

多输入融合对抗网络的水下图像增强

林 森^{1,2,3}, 刘世本¹, 唐延东^{2,3}

- (1. 辽宁工程技术大学 电子与信息工程学院, 辽宁 葫芦岛 125105;
2. 中国科学院沈阳自动化研究所 机器人学国家重点实验室, 辽宁 沈阳 110016;
3. 中国科学院机器人与智能制造创新研究院, 辽宁 沈阳 110016)

摘要: 针对水下图像出现对比度低、颜色偏差和细节模糊等问题, 提出了多输入融合对抗网络进行水下图像增强。该方法主要特点是生成网络采用编码解码结构, 通过卷积层滤除噪声, 利用反卷积层恢复丢失的细节并逐像素进行细化图像。首先, 对原始图像进行预处理, 得到颜色校正和对比度增强两种类型图像。其次, 利用生成网络学习两种增强图像与原始图像之间差异的置信度图。然后, 为减少在生成网络学习过程中两种增强算法引入的伪影和细节模糊, 添加了纹理提取单元对两种增强图像进行纹理特征提取, 并将提取的纹理特征与对应的置信度图进行融合。最后, 通过构建多个损失函数, 反复训练对抗网络, 得到增强的水下图像。实验结果表明, 增强的水下图像色彩鲜明并且对比度提升, 评价指标 UCIQE 均值为 0.639 9, NIQE 均值为 3.727 3。相比于其他算法有显著优势, 证明了该算法的良好效果。

关键词: 深度学习; 生成对抗网络; 多输入融合; 编码解码框架; 水下图像增强
中图分类号: TP391 **文献标志码:** A **DOI:** 10.3788/IRLA20200015

Multi-input fusion adversarial network for underwater image enhancement

Lin Sen^{1,2,3}, Liu Shibben¹, Tang Yandong^{2,3}

- (1. Electronic and Information Engineering School, Liaoning Technical University, Huludao 125105, China;
2. State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;
3. Institutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110016, China)

Abstract: For underwater image of low contrast, color deviation and blurred details and other issues, the multi-input fusion adversarial networks was proposed to enhance underwater images. The main feature of this method was that the generative network used encoding and decoding structure, filtering noise through convolution layer, recovering lost details through deconvolution layer and refining the image pixel by pixel. Firstly, the original image was preprocessed to obtain two types of images: color correction and contrast enhancement. Secondly, the confidence graph of the difference between the two enhanced images and the original image was learned by using the generated network. Then, in order to reduce artifacts and details blur introduced by the two enhancement algorithms in the process of generating network learning, the texture extraction unit was added to extract texture features from the two enhanced images, and the extracted texture features were fused with the corresponding confidence map. Finally, the enhanced underwater image was obtained by constructing multiple loss functions

收稿日期: 2020-02-14; 修订日期: 2020-03-05

基金项目: 国家自然科学基金 (61473280, 91648118); 辽宁省自然科学基金面上项目 (2015020100); 辽宁省教育厅科研项目 (LJ2019JL022)

作者简介: 林森 (1980-), 男, 副教授, 博士后, 主要从事图像处理、机器视觉、模式识别等方面的研究。Email: lin_sen6@126.com

and training the adversarial network repeatedly. The experimental results show that the enhanced underwater image has bright color and improved contrast, the average value of UCIQE and NIQE is 0.639 9 and 3.727 3 respectively. Compared with other algorithms, the algorithm has significant advantages and proves its good effect.

Key words: deep learning; generative adversarial network; multi-input fusion; encoding and decoding structure; underwater image enhancement

0 引言

随着国家大力提倡人工智能产业的发展,水下机器人被广泛使用在深海勘探等方面。由于悬浮的散射颗粒对光场的吸收和散射作用导致水下图像出现对比度低、颜色偏差和细节模糊等问题^[1],使得水下机器人无法获取高质量的水下清晰图像,因此水下图像增强成为一个非常重要的处理步骤。

近年来,一些研究者尝试利用深度学习技术改善图像质量问题,并在图像去雾^[2]等方面得到广泛应用。Fabbri 等^[3]提出水下生成对抗网络(Underwater Generative Adversarial Networks, UGAN),生成器使用了类似于编解码框架,而判别器通过对输出进行 L 约束,能较好地提升水下图像质量。针对水下图像存在细节模糊和颜色失真问题,Guo 等^[4]介绍了一种多尺度密集块(Multiscale Dense Block, MSDB)算法进行水下图像增强,即密集生成对抗网络(Dense Generative Adversarial Networks, DensGAN),在 MSDB 中,输入的特征需通过两个分支,并且特征会在两个分支中间进行串联之后再次反馈到各自支路中,判别器类似于 PatchGAN^[5](Patch Generative Adversarial Networks)。Ye 等^[6]提出了一种堆叠条件生成对抗网络的水下图像增强(Underwater Image Enhancement Based On Stacked Generative Adversarial Networks, UIE-sGAN),包括雾度检测子网和色彩校正子网,雾度检测子网的输出是雾度掩膜(Haze mask),并将雾度掩膜和 RGB 图像作为颜色校正子网的输入,并输出颜色校正的水下图像。

