

DOI: 10.19650/j.cnki.cjsi.J2006915

基于深度学习的航天密封圈表面缺陷检测*

陶晓天¹, 何博侠¹, 张鹏辉¹, 田德旭¹
(南京理工大学机械工程学院 南京 210094)

摘要:针对航天密封圈表面缺陷人工检测效率低、传统图像处理检测算法通用性差的问题,提出了两种基于深度学习的密封圈表面缺陷检测算法。首先,针对缺陷大部分为小目标的特点,选取对小目标较敏感的 RetinaNet 网络作为检测算法的基本架构,通过在 RetinaNet 网络中引入轻量级网络 MoGaN 构建出 MoGaN-RetinaNet 算法。然后,为了提高检测精度,在 MoGaN-RetinaNet 基础上,用分解卷积模块代替 MoGaN 骨干网络中的深度卷积构建了 newMoGaN 骨干网络,设计出 newMoGaN-RetinaNet 算法。最后,在测试集上的实验结果表明,MoGaN-RetinaNet 算法比 RetinaNet 算法检测速度更快,但检测准确率略低;而 newMoGaN-RetinaNet 算法实现了检测精度与检测速度的良好平衡,比 RetinaNet 算法准确率提升 4.5%,达到 92%,检测速度提升 55%,达到 31 frame/s,网络参数量减少 50%。所设计的新 MoGaN-RetinaNet 算法可以实现密封圈表面缺陷的快速准确检测。

关键词: 航天密封圈;深度学习;分解卷积;RetinaNet;缺陷检测

中图分类号: TP391.4 TH878 文献标识码: A 国家标准学科分类代码: 510.4050

Surface defect detection of aerospace sealing rings based on deep learning

Tao Xiaotian¹, He Boxia¹, Zhang Penghui¹, Tian Dexu¹

(School of Mechanical Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: Aiming at the problems of low aerospace seal ring surface defect detection efficiency of manual inspection and poor versatility of traditional image processing detection algorithms, two kinds of deep learning based surface defect detection algorithms for aerospace sealing rings are proposed. Firstly, aiming at the characteristic that most of the defects are small targets, the RetinaNet network that is more sensitive to small targets is selected as the basic architecture of the defect detection algorithm, and the MoGaN-RetinaNet algorithm is constructed by introducing the lightweight network MoGaN into the RetinaNet network. Secondly, in order to improve the detection accuracy, on the basis of MoGaN-RetinaNet, the newMoGaN backbone network is constructed using the decomposition convolution module to replace the depthwise convolution in the MoGaN backbone network, and the newMoGaN-RetinaNet algorithm is designed. Finally, the experiment results on the test set show that the MoGaN-RetinaNet algorithm has faster detection speed but slightly lower detection accuracy compared with the RetinaNet algorithm; the newMoGaN-RetinaNet algorithm achieves a good balance of detection accuracy and detection speed. Compared with those of RetinaNet algorithm, the detection accuracy rate increases by 4.5%, reaches to 92%; the detection speed increases by 55%, reaches to 31 frame/s; and the number of network parameters is reduced by 50%. The newly designed newMoGaN-RetinaNet algorithm can achieve fast and accurate detection of the seal ring surface defects.

Keywords: aerospace seal ring; deep learning; decomposition convolution; RetinaNet; defect detection

0 引言

密封圈是一种常见的橡胶密封元件,因其具有优良的密封性、耐腐蚀性以及经济适用性被广泛用于航空航

天器中,其中最常见的是 O 型密封圈(下文“密封圈”特指航天器用 O 型密封圈)。密封圈的表面缺陷是表面质量评价的核心指标,不符合 CS 级标准的表面缺陷都可能导致密封失效,从而引起航空器、航天器密封系统故障,甚至造成灾难性事故^[1-2],因此,确保密封圈的表面质量

收稿日期:2020-09-16 Received Date:2020-09-16

* 基金项目:国家自然科学基金(51575281)、中央高校基本科研业务费专项资金(30916011304)项目资助

尤为重要。

目前,针对密封圈表面缺陷的检测方法主要有人工目测法、传统图像处理方法、浅层机器学习法等。人工目测法^[3]首先通过人眼检测缺陷,发现问题后再用工具显微镜或投影仪复核,在大批量检测情况下,这种检测方式易使眼睛疲劳,检测稳定性差,且检测效率低。传统的图像处理方法主要采用模板匹配法提取密封圈表面缺陷特征,通过计算缺陷的周长或者面积来判断缺陷特征的尺寸是否在规定范围内,从而确定橡胶圈是否存在缺陷^[4-5]。由于密封圈表面为全向曲面,视觉成像时存在高亮区域和深暗区域,图像的一致性差,且缺陷位置随机性强,轮廓多变,上述传统图像处理方法存在通用性差的问题。在浅层机器学习领域,Peng等^[6]提出了一种基于机器视觉的检测方法,该方法利用完全核Fisher判别分析(complete kernel fisher discriminant analysis)对O形圈的4种典型缺陷进行检测。Hong等^[7]提出了一种基于聚类分析的密封圈缺陷检测算法,缺陷检测样本包括500个密封圈图像,提出的算法检测准确率很高。然而,利用浅层机器学习法检测密封圈表面缺陷时,由于隐层网络较浅无法提取出密封圈表面复杂的缺陷特征,导致该方法表达能力弱,同时,当一幅密封圈图像包含多类缺陷时,上述浅层机器学习模型存在无法对缺陷进行正确分类的问题。

