

基于旋转目标检测的飞机蒙皮损伤检测

王童, 王宏伟*, 王红

中国民航大学计算机科学与技术学院, 天津 300300

摘要 飞机蒙皮作为航空器的重要部件,直接影响到飞行安全,故飞机蒙皮损伤检测对于有效预防航空安全事故具有重要意义,基于边界框边缘感知向量(BBAVectors)提出一种改进的旋转目标检测方法。首先针对损伤尺度变化大的问题,采用特征融合网络(FFN)提升多尺度检测效果;其次针对飞机蒙皮图片存在大量背景噪声的问题,引入 coordinate attention(CA)机制来增强目标特征信息;最后针对蒙皮损伤分布方向任意的问题,通过 BBAVectors 表示任意角度的损伤位置,以提升目标定位的准确性。实验结果表明,改进的旋转目标检测方法相比原模型检测精度提升了 5.7 个百分点,并且检测精度高于主流的水平目标检测方法,在有效解决方向任意的飞机蒙皮损伤检测效果的基础上,为航空器损伤检测方法的提升提供更好的技术支持。

关键词 图像处理; 旋转目标检测; 飞机蒙皮损伤检测; 特征融合; 注意力机制

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP221169

Aircraft Skin Damage Detection Based on Rotating Object Detection

Wang Tong, Wang Hongwei*, Wang Hong

Computer Science and Technology College, Civil Aviation University of China, Tianjin 300300, China

Abstract As an important part of an aircraft, aircraft skin is directly related to the occurrence of aircraft accidents, so the detection of aircraft skin damage is of great significance for the effective prevention of aviation safety accidents. In this paper, an improved rotated object detection method based on box boundary-aware vectors (BBAVectors) is proposed. First, for the problem of large variation of damage scale, the feature fusion network (FFN) is used to improve the multi-scale detection effect. Second, for the problem of lots of background noise in aircraft skin images, coordinate attention (CA) mechanism is introduced to enhance the object feature information. Finally, for the problem of arbitrary skin damage distribution direction, the damage position of arbitrary angle is represented by the BBAVectors to improve the accuracy of object localization. The experimental results show that the improved rotated object detection method improves the mean average precision by 5.7 percentage points compared with the original model, and the detection performance is better than the horizontal object detection method. On the basis of effectively solving the effect of aircraft skin damage detection in arbitrary directions, it provides better technical support for the improvement of aircraft damage detection methods.

Key words image processing; rotated object detection; detection of aircraft skin damage; feature fusion; attention mechanism

1 引言

飞机蒙皮是机身的表面结构,用于维持飞机的气动外力和克服飞行中承受的空气阻力^[1]。由于各种外力和天气原因,蒙皮结构在飞机服役过程中极易受到损伤。据研究统计一架商用飞机平均每年遭受一次雷击,会导致不同程度的飞机蒙皮损伤^[2]。蒙皮的可靠性影响着飞行安全,是确定飞机生存概率的重要因

素^[3],按时进行飞机蒙皮损伤检查对航空安全有重要意义。

早期的检测方法主要为人工目视^[4],之后超声波检测、涡流检测等技术也被用于蒙皮损伤检测^[5-7]。这些传统的方法检测工艺繁琐、检测成本高,受人为等因素影响,容易出现漏检、误检^[8]。随着自动化的发展,基于机器视觉的自动检测系统实现了较好的检测效果^[9-10],许多主流的目标检测方法被用于系统的图像处

收稿日期: 2022-03-31; 修回日期: 2022-04-18; 录用日期: 2022-05-10; 网络首发日期: 2022-05-20

基金项目: 国家自然科学基金(U1633110)、空中交通管理系统与技术国家重点实验室开放基金(SKLATM201902)

通信作者: *2019051007@cauc.edu.cn

理模块^[11-14]。文献[11]使用SSD在不同大小的卷积层上进行预测,实现多尺度变化的损伤检测。文献[12]提出一种增强的SSD MobileNet,该网络通过数据预处理减少背景干扰,然后利用MobileNet的输出和SSD不同的卷积层进一步提升多尺度损伤的检测效果。文献[13]针对蒙皮损伤数据中存在损伤方向任意的问题,在SSD上引入倾斜边界框,实现多种方向的损伤定位。文献[14]使用改进的YOLOv4结合特征融合增强特征表达能力,进一步提升检测效果。针对损伤尺度变化大和蒙皮背景噪声的问题,上述方法利用不同层的特征信息和注意力机制进行特征增强,但是蒙皮损伤还存在分布方向任意的特点,水平目标检测方法不能准确地定位目标。文献[13]针对这个问题引入倾斜边界框,但现实中损伤的分布角度不局限于设定的几种固定方向。

旋转目标检测是指使用可旋转边界框代替水平边界框的目标检测方法^[15],主要应用于遥感图像的检测,其基本原理是使用可旋转边界框精确地表示任意角度的目标位置,提升检测性能。目前关于旋转目标检测方法的研究集中在通过角度学习实现任意方向的目标定位^[15-17],但是角度变化对训练的总损失影响不大,不能很

