

改进 YOLOv4 算法的航空发动机部件表面缺陷检测

李彬, 汪诚*, 吴静, 刘吉超, 童立甲, 郭振平

空军工程大学基础部, 陕西 西安 710038

摘要 针对传统方式检测航空发动机部件表面缺陷存在检测精度低、检测速度慢的问题, 提出了一种改进 YOLOv4 算法的航空发动机部件表面缺陷检测方法。构建航空发动机部件表面缺陷数据集, 使用 K-means 算法对缺陷样本进行聚类, 获得不同大小的先验框参数; 利用改进的参数调整算法对先验框尺寸进行缩放, 加大先验框尺寸差异, 提高先验框与特征层之间的匹配度; 在主干特征提取网络输出的不同特征层后和空间金字塔池化结构后增加卷积层, 提高网络对缺陷特征的提取能力。实验结果表明, 改进后的 YOLOv4 算法在测试集上的平均精度均值(mAP)高达 82.67%, 比原始的 YOLOv4 算法提高了 4.55 个百分点, 单张图片的平均检测时间为 0.1240 s, 与原始算法检测时间基本持平, 检测性能也优于 Faster R-CNN 和 YOLOv3。

关键词 机器视觉; YOLOv4; 航空发动机; 表面缺陷检测; 深度学习

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.1415004

Surface Defect Detection of Aeroengine Components Based on Improved YOLOv4 Algorithm

Li Bin, Wang Cheng*, Wu Jing, Liu Jichao, Tong Lijia, Guo Zhenping

Fundamentals Department, Air Force Engineering University, Xi'an, Shaanxi 710038, China

Abstract Aiming at solving the problems of low accuracy and slow speed in the surface defects detection of aeroengine components using traditional methods, an improved YOLOv4 algorithm is proposed herein. First, an aeroengine component surface defects dataset was developed and the K-means clustering algorithm was suggested to cluster the defect samples for obtaining the priori anchor's parameters of different sizes. Second, the improved parameter-adjustment algorithm was used to scale the priori anchor's sizes and increase the difference in sizes to improve the matching rate between priori anchors and feature maps. Finally, convolution layers were added after the different feature layers of the backbone feature extraction network output and spatial pyramid pooling structure to improve the ability of network to extract defect features. Experimental results show that the mean average precision (mAP) value of the improved YOLOv4 algorithm in the test dataset is as high as 82.67%, which is 4.55 percent point greater than that of the original YOLOv4 algorithm. The average detection time of a single image is 0.1240 s, which is basically the same as that of the original algorithm. Moreover, the detection performance is better than Faster R-CNN and YOLOv3.

Key words machine vision; YOLOv4; aeroengine; surface defect detection; deep learning

OCIS codes 150.1135; 150.0155; 100.4996

1 引言

航空发动机通常在高温、高压、高转速的恶劣环

境下运转, 长期运转将易导致其关键部件出现裂纹、缺口、凹坑、划痕等损伤^[1], 这些损伤会对航空发动机构成严重的威胁, 重则机毁人亡。目前, 实际应用

收稿日期: 2020-11-05; 修回日期: 2020-11-11; 录用日期: 2020-11-18

基金项目: 国家自然科学基金(52004295)

通信作者: * warrant_74@163.com

的检测手段主要是通过检测员使用工业内窥镜深入发动机内部进行观察,或者将部件拆卸下来采用磁粉检测、渗透检测、涡流检测等方式^[2]进行判断。这些传统检测方法不仅效率低下,而且极大地依赖于检测员的经验水平,长时间工作也极易产生视觉疲劳,造成误判。因此,研究一种智能高效的航空发动机部件表面缺陷检测方法具有十分重要的意义。

近年来,随着卷积神经网络为代表的深度学习模型在诸多计算机视觉领域的成功应用^[3],基于深度学习的目标检测方法在很多场景中得到了广泛应用。目前应用广泛的深度学习模型多为以 SSD (single shot multibox detector)^[4]、YOLO (you only look once)^[5]、YOLOv2^[6]、YOLOv3^[7]、YOLOv4^[8]等网络为代表的一阶段网络和以 R-CNN^[9]、Fast R-CNN^[10]、Faster R-CNN^[11]和 Mask R-CNN^[12]等网络为代表的两阶段网络。例如,文献[13]提出了一种基于改进 YOLOv3 网络的齿轮缺陷检测方法,文献[14]提出了一种基于 S-YOLOv3 的织物实时缺陷检测方法,文献[15]提出一种基于优化 YOLOv3 算法的交通灯检测方法。部分学者也开始尝试将深度学习方法迁移到航空部件表面缺陷的检测任务中。文献[16]将优化算法与卷积神经网络(CNN)结合进而用于发动机叶片损伤的检测。文献[17]则根据航空发动机叶片裂纹的特点,对 R-FCN 网络中的先验框和 YOLOv3 中的特征金字塔结构进行改进,但该类算法仅针对裂纹这一类缺陷进行检测。文献[18]提出了结合深度可分离卷积、特征金字塔和 YOLOv3 的 YOLOv3-Lite 模型,用于检测飞机结构中的裂纹,但检测精度较低。文献[19]提出了基于聚类分析改进算法和多种图像处理算法相结合的 SSD 算法,用于航空发动机内部凸台缺陷的检测研究,但该类算法仅针对凸台这一类缺陷进行检测。