近年来,深度卷积神经网络凭借其特征学习和迁移学习的强大能力在图像分类方面取得了一系列突破,在目标检测方面,它越来越受到人们的重视^[8],被广泛应用于目标检测等领域。He等^[9]提出了一种新的分类优先网络和一种新的多组卷积神经网络来检测热轧钢板表面缺陷,实验结果表明,与以往用于钢板表面缺陷的检测方法相比,性能更好,在生产线上的分类率达到96%以上。Yu等^[10]提出了一种基于YOLOv3改进的齿轮缺陷检测网络(smoothing-YOLOv3, S-YOLO),在S-YOLO网络结构中,在网络前端加入图像平滑层,以减弱生产过程中齿轮图像采集的背景噪声,结果表明,S-YOLO比YOLOv3目标识别网络对复杂背景下的微小缺陷具有更好的识别能力。Mei等^[11]提出了一种新的无监督学习模型,该模型能够处理纺织物表面不同类型的缺陷,是一种多尺度卷积去噪自编码结构。李晖晖等^[12]针对图像上舰船目标尺寸较小等特点,在SSD网络中添加CReLU、特征金字塔网络设计了新算法,实验结果表明,新算法检测精度较SSD网络有10%的提升。总之,深度学习算法可以准确定位缺陷位置,并且通过多层次网络架构对原始输入图像数据进行逐层提取与抽象,获取的特征能更好的表达图像所包含的信息^[13],具有较强的泛化能力。

本文针对密封圈表面缺陷大部分为小目标,选取包含特征金字塔结构的RetinaNet算法作为基本架构,通过

在其网络中引入轻量级网络MoGaA,构建出MoGaA-RetinaNet算法,为了提高检测精度,将分解卷积模块和标准卷积模块引入MoGaA-RetinaNet网络,构建出新MoGaA-RetinaNet算法,并与经典的SSD、RetinaNet算法作比较,证实本文算法具有最佳的缺陷检测性能。

1 密封圈表面缺陷检测算法设计

通过对数据集中密封圈表面缺陷的特征分析,发现密封圈表面大部分缺陷具有小目标特点,即缺陷标注面积小于1024(32×32)pixel,符合小目标特点的缺陷有飞边、杂质和流痕,如图1所示。在运用深度学习算法检测目标时,小目标难以检测,原因如下:1)由于小目标分辨率低,图像模糊,携带的信息较少,导致特征表达能力弱,卷积神经网络能提取到的特征很少,不利于小目标检测,2)在目标检测模型中,输入图像经过骨干网络的数次下采样操作到达分类回归层时,部分小目标特征的感受野映射回原图会大于小目标在原图的尺寸,造成检测效果差。因此,针对小目标特性,在对小目标检测识别时,通常会在骨干网络与分类回归网络之间加上特征金字塔网络(feature pyramid network, FPN),FPN通过融合高低不同维度的特征图信息,使小目标在低层特征图上具有较大分辨率和丰富的语义信息,从而提高小目标质量。RetinaNet^[14]算法包含特征金字塔结构,具备高效检测小目标的能力,并且在coco数据集上实验结果表明,RetinaNet相比一阶段法(SSD, DSSD等)和二阶段法(Faster RCNN等),性能更好,故选用RetinaNet作为密封圈缺陷检测网络的基本架构。

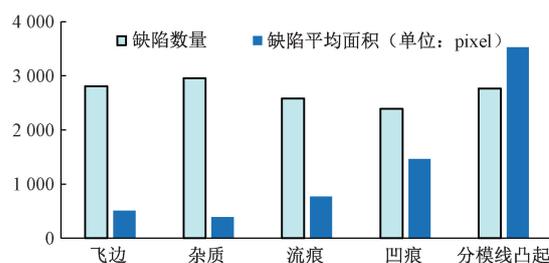


图1 密封圈数据集5类缺陷统计

Fig. 1 Statistic of five types of defects in seal ring data set

1.1 MoGaA-RetinaNet 网络结构

由于更大的骨架网络带来高精度检测的同时,检测速度会下降,为了满足实时检测的要求,本文选用轻量级网络MoGaA^[15](MobileGPU-Aware-A, MoGaA)作为RetinaNet的骨干网络,设计出MoGaA-RetinaNet检测算法。

新模型MoGaA-RetinaNet的设计思想是用MoGaA特征图提取网络代替传统RetinaNet算法的骨干网络

ResNet。如图 2 所示,MoGaA 网络的主干部分由虚线以下 14 个倒置残差模块构成。倒置残差模块的结构如图 3(a) 所示,其输入为 X , 输出为 $X\sim$, 由深度可分离卷积^[16-17]单元 (depthwise separable convolutions)、残差单元^[18] (residual module)、及挤压激励^[19] (squeeze-and-excitation, SE) 单元组成。

