

文章编号 1004-924X(2026)11-1776-15

基于 YOLOv8s 的复杂纹理织物缺陷轻量化高精度检测

徐士鹏¹, 王文琪^{1*}, 糜小涛², 李 兵^{1*}, 程银宝¹, 崔长彩¹

(1. 中国计量大学 计量测试与仪器学院, 浙江 杭州 310018;

2. 中国科学院 长春光学精密机械与物理研究所, 吉林 长春 130033)

摘要:针对纺织工业中织物缺陷检测因缺陷尺度微小、强纹理干扰以及形态复杂多变而面临的挑战,提出一种基于 YOLOv8s 框架的改进轻量化高精度检测模型(YOLOv8s-WRHU),提升了复杂纹理织物缺陷检测的稳定性与定位准确性。为解决多尺度特征融合中信息丢失及权重分配固定问题,设计可学习加权特征拼接模块,并构建基于该模块的加权特征金字塔网络,使模型能够自适应融合不同层次特征。在主干网络前端引入 Haar 小波下采样替代传统方法,以减少下采样过程中的高频细节损失。最后,采用动态加权统一交并比损失函数,提高边界框回归精度。通过改进颈部多尺度融合与浅层下采样模块,有效降低了模型参数量和计算复杂度。在 Roboflow 公开织物缺陷数据集上的实验结果表明,与 YOLOv8s 相比,本模型的准确率、mAP 和召回率分别提升 2.9%, 3.4% 和 1.1%, 参数量降低约 24.37%, 计算量减少 4.4 G, 在保持高精度的同时显著提升了推理效率。该模型平衡了检测精度与模型复杂度,具备工业应用潜力。

关键词:缺陷检测;轻量化 YOLOv8s;加权特征金字塔网络;Haar 小波采样;统一交并比损失函数

中图分类号:TP391.4 文献标识码:A

doi:10.37188/OPE.20263411.1776

CSTR:32169.14.OPE.20263411.1776

YOLOv8s-based lightweight and high-accuracy detection for complex-textured fabric defects

XU Shipeng¹, WANG Wenqi^{1*}, MI Xiaotao², LI Bing^{1*}, CHENG Yinbao¹, CUI Changcai¹

(1. College of Metrology & Measurement Engineering, China Jiliang University,
Hangzhou 310018, China;

2. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences,
Changchun 130033, China)

* Corresponding author, E-mail: wqwang@cljl.edu.cn; libing@cjl. edu. cn

Abstract: To address the challenges of small-scale defects, strong textural interference, and diverse defect morphologies in textile inspection, a lightweight and high-accuracy model, YOLOv8s-WRHU, is proposed based on the YOLOv8s framework. The model is designed to enhance robustness and localization accuracy for defect detection in complex-textured fabrics. Systematic improvements are introduced in three key aspects: feature fusion, detail enhancement, and localization optimization. First, to alleviate informa-

收稿日期:2026-02-24;修订日期:2026-04-22.

基金项目:浙江省自然科学基金资助项目(No. LQN26E050016)

tion loss and fixed weight assignment in multi-scale feature fusion, a learnable weighted feature concatenation module is designed, and a weighted feature pyramid network built upon this module is introduced to adaptively fuse features from different levels. Second, Haar wavelet downsampling is incorporated into the early stage of the backbone network to replace conventional downsampling methods, thereby reducing the loss of high-frequency details. Third, a dynamically weighted unified IoU loss function is employed to improve bounding box regression accuracy. In addition, optimizations of the multi-scale fusion strategy in the neck and the shallow downsampling modules effectively reduce the parameter count and computational complexity of the model. Experimental results on the public Roboflow fabric defect dataset show that, compared with YOLOv8s, the proposed model improves precision, mAP, and recall by 2.9%, 3.4%, and 1.1%, respectively, while reducing the number of parameters by approximately 24.37% and computational cost by 4.4 G. High detection accuracy is maintained with significantly improved inference efficiency. The proposed model achieves a favorable balance between detection accuracy and model complexity, demonstrating strong potential for practical industrial applications.

Key words: defect detection; lightweight YOLOv8s; weighted feature pyramid network; Haar wavelet downsampling; unified IoU loss function

1 引 言

织物表面缺陷检测是纺织工业质量控制的核心环节,其检测结果的准确性与实时性直接影响产品等级评定、生产成本控制与流程优化^[1]。视觉检测能够实现非接触、在线式检测,为纺织缺陷的自动化检测提供了高效的技术路径^[2]。然而,在实际生产中,织物缺陷常表现为弱对比度、小尺度且形态多样,并与复杂背景纹理难以区分^[3]。传统图像处理的方法虽计算效率较高,但对人工设计特征依赖较强,在弱特征缺陷和复杂纹理背景的检测性能受限。

近年来,深度学习技术迅猛发展,基于卷积神经网络(Convolutional Neural Network, CNN)能够从大规模标注数据中自动学习缺陷表征,在复杂工业场景下表现出较好的检测性能。以 YOLO 系列为代表的一阶段目标检测算法,凭借端到端训练范式与高效推理性能,在工业在线检测场景中得到了广泛应用^[4]。孙小栋等^[5]针对超纤革表面多尺度、微小瑕疵多的检测难点,提出 MFL_YOLOv8 算法,通过改进特征提取模块与损失函数,显著提升了小尺寸瑕疵的检测精度。孙世政等^[6]面向复杂环境下的垃圾检测任务,对 YOLOv8n 进行轻量化改进,大幅降低了模型复杂度并优化在遮挡场景下的检测性能。

然而,将此类通用目标检测框架直接迁移至

织物缺陷检测任务时,仍存在以下三方面问题。其一,连续步长的卷积下采样易导致小尺度与细长缺陷的高频细节丢失,削弱了边缘及纹理特征的代表能力。其二,标准卷积局限于局部感受野内的特征建模,难以有效捕捉织物表面因强周期性和重复纹理而产生的长距离依赖关系。其三,传统的特征金字塔网络在跨尺度特征融合过程中多采用线性拼接或简单加和方式,缺乏对不同层级语义信息的自适应权重分配机制,因而易引入背景噪声,诱发误检。

