

文章编号 1004-924X(2025)02-0311-13

用于超纤革表面瑕疵识别的 MFL_YOLOv8 算法

孙小栋¹, 朱启兵^{1*}, 徐华伟², 邢同振³, 朱海斌³

- (1. 江南大学 物联网工程学院, 江苏 无锡 214122;
2. 禾欣可乐丽超纤皮(嘉兴)有限公司, 浙江 嘉兴 314003;
3. 浙江迈沐智能科技有限公司, 浙江 嘉兴 314000)

摘要:超纤革是一种用于高端产品的新型复合材料,其瑕疵检测对产品质量至关重要。针对超纤革表面瑕疵多尺度、长宽比差异大和微小瑕疵较多的难点,提出用于超纤革表面瑕疵识别的 MFL_YOLOv8 算法。MFL_YOLOv8 算法首先基于 Deformable Large Kernel Attention(DLKA)机制设计了多尺度特征提取模块 DCNv3-LKA,显著增强了主干网络的多尺度特征提取能力;然后通过特征金字塔网络中引入 P2 特征图和 Dysample 上采样模块,强化了网络对小目标的细节信息提取;最后引入 Minimum Points Distance Intersection over Union(MPDIoU)以缓解训练初期小目标上的损失函数失效问题,提升了小目标的检测效果。在自制超纤革表面瑕疵数据集上的实验结果表明,相比于 YOLOv8n,所提算法的平均检测精度和召回率分别提高了 5.38% 和 7.27%,达到 92.47% 和 92.40%,每秒帧率(FPS)为 135.2 frame/s,满足工业现场的准确性和实时性要求。

关键词:超纤革;瑕疵检测;DCNv3-LKA;MPDIoU

中图分类号:TP391.4 **文献标识码:**A

doi:10.37188/OPE.20253302.0311 **CSTR:**32169.14.OPE.20253302.0311

MFL_YOLOv8 algorithm for surface defect detection of microfiber leather

SUN Xiaodong¹, ZHU Qibing^{1*}, XU Huawei², XING Tongzhen³, ZHU Haibin³

- (1. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China;
2. Hexin Kuraray Micro Fiber Leather (Jiaxing) Co., Ltd, Jiaxing 314003, China;
3. Zhejiang Maimu Intelligent Technology Co., Ltd, Jiaxing 314000, China)

* Corresponding author, E-mail: zhuqib@163.com

Abstract: Microfiber leather is a high-end composite material, and its defect detection is critical for ensuring product quality. To address the challenges posed by the multi-scale, diverse aspect ratios, and numerous small defects on the surface of microfiber leather, the MFL_YOLOv8 algorithm for surface defect detection was proposed in this study. The MFL_YOLOv8 algorithm first introduced the multi-scale feature extraction module DCNv3-LKA based on the Deformable Large Kernel Attention (DLKA) mechanism, which significantly enhanced the backbone network's multi-scale feature extraction capabilities. Subsequently, the incorporation of a P2 feature map and a Dysample upsampling module in the feature pyramid

收稿日期:2024-09-19;修订日期:2024-10-21.

基金项目:浙江省基础公益研究计划项目(No. LZ22A020006)

network strengthened the network's ability to extract detail information from small targets. Finally, the Minimum Points Distance Intersection over Union (MPDIoU) was utilized to mitigate the inefficacy of the loss function on small targets during the initial stages of training, thus improving the detection performance for small targets. Experimental results on a self-constructed microfiber leather surface defect dataset demonstrate that the proposed algorithm achieved 92.47% of average detection precision and 92.40% of average detection recall, with improvements of 5.38% and 7.27% compared to YOLOv8n. Additionally, the algorithm attained a frame rate of 135.2 frames per second (FPS), meeting the accuracy and real-time requirements for industrial applications.

Key words: microfiber leather; defect detection; DCNv3-LKA; MPDIoU

1 引言

超细纤维合成革(简称“超纤革”)是一种结构与性能都酷似天然皮革的新型复合材料,广泛应用于汽车内饰、服装、医疗、军事等领域^[1-2]。超纤革制备工艺包括聚氨酯树脂含浸、固化、减量及后整理等生产工序。生产过程中受力不均或卷绕不紧、原材料中的杂质以及生产工艺的波动,使得超纤革容易产生垃圾、污印、浆斑、皱印、接头不良等表面瑕疵^[3-5]。如果这些瑕疵未能及时检测和处理,可能会严重影响到后续工艺和成品质量,甚至导致整批产品报废。因此,实时检测超纤革基布的表面瑕疵至关重要。

