

引用格式: TIAN Huijuan, ZHAI Jiahao, LIU Jianxin, et al. A Low-quality Iris Image Segmentation Algorithm Based on SRN-UNet[J]. Acta Photonica Sinica, 2022, 51(2):0210006

田会娟, 翟佳豪, 柳建新, 等. 基于 SRN-UNet 的低质量虹膜分割算法[J]. 光子学报, 2022, 51(2):0210006

基于 SRN-UNet 的低质量虹膜分割算法

田会娟^{1,2}, 翟佳豪^{1,2}, 柳建新³, 刘嘉伟^{1,2}, 邓琳琳^{1,2}

(1 天津工业大学 电气与电子工程学院 天津市光电检测技术与系统重点实验室, 天津 300387)

(2 大功率半导体照明应用系统教育部工程研究中心, 天津 300387)

(3 天津成科传动机电技术股份有限公司, 300384)

摘 要: 针对低质量虹膜图像分割精度低问题, 提出一种基于 SRN-UNet (SEResNext-UNet) 的虹膜分割算法。在编码阶段增加 SE-ResNext 模块, 该模块在 RexNext 模块后级联 SENet (Squeeze-and-Excitation Network) 模块, 以聚焦目标特征, 在不增加网络参数的情况下提升分割精度和网络性能。在解码阶段的上采样层降低模型参数量, 以提升训练速度。为解决图像类别不均衡问题, 结合两种损失函数 Dice Loss 和 Focal Loss 训练 SRN-UNet 网络。基于 CASIA-Iris 数据集和自建的低质量虹膜图像数据集的实验结果表明, 与其它算法相比, 所提算法在视觉效果和客观评价指标上均有较好分割效果。与 U-Net 算法相比, 所提算法的平均交并比、F1 分数与精确率分别提升了 4.20%、2.27%、5.38%, 且运行速度高于 U-Net。

关键词: 图像分割; 虹膜图像; 低质量; U-Net; 深度学习

中图分类号: TP391.4

文献标识码: A

doi: 10.3788/gzxb20225102.0210006

0 引言

虹膜纹理以其独特稳定、非接触和防伪的特点在国防和安全领域发挥着重要作用^[1-3]。一个完整的虹膜识别系统通常包括: 1) 通过成像设备获得虹膜图像; 2) 通过虹膜分割算法定位虹膜区域; 3) 通过特征提取算法提取虹膜特征; 4) 将提取的虹膜特征用于虹膜识别。其中虹膜分割在虹膜识别系统中具有重要意义, 算法的准确性和鲁棒性直接影响后续的虹膜提取、验证和识别^[4]。理想条件下的虹膜图像清晰、无遮挡, 当前多数的虹膜分割算法可以准确地分割虹膜区域。然而, 在虹膜图像像素低、光照不均匀、睫毛或眼睑遮挡、镜面反射等非理想条件下, 设计鲁棒性强的虹膜分割算法来精确分割虹膜区域仍然是一项具有挑战性的任务。

近年来, 随着深度学习技术的发展, 特别是卷积神经网络 (Convolutional Neural Network, CNN)^[5] 在图像分类、分割、识别等方面的广泛应用, 研究人员开始尝试将深度学习用于图像分割。2015 年, LONG J 等^[6] 在 CNN 的基础上提出全卷积神经网络 (Fully Convolutional Network, FCN) 来进行语义级别的图像分割, 随后各种语义分割网络纷纷出现。当前经常使用且性能较好的语义分割网络有 U-Net^[7], SegNet^[8], PSPNet^[9] 以及 Deeplabv3^[10] 等, 其中 U-Net 网络被广泛用于医学图像分割领域。JALILIAN E 等^[11] 最早将深度学习方法应用在虹膜分割领域, 他们提出了三种基于 FCNs 的虹膜分割网络结构, 并将其命名为全卷积编解码网络 (FCEDNs), 实验结果表明 FCEDNs 优于传统算法。ZHOU W 等^[12] 对 U-Net 原网络进行改进, 提出了适用于异质虹膜分割的神经网络模型 PI-Unet, 在 CASIA-v4 和 UBIRIS.v2 虹膜数据库上的 Miou 分别达到 97.50% 和 95.95%。ZHANG W 等^[13] 将 U-Net 与空洞卷积结合, 提出 FD-Unet 用于虹膜分割, 在 CASIA-Iris-interval 和 UBIRIS.v2 上的 F1 score 分别达到了 97.36% 和 94.81%。YANG Y 等^[14] 提出了一种结合

基金项目: 国家自然科学基金 (No. 61504095), 天津市科技计划 (No. 18ZXCLGX00090)

第一作者: 田会娟 (1979—), 女, 副教授, 博士, 主要研究方向为光电检测和控制技术。Email: tianhjx@126.com

收稿日期: 2021-07-28; 录用日期: 2021-08-31

<http://www.photon.ac.cn>

FCN和扩张卷积分割虹膜的网络模型,并在CASIA-iris-interval-v4.0、UBIRIS.v2和IITD Delhi数据集上进行了训练和测试,准确率分别为98.6%、98.4%和95.7%。ARSALAN M等^[15]在SegNet-basic的基础上提出的IrisDenseNet,用5个密集块代替原编码器的VGG16,以更好的信息梯度流检测出准确的虹膜边界。

