

# 基于改进 Cascade RCNN 网络的 X 光安检违禁品检测<sup>①</sup>



张娜<sup>1</sup>, 罗源<sup>1</sup>, 包晓安<sup>1</sup>, 金瑜婷<sup>2</sup>, 涂小妹<sup>2</sup>

<sup>1</sup>浙江理工大学 信息学院, 杭州 310018)

<sup>2</sup>浙江广厦建设职业技术大学, 东阳 322100)

通信作者: 涂小妹, E-mail: txm\_95@163.com

**摘要:** 针对 X 光安检违禁品检出率低下问题, 提出了一种基于改进 Cascade RCNN 网络的 X 光安检违禁品检测算法. 该算法在网络结构上引入批特征擦除 (batch feature erasing, BFE) 模块. BFE 模块通过随机擦除相同区域来增强局部特征学习, 进而强化网络对剩余特征的学习表达. 此外, 针对检出率低下问题, 在该算法中提出加权 SD loss 损失函数, 该损失函数使用权重融合的方式将 Smooth L1 loss 与 DIoU loss 进行加权融合, 通过改变权重比例系数, 能够使目标检测结果更加准确, 一定程度上提高了检出率. 实验结果表明: 在公开的 X 光安检违禁品数据集上, 测试性能与原算法相比, 改进 Cascade RCNN 网络对 X 光安检违禁品检出率增长了 3.11%, 改进算法的识别精度有一定的提高.

**关键词:** X 光安检图像; 批特征擦除; SD loss 损失函数; 安检违禁品检测; Cascade RCNN

引用格式: 张娜, 罗源, 包晓安, 金瑜婷, 涂小妹. 基于改进 Cascade RCNN 网络的 X 光安检违禁品检测. 计算机系统应用, 2022, 31(7): 224-230. <http://www.c-s-a.org.cn/1003-3254/8624.html>

## X-ray Security Inspection for Contraband Detection Based on Improved Cascade RCNN Network

ZHANG Na<sup>1</sup>, LUO Yuan<sup>1</sup>, BAO Xiao-An<sup>1</sup>, JIN Yu-Ting<sup>2</sup>, TU Xiao-Mei<sup>2</sup>

<sup>1</sup>(School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

<sup>2</sup>(Zhejiang Guangsha Vocational and Technical University of Construction, Dongyang 322100, China)

**Abstract:** Considering the low detection rate of X-ray security inspection of contraband, an algorithm based on the improved Cascade RCNN is proposed. By this algorithm, a batch feature erasing (BFE) module is introduced into the network structure, which can enhance local feature learning by randomly erasing the same region and thus further enhance the learning expression of residual features. In addition, the weighted SD loss function is presented in this algorithm to solve the problem of low detection rates, which employs weight fusion to fuse Smooth L1 loss and DIoU loss, and by changing the proportion coefficient of weights, it can make the detection result more accurate. The experimental results show that the detection rate of the improved Cascade RCNN on an open contraband dataset for X-ray security inspection is increased by 3.11% compared with that of the original algorithm, and the accuracy of the improved algorithm is raised.

**Key words:** X-ray security inspection images; batch feature erasing (BFE); SD loss function; security inspection for contraband detection; Cascade RCNN

① 基金项目: 浙江省重点研发计划 (2020C03094); 国家自然科学基金 (6207050141)

收稿时间: 2021-10-25; 修改时间: 2021-12-14; 采用时间: 2021-12-21; csa 在线出版时间: 2022-05-30

X光安检是我国广泛应用的安检技术手段,应用于各个重要领域.使用人工智能技术辅助一线安检员进行X光安检判图,有效的降低漏报问题.X光安检违禁品检测实际上是对违禁品的定位和分类.即用目标检测的方式检测是否有违禁品,并在安检图片上标出违禁品的位置及类别.