上述算法是单分支或多分支网络进行水下图像增强,能有效地进行水下图像颜色校正,但是都是单输入图像,不能同时对多个退化特征有效地进行增强。而文中针对对比度低、颜色偏差和细节模糊等问题,提出基于多输入融合对抗网络的水下图像增强(Underwater Image Enhancement Base On Multi-Input

Fusion Adversarial Network, MFGAN),算法主要有以下特点:(1)以生成对抗网络为基本框架,并利用生成网络学习同一图像的不同特征增强之间的置信度图,还引入了两个纹理提取单元进行纹理特征提取,通过融合操作,获得清晰图像。此外,为提高网络的鲁棒性,构建了多损失函数。(2)在 MFGAN 的残差连接中加入一层卷积层,通过对比实验证明其结构更有效地学习细节特征。(3)构建了从水下退化图像到清晰图像的端到端映射,不依赖于任何水下成像模型和先验知识,适用性更强。通过主观和客观评价两方面表明 MFGAN 与其他经典及新颖算法相比,处理后的图像色彩鲜明和对比度提升。

1 理论模型

1.1 预处理

梁天全等^[7]通过改进暗通道方法对水下图像进行复原,取得比较好的结果。而文中利用暗通道先验^[8](Dark Channel Prior, DCP)进行预处理,初步获取色彩鲜明、对比度高的水下图像,为 MFGAN 提供不同特征增强的水下图像。首先利用 DCP 对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(White Balance, WB)和基于加权分布的自适应伽马校正(Adaptive Gamma Correction With Weighted Distribution, AGCWD),获得颜色鲜明和高对比度的水下图像,上述算法过程分别简称为 DCP_WB, DCP_AGCWD。DCP_WB 能有效地恢复原始图像的色彩信息,如图 1(b)所示。DCP_AGCWD 用于水下图像




图 1 预处理图

Fig.1 Preprocessing graph

的对比度提升效果良好,如图 1(c) 所示,图 1(a) 为原始图像。上述预处理只能进行单个特征增强,不能进行多个特征增强,需把预处理图像输入到 MFGAN 中进行训练,得到色彩鲜明而且视觉效果得到显著提升的水下图像。

1.2 卷积

卷积层由一系列卷积滤波器组成,在输入的特征图上执行卷积运算,每个卷积层的输出如公式 (1) 所示:

$$f^{l+1} = \text{ReLU}(f^l * k^{l+1} + b^{l+1}) \quad (1)$$

式中: f^{l+1} 、 f^l 分别代表第 l 层和 $l+1$ 层对应的特征图; k^{l+1} 为卷积核的大小; b^{l+1} 为偏差, $\text{ReLU}()$ 为修正线性单元。卷积层输出的特征图大小计算如公式 (2) 所示:

$$O = \frac{i+2*p+k}{s} + 1 \quad (2)$$

式中: O 为输出特征图的大小; i 为输入特征图的大小; k 为卷积核大小; p 为补零填充; s 为步长 (图 2 中 $i=6, k=3, p=1, s=1$)。从图 2 的 Conv 可以看出,卷积是特征图多对一的映射关系,通过这种映射关系可以对图像噪声进行过滤。为保持图像大小不变,在卷积操作过程中对特征图进行“补零填充”,如图 2 中的 Conv 虚线所示。Conv 表示卷积,Deconv 表示反卷积,通过级联卷积和激活函数,使原始低质量图像滤除噪声,进而被增强。




图 2 卷积和反卷积

Fig.2 Convolution and deconvolution

1.3 反卷积

在图像检测^[9]中,利用反卷积从上采样过程中获取密集的特征图,在此,MFGAN 利用反卷积运算恢复卷积运算过程中丢失的细节特征。如图 2 中的 Deconv 所示,反卷积运算是一对多映射关系,与卷积

