

基于改进 Faster RCNN 的水接触角测量方法

王慧¹, 王军^{1,2*}, 曹召良^{1,2}¹苏州科技大学物理科学与技术学院, 江苏 苏州 215009;²中国科学院长春光学精密机械与物理研究所应用光学国家重点实验室, 吉林 长春 130033

摘要 针对传统水接触角测量过程需要人工干预, 导致测量结果精度低、可复现性差等问题, 提出一种基于改进 Faster RCNN 的水接触角测量方法。首先, 把 Faster RCNN 骨干网络 VGG16 替换为 ResNet101, 在其残差块末尾处添加注意力机制模型 convolutional block attention module (CBAM), 增强网络提取特征的能力; 其次, 融入特征金字塔网络 (FPN), 充分提取不同尺度下的特征信息, 此外, 引入 Focal 损失函数来解决正负类样本不均衡的问题; 最后, 对定位到的水滴进行边缘检测和角点提取, 再利用迭代重加权最小二乘法 (IRLS) 拟合椭圆轮廓计算水接触角。实验结果表明, 改进后的 Faster RCNN 目标检测算法与原算法相比, 平均精度均值提高 10.794%, 速度提升 11 frame/s, 水接触角测量结果平均标准偏差为 0.109°。

关键词 图像处理; 水接触角; 特征金字塔网络; 注意力机制; Faster RCNN

中图分类号 TP391.41 文献标志码 A

DOI: 10.3788/LOP231404

Water Contact Angle Calculation Method Based on Faster RCNN

Wang Hui¹, Wang Jun^{1,2*}, Cao Zhaoliang^{1,2}¹School of Physical Science and Technology, Suzhou University of Science and Technology,
Suzhou 215009, Jiangsu, China;²State Key Laboratory of Applied Optics, Changchun Institute of Optics, Fine Mechanics and Physics,
Chinese Academy of Sciences, Changchun 130033, Jilin, China

Abstract A water contact angle measurement method based on the improved Faster RCNN is proposed to address the issues of low accuracy and poor reproducibility caused by manual intervention in traditional water contact angle measurement processes. First, the Faster RCNN backbone network VGG16 was replaced with ResNet101, and the attention mechanism model convolutional block attention module (CBAM) was added at the end of its residual block to enhance the network's ability to extract features. Second, the feature pyramid network (FPN) was incorporated to fully extract feature information at different scales, and the Focal loss function was introduced to solve the problem of imbalanced positive and negative class samples. Finally, edge detection and corner extraction were performed on the located water droplets, and then the iterative reweighted least squares (IRLS) method was used to fit the elliptical contour to calculate the contact angle angle. The experimental results show that the improved Faster RCNN object detection algorithm improves mean average precision by 10.794% and speed by 11 frame/s over the original algorithm. The average standard deviation of contact angle angle measurements is 0.109°.

Key words image processing; water contact angle; feature pyramid network; attention mechanism; Faster RCNN

1 引言

为了更直观地判断材料表面的润湿性, 通常会测量固体表面上液滴的接触角, 水接触角是指当液体处于稳定状态时, 固-液界面和气-液界面在三相交界面^[1]

间的夹角。水接触角是评测液体对各种材料表面浸润性的主要依据, 科研人员可通过它快速准确地分析物体表面浸润特性, 甚至进一步研究液体分子间的内聚力和固液间的分子相互作用力。如果测量结果超过 90°, 说明固液间润湿性较差, 即固体表面呈疏水性^[2];

收稿日期: 2023-05-30; 修回日期: 2023-06-01; 录用日期: 2023-07-24; 网络首发日期: 2023-08-18

基金项目: “十四五”江苏省重点学科资助(2021135)、中国航天科技集团公司第八研究院产学研合作基金资助(SAST2020-025)

通信作者: *wjhl@126.com

反之,则说明固体表面呈亲水性。目前,水接触角测量技术被广泛应用于电子、科教、医药和印染等行业,通过测试不同材料水滴角,实现对固体表面亲/疏水性分析、洁净度检测及处理效果评估,为高效研究材料表面性能提供参考。因此,如何高精度测定水接触角被大家广泛研究。

接触角测量方法由早期的测力法、长度法、量角法等物理方法发展到现在利用图像处理算法来进行测算。早期接触角测量方法主要依靠人工进行,其结果受操控人员影响,难以复现,误差较明显。Smedley等^[3]提出测力法,通过测量液体表面张力^[4]计算接触角。为了减小因操作人不同对测量结果造成的影响,研究者们开始采取数学算法处理相关数据。Bateni等^[5]采用自动多项式拟合算法测量接触角,可避免因操作者不同而引起的误差。随着图像处理技术的发展,不少学者开始采用图像处理技术来计算接触角。Rotenberg等^[6]利用牛顿迭代法拟合图像轮廓,计算对称类液滴的接触角;Cheng等^[7]在文献^[6]的基础上采用边缘检测算子^[8]提取边缘,减小因人工提取边缘而出现的误差;Chini等^[9]通过液滴的反射现象寻找与基座的接触点,而后用多项式拟合来计算接触角,但反射现象很微弱时,仅能通过人工确定接触点;Mirzaei^[10]采用Harris角点检测^[11]来提取液滴与工作台的接触点,不仅可以获取液滴轮廓的起止点,还可以借助两个角点坐标判定工作台是否处于水平状态。上述方法都获得了有效的测量结果,但依然存在无法精确检测水滴区域的问题,只能采用人工方式裁剪图像到液滴位置,从而引入较多误差。也有学者尝试利用图像处理