传统的安检图像处理算法对安检违禁品检测做出很多贡献.苏冰山等<sup>[1]</sup>提出了一种新型X光图像民航违禁品分类方法,对X光图像提取Contourlet变换后图像的共生矩阵、Tamura纹理特征和直方图特征,最后将这3种特征的特征向量串联起来得到联合特征向量.刘颖等<sup>[2]</sup>提出了一种基于有偏彩色纹理字典的X光安检图像检测,此算法是根据被检测物体的颜色分布构建色彩权值矩阵,提取多通道图像的局部纹理特征,结合词袋模型生成多通道优化的图像字典.王宇等<sup>[3]</sup>提出了基于计算机视觉的X射线图像异物分类研究,该算法主要是利用Tamura纹理特征和随机森林<sup>[4]</sup>对X射线异物进行自动识别分类.以上传统算法特征捕捉能力较差,检测模型缺少泛化能力,无法应用于海量数据集.

随着深度学习的发展,深度学习在安检图像处理算法得到了广泛应用.张友康等<sup>[5]</sup>提出了使用X光安检图像多尺度违禁品检测网络,对SSD网络<sup>[6]</sup>进行改进,增加了小卷积非对称模块、空洞多视野卷积模块以及多尺度特征图融合策略分别用于小尺度违禁品检测、违禁品遮挡以及背景干扰情况下违禁品的检测.马喆等<sup>[7]</sup>提出了一种改进的YOLOv3网络检测算法,对基础网络进行改进,引入多维输入图和多分辨率输入图,增加了输入样本的多样性,有效解决了模型的适应性差的问题.苏志刚等<sup>[8]</sup>提出了基于语义分割的多目标违禁品识别算法,在编码阶段设计使用空洞空间金字塔卷积模块(ASPC),同时引入注意力机制,对ASPC模块的特征提取过程进行监督,进一步提升模块的特征提取能力.Cui等<sup>[9]</sup>提出了一种使用RetinaNet自动检测货物X射线图像中枪支的方法,该方法提供了更精确的对象定位和更快的检测速度.然而以上基于深度学习的算法检出率并不是很高,存在漏检及误检的情况.

针对以上问题,本文基于深度学习的方法,提出了改进的Cascade RCNN<sup>[10]</sup>.在网络结构上,原有的Cascade RCNN网络在ROI Align<sup>[11]</sup>之后的特征并没有做任何

改动,而是直接进入后续的分类和回归,网络往往关注的是局部特征,其他特征就会受到抑制,从而不能得到有效鲁棒的特征.为了得到更加有效鲁棒的特征,在ROI Align之后添加批特征擦除(BFE)模块<sup>[12]</sup>,通过随机擦除同一批次特征,迫使网络强化其他特征的表达.在损失函数上,原有的损失函数在位置回归损失上缺少DIoU损失<sup>[13]</sup>,通过权重融合的方式将位置回归损失与DIoU损失进行融合,相当于为原网络增加了重叠面积和中心点距离损失,这样使得目标检测结果更加精确.

## 1 Cascade RCNN 设计与分析

### 1.1 Cascade RCNN 网络结构及原理

Cascade RCNN网络主要由特征提取网络ResNet101<sup>[14]</sup>、特征金字塔网络(feature pyramid network, FPN)<sup>[15]</sup>、RPN(region proposal network)<sup>[16]</sup>网络层以及级联检测器组成.特征提取网络ResNet101用于提取图片特征,将原图经过Conv1、Conv2、Conv3、Conv4以及Conv5卷积操作以及不同层次的特征融合得到不同尺度的特征图P2、P3、P4以及P5.然后将P2、P3、P4以及P5不同尺度的特征图输入到RPN中用于得到候选目标区域,将所得的候选目标区域做ROI Align操作后,得到7×7大小的ROI特征图.如图1 Cascade RCNN网络结构图.

