

# 基于改进 Faster R-CNN 的纸病检测算法

汤伟, 王锦韞, 张龙

(陕西科技大学, 电气与控制工程学院, 西安 710021)

**摘要:** **目的** 达到纸病检测中能够充分提取纸病特征、提高检测精度、降低小目标漏检率的目标。**方法** 基于 Faster R-CNN 的检测算法进行改进, 主要改进的做法是利用深度残差网络 ResNet-50 替换原模型的骨干特征提取网络 VGG16, 以保留更多的纸病特征信息, 增强特征网络对纸张缺陷的提取能力; 在算法中添加空间和通道的双重注意力机制 CBAM, 用来提高纸病检测精度; 将 ROI-Pooling 替换为 ROI-Align, 增强网络的泛化能力。**结果** 实验结果表明, 改进后的算法平均精度达到 98%, 较原算法平均精度提升了 9%。**结论** 改进后的算法能够充分提取纸病特征信息, 有效提高了纸病的检测精度, 以及提高了小目标纸病的检测率, 降低了错漏检率。

**关键词:** 纸病检测; Faster R-CNN; ResNet-50; 卷积块双重注意力机制; ROI-Align

**中图分类号:** TP391 **文献标识码:** A **文章编号:** 1001-3563(2023)21-0260-07

**DOI:** 10.19554/j.cnki.1001-3563.2023.21.032

## Paper Defect Detection Algorithm Based on Improved Faster R-CNN

TANG Wei, WANG Jin-yun, ZHANG Long

(School of Electrical and Control Engineering, Shaanxi University of Science & Technology, Xi'an 710021, China)

**ABSTRACT:** The work aims to achieve the goal of fully extracting paper defect features, improving detection accuracy and reducing detection rate of small targets in paper defect detection. The detection algorithm was improved based on Faster R-CNN. The main improvements were as follows: the backbone feature extraction network VGG16 of the original model was replaced by the deep residual network ResNet-50 to retain more feature information of paper defect and enhance the feature network's ability to extract paper defects. The dual attention mechanism CBAM of space and channel was added to the algorithm to improve the accuracy of paper defect detection. ROI-Pooling was replaced with ROI-Align to enhance the generalization ability of network. The experimental results indicated that the average accuracy of the improved algorithm reached 98%, which was 9% higher than that of the original algorithm. The improved algorithm can fully extract the feature information, effectively improve the detection accuracy of paper defect, improve the detection rate of small target paper defect, and reduce the error and miss detection rate.

**KEY WORDS:** paper defect detection; Faster R-CNN; ResNet-50; Convolution at Block Attention Module; ROI-Align

在纸张产品制造过程中, 受到机器设备损坏、生产工艺、现场条件等诸多因素干扰, 造成纸张产生不同的瑕疵, 如褶皱、黑点、孔洞、裂缝、蚊虫等, 称为纸病。就一般纸张而言, 纸病会对普通纸张的美观产生负面影响<sup>[1]</sup>, 对纸张的应用亦产生了不同程度的

不良影响。作为高端或特种应用的纸张来说, 微小的纸病就可以带来很大的影响, 例如对航空航天用纸而言, 可能会造成飞行记录出错, 造成巨大的经济损失, 甚至带来安全隐患<sup>[2]</sup>。因此, 纸病诊断是造纸过程中必不可少的一环。

收稿日期: 2023-03-15

基金项目: 陕西省技术创新引导专项 (2020CGHJ-007); 陕西省教育厅自然专项 (17JK0645); 西安市科技计划项目 (2020KJRC0146)

传统的纸病检测算法一般使用人工方式提取纸病特征<sup>[3]</sup>, 人们通过肉眼发现纸张存在的问题, 再将获取到的纸病特征输入到分类器中, 但是传统的提取方法适用于较低车速的纸机, 随着纸机车速和纸张宽幅不断提高, 纸张出现缺陷的几率增加, 传统的人工提取特征的方法已经无法满足生产需要。由于卷积神经网络 (Convolutional Neural Network, CNN) 具有直接提取特征, 并进行筛选和分类的能力<sup>[4]</sup>。因此基于深度学习的目标检测, 利用 CNN 直接提取图像中的特征, 再对提取到的特征进行分类, 使得检测效果大大提高。

