

文章编号: 2095-2163(2022)06-0131-06

中图分类号: TP391

文献标志码: A

# 基于改进 YOLOv3 算法的布匹瑕疵检测研究

苏茂锦, 曹 民

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

**摘要:** 布匹瑕疵检测是纺织行业生产过程中的重要环节, 实现高效、准确的布匹瑕疵检测对提升纺织工业的产能具有重要意义。针对目前布匹瑕疵大小差异较大、背景与目标难区分、传统检测方法效率较低等问题, 提出一种基于改进 YOLOv3 的布匹瑕疵检测方法, 通过引入深度可分离卷积减少模型参数量以提升检测速度, 在特征金字塔中嵌入 SENet 使模型更关注有效特征、抑制无效特征, 使用 *Focalloss* 损失函数替换原分类损失函数以降低易分类样本对模型产生的偏向性影响。通过实验对比表明, 改进后算法相比于原算法, *mAP* 指标提升了 4.9%, 召回率提升了 5.12%, 准确率提升了 37.78%, *FPS* 指标提升了 7%。

**关键词:** 布匹瑕疵检测; 卷积神经网络; SENet 结构; YOLOv3 网络

## Fabric defect detection based on improved YOLOv3

SU Maojin, CAO Min

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

**【Abstract】** Cloth defect detection is an important link in the production process of the textile industry. The realization of efficient and accurate cloth defect detection is of great significance to improve the production capacity of the textile industry. Aiming at the problems such as obvious difference in size of cloth defects, difficulty in distinguishing background and target, and low efficiency of traditional detection methods, a cloth defect detection method based on improved YOLOv3 is proposed. By introducing depthwise separable convolution to reduce the amount of model parameters for improving the detection speed, embedding SENet in the feature pyramid makes the model pay more attention to effective features and suppressing invalid features, and uses the *Focalloss* loss function to replace the original classification loss function to reduce the biased impact of easily classified samples on the model. The experimental result shows that, compared with the original algorithm, the improved algorithm improves the *mAP* index by 4.9%, the recall rate by 5.12%, the accuracy rate by 37.78%, and the *FPS* index by 7%.

**【Key words】** fabric defect detection; Convolutional Neural Network; SENet; YOLOv3

## 0 引言

纺织业作为中国传统经济的支柱产业, 其发展备受国家重视。目前, 国内纺织业的总产量在国际上处于领先地位, 但纺织企业在维持高产量的同时也不可避免会生产很多带瑕疵的布匹, 这些瑕疵布匹会让企业利润蒙受大量损失<sup>[1]</sup>。因此纺织厂会要求员工检查布匹中存在的各种复杂瑕疵, 但是人工检查布匹的速度一般为 10~20 m/min, 效率低下, 同时人工成本较大, 且人工检测布匹瑕疵检出率约为 70%, 这在一定程度上也会限制布匹的生产。因此, 高效率、低成本的自动化布匹瑕疵检测已经成为计算机、智能化等领域的研究热点<sup>[2]</sup>。

传统的机器视觉布匹瑕疵检测的方法有频谱分析方法<sup>[3]</sup>、模型方法<sup>[4-5]</sup>等。其中, 频谱分析方法比

较依赖滤波器组的选择, 模型方法计算量较大。这些机器视觉检测方法都需要对图像的特征进行提取, 面料不同, 图像的提取特征可能也是不同的, 常常需要对算法进行重新设计, 模型的可迁移性不高, 在面对具有复杂背景环境、布匹瑕疵大小差异悬殊、大分辨率的图片时, 亟需研发出一种更具一般性、且低训练成本的检测办法。

目前, 卷积神经网络 (Convolutional Neural Network, CNN) 在图像识别领域占据重要地位, 不仅对图像中的特征有着强大的提取能力, 而且在图像变换不变性的条件下仍然有着很强的分类和泛化能力<sup>[6]</sup>。因此, CNN 渐渐取代了传统目标检测算法, 现已成为目标检测领域的主要方法。