在检测阶段,与Faster RCNN不同的是,Cascade RCNN使用级联检测器的方式进行检测,由3个检测器分别设置不同的阈值进行检测.每个检测器包括了ROI Align、全连接层、分类得分C和边框回归位置坐标B组成.检测时通过前一阶段检测器输出的边框回归B对候选目标区域进行重采样,逐步提升IoU阈值训练得到新的分类得分C和边框回归B,最终提升样本质量和网络训练效果.

### 1.2 Cascade RCNN 网络的RPN结构

RPN网络主要用于生成候选目标区域,首先通过RPN生成一堆anchor box<sup>[17]</sup>,对其进行设置阈值过滤后通过Softmax<sup>[18]</sup>分类器判断该anchors中的目标属于目标或者背景;同时,另一分支边框回归(bounding box regression<sup>[19]</sup>)修正anchor box,用于生成较为准确的proposal.

### 1.3 Cascade RCNN 网络的级联检测器

Cascade RCNN主要的改进是在Faster RCNN网络的基础上加入了级联检测器,级联各个检测模型,设置

不同的  $IoU^{[20]}$  阈值界定样本去训练模型, 让每一个阶段的检测都专注于检测  $IoU$  在某一个范围内的 proposal, 上一个检测模型的输出作为下一个检测模型的输入,

越往后检测模型的  $IoU$  阈值越不断提升, 反而也能使 RPN 网络输出更准确的候选目标区域, 从而减少假正样本出现的次数, 提高网络的精确度.

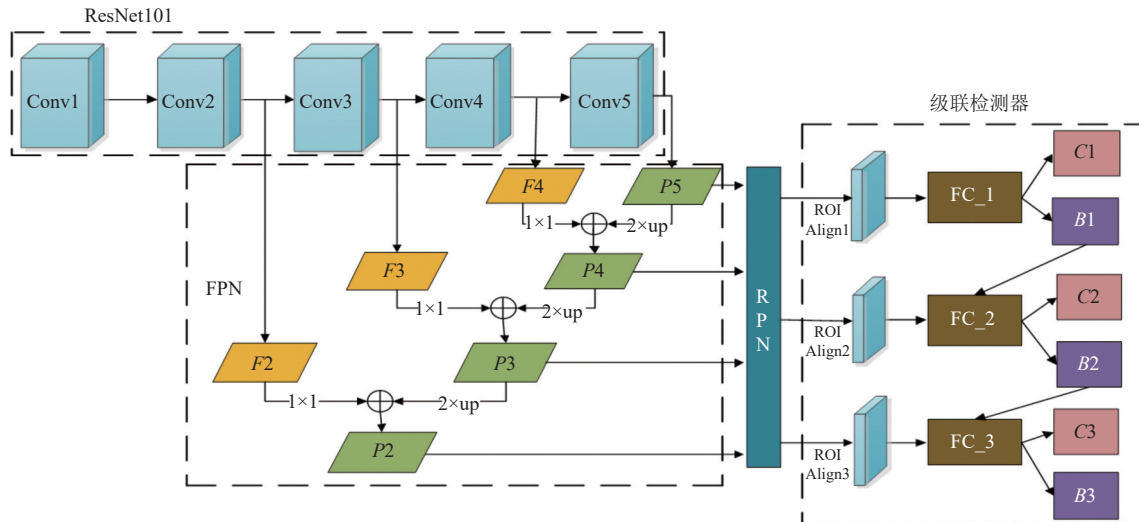


图1 Cascade RCNN 网络结构图

## 2 改进的 X 光安检图像检测模型

针对 Cascade RCNN 网络对 X 光违禁品检测存在检测率低下的问题, 本文提出了改进的 Cascade RCNN 网络违禁品检测算法如图 2 所示. 改进的 Cascade RCNN 将 ResNet101 网络输出的特征图自浅层至深层融合为特征金字塔并输出到 RPN 网络. 经过 RPN 进行候选区域的选取后, 将映射到原图的

ROI 与 P2、P3、P4 以及 P5 通过 ROI Align 层统一尺寸后融合. 然后将统一尺寸后的 ROI 特征图后引入一个 BFE 模块, 进行随机擦除同一批次的特征. 输入到全连接层 FC 进行分类和回归. 通过前一个阶段的检测器输出的边框回归对候选框目标区域进行重采样并逐步提升  $IoU$  阈值, 最终训练得到新的分类得分和边框回归.