目前, 已经有研究人员将 CNN 应用到纸病检测中, 例如曲蕴慧等<sup>[4]</sup>将 VGG16 网络与迁移学习结合, 提高了纸病识别精度和准确性; 高乐乐等<sup>[5]</sup>利用 CNN 深层次提取纸病特征, 解决了传统算法中纸病特征量提取困难的问题; 李果等<sup>[6]</sup>提出了基于 Faster R-CNN 的纸张缺陷检测方法, 引入非局部均值算法, 能够实现准确定位和分割纸病图像。但目前这些算法通常以较大纸病为主, 小目标纸病的检测精度较低, 因此针对小目标的检测精度较低的问题, 提出一种基于改进 Faster R-CNN 的纸病检测算法。首先选择 Faster R-CNN<sup>[6]</sup>作为纸病检测模型, 原始的 Faster R-CNN 算法中选择的 VGG16<sup>[7-8]</sup>基础网络, 在每个卷积层后都接了池化层对特征图进行池化, 进行了多次池化操作, 可能会造成特征信息的丢失, 而 ResNet-50<sup>[9-11]</sup>网络是一个基于残差单元的深度卷积神经网络, 虽然层数较深, 但参数较少, 并且只有 2 个池化层, 能够保留更多的图片特征信息。其次通过添加空间和通道的卷积块注意力机制 (Convolution at Block Attention Module, CBAM), CBAM 中同时使用最大池化和平均池化池化, 能够保证特征信息的充分提取, 提高纸病检测精度, 以及使用 ROI-Align 代替 ROI-Pooling 的方式增强网络的泛化能力, 提高小目标纸病的检测率, 降低漏检率。

本文首先介绍目标检测算法 Faster R-CNN 的研究背景及主要结构, 然后对 Faster R-CNN 的缺点进行的改进, 最后进行实验, 并对原模型和改进后算法进行分析对比。

## 1 Faster R-CNN 目标检测算法模型

R-CNN 通过 CNN 网络提取特征, 再利用 SVM 训练器进行特征分类; Fast R-CNN 则是通过构建 ROI 池化层提取特征区域, 并通过 SoftMax 函数实现对特征的分类, 进一步提高速率和准确性; 在 Fast R-CNN 基础上进行优化的检测算法 Faster R-CNN, 是利用加入神经网络 RPN 实现边缘提取的方法, 通过直接获取候选区域, 以进一步提高模型的时间有效性和检测目标的精度。Faster R-CNN 基本结构如图 1 所示。

Faster R-CNN 具体的工作流程<sup>[12]</sup>如下。

1) 特征提取。首先将图像输入到卷积神经网络中提取图像的特征数据, 并得到对应的特征图, 然后把得到的特征图导入到区域生成网络 (RPN) 中生成相应的候选区域。

2) 候选框生成。RPN 负责在特征图上生成候选区域, 再通过归一化指数函数 (SoftMax) 将锚框 (Anchors) 进行二分类, 然后使用边框回归网络 (Bounding Box Regression) 对锚框进一步校正, 得到更加精确的目标候选框 (Proposal boxes)。

3) ROI 池化。ROI-Pooling 池化层收集了第 2 步中得到的目标候选框以及第 1 步得到的特征图像, 把这些目标候选框映射回特征图中获取目标特征图 (Proposal Feature Maps), 并输入至后面的全连接层, 以判断目标类型。

4) 分类回归。边界回归利用目标特征图计算每个目标不同类别的概率信息, 利用边界回归网络确定目标对象的准确位置, 以此获得检测结果。

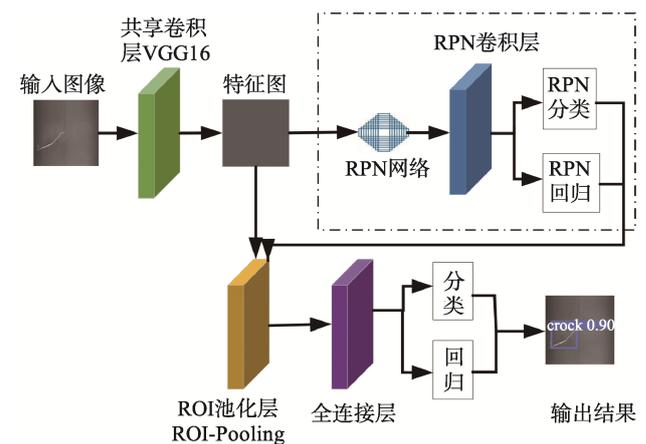


图 1 Faster R-CNN 基本结构  
Fig.1 Basic structure of Faster R-CNN

虽然 Faster R-CNN 能够实现高精度的检测, 但仍存在以下缺点: 原模型中 VGG16 网络结构存在网络参数多, 但层数少的问题, 容易出现梯度消失的情况; ROI-Pooling 中存在 2 次取整量化, 会引起精度丢失。针对这些问题, 该算法提出了改进。

