

基于改进YOLOv3的棉花异性纤维检测

巫明秀, 吴谨, 张晨, 朱磊

引用本文:

巫明秀, 吴谨, 张晨, 等. 基于改进YOLOv3的棉花异性纤维检测[J]. 液晶与显示, 2020, 35(11): 1195–1203.

WU Ming-xiu, WU Jin, ZHANG Chen, et al. Detection of foreign fiber in cotton based on improved YOLOv3[J]. *Chinese Journal of Liquid Crystals and Displays*, 2020, 35(11): 1195–1203.

在线阅读 View online: <https://doi.org/10.37188/YJYXS20203511.1195>

您可能感兴趣的其他文章

Articles you may be interested in

改进的GDT-YOLOV 3目标检测算法

Improved algorithm of GDT-YOLOV 3 image target detection

液晶与显示. 2020, 35(8): 852–860 <https://doi.org/10.37188/YJYXS20203508.0852>

基于深度可分离卷积的交通标志识别算法

Traffic sign recognition algorithm based on depthwise separable convolutions

液晶与显示. 2019, 34(12): 1191–1201 <https://doi.org/10.3788/YJYXS20193412.1191>

基于深度学习的航空对地小目标检测

Detection of small target in aerial photography based on deep learning

液晶与显示. 2018, 33(9): 793–800 <https://doi.org/10.3788/YJYXS20183309.0793>

基于深度学习的乳液泵缺陷检测算法

Defect detection algorithm of lotion pump based on deep learning

液晶与显示. 2019, 34(1): 81–89 <https://doi.org/10.3788/YJYXS20193401.0081>

基于深度学习的木材表面缺陷图像检测

Image detection of wood surface defects based on deep learning

液晶与显示. 2019, 34(9): 879–887 <https://doi.org/10.3788/YJYXS20193409.0879>

文章编号:1007-2780(2020)11-1195-09

基于改进 YOLOv3 的棉花异性纤维检测

巫明秀^{1,2}, 吴 谨^{1,2*}, 张 晨^{1,2}, 朱 磊^{1,2}

(1. 武汉科技大学 信息科学与工程学院, 湖北 武汉 430081;

2. 冶金自动化与检测技术教育部工程中心, 湖北 武汉 430081)

摘要:针对棉花异性纤维检测准确率不高、实时性较差的问题,以棉花为研究对象,提出了一种基于改进 YOLOv3 的棉花异性纤维检测方法。引入轻量级 MobileNets 网络为特征提取网络,结合 YOLOv3 的多尺度特征融合检测网络,构建改进的 MobileNets-YOLOv3 模型。提出一种分段式学习率,以增强学习效果。将实际采集到的真实棉花异性纤维图像数据集按 4:1 的比例划分为训练集和测试集,并使用对比度增强、水平镜像等 6 种图像增广方法扩充数据集。对扩充前后的数据集、不同的学习率、改进前后的 YOLOv3 模型、本文模型与 Faster R-CNN 和 SSD_300 模型做了对比试验。实验结果表明,数据集的增广、改进后的分段式学习率均能改善训练模型的过拟合现象,在测试集上的平均正确率(mAP)分别提高了 3.6%、5.64%;改进后的 YOLOv3 模型对测试集进行检测的平均正确率(mAP)为 84.82%,帧速率为 66.67 f·s⁻¹,识别精度优于 YOLOv3 模型,提高了 2.03%,帧速率是 YOLOv3 模型的 3 倍,总体性能也优于 Faster R-CNN 和 SSD_300 模型,能较好地满足棉花异纤检测的精度和实时性要求。

关键词:棉花;目标检测;YOLOv3 网络;MobileNets 网络;深度学习

中图分类号:TP391 **文献标识码:**A **doi:**10.37188/YJYXS20203511.1195

Detection of foreign fiber in cotton based on improved YOLOv3

WU Ming-xiu^{1,2}, WU Jin^{1,2*}, ZHANG Chen^{1,2}, ZHU Lei^{1,2}

(1. School of Information Science and Engineering,

Wuhan University of Science and Technology, Wuhan 430081, China;

2. Engineering Research Center of Metallurgical Automation and Measurement Technology,
Ministry of Education, Wuhan 430081, China)

Abstract: In order to solve the problems of low identification efficiency and poor real-time performance to cotton foreign fiber detection, an improved method of cotton foreign fiber detection based on YOLOv3 was proposed. The constructed model of MobileNets-YOLOv3 was designed, in which a lightweight MobileNets network was selected as the feature extraction network, combined with YOLOv3's multi-scale feature fusion detection network. A segmented learning rate was proposed to enhance the learning effect. The cotton foreign fiber image data set collected from the equipment on real site was divided into a training set and a test set, according to a ratio of 4:1. Six image augmen-

收稿日期:2020-04-26;修订日期:2020-05-25.

