |
| SIoU | 0.890 | 0.887 | 0.939 | 0.589 |
| EIoU | 0.881 | 0.870 | 0.935 | 0.591 |
| Wise-IoU | 0.929 | 0.936 | 0.964 | 0.599 |

### 4.4　多种注意力机制对比

CPCA 模块融合了空间注意力模块和通道注意力模块，为验证模块的效果，将经典的空间与通道注意力模块进行对比[13-14]。在原 YOLOv8n 模型骨干网络中的快速空间金字塔池化（spatial pyramid pooling-fast，SPPF）层之后加入注意力机制，其余结构和参数设置保持不变，对比结果如表 3 所示。其中，SE 模块和 CAM 模块是通道注意力模块，相比于 SE 模块、CAM 模块，CPCA 模块的检测性能稍有提高，mAP@0.5:0.95 分别提高了 0.8、1.7 个百分点。SAM 模块是一种空间注意力模块，相比于 SAM 模块，CPCA 模块的 mAP@0.5:0.95 提高了 2.7%。而 CBAM 模块同样融合了空间注意力模块和通道注意力模块，它与 CPCA 模块的检测性能差距较小，CPCA 模块比 CBAM 模块的 mAP@0.5:0.95 提高了 0.4 个百分点。

**表 3　不同注意力机制对比**

**Tab.3　Comparison of different attention mechanisms**

| 注意力模块 | *P* | *R* | mAP@0.5 | mAP@0.5:0.95 |
|---|---|---|---|---|
| SE | 0.907 | 0.903 | 0.953 | 0.620 |
| CBAM | 0.905 | 0.911 | 0.956 | 0.624 |
| SAM | 0.894 | 0.900 | 0.950 | 0.601 |
| CAM | 0.899 | 0.903 | 0.952 | 0.611 |
| CPCA | 0.909 | 0.908 | 0.956 | 0.628 |

### 4.5　消融实验

为验证改进的 YOLOv8n 网络中各个模块在气缸套数据集上的检测效果，以 YOLOv8n 网络为基准，将各个改进模块逐步添加到网络中，通过消融实验来评估不同模块对最终目标检测性能带来的影响，消融实验结果如表 4 所示。

**表 4　消融实验**

**Tab.4　Ablation experiments**

| 序号 | SC-C3 | CPCA | Wise-IoU | mAP@0.5 | mAP@0.5:0.95 | Parameters/M | GFLOPs | *P* | *R* | FPS |
|---|---|---|---|---|---|---|---|---|---|---|
| 1 | | | | 0.947 | 0.605 | 3.01 | 8.2 | 0.909 | 0.883 | 434 |
| 2 | √ | | | 0.924 | 0.537 | 2.56 | 7.2 | 0.876 | 0.865 | 526 |
| 3 | | √ | | 0.956 | 0.628 | 3.14 | 8.4 | 0.909 | 0.908 | 400 |
| 4 | | | √ | 0.964 | 0.599 | 3.01 | 8.2 | 0.929 | 0.901 | 434 |
| 5 | √ | √ | | 0.944 | 0.573 | 2.69 | 7.5 | 0.897 | 0.896 | 465 |
| 6 | √ | | √ | 0.962 | 0.565 | 2.57 | 7.3 | 0.934 | 0.921 | 486 |
| 7 | | √ | √ | 0.980 | 0.616 | 3.14 | 8.4 | 0.946 | 0.940 | 403 |
| 8 | √ | √ | √ | 0.967 | 0.606 | 2.69 | 7.5 | 0.934 | 0.925 | 476 |

