

改进 Faster RCNN 模型在棉花异性纤维识别中的应用

杜玉红^{1,2*}, 董超群^{1,2}, 赵地^{1,2}, 任维佳^{1,2}, 蔡文超³

¹天津工业大学机械工程学院, 天津 300387;

²天津市现代机电装备技术重点实验室, 天津 300387;

³北京大恒图像视觉有限公司, 北京 100085

摘要 采用深度学习方法对棉花中的异性纤维进行分类识别。首先建立异性纤维数据集, 针对异性纤维尺寸和形状多样性的特点, 采用基于 Faster RCNN 的目标识别框架, 以 RseNet-50 代替原始的 VGG16 作为异性纤维分类模型的特征提取网络, 并采用 k-means++ 聚类算法对候选框生成尺寸进行改进; 然后对模型进行训练, 实现棉花中异性纤维的分类和定位。训练后的模型在验证集上的准确率达到 94.24%, 精度为 98.16%, 召回率为 95.93%, 精确率和召回率的调和平均数(F_1 分数)为 0.970。对比改进前、后模型对异性纤维的识别效果, 改进后的模型在小尺寸、大长宽比和密集出现的情况具有更好的识别效果, 相对于原始模型, 其准确率、精度、召回率和 F_1 分数分别提高了 3.21%、0.90%、2.51% 和 0.017。

关键词 图像处理; 异性纤维; 深度学习; 目标识别; Faster RCNN; k-means++

中图分类号 TP391.4; TS117

文献标志码 A

doi: 10.3788/LOP57.121007

Application of Improved Faster RCNN Model for Foreign Fiber Identification in Cotton

Du Yuhong^{1,2*}, Dong Chaoqun^{1,2}, Zhao Di^{1,2}, Ren Weijia^{1,2}, Cai Wenchao³

¹College of Mechanical Engineering, Tianjin Polytechnic University, Tianjin 300387, China;

²Tianjin Key Laboratory of Advanced Mechatronics Equipment Technology, Tianjin 300387, China;

³Beijing Daheng Image Vision Co., Ltd., Beijing 100085, China

Abstract Generally, deep learning methods are used to identify and classify the foreign fibers in cotton. First, a target recognition framework is adopted based on Faster RCNN to develop a foreign fiber dataset according to the characteristics of foreign fiber size and shape diversity. Next, the original VGG16 is replaced by RseNet-50 as the feature extraction network in the foreign fiber classification model, and the size of the mark box is improved using the k-means++ clustering algorithm. Subsequently, the model is trained to identify and classify the foreign fibers in cotton. The trained model achieves an accuracy rate of 94.24%, a precision of 98.16%, a recall rate of 95.93%, and an F_1 score of 0.970 with respect to the verification set. When compared with the original model, the recognition effect is observed to improve in case of small sizes, large aspect ratios, and dense occurrences when the proposed model is used. Furthermore, the accuracy, precision, recall rate, and F_1 score of the proposed model improve by 3.21%, 0.90%, 2.51%, and 0.017, respectively, when compared with those of the original model.

Key words image processing; foreign fiber; deep learning; object detection; Faster RCNN; k-means++

OCIS codes 100.2980; 150.1135; 150.3040

收稿日期: 2019-09-23; 修回日期: 2019-10-24; 录用日期: 2019-10-30

基金项目: 国家自然科学基金(51205288, U1733108)、天津市自然科学基金(17JCYBJC19400)

* E-mail: DYH202@163.com

1 引言

棉花中的异性纤维^[1]是影响棉花质量的主要因素之一,在纺纱和织布过程中会导致纱线断裂和出现疵点等^[2],国标 GB 1103—2012 中规定异性纤维含量是棉花等级评价的重要指标。异性纤维种类繁多,且各类异性纤维的理化性质不同^[3],在纺纱和织布过程中产生的疵点数量及其危害程度相差较大^[4],因此,基于机器视觉技术对每批棉花中的各类异性纤维进行识别,能获得各类异性纤维的含量,可以综合评定每批棉花的整体质量。