技术检测液滴区域,但由于多次使用图像处理算法会造成图像信息损失,导致无法精确检测目标区域,进而使水接触角测量结果精度较低。

本文在检测精度较高的Faster RCNN目标检测模型^[12]上继续改进,全程避免人工操作实现水滴区域检测,消除因人工干预而产生的系统误差。使用深层次残差网络ResNet101^[13]代替基础网络VGG16^[14]并对其微调后加入注意力机制,提升模型检测精度^[15]的同时增强特征提取能力,接着引入特征金字塔网络(FPN)以提取不同尺度的特征信息。此外,采用Focal损失函数^[16]解决正负类样本不均衡问题,然后对检测到的目标进行轮廓提取、角点检测,最后利用迭代重加权最小二乘法(IRLS)^[17]拟合椭圆轮廓计算水接触角。

2 基于改进的Faster RCNN水滴检测与定位方法

2.1 传统的Faster RCNN算法

Faster RCNN是第一个真正意义上的端到端的深度学习检测算法,其最大的创新之处就在于通过添加region proposal network (RPN),基于anchor机制来生成候选框(代替selective search),最终将特征提取、候选框选取、边框回归和分类都整合到一个网络中,从而有效提高检测精度和检测效率,其结构如图1所示。

其中,Faster RCNN将VGG16作为骨干网络,但由于存在模型复杂度高、训练和推理速度慢、特征提取能力受限和容易出现梯度消失等缺点,所以将骨干网替换为更高效、更强大的ResNet101,以进一步提高检测精度、加快训练速度及缓解梯度消失现象。

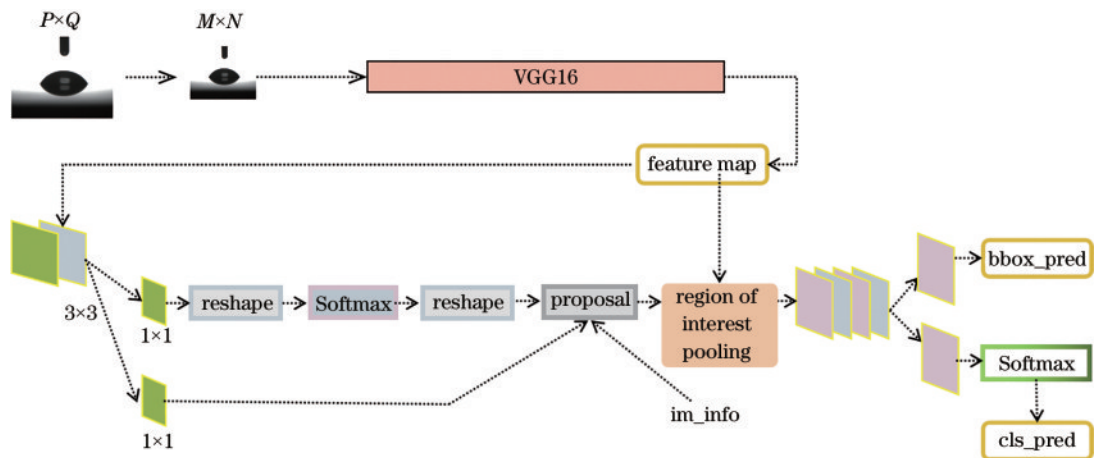


图1 传统Faster RCNN模型

Fig. 1 Traditional Faster RCNN model

2.2 ResNet101模型

ResNet101的网络结构非常深,共有101层,包括100个卷积层和1个全局平均池化层,网络结构如图2所示。ResNet101的基本结构由多个残差块组成,其中,1个残差块包含2个卷积层和1个跳跃连接。通过残差块,ResNet101可以构建非常深的神经网络,并取

得很好的性能。因为在残差块中,特征的信息可以直接通过跳跃连接传递到后面的层,不会像普通的卷积块一样,需要经过多层的卷积操作才能传递,从而避免梯度消失的问题,使得网络可以更好地学习复杂的特征,其结构如图3所示。

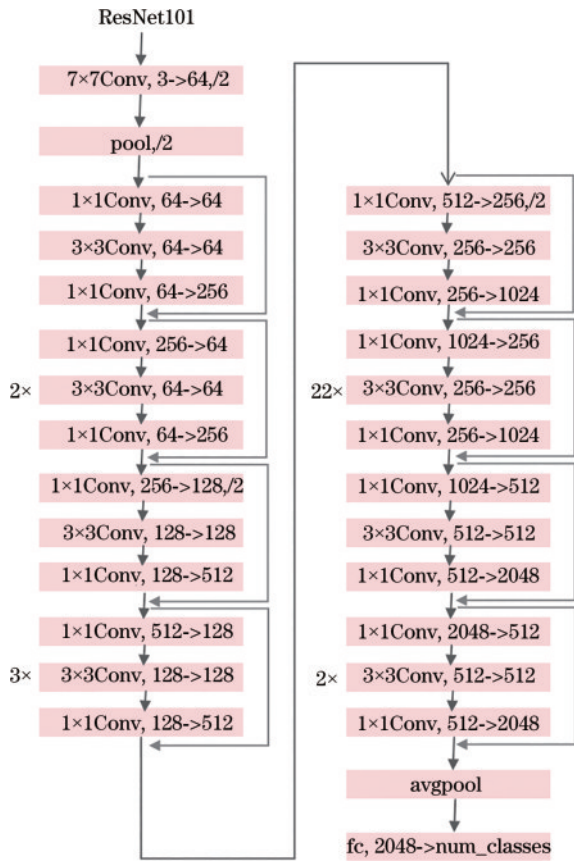


图 2 ResNet101 结构模型
Fig. 2 ResNet101 architecture model

2.3 特征金字塔网络

FPN 是一种用于解决多尺度物体检测问题的神经网络结构,通过构建不同尺度的特征金字塔来提取图像




图 3 残差模块
Fig. 3 Residual module

的多尺度特征^[18],将 ResNet101 与 FPN 融合代替 VGG16 作为骨干网络可以解决多尺度目标检测问题,可以在不同尺度上进行特征提取,不同层次的特征都能够被充分利用,从而提高检测性能,还可以通过特征重用和共享来减少网络参数的数量,从而加速检测速度。网络架构如图 4 所示,具体流程如下:

