

基于改进 U-Net 网络的液滴分割方法

高心悦, 田汉民

引用本文

高心悦, 田汉民. 基于改进 U-Net 网络的液滴分割方法[J]. 计算机科学, 2022, 49(4): 227-232.

GAO Xin-yue, TIAN Han-min. Droplet Segmentation Method Based on Improved U-Net Network[J].

Computer Science, 2022, 49(4): 227-232.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

共享浅层参数多任务学习的脑出血图像分割与分类

Intracerebral Hemorrhage Image Segmentation and Classification Based on Multi-task Learning of Shared Shallow Parameters

计算机科学, 2022, 49(4): 203-208. <https://doi.org/10.11896/jsjcx.201000153>

基于多级特征融合与注意力模块的场景识别方法

Scene Recognition Method Based on Multi-level Feature Fusion and Attention Module

计算机科学, 2022, 49(4): 209-214. <https://doi.org/10.11896/jsjcx.210100135>

改进 YOLOv3 网络模型的人体异常行为检测方法

Human Abnormal Behavior Detection Method Based on Improved YOLOv3 Network Model

计算机科学, 2022, 49(4): 233-238. <https://doi.org/10.11896/jsjcx.210300251>

基于改进 YOLOv3 的机坪工作人员反光背心检测研究

Study on Reflective Vest Detection for Apron Workers Based on Improved YOLOv3 Algorithm

计算机科学, 2022, 49(4): 239-246. <https://doi.org/10.11896/jsjcx.210200119>

基于特征定位与融合的行人重识别算法

Person Re-identification Based on Feature Location and Fusion

计算机科学, 2022, 49(3): 170-178. <https://doi.org/10.11896/jsjcx.210100132>

基于改进 U-Net 网络的液滴分割方法

高心悦¹ 田汉民^{1,2}

1 河北工业大学电子信息工程学院 天津 300401

2 天津市电子材料与器件重点实验室 天津 300401

(936869913@qq.com)

摘要 液滴图像的精确分割是高精度接触角测量的重要环节,针对在液滴分割过程中存在的目标不准确、轮廓不完整以及固-液-汽 3 项交点和边界细节效果不佳的问题,文中提出了一种适用于液滴分割的神经网络模型。该模型以 U-Net 网络为基础,在其输入处加入 1×1 卷积层汇总图像特征,避免从初始图像中丢失信息;并采用 Resnet18 结构作为 U-Net 的特征学习编码器,增强了网络的表达能力,促进了梯度的传播。在解码过程中引入密集连接的特征融合技术,在提升分割目标细节信息的同时降低了网络参数。最后在每个卷积层后都添加批量归一化操作,进一步优化了网络性能。实验结果表明,改进的 U-Net 模型能够有效提高液滴识别的准确率,提升分割效果,在接触角测量领域具有一定的参考价值。

关键词: 液滴分割; U-Net; 残差网络; 特征融合; 接触角测量

中图法分类号 TP391

Droplet Segmentation Method Based on Improved U-Net Network

GAO Xin-yue¹ and TIAN Han-min^{1,2}

1 School of Electronic and Information Engineering, Hebei University of Technology, Tianjin 300401, China

2 Tianjin Key Laboratory of Electronic Materials and Devices, Tianjin 300401, China

Abstract The accurate segmentation of liquid drop image is an important part of high precision contact Angle measurement. Aiming at the problems of inaccurate target, incomplete contour, and poor effect of solid-liquid-vapor intersection and boundary details in the process of liquid drop segmentation, a neural network model suitable for liquid drop segmentation is proposed. The model is based on U-Net network, and a 1×1 convolution layer is added at its input to summarize image features to avoid losing information from the initial image. Resnet18 structure is used as the feature learning encoder of U-Net to enhance the expression ability of the network and promote the propagation of gradient. The feature fusion technology of dense connection is added in the decoding process, which improves the detail information of segmented target and reduces the network parameters. Finally, a batch normalization operation is added after each convolution layer to further optimize the network performance. Experimental results show that the improved U-Net model can effectively improve the accuracy of droplet identification and segmentation effect, and has a certain reference value in the field of contact Angle measurement.