目前,国内外对异性纤维的检测主要采用基于机器视觉技术的检测方法^[5-8],而对分类方法的研究较少。杨文柱等^[9]使用彩色和黑白相机分别检测彩色和白色异性纤维,利用多特征多分类器集成的模糊方法进行分类,平均分类准确率可达到 80%。Wang 等^[10]建立 BP 神经网络模型,对棉花中异性纤维的红色(R)、绿色(G)、蓝色(B)通道均值进行训练;利用概率统计方法计算特征向量的绝对值和方差,实现对棉花中异性纤维的分类。刘双喜等^[11]将异性纤维轮廓的面积与周长平方之比作为力矩,根据不同种类异性纤维的力矩差别进行分类,分类准确率达到 96%。Zhang 等^[12]基于最小冗余-最大相关性的特征选择方法确定异性纤维近红外高光谱图像中的最佳光谱波段;利用选定的最佳波长,使用线性判别分析和支持向量机(SVM)对异性纤维进行分类,其准确率达到 95%以上。王金星等^[13]利用改进的离散型粒子群算法,实现了对异性纤维特征的快速选择,且分类准确率达到 93%。Du 等^[14]提出一种基于异性纤维颜色的分类模型,应用聚类方法实现异性纤维的分类。对异性纤维分类的研究成果主要分为两类:一类是基于异性纤维的颜色、形状和纹理等人工设计特征,结合聚类方法或分类器对异性纤维进行分类,但异性纤维特征具有多样性,且特征提取时受不同生产环境下光照的影响较大,人工设计的特征不具有普适性。同时异性纤维在图像中面积占比很小,需要将整幅图像分成小块才能确定异性纤维的位置。另一类是基于光谱信息差异进行分类,但光谱成像和光谱信息的获取速度较慢,而且设备成本较高,难以应用于实际生产环境的异性纤维识别。

相对于传统方法,深度学习方法通过对大量有标签样本进行训练,自主学习可以区分不同目标的最优特征,实现目标识别。当前,已有研究人员将深度学习目标识别技术应用到农业中,并取得了较好的效

果。谭文学等^[15]基于深度学习神经网络实现了苹果果体的病虫害智能监控。赵德安等^[16]基于机器视觉和 YOLOv3 深度学习网络结构实现了水下河蟹识别。熊俊涛等^[17]基于 Faster RCNN 网络实现了对树上绿色柑橘的识别。孙钰等^[18]基于 SSD 目标检测框架实现了油松受害情况的检测。同时,深度学习技术已应用在各行业的研究中^[19-29]。现在较为常用的网络主要有 Faster RCNN、SSD、YOLO、Mask RCNN 等,它们都有较为突出的特点,但上述模型都是针对 PASCAL VOC、COCO 等竞赛类大数据集进行设计,数据集中目标的类间差距较大,类内差距较小,很难将模型直接应用到异性纤维识别中。

本文采用深度学习方法实现棉花中异性纤维的分类识别,将塑料薄膜、化学纤维、丙纶丝和羽毛 4 种最常见的异性纤维作为研究对象,提出基于 Faster RCNN 的网络框架,将改进的残差网络(ResNet)^[30]作为异性纤维图像的特征提取部分,并基于 k-means++^[31]算法对候选框尺寸和数量进行改进,实现了小尺寸、大长宽比和密集分布等情况下异性纤维的自动化识别和定位,为综合评定棉花质量等级提供技术支持。

2 异性纤维数据集建立

2.1 图像采集

实验材料由北京大恒图像视觉有限公司提供,主要为湖北谷城银纺公司等 10 个棉纺企业的实际生产中从棉花中剔除的异性纤维,实验原材料如图 1(a)所示。实验原材料中塑料薄膜、化学纤维、丙纶丝和羽毛含量最多,从原材料中挑选出的材料如图 1(b)所示,本文针对这 4 类异性纤维的识别方法进行研究。图像采集设备为德国 Allied Vision 公司生产的 Manta G-1236C 彩色面阵工业相机,采集图像尺寸为 4112 pixel×3008 pixel,光源为白色 LED 面光源。为提高样本多样性,采集图像时每幅图像中异性纤维的种类、数量、尺寸和位置均为随机选择和摆放,同时每采集 50 幅图像对棉花背景进行重新铺放,共采集 400 幅图像。图像采集设备和样本示例如图 2 所示。

2.2 数据增强

利用深度学习网络对样本进行训练时,经常出现网络层数较深且数据量不足导致模型过拟合的现象,为了保证训练后模型的泛化能力和识别效果,需要大量带有标签的数据样本。而图像采集耗时较长,因此采用数据增强手段对原始数据集进行扩充。




图1 实验材料。(a)实验原材料;(b)挑选出的材料

Fig. 1 Experimental materials. (a) Experimental raw materials; (b) selected materials



图2 图像采集设备和样本示例。(a)图像采集设备;(b)小尺寸样本;(c)中尺寸样本;(d)大尺寸样本;(e)密集分布样本

Fig. 2 Image acquisition equipment and sample examples. (a) Image acquisition device; (b) small size sample; (c) medium size sample; (d) large size sample; (e) densely distributed sample

异性纤维方向性的变化不会引起种类的改变,而棉花背景具有原始颜色的确定性,因此通过对图像进行翻转、亮度和对比度变换,以及放大后随机裁剪,将原始数据量扩增6倍,总样本图像数量为2800幅。

2.3 数据集建立

原始图像尺寸过大,导致模型训练时计算量增加,在不影响细节特征的情况下,将所有图像尺寸转换为 $640 \text{ pixel} \times 468 \text{ pixel}$ 。使用labelImg软件标注图像,标注框为矩形,标注内容包括每个异性纤维的位置和种类。标注时以外接矩形进行位置标注,尽量减少标注框的背景信息,防止模型训练时将背景中的其他非异性纤维特征当作异性纤维特征进行学习,造成模型训练收敛困难和误检率提高。