## 2 Faster R-CNN 算法模型的改进

### 2.1 特征提取网络的选取

将 Faster R-CNN 原模型的骨干网络 VGG16 替换为深度残差网络 ResNet-50, 可以更好地提取图像上的特征, 使得提取到的纸病特征更加精细, 从而优化后续的检测效率。

VGG16 网络结构的缺点是网络参数多, 但是层数少, 而 ResNet-50 网络是一个基于残差单元的深度

卷积神经网络, 残差单元结构如图 2 所示。假设残差网络的输入为  $x$ , 第 1 个卷积层对输入进行卷积操作, 第 2 个卷积层将卷积后的结果再次进行卷积操作, 并将卷积结果与输入  $x$  相累加, 得到最终的输出  $F(x)+x$ 。当卷积神经网络发生梯度弥散问题时,  $F(x)=0$ , 即输入输出为恒等映射。残差网络的优点是通过跨层直接连接的方式将前面的信息直接添加到后面的层中, 从而有效克服了传统深层网络在训练过程中可能出现的梯度消失和梯度爆炸问题, 也使得模型更加易于训练和收敛<sup>[13]</sup>。

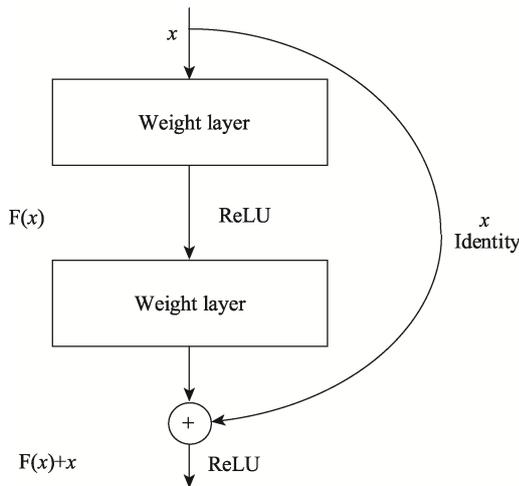


图 2 残差单元结构  
Fig.2 Residual element structure

VGG16 特征选取网络有 13 层为卷积层, 每个卷积层后都接了池化层对特征图进行池化, 进行多次池化操作, 可能会造成特征信息的丢失。替换后的 ResNet-50 网络结构如图 3 所示, 该网络结构中只含有 2 个池化层, 能够避免多次池化造成的信息丢失问题, 以保留更多的图片特征信息。

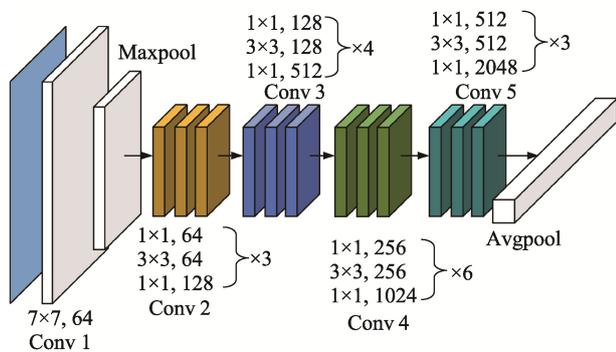


图 3 ResNet-50 结构  
Fig.3 Structure of ResNet-50

## 2.2 注意力机制的添加

CBAM 是一个用于前馈卷积神经网络的注意力

模块<sup>[14]</sup>, 它融合了空间和通道 2 种注意力机制, 能够突出特征图中的关键特征, 舍弃无关特征。CBAM 模块的结构如图 4 所示, 其中包含了通道注意力模块 (Channel Attention Module, CAM) 和空间注意力模块 (Spatial Attention Module, SAM)。