Keywords Droplet segmentation, U-Net, ResNet, Feature fusion, Contact angle measurement

1 引言

液滴在不同固体表面会形成相应的接触角,接触角是衡量固体材料表面性能的重要参数,也是测试材料表面润湿性和洁净度的重要指标^[1],在工业、农业、军事、医疗卫生等领域发挥了重要作用。接触角指液滴轮廓的切线与接触面之间的夹角,因此有效地提取出正确的液滴轮廓边界,是获得准确接触角值的前提。传统的接触角测量工作大多是在计算机的辅助条件下,通过人工操作与肉眼结合的方式进行,难以实现高效性和高精度。目前,图像外形分析法^[2]是接触角测量应用最广泛的方法,其通过图像处理技术结合测量方法计算接触

角。故利用计算机高效、准确地对图片中的液滴进行分割,是接触角测量的关键环节。

为了得到更优的区域和边界信息,研究人员对液滴的分割进行了相应的实践与改进,主要是基于边缘检测、轮廓跟踪与特征点检测等。文献[3]将粒子群优化的边缘检测算法用于液滴边界的分割,该算法利用粒子群迭代计算的优化特点,将最优阈值融入 Canny 算子中,具有一定抑制噪声的作用。文献[4]采用八邻域轮廓跟踪和手动消除的方式获得液滴的轮廓,并去除了图像中多余的干扰线。文献[5]提出了一种基于子图像邻域梯度信息度量的液滴边缘提取算法,通过构造邻域信息映射矩阵并根据矩阵梯度信息度量值来判定边界。

文献[6]将一个设定阈值的圆形模板在液滴边缘移动,筛选获得液滴的特征点坐标,进而直接计算接触角。传统的形态学处理方法通常着重于获取图像的低阶信息,而忽视了像素块之间的联系和图像中目标的语义信息。文献[5]中的研究表明,由于固体表面材质不一、液滴的透光性差以及机械水平位置偏差等影响,拍摄出的液滴图像容易出现边界亮度不均、细节粗糙等问题,采用传统或改进的图像处理方法很难获得准确的目标信息。精确地识别并分割液滴,自动去除图像中的干扰目标,对接触角测量的准确性和高效性十分重要。

近年来,计算机视觉在图像分割领域表现出了巨大的潜力,其分割原理可以视为图像单个像素的分类问题,先将标注好的图片作为训练样本,训练支持向量机(Support Vector Machine, SVM)、逻辑回归(Logistic Regression, LR)、神经网络(Neural Network, NN)等分类器,再以训练好的分类器对输入图片进行逐像素分类,将图像中的每一个像素关联到一个类别标签上,根据像素分类情况得到图像的分割结果,称为语义分割^[7]。近年来,随着深度学习的普及,大多语义分割问题皆采用深层次的结构来解决,最常见的是卷积神经网络(Convolutional Neural Network, CNN),其在精度和效率上大大超越了其他方法。在此基础上,全卷积神经网络(Fully Convolution Network, FCN)^[8]被提出,它将 CNN 的全连接层替换为卷积层,又通过上采样恢复了图像的尺寸,从而使卷积神经网络在语义分割领域得以应用。Ronneberger 等^[9]根据 FCN 模型提出了 U-Net 对称网络,该网络模型为一个 U 型结构,主要由收缩路径和对称扩张路径组成。收缩路径用于学习图像不同层次的特征,以及捕获上下文信息;扩张路径能够还原目标的位置,精确定位分割边界与细节,将特征图恢复到输入图片的大小和分辨率,同时网络的跳跃连接可以将高低层次的语义信息相结合,进行特征复用。目前,很多分割任务都在 U-Net 网络的基础上进行,尤其是医学图像分割领域,且实现了较好的分割效果。文献[10]提出了 Attention Res-Unet 结构,用于分割图像中的阴影目标,该网络使用 ResNeXt101 作为特征提取前端,增强了特征的学习能力,并融入注意力机制和非局部操作进一步提升了分割效果。文献[11]将轻量级网络 MobileNetV2 作为 U-Net 编码器,对劣质图片中的织物缺陷进行提取,不仅降低了网络的复杂度,还在分割精度和检测速度上都达到了较高水平。文献[12]基于 U-Net 结构提出了一种用于 CT 图像分割的自适应全密度(AFD)神经网络,通过引入多层密集连接和融合多尺度语义信息,加强了网络层之间的特征传递。文献[13]将残差连接引入 U-Net 模型建立编解码网络,用于视网膜血管的高精度分割,大大简化了网络的学习过程,促进了梯度的传播。

