DOI:10.3969/j.issn.2096-8248.2024.03.008

基于多路特征的改进生成对抗网络水下图像增强算法*

赵雪峰,陈荣军,王宇翔,仲兆满

(江苏海洋大学 计算机工程学院,江苏 连云港　222005)

摘　要:针对水下图像颜色偏差、细节模糊以及对比度低等问题,提出多路特征增强生成对抗网络进行水下图像增强算法。首先,为实现对水下图像的色彩平衡,通过构建蓝绿通道与红色通道之间的衰减矩阵,设计红色通道补偿算法。其次,分别搭建生成网络和判别网络。为获得不同层次特征信息,生成网络由不同深度的特征提取网络组成,并搭建特征增强模块,并行增强多路特征,提高特征的质量。同时,为提高网络细节增强能力,搭建多尺度判别网络,对生成图像进行判别。最后,构建多个损失函数优化网络参数,提高网络鲁棒性。实验结果表明,增强图像相较原始图像色彩更加丰富,对比度较高。与现有的算法相比,该方法能够有效恢复水下图像的真实色彩和纹理细节,显著提高水下图像质量。

关键词:水下图像增强;生成对抗网络;衰减矩阵;特征增强

中图分类号:TP391.41　　**文献标志码**:A　　**文章编号**:2096-8248(2024)03-0062-08

引用格式:赵雪峰,陈荣军,王宇翔,等.基于多路特征的改进生成对抗网络水下图像增强算法[J].江苏海洋大学学报(自然科学版),2024,33(3):62-69.

Improved Generative Adversarial Network Underwater Image Enhancement Algorithm Based on Multi-channel Features

ZHAO Xuefeng, CHEN Rongjun, WANG Yuxiang, ZHONG Zhaoman

(School of Computer Engineering, Jiangsu Ocean University, Lianyungang 222005, China)

Abstract: To address issues such as color deviation, blurry details, and contrast in underwater images, a multi-channel feature enhancement generative adversarial network is proposed for underwater image enhancement algorithms. Firstly, to achieve color balance in underwater images, a red channel compensation algorithm is designed by constructing an attenuation matrix between the blue-green channel and the red channel. Secondly, a generative network and a discriminative network is built separately. To obtain feature information at different levels, the generative network is composed of feature extraction networks of different depths, and a feature enhancement module is built to enhance multiple features in parallel and improve the quality of the features. At the same time, in order to improve the network's ability to enhance details, a multi-scale discriminative network is built to discriminate the generated images. Finally, multiple loss functions are constructed to optimize network parameters and improve network robustness. The experimental results show that the enhanced image has richer colors and higher contrast compared to the original image. Compared with existing algorithms, this method can effectively restore the true color and texture details of underwater images, significantly improving the quality of underwater images.

* **收稿日期**:2023-10-12;**修订日期**:2024-03-13

基金项目:国家自然科学基金资助项目(72174079);江苏省"青蓝工程"优秀教学团队项目(2022-29)

作者简介:赵雪峰(1976—),男,四川西充人,副教授,博士,研究方向为机器视觉、自然语言处理,(E-mail)zhaoxf@jou.edu.cn。

Key words: underwater image enhancement; generative adversarial network; attenuation matrix; feature enhancement

0 引言

海洋是人类生存发展的重要物质基础,是高质量发展的战略要地。我国实施的“透明海洋”战略[1],已经成为海洋科技创新的一个重要方向,而水下观测是其中重要一环。但是大量水下漂浮颗粒使光在水中散射严重,导致水下图像往往存在对比度较低、细节模糊等问题,退化现象十分严重。因此,水下图像增强技术是我国海洋开发中的重要技术之一。

