

文章编号 1672-6634(2022)06-0001-10

DOI 10.19728/j.issn1672-6634.2022020004

融合形变卷积和自注意力的素色布匹瑕疵检测

李 辉,吕祥聪,徐凌伟,申贝贝

(青岛科技大学 信息科学技术学院,山东 青岛 266061)

摘 要 在布匹生产过程中,会产生不同种类的瑕疵,准确的瑕疵检测对于提高纺织工业的生产效率具有重要意义。然而,布匹瑕疵仍存在小目标、极端纵横比、数量不均衡等问题,导致布匹瑕疵检测识别率低、错检漏检频发。因此提出了融合形变卷积和自注意力的素色布匹检测方法。首先,提出了融合形变卷积的多尺度特征提取,缓解模型对不规则瑕疵特征提取能力不足的问题。其次,构建多通道注意力聚合网络,生成新的具有强语义和精确位置信息的瑕疵特征图,提高小目标瑕疵检测的准确率。最后,设计自适应边框生成器,指导生成更精确的瑕疵边界框,解决部分纵横比悬殊的瑕疵无法生成紧密包围框的问题。在标准数据集上的实验结果表明,提出的方法有效提升了布匹瑕疵检测的准确率和效率。

关键词 布匹瑕疵检测;目标检测;形变卷积;自注意力

中图分类号 TP391

文献标识码 A

开放科学(资源服务)标识码(OSID)



Plain Fabric Defect Detection Using Deformation Convolution and Self-Attention

LI Hui, LÜ Xiangcong, XU Lingwei, SHEN Beibei

(School of Information Science and Technology, Qingdao University of Science and Technology, Qingdao 266000, China)

Abstract In the process of fabric production, different kinds of defects will occur, and accurate defect detection is of great significance to improve the production efficiency of the textile industry. However, there are still problems such as small targets, extreme aspect ratios, and unbalanced numbers of cloth defects, which lead to a low recognition rate of cloth defect detection and frequent false detections and missed detections. Therefore, a plain cloth detection method integrating deformed convolution and self-attention is proposed. First, a multi-scale feature extraction fused with deformation convolution is proposed to alleviate the problem of the model's insufficient ability to extract irregular flaw features. Secondly, a multi-channel attention aggregation network is constructed to generate a new defect feature map with strong semantics and precise location information to improve the accuracy of small target defect detection. Finally, an adaptive bounding box generator is designed to guide the generation of more accurate defect bounding boxes to solve the problem that some defects with large aspect ratios cannot generate tight bounding boxes. The experimental results on standard datasets show that the proposed method effectively improves the accuracy and efficiency of fabric defect detection.

Key words fabric defect detection; object detection; deformed convolution; self-attention