目前卷积神经网络在液滴识别领域的应用和研究较少,且本文所研究的液滴图片与医学图像有着较多的共同之处。首先,图片均是固定的目标成像,结构复杂度适中且二分类语义信息较为直观,此时需要低分辨率信息用于目标的识别;其次,液滴图像与医学图像均存在部分边界模糊、梯度复杂的问题,需要较多的高分辨率信息用于精准分割。因此高级语义

信息和低级特征都显得尤为重要,本文选用的 U-Net 算法同时结合了高低分辨率信息,适用于液滴图像的分割。但由于实验环境多样,液滴形态各异且部分图片的对比度不强,液滴存在边缘虚化、易受其他区域影响等问题。在进行网络模型训练时,易出现编码器学习能力不足、无法准确地提取液滴轮廓、部分细节丢失、网络收敛速度慢、特征利用率不高等情况。综上,本文在 U-Net 模型的基础上,针对液滴图片的实际特点,提出了一种改进的 U-Net 网络。具体改进如下:

(1)为了汇总图像特征,避免从初始液滴图像中丢失信息,在 U-Net 模型输入处添加了一个 1×1 卷积层来增加初始特征图的数量。

(2)将 Resnet18 作为 U-Net 的特征学习编码器,通过增加编码器的卷积层数,来增强液滴图片特征的学习能力。恒等映射层促进了梯度的传播,还能避免液滴图像的细节信息在多层卷积操作后丢失。

(3)在解码过程中引入密集连接的特征融合操作,在提升液滴分割细节信息的同时降低了网络参数,有助于提高液滴的分割精度。

(4)在网络的每个卷积层后都添加了批量归一化(Batch Normalization, BN)和线性修正单元(Rectified Linear Unit, Relu),进一步提升了网络的泛化能力和非线性表达性能。

2 U-Net 网络的改进方法

2.1 残差网络模块

一般来说,网络越深,表达能力就越强。由于 U-Net 网络不够深,对特征的表达不够准确,神经网络层数的增加可以增强 U-Net 的特征学习能力,但随着网络的加深,梯度消失现象愈加明显,网络性能也随之退化,无法达到最好的训练效果。2015 年 He 等提出了一种 ResNet^[14]网络模型,通过在网络上叠加恒等映射层(Identity Mappings),解决了随着网络加深引起的收敛速度缓慢、梯度消失和网络退化等问题。残差模块表示为:

$$y_l = h(x_l) + F(x_l, W_l)$$
 (1)

$$x_{l+1} = f(y_l)$$
 (2)

其中,神经网络的输入和输出分别是 x_l, x_{l+1} ,在引入恒等映射 $h(x_l)$ 后,就可以直接将输入 $h(x_l)$ 作为初始输出结果,此时网络的学习目标仅为残差 $F(x_l, W_l)$,不再是学习一个完整的输出 x_{l+1} 。与传统的神经网络相比,残差神经网络有两条分路,主路用于学习残差,输入经恒等映射层直接输出,最后将两分支相加,得到最终的结果。

受 Resnet18 网络的启发,文中 U-Net 编码器中的每个特征学习子模块均由 Conv block 和 Identity block 组成,结构如图 1 所示。其中残差模块的主路都是由两个 3×3 卷积学习残差特征。Identity block 是 Resnet 中的标准块,其对应的输入和输出具有相同的维度。当输入与输出的维度不同时,Conv block 能够通过恒等映射分支上的卷积进行调整。相比原始结构,改进编码器的每个子模块均增加了两层特征学习卷积,提升了网络的表达能力,并通过残差连接的优化,简化

