

基于多输入对抗网络的水下图像增强

林森, 刘世本

(辽宁工程技术大学电子与信息工程学院, 葫芦岛 125105)

摘要: 由于水体吸收和散射的影响, 水下图像往往存在纹理特征模糊、对比度降低以及颜色失真等现象。为提高水下图像的视觉质量, 本文提出一种基于多输入对抗网络水下图像增强。首先, 利用经典的 DCP 算法对原始图像进行去雾, 针对上去雾图像分别使用白平衡(WB)和对比度受限的自适应直方图均衡化(CLAHE)算法, 得到颜色校正和对比度增强图像; 然后, 利用编码器-解码器学习原始图像、颜色校正和对比度增强图像之间的特征差异的置信度图, 为减少 WB 和 CLAHE 算法引入的伪影和细节模糊, 引入两个子网络分别滤除干扰信息, 保留重要特征信息; 最后, 通过对每个子网络输出的重要特征进行门融合操作, 利用判别网络和参数固定的 VGG-19 网络进行训练以达到最优解, 获得增强的水下图像。对增强后的水下图像进行测试与评估, 实验结果表明, 增强后的水下图像色彩鲜明和细节清晰, 该网络对视觉效果有显著提升。

关键词: 生成对抗网络; 融合; 密集块; 水下图像增强

中图分类号: TP510.4050

Multi-input adversarial network for underwater image enhancement

Lin sen, Liu Shibei

(Electronic and Information Engineering School, Liaoning Technical University, Huludao 125000)

Abstract: Due to the influence of water absorption and scattering, underwater images often have blurred texture features, reduced contrast, and color distortion. In order to improve the visual quality of underwater images, the paper proposes an underwater image enhancement based on multi-input adversarial network. First, the original image is defogged using the classical DCP algorithm, and white balance (WB) and contrast-limited adaptive histogram equalization (CLAHE) algorithm are used for the defogged image to obtain color correction and contrast enhancement images; Then, encoder-decoder is used to learn the confidence map of the difference between the original image, the color correction and the contrast-enhanced image. To reduce the artifacts and detail blur introduced by the WB and CLAHE algorithms, two sub-networks are introduced to filter the interference information separately. The important feature information is retained; Finally, the gate fusion operation is performed on the important features of each sub-network output, discriminant network and VGG-19 network with the fixed parameter is used for training to achieve the optimal solution, the enhanced underwater image is obtained. The enhanced underwater image was tested and evaluated. The experimental results show that the enhanced underwater image has clear colors and clear details, and the network has a significant improvement in visual effects.

Key words: Generate adversarial network; Fusion; Dense block; Underwater image enhancement

0 引言

目前, 开发、探索和保护海洋资源已成为国际社会的战略中心。清晰的水下图像为水下世界提供有价值的信息, 这对于水下考古、水下监测等研究任务是必不可少的。由于海水的

基金项目: 国家自然科学基金(61473208); 国家自然科学基金委员会

作者简介: 林森(1980-), 男, 副教授、硕导, 主要研究方向: 图像处理、机器视觉、模式识别. E-mail: lin_sen6@126.com

吸收和散射导致水下图像具有低对比度和亮度、颜色偏差和细节模糊等问题^[1]，限制它们在实际场景中的应用，因此水下图像增强是一个不可或缺的处理步骤。

近年来，在基于多分支的深度学习技术在水下图像处理方面也得到广泛应用。其中 Wang 等人^[2]提出了一种基于卷积神经网络的水下图像增强方法，简称 UIE-Net。UIE-Net 有两个分支：颜色校正网络（CC-Net）和去雾网络（HR-Net），分别输出色彩校正图像和传输图，利用文献^[3]的水下成像模型，获得清晰图像。Li 等人^[4]提出了门控融合的卷积神经网络用于水下图像增强，即 DUIENet，通过卷积神经网络学习三个置信度图，利用门融合网络，把特征转换单元(FTUs)的三个输出与三个置信度图对应相乘，得到增强后的水下图像。上述两种多分支设计是基于卷积神经网络设计的，而 Li Hanyu 等人^[5]提出基于生成对抗的融合网络，即 FGAN。生成网络使用了两个输入并将它们通过同一网络中的不同分支，在生成网络的损失之前对特征进行求和，利用生成网络与判别网络的相互博弈，进而得到清晰图像。

