

DOI: 10.13382/j.jemi.B2206148

基于改进 Mask R-CNN 的光学元件划痕缺陷检测研究

马志程 李丹 张宝龙

(天津科技大学电子信息与自动化学院 天津 300222)

摘要:光学元件缺陷会直接影响整个光学系统的性能,在光学元件缺陷检测中,划痕缺陷无疑是检测的难点,划痕缺陷存在着尺寸小,长宽比却比较大,易受杂质影响的问题,本文将深度学习算法应用到光学元件缺陷检测,并根据划痕缺陷的特点,对Mask R-CNN 网络模型进行了改进,使算法对划痕缺陷也有了更好的检测效果。首先,将原有的 ResNet 更换为本文提出的 CSPRepResNet,并添加 ESE 注意力机制,提高了特征提取的能力并减少了计算量;其次,利用 K-means 算法重新聚类 anchor boxes 的长宽比例;再次,将目标检测的损失函数由 Cross Entropy 改为梯度均衡化的 Focal Loss,解决了正负样本不平衡问题的同时,更有利于对困难样本的检测,还可以消除离群点的影响。总体来说,检测的 mAP@.5 由原来的 52.1% 提高到 57.3%,提高了 5.2%,且推理速度几乎不变,可见,改进后 Mask R-CNN 对光学元件划痕缺陷有更好的检测效果。

关键词:缺陷检测;Mask R-CNN;注意力机制;梯度均衡化的 Focal Loss

中图分类号: TN98 文献标识码: A 国家标准学科分类代码: 520.20

Research on scratch defect detection of optical elements based on improved Mask R-CNN

Ma Zhicheng Li Dan Zhang Baolong

(School of Electronics and Automation, Tianjin University of Science and Technology, Tianjin 300222, China)

Abstract: Optical element defects will directly affect the performance of the entire optical system. In the detection of optical element defects, scratch defects are undoubtedly the difficulty of detection. The scratch defects have the problems of small size, large aspect ratio, and easy to be affected by impurities. In this paper, depth learning algorithm is applied to optical element defect detection, and according to the characteristics of scratch defects, the Mask R-CNN network model is improved. The algorithm also has a better detection effect on scratch defects. First, the original ResNet is replaced by CSPRepResNet proposed in this paper, and ESE attention mechanism is added to improve the ability of feature extraction and reduce the amount of computation. Secondly, K-means algorithm is used to recluster the length width ratio of anchor boxes. Thirdly, the loss function of target detection is changed from Cross Entropy to gradient balanced Focal Loss, which solves the problem of imbalance between positive and negative samples, is more conducive to the detection of difficult samples, and can also eliminate the influence of outliers. In general, the tested mAP@.5 The original 52.1% is increased to 57.3%, an increase of 5.2%, and the reasoning speed is almost unchanged. It can be seen that the improved Mask R-CNN has a better detection effect on optical element scratch defects.

Keywords: defect detection; Mask R-CNN; attention mechanism; GHM-Focal Loss

0 引言

光学元件表面缺陷检测是光学检测技术研究领域的重点。鉴于光学元件的表面质量直接影响到整个光学系统的性能,所以要使光学仪器设备更高效地工作,不仅在

加工时需要注意光学元件的表面质量,还要关注成品的检测工作。因此,光学元件表面缺陷检测是一项重要的研究课题^[1]。工业生产中光学元件出现的缺陷主要有划痕、麻点、内裂、气泡和脱膜等,本文主要针对划痕的缺陷进行检测。

传统的光学元件缺陷检测方法主要分为目视法和数

字图像处理法两类。目视法^[2]的缺点是带有十分明显的主观性,检测结果容易受检测人员的经验以及眼睛的疲劳影响,检测质量因人而异,所以目视法的检测效率很低,非常依赖人眼的主观判断,一系列的问题限制了该检测方法的发展。数字图像处理法^[3]也存在着一定的问题,如阈值的选取依赖经验、检测的速度慢、难以判别缺陷的类型等,这些问题制约着该方法的发展。

随着标注样本数据集的快速增长和图形处理器(graphics processing unit, GPU)性能的大幅度提高,卷积神经网络的相关研究得到了迅速的发展,其特征学习和特征表达能力进一步加强,使得深度学习算法应用到缺陷检测上成为可能^[4]。Soukup 等^[5]首先提出了利用卷积神经网络进行钢轨表面的缺陷检测,但需要手工提取特征图像;Park 等^[6]提出了一种新的基于卷积神经网络(convolution neural network, CNN)的表面缺陷检测方法,该方法在深度神经网络的分类性能上显示出了良好的缺陷检测效果;文献[7]提出了一种基于共轭梯度神经网络的方法,该方法是一种将相位图与缺陷图相结合的玻璃缺陷识别方法;郭瑞奇等^[8]利用 U-Net 网络实现了汽车轮毂表面的缺陷分割,但算法存在着严重的误判和漏判现象;陈其浩等^[9]提出利用改进 U²-Net 网络对透明件划痕缺陷检测,但其没有排除杂质对网络的影响,会把类似于缺陷的杂质误判为划痕;Pan 等^[10]基于 Mask R-CNN 网络完成了在复杂背景下的透明建筑材料表面划痕的识别,但模型训练与检测耗时较长,检测精度需进一步提升。虽然以上方法对缺陷检测有一定的借鉴价值,但都没有针对光学元件划痕这一缺陷进行具体研究,因此,本文根据划痕缺陷的特点及其存在的问题,提出利用改进的 Mask R-CNN 对划痕缺陷进行检测和分割。