好保证有效的intersection over union(R_{IOU})误差优化。文献[18]提出的边界框边缘感知向量(BBAVectors)模型使用BBAVectors描述可旋转边界框,在一定程度上克服了角度学习进行检测的不足,但是对损伤尺度差异大和背景噪声的问题还没有较好的效果。

针对上述问题,本文将旋转目标检测方法引入飞机蒙皮损伤检测,通过改进BBAVectors模型的特征提取效果,解决飞机蒙皮损伤检测中损伤尺度变化大和蒙皮图片存在大量背景噪声的问题。

2 基于旋转目标检测的方法

所提模型主要包括特征提取网络和预测模块2个部分。在特征提取网络中,以ResNet101前五层网络作为骨干网络对图像进行特征提取。在预测模块中,通过特征图预测目标的热力图、中心点偏移量、边界框参数和边界框类型,最后预测出对象的类别信息和边界框信息,实现任意方向的损伤检测。针对飞机蒙皮损伤存在目标尺寸变化大、小目标容易被背景噪声淹没的问题,在特征提取网络中加入特征融合网络(FPN)和coordinate attention(CA)模块,实现更精确的飞机蒙皮损伤检测。所提模型结构图如图1所示。

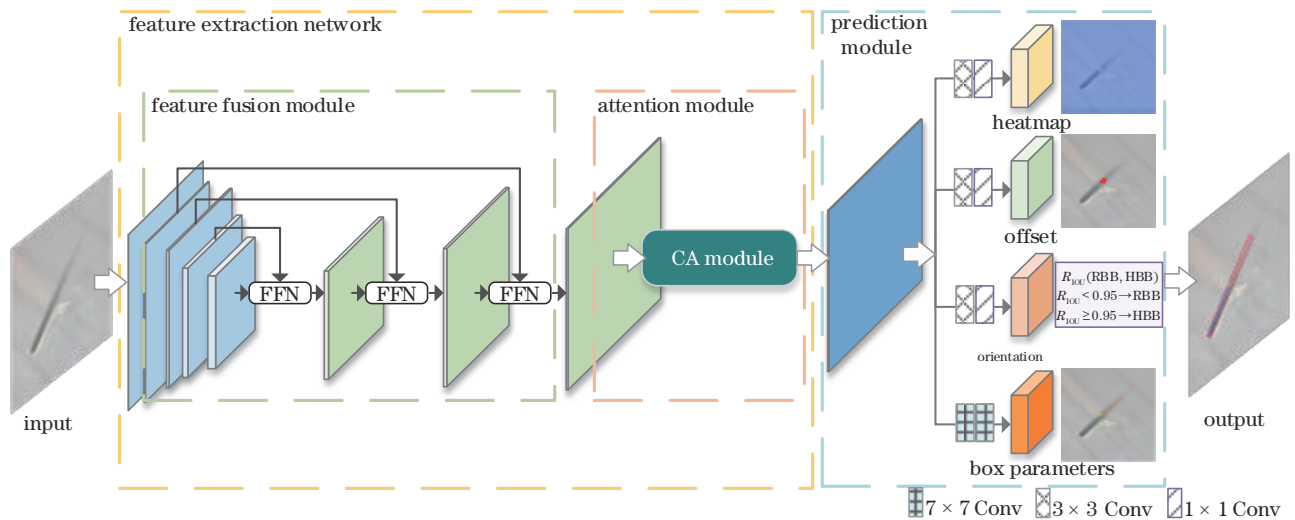


图1 所提模型结构图

Fig. 1 Structure diagram of proposed model

2.1 特征提取网络

飞机蒙皮不同类型的损伤在尺寸上有很大的差异,并且蒙皮表面由于污痕、雨点和光照等因素存在很多噪声干扰,导致目标特征不明显,如图2所示。在图2(a)中,雷击烧蚀的尺寸是铆钉损伤的数十倍,是漆层变色的数百倍。在图2(b)中,多处雨水痕迹和蒙皮表面反光造成大量背景噪声。针对上述问题,本研究在特征提取网络中加入FPN和CA模块进行特征增强。

2.1.1 FPN

卷积网络的浅层特征分辨率高,有丰富的位置和

细节信息,深层特征通过多次下采样,包含更多的语义信息。通过特征融合充分利用融合后的多尺度信息有利于多尺度目标的检测。特征金字塔网络(FPN)^[19]通过融合高层语义信息和低层细节信息获取丰富的特征信息,在计算机视觉任务中得到广泛应用,原模型也通过上采样深层网络与浅层网络进行特征融合,但是这些方法只是将深层和浅层输出的特征映射在结构上进行聚合,没有考虑融合后的信息。不同特征层学习到的感受野和语义信息不同,直接进行融合会减弱多尺度特征的表达能力,不能对融合后特征进行有效利用^[20]。本研究在上采样聚合高低层特征后,接入几个




图 2 飞机蒙皮损伤数据特点。(a)损伤尺度变化大;(b)大量背景噪声

Fig. 2 Characteristics of aircraft surface damage data. (a) Large variation in scale of damage; (b) lots of background noise