随着人工智能的发展,具有良好实时性的目标检测算法(如CNN^[6]、SSD^[7]和YOLO系列^[8]算法)在织物瑕疵检测中的应用得到了广泛的报道。Xie等人^[9]在传统SSD中引入了全卷积压缩激励(FCSE)模块,以提高模型的检测精度,并调整了默认框的数量以适应织物表面长条形缺陷的检测,显著提升了长条形瑕疵的检测效果,但也导致了模型计算复杂度的增加。Luo等人^[10]提出的鲁棒破损检测网络(RBD-Net)在主干网络部分引入跨阶段部分密集连接网络(CSP-DenseNet),以改善特征提取并增强特征复用能力,并添加了决策网络,以更好地识别皮革破损的全局和局部瑕疵。Liu等人^[11]提出基于了一种基于YOLOv7改进的织物瑕疵检测算法,通过引入RFB感受野增强模块和CARAFE上采样算子实现在更大的感受野上聚合上下文信息,从而显著改善特征融合效果。但是,现有的瑕疵检测算法主要是针对普通织物和皮革的应用场景,这些场景下的瑕疵往往具有较大尺寸和相对规则的

形态。超纤革的表面则更为复杂,存在多尺度、长宽比差异大和微小瑕疵较多的特点,导致这些算法在超纤革的应用中精度和召回率难以达到实际需求。因此,针对这些算法在处理超纤革表面时的局限性,亟需新的方法进行改进和优化。

本研究提出了一种用于超纤革表面瑕疵识别的目标检测算法(MFL_YOLOv8),以应对超纤革表面瑕疵检测中的多尺度、长宽比差异大和微小瑕疵较多等挑战。通过引入DCNv3-LKA模块、P2特征图、Dysample上采样模块和MPDIoU损失函数,显著提升了检测精度和实时性。实验结果表明,所提方法在多个指标上均超越了现有方法,具有良好的应用前景。

2 数据集与采集设备

实验用数据集由图1所示的采集系统在生产现场采集。根据现场生产工艺,宽度为1.6 m的超纤革由电机带动以20~50 m/min的速度运动。为了采集超纤革的全幅图像和清晰地捕捉小目标瑕疵,系统采用两台8K线阵真彩相机(型号为MV-CL086-91CC-PRO)同步并排采集不同区域的超纤革图像。为保证光照均匀,系统采用LED线性光源。采集卡使用的型号为MV-GC1002-V2,以支持高速数据传输和处理。

在相机软件中,设置每采集4 096行像素形成一张 $8\,192 \times 4\,096$ pixels的图像,并将两个相机的图像拼接得到 $16\,384 \times 4\,096$ pixels的原始图像。在检测过程中,为适应瑕疵检测算法的输入尺寸要求,需要将超纤革区域图像分割为48个区域互不重叠的子图进行逐图的瑕疵检测。在超纤革基布的生产线上,进给速度最高可达50 m/min,在




图1 图像采集设备图

Fig. 1 Diagram of imaging equipment

此速度下,每张原始图像的采集时间为0.4915 s。为满足实时检测需求,需要在0.4915 s内完成48张小图的检测。考虑到内存读取、图像预处理等因素,每张子图的处理时间应该小于10 ms(检测帧率(FPS)大于100 frame/s)。

16384×4096 pixels的原始图像包含了两边的辊子区域,该区域的油污和反光可能会干扰瑕


疵检测结果。为减少干扰,本研究采用OpenCV算法库中的OTSU阈值分割算法,识别并分割超纤革区域和辊子区域,并进行裁剪和拉伸,得到12288×4096 pixels的超纤革区域图像,该图像在分割为48个子图后,对于每个子图进行下采样操作,最终得到每个子图的尺寸为640×640 pixels,作为模型的输入图片。

本研究采集并标注了4732张超纤革基布表面瑕疵子图,涵盖了污印、垃圾、皱印、浆斑和接头五类典型瑕疵。图2给出了含有不同瑕疵的超纤革基布图像,其中红框内是需要检测出的瑕疵(彩图见期刊电子版)。图3给出了训练集中各种类瑕疵的尺寸分布情况和样本数量。从图中看出,这些瑕疵呈现出不同的图像特征,其中:污印瑕疵的形状和尺寸表现出高度的随机性和多样性;垃圾瑕疵的尺寸很小;皱印瑕疵表现为多尺度、长宽比变化显著的特点;接头不良瑕疵具有横向分布且尺寸较大的特点;而浆斑瑕疵的尺寸通常较小并且难以和纹理背景区分。这些特点给基于深度学习的超纤革瑕疵检测带来了困难。



图2 超纤革表面瑕疵图

Fig. 2 Surface defects of microfiber Leather

(a) 垃圾瑕疵尺寸分布
(a) Size distribution of debris(b) 污印瑕疵尺寸分布
(b) Size distribution of stains(c) 浆斑瑕疵尺寸分布
(c) Size distribution of spots