研究可知, 基于卷积神经网络的目标检测算法主要分为一步式检测和两步式检测。总地说来, 两

**作者简介:** 苏茂锦(1997-), 男, 硕士研究生, 主要研究方向: 人工智能与机器视觉; 曹 民(1970-), 男, 博士, 高级工程师, 硕士生导师, 主要研究方向: 机器视觉及运动控制、检测仪器及认证。

**通讯作者:** 曹 民 Email: mincao@usst.edu.cn

收稿日期: 2021-12-18

步式检测预先生成可能包含待检测物体的候选框,然后进行细粒度物体检测。两步式目标检测算法检测精度较高,但很难满足实时需求,代表算法有:RCNN, Fast-RCNN。而一步式检测算法则直接在网络中提取目标特征,并生成预测物体的种类和位置信息。一步式目标检测算法端到端地生成预测信息,在保证精度的同时大幅度地提升了检测速度,代表算法有:YOLO系列和SSD系列。尤需指出的是,YOLO系列里第三代算法(YOLOV3)<sup>[7]</sup>的提出使得目标检测在工业应用上、包括人脸识别、工业零件计数、工业缺陷检测等方面都有了很大的进步。

本次研究根据布匹瑕疵大小差异较大、各瑕疵数量不平均导致的训练结果具有偏向性、负样本过多等问题在YOLOv3的基础上进行改进:在YOLOv3的FPN特征金字塔中加入通道注意力机制(SENNet模块),提升网络对重要特征的选择能力。使用深度可分离卷积替代FPN中的 $3 \times 3$ 卷积,降低网络参数量,提升算法检测速度。使用Focalloss损失函数替换YOLOv3中的分类损失函数,降低样本类别不平衡产生的影响。

## 1 YOLOv3介绍

### 1.1 YOLOv3算法原理

YOLOv3<sup>[8-9]</sup>将图片划分为 $S \times S$ 个栅格,每个栅格有 $N$ 个边界框(bounding box),如果待检测目标中心落到某个栅格中,则该目标由这个栅格中的边界框进行预测,每个边界框包含3类信息,分别是:位置信息( $x, y, w, h$ )、置信度(confidence)以及 $C$

个类别的概率( $cls$ ),因此最终输出维度为 $S \times S \times N \times (4 + 1 + C)$ 。由预测框的位置信息获取真实框位置信息的计算公式如下:

$$\begin{cases} b_x = \text{sigmoid}(x) + c_x \\ b_y = \text{sigmoid}(y) + c_y \\ b_w = p_w \times e^w \\ b_h = p_h \times e^h \end{cases} \quad (1)$$

其中, $b_x, b_y, b_w, b_h$ 为真实框的中心位置以及宽、高信息; $p_w, p_h$ 为预设锚框的宽、高; $c_x, c_y$ 为预测框所属栅格左上角的坐标。

置信度信息代表当前边界框是否有对象的概率 $Pr(\text{Object})$ 以及当边界框有对象时,能够预测的box与物体真实box的IOU值。其公式如下:

$$\text{Confidence} = Pr(\text{Object}) \times IOU_{\text{pred}}^{\text{true}} \quad (2)$$

其中, $Pr(\text{Object})$ 表示栅格是否包含真实对象:假设栅格包含物体,则 $Pr$ 取1,否则取0; $IOU$ 表示真实框与预测框的交并比,也就是真实框和预测框交集面积与并集面积的比值。

### 1.2 YOLOv3网络结构

YOLOv3的网络结构如图1所示。结构中采用DarkNet53作为特征提取主干网络,相对于YOLO2的DarkNet19引入了残差块,此结构由连续的 $1 \times 1$ 卷积和 $3 \times 3$ 卷积构成,后又通过将残差块的输入与连续卷积后的结果进行跳跃连接得到最终输出。分析可知,该结构特点就是加深网络的深度、从而提高网络预测的准确性,同时也缓解了随着网络深度的增加而出现的梯度消失问题<sup>[9]</sup>。