由不同空洞卷积构成的子网络。空洞卷积在卷积核中插入“洞”，可以保持网络的分辨率同时获得更大的感受野^[21]，既有利于小尺寸目标的检测，又不影响大尺寸目标的检测精度。通过改变各个子网络中空洞卷积的膨胀率(dilation rate)，可以得到不同感受野的子网络，捕获多尺度上下文信息。

FFN 模块首先对深层特征进行 1×1 卷积调整通

道数，然后使用双线性插值的方法上采样深层网络，并与浅层特征进行逐像素相加，将不同层的特征融合。融合后的特征映射接入不同层次的空洞卷积，在增大感受视野的同时得到 3 个包含不同感受视野的子网络，分别在不同的感受视野内进行更多的信息增强，最后在通道维度上对子网络进行拼接，有效融合不同特征层的上下文信息，如图 3 所示。

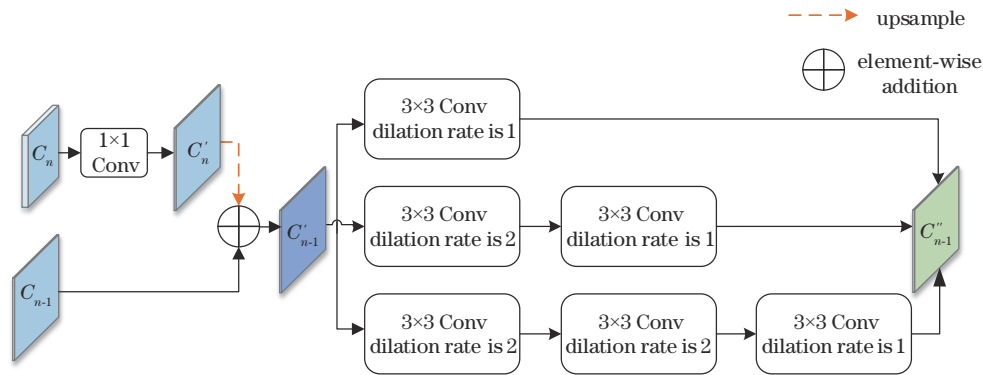


图 3 FFN

Fig. 3 Feature fusion network

FFN 模块在不丢失分辨率的前提下，利用不同的子网络进一步提高不同感受视野特征表达能力。这一方法既获取了高层语义信息，又保留了更多低层细节信息，并且充分考虑了不同层融合之后特征信息，从而获得更具鉴别能力和鲁棒性的特征，有利于多尺度的目标检测。

2.1.2 CA 模块

注意力机制在许多计算机视觉任务中发挥了重要的作用，它可以将特征提取过程引导到信息量更大、更相关的区域。例如经典的通道注意力机制 squeeze-and-excitation networks (SENet)^[22] 借助全局池化计算不同通道的权重系数，引导网络更加关注相关性更高的通道，获得显著的检测性能提升。但通道注意力只考虑通道关系来评估每个通道的重要性，而忽略了位置信息，在目标检测任务中目标的位置信息是很重要的。convolutional block attention module (CBAM)^[23]

通过减少输入的通道维数挖掘位置信息，然后利用卷积计算空间注意力，但无法对视觉任务建立长距离的依赖关系^[24]。为了更好地增强损伤目标的特征表达，本研究使用 CA^[24] 机制，CA 机制既可以同时捕获位置信息和通道关系，又获取了远程依赖关系，增强网络的特征表示。CA 模块包括协调信息嵌入和协调注意生成 2 个转换部分，其网络结构如图 4 所示。

在协调信息嵌入过程中，将传统通道注意力中使用的全局池化分解，避免将全局空间信息压缩到通道中导致位置信息难以保存，对输入的特征图沿水平和垂直两个方向全局池化，使用尺寸为 $(1, W)$ 和 $(H, 1)$ 的池化卷积核每个通道进行编码，得到水平和垂直两个方向的特征图。这两种变换分别沿水平和垂直两个方向聚合特征，使注意力模块可以沿一个方向捕获长依赖关系，同时沿另一个方向保留精确的位置信息。

