

一种基于级联 RCNN 的织物瑕疵检测算法

赵玉香 段先华 赵楚

(江苏科技大学计算机学院 江苏 镇江 212000)

摘要 为了识别织物中的瑕疵,减少经济损失,针对现有一些网络检测方法存在检测精度不高以及对小目标检测不灵敏的问题,提出一种基于级联 RCNN 织物瑕疵算法 ZS-Cascade RCNN。首先,在特征提取阶段,加入可变形卷积,保留特征的完整性;其次,调整锚框来适应不同纵横比的瑕疵检测需求,提高检测效果;最后,采用交并比均衡采样,均衡正负样本。实验表明,ZS-Cascade RCNN 算法比原始算法准确率提高 4.5 个百分点,平均精度提升 17.8 个百分点,对织物瑕疵检测效果有明显提升。

关键词 卷积神经网络 深度学习 瑕疵检测 级联检测器

中图分类号 TP3

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.11.034

FABRIC DEFECT DETECTION ALGORITHM BASED ON CASCADE RCNN

Zhao Yuxiang Duan Xianhua Zhao Chu

(College of Computer, Jiangsu University of Science and Technology, Zhenjiang 212000, Jiangsu, China)

Abstract In order to identify fabric defects and reduce economic losses, aiming at the problems of low detection accuracy and insensitivity to small target detection in some existing network detection methods, this paper proposes a fabric defect algorithm ZS-Cascade RCNN based on cascade RCNN. In the feature extraction stage, deformable convolution was added to preserve the integrity of feature. The anchor frame was adjusted to meet the defect detection requirements of different aspect ratios to improve the detection effect. The cross and parallel ratio equalization sampling was used to equalize positive and negative samples. Experimental results show that the accuracy of ZS-Cascade RCNN algorithm is 4.5 percentage points higher and the average accuracy is 17.8 percentage points higher than that of the original algorithm. The effect of fabric defect detection is obviously improved.

Keywords Convolution neural network Deep learning Defect detection Cascade detectors

0 引言

纺织业是我国国民经济的传统支柱型产业和重要的民生产业,纺织成品的生产成本往往会受到原始坯布品质的影响,一旦原始布匹的质量出了问题,那么将会大大影响其相关产业的盈利。纺织行业中大部分质量问题都与织物缺陷有关,这是纺织业面临的主要问题之一^[1]。织物瑕疵主要是指在工业化生产和制造过程中织物表面出现的外观上的缺陷。这些织物瑕疵主要由机器故障、纱线问题、不良加工、过度拉伸等问题引起的,此外在远距离的路途运输、搬运的过程中也不

可避免地对织物品质产生影响,产生一些破洞、磨损、污渍等瑕疵^[2]。严重的瑕疵问题会导致织物产品的滞销和巨大的经济损失,而织物瑕疵检测目的就是识别和定位这些瑕疵。多年来,传统的织物瑕疵检测都是靠人工肉眼去识别^[3],人工检测的方法虽然可以做到纠正一些错误,挽救一些损失,但是工人工作强度大,检测效率低下,并且人工检测通常不会注意到较为微小的瑕疵,容易漏检^[4]。因此改善瑕疵检测过程中小目标的检测问题并提高检测精度,已成为瑕疵检测领域的研究热点^[5]。

近年来,基于深度学习的目标检测取得了飞速发展,研究者们提出了越来越复杂的网络结构目的就是

提高目标检测的效果,主要包括 R-CNN、SPP-Net、Fast R-CNN、Faster R-CNN、Cascade R-CNN、YOLO 和 SSD 等。Wang 等^[6]提出了一种基于级联深度 SVDD 的织物疵点检测方法,利用深度卷积网络,了解更多丰富的纹理特征,不需要寻找大量的织物缺陷图像。只需要少量的正态样本就可以完成训练。对大多数织物疵点都有很好的检测效果,但是不能分辨出具体的瑕疵种类。刘露露等^[7]提出一种 FS-YOLOv3 网络来自动检测棉布瑕疵。该网络结合 K-Means++ 聚类算法,以交并比为距离度量获取较好尺寸的锚框,提高检测速度。整体性能优于传统的检测方法,虽然速度快,但是检测精度不高。Jun 等^[8]提出了一种基于学习的织物疵点自动检测框架。但是该方法有一个致命的缺点就是它使用一个固定大小的方形滑块,将原始图像裁剪成一定的步长和规则性的方块。这个过程中会产生许多的误差,丢失大量的特征,特别是对小目标来说,致使其准确率大大降低。