- 1) 自下而上:将提前处理过的图像传进提前经过训练的网络,建立自下而上的网络,如图 4 中的(C₂、C₃、C₄、C₅)这一组金字塔所示。
- 2) 自上而下:将 C₅ 复制变为 P₅,对层 P₅ 进行上采样操作(就是 2×up),再用 1×1 卷积对 C₃ 进行降维处理,然后将深、浅层特征汇总,这样就得到了层 P₄、P₂、P₃ 层以此类推,如图 4(P₂、P₃、P₄、P₅) 金字塔所示。
- 3) 卷积融合:最后对层(P₂、P₃、P₄、P₅) 分别进行卷积操作得到最终预测(对应图 4 中的 predict)。

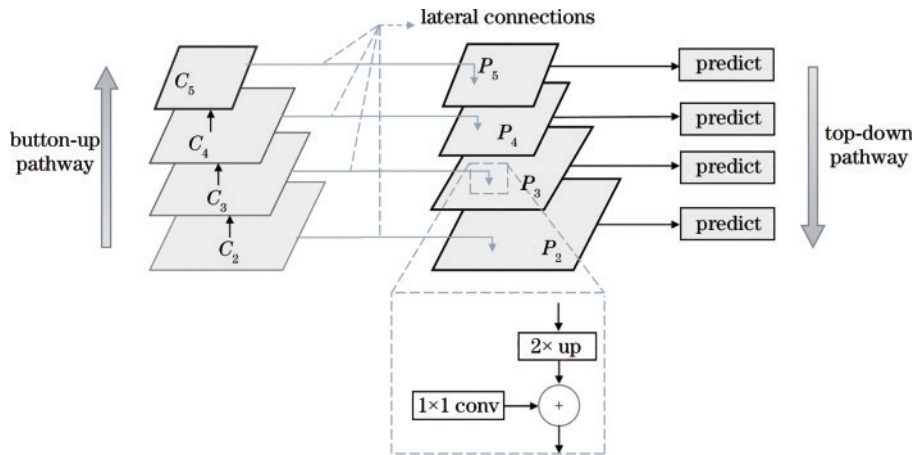


图 4 FPN 框架
Fig. 4 FPN framework

ResNet101 与 FPN 结合后的网络结构如图 5 所示,图中 C₂、C₃、C₄、C₅ 分别对应 ResNet101 网络 Conv1~Conv5 卷积块,然后采用 1×1 卷积横向连接进行逐元素相加得到新的特征图 P₂~P₅,接着进行 3×3 卷积生成最终特征图,记为 P₂、P₃、P₄、P₅、P₆。

2.4 注意力机制

注意力机制模型主要分为通道注意力机制(CAM)和空间注意力机制(SAM)^[19],通道注意力机制的典型代表为 SENet,它通过自适应地调整特征图中每个通道的权重,加强特征表达能力。

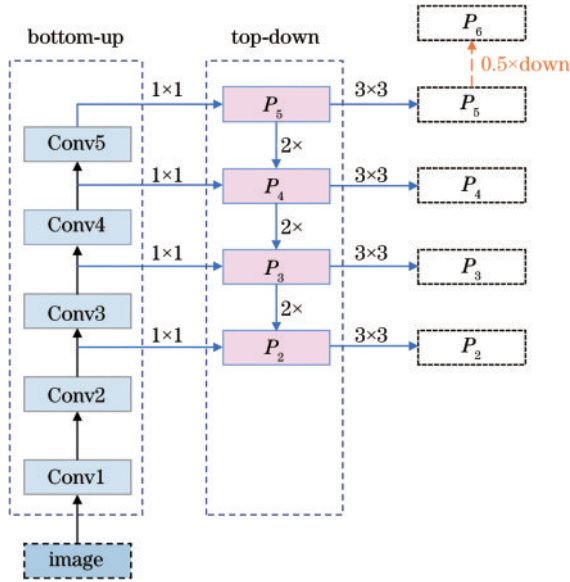


图 5 ResNet101 与 FPN 融合的网络结构
Fig. 5 Network structure of ResNet101 and FPN

图 6 为 SENet 模型, SENet 首先对输入的特征层进行全局平均池化^[20], 然后进行两次全连接, 第一次全连接神经元个数较少, 第二次全连接神经元个数和输入特征层相同, 接着再通过 Sigmoid 激活函数将值固定到 0~1 之间, 此时获得了输入特征层每一个通道的权值, 最后将获得的权值乘上原输入特征层即可。

空间注意力机制则可获得输入的特征层上的每个特征点的权值^[21], 模型结构如图 7 所示。对输入进来的特征层, 在每一个特征点的通道上取最大值和平均值^[22], 然后将这两个结果堆叠并采用通道数为 1 的卷积调整通道数^[23], 接着再通过 Sigmoid 激活函数将每个特征点权值控制在 0~1, 最后将权重与特征图点乘。

convolutional block attention module (CBAM) 将通道注意力机制和空间注意力机制结合来自适应调整特征图中每个通道的权重以及每个像素点的空间权重^[24], 模型如图 8 所示。




图 6 通道注意力模块网络框架
Fig. 6 Network framework of channel attention module




图 7 空间注意力模块网络框架
Fig. 7 Spatial attention module network framework

在 ResNet101 结构中引入 CBAM 注意力机制模型可以更加准确选择和强化有用的特征, 抑制不相关特征, 提高网络分类精度, 减轻过拟合并提高鲁棒性, 同时还能快速训练。