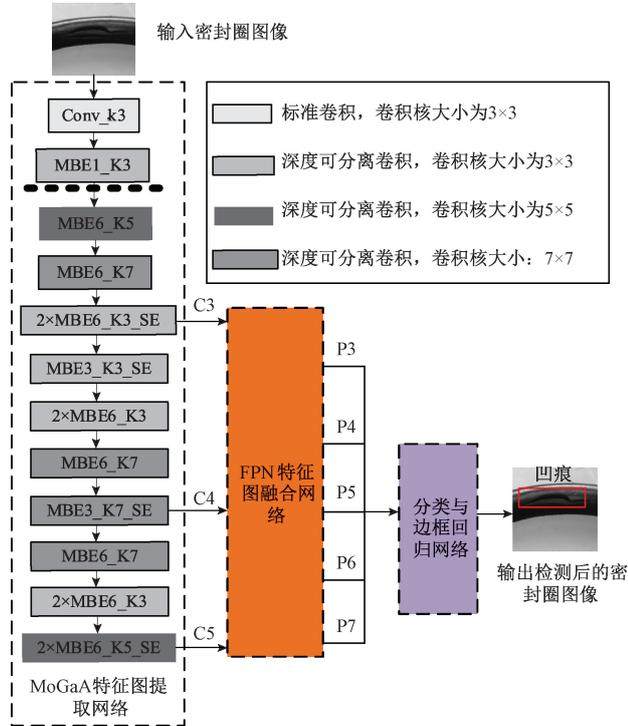


图 2 MoGaA-RetinaNet 网络结构

Fig. 2 The network structure of MoGaA-RetinaNet

如图 2 所示,MoGaA-RetinaNet 模型分别从第 4、9、14 层倒置残差模块输出特征图 C3、C4、C5 至 FPN 网络, C3、C4、C5 特征图的大小分别为 $40\times 40\times 160$ 、 $20\times 20\times 80$ 和 $10\times 10\times 160$ 。FPN 特征图融合网络先将尺度最小的特征图 C5 经过一系列卷积操作得到 P5。为了实现不同深度信息的融合,再将 P5 通过 2 倍上采样操作,放大到原来大小的 2 倍,然后与经过卷积操作的 C4 结合得到 P4, P4 再通过 2 倍上采样操作,放大到原来大小的 2 倍后与经过卷积操作的 C3 结合得到 P3。最后,为了提取深层次的语义信息,P5 通过两次 3×3 卷积操作得到 P6 和 P7。FPN 网络共产生 P3~P7 五张特征图,分别输入至分类和边框回归网络,从而得到密封圈缺陷的位置和类别信息。图 2 中的 MBE_x-K_y-SE, Ex 表示扩展层的扩展速率为 x , K_y 表示深度卷积层 (depthwise convolution) 卷积核的大小为 y , SE 为挤压激励层。

1.2 newMoGaA-RetinaNet 网络结构

分解卷积由 GoogLeNet^[20] 网络中提出,该网络大部分收益来自于大量的使用降维,这是一种高效率的计算方式,是分解卷积的特例,设计原则来源于空间聚合可以通过低维嵌入,这种嵌入不会导致网络表示能力的降低。例如在进行大尺寸的卷积 (如 3×3) 之前,可以在空间聚合前先对输入信息进行降维处理,如,在输入 3×3 卷积前经过 1×1 卷积处理,使用 1×1 的卷积,主要是 3 点作用:1) 对输入进行降维,如果这些信号是容易压缩的,那么降维可以加快学习速度;2) 卷积后要经过激活函数,引入了更多的非线性,可以解耦合更多的特征,那么网络就会训练的更快,提高泛化能力;3) 提高网络的深度,增强网络提取特征的能力。

深度可分离卷积其基本思想是用因子化的方法拆分标准卷积,将标准卷积分成两个独立的层,第 1 层称为深度卷积 (depthwise convolution),它通过在每个输入通道上应用单卷积滤波器来实现轻量级滤波。第 2 层是 1×1 卷积,称为逐点卷积 (pointwise convolution),负责将输入通道线性组合来构建新特征。虽然可以降低网络的计算量,但由于参数的大幅削减,网络结构的过分剪枝,当目标类间相似度高,类内差异性大时,网络难以提取出目标丰富的语义信息,参数难以刻画目标类间的微小差异,会导致模型表达能力差。

与深度卷积相比,分解卷积模块可以充分挖掘并抽象通道间的细粒度几何特征,从而提高整体网络检测缺陷的能力,因此,用分解卷积模块替代 MoGaA 网络中残差模块中的深度卷积,设计出了 newMoGaA 骨干网络,其网络结构如图 4 中左侧虚线框所示,该网络由两个 3×3 的标准卷积模块和 14 个倒置残差模块构成。如图 3(b) 所示,一个倒置残差模块的分解卷积由两部分构成,第 1 部分使用 1×1 卷积对输入 L_1 进行降维,输出 O_1 通道数