表 4 中，第 1 组是作为基准的角 YOLOv8n 模型，第 2～4 组分别对改进的单个模块进行添加，结果表明 SC-C3 模块能够平衡检测精度和速度，以损失 2.3% 检测精度来降低 14.7% 的计算量，并将帧率(FPS)提高了 21.2%；CPCA 是有参注意力模块，会增加 0.2 GFLOPs，但是有助于增强网络的定位能力，提高召回率和检测精度；Wise-IoU 可以有效地改善低质量样本带来的负面影响，进一步提高模型检测精度。第 5～7 组分别加入两个不同模块，进一步验证了各个模块的有效性，且当有足够计算资源时，采用第 7 组的模型可以最大程度上提高网络的检测性能，mAP@0.5 达到 98%，相较于第一组原 YOLOv8n 模型提高了 3.3 个百分点。第 8 组是最终组合结果，在主干网络末端加入 CPCA 机制替换颈部网络中的 C2f 结构，并用 Wise-IoU 替换 CIoU 作为边界框回归损失，在兼顾轻量化网络的同时实现了检测精度、召回率等全面提升。最终改进的 YOLOv8n 模型如图 11 所示。

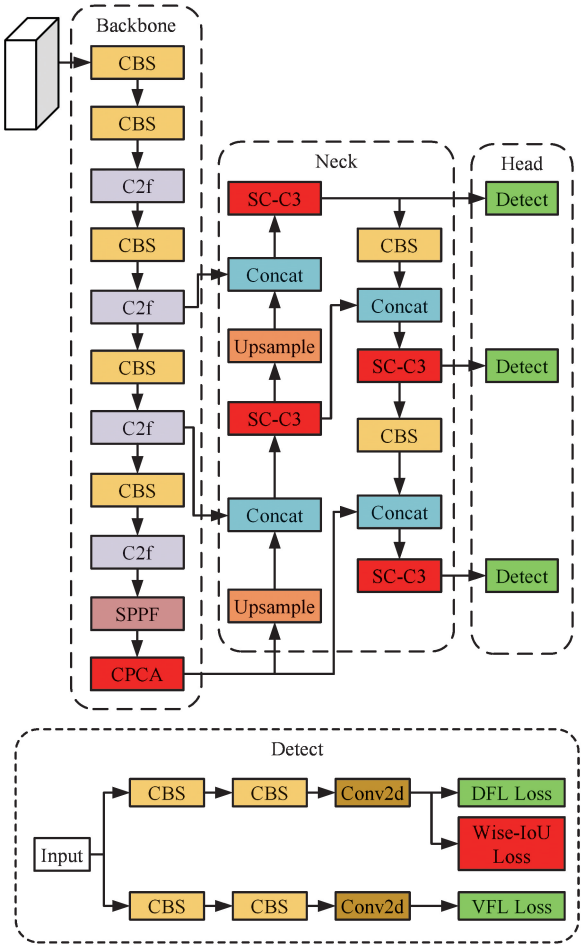



**图 11　改进的 YOLOv8n 模型网络结构**

**Fig.11　Network structure of the improved YOLOv8n model**

### 4.6　主流算法对比

将改进的 YOLOv8n 模型与原 YOLOv8n 模型以及同计算量级下的 5 种主流目标检测模型进行对比，实验结果如表 5 所示[15-18]，可以看出，原 YOLOv8n 模型的 mAP@0.5 优于其他 5 种主流模型的 mAP@0.5，在检测速度上仅仅逊色于 YOLOv5n 模型，检测性能十分优秀，故选择原 YOLOv8n 模型作为基准。

由表 5 可知，相比于原 YOLOv8n 模型，改进的 YOLOv8n 模型的召回率、准确率均更优，并且 FPS 增加了 41 帧/秒，检测精度和检测速度均有所提高。与目前性能优异的 YOLO 系列算法 YOLOv7、YOLOv5n、YOLOx 进行对比，当 IoU 为 0.5 时，改进 YOLOv8n 模型的 mAP 值分别高出 7.9、4.1、7.2 个百分点，并且检测速度略优于 YOLOv5n 模型。与 Faster R-CNN 对比，改进 YOLOv8n 模型的准确率和召回率均高出 10 个百分点以上，且 FPS 约为采用 Faster R-CNN 时的 4 倍。与同为单阶段算法的 SSD 相比，改进 YOLOv8n 模型的 mAP@0.5:0.95 高出 13.9 个百分点，FPS 约为采用 SSD 时的 1.6 倍。综上，相较于主流模型，改进 YOLOv8n 模型具有更优秀的检测性能。

