

DOI:10.16136/j.joel.2022.11.0888

基于ARD-PSPNet网络下的水下鱼类图像分割算法研究

岳有军^{1*}, 耿连欣¹, 赵 辉^{1,2}, 王红君¹

(1. 天津理工大学 电气电子工程学院 天津市复杂系统控制理论与应用重点实验室,天津 300384; 2. 天津农学院 工程技术学院,天津 300392)

摘要:水下鱼类图像因受到光线散射和吸收、水体杂质等因素影响,导致水下鱼类图像质量较低,本文通过改进自动彩色均衡(automatic color equalization, ACE)算法进行水下鱼类图像增强,有效改善图像质量,并为后续的水下图像分割打下良好的基础。针对水下鱼类图像分割效果差、实时性低等问题,本文提出ARD-PSPNet网络模型,使用ResNet101网络模型作为特征提取网络,利用分割性能良好的PSPNet(pyramid scene parsing network)网络模型作为基础图像分割模型,通过引入深度可分离卷积来降低计算量,通过R-MCN网络结构,充分利用浅层网络特征层丰富的位置信息和完整性,改进损失函数使得分割位置更加准确,在Fish4knowledge数据集上进行实验,结果表明:新模型与原模型相比,在平均交并比(mean intersection over union, MIOU)上提高了2.8个百分点,在平均像素准确率(mean pixel accuracy, MPA)上提高了约2个百分点。

关键词:图像增强; PSPNet网络模型; R-MCN模块; 深度可分离卷积; 损失函数

中图分类号:TP391.41;TP183 文献标识码:A 文章编号:1005-0086(2022)11-1173-10

Research on segmentation algorithm of underwater fish image based on ARD-PSPNet network

YUE Youjun^{1*}, GENG Lianxin¹, ZHAO Hui^{1,2}, WANG Hongjun¹

(1. Tianjin Key Laboratory of Complex System Control Theory and Application/School of Electrical and Electronic Engineering, Tianjin University of Technology, Tianjin 300384, China; 2. Institute of Engineering Technology, Tianjin Agricultural University, Tianjin 300392, China)

Abstract: Underwater fish images are affected by light scattering and absorption, water impurities and other factors, resulting in low underwater fish image quality. This article uses improved automatic color equalization (ACE) algorithm to enhance underwater fish images to effectively improve image quality, and lay a good foundation for the subsequent underwater image segmentation. Aiming at the problems of poor segmentation effect and low real-time performance of underwater fish images, this paper proposes the ARD-PSPNet network model, using the ResNet101 network model as the feature extraction network, and using the pyramid scene parsing network (PSPNet) network model with good segmentation performance as the basic image segmentation model. The segmentation model reduces the amount of calculation by introducing deep separable convolutions. Through the R-MCN network structure, it makes full use of the rich location information and completeness of the shallow network feature layer, and improves the loss function to make the segmentation position more accurate. In experiments and completed on the Fish4knowledge data set. Experimental results show that the new model has an increase of 2.8% in mean intersection over union (MIOU) and about 2% in mean pixel accuracy (MPA) compared with the original model.

Key words: image enhancement; PSPNet network model; R-MCN module; depth separable convolution; loss function

* E-mail:bakeryyuej@163.com

收稿日期:2022-02-28 修订日期:2022-03-29

基金项目:天津市科技支撑计划项目(18YFZCN1120,19YFZCSN0360)资助项目

1 引言

在鱼类目标识别的研究工作中,从获取的影像中定位目标,并将其从背景中提取出来,即目标分割是实现鱼类目标识别的前提,后续的目标识别效果很大程度上取决于目标分割的效果。然而,由于水中有诸多因素干扰,导致所得到的图像出现图像模糊、对比度低、亮度不均等问题,使得对目标的准确分割变得十分困难。

水下图像增强方法可以在很大程度上解决图像不清晰、对比度不高、亮度不均等问题,对水下图像识别能够带来很多便捷。Retinex^[1]图像增强方法的基本原理是颜色的平衡性,颜色随着反射两次的变化而变化^[2]。JOSHI 等^[3]利用上述方法对于水下图像进行了一定的增强,然而效果比较一般。FU 等^[4]首先利用颜色空间的变化,然后借 LAB 中的 L 分量通过 Retinex 方法将图像的反射和光照分量进行分离。这种方法具有很好的增强效果和色彩校正结果,缺点是计算较为复杂。ALEX 等^[5]再次利用颜色空间的变化方法,把 YCbCr 颜色空间的 Y 和 Cr 通道通过 Retinex 分解,再进行卷积操作,效果有了非常大的提升。刘柯等^[6]在 MSRCR 的方法的基础上,加入了滤波方法,在不损失边界等信息的同时,提高了对比度。在深度学习领域中,李庆忠等^[7]将 Cycle GAN 的损失函数做出了改进,不仅保证图像细节信息不缺失,而且还减少了由于对比度缺失带来的影响。UPLAVIKAR 等^[8]以域对抗学习为理论依据研究了一种新型水下图像增强方法,充分利用图像中的关键信息。虽然此方法对于不同类型的图像增强效果非常好,然而需要大量的数据来支撑。

针对水下目标图像的分割问题,张铭钧等^[9]通过改变灰度化权值来进行水下图像分割,然而此方法鲁棒性较差。郭传鑫等^[10]提出了一种基于 GrabCut 算法和显著图模型的水下海参图像分割方法,然而该方法只能用于背景较为简单的图像分割中。徐玉如等^[11]提出了一种基于模糊划分嫡和 PSO 的水下图像分割方法,然而在图像背景和目标像素差别较小时,该算法分割效果不佳。席志红等^[12]提出了一种基于变分水平集理论的水下图像分割方法,然而该方法在实际应用时比较困难。深度学习图像分割算法包括 FCN^[13]、PSPNet (pyramid scene parsing network)^[14]、Seg-

