

DOI:10.19651/j.cnki.emt.2212164

复杂纹理布匹五类典型瑕疵图像检测算法研究

吴志华 钟铭恩 谭佳威 许平平 赵昱廷
(厦门理工学院机械与汽车工程学院 厦门 361024)

摘要: 针对复杂纹理布匹瑕疵检测这一纺织工业质检环节中的技术难点,基于深度卷积神经网络提出一种图像检测算法模型。首先对比选用 YOLOv7-tiny 模型为算法参考框架然后进行优化改进,包括使用 SimAM 模块重构特征融合层,以提升模型对瑕疵局部特征的提取能力并抑制背景特征;采用 SIOU 优化坐标定位损失函数,以加快目标框的回归效率;引入 FReLU 激活函数,以增强非线性激活层对空间信息的利用能力,提升激活函数的空间敏感性。实验结果表明,该模型在复杂纹理布匹五类典型瑕疵的检测任务上的查准率和查全率都优于现有其他算法,mAP 达到最高值 80.5%,且模型大小仅为 9.2 M,在 PC 端上单帧图像检测只需 21.13 ms。

关键词: 复杂纹理布匹;瑕疵检测;YOLOv7-tiny;SimAM;SIOU;FReLU

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 54099

Research on five types of typical defects image detection algorithms for complex textured fabrics

Wu Zhihua Zhong Ming'en Tan Jiawei Xu Pingping Zhao Yuting

(School of Mechanical and Automotive Engineering, Xiamen University of Technology, Xiamen 361024, China)

Abstract: Aiming at the technical difficulties in the quality inspection process of the textile industry for the defect detection of complexly textured fabrics, an image detection model based on a deep convolutional neural network is proposed. Firstly, the YOLOv7-tiny model was selected as the reference frame of the algorithm, and then the optimization was carried out, including using the SimAM module to reconstruct the feature fusion layer so as to improve the model's ability to extract local features of defects and suppress background features. SIOU was used to optimize the coordinate positioning loss function to speed up the regression efficiency of bounding boxes. The FReLU activation function is introduced to enhance the utilization of spatial information in the nonlinear activation layer and improve the spatial sensitivity of the activation function. The experimental results show that the accuracy and recall ratio of this model are better than those of other existing algorithms in the detection tasks of five typical defects for complex texture fabrics. The mAP reaches the maximum value of 80.5%, the size of the model is only 9.2 M, and the detection of a single frame image on the PC is only 21.13 ms.

Keywords: complexly textured fabrics; defect detecting; YOLOv7-tiny; SimAM; SIOU; FReLU

0 引言

在布匹的自动化生产环节中,对布匹表面进行瑕疵检测是质检环节中的重要一环,而质量检测环节仍大量依赖人工。在布匹的生产过程中,断经、断纱、毛球、破洞和污渍是生产线上 5 种典型的瑕疵,严重的瑕疵会影响布匹产品的质量和美观。布匹瑕疵的人工视检方法易受检验人员经验、情绪以及视觉疲劳等因素的影响,长时间在高光下观察布匹表面寻找瑕疵,易造成漏检、错检,导致质检效率低下、质检质量不一且成本居高不下,因此,提出一种快速高精度

的布匹瑕疵检测方案,对解决布匹产业在工业自动化场景下的瓶颈问题具有重要意义。

早期机器视觉布匹瑕疵检测的方法主要是依赖数学建模、频谱分析等。其中,数学建模的计算量较大,频谱分析方法比较依赖滤波器组的选择。这些传统视觉检测方法都需要人工设计的特征描述子提取特征,常用的如 HOG 算子(histogram of oriented gradient, HOG)^[1]、Harr-like 算子(Harr-like features, Harr-like)^[2],面料不同,图像的提取特征也是不尽相同,导致算法的鲁棒性不高,模型不易迁移使用。在面对具有复杂背景环境、布匹瑕疵大小占用像素