因此,为提高对航空发动机部件表面多种类型缺陷的检测性能,本研究采用改进的 YOLOv4 算法进行航空发动机部件表面缺陷的检测研究。首先,收集航空发动机部件表面不同种类缺陷的图片构建数据集,采用 K-means 算法对标注好的数据样本进行聚类,获得不同大小的先验框参数;其次,改进先验框参数调整算法,加大先验框尺寸差异,提高先验框与特征层的匹配度;然后,在主干特征提取网络输出的不同特征层后和空间金字塔池化结构后增加卷积层,提高网络对缺陷特征的提取能力;最后,使用划分好的测试集进行检测,评估不同改进方式下算

法的检测性能,同时与目前常用的 Faster R-CNN 和 YOLOv3 算法进行性能对比。

2 YOLOv4 算法

2.1 算法原理

YOLOv4 是在 YOLO、YOLOv2、YOLOv3 基础上改进而来的,属于一阶段检测算法,检测时首先将待测图片分割成不同大小的网格,每个网格负责不同的区域,如果待检测目标的中心落在某个网格中,则由该网格负责检测目标。其网络结构主要包括主干特征提取网络(CSPDarknet53)、空间金字塔池化结构(SPP)、路径聚合网络(PANet),网络结构如图 1 所示。

在特征金字塔结构部分,YOLOv4 采用了 SPP 结构和 PANet 结构。SPP 结构是对特征层 P5 中的特征作三次卷积后进行最大池化。池化过程中共使用 4 种不同尺度的池化层进行处理,池化核大小分别为 1×1 、 5×5 、 9×9 、 13×13 。经过 SPP 处理后可有效增加感受野,分离出显著的上下文特征。PANet 结构是由卷积操作、上采样操作、特征层融合、下采样操作构成的循环金字塔结构。经过 PANet 结构后,不同特征层的特征之间充分融合,能有效提高缺陷的特征提取能力。最后,YOLOv4 Head 利用 PANet 处理后的 3 个特征层进行结果预测,与 YOLOv3 Head 的原理一样,进行大小为 3×3 和 1×1 的两次卷积操作,对每个特征层的 3 个先验框进行判别,判断其内部是否包含目标,同时判断目标种类,最后进行非极大抑制处理和先验框调整,以获得最终的预测框。

2.2 损失函数

YOLOv4 的损失函数是在 YOLOv3 的损失函数基础上使用 CIOU (complete intersection over union) 误差代替了 MSE (mean square error) 误差作为回归框预测误差。损失函数可分为回归框预测误差 L_{loc} 、置信度误差 L_{conf} 、分类误差 L_{cls} 三部分,表达式为

$$L = L_{loc} + L_{conf} + L_{cls}, \quad (1)$$

其中,回归框预测误差 L_{loc} 为

$$L_{loc} = 1 - \eta_{IOU}(M, N) + \frac{\rho^2(M_{ctr}, N_{ctr})}{m^2} + \alpha v, \quad (2)$$

$$\alpha = \frac{v}{[1 - \eta_{IOU}(M, N)] + v}, \quad (3)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2, \quad (4)$$

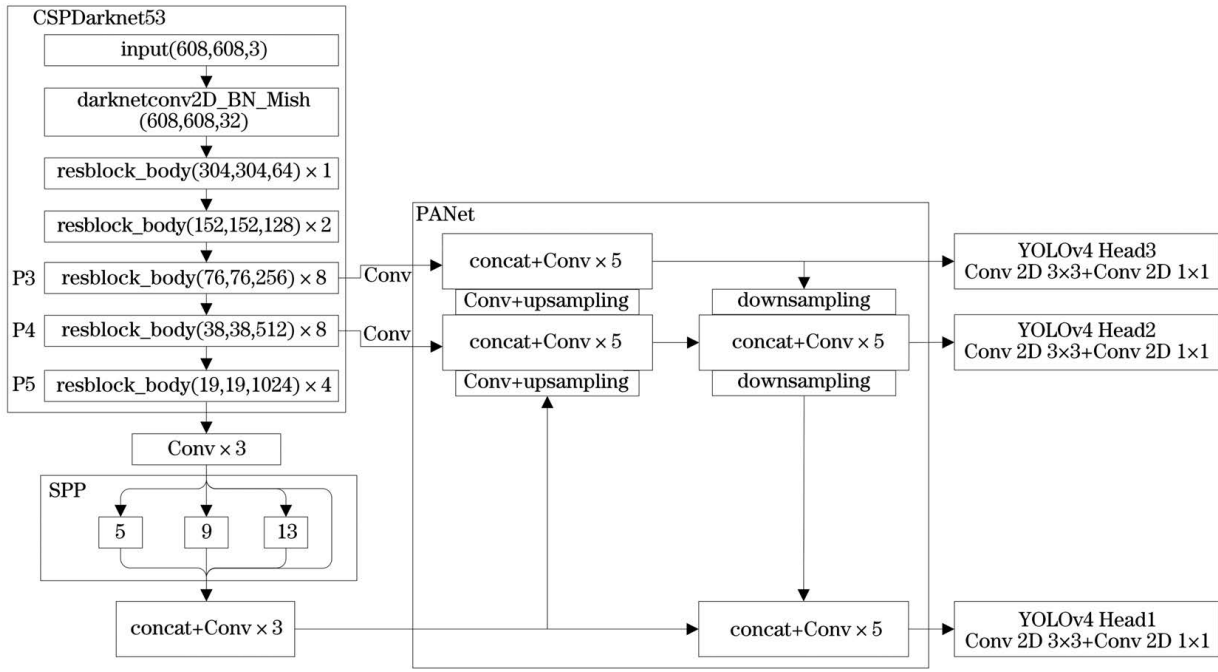


图 1 YOLOv4 网络结构

Fig. 1 YOLOv4 network structure

式中, $\eta_{IOU}(M, N)$ 是预测框和真实框的交并比, $\rho^2(M_{ctr}, N_{ctr})$ 是预测框和真实框的中心点的欧氏距离; m 是同时包含预测框和真实框的最小封闭区域