基金项目:国家自然科学基金项目(No.61502358, No.61702384)

Supported by National Natural Science Foundation of China (No.61502358, No.61702384)

* 通信联系人, E-mail: wujin@wust.edu.cn

tation methods, such as contrast enhancement, brightness enhancement and so on, was induced, to expand the original data set. Based on the training set before and after expansion, different learning rates, the YOLOv3 model before and after improvement, the proposed model and Faster R-CNN along with SSD_300, different models were tested and compared. The experimental results showed that the data expansion and the segmented learning rate can improve the overfitting of the training model, and the mean average precision (mAP) on the test set was increased by 3.6% and 5.64% respectively. The improved YOLOv3 model can significantly reduce the mistake rate and miss rate of detection. The mAP of the test set was 84.82%, and the frame rate was $66.67 \text{ f} \cdot \text{s}^{-1}$. Compared with YOLOv3, the mAP of MobileNets-YOLOv3 was increased by 2.03%, the frame rate was raised to 3 times as it and the duration of training was shortened to 1/4 times as it. The overall performance of MobileNets-YOLOv3 was also better than that of Faster R-CNN and SSD_300. The proposed method can better satisfy the accuracy and real-time performance of cotton foreign fiber detection.

Key words: cotton; target detection; YOLOv3 network; MobileNets; deep learning

1 引言

棉花作为棉纺业的重要基础原料,对促进国民经济和生产发展具有重大意义。但是棉花中易掺杂异于棉花的异性纤维(简称异纤),会影响棉纺织品的品质和生产效率。因此,棉花异纤检测系统作为棉花异纤清除机的重要组成部分,其检测的准确性和快速性会影响棉花分拣的质量和效率。如何智能、高效且快速地检测出棉花中的异纤是棉产品加工需要解决的重要问题。

近年来,国内外关于棉花异纤检测的研究取得了一些进展。Gamble^[1]和 Mustafic^[2]通过荧光光谱法实现了棉花异纤的检测。郝东耀和丁天怀^[3]提出一种多波段光谱信息融合成像检测方法实现棉花异纤的检测。此类研究需要使用光谱仪,且增加新样本时需要重新寻找合适的光谱范围来进行检测。杜玉红^[4]等人采用聚类统计 RGB 图像信息的方法实现异纤的识别定位。师红宇^[5-6]等人构建图像的灰度和方向特征差分图进行异纤的检测。此类研究多基于传统图像处理方法进行异纤检测。杨文柱^[7-8]等人提出基于遗传算法、支持向量机(SVM)的异纤检测方法。

2014 年 R-CNN^[9]的提出,使得基于深度学习的目标检测算法受到越来越多的关注。卷积神经网络特征提取方法的泛化性能优于传统人工特征提取方法,在医学^[10]、道路检测^[11]等不同场景的图像分类和检测任务中均得到了广泛应用。但是深层神经网络存在计算复杂度较高的问题。

2017 年 Andrew G.Howard^[12]提出了可移植于移动端或嵌入式设备的轻量级 MobileNets 网络进行目标分类,采用了深度可分离卷积,减少了计算量,检测速度得到了明显提升。

目前鲜有研究将深度学习网络应用于棉花异纤检测,且研究的试验数据多为专用实验室测试平台采集的几十或百张图像,对实际设备现场采集图片的检测效果尚需进一步验证。为此,本文基于 YOLOv3^[13]多尺度特征融合网络架构,引入 MobileNets 作为特征提取器,并提出一种分段式学习率来优化训练网络,采集了 5 099 张现场实际棉花异纤图像进行网络训练,并使用图像数据扩增方法扩充数据集,以实现棉花异纤的检测。