基于深度学习的虹膜分割算法在分割成像质量高、虹膜特征清晰、虹膜区域位于图像中间位置的高质量虹膜图像时均具有各自的优势,但在非限制条件下算法的性能会受到一定影响,尤其是在分割普通摄像头下采集到的图像像素低、模糊、尺度不一、睫毛遮挡、反射光斑等低质量虹膜图像时精度不高。针对上述问题,本文提出了一种基于SRN-UNet的低质量虹膜分割算法。该算法对U-Net的编码器模块进行了改进,编码器模块根据ResNet50^[16]进行设计,引入ResNext^[17]模块替代ResNet模块,并在该模块后级联SENet模块^[18],通过压缩、激励以及权重的重新分配,从特征通道相关性的角度出发构建网络模型,选择性地强调重要特征并抑制非重要特征,从特征通道之间的全局信息关系方面进一步提升虹膜分割的准确率。

1 算法原理

1.1 SRN-UNet框架

基于SRN-UNet虹膜分割算法模型如图1所示。本文所提SRN-UNet网络基于U-Net进行改进,主要由预处理、编码器、解码器和跳层拼接四部分构成^[19]。预处理可将输入图像的通道数加深为64。编码器包括Res-block模块和下采样层,每个Res-block模块分别由3、4、6、3个SE-ResNext模块串联构成。SE-ResNext模块由ResNext模块级联SENet模块组成,其中ResNext模块可在不增加网络参数的情况下提升网络性能;SENet模块通过压缩、激励以及权重的重新分配,从特征通道相关性的角度出发构建网络模型,对于低质量虹膜图像,该模块可在一定程度上激励有用的特征,抑制无用的特征,提升虹膜分割精度。在每一个Res-block模块后都添加一个大小为 2×2 ,步长为2的最大池化层进行下采样,目的是增大深层特征感受野,确保特征描述具有一定的全局性。解码器由卷积块和上采样层构成,和U-Net不同的是,本文去掉了解码部分的一个 3×3 卷积层,减少了计算量和参数量,简化了模型。上采样层是一个大小为 2×2 ,步长