收稿日期:2022-02-04

基金项目:国家自然科学基金项目(61702295)资助

通讯作者:徐凌伟,男,汉族,博士,副教授,研究方向:智能信息与通信, E-mail:gaomilaojia2009@163.com。

0 引言

布匹瑕疵的检测是纺织业急需解决的一大难题,在生产布匹的过程中,一旦出现缺陷,没能及时发现,通常会大批量的生产,将会造成无法弥补的损失,一旦流入市场,将直接影响企业的信誉,且目前的布匹瑕疵检测方法,依旧大多数采用人工结合放大镜进行质检,但由于无法克服自身的生理因素,容易出现大量漏检和误检。因此,布匹瑕疵检测对于纺织业生产具有重要的研究价值和研究意义,通过专门的布匹检测方法应用到视觉仪器上,用机器代替人工质检,可以有效提高布匹瑕疵的检测率,产出更高质量的布匹。当前布匹检测方法主要分为两大类,传统的检测方法和基于深度学习的布匹检测方法,传统的布匹检测方法除了人工检测,还有利用波谱检测^[1]、数学统计^[2,3]、图像差分^[4,5]以及图像纹理^[6]等方法进行布匹瑕疵特征提取,上述传统方法可以实现某种布匹瑕疵的检测,但是往往只针对一种瑕疵设计,鲁棒性和迁移性较差,检测能力有限,且无法真正应用到市场中,通常只在仿真中实现。目前采用基于深度学习的检测方法,是当今目标检测研究的主要方向,采用深度学习可以更加有效的学习到目标特征,对目标的检测率更高,且精度远高于传统的检测方法,可以最大化的节省人力,提高生产的效率^[7,8]。基于深度学习^[9,10]的检测方法主要分两阶段^[11,12]和单阶段^[13,16]检测方法,Qin等^[17]提出了多分支残差网络的布匹缺陷检测研究,该方法在原有残差模块的基础上,增加了一个新的卷积分支,随着网络层数动态调整感受野的大小,然后在下采样阶段替换了残差模块,提出了一种新的多分支残差骨干网。Wei等^[18]首先利用瑕疵图像的特征,减少了Faster RCNN中的锚点数量,然后在候选区域阶段生成前景锚点和边界框回归,最后反馈到感兴趣区域进行分类。Yan等^[19]提出了改进的深度残差网络进行素色布匹瑕疵特征提取,再通过设计特征金字塔和候选区域网络实现对瑕疵点的分类与检测。Liu等^[15]提出了基于SSD算法的自适应素色布匹瑕疵检测方法,采用特征金字塔的方式加强了特征图之间的传递,缓解了梯度消失问题,但该方法对小目标瑕疵检测准确率有待提高。Zhao等^[20]针对SSD对小瑕疵目标检测效果不理想,提出了将多尺度特征融合用于布匹瑕疵小目标的检测,该方法在多层特征提取时引入残差模块,通过多尺度特征融合提高了模型对小瑕疵目标的检测率。Jing等^[21]提出了改进的YOLOv3模型用于素色布匹瑕疵检测,该方法首先通过结合布匹瑕疵尺寸和k-means算法对目标瑕疵进行维度聚类,然后将底层特征与高层信息相结合,在不同大小的特征图上加入YOLO检测层,虽然方法检测速度快,但是对于瑕疵检测效果精度较差。

当前布匹缺陷检测任务的难点主要有以下几个方面:(1)小目标问题,布匹中的一些瑕疵特征极其小且数目繁多,难以用肉眼进行判别。(2)极端长宽比,布匹中的各类瑕疵形状各不相同,尺寸跨度极大。(3)样本不均衡,样本不均衡是指部分疵点拥有大量的训练样本,而另一部分瑕疵点则只有少数的样本;已有的目标检测算法都难以解决小目标瑕疵、尺度变化大、样本不均衡等布匹疵点的漏检和瑕疵准确定位低的问题,因此本文提出了一种融合形变卷积和自注意力的素色布匹瑕疵检测方法。该方法(1)针对原始的ResNet^[11]中残差模块中由于目标几何畸变而导致特征图对瑕疵特征表达能力不足的问题,提出了融合形变卷积(DCN)^[22]的多尺度特征提取,从而提升模型对不规则瑕疵特征的表达能力。(2)针对数据集中小目标瑕疵居多的问题,提出了双通道特征融合模块,通过引入自注意力机制^[23,24]自适应地融合深层的语义信息与浅层的结构信息,提高小目标瑕疵的准确率。(3)针对布匹瑕疵中尺度变化悬殊的疵点,在候选区域(RPN)阶段设计自适应边界框生成器,引导初始锚定框设计,适应极端长宽比的目标,利于后续检测框回归,使检测效果进一步优化。

1 提出的布匹瑕疵检测方法

本文提出的布匹瑕疵检测方法主要分为三部分:(1)设计融合形变卷积的多尺度特征提取网络,从而更好地处理布匹图像中的目标形变问题,有效提取瑕疵特征;(2)由于布匹瑕疵中小目标占比较多,在骨干网络后接入多通道注意力聚合网络,生成新的具有强语义和精确位置信息的特征图;(3)在RPN阶段,设计自适应锚框聚类生成器,获得更紧密的包围框,同时级联具有不同IOU阈值的检测网络逐级完成瑕疵的精确定位。