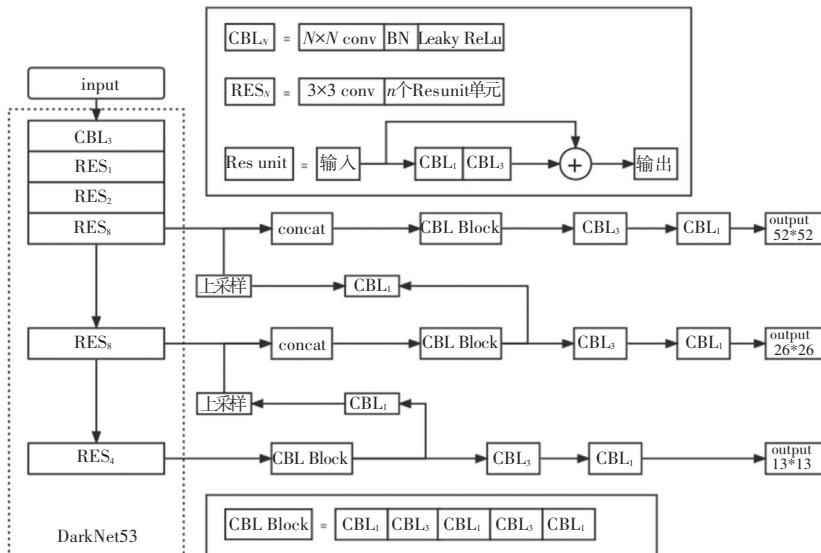


图1 YOLOv3结构图

Fig. 1 YOLOv3 structure

YOLOv3 完成对输入图片的特征提取后会生成 3 个特征层, 3 个特征层位于主干网络 DarkNet53 的不同部分。接下来, 利用 3 个特征层构建 FPN 特征金字塔, 将 3 个特征层进行特征融合, 既利用了深层特征较强的语义信息, 又利用了浅层特征的高分辨率信息。

## 2 基于 YOLOv3 的改进算法

### 2.1 深度可分离卷积

传统的标准卷积在运算过程中会考虑所有的通道数, 因此会产生大量参数和计算。假设输入特征图的尺寸为  $D_F \times D_F \times M$ , 卷积核尺寸为  $D_K \times D_K \times M$ , 输出特征图尺寸为  $D_F \times D_F \times N$ , 则标准卷积的参数数量为  $(D_K \times D_K \times M) \times N$ 。标准卷积过程示意图 2。

深度可分离卷积 (Depthwise separable convolution) [10-12] 过程如图 3、图 4 所示。由图 3、图 4 可知, 这一过程可分为 2 步。第一步是深度卷积, 用于滤波, 尺寸为  $D_K \times D_K \times 1$ , 共  $M$  个, 参数数量为  $(D_K \times D_K \times 1) \times M$ , 作用在输入的每个通道上, 改变特征图的宽、高; 第二步是逐点卷积, 用于转换通道, 尺寸为  $1 \times 1 \times M$ , 共  $N$  个, 参数数量为  $(1 \times 1 \times M) \times N$ , 作用在深度卷积的输出特征映射上。两者合起来就是深度可分离卷积。总参数数量等于 2 个部分之和:

$$Params = D_K \times D_K \times M + M \times N \quad (3)$$




图 2 标准卷积过程

Fig. 2 Standard convolution procedure




图 3 深度卷积

Fig. 3 Depthwise convolution




图 4 逐点卷积

Fig. 4 Pointwise convolution

所以深度可分离卷积的参数数量相当于标准的  $\frac{D_K \times D_K \times M + M \times N}{D_K \times D_K \times M \times N} = \frac{1}{N} + \frac{1}{D_K^2}$ , 对于每个  $3 \times 3$  卷积, 深度可分离卷积的参数数量缩减为原来的  $\frac{1}{N} + \frac{1}{9}$ 。

由此可见, 使用深度可分离卷积可有效降低网络计算量, 提高网络预测速度, 本文中我们将 FPN 中的  $3 \times 3$  卷积全部替换成深度可分离卷积, 降低 YOLOv3 检测头的参数数量, 同时也不影响主干网络的迁移训练。

### 2.2 嵌入 SENet

SENet [13-14] 是由胡杰团队于 2017 年提出的网络结构, 相对于传统卷积只是进行特征的提取, SENet 通过给每个通道进行加权, 使每个通道能够获得一个常数权重, 从而得到占有更大权重的重要特征。模型可以通过学习的方式自动获取每个特征通道的重要程度, 使模型更加关注对当前任务有效的特征、抑制对任务无效的特征。

SENet 的结构如图 5 所示。由图 5 可知, 主要包含 2 个过程: *Squeeze* 以及 *Excitation*。对此拟展开分述如下。




图 5 SENet 网络结构

Fig. 5 SENet structure

(1) *Squeeze*: SENet 将输入的特征图进行一次全局平均池化 (global average pool), 将一个通道上的整个空间特征编码作为一个全局特征得到一个标量,  $C$  个通道则会获取到  $C$  个标量, 该过程输出的维度为  $1 \times 1 \times C$ , 计算公式如下:

$$Z_C = F_{Squeeze}(input) = \frac{1}{H + W} \sum_{i=1}^H \sum_{j=1}^W input(i, j) \quad (4)$$

