

DOI:10.19651/j.cnki.emt.2517792

基于改进 RT-DETR 的织物疵点检测方法^{*}

李敏^{1,2,3} 周双¹ 朱萍¹ 崔树芹¹ 颜小运¹

(1. 武汉纺织大学计算机与人工智能学院 武汉 430200; 2. 湖北省服装信息化工程技术研究中心 武汉 430200;

3. 纺织服装智能化湖北省工程研究中心 武汉 430200)

摘要: 针对织物疵点种类有限、尺度变化大以及模型检测精度低等问题,提出了一种基于 RT-DETR 的织物疵点检测方法 DHR-DETR。首先,创新性地设计了多路径坐标注意力机制模块(MPCA),并将其与可变形卷积模块(DCNv2)深度融合,构建动态可变形卷积模块,以应对复杂多样的疵点形状。其次,采用高水平筛选特征金字塔(HS-FPN)替换跨尺度特征融合模块(CCFM),实现多层次特征的高效融合并有效降低了模型复杂度。最后,构建了兼具轻量化和特征增强能力的 RetBlockC3 模块,并集成至 HS-FPN 网络,进一步强化模型对局部信息的捕捉能力,同时显著提升模型的轻量化性能。试验结果表明,DHR-DETR 方法在公开和自制织物数据集上的 mAP@0.5 分别达到了 50.9% 和 97.5%,相较原模型提高了 2.9% 和 0.6%,参数量仅为 17.9 M,计算量降低了 37%,显著提升了模型的检测性能和部署效率,具备在实际工业检测任务中的应用潜力。

关键词: RT-DETR; 疵点检测; 动态可变形卷积; 高水平筛选特征金字塔; 轻量化

中图分类号: TN38 **文献标识码:** A **国家标准学科分类代码:** 520.2040

Fabric defect detection method based on improved RT-DETR

Li Min^{1,2,3} Zhou Shuang¹ Zhu Ping¹ Cui Shuqin¹ Yan Xiaoyun¹

(1. School of Computer Science and Artificial Intelligence, Wuhan Textile University, Wuhan 430200, China;

2. Engineering Research Center of Hubei Province for Clothing Information, Wuhan 430200, China;

3. Hubei Engineering Research Center of Intelligent Textile and Fashion, Wuhan 430200, China)

Abstract: To address the challenges of limited fabric defect categories, significant scale variations, and low detection accuracy in existing models, this study introduces DHR-DETR, a fabric defect detection method based on RT-DETR. Firstly, a Multi-Path Coordinate Attention(MPCA) module is innovatively designed and deeply integrated with the Deformable Convolution Module(DCNv2) to construct a Dynamic Deformable Convolution Module. This integration effectively accommodates the diverse and complex shapes of fabric defects. Secondly, a High-Level Screening Feature Pyramid Network(HS-FPN) is employed to replace the Cross-Scale Feature Fusion Module(CCFM), enabling efficient multi-level feature fusion while significantly reducing model complexity. Finally, a lightweight yet feature-enhancing RetBlockC3 module is developed and incorporated into the HS-FPN network. This module enhances the model's capability to capture local information and further improves its lightweight design. Experimental evaluations demonstrate that the proposed DHR-DETR method achieves mAP@0.5 scores of 50.9% and 97.5% on public and custom fabric datasets, respectively, reflecting improvements of 2.9% and 0.6% compared to the baseline model. Additionally, the parameter count is reduced to just 17.9 M, with a 37% decrease in computational complexity. These results indicate substantial improvements in detection performance and deployment efficiency, showcasing the potential of DHR-DETR for practical applications in industrial fabric inspection tasks.

Keywords: RT-DETR; defect detection; dynamic deformable convolution; high-level screening feature pyramid; lightweight design

0 引言

织物疵点检测在纺织行业中具有重要应用价值,能够

提升生产效率、降低成本并保证产品质量。在工业生产中,自动化织物疵点检测可取代传统人工方法,以更高的效率和可靠性满足实际需求。然而,由于织物疵点形态复杂、尺

收稿日期:2025-01-02

*基金项目:湖北省教育厅科学研究计划重点项目(D20211701)资助

寸分布不均,以及材质、图案、光照和背景等因素的干扰,现有的自动化检测系统往往难以达到理想的检测效果,导致误检率和漏检率较高。文献[1-2]研究了机器视觉技术在对产品质量进行检测方面的应用,其自动、准确且能够快速识别的特点对于保证产品的质量具有极其重要的意义和实际价值。

近年来,深度学习在目标检测领域的快速发展为织物疵点检测提供了新的技术手段。基于深度学习的目标检测算法通常可分为单阶段检测和双阶段检测两类。经典的双阶段检测方法如 Faster R-CNN (faster region-based convolutional neural network)^[3] 以及 Cascade R-CNN 等^[4],采用区域提取与分类结合的策略,分阶段执行候选区域生成和目标分类,从而实现较高的检测精度,但模型复杂度较高,难以满足工业检测需求。Chen 等^[5]提出的 Faster GG R-CNN(genetic algorithm gabor faster R-CNN)模型通过嵌入 Gabor 滤波器和遗传算法(genetic algorithm, GA)优化训练,有效减少背景噪声干扰,显著提升检测精度。雷承霖等^[6]基于 Swin Transformer 改进 Cascade R-CNN,实现了对 20 种织物疵点的高精度检测;而单阶段检测方法如 SSD(single shot multibox detector)^[7] 和 YOLO(you only look once)系列^[8-10],将目标定位与分类整合在一个网络中,显著降低了模型复杂度并提升检测速度。然而,这类方法在处理复杂背景时精度表现有限,难以完全满足高精度检测需求。颜学坤等^[11]提出了一种基于 YOLOv5 改进算法的印花图案瑕疵检测模型,引入卷积注意力模块(convolutional block attention module, CBAM)并优化检测层结构,有效提升了检测精度和速度。Di 等^[12]通过在 YOLOv5s 模型中引入上下文感受野模块(context receptive field block, CRFB)和基于反卷积的自适应特征融合网络(deconvolution-based adaptive feature fusion, DAFF),优化特征提取与信息传递效率,并结合指数距离 IoU(exponential distance IoU, EDIoU)改进边界框损失,提升检测性能。王帅等^[13]提出了一种融合可变形卷积 v4 (deformable convolutional networks version 4, DCNv4) 算子和多尺度卷积注意力空间注意力模块(multiscale convolutional attention spatial attention module, MCASAM)的改进 YOLOv8s 算法,显著提升了对疵点的检测效果。尽管这两类检测方法各有特点,但都需要通过阈值筛选和非极大值抑制(Non-Maximum suppression, NMS)来过滤候选框,增加了计算复杂度,并在一定程度上影响了模型的鲁棒性和检测效率。