2.5 改进 ResNet101 网络层

原始 ResNet101 网络中所有的卷积层都使用 3×3 的卷积核大小, 在这些卷积层中, 参数数量占整个模型参数数量的比例较大。因此, 对 ResNet101 进行改进, 将卷积核大小调整为 2×2 来减少参数数量和计算量。此外, 将 CBAM 注意力机制添加到每个残

差块的末尾, 即 1×1 卷积层之后, 从而可以更好地引导网络关注有用的特征并且抑制冗余信息, 提高网络的性能。改进后的 ResNet101 网络层参数如表 1 所示。

2.6 改进损失函数

为解决正负样本数量不平衡的问题, 引入 Focal 损失函数代替原交叉熵函数来调整损失函数中每个样本的权重, 使得分类效果较差的样本在训练过程中得到更多的关注和修正。




图 8 CBAM 网络框架

Fig. 8 CBAM network framework

表 1 ResNet101 改进前后网络层参数对比表
Table 1 Network layer parameters before and after ResNet101 improvement

Layer name	Output size	ResNet101	Improved ResNet101
Conv1	112×112	7×7, 64, stide 2 3×3 max pool, stide 2	
Conv2_x	56×56	1×1, 64 3×3, 64×3 1×1, 256	1×1, 64 2×2, 64×3 1×1, 256 CBAM-block
Conv3_x	28×28	1×1, 128 3×3, 128×4 1×1, 512	1×1, 128 2×2, 128×4 1×1, 512 CBAM-block
Conv4_x	14×14	1×1, 256 3×3, 256×23 1×1, 1024	1×1, 256 2×2, 256×23 1×1, 1024 CBAM-block
Conv5_x	7×7	1×1, 512 3×3, 512×3 1×1, 2048	1×1, 512 2×2, 512×3 1×1, 2048 CBAM-block
	1×1	average pool, 1000-d FC, Softmax	

交叉熵损失函数如式(1)所示, y 表示目标真实类别情况, p 表示检测模型输出是目标的概率, 取值范围

为 $(0, 1]$ 。

$$L_{CE}(p, y) = \begin{cases} -\log(p), & y = 1 \\ -\log(1-p), & y = 0 \end{cases} \quad (1)$$

平衡交叉损失函数在交叉熵公式前面增加权重 α , α 值越小, 负样本的权重相对降低, 同时正样本的权重相对增加, 如式(2)所示:

$$L_{CE}(p, y) = \begin{cases} -\alpha \log(p), & y = 1 \\ -(1-\alpha) \log(1-p), & y = 0 \end{cases} \quad (2)$$

在平衡交叉熵损失函数中加入调节因子, 形成 Focal 损失函数, 用于调整难易样本的权重, 如式(3)所示。当样本属于易分类时, 调制因子趋近于 0, 对损失值影响较小, 当样本属于难分类时, 调制因子趋近于 1, 对损失值影响较大, 从而控制难易分类样本在损失函数中所占的比重。

$$L_{CE}(p, y) = \begin{cases} -\alpha(1-p)^{\gamma} \log(p), & y = 1 \\ -(1-\alpha)p^{\gamma} \log(1-p), & y = 0 \end{cases} \quad (3)$$

2.7 改进后的 Faster RCNN 模型

将 Faster RCNN 的骨干网络替换为融合 FPN 并加以改进的 ResNet101, 并添加 CBAM 注意力机制, 另外将原始交叉熵损失函数替换为 Focal 损失函数。改进后的 Faster RCNN 结构如图 9 所示。

利用改进后的 Faster RCNN 目标检测网络对水滴

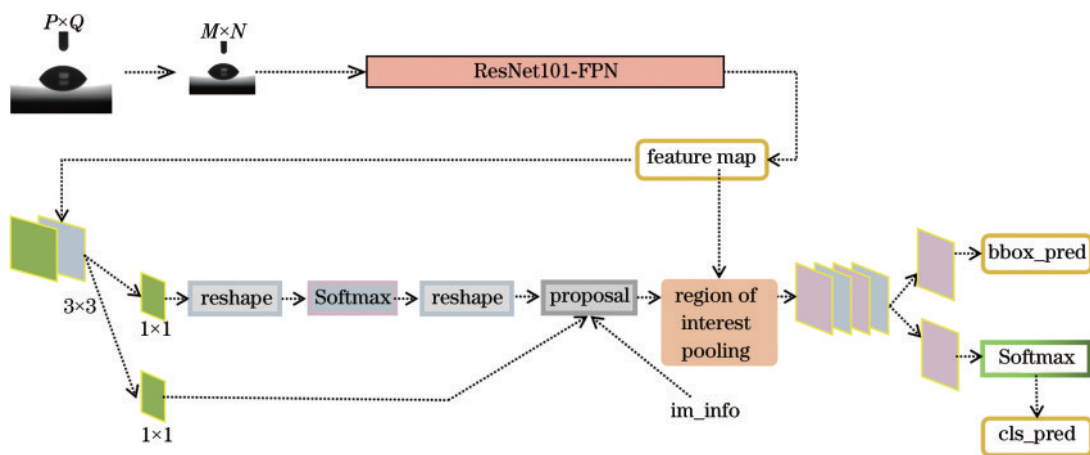


图 9 改进后的 Faster RCNN 结构

Fig. 9 Network structure of improved Faster RCNN

进行检测,如图 10 所示。采用改进后的网络对图 10 中 4 幅图像进行检测,置信度分别为 0.953、0.948、0.925、0.969,没有出现漏检或者错检的现象,液滴区域均处于检测框以内,可以较为准确检测到液滴所在区域。