2 试验数据

2.1 图像数据采集

目前网络上尚无数量大且类型统一的棉花异纤公开数据集。本文的数据集使用棉花异纤清除机上的 CCD 摄像机进行图像采集。获取的棉流图视频数据如图 1 所示,然后再以 132×50 分辨率进行抽帧裁剪。数据集共有 5 099 张图像,棉花异纤种类分为 4 种:分别为块状异性纤维(死棉、废纸、塑料薄膜、地膜、鸡毛)、块状伪异纤(黄棉花、棉叶)、条状异性纤维(丙纶丝、绒线),以及条状伪异纤(棉秸秆)。4 种棉花异纤图像示例如图 2 所示。

从数据集中选取 80% 的图像作为训练集(4 079 张),20% 的图像作为测试集(1 020 张)。

完成数据集的采集后,使用 LabelImg 软件对原始数据集进行手工标注,标注情况如表 1 所示。



图 1 CCD 摄像机拍摄棉流图

Fig.1 Cotton flow image taken by CCD camera




图 2 棉花异纤图像示例

Fig.2 Example of foreign fiber images

表 1 训练集和测试集中各类别标注框的个数

Tab.1 Number of ground truth for each class in the data set

类别	训练集标注框	测试集标注框	总计
块状异纤	1 274	343	1 617
块状伪异纤	586	139	725
条状异纤	1 096	257	1 353
条状伪异纤	1 284	326	1 610
总计	4 240	1 065	5 305

2.2 图像数据增广处理

图像增广可以增加图像样本的多样性,提高训练模型的泛化能力和鲁棒性。本文采用了增强对比度、增加亮度、添加高斯噪声、水平镜像、裁剪、平移共 6 种方法进行图像增广,同时对标注框的位置也进行相应的操作。对棉花异纤图像进行图像增广处理后的结果示意图如图 3 所示。




图 3 棉花异纤图像增广示例

Fig.3 Example of foreign fiber image augmentation

3 棉花异纤图像检测模型构建

3.1 改进的 YOLOv3 模型结构

YOLOv3 是基于回归的目标检测算法。该网络不需要生成区域建议框,直接将图像输入至网络中回归检测目标,反向传播可以贯穿整个网络。由于实验数据集的图像分辨率低,因此将 YOLOv3 原有的 Darknet53 特征提取网络替换为结构更简单、运算复杂度更低的 MobileNets 网络,并取消了 MobileNets 分类网络最后的池化层和全连接层。MobileNets 网络共 27 层,其结构如表 2 所示,其中 conv 为标准卷积,conv dw 为深度卷积。

表 2 MobileNets 结构

Tab.2 MobileNets structure

模块	输入	卷积类型	滤波器尺寸/步长
Block1	224×224×3	conv	3×3×3×32/2
	112×112×32	conv dw	3×3×32/1
	112×112×32	conv	1×1×32×64/1
	112×112×64	conv dw	3×3×64/2
	56×56×64	conv	1×1×64×128/1
	56×56×128	conv dw	3×3×128/1
	56×56×128	conv	1×1×128×128/1
	56×56×128	conv dw	3×3×128/2
	28×28×128	conv	1×1×128×256/1
	28×28×256	conv dw	3×3×256/1
	28×28×256	conv	1×1×256×256/1

续 表

模块	输入	卷积类型	滤波器尺寸/步长
Block2	$28 \times 28 \times 256$	conv dw	$3 \times 3 \times 256/2$
	$14 \times 14 \times 256$	conv	$1 \times 1 \times 256 \times 512/1$
Block3	$14 \times 14 \times 512$	conv dw	$3 \times 3 \times 512/1$
	$14 \times 14 \times 512$	conv	$1 \times 1 \times 512 \times 512/1$
Block4	$14 \times 14 \times 512$	conv dw	$3 \times 3 \times 512/2$
	$7 \times 7 \times 512$	conv	$1 \times 1 \times 512 \times 1024/1$
	$7 \times 7 \times 1024$	conv dw	$3 \times 3 \times 1024/1$
	$7 \times 7 \times 1024$	conv	$1 \times 1 \times 1024 \times 1024/1$