图 1 瑕疵检测网络框架图

1.1 融合形变卷积的多尺度特征提取

本文采用的特征提取骨干网络是残差网络 ResNet,主要有五个特征提取层,第一个特征提取层,包含卷积核、批处理以及最大池化层。其余四个特征提取层,分别用同样结构的残差模块组成,经过深度残差网络特征提取,输出五个特征表示层 C1 到 C5,针对布匹瑕疵呈现出的极端长宽比,常规卷积不能有效进行特征提取,因此本文在 C3 到 C5 特征提取层,通过融合形变卷积替换常规卷积对布匹瑕疵进行特征提取,整体网络提取过程如图 2 所示。




图 2 ResNet 引入 DCN 模块网络结构图

本文在骨干网络的最后三个阶段采用形变卷积替换普通卷积,通过学习中心点的偏移和权重,使采样点感受野可以根据目标特征进行自适应变化,以此来适应不同形状的瑕疵,缓解了传统卷积采样无法适应目标的几何形变问题,具体结构如表 1 所示,改进后的骨干网络更能适应布匹疵点的极端长宽比,有利于疵点的精确检测。

表 1 融合形变卷积的多尺度特征提取网络结构

Stage	Output	DCN	Resnet101
Conv1	1 223×500	×	7×7,64, stride 2 3×3 max pool, stride2
Con2_x	611×250	×	$\begin{pmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{pmatrix} \times 3$
Con3_x	305×125	✓	$\begin{pmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{pmatrix} \times 4$
Con4_x	152×62	✓	$\begin{pmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{pmatrix} \times 23$
Con5_x	76×31	✓	$\begin{pmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2\ 048 \end{pmatrix} \times 3$

1.2 多通道注意力聚合网络

常用特征聚合方式是通过将不同的特征图进行重新放大或者缩小到统一尺度,再进行简单的通道相加,将不同特征的通道信息进行融合,可以有效地提高特征图的语义信息,但该特征聚合方式仍有一定的不足,对于一些小目标的特征信息表现的不是很明显,容易丢失,因此,本文通过改进自注意力机制,提出多通道特征聚合网络模块(MCFA)。该注意力网络,可以融合特征图中目标的关键信息,增强目标的特征与位置信息,尤其是对于小目标瑕疵,可以有效地解决小目标瑕疵特征难提取问题,提高网络处理极端目标的检测能力,增强网络的鲁棒性。

1.2.1 特征通道注意力模块。采集到的布匹图像中,小目标的数量占比较大,在布匹瑕疵检测任务中,为了获取更多小瑕疵目标特征信息,本文提出了改进的特征通道注意力网络,该网络通过将其中一个全局最大池化层去掉,采用全局平均池化层,减少池化层造成小目标瑕疵信息的丢失;其次将另一个全局最大池化层改为全局未池化层,增强小瑕疵目标的特征信息,对每个特征通道建模,产生特征依赖关系,使得特征通道获取更多的权重。详细的网络结构如图3所示,首先将特征图 $F \in R^{H \times W \times C}$ 进行全局平均池化层 $F_{avg} \in R^{C \times 1 \times 1}$ 和全局未池化层 $F_{no} \in R^{C \times 1 \times 1}$,生成两个不同的特征通道层,再经过两个全连接层增加或减少通道数,将两个不同的特征层通道数变成一致,再结合激活函数 Relu,对特征层赋予不同的权重,再进行特征通道逐元素相乘聚合两个特征层的通道信息,最终得到特征通道注意力图 $F_{CA} \in R^{C \times 1 \times 1}$ 。




图3 通道注意力模块结构图

1.2.2 空间注意力模块。由于特征通道注意力网络只对目标特征进行了增强,但没有对目标位置信息进行建模,对于一些小瑕疵的位置信息,依然不能很好定位,出现一定的偏移。因此,在上述特征通道注意力网络的基础上,提出了空间通道注意力网络,通过在空间通道中,对瑕疵位置信息进行加权,空间选择性的聚合每个瑕疵的位置信息,实现更加精准的定位。空间通道注意力网络具体的过程如图4所示。