面积多变时,研发出一种更具一般性、并且低训练成本的检测方法符合布匹工业生产的需求。

由于泛化能力强,检测准确度高等特点,卷积神经网络已经成为布匹瑕疵检测领域的研究热点,并得到广泛的应用。例如,孟志青等^[3]针对复杂花色布匹的瑕疵定位与分类难的问题,在卷积神经网络的基础上提出了一种基于级联的复杂花色布匹瑕疵检测算法,对布匹瑕疵进行逐级的回归定位和分类。苏茂锦等^[4]针对布匹瑕疵尺寸变化差异明显,背景和前景不易区分和传统算法效率不高等问题,提出了一种与 SENet 模型(squeeze-and-excitation networks, SENet)结合的改进 YOLOv3 布匹瑕疵检测方法,并通过引入深度可分离卷积,使模型更具轻量化,模型改进后达到实时性的要求。张振宇^[5]针对布匹的小瑕疵和尺度大的问题,引入注意力残差网络、构建特征金字塔,提出了基于 Faster R-CNN 的布匹瑕疵检测算法。许玉格等^[6]利用特征金字塔和残差层特征融合方式对缺陷进行定位,引入加权的 Multi Focal Loss 分类损失函数,减少数据长尾分布的影响,提出了改进的 ResNet50+布匹纹理缺陷检测算法,有效降低了瑕疵检测的误检率和漏检率。俞文静等^[7]提出一种基于图像增强的卷积神经网络算法,通过图像预处理、图像增强和边缘检测算法作用后,突出布匹的纹理特征和瑕疵区域,解决布匹瑕疵检测的低精度问题。文献[8]中对 SSD 模型进行了先验框聚类方法和卷积层优化的方法,用于普通布料缺陷的检测。安静等^[9]优化了一种 Cascade-RCNN 素色布匹瑕疵检测算法,有效改善了素色布匹瑕疵检测准确率低和定位精度低的缺陷。以上所有的改进方案统计后的平均检测精度在 41%~65%之间,普遍存在检测精度较低的问题,没有注重对网络检测速度的提升,对工业实际应用需求仍带来不可抗拒的挑战。2022 年,文献[10]中提出了 YOLOv7-tiny 算法,该模型基于单阶段检测算法改进的方案,在原有神经网络的基础上,既保留了检测精度,又缩短了检测时间,为工业瑕疵检测任务提供了更好的解决方案。

基于深度学习的瑕疵检测方案层出不穷,但是实际应用到工业环境中还有许多问题需要解决。首先,在布匹瑕疵自动化检测中是集瑕疵定位、瑕疵特征提取和瑕疵分类多任务的布匹工艺质检过程,检测算法需要至少实现 3 个方面功能,包括:1)判断布匹图像有无瑕疵;2)对判断有瑕疵的图像进行瑕疵定位;3)对定位的瑕疵进行分类。多任务协同的实现需要端到端的高效检测模型做支撑。其次,布匹背景多样、纹理复杂、瑕疵特征相似和瑕疵大小差异较大等客观条件因素都会让检测难度加大。而为了降低检测难度,通常可以采用图像分割的方案,以获得更具细粒度的瑕疵区域,然后再进行检测。但这会使得后期工作量加大,影响检测效率^[6]。以上问题使模型的落地部署困难,导致算法难以真正获得应用。因此,构建轻量化的检测模型并根据实际场景进行针对性优化将有助于解决上述难题。需

要指出的是,本文布匹瑕疵检测任务中数据集主要存在的问题有如下几点:部分类别瑕疵出现的概率很低,例如“毛球”和“破洞”,导致样本的采集不够均衡,进而对模型训练造成一定的挑战;在图像分辨率较大的情况,瑕疵的尺寸大小不一。选择一种高检测精度的网络模型作为参考并在此基础上进一步改进优化是解决这些问题的可探索路径。为合理的选择基线网络,在本文的数据集前提下,以现有各类主流轻量化模型为基础开展了相关的基线网络性能对比测试实验,发现 YOLOv7-tiny 模型在模型参数最少、最具轻量化的优势情况下,mAP 达到最大值 67.6%。

为此,本文将以 YOLOv7-tiny 为参考网络模型,并在此基础上进行优化改进,提出一种布匹表面瑕疵检测方案。主要方法有:

- 1)引入 SimAM 注意力机制^[11],优化特征融合结构,提升网络对瑕疵特征的提取,抑制背景特征;
- 2)优化损失函数,将 CIoU 损失函数^[12]替换成 SIoU 损失函数^[13],以加快目标框回归,提升检测精度;
- 3)优化激活函数,引入 FReLU 激活函数^[14],以解决在具有多尺度变化的布匹瑕疵检测任务中消除激活函数空间不敏感的问题。