1 Mask R-CNN 模型

Mask R-CNN 网络模型是 2017 年由 He 等^[11]提出的一种简单、灵活、通用的实例分割框架,是在 Faster R-CNN^[12]模型的基础上,添加一个对每个 ROI 预测的 Binary Mask 分支,如图 1 中的虚线框所示,该分支并行已

有的 Classification 和 Boundary box regression 分支,因此可以同时进行目标检测和实例分割,并在这些任务中显示出了良好的性能,但划痕缺陷存在着尺寸小,长宽比却比较大,易受杂质影响的问题,若直接采用 Mask R-CNN 网络对其进行检测,检测精度很低,故本文计划在该网络框架的基础上,对其进行改进,应用到光学元件划痕缺陷检测上,Mask R-CNN 网络结构如图 1 所示。

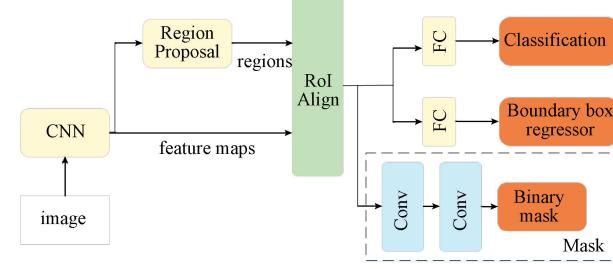


图 1 Mask R-CNN 网络结构
Fig. 1 Mask R-CNN network structure

2 改进的 Mask R-CNN 模型设计

2.1 添加 ESE 注意力机制

光学元件划痕数据集中存在微小的划痕缺陷,而 Mask R-CNN 网络的特征提取部分对其特征提取不够充分,导致这样的缺陷存在着漏检问题,网络模型的特征提取能力需进一步加强,因此,本文在原始网络的特征提取部分中添加注意力机制。SE 注意力机制是 SENet^[13]中提出的权重方法,主要包括两个部分:Squeeze 部分和 Excitation 部分。第 1 部分通过全局平均池化将原始特征图的 $H \times W \times C$ 压缩到 $1 \times 1 \times C$ 的维度,相当于把 $H \times W$ 压缩成一维;第 2 部分将压缩得到 $1 \times 1 \times C$ 的特征图经过全连接层,对每个通道的重要性进行预测,再经过一个 Sigmoid 激活函数,使得预测值规范在 0~1 之间,就得到不同通道重要性的权重,再将这个权重作用到之前的特征图的对应的通道上,这样,每个通道便赋予了不同程度的权重,更有利于特征的提取,SE 模块示意图如图 2 所示。

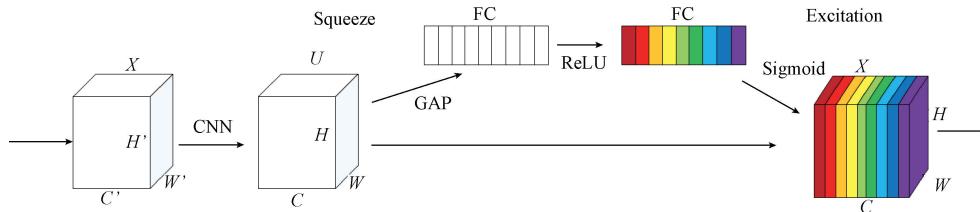


图 2 SE 模块示意图
Fig. 2 SE model sketch map

为了减小模型的计算量,在 SENet 中使用了比例因子 r ,但这无疑降低了 SE 模块提取权重的能力,进而造成特征损失或者说权重表达能力减弱,如图 3(a)所示。在 CenterMask^[14] 算法中,作者提出一种高效的 ESE 模块,如图 3(b)所示,唯一的差别是去掉了带有比例因子 r 的第一个全连接层和 ReLU 激活函数,其出发点就是提升 SE 模块产生的通道注意力权重,同时还降低了模型的计算量。