的对角线距离; w^{gt} 和 h^{gt} 为真实框的宽、高; w 和 h 为预测框的宽、高。

置信度误差 L_{conf} 为

$$L_{conf} = - \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{obj} [\bar{C}_i^j \log(C_i^j) + (1 - \bar{C}_i^j) \log(1 - C_i^j)] - \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{noobj} [\bar{C}_i^j \log(C_i^j) + (1 - \bar{C}_i^j) \log(1 - C_i^j)], \quad (5)$$

式中: S^2 为网格数; B 为每个网格中的先验框个数; I_{ij}^{obj} 为预测的边界框包含目标的指示值, 取值为 1 表示包含, 取值为 0 表示不包含; I_{ij}^{noobj} 为预测的边界框不包含目标的指示值, 取值为 1 表示不包含, 取值为 0 表示包含; C_i^j 为预测置信度, \bar{C}_i^j 为实际置信度, λ_{noobj} 为自行设定的参数值。

分类误差 L_{cls} 为

$$L_{cls} = - \sum_{i=0}^{S^2} I_{ij}^{obj} \sum_{c \in C'} \{ \bar{P}_i^j(c) \log [P_i^j(c)] + [1 - \bar{P}_i^j(c)] \log [1 - P_i^j(c)] \}, \quad (6)$$

式中, c 是检测目标所属的种类, C' 表示缺陷总类别数, $P_i^j(c)$ 是指预测概率, $\bar{P}_i^j(c)$ 为单元格中目标属于类别 c 的实际概率。

3 改进的 YOLOv4 算法

3.1 改进的参数调整算法

在原始 YOLOv4 算法中, 检测分为 3 个特征

层, 每个特征层中含有 3 个大小不同的先验框。先验框是通过 K-means 聚类算法对数据集中标注好的检测目标聚类得到的。在聚类过程中, 首先随机选取初始位置并选定 9 个聚类中心, 计算检测目标中每个标注框与聚类中心点的交并比, 按照交并比的大小将标注框分配给交并比最大的聚类中心, 分配结束后再重新计算聚类中心, 直到聚类中心不再发生改变, 并获得最终聚类好的 9 个先验框的宽和高。具体的目标函数表达式为

$$D = \min \sum_{i=1}^n \sum_{j=1}^k \left(1 - \frac{A_{boxi} \cap A_{cenj}}{A_{boxi} \cup A_{cenj}} \right), \quad (7)$$

式中, A_{boxi} 为检测目标中第 i 个标注框的区域面积, A_{cenj} 为第 j 个聚类中心的区域面积, $A_{boxi} \cap A_{cenj}$ 为标注框与聚类中心区域交集的面积, $A_{boxi} \cup A_{cenj}$ 为标注框与聚类中心区域并集的面积, n 为检测目标的数量, k 为聚类中心个数。

原始 YOLOv4 算法提供的先验框是由 COCO

数据集聚类得到的,而 COCO 数据集图片与航空发动机部件表面缺陷数据集图片中的目标大小和目标类型存在很大的差别,因此采用 K-means 聚类算法

重新生成先验框。聚类时以准确率作为聚类结果的评价指标,计算公式为

$$A_{cc} = \frac{1}{n} \sum_{i=1}^n \max \left(\frac{A_{\text{box}i} \cap A_{\text{cen}1}}{A_{\text{box}i} \cup A_{\text{cen}1}}, \frac{A_{\text{box}i} \cap A_{\text{cen}2}}{A_{\text{box}i} \cup A_{\text{cen}2}}, \dots, \frac{A_{\text{box}i} \cap A_{\text{cen}k}}{A_{\text{box}i} \cup A_{\text{cen}k}} \right) \quad (8)$$

检测过程中, YOLOv4 是将大尺寸的先验框分配给小尺度的特征层用于检测大目标,将小尺寸的先验框分配给大尺度的特征层用于检测小目标。但由于不同类型缺陷的数据量不平衡,聚类后的部分先验框参数相差不大,得到的聚类结果并不能很好地与特征层匹配,无法充分体现 YOLOv4 算法的多尺度特征检测的优势。因此,本文在使用 K-means 算法聚类的基础上,利用改进的参数调整算法对先验框参数进行尺寸缩放,加大先验框参数之间的差距,提高先验框与不同特征层的匹配度。具体改进的参数调整算法表达式为

$$w'_i = \left[\alpha + \frac{(i-1)(\beta-\alpha)}{8} \right] w_i, i = 1, 2, \dots, 9, \quad (9)$$

$$h'_i = h_i * w'_i / w_i, \quad (10)$$

其中, w_i 和 w'_i 分别为第 i 个先验框初始宽度和调整之后的宽度, h_i 和 h'_i 分别是第 i 个先验框初始高度和调整之后的高度, α 和 β 是通过实验取合适值,选择范围为 $0 < \alpha \leq 1, \beta \geq 1$, 以满足尺寸缩放要求。