图3 瑕疵样本数量及尺寸分布统计图

Fig. 3 Statistical chart of sample number of defects and their size distribution

3 MFL_YOLOv8 算法

由于超纤革基布的瑕疵通常较小且存在多尺度、长宽比差异大的特点,原始的YOLOv8n模型在检测这些瑕疵时难以达到预期的效果,本研究对YOLOv8n模型进行了以下改进。首先,针对训练集中瑕疵目标形状复杂且多尺度的特点,在YOLOv8的Backbone部分引入了基于改进DLKA的DCNv3-LKA模块。此模块通过扩展卷积核的感受野并动态调整采样格,增强了模型对多尺度、长宽比差异大的目标的特征提取能力。其次,鉴于小目标瑕疵在不同特征层级上的融合不足,容易导致细节信息丢失的问题,在Neck部分引入了P2特征图,并将原有的上采样模块替换为Dysample模块,通过生成内容感知的偏移量进行上采样,有效保留了小尺寸瑕疵的细节特征。最后,考虑到传统Complete Intersection over Union(CIoU)损失函数在处理小目标定位时存在的不足,本研究在训练过程中将其替换为MPDIoU损失函数,MPDIoU通过直接计算预测框与真实框顶点的距离,进一步提升了模型的收敛速度和检测精度,尤其在小目标检测中表现优异。改进后的网络结构如图4所示,红色框内为改进部分(彩图见期刊电子版)。

3.1 DCNv3-LKA 模块

DLKA模块^[12]结合了大卷积核(Large Kernel Attention, LKA)^[13]和可变形卷积的优势。LKA通过深度卷积、深度扩展卷积和点卷积,用




图4 MFL_YOLOv8结构

Fig. 4 Structure of MFL_YOLOv8

较少的参数量构建了一个具有广泛感受野的卷积核,能够捕捉图像中的全局上下文信息,从而更准确地区分前景和背景,优化多尺度的特征提取。基于此,DLKA进一步引入了基础可变形卷积,通过学习偏移量来动态调整卷积核的采样位置,使其能够灵活适应复杂的目标形状和不同尺度的瑕疵,显著提升了模型对不规则目标边界的捕捉能力,从而更加精准地提取多尺度和长宽比差异大的瑕疵特征。DLKA模块的网络结构如图5所示。

然而,DLKA的基础可形变卷积在多尺度特




图 5 DLKA 结构

Fig. 5 Structure of DLKA

征提取时,容易引入冗余上下文信息,增加特征提取噪声。此外,由于卷积操作使用独立的线性投影权重,导致参数数量和计算复杂度随采样点的数量线性增长,进而限制了模型效率。为此,本研究对 DLKA 模块进行优化,将其中的可变形卷积替换为 DCNv3 模块(Deformable Convolution v3)^[14],形成 DCNv3-LKA 模块。与基础的可变形卷积相比,DCNv3 通过神经元之间的权值共享,显著提高了计算效率和内存效率。此外,DCNv3 引入了多分组机制,每个空间聚合组都有独立的采样偏移量与调节尺度,从而使不同组的卷积层能够适应不同的空间聚合模式,增强了瑕疵的特征表达能力。DCNv3 还使用 SoftMax 进行归一化处理,使得整个训练过程更加稳定。

DCNv3 算子可以表示为公式(1):

$$y(p_0) = \sum_{g=1}^G \sum_{k=1}^K w_g m_{gk} x_g(p_0 + p_k + \Delta p_{gk}), \quad (1)$$

其中, G 表示聚合组的总数。对于第 g 组, $w_g \in \mathbb{R}^{C \times C'}$ 表示组的与位置无关的投影权重,其中 $C' = C/G$ 表示组的维度。 $m_{gk} \in \mathbb{R}$ 表示第 g 组中第 k 个采样点的调制标量,通过 Softmax 在 K 维度上进行归一化。 $x_g \in \mathbb{R}^{C' \times H \times W}$ 表示切分后的输入特征图。 Δp_{gk} 是对应于第 g 组中网格采样位置 p_k 的偏移。

将 DCNv3-LKA 模块添加到主干网络的末端,弥补了传统卷积在长距离建模能力和自适应空间聚合能力上的不足,使模型能更加灵活准确地提取瑕疵特征,进一步提升了对多尺度瑕疵和

不规则形状瑕疵的检测精度。

3.2 Dysample 上采样模块

YOLOv8n 模型默认采用最近邻上采样方法。由于该方法固定的插值规则,常常忽视了特征图中的语义信息,导致小目标的细节信息易于丢失,影响模型对小尺寸瑕疵的检测能力。此外,反卷积等传统基于卷积核的上采样方法虽然能提供一定的灵活性,但往往伴随着较高的计算和参数开销。为解决这些问题,本研究引入了 DySample^[15] 模块,替换了特征融合步骤中的最近邻上采样方法。DySample 是一种轻量级的动态上采样模块,能够根据特征图的上下文信息动态调整采样策略,从而更好地恢复瑕疵的细节特征。DySample 的网络结构如图 6 所示。




图 6 Dysample 结构

Fig. 6 Structure of Dysample

DySample 的核心组件包括采样网格(G)和生成的偏移量(O)。首先,该模块通过一个线性投影层为特征图的每个位置生成初始的偏移量,这些偏移量代表从原始采样格点到目标采样位置的空间变换向量;之后采用像素混洗技术(Pixel Shuffle)^[16]将初始偏移量重组为更高分辨率的偏移量图,使其更准确地对应输入特征图中的位置。使用 PyTorch 的 grid_sample 函数确定采样网格之后,DySample 利用动态生成的偏移量对输入特征图进行重新采样,生成上采样后的特征图。DySample 模块通过基于内容的动态点采样策略,有效避免了耗时的动态卷积操作和额外的子网络构建,实现了对小目标区域细粒度的偏移控制,确保了小尺寸瑕疵和边缘特征在上采样过程中的准确恢复,显著提高模型对小尺寸瑕疵和多形状瑕疵的检测能力。