图2 在 Cascade RCNN 中添加 BFE 模块

如图 2 所示, 改进的 Cascade RCNN 网络主要包括 ResNet101 特征提取网络、FPN 特征融合金字塔、

RPN 网络层以及级联检测器组成. 与原始的 Cascade RCNN 的区别是, 该网络主要在 ROI Align 得到的 ROI

特征图后添加了 BFE 模块进行批特征擦除. BFE 模块通过随机擦除同一批 ROI 特征图的不同区域, 随机丢弃同一批次特征, 防止出现过拟合, 从而使训练达到更好的效果.

### 2.1 批特征擦除

BFE 是通过随机擦除同一批次某个区域图像中所学习到的特征. 与 DropBlock 算法类似的都是丢弃空间相关性, 通过有效的随机丢弃局部语义信息, 激励网络学到更加鲁棒有效的特征. 与 DropBlock 不同的是 BFE 模块是使用批量处理, 将 FPN 层得到的 ROI 特征张量  $T$ , 经过批处理 BFE 模块后随机丢弃张量  $T$  的某个区域, 将该区域内所有单位清零, 迫使网络增强剩余区域的特征学习.

BFE 的本质是为了不让网络太关注那些太显而易见的全局特征. 通常 CNN 网络在卷积后往往会将焦点集中在某个局部位置的学习, 而其他位置则会受到抑制. 通过引入 BFE 模块对同一批次某个区域的所有特征进行随机丢弃, 也就是说它在同一批次图像中禁用了与其语义部分相关的所有特征, 迫使网络学习其他的特征.

BFE 模块结构图如图 3 所示, 将 ROI Align 映射后的特征图采用特征擦除的方式进行随机擦除. 通过随机产生通道数与 ROI 特征图相同、改变宽度缩放比例和高度缩放比例以及随机改变擦除位置, 生成一个

包含 0 与 1 的掩码张量, 将 ROI 特征图与该掩码张量相乘, 从而消除了掩码张量为 0 位置上的 ROI 特征, 保留了掩码张量为 1 的 ROI 特征, 强迫网络学习其它区域的特征, 强化剩余特征的表达, 加快网络的收敛速度. 同时, 采用这种擦除的训练方式去迭代训练, 网络具有更好的鲁棒性. 实验表明, 当掩码张量的宽度和高度缩放比例系数不同时, 训练出来的模型精度也有所差异. 本文中由实验结果证明, 宽度和高度缩放比例系数为 0.18 和 0.18 时可以达到最好的效果.

#### 算法 1. BFE 算法

输入: 输入张量  $T$ , 大小为  $B \times C \times H \times W$ ; 擦除高的缩放比例  $r_h$ , 擦除宽的缩放比例  $r_w$ ;  $T$  表示经过 ROI Align 处理后的特征图;  
输出: 输出张量  $T'$ ;

- 1) 初始化  $H, W$ :  $H, W \leftarrow T.size()[-2:]; /*$  其中,  $H$  和  $W$  分别为特征图的高和宽\*/;
- 2) 初始化  $H', W'$ :  $H' \leftarrow \text{round}(r_h * H), W' \leftarrow \text{round}(r_w * W); /*$   $H'$  和  $W'$  分别为擦除特征图的高和宽,  $\text{round}$  为对数字进行四舍五入\*/;
- 3) 计算  $Sy, Sx$ :  $Sy \leftarrow \text{random.randint}(0, H - H'), Sx \leftarrow \text{random.randint}(0, W - W'); /*$   $Sy$  和  $Sx$  分别为擦除的起始  $y$  坐标和起始  $x$  坐标,  $\text{random.randint}$  为随机产生整数\*/;
- 4) 初始化  $Mask$ :  $Mask \leftarrow T.new\_ones(T.size()); /*$   $Mask$  为与  $T$  大小相同, 值为 1 的张量\*/;
- 5) 计算  $Mask$ :  $Mask[:, :, Sx:Sx+W', Sy:Sy+H'] \leftarrow 0; /*$  将  $Mask$  中需要擦除的位置置为 0, 不需要擦除的位置置为 1\*/;
- 6) 计算  $T'$ :  $T' \leftarrow T * Mask; /*$   $T'$  为擦除后的特征图\*/.