MobileNets 网络采用深度可分离卷积来减少计算量,将标准 3×3 卷积分两步进行:(1)深度卷积,按照通道与 3×3 卷积核进行按位相乘计算。(2)使用 1×1 的点卷积进行标准卷积运算。标准卷积的计算量为 $D_F \times D_F \times D_K \times D_K \times M \times N$,而深度分离卷积的计算量为 $D_K \times D_K \times M \times D_F \times D_F + 1 \times 1 \times M \times N \times D_F \times D_F$ 。因此,通过深度可分离卷积,计算量将会下降 $(1/N + 1/D_K^2)$ 倍,其中 D_F 为特征图尺寸, D_K 为卷积核尺寸, M 为输入通道数, N 为输出通道数。

目标位置预测步骤如下:(1)重置图像尺寸,将原始图像划分为 13×13 的网格。(2)利用划分的网格回归预测目标的相对位置,每个网格预测 3 个锚点框。(3)采用非极大值抑制法(NMS)过滤掉置信度和 IoU(Intersection over Union)较低的锚点框。对每个锚点框预测置信度、边界框的中心坐标 (x, y) 、宽 w 和高 h ,分别记为 t_o, t_x, t_y, t_w, t_h 。则修正后的锚点框的中心坐标、宽和高分别为:

$$\begin{cases} b_x = \sigma(t_x) + c_x \\ b_y = \sigma(t_y) + c_y \\ b_w = p_w e^{t_w} \\ b_h = p_h e^{t_h} \end{cases}, \quad (1)$$

式中, (c_x, c_y) 表示锚点框中心所在单元格相对于图像左上角在 x 轴和 y 轴上的偏移量; p_w 表示原始锚点框的宽度; p_h 表示原始锚点框的高度。

改进后的 YOLOv3 算法(简称 MobileNets-YOLOv3)采用多尺度特征融合的方式,将 $28 \times 28, 14 \times 14, 7 \times 7$ 三种不同大小的特征图进行拼接以检测目标。由于在下采样过程中会丢失部分




图 4 MobileNets-YOLOv3 算法框图

Fig.4 Schematic diagram of MobileNets-YOLOv3 algorithm

图像信息,故结合多尺度特征图进行检测可以提高分类准确率和位置预测准确度。MobileNets-YOLOv3 算法结构如图 4 所示。其中 conv_block 为标准卷积加上正则化和 Leaky ReLu 激活层组成的模块。

3.2 损失函数的计算

MobileNets-YOLOv3 算法使用交叉损失熵方法进行置信度损失(confLoss)、分类损失(probLoss)和边界框坐标损失(xyLoss)的计算,使用总方差法(Sum-Squared Error)进行边界框宽高损失(whLoss)的计算。各损失函数的计算公式如下:

$$\text{totalLoss} = \sum_{i=0}^{S^2} (\text{xyLoss} + \text{whLoss} + \text{probLoss} + \text{confLoss}), \quad (2)$$

$$\text{xyLoss} = \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B -\ell_{ij}^{\text{obj}} [\hat{x}_i \ln x_i + \hat{y}_i \ln y_i + (1 - \hat{x}_i) \ln(1 - x_i) + (1 - \hat{y}_i) \ln(1 - y_i)] \quad (3)$$

$$\text{whLoss} = \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B \ell_{ij}^{\text{obj}} [(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2], \quad (4)$$

$$\text{probLoss} = - \sum_{i=0}^{S^2} \ell_{ij}^{\text{obj}} \sum_{c \in \text{classes}} \ell_{ij}^{\text{obj}} [\hat{p}_i(c) \ln p_i(c) + (1 - \hat{p}_i(c)) \ln(1 - p_i(c))], \quad (5)$$

$$\text{confLoss} = - \sum_{i=0}^{S^2} \sum_{j=0}^B \ell_{ij}^{\text{obj}} [\hat{C}_i \ln C_i + (1 - \hat{C}_i) \ln(1 - C_i)] - \lambda_{\text{noobj}} \sum_{i=0}^{S^2} \sum_{j=0}^B \ell_{ij}^{\text{noobj}} [\hat{C}_i \ln C_i + (1 - \hat{C}_i) \ln(1 - C_i)] \quad (6)$$

式中, $\lambda_{\text{coord}}=5$, $\lambda_{\text{noobj}}=0.5$; (x_i, y_i) 表示预测框的中心坐标值; w_i, h_i 表示预测框的宽和高; p_i 表示预测类别概率; C_i 表示预测目标的置信度; ℓ_{ij}^{obj} 表示单元格内有目标时, 值为 1; ℓ_{ij}^{noobj} 表示单元格内没有目标, 值为 1; S^2 表示网格数, 值为 13×13 ; B 表示每个单元格预测框的个数, 值为 3。