图像标注信息采用Pascal VOC数据集^[26]的格式,文件中包含所标注图像在计算机中的地址、图像尺寸、矩形标注框左上角和右下角坐标以及标注的种类。选取2400幅图像作为训练集,400幅图像作为测试集。训练集和测试集图像中都包含不同尺寸、种类、数量和分布的异性纤维。

3 异性纤维识别方法

棉花中异性纤维的尺寸、形状、颜色和分布具有很大的随机性,本研究基于Faster RCNN目标检测框架,使用残差网络代替原始的VGG16网络作为异性纤维图像的特征提取器,并对区域建议网络(RPN)进行改进,综合提高模型性能。

3.1 Faster RCNN 网络结构

Faster RCNN是由生成目标候选框的RPN和利用这些候选区域的Fast RCNN目标检测器组成,将整个目标候选区域提取、深度特征提取、目标识别和检测过程融入到一个深度神经网络模型中,在保证检测精度的同时提高了处理速度。

首先将特征提取网络生成的一系列异性纤维特征图导入RPN,然后在每个 3×3 卷积核滑窗中心生成多个尺寸比例的候选框(anchors),最后分为候选框分类(cls)和位置回归(reg)两个支路。在候选框分类支路中,根据候选框与标记框(GT)的交并比(IOUS),将候选框分为正样本和负样本,即含有异性纤维的目标和棉花背景。交并比的计算公式为

$$R_{\text{IOU}} = \frac{K_{\text{GT}} \cap A_{\text{anchors}}}{K_{\text{GT}} \cup A_{\text{anchors}}}, \quad (1)$$

式中: R_{IOU} 为候选框与标记框的交并比; K_{GT} 为标记框; A_{anchors} 为候选框。

训练时正、负样本数量应尽量相等,这有利于提高分类器区分正、负样本的性能,RPN在筛选出的正、负样本中各取128个进行训练。但当正样本数量不足时,则由负样本补齐。棉花中异性纤维面积占比比较小,容易导致正、负样本不平衡,因此将与标记框重合最大或交并比超过60%的候选框标记为正样本,交并比小于20%的标记为负样本,其余样本不参与训练。RPN的损失函数分为异性纤维分类损失 L_{cls} 和边界框回归损失 L_{reg} 两部分,整体损失函数为

$$L(\{p_i\} + \{t_i\}) = \frac{1}{N_{\text{cls}}} \cdot \sum_i L_{\text{cls}}(p_i, p_i^*) + \frac{\lambda}{N_{\text{reg}}} \cdot \sum_i p_i^* \cdot L_{\text{reg}}(t_i, t_i^*), \quad (2)$$

式中: i 为候选框次序; p_i 为预测第 i 个候选框为正样本的概率; p_i^* 表示第 i 个候选框是否为正样本, 若为正样本, p_i^* 取 1, 否则取 0; t_i 为预测第 i 个候选框坐标; t_i^* 为与第 i 个候选框对应标记框的坐标; N_{cls} 为参与训练的候选框数量; N_{reg} 为特征图像素数量; λ 为平衡权重。

$$L_{\text{cls}}(p_i, p_i^*) = -\lg[p_i p_i^* + (1 - p_i)(1 - p_i^*)], \quad (3)$$

$$L_{\text{reg}}(t_i, t_i^*) = \text{smooth } L_1(t_i - t_i^*) = \begin{cases} 0.5(t_i - t_i^*)^2, & |t_i - t_i^*| < 1 \\ |t_i - t_i^*| - 0.5, & \text{else} \end{cases}. \quad (4)$$

将训练学习到的候选框位置与尺度变化规则应用到正样本候选框上, 使其更接近标记框, 再将特征图中的候选框映射回原图, 并剔除严重超出边界的候选框。通过非极大抑制(NMS)方法对候选框进行筛选, 输出建议框并将其作用于特征提取网络生成的特征图, 直接提取出对应区域的特征, 并用这些特征进行目标类别和边界框的预测。

3.2 改进的特征提取网络

为提高异性纤维模型的识别效果, 理论上增加网络层数可以起到很好的效果, 但模型训练时需要通过网络将误差反向传播进行权重更新, 不断增加网络深度会使反向传播的梯度发生弥散或消失, 导致训练误差增大。而残差网络采用捷径连接的方法将输入与输出进行叠加, 加深其网络深度, 提升模型识别效果, 但训练模型的计算量和难度并没有提高。残差模块结构如图 3 所示。




图 3 残差模块结构

Fig. 3 Residual module structure

由图 3 可知, x 表示输入, $F(x)$ 表示在第二层激活函数前的输出, 原始网络训练目标为 $F(x) = H(x)$, 而在残差网络中加入捷径连接后, 输出变为 $F(x) + x$, 训练目标变为 $F(x) = H(x) - x$, 即残