目前,深度学习在图像处理领域的应用愈加广泛,其强大的数据拟合能力,能够有效改善水下图像质量。Perez 等[2]首次提出基于 CNN 的水下图像增强方法,训练模糊图像和相应的清晰图像之间的映射。Wang 等[3]提出了 UIE-Net,包括颜色校正网络以及去雾网络,能够缓解水下图像的偏色现象。Anwar 等[4]提出了水下增强神经网络(underwater enhancement CNN,UWCNN)方法,该网络利用 10 种 Jerlov 水体类型的图像分别训练,泛化能力较强。但是,此类算法需要大量数据协助模型训练,大量数据的获取和标注限制了模型实际应用。自 GAN 提出以来,基于 GAN 的改进模型在图像生成领域应用愈加广泛[5]。由于 GAN 能够生成多样性、逼真性高的图像,有助于改善图像质量,在生成图像领域获得了良好的效果。Fabbri 等[6]提出的 UGAN(using generative adversarial network, UGAN),该算法的生成器使用了类似编码解码的框架,对生成器的输出进行 L 约束,能够较好地提升水下图像质量。Islam 等[7]提出的 FUnIE-GAN(fast underwater image enhancement)建立了一个基于图像的全局内容、局部纹理和风格信息的多任务目标函数训练模型,评估图像的感知质量,同时该模型通过循环一致性损失函数实现了非成对训练,但该模型对水下机器视觉感知的提升不稳定,鲁棒性不理想。Du 等[8]提出了 UW-CycleGAN 模型,通过在生成器中添加 DenseNet 块,保留更多特征图信息。Zong 等[9]提出了 Local-CycleGAN,结合局部判别器和全局判别器判别增强图像,提高模型的细节增强能力。

上述算法能够有效提高图像质量,但都是单路处理,而图像的增强过程是串行的,无法同时处理不同深度的特征信息,限制了模型的能力。因此,本文提出多路特征增强生成对抗网络(multi-channel feature enhancement generative adversarial network, MCFEGAN),其特点为:① 设计色彩平衡算法,处理水下图像的颜色通道;② 以 GAN 为基本框架,利用对称编码解码结构,构建不同深度的特征提取网络;③ 设计特征增强模块(feature enhancement module, FEM)提高网络并行处理特征信息的能力;④ 引入 Patch GAN 的判别网络结构,并连接不同尺度的输出,感知生成图像和真实图像的局部差异;⑤ 构建多个损失函数联合判别网络,加速网络收敛,协助网络学习水下退化图像到清晰图像的映射。通过定性以及定量分析,验证模型有效性。

1 多路特征增强生成对抗网络

1.1 色彩平衡

不同波长的光在水下的衰减程度不同,在水下图像中红色光的衰减最快,蓝绿光相对红光而言较慢,因此水下图像一般呈现偏绿、偏蓝的现象。为缓解该现象,提高网络对水下图像的色彩平衡效果,本文构建了颜色补偿公式。

首先,通过式(1)计算单一通道的像素总值 S_c,

$$S_c=\sum_{i=1}^{M}\sum_{j=1}^{N}I_c(i,j),c\in\{R,G,B\}。\quad(1)$$

式中:M 和 N 代表输入图像的空间分辨率;c 表示 R,G,B 3 个通道;$I_c(i,j)$表示 c 通道像素(i,j)的值。然后,通过式(2)计算单一通道的归一化平均值 Avg_c,

$$\mathrm{Avg}_c=\frac{1}{255\times MN}S_c,c\in\{R,G,B\}。\quad(2)$$

为了计算均衡化系数,通过式(3)计算所有通道的像素平均值 Avg,

$$\mathrm{Avg}=(\mathrm{Avg}_R+\mathrm{Avg}_G+\mathrm{Avg}_B)/3。\quad(3)$$

由于水下图像的红色通道衰减速度较其他通道快,简单采用与其他通道一样的颜色均衡化或修正会导致不自然的颜色重建,从而引起色彩失真问题,因此,此处仅对蓝绿色通道进行矫正。通过式(4)计算分别得到绿色、蓝色两个通道的均衡化系数 θ_c,