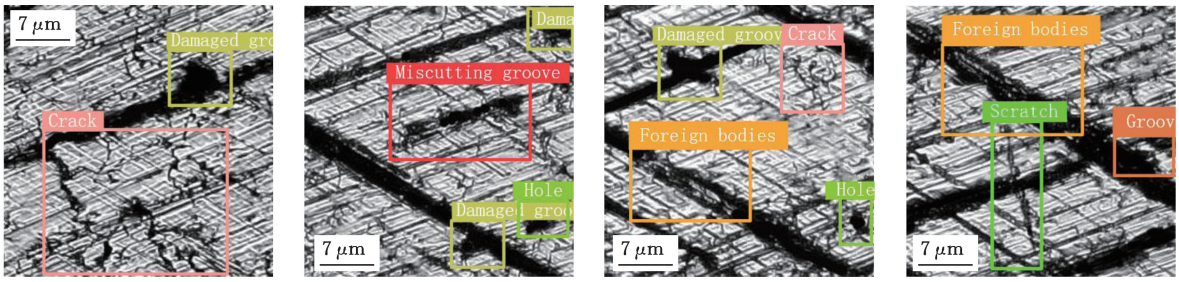
### 4.7　预测结果对比

以 4 张覆盖 7 类缺陷的气缸套图片为例，用原 YOLOv8n 模型与改进的 YOLOv8n 模型分别对测试集数据进行预测，并与原标注结果进行对比，结果如图 12 所示，其中图 12a 所示为缺陷标注结果，图 12b 所示为采用原 YOLOv8n 模型进行预测结果，图 12c 所示为采用改进 YOLOv8n 模型进行预测结果。

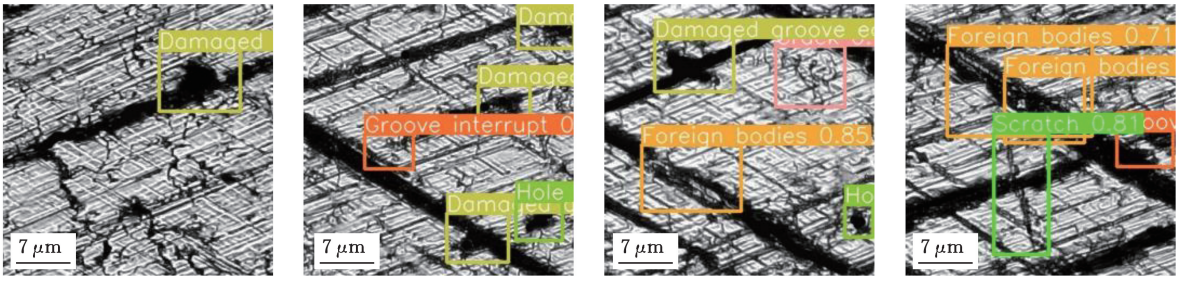
**表 5　主流算法与所提算法对比**

**Tab.5　Comparison amang main and the developed algorithms**

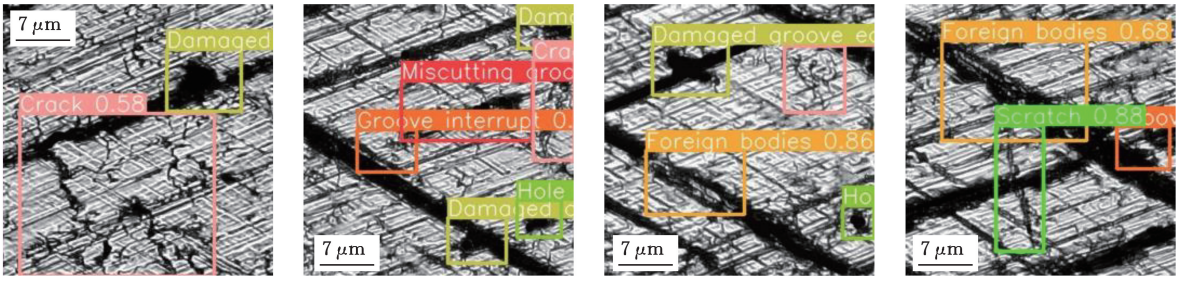
| 模型 | *P* | *R* | mAP@0.5 | mAP@0.5:0.95 | Parameters/M | GFLOPs | FPS |
|---|---|---|---|---|---|---|---|
| 原 YOLOv8n | 0.909 | 0.883 | 0.947 | 0.605 | 3.01 | 8.2 | 435 |
| YOLOv7 | 0.843 | 0.825 | 0.88 | 0.481 | 3.72 | 13.2 | 370 |
| YOLOv5n | 0.885 | 0.888 | 0.926 | 0.523 | 1.90 | 4.5 | 470 |
| YOLOx | 0.849 | 0.851 | 0.895 | 0.507 | 8.94 | 26.8 | 314 |
| Faster R-CNN | 0.764 | 0.828 | 0.854 | 0.432 | 72.06 | 692.0 | 112 |
| SSD | 0.795 | 0.849 | 0.870 | 0.457 | 24.52 | 273.7 | 287 |
| 改进 YOLOv8n(本文算法) | **0.934** | **0.925** | **0.967** | **0.598** | **2.69** | **7.5** | **476** |