差。残差模块的最终输出 y 可表示为

$$y = \sigma[H(x)] = \sigma[F(x) + W_s x] = \sigma[W_2 \sigma(W_1 x) + W_s x], \quad (5)$$

式中: σ 为 ReLU 激活函数; W_1 为第一层网络权重; W_2 为第二层网络权重; W_s 为输入权重, 以保持输入与输出维度一致。

若 $\|F(x)\| = 0$, 输入与输出为恒等映射; 若 $\|F(x)\| \neq 0$, $F(x)$ 则作为残差模块需要学习的差别部分, 也可以看作是恒等映射的扰动。使用 ResNet-50 作为异性纤维图像的特征提取器, 由于部分异性纤维尺寸较小且密集出现, 将原始 ResNet-50 特征提取步长由 16 pixel 减小为 8 pixel, 以提高特征提取密度, 从而提升小尺寸异性纤维的检测效果。

3.3 基于 k-means++ 方法改进候选框生成尺寸

原始 RPN 生成的候选框有三种规格, 分别为 128, 256, 512 pixel, 每种规格的长宽有三个比例, 分别为 1:1、1:2 和 2:1, 共生成 9 种尺寸的候选框。由于数据集差异, 原始候选框的尺寸和长宽比不能完全满足异性纤维数据集的要求。本研究采用 k-means++ 算法对标记框的尺寸和长宽比进行分析, 以避免 k-means 算法随机初始化聚类中心造成结果不可靠的问题。取聚类中心数 $k=12$ 对标记框尺寸进行聚类, 标记框尺寸聚类分析如图 4 所示。由图 4 可知, 4 种异性纤维的尺寸主要集中在 50~200 pixel 范围内, 同时由于化学纤维和丙纶丝为条状异性纤维, 部分长宽比例较大, 因此对标记框聚类中心尺寸和长宽比进行统计, 结果如表 1 所示。




图 4 标记框尺寸聚类分析

Fig. 4 Cluster analysis of mark box size

为满足数据集中样本尺寸要求, 确定生成候选框的规格为 64 pixel 和 128 pixel, 长宽比为 1:1、1:2、1:3、1:4、2:1、3:1 和 4:1, 改进前、后候选框生成尺寸对比如图 5 所示。可以看到, 改进后的候选框尺寸更接近样本的实际尺寸, 从而增加了正样本的数量, 减小了候选框中背景图像比例, 有利于模型充分学习异性纤维特征。

表1 标记框聚类中心尺寸和长宽比

Table 1 Size and aspect ratio of the cluster center of mark box

Serial number	1	2	3	4	5	6	7	8	9	10	11	12
Length /pixel	78.7	129.2	90.8	83.7	100.3	60.5	116.5	299.3	167.0	52.9	183.4	49.8
Width /pixel	261.8	103.7	134.8	95.4	54.4	178.8	176.5	87.7	70.6	71.1	123.9	118.9
Aspect ratio	1 : 3.3	1.2 : 1	1 : 1.5	1 : 1.1	1.8 : 1	1 : 3.0	1 : 1.5	3.4 : 1	2.4 : 1	1 : 1.3	1.5 : 1	1 : 2.4




图5 改进前、后候选框生成尺寸对比。(a)(b)改进前;(c)(d)改进后

Fig. 5 Comparison of anchors generation size before and after improvement. (a)(b) Before improvement; (c)(d) after improvement

4 实验与结果分析

4.1 模型训练与评价

以 ResNet-50 作为图像特征的提取网络,训练时采用小批量训练方式,每批次包含 10 幅图像,每训练一批图像,网络中各层权重值更新一次。同时使用随机梯度下降算法^[32]进行优化,动量参数设为 0.9,初始学习率设为 0.0003,并在损失值基本稳定后,将学习率减小到原来的一半继续训练,直到模型完全收敛。训练环境基于 Ubuntu 16.04, tensorflow-gpu 1.10.0, Python 3.5, CUDA 9.0, cuDNNv 7.0.5,硬件平台为 Intel i5-4590CPU,显卡为 Nvidia GTX750Ti,8 GB 内存。

为了验证模型的有效性,采用准确率 A 、精确率 P 、召回率 R 和 F_1 得分等指标对模型进行评价,计算公式为

$$A_i = \frac{N_{TP,i}}{N_{TP,i} + N_{FP,i} + N_{FN,i}} \times 100\%, \quad (6)$$

$$P_i = \frac{N_{TP,i}}{N_{TP,i} + N_{FP,i}} \times 100\%, \quad (7)$$

$$R_i = \frac{N_{TP,i}}{N_{TP,i} + N_{FN,i}} \times 100\%, \quad (8)$$

$$F_{1,i} = \frac{2P_iR_i}{P_i + R_i}, \quad (9)$$

式中: i 为异性纤维种类代号; $N_{TP,i}$ 为正确识别的第 i 类异性纤维的数量; $N_{FP,i}$ 为第 i 类之外的异性纤维和背景被预测为第 i 类异性纤维的数量; $N_{FN,i}$ 为第 i 类异性纤维被预测为第 i 类之外异性纤维和背景的数量。