Net^[15]和 DeepLab 系列^[16],随着时间的推移也在不断进步,这些方法在水下图像分割领域有着广泛应用。

目前,虽然水下图像增强算法已经应用到了水下图像处理和深度学习的各个领域,但仍然存在着一些不足。在图像增强领域中,对像素较低的水下图像增强效果不佳,增强算法的复杂度较高导致增强方法在图像分割效率偏低。在深度学习领域中,在水下较为复杂的环境下,传统的深度学习方法对图像的分割精确度较低、实时性较差;在分割效果上,对图像边界的分割较为模糊,在具体任务中对不同类别、数目的训练样本差别较大。

针对水下图像增强中存在增强效果不佳和复杂度较高的问题,提出了改进型自动彩色均衡 (automatic color equalization, ACE) 图像增强算法,最终加快了图像增强的速度,提升了图像增强的效果;针对图像分割中存在精确度较低、实时性较差和对图像位置分割不准确的问题,提出了 ARD-PSPNet 模型,最终结果表明,所提模型能够有效提高图像分割的精度和实时性,使图像分割的位置更加准确。

2 改进 ACE 算法

由于水下鱼类图像受到光线折射、图像背景以及水体杂质等影响,导致水下鱼类图像质量较差,因此提出一种改进型 ACE 图像增强算法,其流程图如图 1 所示。在 ACE 算法的基础上,减小滤波窗口,将原图像不断进行 4 分解,直到不能被 4 分解时停止分解,再将增强后的信息按原尺寸合成得到与原来图像大小相等的图像。在增强细节信息的同时,减少全局信息的缺失。具体过程如下。

2.1.1 减小滤波窗口

输入图像 I ,该步是对单通道图像 I 中所有点 p 的区域自适应滤波,计算式如下^[17]:

$$R_c(p) = \sum_{j \in \text{Subset}, j \neq p} \frac{S_a(I_c(p) - I_c(j))}{d(p, j)}, \quad (1)$$

式中: $I_c(p) - I_c(j)$ 为 p, j 两个像素点间的灰度差值; $d(p, j)$ 表示距离度量函数,使用两点间的欧氏距离,作用上控制点 j 对 p 的影响权重; $S_a(g)$ 是亮度表现函数,本文算法选择经典 Saturation 函数。

不同亮度函数和参数的选择控制了对比度增强的程度,如图 2 所示经典的 Saturation 函数取越大的斜率,结果的增强效果越好,如下式^[18]:

$$S_a(x) = \begin{cases} 1, & x < -\alpha \\ x/\alpha, & -\alpha < x < \alpha \\ 1, & x > \alpha \end{cases} \quad (2)$$

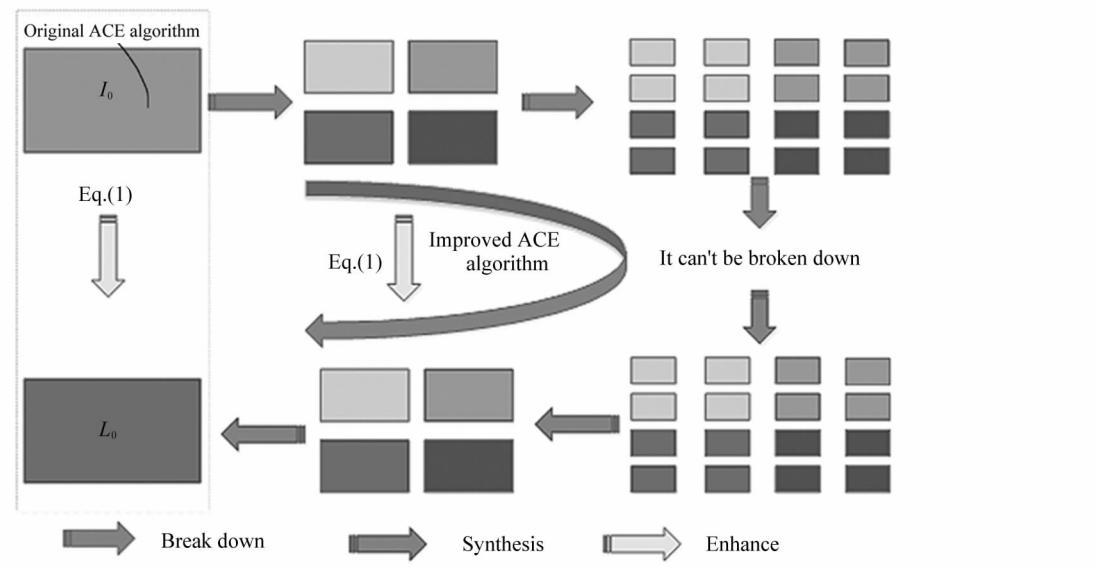


图 1 改进 ACE 算法过程

Fig. 1 Process of improved ACE algorithm

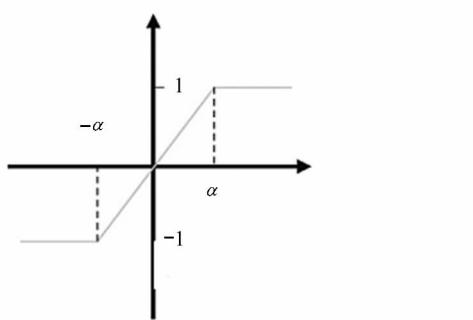


图 2 Saturation 函数

Fig. 2 Saturation function

对图像进行自适应滤波, 滤波窗口越大计算量越高, 如果对大小为 M 的图像进行滤波窗口大小为 M 的全局滤波, 那么计算量就会大于 M 的平方, 如果图像的大小是 $M/4$ 尺寸, 那么计算量就可以减少 16 倍, 所以减小滤波窗口为原来的 $1/4$, 图像的尺寸和图像滤波窗口的尺寸越小, 计算量越低。