3.2 改进的网络结构

YOLOv4 算法使用 CSPDarknet53 作为主干特

征提取网络,并输出 3 个不同大小的特征层,特征层 P3、P4、P5 的宽和高分别为原始输入尺寸的 1/8、1/16、1/32。特征层 P3 和 P4 分别经过一次 1×1 的卷积操作后进入 PANet 结构中进行特征融合,特征层 P5 中的特征经过 $1 \times 1, 3 \times 3, 1 \times 1$ 的三次卷积操作后进入 SPP 结构中进行最大池化,这些做法在一定程度上可对不同尺寸、类型的缺陷特征进行提取,但由于航空发动机部件表面中的裂纹和划痕特征比较相近,凹坑与部件设计的孔洞特征存在一定的相似性,若直接使用原始的 YOLOv4 算法进行训练与检测,检测效果并不理想。

因此,针对缺陷类型之间以及缺陷与部件结构之间的特征区分度不明显的问题,本文借鉴原始 YOLOv4 算法中卷积层的设计思想,将 CSPDarknet53 输出的特征层 P3、P4 后的一个卷积层增加为三个卷积层,卷积核分别为 $1 \times 1, 3 \times 3, 1 \times 1$; 同时将 SPP 结构前后的三个卷积层都增加为五个卷积层,卷积核分别为 $1 \times 1, 3 \times 3, 1 \times 1, 3 \times 3, 1 \times 1$, 改进的网络结构如图 2 虚线框所示。三个特征层经过改进的多次小卷积处理后,一方面可加深

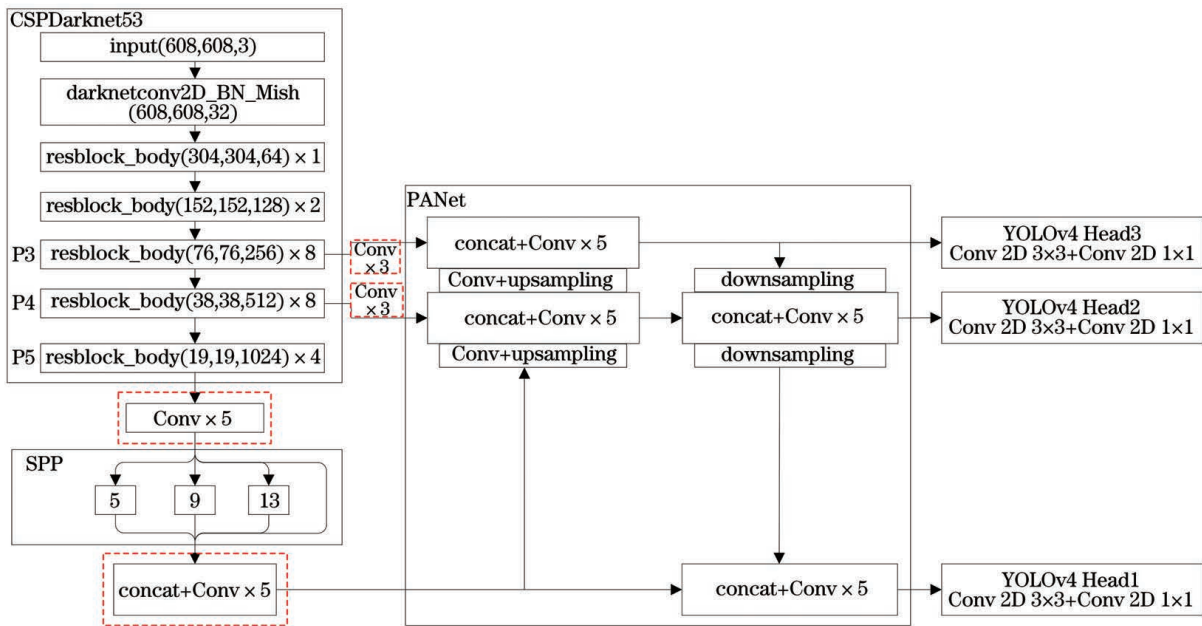


图 2 改进的 YOLOv4 网络结构

Fig. 2 Improved YOLOv4 network structure

网络深度,从而增加网络容量和复杂度,另一方面能获得更大的感受野,获取更为全局、语义层次更高的特征信息,从而更加有效地提取缺陷目标的特征。

4 实验结果与分析

4.1 实验平台

本文进行的实验是在 Windows10 操作系统下完成的。实验采用的硬件配置为:中央处理器(CPU):Inter(R) Xeon(R) Gold 5218 CPU @ 2.30 GHz;图形处理器(GPU):NVIDIA GeForce RTX 2080Ti。使用的开发框架为 PyTorch;编程语言为 Python。

4.2 数据集

4.2.1 数据处理

本实验所用的数据是由合作单位搜集的航空发动机真实部件的表面缺陷图片,图片中缺陷类型包含裂纹(crack)、缺口(gap)、凹坑(pit)、划痕(scratch)4类缺陷,如图3所示。在航空发动机部件表面缺陷数据集的制作过程中,由于最初提供的