$$\theta_c=\frac{\mathrm{Avg}}{\mathrm{Avg}_c},c\in\{G,B\}。\quad(4)$$

式(5)乘以均衡化系数,对 G、B 通道分别进行均衡化处理,

$$I_c(i,j)'=\theta_c\times I_c(i,j),c\in\{G,B\}。\quad(5)$$

式中,$I_c(i,j)'$为颜色均衡化后的像素值。

最后,针对衰减过快的红光,计算蓝绿色通道与红色通道的差值占比,进行单独补偿。分别在红蓝色通道和红绿色通道之间构建衰减矩阵 $\boldsymbol{AM}$ (attenuation matrix),式(6)、式(7)计算衰减矩阵 $\boldsymbol{AM}_{GR}$ 和 $\boldsymbol{AM}_{BR}$,

$$\boldsymbol{AM}_{GR}=(I_G(i,j)-I_R(i,j))。\quad(6)$$

$$\boldsymbol{AM}_{BR}=(I_B(i,j)-I_R(i,j))。\quad(7)$$

根据式(6)、式(7)得到总衰减矩阵 $\boldsymbol{AM}$ 的计算式(8),

$$\boldsymbol{AM}=\boldsymbol{AM}_{GR}\times\frac{\mathrm{Avg}_G-\mathrm{Avg}_R}{(\mathrm{Avg}_G-\mathrm{Avg}_R)+(\mathrm{Avg}_B-\mathrm{Avg}_R)}+\boldsymbol{AM}_{BR}\times\frac{\mathrm{Avg}_B-\mathrm{Avg}_R}{(\mathrm{Avg}_G-\mathrm{Avg}_R)+(\mathrm{Avg}_B-\mathrm{Avg}_R)}。\quad(8)$$

比较 R,G,B 每个通道的总像素值,从大到小依次定义为最大颜色通道、中间颜色通道以及最小颜色通道。通过式(9)对红色通道进行矫正,

$$I_R(i,j)'=I_R(i,j)+\left(\frac{64\times\boldsymbol{AM}}{I_{\max}-I_{\min}}\right)。\quad(9)$$

式中,$I_{\min}$,$I_{\max}$ 分别表示最大颜色通道的最小值和最大值。

1.2　多路特征增强生成对抗网络模型结构设计

MCFEGAN 的结构主要由生成网络和判别网络组成。生成网络提取原始图像以及色彩平衡图像的特征信息,并引入 EM 对特征提取网络(feature extraction network,FEN)的输出进行增强,提高提取特征的质量;通过融合模块(fusion module,FM)融合多路增强特征,生成信息丰富、色彩鲜明的高质量图像。判别网络则用来区分输入图像和目标图像的差异,驱使网络生成图像更接近目标图像。将生成网络的输出和目标图像作为输入送入判别网络中,计算二者偏差,结合损失函数一起将偏差返回到生成网络各层以及各个 FEM,不断优化网络参数,提高网络增强水下图像的能力,最终生成色彩鲜明、信息丰富的高质量图像。网络整体结构如图 1 所示。