了编码器的学习过程,促进了梯度的传播,还能够缓解图像中液滴的细节信息在经过多层卷积处理后丢失的问题。




图 1 编码器特征提取模块

Fig. 1 Encoder feature extraction module

2.2 特征融合模块

通常网络每层提取的特征仅被学习一次,不同层次之间的信息无法关联,导致特征利用率不高,分割效果不佳。Densenet^[15]模型通过建立网络层之间的连接关系,使得网络每一层的输入是前面所有层特征输出的并集,如图 2 所示。这种密集连接机制充分加强了不同层之间的特征传递,实现了特征的高效复用,能够促进网络更好地捕获目标的细节信息,还能利用浅层复杂度低的特征减轻由输入信息和梯度信息在多层网络之间传递引起的梯度消失问题,有效抑制了过拟合,提升了模型性能。




图 2 Densenet 密集连接机制

Fig. 2 Densenet dense connection mechanism

受 Densenet 密集连接理念的启发,本文将 U-Net 解码器中的子模块用特征融合模块来代替,结构如图 3 所示。该模块包括跳跃连接和 3 次特征融合操作,3 次特征融合操作分别为编码器浅层特征与解码器相同维度的上采样特征以及子模块中两个卷积提取到的特征之间的融合,有效地缩短了编码器与解码器之间的语义鸿沟,促进了液滴特征的传递,减少了分割过程中的信息损失,能够使网络更准确、细化地定位液滴的区域位置和边界轮廓。经过密集连接操作后输入到每一层的图像维度较大,因此在模块的每个 3×3 卷积前都加入了一个 1×1 卷积,在模块与上采样之间也添加了一个 1×1 卷积。该操作既能降维,减少计算量,又可以将特征融合的过程变成可学习的过程。




图 3 解码器特征融合模块

Fig. 3 Decoder feature fusion module

2.3 网络结构

本文改进的 U-Net 网络结构如图 4 所示。该模型主要由编码器、解码器、分类器和跳跃连接 4 部分组成。




图 4 改进的 U-Net 网络

Fig. 4 Improved U-Net network

编码器部分包括一个 1×1 卷积层、残差学习模块和最大池化。将输入的三通道图像首先通过一个内核大小为 1×1、滤波器数量为 32 的卷积层,通过增加特征图数量和汇总特征,来避免从初始图像中丢失信息。编码器部分共有 5 个残差学习子模块,每个子模块中都包含 Conv block 和 Identity block,共 20 个 3×3 卷积用于提取图像的语义特征。最大池化通过下采样缩小特征图,扩大感受野,降低网络的冗余,进一步促进特征的学习能力。表 1 列出了编码器中卷积的参数设置。

表 1 编码器卷积参数设置

Table 1 Encoder convolution parameter setting

Layer	Filters	kernel_size	Strides
Input	1×1	32	1
Resblock1	3×3	64	1
Pool1	2×2	—	2
Resblock2	3×3	128	1
Pool2	2×2	—	2
Resblock3	3×3	256	1
Pool3	2×2	—	2
Resblock4	3×3	512	1
Pool4	2×2	—	2
Resblock5	3×3	1024	1

解码器部分主要包括反卷积、特征融合模块、跳跃连接和分类器。特征图每经过一次反卷积,其尺寸和分辨率都增大一倍,经过编码器的 4 次反卷积操作后,特征图就能够恢复到原来的大小和分辨率。跳跃连接将编码器的浅层特征通过特征融合模块与相同维度的解码器深层特征进行 3 次融合和学习。每次融合操作后,都连接一个内核大小为 1×1 的卷积层,其滤波器数量为模块中 3×3 卷积滤波器数量的一半,有效地减少了输入特征图的数量。加入 1×1 卷积这一降维操作既能减少计算量,又能将特征融合的过程变成可学习的过程。最后,使用由 1×1 的卷积和 softmax 激活函数组成的分类器进行逐像素分类,得到液滴分割图。表 2 列出了解码器中卷积的参数设置。

表 2 解码器卷积参数设置

Table 2 Decoder convolution parameter setting			
Layer	Filters	kernel_size	Strides
Upconv1	2×2	512	2
Denseblock1	1×1	256	1
	3×3	512	1
Upconv2	2×2	256	2
Denseblock2	1×1	128	1
	3×3	256	1
Upconv3	2×2	128	2
Denseblock3	1×1	64	1
	3×3	128	1
Upconv4	2×2	64	2
Denseblock4	1×1	32	1
	3×3	64	1
Softmax	1×1	2	1

