

基于生成对抗网络的深海图像增强算法^{*}

郭银辉 张春堂 樊春玲

(青岛科技大学自动化与电子工程学院 青岛 266061)

摘要: 在复杂的深海环境中提高图像的质量和可视化效果对水下科学研究和工程应用具有重要意义。针对深海特殊环境导致深海数据集稀缺,以及深海图像存在的色彩失真、对比度低等问题本文构建了一个成对的深海图像数据集 DSIEB,并在此基础上提出了一种结合 DC 注意力和 MSDR 多尺度密集残差的生成对抗网络 DM-GAN 算法。首先,在网络跳跃连接部分构建 DC 双重通道注意力机制,用于加强通道间联系,提取图像细节纹理特征。其次,在生成器结构中嵌入 MSDR 多尺度密集残差块,提高对局部信息的关注和特征重用能力。最后,重构新的损失函数,引入平滑保真度 SF 损失,从多个角度引导网络学习原始图像到目标图像的映射。通过自建数据集 DSIEB 上进行实验验证,并与 7 种先进水下图像增强算法进行对比实验,实验结果表明本文所提算法具有更强的泛化能力,适应于多样性的深海图像。

关键词: 深海图像增强;生成对抗网络;DC 双重通道注意力机制;MSDR 多尺度密集残差块;SF 损失

中图分类号: TN98 **文献标识码:** A **国家标准学科分类代码:** 520.60

Deep-sea image enhancement algorithm based on generative adversarial network

Guo Yinhui Zhang Chuntang Fan Chunling

(College of Automation and Electronic Engineering, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: Improving image quality and visualization in complex deep-sea environments is of great importance for underwater scientific research and engineering applications. In order to solve the problems of scarcity of deep-sea datasets caused by the special environment of the deep-sea, as well as the problems of color distortion and low contrast of deep-sea images, a paired deep-sea image dataset DSIEB was created, and on this basis a generative adversarial DM-GAN was built algorithm proposed for networks combining DC attention and MSDR multi-scale dense residuals. First, the DC dual-channel attention mechanism is built in the network hopping connection part to strengthen the connection between channels and extract the texture features of image details. Second, the MSDR multi-scale residual block is embedded in the generator structure to improve the attention is on local information and the ability to reuse features. Finally, a new loss function is reconstructed and the smoothing fidelity SF loss is introduced to guide the network to learn the mapping from the original image to the target image from multiple perspectives. Experiments are carried out on the self-built dataset DSIEB, and compared with seven advanced underwater image enhancement algorithms. The experimental results show that the proposed algorithm has stronger generalization ability and is suitable for various deep-sea images.

Keywords: deep-sea image enhancement; generative adversarial network; DC dual-channel attention mechanism; MSDR multi-scale dense residual block; SF loss

0 引言

随着海洋资源的开发和利用,高质量的深海图像为探索海洋生物、勘探海底地貌、监测海洋环境等^[1]提供重要保

障。由于海水对光的吸收,光强度会发生减弱,其中对红光衰减最严重,因此深海图像通常呈现蓝绿色调^[2]。并且海水是一种混合介质,水中漂浮着大量悬浮杂质和浮游生物,使光在水中发生折射和散射作用,导致拍摄的深海图像存

在细节模糊、雾化等问题^[3]。这些问题对于深海图像拼接、目标识别和目标检测的进一步研究造成了严重影响。因此,对低质量的深海图像进行增强具有重要的意义。

目前,水下图像增强算法可以分为基于物理模型、基于非物理模型和基于深度学习三类。基于物理模型^[4]的典型算法有红色通道、水下暗通道、最小信息等算法,它们依赖于模型的先验算法,通常对特定的水下环境和成像条件具有一定的敏感性。基于非物理模型的典型算法有直方图均衡化^[5]、白平衡以及像素分布调整^[6]等算法,需要大量的训练数据来建立模型和学习规律,且对训练的数据具有依赖性。而基于深度学习的水下图像增强算法^[7],可以通过神经网络实现对复杂非线性系统的端到端建模,从而提高感知图像的质量。近年来,基于深度学习的生成对抗网络被广泛应用于图像增强领域,通过博弈思想,推动生成器和鉴别器的相互学习和优化,使生成的图像细节纹理更加清晰。因此本文选用生成对抗网络作为深海图像增强的网络基础模型。