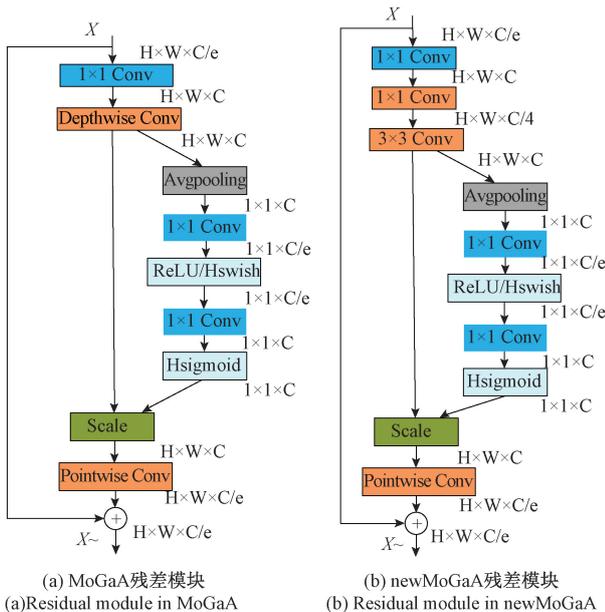


图 3 残差模块结构

Fig. 3 The structure of residual modules

为输入 L_1 通道数的 $1/4$;第2部分再通过 3×3 卷积对 O_1 进行升维,输出 O_2 通道数与 L_1 保持一致,最后,将 newMoGaA 与 RetinaNet 网络结合,设计出了 newMoGaA-RetinaNet 目标检测算法,设计思想与 MoGaA-RetinaNet 类似。为了提升模型提取密封圈表面缺陷语义几何特征的能力,在 FPN 输出特征图的 P3、P4 和 P5 层添加标准卷积模块,每个模块由 3 个 3×3 标准卷积构成,为了减少模型的时间复杂度,将 5×5 和 7×7 的卷积核改成 3×3 大小,newMoGaA-RetinaNet 网络结构如图 4 所示。

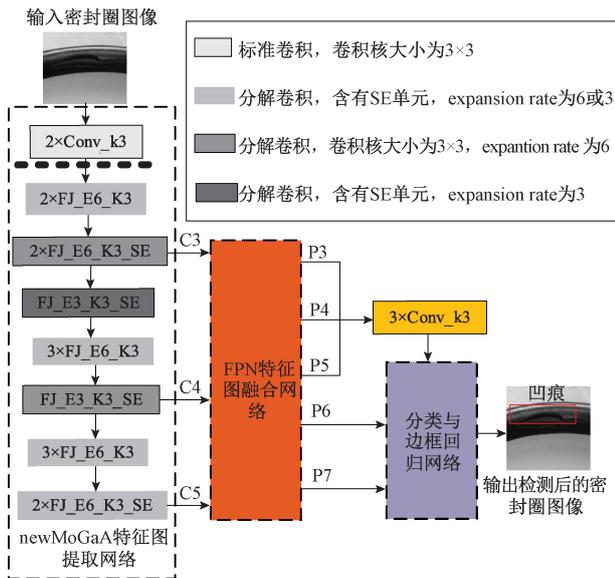


图4 newMoGaA-RetinaNet 网络结构

Fig. 4 The network structure of newMoGaA-RetinaNet

1.3 损失函数焦点损失

在本文提出的新算法中,首先骨干网络将特征图输入到分类和回归子网中,借助损失函数反映网络输出值与期望值的误差,然后根据损失值来反向传播求梯度,更新网络权重,使前向传播误差越来越小,从而训练出的模型能更准确检测目标,本文中边框回归网络和分类网络的损失函数继承了 RetinaNet 网络的损失函数,其中分类网络的损失函数为焦点损失 (focal loss),焦点损失的提出是为了解决目标检测场景中,训练期间正负样本不平衡带来的分类不准确问题。焦点损失如式(1)所示。

$$FL(p_i) = -\alpha_i (1 - p_i)^\gamma \log(p_i) \quad (1)$$

$$p_i = \begin{cases} p, & y = 1 \\ 1 - p, & \text{其他} \end{cases} \quad (2)$$

式中: α 和 γ 为超参数,用于调节难易样本影响损失函数的权重,目的是使困难样本对损失函数的贡献相对较大,使易检测样本对损失函数贡献较小,一般取值为 0.25 和

2 ; p_i 为二分类情况下对应的模型估计概率; p 是模型估计的概率; $y = 1$ 为真实标签。

2 实验与结果

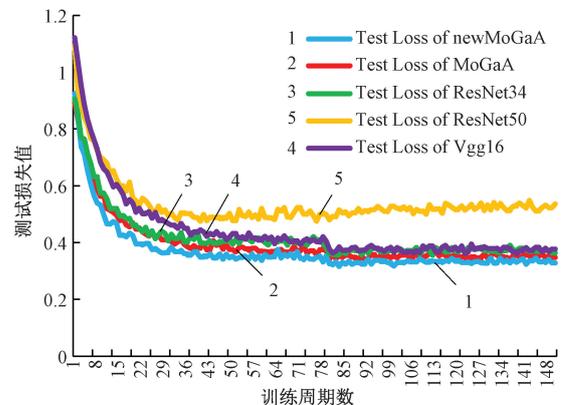
2.1 数据集制作

密封圈数据集(命名为 O-rings-4000 数据集):根据 GB/T3452 中 CS 级标准和航空航天工程实际需求,缺陷类型分为飞边、流痕、杂质、凹痕、分模线凸起,共 5 类,总计 4 000 张 O 型密封圈表面缺陷图像,每一张图像最少含有一种缺陷,然后利用标注工具按 PASCAL VOC 数据集的标注格式对图像进行标注,生成 XML 类型的标注文件。又根据训练不同模型需要,利用 python 将 XML 格式的数据集转换成 CSV 类型的标注文件。