图像中异性纤维被识别出的认定标准以识别时具体判定为某类异性纤维的概率大小和识别框与标记框的重合程度来判断。通过分析样本情况,若正确判定异性纤维种类且判定概率和识别框与标记框的交并比同时超过 50%,即认定该异性纤维被识别。

4.2 不同尺寸异性纤维的识别

由于异性纤维的尺寸呈现多样性,为进一步测试训练模型对异性纤维的识别能力,对不同种类、不同尺寸的异性纤维进行测试。以外接矩形的长边长度为标准,将异性纤维尺寸分为小、中、大 3 个等级,对应尺寸分别为 < 100 pixel、 $100 \sim 150$ pixel 和 > 150 pixel。训练后模型对不同尺寸异性纤维的识别评价参数如表 2 所示。从表 2 可以看出,训练后的模型对 4 种异性纤维整体识别效果较好,准确率、精度值、召回率和 F_1 分数基本保持在 90% 以

上,其中对小尺寸异性纤维的识别效果较差,这是因为小尺寸异性纤维在整幅图像中的面积占比较小,细节特征不明显,容易造成漏检。而中尺寸和大尺寸异性纤维特征明显,理论上不会出现漏检的情况,但这两种尺寸的化学纤维、塑料薄膜和丙纶丝的召回率没有达到 100%,主要是因为这些材料包含与棉花背景相似度很高的白色或接近透明的异性纤维,所提模型将其从背景中识别出来的效果相对较

差,出现了少量漏检的情况。

棉层凸起处在光源照射下呈现高亮斑块,与较小尺寸且接近透明的塑料薄膜和丙纶丝具有相似性,因而出现了少量的误判。棉团相连处和多个相互粘连的丙纶丝可能会被误判为小尺寸化学纤维,从而导致精度值下降。而羽毛与棉花背景的差异较大,只在小尺寸异性纤维中出现漏检,在其他尺寸中的精确率和召回率都达到了 100%。

表 2 不同尺寸异性纤维识别评价参数

Table 2 Identification and evaluation parameters of different sizes of foreign fibers

Species	Size code	Number	$A / \%$	$P / \%$	$R / \%$	F_1	F_1 average
Chemical fiber	Small	26	88.89	92.31	96.15	0.942	0.975
	Middle	91	94.62	97.78	96.70	0.972	
	Big	87	97.70	100.00	97.70	0.988	
Plastic film	Small	115	91.45	93.04	96.52	0.948	0.941
	Middle	88	94.51	96.63	97.72	0.972	
	Big	7	100.00	100.00	100.00	1.000	
PP yarn	Small	83	84.27	92.59	90.36	0.915	0.913
	Middle	70	94.37	98.53	95.71	0.971	
	Big	57	92.98	100.00	92.98	0.964	
Feather	Small	20	90.00	100.00	90.00	0.947	0.991
	Middle	109	100.00	100.00	100.00	1.000	
	Big	93	100.00	100.00	100.00	1.000	

典型识别错误示例如图 6 所示。图 6(a) 中识别框没有完全框出丙纶丝,虚线框为丙纶丝的实际位置;图 6(b) 中塑料薄膜、羽毛和化学纤维被识别

出,而被虚线框标记的小尺寸丙纶丝出现了漏检;图 6(c) 中 4 个丙纶丝相互接触,被误判为一个整体,且将整体误判为化学纤维。




图 6 典型识别错误示例。(a)检测框位置不准确;(b)漏检;(c)误检

Fig. 6 Typical examples of recognition errors. (a) Inaccurate detection frame position; (b) missed detection; (c) false detection

4.3 模型有效性验证

为验证改进模型的有效性,采用改进前、后模型对 4 种异性纤维进行识别,改进前、后模型评价参数如表 3 所示。可以看到,改进后模型(Faster RCNN Pro)的评价参数优于原始模型(Faster RCNN)。相对于原始模型,改进后模型的准确率、精度、召回率和 F_1 分数分别提高了 3.21%、0.90%、2.51% 和 0.017。对改进前、后模型的识别情况进行对比分析,改进前、后模型识别效果示例如图 7 所示。由图 7 可知,差异部分主要体现在三方面:1)在对小尺寸异性纤维的识

别中,由于原始模型生成的最小候选框尺寸为 128 pixel,所以小尺寸异性纤维被识别为正样本的概率较小,对其特征的学习不充分,出现漏检的情况较多;2)在对长宽比较大的异性纤维识别中,由于原始模型生成的候选框最大长宽比为 1:2,无法满足大长宽比异性纤维的尺寸要求,将一个异性纤维识别为两个或多个异性纤维的情况较多;3)当多个异性纤维密集出现且距离较近时,由于原始模型特征提取步长较大,每一步提取到的特征较多,可能将多个相近的异性纤维误认为一个纤维或者发生重复识别的情况。