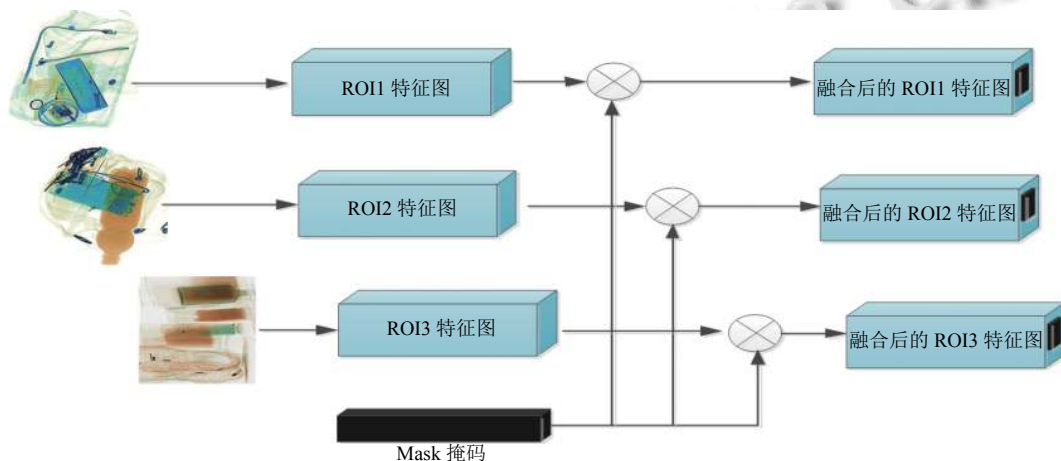


图 3 BFE 模块结构图

### 2.2 SD loss 损失函数

本文主要针对 Cascade RCNN 边框损失函数进行改进. Cascade RCNN 的损失函数主要由两部分组成,

分别是分类误差、坐标回归误差. 其公式如式 (1), 式 (2) 所示.

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

$$L_{\text{loc}}(t^u, v) = \sum_{i \in \{x, y, w, h\}} \text{smooth}_{L_1}(t_i^u - v_i) \quad (2)$$

其中,  $v = (v_x, v_y, v_w, v_h)$  表示真实框坐标,  $t^u = (t_x^u, t_y^u, t_w^u, t_h^u)$  表示预测框坐标, 利用  $\text{smooth}_{L_1}$  损失函数作为边框回归损失. 然而实际上评价框检测的指标是使用  $\text{IoU}$ , 多个检测框可能有相同的大小的  $\text{smooth}_{L_1}$ ,  $\text{IoU}$  可能差异很大. 为了解决这个问题, 在  $\text{smooth}_{L_1}$  的基础上, 与  $\text{DIOU loss}$  进行加权求和, 进而提高目标回归的准确性.