本文提出了基于多输入对抗网络水下图像增强，简称为 MI-GAN。研究者发现池化层（Pooling）可以压缩数据和减少过拟合，但是容易造成细节特征丢失，本文通过卷积操作进行数据压缩（步长设置为2），进而避免了细节特征丢失。MI-GAN 引入编码器-解码器结构，使前面的特征重复使用，对后面的特征进行矫正，此外，还加入密集块结构（Dense Block，DB），网络具有更高的参数效率且具有更深的网络结构。通过实验测试表明本文算法与其他经典、新颖算法相比，处理后的图像色彩鲜明、对比度高，具有良好的可视性。

1 网络模型

1.1 预处理

本文通过对原始图像进行预处理，初步获取色彩鲜明、对比度高的水下图像，为网络提供不同层次特征的水下图像。首先利用经典 DCP^[6]原始图像进行去雾处理，其次对去雾后的图像分别使用白平衡算法(WB)和对比度受限的自适应直方图均衡化(CLAHE)^[7]来获得颜色鲜明和高对比度的水下图像，分别称为 DCP_WB，DCP_CLAHE。DCP_WB 具有良好的颜色矫正效果，能有效恢复出水下退化图像的色彩信息，如图 2 所示。DCP_ CLAHE 用水下图像的对比度提升效果良好，如图 3 所示，原始图像如图 1 所示。



图 1 原始图像



图 2 DCP_WB 处理图




图 3 DCP_CLAHE 处理图

Fig.1 Original image Fig.2 DCP_WB processing image Fig.3 DCP_CLAHE processing image

1.2 编码器-解码器

在一些水下图像处理算法^[8]中，采用了编码器-解码器（Encoder-Decoder）结构作为生成器，使前面的特征对后面的特征进行校正并保留水下图像的细节特征。编码器层的图像被逐步向下采样，直到瓶颈层（Bottle Block），然后这个过程被解码器层上采样以获得输出图

像。通过 ResNet^[9]的短路连接 (Skip connections)，使输出和输入共享大量的结构信息，但是容易导致某些层的信息阻塞或者选择性丢弃。ResNet 的短路连接如公式 (1) 所示：

$$X_l = H_l(X_{l-1}) + X_{l-1} \quad (1)$$

80 l ：表示层， X_l ：表示 l 层的输出， H_l 表示一个非线性变换。所以对于 ResNe 而言， l 层的输出是 $l-1$ 层的输出加上对 $l-1$ 层输出的非线性变换。最近，DenseNet 架构^[10]被引入到 U-Net 中，核心组件是密集块，它将每一层的输出与输入在维度上进行连接，并将其传递给下一层，这加强了特征的传递和减轻了梯度消失。DenseNet 的维度连接(Concatenation)如公式 (2) 所示：

$$X_l = H_l([X_0, X_1, \dots, X_{l-1}]) \quad (2)$$

85 $[X_0, X_1, \dots, X_{l-1}]$ 表示将0到 $l-1$ 层输出的特征映射(Feature map)进行连接。维度连接是通道的合并而不是像短路连接进行像素相加， H_l 包括批量归一化(Batch Normalization, BN)，线性整流函数(ReLU)和卷积(Convolution)。本文把编码器-解码器和密集块同时应用到水下图像处理，使参数效率极高的同时还使网络性能得到大幅提升。