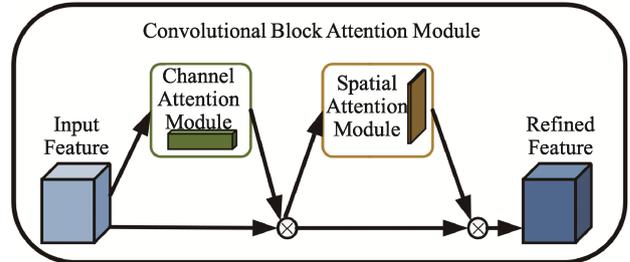


图 4 CBMA 注意力机制模块  
Fig.4 CBAM module

CAM 子模块: 通道层次不变, 减少空间层次。如图 5 所示, 首先对输入的特征图像并行地执行最大池化 (MaxPool) 和平均池化 (AvgPool) 操作来聚合特征图的空间信息, 生成 2 个不同的空间描述, 分别表示平均池化特征和最大池化特征。将特征图从  $C \times H \times W$  变为  $C \times 1 \times 1$  的大小, 再将其输入一个共享全连接 (Share MLP) 模块得到 2 个输出结果, 共享网络包含隐藏层, 隐藏激活大小设置为  $R^{C/r \times 1}$ , 其中  $r$  为缩减比, 然后将 2 个输出结果进行相加, 并通过一个 sigmoid 激活函数获得通道注意力的输出结果, 再和原图相乘, 变回  $C \times H \times W$  的大小。文献[14]中认为最大池化用来编码最显著部分的特征, 可以对平均池化特征进行补偿编码。与单独使用一个池化特征相比, 同时利用这 2 个特征能够大大提高网络的表征能力。通过消融实验, 分别对单独使用最大池化、单独使用平均池化、并行使用最大池化与平均池化作对比, 发现并行最大池化和平均池化操作效果最好。

通道注意力公式见式 (1)。

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) = \sigma(W_1(W_0(F_{avg}^C)) + W_1(W_0(F_{max}^C))) \quad (1)$$

式中:  $F$  为输入特征;  $\sigma$  为 sigmoid 函数;  $W_0 \in R^{C/r \times C}$ ;  $W_1 \in R^{C/r \times r}$ 。MLP 权重  $W_0$  和  $W_1$  是 2 个输入共享的。

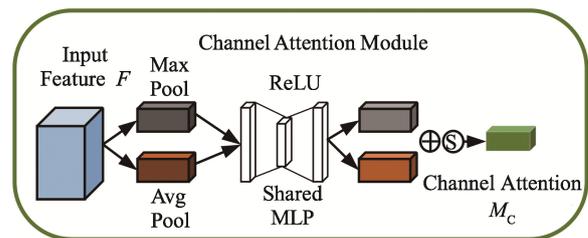


图 5 CAM 子模块示意图  
Fig.5 Schematic diagram of CAM module

SAM 子模块: 空间层次不变, 压缩通道层次。如图 6 所示, 与 CAM 相对应, 将通道注意力模块得到的输出结果依次进行最大池化和平均池化操作, 将它们连接起来能够生成一个有效的特征描述符 (文献[14]说明沿着通道轴进行最大池化和平均池化操作能够更加有效地显示信息域), 获得 2 个  $1 \times H \times W$  的特征图并加以拼接; 随后再经过  $7 \times 7$  的卷积运算操作获得单通道的特征图; 然后通过利用一个 sigmoid 函数获得空间注意力的输出结果; 最后与原图相乘变回  $C \times H \times W$  大小。

空间注意力公式见式 (2)。

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) = \sigma(f^{7 \times 7}([F_{\text{avg}}^S; F_{\text{max}}^S])) \quad (2)$$

式中:  $F$  为输入特征;  $\sigma$  为 sigmoid 函数;  $f^{7 \times 7}$  为  $7 \times 7$  的卷积核。

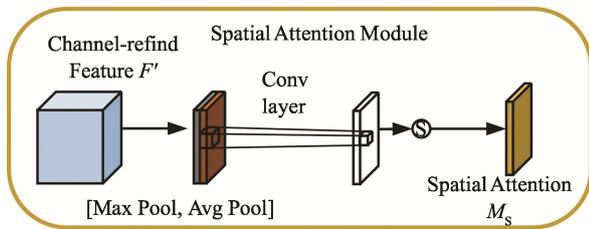


图 6 SAM 子模块示意图  
Fig.6 Schematic diagram of SAM submodule

文献[14]还对通道和空间 2 个模块的串行顺序和并行方式放置进行了广泛的消融实验, 最终发现先通道再空间模块的排列效果最好。

### 2.3 ROI-Pooling 的替换

在 Faster R-CNN 中, RPN 网络会产生不同尺寸的候选框, 于是引入 ROI-Pooling 层, 通过特征池化使得不同大小的候选框区域大小相同。ROI-Pooling 中有 2 次取整量化, 第 1 次是将输入的候选框浮点数的位置坐标量化为整数, 第 2 次则是将量化后的候选区域平均划分成  $M \times M$  单元, 然后对每个单元的边沿加以取整量化。这 2 次量化操作容易造成测量框的位置误差, 对小目标的检测效果不明显, 会降低检测的精度。本文检测目标为纸病, 部分纸病几何面积较小, 所占图像像素个数较少, 因此利用 ROI-Align 进行改进, 提高网络的泛化能力。