4 模型训练与试验结果分析

4.1 试验环境

本文使用 TensorFlow 深度学习框架实现 MobileNets-YOLOv3 算法。电脑配置为 Inter (R) Core i7-8750H CPU @ 2.20 GHz 处理器, 16G 运行内存, 256GB SSD+1T 硬盘容量, 6GB GTX 1060 GPU, 操作系统为 Windows 10。使用 Pycharm 2018.2.3 编译器, 并配置了 CUDA 9.2.217, cuDNN 7.2.1 进行 GPU 加速计算。采用 TensorBoard 可视化工具分析训练模型的性能。

4.2 棉花异纤检测网络训练

棉花异纤检测网络的训练流程如图 5 所示。




图 5 棉花异纤检测训练流程

Fig.5 Training process of cotton foreign fiber detection

首先对采集的棉花异纤数据集进行边界框的手工标注, 将数据集按 8 : 2 的比例分为训练集和测试集, 然后对训练集进行图像增强操作, 同时训练集的标注框也进行相应的操作, 最后使用 MobileNets-YOLOv3 为训练网络, 获得检测模型, 并利用测试集进行检测验证。

设置合理的网络超参数能更有效地训练网络且能提高检测结果的精确度, 具体设置如表 3 所示。

表 3 超参数表

Tab.3 Hyper parameters

参数名	参数取值
图片尺寸	224
滑动平均衰减率	0.999 5
批尺寸(batch_size)	4
迭代轮数(epochs)	200
IoU 阈值	0.5
置信度阈值	0.3

在网络训练中, 学习率通常采用指数衰减法进行网络优化。指数衰减法学习率(简称 ED_LR)如式(7)所示, 式中 step 表示当前迭代步数, 初始学习率 $\alpha_0 = 1 \times 10^{-4}$, 衰减速度 decay_steps = 1 020。

$$\text{ED_LR} = 0.95^{\frac{\text{step}}{\text{decay_steps}}} \times \alpha_0 \quad (7)$$

为了提高网络训练性能, 本文对学习率进行了改进, 将学习率划分为两个阶段(如图 6 所示): 第一个阶段从 0 开始线性增加学习率, 避免总损失函数出现无穷大的现象; 第二个阶段采用余弦函数非线性减小学习率, 避免出现梯度震荡, 总损失函数不收敛的现象。改进后的分段式学习率(简称 S_LR)如式(8)所示。设置最大学习率为 1×10^{-4} , 学习率最后减小至 1×10^{-6} , 式中, 第一阶段截止步数 wsteps = 5 099, 总训练步数 tsteps = 203 950。




图 6 分段式学习率变化曲线

Fig.6 Curve of segmented learning rate

$$S_LR = \begin{cases} 10^{-4} \times \frac{\text{step}}{\text{wsteps}} & \text{step} \leq \text{wsteps} \\ 10^{-6} + 0.5 \times (10^{-4} - 10^{-6}) \times \left(1 + \cos\pi \left(\frac{\text{step} - \text{wsteps}}{\text{tsteps} - \text{wsteps}}\right)\right) & \text{wsteps} < \text{step} \leq \text{tsteps} \end{cases} \quad (8)$$

4.3 试验结果与分析

4.3.1 评价指标

本文选取平均准确率(mAP)和帧速率作为整个模型检测效果的评价指标。AP(Average Precision)指的是 Precision- Recall 曲线与横轴包围的面积,mAP 为所有类的 AP 值取平均,计算公式如下:

$$\text{Precision} = \frac{TP}{TP + FP}, \quad (9)$$

$$\text{Recall} = \frac{TP}{TP + FN}, \quad (10)$$

$$\text{AP} = \sum_{k=1}^N \max_{\tilde{k} \geq k} P(\tilde{k}) \Delta r(k), \quad (11)$$

$$\text{mAP} = \frac{1}{n} \sum_{i=1}^n \text{AP}_i, \quad (12)$$


式中, TP 表示正样本被正确预测的数量; TN 表示负样本被正确预测的数量; FP 表示正样本被错误预测的数量; FN 表示负样本被错误预测的数量; N 表示置信度级别值的个数; $P(\tilde{k})$ 表示每一级别对应的最大 Precision 值; $\Delta r(k)$ 表示级别数从 $k-1$ 变化到 k 时,Recall 值变化的差值; n 表示棉花异纤的类别数。