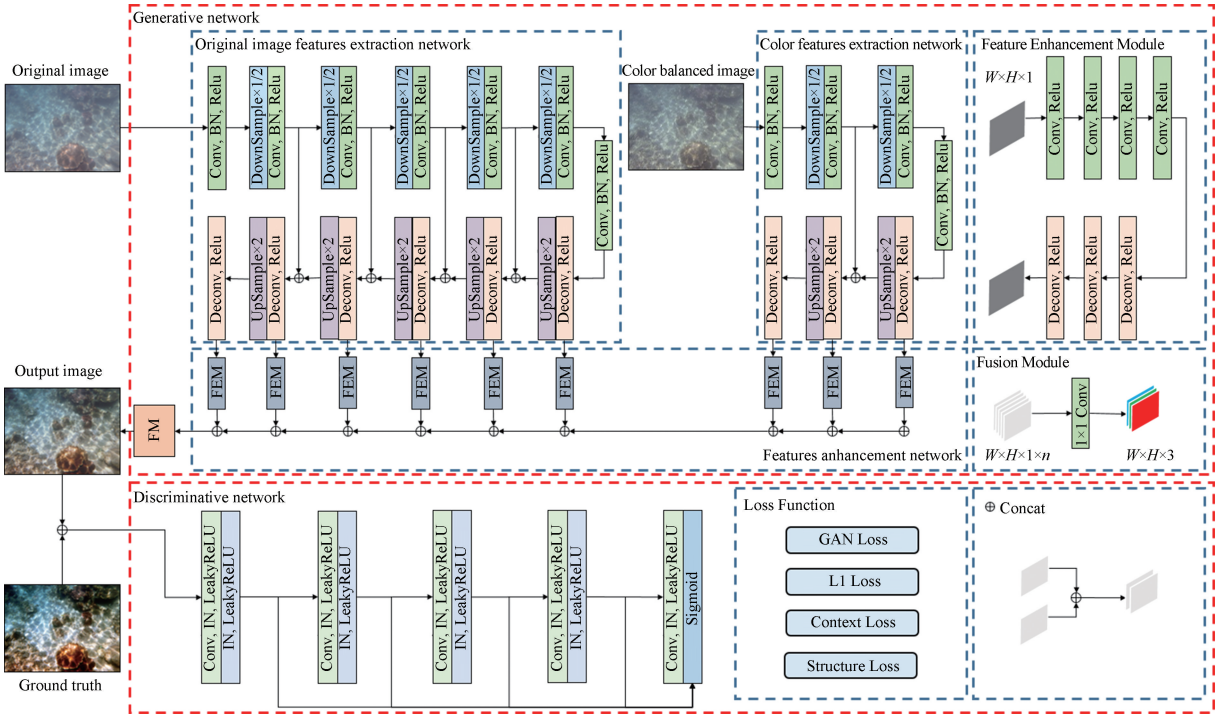


图 1　多路特征增强生成对抗网络

Fig. 1　Multi-channel feature enhanced generative adversarial network

1.2.1　生成网络模型　为了提取原始图像的更多细节特征,以及恢复图像更好的色彩效果,本文利用生成网络学习原始图像和色彩平衡图像不同深度的特征。由图 1 生成网络部分可见,针对两种图像需

要提取不同层次特征,构建不同深度的 FEN,该结构由卷积层与反卷积层构成,卷积层能够有效提取图像特征并对噪声进行滤除;然而,卷积操作会对图像进行平滑处理,从而导致部分细节信息的损失。因此,在设计网络架构时考虑特征提取和细节保留的平衡,在卷积后连接 BN(batch normalization)层以及 ReLU 激活函数。由于分布更接近 0 均值的输入,能够展现 ReLU 的单侧抑制作用,所以在网络搭建时,先接入 BN 层再送入 ReLU 激活函数。但是,卷积无法直接生成增强图像,为了提取高质量图像特征,构建了与之对应的反卷积层,对提取的特征进行细化、扩张,并通过 concat 拼接卷积层输出和对应反卷积层的输入,在挖掘图像深度特征信息的同时保留浅层特征。在网络中设计了 FEM 对多路反卷积层输出特征并行增强,改进模型的整体性能、增加模型容量和表达能力、增强鲁棒性等。为了针对性地处理图像不同的退化问题,提高不同层次的特征质量,所有 FEM 单独训练,相互间不共享网络参数。最终通过 FM 将多个增强后的特征进行融合生成增强图像。

1.2.2　判别网络模型　PatchGAN 是一种局部判别器,用于对输入图像的局部区域进行判别。为了提高图像增强过程中的细节处理能力,基于 PatchGAN 构建多尺度判别网络模型。首先,对于每个尺度的特征图,分别构建 PatchGAN 判别器,这些判别器将在不同尺度上对局部图像块进行判别;然后,将不同尺度判别器的输出进行连接,实现特征融合,从而获得更全面、细节更丰富的判别结果。在图 1 所示的判别网络部分,在每个尺度的判别器中应用 LeakyReLU 函数进行非线性化处理,以增强网络表达能力,该函数表示为

$$f(x)=\begin{cases}x, & x\geqslant 0;\\ ax, & x<0。\end{cases} \tag{10}$$

式中,a 设置为 0.2。相较于 ReLU 函数,该函数可以一定程度上保留负值信息,避免出现梯度为零的现象,解决了部分神经元学习不充分的问题,能够更加充分地学习图像特征。