2.1.2 分解逐步增强

为了解决图像增强存在效果差的问题, 本文对图像进行分解并且逐步进行图像增强。假设对原图像 I_0 进行增强后得到的结果为 L_0 , 对原图像 I_0 分为 4 部分再将每个部分通过式(1)算法增强之后再合成得到的图像是非常接近的, 全局背景信息相同, 细节信息得到优化的同时, 降低的计算量。

通过多尺度金字塔的思想, 层层递进增强特征信息, 将图像不断分解后再合成, 通过较小的滤波窗口处理图像既可以降低计算量, 又能得到更多的细

节信息。将距离像素点远的区域进行增强后得到的结果图作为 I_0 的全局背景信息。这样就可以看出, L_0 和 I_0 的全局背景信息相同, 通过降采样获得更多细节信息以及通过上采样获得全局信息。对图像分解降采样, 直到图像的行列值小于 4 时停止分解, 再将分解后的图像合成得到增强后的图像。

3 ARD-PSPNet 网络模型

3.1 R-MCN

为了充分利用浅层网络特征层丰富的位置信息, 引入 R-MCN^[19] 模块, 如图 3 所示, 该模块通过 7×7 和 5×5 两种大核卷积增大训练的感受野, 能够充分联系上下文信息; 并且把两个核卷积分解为 1×7 、 7×1 和 1×5 、 5×1 的卷积核, 目的是降低模块的计算量。

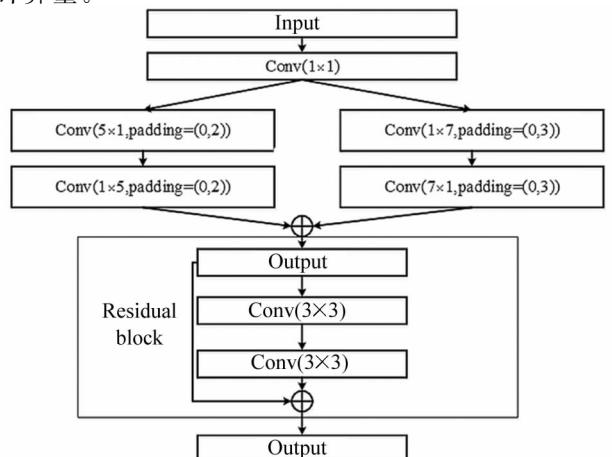


图 3 R-MCN 模块

Fig. 3 R-MCN module

3.2 深度可分离卷积

为了降低计算量,在基础模型中将标准卷积替换为深度可分离卷积^[20]。如图4所示,输入特征先将每一个通道进行 3×3 卷积,让他们的通道分离。然后进行拼接操作,得到的特征进行 1×1 卷积,得到最终的特征。深度可分离卷积与标准卷积相比,减少了训练网络的参数。利用该模块的优点,在不影响分割精度的情况下,减少网络训练的时间。

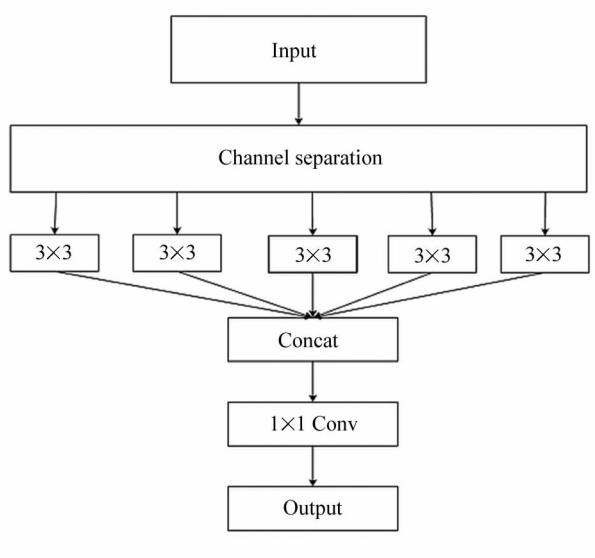


图4 深度可分离卷积结构

Fig. 4 Depth separable convolution structure

3.3 ARD-PSPNet 模型

以上提到的PSPNet模型、R-MCN模块、深度可分离卷积模块这3种模型在处理图像分割的不同方面有着良好的效果,但是单一网络模型不能够解决上述所有问题,因此本文融合了上述3种模型的优势,提出一种新模型ARD-PSPNet,可以有效解决以上问题。如图5所示,在ARD-PSPNet模型中,用深度可分离卷积代替基础网络中的普通卷积,并将R-MCN模块嵌入PSP模块中,可以把浅层特征网络提取的信息和深层特征网络提取的信息全部拼接在一起,使得捕获图像上下文信息更加全面,分割精度更高,并且可以使得分割边界更加清晰,使得特征信息能够更加完整地体现出来。

在ARD-PSPNet网络结构中,对于输入的水下鱼类图像,首先通过改进后的ACE算法进行图像增强,对增强后的图像通过ResNet101主干网络进行特征提取,得到全局特征信息,然后对提取的特征进行不同程度的池化操作,通过PSPNet网络作为水下鱼类图像分割网络,在金字塔池化模块中得到4个不同尺寸(1×1 、 2×2 、 3×3 、 6×6)的特征信息,对于4个不同尺寸的特征信息分别进行可分离卷积操作,将每个通道进行卷积,然后将他们的通道分离,再通过 1×1 大小的卷积拼接,从而降低了参数量以及计算量,然后把得到的特征信息通过R-MCN模块,利用R-MCN模块中的大卷积核充分提取图像浅层网