4.3.2 试验结果与分析

采用 4.2 节设置的参数进行棉花异纤检测网络的训练。训练模型的总损失函数约 8 万步时开始收敛,第 200 轮时,置信度损失为 2.5×10^{-4} ,边界框的位置预测损失为 0.103 3,分类损失为 0.099 2,总损失为 0.202 6。


选择保存的第 200 轮训练模型分别对训练集和测试集进行检测,得到的结果如图 7 所示。由图 7(a)可知,训练集的预测准确率达到 90% 以上,且块状伪异纤的误检率最低,表明了该训练模型能有效地学习训练集样本数据的特征。由图 7(b)可知,测试集的预测准确率平均为 80%,对块状伪异纤的检测效果最好,而条状异纤的误检率最高,表明该检测模型具有泛化性,对测试集的棉

花异纤具有较好的检测效果。



(a) 训练集上的检测结果比较

(a) Comparison of the number of detected objects in train dataset



(b) 测试集上的检测结果比较

(b) Comparison of the number of detected objects in test dataset

图 7 数据集检测目标数对比

Fig.7 Comparison of the number of detected objects in dataset

图 8 给出了 6 张测试集图像检测结果图。前 4 张均为预测正确的结果图,且置信度均高于 0.96。图 8(e)为误检的结果图,将条状伪异纤检测为块状异纤(置信度为 0.54)和条状伪异纤(置

信度为 0.81),图 8(f)为测试集里唯一一张漏检的结果图。




图 8 检测效果

Fig.8 Detection results

4.3.3 图像数据增广对模型的影响

本文对数据增广前、后训练的模型检测结果进行了对比试验。试验结果如表 4 所示,其中策略 A 表示未对原图像数据进行增广处理,策略 B 表示对原始数据进行了增广处理。由表 4 可知,经过图像增广后训练的检测模型 mAP 提高了 3.6%,训练时长缩短了 0.46 h。表 5 给出了不同训练集各类别异纤的 AP 值结果。由表 5 可知,训练集经过图像增广后,块状异纤、块状伪异纤,条状异纤和条状伪异纤的 AP 值分别提高了 1.35%,4.65%,4.72%和 3.65%。

表 4 不同训练集检测指标对比

Tab.4 Comparison of results in different training sets

策略	mAP/%	帧速率/ ($f \cdot s^{-1}$)	训练时长/ h	收敛迭代 步数
A	81.22	66.67	9.29	40k
B	84.82	66.67	8.83	80k

表 5 不同训练集各个类别的 AP 值对比

Tab.5 Comparison of AP in different training sets

类别	A_AP	B_AP
块状异纤	85.09	86.44
块状伪异纤	76.67	81.32
条状异纤	77.20	81.92
条状伪异纤	85.93	89.58

综上,图像增广后,虽然训练模型时的收敛速度略有减慢,但是改善了模型的过拟合现象,提高了训练网络的检测准确度,且加快了训练速度,是一种有效的数据处理方式。

4.3.4 学习率的改进对模型的影响

分别使用分段式学习率、指数衰减法学习率训练模型,检测结果对比如表 6 所示。使用分段式学习率训练的模型在测试集上的 mAP 比指数衰减法高了 5.64%,除了块状异纤的 AP 值略微下降了 0.26%,块状伪异纤、条状异纤和条状伪异纤的 AP 值分别提高了 8.98%、5.85%和 7.99%。综上,分段式学习率能够加强训练模型的学习效果,提高检测的泛化能力。

表 6 不同学习率在测试集上的 AP 值对比

Tab.6 Comparison of AP in different learning rate

类别	ED_LR	S_LR
块状异纤	86.70	86.44
块状伪异纤	72.34	81.32
条状异纤	76.07	81.92
条状伪异纤	81.59	89.58
mAP	79.18	84.82

4.3.5 与改进前网络检测结果的对比

分别以 MobileNets 和 Darknet53 为特征提取网络的检测结果如表 7、表 8 所示。训练集的检测结果 mAP 比改进前提高了 1.85%,测试集的检测结果 mAP 比改进前提高了 2.03%,且帧速率加快至 3 倍,训练时间缩短至 1/4 倍。MobileNets 的网络层数是 Darknet53 网络的 1/2 倍,针对数据集尺寸较小的特点,减少特征提取次数有利于检测结果精度的提高。同时,MobileNets 采用的深度分离