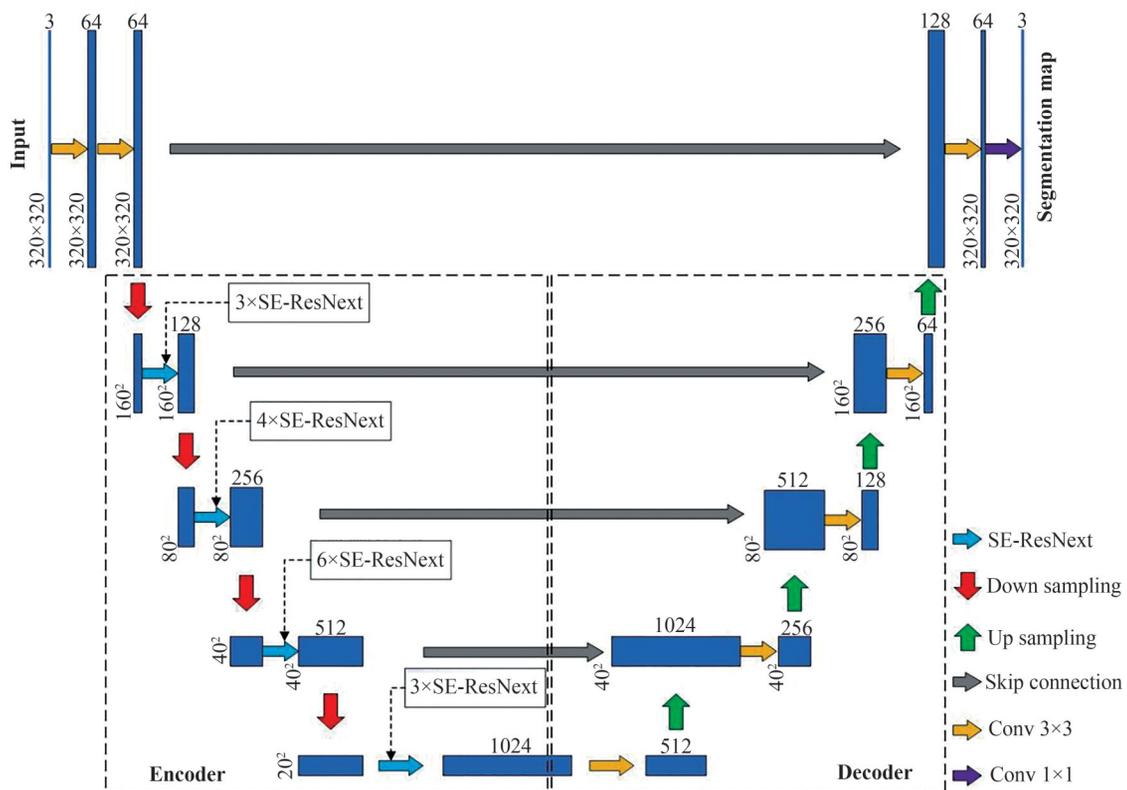


图1 SRN-UNet整体网络结构

Fig.1 Overall network structure of SRN-UNet

为2的反卷积层,上采样操作后会造成一部分虹膜信息损失,所以将上采样之后的特征图与对应的具有相同分辨率的编码器特征图进行跳层拼接。最后通过 1×1 的全连接层以及 Sigmoid 激活函数对虹膜与背景图像进行分类,输出虹膜分割结果。

1.2 SE-ResNext 模块

为了更准确地完成虹膜图像分割任务,本文提出了 ResNext 级联 SENet 的 SE-ResNext 网络结构作为 SRN-UNet 网络编码阶段的基本模块,图 2 为 SE-ResNext 模块的网络结构。首先通过模块中的分组卷积操作提取 x 的特征并进行合并,得到通道为 32 的特征图。其次通过采用全局平均池化函数来完成压缩操作,以获得 $1 \times 1 \times C$ 的实数列。然后对 $1 \times 1 \times C$ 的实数列进行两级全连接(Full Connection, FC),对通道重新加权校准,捕获通道之间的相互依赖性从而获得比例因子。最后把通过激活函数 Sigmoid 的输出作为一个缩放尺度乘到原输入的各个通道上,完成对特征的重新标定。

1.3 ResNext 模块

ResNext^[17]结构最早应用于图像分类领域,是在 ResNet 基础上进行的优化。与 ResNet 相比,ResNext 提出了分组卷积的策略,将残差学习由单路径卷积扩展成多路径分组卷积,多路径分组卷积遵循分割、转换、合并范式,输入数据会被分别送入数量为分支基数(Cardinality)的多路径中,各路径独立进行卷积计算,并将结果以通道为基准进行连接,其特点是网络结构简单、参数少、准确率高、便于移植。图 3 列出了 ResNet 和 ResNext 的基本单元,其中 Path 表示分组数。