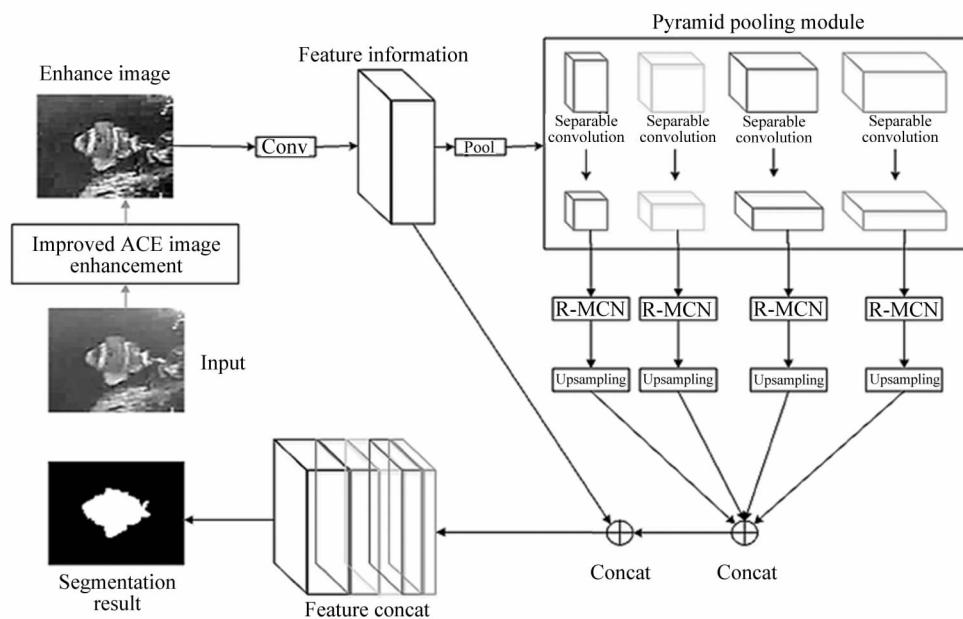


图5 ARD-PSPNet 网络结构

Fig. 5 ARD-PSPNet network structure

络的细节信息,然后将提取的特征分别进行上采样,再和原始特征映射通过双线性插值,将浅层特征网络和深层特征网络提取的信息有效地融合在一起,使得图像分割的结果精度更高,最后将不同尺寸的特征图拼接得到最后的全局特征,即图像分割的结果。

3.4 损失函数改进

水下图像分割存在分割位置不准确的问题,为了解决上述问题,将 BCE 损失函数与 Dice 损失函数相结合,得到结合后的损失函数,再将其进行模型优化。

1) BCE 损失函数

假设有 N 个 batch,每个 batch 预测 n 个标签,BCE 损失函数为:

$$L_{\text{BCE}} = \{l_1, \dots, l_N\}, \quad (3)$$

$$l_n = -y_n \cdot \log(x_n) - (1 - y_n) \cdot \log(1 - x_n), \quad (4)$$

式中, x_n 和 y_n 表示的是 Predict mask 和 Ground True。

2) Dice 损失函数

Dice 系数是一种集合相似度度量函数,通常用于计算两个样本的相似度,Dice 损失函数用 1 减去 Dice 系数,这样可以减少环境因素的影响,更加有效地提取图像位置信息,Dice 损失函数式为:

$$L_{\text{Dice}} = 1 - \frac{2 |x_n \cap y_n|}{|x_n| + |y_n|}, \quad (5)$$

式中, $|x_n \cap y_n|$ 表示集合 x_n 和 y_n 的交集, x_n 和 y_n 表示的是 Predict mask 和 Ground True。

3) 联合损失

将上述两种损失函数融合,得到的联合损失函数定义为:

$$L = L_{\text{BCE}} + L_{\text{Dice}}. \quad (6)$$

4 实验仿真

4.1 数据准备

通过 Fish4knowledge 鱼类开源数据库作为鱼类图像,数据库中存在 23 种水下鱼种类,共有 27 370 张鱼类图像,通过此数据集进行水下鱼类图像增强及图像分割实验仿真。

4.2 图像增强实验

利用峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似性(structural similarity, SSIM)作为评价图像增强的性能指标,PSNR 越大,说明增强的效果越好,PSNR 由均方差误差(mean square error, MSE)导出,MSE 定义为:

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} I(i, j) - k(i, j)^2. \quad (7)$$

PSNR 计算式为:

$$PSNR = 10 \cdot \lg \frac{MAX_l^2}{MSE}, \quad (8)$$

式中, MAX_l 为最大像素, m, n 是图像行列值。

SSIM 计算式为:

$$SSIM(x, y) = [l(x, y)]^\alpha [c(x, y)]^\beta [s(x, y)]^\gamma, \quad (9)$$

式中, $\alpha > 0, \beta > 0$ 和 $\gamma > 0$

$$l(x, y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1}, \quad (10)$$

$$c(x, y) = \frac{2\sigma_{xy} + c_2}{\sigma_x^2 + \sigma_y^2 + c_2}, \quad (11)$$

$$s(x, y) = \frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3}, \quad (12)$$

式中, $l(x, y)$ 是亮度对比, $c(x, y)$ 是对比度对比, $s(x, y)$ 是结构对比, μ_x 和 μ_y 分别代表 x 和 y 的平均值, σ_x 和 σ_y 分别代表 x 和 y 的标准差, σ_{xy} 代表 x 和 y 的协方差, c_1, c_2, c_3 分别为常数。