针对上述问题,现有研究主要从特征融合、细节保留和优化策略等方面进行改进。在特征提取与融合方面,吕世杰等^[7]结合空间深度转换卷积与多尺度特征金字塔以减少信息损失。张平等^[8]则引入轻量级特征融合与注意力机制,利用视觉 Transformer 为复杂纹理检测的场景提供了新思路。在泛化与环境适应性方面,张俊杰等利用 CycleGAN 与 YOLO 结合的数据增强策略提升泛化能力,而 Revathy 等^[8]通过预处理优化与分割模型改进,有效提升了背景干扰下的分类精度。此外,李叔罡等^[9]提出的跨域对齐方法改善了数据分布差异导致的性能下降问题。在定位优化方面^[10],部分研究通过改进损失函数解决分类与定位错位的问题^[11],且特征增强与迁移学习^[12]也是目前研究中的主要改进方向^[13]。尽管上述方法在一定程度上提高了检测性能,但在

细长缺陷建模、复杂纹理背景抑制、跨数据集适应性^[14]以及轻量化部署方面仍存在不足^[15]。

基于上述分析,本文在 YOLOv8s 框架^[16]基础上,提出一种面向复杂纹理织物缺陷的轻量化高精度检测模型 YOLOv8s-WRHU。针对多尺度特征融合中不同层级信息贡献不均衡的问题,设计了一种可学习加权的特征金字塔网络(WRepGFPN),强化跨尺度特征的语义信息融合与关键特征提取能力;针对下采样过程中的细节丢失问题,在骨干网络浅层采用 Haar 小波变换替代传统的池化或跨步卷积下采样。该方法能更有效地分离并保留包含缺陷边缘与纹理细节的高频成分,增强模型对小尺度及低对比度缺陷的感知能力;在边界框回归任务中,引入了 Unified-IoU 动态加权损失函数。该损失通过综合考虑重叠面积、中心点距离与纵横比差异,并赋予动态调整的权重,实现了对缺陷框由粗到精的稳定优化,提升了复杂形状缺陷的定位精度。

2 原 理

2.1 YOLOv8s WRHU 模型

YOLOv8s 主要以主干网络、颈部网络以及

检测头三大部分组成。其中,颈部网络通常采用路径聚合网络(PANet)结构来进行多尺度特征融合^[17]。PANet通过自顶向下的路径传递高层语义信息,借助自底向上的路径补充低层定位信息,从而增强不同尺度特征之间的信息交互能力^[18]。然而,标准的 PANet 结构在织物缺陷检测任务中仍存在局限性:一方面,在深层特征向浅层传递的过程中,微小缺陷的关键语义信息易被稀释;另一方面,在浅层特征向深层汇聚过程中,精确的边缘和定位信息易丢失,导致模型难以在复杂背景下精确捕捉到细微及尺度差异较大缺陷。

为应对工业场景下织物缺陷检测面临的尺度跨度大、背景复杂等任务需求,本文以 YOLOv8s 为基础架构,通过深度优化算法模块,提出了改进模型 YOLOv8s-WRHU。该模型分别从头部网络下采样结构、颈部网络多尺度特征融合以及边界框回归策略 3 个方面进行了针对性改进,其整体架构如图 1 所示。

为解决主干网络在早期下采样过程中高频细节信息的损失,本文采用 Haar 小波下采样模块替代传统的 Stride-2 下采样层,以保留更多与缺陷判别相关的高频纹理和边缘信息。该设计




图 1 YOLOv8s-WRHU 模型结构

Fig. 1 Structure of YOLOv8s-WRHU model

有助于保留对微小裂纹、细长缺陷及弱边界区域判别的高频特征。在多尺度特征融合阶段,本文构建了WRepGFPN颈部结构,并引入可学习加权融合模块WConcat,以增强高层强语义信息与浅层高分辨率特征之间的交互,同时减弱复杂织物底纹带来的冗余响应,该结构更适用于复杂纹理背景下的多尺度缺陷表征与融合。在边界框回归阶段引入了Unified-IoU(UIoU)损失策略,通过动态调节预测框与真实框之间的交互区域,使训练过程由粗定位逐步过渡到精细边界贴合,从而更适用于细长、弱边界织物缺陷的定位优化。

2.2 WRepGFPN 融合网络

广义金字塔连接(Generalized-FPN Connections, GFPN)不同于PANet仅依赖相邻层级的路径聚合,在保留自顶向下和自底向上信息传递路径的基础上,引入了更密集的跨越层级的跳跃连接以及同层级内部的横向连接。在织物缺陷检测任务中,这种结构有助于增强不同尺度特征之间的直接交互,高层强语义信息能够更充分地跨层注入浅层,同时浅层的高分辨率纹理与边缘信息也能更有效地与深层表征融合。因此,相较于标准PANet,RepGFPN更适用于复杂纹理织物缺陷检测中的多尺度融合基础。然而,RepGFPN颈部结构中普遍采用特征拼接融合方式进行多尺度融合,即在通道维度上直接拼接各分支

特征,再通过后续卷积完成信息整合。该方法实现简单,但默认各尺度分支对融合结果的贡献相等,缺乏区分性。实际织物缺陷中,断经、裂纹等细长缺陷更依赖浅层高分辨率的纹理与边缘线索,而污渍、破洞等较大尺度缺陷则需要深层语义信息。若采用无差别的特征堆叠,不仅增加后续卷积的筛选负担,还容易将织物底纹引起的冗余响应引入融合结果,进而影响小尺度缺陷的表征能力与跨层语义对齐。

针对上述问题,本文在RepGFPN基础上提出可学习加权融合模块WConcat,并构建WRepGFPN融合网络以替代传统硬拼接方式。该模块可自适应调整不同尺度特征在融合中的权重,使网络根据缺陷类型动态聚焦有效特征分支,从而提升复杂纹理背景下多尺度缺陷的表征与融合能力。