ResNext 网络的具体计算公式如式(1)所示。其中 x 表示输入特征, $T_i(x)$ 可以为任意函数,在此处表示三个卷积层的堆叠, C 为网络输入宽度。

$$y = x + \sum_{i=1}^C T_i(x) \quad (1)$$

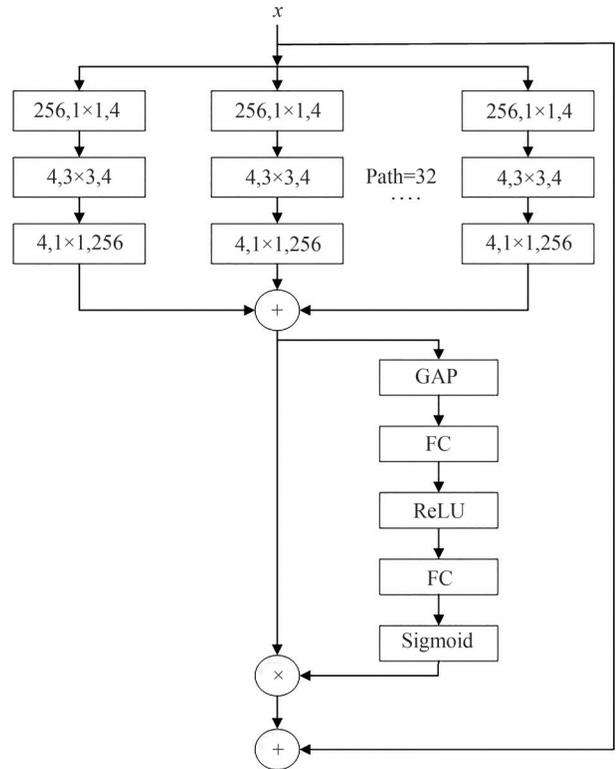


图 2 SE-ResNext 模块网络结构
Fig.2 Network structure of SE-ResNext module

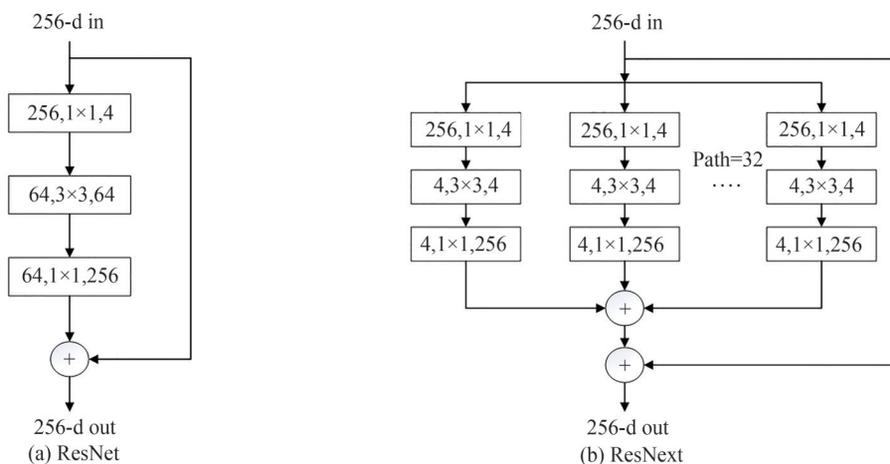


图 3 ResNet 和 ResNext 的基本单元
Fig.3 The basic unit of ResNet and ResNext

1.4 SENet 模块

在使用 ResNext 网络进行特征提取时,一些通道上的无效信息可能会被保留,影响虹膜分割准确率的提升。针对此问题,本文引入 SENet^[18],对于低质量虹膜图像,可以使模型聚焦于具有更多有效特征信息的通道,提升虹膜分割的精度。SENet 网络结构如图 4 所示。

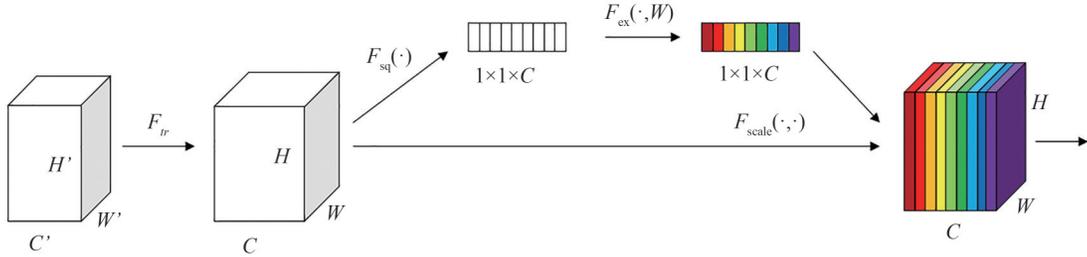


图 4 SENet 网络结构

Fig.4 Network structure of SENet

图 4 中,左侧为 $H' \times W' \times C'$ 的特征图,经过一系列卷积操作 F_{tr} 之后,得到 $H \times W \times C$ 大小的特征图。为得到输入特征图各通道的权重,SENet 将进行压缩(Squeeze)和激励(Excitation)两步操作。首先进行全局平均池化(Global Average Pooling,GAP),对每个特征通道在空间维度 $H \times W$ 上进行压缩(Squeeze),其计算公式为

$$\mathbf{Z} = F_{sq}(\mathbf{X}_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W \mathbf{X}_c(i, j) \quad (2)$$

式中, \mathbf{Z} 代表压缩操作生成的权重。

然后执行激励操作(Excitation),对 $1 \times 1 \times C$ 的输入通过两个全连接层结合 ReLU 函数建立各通道之间的相关性。为减少参数量、提高泛化能力,第一个全连接层将参数降维 r 倍,本文中 r 取 16,再经过一个全连接层得到原来的维度 C 。激励操作的计算过程可表示为

$$\mathbf{S}_c = F_{ex}(\mathbf{Z}, \mathbf{W}) = \sigma(g(\mathbf{Z}, \mathbf{W})) = \sigma(\mathbf{W}_2 \delta(\mathbf{W}_1 \mathbf{Z})) \quad (3)$$

式中, δ 表示 ReLU 函数, σ 表示 Sigmoid 函数, \mathbf{S}_c 表示生成的通道注意力权重。

最后,将权重 \mathbf{S}_c 加入到原始的特征通道中,其计算公式为

$$\bar{\mathbf{X}} = F_{scale}(\mathbf{X}_c, \mathbf{S}_c) = \mathbf{X}_c \otimes \mathbf{S}_c \quad (4)$$

式中, \otimes 代表逐元素相乘, $\bar{\mathbf{X}}$ 代表经过 SENet 处理输出的特征图。

2 实验结果及分析

2.1 数据集和数据增强

本文选用的数据集由两部分组成。第一部分为近红外虹膜图像,来源于中国科学院自动化所虹膜数据库(CASIA iris image database, CASIA-Iris)^[20]。分别从 CASIA-Iris 的子数据库 CASIA-IrisV2, CASIA-IrisV3 以及 CASIA-IrisV4 中各选取 900 张虹膜图像,每张虹膜图像的尺寸为 640 pixel \times 480 pixel。第二部分为低质量虹膜图像,通过笔记本电脑前置摄像头采集并裁剪出 5 名成员在复杂光照环境下不同姿态各 100 张低质量虹膜图像。共计选用虹膜图像 3 200 张,数据集中部分样本如图 5 所示。

将数据集按照 9:1 的比例划分为训练集和测试集,采用 labelme 软件对样本标签进行标定,部分数据集及标注如图 6 所示。

为了增强模型的泛化能力,减少过拟合现象,以不发生图像形变为前提对虹膜图像进行亮度增强、噪声扰动、随机缩放,将训练集扩充为原来的 4 倍。最后将输入网络训练前的虹膜图像统一裁剪成 320 pixel \times 320 pixel 的固定大小。