此外,在网络的每个卷积层后都添加了批量归一化和线性修正单元,以进一步提升网络泛化能力和非线性表达性能。

3 实验

本实验的硬件采用 Windows10 操作系统和 Geforce GTX1080Ti GPU 进行训练。软件环境为 tensorflow2.0 深度学习框架和 python3.6 编程语言。使用 Adam 优化器更新模型参数,设置学习率为 0.0003, Batch_size 为 2, 训练 50 个 Epoch,并将交叉熵(Cross Entropy)作为模型训练的损失函数,其表达式为:

$$Loss = -\frac{1}{N} \sum_{i=1}^N (y_i \cdot \log(p_i) + (1 - y_i) \cdot \log(1 - p_i)) \quad (3)$$

图 5、图 6 分别给出了相同实验环境与参数下,原始 U-Net 模型和本文改进模型训练时的损失函数变化曲线。从图中可以看出,随着训练次数的增加,训练集和验证集损失函数均逐渐达到平稳的数值范围。对比图 5、图 6 可看出,本文算法的训练集损失函数下降到 0.04 以内仅需要 5 次迭代,下降到 0.02 以内仅需要 12 次迭代,验证集损失函数下降到 0.04 以内仅需要 6 次迭代,而 U-Net 模型的训练集损失函数下降到 0.04 以内需要 11 次迭代,下降到 0.02 以内需要 22 次迭代,验证集损失函数下降到 0.04 以内需要 16 次迭代。由此可知,本文算法通过增加残差模块解决了网络收敛速度慢的问题。稳定后本文算法的训练集损失函数为 0.0055,验证集损失函数为 0.0191;U-Net 网络的训练集损失函数为 0.0115,验证集损失函数为 0.0323。可以看出,本文改进的液滴分割模型可以从总体上提升学习能力和预测效果。




图 5 U-Net 损失值与迭代次数的关系

Fig. 5 Relationship between U-NET loss value and iteration number




图 6 本文算法损失值与迭代次数的关系

Fig. 6 Relationship between the presented algorithm loss value and iterations number

3.1 数据集

本文利用高清摄像头对多种不同形态、不同环境的液滴定态铺展视频进行拍摄,并将视频传入计算机进行逐帧提取,得到的图片尺寸为 600×800。在提取出的不同铺展形态的液滴图片中筛选出 300 张进行人工标注,并进行数据集增强,包括翻转、旋转固定的角度、亮度增加、亮度降低、轻度模糊和添加高斯噪声,数据集的增强不仅能够减少网络的过拟合现象,还能通过对训练图片进行变换来得到泛化能力更强的网络。扩充后的数据共有 3000 张,设置训练集和测试集的比例为 2:1。

3.2 评价指标

为了验证算法的可行性,本文使用 F1 分数(F1 score)和交并比(IOUS)对分割性能进行客观的评价,其定义为:

$$F1 = 2 \times \frac{PR}{P+R} \quad (4)$$

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

$$Recall = \frac{TP}{TP+FN} \quad (6)$$

$$IOU = \frac{TP}{TP+FP+FN} \quad (7)$$

真正(True Positive, TP)代表模型正确分割为液滴的像素点;真负(True Negative, TN)表示模型正确分割为背景的像素点;假正(False Positive, FP)表示模型将背景预测为液滴的像素点,即误报;假负(False Negative, FN)表示模型将液滴预测为背景的像素点,即漏报。

F1 分数综合考虑了精确率(Precision)和召回率(Recall)两个评价指标,选择一个阈值,让模型的精准度和全面性同时达到最高,取得平衡。交并比(IOUS)指实际分割区域与模型预测分割区域的交集和并集的比值,用于测量真实和预测之间的相关度,判断目标的捕获程度和精确程度。

4 结果

4.1 分割效果

图 7 给出了本文算法对液滴的分割效果,从图中可看出,该算法能够准确识别图像中的液滴,并精确定位其位置边界。对于不同形态、位置和拍摄环境的液滴也有着较强的鲁棒性。对于没有液滴的图像,如图 8 所示,随机选取不在训练集中的无液滴的图像进行预测,该算法也能够进行准确的判断。综上所述,本文算法在训练过程中准确且充分地学习到了液滴的特征。