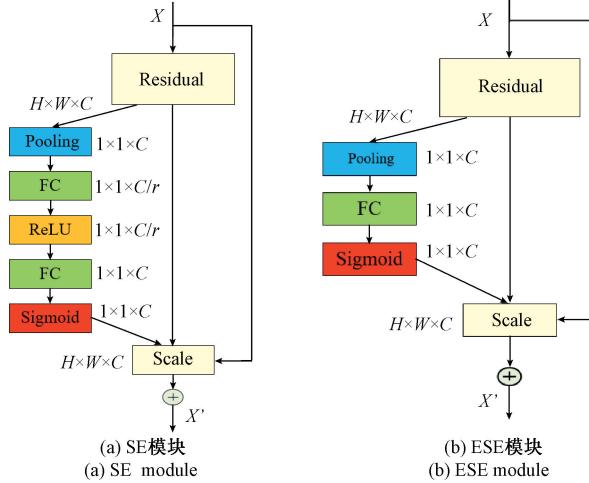


图 3 SE 模块与 ESE 模块对比

Fig. 3 Comparison between SE module and ESE module

2.2 Backbone 部分

原始的 Mask R-CNN 的 Backbone 部分为 ResNet^[15], ResNet 引入了残差块,通过跳跃连接将上一层信息映射到下一层;DenseNet^[16]指出,当在一个残差块中使用太多的层时,可能会阻碍网络中的信息流,为了确保各层之间最大限度的信息流,DenseNet 将具有相同大小特征图的所有层直接相互连接。然而,中间层的密集连接是冗余的,这导致了低效率,为了提高效率,VoVNet^[17]提出了一个 OSA 模块,如图 4(a)所示,在最后一个特征图中只连接所有特征一次,这使输入大小恒定,并允许扩大一个新的输出通道,尽管 OSA 模块在性能改进方面显示出巨大的潜力,但它还不够轻量化,目前仍有提高效率的空间。TreeNet^[18] 基于 ResNet 中引入的瓶颈结构,提出了一个更为轻量级的 Tree 模块,如图 4(b)所示,OSA 模块中的每个 3×3 Conv 层被一个 3×3 层和一个 1×1 卷积所取代,其中, 1×1 层负责增加维数,而 3×3 层则通过后续的卷积层进行进一步处理,所有 1×1 层和最后 3×3 层的输出都被连接起来,然后通过一个过渡层进行转换,Tree 模块具有较深的网络结构,而模型的复杂度较低。

本文简化了原始的 Tree 模块,如图 5(a)所示,然后,用元素级添加操作替换连接操作,如 5(b)所示,可以减少计算量,本文命名为 RepResBlock,本文使用

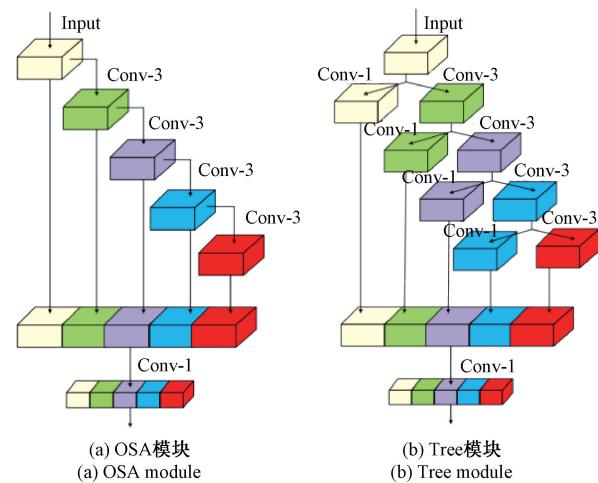


图 4 OSA 模块与 Tree 模块对比

Fig. 4 Comparison between OSA module and Tree module

RepResBlock 来构建网络的主干和颈部。与 ResNet 类似,主干命名为 CSPRepResNet,由 N 个 RepResBlock 堆叠,如图 5(c)所示,在每个阶段,都使用 1×1 卷积跨阶段连接,避免了大量 3×3 卷积层带来的大量参数和计算负担。上文介绍的 ESE 层也用于在每个 CSPRepRes 阶段施加通道注意。

2.3 K-means 聚类先验框

在原始的 Mask R-CNN 的 RPN 部分,是在每个特征图的像素中预先设置 $3 \times 3 = 9$ 个先验框,这 9 个先验框默认的是 $\{128, 256, 512\}$ 3 个尺度,拥有 $\{1:1, 1:2, 2:1\}$ 3 种长宽比。但本文光学元件的划痕缺陷数据集长宽比例分布不均,且存在长宽比例很大的情况,如采用官方默认的先验框长宽比,容易出现漏检的情况;如在检测的时候采用旋转图片的方式来使图片的长宽比适合官方先验框的长宽比,费时费力,效果并不好,所以就需要重新设置先验框的长宽的比例。本文利用 K-means^[19]聚类的方法根据缺陷数据集中标注框的长宽的比例聚类出适合本数据集的先验框,高(Height)与宽(Width)的比例例如图 6 所示,其中黑色点是随机选的 200 个物体框的大小,三角为聚类结果,K-means 聚类出 25 组 anchor 的大小,其长宽比(Height/Width)分布如图 7 所示,所以本文选用 $\{1:1, 4:1, 8:1\}$ 3 种长宽比,兼顾了不同的 anchor 框的长宽比,提高了网络的召回率,加快了先验框收敛的速度,并减少了推理测试的时间。

2.4 改进的 Focal Loss 损失函数

原始 Mask R-CNN 的损失函数由 3 个部分组成:RPN 部分的损失、Fast R-CNN 部分的损失和 mask 分支部分的损失。Fast R-CNN 部分的损失又由分类的损失函数和预测框回归的损失函数组成,该网络物体分类的损失函数是交叉熵损失函数(cross entropy, CE),如式(1)所示,是