表3 改进前、后模型评价参数

Table 3 Model evaluation parameters before and after improvement

Model	A / %	P / %	R / %	F_1
Faster RCNN (before improvement)	91.03	97.26	93.42	0.953
Faster RCNN Pro (after improvement)	94.24	98.16	95.93	0.970

4.4 不同方法检测效果对比

为进一步验证改进后模型对棉花异性纤维识别的可靠性,分别与YOLOv3、SSD和HOG+SVM方

法进行对比。YOLOv3是将DarkNet作为特征提取网络,通过3个不同尺度的特征图对目标物进行回归预测,该网络结构具有较好的实时性和较高的检测精度。SSD是一种单向多框检测器,基于前馈卷积网络,其产生固定大小的边界框集合和框中对象类别的分数,并通过非极大值抑制生成最终检测。HOG+SVM方法首先通过颜色空间归一化、梯度计算、方向梯度直方图(HOG)和重叠块直方图归一化提取出图像中目标物的HOG特征,并通过SVM对这些特征进行分类。




图7 改进前、后模型识别效果示例。(a)漏检,Faster RCNN;(b)误判为两个异性纤维,Faster RCNN;(c)重复识别,Faster RCNN;(d)未漏检,Faster RCNN Pro;(e)识别为一个异性纤维,Faster RCNN Pro;(f)未重复识别,Faster RCNN Pro

Fig. 7 Examples of model detection effect before and after improvement. (a) Missed detection in Faster RCNN; (b) misjudged as two foreign fibers in Faster RCNN; (c) repeat recognition in Faster RCNN; (d) not missed in Faster RCNN Pro; (e) recognized as a foreign fiber in Faster RCNN Pro; (f) not re-identified in Faster RCNN Pro

不同模型的评价参数对比如表4所示,从表4可以看出,YOLOv3和SSD模型的识别效果与改进后模型的识别效果较为相近,但在准确率和召回率上还有一定的差距。HOG+SVM方法对异性纤维的识别效果最差,其准确率和召回率与Faster RCNN Pro差距较大,这是因为HOG特征具有一定的方向性,而异性纤维在棉花中的分布杂乱无章,导致提取到的HOG特征不具有一定的代表性,SVM无法对其特征进行准确分类。通过对比可知,改进后的Faster RCNN识别效果最优。

表4 不同模型评价参数对比

Table 4 Comparison of different model evaluation parameters

Model	A / %	P / %	R / %	F_1
Faster RCNN Pro	94.24	98.16	95.93	0.970
SSD	90.22	97.11	92.70	0.949
YOLOv3	90.89	97.49	93.06	0.952
HOG+SVM	76.49	69.62	70.45	0.700

5 结 论

基于改进的Faster RCNN异性纤维识别模型通过自主学习训练集中的样本特征,避免了人工设计特征的局限性,实现了对4种异性纤维的准确分类和定位。

1) 针对棉花中最常见的4种异性纤维建立数据集,并通过数据增强手段进行数据集扩充,有效避免了训练过程中的过拟合。

2) 基于Faster RCNN目标识别框架,使用ResNet-50代替原有的VGG16网络作为图像的特征提取部分,同时将特征提取步长由16 pixel改为8 pixel,并基于k-means++方法对原始候选框的尺寸和比例进行改进,提高了小尺寸和密集出现异性纤维的识别效果。

3) 改进后的模型在验证集上的准确率达到94.24%,精度为98.16%,召回率为95.93%, F_1 分

数为 0.970, 具有较好的识别效果。

4) 通过对比改进前、后模型的识别结果, 发现改进后的模型对小尺寸、大长宽比和密集出现情况下的异性纤维识别效果要优于原始模型。相对于原始模型, 改进后模型的准确率、精度、召回率和 F_1 分数分别提高了 3.21%、0.90%、2.51% 和 0.017。同时, 与 YOLOv3、SSD 模型和 HOG+SVM 方法进行对比发现, YOLOv3、SSD 模型的识别效果与改进后的 Faster RCNN 模型识别效果较为相近, HOG+SVM 方法效果最差, 改进后的 Faster RCNN 识别效果最优。