原始图片数量有限,本文运用独立目标裁剪、曝光度调整、水平翻转操作对原始图片进行了线下数据增强。数据增强后最终数据集含 1080 张图片,以 8:2 的比例划分训练集和测试集,训练集有 864 张,测试集有 216 张。

由于数据集中的图片大小不一,在训练前需将图片大小统一处理为 608 pixel×608 pixel,同时,进行网络训练时,需使用 Mosaic 数据增强方法来增加样本的多样性。每次读取 4 张图片,对每张图片进行尺寸缩小、随机水平翻转、随机色域变换(色调、饱和度和、明度变换),最终将其拼接成一张 608 pixel×608 pixel 的图片作为输入的训练数据,并修改相对应的 xml 标签数据。Mosaic 数据增强可以极大地丰富所检测目标的背景,能够在图像处理器(GPU)资源有限的条件下得到更好的结果。本文所使用的部分数据增强的示意图如图 4 所示。此外,由于本文线下数据增强采用了水平翻转,为防止数据泄露,需将线上 random 数据增强中的翻转设定为随机垂直翻转,以避免在训练过程中出现过拟合。




图 3 缺陷类型。(a)裂纹;(b)缺口;(c)凹坑;(d)划痕

Fig. 3 Type of defect. (a) Crack; (b) gap; (c) pit; (d) scratch




图 4 数据增强示意图。(a)原始图片;(b)水平翻转;(c)曝光度调整;(d)Mosaic 数据增强

Fig. 4 Data enhancement diagram. (a) Original picture; (b) horizontal flip; (c) exposure adjustment;

(d) Mosaic data enhancement

4.2.2 数据标注

接着,采用 Labelimg 软件对数据集图片中的缺陷进行标注。Labelimg 软件是基于 Python 编写的图片标注工具,用于将图片路径、标签和标注区域的坐标等信息存入到 xml 文件。具体操作流程如下:使用 Labelimg 软件打开样本图片,在图片上创建矩

形框包围缺陷位置,并对不同类型的缺陷进行命名,命名结束后软件会生成相应的 xml 文件,数据标注示意图如图 5 所示。之后利用格式转换程序将 xml 文件转化为包含样本图片路径、缺陷类别和缺陷所在区域坐标信息的文本格式(txt)文件,为训练做好准备。




图 5 数据标注示意图。(a)原始图片;(b)图片标注示例;(c)xml 标签文件

Fig. 5 Data labeling diagram. (a) Original picture; (b) picture annotation example; (c) xml tag file

4.3 超参数选取

在选择 COCO 数据集预训练权重的基础上对 YOLOv4 算法的超参数进行了设定,整个训练过程包含 100 个 epoch,设置权重衰减系数为 0.0005。前 50 个 epoch 训练学习率为 0.001,设置 Batchsize 为 4,每个 epoch 的迭代次数为 216 次;后 50 个 epoch 训练学习率为 0.0001,设置 Batchsize 为 2,每个 epoch 的迭代次数为 432 次。整个训练过程共迭代 32400 次,并在每一轮 epoch 训练时开启 Mosaic 数据增强和 random 数据增强。整个训练过程中的损失函数变化情况如图 6 所示,经过 100 个 epoch 迭代训练后网络已经收敛,收敛时的训练损失值为 9.9718。

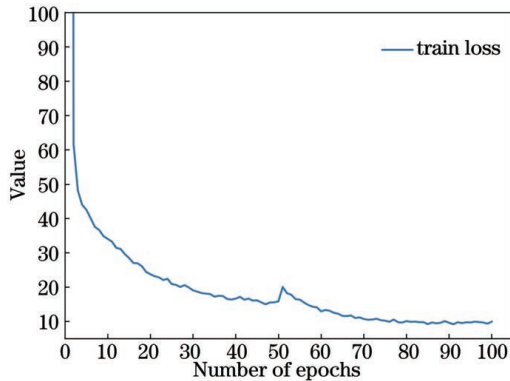


图 6 损失函数变化曲线

Fig. 6 Loss function curve

4.4 算法性能测试

4.4.1 评价准则

在目标检测中,通常将预测框与目标真实框的交并比(IoU, η_{IoU})大于 0.5 设定为成功预测到目标位置,通过准确率(P)和召回率(R)计算平均精度(AP, X_{AP})和加权调和平均(F_β),并以平均 AP 值(mAP, X_{mAP})作为算法检测精度的综合评价指标。AP 用于评估模型在单个检测类别上的精度表现,而 mAP 越大表明整体检测精度越高。 F_β 是基于准确率和召回率的加权调和平均,反映了算法的综合性能, F_β 越大表明检测性能更佳。由于航空发

动机部件表面上的缺陷对飞机安全性能的影响效果很大,在进行缺陷检测时希望尽可能地减少缺陷目标的遗漏,因此本文将 F_β 的 β 值设定为 1.2 以保证召回率的重要程度。准确率、召回率、加权调和平均以及平均 AP 值的计算公式为

$$P = \frac{X_{TP}}{X_{TP} + X_{FP}}, \quad (11)$$

$$R = \frac{X_{TP}}{X_{TP} + X_{FN}}, \quad (12)$$

$$F_\beta = \frac{(1 + \beta^2)PR}{(\beta^2 \times P) + R}, \quad (13)$$

$$X_{mAP} = \frac{\sum X_{AP}}{C'}, \quad (14)$$

其中, X_{TP} 表示检测正确的目标数量, X_{FP} 表示检测错误的目标数量, X_{FN} 表示漏检的目标数量, $\sum X_{AP}$ 表示所有缺陷类别的 AP 值总和。