ROI-Align 结构克服了 ROI-Pooling 结构中存在的 2 次量化误差, 维持原有浮点数值不变, 采用双线性插值算法得到图像坐标浮点数的像素值, 尽可能地减少量化误差。ROI-Align 的结构如图 7 所示, 水平虚线落在像素点上, 表明并不是直接进行量化, 而是保留了浮点数, 然后再利用双线性插值方法找到图中“×”的像素点, 以减少量化误差的产生。

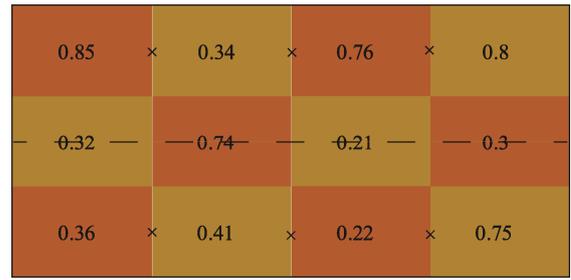


图 7 ROI-Align 结构示意图  
Fig.7 Schematic diagram of ROI-Align structure

操作过程如图 8 所示, 虚线框表示卷积后获得的特征图, 实线框表示 ROI 特征, 利用双线性插值算法来估计这些双线性插值的网格点所对应的像素值, 然后在全部的橘色区域里面进行最大池化计算和平均池化计算, 最后都会输出  $2 \times 2$  的结果。ROI-Align 在操作过程中由于没有采用量化运算操作, 因此不会引入误差, 可以大大提高检测的精度。改进后的 Faster R-CNN 算法结构如图 9 所示。

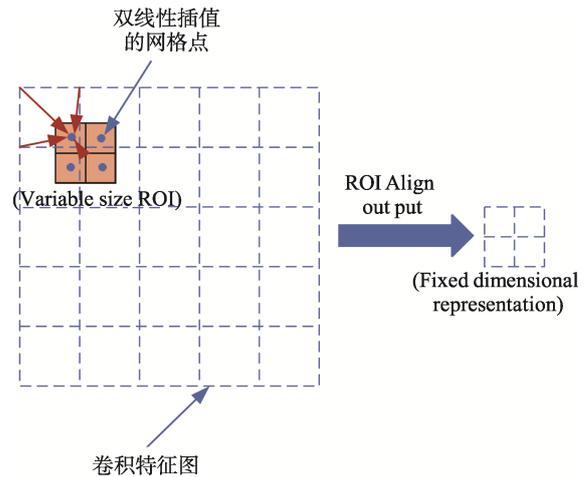


图 8 ROI-Align 操作示意图  
Fig.8 Schematic diagram of ROI-Align operation

## 3 实验结果对比分析

### 3.1 纸病图像数据集采集及预处理

在本课题中, 主要选择对孔洞、黑点、褶皱、裂痕这 4 类常见纸病图像进行研究, 通过实验室纸机设备采集了 4 类纸病图像以及无纸病图像进行研究。对于实验室采集的纸病图像, 其来源是相机拍摄的原始图像, 它们的尺寸不一, 因此需要进行标准化处理, 以方便后续算法的处理。为了使算法的复杂度尽可能地降低, 并且使纸张图像尽可能地突显病区, 可以使用最小外接矩形的方法来对纸张图像进行截取, 并将所有图像的尺寸通过软件调整为  $224 \times 224$  像素的图像。经过尺寸标准化处理后, 再使用 labeling 图片标注工具对每个样本图像进行纸病类型的标记。最终得到的纸病图像数据集, 如表 1 所示。