图 7 液滴图像分割结果
Fig. 7 Droplet image segmentation results




图 8 无液滴图像分割结果
Fig. 8 Droplet-free image segmentation results

为验证改进算法的效果,采用 GrabCut^[16], SegNet^[17], U-Net 和本文算法分别验证从测试集中随机选取的 50 张液滴图片。液滴分割评价指标如表 3 所列,相比传统的 GrabCut 分割算法,本文算法在 F1 和 IOU 上都有较大的提升。相比 Segnet 和 U-Net 深度学习模型,本文算法在 F1 上分别提升了 2.08% 和 0.73%,在 IOU 上分别提升了 2.92% 和 1.41%。

表 3 各算法的分割效果对比

Table 3 Segmentation effect of each algorithm compared

	F1	IOU
GrabCut	0.885 7	0.813 1
SegNet	0.969 5	0.952 0
U-Net	0.983 0	0.967 1
本文算法	0.990 3	0.981 2

为了对分割效果进行定性分析,本文将不同算法得到的液滴分割图进行对比,如图 9、图 10 所示。液滴原图分别存在着对比度不强、亮度不均匀、水平面及液滴反光、固液界面不清晰等问题。从图中可看出,GrabCut 算法由于没有考虑像素块之间的关系和液滴的语义信息,因此导致分割效果不佳。SegNet 和 U-Net 模型虽然可以较完整地分割出图像中的液滴,但仍存在着一些缺陷。SegNet 由于没有考虑层次之间的特征融合,因此对边缘信息的处理效果较差;U-Net 由于网络不够深,对特征的表达不够准确,导致部分较大的液滴目标存在空洞,对于小液滴边界的分割细节和精度也有待提高。相比之下,本文算法表现更为优秀,能够完整地分割出液滴目标,并能有效地处理液滴的边缘细节,得到的液滴区域和轮廓更加准确。




图 9 各算法对大液滴图片的分割结果对比
Fig. 9 Comparison of segmentation results of large droplet images by different algorithms




图 10 各算法对小液滴图片的分割结果对比
Fig. 10 Comparison of segmentation results of small droplet images by different algorithms

4.2 各模块的分割效果

为了验证本文改进的算法中各模块的有效性,将单独添加了 BN 操作的 U-Net+BN 网络、舍弃了特征融合模块的 Res-Unet 网络和舍弃了残差模块的 Dense-Unet 网络分别进行训练和测试,以进一步验证改进 U-Net 网络中各模块的作用,得到的液滴分割评价指标结果如表 4 所列。从表中可看出,单独使用了 BN、残差模块和特征融合模块的 U-Net 网络的各项指标相比原始模型均有提升,表明模块均具备有效性。与以上 4 种网络相比,本文算法在综合性能上皆表现最优,由此可证明本文结构设计的合理性。

表 4 改进算法中各模块的分割效果对比

Table 4 Comparison of segmentation effect of each module in the improved algorithm

	F1	IOU
U-Net	0.983 0	0.967 1
U-Net+BN	0.983 7	0.967 5
Dense-Unet	0.985 9	0.972 6
Res-Unet	0.986 8	0.974 2
本文算法	0.990 3	0.981 2

各网络的分割效果对比如图 11 所示。由图可看出,单独使用了残差模块和特征融合模块的算法相比 U-Net 均有一定程度的提升,但是在边界及固-液-气 3 项交点的处理上仍存在偏差。相比之下,本文算法的分割结果与真实结果较为相近,在液滴轮廓的细节处理上表现优秀,边界定位准确,同时在较为劣质的液滴图像中还能表现出较强的鲁棒性。




图 11 改进算法中各模块对劣质液滴图片的分割结果对比
Fig. 11 Segmentation results of inferior droplet images compared by each module in the improved algorithm