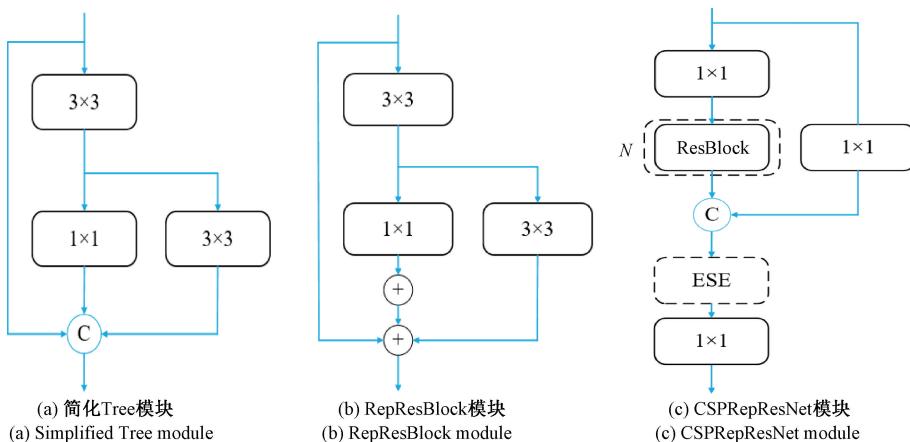


图 5 简化 Tree 模块, RepResBlock 和 CSPRepResNet 对比示意图

Fig. 5 Simplified Tree module, RepResBlock and CSPRepResNet comparison diagram

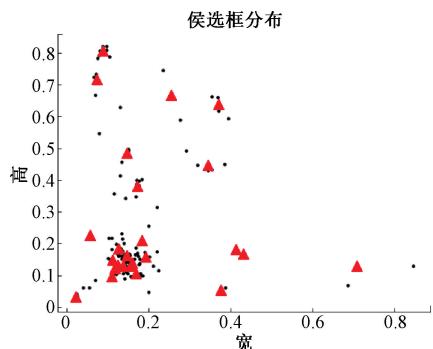


图 6 K-means 聚类出的先验框

Fig. 6 K-means clustered prior box

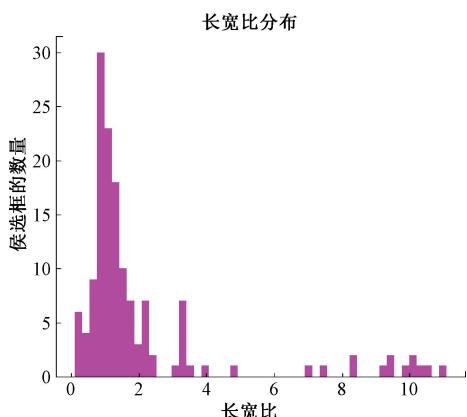


图 7 先验框长宽比示意图

Fig. 7 Length width ratio of prior frame

最常用的一种物体分类的损失函数。

$$CE(p_t) = -\log(p_t) \quad (1)$$

Focal Loss^[20]损失函数的公式如式(2)所示, 它在交叉熵损失函数的基础上新引入了 3 个参数: 引入了 α 权重, 是为了调节正负样本不平衡; $(1 - p_t)$ 是为了调节难

易样本的权重: 当一个边界框被误分类时, p_t 较小, 表明分类效果不好, 为困难样本, 则 $(1 - p_t)$ 接近于 1, 其损失几乎不受影响; 当 p_t 接近于 1 时, 表明是分类预测较好, 是简单样本, $(1 - p_t)$ 接近于 0, 其损失就被调低了, 这样就可以更好得训练困难样本; γ 是一个调质因子, γ 越大, 简单样本损失的贡献就会越低。

$$FL(p_t) = -\alpha(1 - p_t)^\gamma \log(p_t) \quad (2)$$

本文采用的光学元件缺陷数据集正负样本极不平衡, 而且大多数据集都是小目标的物体检测, 为困难样本的检测, 用交叉熵损失函数做物体分类的损失函数存在很大的误差, 虽然 Focal Loss 一般情况下有很好的效果, 但它也存在着问题, 样本中存在离群点, 可能模型已经收敛了但是这些离群点还是会被判断错误, 让模型去关注这样的样本, 会影响模型的鲁棒性, 因此本文对 Focal Loss 进行了改进, 提出梯度均衡机制 (gradient harmonizing mechanism, GHM)。难易样本的 loss 差别较大, 其实质是训练过程中梯度大小的差别, 本文定义了一个梯度模长 g (gradient norm), 如式(3)所示:

$$g = \|p - p^*\| = \begin{cases} 1 - p, & p^* = 1 \\ p, & p^* = 0 \end{cases} \quad (3)$$

式中: p 是模型预测的概率, p^* 是 ground-truth 的标签。

由式(3)可以发现, g 正比于检测样本的难易程度, g 越大则检测难度越大, 梯度模长和样本数量 (fraction of examples) 之间的分布统计如图 8 所示。

本文确实不应该过多关注易分样本, 但是特别难分的样本(离群点)也不该关注, 这些离群点的梯度模长 g 要比一般的样本大很多, 如果模型被迫去关注这些样本, 反而有可能降低模型的准确度, 所以需要同时衰减易分样本和特别难分的样本, 由图 8 可知, 梯度模长接近于 0 的样本数量最多, 随着梯度模长的增长, 样本数量迅速减少, 但是在梯度模长接近于 1 时, 样本数量也很多, 也就