基于  $\text{IoU}$  系列的检测算法损失函数一般可以定义为  $L = 1 - \text{IoU} + R(B, B^{\text{gt}})$ , 其中  $B$  定义为预测框,  $B^{\text{gt}}$  定义为真实框,  $R(B, B^{\text{gt}})$  定义为  $B$  和  $B^{\text{gt}}$  的惩罚项. 而  $\text{DIOU loss}$  的惩罚项表示为  $R_{\text{DIOU}} = \frac{\rho^2(b, b^{\text{gt}})}{c^2}$ ,  $\rho(\cdot)$  定义为欧式距离公式,  $b$  表示预测框  $B$  的中心点,  $b^{\text{gt}}$  表示  $B^{\text{gt}}$  的中心点,  $c$  表示  $B$  和  $B^{\text{gt}}$  的最小外界矩形的对角线距离.  $\text{DIOU loss}$ 、 $\text{SD loss}$  定义如式 (3)–(4):

$$L_{\text{DIOU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} \quad (3)$$

$$L_{\text{SD}} = \alpha \text{smooth}_{L_1} + \beta L_{\text{DIOU}} \quad (4)$$

其中,  $\alpha$  和  $\beta$  分别是权重比例系数, 本文中  $\alpha$  和  $\beta$  均为 1.  $\text{SD loss}$  结合了坐标回归损失和  $\text{DIOU loss}$ , 在原有的坐标回归损失的基础上, 考虑到重叠面积和中心点距离的因素, 加上了重叠面积和中心点距离损失. 对坐标回归损失和  $\text{DIOU loss}$  这两种损失函数以权重比例系数的方式进行加权融合, 使目标回归的准确率更高, 并且模型收敛速度更快.

## 3 实验设计与结果分析

### 3.1 实验环境以及数据集构建

为了分析和评估本文提出的算法的性能. 本节在 X 光数据集上进行对比实验.

实验环境配置: CPU 为 Intel(R) Core(TM) i7-4790K CPU; 主频为 4.00 GHz; 内存为 8 GB; 系统为 Linux 4.4.0-130-generic x86\_64 位; GPU 为 NVIDIA Corporation GM204 [GeForce GTX 970].

数据集: 在构建数据集上, 从公开数据集中采集了 3 600 张 X 光安检图像, 数据集中包括需要检测 10 种类别的违禁品, 包括刀具、剪刀、打火机、打火机油、压力容器罐、弹弓、手铐、指甲油、充电宝、烟花爆竹. 使用了 3 240 张作为训练集, 360 张作为验证集. 如图 4 所示数据集样本.




图 4 样本数据集样例

### 3.2 消融实验

#### 3.2.1 BFE 不同宽高比缩放比例系数的对比实验

本节实验采用 `mmdetection` 工具进行实验, 特征提取网络 backbone 使用 ResNet101, 使用 ImageNet 的预训练模型, 学习率设置为 0.001 25, Batchsize 设置为 2, 训练 50 个 epoch. 采用 Cascade RCNN+ResNet101+BFE 进行实验发现, 使用 BFE 模块进行训练的过程中, 采用不同的宽高缩放比例, 即  $r_h$  和  $r_w$  不同缩放比例系数时, 测试 X 光图像数据集的 mAP 值均有所差异. 当采用不同的宽高缩放比例系数时, 得到如表 1 所示结果.

表 1 验证 BFE 模块使用不同的宽高缩放比例系数时 mAP 的增长情况 (%)

宽高缩放比例系数	mAP
0.15, 0.15	84.56
0.16, 0.16	84.79
0.18, 0.18	85.71
0.19, 0.19	85.70
0.20, 0.20	84.99
0.21, 0.21	84.76
0.22, 0.22	84.73
0.23, 0.23	84.66
0.24, 0.24	84.58
0.25, 0.25	84.59

如表 1 所示, 当设置 BFE 模块的宽高缩放比例系数为 0.15 和 0.15 时, 验证 X 光数据集的 mAP 为 0.845 6, 当宽高缩放比例系数为 0.18 和 0.18 时, mAP 增长了 1.15%, 当宽高缩放比例系数超过 0.18 和 0.18 时, 验证 X 光数据集的 mAP 在不断减小. 说明宽高缩放比例系数的大小对 BFE 模块是一个重要的因素, 同时也影