(a)标注结果




(b)原 YOLOv8n 模型检测结果




(c)改进 YOLOv8n 模型检测结果

**图 12　预测结果对比**

**Fig.12　Comparison of prediction results**

由图 12 可知，原 YOLOv8n 模型出现了错检、漏检，重复检测等问题，且置信度较改进 YOLOv8n 模型更低。错检和漏检的原因主要由缺陷本身的综合性和多样性导致，置信度低则源于原模型缺陷特征识别能力和低质量样本抗干扰能力有所欠缺。以错切槽缺陷为例，错切槽缺陷与正常网纹沟槽存在相似特征，当槽的末端靠近相邻沟槽时，该缺陷部分特征亦符合沟槽中断缺陷特征，而错切槽缺陷也会存在槽边缘破损缺陷，因此一种缺陷往往综合了多种缺陷的特征。此外复杂的纹理背景增加了缺陷的多样性，尤其是裂纹缺陷。原模型对复杂纹理背景下复合型缺陷的检测能力较弱，且复合型缺陷在标注时易导致低质量样本，会进一步降低原模型的检测性能。而改进 YOLOv8n 模型利用 CPCA 机制和 Wise-IoU 损失函数可提高模型的特征提取能力，降低模型对复杂纹理背景的敏感性，降低错检率，增强模型鲁棒性。

## 5　结论

本文提出一种基于改进 YOLOv8n 模型的气缸套内表面珩磨网纹缺陷检测方法，该方法可避免检测人员主观性导致的误差，实现对沟槽破损、沟槽中断、错切槽、划痕、孔洞、裂纹、异物共 7 类缺陷的识别和定位。实验结果表明，本文提出的改进 YOLOv8n 模型实现了 2% 的检测精度提高，降低了 14.7% 的计算量，并提高了 9.6% 的检测速度，实现了对复杂纹理背景下缺陷的高速高精检测。

本研究有助于企业掌握气缸套产品质量分布情况，提高产品质量。下一步工作会将气缸套网纹结构参数和表面缺陷相结合，提出更加全面的综合质量评价方法。

**参考文献：**

[1]　陈冰，罗良，焦浩文，等. 基于磨削痕迹仿真的磨削纹理生成机理[J]. 中国机械工程，2021，32(14)：1677-1685.
CHEN Bing，LUO Liang，JIAO Haowen，et al. Mechanism of Grinding Texture Generation Based on Grinding Trace Simulation[J]. China Mechanical Engineering，2021，32(14)：1677-1685.

[2] 华希俊，符永宏，王霄，等. 内燃机缸套激光珩磨技术及其性能试验研究[J]. 中国机械工程，2007，18(24)：2989-2992.
HUA Xijun，FU Yonghong，WANG Xiao，et al. Research on Laser Honing Technology and Performance Test of Internal Combustion Engine Cylinder Liners[J]. China Mechanical Engineering，2007，18(24)：2989-2992.

[3] GÜNER M，DANIEL M，BÄHRE D. Approach and Development of a Methodology for Machining of Shapes in Cylindrical Bores by Precision Honing[J]. Manufacturing Letters，2022，33：365-372.