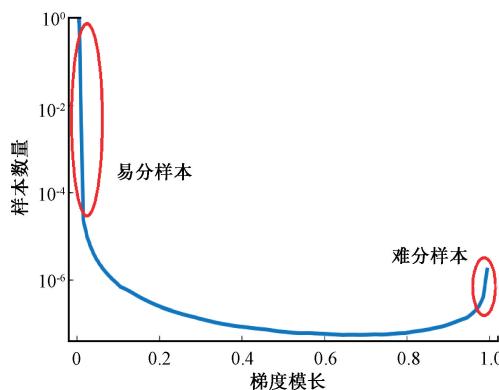
图 8 梯度模长 g 和样本数量的关系

Fig. 8 Gradient norm and fraction of examples

是说易分样本和特别难分的样本数量都很多,所以本文定义了梯度密度,让这个变量去衡量一定梯度范围内的样本数量,用来平衡易分样本和特别难分的样本,如式(4)所示。

$$GD(g) = \frac{1}{l_\varepsilon} \sum_{k=1}^N \delta_\varepsilon(g_k, g)$$

$$\text{其中: } \delta_\varepsilon(x, y) = \begin{cases} 1, & y - \frac{\varepsilon}{2} \leqslant y + \frac{\varepsilon}{2} \\ 0, & \text{其他} \end{cases}$$

$$l_\varepsilon = \min(g + \frac{\varepsilon}{2}, 1) - \max(g - \frac{\varepsilon}{2}, 0) \quad (4)$$

最终, GHM 得出进行分类的损失函数如式(5)所示,即 Focal Loss 除以梯度密度,梯度密度大的 loss 会被抑制,易分样本和特别难的样本都被抑制了,从而起到了样本均衡的作用。

$$L_{GHM-C} = \sum_{i=1}^N \frac{FL(p_i)}{GD(g_i)} \quad (5)$$

图 9 是 Cross Entropy(CE), FL(focal loss) 和 GHM-C 样本的原始梯度模长(original gradient norm)关于模型训练梯度贡献(total gradient contribution)的对比曲线图。

可以发现,候选样本中的简单负样本和非常困难的异常样本的权重都会被降低,即 loss 会被降低,对于模型训练的影响也会被大大减小,正常困难样本的权重得到提升,这样模型就会更加专注于那些更为有效的正常困难样本,以提升模型的性能,所以本文采用梯度均衡化的 Focal Loss 损失函数替换原来的交叉熵损失函数。

3 构建数据集

为采集到光学元件划痕缺陷数据集,搭建了显微暗室成像实验平台,该平台包括显微成像系统、照明光源、二维平移控制台以及数字成像系统等部分,示意图如图 10 所示,系统实物图如图 11 所示。将待测光学元件放

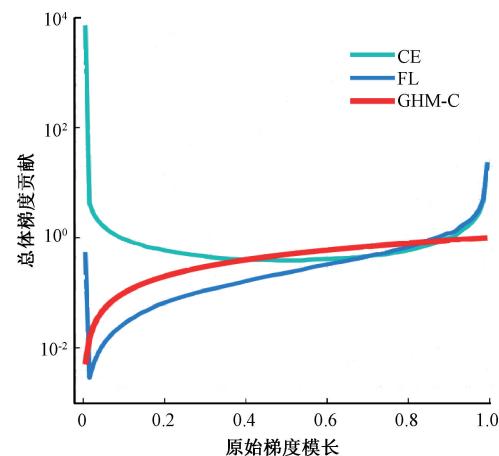


图 9 样本梯度修正

Fig. 9 Sample gradient correction

置在旋转台上,照明光源通过斜入射到光学表面,此时表面缺陷处产生的散射光进入显微成像系统,被显微镜头接收并放大后传输到探测器 CCD 上进行成像,采集到的是一幅暗背景的亮疵病图像,并由数据传输到数字成像系统中进行存储,作为实验的数据集,缺陷图片如图 12 所示,还可以通过平移控制台实现各个角度的精准定位,观察不同位置的表面缺陷,共采集到划痕缺陷数据 253 张,并利用标注软件进行了标注。

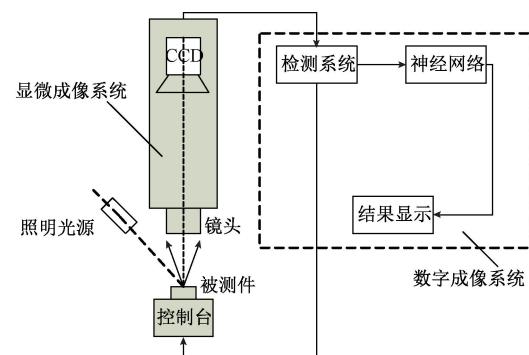


图 10 显微暗室成像实验平台

Fig. 10 Micro darkroom imaging experimental platform

4 实验与讨论

4.1 实验环境及参数设置

本实验均是在 Pytorch 深度学习框架下进行的,Pytorch 版本为 torch-gpu = 1.9.0, 代码语言为 Python3.8 版本, 并使用 GPU 加速训练, 配置相应的 CUDA 版本为 11.1, CUDNN 版本为 8.4。模型训练过程中,根据以往神经网络训练经验,均采用表 1 的参数进行训练。