目前,现有的基于 Cascade RCNN 的改进方法,主要是在网络层上进行改进。如采用通道叠加提高特征的表达能力,或者采用双路残差网络提高检测效率。这样的改进方法虽然可以提高检测效果,但是通道叠加和采用双路的残差网络,不但增加了计算时间而且耗费了大量的内存。而且单纯的通道的叠加会增加网络的负荷,造成网络的过拟合,检测结果严重失真。对于本文实验对象,原始的 Cascade RCNN 基础网络,对小目标的检测精度不高,还存在漏检率高等问题。

针对上述问题,本文提出了一种改进的级联 RCNN 的织物瑕疵检测 ZS-Cascade RCNN 算法。首先,在提取特征时,加入可变形卷积,和现有的一些改进措施相比,在不增加网络额外负担的情况下,保留更多的更完整的特征。其次,在区域提议网络阶段调整锚框使其满足一些非常规大小比例的瑕疵的检测需求。最后,在检测器中,采用交并比均衡采样方式,均衡正负样本,提高算法的鲁棒性。和很多随机采样或者采用在线难样本采样的网络对比,随机采样不能解决样本不均衡的问题,在线难样本采样对研究数据的质量要求比较高,数据集比较脏时,其表现不佳,交并比均衡采样更适合本文的研究对象,检测效果也表现更好。实验结果表明,以上改进措施对瑕疵的检测效果有较好的提升。

1 Cascade RCNN 网络结构

Cascade RCNN 网络^[9]是 2018 由何凯明提出来的目标检测模型,如图 1 所示,该模型是由特征提取网

络、特征金字塔网络 (Feature Pyramid Networks, FPN)^[10]和级联检测器^[11]三大部分组成。特征提取网络对图片进行特征提取,特征金字塔将每层输出的这些特征图由深至浅地进行特征融合,然后将这些融合后的特征图送入区域建议网络 (Region Proposal Networks, RPN)^[12]得到候选目标区域 (proposals),再将这些候选的目标区域送入级联检测器中。级联检测器包含三个相同的目标检测模块,每个检测模块包含感兴趣区域池化 (Region of Interest Pooling, ROI Pooling)、检测器头部、分类和边框回归。检测时,通过前一个检测器输出的边框回归对候选目标区域进行重采样,逐步提升交并比 (Intersection over Union, IoU) 阈值训练得到新的分类得分和边框回归。每个检测器均接受上一级检测器的边框回归结果作为其输入,三个检测器将提议框判定为正类的交并比阈值逐渐升高,最后一个检测器的输出结果作为最终结果。

虽然 Cascade RCNN 对小目标的检测精度有一定提升,但仍然存在以下问题: Cascade R-CNN 里在特征提取阶段普通的卷积层提取的特征不够完整和精确,在区域提议网络中默认的锚框 (anchor),面积和比例只有九种,很难满足小目标检测的需求。三个检测器阈值逐步升高,只选中正类,而将低于阈值的负样本舍弃,容易造成正负样本不均衡。而本文所提出的一种改进级联 RCNN 的织物瑕疵检测 ZS-Cascade RCNN 算法可以很好地解决上述问题。