图5 数据集样本展示
Fig.5 Data set sample display

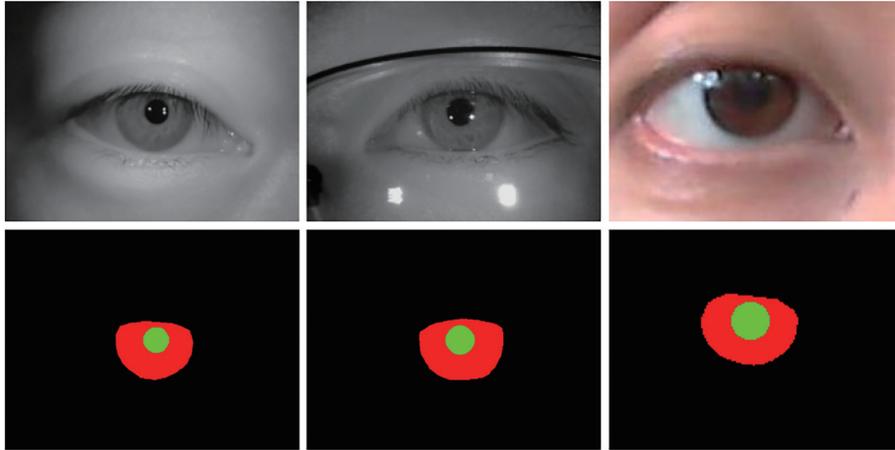


图6 部分数据集及对应标注
Fig.6 Part of the data set and corresponding annotations

2.2 训练细节

在图像分割任务中,常采用的损失函数为交叉熵损失函数(Cross Entropy Loss)。为了解决图像正负类别不均衡的问题,本文结合两种损失函数 Dice Loss^[21]和 Focal Loss^[22]训练 SRN-UNet 网络,其损失函数为

$$L = L_{\text{Dice}} + \lambda L_{\text{Focal}} = C - \sum_{c=0}^{C-1} \frac{\text{TP}_p(c)}{\text{TP}_p(c) + \alpha \text{FN}_p(c) + \beta \text{FP}_p(c)} - \lambda \frac{1}{N} \sum_{c=0}^{C-1} \sum_{n=1}^N g_n(c) (1 - p_n(c))^2 \log(p_n(c)) \quad (5)$$

式中, c 表示某个特定的类别, $\text{TP}_p(c)$ 、 $\text{FN}_p(c)$ 、 $\text{FP}_p(c)$ 分别为类别的真阳性率、假阴性率、假阳性率, $p_n(c)$ 是像素 n 为 c 类的预测概率; $g_n(c)$ 是像素 n 为 c 类的真实情况; C 为总类别数; N 为总像素数量; α 和 β 分别为假阴性和假阳性的惩罚权重,均设置为0.5; λ 为 Dice Loss 和 Focal Loss 之间的权重,设置为0.5。

本文实验环境基于深度学习框架 Keras 结合 Python 编程语言进行搭建。计算机配置如下:处理器为 Intel Core i7-6 800 K;GPU 为 NVIDIA GeForce GTX 1080Ti, 11 GB 内存;系统内存 32 GB。采用 Adam 算法优化损失函数,初始学习率设为 0.001,批量大小为 16,训练迭代次数为 100。训练时,若 10 次迭代后 loss 仍不下降,则停止训练,防止模型过拟合。

2.3 评价指标

为了评估本文所提算法的分割效果,从主观评价和客观评价两方面对实验结果进行了对比与分析。主观评价主要从视觉效果上比较图像的整体分割及微弱边缘的分割情况。客观评价采用图像分割中常用的平均交并比(Miou)、F1 分数(F1 score)、精确率(Precision)作为评价指标,计算公式分别为

$$Miou = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ij}}{\sum_{j=0}^k p_{ji} - p_{ii}} \quad (6)$$

$$F1 = \frac{2R \times P}{R + P} \quad (7)$$

$$P = \frac{TP}{TP + FP} \quad (8)$$

2.4 实验结果

2.4.1 不同损失函数对比分析

本文研究了损失函数对虹膜分割网络性能的影响。针对图像分割中常用的交叉熵损失函数与本文选用的Dice Loss + Focal Loss混合损失函数进行了对比实验,实验结果如表1所示。可以看出,本文选用的混合损失函数分割效果优于交叉熵损失函数。其原因在于虹膜在图像上面积占比较小,采用交叉熵损失函数训练网络,易受背景区域影响,难以学习虹膜特征,使训练效果降低。混合损失函数可在网络反向传播过程中对难以学习的样本进行稳定且有针对的优化,通过Focal Loss降低了易分类样本的权重,使模型更好地关注难分类样本,保留复杂的边界细节;通过Dice Loss解决像素类别不平衡问题,在一定程度上缓解Focal Loss带来的噪声,提升模型的分割精度。