3.3 P2 特征图融合

在 YOLOv8n 模型中,输入图像在 Backbone (主干网络)部分经过多次下采样,最终生成了三张不同尺寸的特征图,分别是 H3, H4 和 H5,用于

检测不同尺度的目标。然而,随着卷积层的逐渐加深,虽然模型在高层特征图中获得了更多的语义信息,但也导致了细节信息的丢失,特别是在检测小尺寸目标和细微瑕疵时表现不佳。为了解决这一问题,本文在 YOLOv8n 的 Neck 部分进行了改进,新增了一个 P2 特征图(大小为 160×160),以保留更多的底层特征信息,从而提升模型对小目标的检测能力。

P2 特征图的引入通过融合来自不同层次的特征图来实现更好的特征表达。具体来说,首先将来自 YOLOv8n 主干网络中 C3 层(80×80)、C4 层(40×40)和 C5 层(20×20)的特征图进行自顶向下的融合,以生成更为精细的 P3 特征图。然后,再将这一 P3 特征图与主干网络中 C2 层(160×160)的特征进行融合,最终生成 P2 特征图。该 P2 特征图在 Neck 部分进一步与原有的 H3、H4、H5 特征图进行融合,使得小目标的底层特征能够有效传递到高层特征图中,减少了小目标信息的丢失。通过这一改进,网络的特征融合能力显著增强,从而有效提升了对小尺寸瑕疵的检测精度和召回率。

3.4 MPDIoU 损失函数

CIoU 是 YOLOv8n 网络采用的边界框回归损失函数。由于超纤革表面瑕疵中存在大量的小尺度目标,所以在训练的初期,常常出现预测框与真实框中心点重叠的情况,此时如果预测框和真实框之间长宽比相同但尺寸存在差异,CIoU 损失函数退化为 IoU 损失函数,难以有效表达损失。该问题导致模型在训练前期收敛速度较慢,影响小目标的检测效果。为了克服 CIoU 的这一局限性,本研究将 CIoU 替换为 MPDIoU 损失函数。MPDIoU 不仅保留了 CIoU 的核心特性,还通过最小化预测框和真实框之间左上角和右下角的顶点距离来进一步优化边界框回归。MPDIoU 的计算公式如式(2)~式(4):

$$L_{\text{MPDIoU}} = 1 - \text{IoU} + \frac{d_1^2}{h^2 + w^2} + \frac{d_2^2}{h^2 + w^2}, \quad (2)$$

$$d_1^2 = (x_1^{\text{pred}} - x_1^{\text{gt}})^2 + (y_1^{\text{pred}} - y_1^{\text{gt}})^2, \quad (3)$$

$$d_2^2 = (x_2^{\text{pred}} - x_2^{\text{gt}})^2 + (y_2^{\text{pred}} - y_2^{\text{gt}})^2, \quad (4)$$

其中: w, h 分别为网络中输入图片的宽和高, $(x_1^{\text{pred}}, y_1^{\text{pred}}), (x_2^{\text{pred}}, y_2^{\text{pred}})$ 分别是预测框的左上角和右下角坐标, $(x_1^{\text{gt}}, y_1^{\text{gt}}), (x_2^{\text{gt}}, y_2^{\text{gt}})$ 则分别是真实框

的左上角与右下角坐标。在式(2)中,由于 $\text{IoU} < 1$ 且最后两项各自小于 1, 因此 L_{MPDIoU} 总是有界的, 即 $0 \leq L_{\text{MPDIoU}} < 3$ 。




图 7 两种情况下不同损失的计算结果

Fig. 7 Calculation results of different losses in two cases

如图 7 所示,绿色框为真实框,红色框为预测框(彩图见期刊电子版),当预测框和真实框的中心点重叠宽高比相同时,对于不同宽高的预测框,CIoU 损失函数计算结果均为 0.75。而 MPDIoU 对不同宽高的预测框计算出了不同的损失函数值,能更有效地引导预测框接近真实框,解决了 CIoU 失效的问题。MPDIoU 损失函数在设计上充分考虑了 CIoU 的局限性,更适用于超纤革小尺寸瑕疵检测。当预测框与真实框的中心点不重叠时,通过最小化顶点距离,有效地引导预测框接近真实框的位置;即使在中心点重叠、长宽比一致但具体尺寸不同的情况下,MPDIoU 的惩罚项仍然有效,不会退化为 IoU 损失。因此,相比于 CIoU 损失函数,MPDIoU 不仅简化了计算过程,而且稳定了模型的收敛,提高小尺寸瑕疵的检测效果。