此外,检测速度也是判定算法性能的重要指标之一。本文采用单张图片平均检测时间 t 作为检测速度的评价指标。平均检测时间越小,表示检测速度越快,越容易达到实时检测。平均检测时间的表达式为

$$t = \frac{t_{total}}{M}, \quad (15)$$

式中, t_{total} 为检测的总时间, M 为检测的图片数量。

4.4.2 性能对比

为测试改进的参数调整算法和网络结构在航空发动机部件表面缺陷测试集中的检测效果,本文设定了 4 组实验进行检测效果评估。实验一是利用 K-means 算法聚类后的原始 YOLOv4 网络进行训练和测试,获得评估检测效果的基准值。实验二是在原始 YOLOv4 网络和 K-means 算法的基础上,采用改进的参数调整算法处理后进行训练和测试,并在实验中确定合适的 α, β 值,本文最终采用的 α, β 值分别为 0.5、2.0。实验三是在 K-means 算法

聚类基础上,采用改进的网络进行训练和测试,用于评估网络结构改进对缺陷检测性能的影响。实验四是综合实验二的参数调整算法和实验三的网络结构进行训练和测试,用于评估综合两种改进方法后对缺陷检测性能的影响。每组实验训练结束后选取最

后 3 个 epoch 的权重文件 (pth 文件) 分别进行测试,并将 3 次测试后的结果取平均作为最终的结果。各类缺陷图片的检测结果如图 7 所示,其中,Test images 是代表 4 类缺陷的测试图,Test results 是检测后的结果图。




图 7 各类缺陷检测结果。(a)(e)裂纹;(b)(f)缺口;(c)(g)凹坑;(d)(h)划痕

Fig. 7 Various defect detection results. (a) (e) Crack; (b) (f) gap; (c) (g) pit; (d) (h) scratch

对比实验一和实验二的检测性能,图 8 和图 9 分别给出不同算法在原始 YOLOv4 网络下 AP 和 F_β 的对比情况。采用改进的参数调整算法后,大部分缺陷的 AP 值都有所提升,所有缺陷的 F_β 值都有所提升,特别是凹坑这类缺陷从 65.45% 提升到 71.47%, F_β 增加了 6.02 个百分点。这是因为使用改进的参数调整算法后,加大了不同先验框之间的尺寸差异,提高了先验框与不同特征层之间的匹配程度,利于检测不同尺寸大小的缺陷,减小了遗漏缺陷的可能性。由于有些待测图片中存在一些小杂质、细纹以及部件本身的纹理,增大先验框尺寸差

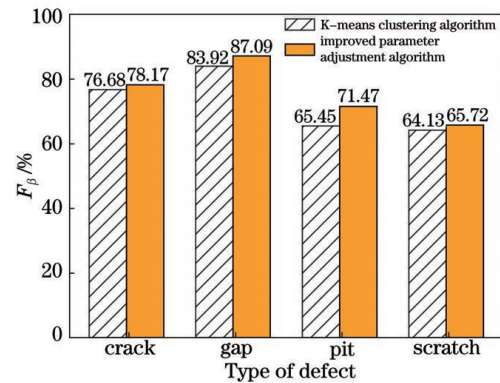


图 9 不同算法在原始 YOLOv4 网络下的 F_β 对比

Fig. 9 Comparison of the F_β of different algorithms under the original YOLOv4 network

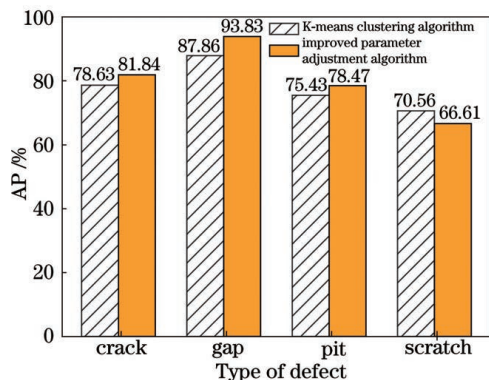


图 8 不同算法在原始 YOLOv4 网络下的 AP 对比

Fig. 8 Comparison of the AP of different algorithms under the original YOLOv4 network

异后,容易将小杂质、细纹和部件本身的纹理误识别为划痕,导致划痕这类缺陷的检测效果稍有下降。但从整体结果上来说,相比于原始 K-means 聚类算法,改进参数调整算法后的检测效果更佳。

对比实验二和实验四的检测性能,图 10 和图 11 分别给出不同网络在改进的参数调整算法下的 AP 和 F_β 对比情况。从图中可以看出,在实验二的情况下改进网络结构,大部分缺陷的 AP 值都有所提升,其中裂纹的 AP 值增加 3.32 个百分点,凹坑的 AP 值增加 4.87 个百分点,划痕的 AP 值增加 2.53 个百分点;各类缺陷的 F_β 值也都有所提升。