随着 Transformer^[14]在目标检测中的应用,Facebook 团队于 2020 年提出了基于 Transformer 的端到端目标检测算法 DETR(detection transformer),巧妙地消除了上述处理步骤,从而简化了处理流程,带来了高效直接的检测体验。然而,尽管 DETR 在结构上进行了简化,但其较大的参数量也成了一个挑战,需要在保持模型性能的同时,寻

求参数优化的策略。百度针对 DETR 高计算成本的问题,提出了基于 DETR 的实时检测方法 RT-DETR(real time detection transformer)^[15],通过优化模型结构减少了计算量,使得 RT-DETR 在更少的迭代次数下就能达到更高的训练精度。

尽管 RT-DETR 在通用目标检测任务中取得了良好效果,但在织物疵点检测这一特定场景中仍然存在局限性。首先,其主干网络采用固定大小的卷积核,这使得模型难以有效适应织物疵点的复杂形态和多变的尺度。织物疵点(如破洞、污渍、断纱等)不仅在形状上具有较大的多样性,且在尺寸上差异显著(从微小点到较大区域不等),而 RT-DETR 的固定卷积核和传统的特征融合模块难以动态调整感受野,导致对不规则和多尺度疵点的定位精度不足。

其次,RT-DETR 的跨尺度特征融合模块(cross-scale feature fusion module, CCFM)在融合多尺度特征时存在信息冗余和效率低下的问题。在织物疵点检测中,由于背景和纹理的复杂性,传统的特征融合方法无法有效减少冗余信息,进一步影响了模型对疵点的精准识别能力,特别是在面对复杂背景(如织物的纹理和图案变化)时,容易造成误检和漏检。

此外,尽管 RT-DETR 通过一定优化降低了计算量,但其模型参数量较大,仍然难以满足工业检测任务中对实时性和部署效率的高要求。因此,RT-DETR 的轻量化不足,使其在工业场景中的实际应用受到制约。

鉴于此背景,本文提出一种基于 RT-DETR 的织物疵点检测方法 DHR-DETR。主要工作如下:

1) 创新性设计了一种多路径坐标注意力机制模块(multi-path coordinate attention, MPCA),通过多路径特征融合机制,增强对全局上下文信息和局部细节特征的捕捉能力,显著提升模型在复杂背景下的特征提取效果。结合可变形卷积 v2 模块(deformable convolutional networks version 4, DCNv2),构建了 Dynamic-DCNv2 模块,该模块可根据疵点的尺寸和形状自适应调整感受野范围,实现对复杂、不规则疵点的精准识别,有效抑制无关背景干扰,从而大幅提升检测精度和适应性。

2) 为提升模型的特征融合性能,采用高水平筛选特征金字塔(High-level Screening-feature fusion pyramid, HS-FPN)模块替代传统的跨尺度特征融合模块(CCFM)。相比 CCFM,HS-FPN 通过增强特征筛选的精确性和跨尺度特征的融合效率,有效整合了不同尺度的关键特征信息,在保持重要信息完整性的同时,显著提升了特征判别能力。此外,HS-FPN 通过重新分配特征权重,优化特征层级间的空间分布,使重要特征能够在不同尺度间高效传递和共享,从而提升模型在复杂背景下的疵点识别性能。多层次特征筛选与优化融合机制的引入,不仅减少了冗余信息,还降低了计算成本并提高了检测效率。

3) 为进一步优化模型性能并简化其结构,设计了一种

结合轻量化与特征增强能力的 RetBlockC3 模块。该模块通过引入空间衰减矩阵,聚焦于织物疵点的关键区域,有效抑制背景干扰,从而显著提升检测精度。此外,RetBlockC3 模块采用注意力分解机制,优化了特征提取过程,不仅增强了特征表达能力,还显著降低了模型复杂度。集成至 HS-FPN 网络后,进一步提升了模型的特征捕捉效率,实现了更高程度的模型轻量化与性能优化。

1 本文方法

本文所作改进基于 RT-DETR-ResNet18 进行,其由主干网络、编码器、颈部网络、交并比感知查询模块以及解码器组成,旨在实现高效特征提取、多尺度特征融合以及精准的目标框生成。主干网络采用 ResNet18 结构,用于从输入图像中提取多尺度基础特征,为编码器和特征融合提供必要的图像信息;编码器采用 Transformer 中标准的编码器,使用多头自注意力机制与跨尺度特征交互模块(attention-based intra-scale feature interaction, AIFI),在不同空间位置和尺度之间捕捉特征关联信息,从而显著增强图像特征的表达能力和辨别力;在特征融合部分,颈部网络通过跨尺度特征融合模块(CCFM)聚合多尺度特征,以更好适应目

标检测任务的多尺度需求;交并比感知查询模块在训练阶段对目标查询特征进行优化约束,使解码器生成的目标查询特征具有更高的分类分数和交并比分数,进而提高目标框定位的精确性;解码器结构参考了 DINO^[16]设计理念,生成固定数量的预测框,并通过一对一匹配策略将预测框与真实框进行匹配,通过一定的规则选择最适配的预测框,再计算损失函数。