4 实验结果

4.1 实验环境与参数

本实验在 NVIDIA GeForce RTX4090 显卡上进行,显存大小为 24 GB,操作系统为 Ubuntu20.04。软件方面,本文使用了 Python3.8, PyTorch1.10.0 和 CUDA11.3 深度学习框架。实验中使用 Adam 优化器,初始学习率为 0.01,动量参数为 0.973,权重衰减因子为 0.0005, batchsize 为 48, epoch 为 300 轮。本研究使用 4 732 张标注图像(图像尺寸 640×640 pixels),按照 8:2 的比例随机划分为训练集(3 786 张)和测试集(946 张)。

4.2 评价指标和检测需求

本研究的评价指标主要包括精度(Precision)、召回率(Recall)、参数量(Params)和计算量(GFLOPs),并通过每秒检测帧率(FPS)来评估算法的实时性表现。

精度(Precision)衡量的是模型在检测出的瑕疵中,实际为瑕疵的比例。精度高意味着误检率低,这对于减少不必要的停产检查和返工成本尤为关键。工业现场要求超纤革瑕疵识别中各类瑕疵的平均精度达到90%以上,以确保在不影响生产流程的前提下,最大限度提高检测的可靠性。

召回率(Recall)衡量的是模型能检测出实际存在的所有瑕疵的比例。在超纤革生产中,未被检测出的瑕疵可能会严重影响后续工艺的质量,甚至导致整批产品的报废。因此,对于不可逆的瑕疵(如污印、浆斑、皱印、接头),召回率要求不低于90%。而对于生产过程中可以被清除的瑕疵(如垃圾),由于清洁工艺的存在,要求召回率达到80%以上即可满足检测需求。

参数量(Params)用于衡量模型的空间复杂度,计算量(GFLOPs)评估模型的计算复杂度和效率,两者直接影响检测系统的硬件需求和实时性。在工业现场,检测系统需要在高速度的生产线上以至少100 frame/s(FPS)的速率完成检测,

以避免影响生产过程。因此,模型的参数量和计算量需要在满足精度和召回率要求的同时,控制在合理范围内,以实现高效的现场部署。

4.3 实验结果及分析

4.3.1 对比实验

基于实时性考虑,本研究主要选择多种轻量级的模型变体进行对比实验,包含SSD, YOLOv4-tiny, YOLOv5n, YOLOv5s, YOLOv7-tiny, YOLOv8n, YOLOv8s 和 YOLOv9n, 比较结果见表1。

SSD, YOLOv5s, YOLOv7-tiny 和 YOLOv8s 的参数量和计算量较大,导致检测速度较低,未能满足实时性要求。尽管YOLOv5n拥有最快的检测速度,但其精度和召回率均低于80%,无法满足精度要求。相比于YOLOv4-tiny 和 YOLOv9n, YOLOv8n 的精度分别提高2.82%和5.74%,召回率分别提高2.15%和5.74%,而且模型的参数量和计算量仅为3 M和8.1 GFLOPs, FPS为149.3 frame/s。因此,本研究选择YOLOv8n作为基线模型进行改进。改进后的算法虽然略微增加了参数量,但检测速度保持在135.2 frame/s,且检测精度和召回率显著提高,分别达到了92.47%和92.40%,远超其他模型,充分满足了超纤革表面瑕疵检测的准确性和实时性要求。

表1 不同算法的瑕疵检测结果

Tab. 1 Defect detection results of different algorithms

Models	Precision/%	Recall/%	Params/M	FLOPs/G	FPS/(frames ⁻¹)
SSD	72.31	68.46	24.3	62.3	43.2
YOLOv4-tiny	84.27	82.98	6.0	16.5	103.2
YOLOv5n	79.21	77.83	1.8	4.2	179.3
YOLOv5s	82.47	83.15	7.0	18.5	87.2
YOLOv7-tiny	84.16	83.96	6.1	13.1	82.5
YOLOv8n	87.09	85.13	3.0	8.1	149.3
YOLOv8s	87.75	85.22	11.1	28.5	78.2
YOLOv9n	81.35	78.31	4.1	8.1	120.8
MFL_YOLOv8	92.47	92.40	3.6	9.4	135.2

4.3.2 消融实验

为了全面评估各改进模块对YOLOv8n基线模型在超纤革表面瑕疵检测任务中的影响,本研究设计了一系列消融实验,对各模块的单独引入

及组合引入进行了详细分析。实验结果如表2所示。

首先,加入DCNv3-LKA模块后,检测精度从87.09%提升至89.18%,召回率从85.13%

表 2 消融实验结果
Tab. 2 Ablation experiments results

DCNv3-LKA	P2	Dysample	MPDIoU	Precision/%	Recall/%	Params/M	FLOPs/G	FPS/(frame·s ⁻¹)
				87.09	85.13	3.0	8.1	149.3
✓				89.18	88.32	3.5	8.5	140.5
	✓			88.52	87.25	3.1	9.0	135.6
		✓		88.13	86.69	3.0	8.1	151.2
			✓	87.91	86.83	3.0	8.1	149.6
✓	✓			90.25	89.91	3.6	9.4	132.1
✓	✓	✓		91.62	91.12	3.6	9.4	135.1
✓	✓	✓	✓	92.47	92.40	3.6	9.4	135.2