图4 空间注意力模块结构图

通过将特征通道注意力输出的特征图与低层的特征图作为空间通道注意力网络的输入端,首先将该两个特征图进行简单通道拼接,保留更多的低层特征信息,再进行批处理 BN 层,再通过 Relu 层的 1×1 的卷积生成两个特征图 $F1$ 和 $F2$ 。先对 $F1$ 重塑再转置,即得到矩阵 Q^T ,将 $F2$ 重塑为 M 矩阵,最后将 Q^T 与 M 矩阵进行相乘,再经过 Sigmoid 函数生成空间通道注意力矩阵,表达式如

$$K = Q^T M. \quad (1)$$

再将生成的空间通道注意力矩阵与特征通道注意力矩阵进行逐元素相加,生成多通道注意力特征图。表达式如

$$Z = S \oplus G. \quad (2)$$

1.3 自适应锚框聚类

在 Cascade RCNN 的候选区域建议网络(RPN)阶段,一般来说,会设置一些固定大小的先验框,如图 5(a)所示,纵横比通常为 0.5、1.0、2.0,这样网络就可以从真实框中学习先验框的偏差值。但是在布匹瑕疵检测样本图片中,由于布匹疵点的特殊性,经常存在任意形状和尺度大小不一的瑕疵点。如果通用先验框的尺寸设计的不合理,很容易使得真实瑕疵目标与相对应的 Anchor 存在过大过小的情况,导致最终模型拟合效果较差。为了使算法模型在训练过程中可以实现较理想的收敛效果,增大布匹瑕疵检测的准确率,本文改进基于 K-means 聚类算法,设计了自适应边框生成器。重新设计针对布匹瑕疵数据较为合适的 Anchor 尺寸,使得生成的候选框(Anchor box)和与之临近的真实框(Ground truth)有更大的交并比,如图 5(b)所示。这样设计不仅能够加快模型收敛速度,而且还能有效提高检测瑕疵的精度。




图5 Anchor 与 IOU

传统聚类方式使用欧式聚类作为度量标准进行聚类,这种方式对于布匹瑕疵数据集中存在的纵横比悬殊问题并不适用。为了适应布匹瑕疵数据集分布特点,本文采用一种新的度量方式 IOU 度量替换欧式距离度量,指导 Anchor 对锚框大小进行聚类。过程如式(3),其中 b 是标注的真实边界框, c 是聚类的中心点,

$$d(b, c) = 1 - \text{IOU}(b, c). \quad (3)$$

详细描述如:(1) 聚类使用的原始数据为训练集中的布匹瑕疵数据,其中包含的信息为样本集中真实瑕疵框坐标信息。(2) 对于每类瑕疵,随机选取 k 个初始聚类中心点,每一个聚类中心代表一类瑕疵集簇。(3) 对所有的真实标注框按公式(3)计算与 k 个瑕疵中心点的距离,并将各标注框归类给距离最近的聚类中心,形成 k 个簇。(4) 所有瑕疵集标注框分配完毕以后,对每个簇重新计算聚类中心点,计算公式为

$$\mu_i = \frac{1}{|C_i|} \sum_{x \in C_i} x. \quad (4)$$

(5) 重复(3)和(4),直到算法计算得到最优的锚定框,具体过程如算法 1 所示。

算法 1:自适应边框生成器算法

输入:每类待聚类瑕疵样本集真实边界框: $B = \{b_i, i \in \{1, 2, \dots, n\}\}$

初始 Anchor 大小: $A = \{a_j, j \in \{1, 2, \dots, m\}\}$

输出:最优初始锚定框 $A^* = \{a_{j^*}, j^* \in \{1, 2, \dots, m\}\}$

算法过程:

```

1   Repeat
2   令  $C_j = \emptyset, j \in \{1, 2, \dots, m\}$ 
3   for  $i = 1, 2, \dots, n$  do
4        $d_{ij} = 1 - \text{IOU}(b_i, a_j)$  //计算真实边界框和当前 Anchor 的距离
5        $\lambda_j = \arg\min_{j \in \{1, 2, \dots, m\}} d_{ij}$  //距离最近的 Anchor 确定的  $b_i$  簇标记
6        $c_{\lambda_j} = c_{\lambda_j} \cup \{b_i\}$  //将真实边界框  $b_i$  划入相应的簇
7   end for
8    $A^* = \emptyset$ 
9   for  $j = 1, 2, \dots, m$  do
10       $\mu_j = \frac{1}{|C_j|} \sum_{b_i \in c_j} b_i$  //计算新的 Anchor 大小
11       $A^* = A^* \cup \mu_j$  //将计算的 Anchor 大小添加到  $A^*$  中
12  end for
13  Until 达到最大迭代次数获得最优锚定框