图 10 改进后模型水滴识别效果

Fig. 10 Improved model water droplet recognition effect

3 基于 Faster RCNN 的水接触角计算流程

使用 Faster RCNN 精确定位水滴可以大大提高后续水接触角计算的精度,避免了繁琐的手工裁剪和其他处理过程。之后需要采用 Canny 边缘检测算法提取目标区域的边缘轮廓,在提取到的轮廓上进行 Harris 角点检测,最后通过 IRLS 拟合液滴左右两边轮廓来计算两侧水接触角,流程图如图 11 所示。

3.1 边缘检测

在高精度定位液滴后需要进一步提取液滴边缘,为了可以明显观察边缘检测的效果并与原图进行对比,对图 10 的图像进行边缘提取,结果如图 12 所示。从图中可以看出,4 种不同形态的液滴轮廓均可被清晰提取,在角度极小、中等、偏大的情况下,检测到的边缘都较为完整,图像整体边缘清晰可见,没有出现断裂或者错检的现象。

3.2 角点检测

采用 Harris 角点检测算法对边缘检测的结果进行角点提取的结果如图 13 所示,角点通过易于观察的十字丝进行标识。从图中可以看出,无论是较大角度的液滴还是较小角度的液滴,其左右两侧的三相接触点均能被正确提取。

3.3 轮廓拟合

采用 IRLS 拟合椭圆求取水接触角。提取到角点后,将两个角点连线中点所在垂线拆分为两半分别来拟合轮廓,拟合效果如图 14 所示,大约经过两三次迭

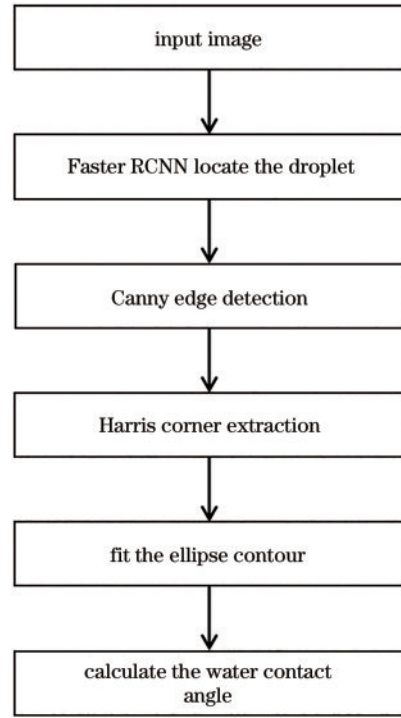


图 11 水接触角计算流程

Fig. 11 Water contact angle calculation flow




图 12 Canny 边缘检测

Fig. 12 Canny edge detection




图 13 Harris 角点提取

Fig. 13 Harris corner extraction

代即可获得收敛解。然后,通过求解椭圆方程各参数,得出椭圆中心坐标、长短轴后建立坐标系,将角点坐标转化为椭圆坐标系上的坐标,图 15 即为计算右侧接触角的示意图。

计算接触角的公式如式(4)所示,其中,长轴旋转角度为 θ ,右侧角点处斜率为 k ,该切线与水平方向夹角 φ 为水接触角。




图 14 IRLS 轮廓拟合
Fig. 14 IRLS contour fitting




图 15 以椭圆中心建立坐标系计算右侧水接触角
Fig. 15 The right water contact angle calculated by establishing the coordinate system with the center of the ellipse

$$\varphi = \pi - [\theta - \arctan(k)]. \quad (4)$$

4 实验与结果分析

4.1 数据集与评价指标

现有目标检测的公开数据集如 VOC2007^[25-27]都针对通用目标,应用在水滴检测上的效果并不好,但目前还没有关于水滴的公开数据集。因此,采用去离子




图 16 液滴区域定位结果对比图。(a)~(f)原始 Faster RCNN 检测结果;(g)~(l)改进后的 Faster RCNN 检测结果
Fig. 16 Comparison of location results of droplet region. (a)~(f) The detection results of the original Faster RCNN; (g)~(l) the detection result of improved Faster RCNN

从图 16 可以看出:采用 VGG16 作为骨干网络的传统 Faster RCNN 目标检测算法检测这 6 幅图像的置信度分别为 0.869、0.901、0.892、0.884、0.873、0.928,并且在检测图 16(e)这种角度极小的液滴时,检测精度较低,液滴两侧角点均处在检测框之外,存在漏检现


象,那么后续计算接触角时会存在较大误差;改进后的网络置信度显著提升,分别提升至 0.948、0.963、0.971、0.957、0.953、0.987,可以较为准确检测到液滴所在区域,分别如图 16(g)~(l)所示。图 17 为改进前后的 Faster RCNN 的 mAP 曲线,从图中可以看出,

水制作水滴数据集,采用型号为 MV-CA016-10GM 的海康工业相机,通过蓝色面光源打光的方式进行拍摄,拍摄总时长约为 46 h,在拍摄过程中采用以下方法增加样本的多样性:在不同物体表面拍摄液滴,以采集形状不同、大小不一的水滴图像;改变相机视角和距离,以改变水滴在整幅图像的位置;添加不同类型的背景和干扰物,在水滴周围放置不同物体,以增加样本的复杂性;改变蓝色面光源强度、方向,采集不同光照情况下的水滴图像。采集的图像分辨率为 640 pixel × 512 pixel,共 1462 张图,其中,80% 的图像作为训练图像,20% 作为测试图像,最后,采用 LabelImg 对图像中的水滴进行标注。

4.2 目标检测精度验证

4.2.1 检测结果

为验证所提方法的有效性,基于 PyTorch 1.2 及 Python 3.8 的深度学习框架进行实验^[28],使用 CUDA10.0 加速 GPU 运算,GPU 选用 NVIDIA GXT-1050Ti,共训练 350 epoch。将所提方法与基于 Faster RCNN 模型的 VGG 传统网络模型的检测效果进行对比分析,检测效果如图 16 所示,由于液滴在样品台上存在反光现象,所以拍摄到的液滴图像呈上下对称状。