图2展示了WRepGFPN的整体融合结构。本文在关键融合节点引入WConcat模块,以替代传统的直接通道拼接方式。考虑到不同尺度特征分支在通道维度和语义贡献上存在差异,WConcat首先对各分支特征进行通道对齐,进一步通过可学习权重实现自适应融合。假设经过上采样或者下采样后得到的 n 路输入特征为 $\{x_i\}_{i=1}^n$,其中每个特征满足 $x_i \in \mathbf{R}^{C_i \times H \times W}$,且所有特征的空间分辨率均已对齐至 $H \times W$ 。由于各分支通道数 C_i 通常不一致,WConcat模块首先对




图2 WRepGFPN网络结构

Fig. 2 Structure of WRepGFPN network

每一路特征执行通道对齐与重编码,使用独立的 1×1 卷积映射到统一通道维 C :

$$\hat{x}_i = \phi_i(x_i), \hat{x}_i \in \mathbf{R}^{C \times H \times W}, i = 1, \dots, n, \quad (1)$$

其中: ϕ_i 表示第 i 路分支的 1×1 卷积(通常包含 BN 与激活),其作用是将不同来源、不同通道维度的特征投影到同一表征空间,便于后续进行可加性融合。

完成通道对齐后, WConcat 为每一路分支引入可学习权重 w_i , 并采用非负约束与归一化策略获得稳定的融合系数。即先通过 ReLU 将权重限制为非负:

$$\alpha_i = \text{ReLU}(w_i). \quad (2)$$

然后,进行归一化以避免权重尺度不受控并增强数值稳定性:

$$\tilde{\alpha} = \frac{\alpha_i}{\sum_{j=1}^n \alpha_j + \epsilon}, \quad (3)$$

其中: ϵ 为极小常数,用于防止分母为零并抑制极端权重带来的梯度震荡。最终,融合输出特征由各路对齐特征的加权求和得到:

$$y = \sum_{i=1}^n \tilde{\alpha} \cdot \hat{x}_i, y \in \mathbf{R}^{C \times H \times W}. \quad (4)$$

上述公式体现了 WConcat 的核心思想,在融合阶段显式学习不同尺度的贡献度,而非像传统 Concat 那样先在通道维进行硬拼接后交由后续卷积被动筛选。进一步从优化角度分析,若检测损失为 L ,则对第 i 路输入对齐特征的梯度满足:

$$\frac{\partial L}{\partial \hat{x}_i} = \tilde{\alpha} \cdot \frac{\partial L}{\partial y}. \quad (5)$$

归一化权重 $\tilde{\alpha}$ 直接影响各分支所接收的梯度强度,从而实现多尺度特征贡献的自适应调。该机制有助于减弱复杂底纹带来的冗余响应,并增强浅层纹理与边缘线索对融合结果的有效贡献。

除关键融合机制外, WRepGFPN 还引入了 CSPStage 结构,以增强融合节点的特征表达能力。RepGFPN^[19] 在特征融合节点中集成了 CSPNet 与 ELAN 架构,并引入了结构重参数化 (Structural Re-parameterization), CSPStage 模块的具体结构如图 3 所示。

图 3 展示了 CSPStage 模块的结构。图 3(a) 为训练阶段的多分支结构,该结构通过并行分支增强特征表达能力,以提高模型对复杂织物底纹




图 3 CSPStage 网络结构

Fig. 3 Structure of CSPStage network

中微弱缺陷纹理的表征能力。图 3(b) 为推理阶段经结构重参数化后的等效结构,它将训练阶段的多分支表示转换为单分支卷积形式,从而在保持表征能力的同时降低推理开销。由图 3 可知, CSPStage 的设计兼顾了训练阶段的表达丰富性与推理阶段的结构简化需求,适合用于复杂纹理背景下的高效特征融合。

由此可见, WRepGFPN 通过 WConcat 与 CSPStage 的协同设计,实现了对不同尺度特征贡献的自适应调节与高效整合,更适用于复杂纹理背景下的织物缺陷特征融合任务。

2.3 Haar 小波下采样

在织物缺陷任务中,缺陷往往呈现低对比度、细长、细碎以及与背景纹理强耦合视觉特征,常规步长卷积或池化下采样在降低空间分辨率的同时,容易削弱浅层高频细节信息,从而影响微小缺陷和细长缺陷的表征能力。为减小这一过程中的信息损失,本文采用 HWD 替代传统步长卷积下采样,以保留更多与缺陷识别相关的纹理和边缘信息。HWD 通过对输入特征在局部邻

域内进行小波分解,将原始空间信息拆分到不同频带中,从而在降低分辨率的同时保留更多方向性纹理和边缘响应。对输入特征图(单通道) X 取 2×2 邻域:

$$\begin{aligned} x_{00} &= X(2i, 2j), x_{01} = X(2i, 2j+1) \\ x_{10} &= X(2i+1, 2j), x_{11} = X(2i+1, 2j+1) \end{aligned} \quad (6)$$

则4个子带可以直接写为:


$$\begin{aligned} LL(i, j) &= \frac{x_{00} + x_{01} + x_{10} + x_{11}}{2}, \\ LH(i, j) &= \frac{x_{00} - x_{01} + x_{10} - x_{11}}{2}, \\ HL(i, j) &= \frac{x_{00} + x_{01} - x_{10} - x_{11}}{2}, \\ HH(i, j) &= \frac{x_{00} - x_{01} - x_{10} + x_{11}}{2}, \end{aligned} \quad (7)$$

其中: X 为输入特征图,二维矩阵,尺寸为 $H \times W$; (i, j) 为下采样后的坐标索引, LL 表示低频近似分量,主要保留输入特征的整体轮廓信息, LH, HL 和 HH 分别对应不同方向的高频响应,对垂直变化、水平变化以及对角纹理变化

更为敏感。这些方向性高频信息有助于保留裂纹、断纱及局部纹理突变等缺陷的判别线索,从而减轻传统下采样造成的细节损失。


本文将HWD置于在Backbone浅层,一方面浅层特征对纹理、边缘、细小结构最敏感,而传统下采样过程中带来的不可逆信息丢失往往在这一阶段发生;另一方面,HWD将方向性高频信息显式编码出来,从而使后续C2f模块在更低分辨率下仍能找到缺陷边界与纹理突变的表征能力。