针对原始的 RT-DETR 网络未针对织物疵点检测进行优化,限制了其在织物疵点检测中的有效性问题,对 RT-DETR 结构进行了改进,改进结构图如图 1 所示。首先,提出多路径坐标注意力机制(MPCA),并结合可变形卷积模块(DCNv2),构建了 Dynamic-DCNv2 模块,优化主干网络结构以提升检测精度。其次,在特征融合中采用高水平筛选特征金字塔(HS-FPN)替代传统跨尺度特征融合模块(CCFM),实现高效的多尺度特征传递,并有效降低模型复杂度。最后,引入轻量级的 RetBlockC3 模块,在强化模型特征捕捉能力的同时进一步减少计算负担。这些改进使得 DHR-DETR 在保持高检测精度的同时具备更优的轻量化性能,更适用于织物疵点检测任务。

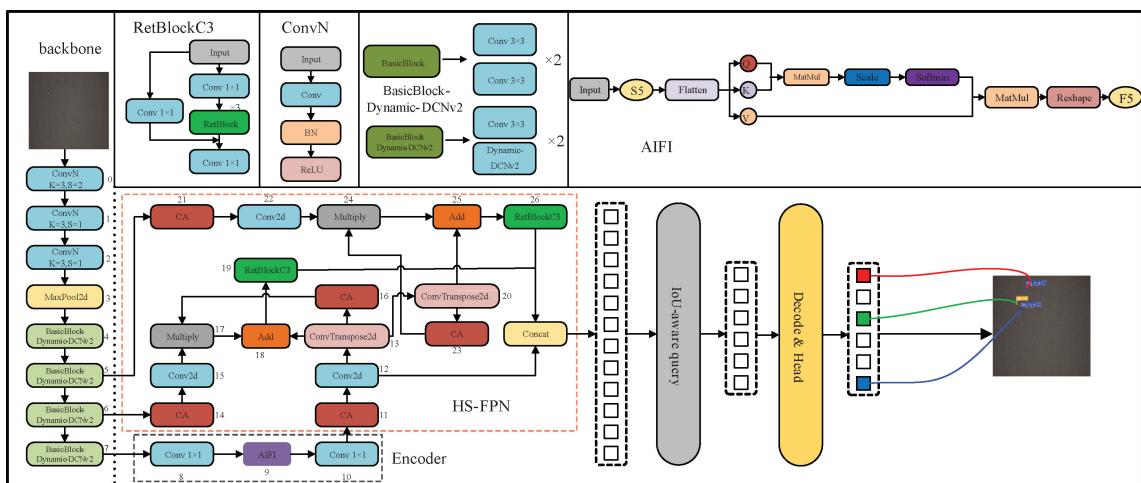


图 1 DHR-DETR 结构

Fig. 1 Structure of DHR-DETR

1.1 Dynamic-DCNv2

在织物疵点检测中,疵点通常表现为大小不一、形状复杂多变的特点,这显著增加了检测任务的难度。传统卷积神经网络使用固定大小和形状的滑动窗口来提取特征,难以灵活适应疵点的多样化特征,导致定位和检测性能较差。为了应对这一挑战,本文在 ResNet-18 的主干网络基础上,将颈块中的常规 3×3 卷积替换为具有更强空间变形能力的 Dynamic-DCNv2,以动态调整卷积核的感受野,使其更贴合疵点的形状和大小,从而提升定位和检测性能。

Zhu 等^[17]在传统可变形卷积的基础上提出了 DCNv2,

通过引入调制模块来合理控制卷积核的采样范围,使采样点能够保持在理想的特征范围内。受此启发,本文通过 MPCA 改进调制模块和学习变化幅度,得到改进的 Dynamic-DCNv2 模块,如图 2 所示。

在 Dynamic-DCNv2 模块中,给定一个具有任意 K 个采样位置的卷积核, P_k 和 w_k 分别表示第 k 个位置的预先指定的偏移和权重, P 表示输出特征图上的位置。在输入特征图 X 通过 Dynamic-DCNv2 模块后,得到的输出特征图 Y 表示如下:

$$Y(p) = \sum_{k=1}^K w_k \cdot X(p + p_k + \Delta p_k) \cdot \Delta m_k \quad (1)$$

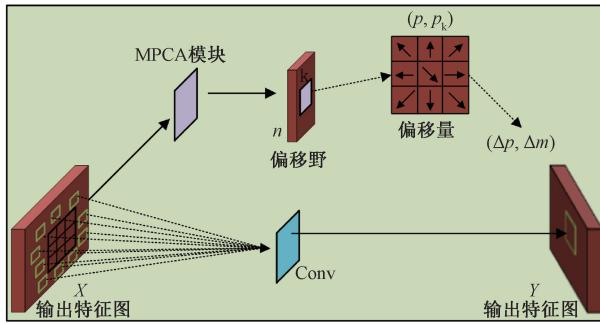


图 2 Dynamic-DCNv2 模块结构

Fig. 2 Structure of the Dynamic-DCNv2 module

其中, Δp_k 和 Δm_k 分别表示第 k 个位置的可学习偏移和调制标量。其中, 偏移量用于调整卷积核的采样位置, 使其更精准地贴合目标特征; 调制标量则通过 sigmoid 函数约束在 $[0, 1]$ 范围内, 用于控制每个采样点的响应幅度, 从而灵活优化感受野的分布。通过对偏移量和调制标量的联合调整, Dynamic-DCNv2 克服了传统卷积核在捕捉复杂形状和多样化疵点特征时的局限性。这种灵活性使得模型对疵点形状、大小和边界细节的适应性显著提高, 显著提升了特征提取的精度和疵点检测的准确性。