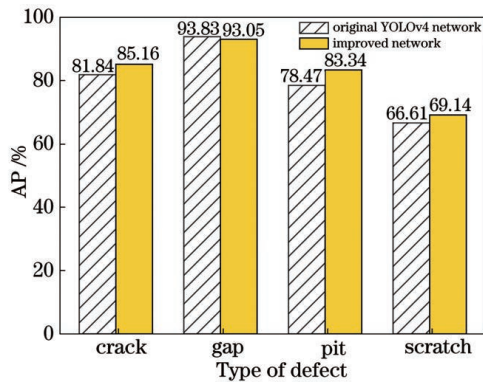


图 10 不同网络在改进参数调整算法下的 AP 对比
Fig. 10 Comparison of the AP of different networks under improved parameter adjustment algorithm

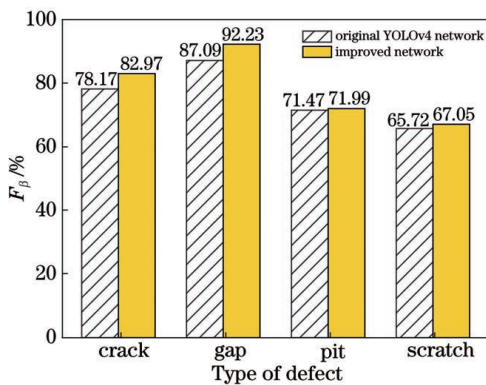


图 11 不同网络在改进参数调整算法下的 F_{β} 对比
Fig. 11 Comparison of the F_{β} of different networks under improved parameter adjustment algorithm

其主要原因在于加深网络有利于缺陷特征的提取,能提高模型对缺陷的特征识别度,对大部分缺陷都能达到很好的效果,但缺口这类缺陷的样本数量较少,加深网络后缺陷的检测误差存在波动,导致缺口的平均精确度略有波动;但加深网络后所有缺陷的 F_{β} 都有所提升,这说明加深网络在一定程度上能减少遗漏缺陷的情况,更有利于航空发动机部件的检修与安全保障。

综合对比两种改进方式的检测精度和检测速度,对比结果如表 1 所示。表 1 是不同网络结构和算法模型两两结合后 mAP 和单张图片平均检测时间的对比情况。从表 1 可以看出,在检测精度方面,改进参数调整算法或者改进 YOLOv4 网络结构, mAP 均有提升。改进参数调整算法后, mAP 提升了 2.07 个百分点;在原始 K-means 基础上改进网络结构后, mAP 提升了 3.71 个百分点;在改进参数调整算法基础上改进网络结构后, mAP 提升了 2.48 个百分点。其中,改进网络结构对 mAP 的提升作用更大,缺陷检测的效果更好。在检测速度方面,参数调整算法仅改变先验框参数,网络结构参数未改变,因此单张图片的平均检测时间和原始模型一致。改进网络结构后单张图片平均检测时间略有增加,这是由于加深网络后会增加一定的参数量,从而影响计算效率。但总体而言,4 组实验中的单张图片平均检测时间基本持平,改进参数调整算法和改进网络结构对整体模型检测速度的影响并不大。

表 1 改进 YOLOv4 的性能对比

Table 1 Improve the performance comparison of YOLOv4

Network structure	Algorithm model	mAP / %	Time / s
Original YOLOv4	K-means	78.12	0.121
Original YOLOv4	Improved algorithm	80.19	0.121
Improved YOLOv4	K-means	81.83	0.123
Improved YOLOv4	Improved algorithm	82.67	0.124

表 2 为不同算法在航空发动机部件表面缺陷数据集上的检测性能对比, Faster R-CNN 算法是目前主流的二阶段检测网络, VGG16 和 ResNet-50 是 Faster R-CNN 常用的主干特征提取网络, YOLOv3 则是目前较为常用的一阶段检测网络。对比各类算法在不同缺陷下的检测性能,可以发现:

表 2 不同算法的检测性能对比

Table 2 Comparison of detection performance of different algorithms

Network structure	mAP / %	Time / s	F_{β} / %			
			Crack	Gap	Pit	Scratch
Faster R-CNN+VGG16	57.13	0.4653	44.60	36.27	31.59	31.66
Faster R-CNN+ResNet-50	64.81	0.8025	44.09	39.87	34.84	30.81
YOLOv3	75.45	0.1262	85.13	84.72	67.88	64.70
YOLOv4	78.12	0.1210	76.68	83.92	65.45	64.13
Improved YOLOv4	82.67	0.1240	82.97	92.23	71.99	67.05

1) 相比于分别以 VGG16 和 ResNet-50 为主干特征提取网络的 Faster R-CNN, 改进后的 YOLOv4 在 mAP 上分别提升了 25.54 个百分点和 17.86 个百分点, 检测时间大大缩短; 不同类型缺陷的 F_{β} 也有很大程度的提升。

其主要原因在于 Faster R-CNN 的先验框长宽比是预先固定的, 无法根据数据集目标大小进行自由调整。裂纹和划痕目标框为细长型, Faster R-CNN 检测时裂纹和划痕不易被遗漏, 而凹坑和缺口这类缺陷目标尺寸较小, Faster R-CNN 检测时凹坑和缺口容易被遗漏, 整体检测效果不好。改进后的 YOLOv4 算法中的先验框是由 K-means 算法聚类和改进参数调整算法获得的, 先验框尺寸更接近数据集目标大小, 更适合检测各类缺陷。