表1 不同损失函数分割性能对比

Table 1 Comparison of segmentation performance of different loss functions

Loss	Miou/%	F1 score/%	Precision/%
Cross entropy loss	93.88	96.84	97.08
Dice+Focal	95.19	97.48	97.82

2.4.2 网络运行时间对比

本文统计了本文算法和U-Net算法在Batch尺寸分别为10、20、50时的网络运行时间,实验结果如表2所示。可以看出,本文算法的运行时间低于U-Net算法,当Batch达到50次时,本文算法运行时间比U-Net缩短了30.95%,有效提高了网络的运行速度。

表2 网络运行所需时间(s)

Table 2 Time required for network operation (s)

Algorithm	Batch=10	Batch=20	Batch=50
U-Net	0.909 4	1.749 3	4.414 7
Ours	0.621 0	1.237 4	3.048 3

2.4.3 不同算法性能比较

不同算法的分割结果如图7和图8所示,图7为不同算法在测试集中的近红外虹膜图像上的分割结果,图8为不同算法在测试集中的低质量虹膜图像上的分割结果。其中第1列为虹膜图像,第2列为虹膜图像标签,第3列至第7列分别为U-Net算法、SegNet算法、PSPNet算法、Deeplabv3算法以及本文所提算法的分割结果。

实验结果显示,由于近红外虹膜图像成像质量高、虹膜轮廓明显,各种算法均取得较好的分割结果,对于数据集中的低质量虹膜图像,U-Net、SegNet、PSPNet分割效果较差,Deeplabv3算法出现了不同程度的过分割现象,且边界分割较粗糙,相比之下,本文算法的虹膜分割内外边界更加平滑、分割结果更接近于真实标签。

尽管主观评价简单直接,但其容易受主观因素影响,因此仍需对分割结果进行定量评价,表3展示了不同虹膜分割算法的定量评价结果,可以看出SRN-UNet在三项评价指标上的表现均优于其它算法,其在测试集的平均交并比达到了95.19%,F1分数达到了97.48%,精确率达到了97.82%,与U-Net原始网络相比分别提高了4.20%、2.27%、5.38%。综上所述,本文提出的SRN-UNet网络在虹膜分割性能方面有很大的提升,且更加适用于低质量虹膜图像的分割。

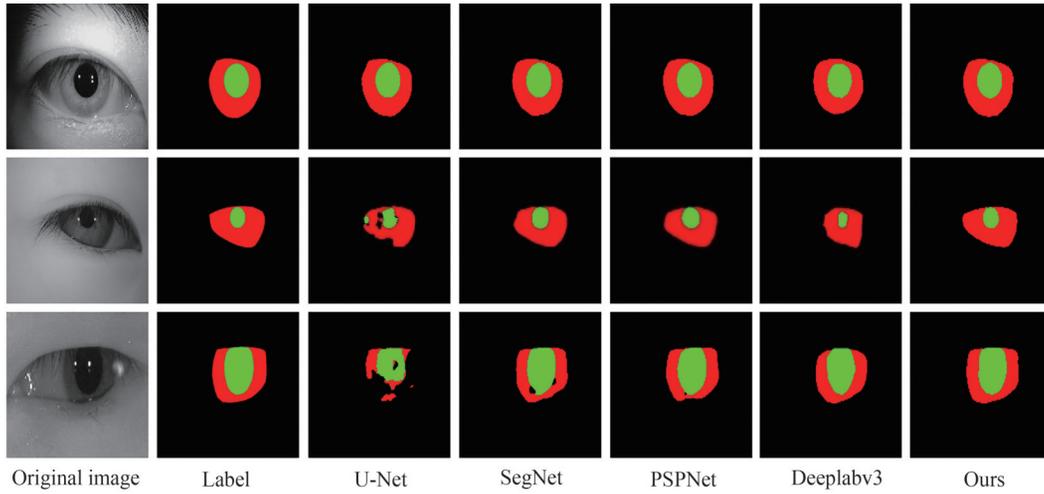


图7 不同算法在近红外虹膜图像的预测结果

Fig.7 The prediction results of different algorithms for near-infrared iris images