1.2 MPCA

MPCA 模块通过与 DCNv2 卷积模块的结合, 有效引导卷积操作, 使其更加聚焦于织物疵点的关键区域和细节。这种结合不仅赋予 DCNv2 动态调整感受野的灵活性, 还在 MPCA 的引导下增强了特征捕捉的精度, 提升了模型在复杂背景下对疵点的敏感性和识别能力。

其中 MPCA 模块结构如图 3 所示。具体而言, MPCA 模块基于通道注意力(channel attention, CA)^[18]进行优化, 以更精确地捕捉特征间的空间和通道依赖关系。首先, 它对输入特征图在高度和宽度方向分别进行平均池化, 生成两对具有方向感知的特征图。这些特征图能够保留沿单一空间方向的精确位置信息, 从而帮助模型更准确地聚焦于目标位置。接着, MPCA 模块对特征图进行全局平均池化, 生成具有全局感受野的特征图, 进一步增强了通道信息的表达能力。最后, MPCA 通过特征融合策略, 将方向感知特征图与全局特征图进行交互, 以捕捉不同尺度空间信息之间的依赖关系。通过这种多路径聚合的特征融合方式, MPCA 能够有效减少背景干扰, 并强化疵点区域的特征表达。整体而言, MPCA 模块显著提升了织物疵点检测模型的精度和鲁棒性。

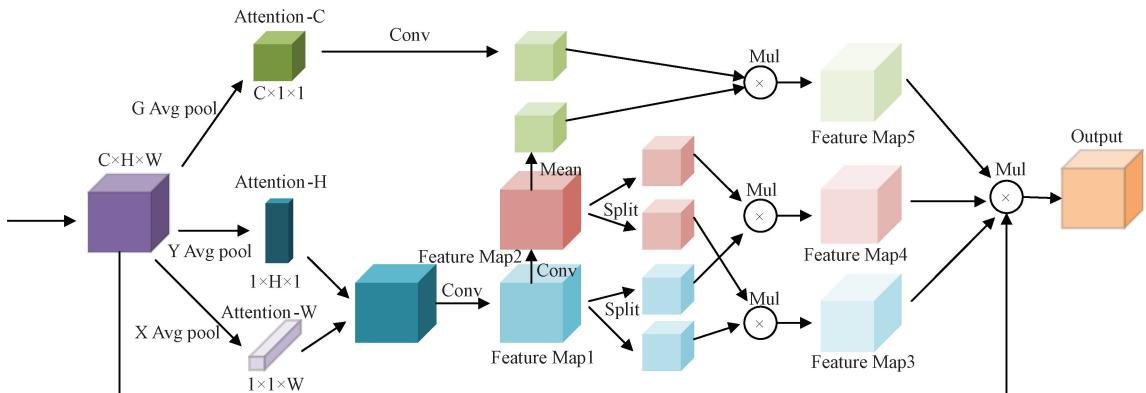


图 3 MPCA 结构

Fig. 3 Structure of the MPCA module

1.3 高水平筛选特征金字塔

在织物疵点检测中, 由于疵点种类和尺度的多样性, RT-DETR 模型中传统的特征融合方法(CCFM)难以有效捕捉疵点的细节信息和语义信息。为提升模型对不同尺寸疵点的检测能力, 本文对 RT-DETR 模型的特征融合部分进行了优化, 提出了高水平筛选特征金字塔(HS-FPN), 以实现多尺度特征的高效融合。HS-FPN^[19]结构如图 4 所示, 主要包括特征选择模块和特征融合模块。

特征选择模块通过通道注意力(channel attention, CA)和维度匹配(dimensional matching, DM)机制, 筛选并强化多尺度特征图中的关键信息, 从而为后续的特征融合提供支持。具体而言, CA 模块首先对输入特征图执行全局平均池化和最大池化, 以提取各通道的平均值和最大值, 再通过 Sigmoid 激活生成每个通道的权重。该权重用

于增强关键特征通道的显著性, 同时抑制无关或冗余信息, 使模型能够更关注与疵点相关的有效特征。随后, DM 模块通过 1×1 卷积操作, 将不同尺度的特征图通道数统一, 实现维度匹配, 以便后续的多尺度特征融合。

特征融合模块(select feature fusion, SFF)通过将高层特征作为权重, 筛选底层特征中具有重要语义的信息, 有效地结合了高级特征的语义信息和低尺度特征的细节信息, 从而提升了多尺度特征融合的效果。

1.4 RetBlock

RetBlock^[20]通过引入空间衰减矩阵, 使模型能够更精确地捕捉织物疵点之间的相对位置, 增强了对空间信息的理解, 结构如图 5 所示。这种基于距离的权重调整机制, 有助于模型聚焦于织物图像中的关键区域, 从而有效抑制复杂纹理等常见干扰对疵点检测精度的负面影响。