```

2 实验结果

2.1 实验环境及数据集

实验环境:本文实验所有的环节在 Ubuntu18.04 系统上搭建,内存为 64 位,显卡为 NVIDIA GeForce RTX 3080Ti,代码的运行环境为 Python3.8,使用 Pytorch 作为本文的代码实验框架。为了排除其他相关变量对实验结果的影响,所有实验都是基于上述环境进行训练和测试的。

实施细节:实验数据集采用 COCO^[25]数据集的格式,模型使用的优化器类型为 Adam 优化器,其中初始学习率为 0.000 1,动量为 0.9,Batch Size 设置为 8,衰减系数为 0.001,训练步数为 20 000,为了加快收敛速度,使用了 COCO 的预训练权重,并设置了梯度裁剪来稳定训练过程,避免产生梯度爆炸或梯度消失。

数据集:实验采用的数据集来自天池布匹挑战大赛布匹瑕疵图像,素色布匹图片一共 9 596 张,其中包含正常图片 3 683 张和瑕疵图片 5 913 张,每张瑕疵图片中包含 1 种或多种瑕疵,图像分辨率为 $2\,446 \times 1\,000$,在实验中,对所有的瑕疵图像按照 8:2 划分训练集与测试集。样本集中包含纺织工业中常见的 20 类瑕疵类别,如破洞、污渍、三丝、结头、毛粒、松经、断经等,数据集样本瑕疵分布及数量如表 2 所示。

表 2 布匹瑕疵的分类与数量

瑕疵名称	数量	瑕疵名称	数量
破洞	312	吊经	160
水渍、油渍、污渍	401	粗维	915
三丝	1 055	纬缩	452
结头	1 996	浆斑	336
花板跳	134	整经结	473
百脚	161	星跳、跳花	302
毛粒	195	断氨纶	546
粗经	213	稀密档、色差档	361
松经	396	磨痕、修痕	470
断经	284	跳纱、云织	361




图 6 不同类别目标数统计




图 7 目标面积统计

表 2 真实的反映出数据集的瑕疵类别分布极不平衡的问题,其中,结头瑕疵点达到了 1 996,而白脚瑕疵点仅有 161,图 6 为数据集中不同类型瑕疵点的目标数统计,不同瑕疵点间数目差异巨大,种类分布严重不均,例如结头近 2 000 个样本,而花板跳只有 123 个样本,这容易产生过拟合,使训练出来的模型泛化能力较差,图 7 为不同面积目标的数量占比其中小目标占比较高约四分之一,这些都给布匹疵点的检测带来了困难。

为达到理想训练效果,在训练深度学习网络模型时,通常需要大量的瑕疵样本,因此本文采用数据增强的方式对原始的瑕疵样本进行数据扩充,为避免失真,对原始瑕疵样本集分别进行水平和垂直方向的翻转,并对其疵点较少的样本进行对称变化等方式数据扩充,数据增强后的瑕疵样本图片数量为原来的 2 倍。

2.2 训练

图8是采用不同算法训练时模型的损失收敛变化情况,从图中可以看出,损失曲线逐渐拟合于所训练的布匹瑕疵数据集。本文所提出的方法模型拥有更好的收敛性,并且误差也降低到较低的水平,这是由于通过融合形变卷积的多尺度特征提取,引入自注意力机制使模型表现出更强的判别瑕疵特征的能力,在RPN阶段采用自适应边框生成器,指导初始锚设计,从而使所提出的方法拥有更好的收敛性。