运算的多对一映射相反,但是一对多映射操作使特征映射图比原特征图更大,因此需要减去特征图的边缘以保持大小一致,如图 2 中 Deconv 中的虚线所示。

1.4 网络结构图

MFGAN 的网络结构主要分为两部分,第一部分是生成网络,目的是学习两种增强图像与原始图像之间差异的置信度图,输出分别为 C_{WB} 、 C_{AGCWD} 。第二部分是判别网络,用来区分生成网络生成的图像和目标图像,驱使生成图像更接近目标图像。为减少 DCP_WB 和 DCP_AGCWD 算法引入的伪影和细节模糊,添加两个纹理提取单元进行纹理特征提取,输出分别为 D_{WB} 、 D_{AGCWD} 。其次生成网络输出的置信度图 (C_{WB} 和 C_{AGCWD}) 与纹理提取单元输出的纹理特征 (D_{WB} 和 D_{AGCWD}) 进行融合,获得生成图像。最后生成图像和目标图像输入到判别网络,计算两者之间的偏差,进而把偏差返回到生成网络的各个卷积层,不断更新网络参数,最终获得色彩鲜明和对比度提升的水下图像。网络结构如图 3 所示。

在图 3 中, BN(Batch Normalization) 表示批量归一化, $3*3$ 、16、1 分别表示卷积核大小、卷积核数量、步长。Concat 表示在维度上进行连接。生成网络的输入从右到左依次是原始图、DCP_WB 和 DCP_AGCWD 图像。从上到下,第一个纹理提取单元输入是原始图像和 DCP_WB 图像,第二个纹理提取单元输入是原始图像和 DCP_AGCWD 图像。

在卷积运算之前应用非线性激活函数可以使像素点更集中于某个区域,减少过拟合现象。MFGAN 的生成网络中使用激活函数 (ReLU) 以添加非线性因子的形式来补偿线性模型,使网络在深度模型中更好地学习其映射关系。将有无 ReLU 函数 (图 3 中红色标注为 ReLU 函数) 进行对比实验。如图 4 所示,第一行是原始图像,第二行是无 ReLU 函数处理之后的图像,第三行是有 ReLU 函数得到的结果图,第四行为蓝色框的局部放大子图。

从图 4 中看出无 ReLU 函数得到的结果图对比度提升,但是出现红色伪影,如图 4 中 Image3 的蓝色框区域和局部放大子图。ReLU 函数获得的结果图色彩鲜明和对比度提升,则 ReLU 函数在 MFGAN 中能有效地恢复水下图像更多的特征信息。