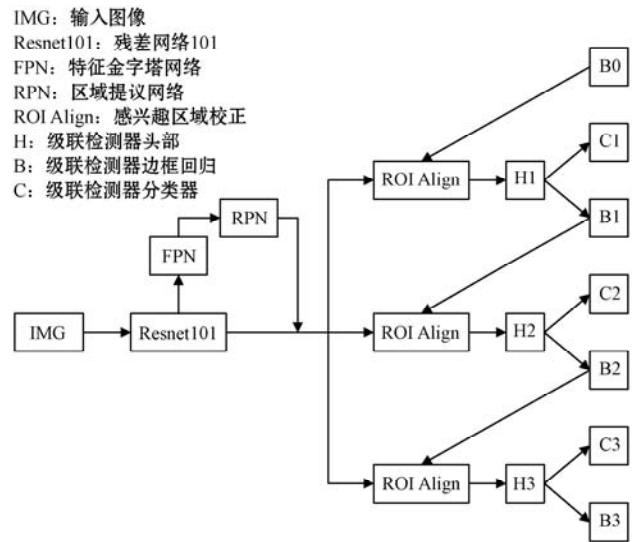


图 1 Cascade RCNN 网络结构图

2 ZS-Cascade RCNN 网络结构

2.1 添加可变形卷积

特征提取网络 Resnet101 可以分成五个部分。一个初始块和四个复杂语义信息块,每个复杂信息块是

通过 1×1 、 3×3 、 1×1 的残差卷积层的交替堆叠而成^[13]。这些模块主要完成对图片特征的提取工作,但是这样的特征提取方式存在一定的缺陷,其原因在于它对特征的提取采用规则的矩形,这样一些完整的特征将会被打散,导致特征丢失严重。

为解决这个问题,本文使用可变形卷积替代 Resnet101 最后一个阶段中的 3×3 卷积层。如图 2 所示,可变形卷积先通过一个卷积层输出偏移量,接着将其作用在卷积核上,从而达到可变形卷积的效果。通过对该偏移量的学习,可变形卷积的位置和大小发生了很大变化,肉眼最直观的感受就是,卷积核的采样点随着识别目标大小和形状的变化,而发生了自适应的变化。




图 2 可变形卷积示意图

可变形卷积是在规则的网格 R 上进行采样后加权运算, R 定义了感受野的大小和扩张。规则的网格 R 在特征图上滑动过程中通过 $\{\Delta p_n | n = 1, 2, \dots, N\}$ 增大,其中 $N = |R|$,输出特征映射 $y(p_0)$,最终得到不局限于常规网格的特征,从而避免了有效瑕疵特征信息的流失,公式为:

$$y(p_0) = \sum_{p_n \in R} w(p_n) \cdot x(p_0 + p_n + \Delta p_n) \quad (1)$$

2.2 调整锚框

由于本实验研究对象的特殊性,数据集中出现的瑕疵一般都是面积比较小,纵横比差异比较大。因此针对小目标检测的问题,锚框的选择非常重要。我们可以通过调整 Cascade RCNN 中的区域提议阶段的锚框的大小和数量来提高检测效果^[14]。在 RPN 中,每个锚点默认拥有 9 个矩形框,共有 3 种基本形状,纵横比为 0.5、1.0、2.0。面积为 8、16、32。调整其具体参数,首先要对训练的数据集进行分析,由表 1 统计可知,绝大多数的瑕疵的纵横比都在 1:1 到 1:50 之间。所以在原有数据的基础上,保持面积不变,但是修改纵横比为 0.02、0.05、0.1、0.5、1.0、2.0、10.0、20.0、50.0,则每个锚点产生不同的纵横比的锚框来适应不同大小的瑕疵,提高检测效果。

表 1 不同纵横比数量统计表

纵横比	数量
1:1 ~ 1:10	5 868
1:11 ~ 1:20	854
1:21 ~ 1:30	455
1:31 ~ 1:40	289
1:41 ~ 1:50	186
1:51 ~ 1:60	7
1:61 ~ 1:70	1

2.3 均衡正负样本

本文研究对象瑕疵的面积占整幅图片的面积偏小,负样本的感兴趣区域的提议数量要远远高于正样本的数量。由于负样本 IoU 的不平衡,当采用随机采样后,会出现难负和易负样本不平衡采样,导致实验结果不好,因此采用在线难样本挖掘 (Online Hard negative Example Mining, OHEM) 来解决这个问题^[14],但是 OHEM 在实际试验中增加了整个网络模型的损耗,不但计算量大,而且对于人为标注的 COCO 格式的数据集鲁棒性低。所以最后采用 IoU 均衡采样,不但关注了难样本,也关注到了其他样本,鲁棒性高,参数易调,没有增加系统的损耗,速度可观。

基础网络默认采用随机采样,由文献[15]可知超过 70% 随机采样到的样本的 IoU 是在 0 到 0.05 之间,而在这区间内都是易学习的负样本。经过实际统计 60% 的难负样本 IoU 在 0.05 左右,所以随机采样只提供了 30% 左右的难负样本,数量过少。