图9展示了不同类别的布匹瑕疵特征图可视化,其中特征图中红色部分为重点关注的瑕疵区域部分,显而易见,对于不规则、尺度变化大和小瑕疵的目标,该模型成功捕获到了布匹的瑕疵特征。

最主要的原因归于采用自注意力机制设计了双通道特征融合,通过进行自适应的调整融合获取更为有效的瑕疵特征,使得模型更加关注瑕疵特征,表现出更强判别极端瑕疵特征的能力。




图8 模型的损失收敛曲线图




图9 布匹瑕疵特征图可视化

2.3 实验结果与分析

为了分析和评价提出的瑕疵检测方法的性能,设置4组对比实验,采用准确率(Acc)、平均精度均值(mAP)、F1度量(F1-Score)和误检率(NF)四个评价指标综合说明算法的瑕疵和缺陷检验的准确性和有效性。

表3 不同特征提取网络对比结果

主干网络	加入 DCN	mAP	F1-Score	准确率	误检率
Resnet50	×	46.61	88.47	89.52	10.48
Resnet50	✓	47.76	90.43	91.52	8.48
Resnet101	×	46.54	91.42	92.42	7.58
Resnet101	✓	50.48	93.14	93.98	6.02

(1) 验证融合形变卷积多尺度特征提取网络对模型性能的有效性,即在级联网络模型中分别以 Resnet50、Resnet101 以及加入形变卷积后的实验对比。从表3中可以看出,在 Resnet101 中加入形变卷积后,

准确率提高了 1.56 个百分点,且误检率降到了 6.02%,这说明引入形变卷积后,多尺度特征提取网络获得具有更多瑕疵的关键信息的特征图,使算法更精确的对不规则瑕疵进行定位。

(2) 多通道特征聚合网络(MCFA)对模型性能的有效性,实验对比如表 4 所示。从表 4 中可以看出,在基线方法的基础上,添加特征通道注意力模块后(TA),模型的 mAP 提升了 0.75%,然后添加空间注意力模块后(PA),模型的 mAP 提升了 0.66%,说明了空间注意力模块有助于定位小目标疵点特征;添加 MCFA,本文模型的 mAP 提升了 2.49%,且准确率达到 95.84%,从而证明了 MCFA 的有效性。利用注意力机制筛选出语义信息更丰富的小瑕疵特征,缓解了小瑕疵目标特征表达的不足,实现了更准确的瑕疵识别与定位。

表 4 不同特征融合性能对比结果

Resnet101	MCFA		mAP	F1-Score	准确率	误检率
	TA	PA				
✓			50.48	93.14	93.98	6.02
✓	✓		51.23	93.65	94.17	5.83
✓		✓	51.89	93.92	94.76	5.24
✓	✓	✓	52.97	94.84	95.84	4.16

(3) 验证自适应锚框聚类对模型性能的有效性。实验对比结果如表 5 所示,针对松经、断经、吊经这类瑕疵极端长宽比的情况,采用自适应边界框生成器后,平均检测精度均提升明显,充分说明了自适应锚框聚类算法的有效性。这得益于生成器计算最优锚定框后,锚定框的尺寸适用于部分瑕疵极端长宽比的比例值,平均检测精度提升的主要原因是初始锚定框设计的更加合理,尺寸适应布匹瑕疵真实框大小,利于后续的检测和回归,有效缓解极端瑕疵长宽比悬殊大对模型检测性能的影响,增强瑕疵检测模型的学习能力。

表 5 部分瑕疵 AP 对比结果

瑕疵种类	无自适应边框聚类/AP	采用自适应锚框聚类/AP
松经	39.24	88.31
断经	62.14	80.46
吊经	28.79	63.71
浆板	76.11	79.65
稀疏、色差	46.84	61.42
跳纱、云织	33.98	56.89

(4) 提出方法与其他先进的一阶段和两阶段方法进行了实验对比。表 6 为本文提出的方法与其它先进检测方法在素色布匹瑕疵数据集上的效果比较,可以看出,级联检测器采用级联的结构,设计了多个检测器,