Islam 等^[8]基于 C-GAN 提出一种全卷积 FUnIE-GAN 算法,通过循环一致损失函数,实现非成对图像之间的训练,由于采用无监督训练,该模型增强后的图像存在少许失真或伪影等问题。Wu 等^[9]结合通道注意力机制提出 FW-GAN 算法,并在生成器网络中引入多个非物理模型分支进行多特征提取,但该网络依赖于水下先验知识,同时需要大量数据和计算资源。Qian 等^[10]结合多尺度特征提取和密集残差连接提出 DRGAN 算法,利用不同尺度的卷积核大小提取纹理和全局信息,通过残差连接提高特征利用率确保图像完整性,对明亮部分进行增强后出现过曝光现象。Bakht 等^[11]在基于 U-Net 结构的生成器模块中,通过引入空间通道双重注意力提出了 MuLA-GAN 算法,将残差块

和注意力机制相结合更大程度聚焦细节信息,对色偏严重的图像增强后仍存在模糊等问题。针对以上问题,本文提出了一种基于 GAN 的 DM-GAN 深海图像增强算法,该算法能够有效地捕捉图像上下文信息,使生成的图像色彩更真实、细节纹理更清晰。本文做了以下工作:

1) 针对深海图像数据稀缺以及难以获取正常光照下的参考图像等问题,本文从主观和客观两方面进行研究,构建了一个深海图像基准数据集 DSIEB (deep-sea image enhancement dataset)。

2) 提出 DM-GAN 深海图像增强网络,设计 DC (dual-channel attention) 双重通道注意力机制和 MSDR (multi-scale dense residual block) 多尺度密集残差块并引入到以 U-Net^[12] 为骨架的生成器上,使生成器更好地提取图像的细节纹理特征。

3) 重构损失函数,提出平滑保真度 SF (smooth fidelity) 新的损失函数,来减少图像中的噪声和更好地保留图像的结构特征。将 SF 损失与感知损失和对抗损失线性结合,使网络生成的图像更加接近目标图像。

1 DM-GAN 网络模型

DM-GAN 网络模型包括:以 U-Net 为骨干构成生成器网络模块;基于 Patch-GAN^[13] 鉴别器模块;重构损失函数模块。首先将原始深海图像输入到生成器中进行特征提取,然后鉴别器对生成的图像进行真伪鉴别,最后通过对损失函数不断更新和优化,提高生成样本的质量和鉴别样本的准确性。这种优化策略可以使生成对抗网络逐步收敛到一个平衡状态,来生成更真实的深海图像。DM-GAN 网络结构如图 1 所示。