提高至 88.32%，虽然计算量和参数量略微增加，但模型在多尺度和长宽比差异较大的瑕疵检测上表现显著增强，证明了 DCNv3-LKA 模块通过结合可变形卷积和大卷积核提升了模型的特征提取能力。其次，加入 P2 特征图模块后，检测精度提升至 88.52%，召回率提升至 87.25%，尽管计算量有所增加，导致 FPS 略微下降至 135.6 frame/s，但该模块通过加强深层次特征融合，有效保留了小目标的细节信息，显著提升了小尺寸瑕疵的检测效果。集成 Dysample 上采样模块后，精度达到 88.13%，召回率提升至 86.69%，虽然参数量和计算量未发生显著变化，但 Dysample 模块通过细粒度的偏移控制，有效恢复了小目标的边缘特征，在处理小尺

寸目标时表现出色。采用 MPDIoU 替换 CIoU 损失函数后，检测精度和召回率分别提升至 87.91% 和 86.83%，MPDIoU 通过优化小目标的边界框回归，有效解决了训练初期由于中心点重合导致的 CIoU 失效问题，显著提高了小目标的检测效果。最终，综合所有改进后，平均检测精度提升了 5.38%，平均召回率提高了 7.27%，FPS 稳定在 135.2 frame/s，充分满足了超纤革表面瑕疵检测对实时性和准确性的严格要求。

4.3.3 混淆矩阵及结果可视化

表 3 展示了改进前后算法在不同瑕疵类别上的混淆矩阵对比结果，直观反映了各类瑕疵检测性能的提升情况。改进后的模型在所有瑕疵类

表 3 混淆矩阵对比
Tab. 3 Comparison of confusion matrices

True Pred	Background	Stains (368)	Debris (247)	Spots (165)	Wrinkles (169)	Seams (84)	Precision/%
Background	—	22(−15)	41(−44)	6(−2)	5(−8)	3(−2)	—
Stains	29(−28)	343(+22)	7(−2)	0(−3)	1	0	90.26(+8.16)
Debris	18(−5)	1(−5)	198(+47)	0	0	0	91.24(+7.35)
Spots	9(−6)	2(−2)	1(−1)	158(+5)	0	0(−1)	92.94(+5.51)
Wrinkles	13(−8)	0	0	0	163(+8)	0	92.61(+4.54)
Seams	3(−1)	0	0	1	0	81(+3)	95.29(+1.31)
Recall/%	—	93.21 (+5.98)	80.16 (+19.03)	95.76 (+3.03)	96.45 (+4.73)	96.43 (+3.57)	—

别上的检测效果都有显著提升。特别是在污印和垃圾的小尺寸瑕疵检测中,改进后的模型显示出更高的精度和召回率。对于皱印和接头等多尺度且长宽比差异大的瑕疵,改进后的模型同样表现出显著的检测性能提升。总的来看,改进后的模型达到了工业应用的指标要求。所有类别的精度均超过了90%的标准,垃圾瑕疵的召回率也超过了80%的最低要求,其余瑕疵类别的召回率均超过了90%。

图 8 以直观的方式展示了使用 MFL_YOLOv8 算法与 YOLOv8 算法对五种瑕疵类型的检测对比图。在图中,橙色框表示 MFL_YOLOv8 算法的检测结果,蓝色框标示了 YOLOv8 的结果。结果清楚表明,本研究提出的 MFL_YOLOv8 算法在精准识别和召回小尺寸及复杂形状瑕疵方面,明显优于标准的 YOLOv8 算法,满足了超纤革瑕疵检测的工业应用需求(彩图见期刊电子版)。



图 8 不同模型的检测结果
Fig. 8 Detection results of different models

4. 3. 4 DCNv3-LKA 模块有效性分析

表 4 给出了基线模型、DLKA 模块和 DCNv3-LKA 模块的对比实验结果。结果表明,将 DLKA 模块加入主干网络后,改善了特征提取,检测的精度和召回率分别提升 0.72% 和 1.15%,但参数量增加 1.7 M, FPS 下降至 108.3 frame/s,检测速度大幅降低。在此基础

上改进的 DCNv3-LKA 模块通过在神经元之间共享权值并引入多分组机制,大幅提升了计算效率和内存利用率,改进后的 DCNv3-LKA 模块不仅将精度和召回率提高了 2.09% 和 3.19%,而且相较于 DLKA 模块,参数量减少了 1.2 M, FPS 提高至 140.5 frame/s,能充分满足实时检测的需求。

表 4 DLKA 和 DCNv3-LKA 的实验结果
Tab. 4 Experimental results of DLKA and DCNv3-LKA

Models	Precision/%	Recall/%	Params/M	FLOPs/G	FPS/(frames·s ⁻¹)
Baseline	87.09	85.13	3.0	8.1	149.3
DLKA	87.81	86.28	4.7	9.5	108.3
DCNv3-LKA	89.18	88.32	3.5	8.4	140.5