表 7 改进网络前后检测结果对比

Tab.7 Comparison of detection results before and after network improvement

检测模型	测试集 mAP/%	训练集 mAP/%	帧速率/ ($f \cdot s^{-1}$)	训练时长/ h
MobileNets- YOLOv3	84.82	99.27	66.67	8.83
YOLOv3	82.79	97.42	20.00	36.09

卷积减少了大量的计算量,因此帧速率有大幅度提高。实验结果表明改进后的检测模型具有更高的准确度和更好的实时性,误检率和漏检率明显降低。

表 8 改进网络前后各个类别的 AP 对比

Tab.8 AP comparison before and after improving the network %

类别	测试集		训练集	
	MobileNets- YOLOv3	YOLOv3	MobileNets- YOLOv3	YOLOv3
块状异纤	86.44	85.19	99.63	98.67
块状伪异纤	81.32	77.92	98.96	96.45
条状异纤	81.92	81.58	98.97	96.64
条状伪异纤	89.58	86.48	99.53	97.91

4.3.6 与其他检测模型的对比

将本文算法与另外两种卷积神经网络 Faster R-CNN^[14]、SSD_300^[15]的检测效果进行了对比,结果如表 9 所示。由表 9 可知,Faster R-CNN 的检测准确率最高,比本文的 MobileNets-YOLOv3 算法高 2%,但是其帧速率只有 $6.58 \text{ f} \cdot \text{s}^{-1}$,同时网络训练时间最长,为 116.63 h。主要原因是

表 9 不同检测模型的对比

Tab.9 Comparison of different detection models

检测模型	测试集 mAP/%	训练集 mAP/%	帧速率/ ($\text{f} \cdot \text{s}^{-1}$)	训练时长/ h
MobileNets- YOLOv3	84.82	99.27	66.67	8.83
Faster R- CNN	86.82	88.84	6.58	116.63
SSD_300	72.66	78.20	15.89	18.30

参 考 文 献:

- [1] GAMBLE G R, FOULK J A. Quantitative analysis of cotton (*Gossypium hirsutum*) lint trash by fluorescence spectroscopy [J]. *Journal of Agricultural and Food Chemistry*, 2007, 55(13): 4940-4943.
- [2] MUSTAFIC A, LI C Y, HAIDEKKER M. Blue and UV LED-induced fluorescence in cotton foreign matter [J]. *Journal of Biological Engineering*, 2014, 8: 29.
- [3] 郑东耀,丁天怀.棉花中异性纤维的多光谱检测[J]. 清华大学学报(自然科学版),2005,45(2):193-196.

JIA D Y, DING T H. Detecting foreign fibers in cotton using a multi-spectral technique [J]. *Journal of Tsinghua*

Faster R-CNN 用区域生成网络生成 2 000 多个可能包含目标的候选区域,然后用 CNN 对每个候选区域进行分类,复杂的框架增加了网络的计算量。Faster R-CNN 无法满足实时性的需求。而 SSD_300 无论在检测精度和检测速度上都差于本文算法,主要原因是 SSD_300 模型低级的特征图存在特征提取不充分问题,检测异纤这种小目标误检率较高。

综上,本文提出的 MobileNets-YOLOv3 检测模型相较于 Faster R-CNN、SSD_300 深度学习算法,在保证精度的前提下,训练时间大幅缩减,且帧速率达到了 $66.67 \text{ f} \cdot \text{s}^{-1}$,可以满足工业检测对实时性的需求。

5 结 论

(1)提出了一种基于 MobileNets-YOLOv3 的棉花异性纤维检测方法,以及一种分段式学习率优化方式,并采用了图像数据增广的数据处理方式,对测试集的准确率 mAP 为 84.82%,帧速率达 $66.67 \text{ f} \cdot \text{s}^{-1}$ 。

(2)与 YOLOv3 算法相比,采用 MobileNets 作为特征提取网络的改进 YOLOv3 检测算法,mAP 值提高了 2.03%,帧速率加快至 3 倍,训练时间缩短至 1/4 倍,具有更高的识别准确度,实时性优势明显。