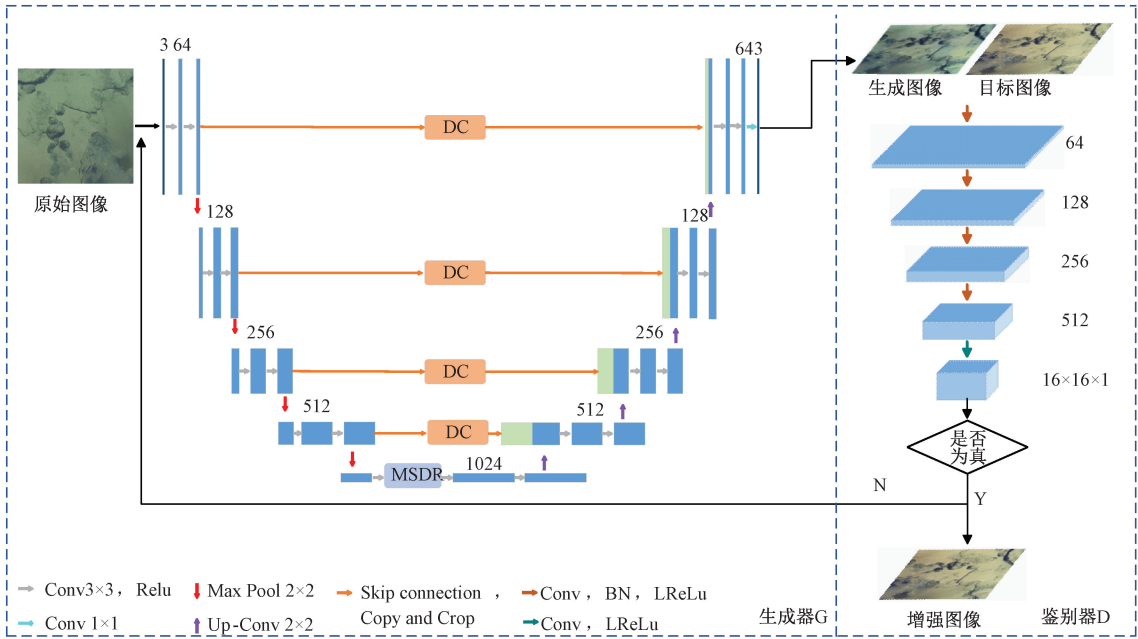


图 1 DM-GAN 网络模型结构
Fig. 1 DM-GAN network model structure

1.1 DC 双重通道注意力机制

文献[9]将通道注意力融入生成器网络解码部分,用于学习先前特征之间的相关性,但是忽略了像素之间的位置信息,增强后的图像仍存在蓝绿色偏现象。文献[11]将通道注意力和空间注意力并行连接设计了 SCA 模块,并将其融入解码部分,利用空间注意力提供信息位置,通道注意力调节不同通道间特征的权重,使细节纹理特征更加明显。为了捕获长距离通道之间的信息加强通道间信息依

赖关系,本文构建了 DC 双重通道注意力机制,并将其融入到 U-Net 网络的跳跃连接部分。DC 双重通道注意力机制如图 2 所示,分为上下两个分支,上半部分引入平均池化和最大池化,在通道间用来聚合特征映射的空间信息,更好地捕捉图像的纹理和背景信息^[14]。下半部分为 SE (squeeze and excitation) 模块,用来自适应地学习通道权重来增强有用的特征通道。通过两部分互补性学习,使网络更加聚焦于深海原始图像的细节纹理、色彩等信息。




图 2 DC 双重通道注意力机制

Fig. 2 DC dual-channel attention mechanism

1.2 MSDR 多尺度密集残差块

随着网络深度的增加,低级信息逐渐消失。受文献[10]和 DenseNet 启示,采用不同尺度卷积核可以充分提取空间特征在一定程度上避免浅层细节丢失,密集连接方式可以促进网络各层之间的数据传输改善特征重用能力,残差网络则让深层更专注浅层信息地学习防止模型退化。为了更好地提取深海图像的全局和局部信息,本文将多尺度特征提取和密集残差相结合设计了 MSDR

多尺度密集残差块,并将其引入到生成器网络的底层。MSDR 网络结构如图 3 所示,首先将通道数平分 4 个子集,分别采用卷积核大小为 1×1 、 3×3 、 5×5 、 7×7 来获取多尺度的感受野,然后采用特征映射的方法,使得每层卷积层能够接受并融合来自前一层的多尺度特征信息,获得不同的感受野,有助于特征重用,减少图像特征丢失。同时采用残差模块有助于缓解梯度分散问题,使训练更快^[15]。




图 3 MSDR 多尺度密集残差模块

Fig. 3 Multi-scale dense residual module of MSDR

1.3 鉴别器 D

鉴别器 D 采用 Patch-GAN 网络架构,其输出是一个 $N \times N$ 的矩阵,将矩阵的均值用来判断图像为真实图像的概率,不仅考虑整个图像的一致性,还关注图像的局部细节。从图 1 可以看出,鉴别器 D 是由 4 个全卷积层构成,通道数分别为 64、128、256 和 512,用来逐层提取图像的特征信息。与全局鉴别器相比,局部鉴别器需要的参数更少、效率更快。

1.4 重构损失函数

由于原网络增强后的深海图像存在阴影部分明显、像素点不平滑等问题,本文进一步对损失函数进行改进和重

构,设计了平滑保真度 SF 损失。整个网络的损失函数由感知损失、对抗损失、SF 损失三部分组成,从多个角度来引导 DM-GAN 学习原始图像到目标图像的映射关系。

1) 感知损失

感知损失用于限制生成器生成的图像与其对应的目标图像之间的特征提取距离,使用 VGG 感知损失函数可以减少网络在编码解码过程中造成的高频特征丢失。感知损失公式如下:

$$L_{con} = \frac{1}{C_j H_j W_j} \|\varphi(I^C) - \varphi(I^D)\|_2^2 \quad (1)$$

式中: I^C 表示目标图像, I^D 表示经过生成器生成的图像,

$C_j H_j W_j$ 指第 j 层特征图的尺寸大小, φ 是 VGG19 网络提取的高级语义信息。

2) 对抗损失

对抗损失不仅能对网络训练过程进行优化,而且引导生成器生成更加真实的深海图像,提高鉴别器鉴别真伪的能力,确保生成图像和目标图像具有相同的风格。对抗损失函数如下:

$$L_{adv}(D, G) = E_{x \sim p(x)} [\log D(x)] + E_{z \sim p(z)} [\log(1 - D(G(z)))] \quad (2)$$

式中: $L_{adv}(D, G)$ 是生成器和鉴别器不断更新优化的结果, G 为生成器网络, D 为鉴别器网络, E 表示数学期望, x 指的是输入图像, z 代表噪声。