在协调注意生成转换中：首先将协调信息嵌入转

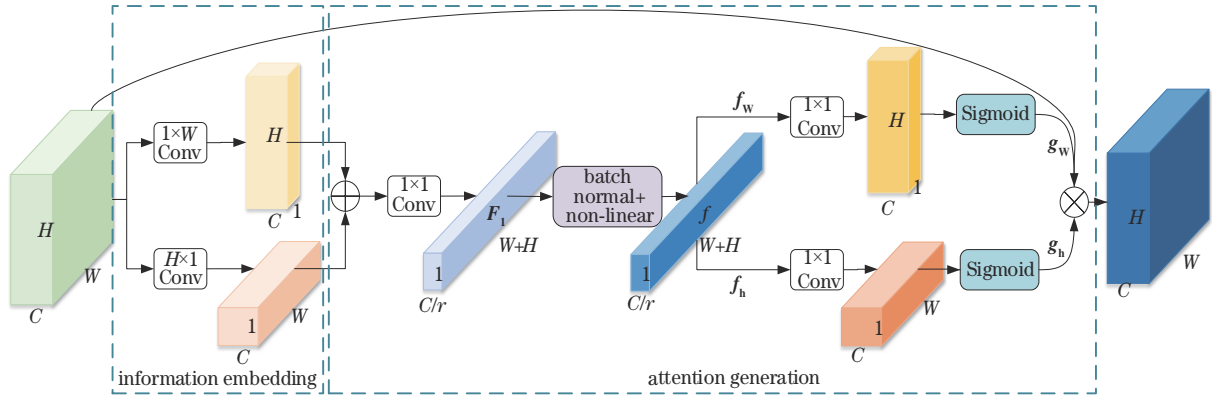


图4 CA机制

Fig. 4 CA mechanism

换得到的两个特征图拼接在一起,通过 1×1 卷积降维得到特征图 F_1 ,对其使用批量归一化得到特征图 f ;然后将特征图 f 沿水平和垂直分解为 $f_w \in \mathbf{R}^{C/r \times W}$ 和 $f_h \in \mathbf{R}^{C/r \times H}$, r 为缩减率,分别对 f_w 和 f_h 进行 1×1 的卷积,得到通道数与原来一样的特征图 F_w 和 F_h ,使用Sigmoid激活函数,分别得到特征图在两个空间方向的注意力权重 g_w 和 g_h ;最后将原始特征图与在水平和垂直方向上的注意力权重相乘,将水平和垂直两个方向的注意力同时应用于输入的特征。

由CA机制可获取通道间的关系,同时利用精确的位置信息捕获长期依赖关系可以更好关注目标特征以弱化背景噪声,实现更加精确的损伤定位。

2.2 预测模块

预测模块分为4个分支:中心点热图、中心点偏移量、边界框类型和边界框参数。这4个分支共享同1个特征提取网络分别进行训练,最后整个模块预测出每个损伤目标的类别信息和边界框信息,实现任意方向的损伤检测,如图1所示。

2.2.1 中心点热图

该分支将特征图映射为中心点热图 $\hat{Y} \in [0, 1]^{\frac{H}{S} \times \frac{W}{S} \times C}$ 检测中心点,然后通过中心点对损伤目标进行分类和定位。其中, H 、 W 分别代表输入图片的高和宽, S 为下采样倍数(本研究取 $S=4$), C 为特征图的通道数,对应损伤的种类数,每个类别通道上的映射由Sigmoid函数传递, $\hat{Y}_{xyc} = 1$ 代表在 (x, y) 处检测到类别 c 的中心点。

训练时,首先根据标注信息和下采样倍数,得到在低分辨率特征图上对应的中心点 $p = (p_x, p_y)$,然后将每个损伤目标的中心点通过高斯核映射到中心点热图 $Y \in [0, 1]^{\frac{H}{S} \times \frac{W}{S} \times C}$,高斯核公式为

$$Y_{xyc} = \exp \left[-\frac{(x - p_x)^2 + (y - p_y)^2}{2\sigma^2} \right], \quad (1)$$

式中: σ 为与目标大小相关的标准差; x, y 为热图上对

应像素点的坐标值。由于热图中除了中心点为正样本,其余像素点均为负样本,正负样本不均衡。本研究使用focal损失函数调整正负样本的惩罚权重,回归中心点的位置和类别信息:

$$L_h = -\frac{1}{N} \sum_{xyc} \begin{cases} (1 - \hat{Y}_{xyc})^\alpha \log(\hat{Y}_{xyc}), & Y_{xyc} = 1 \\ (1 - Y_{xyc})^\beta (\hat{Y}_{xyc})^\alpha \log(1 - \hat{Y}_{xyc}), & \text{otherwise} \end{cases} \quad (2)$$

式中:参数 α, β 参考focal损失设置为2和4; N 为目标总数。

2.2.2 中心点偏移量

从中心点热图中选取目标的中心点 p 时,得到的数值为整数,但是下采样之后的中心点是浮点数,导致特征图上的中心点重新映射到原始图像上时会存在精度误差。在该分支中预测一个偏移量 o 弥补精度误差,根据标注信息可以得到原始图像中真实框的中心点 $p' = (p'_x, p'_y)$,中心点的偏移量定义如下:

$$o = \left(\frac{p'_x}{S} - \left\lfloor \frac{p'_x}{S} \right\rfloor, \frac{p'_y}{S} - \left\lfloor \frac{p'_y}{S} \right\rfloor \right), \quad (3)$$

式中: $\lfloor \cdot \rfloor$ 表示向下取整。使用Smooth L_1 损失函数优化中心点偏移量:

$$L_o = \frac{1}{N} \sum_{k=1}^N \text{Smooth}_{L_1}(o_k - \hat{o}_k), \quad (4)$$

式中: o 和 \hat{o} 分别代表预测和真实的偏移量; k 为目标的索引值。

2.2.3 边界框类型

蒙皮损伤图像中除了角度任意的损伤需要用旋转边界框表示位置,很多目标可以用水平框来定位区分,本研究同时使用水平和旋转两种边界框对目标进行定位。对角度明显、长宽比较大的目标使用旋转边界框精确定位损伤位置,其余的损伤使用水平边界框定位。当目标的水平边界框和旋转边界框的 R_{IoU} 值小于0.95的时候使用旋转边界框,其他情况下使用水平边界框,使用交叉熵损失函数回归预测类型 α :

$$L_a = -\frac{1}{N} \sum_{k=1}^N [\hat{\alpha}_i \log(\alpha_i) + (1 - \hat{\alpha}_i) \log(1 - \alpha_i)], \quad (5)$$