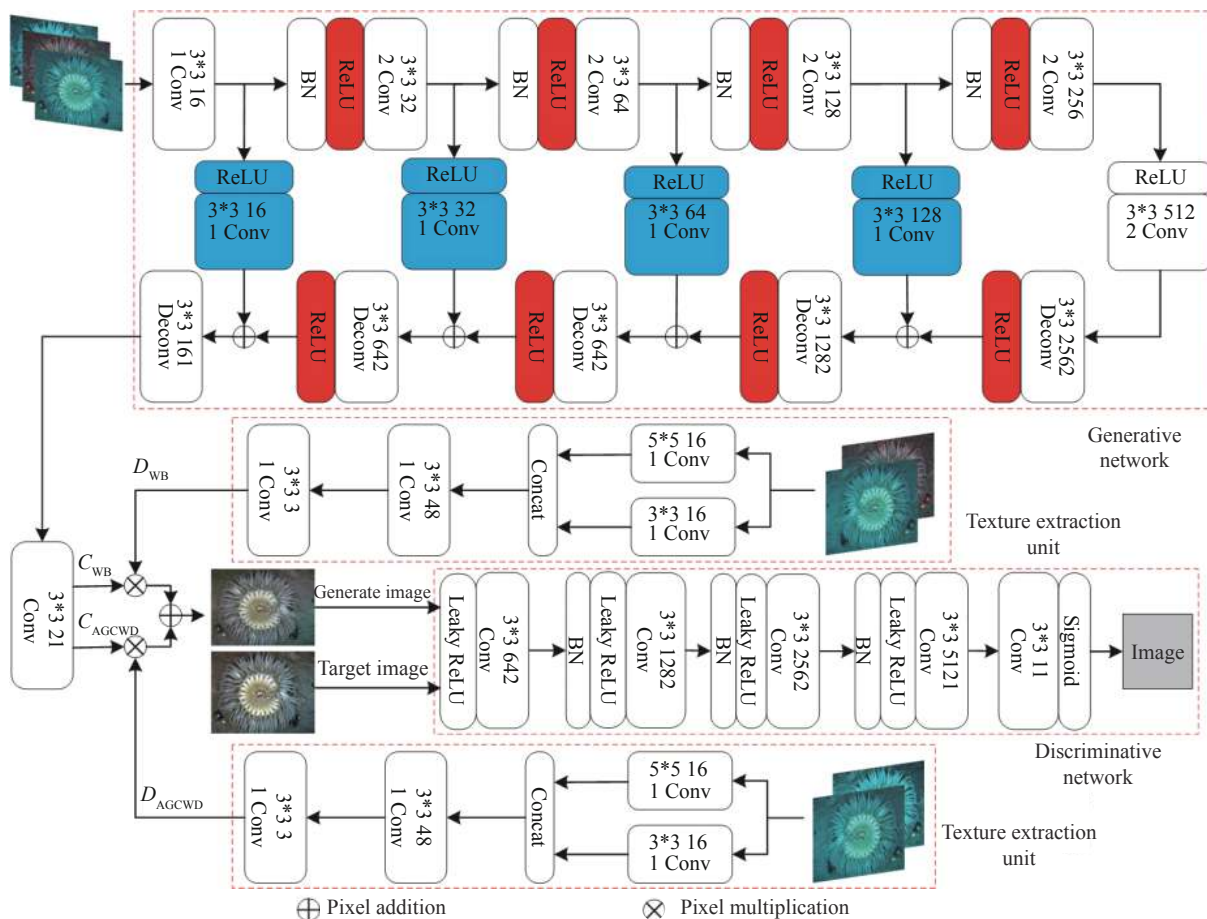


图 3 网络结构图

Fig.3 Network structure diagram




图 4 ReLU 对比实验

Fig.4 ReLU comparison experiment

1.5 残差连接

残差连接^[10](Skip Connection)首次提出是解决梯

度消失/梯度爆炸问题,提高了深度网络的速度和准确性。在 MFGAN 的生成网络中,引入残差连接避免低层次特征丢失,使细节纹理信息在解码过程中得到保护,因为低层次的卷积层可以捕获输入图像的细节信息,并有利于反卷积层的特征恢复。同时,它也加快网络的训练过程。

此外,为反卷积层更好地获得输入图像的细节特征,在残差连接中加入了卷积层,连接方式如图 3 蓝色标注区域所示。为证明其合理性,将不加入残差连接,残差连接中不使用卷积层和使用一层卷积层进行图像对比实验,如图 (5) 残差连接实验所示。

从图 5 可以看出无残差连接获得的图像对比度较低和颜色不均衡,如 Image2 和 Image3。加入残差连接获得的图像对比度提升,但是细节特征不突出,如 Image2。红色框所示,跳跃连接和一层卷积层获得图像的对比度提升和细节特征更加突出,且更符合视觉效果。

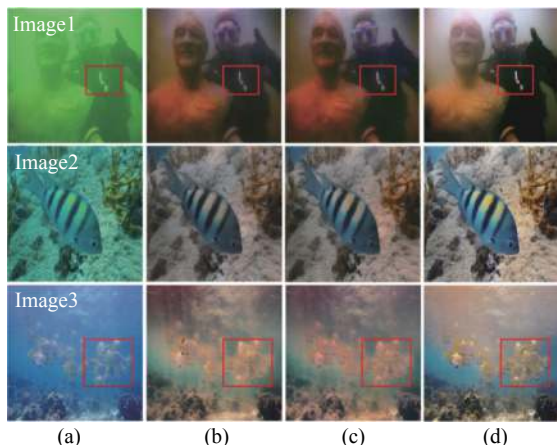


图 5 残差连接实验。(a) 原图; (b) 无残差连接; (c) 残差连接; (d) 残差连接和一层卷积层

Fig.5 Skip connection experiment. (a) Original drawing; (b) No residual connection; (c) Residual connection; (d) Residual connection and one layer of convolution

2 网络模型

2.1 生成网络

为了获得色彩鲜明, 细节特征突出的图像, 利用生成网络学习原始图像与 DCP_WB 图像, 原始图像与 DCP_AGCWD 图像之间差异的置信度图。由图 3 的生成网络可见, 生成网络中的卷积层和反卷积层是对称的, 类似于对称的编解码器结构。卷积层能滤除噪声并保留关键的水下图像细节, 但是卷积运算无法恢复低质量的图像, 因此在去噪后引入反卷积层对特征进行细化, 并在卷积层和反卷积层加入残差连接, 使低层次特征在反卷积过程中得到保护。为减少 DCP_WB 和 DCP_AGCWD 算法引入的伪影和细节模糊, 加入两个纹理提取单元进行纹理特征提取, 且网络结构相同。在损失函数之前, 使两个子网络的输出 (D_{WB} 和 D_{AGCWD}) 与生成网络输出的两个置信度图 (C_{WB} 和 C_{AGCWD}) 进行融合, 获得细节特征突出、色彩鲜明和对比度提升的融合图像。最终融合图像如公式 (3) 所示:

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

\otimes 表示相乘; $+$ 表示像素点相加; I 为增强图像。

2.2 判别网络

MFGAN 的判别网络采用五个卷积层, 类似于 70×70 的马尔科夫判别器 (PatchGAN)^[5]。如图 3 中判别网络所示, 判别网络加入 Leaky Relu 函数, 相对于

ReLU 函数, 避免负值输入的梯度为零, 进而解决部分神经元不学习的问题, 更充分地学习图像特征, Leaky Relu 函数如公式 (4) 所示:

$$f(x) = \begin{cases} x & x \geq 0 \\ ax & x < 0 \end{cases} \quad (4)$$

式中: a 为 0.2。

判别网络输出是长和宽为 30 的图像, 输入为生成网络生成的图像和目标图像, 如果两者某个区域差别较小, 则输出图像的对应像素点的值接近于 1, 反之接近于 0。其优点是输出图像的每一个像素点对应于输入图像的一个局部感受野, 进而判断输入图像局部感受野之间的差别, 而不是整幅图像之间的差别, 减少了人为干扰因素。最后一层使用 Sigmoid 函数, 将输出每个像素点的范围映射到 $[0, 1]$, 有利于判别网络鉴别生成图像和目标图像在某个区域的真假, Sigmoid 函数如公式 (5) 所示:

$$y(x) = \frac{e^{-x}}{(1 + e^{-x})^2} \quad (5)$$

2.3 损失函数

对抗网络的训练过程就是交替优化生成网络和判别网络的过程, 对抗网络的损失函数如公式 (6) 所示:

$$L_{GAN} = E(y)[\log(D(y))] + E(x)[\log(1 - D(G(x)))] \quad (6)$$

式中: D 为判别器; G 为生成器; x 为水下退化图像; y 为水下目标图像; E 为数学期望。在训练过程中, 为防止梯度消失, 对判别网络更新一次再对生成网络更新一次, 如此反复进行更新, 当判别网络不能鉴别生成图像和目标图像的区别时, 则为动态平衡, 进而获得了清晰的水下图像。

如参考文献 [5] 中所述, $L1$ 损失函数和对抗损失函数联合使用可以减少输出图像中的人为干扰因素, 则目标图像 y 和生成网络生成的图像 $G(x)$ 的 $L1$ 损失函数如公式 (7) 所示:

$$L_1 = E(x, y)[\|y - G(x)\|_1] \quad (7)$$

通过感知损失函数进行水下图像的特征重建, 感知损失函数定义如公式 (8) 所示:

$$L_{VGG} = \frac{1}{CWH} \sum_{c=1}^C \sum_{w=1}^W \sum_{h=1}^H \|V(G(x)^{c,w,h}) - V(y^{c,w,h})\|_2^2 \quad (8)$$

式中: C 、 W 、 H 分别表示图像的通道、宽度和高度;

V 表示经过 VGG-19 网络的 Conv4_3 层进行的非线性转换。

MFGAN 使用多个损失函数进行网络的学习, 有利于网络参数更快的收敛, 提高网络的鲁棒性。目标函数利用对抗损失 (L_{GAN})、感知损失 (L_{VGG}) 和 $L1$ 损失函数进行线性叠加。目标函数如公式 (9) 所示:

$$L = \lambda_1 * L_{GAN} + \lambda_2 * L_{VGG} + \lambda_3 * L_1 \quad (9)$$

式中: $\lambda_1, \lambda_2, \lambda_3$ 表示常数, 设置为 2, 5, 60。

3 实验结果与分析

为验证 MFGAN 的鲁棒性和有效性, 将 MFGAN 与其他典型算法 (包括基于深度学习和传统算法) 进行实验对比, 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 MFGAN 在水下图像增强方面具有很强的实用性。

3.1 数据集和训练

利用水下生成对抗网络 (Underwater Generative adversarial network, UGAN)^[3] 进行训练获得 6 128 张水下图像, 对 6 128 张图像进行筛选, 获得 6 000 张图像作为 MFGAN 的数据集。MFGAN 中的输入是长和宽为 256 的 RGB 图像, 优化器为 Adam, 学习率为 0.000 2, 批量大小 (batchsize) 为 4, 时期 (epoch) 为 60。

3.2 主观评价

通过颜色恢复试验来验证 MFGAN 算法在水下图像颜色校正方面的有效性, 该实验基于无失真色卡因水下成像环境复杂而产生色偏, 通过对退化的色卡图像进行处理, 可有效地验证 MFGAN 的颜色恢复效果。将 MFGAN 与基于 $L_{a\beta}$ 颜色空间的水下颜色校正 (LAB)、水下图像增强深度网络 (Deep Underwater Image Enhancement Network, DUIENet)^[11]、暗通道先验 (DCP)^[8]、去雾网络结合混合小波与方向滤波器组 (DehazeNet and HWD)^[12] 进行对比, 实验结果如图 6 所示。