(2) *Excitation*: 经过 *Squeeze* 操作后网络得到了全局特征, 又通过 2 层全连接构成微型神经网络模块自主学习通道权重 (FC-Relu-FC-Sigmoid), 得到  $C$  个 0~1 之间的标量作为通道的权重, 再将原来输出特征的所有通道进行加权, 数学计算公式如下:

$$s = F_{Excitation}(z, W) = sigmoid(g(z, W)) =$$

$$\text{sigmoid}(W_2\delta(W_1z)) \quad (5)$$

$$\text{output} = F_{\text{Scale}}(\text{input}, s) = \text{input} \times s \quad (6)$$

其中,  $W_1 \times z$  表示全连接过程,  $\delta$  表示 ReLu 层。

由此得到的结果再与  $W_2$  做全连接, 得到的输出就是各个通道的权重, 最后将权重与输入特征图进行加权就是整个 SENet 的输出。

本文通过将 SENet 与深度可分离卷积引入到 YOLOv3 的特征金字塔, 实现对网络的优化, 使模型更加关注有效特征、抑制无效特征对输出结果产生的干扰, 降低网络参数量以提升算法运行速度。由此文中得到的改进算法的网络结构如图 6 所示。

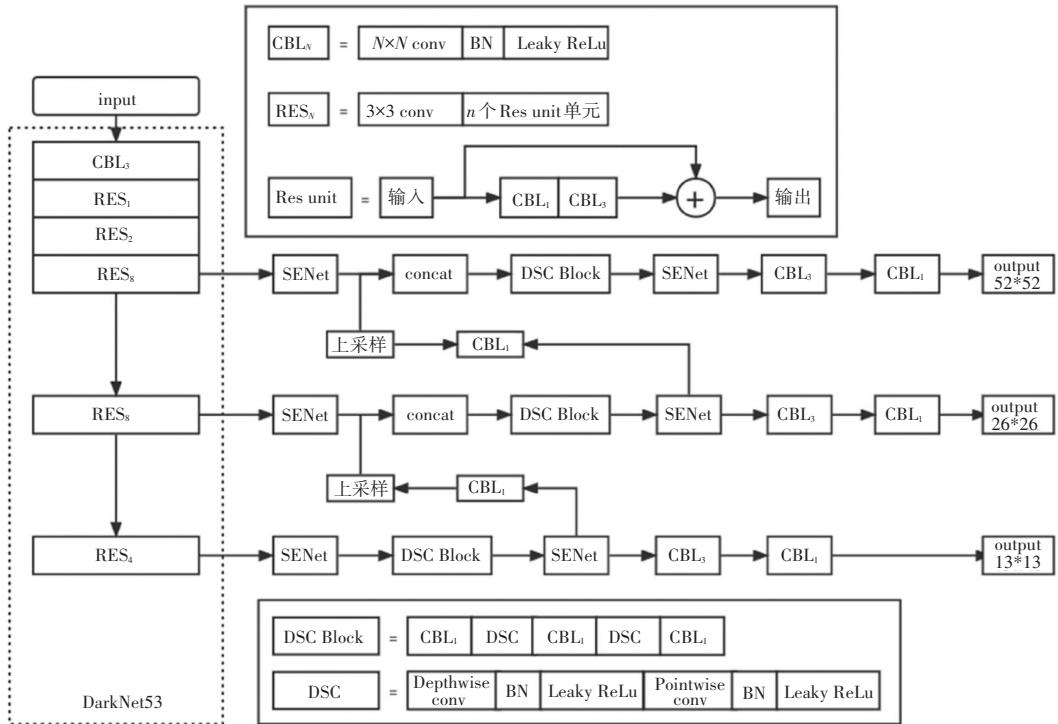


图 6 改进后算法结构图

Fig. 6 Improved algorithm structure diagram

### 2.3 损失函数改进

YOLOv3 的损失函数主要分为 3 类: 回归损失、置信度损失以及分类损失, 其中分类损失采用的是二分类交叉熵, 本文用  $Focalloss^{[15]}$  替代 YOLOv3 的分类损失。

$Focalloss$  是由何凯明团队于 2017 年提出的损失函数。 $Focalloss$  函数主要是为了提升一步式目标检测的准确度, 研究中认为一步式目标检测算法的准确度往往不如两步式目标检测算法的主要原因就在于样本的类别不平衡。

样本的类别不平衡主要分为 2 个方面。一是正、负样本不平衡; 二是难、易样本不平衡。实际情况中, 易分样本占总体样本比例较高, 由此产生的损失函数将主导着总体损失, 但是这部分样本本身就能被模型很好地识别出来, 如此一来, 在整体背景下的损失函数对参数的更新并不会改善模型的预测能力, 模型应该关注难分的样本。因此  $Focalloss$  函数