象,那么后续计算接触角时会存在较大误差;改进后的网络置信度显著提升,分别提升至 0.948、0.963、0.971、0.957、0.953、0.987,可以较为准确检测到液滴所在区域,分别如图 16(g)~(l)所示。图 17 为改进前后的 Faster RCNN 的 mAP 曲线,从图中可以看出,

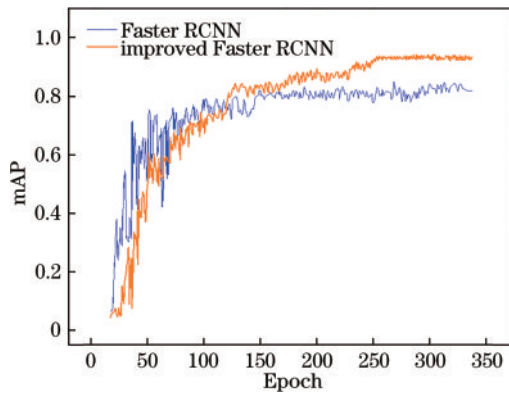


图 17 原网络 mAP 曲线(细)与改进后 Faster RCNN 网络的 mAP 曲线(粗)对比

Fig. 17 Comparison of the original network mAP curve (thin) and the improved Faster RCNN network mAP curve (thick)

150~350 epoch 两模型已逐渐趋于收敛,在 120 epoch 之后改进后网络的 mAP 已逐渐超过未改进的传统网络模型。

4.2.2 消融实验及对比实验

在自制数据集上进行消融实验来验证在 Faster RCNN 中添加某模块对于网络性能的影响。以网络层被改进的 ResNet101 作为基础框架,不做其他改动,记为 Basic,具体实验结果如表 2 所示。

表 2 消融实验对比表

Table 2 Comparison of ablation experiments

Module	mAP / %	Omission ratio / %
Basic	86.625	11.1
Basic+FPN	87.264	8.9
Basic+CBAM	87.912	7.3
Basic+Focal loss	86.757	12.7
Basic+FPN+CBAM	91.516	9.4
Basic+CBAM+Focal loss	89.731	10.1
Basic+FPN+Focal loss;	89.862	7.8
Basic+CBAM+FPN+Focal loss	95.658	5.2

从表 2 可以看出,只修改了 ResNet101 网络层的算法的 mAP、漏检率分别为 86.625%、11.1%,而改进后网络的指标相比传统网络均有所提升,Basic+CBAM+FPN+Focal loss 模型的 mAP 提高 9.033 百分点,漏检率降低 5.9 百分点。因此,改进后的 Faster RCNN 相比原网络和另外的模型来说是比较有效的。

进一步将改进后的 Faster RCNN 算法和分别以 VGG16、ResNet101 为骨干网络的 Faster RCNN、YOLO、SSD、YOLOv2 算法进行对比,在同样的实验条件下在所制作的数据集上进行训练。此外,添加了新的评估指标 FPS,用于衡量算法的运行速度和实时性,结果如表 3 所示。

从表 3 可以看出:传统 Faster RCNN 算法的

表 3 与相关算法的对比结果

Table 3 Comparison results with relevant algorithms

Algorithm	mAP / %	Omission ratio / %	FPS / (frame/s)
Faster RCNN(VGG16)	84.864	8.8	15
Faster RCNN(ResNet101)	86.011	9.6	19
SSD	80.924	14.2	21
YOLOv2	78.325	12.1	30
Improved Faster RCNN	95.658	5.2	26

mAP、漏检率分别为 84.864%、8.8%,改进后的网络在 mAP、漏检率方面均有显著提升,mAP 相比原算法提高 10.794 百分点,漏检率降低 3.6 百分点。虽然改进后的 Faster RCNN 算法的 FPS 值相比于原算法提高 11 frame/s,但比 YOLOv2 低 4 frame/s,不过仍然可以满足实际需求。

4.3 水接触角测量精度验证

采用平均值和标准偏差作为水接触角测量结果的评价指标。在恒温恒湿,使用同一测试样品的条件下进行水接触角的测量,在液滴与工作台接触时间达到 40 s 处于稳定状态后,每隔 2 s 采取 10 帧图像,分别测量每帧图像左右两侧角点处的接触角取其平均值作为水接触角测量结果,连续采集 10 组,将所提方法(记为 Ours)与杨氏方程拟合(记为 Y-L)、多项式拟合(记为 P-F)、最小二乘拟合(记为 L-S)这几种常用的拟合方式进行对比实验。将每组水接触角测量结果的平均值记为 θ_{CA} ,标准偏差记为 θ_{STD} ,实验数据如表 4 所示。

从表 4 可以看出:通过所提方法测得的每组数据的标准偏差都是最低的,而多项式拟合每次都需要人工确定拟合阶数,这比较依赖人的主观经验,因此会存在较大标准偏差;最小二乘法也具有较大的标准偏差,因为采用单一方程无法实现对轮廓的准确拟合,导致计算水接触角时出现很大误差;在液滴处于完全对称的情况下,杨式方程拟合轮廓效果可观,但对于非对称的液滴形状,该方程无法计算,所以在轮廓拟合时会出现较大误差。对比其他 3 种方法,所提方法测量的结果完全独立于操作者,不依赖人的主观判断,在多次重复实验中均获得最小标准偏差,最小为 0.104° ,说明该实验复现性较好。

水接触角测量结果随时间变化的曲线如图 18 所示,横轴代表时间,纵轴代表角度值。从图中可以看出,在水滴达到稳定后的 42~60 s 的这段时间里,采用所提方法计算的水接触角值上下浮动不大,曲线走势相对平稳,而采用其他 3 种方法计算得出的水接触角值标准偏差较大,所以曲线起伏较为明显,说明所提方法采用的拟合轮廓的方法更为合适,测得的数据准确性较高。