式中: $\hat{\alpha}$ 为真实类型。

2.2.4 边界框参数

在该分支通过预测边界框的边缘感知向量和边界框的尺寸信息来描述边界框, 边界框边缘感知向量是从目标中心点分别指向边缘的 4 条向量, 分别是指向顶部的 t 、指向右边的 r 、指向底部的 b 和指向左边的 l , 它们固定分布在笛卡儿坐标系的 4 个象限中。边界框参数被定义为 $\mathbf{d} = [t, r, b, l, w, h]$, 其中 w, h 分别代表外部水平边界框的宽和高。当边界框类型为旋转时, 使用边缘感知向量计算边界框尺寸信息, 当边界框类型为水平时, 直接使用 w, h 作为边界框尺寸信息, 可旋转边界框的表示如图 5 所示。使用 Smooth_{L_1} 损失函数回归边界框参数:

$$L_b = \frac{1}{N} \sum_{k=1}^N \text{Smooth}_{L_1}(\mathbf{d}_k - \hat{\mathbf{d}}_k), \quad (6)$$

式中: \mathbf{d} 和 $\hat{\mathbf{d}}$ 分别为预测的和真实的边界框参数。

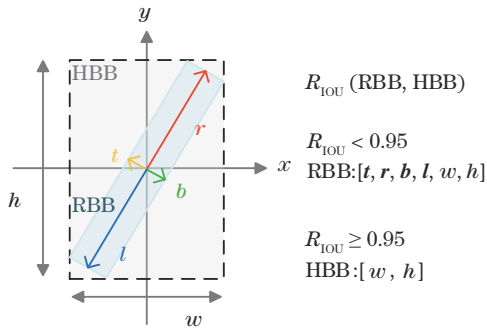


图 5 可旋转边界框

Fig. 5 Oriented bounding box

3 飞机蒙皮损伤检测的过程与实验效果分析

3.1 飞机蒙皮损伤检测过程

3.1.1 实验过程

飞机蒙皮损伤检测的实验过程如图 6 所示, 实验过程具体流程如下:

1) 在模型输入处理阶段, 对飞机蒙皮损伤数据集进行数据预处理。首先根据损伤特点对损伤种类进行划分, 然后设置训练参数, 在模型训练之前对输入的图片进行数据增强和数据增广, 提高模型的检测能力和泛化能力。

2) 在模型训练阶段, 首先加载改进的 BBAVectors 模型, 输入数据预处理后的图片, 然后开始训练模型, 直至损失函数收敛。

3) 在模型测试和评估阶段, 将训练好的模型在测试集上进行检测, 预测损伤的类别信息和位置信息, 然后通过计算平均精度均值 (mAP) 对模型进行评估。

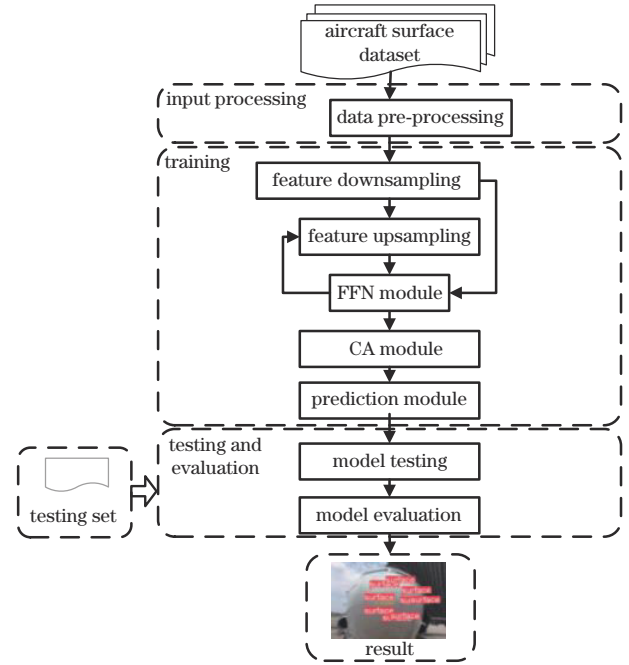


图 6 实验过程

Fig. 6 Experimental process

3.1.2 实验环境及参数设置

使用和 BBAVectors 模型相同的设置来初始化和训练模型, 在训练和测试阶段, 将输入图像的大小调整为 608×608 , 输出大小为 152×152 。模型实现工具为 PyTorch, 主干权重是在 ImageNet 数据集中预先训练的。训练过程中对图像采用包括随机翻转、随机颜色变换和 mosaic 的数据增强方法, batch size 设置为 10, 初始学习率设为 6.25×10^{-5} , 使用 Adam 机制优化总损失, 训练总轮数为 80。