图4展示了Haar小波下采样^[20]的基本原理及其对特征保留效果的影响。图4(a)为Haar小波分解原理示意图,输入特征在 2×2 局部邻域内被分解为 LL, LH, HL 和 HH 4个子带。图4(b)为下采样效果对比示意图,说明采用HWD后,特征图在降低空间分辨率的同时仍能较好保留边缘与纹理细节。对于织物缺陷检测任务而言,该特性有利于保留细长缺陷及弱边界缺陷的判别信息,从而缓解传统步长卷积下采样带来的细节丢失问题。



(a) Haar小波下采样原理

(a) Haar wavelet downsampling principle



(b) Haar小波下采样效果

(b) Haar wavelet downsampling result

图4 Haar小波下采样原理及效果

Fig. 4 Principle and result of Haar wavelet downsampling

由此可见,HWD在降低特征分辨率的同时保留了低频整体轮廓与高频异常响应,更适用于处理具有重复纹理背景和局部突变缺陷并存的织物缺陷检测任务。

2.4 UIoU 交互比损失函数

在织物缺陷检测任务中,部分目标具有细长、低对比度和弱边界等几何特征。这类目标在训练早期往往只能得到质量较低的预测框,若直接采用对高质量重叠更敏感的回归损失,容易导致低质量预测框获得的有效优化信号不足,从而影响后续边界贴合精度。针对这一问题,本文引入 Unified-IoU (UIoU) 损失^[21],不再继续叠加新的几何惩罚项,而是通过动态缩放预测框与真实框的交互区域,使回归过程由训练早期的粗定位逐步过渡到训练后期的精细配准,从而更适应细长缺陷和弱边界缺陷的定位优化需求。

UIoU的核心在于引入一个随训练阶段变化的缩放因子 r 。在计算交互比之前,保持预测框与真实框中心点不变,并对两者尺寸进行同步缩放,从而得到新的边界框表示,设 $B_{gt}=(x_{gt}, y_{gt}, w_{gt}, h_{gt})$ 为织物缺陷的真实边界框, $B_p=(x_p, y_p, w_p, h_p)$ 表示中心点坐标, (w, h) 表示宽和高。

UIoU引入一个随训练阶段变化的缩放因子 r 。在计算交互比之前,保持中心点坐标不变,对预测框和真值框的尺寸同步缩放,得到新的边界框 B_{gt}' 和 B_p' :

$$\begin{aligned} w_{gt}' &= w_{gt} \times r, h_{gt}' = h_{gt} \times r \\ w_p' &= w_p \times r, h_p' = h_p \times r \end{aligned} \quad (8)$$

其中:中心点坐标保持不变,即 $x'=x, y'=y$ 。此时,修正后的UIoU定义为缩放后新框的交互比:

$$UIoU_{val} = \frac{Area(B_{p'} \cap B_{gt'})}{Area(B_{p'} \cup B_{gt'})}. \quad (9)$$

为了实现从关注检出率到关注定位精度的平滑过渡,引入余弦退火的缩放因子衰减策略。设当前训练轮次为 t ,总训练轮次为 T_{max} ,则:

$$r(t) = 0.75 \times \cos\left(\frac{t}{T_{max}} \pi\right) + 1.25. \quad (10)$$

式(10)表明, r 随训练轮次按余弦退火策略动态变化,并由训练初期的较大取值逐步减小至训练后期的较小取值。该变化用于调节不同阶

段边界框回归的优化侧重点。

结合YOLOv8的回归分支,最终的边界框回归损失函数 L_{UIoU} 定义为:

$$L_{UIoU} = 1 - UIoU_{val}. \quad (11)$$

与继续叠加几何惩罚项的回归损失不同,UIoU更关注不同训练阶段中预测框质量差异对优化过程的影响,通过动态调节交互区域实现由粗定位到精细贴合的平滑过渡。

图5展示了UIoU的边界框动态缩放机制。该机制引入一个可动态调整的比例系数,其值随训练轮次增加而逐步衰减。在训练早期,该系数





图5 UIoU 模块示意图

Fig. 5 Schematic diagram of UIoU module

取值较大,从而扩大预测框与真实框之间的有效交互区域,使低质量预测框能够获得更稳定的优化信号,显著缓解因初始定位偏差过大而导致的梯度不稳定问题,提升粗定位阶段的收敛稳定性。随着训练进程推进,比例系数逐步减小,交互区域相应收缩,损失函数对边界偏移和尺度偏差的敏感度随之增强,优化重点从目标检出自然过渡到边界贴合。

对于细长、弱边界缺陷(如断经、裂纹等),该机制展现出独特优势。训练早期的宽交互区域可有效缓解边界框回归初期的抖动与错位现象,避免模型陷入局部最优;训练后期收缩的交互区域则迫使网络精细调整预测框的边界位置,显著提高检测框与真实缺陷区域之间的匹配精度。

因此,UIoU 通过动态调节交互区域实现了边界框优化重点的阶段性迁移,克服了传统 IoU 及其变体采用固定交互范围所导致的“低质量框优化困难”与“精细定位不足”之间的矛盾,更适合处理具有长宽比变化明显、边界模糊且定位敏感特征的织物缺陷目标。

3 实验与分析

3.1 数据集以及实验环境

实验数据集来自 roboflow 的 fabric defect detection jdyz3^[22],包括 5 810 张织物缺陷的图片,如图 6 所示。图像尺寸统一为 640×640,该公开数据集主要包含 4 类织物缺陷:污渍、切割、破洞和纱线错误。各类缺陷在对比度表现、几何形状及纹理影响等方面存在明显差异,其特征对比如表 1 所示。

实验基于 Windows 系统平台,深度学习框架采用 Ultralytics YOLO(8.3.86),运行环境为

表 1 缺陷特征对比

Tab. 1 Comparison of defect features

缺陷类型	对比度表现	几何形状	纹理影响
污渍	较高	不规则块状	表面覆盖
切割	中高	细长线状	纤维切断
破洞	极高	闭合空腔	物质缺失
纱线错误	极低	线性、点状	结构畸变