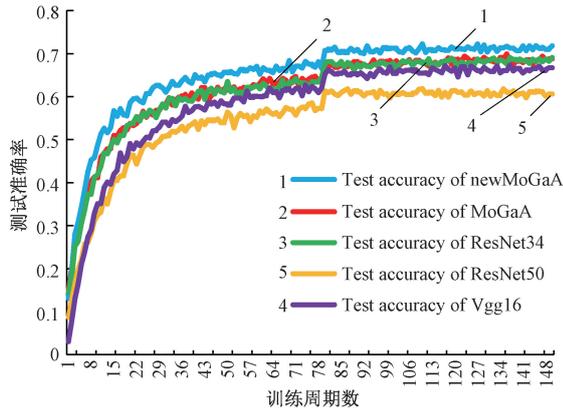
本文算法是基于 pytorch 实现的,实验所用计算机配置为:CPU: Intel (R) Core (TM) i5-6500 3.20 GHz 4.00 G, GPU: NVIDIA GTX 1080Ti。使用的操作系统为 Ubuntu16.04,安装了 CUDA 和 cuDNN 库。

2.2 骨干网络实验对比

一般来说,模型整体性能的好坏与骨干网络性能呈正相关。本文基于 MoGaA 算法提出了 newMoGaA 骨干网络,为了验证该网络的性能,将其与 MoGaA、ResNet34、ResNet50 以及 Vgg16 算法进行实验对比,考虑到硬件的性能,选择 miniImageNet 数据集进行模型训练和测试,共 60 000 张图像分为 100 类别。为保证结果的科学性,各模型训练和优化的超参数相同,优化器选用随机梯度下降 (stochastic gradient descent, SGD) 算法;动量:0.9;权重衰减: 10^{-5} ;批张数:16;损失函数:交叉熵损失函数,训练 150 个 epoch,初始学习率为 0.001,分别在 80, 120, 140epoch 分别减小到当前值的 $1/10$ 。在上述的超参数条件下,5 个骨干网络的测试结果如图 5 所示。



(a) 5种骨干网络损失值训练记录
(a) The training records of the loss values of five backbone networks



(b) 5种骨干网络分类准确率训练记录
(b) The training records of the classification accuracies of five backbone networks

图 5 骨干网络训练记录

Fig. 5 The training records of backbone networks

从图 5(a)可以看出,本文所提出的 newMoGaA 骨干网络的收敛速度快于其余网络,收敛的损失值与其余网络相比也是最小。图 5(b)显示,newMoGaA 检测精度在 5 种网络中最高,测试准确率与 MoGaA 网络相比,高出 3%,达到 72.3%,与主流的骨干网络 Vgg16、ResNet 相比,在具有更少参数数量和计算量的情况下,检测精度更高,5 种网络的实验结果如表 1 所示。

2.3 整体网络实验对比

为了验证本文新设计的密封圈表面缺陷检测算法在航天密封圈上检测缺陷的性能,在 O-rings-4000 密封圈

表 1 5 种骨干网络在 miniImageNet 数据集上的实验结果
Table 1 Experiment results of five backbone networks on miniImageNet dataset

模型	参数量/M	计算量/G	模型内存/MB	测试准确率/%
newMoGaA	12.5	3.47	52.4	72.27
MoGaA	3.97	0.92	16.2	69.25
ResNet34	26.39	7.49	85.5	67.91
ResNet50	43.93	8.37	95.1	64.87
Vgg16	19.83	31.32	79.3	66.98

数据集上,按照 8:1:1 的比例将数据集划分为训练集 3 200 张、验证集 400 张、测试集 400 张。为验证 newMoGaA 骨干网络提取特征的能力,将其代替 SSD 算法的原有骨干网络设计出了 newMoGaA-SSD 密封圈表面缺陷检测算法。综上,新设计的算法分别为 newMoGaA-SSD、newMoGaA-RetinaNet、MoGaA-RetinaNet 3 种,将该 3 种算法与经典的 ResNet50-RetinaNet、Vgg16-SSD 算法做对比,在密封圈测试集上的实验结果如表 2 所示,5 种网络训练时在验证集上收敛性结果如图 6 所示,一共迭代 120 000 次,每迭代 1 000 次,在密封圈验证集上测 1 次损失值和准确率。为了保证实验结果的科学性,对比所使用训练集、验证集、测试集均相同,各模型训练和优化的超参数也相同,如表 3 所示。