为进一步验证 DCNv3-LKA 模块在提取不规则形状瑕疵特征方面的有效性,本研究采用 Grad-CAM (Gradient-weighted class activation mapping) 技术对原始 YOLOv8n 模型、加入 DLKA 模块的 YOLOv8n 模型以及加入 DCNv3-LKA 模块后的 YOLOv8n 模型进行了热力图分析。图 9(a)为皱印瑕疵的原图。图 9(b)表明,

在未引入大卷积核和可变形卷积的情况下,原始模型主要关注了局部瑕疵区域,同时捕捉到了一些包含纹理背景的非瑕疵区域,其特征提取存在一定局限性。引入 DLKA 模块后,图 9(c)显示模型能够捕捉到更丰富的全局上下文信息,减少了背景的干扰,关注区域更为准确,模型在一定程度上能够更全面地学习到不规则

形状瑕疵的特征。图 9(d) 进一步表明,在 DLKA 中加入 DCNv3 后,模型显著优化了关注区域的定位,增强了对瑕疵特征的提取能力,从而提升了整体检测性能。




图 9 热力图可视化
Fig. 9 Heatmap visualization

4. 3. 5 Dysample 模块有效性分析
本研究在 YOLOv8n 基础模型上分别对最近邻插值、双线性插值、CARAFE^[17]和 Dysample 模块进行对比实验,结果如表 5 和图 10 所示。

表 5 不同上采样模块的实验结果
Fig. 5 Experimental results of different upsampling modules

Models	Precision/%	Recall/%	Params/M	FLOPs/G	FPS/(frames·s ⁻¹)
Nearest	87.09	85.13	3.007	8.1	149.3
Bilinear	86.28	84.95	+0.005	8.2	140.5
CARAFE	87.76	85.33	+0.076	8.1	138.2
Dysample	88.13	86.69	+0.012	8.1	151.2




图 10 特征图可视化
Fig. 10 Feature map visualization

从表5的实验结果可知,最近邻插值和双线性插值尽管计算效率较高,但由于采用固定规则进行插值,未能充分保留小目标和边缘特征信息。相比之下,CARAFE上采样模块通过引入可学习参数与动态卷积核,改善了特征重组效果,略微提升了精度和召回率,但参数量增加了0.076 M,FPS下降至138.2 frame/s。Dysample模块则通过调整采样网格和偏移量,实现了更高效的内容感知上采样,仅增加了0.012M的参数量,精度和召回率分别提升1.02%和1.56%,FPS达到151.2 frame/s。

图10展示了各模型在Neck部分第18层采用不同方式上采样后的特征图。从图中可以明显看出,与其他上采样方式相比,Dysample模块能够更好地恢复瑕疵的细节特征,尤其在处理小目标和边缘细节方面表现出色。这表明Dysample在精度和细节保留能力上具有显著优势,更加适用于小尺寸瑕疵的检测任务。

5 工业现场验证

为了评估MFL_YOLOv8算法在实际生产环境中的表现,本研究在超纤革生产线上进行了为期三个月的现场测试。在测试期间,MFL_YOLOv8算法集成于现有生产检测系统中,对宽度为1.6 m的超纤革基布在20~50 m/min的进给速度范围内进行了实时瑕疵检测。图11记录了三个月测试期间,145卷超纤革在工业环境中的检测统计结果。数据显示,MFL_YOLOv8算法在检测的精度和检出率方面均达到了工业应用的要求。与传统人工检测方法相比,MFL_YOLOv8算法显著提高了检测效率,减少了因漏检或误检引发的产品报废,并有效降低了人工检测成本。基于以上结果,MFL_YOLOv8算法在超纤革表面瑕疵检测中的有效性和实用性得到了生产线操作人员和管理层的高度认可,具有广阔的应用和推广前景。




图11 工业现场中的检测结果

Fig. 11 On-site detection results in industry

6 结论

本研究提出了MFL_YOLOv8算法,解决了超纤革表面瑕疵检测中微小瑕疵多、尺度变化大和长宽比差异显著的难题。首先,在Backbone部分设计了基于DCNv3-LKA模块的多尺度特征提取网络,显著提升了模型对多尺度和长宽比差异大的目标的特征提取能力;其次,在Neck部分引入P2特征图和Dysample上采样模块,优化了小尺寸瑕疵的细节保留,增强了特征融合效果;最后,提出使用MPDIoU损失函数代替传统的CIoU,解决了小目标检测中的损失函数失效问题,提高了小目标的定位精度。该算法已在工业生产线上成功部署,并验证了其在高速生产环境中的实用性和稳定性,展示了良好的应用前景和推广价值。未来的研究工作将侧重于进一步优化算法结构,以提升检测精度,并探索其在其他工业应用中的广泛适用性。

作者贡献说明:

孙小栋:方法论,模型改进,实验验证,论文构思和撰写;

朱启兵:模型改进,论文写作与审阅;

徐华伟:项目需求分析,数据采集协调,工业现场验证;

邢同振:数据采集、分析与预处理;

朱海斌:项目需求分析和资源调度。

参考文献:

- [1] BASAK S, SHAKYAWAR D B, SAMANTA K K, *et al.* Development of natural fibre based flexural composite: a sustainable mimic of natural leather [J]. *Materials Today Communications*, 2022, 32: 103976.
- [2] 任龙芳, 赵国徽, 强涛涛, 等. 超细纤维合成革仿天然皮革研究进展[J]. *皮革科学与工程*, 2012, 22(1): 36-40.
REN L F, ZHAO G H, QIANG T T, *et al.* Advances in the microfiber synthetic materials emulating natural leather [J]. *Leather Science and Engineering*, 2012, 22(1): 36-40. (in Chinese)
- [3] 李琛, 王冬, 仲鸿天, 等. 超纤革水性含浸工艺的改进[J]. *印染*, 2024, 50(1): 36-39, 43.
LI C, WANG D, ZHONG H T, *et al.* Improvement of water-based impregnation process for microfiber leather [J]. *China Dyeing & Finishing*, 2024, 50(1): 36-39, 43. (in Chinese)
- [4] 张昕, 范浩军, 李静, 等. 甲苯减量型超纤含浸用水性聚氨酯的制备与应用性能评价[J]. *皮革科学与工程*, 2020, 30(5): 1-8.
ZHANG X, FAN H J, LI J, *et al.* Preparation and application performance evaluation of toluene de-weighting type microfiber impregnated waterborne polyurethane [J]. *Leather Science and Engineering*, 2020, 30(5): 1-8. (in Chinese)
- [5] ZHAO B B, QIAN X M, QIAN Y, *et al.* Preparation of high-performance microfiber synthetic leather base using thermoplastic polyurethane/sulfonated polysulfone electrospun nanofibers [J]. *Textile Research Journal*, 2019, 89(14): 2813-2820.
- [6] 刘颖, 姜威, 李冠典, 等. 基于标签嵌入方法的纺织品瑕疵识别网络[J]. *光学精密工程*, 2023, 31(10): 1563-1579.
LIU Y, JIANG W, LI G D, *et al.* Textile defect recognition network based on label embedding [J]. *Opt. Precision Eng.*, 2023, 31(10): 1563-1579. (in Chinese)
- [7] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: Single Shot Multibox Detector [C]. *Computer Vision - ECCV 2016*. Cham: Springer International Publishing, 2016: 21-37.
- [8] TERVEN J, CÓRDOVA-ESPARZA D M, ROMERO-GONZÁLEZ J A. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS [J]. *Machine Learning and Knowledge Extraction*, 2023, 5(4): 1680-1716.
- [9] XIE H S, ZHANG Y F, WU Z S. An improved fabric defect detection method based on SSD [J]. *AATCC Journal of Research*, 2021, 8(1): 181-190.
- [10] LUO R, CHEN R H, JIA F T, *et al.* RBD-Net: robust breakage detection algorithm for industrial leather [J]. *Journal of Intelligent Manufacturing*, 2023, 34(6): 2783-2796.
- [11] LIU B, WANG H, CAO Z, *et al.* PRC-Light YOLO: An efficient lightweight model for fabric defect detection [J]. *Applied Sciences*, 2024, 14(2): 938.
- [12] AZAD R, NIGGEMEIER L, HÜTTEMANN M, *et al.* Beyond Self-Attention: Deformable Large Kernel Attention for Medical Image Segmentation [C]. *2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*. January 3-8, 2024, Waikoloa, HI, USA. IEEE, 2024: 1276-1286.
- [13] LAU K W, PO L M, REHMAN Y A U. Large separable kernel attention: rethinking the large kernel attention design in CNN [J]. *Expert Systems with Applications*, 2024, 236: 121352.
- [14] WANG W H, DAI J F, CHEN Z, *et al.* Intern-image: exploring large-scale vision foundation models with deformable convolutions [C]. *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 17-24, 2023, Vancouver, BC, Canada. IEEE, 2023: 14408-14419.
- [15] LIU W Z, LU H, FU H T, *et al.* Learning to upsample by learning to sample [C]. *2023 IEEE/CVF International Conference on Computer Vision (ICCV)*. October 1-6, 2023, Paris, France. IEEE, 2023: 6004-6014.
- [16] SHI W Z, CABALLERO J, HUSZÁR F, *et al.* Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C]. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 1874-1883.
- [17] WANG J Q, CHEN K, XU R, *et al.* CARAFE:

Content-Aware Reassembly of Features[C]. 2019
IEEE/CVF International Conference on Computer

Vision (ICCV). October 27-November 2, 2019,
Seoul, Korea (South). IEEE, 2019: 3007-3016.

作者简介:



孙小栋(2000—),男,江苏徐州人,硕士研究生,2022年扬州大学获得学士学位,主要从事深度学习目标检测方面的研究。E-mail: sxdazzz1819@163.com

通讯作者:



朱启兵(1973—),男,安徽合肥人,教授,博士生导师,2006年于东北大学获得博士学位,主要从事传感与检测技术、信息感知与智能处理、物联网技术等领域的研究工作。E-mail: zhuqib@163.com