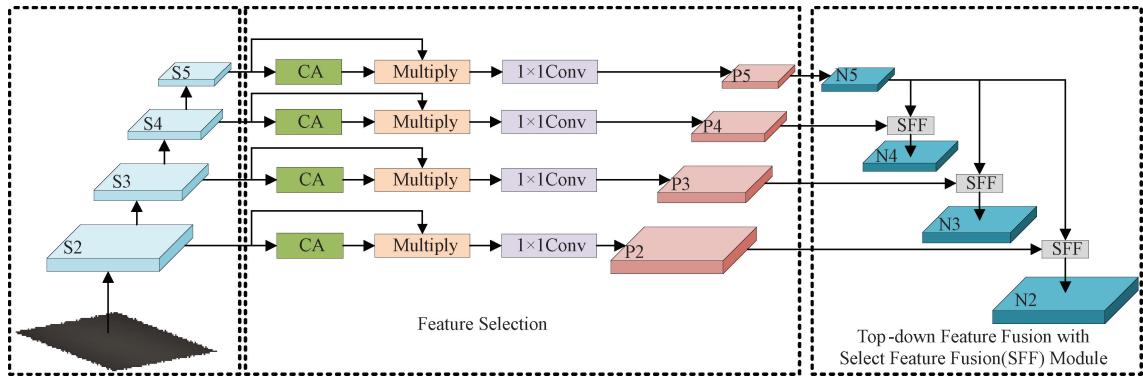


图 4 HS-FPN 网络结构
Fig. 4 HS-FPN network structure

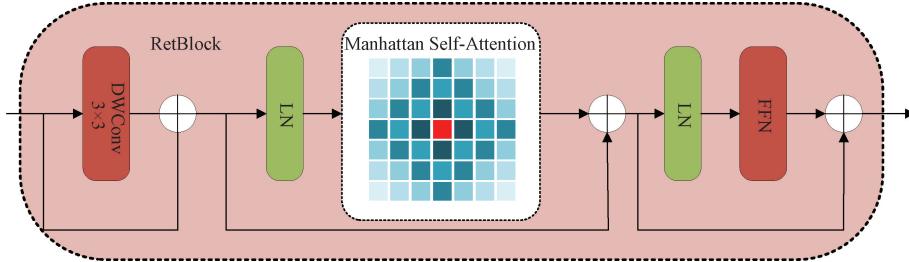


图 5 RetBlock 结构
Fig. 5 RetBlock structure

RetBlock 的核心创新在于将空间衰减矩阵与注意力分解机制相结合,协同提升模型对关键区域的关注能力与整体图像识别性能。

1) 空间衰减矩阵

为增强二维图像处理的效果,RetBlock 将一维衰减扩展到二维。在二维图像的上下文中,每个标记(表示图像中特征点的位置)通过其在平面内的坐标 (x_n, y_n) 来唯一定位。为了适应这一点,调整矩阵 \mathbf{D} 中的每个元素,以表示基于各自标记对的二维坐标的曼哈顿距离。矩阵 \mathbf{D} 重新定义为:

$$\mathbf{D}_{nm}^{2d} = \gamma^{|x_n - x_m| + |y_n - y_m|} \quad (2)$$

其中, x_n 和 x_m 分别是图像中第 n 个和第 m 个标记的横坐标, y_n 和 y_m 是它们对应的纵坐标。 γ 是一个衰减系数,用于控制注意力分数随距离增加而衰减的速率。这个全新的二维空间衰减矩阵确保了模型在计算注意力时能够更好地关注与疵点相关的局部区域,从而减少了远离目标的背景干扰。

2) 自注意力分解机制

曼哈顿自注意力(manhatten self-attention, MaSA)是一种受 RetNet 启发的自注意力机制,借鉴了 RetNet 显式建模空间依赖关系的设计思路,通过结合空间衰减矩阵 D^{2d} 有效引入显式空间先验,从而进一步提升模型的特征捕捉能力。MaSA 的计算可以表示为:

$$\text{MaSA}(X) = (\text{Softmax}(QK^H) \odot D^{2d})V \quad (3)$$

其中, Q, K, V 是通过线性变换得到的注意力矩阵, \odot 表示即逐元素乘法, 使用 softmax 函数对注意力权值进行归一化。

为了降低计算复杂度,同时保留空间衰减矩阵中的先验信息,RMT 使用了一种注意力分解形式,分别从垂直和水平方向计算注意力得分,并对这些注意力权重应用一维双向衰减矩阵。

$$\text{Attn}_H = \text{Softmax}(Q_H K_H) \odot D^H \quad (4)$$

$$\text{Attn}_W = \text{Softmax}(Q_W K_W) \odot D^W \quad (5)$$

$$\text{MaSA}(X) = \text{Attn}_H(\text{Attn}_W V) \quad (6)$$

其中, Q_H, K_H, V_H 分别是水平方向的查询矩阵、键矩阵和值矩阵。 Q_W, K_W, V_W 为垂直方向对应的矩阵。 D^H 和 D^W 分别为水平和垂直衰减矩阵,分别表示标记在水平和垂直方向上的距离衰减。通过这种分解,RetBlock 在保持空间先验的同时,将自关注的计算复杂度从二次型降低到线性型,显著提高了模型的效率。

尽管 MaSA 在捕捉长距离依赖方面表现出色,但其对局部上下文的表达能力仍存在不足。为此,RetBlock 引入了深度可分离卷积(depthwise separable convolution, DWConv)模块,用于捕捉局部上下文信息并增强特征细节表达能力。DWConv 的引入有效补充了自注意力机制的局部表达能力短板,使 RetBlock 在处理织物疵点检测任务时展现出更强的鲁棒性和表现力。最终计算公式如下:

$$X_{\text{out}} = \text{MaSA}(X) + \text{LCE}(V) \quad (7)$$

3) RetBlockC3

RetBlockC3 是在 RetBlock 的基础上构建的全新模块, 其结构如图 1 所示。相比原始的 RepC3 模块, RetBlockC3 引入了空间衰减矩阵和注意力分解形式的设计, 有效提升了模型在织物疵点检测任务中的表现。空间衰减矩阵通过曼哈顿距离量化特征点之间的空间关系, 使得模型能够动态调整注意力分数。距离较远的特征点注意力逐步减弱, 而靠近疵点区域的特征点注意力保持较高, 从而确保对图像中疵点特征保持高敏感性。这一机制显著增强了模型对疵点区域的聚焦能力, 同时有效抑制背景干扰。此外, RetBlockC3 采用注意力分解形式, 将复杂的注意力计算拆分为更易管理的子任务, 降低了计算复杂度并提升了模型的效率。