3.2 数据预处理

3.2.1 数据集构建

以飞机蒙皮雷击损伤图片作为数据集进行实验, 数据集由航空公司提供的 1000 张飞机蒙皮图像组成, 图像尺寸变化从 $400 \text{ pixel} \times 800 \text{ pixel} \sim 3000 \text{ pixel} \times 4000 \text{ pixel}$ 。根据损伤特点将雷击损伤分为边缘缺口 (edge)、铆钉损伤 (rivet)、漆层变色 (paint)、雷击烧蚀 (ablation)、金属熔化 (melt) 和碳纤维损伤 (fibre) 等 6 个类别。图 7 为以上 6 类雷击损伤示例图片。

数据集使用 Rollabelling 标记工具对雷击损伤类别信息和位置信息进行标注, 按照 8:2 的比例随机选取 800 张图片作为训练集, 200 张图片为测试集, 各损伤类型实例数量的具体分布情况如表 1 所示。

3.2.2 数据增强

由于飞机蒙皮损伤图片的获取环境多变, 并且数据集的数据量较小。为了提高模型的检测能力和泛化能力, 通过数据增强增加输入图像的可变性和数量, 使模型对从不同环境获得的图像具有更高的鲁棒性, 同时将数据增广到更大的数据量。

首先对图片使用随机翻转和随机颜色变换, 同时




图 7 雷击损伤类别。(a)边缘缺口;(b)铆钉损伤;(c)漆层变色;(d)雷击烧蚀;(e)金属熔化;(f)碳纤维损伤
Fig. 7 Lightning damage category. (a) Edge; (b) rivet; (c) paint; (d) ablation; (e) melt; (f) fiber

表 1 雷击损伤各实例分布情况

Table 1 Distribution of each instance of lightning damage

Classe	edge	rivet	paint	ablation	melt	fibre	total
Training set	85	119	243	433	235	87	1202
Testing set	28	33	50	92	29	31	263

对数据量进行扩增,如图 8 所示,图 8(a)为原图,图 8(b)、(c)分别为随机翻转和随机颜色变换操作后的图片。

然后使用 mosaic 数据增强方法,通过同时对多张图片进行随机缩放和拼接达到数据增强的效果,图 9 分别

为尺寸合适和尺寸不合适留下空白区域的情况。mosaic 方法从数据集中随机选择 4 幅图像,然后在不遮挡目标的情况下随机将它们拼凑在一起,丰富图像的训练。一方面,随机缩放可以增加类内目标更多的尺寸变化;另一方面,将 4 张图片拼在一起,混合不同语义信息,




图 8 数据增强效果图。(a)原图;(b)随机翻转;(c)随机颜色变换

Fig. 8 Data enhancement effect. (a) Original image; (b) random flip; (c) random color shift




图 9 mosaic 数据增强。(a)尺寸合适;(b)尺寸不合适

Fig. 9 mosaic data enhancement. (a) Suitable size; (b) size not suitable

提高模型鲁棒性。此外在训练时, batch normalization (BN) 可以同时计算 4 个图像的激活统计信息, 减少了对 mini-batch 大小的需求, 降低 GPU 的消耗。

3.3 评价指标

实验使用 mAP 作为模型评判标准, 通过计算多个类别平均精度 (AP) 的平均值可以得到 mAP。每个类别根据准确率 (precision) 和召回率 (recall) 绘制一条 precision-recall 曲线, 通过计算曲线下的面积获得该类的 AP 值。准确率 (P)、召回率 (R)、AP 和 mAP 的表达式分别为

$$P = N_{TP} / (N_{TP} + N_{FP}), \quad (7)$$

$$R = N_{TP} / (N_{TP} + N_{FN}), \quad (8)$$

$$P_{AP} = \int_0^1 p(r) dr, \quad (9)$$

表 2 引入不同模块对比实验结果

Table 2 Comparative experimental results of different modules

unit: %

Model	edge	rivet	paint	ablation	melt	fibre	mAP
BBAV	65.23	66.38	53.81	63.32	49.85	68.16	60.13
BBAV+Data1	65.81	66.52	53.42	62.93	50.31	68.37	61.23
BBAV+Data2	66.75	66.71	53.92	63.01	49.02	69.06	61.41
BBAV+Data*	67.86	67.37	54.01	63.24	51.58	69.37	62.26
BBAV+FFN	69.37	67.81	55.14	65.73	51.97	71.93	63.66
BBAV+CA	68.05	68.52	57.78	64.62	54.53	70.04	63.92
BBAV+All	70.96	68.83	59.75	66.27	57.22	71.96	65.83

在雷击损伤数据集上使用原始模型 BBAV 检测, mAP 为 60.13%; 在原始模型上对数据集进行数据增强, 单独使用随机变换和 mosaic 数据增强方法, mAP 分别提高了 1.1 个百分点和 1.28 个百分点, 同时使用所有数据增强方法后, mAP 提高了 2.13 个百分点, 既增加了数据集样本的多样性和数据量, 又有效提升了模型的泛化能力; 在原始模型上引入 FFN, mAP 提高了 3.23 个百分点。对于雷击烧蚀、碳纤维损伤这两类损伤, 类内尺度变化大并且类内大尺度损伤明显大于其他类型损伤, 在引入 FFN 模块之后 AP 分别提升了 2.41 个百分点和 3.77 个百分点。对于边缘缺口这类形状细长、尺寸和其他类型损伤相比相差很大的目标, 在引入 FFN 模块之后 AP 提升了 4.14 个百分点。所以引入 FFN 模块有效利用了融合之后的特征信息, 获得了更多可辨别性和鲁棒性特征, 有利于尺度差异大的目标检测; 在原始模型上引入 CA 模块, mAP 提高了 3.79 个百分点。对于铆钉损伤、漆层变色和金属熔化这类背景复杂、噪声干扰多的损伤, AP 分别提高了 2.14 个百分点、3.97 个百分点和 4.58 个百分点。同时其他类型损伤的检测性能也有不同程度的提升, 所以引入 CA 模块同时关注目标特征的位置信息和关键通道信息, 有效抑制了背景噪声, 提升检测性能; 最后将所有模块应用到原始模型中, mAP 提升至 65.83%, 相