图 6 织物缺陷数据集

Fig. 6 Fabric defects dataset

Python3.9.25 与 PyTorch 2.6.0 (CUDA 11.8), GPU 选用 NVIDIA GeForce RTX4060Ti (8GB 显存)。训练输入尺寸设为 640×640 , 训练轮数为 150, 初始学习率 $lr_0=0.01$, 末端学习率系数 $lrf=0.01$, 动量 $momentum=0.937$, 权重衰减 $weight_decay=0.0005$, 并设置 $warmup_epochs=3.0$ 。

3.2 评价指标

检测精度和检测速度是衡量模型性能的重要指标。本文采用的模型评价指标有准确率 (P)、召回率 (R)、平均精度 (AP) 以及平均均值精度 (mAP)。计算公式如下:

$$P = \frac{TP}{TP + FP}, \quad (12)$$

$$R = \frac{TP}{TP + FN}, \quad (13)$$

其中: TP 为正确检测出的缺陷目标数, FP 表示误检出的缺陷目标数, FN 为漏检的缺陷目标数, AP 为平均准确率, 代表所有可能召回值获得的所有准确率的平均值。 mAP 是所有类别 AP 的

平均值。 AP , $F1$ 和 mAP 的计算公式如下:

$$AP = \frac{TP + TN}{TP + TN + FP}, \quad (14)$$

$$F1 = 2 \times \frac{P \times R}{P + R}, \quad (15)$$

$$mAP = \frac{1}{m} \sum_{i=1}^m AP(i), \quad (16)$$

其中: TN 为同时准确检测到的布匹缺陷数量, i 为具体类别, $mAP(i)$ 为第 i 类的平均精度, m 为数据集对类别的总体分类计数。

3.3 消融实验

对织物缺陷区域进行检测, 图像检测效果如图 7 所示, 采用消融实验对 YOLO-WRHU 检测性能进行验证。首先, 将 WRepGFPN, Haar 小波下采样以及 UIoU 损失函数 3 个模块分别添加到 YOLOv8s 网络中, 以验证各个模块对 YOLOv8 网络检测效果的提升作用。然后, 将 3 种改进模块全部加入 YOLOv8s 网络模型中, 对改进模型的检测精度、召回率、 mAP 和参数量等指标进行评估, 综合验证改进后的 YOLOv8s-WRHU 模型的检测能力。




图 7 缺陷检测结果对比

Fig. 7 Result comparison of defects detection

消融实验结果如表 2 所示。3 种改进模块的作用如下: WRepGFPN 网络以强化跨尺度特征融合, 以及使网络能够根据任务数据分布自动学习不同尺度特征的有效贡献; Haar 小波下采样能

够保留模型在前期容易丢失的高频信息, 从机制上更有利于保留微小纹理缺陷与弱边界线索; UIoU 损失函数使训练过程从早期的粗定位快速收敛逐步过渡到后期的高质量精定位优化, 避免

大量低质量候选框长期主导梯度更新,从而提升 高 IoU 阈值下的定位精度与稳定性。

表 2 消融实验检测结果

Tab. 2 Detection results of ablation experiments

算 法	$P/\%$	$R/\%$	mAP@ 0.5/ $\%$	mAP@0.5: 0.95/ $\%$	Param	GFLOPs
YOLOv8s	77.5	72.5	76.2	46.2	11 127 132	28.4
YOLOv8s+WRepGFPN	78.3	71.3	77.8	47.0	9 383 270	26.3
YOLOv8s+HWD	78.1	74.4	78	46.4	10 258 652	26.4
YOLOv8s+UIoU	77.9	75.3	79.5	49.5	11 127 132	28.4
YOLOv8s+WRepGFPN+HWD	75.7	72.2	76.8	45.5	8 431 712	24.0
YOLOv8s+WRepGFPN+UIoU	77.4	74.2	78.7	49.2	9 300 192	26.1
YOLOv8s+HWD+UIoU	78.5	74.1	78.7	47.2	10 258 652	26.4
YOLOv8s-WRHU	80.4	73.6	79.6	47.9	8 415 070	24.0

由检测结果可知,使用YOLOv8s进行织物缺陷识别检测时召回率为72.5%,训练平均精度为76.2%。分别将WRepGFPN, Haar小波下采样以UIoU损失函数3个模块分别添加到YOLOv8s,可得改进后的网络检测精度分别为78.3%, 78.1%, 77.9%; mAP@0.5值分别为77.8%, 78%, 79.5%。可以看出, WRepGFPN对检查精度影响较大,引入的UIoU对平均精度

影响最大。

消融实验结果表明, YOLOv8s-WRHU网络模型与原网络模型相比,检测精度提升2.9%,平均检测精度提高3.4%,召回率提升1.1%,参数量下降近30%,计算量降低4.4 G,因此检测速率较高,如图8所示。YOLOv8s-WRHU检测模型的性能显著提升,具有较好的稳定性。




图 8 YOLOv8s-WRHU 与 YOLOv8s 的检测精度和平均精度对比

Fig. 8 Comparison of detection precision and average precision between YOLOv8s-WRHU and YOLOv8s

3.4 不同边界框回归损失函数对比实验

为进一步验证UIoU的有效性,本文在保持

网络结构、训练策略及实验配置一致的条件下,将它与CIoU, EIoU 和 WIoU 等常用边界框回归

损失函数进行了对比。由于该组实验仅替换回归损失函数,网络结构保持不变,因此各模型的参数量与GFLOPs保持一致,性能差异主要来源于不同损失函数对边界框优化方式的影响。当前稿件中的实验环境保持为 Windows 平台、Ultralytics YOLO 8.3.86、PyTorch 2.6.0、输入尺寸为 640×640 、训练轮数为 150。

由表 3 可知,不同损失函数对应模型的参数

量与GFLOPs完全一致,说明边界框回归损失函数的替换不会改变模型推理阶段的结构复杂度。相比CIoU,EIoU和WIoU,UIoU在 $P,R,mAP@0.5$ 以及 $mAP@0.5:0.95$ 指标上均取得了更优结果,表明它在当前织物缺陷检测任务中具有更好的边界框回归能力。CIoU与EIoU的整体性能较为接近,而WIoU在本任务中的检测性能下降较为明显。