1 本文方法

1.1 YOLOv7-tiny 目标检测框架

YOLOv7-tiny 源自 YOLOv7 的轻量版,是基于 Anchor-base 的单阶段目标检测算法,网络主要由特征提取网络、特征融合网络、检测头 3 个部分组成。训练图像经数据增强、锚框重新聚类预处理后,依次经过训练迭代提取特征。另外,YOLOv7-tiny 采用多尺度进行预测,利用 8 倍、16 倍和 32 倍下采样的特征图进行特征融合,类似于 FPN 特征金字塔结构,最后 3 个检测头分别输出预测结果。

本文在 YOLOv7-tiny 的基础上进行了 3 方面的改进措施,包括嵌入 SimAM 注意力模块;优化 SIoU 损失函数和引入 FReLU 激活函数。如图 1 所示,为优化后的布匹瑕疵检测模型结构图,可以看到改进的地点被点线方框标记,具体的为在上采样模块后和 Concat 拼接前的中间嵌入的两个 SimAM 模块、将 SiLU 激活函数替换为 FReLU 激活函数,而将 SIoU 损失函数替换 CIoU 损失函数的改进步骤在结构图中无法展示,因此不再赘述。

1.2 优化特征融合结构层

本文中的布匹瑕疵尺度差异较大,背景与目标颜色相近,这些问题直接影响关键语义特征的提取,造成漏检的发生。为了解决上述问题,改善算法对小尺度瑕疵的检测能力,本文引入注意力机制提升网络对瑕疵区域特征的提取,抑制背景特征。常用的 SE 注意力机制(squeeze-and-excitation, SE)^[15]、CBAM 注意力机制(convolutional block attention module, CBAM)^[16]和 CA 注意力机制(coordinate

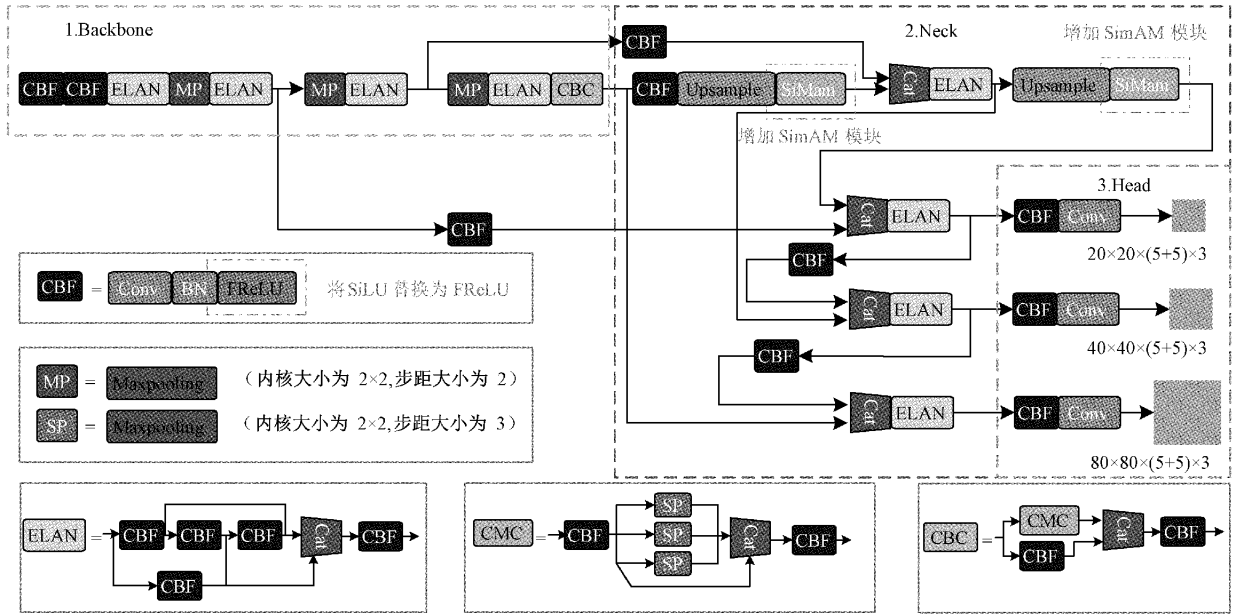


图 1 改进的 YOLOv7-tiny 模型结构

attention, CA)^[17]在进行权值分配时往往会缺失部分必要特征,例如布匹瑕疵的边缘信息、纹理信息和颜色特征等。SimAM 模拟人脑视觉信号处理过程,使通道和空间注意力协同作用,为特征图推导出三维注意力权值,对每个神经元分配唯一权重,该过程的参数配置和计算原理如下:

$$e_m^* = \frac{4(\hat{\beta}^2 + \lambda)}{(m - \hat{\alpha})^2 + 2\hat{\beta}^2 + 2\lambda} \quad (1)$$

$$\tilde{\chi} = \text{sigmoid}\left(\frac{1}{E}\right) \odot \chi \quad (2)$$

式中: m 是目标神经元在单一通道中的输入特征, $\hat{\alpha}$ 和 $\hat{\beta}^2$ 分别为在该通道内所有神经元的均值和方差,超参数 λ 设置为 0.001, e_m^* 为单个神经元 m 的最小能量值,该值越低,神经元 m 与周围神经元区别越大,重要性越高, χ 为输入特征, \odot 为对应位置相乘运算符, $\tilde{\chi}$ 为输出特征。

本文在 YOLOv7-tiny 的 Head 特征融合层上采样操作后分别嵌入两个 SimAM 注意力机制,如图 1 所示。该方法不仅能够较大程度的提升网络对布匹瑕疵重要局部区域的关注度,给检测性能带来实质性的提升,而且带来的计算开销可以忽略不计,不影响模型的检测效率。

1.3 优化损失函数

YOLOv7-tiny 使用 CIoU 作为边界框回归损失函数,用以评判预测边界框(predicted bounding boxes, PB)和真实边界框(ground truth bounding boxes, GT)的距离。CIoU 损失函数的优势是引入重叠面积、中心点距离、纵横比等几何因素。CIoU 损失函数的问题在于未考虑 GT 与 PB 之间的方向,导致在实际训练中收敛速度较慢,并且预测的边界框精度较低。对此,SIoU 针对这些问题,同时考虑了 PB 和 GT 的角度、距离和形状,如式(3)所示。

$$SIoU = IoU - \frac{\Delta + \Omega}{2} \quad (3)$$

式中: Δ 表示距离损失, Ω 表示形状损失,二者计算如下:

$$\Delta = \sum_{t=x,y} (1 - e^{-\rho^t}) = 2 - e^{-\rho^x} - e^{-\rho^y} \quad (4)$$

$$\Omega = \sum_{t=w,h} (1 - e^{-\omega^t})^\rho \quad (5)$$

其中, $\rho^x = \left(\frac{b_{cx}^{gt} - b_{cx}}{d_w}\right)^2$, $\rho^y = \left(\frac{b_{cy}^{gt} - b_{cy}}{d_h}\right)^2$, $\epsilon = 2 - \Delta$, 这里 (d_w, d_h) 为 PB 和 GT 最小外接矩形的宽度和高度,当中 Δ 表示为角度损失, $\Delta = 1 - 2 \times \sin^2(\arcsin(x) - \frac{\pi}{4})$, 其中 $x = \frac{c_h}{\gamma}$, $\gamma = \sqrt{(b_{cx}^{gt} - b_{cx})^2 + (b_{cy}^{gt} - b_{cy})^2}$, $c_h = \max(b_{cy}^{gt}, b_{cy}) - \min(b_{cy}^{gt}, b_{cy})$, 这里 $(b_{cx}^{gt}, b_{cy}^{gt})$ 为 GT 的中心坐标, (b_{cx}, b_{cy}) 为 PB 的中心坐标,如图 2 所示,可以注意到当 α 为 $\frac{\pi}{2}$ 或 0 时,角度损失 Δ 为 0,在训练过程中若 $\alpha < \frac{\pi}{4}$, 则最小化 α , 否则最小化 β 。




图 2 角度成本对损失函数贡献的计算方案

补充的是,对于式(3)中的形状损失,计算方法为:

$$\omega_w = \frac{|\omega - \omega^{gt}|}{\max(\omega, \omega^{gt})}, \omega_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})},$$

当中 (ω, h) 和 (ω^{gt}, h^{gt}) 分别为 PB 和 GT 的宽度和高度, θ 控制对形状损失的关注程度, 由于布匹瑕疵尺寸形状多变, 故使用遗传算法后, θ 设定为 6。

相比于原始 YOLOv7-tiny 中使用的 CIoU 损失函数, SIOU 损失函数在损失项中加入 PB、GT 的角度变化和形状差异的惩罚项, 使模型在训练中能更合理的计算边界框回归损失的大小, 保证更快的收敛, 从而得到更高的回归定位精度, 本文将 SIOU 损失函数定义为网络的损失函数, 在尽可能减少模型参数数量的前提下, 以达到优化模型的检测性能的目的。