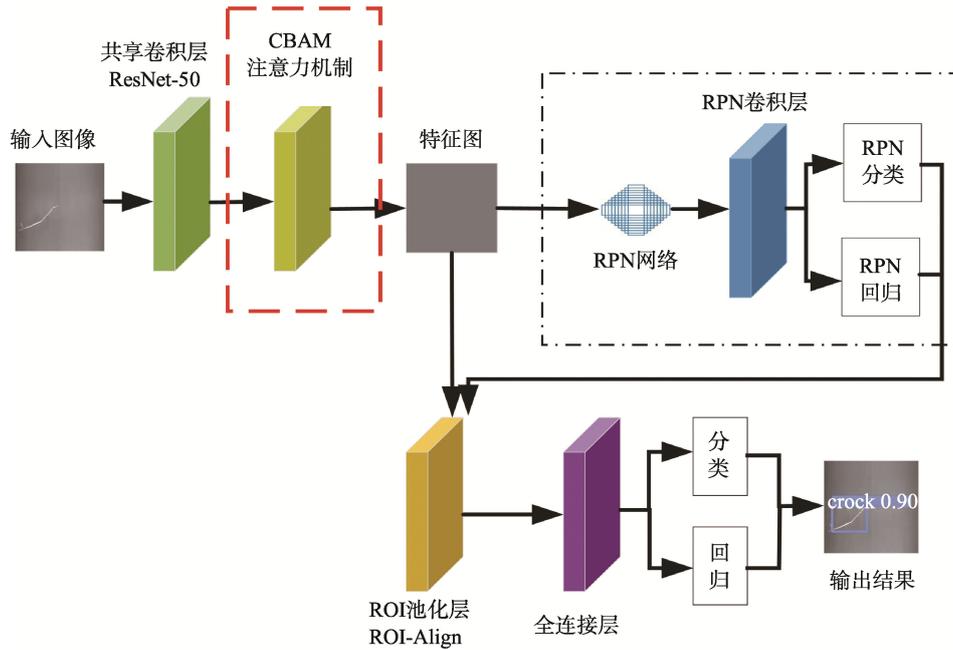


图9 改进后的 Faster R-CNN 结构图  
Fig.9 Structure diagram of the improved Faster R-CNN

表1 纸病数据集的统计信息  
Tab.1 Statistics for paper defect dataset

数据集	孔洞	划痕	黑点	褶皱
训练集	635	657	652	639
测试集	97	105	80	137
合计	732	762	732	776

### 3.2 实验配置

纸病检测模块实验环境配置如表2所示。

表2 实验环境配置  
Tab.2 Experimental environment configuration

实验环境	配置参数
CPU	Intel(R) Core(TM) i5-10210X CPU @ 1.60 GHz
GPU	NVIDIA GeForce MZ350
操作系统	Win10
编程语言	Python3.9
深度学习框架	Pytorch1.13

超参数的设置：采用批量梯度下降算法，将批量 batch size 定义为 4，训练次数 epoch 定义为 100，初始学习率定义为 0.001，衰减系数定义为 0.000 5。

### 3.3 评价指标

在深度学习的目标检测模型中选用的主要评价指标有：精确率  $P$ 、召回率  $R$ 、平均精度  $\delta_{AP}$  以及平

均精度均值  $\delta_{mAP}$ ，计算式分别见式(3)~(6)。

$$\delta_P = \frac{\delta_{TP}}{\delta_{TP} + \delta_{FP}} \quad (3)$$

$$\delta_R = \frac{\delta_{TP}}{\delta_{TP} + \delta_{FN}} \quad (4)$$

$$\delta_{AP} = \int_0^1 \delta_P(\delta_R) d\delta_R \quad (5)$$

$$\delta_{mAP} = \sum_{i=1}^n \delta_{AP_i} \quad (6)$$

式中： $\delta_{TP}$  为算法正确识别出的纸病样本； $\delta_{FN}$  为算法没有正确识别出的纸病样本； $\delta_{FP}$  为算法检测错误的负样本。

对生产企业来说，纸病检测中纸病的漏检率和误检率也是一项重要的性能指标。

### 3.4 实验结果对比分析

实验1选取了待检测纸病图像孔洞、裂痕、黑点、褶皱各100张，分别对Faster R-CNN原始算法和本文改进后的Faster R-CNN算法进行检测。错检、漏检结果如表3和表4所示。

表3 Faster R-CNN 算法错漏检结果  
Tab.3 Error and miss detection results of Faster R-CNN algorithm

纸病	正确检测数	正确率/%	漏检数	漏检率/%	误检数	误检率/%
孔洞	96	96	3	3	1	1
裂缝	98	98	2	2	0	0
黑点	94	94	4	4	2	2
褶皱	96	96	2	2	2	2

表 4 改进后的 Faster R-CNN 算法错漏检结果  
Tab.4 Error and miss detection results of improved Faster R-CNN algorithm

纸病	正确检测数	正确率/%	漏检数	漏检率/%	误检数	误检率/%
孔洞	99	0.99	1	1	0	0
裂缝	100	1.00	0	0	0	0
黑点	98	0.98	2	2	0	0
褶皱	99	0.99	1	1	0	0