1.3 生成网络

90 MI-GAN 中的生成网络为了学习不同水下图像之间的差异，保留水下图像的高对比度和色彩鲜明等重要特征。该生成网络分为三个子网络，如图4所示，第一个子网络是 CM-Net，学习原始水下图像与 DCP_WB 和 DCP_CLAHE 算法处理之后的两幅图像之间特征差异的置信度图，分别为 C_{WB} 和 C_{LAB} 。CM-Net 由编码器和解码器两个部分组成，编码器由两个向下转换层 (Transition Down, TD) 两个密集块组成，解码器由两个向上转换层 (Transition Up, 95 TU) 和两个密集块构成，且编码器的密集块与解码器的上采样转换层对应的特征映射在维度上进行连接，形成线性结构，使水下图像的特征叠加，有利于对后面的特征进行校正。原始图像、DCP_WB 和 DCP_CLAHE 三幅图像在维度上进行连接作为 CM-Net 的输入，经过 CM-Net 学习颜色矫正和高对比度的两个置信度图，分别为 C_{WB} 和 C_{CLAHE} ，保留了输入图像留下的重要特征信息。第二个子网络为 WB-Net，为了减少颜色失真和保留颜色特征信息并由4个卷积-线性整流函数模块组成，且加入两个维度连接，有效的保留了 DCP_WB 处理图 100 像的细节特征。WB-Net 输入为原始图像和 DCP_WB 算法处理后的图像。第三个子网络是 CLAHE-Net，为了保留输入图像的高对比度特征，防止对比度降低。CLAHE-Net 的输入为原始图像和 DCP_CLAHE 处理后的图像。WB-Net 和 CLAHE-Net 网络结构是相同的且分别输出为 D_{WB} 和 D_{CLAHE} 。最后，利用门融合网络，使学习的两个置信度图 (C_{WB} 和 C_{CLAHE}) 105 与另外两个子网络的输出 (D_{WB} 和 D_{CLAHE}) 对应相乘，得到相乘结果之后并进行像素叠加，则为增强图像，最终融合的图像如公式 (3) 所示：

$$I = D_{WB} \otimes C_{WB} + D_{CLAHE} \otimes C_{CLAHE} \quad (3)$$

研究发现,在卷积运算之前应用非线性激活函数是至关重要的,则本文的密集块由四个复合层组成,如图4所示,复合层具有批量归一化、线性整流函数、卷积和失活函数(Dropout)操作,在大气去雾领域取得不错的结果。第一层从输入获取 k 个特征映射,在 DenseNet 中 k 为增长率,本文 k 设置为12,第一层得到的特征映射与第一层输入进行维度连接。然后作为第二层输入,依此类推,则第四层的输入和第四层获得的特征映射进行维度连接作为密集块的输出。