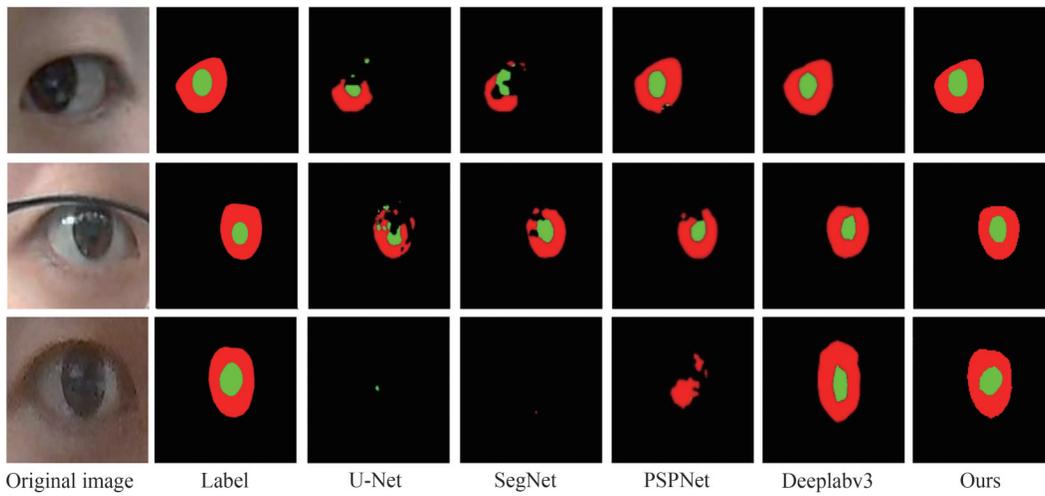


图8 不同算法在低质量虹膜图像上的预测结果

Fig.8 The prediction results of different algorithms for low-quality iris images

表3 不同虹膜分割算法结果对比

Table 3 Comparison of different iris segmentation algorithms

Algorithm	Miou/%	F1 score/%	Precision/%
U-Net	90.99	95.21	92.44
SegNet	91.18	95.32	92.15
PSPNet	92.28	95.97	94.12
Deeplabv3	92.31	96.00	95.73
Ours	95.19	97.48	97.82

2.4.4 各模块对整体模型的影响

为了验证各个模块对整体模型的影响,对U-Net网络、增加 ResNext 模块的 U-Net 网络、增加 SENet 模块的 U-Net 网络以及 SRN-UNet 网络进行对比实验,实验结果如表 4 所示。U-Net 作为原始网络,其平均交并比为 91.02%,F1 分数为 95.20%,精确率为 92.51%;分别增加 ResNext 模块和 SENet 模块的 U-Net 网络的 3 项评价指标均有不同程度提高;当聚合各个模块后,其平均交并比为 95.19%,F1 分数为 97.48%,精确率为 97.82%,相比于 U-Net 原始网络,各项指标分别提升了 4.17%、2.28%、5.31%。

表4 各个模块对整体模型的影响
Table 4 Influence of each module on whole model

U-Net	ResNext-UNet	SENet-UNet	Miou/%	F1 score/%	Precision/%
+			91.02	95.20	92.51
+	+		91.89	95.47	93.18
+		+	92.01	95.30	93.27
+	+	+	95.19	97.48	97.82

3 结论

虹膜分割是虹膜识别系统中一个关键部分,虹膜分割是否准确将直接影响整个虹膜识别系统的性能。为了提高低质量虹膜图像的分割精度,本文提出了一种基于SRN-UNet的虹膜分割算法。该算法采用ResNext级联SENet的SE-ResNext作为编码器的基础模块,对低质量虹膜图像具有更强的特征提取能力。同时对解码器进行了修改,降低了模型的参数量,更加适合模型训练。实验结果表明,所提算法的3项评价指标均优于其它4类对比算法,其中平均交并比达到了95.19%,F1分数达到了97.48%,精确率达到了97.82%,相比于U-Net算法分别提升了4.20%、2.27%、5.38%。所提算法对低质量虹膜图像具有更高的分割精度,与传统的U-Net网络相比整体性能较优,分割结果可观,且运行速度高于U-Net。

参考文献

- [1] LI Peihua, WU Guolong, MA Hongwei. Iris recognition via non-local region association and probability modeling[J]. Chinese Journal of Electronics, 2014, 42(12): 2379-2385.
李培华, 吴国龙, 马宏伟. 基于非局部区域关联和概率建模的虹膜识别方法[J]. 电子学报, 2014, 42(12): 2379-2385.
- [2] YUAN Weiqi, FENG Qi, BAI Xiaoguang. Noise detection method of iris by using the 2D-gabor filter[J]. Acta Photonica Sinica, 2010, 39(2): 369-374.
苑玮琦, 冯琪, 白晓光. 基于2D-Gabor滤波器的虹膜噪声检测方法[J]. 光子学报, 2010, 39(2): 369-374.
- [3] CHEN Rui, SUN Jingyu, LIN Xirong, et al. An algorithm for fake irises detection using multi-spectral images[J]. Chinese Journal of Electronics, 2011, 39(3): 710-713.
陈瑞, 孙静宇, 林喜荣, 等. 利用多光谱图像的伪造虹膜检测算法[J]. 电子学报, 2011, 39(3): 710-713.
- [4] CHEN Y, WANG W, ZENG Z, et al. An adaptive CNNs technology for robust iris segmentation[J]. IEEE Access, 2019, 7(99): 64517-64532.
- [5] RAZAVIAN A S, AZIZPOUR H, SULLIVAN J, et al. CNN features off-the-shelf: an astounding baseline for recognition[C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2014: 512-519.
- [6] 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.
- [7] RONNEBERGER O, FISCHER P, BROX T, et al. U-Net: convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing & Computer-Assisted Intervention. Springer International Publishing, 2015, 9351: 234-241.
- [8] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.
- [9] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]. IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2017: 6230-6239.
- [10] CHEN L C, PAPANDREOU G, SCHROFF F, et al. Rethinking atrous convolution for semantic image segmentation[J]. ArXiv Preprint, 2017, arXiv: 1706.05587.
- [11] JALILIAN E, UHL A. Iris segmentation using fully convolutional encoder - decoder networks[M]. In Deep Learning for Biometrics; Springer: Berlin, Germany, 2017: 133-155.
- [12] ZHOU Ruiye, SHEN Wenzhong. PI-Unet: Research on precise iris segmentation neural network model for heterogeneous iris[J]. Computer Engineering and Applications, 2021, 57(15): 223-229.
周锐烨, 沈文忠. PI-Unet: 异质虹膜精确分割神经网络模型的研究[J]. 计算机工程与应用, 2021, 57(15): 223-229.
- [13] ZHANG W, LU X, GU Y, et al. A robust iris segmentation scheme based on improved U-Net[J]. IEEE Access, 2019, 7(99): 85082-85089.
- [14] YANG Y, SHEN P, CHI C. A Robust Iris segmentation using fully convolutional network with dilated convolutions[C]. 2018 IEEE International Symposium on Multimedia(ISM), IEEE, 2018: 9-16.
- [15] ARSALAN M, NAQVI R A, DONG S K, et al. IrisDenseNet: robust iris segmentation using densely connected fully convolutional networks in the images by visible light and near-infrared light camera sensors[J]. Sensors, 2018, 18(5): 1-30.