从表 3 和表 4 的数据可以看出, 本文采用改进后的 Faster R-CNN 算法模型在测试准确率上表现良好, 且错检和漏检率也有所降低。

实验 2 设计了消融实验, 分别对 Faster R-CNN 算法、各项改进后的 Faster R-CNN 算法以及整体改进后的算法进行对比, 对比结果如表 5 所示。

表 5 原始算法与改进算法的精度对比  
Tab.5 Accuracy comparison between the original algorithm and the improved algorithm

算法	平均精度/%				平均精度均值/%
	孔洞	划痕	黑点	褶皱	
Faster R-CNN	85.4	89.2	92.3	91.1	89.5
Faster R-CNN+ResNet-50	92.7	94.1	97.2	95.2	94.8
Faster R-CNN+CBAM	91.3	93.4	96.7	96.8	94.5
Faster R-CNN+ROI-Align	93.1	93.8	97.8	95.6	95.1
改进后的 Faster R-CNN	96.3	97.8	99.5	98.2	98.0

由表 5 中可知, 经过各项改进后的 Faster R-CNN 算法与原 Faster R-CNN 算法相比, 都进一步提升了检测准确度, 证明了算法的优越性。

原 Faster R-CNN 算法和各项改进后的 Faster R-CNN 算法对纸病检测结果的 P-R 曲线如图 10 所示。曲线与坐标轴包围的区域面积为平均精度值, 区

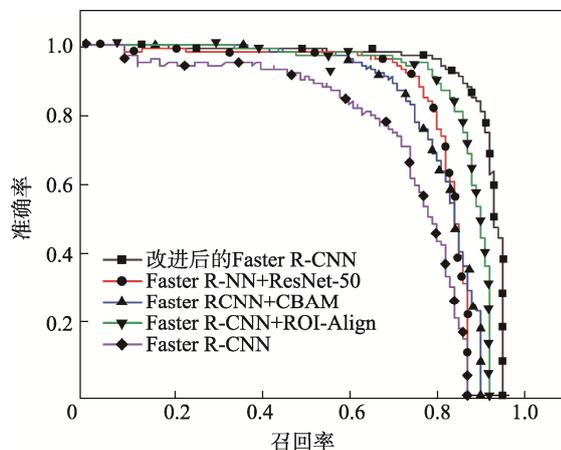


图 10 改进前后算法的 P-R 曲线  
Fig.10 P-R graph before and after the algorithm improvement

域面积越大, 检测性能越好。从图 10 中可以看出, 改进后的 Faster R-CNN 模型在纸病检测方面的效果都得到了提升。

改进后的算法检测出的纸病结果如图 11 所示。图 11 中展示了几种纸病的检测结果, 包括黑斑、划痕、孔洞和褶皱等。这些纸病在图像中的占比不同, 其中褶皱和黑点的纸病图像与背景的对比度差距特别小, 但是改进后的算法仍能保持较高的检测精度和精准的定位。

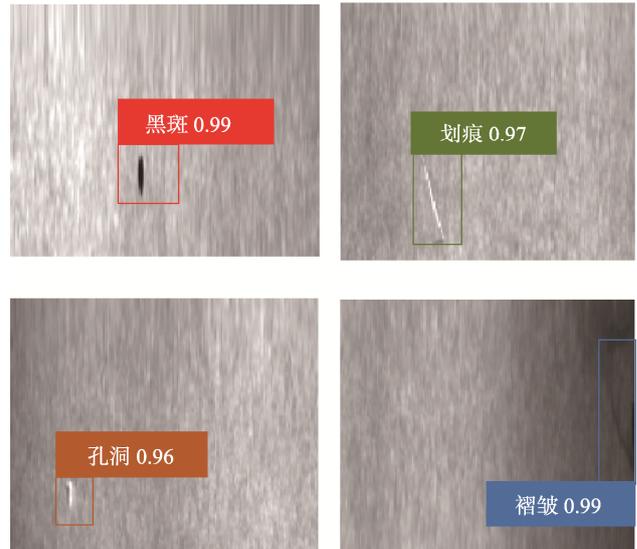


图 11 纸病检测效果  
Fig.11 Paper defect detection effect

## 4 结语

本文针对 Faster R-CNN 算法中特征提取不够充分、小目标纸病检测精度不佳等问题, 对原 Faster R-CNN 算法进行改进, 通过实验对比 2 种骨干特征网络, 选择了 ResNet-50 代替 VGG16 作为特征提取网络, 增加了网络层数, 能够提取更为丰富的纸病特征, 还添加了 CBAM 注意力机制, 提高纸病的检测精度, 此外还使用 ROI-Align 代替 ROI-Pooling 的方式增强网络的泛化能力。实验结果显示改进后的算法平均精度达到 98%, 较原算法平均精度提升了 9%, 并且降低了错检、漏检率。这表明改进后的算法能够有效提高目标纸病的检测效率和精度, 证明了算法的鲁棒性。