如图 6 所示,以 5 种鱼为样本,图中,(a)表示通过 MSRCR^[21] 图像增强算法增强后的效果,(b)表示通过 ACE 算法增强后的效果,(c)表示通过改进 ACE 算法增强后的效果。

通过图 6 可以看出,使用改进 ACE 算法进行图像增强后的效果明显优于使用 MSRCR 和 ACE 算法。对比的 PSNR 值以及柱状图分别如表 1 和图 7 所示,SSIM 值以及柱状图如表 2 和图 8 所示。

表 1 通过不同算法增强后的 PSNR 值

Tab. 1 PSNR values enhanced by different algorithms

Image	MSRCR	ACE	Improve ACE
0	16.06	18.56	25.23
1	12.67	14.26	17.21
2	13.24	15.23	19.33
3	11.01	12.32	16.54
4	14.98	15.87	19.57

表 2 通过不同算法增强后的 SSIM 值

Tab. 2 SSIM values enhanced by different algorithms

Image	MSRCR	ACE	Improve ACE
0	0.617	0.632	0.854
1	0.524	0.578	0.702
2	0.601	0.632	0.754
3	0.421	0.512	0.684
4	0.498	0.562	0.691

由上数值表和柱状图可以看出,改进 ACE 图像增强算法在 PSNR 和 SSIM 两个指标上明显高于其

他两种图像增强算法。

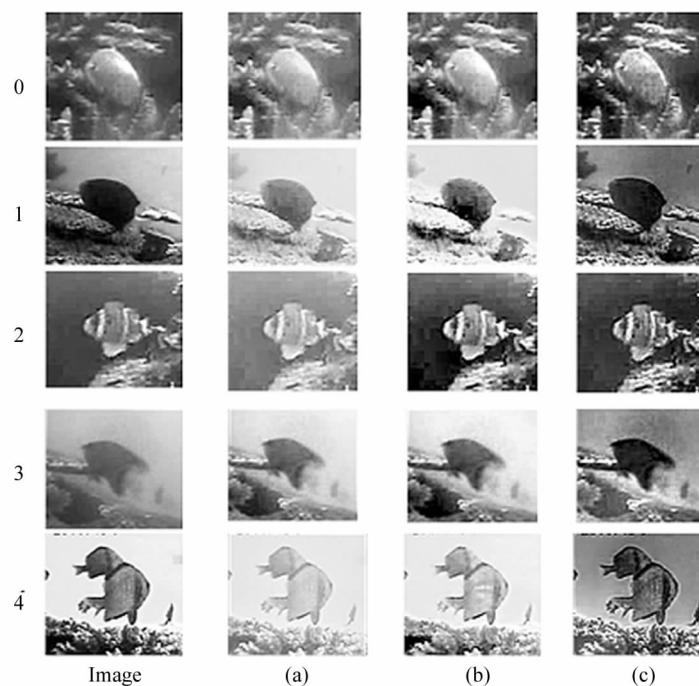


图 6 通过不同算法增强后的效果

Fig. 6 The effect enhanced by different algorithms

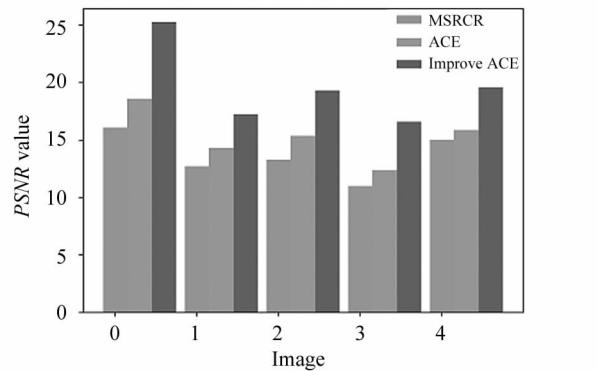


图 7 不同种类鱼增强后的 PSNR 值柱状图

Fig. 7 Histogram of enhanced PSNR values of different species of fish

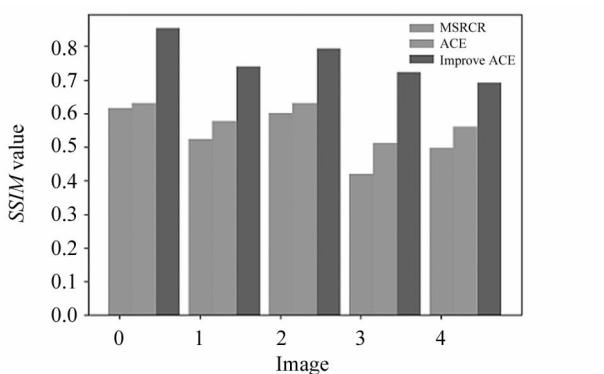


图 8 不同种类鱼增强后的 SSIM 值柱状图

Fig. 8 Histogram of enhanced SSIM values of different species of fish

4.3 图像分割实验

4.3.1 实验环境

已配置用于训练学习网络的机器,采用 Linux 系统,配备 64 G 运行内存、48 核 intel Xeon CPU、2 张 GeForce GTX 1080Ti 显卡以及 4 块 2T 机械硬盘。将训练集、测试集和验证集通过 8 : 1 : 1 的比例划分,利用 Python 编程语言,基于 Pycharm 平台进行编程仿真,在训练和测试时,使用 cuDNN 和 CUDA 来进行训练的加速。