1.4 优化激活函数

在卷积神经网络中主要由卷积层和非线性激活层两部分构成。在卷积层中, 自适应地捕获空间相关性是一个挑战, 因此, 研究者已经提出了许多更复杂和有效的卷积在图像中自适应地捕获局部上下文信息, 这在密集的预测任务上取得了不错的性能提升。但随着卷积的复杂性也带来了一个问题: 在复杂视觉布匹瑕疵检测任务中, 单纯依赖卷积难以达到更高的检测精度。为次, 通常需在卷积层线性捕捉空间依赖性后, 再由激活层进行非线性变换。目前最广泛使用的激活仍然是 ReLU 激活函数, 本文采用 FReLU 激活函数以解决在具有多尺度变化的布匹瑕疵检测任务中, 消除激活函数空间不敏感的问题。具体来说, 如式(6)所示。

$$\begin{cases} f(x_{c,i,j}) = \max(x_{c,i,j}, \mathbb{N}(x_{c,i,j})) \\ \mathbb{N}(x_{c,i,j}) = x_{c,i,j}^{\omega} \cdot p_c^{\omega} \end{cases} \quad (6)$$

式中: $\mathbb{N}(\cdot)$ 为定义的漏斗式条件, $x_{c,i,j}^{\omega}$ 表示第 c 个通道上, 以二维位置 (i, j) 为中心的窗口。FReLU 将 ReLU 修改为一个依赖于空间上下文的二维漏斗状条件, 视觉条件有助于提取物体的精细空间布局, 使得网络可以在每个像素的非线性激活中产生空间条件。该网络同时进行非线性变换并产生空间依赖性, 而通常的做法是在卷积层创建空间依赖性, 并分别进行非线性变换。在通常做法下, 模型的非线性变化过程中不明确地依赖于空间条件, 而在漏斗条件的情况下, 它们依赖于空间条件。

因此, 逐像素条件使得网络具有像素化的建模能力, 函数 $\max(\cdot)$ 给每个像素提供了一个看空间背景或不看空间背景的选择。具体地, 考虑一个有 n 个 FReLU 层的网络 $\{F_1, F_2, \dots, F_n\}$, 每个 FReLU 层 F_i 有 $k \times k$ 个参数窗口。为了简洁起见, 只分析 FReLU 层, 而不考虑卷积层。由于最大选择在 1×1 和 $k \times k$ 之间, 所以 F_1 之后的每个像素都有一个激活函数集 $\{1, 1+r\}$ ($r = k-1$)。在 F_n 层之后, 该集合变成了 $\{1, 1+r, 1+2r, \dots, 1+nr\}$, 这给每个像素提供了更多的选择, 如果 n 足够大, 可以让网络建模中的空间形状近似于任何布局, 弥补了模型的非线性表达能力不足的缺陷。

2 混色布匹数据集

本实验数据集采用 2021 无锡雪浪制造 AI 挑战赛提供的布匹瑕疵检测数据集, 数据集使用工业 CCD 相机获取。对布匹瑕疵检测数据集进行统计分析, 共包含 1 601 张尺寸大小为 $800 \text{ pixels} \times 600 \text{ pixels}$ 的布匹图像, 布匹类别涵盖格子布、条纹布和素色布等类型, 具有颜色丰富、纹理复杂的特点。标注的瑕疵类别共包含断经 (broken warp)、断纱 (broken yarn)、毛球 (hairball)、破洞 (hole) 和污渍 (stains) 五类, 分别占标注总数的 13%、42%、5%、9% 和 31%。

对于 Anchor-base 的目标检测模型, 锚框的合理设置尤为重要, 为适应图像的训练, 采用 K-means 聚类算法对标签重新聚类。由图 3 聚类结果可知, 标注标签较多地分布在聚类结果的左下角、左上角和右下角处, 表明数据集的目标尺度变化较大, 大小不一, 且小目标居多。最终统计聚类的 Anchor-size 分别为 (20, 19)、(35, 34)、(118, 20)、(65, 65)、(258, 39)、(37, 315)、(131, 113)、(570, 28) 和 (573, 51)。所有训练中按照 8:1:1 的比例将数据集划分为训练集、验证集和测试集。