表 3 不同边界框回归损失函数的对比实验结果

Tab. 3 Comparison experiment results of different bounding box regression loss functions

算 法	$P/\%$	$R/\%$	$mAP@0.5/\%$	$mAP@0.5:0.95/\%$	Param	GFLOPs
YOLOv8s-WRHC(CIoU)	45.5	50.1	44.7	23.8	8 415 070	24.0
YOLOv8s-WRHE(EIoU)	49.3	48.8	43.8	23.2	8 415 070	24.0
YOLOv8s-WRHW(WIoU)	30.8	17.2	15.0	6.9	8 415 070	24.0
YOLOv8s-WRHU(UIoU)	80.4	73.6	79.6	47.9	8 415 070	24.0

3.5 跨数据集泛化验证

为进一步验证所提模型的跨数据集适应能力,本文在原有公开织物缺陷数据集实验基础上,补充采用第二个数据集进行测试^[23]。为保证对比结果的可比性,第二数据集实验中模型结构、训练策略、输入尺寸及评价指标均与前述实验保持一致,仅对数据来源进行更换。

由表 4 可知,在第二数据集上,YOLOv8s-

WRHU的 $mAP@0.5$ 由80.2%提升至82.5%,提高了2.3%; $mAP@0.5:0.95$ 由38.5%提升至40.4%,提高了1.9%;召回率由76.9%提升至80.5%,提高了3.6%。与此同时,改进模型参数量由11 127 906降至8 415 844,计算量由28.4 GFLOPs降至24.0 GFLOPs,说明所提模型在保持轻量化特征的同时,仍能够在新的数据分布下取得较优的综合检测性能。

表 4 第二数据集泛化验证结果

Tab. 4 Generalization validation results on second dataset

算 法	$P/\%$	$R/\%$	$mAP@0.5/\%$	$mAP@0.5:0.95/\%$	Param	GFLOPs
YOLOv8s	85.0	76.9	80.2	38.5	11 127 906	28.4
YOLOv8s-WRHU	84.7	80.5	82.5	40.4	8 415 844	24.0

上述结果表明,在更换数据来源后,YOLOv8s-WRHU仍能保持较好的检测性能提升趋势,尤其在召回率和 mAP 指标上表现出更优结果,说明所提方法并非仅对单一数据集有效,而对复杂纹理织物缺陷检测任务具有一定的跨数据集适应能力^[24]。结合轻量化结果可以看出,本文提出的特征融合、下采样及边界框回归优化策略在不同数据分布条件下具有一定稳定性。

3.6 对比实验

为了验证 YOLOv8s-WRHU 算法的检测能

力和稳定性,在相同实验环境下,分别采用YOLOv8-p2,YOLOv10s,YOLOv12,YOLO26-s算法对织物缺陷进行检测^[25],并对检测性能进行对比,实验结果如表5所示。

由表5可知,YOLOv8s-WRHU的召回率达到73.6%,表现最优,同时在核心指标上取得 $mAP@0.5=79.6\%$ 与 $mAP@0.5:0.95=47.9\%$,两项均为表中最佳,说明该模型不仅能更充分地检出缺陷目标,还能在更严格的IoU阈值下保持更高的定位质量^[26]。与原始YOLOv8s相比,YOLOv8s-WRHU在 $mAP@0.5$ 与 $mAP@$

表 5 不同算法对复杂织物缺陷检测对比实验数据

Tab. 5 Comparative experiment data of complex-textured fabric defects detection by different algorithms

算 法	<i>P</i> /%	<i>R</i> /%	mAP@0.5/%	mAP@0.5:0.95/%	Param	GFLOPs
YOLOv8s	77.5	72.5	76.2	46.2	11 127 132	28.4
YOLOv8-p2	70.9	68.8	71.6	41.6	2 921 568	12.2
YOLOv10s	60.9	66.3	61.8	36.3	8 038 056	24.5
YOLOv12	66.1	60.8	63.6	33.6	2 557 508	6.3
YOLO26-s	56.2	61.4	59.1	32.8	9 466 728	20.5
YOLOv8s-WRHU	80.4	73.6	79.6	47.9	8 415 070	24.0

0.5:0.95 上分别提升 3.2% 与 1.7%,并且在参数量从 11.13 M 降至 8.41 M 的情况下仍实现更高精度,体现了改进结构带来的有效特征表达与更优的效率与精度平衡。与 YOLOv8s, YOLOv8-p2, YOLOv10s 及 YOLOv12 等模型相比, YOLOv8s-WRHU 在 mAP 指标上同样保持显著优势^[27]。

3.7 轻量化特征及边缘部署潜力分析

为进一步说明所提模型的工程可用性,本文从整体复杂度变化、关键节点参数压缩及边缘部署潜力三个方面对 YOLOv8s-WRHU 进行分析。与 YOLOv8s 相比,改进模型的参数量由 11 127 132 降至 8 415 070,下降约 24.37%;计算量由 28.4 GFLOPs 降至 24.0 GFLOPs,下降约 15.49%,表明所提方法在保持检测性能提升的同时实现了较好的轻量化效果。

替换为 HWD 下采样模块,并在 Neck 中采用 WConcat 与 CSPStage 优化多尺度融合路径,从而减少通道冗余和后续卷积整合负担。与此同时,改进模型将检测头三尺度输入通道由基线模型的 128,256 和 512 统一压缩为 128,128 和 128,使 Detect Head 输入总通道数由 896 降至 384,减少约 57.14%。表 6 进一步给出了关键轻量化节点的参数量对比,说明模型复杂度下降主要来源于下采样模块、深层融合节点和检测头输入端的结构性压缩。

表 6 YOLOv8s 与 YOLOv8s-WRHU 关键轻量化节点参数量对比

Tab.6 Parameter comparison of key lightweight nodes between YOLOv8s and YOLOv8s-WRHU