2 试验结果与分析

2.1 织物疵点数据集

本研究使用了两个织物疵点图像数据集。第一个数据集为公开的天池 2019 织物疵点数据集, 包含 5 913 张织物图像, 涉及 9 523 个疵点, 尺寸为 2446×1000 , 涵盖 20 个类别, 包括破洞、水渍油渍污渍、三丝、结头、花跳板、百脚、毛粒、粗经、松经、断经、吊经、粗维、纬缩、浆斑、整经结、星跳跳花、断氨纶、稀密档浪纹、磨痕轧痕、死皱云织双维等。另一个为实验室自制的色织物疵点数据集, 包含 2 115 张图像, 尺寸为 512×512 , 分为 6 个类别: 带纱、断纱、棉球、破洞、脱纱和污渍。图 6 展示了这 6 种疵点类型的部分检测图像。两个数据集按 8:2 的比例随机划分为训练集和测试集, 用于模型的训练与评估。

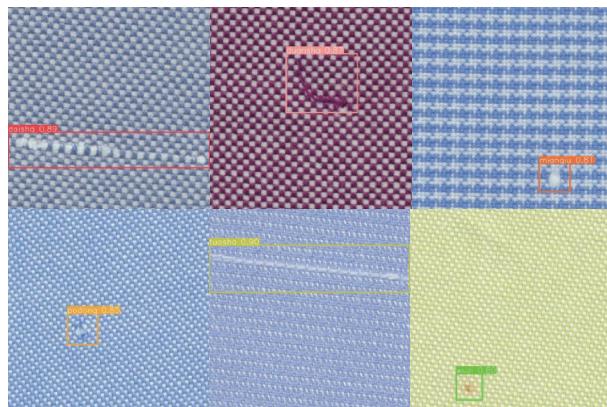


图 6 色织物图像检测效果

Fig. 6 Detection effectiveness of colored fabric image detection

2.2 试验环境与评价指标

试验使用 Ubuntu 22.04 操作系统, CPU 型号 AMD EPYC 7402 24-Core Processor, GPU 型号 NVIDIA GeForce RTX 3090 显卡, 显存 24 G, 深度学习框架选择 python-3.10、cuda-12.1、pytorch-2.2.0。两个数据集试验参数设置如下: 初始学习率设置为 0.0001, Batch Size 设置

为 8, 优化器使用 AdamW, 训练轮次设置为 350, 输入图像大小调整为 640×640 。本文采用 mAP@0.5、mAP@0.5:0.95、参数量(Params)、浮点运算量(FLOPs)作为检测评价指标。

2.3 消融试验

在相同条件下为测试每个改进模块的有效性, 通过消融试验来验证 Dynamic-DCNv2、HS-FPN、RetBlockC3 对算法性能的影响, 消融结果如表 1 所示。首先, 单独将 Dynamic-DCNv2 模块集成到骨干网络中, 该模块通过 MPCA 改进调制模块, 使得采样位置能够根据输入特征动态调整, 更精准地捕捉到织物疵点的纹理细节和不规则形状, 在仅增加 0.5 M 参数量的情况下, 使 mAP@0.5 提升了 1%, mAP@0.5:0.95 提升了 0.7%, 显著增强了模型的特征提取能力; 在 Dynamic-DCNv2 提供的精细局部特征和全局语义信息基础上, 采用 HS-FPN 替换跨尺度特征融合模块(CCFM), 从而更高效地融合不同尺度的特征, 同时降低了模型复杂度, 并使 mAP@0.5 提升了 1.4%, 显著优化了模型的检测性能; 当同时添加了 Dynamic-DCNv2 和 HS-FPN 模块时, 模型实现了特征细节的丰富表达和多尺度信息的高效融合, 在此基础上进一步引入 RetBlockC3 模块, 通过其空间衰减矩阵和注意力分解机制, 模型的特征表达能力得到了进一步优化, 模型 mAP@0.5 和 mAP@0.5:0.95 分别提升至 50.9% 和 27.1%, 相较于改进前的 RT-DETR 模型分别提高 2.9% 和 1.8%。同时, 集成三种改进后的模型参数量降低至 17.9 M, 浮点运算量减少至 35.9 G, 分别较原版减少 9.7% 和 37%。结果表明, 集成改进模块不仅显著提升了模型的检测精度, 还大幅降低了模型的复杂度, 充分证明了 DHR-DETR 算法在织物疵点检测性能方面优于原版 RT-DETR 算法。

2.4 对比试验

为了验证所提方法的有效性, 在目标检测任务中将所提的 DHR-DETR 模型与多种主流的检测模型进行对比, 包括 CenterNet、Faster R-CNN、YOLO 系列(YOLOv5m、YOLOv8m、YOLOv10b、YOLOv11m)、文献[21]、文献[22]、RT-DETR。如表 2 所示, DHR-DETR 在 mAP@0.5 和 mAP@0.5:0.95 上均表现优异, 其中, DHR-DETR 的 mAP@0.5 和 mAP@0.5:0.95 分别为 50.9% 和 27.1%, 均高于对比的目标检测算法。对于原版 RT-DETR 算法, 得益于更高效的动态可变形卷积模块(Dynamic-DCNv2)和创新的多尺度特征融合模块(HS-FPN+RetBlockC3), DHR-DETR 在天池织物数据集上的 mAP@0.5 和 mAP@0.5:0.95 分别提高了 2.9% 和 1.8%, 且参数量减少了 1.9 M, 计算量降低了 21.1 G; 与两阶段的 Faster R-CNN 模型相比, DHR-DETR 在检测精度上远超前者, 并且更加轻量化; 相较于 CenterNet, mAP@0.5 和 mAP@0.5:0.95 分别提升了 9.6% 和 9.7%, 同时参数量减少了 14.7 M, 计算量降低了 34.3 G; 相较于 YOLO 系列算法, DHR-DETR

表 1 消融试验

Table 1 Ablation study

试验序号	基准模型	Dynamic-DCNv2	HS-FPN	RetBlockC3	参数量/M	计算量/G	mAP@0.5/%	mAP@0.5:0.95/%
1	√	×	×	×	19.8	57.0	48.0	25.3
2	√	√	×	×	20.3	45.0	49.0	26.0
3	√	√	√	×	18.6	41.3	50.4	26.0
4	√	√	√	√	17.9	35.9	50.9	27.1