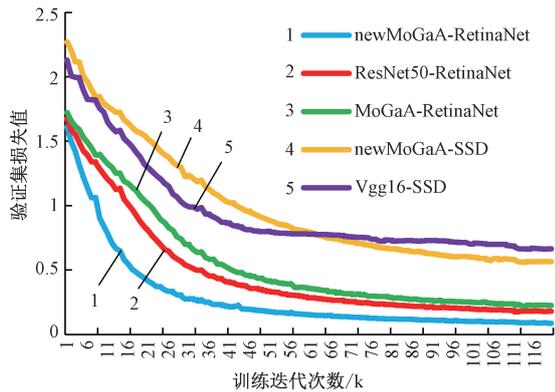
表 2 五种模型在密封圈数据集上的实验结果

Table 2 Experiment results of five models on seal ring data set

模型	骨干网络	参数量 /M	计算量 /G	平均准确率(AP)/%					平均准确率 均值(mAP)/%	检测速度 (frame·s ⁻¹)
				飞边	杂质	流痕	凹痕	分模线凸起		
RetinaNet	newMoGaA	26.65	10.41	86.7	84.9	94.3	95.9	98.2	92.00	31
RetinaNet	MoGaA	16.34	6.94	78.6	78.2	85.3	83.1	86.8	82.33	33
RetinaNet	ResNet50	51.15	20.59	83.8	81.6	87.9	91.9	92.1	87.46	20
SSD	newMoGaA	17.22	6.58	45.7	52.8	72.6	80.4	82.5	66.80	23
SSD	Vgg16	24.27	30.62	33.5	44.8	58.9	71.6	76.8	57.13	16

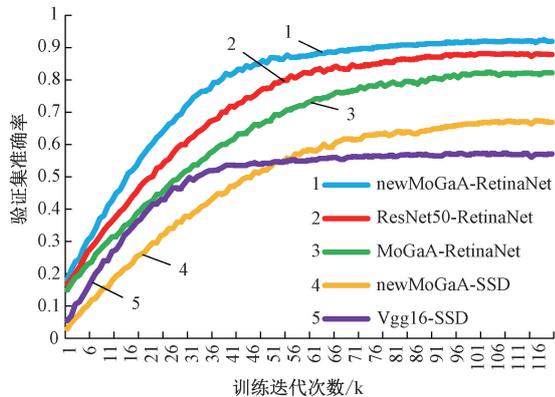
图 6 表明,本文提出的 newMoGaA-RetinaNet 网络的收敛速度快于其余网络,收敛的损失值也是最小。newMoGaA-RetinaNet 检测精度在五种网络中也是最高。从表 2 的实验结果可以看出,本文提出的 MoGaA-RetinaNet 算法实现了轻量化网络结构以及实时检测,与 ResNet50-RetinaNet 相比,检测速度提升 65%,但检测精度略低;newMoGaA-RetinaNet 算法实现了密封圈表面缺陷的实时和准确检测,检测速度达到 31 frame/s,检测精度达到 92%,与 ResNet50-RetinaNet 相比,检测速度提升

55%,检测精度提升 4.5%,计算量与参数量减少近 50%。newMoGaA-RetinaNet 检测密封圈表面缺陷性能优于 newMoGaA-SSD 算法,充分验证了 RetinaNet 网络架构下模型检测小目标的有效性;newMoGaA-SSD 与 Vgg16-SSD 算法相比,性能更好,验证了 newMoGaA 骨干网络提取特征的能力较强。如图 7 所示,newMoGaA-RetinaNet 算法对 5 类缺陷的检测结果均优于其他 4 种方法,且都获得了较高的检测精度。综上所述,选用 newMoGaA-RetinaNet 作为密封圈表面缺陷检测算法。图 8 所示为测



(a) 5种检测网络损失值收敛曲线

(a) Convergence curves of the loss values of five detection networks



(b) 5种检测网络分类准确率收敛曲线

(b) Convergence curves of the classification accuracies of five detection networks

图6 5种检测网络收敛曲线对比

Fig. 6 Comparison of the convergence curves of five detection networks

表3 5种模型训练和优化的超参数
Table 3 Hyperparameters for the training and optimization of five models

数据集	O-rings-4000;共5类
批张数(batchsize)	16
最大迭代次数	120 000
优化器	SGD 算法
动量(momentum)	0.9
权重衰减系数(weight decay)	0.000 5
初始学习率	0.001
置信度(confidence)	0.5
模型输入图像尺寸/pixel	320×320