表 4 接触角测量结果

Table 4 Measurement results of contact angle

Number	Ours		Y-L		P-F		L-S	
	θ_{CA}	θ_{STD}	θ_{CA}	θ_{STD}	θ_{CA}	θ_{STD}	θ_{CA}	θ_{STD}
1	76.16	0.108	75.99	2.032	77.15	1.265	75.45	2.702
2	76.02	0.110	77.01	1.815	75.55	2.652	75.46	1.952
3	76.21	0.107	76.45	1.213	75.88	2.492	77.15	3.120
4	76.28	0.109	78.01	0.961	77.25	5.216	75.41	4.051
5	76.03	0.112	77.78	1.624	75.79	2.928	75.24	1.282
6	76.31	0.104	77.08	2.152	76.51	0.985	75.65	2.882
7	76.19	0.110	75.79	0.913	77.40	3.815	77.00	1.585
8	76.35	0.112	77.06	1.925	75.48	1.983	77.31	4.925
9	76.14	0.110	76.42	1.313	74.98	1.268	75.51	4.462
10	76.33	0.108	77.27	2.145	75.99	2.315	76.45	2.273

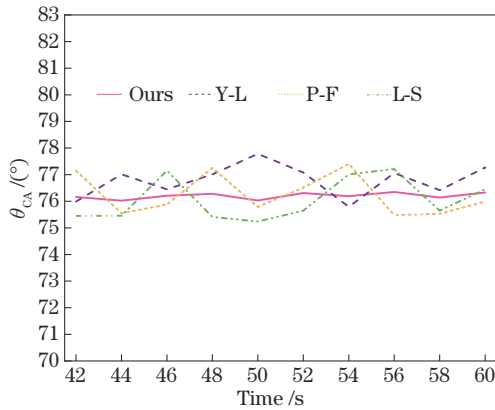


图 18 接触角随时间变化图像

Fig. 18 Image of contact angle changing over time

5 结 论

以 Faster RCNN 为基础,提出一种改进的 Faster RCNN 的水接触角计算方法,实现了水滴区域的检测与水接触角的计算,整个计算流程避免了人工干预产生的误差。将 Faster RCNN 基础框架替换为 ResNet101,并对 ResNet101 网络层进行改进,将卷积核大小调整为 2×2 来减少参数数量和计算量,之后在 ResNet101 每个残差块的末尾添加 CBAM 注意力机制后与 FPN 融合,不仅可以更好地引导网络关注有用的特征,在抑制冗余信息的同时还可以充分提取不同尺度下的特征信息,此外,使用 Focal 损失函数来解决正负类样本不均衡的问题。实验结果表明,改进后的模型检测准确率为 95.658%,能较精确地识别到原模型未能正确识别的角度极小的液滴,相比于原 Faster RCNN 算法,mAP、FPS 分别提升了 9.033 百分点、11 frame/s。多次重复实验结果表明,所提方法可以较准确地测量水接触角且平均标准偏差为 0.109° ,满足实际需求。

参 考 文 献

- [1] 郑志霞,李文芳,张丹,等. 激光刻蚀紫铜表面润湿性的快速转变[J]. 激光与光电子学进展, 2022, 59(7): 0714010.
Zheng Z X, Li W F, Zhang D, et al. Rapid transformation of wettability on surface of laser etched red copper[J]. Laser & Optoelectronics Progress, 2022, 59(7): 0714010.
- [2] 刘祁文,刘国东,李子航,等. 纳秒激光制备镁合金超疏水表面及其性能研究[J]. 激光与光电子学进展, 2022, 59(5): 0514004.
Liu Q W, Liu G D, Li Z H, et al. Preparation and properties of superhydrophobic surface of magnesium alloy by nanosecond laser[J]. Laser & Optoelectronics Progress, 2022, 59(5): 0514004.
- [3] Smedley G T, Coles D E. A refractive tilting-plate technique for measurement of dynamic contact angles[J]. Journal of Colloid and Interface Science, 2005, 286(1): 310-318.
- [4] Drelich J. Contact angles: from past mistakes to new developments through liquid-solid adhesion measurements [J]. Advances in Colloid and Interface Science, 2019, 267: 1-14.
- [5] Bateni A, Laughton S, Tavana H, et al. Effect of electric fields on contact angle and surface tension of drops [J]. Journal of Colloid and Interface Science, 2005, 283 (1): 215-222.
- [6] Rotenberg Y, Boruvka L, Neumann A W. Determination of surface tension and contact angle from the shapes of axisymmetric fluid interfaces[J]. Journal of Colloid and Interface Science, 1983, 93(1): 169-183.
- [7] Cheng P, Li D, Boruvka L, et al. Automation of axisymmetric drop shape analysis for measurements of interfacial tensions and contact angles[J]. Colloids and Surfaces, 1990, 43(2): 151-167.
- [8] Huang M L, Liu Y L, Yang Y M. Edge detection of ore and rock on the surface of explosion pile based on