节 点	基线 参数量	WRHU 参数量	降低 比例/%
Downsample-1	18 560	8 384	54.83
Downsample-2	73 984	33 152	55.19
Downsample-3	295 424	131 840	55.37
Downsample-4	1 180 672	525 824	55.46
关键融合节点 A	591 360	509 696	13.81
关键融合节点 B	1 969 152	160 640	91.84
Detect Head	2 118 370	1 233 634	41.76
总模型	11 127 132	8 415 070	24.37




图 9 YOLOv8s 与 YOLOv8s-WRHU 关键轻量化节点结构对比

Fig. 9 Structural comparison of key lightweight nodes between YOLOv8s and YOLOv8s-WRHU

图 9 表明,本文并非通过显著减少 Backbone 中 C2f 模块重复次数实现压缩,而是在保持主干层级基本稳定的前提下,将传统步长卷积下采样

本文模型具备较低的参数量和计算量,能够有效降低其在低功耗边缘设备上的存储与计算开销,这表明 YOLOv8s-WRHU 具有在资源受限平台部署的潜力^[28]。综合模型复杂度分析,该模型已具备面向边缘端应用的基础条件,后续将结合模型量化、剪枝压缩及轻量化推理框架优化,进一步开展基于嵌入式硬件平台的推理性能评估与工业现场应用研究^[29]。

4 结 论

本文针对纺织工业缺陷检测面临的织物缺陷小目标占比高、底纹干扰强、边界模糊且形态多样等检测难点,在YOLOv8s框架基础上进行改进,并通过消融实验验证了各模块的有效性。结构层面引入WRepGFPN模块,增强了跨尺度特征的信息回流能力,提升了细节纹理在特征金字塔中的传递效率;在特征融合层面,提出了一种选择性加权融合策略,将其部署于对小缺陷敏感的关键节点,在保持表征能力的同时避免全局融合可能带来的性能波动;在骨干网络早期采用 Haar 小波下采样替代部分步长卷积,从而更有效地保留高频边缘与细微纹理信息;在边界框回归方面,结合 Unified-IoU 的动态优化机制,使训练过程更贴合“由粗到精”的定位收敛规律,从而提升检测框与真实缺陷区域的

贴合精度。实验结果表明,上述改进在复杂纹理背景下显著增强了模型对微小及细长缺陷的稳定检出能力,同时验证了多模块协同设计中“关键位置优先、训练动态匹配”原则的有效性,为实现检测精度与模型稳定性的平衡提供了可靠方案。

作者贡献声明:

徐士鹏:算法提出,实验程序编写,实验数据整理,论文初稿撰写;

王文琪:论文架构设计,改进模型算法优化与程序修改,初稿撰写与编辑;

糜小涛:模型优化与修改,初稿撰写;

李 兵:实验设计,实验数据分析;

程银宝:对比实验与轻量化思路提出,实验指导;

崔长彩:论文审核与编辑,写作指导。

参考文献:

- [1] 郑兆伦,鲁玉军. 基于奇异值分解的双算法织物缺陷检测[J]. 纺织学报, 2022, 43(11): 59-67.
ZHENG ZH L, LU Y J. Dual-algorithm for fabric defect detection based on singular value decomposition [J]. *Journal of Textile Research*, 2022, 43 (11): 59-67. (in Chinese)
- [2] 孙迪,王旭彬. 基于多尺度特征融合神经网络的织物表面缺陷检测方法[J]. 辽宁师范大学学报(自然科学版), 2024, 47(3): 331-341.
SUN D, WANG X B. Fabric surface defect detection method based on multi-scale feature fusion neural network [J]. *Journal of Liaoning Normal University (Natural Science Edition)*, 2024, 47 (3): 331-341. (in Chinese)
- [3] 张平均,马振江,赖礼泮,等. 基于GEM-YOLOv8n的轻量化织物缺陷检测系统研究[J]. 机电技术, 2025(4): 5-12, 16.
ZHANG P J, MA ZH J, LAI L P, et al. A study on lightweight fabric defect detection system based on GEM-YOLOv8n [J]. *Mechanical & Electrical Technology*, 2025(4): 5-12, 16. (in Chinese)
- [4] 王川,李晓龙,王公轲,等. 基于改进YOLOv8的织物缺陷检测算法[J]. 毛纺科技, 2025, 53(4): 133-141.
WANG CH, LI X L, WANG G K, et al. Fabric defect detection algorithm based on improved YO-
- LOv8 [J]. *Wool Textile Journal*, 2025, 53 (4): 133-141. (in Chinese)
- [5] 孙小栋,朱启兵,徐华伟,等. 用于超纤革表面瑕疵识别的MFL_YOLOv8算法[J]. 光学精密工程, 2025, 33(2): 311-323.
SUN X D, ZHU Q B, XU H W, et al. MFL_YOLOv8 algorithm for surface defect detection of micro-fiber leather [J]. *Optics and Precision Engineering*, 2025, 33(2): 311-323. (in Chinese)
- [6] 孙世政,何玲玲,郑帅,等. 改进YOLOv8n的复杂环境下垃圾轻量化检测[J]. 光学精密工程, 2025, 33(12): 1984-1998.
SUN SH ZH, HE L L, ZHENG SH, et al. Improved lightweight garbage detection method for YOLOv8n in complex environments [J]. *Optics and Precision Engineering*, 2025, 33(12): 1984-1998. (in Chinese)
- [7] 吕世杰,刘国华. 基于改进下采样与多尺度特征融合的织物瑕疵检测算法[J/OL]. 光电子·激光, 1-8 [2026-01-10] <https://link.cnki.net/urlid/12.1182.04.20251114.1137.004>.
LÜ SH J, LIU G H. Fabric Defect Detection Algorithm Based on Improved Downsampling and Multi-Scale Feature Fusion [J/OL]. *Journal of Optoelectronics·Laser*, 2026: 1-8 [2026-01-10] <https://link.cnki.net/urlid/12.1182.04.20251114.1137.004>.