表 6 不同网络瑕疵检测结果

主干网络	mAP	F1-Score	准确率	误检率	T/ms
YOLOv3	43.98	76.64	78.92	21.08	20.18
RetinaNet	45.06	76.38	77.32	22.68	68.23
YOLOv5	46.92	81.94	81.23	18.77	5.62
Faster RCNN	47.54	81.98	83.73	16.24	68.32
Mask RCNN	49.56	89.43	90.12	9.88	86.56
Cascade RCNN	51.61	93.51	95.06	4.94	79.01
DLDA Net ^[21]	54.30	—	96.80	2.20	66.00
MSDA Net ^[26]	55.26	—	97.20	2.80	—
DACF Net ^[27]	65.00	—	97.00	3.00	80.00
Ours	68.31	96.59	98.14	1.86	70.32

通过逐步提升检测框的 IOU 阈值,所以检测准确率要优于 Mask RCNN、RetinaNet、YOLOv5 等,与未改进

的原 Cascade RCNN 相比,在检测时间增加 8.69 ms 的前提下,准确率达到 98.14%,mAP 值提升 16.7%。从实验结果可以看出,本文所提方法单张样本瑕疵检测用时 70.32 ms,可以满足实际工厂车间生产要求,且平均检测精度和准确率都达到了最高,因此本文方法对不规则瑕疵、小目标瑕疵和尺度变化大的瑕疵适用性更强。




图 10 布匹瑕疵检测结果

为了验证改进后模型对素色布匹瑕疵的检测性能,在测试集中针对不同瑕疵类别进行测试。图 10 给出了本文方法在素色布匹瑕疵数据集上的效果图,其中,左侧数字表示瑕疵类别,右侧数字表示检测精度,从该图中可以看出,所提出的检测方法对目标瑕疵的边界识别更加精准,对小目标的检出能力更强,疵点检测效果更好;对瑕疵尺度变化大的目标检测效果也相对较好,能够得到精确地包围框和较高的分类得分。

3 结论

布匹瑕疵的自动检测是工业界的重要研究热点。将深度学习算法应用于布匹瑕疵检测对于提高布匹瑕疵检测性能有着重要意义。本文分析了实际工厂车间素色布匹瑕疵的特点,针对素色布匹中瑕疵不规则、小瑕疵目标多、瑕疵纵横比悬殊等问题,提出了融合形变卷积和自注意力的素色布匹瑕疵检测方法。通过融合形变卷积的多尺度特征提取、构建双通道特征聚合的注意力模块和采用自适应边框生成器的方式,有效地提升了布匹瑕疵点的检测精度。经实验对比分析发现,这些改进很好地解决了不规则瑕疵、小目标瑕疵和瑕疵纵横比悬殊带来的负面影响,同时在素色布匹瑕疵数据集的消融实验和性能对比实验表明,对 20 种素色布匹瑕疵的整体检测准确率达到 98.14%,平均精度均值为 68.31%,单张瑕疵图片的检测时间为 70.32 ms,优于当前主流的素色布匹瑕疵检测方法,证明了提出方法的先进性。但由于是采用两阶段的级联检测器,该模型存在较多参数,影响了检测时间。因此,在保证检测精度的同时减少参数数量,使模型更加轻量化,更好的