从图 6 中可以看出, LAB 算法处理后的色卡图像整体偏暗, 颜色信息不明确, 而 DehazeNet and HWD 的对比度明显提高, 但是各相同色系颜色区分度降低。DCP 处理后的色卡图像颜色块不均匀, 整体偏蓝, 与真实的色卡颜色不符合。DUIENet 的色卡图像整体偏暗和偏红色, 且色卡图像中出现红色伪影。MFGAN 的色卡图像色彩鲜明, 不同色系颜色可清晰

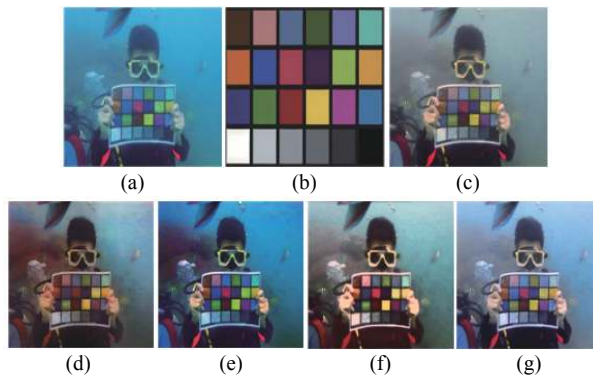


图 6 颜色恢复试验。(a) Original; (b) 标准颜色卡; (c) LAB; (d) DUIENet; (e) DCP; (f) DehazeNet and HWD; (g) MFGAN

Fig.6 Experimental of color restoration. (a) Origanl; (b) Standard color card; (c) LAB; (d) DUIENet; (e) DCP; (f) DehazeNet and HWD; (g) MFGAN

区分, 且相近色系如蓝色与紫色等颜色对比度增强, 增强的色卡图像颜色与真实色卡接近。

进一步验证水下图像的颜色校正和清晰度恢复效果, 对 6 幅不同环境的水下图像进行实验。将 MFGAN 与传统的经典算法以及最新的深度学习方法进行分析比较, 如图 7 所示。

从图 7 可以看出, DCP 算法对恢复水下退化图像清晰度方面效果很差, 如 Image4 和 Image5, 由于缺少颜色校正处理, 进行颜色校正基本无效。DehazeNet and HWD 算法有效地解决色偏问题, 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。在 Image3 中, 限制对比度自适应直方图均衡化 (Contrast-limited Adaptive Histogram Equalization, CLAHE) 算法处理之后整体偏绿, 细节纹理特征比较清晰, DCP 和 UGAN 算法的去雾效果良好, 但是颜色恢复效果比较差, MFGAN 算法在颜色校正和去雾两个方面均表现较好, 比较符合视觉效果。DUIENet 算法在清晰度恢复能力差, 如 Image4, 而该算法在颜色恢复上取得不错效果, 如 Image5。UGAN 与文中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, 文中算法在颜色信息校正 (如 Image1) 和去雾 (如 Image3) 更具有优势。

从图 7 的 Image4 中红色框的部分可以看出, 针对远景区域的图像去模糊和颜色校正的效果, MFGAN、DUIENet 和 UGAN 对偏绿图像进行颜色校正效果更好更彻底。Image2 红框部分, DCP、CLAHE




图 7 实验结果图。(a) Original; (b) DCP; (c) LAB; (d) CLAHE; (e) DehazeNet and HWD; (f) DUIENet; (g) UGAN; (h) MFGAN
 Fig.7 Experimental result . (a) Original; (b) DCP; (c) LAB; (d) CLAHE; (e) DehazeNet and HWD; (f) DUIENet; (g) UGAN; (h) MFGAN

和 MFGAN 对远距离纹理特征恢复更好。相比之下, MFGAN 算法增强后的图像颜色更加自然、对比度更高和细节特征更突出。

3.3 客观评价

为了更客观地评价和分析所提出算法的性能,进一步采用加速稳健特征^[13]进行特征点匹配测试,水下彩色图像质量评价综合指标 (Underwater Color Image Quality Evaluation, UC IQE)^[14]和自然图像质量评价指标 (Natural Image Quality Evaluator, NIQE)^[15]进行质量测评。

采用加速稳健特征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,验证算法在后续特征匹配过程中的应用效果,进而评估算法性能。一般情况下,图像清晰度越高,特征点匹配数目越多,在后续特征提取等过程中应用效果越好。DCP^[8]、