3) SF 损失

为减少像素点之间的差异和保留图像边缘信息的完整性,避免增强后的图像出现曝光、模糊等现象, SF 损失从图像去模糊和增强细节两方面出发。一方面通过计算网络输出图像和真实图像之间绝对差值的平均值,来减少图像中噪声和模糊,但会导致图像的边缘过于平滑,丢失部分信息;另一方面通过度量图像中相邻像素之间的差异,对图像进行平滑操作,保留图像的结构特征和边缘信息。将两者按一定的权重进行分配组合。SF 损失函数公式如下:

$$L_{SF} = \lambda_1 E(x, y) [\|I^C - G(I^D)\|_1] + \lambda_2 \frac{1}{CHW} \|\nabla_x K w(I^s) + \nabla_y K w(I^s)\| \quad (3)$$

式中: x 表示是输入图像, y 为输出图像, C 、 H 和 W 表示生成图像 $K w(I^s)$ 的维度, ∇_x 和 ∇_y 分别表示 x 方向和 y 方向的梯度,通过对网络的不断学习,最终确定 $\lambda_1 = \lambda_2 = 0.5$ 。

网络总损失为三者的线性组合,公式如下:

$$L_{total} = L_{adv} + L_{con} + L_{SF} \quad (4)$$

2 评价指标与数据集

2.1 评价指标

水下图像评价指标的作用在于评估和比较水下图像的质量、清晰度和可见性,为水下图像的采集、处理和分析提供了重要的参考和指导。目前,水下图像评价指标主要分为主观和客观两种类型,在实际应用中,通常将主观和客观评价指标结合使用,以全面评估水下图像的质量。

主观评价是从人类视觉观察角度来评估增强后的图像质量和视觉效果,与人的感知相一致,直观且准确。客观评价通过分析计算图像的特征和属性,以准确、可量化的方式来评估图像的质量,避免主观因素对图像评价的影响,从而提高评价结果的客观性和可信度。

本文选取全参考峰值信噪比 PSNR、结构相似性 SSIM 和无参考信息熵 IE、水下图像质量评价指标 UIQM、水下彩色图像质量评价指标 UCIQE 来评价目标图像和网络输

出图片的质量。PSNR 是一种可视误差,取决于原始图像与生成图像对应像素间的差异。SSIM 从亮度、对比度、结构 3 个方面,对图像相似性进行评估。IE 是描述水下图像颜色丰富度的平均信息数,反映了图像信息的丰富性。UCIQE 是用来定量评价水下图像非均于的色偏、模糊和低对比度的情况。UIQM 根据水下图像的退化机理与成像特点,从色彩、清晰度和对比度三方面评估图像质量。以上 5 个评价指标的值越大,代表图像质量越高。

2.2 自建数据集

由于水下地理环境的复杂性以及光照不均等因素的影响,使得水下数据集稀缺。目前,常用的水下数据集(EUVP、UFO-120、UIEBD 等)都是浅海类数据集,而本文所使用的数据集来源深海拍摄的图像,图像存在能见度低、色偏严重、细节模糊等问题。由于一种复原或增强算法不能适用于所有水下场景,且深度学习算法的通用性较差,本文通过去雾算法 DCP^[16]、传统增强算法(CLAHE^[17]、RGHS^[18]、BLOT^[19]、PSO^[20]、IBLA^[21]、ULAP^[22])以及商业应用(Dive+)对原始图像进行复原,生成 8 种参考图像。

邀请 6 位志愿者对生成的 8 种参考图像进行选择,将 6 位志愿者 3 人一队分成两组,两组志愿者并行选取图像。首先,从 8 种方法生成的参考图像中随机抽取两张与原始图像作为第一轮对比,如图 4 所示。志愿者从中挑选较为符合视觉效果的进行下一轮的比较。经过 7 次对比直到选出最佳图像。当两组志愿者选出来的目标图像不一致时,将两张图像进行客观评价指标运算,得分高者作为最终目标图像,由此构建了一个包含 1 000 对的深海数据集 DSIEB。目标图像的选取过程如图 5 所示。




图 4 原始图像和两种参考图像的对比图

Fig. 4 Comparison of the original image and the two reference images

从定量的角度进行评价,本文从 8 种算法生成的参考图像中挑选出最佳图像,作为深海数据集 DSIEB 的目标图像,从表 1 中可以看出,在 5 种客观评价指标中,目标图像 PSNR 指标仅次于 PSO 算法,这可能与 PSNR 本身有关,PSNR 是一种基于误差敏感的图像质量评价指标,在选取目标图像时会出现评价结果与人的主观视觉不一致的情况,SSIM 和无参考指标都相对突出。