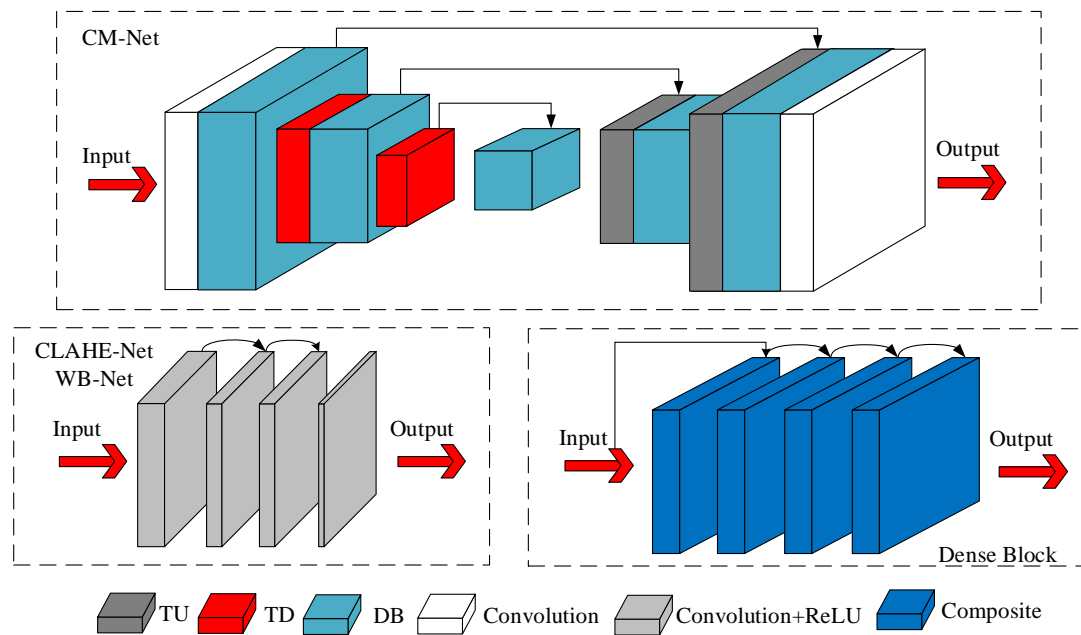


图4 生成网络结构

Fig.4 Generative network structure

黑色的连接线: 线条尾部连接模块的输出与箭头连接模块的输出进行维度连接, Input 和 Output 分别代表输入和输出。

1.4 判别网络

MI-GAN 的判别网络采用五个卷积层, 批量归一化, 类似于 pix2pix^[11]中 70*70 的 PatchGAN。判别网络是用来判别输入图像的局部块是真是假, 因此在特征图上的有效接收域覆盖了输入图像的一小块区域, 这样会删除更多的人为干扰因素。此外, 批量归一化使分布更易集中, 判断局部块真假的效果更好, 判别网络的输入为生成网络生成的图像和目标图像(清晰图像)。在对抗训练过程, 判别网络学习区分目标图像与生成图像, 并且生成网络通过训练学习, 生成一个足以以假乱真的生成图像来欺骗判别网络, 当判别网络难以区分清晰图像与生成图像时, 则获得了色彩鲜明、具有较高对比度的清晰图像, 提高水下图像的可视质量。网络中的参数设置: 学习率为 0.001; 图像的输入大小 (256,256,3); 批尺寸 (batch size) 为 4; 迭代 (iteration) 为 5; 时期 (epoch) 为 100。在本文程序运行过程中, 执行一次生成器更新, 然后就执行一次鉴别器更新, 判别网络结构如图 5 所示。




图5 判别网络结构

Fig.5 Discriminant network structure

1.5 损失函数

为了更好的保留输入图像的色彩鲜明和高对比度特征，本文采用了对抗损失函数^[12]、L1损失和感知损失函数三个损失函数进行线性叠加，对抗损失函数如公式（4）所示：

$$L_{GAN} = E(x, y)[\log(D(x, y))] + E(x, z)[\log(1 - D(x, G(x, z)))] \quad (4)$$

D ：判别器， G ：生成器。 x ：输入的水下模糊图像， y ：与 x 对应的水下清晰图像， z ：噪声输入，采用文献^[11]中的方法，以随机失活（Dropout）作为噪声源，提高模型的随机性。本文利用感知损失函数进行水下图像的特征重建。生成网络生成的图像和目标图像通过一个网络模型参数固定的VGG-19网络，传递到VGG-19的Conv4_3层后输出，利用L2损失函数对输出图像进行计算。则损失函数定义如公式（5）所示：

$$L_{vgg} = \frac{1}{CWH} \sum_{c=1}^C \sum_{w=1}^W \sum_{h=1}^H \|V(G(x, z)^{c,w,h}) - V(y^{c,w,h})\|_2^2 \quad (5)$$

C 、 W 、 H 分别表示输出图像的通道，宽度和高度。 V 表示由VGG-19网络进行的非线性转换。如文献^[11]中所述，使用加权L1损失和对抗性损失减少了输出图像中的人工干扰因素，则目标图像 y 和生成的图像 $G(x, z)$ 的L1损失计算如公式（7）所示：

$$L_1 = E_{x,y,z} [\|y - G(x, z)\|_1] \quad (6)$$

总损失函数如公式（7）所示：

$$L = \lambda_1 * L_{GAN} + \lambda_2 * L_{vgg} + \lambda_3 * L_1 \quad (7)$$

λ_1 ， λ_2 ， λ_3 ：代表常数，分别设置为2，5，60。网络的相关参数如表1所示。

表1 网络的相关参数

Tab.1 Network parameters

结构(Architecture)	
CM-Net	复合层 (composite)
输入：(4,256,256,9)	批量归一化 (BN)
3*3卷积，Stride=1，(4,256,256,48)	激活函数 (ReLU)
DB (4复合层) + TD，(4,128,128,48)	3*3 卷积，Stride=1
DB (4复合层) + TD，(4,64,64,48)	失活函数 (Dropout)，p=0.2