CLAHE、DUIENet^[11]和 MFGAN 进行特征点匹配实验,测试效果如图 8 所示,每幅图的左上角为特征点匹配数,红色为最优值。在相同特征相似度阈值条件下, MFGAN 相比其他算法,处理后的水下图像能匹配出更多的特征点,则 MFGAN 在后续特征匹配过程应用效果良好。

UC IQE 代表水下图像色度、饱和度和对比度的综合指标, UC IQE 值越高代表图像具有更好的视觉质量。UC IQE 计算如公式 (10) 所示:

$$UC IQE = c_1 \times \sigma_c + c_2 \times con_l + c_3 \times \mu_s \quad (10)$$

式中: σ_c 为色度的标准差; con_l 代表亮度的对比度; μ_s 为饱和度的平均值; c_1, c_2, c_3 为加权系数。表 1 对图 7 的 UC IQE 评价指标结果,加粗字体为算法的最优值。

Image1 经 UGAN 算法处理之后,因水体颜色信息恢复不彻底,导致色度、饱和度指标较高,影响了




图 8 特征匹配实验结果

Fig.8 Experimental results of feature matching

表 1 UCIQE 评价指标结果

Tab.1 Quantitative results in terms of UCIQE

Image	DCP	LAB	CLAHE	DehazeNet and HWD	DUIENet	UGAN	MFGAN
1	0.676 2	0.600 8	0.645 5	0.669 7	0.630 3	0.690 6	0.676 6
2	0.636 3	0.576 9	0.615 8	0.613 8	0.577 2	0.619 6	0.641 0
3	0.595 1	0.466 6	0.461 6	0.546 9	0.441 2	0.561 6	0.637 7
4	0.598 5	0.569 9	0.605 1	0.653 3	0.566 8	0.601 5	0.624 1
5	0.590 3	0.546 8	0.577 7	0.580 7	0.593 8	0.577 7	0.624 4
6	0.638 8	0.568 5	0.592 6	0.639 1	0.568 1	0.592 6	0.640 3
Average	0.622 5	0.554 9	0.583 1	0.617 2	0.562 9	0.607 3	0.639 9

UCIQE 指标的结果。经 DehazeNet and HWD 算法处理后的 Image4, 因过度曝光使得处理后的图像色彩过于鲜明, 导致其 UCIQE 值较高, 表 1 数据表明, MFGAN 在测试图像中整体表现出较高的 UCIQE 值, 尤其是针对偏蓝和偏绿的图像, 如 Image5 和 Image6, 相比于对比算法能更好地平衡色度、饱和度 and 对比度, 且颜色信息恢复自然, 具有较高的清晰度。

NIQE 满足水下图像无参考的特点, 利用待评价的图像特征模型参数与预先建立的模型参数之间的

距离来确定图像质量, 便可得到主观评价分数。NIQE 与图像的自然性存在着负相关, 值越小时, 图像越接近自然状态。NIQE 的计算如公式 (11) 所示:

$$D(v_1, v_2, \Sigma_1, \Sigma_2) = \sqrt{((v_1 - v_2)^T \left(\frac{\Sigma_1 + \Sigma_2}{2} \right)^{-1} (v_1 - v_2))} \quad (11)$$

式中: v_1, v_2 分别表示自然图像和处理图像的均值向量; Σ_1, Σ_2 分别表示自然图像 MVG 模型和处理图像 MVG 模型的协方差。表 2 为图 8 的 NIQE 评价指标结果,

表 2 NIQE 评价指标结果

Tab.2 Quantitative results in terms of NIQE

Image	DCP	LAB	CLAHE	DehazeNet and HWD	DUIENet	UGAN	MFGAN
1	3.559 5	3.850 2	3.909 8	4.715 6	4.700 6	4.663 0	3.614 4
2	3.581 4	3.547 5	3.411 6	4.873 4	4.901 1	3.525 3	3.442 2
3	6.457 1	6.047 4	5.804 9	8.510 4	6.034 8	3.327 0	4.548 6
4	3.585 5	3.712 1	3.875 2	3.993 4	4.150 3	4.562 4	3.359 9
5	4.050 1	4.065 9	3.904 6	3.868 5	4.507 8	5.097 9	3.745 3
6	3.226 1	3.400 2	3.497 2	3.580 7	3.061 8	5.546 0	3.455 4
Average	4.076 6	4.058 9	4.067 2	4.923 6	4.559 4	4.453 6	3.727 3