经过定性定量的选取和评价,从 DSIEB 数据集中选取了 4 张原始图像和与之对应的 4 张目标图像,如图 6 所示。

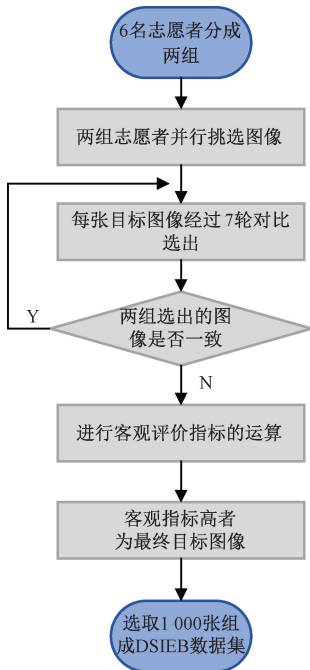


图 5 目标图像的选取方式

Fig. 5 Selection method of target image

表 1 不同算法生成的参考图像与选取目标图像质量评价结果

Table 1 Reference images and selected target images generated by different algorithms quality evaluation results

图像来源	PSNR	SSIM	IE	UIQM	UCIQE
DCP	14.322	0.728	5.887	2.022	0.694
CLAHE	19.667	0.657	6.510	2.833	0.504
RGHS	13.335	0.554	7.504	2.779	0.753
BLOT	16.830	0.840	6.264	2.786	0.439
PSO	20.090	0.854	5.876	2.243	0.457
IBLA	16.778	0.733	6.838	2.598	0.737
ULAP	16.148	0.834	6.426	2.613	0.548
Dive+	16.520	0.576	6.676	2.795	0.523
目标图像	19.767	0.878	7.712	3.130	0.767

3 实验环境与实验结果及分析

3.1 实验环境

实验环境为 Windows 11 64 位操作系统, GPU 为 NVIDIA GeForce RTX 3070 Ti Laptop, 15.7 GB 内存, 基于 Pytorch 深度学习框架, 使用 Python3.6 语言编写程序。DSIEB 数据集包含 1 000 对深海图像, 其中(训练集: 验证集): 测试集=(9:1):1。采用 Adam 优化器, Batch size 为 4, 学习率设为 0.000 3。

3.2 消融实验

为了更好地验证 DC 双重通道注意力机制、MSDR 多




图 6 DSIEB 数据集中的原始图像和目标图像

Fig. 6 Raw and target images in the DSIEB dataset

尺度密集残差块和 SF 损失函数的效果, 本文从数据集中选取 3 张低光照、低饱和度且存在阴影的图像来进行消融实验。在原始生成对抗网络上添加 DC 注意力作为改进方法一; 添加 DC 注意力、MSDR 多尺度残差块作为改进方法二; 在方法二的基础上添加 SF 损失函数作为改进方法三。3 类方法均在测试集上进行消融实验, 且在相同的配置下进行训练。消融实验结果如图 7 所示, 可以看出原始网络增强后的图像存在阴影部分加深、色偏严重等问题。

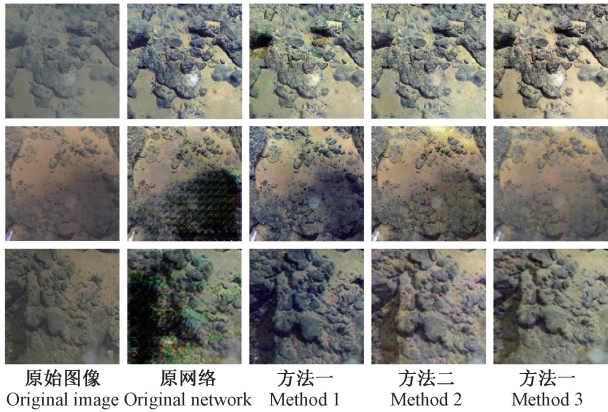


图 7 消融实验对比结果

Fig. 7 Comparison results of ablation experiments

方法一添加 DC 注意力后, 图像阴影部分像素点变得平滑, 色偏依旧明显。方法二淡化了阴影, 改善了图像的亮度和色偏。方法三进一步淡化了阴影和校正了色偏, 减少图像中存在的噪声。为了进一步验证添加 3 个模块的有效性, 对其进行定量的分析, 3 种方法在测试数据集上的平均值如表 2 所示。