$$P_{mAP} = \frac{1}{c} \sum_{i=1}^c P_{AP_i}, \quad (10)$$

式中: N_{TP} 代表将正样本正确检测出来的数量; N_{FN} 代表将负样本错误检测成正样本的数量; N_{FP} 代表正样本没有被检测出来的数量; c 为检测目标的总类数。

3.4 实验效果分析

3.4.1 不同模块对比实验

为了验证各个模块的有效性, 在雷击损伤数据集上进行一组消融实验。各组实验采用相同的设置对模型进行初始化和训练, 实验结果如表 2 所示。其中, BBAV 为改进之前的模型, +Data1、+Data2、+Data*、+FFN、和 +CA 分别代表在原始模型上加入随机变换数据增强方法、mosaic 数据增强方法、所有数据增强方法、FFN 和 CA 的模型, 最后 +all 表示将所有模块加入原始模型, 即所提模型。

比原模型提升了 5.7 个百分点。通过这组消融实验, 证明了各个模块的有效性。

3.4.2 主流算法对比实验

为了进一步评估改进算法的检测效果, 同时验证旋转目标检测方法的的优势, 与一些主流的水平目标检测算法进行对比实验。基于雷击损伤数据集, 在相同训练、测试样本的条件下, 对比不同算法得到的结果如表 3 所示。

从表 3 可以看出, 所提算法相比 SSD、YOLOv3、YOLOv4、YOLOv5 和 Faster RCNN 这些主流算法, 检测精度分别提升 17.72 个百分点、14.8 个百分点、7.04 个百分点、6.08 个百分点和 5.89 个百分点。SSD 使用 vgg16 作为传统骨干网络, 检测性能在该数据集上较差; YOLOv3 使用 FPN 进行特征融合, 检测精度相比 SSD 提升了 2.94 个百分点; YOLOv4 和 YOLOv5 使用路径聚合网络 (PAN) 进行特征融合, 同时引入注意力机制和不同的数据增强方法, 检测精度分别为 58.79% 和 59.75%; Faster RCNN 使用 FPN, 同时作为二阶段检测模型, 候选框区域的选择减少了背景样本影响, 检测精度达到 59.94%。但是以上算法都是基于水平边界框的检测方法, 所提算法通过可旋转边界框准确定位方向任意的损伤, 对于边缘缺口和碳纤维损伤这类长宽比大并且方向任意的损伤, AP

表 3 不同算法检测结果对比
Table 3 Comparison of detection results of different algorithms

unit: %

Model	edge	rivet	paint	ablation	melt	fibre	mAP
SSD	39.46	50.87	51.48	52.64	50.85	43.29	48.11
YOLOv3	41.56	53.67	51.63	60.45	49.21	49.67	51.03
YOLOv4	49.69	59.77	60.08	67.82	58.49	56.91	58.79
YOLOv5	51.74	60.63	59.79	68.44	59.85	58.06	59.75
Faster RCNN	50.86	61.10	60.13	68.76	59.43	59.34	59.94
Proposed model	70.96	68.83	59.75	66.27	57.22	71.96	65.83

相比 Faster RCNN 分别提升了 20.1 个百分点、12.62 个百分点, mAP 相比水平的目标检测方法有不同程度的提升, 体现了旋转目标检测在飞机蒙皮损伤检测上的优势。

4 结 论

提出一种基于 BBAVectors 的改进模型并应用于飞机蒙皮损伤检测, 通过 FFN 有效利用融合后的特征信息, 加强多尺度特征表达能力, 引入 CA 模块同时关注通道和目标位置信息突出目标特征, 有效减少飞机蒙皮损伤图片中雨滴、污渍等背景干扰, 采用边界框边缘感知向量描述损伤位置, 实现了对任意方向的损伤进行准确的定位。实验结果表明, 所提模型对雷击损伤检测精度达到 65.83%, 与原模型相比检测精度提升了 5.7 个百分点, 检测精度高于水平目标检测方法。未来可以通过进一步强化数据集的规范性提升检测效果, 并针对不同类型的损伤特征, 全面提升飞机蒙皮损伤检测的质量。