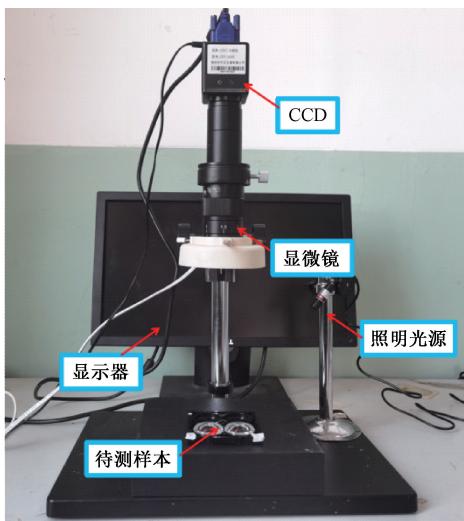


图 11 显微成像实验平台实物图

Fig. 11 Picture of microscope imaging experimental platform

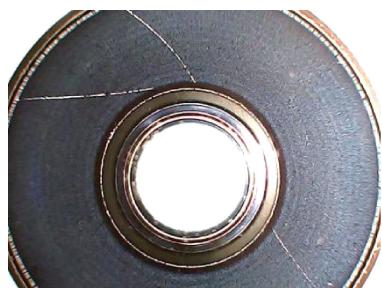


图 12 划痕缺陷数据

Fig. 12 Self built scratch defect data

表 1 网络模型参数设置

Table 1 Network model parameter settings

参数设置	说明
Batch_size = 4	批处理个数为 4
Epoch = 100	训练 100 轮数据
Learing_rate = 0.004	初始学习率为 0.004
SGD	优化器
Weight_decay = 0.0001	权重衰减系数为 0.0001

4.2 评估指标

在评估实例分割网络模型的检测效果时,通常会利用平均精度均值(mean average precision, mAP)来衡量,mAP 是要检测各个类别的平均准确率(average precision, AP)的均值,AP 是以精度(precision)为纵坐标,以召回率(recall)为横坐标围成的 PR 曲线的面积,而精度和召回率又与 TP(true positive)、FP(false positive)、TN(true negative)和 FN(false negative)4 个统计量相关^[21]。精度是从预测结果的角度来统计的,表示预测对象为实例的数据中,有多少个是真正的实例,如式(6)所示;召回率

是从真实的样本集来统计的,表示在总的实例中,模型找回了多少个实例,如式(7)所示。

$$precision = \frac{TP}{TP + FP} \quad (6)$$

$$recall = \frac{TP}{TP + FN} \quad (7)$$

另一个评价指标是推理速度,是在推理阶段,网络检测完同一张图片所需要的时间,本文命名为 Test_time(s),推理速度在实际场景中也比较重要,关乎网络的实时性,关乎使用生产的效率。

4.3 实验结果

实验分别针对更换 Backbone、添加 ESE 注意力机制、更换相应的先验框和更换损失函数 4 个改进措施设置对比实验,分析不同改进措施对网络检测效果的影响。

1) 更换 Backbone 对比实验

由表 2 可知,更换后的 CSPRepResNet 相比与 ResNet50 有更好的特征提取的能力,又由于加入了轻量化模型,推理速度几乎不受影响。

表 2 更换 Backbone 对网络性能的影响

Table 2 Impact of Backbone replacement on network performance

Backbone	mAP	Test_time/s
ResNet50	52.1%	0.080
CSPRepResNet	53.5%	0.085

2) 添加 ESE 注意力机制对比实验

ESE model 是即插即用模块,实验分别在 ResNet50 的 Conv1、Conv2、Conv3、Conv4 和这 4 个卷积层后面都添加 ESE model,如表 3 所示。

表 3 不同卷积层添加 ESE 对网络性能的影响

Table 3 The effect of adding ese to different convolution layers on network performance

Backbone	SE model (W/O)	mAP/%	Test_time/s
ResNet50	O	52.1	0.080
Conv1	W	52.8	0.085
Conv2	W	53.3	0.084
Conv3	W	53.8	0.085
Conv4	W	53.6	0.083
Conv-all	W	54.6	0.084

可见,分别在单个卷积层后面添加 ESE model 对网络的影响大致相同,在每个卷积层后面都添加 ESE model,对网络检测效果的提升最为明显,mAP 由原来的 52.1% 提升到了 54.6%,提升了 2.5%,检测时间增加并不明显,所以采用每层卷积后面都添加 ESE model 来构建改进 Mask R-CNN 的 Backbone 部分。

3) 重设先验框对比实验

根据标注数据集缺陷的长宽比例,利用 K-means 聚类出的先验框的长宽比例为 $\{1:1, 4:1, 8:1\}$,代替官方预设的 $\{1:1, 1:2, 2:1\}$ 3 种长宽比,实验结果如表 4 所示。

表 4 重设先验框对网络性能的影响

Table 4 Influence of replacement loss function on network performance

先验框	mAP/%	Test_time/s
预设先验框	52.14	0.080
重设先验框	53.13	0.078

可见,重设后的先验框更接近于数据集中标注框的长宽比,检测精度略有提升,也会提高推理的速度。

4) 更换损失函数对比实验

Focal Loss 损失函数是针对小样本困难样本提出的一种损失函数,梯度均衡化的 Focal Loss 在此基础之上又去除了离群点的影响,而本实验的数据集为光学元件的划痕缺陷,形状都比较微小且离群点较多,利用梯度均衡化 Focal Loss 损失函数代替交叉熵损失函数,将更有利用对困难样本的检测,并消除干扰点的影响,由表 5 也可明显地看出, mAP 由 52.1% 提升到 53.2%, 提到了检测精度。