经实验验证, Faster RCNN Pro 可以准确地对典型异性纤维进行分类和定位, 其分类识别率明显提高。

参 考 文 献

- [1] National Quality Supervision, Inspection and Quarantine Bureau. Fine cotton cotton: GB 1103—2012 [S]. Beijing: National Standardization Management Committee, 2012.
国家质量监督检验检疫局. 棉花细绒棉: GB 1103—2012[S]. 北京: 国家标准化管理委员会, 2012.
- [2] Gai W Q, Xu L, Ding Y D. Causes, classification, harm and solutions of foreign fibers in cotton [J]. China Fiber Inspection, 2017(9): 85-86.
盖文桥, 徐雷, 丁曰东. 浅析棉花异性纤维形成的原因、分类、危害和解决措施[J]. 中国纤检, 2017(9): 85-86.
- [3] Zhou Z C. Construction of the evaluation model of the content grade of foreign fiber [D]. Tianjin: Tianjin Polytechnic University, 2019.
周志超. 异性纤维含量等级评价模型的构建[D]. 天津: 天津工业大学, 2019.
- [4] Luo Y H, Du Y H, Liu R J, et al. Discussion on rough set theory for classification and recognition of foreign fiber in cotton [J]. Cotton Textile Technology, 2015, 43(9): 73-76.
罗永恒, 杜玉红, 刘仁杰, 等. 粗集理论用于棉花异纤归类识别的讨论[J]. 棉纺织技术, 2015, 43(9): 73-76.
- [5] Wei P, Zhang L, Liu X, et al. Detecting method of foreign fibers in seed cotton using double illumination imaging [J]. Journal of Textile Research, 2017, 38(4): 32-38.
韦平, 张林, 刘翔, 等. 籽棉中异性纤维的双光源成像检测方法[J]. 纺织学报, 2017, 38(4): 32-38.
- [6] Shi H Y, Guan S Q. Cotton foreign fibers detection based on visual attention computational model [J]. Journal of Donghua University (Natural Science), 2016, 42(3): 400-405.
师红宇, 管声启. 基于视觉注意计算模型的棉花异性纤维检测[J]. 东华大学学报(自然科学版), 2016, 42(3): 400-405.
- [7] He X Y, Wei P, Zhang L, et al. Detection method of foreign fibers in seed cotton based on deep-learning [J]. Journal of Textile Research, 2018, 39(6): 131-135.
何晓响, 韦平, 张林, 等. 基于深度学习的籽棉中异性纤维检测方法[J]. 纺织学报, 2018, 39(6): 131-135.
- [8] Zhang L, Wei P, Wu J B, et al. Detection method of foreign fibers in cotton based on illumination of line-laser and LED [J]. Transactions of the CSAE, 2016, 32(15): 289-293.
张林, 韦平, 伍剑波, 等. 基于线激光与 LED 的棉花中异性纤维检测方法[J]. 农业工程学报, 2016, 32(15): 289-293.
- [9] Yang W Z, Li D L, Wei X H, et al. AVI system for classification of foreign fibers in cotton [J]. Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(12): 177-181, 227.
杨文柱, 李道亮, 魏新华, 等. 基于自动视觉检测的棉花异性纤维分类系统[J]. 农业机械学报, 2009, 40(12): 177-181, 227.
- [10] Wang J F, Du Y H, Jiang X M, et al. Classification processing method of cotton foreign fibers based on probability statistics and BP neural network [J]. Applied Mechanics and Materials, 2014, 598: 428-431.
- [11] Liu S X, Wang J X, Zheng W X, et al. Classification method of adaptive threshold segmentation algorithm and moment for foreign fibers in cotton [J]. Transactions of the CSAE, 2009, 25(S2): 320-324.
刘双喜, 王金星, 郑文秀, 等. 基于自适应阈值分割与力矩的棉花异性纤维分类方法[J]. 农业工程学报, 2009, 25(S2): 320-324.
- [12] Zhang M Y, Li C Y, Yang F Z. Classification of foreign matter embedded inside cotton lint using short wave infrared (SWIR) hyperspectral transmittance imaging [J]. Computers and Electronics in Agriculture, 2017, 139: 75-90.
- [13] Wang J X, Li H B, Wang R, et al. A fast feature selection for cotton foreign fiber objects based on BPSO [J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(2): 188-191.