[4] 张农，黄凯，罗亮，等. 基于机器视觉的发动机气缸壁珩磨角测量方法[J]. 电子测量技术，2022，45(16)：123-129.
ZHANG Nong，HUANG Kai，LUO Liang，et al. Machine Vision Based Measurement Method for Honing Angle of Engine Cylinder Linear[J]. Electronic Measurement Technology，2022，45 (16)：123-129.

[5] 吕延军，强程，张永芳，等. 基于 GRNN 的珩磨缸套表面 3D 粗糙度图像检测方法[J]. 中国表面工程，2022，35(6)：116-127.
LYU Yanjun，QIANG Cheng，ZHANG Yongfang，et al. A 3D Roughness Image Detection Method for Honing Cylinder Liner Surface Based on GRNN[J]. China Surface Engineering，2022，35(6)：116-127.

[6] BEYERER J，PUENTE L F. Detection of Defects in Groove Textures of Honed Surfaces[J]. International Journal of Machine Tools and Manufacture，1997，37(3)：371-389.

[7] WANG L M. Analysis and Evaluation of Cylinder Bore Surfaces in Micrographs [D]. Karlsruhe：Karlsruhe Institute of Technology，2013.

[8] LI J F，WEN Y，HE L H. SCConv：Spatial and Channel Reconstruction Convolution for Feature Redundancy[C] // 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver，2023：6153-6162.

[9] HUANG H L，CHEN Z，ZOU Y，et al. Channel Prior Convolutional Attention for Medical Image Segmentation[J]. Computers in Biology and Medicine，2024，178：108784.

[10] TONG Z，CHEN Y，XU Z，et al. Wise-IoU：Bounding Box Regression Loss with Dynamic Focusing Mechanism[EB/OL]. ArXiv，2023：2301.10051. http：// arxiv. org/abs/2301.10051.

[11] 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.

[12] GEVORGYAN Z. SIoU Loss：More Powerful Learning for Bounding Box Regression[EB/OL]. ArXiv，2022：2205.12740. http：// arxiv. org/abs/2205.12740.

[13] HU J，SHEN L，ALBANIE S，et al. Squeeze-and-excitation Networks[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City，2018：7132-7141.

[14] WOO S，PARK J，LEE J Y，et al. CBAM：Convolutional Block Attention Module[C] // Computer Vision—ECCV 2018. Munich，2018：3-19.

[15] REN S，HE K，GIRSHICK R B，et al. Faster R-CNN：towards Real-time Object Detection with Region Proposal Networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2015，39：1137-1149.

[16] GE Z，LIU S，WANG F，et al. YOLOX：Exceeding YOLO Series in 2021 [EB/OL]. ArXiv，2021：2107.08430. http：// arxiv. org/abs /2107.08430.

[17] LIU W，ANGUELOV D，ERHAN D，et al. SSD：Single Shot MultiBox Detector[C] // Computer Vision—ECCV 2016. Amsterdam，2016：21-37.

[18] WANG C Y，BOCHKOVSKIY A，LIAO H Y M. YOLOv7：Trainable Bag-of-freebies Sets New State-of-the-art for Real-time Object Detectors[C] // 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver，2023：7464-7475.

（编辑 胡佳慧）

**作者简介**：罗 亮，男，1986 年生，博士、讲师。研究方向为先进制造、新能源关键零部件等。E-mail：Liang_LUO@hfut.edu.cn。
**祖国庆***（通信作者），男，1986 年生，副教授、博士研究生导师。研究方向为结构材料设计与开发、金属材料摩擦磨损及失效分析。E-mail：guoqingzu@yeah.net。

**本文引用格式**：
罗亮，郎霄，祖国庆，等. 一种基于改进 YOLOv8n 的气缸套缺陷检测方法[J]. 中国机械工程，2025，36(5)：1054-1064.
LUO Liang，LANG Xiao，ZU Guoqing，et al. A Cylinder Liner Defect Detection Method Based on Improved YOLOv8n[J]. China Mechanical Engineering，2025，36(5)：1054-1064.