响整个改进的 Cascade RCNN 网络的精度。

### 3.2.2 SD loss 不同权重比例系数的对比实验

采用 Cascade RCNN+ResNet101+SD loss 进行实验发现,使用 SD loss 损失函数进行训练时,不同的权重比例系数会影响实验结果。当采用不同的权重比例系数时,得到如表 2 所示结果。

表 2 验证 SD loss 使用不同的权重比例系数时

mAP 的增长情况 (%)	
权重比例系数	mAP
0.5:1	84.58
1:1	87.53
1:0.5	84.59

如表 2 所示,当使用 SD loss 损失函数权重比例系数设置为 0.5:1 时,验证 X 光数据集的 mAP 为 0.845 8,当权重比例系数为 1:1 时,mAP 增长了 2.95%,说明权重比例系数的大小对 SD loss 损失函数是一个重要的因素,同时也影响整个改进的 Cascade RCNN 网络的精度。

### 3.2.3 不同模型的对比实验

在实验的过程中,分别加入 BFE 模块以及 SD loss 损失函数不同模型进行对比实验,使用 mAP 作为评价标准。实验结果如表 3 所示。

表 3 验证分别加入 BFE 模块以及 SD loss 损失函数后的

mAP 的增长情况 (%)	
模型	mAP
Cascade RCNN+ResNet101	84.53
Cascade RCNN+ResNet101+BFE	85.71
Cascade RCNN+ResNet101+BFE+SD loss	87.64

如表 3 所示,当使用 Cascade RCNN+ResNet101 进行训练时,验证 X 光数据集的 mAP 值为 0.845 3。加入 BFE 模块后 mAP 为 0.857 1,加入后增长了 0.011 8。说明加入 BFE 模块后准确率有一定的提高,再加入 SD loss 损失后 mAP 值为 0.876 4,相比原算法提升了 0.031 1。说明改进的损失函数和改进的网络结构对 X 光安检检测的准确率有一定的提升。

### 3.2.4 不同算法的对比实验

在实验的过程中,分别将改进的 Cascade RCNN 算法与其它目标检测算法进行对比实验,使用 mAP 作为评价标准。实验结果如表 4 所示。

如表 4 所示,当使用改进的 Cascade RCNN 算法进行训练时,验证 X 光数据集的 mAP 值为 0.876 4。当

使用 Faster RCNN 和 Mask RCNN 这些双阶段算法进行训练时,验证 X 光数据集的 mAP 值分别为 0.802 8 和 0.817 3。同时,也对比了单阶段 RetinaNet 检测算法,说明改进的 Cascade RCNN 算法比同类型的双阶段检测算法以及单阶段检测算法的精度更高。

表 4 分别验证其它目标检测算法和改进 Cascade RCNN 算法的 mAP 的增长情况 (%)

目标检测算法	mAP
Cascade RCNN+ResNet101+BFE+SD loss	87.64
Cascade RCNN+ResNet101	84.53
Faster RCNN+ResNet101	80.28
Mask RCNN+ResNet101	81.73
RetinaNet+ResNet101	73.74

## 4 结论与展望

本文基于 Cascade RCNN 网络,在网络结构上,引入一个 BFE 批特征擦除模块,通过随机擦除同一批次中的相同区域,迫使网络学习其他区域的特征,加强其他区域特征的学习,增强了模型的鲁棒性。同时,验证了当 BFE 中宽高缩放比例系数为 0.18 和 0.18 时,可以达到最好的效果。提出一个加权 SD loss 损失函数,该损失函数将 Smooth L1 loss 与 DIoU loss 进行加权融合,通过调整权重比例系数,使边界检测结果更加准确。测试性能与原算法相比,改进的 Cascade RCNN 网络的 mAP 增长了 3.11%,精度得到了提升。最后,将改进的算法与同类型的双阶段检测算法和单阶段检测算法进行对比,改进的算法比其它目标算法的精度更高。