水下环境瞬息万变,受此影响不同水下图像可能具有不同的风格、纹理和特征。由于 BN 在小批次内进行标准化可能会造成不同图像之间的信息混合,进而影响生成图像的多样性和风格,因此在判别网络中引入实例标准化(instance normalization,IN),该方法仅对单张图片的单个通道进行标准化操作,保证每个图像实例之间的独立性,能够更好地学习并保留每个图像的细节和风格特征,从而生成更真实、更准确的增强图像。通过式(11)和(12)计算 IN 的均值 μ_{ti} 以及方差 σ_{ti}^2,表示为

$$\mu_{ti}=\frac{1}{HW}\sum_{j=1}^{W}\sum_{k=1}^{H}\boldsymbol{x}_{tijk}, \tag{11}$$

$$\sigma_{ti}^2=\frac{1}{HW}\sum_{j=1}^{W}\sum_{k=1}^{H}(\boldsymbol{x}_{tijk}-ku_{ti})^2。 \tag{12}$$

式中:$\boldsymbol{x}_{tijk}$ 为输入图像;t 为图像的索引;i 为特征图索引;H 和 W 为输入图像的分辨率。

最终,IN 的计算公式表示为

$$\boldsymbol{y}_{tijk}=\frac{\boldsymbol{x}_{tijk}-\mu_{ti}}{\sqrt{\sigma_{ti}^2+\varepsilon}}。 \tag{13}$$

式中:$\boldsymbol{y}_{tijk}$ 为输出图像;ε 为分母修正项,一般设置为 0.000 01,其主要作用是保证数值稳定性。

为了在快速缩小图像的前提下保留更多信息,前 4 层均使用了尺寸为 4 的卷积核,并在卷积操作之后添加 IN 层和 LeakyReLU 激活函数来抑制梯度爆炸并加快训练速度。最后一层卷积层加入 Sigmoid 函数,对所有 PatchGAN 的输出进行综合判断,鉴别生成图像与目标图像对应区域的真假。

1.2.3　损失函数　GAN 在训练过程中,判别网络尝试最大化目标函数值,而生成网络需要使其最小,二者交替优化,其损失函数表示为

$$L_{\mathrm{GAN}}=E(\boldsymbol{y})[\log(D(\boldsymbol{y}))]+E(\boldsymbol{x})[\log(1-D(G(\boldsymbol{x})))]。 \tag{14}$$

式中:$D(\boldsymbol{y})$ 为判别网络;$G(\boldsymbol{x})$ 为生成网络;$\boldsymbol{x}$ 为退化水下图像;$\boldsymbol{y}$ 为水下目标图像;$E(\boldsymbol{x})$,$E(\boldsymbol{y})$ 为数学期望。

GAN 在训练过程中容易出现梯度消失的现象,其根本原因是 GAN 使用的 KL 散度和 JS 散度衡量两个分布之间的差异。当两个分布之间有重叠时优化 JS 散度是可行的,但有时真实样本分布和生成器样本分布之间重叠部分很少甚至完全不重叠,两个分布在高维空间相交是非常困难的,即便相交,二者相交部分只是高维空间中的一个测度为 0 的低维流形,这说明输入数据和生成数据在分布重叠部分少时可以视作二者不重叠。当两个分布在概率空间中不重叠的情况下,JS 散度的值是一个定值,这对梯度下降法(gradient descent,GD)来说意味着传回上层网络的梯度值为 0,即整个网络出现了梯度消失现象。