加粗字体为最优值。

Image1 经 DCP 处理后的 NIQE 的值比较低,但是颜色恢复效果不明显,对水体偏蓝图像作用效果较小。经 CLAHE 处理后的 Image2, UCIQE 的值不是很高,表明色彩信息恢复不准确,对比度低,然而从图 7 可以看出,CLAHE 处理之后的 Image2 更符合视觉效果,因此有较高的 NIQE 值。Image3 经 UGAN 处理后,整体偏白,色彩信息恢复不自然,导致 NIQE 的值偏低。经 DUIENet 处理后的 Image6,饱和度和对比度较低,具有较低的 UCIQE 值,但是更符合训练好的模型参数,进而获得更小的 NIQE 值。MFGAN 在测试图像中整体表现出较低的 NIQE 值,相比于其他算法更接近与自然状态。

4 结 论

针对水下图像颜色失真、雾化和低对比度等问题,设计了基于多输入融合对抗网络的水下图像增强。MFGAN 主要由一个生成网络和一个判别网络组成。生成网络主要负责合成水下清晰图像,判别网络的作用是不断驱动生成网络合成与参考图像在视觉上相同的图像。其次,为了网络更好学习图像的特征,利用多个子网络对同幅图像不同的增强特征进行学习,对应输出相乘相加。最后,构建了多损失函数,提高网络的鲁棒性,利用生成网络与判别网络进行相互交替训练。实验结果表明,相比于对比算法,MFGAN 的 UCIQE 平均值为 0.639 9, NIQE 平均值为 3.727 3,特征点匹配平均高 5-10 个匹配点,证明了 MFGAN 能恢复出更多的细节信息,适用于在不同类型的水下退化图像。在未来的工作将考虑水下成像模型与网络训练相结合,对水下退化图像进行复原。

参考文献:

- [1] Hu Haofeng, Li Xiaobo, Liu Tiegeng. The latest development of underwater image restoration technology based on polarization imaging [J]. *Infrared and Laser Engineering*, 2019, 48(6): 0603006. (in Chinese)
- [2] Chen Qingjiang, Zhang Xue. Application of hybrid residual learning and guided filtering algorithm in image defogging [J]. *Optical Precision Engineering*, 2019, 27(12): 2702-2712. (in Chinese)
- [3] Cameron Fabbri, Md Jahidul Islam, Junaed Sattar. Enhancing underwater imagery using generative adversarial networks[C]//IEEE International Conference on Robotics and Automation(ICRA), 2018: 7159-7165.
- [4] Guo Yecai, Li Hanyu, Zhuang Peixian. Under-water image enhancement using a multiscale dense generative adversarial network [J]. *IEEE Journal of Oceanic Engineering*, 2019-2911447.
- [5] Li Chuan, Michael Wand. Precomputed real-time texture synthesis with markovian generative adversarial networks[C]//European Conference on Computer Vision Springer, 2016: 702-716.
- [6] Ye Xinchun, Xu Hongcan, Ji Ming, et al. Underwater image enhancement using stacked generative adversarial networks[C]//Pacific Rim Conference on Multimedia, 2018: 514-524.
- [7] Liang Tianquan, Zhang Xiaoyun, Duan Peng, et al. Target detection of underwater strong scattering medium by improved dark channel method [J]. *Infrared and Laser Engineering*, 2020, 49(2): 0203012. (in Chinese)
- [8] He Kaiming, Sun Jian, Fellow, et al. Single image haze removal using dark channel prior [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2011, 33(12): 2341-2353.
- [9] Wang Chunzhe, An Junshe, Jiang Xiujie, et al. Candidate region optimization algorithm based on convolutional neural network [J]. *Chinese Optics*, 2019, 12(6): 1348-1361. (in Chinese)
- [10] Long Jonathan, Shelhamer Evan, Darrell Trevor. Fully convolutional networks for semantic segmentation[C]// IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2015, 3434-3440.
- [11] Li Chongyi, Guo Chunle Wenqi Ren, et al. An underwater image enhancement benchmark dataset and beyond [J]. *IEEE Transactions on Image Processing*, 2020, 29: 4376-4389.
- [12] Pan Panwang, Fei Yuan, Cheng En. Underwater image de-scattering and enhancing using dehazenet and hwd [J]. *Journal of Marine Science and Technology*, 2018, 26(4): 531-540.
- [13] Miao Yang, Sowmya Arcot. An underwater color image quality evaluation metric [J]. *IEEE Transactions on Image Processing*, 2015, 24(12): 6062-6071.
- [14] Mittal Anish, Rajiv Soundararajan, Alan C Bovik, et al. Making a "completely blind" image quality analyzer [J]. *IEEE Signal Processing Letters*, 2013, 20(3): 209-212.
- [15] Dai Chenggang, Lin Mingxing, Wang Zhen, et al. Color compensation based on bright channel and fusion for underwater image enhancement [J]. *Acta Optica Sinica*, 2018, 38: 1110003. (in Chinese)