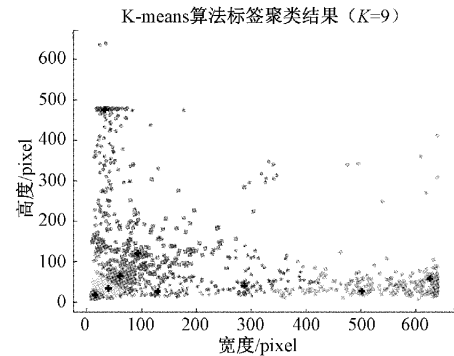


图 3 数据标签 K-means 算法聚类结果

3 实验结果与分析

实验在配备 NVIDIA RTX 3080 的 Win10 平台上完成, 并利用 CUDA11.1.0 和 Cudnn8.0.5 加速器进行硬件加速。部署的 PC 端边缘设备处理器为 AMD Ryzen 7 5800H@3.20 GHz。

3.1 算法评估

考虑到生产中的实际应用, 根据平均精度 (average precision, AP)、平均精度均值 (mean average precision, mAP)、每秒检测帧数 (frames per second, FPS) 3 项指标对算法进行评估, 进而比较及验证算法性能。AP 为 P-R (precision-recall) 曲线的积分面积, 其计算方法描述为:

$$AP = \int_0^1 P(r) dr \quad (7)$$

式中: 查准率 (precision, P) 和查全率 (recall, R) 分别定义为 $P = TP / (TP + FP)$ 和 $R = TP / (TP + FN)$, 其中 TP 为

真阳性样本数目, FP 为假阳性样本数目, FN 为假阴性样本数目。 mAP 为各个类别的 AP 均值 (IoU 阈值取 0.5), 计算公式为:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP(k) \quad (8)$$

式中: N 代表待检测的布匹瑕疵总类别数目, 取值为 5。FPS 则为每秒瑕疵检测的图像帧数。

3.2 优化特征融合结构

为了比较不同注意力机制对模型检测效果的影响, 在 YOLOv7-tiny 的基础上进行了相关的对比实验, 如表 1 所示。

可以看出, 引入 SimAM 改进模型的 mAP 提升最多, 检测精度达到 74.6%, 而额外增加的参数量最低, 仅为

表 1 不同注意力机制对网络性能影响的实验结果

所用方法	# Param/M	M-adds/M	mAP50/%
Base(YOLOv7-tiny)	6.54	—	67.6
+SE	6.73	0.19	73.9
+CBAM	6.71	0.17	73.5
+CA	6.68	0.14	74.2
+SimAM	6.67	0.13	74.6

0.13 M。采用 Grad-CAM 热力图进行分析可知, 相比于图 4(b) 中的原 YOLOv7-tiny 算法, 图 4(c) 引入 SimAM 后的算法提取瑕疵特征的面积更大 (如实线框所示), 提取的背景干扰特征的面积更小 (如虚线框所示), 说明优化模型瑕疵检测性能更佳。