通过消融实验可以看出每添加一种方法, 图像的质量指标都有所上升, 方法三所展示的数据即本文算法, UCIQE、UIQM、IE、SSIM、PSNR 五种指标都排列第一, 分别为 0.612、3.482、7.513、0.816、19.658, 分别比原始网络提高了 16.3%、3.33%、0.89%、13.6%、5.70%。

3.3 DM-GAN 网络结果评价

为了验证本文 DM-GAN 算法对深海图像增强的有效性, 选取 DSIEB 数据集 4 种代表性图像, 如图 8 所示。图 8

表 2 消融实验图像质量评价结果

Table 2 Image quality evaluation results of ablation experiments

方法	DC	MSDR	SF	无参考			全参考	
				UCIQE	UIQM	IE	SSIM	PSNR
原网络	×	×	×	0.512	3.366	7.446	0.705	18.537
方法一	✓	×	×	0.569	3.425	7.458	0.725	18.769
方法二	✓	✓	×	0.596	3.460	7.472	0.782	19.354
方法三	✓	✓	✓	0.612	3.482	7.513	0.816	19.658




图 8 不同算法对原始图像增强后的结果比较

Fig. 8 Comparison of the results of different algorithms after enhancing the original image

第 1 列为 DSIEB 数据集中原始图像,从上到下分别代表图像对比度和色温低一类、细节纹理特征丰富一类、图像颜色偏绿一类和图像颜色偏蓝一类。将本文所提算法与经典算法 FUnIE-GAN^[8]、Shallow-UWnet^[23]、UGAN^[24]和最新算法 MMLE^[25]、FW-GAN^[9]、DRGAN^[10]、MuLA-GAN^[11]生成的图像之间进行主观对比。

通过图 8 可以看出,FUnIE-GAN 算法会加重图像存在的阴影部分,对对比度低的图像增强效果较好。Shallow-UWnet 算法成功改善了图像的色偏问题,由于网络模型的深度较浅,导致增强后的图像对比度和色彩饱和度较低,丢失部分颜色特征。UGAN 算法对蓝绿色偏图像增强后,图像呈现过饱和现象。MMLE 算法有效纠正蓝绿色偏,对色彩饱和度低的图像增强后效果不明显。FW-GAN 算法对偏蓝图像增强后会使图像边缘出现过蓝现象,偏绿图像增强后呈现过饱和状态,导致颜色失真。

DRGAN 算法可以有效地去除蓝绿色偏,但对明亮部分增强后出现过饱和现象,整体存在饱和度低的问题。MuLA-GAN 算法会加重阴影部分,增强后图像边缘仍存在蓝绿色偏。相比之下,本文算法可以有效地解决上述算法出现的问题,具有较强的泛化能力。

为进一步验证本文算法的有效性,采用 PSNR、SSIM、IE、UCIQE、UIQM 五种客观评价指标对各算法生成的图像进行定量评价,表 3 和 4 分别是 4 类代表性图像的无参考和全参考指标,表明选取的 4 类代表性图像在主客观评价上均表现突出。表 5 为在测试数据集上 7 类算法的平均指标,可以看出,本文 DM-GAN 算法增强后的图像在 UCIQE、IE、SSIM 和 PSNR 指标得分上最高,分别为 0.612、7.513、0.816 和 19.658,分别比第二名提高了 2.45%、2.29%、2.82% 和 0.77%,UIQM 指标得分次之。

表 3 不同算法生成的图像无参考质量评价结果

Table 3 The images generated by different algorithms have no reference quality evaluation results

方法	图 8 第 1 行			图 8 第 2 行			图 8 第 3 行			图 8 第 4 行		
	UCIQE	UIQM	IE	UCIQE	UIQM	IE	UCIQE	UIQM	IE	UCIQE	UIQM	IE
FUnIE-GAN	0.650	3.452	7.469	0.490	3.466	6.368	0.610	3.421	7.241	0.504	3.408	6.607
Shallow-UWnet	0.469	3.222	6.402	0.360	2.704	4.949	0.382	2.746	5.698	0.538	2.508	5.417
UGAN	0.674	3.441	7.659	0.522	3.480	6.148	0.602	3.402	7.129	0.514	3.380	6.258
MMLE	0.481	2.980	6.830	0.563	3.307	6.824	0.571	2.891	6.835	0.578	3.439	7.268
FW-GAN	0.623	3.473	7.510	0.503	3.239	6.288	0.582	3.388	6.901	0.482	2.730	6.174
DRGAN	0.508	3.286	6.749	0.468	2.884	5.560	0.579	3.200	7.206	0.497	3.101	6.507
MuLA-GAN	0.662	3.409	7.571	0.590	3.628	7.427	0.563	3.243	6.209	0.520	3.530	7.306
DM-GAN	0.689	3.505	7.692	0.583	3.592	7.407	0.631	3.412	7.476	0.577	3.450	7.477