- [16] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [17] XIE S, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks[C]. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition, Piscataway: IEEE, 2017: 5987-5995.
- [18] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [19] HUANG Hong, LÜ Rongfei, TAO Junli, et al. Segmentation of lung nodules in ct images using improved U-Net++ [J]. Acta Photonica Sinica, 2021, 50(2): 0210001.
黄鸿, 吕容飞, 陶俊利, 等. 基于改进U-Net++的CT影像肺结节分割算法[J]. 光子学报, 2021, 50(2): 0210001.
- [20] Institute of Automation, Chinese Academy of Sciences. CASIA Iris Image Database [DB/OL]. [2019-07-16]. <http://biometrics.idealtest.org/>.
- [21] MILLETARI F, NAVAB N, AHMADI S A. V-Net: fully convolutional neural networks for volumetric medical image segmentation[C]. 2016 Fourth International Conference on 3D Vision (3DV), 2016: 565-571.
- [22] 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.

A Low-quality Iris Image Segmentation Algorithm Based on SRN-UNet

TIAN Huijuan^{1,2}, ZHAI Jiahao^{1,2}, LIU Jianxin³, LIU Jiawei^{1,2}, DENG Linlin^{1,2}

(1 Tianjin Key Laboratory of Optoelectronic Detection Technology and System, School of Electrical and Electronics Engineering, Tiangong University, Tianjin 300387, China)

(2 Engineering Research Center of Ministry of Education on High Power Solid State Lighting Application System, Tianjin 300387, China)

(3 Tianjin Chengke Transmission Electromechanical Technology Co., Ltd., Tianjin 300384, China)

Abstract: In recent years, iris recognition has been widely used in various fields. Iris segmentation is the most critical step in the iris recognition process. The accuracy of the iris segmentation algorithm directly affects the performance of the entire iris recognition system. In this study, an iris image segmentation algorithm SRN-UNet (SeResNext-UNet) is proposed to solve the problem of low segmentation accuracy for segmenting low-quality iris images. In the coding stage, the SE-ResNext module is added, which is cascaded with the SENet (Squeeze-and-Excitation Network) module after the ResNext module. The ResNext module can improve the network performance without increasing the network parameters; the SENet module builds a network model from the perspective of feature channel correlation through squeeze, excitation, and weight redistribution. For low-quality iris images, the SENet uses global information to selectively emphasize informative features and suppress less useful ones, and improve the accuracy of iris segmentation. In the up-sampling layer of the decoding stage, the amount of model parameters is reduced to increase the training speed. In order to solve the problem of image category imbalance, the SRN-UNet is trained by combining the Focal loss function and the Dice loss function. Among them, the Focal loss function can reduce the weight of easy-to-classify samples, make the model pay more attention to the training of difficult samples, and guide the network to retain complex boundary details; the Dice loss function can solve the problem of pixel category imbalance and alleviate the noise caused by the Focal loss function. Experimental results based on CASIA-Iris dataset and self-built low-quality iris image dataset show that compared with other algorithms, the proposed algorithm has better segmentation effects in terms of visual effects and objective evaluation indicators. Among them, the Mean Intersection Over Union of the proposed algorithm reached 95.19%, the F1 score reached 97.48%, and the Precision reached 97.82%. Compared with U-Net, the Mean Intersection Over Union, F1 score and Precision of proposed algorithm have increased by 4.20%, 2.27%, and 5.38% respectively, and the algorithm is faster than U-Net.

Key words: Image segmentation; Iris image; Low-quality; U-Net; Deep learning

OCIS Codes: 100.3008; 100.4996; 110.2970