- improved Canny operator[J]. Alexandria Engineering Journal, 2022, 61(12): 10769-10777.
- [9] Chini S F, Amirfazli A. A method for measuring contact angle of asymmetric and symmetric drops[J]. Colloids and Surfaces A: Physicochemical and Engineering Aspects, 2011, 388(1/2/3): 29-37.
- [10] Mirzaei M. A new method for measuring the contact angles from digital images of liquid drops[J]. Micron, 2017, 102: 65-72.
- [11] Cui J, Xie J B, Liu T, et al. Corners detection on finger vein images using the improved Harris algorithm[J]. Optik, 2014, 125(17): 4668-4671.
- [12] 张寅, 朱桂熠, 施天俊, 等. 基于特征融合与注意力的遥感图像小目标检测[J]. 光学学报, 2022, 42(24): 2415001.
Zhang Y, Zhu G Y, Shi T J, et al. Small target detection in remote sensing images based on feature fusion and attention[J]. Acta Optica Sinica, 2022, 42(24): 2415001.
- [13] Khan M A, Khan M A, Ahmed F, et al. Gastrointestinal diseases segmentation and classification based on Duo-deep architectures[J]. Pattern Recognition Letters, 2020, 131: 193-204.
- [14] Song Z Z, Fu L S, Wu J Z, et al. Kiwifruit detection in field images using Faster R-CNN with VGG16[J]. IFAC-PapersOnLine, 2019, 52(30): 76-81.
- [15] 王启胜, 王凤随, 陈金刚, 等. 融合自适应注意力机制的 Faster R-CNN 目标检测算法[J]. 激光与光电子学进展, 2022, 59(12): 1215016.
Wang Q S, Wang F S, Chen J G, et al. Faster R-CNN target detection algorithm with adaptive attention mechanism[J]. Laser & Optoelectronics Progress, 2022, 59(12): 1215016.
- [16] 崔子越, 皮家甜, 陈勇, 等. 结合改进 VGGNet 和 Focal Loss 的人脸表情识别[J]. 计算机工程与应用, 2021, 57(19): 171-178.
Cui Z Y, Pi J T, Chen Y, et al. Facial expression recognition combined with improved VGGNet and focal loss[J]. Computer Engineering and Applications, 2021, 57(19): 171-178.
- [17] Dembinski H, Schmelling M, Waldi R. Application of the iterated weighted least-squares fit to counting experiments[J]. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 2019, 940: 135-141.
- [18] 刘峰, 郭猛, 王向军. 基于跨尺度融合的卷积神经网络小目标检测[J]. 激光与光电子学进展, 2021, 58(6): 0610012.
Liu F, Guo M, Wang X J. Small target detection based on cross-scale fusion convolution neural network[J]. Laser & Optoelectronics Progress, 2021, 58(6): 0610012.
- [19] 宋敏毓, 陈力荣, 梁建安, 等. 轻量化改进网络的实时光纤端面缺陷检测模型[J]. 激光与光电子学进展, 2022, 59(24): 2415006.
Song M Y, Chen L R, Liang J A, et al. Real-time optical fiber end-face defect detection model based on lightweight improved network[J]. Laser & Optoelectronics Progress, 2022, 59(24): 2415006.
- [20] 程松, 杨洪刚, 徐学谦, 等. 基于 YOLOv5 的改进轻量型 X 射线铝合金焊缝缺陷检测算法[J]. 中国激光, 2022, 49(21): 2104005.
Cheng S, Yang H G, Xu X Q, et al. Improved lightweight X-ray aluminum alloy weld defects detection algorithm based on YOLOv5[J]. Chinese Journal of Lasers, 2022, 49(21): 2104005.
- [21] 丁兆敏, 郑凯东. 融合注意力机制与 HRNet 的人群计数算法[J]. 信息技术与信息化, 2022(10): 31-34.
Ding Z M, Zheng K D. Crowd counting algorithm combining attention mechanism and HRNet[J]. Information Technology and Informatization, 2022(10): 31-34.
- [22] 陈翰琦, 韩永华. 基于注意力机制和迁移学习的轮胎花纹分类[J]. 软件, 2022, 43(6): 65-69.
Chen H Q, Han Y H. Tire pattern classification based on attention mechanism and transfer learning[J]. Software, 2022, 43(6): 65-69.
- [23] 黄震, 朱华波, 陶友瑞. 基于 YOLOv5 的打磨表面质量快速评价方法[J]. 智能计算机与应用, 2022, 12(11): 247-252.
Huang Z, Zhu H B, Tao Y R. Rapid evaluation method of polished surface quality based on YOLOv5[J]. Intelligent Computer and Applications, 2022, 12(11): 247-252.
- [24] 曲海成, 王馨心, 欧阳俊. 基于融合混合域模块与空洞卷积的红外小目标检测[J]. 激光与光电子学进展, 2023, 60(10): 1010002.
Qu H C, Wang X X, Ouyang J. Infrared small-target detection based on hybrid domain module and hole convolution[J]. Laser & Optoelectronics Progress, 2023, 60(10): 1010002.
- [25] Wang Y, Li Y, Guo X H, et al. CDANet: common-and-differential attention network for object detection and instance segmentation[J]. Pattern Recognition Letters, 2022, 158: 48-54.
- [26] 满英杰, 王宪, 孙冬悦, 等. 目标检测与图像分类网络融合的金属化陶瓷环缺陷检测[J]. 激光与光电子学进展, 2023, 60(20): 2015007.
Man Y J, Wang X, Sun D Y, et al. Defect detection of metallized ceramic rings based on fusion of target detection and image classification networks[J]. Laser & Optoelectronics Progress, 2023, 60(20): 2015007.
- [27] 白宗宝, 张俊举, 高原, 等. 基于注意力机制的航拍图像目标检测算法[J]. 激光与光电子学进展, 2023, 60(12): 1215003.
Bai Z B, Zhang J J, Gao Y, et al. Attention mechanism-based object detection algorithm in aerial images[J]. Laser & Optoelectronics Progress, 2023, 60(12): 1215003.
- [28] 王友伟, 郭颖, 邵香迎. 基于改进级联算法的遥感图像目标检测[J]. 光学学报, 2022, 42(24): 2428004.
Wang Y W, Guo Y, Shao X Y. Target detection in remote sensing images based on improved cascade algorithm[J]. Acta Optica Sinica, 2022, 42(24): 2428004.