004. (in Chinese)
- [8] REVATHY G, KALAIVANI R. Fabric defect detection and classification *via* deep learning-based improved Mask RCNN[J]. *Signal, Image and Video Processing*, 2024, 18(3): 2183-2193.
- [9] 李叔罡, 李爽, 刘驰. 基于纹理知识引导的跨域织物缺陷检测[J]. 计算机工程, 2026, 52(1): 166-175.
- LI SH G, LI SH, LIU CH. Cross-domain fabric defect detection guided by texture knowledge[J]. *Computer Engineering*, 2026, 52(1): 166-175. (in Chinese)
- [10] MEI S Q, SHI Y S, GAO H, *et al.* Research on fabric defect detection algorithm based on improved YOLOv8n algorithm[J]. *Electronics*, 2024, 13(11): 2009.
- [11] LIU S S. Research on fabric defect detection algorithm based on improved YOLOv8s[C]. 2024 10th International Conference on Computer and Communications (ICCC). December 13-16, 2024, Chengdu, China. IEEE, 2025: 2063-2067.
- [12] PRUNELLA M, SCARDIGNO R M, BUONGIORNO D, *et al.* Deep learning for automatic vision-based recognition of industrial surface defects: a survey[J]. *IEEE Access*, 2023, 11: 43370-43423.
- [13] GUO P Y, LIU Y P, WU Y, *et al.* Intelligent quality control of surface defects in fabrics: a comprehensive research progress[J]. *IEEE Access*, 2024, 12: 63777-63808.
- [14] 王奥, 万贤福, 汪军. 基于深度学习的织物疵点检测[J]. 纺织器材, 2025, 52(4): 7-12.
- WANG A, WAN X F, WANG J. Fabric defect detection based on deep learning[J]. *Textile Accessories*, 2025, 52(4): 7-12. (in Chinese)
- [15] TIE J, ZHU C G, ZHENG L, *et al.* LSKA-YOLOv8: a lightweight steel surface defect detection algorithm based on YOLOv8 improvement[J]. *Alexandria Engineering Journal*, 2024, 109: 201-212.
- [16] VARGHESE R, M S. YOLOv8: a novel object detection algorithm with enhanced performance and robustness[C]. 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). April 18-19, 2024, Chennai, India. IEEE, 2024: 1-6.
- [17] JIN Y X, LIU X Y, NAN K L, *et al.* A real-time fabric defect detection method based on improved YOLOv8[J]. *Applied Sciences*, 2025, 15(6): 3228.
- [18] 梁礼明, 龙鹏威, 冯耀, 等. 改进轻量化 VTG-YOLOv7-tiny 的钢材表面缺陷检测[J]. 光学精密工程, 2024, 32(8): 1227-1240.
- LIANG L M, LONG P W, FENG Y, *et al.* Improving the lightweight VTG-YOLOv7-tiny for steel surface defect detection[J]. *Optics and Precision Engineering*, 2024, 32(8): 1227-1240. (in Chinese)
- [19] XU X Z, JIANG Y Q, CHEN W H, *et al.* DAMO-YOLO: a report on real-time object detection design [EB/OL]. 2022: *arXiv*: 2211.15444. <https://arxiv.org/abs/2211.15444>.
- [20] XU G P, LIAO W T, ZHANG X, *et al.* Haar wavelet downsampling: a simple but effective downsampling module for semantic segmentation[J]. *Pattern Recognition*, 2023, 143: 109819.
- [21] LUO X J, CAI Z H, SHAO B, *et al.* Unified-IoU: for high-quality object detection [EB/OL]. 2024: *arXiv*: 2408.06636. <https://arxiv.org/abs/2408.06636>.
- [22] YOLOv7-vdg8u, "Fabric defect detection (jdyz3dataset)," Roboflow Universe, ver. 3, CC BY 4.0 [EB/OL]. [2026-02-08]. <https://universe.roboflow.com/yolov7-vdg8u/fabric-defect-detection-jdyz3/dataset/3>.
- [23] Markbil-projects, "Fabric defect dataset," UniverseRoboflow, ver. 3, CC BY 4.0 [EB/OL]. [2026-04-02]. <https://universe.roboflow.com/markbil-projects/fabric-defect-dataset/dataset/X>.
- [24] 张俊杰. 基于改进 CycleGAN 和 YOLOv8 的织物疵点检测方法研究[D]. 上海: 东华大学, 2025.
- ZHANG J J. *Research on Fabric Defect Detection Method Based on Improved CycleGAN and YOLOv8*[D]. Shanghai: Donghua University, 2025. (in Chinese)
- [25] 张捷皓, 张进峰, 吴威涛, 等. 基于高精多尺度集成的轻量织物缺陷检测方法[J]. 浙江大学学报(工学版), 2025, 59(12): 2556-2565.
- ZHANG J H, ZHANG J F, WU W T, *et al.* Lightweight fabric defect detection method based on high precision multi-scale integration[J]. *Journal of Zhejiang University (Engineering Science)*, 2025, 59(12): 2556-2565. (in Chinese)
- [26] LIU Q, WANG C, LI Y S, *et al.* A fabric defect detection method based on deep learning[J]. *IEEE Access*, 2022, 10: 4284-4296.
- [27] GUO Y B, KANG X J, LI J F, *et al.* Automatic

- fabric defect detection method using AC-YOLOv5 [J]. *Electronics*, 2023, 12(13): 2950.
- [28] LI X S, ZHU Y. A real-time and accurate convolutional neural network for fabric defect detection [J]. *Complex & Intelligent Systems*, 2024, 10 (3): 3371-3387.
- [29] HE Y, ZHANG H D, HUANG X Y, *et al.* Fabric defect detection based on improved faster RCNN [J]. *International Journal of Artificial Intelligence & Applications*, 2021, 12(4): 23-32.

作者简介:




徐士鹏(2002—),男,江苏扬州人,硕士研究生,主要研究方向为机器视觉、精密仪器。E-mail: 3103807747@qq.com

通讯作者:



李 兵(1974—),男,黑龙江巴彦人,工程师,主要研究方向为工业自动化与智能优化算法在工程中的应用。E-mail: libing@cjlu.edu.cn

通讯作者:



王文琪(1994—),女,辽宁大连人,博士,讲师,主要研究方向为复杂工业场景下的三维视觉成像与复杂形貌工件几何量精密测量。E-mail: wqwang@cjlu.edu.cn