4.3.2 图像分割实验过程

首先将特征提取模型进行预训练,将预训练好的模型开始训练新制作的数据集,训练过程之前要将图像的尺寸调整到相同大小,主干网络使用 ResNet101 网络模型,并使用 SGD 模型优化器,为了防止过拟合,将学习率设置为 0.005,每次输入图片数量(batch size)为 16,总 Epoch 设置为 100。SGD 的计算式如下:

$$\theta = \theta + (y^{(i)} - h_{\theta}(x^{(i)}))x_j^i, \quad (13)$$

式中, θ 表示的是初始参数。本文主要使用的评价指标是平均交并比(mean intersection over union, MI-OU)和平均像素准确率(mean pixel accuracy, MPA)作为图像分割的评价指标。具体表达式如下所示:

$$MIOU = \frac{1}{n+1} \sum_{i=0}^n \frac{p_{ii}}{\sum_{j=0}^n p_{ij} + \sum_{i=0}^n p_{ji} - p_{ii}}, \quad (14)$$

$$MPA = \frac{1}{n+1} \sum_{i=0}^n \frac{p_{ii}}{\sum_{j=0}^n p_{ij}}, \quad (15)$$

式中, n 代表类别数; i, j 分别代表真实值、预测值; p_{ij} 表示将 i 预测为 j 的像素数量。

4.3.3 实验结果对比

根据上述评价指标, 将本文提出的 ARD-PSPNet 网络模型与 SegNet^[22]、UNet^[23]、PSPNet^[24] 几

种经典网络在相同数据集上进行实验结果的对比, 效果如图 9 所示, 图中, (a) 为图像标签, (b) 为 SegNet 网络分割的效果, (c) 为 UNet 网络分割的效果, (d) 为 PSPNet 网络分割的效果, (e) 为 ARD-PSPNet 网络分割的效果。

从图可以看出, ARD-PSPNet 网络与其他网络相比, 分割的位置更准确、分割效果更佳。实验结果数据如表 3 所示, 本文提出的 ARD-PSPNet 网络较其他网络分割后的结果在 MIOU、MPA、损失以及分割时间上都有一定的提升。

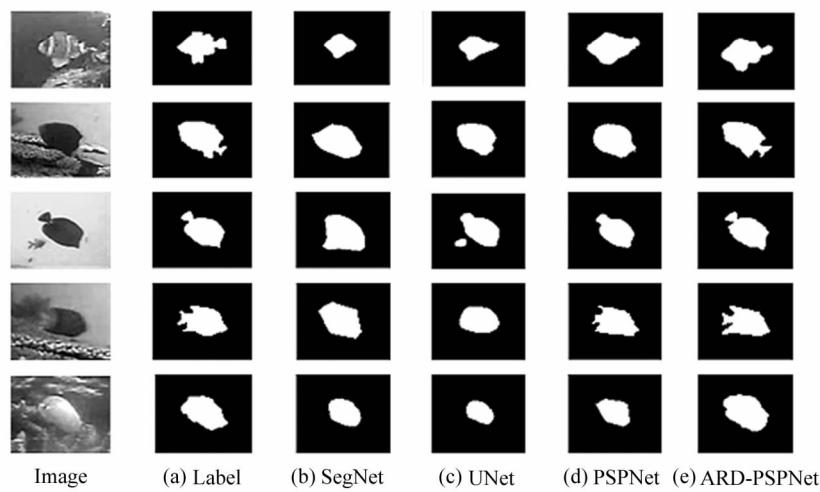


图 9 实验结果对比

Fig. 9 Comparison of experimental results

表 3 图像 MIOU 值和损失值

Tab. 3 MIOU values and loss values of images

Network model	MIOU/%	MPA/%	Loss value	Segmentation time/ms
SegNet	90.52	92.75	0.264	136
UNet	91.22	93.54	0.243	123
PSPNet	92.05	94.16	0.149	139
ARD-PSPNet	94.85	96.12	0.051	96

训练过程中 MIOU 变化曲线如图 10 所示, 在 20 个 Epoch 左右, 模型趋于收敛, 其中 ARD-PSPNet 模型相较于其他模型 MIOU 值最高、收敛速度最快。

训练过程的损失变化曲线如图 11 所示, 在 40 个 Epoch 左右, 损失值趋于收敛, 其中本文方法收敛得最快、损失值最低。

4.3.4 消融实验

针对不同的改进方法的结果如表 4 所示, 通过表 4 可以发现, 仅加入图像增强算法, MIOU 和 MPA 两个指标有了一定的提升, 但是在仅加入 R-MCN 模块中, 这两个指标的提升最明显; 仅加入深度可分离卷积有效减少了分割时间; 仅加入改进损