### 参考文献:

[1] 周强, 陈颖, 沈天宇, 等. 基于机器视觉的纸病检测系统发展综述[J]. 中国造纸, 2016, 35(5): 72-79.  
ZHOU Qiang, CHEN Ying, SHEN Tian-yu, et al. Review on the Development of Paper Defect Detection

- System Based on Machine Vision Technology[J]. China Pulp & Paper, 2016, 35(5): 72-79.
- [2] 曲蕴慧, 汤伟, 冯波. 一种基于差影法及 SVM 的在线纸病检测分类方法[J]. 包装工程, 2018, 39(23): 176-180.
- QU Yun-hui, TANG Wei, FENG Bo. On-Line Paper Defect Detection and Classification Method Based on Subtraction Method and SVM[J]. Packaging Engineering, 2018, 39(23): 176-180.
- [3] JIANG Bo-rui, LUO Rui-xuan, MAO Jia-yuan, et al. Acquisition of Localization Confidence for Accurate Object Detection[C]// Proceedings of the European Conference on Computer Vision, 2018: 784-799.
- [4] 曲蕴慧, 汤伟, 成爽爽. 基于深度卷积神经网络及迁移学习的纸病分类方法研究[J]. 中国造纸, 2021, 40(10): 63-70.
- QU Yun-hui, TANG Wei, CHENG Shuang-shuang. Paper Defects Classification Based on Deep Convolution Neural Network and Transfer Learning[J]. China Pulp & Paper, 2021, 40(10): 63-70.
- [5] 高乐乐, 周强, 王伟刚. 基于 CNN 的深层次特征提取纸病辨识方法研究[J]. 中国造纸学报, 2019, 34(4): 52-58.
- GAO Le-le, ZHOU Qiang, WANG Wei-gang. Paper Defects Recognition Based on Deep Layer Feature Extraction of CNN[J]. Transactions of China Pulp and Paper, 2019, 34(4): 52-58.
- [6] 李果. 基于 Faster-RCNN 改进算法的纸张缺陷自动检测方法[J]. 赣南师范大学学报, 2021, 42(3): 100-104.
- LI Guo. Research on the Automatic Detection of Paper Defect Based on Improved Faster-RCNN Algorithm[J]. Journal of Gannan Normal University, 2021, 42(3): 100-104.
- [7] 周华平, 赵留阳. 基于改进的 Faster-RCNN 的生活垃圾智能检测分类[J]. 阜阳师范大学学报(自然科学版), 2022(3): 49-55.
- ZHOU Hua-ping, ZHAO Liu-yang. Intelligent Detection and Classification of Domestic Waste Based on Improved Faster-RCNN[J]. Journal of Fuyang Normal University (Natural Science), 2022(3): 49-55.
- [8] WANG Yuan-chao, LI Ming-tao, Pan Zhi-chen, et al. Pulsar Candidate Classification with Deep Convolutional Neural Networks[J]. Research in Astronomy and Astrophysics, 2019, 19(9): 119-128.
- [9] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. Computer Science, 2014, :arXiv:1409.1556.
- [10] HE Kaiming, ZHANG Xiaoyu, REN Shaoqing, et al. Deep Residual Learning for Image Recognition[C]// 016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2016.
- [11] REN Shao-qing, HE Kai-ming, 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, 2017, 39(6): 1137-1149.
- [12] 李鑫然, 李书琴, 刘斌. 基于改进 Faster R\_CNN 的苹果叶片病害检测模型[J]. 计算机工程, 2021, 47(11): 298-304.
- LI Xin-ran, LI Shu-qin, LIU Bin. Apple Leaf Diseases Detection Model Based on Improved Faster R\_CNN[J]. Computer Engineering, 2021, 47(11): 298-304.
- [13] ZAGORUYKO S, KOMODAKIS N. Paying more Attention to Attention: Improving the Performance of Convolutional Neural Networks via Attention Transfer[EB/OL]. 2016: arXiv: 1612.03928. <https://arxiv.org/abs/1612.03928.pdf>.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module[C]// In Proceedings of the European conference on computer vision (ECCV), 2018: 3-19.

责任编辑: 曾钰婵