假设在数量为 M 的样本中选择 N 个困难样本,每个困难样本被选中的概率 P 为:

$$P = \frac{N}{M} \quad (2)$$

现在为了均衡正负样本,将原始样本划分为 K 个区间,每个区间的样本数是 M_k ,假设依旧采样 N 个在对每个小区间进行随机采样,则采样概率 P_k 变为:

$$P_k = \frac{N}{K} \times \frac{1}{M_k} \quad k \in [1, K] \quad (3)$$

通过这种采样方式,改变了原有采样的整体分布,使每个区间都可以均匀地被采样,保证易学习负样本和难负样本比例尽量平衡。

3 实验

3.1 实验环境

本次实验基于 Cascade RCNN 的基础上进行微调,

采用随机梯度下降法进行优化,动量因子设为 0.9,权重衰减因子设为 0.000 1,初始学习率为 0.001,在初始的 500 次迭代中,学习率逐渐增加。实验是在 Ubuntu 操作系统下,采用 GPU 对图像进行处理,实验用到 Mmdetection 2.3.0 工具包,该工具箱是一个开源的基于 PyTorch 深度学习目标检测工具。具体实验环境见表 2 所示。

表 2 实验环境

类型	版本号
操作系统	Ubuntu 16.04
GPU	NVIDIA RTX-2080Ti
CPU	Intel Core i7-6700
Cuda	10.2
Cudnn	7.6.5
PyTorch	1.5
PyCharm	2020.2
Mmdetection	2.3.0

3.2 实验数据

本课题选用的数据来自广东省佛山南海纺织车间采集的织物图像,该数据集包含了织物中出现的各类的瑕疵,其中数据集里的每幅图片包含一种或多种瑕疵。本实验采用 COCO 数据集的格式,原始数据集中的瑕疵一共分为 34 种,但有些瑕疵在形态上非常相似,故将这些瑕疵类型进行合并后,如表 3 所示,一共有 20 个瑕疵类别。

表 3 瑕疵分类

类别名	分类号	类别名	分类号
无瑕疵	0	吊经	11
破洞	1	粗维	12
污渍	2	纬缩	13
三丝	3	浆斑	14
结头	4	整经结	15
花板跳	5	跳花	16
百脚	6	断氨纶	17
毛粒	7	稀密档	18
粗经	8	磨痕	19
松经	9	纬纱不良	20
断经	10		

从图 3 可以看出,数据集的瑕疵分类非常不均匀,为了使训练能够得到一个理想的结果,对原始图像数据进行增强,主要方法有裁剪、翻转、加噪、亮度变化

等。扩充后的数据集,采用 9:1 的方式随机选择训练数据集和测试数据集。




图 3 瑕疵数量统计图

3.3 评价指标

本文采用准确率 (Accuracy, Acc)、平均精度 (Average Precision, AP) 和召回率 (Recall) 作为织物瑕疵检测方法的评价指标^[16]。

准确率是指识别正确的数量占总数量的比例^[17],其表达式为:

$$A_{cc} = \frac{T_p + T_N}{T_p + F_p + T_N + F_N} \quad (4)$$

式中: T_p 是判断为正确的正例的个数, F_p 是判断为错误的正例个数, T_N 是判断为正确的负例的个数, F_N 是判断为错误的负例的个数。

精确率 P 是指实际的正样本数量占网络认为是正样本的数量的比例,其表达式为:

$$P = \frac{T_p}{T_p + F_p} \quad (5)$$

召回率 R 是指所有正样本中正确识别的概率,其表达式为:

$$R = \frac{T_p}{T_p + F_N} \quad (6)$$

平均精度 A_p 是指同一类别的瑕疵在不同召回率上的准确率平均值^[18],其表达式为:

$$A_p = \frac{1}{n} \sum_{i=1}^n (P_i | R_i) \quad (7)$$

3.4 对比实验

3.4.1 加入可变卷积后的模型对比

为了验证可变卷积对模型的影响,在采用相同的主干网络 Resnet101 的基础上,其他参数保持不变,加入可变形卷积和不使用可变卷积的效果有明显的提

升,如表 4 所示,虽然耗时增加了,但是准确率提高了 1.15 百分点,平均精度提高了 7.8 百分点,较少的速度减慢对于所得到的效果来说,是合理的。

表 4 是否使用可变形卷积对比

使用可变形卷积	time/s	Acc/%	AP/%
未使用	0.349	94.17	42.0
使用	0.439	95.32	49.8

3.4.2 调整锚框对模型的影响

在 RPN 阶段锚框的设置是非常重要的,对于面积和大小比较规则的瑕疵来说,默认大小的锚框是可以将其选中,但是对于纵横比差异较大的瑕疵,默认的锚框是远远不够的,所以在保证其他参数和基础网络不变的基础上,增加了不同比例之后,如图 4 所示,准确率达到 95.94%,平均精度提高了 6.3 百分点,该改进方法是有效的。