## 参考文献

- 苏冰山,陈继光,陈雨.基于联合特征的 X 光图像违禁品分类方法.数字技术与应用,2019,37(5):76-77.
- 刘颖,王伊琳,王倩,等.基于有偏彩色纹理字典的 X 光安检图像检测.西安邮电大学学报,2017,22(6):35-39.
- 王宇,邹文辉,杨晓敏,等.基于计算机视觉的 X 射线图像异物分类研究.液晶与显示,2017,32(4):287-293.
- 李永丽,王浩,金喜子.基于随机森林优化的自组织神经网络算法.吉林大学学报(理学版),2021,59(2):351-358.
- 张友康,苏志刚,张海刚,等.X 光安检图像多尺度违禁品检测.信号处理,2020,36(7):1096-1106.
- 谢淋东,仲志丹,乔栋豪,等.多尺度卷积特征融合的 SSD 手势识别算法.计算机技术与发展,2021,31(3):100-105.[doi:10.3969/j.issn.1673-629X.2021.03.017]
- 马喆,丁军航,谭虹.基于神经网络的违禁品检测研究.青

- 岛大学学报(工程技术版), 2020, 35(2): 30–36.
- 8 苏志刚, 姚少卿. 基于语义分割的多目标违禁品识别算法. 信号处理, 2020, 36(11): 1940–1946.
  - 9 Cui YQ, Oztan B. Automated firearms detection in cargo X-ray images using RetinaNet. Proceedings of SPIE 10999 Anomaly Detection and Imaging with X-rays (ADIX) IV. Baltimore: SPIE, 2019. 109990P.
  - 10 Cai ZW, Vasconcelos N. Cascade R-CNN: Delving into high quality object detection. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 6154–6162.
  - 11 Teichmann M, Weber M, Zöllner M, *et al.* Multinet: Real-time joint semantic reasoning for autonomous driving. 2018 IEEE Intelligent Vehicles Symposium (IV). Changshu: IEEE, 2018. 1013–1020.
  - 12 Dai ZZ, Chen MQ, Gu XD, *et al.* Batch dropblock network for person re-identification and beyond. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 3690–3700.
  - 13 Zheng ZH, Wang P, Liu W, *et al.* Distance-IoU loss: Faster and better learning for bounding box regression. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993–13000. [doi: [10.1609/aaai.v34i07.6999](https://doi.org/10.1609/aaai.v34i07.6999)]
  - 14 Kim SW, Kook HK, Sun JY, *et al.* Parallel feature pyramid network for object detection. Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018. 239–256.
  - 15 Xu H, Yao LW, Li ZG, *et al.* Auto-FPN: Automatic network architecture adaptation for object detection beyond classification. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 6648–6657.
  - 16 田桂丰, 单志龙, 廖祝华, 等. 基于 Faster R-CNN 深度学习的网络入侵检测模型. 南京理工大学学报, 2021, 45(1): 56–62.
  - 17 万卓, 叶明, 刘凯. 基于改进 YOLOv4 的电机端盖缺陷检测. 计算机系统应用, 2021, 30(3): 79–87. [doi: [10.15888/j.cnki.csa.007808](https://doi.org/10.15888/j.cnki.csa.007808)]
  - 18 Munkhdalai L, Ryu KH, Namsrai OE, *et al.* A partially interpretable adaptive softmax regression for credit scoring. Applied Sciences, 2021, 11(7): 3227. [doi: [10.3390/app11073227](https://doi.org/10.3390/app11073227)]
  - 19 陈兆凡, 赵春阳, 李博. 一种改进 IoU 损失的边框回归损失函数. 计算机应用研究, 2020, 37(S2): 293–296.
  - 20 赵艳芹, 何东来, 朱子寒. 煤矿井下集成学习的安全帽佩戴检测算法. 黑龙江科技大学学报, 2021, 31(2): 240–246. [doi: [10.3969/j.issn.2095-7262.2021.02.018](https://doi.org/10.3969/j.issn.2095-7262.2021.02.018)]

(校对责编: 孙君艳)