DB (12复合层), (4,64,64,228)	向下转化层 (TD)
TU + DB (4复合层), (4,128,128,96)	批量归一化
TU + DB (4复合层), (4,256,256,96)	激活函数
3*3卷积, Stride=1, (4,256,256,2)	3*3 卷积, Stride=2
WB-Net/CLAHE-Net	失活函数, p=0.2
输入: (4,256,256,6)	判别网络
7*7卷积, Stride=1, (4,256,256,32)	输入: (4,256,256,6)
5*5卷积, Stride=1, (4,256,256,44)	3*3卷积, Stride= 2, (4,128,128,64)
3*3卷积, Stride=1, (4,256,256,56)	3*3卷积, Stride= 2, (4,64,64,128)
3*3卷积, Stride=1, (4,256,256,2)	3*3卷积, Stride= 2, (4,32,32,256)
向上转换层 (TU)	3*3卷积, Stride= 1, (4,31,31,512)
3*3 卷积, Stride=2	3*3卷积, Stride= 1, (4,30,30,1)

表1中, 子网络名称和模块名称的字体加粗, Stride 表示步长, (4,256,256,9) 中第一个参数代表批次, 第二个和第三个参数分别为图像定的高和宽, 第四个参数表示维度。

1.6 整体网络结构图

为了解决水下图像颜色失真、低对比度和表面雾化现象, 本文利用门融合网络的思想, 把不同特征的水下图像和生成对抗网络有效地结合。在整个全卷积网络中, 生成网络采用了三个子网络, 并结合了编码器-解码器和密集块, 判别网络采用类似的 PatchGAN, 利用 $L1$ 损失、感知损失函数和对抗损失函数保留了目标图像的特征, 以及 DCP_WB 和 DCP_CLAHE 的图像特征, 整体网络结构图如图6所示。

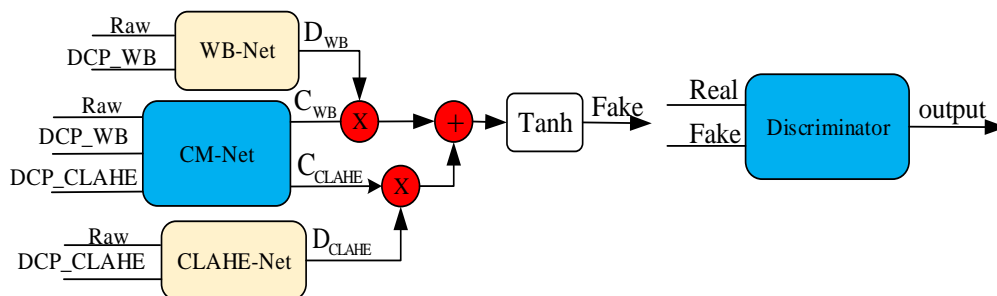


图6 网络结构图

Fig.6 Network structure diagram

Raw、DCP_WB 和 DCP_CLAHE 分别代表原始图像、DCP_WB 和 DCP_CLAHE 算法处理后的图像, Fake 表示生成图像, Real 代表目标图像, output 表示输出图像。

2 实验结果

为验证 MI-GAN 的鲁棒性和有效性, 将 MI-GAN 与其他典型算法 (包括深度学习和传统算法) 进行试验对比, 然后从主观评价和客观评价两方面对处理图进行对比分析, 最后证明 MI-GAN 在深度学习方面进行水下图像处理具有很强的实用性。

2.1 数据集

水下生成对抗网络^[13] (Underwater Generative Adversarial Networks, UGAN) 利用 CycleGAN 的风格转移特性, 通过对 ImageNet 的子集进行了训练, 进而获得了图像对(清晰图像和对应的不清晰图像), MI-GAN 选取此训练集中的 6000 张图像进行训练。

2.2 主观评价

通过颜色恢复试验来验证 MI-GAN 在水下图像颜色矫正方面的有效性, 该实验是基于一幅水下退化的色卡图像及无失真的色卡图像, 由于水下环境复杂, 引起色卡颜色退化, 通过对退化的色卡图像进行处理, 可有效的验证 MI-GAN 的颜色恢复效果。将 MI-GAN 与限制对比度自适应直方图均衡化 (CLAHE) 算法、水下颜色校正 (LAB) 算法、经典的水下暗通道先验 (UDCP) 算法、去雾网络 (DehazeNet) 结合混合小波与方向滤波器组 (DehazeNet and HWD) 算法^[14]进行对比, 实验结果如图 7 所示。