的思想是: 对于正负样本不平衡, 可使用权重  $\alpha$  来进行平衡, 对于难分样本和易分样本, 可将易分样本的损失进行一个幂函数降低, 具体公式如下:

$$Focalloss = \begin{cases} -\alpha \times (1-p)^\gamma \times \log(p) & y = 1 \\ -(1-\alpha) \times p^\gamma \times \log(1-p) & otherwise \end{cases} \quad (7)$$

其中,  $\alpha$  是平衡因子, 主要用于平衡正、负样本之间的数量比例不均;  $\gamma$  是缩放系数, 用于对易分样本产生的损失进行缩放, 使模型更关注难分类样本, 保证模型不会因为太多易分类而产生偏移。对于布匹瑕疵检测来说, 瑕疵与背景区分不明显、难分样本较少, 使用  $Focalloss$  会对模型性能提升有很好的效果。

## 3 实验结果与分析

### 3.1 实验数据及环境配置

实验数据来源于阿里云天池数据大赛平台, 一



张图片的分辨率为 1 000 px×2 446 px,且一张图片中可能存在多种缺陷类型,同时缺陷类型大小差异过大、小目标过多,因而具有较大的识别难度。典型样例如图 7 所示。



图 7 数据集图片样例

Fig. 7 Samples of data set images

本文选取生产中常见的 5 种布匹瑕疵,如三丝、破洞、粗经、结头、整经结来建立布匹瑕疵数据集,图片数量共 1 544 张,取其中 90%作为训练集,10%作为测试集,最后用于训练的图片共有 1 389 张,测试集为 155 张。表 1 为各个样本的分布情况。

表 1 样本分布情况

Tab. 1 Samples distribution

类别	数量/张
三丝	788
破洞	233
结头	1 178
整经结	222
粗经	173

实验运行环境:CPU 为 Intel(R) Core(TM) i5-10300H,内存为 16 GB,GPU 为 NVIDIA GeForce GTX 1660Ti 6 GB,程序代码使用 Windows 环境下的 Pytorch 进行实现。

### 3.2 实验结果与分析

为了验证文中提出的模型性能,将改进算法与 YOLOv3 进行性能测试对比,分别计算 YOLOv3 与改进网络对目标的召回率 (Recall) 以及准确率 (Precision)、平均精准度 (AP) 的结果运算数值。

目标召回率 (Recall) 和检测准确率 (Precision) 可分别由如下公式计算得出:

$$Recall = \frac{X_{TP}}{X_{TP} + X_{FN}} \quad (8)$$

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

其中,  $X_{TP}$  表示正确检测出来的目标数;  $X_{FP}$  表示被错误检测出来的目标数;  $X_{FN}$  表示未被检测出来的目标数。

另据研究分析指出,平均精准度是从召回率和准确率两个角度来衡量检测算法的准确性,可以用来评价单个目标的检测效果。

对测试集中的目标进行测试,分别获取 YOLOv3 与改进算法的性能指标。

不同算法目标检测结果 (Precision、Recall) 的对比见表 2,不同算法检测结果 (AP、mAP) 的对比见表 3,不同算法检测效率对比见表 4。通过表 2、表 3、表 4 对比后可以发现,改进算法对目标的检测准确率较 YOLOv3 提高了 37.78%,召回率提高了 5.12%,针对粗经、整经结这类难识别、难分类的 AP 指标分别提升了 12.42%、22.33%,虽然破洞的 AP 指标降低了 14.51%,但是改进算法的 mAP 指标提升了 4.9%,表明改进算法在全部类别中检测的综合性能更好。在检测效率上,改进算法的 FPS 指标较 YOLOv3 提升了 2.14(7%)。

表 2 不同算法目标检测结果的对比

Tab. 2 Comparison of target detection results of different algorithms %

模型	Precision	Recall
YOLOv3	46.26	19.02
改进算法	84.04	24.14

表 3 不同算法检测结果的对比

Tab. 3 Comparison of target detection results of different algorithms %

模型	AP					mAP
	三丝	破洞	粗经	结头	整经结	
YOLOv3	56.65	71.46	11.69	32.78	8.72	36.26
改进算法	57.17	56.95	24.11	36.49	31.05	41.16