图 4 调整锚框对比图

3.4.3 均衡正负样本对模型的影响

为了验证均衡正负样本对模型的影响,在保持其他参数不变的基础上,将原有的随机采样更改为 IoU 均衡采样,虽然耗时增加了些许,但是准确率提高了 1.56 百分点,平均精度提高了 1.8 百分点,如表 5 所示。较少的速度减慢对于整个网络模型来说影响不大可以忽略,准确率和平均精度都有所提升,是可取的。

表 5 采样方式对比

采样方式	time/s	Acc/%	AP/%
随机采样	0.349	94.17	42.0
IoU 均衡采样	0.396	95.88	43.8

3.4.4 不同改进措施叠加对比

为了进一步验证不同的改进措施对 Cascade RCNN 的效果提升,做了如表 6 所示的对比实验。通过实验,在如表 6 所示的三种改进措施之下的网络模型,从时间来看有增加的趋势,因为每个改进方式或多或少地增加了模型的计算量,但是总体来看速度不是特别的慢。从准确率来说,在改进措施的累加之下,模型的准确率在逐步升高。从平均精度来看,在优化定位方案之后网络模型的平均精度增长到了 59.8%,三种改进

措施的累加对模型的效果有较大提升,虽然减慢了模型的运行速度,但是提高了模型的精度,较少的时间牺牲对于本文模型来说是可取的。

表 6 不同改进措施对模型影响

加入可变形卷积	调整检测框	均衡正负样本	Acc/%	time/s	AP/%
			94.17	0.349	42.0
✓			95.32	0.439	52.8
✓	✓		97.63	0.581	57.3
✓	✓	✓	98.67	0.665	59.8

3.4.5 实验效果

为了检测 ZS-Cascade RCNN 的检测效果,随机抽取了瑕疵类别为三丝、断经和纬纱不良的三幅原图,分别用 Cascade RCNN 和 ZS-Cascade RCNN 对其进行测试。如图 5 所示,原始网络虽然也能将大部分的瑕疵检测出来,但是容易出现误检的情况。ZS-Cascade RCNN 无论是面比较大的瑕疵还是面积特别小的瑕疵,都能将其识别并精准定位。ZS-Cascade RCNN 比 Cascade RCNN 锚框更加贴近瑕疵,减少误检。置信度也更高了,检测效果有很大提升。

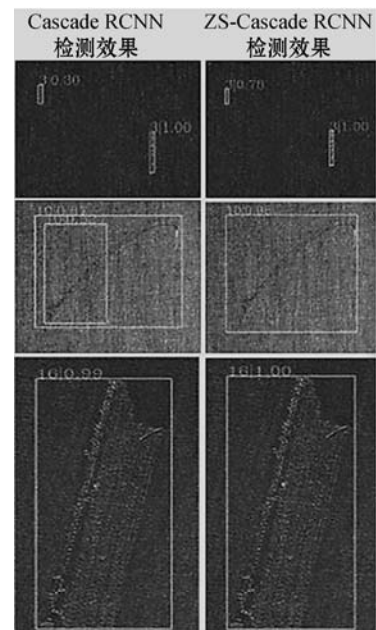


图 5 实验效果对比图

3.4.6 不同网络模型性能对比

为了验证实验对织物瑕疵检测的有效性,选用 Fast RCNN、Faster RCNN、Mask RCNN、Cascade RCNN 和本文所用的模型进行对比实验^[19],实验中参数的设置尽量相同,相同实验环境下进行实验。实验结果如表 7 所示,相比于其他的网络模型,本文所使用的 ZS-Cascade RCNN 无论是在准确率还是平均精度方面都是优于其他模型的。

表 7 不同模型性能对比

网络模型	Acc/%	误检率/%	AP/%
Fast RCNN	90.81	9.19	36.2
Faster RCNN	92.31	8.69	39.0
Mask RCNN	92.96	7.04	40.0
Cascade RCNN	94.17	5.84	42.0
ZS-Cascade RCNN	98.67	1.33	59.8