结束语 本文针对液滴图片的实际特点和液滴分割过程中存在的目标不准确、轮廓不完整以及固-液-汽 3 项交点和边界细节效果不佳的问题,提出了一种改进的 U-Net 网络用于液滴分割。针对 U-Net 学习能力不足的问题,该网络融合了 Resnet18 结构,通过增加卷积层数和恒等映射操作,增强了特征的学习能力,促进了梯度的传播。针对网络对液滴细节处理的不足,引入了特征融合技术,将编码器浅层特征与解码器相同维度的图像特征进行了 3 次融合和降维操作,并增加了 1×1 卷积以及批量归一化操作来进一步促进网络性能。实验结果表明,本文改进的 U-Net 模型能够有效提高液滴识别的准确率,提升分割效果,在液滴自动分割和接触角测量领域具有一定的参考价值。

由于接触角测量工作需要具有高效的特性,在未来的工作中,我们将对液滴图片进行相应的预处理以获得更快的液滴识别速度,选择最优的轮廓拟合方式并将本文算法处理后的液滴图片进行轮廓拟合,将得到的接触角与实际手动测量的液滴接触角值进行对比,从而将这一液滴识别算法拓展到实际应用场景中。

参 考 文 献

[1] ZHANG P. Study on contact angle measurement method based on image analysis technology[D]. Shanghai:East China University of Science and Technology,2014.

[2] ZHAO K Y,TIAN H M,GUO D,et al. Influence of background light on high precision contact angle measurement[J]. Instrument Technology and Sensors,2019(5):100-103.

[3] ZHANG T,TIAN H M,RONG X Y,et al. Application of particle swarm optimization canny operator in high precision contact angle measurement[J]. Journal of Hebei University of Technology,2018,47(3):30-35.

[4] WANG X H,LI J J,YANG W,et al. Image processing and detection of contact angle[J]. Photoelectronic Technique,2011,31(1):14-19.

[5] ZHANG P,WAN Y Q,ZHOU Y L. A new boundary extraction algorithm and its application in contact angle measurement[J]. Journal of East China University of Science and Technology (Natural Science),2014,40(6):746-751.

[6] ZHAO K Y,TIAN H M,GUO D,et al. Automatic measurement method of contact angle based on feature point detection[J]. Journal of Electronic Measurement and Instrumentation,2018,

32(11):147-153.

[7] ZHOU L L,JIANG F. A review of image segmentation methods [J]. Computer Application Research,2017,34(7):1921-1928.

[8] LONG J,SHELHAMER E,DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2015,39(4):640-651.

[9] RONNEBERGER O,FISCHER P,BROX T. U-Net:Convolutional networks for biomedical image segmentation [C]// International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer International Publishing,2015:234-241.

[10] DONG Y,FENG H J,XU Z M,et al. Attention Res-Unet: An efficient shadow detection algorithm[J]. Journal of Zhejiang University (Engineering Science),2019,53(2):172-180,205.

[11] JING J,WANG Z,RÄTSCHE M,et al. Mobile-Unet:An efficient convolutional neural network for fabric defect detection[J]. Textile Research Journal,2020,66(5):1-17.

[12] WANG E K,CHEN C M,HASSAN M M,et al. A deep learning based medical image segmentation technique in internet-of-medical-things domain[J]. Future Generation Computer Systems,2020,108:135-144.

[13] XIAO X,LIAN S,LUO Z,et al. Weighted res-unet for high-quality retina vessel segmentation[C]// 2018 9th International Conference on Information Technology in Medicine and Education (ITME). IEEE Computer Society,2018.

[14] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition[C]// IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE Computer Society,2016:770-778.

[15] HUANG G,LIU Z,MAATEN L V D,et al. Densely connected convolutional networks[C]// IEEE Conference on Computer Vision and Pattern Recognition. 2017:2261-2269.

[16] ROTHER C. GrabCut: Interactive foreground extraction using iterated graph cuts[J]. Acm Trans Graph,2004,23(8):309-314.

[17] BADRINARAYANAN V,KENDALL A,CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation[C]// IEEE Transactions on Pattern Analysis and Machine Intelligence. 2017.



GAO Xin-yue, born in 1996, postgraduate. Her main research interests include deep learning and picture processing.



TIAN Han-min, born in 1975, Ph. D, professor. His main research interests include picture processing and contact angle measurement.