表 5 更换损失函数对网络性能的影响

Table 5 Effect of Replacement Loss Function on Network Performance

Loss 函数	mAP/%	Test_time/s
Cross Entropy loss	52.1	0.080
梯度均衡化的 Focal Loss	53.2	0.082

5) 改进 Mask R-CNN 与其他网络对比

如图 13 所示,图例中“U-Net”为文献[8]所采用的网络模型,“改进 U²-Net”为文献[9]所采用的网络模型。该图是这两个模型与 Mask R-CNN 和本文改进 Mask R-CNN 网络模型在本文数据集下进行相同参数训练得到的网络检测效果图。

由于光学元件划痕缺陷通常尺寸微小,需要更精细的识别与分割,如图 13 所示,相较于 U-Net,Mask R-CNN 网络模型更适用于该缺陷的检测;虽然 U²-Net 相较于 U-Net,采用了更深、更宽的网络结构,检测的精度会有所提升,但该网络没有针对划痕缺陷长宽比比较大、易受离群点影响的问题提出相应的改进措施,检测精度不如改进后的 Mask R-CNN 网络模型。总体来说,改进后 Mask R-CNN 网络模型相比于 Mask R-CNN, mAP 由原来的 52.1% 提高到 57.3%, 提高了 5.2%, 相比于 U-Net 和 U²-Net 网络模型,检测精度也有明显提升,推理速度几乎不变,并且可以同时实现目标检测和语义分割,对于光学元

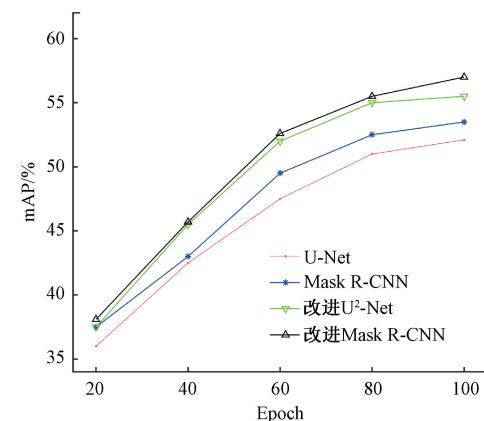


图 13 改进 Mask R-CNN 与其他网络检测效果对比

Fig. 13 Comparison of improved Mask R-CNN and other network detection results

件划痕缺陷有更好的检测效果。

4.4 分割图像结果对比

网络分割图像对比图如图 14 所示,第 1 列为待分割原图,第 2 列为 Mask R-CNN 分割结果图,第 3 列为模型改进后 Mask R-CNN 的分割结果图,改进后的网络对缺陷的拟合效果更好,边缘信息捕捉得更全面,可见,改进后的网络对划痕这类数据集有更好的检测效果。

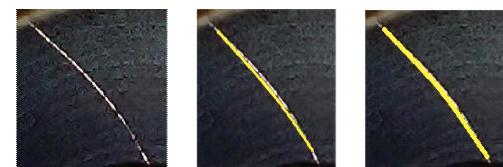


图 14 划痕缺陷数据分割图

Fig. 14 Scratch defect data segmentation diagram

5 结 论

本文为了解决光学元件划痕缺陷检测问题,充分调查和研究了之前的方法和技术,发现先前的技术并没有针对光学元件划痕的特点进行具体研究,检测的精度相对低下。为此,本文提出了采用 Mask R-CNN 深度学习算法模型对光学元件划痕缺陷识别与分割,并根据划痕缺陷尺寸小、长宽比较大、易受杂质影响的特点,对其进行改进。改进后 Mask R-CNN 网络模型检测的 mAP 由原来的 52.1% 提高到 57.3%, 且推理速度几乎不变。可见,改进后 Mask R-CNN 对光学元件划痕缺陷有更好的检测效果,基本可以满足工业场景下划痕缺陷的识别与分割任务。但本文只针对光学元件划痕这一种缺陷类型进行检测,对于各种缺陷类型的检测还需进一步研究。