表 4 不同算法检测效率对比

Tab. 4 Comparison of detection efficiency of different algorithms

模型	FPS
YOLOv3	29.03
改进算法	31.17

改进算法与 YOLOv3 检测结果如图 8、图 9 所示。




图 8 YOLOv3 检测结果

Fig. 8 YOLOv3 detection results



图9 改进算法检测结果

Fig. 9 Improved algorithm detection results

## 4 结束语

本文提出了一种针对布匹瑕疵检测的检测方法,首先将YOLOv3中FPN里的 $3\times 3$ 卷积替换成深度可分离卷积,提高了模型的检测速度,将SENet融入到FPN以及使用了Focalloss损失函数替代原来的二分类交叉熵函数,有效提升了模型对难检测、难分类瑕疵的检测性能。实验结果表明,该方法具有更好的鲁棒性,相对于YOLOv3算法,mAP指标提升了4.9%,对于难识别物体的准确率也均获得提升,检测耗时更短,提高了模型的检测性能。

## 参考文献

- [1] 赵宏威,王亦红. 基于改进Gabor优化选择的布匹瑕疵检测方法[J]. 计算机工程与应用,2019,55(24):202-207.
- [2] 吴志洋,卓勇,李军,等. 基于卷积神经网络的单色布匹瑕疵快速检测算法[J]. 计算机辅助设计与图形学学报,2018,30(12):2262-2270.

(上接第130页)

差,仍需做进一步研究,可能存在的影响因素有:提升装置的震动因素和机器人壳体自重对越障高度的影响。

## 参考文献

- [1] 李爽,范振广,蒋碧含,等. 玻璃清洗机器人国内外发展现状[J]. 中国科技信息,2017(10):84-85.
- [2] 刘星. 高层玻璃幕墙清洗机器人设计与分析[D]. 青岛:山东科

- [3] IZADIAN A, FAMOURI P. Fault diagnosis of MEMS lateral comb resonators using multiple - model adaptive estimators [J]. IEEE Transactions on Control Systems Technology,2010,18(5):1233-1240.
- [4] 严浙平,陈涛,秦政,等. 灰色动态预测在AUV传感器故障诊断中的应用[J]. 传感技术学报,2008(06):1002-1006.
- [5] NSENGIYUMVA P, VERMAAK H, LUWES N. A comparative study of methods for defect detection in textile fabrics[J]. Journal for New Generation Sciences,2015,13(3):1-14.
- [6] 荆辰未,李启顺,朱玉全. 基于改进视觉显著性的布匹瑕疵检测方法[J]. 信息技术,2017(09):22-25,30.
- [7] HSU C C, CHEN C Y. Applications of improved grey prediction model for power demand forecasting [J]. Energy Conversion and Management,2003,44(14):2241-2249.
- [8] REDMON J, DIVVALA S K, GIRSHICK R B, et al. You only look once: Unified, real-time object detection [J]. CoRR,2015, abs/1506.02640.
- [9] 杨紫辉,江磊,任洪娟. 基于改进YOLOv3网络的非机动车检测[J]. 智能计算机与应用,2021,11(08):87-91.
- [10] 王兵,李文璟,唐欢. 改进YOLO v3算法及其在安全帽检测中的应用[J]. 计算机工程与应用,2020,56(09):33-40.
- [11] KHAN Z Y, NIU Zhendong. CNN with depthwise separable convolutions and combined kernels for rating prediction [J]. Expert Systems with Applications,2021,170:114528.
- [12] SIDDIQI R. Efficient pediatric pneumonia diagnosis using depthwise separable convolutions [J]. SN Computer Science, 2020,1(6):343.
- [13] 刘学平,李珂乾,刘励,等. 嵌入SENet结构的改进YOLOV3目标识别算法[J]. 计算机工程,2019,45(11):243-248.
- [14] HU Jie, SHEN Li, SUN Gang. Squeeze-and-excitation networks [J]. arXiv preprint arXiv:1709.01507, 2017.
- [15] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2020,42(2):318-327.

技大学,2017.

- [3] 钱志源,刘仁强,赵言正,等. 一种壁面牵引移动式玻璃幕墙清洗机器人[J]. 上海交通大学学报,2006(11):1818-1821,1826.
- [4] TUN T T, ELARAB M R, KALIMUTHUC M, et al. Glass facade cleaning robot with passive suction cups and self - locking trapezoidal lead screw drive [J]. Automation in Construction, 2018, 96 : 180-188.
- [5] 蒋境伟. 玻璃幕墙清洗机器人控制系统的设计[D]. 哈尔滨:哈尔滨工业大学,2019.