算法检测精度显著提高, mAP@0.5 分别提高了 7.9%、4.8%、11.4% 和 6.8%, 同时 DHR-DETR 的参数量和计算量均为最低, 实现了检测精度与模型复杂度的最佳平衡; 相较于文献[21]和[22]算法, 尽管 DHR-DETR 在参数量(17.9 M)和计算量(35.9 G)方面略高于文献[21](2.8 M)

和 7.1 G)和文献[22](3.1 M 和 8.2 G), 但 DHR-DETR 算法的精度有着明显的优势, mAP@0.5 分别提高了 11.3% 和 11%, 表明其在复杂场景中的检测能力更强。综合对比表明, DHR-DETR 以更优越的模型结构实现了更高的检测精度, 充分展示了其在实际检测任务中的应用潜力。

表 2 不同模型对比试验

Table 2 Comparative study of different models

模型	输入尺寸	主干网络	参数量/M	浮点运算量/G	mAP@0.5/%	mAP@0.5:0.95/%
CenterNet	512×512	ResNet50	32.6	70.2	41.3	17.4
Faster RCNN	600×600	ResNet50	137.0	370.2	29.5	5.0
YOLOv5m	640×640	CspDarkNet	25.0	64.0	43.0	20.7
YOLOv8m	640×640	CspDarkNet	25.8	78.7	46.1	22.9
YOLOv10b	640×640	CSPNet	20.4	98.1	39.5	20.5
YOLOv11m	640×640	CSPNet	20.0	67.7	44.1	21.4
文献[21]	640×640	CspDarkNet	2.8	7.1	39.6	17.6
文献[22]	640×640	CspDarkNet	3.1	8.2	39.9	19.3
RT-DETR	640×640	ResNet18	19.8	57.0	48.0	25.3
DHR-DETR	640×640	ResNet18+DD	17.9	35.9	50.9	27.1

表 3 展示了改进模型与 RT-DETR 在各类别疵点检测任务中的 AP 对比结果。可以看出, 绝大部分疵点的 AP 值都有不同程度的提升, 特别是在小疵点目标如破洞、水渍油渍污渍、结头、毛粒等方面, 性能提升较为明显, 表明改进模型在细小目标的特征提取和检测能力上有显著增强。此外, 对于一些由细小疵点构成的较大疵点, 如浆斑、百脚、花跳板和稀密档浪纹等, 改进模型也带来了显著的性能提升, 这得益于动态感受野调节能力的增强和多尺度特征融合的优化。

表 3 各类疵点检测的 AP 值对比结果

Table 3 Comparison results of AP values for various defect detection types

疵点种类	AP/%	
	RT-DETR	本研究模型
破洞	77.3	78.5
水渍油渍污渍	41.8	48.9
三丝	61.6	60.8
结头	49.3	50.0

表 3(续)

Table 3 (Continued)

疵点种类	AP/%	
	RT-DETR	本研究模型
花跳板	73.6	74.9
百脚	37.4	47.5
毛粒	26.5	27.8
粗经	65.4	73.5
松经	57.9	60.8
断经	14.9	12.6
吊经	15.9	24.8
粗维	52.2	49.1
纬缩	18.5	19.9
浆斑	70.3	72.8
整经结	44.7	45.0
星跳跳花	70.7	70.4
断氨纶	58.7	55.7
稀密档浪纹等	20.9	25.6
磨痕轧痕等	58.9	60.8
死皱云织双维等	44.4	59.5

2.5 可视化试验

图 7 展示了原始 RT-DETR 模型与改进模型在织物图像检测中的对比结果, 其中图 7(a)为原始 RT-DETR 模型的检测效果, 图 7(b)为改进模型的检测效果。第一至第五行分别对应稀密档浪纹、死皱云织双维、松经、结头和污渍疵点的检测表现。与原始 RT-DETR 模型相比, 改进模型在识别稀密档浪纹和死皱云织双维疵点时展现出更强的检测能力, 有效降低了漏检率; 同时, 对松经和污渍疵点检测中存在的多检问题, 改进模型也进行了显著优化。此外, 改进模型还成功纠正了结头被误检为断氨纶的情况, 大幅提升了模型的整体识别准确率。

2.6 泛化分析试验

为进一步验证改进网络的泛化能力, 本文在自制数据集上对各类别的检测结果进行了分析。表 4 展示了改进算法与 RT-DETR 算法在自制数据集上具体疵点类型的检测精度。数据显示, 改进算法在带纱、断纱、棉球、破洞和脱纱的平均精度均高于基准算法, mAP@0.5 提升了 0.6%, 同时模型的参数量和浮点运算量显著降低。实验结果进一步验证了改进方法在织物疵点检测中的泛化性和鲁棒性。



图 7 织物检测效果

Fig. 7 Fabric defect detection results

表 4 泛化性试验

Table 4 Generalization test results

方法	带纱/%	断纱/%	棉球/%	破洞/%	脱纱/%	污渍/%	参数量/M	浮点运算量/G	mAP@0.5/%
RT-DETR	95.9	98.0	95.9	99.0	97.5	94.9	19.8	57.0	96.9
改进算法	97.2	98.9	96.0	99.5	98.3	94.9	17.9	35.9	97.5

3 结 论

本文提出了一种改进的织物疵点检测算法(DHR-DETR), 该算法在优化模型结构的基础上, 成功实现了检测精度与模型轻量化的平衡。通过引入动态可变形卷积模块和高效的特征融合模块, DHR-DETR 显著提升了模型在多尺度疵点特征捕捉和复杂背景下的检测能力。实验结果表明, 与原始 RT-DETR 模型相比, DHR-DETR 在天池织物疵点检测数据集和自制数据集上的 mAP@0.5 分别提升了 2.9% 和 0.6%, 同时参数量仅为 17.9 M, 计算量降低了 37%, 验证了改进算法的有效性与实用性。尽管 DHR-DETR 在织物疵点检测任务中表现出色, 但在实际应用中, 尤其是边缘设备上部署时, 仍然面临计算资源有限、处理速度要求高等挑战。为了解决这些问题, 未来的研究将着重于算法的实际部署, 通过剪枝和知识蒸馏技术进一步精简并优化算法模型, 将其移植到边缘硬件平台中, 确保在资源受限的环境中也能保持较高的检测精度。与此同时, 本文还将扩展数据集, 收集更多的织物疵点类别与场景, 以增强算法在各种复杂实际场景下的泛化能力。