参考文献

- [1] 向弋川,林有希,任志英.光学元件表面缺陷检测方法

- 研究现状[J]. 光学仪器, 2018, 40(1): 78-87.
- XIANG Y CH, LIN Y X, REN ZH Y. Research status of optical element surface defect detection methods [J]. Optical Instruments, 2018, 40 (1): 78-87.
- [2] 陆敏, 王治乐, 高萍萍, 等. 光学元件的疵病检测及现状[J]. 光学仪器, 2020, 42(3): 88-94.
- LU M, WANG ZH L, GAO P P, et al. Defect detection and status quo of optical elements [J]. Optical Instruments, 2020, 42 (3): 88-94.
- [3] 向江华. 光学表面疵病光照特性研究[D]. 西安: 西安工业大学, 2022.
- XIANG J H. Study on the light characteristics of optical surface defects [D]. Xi' an: Xi' an University of Technology, 2022.
- [4] 刘俊明, 孟卫华. 基于深度学习的单阶段目标检测算法研究综述[J]. 航空兵器, 2020, 27(3): 44-53.
- LIU J M, MENG W H. Overview of single-stage target detection algorithm based on deep learning [J]. Aviation Weapons, 2020, 27 (3): 44-53.
- [5] SOUKUP D, HUBER-MÖRK R. Convolutional neural networks for steel surface defect detection from photometric stereo images [C]. Advances in Visual Computing: 10th International Symposium, ISVC 2014, Las Vegas, NV, USA, December 8-10, 2014, Proceedings, Part I 10. Springer International Publishing, 2014: 668-677.
- [6] PARK J K, KWON B K, PARK J H, et al. Machine learning-based imaging system for surface defect inspection [J]. International Journal of Precision Engineering and Manufacturing-Green Technology, 2016, 3: 303-310.
- [7] Engineering-concurrent engineering. Study results from North University of China Broaden Understanding of Concurrent Engineering (Conjugate gradient neural network based on line recognition of glass defects) [J]. Journal of Engineering, 2017: 757-761.
- [8] 郭瑞琦, 王明泉, 张俊生, 等. 基于深度学习的汽车轮毂缺陷自动分割技术[J]. 科学技术与工程, 2020, 20(24): 9976-9981.
- GUO R Q, WANG M Q, ZHANG J SH, et al. Automatic segmentation of wheel hub defects based on deep learning [J]. Science and Technology and Engineering, 2020, 20 (24): 9976-9981.
- [9] 陈其浩, 孙林, 张倩. 基于改进 U²-Net 的透明件划痕检测方法[J]. 科学技术与工程, 2022, 22(2): 620-627.
- CHEN Q H, SUN L, ZHANG Q. Scratch detection method for transparent parts based on improved U²-Net [J]. Science and Technology and Engineering, 2022, 22 (2): 620-627.
- [10] PAN Z F, YANG J, WANG X, et al. Image-based surface scratch detection on architectural glass panels using deep learning approach [J]. Construction and Building Materials, 2021, 282.
- [11] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017: 2961-2969.
- [12] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. Advances in Neural Information Processing Systems, 2015, 28.
- [13] HU J, SHEN L, SAMUEL A, et al. Squeeze and excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018: 7132-7141.
- [14] LEE Y, PARK J. Center Mask: Real-time anchor free instance segmentation [J]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020: 1492-1500.
- [15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [16] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700-4708.
- [17] LEE Y, HWANG J, LEE S, et al. An energy and GPU-computation efficient backbone network for real-time object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2019.
- [18] RAO L. TreeNet: A lightweight one-shot aggregation convolutional network [J]. arXiv preprint arXiv: 2109.12342, 2021.
- [19] DEVIKA T J, RAVICHANDRAN J. A clustering method combining multiple range tests and K-means [J]. Communications in Statistics-Theory and Methods, 2022, 51(21): 7322-7339.
- [20] LIN T Y, PRIYA G, ROSS G, et al. Focal loss for dense object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42 (2): 318-327.
- [21] 丁志江, 李丹, 马志程, 等. 基于 Transformer 的车道线分割算法研究[J]. 电子测量与仪器学报, 2022, 36(10): 227-234.
- DING ZH J, LI D, MA ZH CH, et al. Research on lane line segmentation algorithm based on transformer [J].

Journal of Electronic Measurement and Instrumentation,
2022, 36 (10): 227-234.

作者简介



马志程, 2020 年于辽宁石油化工大学获得学士学位, 现为天津科技大学硕士研究生。主要研究方向为光电检测与计算机视觉检测。

E-mail: 1826831029@qq.com

Ma Zhicheng received his B. Sc. degree in 2020 from Liaoning Shihua University. Now he is a M. Sc. candidate at Tianjin University of Science & Technology. His main research interests include photoelectric detection and computer vision detection.



李丹(通信作者), 1999 年于南开大学获得学士学位, 2002 年于南开大学获得硕士学位, 2007 年于香港大学获得博士学位, 现为天津科技大学副教授, 硕士生导师。主要研究方向为光电检测与计算机视觉检测。

E-mail: lidan@tust.edu.cn

Li Dan (Corresponding author) received B. Sc. degree in

1999 from Nankai University, received M. Sc. degree in 2002 from Nankai University and received Ph. D. degree in 2007 from Hong Kong University. Now she is an associate professor and a M. Sc. advisor at Tianjin University of Science & Technology. Her main research interests include photoelectric detection and computer vision detection.



张宝龙, 1999 年于南开大学获得学士学位, 2001 年于香港科技大学获得硕士学位, 2006 年于香港科技大学获得博士学位, 现为天津科技大学教授, 硕士生导师, 研究方向为集成电路设计及半导体制备工艺的研究。

E-mail: eezbl@tust.edu.cn

Zhang Baolong received his B. Sc. degree in 1999 from Nankai University, received his M. Sc. degree in 2001 from Hong Kong University of Science & Technology and received his Ph. D. degree in 2006 from Hong Kong University of Science & Technology. Now he is a professor and a M. Sc. advisor at Tianjin University of Science & Technology. His main research interests include IC design and semiconductor fabrication process.