满足实时性应用和需求,将是下一步的研究方向,未来还可以考虑在实际工厂车间对动态视频识别处理,尝试对动态视频进行研究,更具有实际意义。

参 考 文 献

- [1] JING J, FAN X, LI P, et al. Automated fabric defect detection based on multiple gabor filters and KPCA[J]. International Journal of Multimedia and Ubiquitous Engineering, 2016, 11(6): 93-106.
- [2] KARLEKAR V V, BIRADAR M S, BHANGALE K B, et al. Fabric defect detection using wavelet filter[C]. // International Conference on Computing Communication Control and Automation, February 26-27, 2015, Pune, India: IEEE, 2015.
- [3] 王孟涛, 李岳阳, 杜帅. 基于机器视觉的疵点检测方法的研究进展[J]. 现代纺织技术, 2019, 27(5): 57-61.
- [4] 杜帅, 李岳阳, 王孟涛, 等. 基于改进局部自适应对比法的织物疵点检测[J]. 纺织学报, 2019, 40(2): 38-44.
- [5] HANBAY K, TALU M F, ÖZGÜVEN Ö F, et al. Fabric defect detection methods for circular knitting machines[C]. // 23rd Signal Processing and Communications Applications Conference (SIU), Malatya, Malatya, Turkey: IEEE, 2015.
- [6] 韩茜茜, 耿世勇, 李恒毅. 基于机器视觉的缺陷检测应用综述[J]. 电工技术, 2019(14): 117-118+132.
- [7] 郭乔进, 胡杰, 宫世杰, 等. 深度学习计算平台发展综述[J]. 信息化研究, 2019, 45(3): 1-7+25.
- [8] HANBAY K, TALU M F, KUMA S. Hatalarının online/offline tespit sistemlerine yöntemleri[J]. Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2014, 18(1): 49-69.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. Advances in neural information processing systems, 2012, 25(2): 1-8.
- [10] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Columbus, OH, USA: IEEE, 2014.
- [11] GIRSHICK R. FAST R-CNN[C]. // IEEE International Conference on Computer Vision (ICCV), Santiago, Chile: IEEE, 2015.
- [12] REN S Q, HE K M, GIRSHICK R R. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 39(6): 1137-1149.
- [13] REDMON J, DIVVALA S K, GIRSHICK R B, et al. You only look once: unified, real-time object detection[C]. // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA: IEEE, 2016.
- [14] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]. // IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA: IEEE, 2017.
- [15] LIU Z F, LIU S L, LI C L, et al. Fabric defect detection based on SSD[C]. // International Conference on Graphics and Signal Processing, Sydney, NSW, Australia: ACM, 2018.
- [16] ZHOU T, Pang X R, CHEN W Z. Improvement of real time detection algorithm based on SSD[C]. // International Conference on Intelligent Human-Machine Systems and Cybernetics, Hangzhou, China: IEEE, 2018.
- [17] QIN R T, LI Y, FAN Y J. Research on fabric defect detection based on multi-branch residual network[J]. Journal of Physics: Conference Series, 2021, 1907(1): 1907-1913.
- [18] WEI B, HAO K R, TANG X, et al. Fabric defect detection based on faster RCNN [C]. // International Conference on Artificial Intelligence on Textile and Apparel, Hong Kong: Artificial Intelligence on Fashion and Textiles, 2018.
- [19] 晏琳, 景军锋, 李鹏飞. Faster RCNN 模型在坯布疵点检测中的应用[J]. 棉纺织技术, 2019, 47(02): 24-27.
- [20] 赵亚男. 基于深度学习的织物瑕疵小目标检测技术研究[D]. 广州: 广东工业大学, 2019.
- [21] JING J, ZHUO D, ZHANG H, et al. Fabric defect detection using the improved yolov3 model[J]. Journal of Engineered Fibers and Fabrics, 2020, 15(3): 15-21.
- [22] ZHU X, HU H, LIN S, et al. Deformable ConvNets V2: More Deformable, Better Results[C]. // IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, CA, USA: IEEE, 2019.
- [23] XUE H, LIU C, WAN F, et al. Danet: Divergent Activation for Weakly Supervised Object Localization[C]. // IEEE/CVF International Conference on Computer Vision, Seoul, Korea (South): IEEE, 2019.
- [24] DAI Y, GIESEKE F, OEHMCKE S, et al. Attentional Feature Fusion[C]. // Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, Waikoloa, Hawaii, United States: IEEE, 2021.
- [25] LIN T Y, MICHAEL M, SERGE B, et al. Microsoft COCO: Common Objects in Context[C]. // European Conference on Computer Vision, Springer, Cham: Springer, 2014.
- [26] 许胜宝, 郑颀默, 袁德成. 基于改进级联 R-CNN 的面料疵点检测方法[J]. 现代纺织技术, 2022, 30(2): 48-56.
- [27] 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.

(责任编辑: 周相泉)