可以看出,与其他算法相比,newMoGaA-RetinaNet 算法定位缺陷位置更准,漏检率更低。

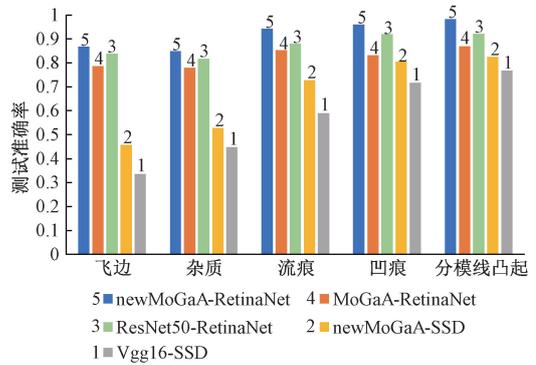
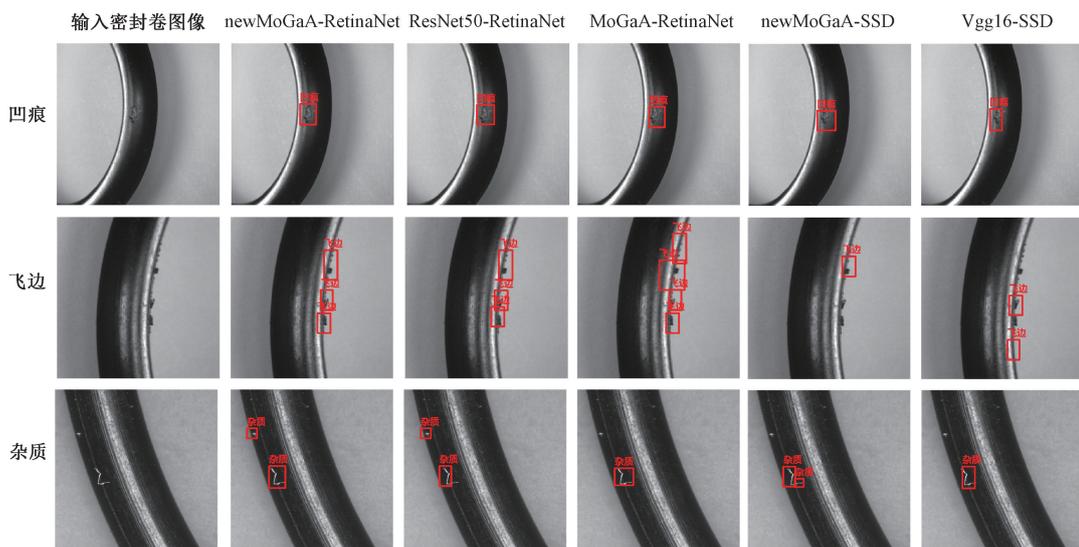


图7 在测试集上各模型检测不同类型缺陷的准确率

Fig. 7 The accuracies of various models in detecting different types of defects on test dataset

试集部分典型图像在不同模型上测试的结果,由图8可



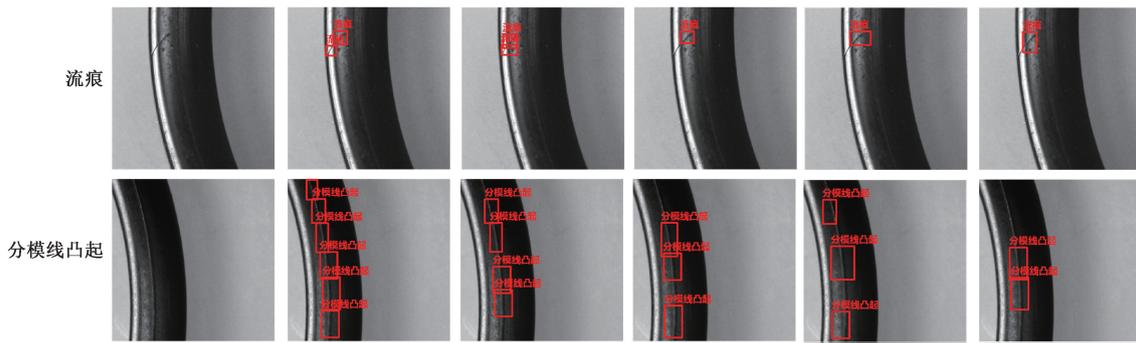


图 8 测试集部分图像在不同模型上测试的结果

Fig. 8 The test results of some images in the test dataset for different models

3 结 论

本文建立了 O-rings-4000 密封圈数据集,标注了 5 类常见航天航空密封圈表面缺陷,为了实现实时准确检测缺陷,基于轻量级网络 MoGaA 并结合分解卷积思想设计出了 newMoGaA 骨干网络,在开源数据集 miniImageNet 上的实验表明,与其他经典网络相比,newMoGaA 网络分类准确率最高,达到 72%,针对密封圈表面大部分缺陷为小目标的特点,基于 RetinaNet 网络架构设计了 MoGaA-RetinaNet 与 newMoGaA-RetinaNet 密封圈表面缺陷检测算法,在 O-rings-4000 数据集上的实验结果表明,与其他检测算法相比,newMoGaA-RetinaNet 算法实现了检测精度与检测速度的良好平衡,检测 5 类缺陷的平均准确率达到 92%,检测速度达到 31 frame/s, newMoGaA-RetinaNet 算法能够实现实时准确检测密封圈表面缺陷。