(3)改进的分段式学习率优化方法比常用的指数衰减法能更好地训练检测网络,在测试集上的 mAP 值提高了 5.64%。对原始图像数据进行数据增广后,训练模型在测试集上的 mAP 值提高了 3.6%,可以改善过拟合现象。

(4)与卷积神经网络 Faster R-CNN 和 SSD_300 相比,本文算法总体性能最佳,既能保证较高的检测精度,又能保证检测效率,符合棉花异纤检测准确率及实时性需求。

- University (Science and Technology)*, 2005, 45(2): 193-196. (in Chinese)
- [4] 杜玉红,王加富,蒋秀明,等.应用聚类统计分析的棉花异纤图形检测算法[J]. *纺织学报*, 2015, 36(3): 135-139.
DU Y H, WANG J F, JIANG X M, *et al.* Algorithm for pattern detection of cotton foreign fibers based on cluster statistic analysis [J]. *Journal of Textile Research*, 2015, 36(3): 135-139. (in Chinese)
- [5] 师红宇,管声启,吴宁.棉花中异性纤维的图像多分辨率差分检测方法[J]. *纺织学报*, 2014, 35(5): 13-18.
SHI H Y, GUAN S Q, WU N. Detection of foreign fibers among cotton based on image multi-resolution difference method [J]. *Journal of Textile Research*, 2014, 35(5): 13-18. (in Chinese)
- [6] 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.
SHI H Y, GUAN S Q. Cotton foreign fibers detection based on visual attention computational model [J]. *Journal of Donghua University (Natural Science Edition)*, 2016, 42(3): 400-405. (in Chinese)
- [7] 杨文柱,李道亮,魏新华,等.基于改进遗传算法的棉花异性纤维目标特征选择[J]. *农业机械学报*, 2010, 41(4): 173-178.
YANG W Z, LI D L, WEI X H, *et al.* Feature selection for cotton foreign fiber objects based on improved genetic algorithm [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2010, 41(4): 173-178. (in Chinese)
- [8] 杨文柱,卢素魁,王思乐.基于多类支持向量机的棉花异性纤维分类方法[J]. *计算机应用*, 2011, 31(12): 3446-3448, 3452.
YANG W Z, LU S K, WANG S L. Classification of cotton foreign fibers based on multi-class support vector machine [J]. *Journal of Computer Applications*, 2011, 31(12): 3446-3448, 3452. (in Chinese)
- [9] GIRSHICK R, DONAHUE J, DARRELL T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Columbus, OH, USA: IEEE, 2014: 580-587.
- [10] 郑欣,田博,李晶晶.基于 YOLO 模型的宫颈细胞簇团智能识别方法[J]. *液晶与显示*, 2018, 33(11): 965-971.
ZHENG X, TIAN B, LI J J. Intelligent recognition method of cervical cell cluster based on YOLO model [J]. *Chinese Journal of Liquid Crystals and Displays*, 2018, 33(11): 965-971. (in Chinese)
- [11] LI J, MEI X, PROKHOROV D, *et al.* Deep neural network for structural prediction and lane detection in traffic scene [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(3): 690-703.
- [12] HOWARD A G, ZHU M L, CHEN B, *et al.* MobileNets: efficient convolutional neural networks for mobile vision applications [J]. arXiv:1704.04861v1, 2017: 1-9.
- [13] REDMON J, FARHADI A. YOLOv3: an incremental improvement [J]. arXiv:1804.02767v1, 2018: 1-6.
- [14] REN S Q, HE K M, GIRSHICK R, *et al.* Faster R-CNN: towards real-time object detection with region proposal networks [C]//*Proceedings of the 28th International Conference on Neural Information Processing Systems*. Montreal, Canada: ACM, 2015: 91-99.
- [15] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: single shot MultiBox detector [C]//*Proceedings of the 14th European Conference on Computer Vision*. Amsterdam, The Netherlands: Springer, 2016: 21-37.

作者简介:



巫明秀(1995—),女,湖北武汉人,硕士研究生,2017 年于武汉科技大学获得学士学位,主要从事图像处理与模式识别方面的研究。E-mail: 2575323028@qq.com



吴 谨(1967—),女,博士,教授,2006 年于华中科技大学获得博士学位,主要从事信号处理、检测技术与自动化装置方面的研究。E-mail: wujin@wust.edu.cn