为解决该问题,Arjovsky 等[10]提出了 WGAN(wasserstein generative adversarial networks)模

型,该模型使用 Wasserstein 距离衡量真实样本和生成样本之间的差异。然而,该损失函数在随机梯度下降(stochastic gradient descent,SGD)过程中会出现不收敛的情况。Gulrajani 等[11]在此基础上增加了一个正则项,引入了梯度约束(GAN-Gradient Penalty,GP)机制,提出了具有梯度约束的 WGAN-GP,该算法引入了 GP 机制直接约束权重裁剪来使得梯度满足 Lipschitz 条件,WGAN-GP 损失函数表示为

$$L_{\text{WGAN-GP}}=E_{\tilde{x}\sim p_g(\tilde{x})}(D(\tilde{x}))-E_{x\sim p_r(x)^+}(D(x))+\rho\underset{x\sim p_{\hat{x}}}{E}((\|\nabla_{\hat{x}}D(\hat{x})\|_2-1)^2)。\tag{15}$$

式中:ρ 为常数,设置为 10;$x\sim p_r(x)$ 表示真实样本;$\tilde{x}\sim p_g(\tilde{x})$ 表示生成样本;$\hat{x}\sim p(\hat{x})$ 是成对真假样本的随机组合;E 表示数学期望;D 表示判别网络;$\rho\underset{x\sim p_{\hat{x}}}{E}((\|\nabla_{\hat{x}}D(\hat{x})\|_2-1)^2)$ 为 GP 惩罚项。

同时,为了减少图像中的人为干扰因素,联合 L_1 损失函数和对抗损失函数,则 L_1 损失函数可表示为

$$L_1=E(x,y)[\|y-G(x)\|_1]。\tag{16}$$

为了减少增强图像对于目标图像的结构扭曲和畸变,添加结构损失函数表示为

$$L_{\text{SSIM}}=\frac{2\mu_x\mu_y+c_1}{\mu_x^2+\mu_y^2+c_1}\cdot\frac{2\sigma_{xy}+c_2}{\sigma_x^2+\sigma_y^2+c_2}。\tag{17}$$

式中:μ_x 表示 x 的平均值;σ_x^2 表示 x 的方差;σ_{xy} 表示 x,y 的协方差;c_1,c_2 为常量。

然而,SSIM 与 MSE 这样的度量标准只关注图像中的浅层特征信息,为了使用深层信息提高视觉质量,使得增强图像有目标图像相似的语义信息,内容损失函数表示为

$$L_{\text{VGG}}=\frac{1}{WHC}\sum_{x=1}^{W}\sum_{y=1}^{H}\sum_{z=1}^{C}\|V(G(x))_{x,y,z}-V(y)_{x,y,z}\|_2^2。\tag{18}$$

式中:$V(x)$ 表示通过 VGG-19 网络卷积层进行了非线性转换;G 表示生成网络。

MCFGAN 使用多个损失函数联合进行网络的训练,有利于加速网络收敛,提高网络鲁棒性。最终损失函数利用对抗损失、L_1 损失、结构损失以及内容损失进行线性叠加,函数表示为

$$L=\lambda_1\times L_{\text{WGAN-GP}}+\lambda_2\times L_1+\lambda_3\times L_{\text{SSIM}}+\lambda_4\times L_{\text{VGG}}。\tag{19}$$

式中,λ 表示加权系数,测试设置 $\lambda_1:\lambda_2:\lambda_3:\lambda_4=5:1:2:2$。

2 实验结果与分析

为验证算法的有效性,将 MCFEGAN 与其他典型算法进行对比,并通过定性和定量分析,证明该算法在水下图像增强方面具有较强的实用性。实验在 Ubantu 操作系统下,基于深度学习框架 PyTorch 实现,服务器 CPU 为 Intel(R) Xeon(R) CPU E5-2660 v3 @ 2.60 GHz,GPU 为 Nvidia Tesla K80 12 GB。

2.1 数据集及训练细节

实验基于 UIEB 数据集(underwater image enhancement benchmark)[12],该数据集包含 950 幅真实水下图像。对这些图像进行专业人员和普通人员的双重筛选,最终挑选了 890 对配对数据作为训练集,60 幅具有挑战性图像作为测试集。在训练集上训练 MCFEGAN 模型,并在测试集上进行评估,获得水下图像增强质量效果的定量和定性分析。