和鲁棒性。

参考文献

- [1] 吴永泽, 俞建峰, 化春键, 等. 基于改进 YOLOv8n 的圆柱电池壳多维缺陷检测技术研究[J]. 电子测量与仪器学报, 2024, 38(12): 62-71.
WU Y Z, YU J F, HUA C H J, et al. Research on multi-dimensional defect detection technology for cylindrical battery shells based on improved YOLOv8n[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(12): 62-71.
- [2] 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.
- [3] REN S H 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, 2016, 39(6): 1137-1149.
- [4] CAI ZH W, VASCONCELOS N. Cascade R-CNN: Delving into highquality object detection [C]. IEEE Conference on Computer Vision and Pattern Recognition,2018: 6154-6162.
- [5] CHEN M Q, YU L J,ZHI CH, et al. Improved faster R-CNN for fabric defect detection based on Gabor filter with genetic algorithm optimization [J]. Computers in Industry, 2022, 134: 103551.
- [6] 雷承霖,李敏,王斌.基于 Swin Transformer 的两阶段织物疵点检测[J].棉纺织技术,2023,51(2):41-47.
LEI CH L, LI M, WANG B. Two stage fabric defect detection based on Swin Transformer [J]. Cotton Textile Technology, 2023, 51(2): 41-47.
- [7] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. Computer Vision-ECCV2016:14th European Conference, 2016: 21-37.
- [8] REDMON J. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition,2016.
- [9] WU T H, WANG T W, LIU Y Q. Real-time vehicle and distance detection based on improved YOLOv5 network[C]. 2021 3rd World Symposium on Artificial Intelligence(WSAI). IEEE, 2021: 24-28.
- [10] WANG CH Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition,2023: 7464-7475.
- [11] 颜学坤,楚建安.基于 YOLOv5 改进算法的印花图案疵点检测[J].电子测量技术,2022,45(4):59-65.
YAN X K, CHU J AN. Printing pattern defect detection based on improved YOLOv5 algorithm[J]. Electronic Measurement Technology, 2022, 45 (4): 59-65.
- [12] DI L, DENG SH SH, LIANG J ZH, et al. Context receptive field and adaptive feature fusion for fabric defect detection[J]. Soft Computing, 2023, 27(18): 13421-13434.
- [13] 王帅,刘珊珊,李保田,等.基于改进 YOLOv8s 的织物疵点检测[J].棉纺织技术,2025,53(2):49-55.
WANG SH,LIU SH SH, LI B T, et al. Fabric defect detection based on improved YOLOv8s [J]. Cotton Textile Technology, 2025, 53(2): 49-55.
- [14] BUJAGOUNI K G,PRADHAN S. Transformer based deep learning hybrid architecture for phase unwrapping[J]. Physica Scripta, 2024, 99(7): 076017.
- [15] ZHAO Y, LYU W U, XU S L, et al. Detrs beat yolos on real-time object detection [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.
- [16] ZHANG H, LI F, LIU SH, et al. Dino: Detr with improved denoising anchor boxes for end-to-end object detection[J]. ArXiv preprint arXiv:2203.03605,2022.
- [17] ZHU X ZH, HU H, LIN S, et al. Deformable convnets v2: More deformable, better results [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition,2019: 9308-9316.
- [18] HOU Q B, ZHOU D Q, FENG J SH. Coordinate attention for efficient mobile network design [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition,2021: 13713-13722.
- [19] CHEN Y F, ZHANG CH Y,CHEN B,et al. Accurate leukocyte detection based on deformable-DETR and multi-levelfeature fusion for aiding diagnosis of blood diseases [J]. Computers in Biology and Medicine, 2024, 170: 107917.
- [20] FAN Q H, HUANG H, CHEN M R, et al. Rmt: Retentive networks meet vision transformers [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition,2024: 5641-5651.
- [21] 李耀,徐红伟,柯海森,等.基于改进 YOLOv8n 的织物疵点检测[J].棉纺织技术,2024,52(10):11-18.
LI Y,XU H W,KE H S,et al. Fabric defect detection based on improved YOLOv8n [J]. Cotton Textile Technology, 2024, 52(10): 11-18.
- [22] 王可,李欣雨,郑彬朋,等.基于改进 YOLOv8n 的织物疵点检测方法研究[J].电脑与电信,2024(10):14-20.
WANG K, LI X Y, ZHENG B P, et al. Research on fabric defect detection method based on improved YOLOv8n [J]. Computers and Telecommunications, 2024(10): 14-20.

作者简介

- 李敏**,副教授,主要研究方向为机器学习、计算机视觉、多媒体处理和检索等。
E-mail:2008031@wtu.edu.cn
- 周双**(通信作者),硕士研究生,主要研究方向为织物疵点检测。
E-mail:1643998545@qq.com
- 朱萍**,副教授,主要研究方向为计算机系统结构、人工智能物联网、计算机视觉、绿色计算、信息安全等。
E-mail:zhuping@wtu.edu.cn
- 崔树芹**,讲师,主要研究方向为计算机图形学、虚拟现实技术。
E-mail:csg@wtu.edu.cn
- 颜小运**,讲师,主要研究方向为显著性检测、缺陷检测、人群密度估计、目标检测识别、红外目标检测识别、图像分割和抠图等计算机视觉。
E-mail:maxwell868@sina.com