表 4 不同算法生成的图像全参考质量评价结果

Table 4 The results of image full reference quality evaluation generated by different algorithms

方法	图 8 第 1 行		图 8 第 2 行		图 8 第 3 行		图 8 第 4 行	
	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR
FUnIE-GAN	0.610	17.799	0.680	20.849	0.771	19.582	0.741	19.293
Shallow-UWnet	0.724	19.243	0.625	19.443	0.724	19.347	0.646	19.273
UGAN	0.646	13.574	0.650	17.743	0.765	18.359	0.725	18.916
MMLE	0.637	15.910	0.730	19.752	0.629	18.086	0.805	20.400
FW-GAN	0.788	21.036	0.667	17.503	0.592	17.385	0.672	18.090
DRGAN	0.683	17.820	0.649	18.092	0.774	19.601	0.640	18.352
MuLA-GAN	0.774	19.319	0.762	21.598	0.672	18.180	0.783	19.302
DM-GAN	0.781	20.465	0.794	21.465	0.801	20.575	0.815	20.347

表 5 在测试数据集上各算法的平均指标

Table 5 Average metrics of each algorithm on the test dataset

方法	平均指标				
	UCIQE	UIQM	IE	SSIM	PSNR
FUnIE-GAN	0.580	3.331	6.821	0.682	18.681
Shallow-UWnet	0.396	2.815	5.617	0.736	18.368
UGAN	0.580	3.327	6.759	0.655	16.758
MMLE	0.532	3.172	6.741	0.691	18.507
FW-GAN	0.510	3.097	6.618	0.661	18.490
DRGAN	0.525	3.308	6.661	0.675	18.261
MuLA-GAN	0.597	3.507	7.341	0.793	19.507
DM-GAN	0.612	3.482	7.513	0.816	19.658

4 结 论

针对深海图像数据集稀缺的问题,本文构建了一个深海图像基准数据集 DSIEB,包含 1 000 对原始图像和目标图像。在此基础上结合生成对抗网络提出了 DM-GAN 网

络模型,在以 U-Net 为骨干的生成器模块上设计并引入 DC 注意力和 MSDR 多尺度密集残差块,并重构了损失函数。实现了深海图像的增强,有效地解决了原始图像存在的对比度低、颜色失真等问题。

实验结果表明,本文提出的 DM-GAN 模型与现有方

法相比,在主观和客观评价上均表现良好,在 UCIQE、IE、SSIM 和 PSNR 指标上得分最高,分别为 0.612、7.513、0.816 和 19.658,分别比第二名提高了 2.45%、2.29%、2.82%和 0.77%,UIQM 指标得分第二。表明了本文算法对低质量深海图像增强的优越性。下一步将对增强后的图像应用于拼接算法,通过将多个子块按照相同的重叠区域进行拼接,从而形成一个完整的大组合,以实现对深海地貌场景的重构。