3.4.7 ZS-Cascade RCNN 在不同数据集上的表现

为了验证 ZS-Cascade RCNN 的普适性,选用公开的 MS-COCO 和 PASCAL VOC 数据集进行对比实验。实验结果如表 8 所示,ZS-Cascade RCNN 在两个公开数据集上都表现良好。

表 8 ZS-Cascade RCNN 在不同数据集上的表现

数据集	time/s	AP/%
MS-COCO	0.583	62.7
PASCAL VOC	0.565	74.2

4 结 语

本文针对织物瑕疵小的特点,选取了对小目标检测更为敏感的 Cascade RCNN 为基础算法,提出的 ZS-Cascade RCNN 瑕疵检测算法,通过添加可变形卷积和调整锚框来提高网络的对特征的提取和感兴趣区域的提取能力。由于本文研究对象的特殊性,整个提议样本会偏向负样本,造成正负样本的不均衡,对实验结果有较大影响。采用交并比均衡采样均衡正负样本,提高检测效果,增加算法的鲁棒性。通过对比实验表明,这三条改进措施,确实对网络检测效果有明显的提升作用。但是在实验过程中,对网络的改进使得网络的计算量变大,时间变慢,所需内存也变多,未来需对这些方面考虑改进时耗的问题。

参 考 文 献

[1] 刘艳锋,郑云波,黄惠玲,等. 基于卷积神经网络的织物瑕疵检测方法研究[J]. 信息技术与网络安全,2020,39(11): 62-68.

[2] Peng P R, Wang Y, Hao C, et al. Automatic fabric defect detection method using PRAN-Net[J]. Applied Sciences, 2020,10(23):8434.

[3] 唐有赞,盛晓伟,徐洋,等. 基于轻量级模型的经编布瑕疵在线检测算法[J]. 东华大学学报(自然科学版),2020,46(6):922-928.

[4] Zhao S X, Li Y, Zhang J, et al. Real-time fabric defect detection based on multi-scale convolutional neural network

[J]. IET Collaborative Intelligent Manufacturing, 2020, 2(4):189-196.

[5] Di L, Long H B, Liang J Z. Fabric defect detection based on illumination correction and visual salient features[J]. Sensors,2020,20(18):5147.

[6] Wang X P, Li Y, Luo H C. Fabric defect detection method based on cascade deep support vector data description[J]. Journal of Physics: Conference Series,2020,1651(1):12079.

[7] 刘露露,李波,何征,等. 基于 FS-YOLOv3 及多尺度特征融合的棉布瑕疵检测[J]. 中南民族大学学报(自然科学版),2021,40(1):95-101.

[8] Jun X, Wang J G, Zhou J, et al. Fabric defect detection based on a deep convolutional neural network using a two-stage strategy[J]. Textile Research Journal,2021,91(1/2): 130-142

[9] Felzenszwalb P F, Girshick R B, McAllester D. Cascade object detection with deformable part models [C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition,2010:2241-2248.

[10] Lin T Y, Dollar P, Girshick R, et al. Feature pyramid networks for object detection [C]//IEEE Conference on Computer Vision and Pattern Recognition,2017:936-944.

[11] 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.

[12] Xie H S, Wu Z S. A robust fabric defect detection method based on improved refineDet[J]. Sensors,2020,20(15):4260.

[13] 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.

[14] Shrivastava A, Gupta A, Girshick R. Training region-based object detectors with online hard example mining [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016:761-769.

[15] Pang J M, Chen K, Shi J P. Libra R-CNN: Towards balanced learning for object detection [C]//IEEE Conference on Computer Vision and Pattern Recognition,2019:412-415.

[16] Rasheed A, Zafar B, Rasheed A, et al. Fabric defect detection using computer vision techniques: A comprehensive review[J]. Mathematical Problems in Engineering,2020,2020(1):8189403.

[17] 蔡兆信,李瑞新,戴逸丹,等. 基于 Faster RCNN 的布匹瑕疵识别系统[J]. 计算机系统应用,2021,30(2):83-88.

[18] Simon P, Uma V. Deep learning based feature extraction for texture classification[J]. Procedia Computer Science,2020, 171:1680-1687.

[19] Salem Y B, Abdelkrim M. Texture classification of fabric defects using machine learning[J]. International Journal of Electrical and Computer Engineering,2020,10(4):4390-4399.