2) 相比于 YOLOv3, 改进后的 YOLOv4 算法在检测精度和检测速度上均优于 YOLOv3。而相比于 YOLOv4, 改进后的 YOLOv4 能在保持检测时间基本持平的情况下增加检测精度, 提升整体检测效果。这是因为 YOLOv4 是在 YOLOv3 基础上改进而来的, 检测精度和速度优于 YOLOv3, 同时本文改进的 YOLOv4 算法又在 YOLOv4 基础上进一步提升了检测性能。

5 结 论

本文提出一种基于改进 YOLOv4 算法的航空发动机部件表面缺陷检测方法。首先使用 K-means 算法对航空发动机部件表面缺陷数据进行聚类, 然后通过改进参数调整算法进行先验框尺寸缩放, 加大先验框尺寸差异, 同时在 CSPDarknet53 网络输出的不同特征层后和 SPP 结构后增加不同的卷积层, 提高了网络对缺陷特征的提取能力。实验结果表明, 相比于原始 YOLOv4 算法, 改进后的 YOLOv4 算法可在保证检测速度基本持平的情况下有效提高航空发动机部件表面缺陷的检测精度, 实现对航空发动机部件表面缺陷的智能高效检测。与 Faster R-CNN 和 YOLOv3 相比, 改进后的 YOLOv4 算法的检测精度和检测速度均为最优。但由于原始图片尺寸较大, 原始图片在使用时需将图片尺寸统一设定为 608 pixel \times 608 pixel, 这在一定程度上影响了检测速度。下一步将尝试对原始图片进行预处理, 在满足特征要求的前提下降低对图片尺寸的要求, 同时对网络结构进行优化, 提升缺陷检测速度, 以更好地实现对航空发动机部件表面缺陷的实时智能化检测。

参 考 文 献

- [1] Kuang K J. Research on deep learning and its application on the defects detection for aero engine [D]. Guangzhou: South China University of Technology, 2017.
旷可嘉. 深度学习及其在航空发动机缺陷检测中的应用研究[D]. 广州: 华南理工大学, 2017.
- [2] Li S B, Yang J, Wang Z, et al. Review of development and application of defect detection technology[J]. Acta Automatica Sinica, 2020, 46(11): 2319-2336.
李少波, 杨静, 王铮, 等. 缺陷检测技术的发展与应用研究综述[J]. 自动化学报, 2020, 46(11): 2319-2336.
- [3] Tao X, Hou W, Xu D. A survey of surface defect detection methods based on deep learning [J]. Acta Automatica Sinica, 2021, 47(5): 1017-1034.
陶显, 侯伟, 徐德. 基于深度学习的表面缺陷检测方法综述[J]. 自动化学报, 2021, 47(5): 1017-1034.
- [4] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9905: 21-37.
- [5] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [6] Redmon J, Farhadi A. YOLO9000: better, faster, stronger [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [7] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection [EB/OL]. (2020-04-23) [2020-11-05]. <https://arxiv.org/abs/2004.10934>.
- [8] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 580-587.
- [9] Girshick R. Fast R-CNN [C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1440-1448.
- [10] Ren S Q, He K M, Girshick R, et al. Faster R-

- CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(6): 1137-1149.
- [11] He K M, Gkioxari G, Dollár P, et al. Mask R-CNN [C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2980-2988.
- [12] Zhang G S, Ge G Y, Zhu R H, et al. Gear defect detection based on the improved YOLOv3 network [J]. Laser & Optoelectronics Progress, 2020, 57(12): 121009.
张广世, 葛广英, 朱荣华, 等. 基于改进 YOLOv3 网络的齿轮缺陷检测[J]. 激光与光电子学进展, 2020, 57(12): 121009.
- [13] Zhou J, Jing J F, Zhang H H, et al. Real time fabric defect detection method based on S-YOLOv3 [J]. Laser & Optoelectronics Progress, 2020, 57(16): 161001.
周君, 景军锋, 张缓缓, 等. 基于 S-YOLOv3 的织物实时缺陷检测方法[J]. 激光与光电子学进展, 2020, 57(16): 161001.
- [14] Sun Y C, Pan S G, Zhao T, et al. Traffic light detection based on optimized YOLOv3 algorithm[J]. Acta Optica Sinica, 2020, 40(12): 1215001.
孙迎春, 潘树国, 赵涛, 等. 基于优化 YOLOv3 算法的交通灯检测 [J]. 光学学报, 2020, 40(12): 1215001.
- [15] Zhao Y. Research on blade damage identification method based on convolution neural network [D]. Tianjin: Civil Aviation University of China, 2019.
赵焯. 基于卷积神经网络的叶片损伤识别方法研究 [D]. 天津: 中国民航大学, 2019.
- [16] Li H. Research on aeroengine blade crack detection based on image recognition [D]. Chengdu: University of Electronic Science and Technology of China, 2019.
李浩. 基于图像识别的航空发动机叶片裂纹检测研究 [D]. 成都: 电子科技大学, 2019.
- [17] Li Y D, Han Z Q, Xu H Y, et al. YOLOv3-lite: a lightweight crack detection network for aircraft structure based on depthwise separable convolutions [J]. Applied Sciences, 2019, 9(18): 3781.
- [18] Chen W, Liang C H. Defect detection of aircraft engine internal convex based on SSD algorithms [J]. Electronic Measurement Technology, 2020, 43(9): 29-34.
陈为, 梁晨红. 基于 SSD 算法的航空发动机内部凸台缺陷检测 [J]. 电子测量技术, 2020, 43(9): 29-34.