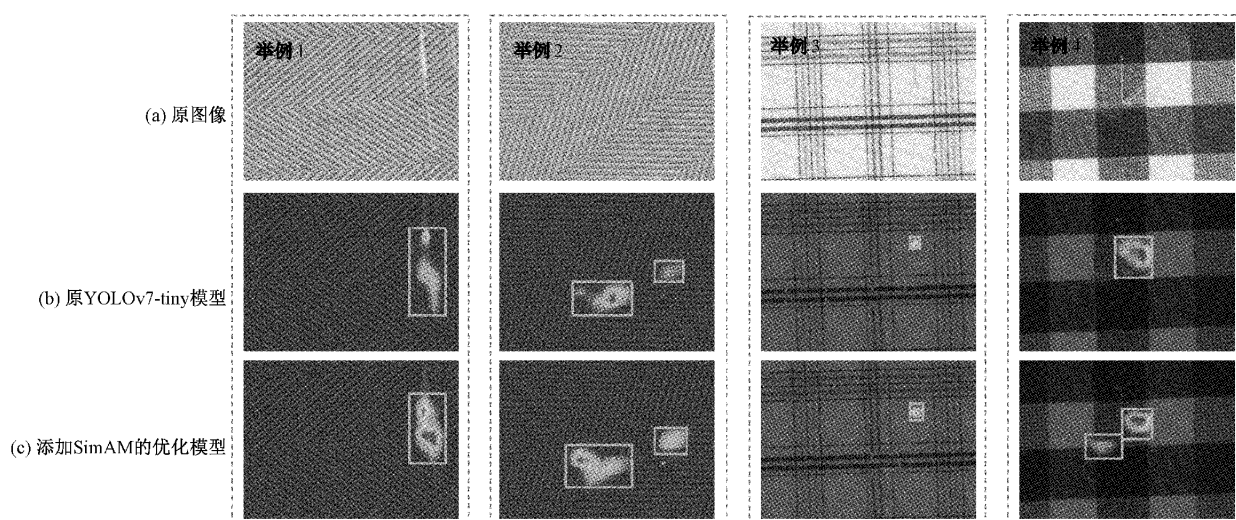


图 4 有无添加 SimAM 模型输出层热力图对比结果

3.3 消融实验

为了量化分析本文提出的各个改进环节对布匹瑕疵检测算法的性能影响, 在相同实验条件下开展了消融实验, 结果如表 2 所示。

表 2 消融实验结果

所用方法	P/ %	R/ %	mAP50/ %	FPS
Base (YOLOv7-tiny)	68.5	66.9	67.6	75.8
+SimAM	75.4	73.5	74.6	74.5
+Siou	78.3	76.8	77.1	74.2
+FReLU	81.6	77.5	80.5	72.3

从表 2 中可以看出: 1) 引入 SimAM 注意力机制优化特征融合结构层后, 模型的查准率、查全率和 mAP 分别达到 75.4%、73.5% 和 74.6%, 与原始模型的 68.5%、66.9% 和 67.6% 相比分别提升了 6.9%、6.6% 和 7.0%, 表明 SimAM 能够促进局部瑕疵特征的提取; 2) 采用 Siou

损失能够使目标定位更为准确, 有利于减少漏检和误检的情况发生, 因此使得检测算法的查准率、查全率和 mAP 分别提升了 2.9%、3.3% 和 2.5%; 3) 改用 FReLU 激活函数后, 能够使模型的查准率、查全率和 mAP 再次分别提升 3.3%、0.7% 和 3.4%, 分别达到 81.6%、77.5% 和 80.5%。这些实验数据表明, 本文对原始 YOLOv7-tiny 模型的改进策略是有效的。

3.4 对比实验


为了进一步探明本文所设计的算法与其他主流目标检测算法在布匹瑕疵检测任务上的性能差异, 在本文布匹瑕疵检测数据集上进行了对比实验。训练和推理的硬件条件为单张 NVIDIA RTX 3080 显卡, 各模型训练 300 个 epoch, 超参数设置一致。最终的实验结果如表 3 所示。

可以看出本文所给出的算法取得了最高 mAP 值 80.5%, 相比于原始 YOLOv7-tiny 算法的 67.6% 高出 12.9%, 且检测速度仅下降了 3.5 fps 仍然达到 72.3 fps, 能够较好的满足工业检测要求。此外, 模型大小仅为 9.2 MB, 有利于边缘设备的部署。


表 3 对比实验结果

目标检测算法	mAP/%	FPS	模型尺寸/M
SSD ^[18]	63.7	70.8	93.1
Faster R-CNN ^[19]	61.9	15.2	515.2
YOLOv3	65.0	46.4	220.7
YOLOv4 ^[20]	65.3	46.6	231.0
YOLOv5s ^[21]	66.0	57.7	25.7
DETR	66.2	40.0	39.6
YOLOx-s ^[22]	66.4	54.0	33.9
YOLOv7-tiny	67.6	75.8	6.5
本文	80.5	72.3	9.2

图 5 列举了本文算法模型针对几类检测难度较大的布匹瑕疵的检测效果,其中图 5(a)是单一布匹瑕疵的情况,图 5(b)为包含多个或多类布匹瑕疵的情况。可以看出,针对背景多变、纹理复杂布匹中的大尺寸“断经”、“断纱”、“破洞”和小尺寸“毛球”、“污渍”等瑕疵,本文所提出的检测算法都拥有良好的检测性能。



(a) 单一瑕疵的情况



(b) 多个或多类瑕疵的情况

图 5 提出算法的布匹瑕疵检测结果举例

4 结 论

在现有布匹瑕疵质检任务中,普遍存在着瑕疵区域定位精度不高、瑕疵类型分类不准、算法模型太大而不易部署等问题。针对这些问题,本文采用深度学习方法,在 YOLOv7-tiny 基础上进行注意力机制的引入、目标框回归方式的替换和优化激活函数等 3 个方面的改进,实验结果

表明,本文提出的算法模型针对文中的 5 类典型布匹瑕疵实现了良好的检测效果。利用 DNN 方式将模型部署至 PC 端后,采用 CUDA 加速器,最终检测精度仍达到 80.5%,单张图像耗时仅 21.13 ms。但是从实验检测结果分析来看,模型容易对纯素色布匹的检测造成漏检和误检,这是由于纯色布匹颜色单一,背景干扰相对较强,以至于瑕疵特征相对无法显现。在下一步工作中将重点分析