参 考 文 献

- [1] 于之靖, 李鑫, 李雁玲, 等. 蜂巢模型标记的飞机蒙皮小型损伤定位方法[J]. 激光与光电子学进展, 2019, 56(18): 180301.
Yu Z J, Li X, Li Y L, et al. Minor damage location method for aircraft skins based on marked honeycomb model[J]. Laser & Optoelectronics Progress, 2019, 56(18): 180301.
- [2] Buckhorst A F, Kluge-Wilkes A, Schmitt R H. Flying metrology and defect identification for aircraft surface inspection[J]. PhotonicsViews, 2019, 16(1): 68-71.
- [3] Xia R B, Zhao J B, Zhang T Y, et al. Detection method of manufacturing defects on aircraft surface based on fringe projection[J]. Optik, 2020, 208: 164332.
- [4] Siegel M, Gunatilake P. Remote enhanced visual inspection of aircraft by a mobile robot[C]//1998 IEEE Workshop on Emerging Technologies, Intelligent Measurement and Virtual Systems for Instrumentation and Measurement, May 15-16, 1998, St. Paul, MN, USA. New York: IEEE Press, 1998.
- [5] Masserey B, Raemy C, Fromme P. High-frequency guided ultrasonic waves for hidden defect detection in multi-layered aircraft structures[J]. Ultrasonics, 2014, 54

- (7): 1720-1728.
- [6] Moustakidis S, Anagnostis A, Karlsson P, et al. Non-destructive inspection of aircraft composite materials using triple IR imaging[J]. IFAC-PapersOnLine, 2016, 49(28): 291-296.
- [7] 王筱晔, 吴松华, 刘晓英, 等. 基于相干多普勒激光雷达的飞机尾涡观测[J]. 光学学报, 2021, 41(9): 0901001.
Wang X Y, Wu S H, Liu X Y, et al. Observation of aircraft wake vortex based on coherent Doppler lidar[J]. Acta Optica Sinica, 2021, 41(9): 0901001.
- [8] 周志新. 机械裂纹无损检测方法综述[J]. 机电工程, 2017, 34(10): 1138-1143.
Zhou Z X. Overview of NDT methods for mechanical cracks[J]. Journal of Mechanical & Electrical Engineering, 2017, 34(10): 1138-1143.
- [9] Jovančević I, Lamier S, Orteu J J, et al. Automated exterior inspection of an aircraft with a pan-tilt-zoom camera mounted on a mobile robot[J]. Journal of Electronic Imaging, 2015, 24(6): 061110.
- [10] 吴军, 李鑫, 刘少禹, 等. 基于后方定位的飞机蒙皮损伤视觉检测全局三维重建方法[J]. 光学学报, 2021, 41(11): 1115002.
Wu J, Li X, Liu S Y, et al. Global three-dimensional reconstruction method for visual detection of aircraft skin damage based on rear positioning[J]. Acta Optica Sinica, 2021, 41(11): 1115002.
- [11] 刘恒鑫. 采用深度网络的飞机表面图像损伤检测与识别[D]. 北京: 北京邮电大学, 2018.
Liu H X. Damage detection and recognition of aircraft surface image using deep network[D]. Beijing: Beijing University of Posts and Telecommunications, 2018.
- [12] Li Y T, Huang H S, Xie Q S, et al. Research on a surface defect detection algorithm based on MobileNet-SSD[J]. Applied Sciences, 2018, 8(9): 1678.
- [13] 李慧. 飞机蒙皮图像的深度特征学习与损伤监测[D]. 北京: 北京邮电大学, 2019.
Li H. High-level feature learning and damage monitoring of aircraft surface images[D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
- [14] 李彬, 汪诚, 吴静, 等. 改进 YOLOv4 算法的航空发动机部件表面缺陷检测[J]. 激光与光电子学进展, 2021, 58(14): 1415004.
Li B, Wang C, Wu J, et al. Surface defect detection of aeroengine components based on improved YOLOv4 algorithm[J]. Laser & Optoelectronics Progress, 2021, 58(14): 1415004.

- [15] Ding J, Xue N, Long Y, et al. Learning RoI transformer for detecting oriented objects in aerial images[EB/OL]. (2018-12-01)[2022-02-04]. <https://arxiv.org/abs/1812.00155>.
- [16] Zhang G J, Lu S J, Zhang W. CAD-net: a context-aware detection network for objects in remote sensing imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(12): 10015-10024.
- [17] Yang X, Yang J R, Yan J C, et al. SCRDet: towards more robust detection for small, cluttered and rotated objects[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 8231-8240.
- [18] Yi J R, Wu P X, Liu B, et al. Oriented object detection in aerial images with box boundary-aware vectors[C]//2021 IEEE Winter Conference on Applications of Computer Vision, January 3-8, 2021, Waikoloa, HI, USA. New York: IEEE Press, 2021: 2149-2158.
- [19] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 936-944.
- [20] Li J, Wang Y B, Wang C G, et al. DSFD: dual shot face detector[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 5055-5064.
- [21] Wang P Q, Chen P F, Yuan Y, et al. Understanding convolution for semantic segmentation[C]//2018 IEEE Winter Conference on Applications of Computer Vision, March 12-15, 2018, Lake Tahoe, NV, USA. New York: IEEE Press, 2018: 1451-1460.
- [22] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [23] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018*. Lecture notes in computer science. Cham: Springer, 2018, 11211: 3-19.
- [24] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 13708-13717.