图 7 颜色恢复试验结果

Fig.7 Experimental results of color restoration

从图 7 中可以看出, CLAHE 算法和 UDCP 算法处理后的图像整体偏蓝, 且 UDCP 算法图像中颜色块不均匀。LAB 算法处理后的图像整体偏暗, 颜色信息不明确。DehazeNet and HWD 算法处理之后的图像颜色加深, 各相同色系颜色区分度降低, 与真实的色卡颜色不符合。本文算法复原后的图像颜色较鲜明且与色卡颜色最为接近。

为进一步验证水下图像的颜色校正和清晰度恢复效果, 对 8 幅不同环境的水下图像进行实验, 如图 8 所示。将本文算法与经典算法以及最新的图像清晰化方法进行比较分析, 对比算法如下: DCP 算法、UDCP 算法、DehazeNet 算法及 DehazeNet and HWD 算法、深水图像增强网络 (DUIENet)、水下生成对抗网络 (UGAN)。从图 8 可以看出, UDCP 算法、DCP 算法和 DehazeNet 算法对偏蓝, 偏绿的图像的作用效果很小, 但是 UDCP 算法能有效的进行颜色补偿。DehazeNet 算法去雾方面表现良好, 由于缺乏颜色校正相关处理, 图像色偏现象仍然存在。DehazeNet and HWD 算法有效的解决色偏问题, 但由于过度曝光及颜色补偿, 导致处理后的水下图像普遍呈灰白色。DUIENet 在恢复图像颜色信息时具有一定效果, 但增强后的图像容易出现红色伪影 (如图 image1), 且存在去雾不彻底的现象 (如图 image3、image8)。UGAN 与本文算法在提高水下图像对比度及清晰度方面均表现良好, 相比之下, 本文算法在颜色信息校正方面更有优势。



(a)原始图像 (b)DCP 算法 (c)UDCP 算法 (d)DehazeNet 算法 (e)DehazeNet and HWD 算法
(f)DUIENet 算法 (g)UGAN 算法 (h)MI-GAN

图 8 实验结果图

Fig. 8 Experimental results

2.3 客观评价

通过主观评价发现 MI-GAN 对去雾和色彩信息恢复都具有良好的增强效果。为了更客观的评价和分析所提出算法的性能，进一步采用水下彩色图像质量评价（Underwater color image quality evaluation, UCIQE）综合指标和加速稳健特征（Speeded up robust features, SURF）并分析算法性能。UCIQE 代表水下图像色度、饱和度和对比度的综合指标。UCIQE 的取值范围为[0,1]，UCIQE 值越高代表图像具有更好的视觉质量，计算公式如下：

$$UCIQE = c_1 \times \sigma_c + c_2 \times con_l + c_3 \times \mu_s \quad (8)$$

其中 σ_c 是色度的标准差， con_l 代表亮度的对比度， μ_s 代表饱和度的平均值， c_1 、 c_2 、 c_3 为加权系数，常用取值为 $c_1 = 0.4680$, $c_2 = 0.2745$, $c_3 = 0.2576$ 。

为进一步评估算法性能，采用 UCIQE 指标对算法在水下图像质量增强结果进行进一步

的客观测评，加粗字体为每幅图像对应算法的最优值，UCIQE 评价指标结果如表 2 所示。表 2 数据表明，算法针对不同情况的水下图像都有较高的测评值，而且这 8 幅图像的 UCIQE 的平均值是最高的，说明处理后的图像具有良好的色度、饱和度及清晰度，且颜色信息恢复自然，具有更好的视觉效果。

220

表 2 UCIQE 评价指标结果
Tab.2 Quantitative results in terms of UCIQE

图像	DCP	UDCP	DehazeNet	DehazeNet and HWD	DUIENet	UGAN	MI-GAN
1	0.6062	0.6156	0.5843	0.6539	0.6159	0.6494	0.6580
2	0.6007	0.6129	0.5861	0.6258	0.5775	0.6037	0.6344
3	0.6363	0.6144	0.6293	0.6138	0.5572	0.6263	0.6672
4	0.5802	0.6195	0.4734	0.5831	0.5875	0.6004	0.6023
5	0.4737	0.4877	0.4728	0.5720	0.6002	0.5914	0.6543
6	0.5564	0.5263	0.4973	0.6359	0.6354	0.6342	0.6499
7	0.6233	0.6116	0.5372	0.6085	0.6234	0.6266	0.6998
8	0.5985	0.611	0.5865	0.6533	0.5668	0.6264	0.6324
平均	0.5844	0.5874	05459	0.6182	0.5955	0.6198	0.6498