可视化后的特征提取热力图,结合权重加重的思想,降低模型针对背景特征提取的权重影响因子,并针对性提升瑕疵特征提取的模型参数权重,使模型达到加强布匹瑕疵特征提取的能力,从而提升模型的布匹瑕疵检测精度。同时,本文依然需要依赖大量具有多样性样本,设计基于小样本的布匹瑕疵检测算法是下一步的研究重点。

参考文献

- [1] PANG Y, YUAN Y, LI X, et al. Efficient HOG human detection[J]. *Signal Processing*, 2011, 91(4): 773-781.
- [2] ZHANG C, LIU J, LIANG C, et al. Image classification using Harr-like transformation of local features with coding residuals[J]. *Signal Processing*, 2013, 93(8): 2111-2118.
- [3] 孟志青,邱健数.基于级联卷积神经网络的复杂花色布匹瑕疵检测算法[J].*模式识别与人工智能*, 2020, 33(12): 1135-1144.
- [4] 苏茂锦,曹民.基于改进YOLOv3算法的布匹瑕疵检测研究[J].*智能计算机与应用*, 2022, 12(6): 131-136.
- [5] 张振宇.基于Faster R-CNN的布匹瑕疵检测算法研究[D].温州:温州大学, 2020.
- [6] 许玉格,钟铭,吴宗泽,等.基于深度学习的纹理布匹瑕疵检测方法[J].*自动化学报*, 2023, 49(4): 857-871.
- [7] 俞文静,刘航,李梓瑞,等.基于图像增强和CNN的布匹瑕疵检测算法[J].*计算机技术与发展*, 2021, 31(5): 90-95.
- [8] XIE H, ZHANG Y, WU Z. An improved fabric defect detection method based on SSD[J]. *AATCC Journal of Research*, 2021, 8(1_suppl): 181-190.
- [9] 安静,唐英杰,马鑫然.基于深度神经网络的素色布匹瑕疵检测算法研究[J].*包装工程*, 2021, 42(3): 246-251.
- [10] 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 [J]. *ArXiv Preprint*, 2022, ArXiv: 2207. 02696.
- [11] YANG L, ZHANG R Y, LI L, et al. Simam: A simple, parameter-free attention module for convolutional neural networks [C]. *International Conference on Machine Learning*. South Korea: PMLR, 2021: 11863-11874.
- [12] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[C]. *Proceedings of the AAAI Conference on Artificial Intelligence*. USA: AAAI, 2020, 34(7): 12993-13000.
- [13] GEVORGYAN Z. SIOU Loss: More powerful learning for bounding box regression [J]. *ArXiv Preprint*, 2022, ArXiv: 2205. 12740.
- [14] MA N, ZHANG X, SUN J. Funnel activation for visual recognition [C]. *European Conference on Computer Vision*. Springer, Cham, UK: ECVA, 2020: 351-368.
- [15] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. USA: CVPR, 2018: 7132-7141.
- [16] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. *Proceedings of the European Conference on Computer Vision (ECCV)*. Germany: ECVA, 2018: 3-19.
- [17] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. China: CVPR, 2021: 13713-13722.
- [18] 苏泽斌,武静威,李鹏飞.改进的Faster R-CNN算法在数码印花织物缺陷检测中的应用[J].*西安工程大学学报*, 2022, 36(4): 1-9.
- [19] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. *European Conference on Computer Vision*. Springer, Cham, Netherlands: ECVA, 2016: 21-37.
- [20] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. *ArXiv Preprint*, 2020, ArXiv: 2004. 10934.
- [21] 肖黎俊,潘睿志,李超,等.基于改进YOLOv5s绝缘子缺陷检测技术研究[J].*电子测量技术*, 2022, 45(24): 137-144.
- [22] 丁田,陈向阳,周强,等.基于改进YOLOX的安全帽佩戴实时检测[J].*电子测量技术*, 2022, 45(17): 72-78.

作者简介

吴志华,硕士研究生,主要研究方向为机器视觉、深度学习。

E-mail: 2021011035@s.xmut.edu.cn

钟铭恩(通信作者),教授,主要研究方向为机器视觉与人工智能、智能汽车等。

E-mail: zhongmingen@xmut.edu.cn