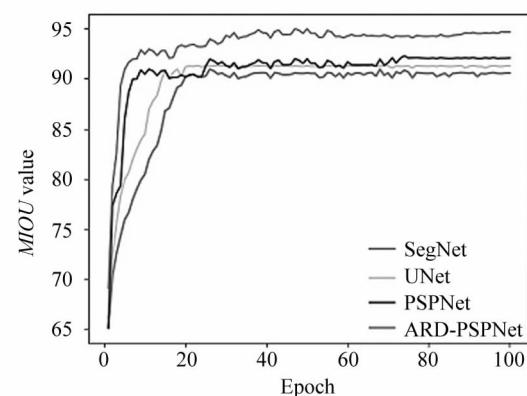


图 10 MIOU 值变化曲线

Fig. 10 Change value curve of MIOU

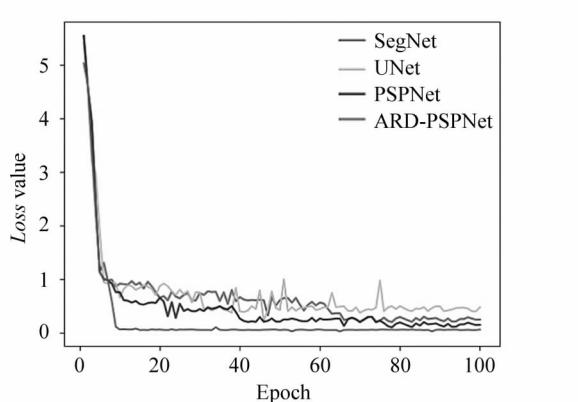


图 11 损失值变化曲线
Fig. 11 Loss value change curve

失函数后,模型的损失值明显降低。本文提出的 ARD-PSPNet 方法结合了上述所有的优势,在表中的 4 个指标上分别展示出良好的分割性能。

如图 12 所示,展示的是不同模型下有无图像增强的分割效果图,可以看出每个模型在图像增强后的分割图像效果明显优于无图像增强后的分割图像。

5 结 论

本文利用改进 ACE 算法进行水下鱼类图像增强,在保证增强效果的同时,降低了计算的复杂度,并且也为后续的水下鱼类图像分割奠定了基础,此

表 4 加入不同方法或模块后的各个指标

Tab. 4 Indicators after adding different methods or modules

Improve	MIOU/%	MPA/%	Segmentation time/ms	Loss value
PSPNet	92.05	94.16	139	0.149
PSPNet+Image enhancement	93.42	95.32	137	0.112
PSPNet+R-MCN	93.74	95.78	138	0.149
PSPNet+Depthwise separable convolution	92.21	93.21	95	0.149
PSPNet+Improve loss function	92.11	93.42	119	0.059
ARD-PSPNet	94.85	96.12	96	0.051

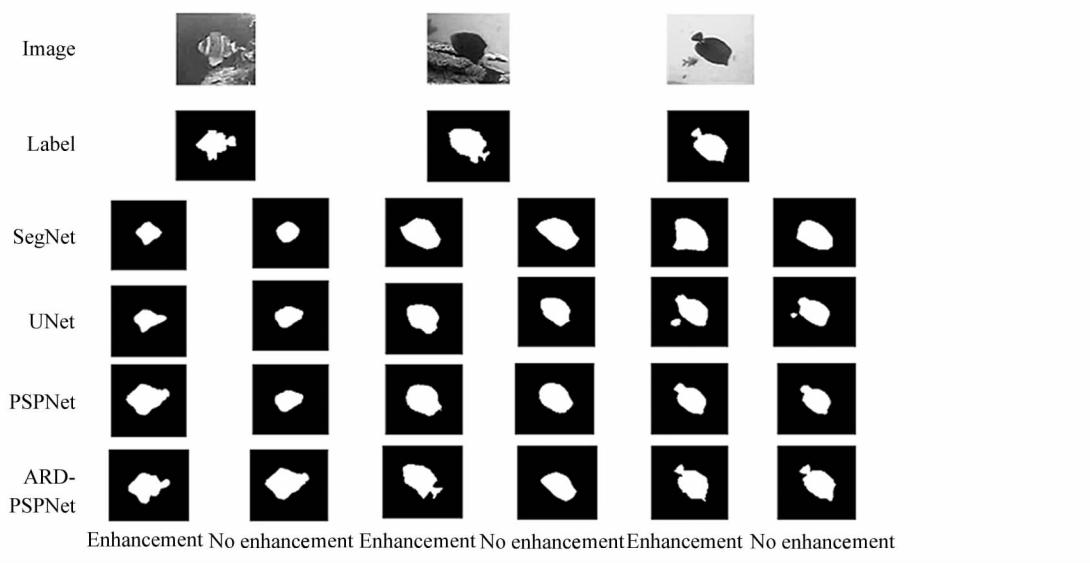


图 12 不同网络在有无增强条件下的效果
Fig. 12 Effects of different networks with or without enhancement

方法在水下环境中的效果良好。在水下鱼类图像分割中,提出了 ARD-PSPNet 网络模型,该模型将 PSPNet 作为基础网络模型,将普通卷积替换为可分离卷积,降低了计算量并且使得实时性得到提高,在空间金字塔池化模块中嵌入 R-MCN 模型,利用 R-

MCN 模块的两个大卷积核来增加训练的感受野,改进损失函数使得模型收敛更快,分割位置更加准确。通过实验得出的结果分别与其他网络模型进行了对比,也展现出了其良好的性能,证明本文提出的 ARD-PSPNet 方法适用于水下环境。

参考文献:

- [1] LAND E H. The retinex theory of color vision[J]. *Scientific American*, 1977, 237(6): 108-128.
- [2] HINES G, RAHMAN Z, JOBSON D, et al. Single-scale retinex using digital signal processors[EB/OL]. (2005-02-22)[2022-02-28]. <https://ntrs.nasa.gov/api/citations/20050091487/downloads/20050091487.pdf>.
- [3] JOSHI K R, KAMATHE R S. Quantification of retinex in enhancement of weather degraded images[C]//International Conference on Audio, Language and Image Processing, July 07-09, 2008, Shanghai, China. New York: IEEE, 2008: 1229-1233.
- [4] FU X Y, ZHUANG P X, HUANG Y, et al. A retinex-based enhancing approach for single underwater image[C]//IEEE International Conference on Image Processing, October 27-30, 2014, Paris, France. New York: IEEE, 2014: 4572-4576.
- [5] ALEX R S M, SUPRIYA M H. Underwater image enhancement using single scale retinex on a reconfigurable hardware[C]//International Symposium on Ocean Electronics, November 18-20, 2015, Kochi, India. New York: IEEE, 2015: 1-5.
- [6] LIU K, LI X J. Dehazing and enhancement methods for underwater and low-light images[J]. *Acta Optica Sinica*, 2020, 40(19): 1910003.
刘柯,李旭健.水下和微光图像的去雾及增强方法[J].
光学学报,2020,40(19):1910003.
- [7] LI Q Z, BAI W X, NIU J. Underwater image color corection and enhancement based on improved cycle-consistent generative adversarial networks[J/OL]. *Acta Automatica Sinica*. (2020-12-04)[2022-02-28]. <https://doi.org/10.16383/j.aas.c200510>.
李庆忠,白文秀,牛炯.基于改进 CycleGAN 的水下图像
颜色校正与增强[J/OL].自动化学报.(2020-12-04)
[2022-02-28].<https://doi.org/10.16383/j.aas.c200510>.
- [8] UPLAVIKAR P M, WU Z Y, WANG Z Y. All-in-one underwater image enhancement using domain-adversarial learning[EB/OL]. (2019-05-30)[2022-02-28]. <https://arxiv.org/abs/1905.13342v1>.
- [9] ZHANG M J, LI X, WANG Y J. Underwater color image segmentation based on weight adjustment for color-to-gray[J]. *Journal of Harbin Engineering University*, 2015, 45(2): 707-713.
张铭钧,李煊,王玉甲.基于灰度化权值调整的水下彩
色图像分割[J].哈尔滨工程大学学报,2015,45(2):
707-713.
- [10] GUO C X, LI Z B, QIAO X, et al. Image segmentation of underwater sea cucumber using GrabCut with saliency map[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2015, 34(1): 147-152.
郭传鑫,李振波,乔曦,等.基于融合显著图与 GrabCut
算法的水下海参图像分割[J].农业机械学报,2015,34
(1):147-152.
- [11] XU R Y, QIN Z B. Underwater image segmentation based on particle swarm optimization and fuzzy partition entropy [J]. *Optical Technique*, 2007, 33(5): 754-758.
徐玉如,秦再白.基于 PSO 和模糊划分熵的水下图像分
割[J].光学技术,2007,33(5):754-758.
- [12] DONG G H, XI Z H, ZHAO Y Q. CV level set image segmentation based on cultural algorithm[J]. *Journal of Systems Engineering and Electronics*, 2012, 34(7): 1499-1504.
董光辉,席志红,赵彦青.基于文化算法的 CV 水平集图
像分割[J].系统工程与电子技术,2012,34(7):1499-
1504.
- [13] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected crfs[J]. *Computational Intelligence and Neuroscience*, 2014, 4: 357-361.
- [14] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs[J]. *IEEE Transactions Pattern Analysis Machine Intelligence*, 2016, 40: 834-848.
- [15] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//European Conference on Computer Vision (ECCV), September 8-14, 2018, Munich, Germany. New York: IEEE, 2018: 833-851.
- [16] ZHANG Z, HUANG J, JIANG T, et al. Semantic segmentation of very high resolution remote sensing image based on multiple band combinations and patchwise scene analysis[J]. *Journal of Applied Remote Sensing*, 2020, 14(1): 016502.
- [17] GUAN H Y, WU W, YANG Y W, et al. Based on the improved ACE algorithm fast to fog method[J]. *Computer Simulation*, 2019, 36(8): 242-246.
官洪运,吴炜,杨益伟,等.基于改进 ACE 算法的快速去
雾方法[J].计算机仿真,2019,36(8):242-246.
- [18] SU J M, LIU L L, HUANG L K. Automatic color equalization algorithm based on visual later inhibition mechanism [J]. *Science Technology and Engineering*, 2019, 19(1): 190-195.
苏俊铭,刘立龙,黄良珂.基于视觉侧抑制特性的自动色
彩均衡算法[J].科学技术与工程,2019,19(1):190-

- 195.
- [19] YE Y X, TAN X, SUN M M, et al. High-resolution remote sensing image classification based on improved DeepLabV3 network [J]. Bulletin of Surveying and Mapping, 2021(4): 40-44.
叶沅鑫, 谭鑫, 孙苗苗, 等. 基于增强 DeepLabV3 网络的高分辨率遥感影像分类[J]. 测绘通报, 2021(4): 40-44.
- [20] XU C, WANG L. Image semantic segmentation method based on improved DeeplabV3+ network [J]. Laser & Optoelectronics Progress, 2021, 58(16): 1610008.
徐聪, 王丽. 基于改进 DeepLabv3+ 网络的图像语义分割方法 [J]. 激光与光电子学进展, 2021, 58(16): 1610008.
- [21] WANG C Z, NIU H X. Sand-dust degraded image enhancement algorithm based on histogram equalization and MSRCR [J]. Computer Technology, 2022, 48(9): 223-229.
王春智, 牛宏侠. 基于直方图均衡化和 MSRCR 的沙尘降质图像增强算法 [J]. 计算机工程, 2022, 48(9): 223-229.
- [22] CHEN H Y, CHEN G Q, ZHANG H Q. Image segmentation of Ochotona curzoniae based on SegNet model [J]. Journal of Hunan Agricultural University (Natural Sciences), 2020, 46(6): 749-752.
陈海燕, 陈刚琦, 张华清. 基于 SegNet 模型的高原鼠兔的图像分割 [J]. 湖南农业大学学报(自然科学版), 2020, 46(6): 749-752.
- [23] HUANG Z, ZHAO Y W, LIU Y H, et al. GCAUNet: a group cross-channel attention residual UNet for slice-based brain tumor segmentation [J]. Biomedical Signal Processing and Control, 2021, 70: 102958.
- [24] ZHU X L, CHEN Z Y, WANG S, et al. Coronary angiography image segmentation based on PSPNet [J]. Computer Methods and Programs in Biomedicine, 2021, 200: 105897.

作者简介:

岳有军 (1970—), 男, 教授, 博士研究生, 研究方向为复杂系统建模及智能控制、机器人导航与控制技术、电力电子技术及应用研究。