此外，采用 SURF 进行特征点匹配测试，通过对比处理前后图像的特征点匹配数目，验证本文算法在后续特征匹配过程中的应用效果。对3幅图像进行 SURF 测试，同一幅图像的左边是原图，右边为 MI-GAN 处理之后的图像，SURF 测试效果如图9所示，图像处理前后的特征点匹配数据如表3所示，可以得出，MI-GAN 处理后的图像具有更多可匹配的特征点，则图像清晰度越高，因此本文算法在后续特征匹配过程中具有良好的应用性。

225




图 9 特征匹配试验结果
Fig.9 Experimental results of feature matching

230

表 3 处理前后图像的特征点匹配数目
Tab.3 Number of feature points matching contrast

图像	原图	MI-GAN
Image1	9	45
Image2	7	28
Image3	12	25

3 结论

235

240

基于深度学习技术的水下图像处理，按照网络进行分类可以分为卷积神经网络和对抗网络两种，而本文针对水下图像颜色失真和低对比度，提出基于多输入生成对抗网络来处理水下退化图像。首先，利用 DCP_WB 和 DCP_LAB 算法对原始图像进行处理，得到颜色校正和高对比度图像。其次，通过生成网络学习目标图像的有效特征，该生成网络最大特点引入编码器-解码器结构，使前面的特征重复被使用，对后面的特征进行矫正，另外还加入了密集块，减少过拟合现象，进而更好的学习细节特征。最后，本文利用多个损失函数进行线性叠加作为总损失函数，通过生成网络和判别网络的相互博弈，使网络训练过程中，收敛更快，学习更有效的特征。目前，基于深度学习技术的水下图像处理，没有统一的水下成像模型，导致深度学习没有传统技术在图像处理应用广泛，归根结底，数据集不具有普适性。在未来的工作中将对数据集进行扩展和网络的研究，使深度学习技术在水下图像处理广泛应用。

[参考文献] (References)

245

250

255

260

265

[1] 郭继昌, 李重仪, 郭春乐, 等.水下图像增强和复原方法研究进展[J]. 中国图象图形学报, 2017, 22(3):0273-0287

[2] Yang W, Jing Z, Yang C, et al. A deep CNN method for underwater image enhancement[C]// 2017 IEEE International Conference on Image Processing (ICIP). 2018.

[3] Zhang S, Jing Z, Shuai F, et al. Underwater stereo image enhancement using a new physical model[C]// IEEE International Conference on Image Processing. 2015.

[4] Li C, Guo C, Ren W, et al. An Underwater Image Enhancement Benchmark Dataset and Beyond[J]. 2019.

[5] Li H, Li J, Wang W. A Fusion Adversarial Underwater Image Enhancement Network with a Public Test Dataset[J]. 2019.

[6] Miyato T, Kataoka T, Koyama M, et al. Spectral Normalization for Generative Adversarial Networks[J]. 2018.

[7] Jyoti D, Shaveta A, Rekha V, et al. Mammogram Image Enhancement Using Entropy and CLAHE Based Intuitionistic Fuzzy Method[C]. International Conference on Signal Processing and Integrated Networks (SPIN), 2019:24-29.

[8] Sun X, Liu L, Li Q, et al. Deep pixel-to-pixel network for underwater image enhancement and restoration[J]. IET Image Processing, 2019, 13(3):469-474.

[9] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[J]. 2015.

[10] Isola P, Zhu J Y, Zhou T, et al. Image-to-Image Translation with Conditional Adversarial Networks[J]. 2016.

[11] Huang G, Liu Z, Laurens V D M, et al. Densely Connected Convolutional Networks[J]. 2016.

[12] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]// International Conference on Neural Information Processing Systems. 2014.

[13] Fabbri C, Islam M J, Sattar J. Enhancing Underwater Imagery Using Generative Adversarial Networks[J]. 2018.

[14] Pan P W, Yuan F, Cheng E. Underwater image de-scattering and enhancing using dehazenet and HWD[J]. Journal of Marine Science and Technology, 2018, 26(4): 531-540.