参考文献

- [1] GUO W, CUI W, YU T, et al. O-ring static sealing reliability model and influence factors analysis [C]. Proceedings of 2013 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering, 2013: 116-121.
- [2] CHANDRASEKARAN C. Rubber seals for fluid and hydraulic systems [M]. Burlington: Elsevier Inc, 2010.
- [3] 李晓舟,于化东,于占江,等. 微小尺寸零件表面缺陷光学检测方法[J]. 兵工学报, 2011,32(7):872-877. LI X ZH, YU H D, YU ZH J, et al. Optical inspection method for surface defects of micro-components [J]. China Ordnance Society, 2011,32(7):872-877.
- [4] 利新琴. 基于机器视觉的密封橡胶圈缺陷检测的研究[D]. 合肥:合肥工业大学,2009. LI X Q. Research for detecting the rubber ring defects based on machine vision [D]. Hefei: Hefei University of Technology, 2009.
- [5] 江伟荣. 基于机器视觉的橡胶密封圈检测的研究[D]. 合肥:合肥工业大学,2012. JIANG W R. Research on machine vision-base detection of the of rubber sealing rings [D]. Hefei: Hefei University of Technology, 2012.
- [6] PENG G L, ZHANG Z J, LI W Q. Computer vision algorithm for measurement and inspection of O-rings[J]. Measurement, 2016, 94: 828-836.
- [7] HONG T, LIANG W J. Research on seal ring defects inspection algorithm based on clustering analysis [J]. Information Technology Journal, 2013, 12 (18): 4805-4811.
- [8] 范丽丽,赵宏伟,赵浩宇,等. 基于深度卷积神经网络的目标检测研究综述 [J]. 光学精密工程, 2020, 28(5):1152-1164. FAN L L, ZHAO H W, ZHAO H Y, et al. Survey of target detection based on deep convolutional neural networks[J]. Optics and Precision Engineering, 2020, 28(5):1152-1164.
- [9] HE D, XU K, ZHOU P. Defect detection of hot rolled steels with a new object detection framework called classification priority network [J]. Computers & Industrial Engineering, 2019, 128: 290-297.
- [10] YU L Y, WANG ZH, DUAN ZH J. Detecting gear surface defects using background-weakening method and convolutional neural network [J]. Journal of Sensors, 2019, 2019:1-13.
- [11] MEI SH, WANG J D, WEN G J. Automatic fabric defect detection with a multi-scale convolutional denoising autoencoder network model [J]. Sensors, 2018, 18(4): 1064.

- [12] 李晖晖,周康鹏,韩太初. 基于 CReLU 和 FPN 改进的 SSD 舰船目标检测[J]. 仪器仪表学报, 2020, 41(4): 183-190.
LI H H, ZHOU K P, HAN T CH. Ship object detection based on SSD improved with CReLU and FPN [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 183-190.
- [13] 李宇,刘雪莹,张洪群,等. 基于卷积神经网络的光学遥感图像检索[J]. 光学精密工程, 2018, 26(1): 200-207.
LI Y, LIU X Y, ZHANG H Q, et al. Optical remote sensing image retrieval based on convolutional neural networks[J]. Optics and Precision Engineering, 2018, 26(1): 200-207.
- [14] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017: 2999-3007.
- [15] CHU X X, ZHANG B, XU R J. MoGA: Searching beyond mobilenetv3 [C]. ICASSP 2020- 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2020: 4042-4046.
- [16] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]. Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 1800-1807.
- [17] HOWARD A, ZHU M L, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [J]. ArXiv preprint, 2017, Arxiv: 1704.04861.
- [18] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [19] HU J, SHEN L, SUN G. 2018 Squeeze-and-excitation networks[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018, 7132-7141.
- [20] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [J]. ArXiv preprint, 2015, Arxiv: 1512.00567.

作者简介



Tao Xiaotian received B. Sc. degree from Anhui Jianzhu University in 2014. He is currently pursuing a master degree at Nanjing University of Science and Technology. His research interest includes deep learning and image processing.

陶晓天, 2018 年于安徽建筑大学获得学士学位, 现为南京理工大学硕士研究生, 主要研究方向为深度学习和图像处理。

E-mail: 18505604976@163.com



He Boxia (Corresponding author) received his Ph. D. degree in 2009 from Southeast University. Now, he is an associate professor in Nanjing University of Science and Technology. His main research interest includes machine vision and industrial artificial intelligence technology.

何博侠(通信作者), 2009 年于东南大学获得博士学位, 现为南京理工大学副教授。主要研究方向为机器视觉和工业人工智能技术。

E-mail: heboxia@163.com



Zhang Penghui received his B. Sc. degree from Henan University of Technology in 2019. Now he is a master candidate at Nanjing University of Science and Technology. His main research interest includes deep learning, dynamic object detecting and tracking.

张鹏辉, 2019 年于河南工业大学获得学士学位, 现为南京理工大学硕士研究生, 主要研究方向为深度学习和动态目标检测与跟踪。

E-mail: xhh0608@foxmail.com



Tian Dexu received his B. Sc. degree from Qingdao University of Science and Technology in 2019. Now, he is a master candidate at Nanjing University of Science and Technology. His main research interest includes artificial intelligence and machine vision.

田德旭, 2019 年于青岛科技大学获得学士学位, 现为南京理工大学硕士研究生, 主要研究方向为人工智能和机器视觉。

E-mail: tiandexv@fomail.com