参考文献

- [1] ZHOU Z Y, LIU J C, YU J Z. A survey of underwater multirobot systems [J]. IEEE/CAA Journal of Automatica Sinica, 2021, 9(1): 1-18.
- [2] 王海涛,林森,陶志勇. 双注意力机制与改进 U-Net 的水下图像增强[J]. 电子测量技术, 2023, 46(1): 181-187.
WANG H T, LIN S, TAO ZH Y. Underwater image enhancement based on dual attention mechanism and improved U-Net [J]. Electronic measurement technology, 2023, 46(1): 181-187.
- [3] 周新,张春堂,樊春玲. 基于 YOLOv5_PGS 的轻量级水下生物识别目标检测[J]. 电子测量技术, 2023, 46(21): 168-175.
ZHOU X, ZHANG CH T, FAN CH L. Lightweight YOLOv5 _ PGS based objective detection for underwater biological identification [J]. Electronic Measurement Technology, 2023, 46(21): 168-175.
- [4] BERMAN D, LEVY D, AVIDAN S, et al. Underwater single image color restoration using haze-lines and a new quantitative dataset [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 43(8): 2822-2837.
- [5] ULUTAS G, USTUBIOGLU B. Underwater image enhancement using contrast limited adaptive histogram equalization and layered difference representation[J]. Multimedia Tools and Applications, 2021, 80(10): 15067-15091.
- [6] ZHANG W, ZHUANG P, SUN H H, et al. Underwater image enhancement via minimal color loss and locally adaptive contrast enhancement[J]. IEEE Transactions on Image Processing, 2022, 31: 3997-4010.
- [7] JIE H, JIAN Z, LIN W, et al. FE-GAN: Fast and efficient underwater image enhancement model based on conditional GAN[J]. Electronics, 2023, 12(5): 1227-1227.
- [8] ISLAM M J, XIA Y Y, SATTAR J. Fast underwater image enhancement for improved visual perception[J]. IEEE Robotics and Automation Letters, 2020, 5(2): 3227-3234.
- [9] WU J, LIU X, LU Q, et al. FW-GAN: Underwater image enhancement using generative adversarial network with multi-scale fusion [J]. Signal Processing, Image Communication: A Publication of the European Association for Signal Processing, 2022.
- [10] QIAN J, LI H, ZHANG B, et al. DRGAN: Dense residual generative adversarial network for image enhancement in an underwater autonomous driving device[J]. Sensors, 2023, 23(19): 8297.
- [11] BAKHT A, JIA Z, DIN M, et al. MuLA-GAN: Multi-level attention GAN for enhanced underwater visibility [J]. ArXiv preprint arXiv: 2312.15633v1, 2023.
- [12] WANG Z, ZHANG K, YANG Z, et al. Underwater image enhancement based on improved u-net convolutional neural network [C]. 2023 IEEE 18th Conference on Industrial Electronics and Applications (ICIEA). IEEE, 2023: 1902-1908.
- [13] ZHANG J, PAN D, ZHANG K, et al. Underwater single-image restoration based on modified generative adversarial net [J]. Signal, Image and Video Processing, 2023, 17(4): 1153-1160.
- [14] QIN X, WANG Z L, BAI Y C, et al. FFA-net: feature fusion attention network for single image dehazing[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 11908-11915.
- [15] GUO Y, LI H, ZHUANG P. Underwater image enhance ment using a multiscale dense generative adversarial network [J]. IEEE Journal of Oceanic Engineering, 2020, 45(3): 862-870.
- [16] DREWS P L J, NASCIMENTO E R, BOTELHO S S C, et al. Underwater depth estimation and image restoration based on single images[J]. IEEE computer graphics and applications, 2016, 36(2): 24-35.
- [17] ZHANG W, ZHUANG P, SUN H H, et al. Underwater image enhancement via minimal color loss and locally adaptive contrast enhancement[J]. IEEE Transactions on Image Processing, 2022, 31: 3997-4010.
- [18] ALMAHAIRI A, RAJESHWAR S, SORDONI A, et al. Augmented cycleGAN: Learning many-to-many mappings from unpaired data [C]. International Conference on Machine Learning, 2018: 195-204.
- [19] SONG W, WANG Y, HUANG D, et al. Enhancement of underwater images with statistical model of background light and optimization of transmission map [J]. IEEE Transactions on

- Broadcasting, 2020, 66(1): 153-169.
- [20] AZMI K Z M, GHANI A S A, YUSOF Z M, et al. Natural-based underwater image color enhancement through fusion of swarm-intelligence algorithm [J]. Applied Soft Computing, 2019, 85: 105810.
- [21] PENG Y T, COSMAN P C. Underwater image restoration based on image blurriness and light absorption [J]. IEEE Transactions on Image Processing, 2017, 26(4): 1579-1594.
- [22] SONG W, WANG Y, HUANG D, et al. A rapid scene depth estimation model based on underwater light attenuation prior for underwater image restoration[C]. Advances in Multimedia Information Processing-PCM, 2018: 19th Pacific-Rim Conference on Multimedia, 2018: 678-688.
- [23] NAIK A, SWARNAKAR A, MITTAL K. Shallow-uwnet: Compressed model for underwater image enhancement(student abstract) [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(18): 15853-15854.
- [24] FABBRI C, ISLAM M J, SATTAR J, et al. Enhancing underwater imagery using generative adversarial networks [C]. IEEE International Conference on Robotics and Automation (ICRA), 2018: 7159-7165.
- [25] ZHANG W, ZHUANG P, SUN H H, et al. Underwater image enhancement via minimal color loss locally adaptive contrast enhancement [J]. IEEE Transactions on Image Processing, 2022, 31: 3997-4010.

作者简介

郭银辉,硕士研究生,主要研究方向为信息检测与处理。

E-mail:gyh19990108@163.com

张春堂(通信作者),副教授,硕士生导师,主要研究方向为深度学习、图像处理、模式识别、检测技术与智能装置。

E-mail:zct1999@163.com

樊春玲,博士,教授,硕士生导师,主要研究方向为图像信息处理技术和多相流传感系统与流体流动。

E-mail:chunlingfan@qust.edu.cn