- 王金星, 李恒斌, 王蕊, 等. 基于BPSO的棉花异性纤维目标特征快速选择方法[J]. 农业机械学报, 2013, 44(2): 188-191.
- [14] Du Y H, Ma T, Yang C W, et al. Detection clustering analysis algorithm and system parameters study of the near-point multi-class foreign fiber[J]. The Journal of the Textile Institute, 2017, 108(6): 1022-1027.
- [15] Tan W X, Zhao C J, Wu H R, et al. A deep learning network for recognizing fruit pathologic images based on flexible momentum [J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(1): 20-25.
- 谭文学, 赵春江, 吴华瑞, 等. 基于弹性动量深度学习神经网络的果体病理图像识别[J]. 农业机械学报, 2015, 46(1): 20-25.
- [16] Zhao D A, Liu X Y, Sun Y P, et al. Detection of underwater crabs based on machine vision [J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(3): 151-158.
- 赵德安, 刘晓洋, 孙月平, 等. 基于机器视觉的水下河蟹识别方法[J]. 农业机械学报, 2019, 50(3): 151-158.
- [17] Xiong J T, Liu Z, Tang L Y, et al. Visual detection technology of green citrus under natural environment [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(4): 45-52.
- 熊俊涛, 刘振, 汤林越, 等. 自然环境下绿色柑橘视觉检测技术研究[J]. 农业机械学报, 2018, 49(4): 45-52.
- [18] Sun Y, Zhou Y, Yuan M S, et al. UAV real-time monitoring for forest pest based on deep learning[J]. Transactions of the CSAE, 2018, 34(21): 74-81.
- 孙钰, 周焱, 袁明帅, 等. 基于深度学习的森林虫害无人机实时监测方法[J]. 农业工程学报, 2018, 34(21): 74-81.
- [19] Yang W, Wang H Y, Zhang J, et al. An improved vehicle real-time detection algorithm based on Faster-RCNN[J]. Journal of Nanjing University (Natural Sciences), 2019, 55(2): 231-237.
- 杨薇, 王洪元, 张继, 等. 一种基于Faster-RCNN的车辆实时检测改进算法[J]. 南京大学学报(自然科学版), 2019, 55(2): 231-237.
- [20] Tang C, Ling Y S, Yang H, et al. Decision-level fusion detection for infrared and visible spectra based on deep learning[J]. Infrared and Laser Engineering, 2019, 48(6): 0626001.
- [21] Ma X Y, Zhu D, Jin C, et al. Bullet appearance defect detection based on improved faster region-convolutional neural network [J]. Laser & Optoelectronics Progress, 2019, 56(15): 151202.
- 马晓云, 朱丹, 金晨, 等. 基于改进Faster R-CNN的子弹外观缺陷检测[J]. 激光与光电子学进展, 2019, 56(15): 151202.
- [22] Lin G, Wang B, Peng H, et al. Multi-target detection and location of transmission line inspection image based on improved Faster-RCNN[J]. Electric Power Automation Equipment, 2019, 39(5): 213-218.
- 林刚, 王波, 彭辉, 等. 基于改进Faster-RCNN的输电线巡检图像多目标检测及定位[J]. 电力自动化设备, 2019, 39(5): 213-218.
- [23] Xue Y, Wu H D, Zhang N, et al. Detection of insulation piercing connectors and bolts on the transmission line based on improved Faster-RCNN [J]. Laser & Optoelectronics Progress, 2020, 57(8): 081008.
- 薛阳, 吴海东, 张宁, 等. 基于改进Faster R-CNN输电线穿刺线夹及其螺栓的检测[J]. 激光与光电子学进展, 2020, 57(8): 081008.
- [24] Li D J, Li R H. Research on the mugs defect detection method based on improved Faster RCNN [J]. Laser & Optoelectronics Progress, 2020, 57(3): 031502.
- 李东洁, 李若昊. 基于改进Faster RCNN的马克杯缺陷检测方法研究[J]. 激光与光电子学进展, 2020, 57(3): 031502.
- [25] Hua X, Wang X Q, Wang D, et al. Multi-objective detection of traffic scenes based on improved SSD[J]. Acta Optica Sinica, 2018, 38(12): 1215003.
- 华夏, 王新晴, 王东, 等. 基于改进SSD的交通大场景多目标检测[J]. 光学学报, 2018, 38(12): 1215003.
- [26] Wang J Q, Li J S, Zhou X W, et al. Improved SSD algorithm and its performance analysis of small target detection in remote sensing images[J]. Acta Optica Sinica, 2019, 39(6): 0628005.
- 王俊强, 李建胜, 周学文, 等. 改进的SSD算法及其对遥感影像小目标检测性能的分析[J]. 光学学报, 2019, 39(6): 0628005.
- [27] Xu L X, Chen X J, Ban Y, et al. Method for intelligent detection of parking spaces based on deep learning[J]. Chinese Journal of Lasers, 2019, 46(4): 0404013.
- 徐乐先, 陈西江, 班亚, 等. 基于深度学习的车位智能检测方法[J]. 中国激光, 2019, 46(4): 0404013.

- [28] Huang G, Liu X L. Automatic extraction and classification of road markings based on deep learning [J]. Chinese Journal of Lasers, 2019, 46(8): 0804002.
黄刚, 刘先林. 基于深度学习的道路标线自动提取与分类方法[J]. 中国激光, 2019, 46(8): 0804002.
- [29] Dai Y, Yi B S, Xiao J S, et al. Object detection of remote sensing image based on improved rotation region proposal network [J]. Acta Optica Sinica, 2020, 40(1): 0111020.
戴媛, 易本顺, 肖进胜, 等. 基于改进旋转区域生成网络的遥感图像目标检测[J]. 光学学报, 2020, 40(1): 0111020.
- [30] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [31] Lattanzi S, Lavastida T, Moseley B, et al. Online scheduling via learned weights [M] // Proceedings of the Fourteenth Annual ACM-SIAM Symposium on Discrete Algorithms. Philadelphia, PA: Society for Industrial and Applied Mathematics, 2020: 1859-1877.
- [32] Everingham M, Eslami S, van Gool L, et al. The pascal visual object classes challenge: a retrospective [J]. International Journal of Computer Vision, 2015, 111(1): 98-136.