在训练过程中,生成网络和判别网络的性能优化交替进行,设置每优化 5 次生成网络优化一次判别网络。同时,为提高模型处理速度,在预处理阶段将图像尺寸压缩至 256×256。模型设置初始学习率为 0.002,并且随着迭代次数增加逐步降低,BatchSize 为 1,总 Epoch 为 1 000。

2.2 定性分析

为了直观体现 MCFEGAN 与其他算法的对比效果,从数据集中选取了偏色、模糊严重程度不同的场景,通过与传统模型方法 RGHS(relative global histogram stretching)[13],IBLA(image restoration based on blurriness and light absorption)[14],以及深度学习方法 UGAN 和 FUnIE-GAN 进行比较。

在传统方法中 IBLA 对于清晰的偏绿水下图像有一定的视觉增强,但在偏色严重的场景下对红蓝色通道进行了过度补偿,导致图像出现偏红偏蓝的现象;RGHS 对于模糊场景的处理效果较好,但是对于严重偏色的水下图像处理效果不佳;UGAN 对于部分水下图像出现的严重色差失真不敏感,并且经常会对场景中的明亮物体进行过度饱和处理;FUnIE-GAN 处理后的水下图像视觉效果有一定的提升,但是对于模糊偏绿的水下图像处理略有不足。相比之下,本文所提出的方法处理后的图像色彩更饱和,对比度更高,可以有效恢复水下图像,并且视觉增强效果较好。各算法最终运行结果如图 2 所示。

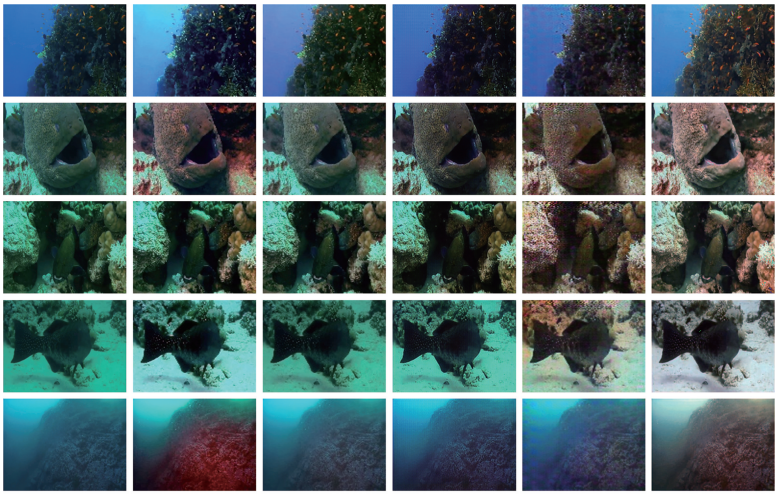


图 2　水下图像增强算法对比

Fig. 2　Comparison of underwater image enhancement algorithms

2.3　定量分析

为了更加客观地评价和分析 MCFEGAN 的性能,选用了通用的无参考水下图像质量评价指标以及有参考的图像质量评价指标对算法进行可观性能分析。其中,无参考水下图像质量评价指标分别为水下图像质量评价指标(underwater image quality measure,UIQM)[15]以及水下色彩图像质量评价指标(underwater color image quality evaluation,UCIQE)[16]。有参考的图像质量评价指标分别为峰值信噪比(peak signal to noise ratio,PSNR)和结构相似性(structural similarity,SSMI)。

UIQM 根据水下图像成像模型和退化机理分成 3 个部分,分别为水下图像色彩测量指标(underwater image colorfulness measure,UICM)、水下图像清晰度测量指标(underwater image sharpness measure,UISM)以及水下图像对比度测量指标(underwater image contrast measure,UIConM),该评价指标将 3 个测量分量的线性组合作为评价水下图像质量的依据,值越大代表图像质量越好,其计算公式表示为

$$\mathrm{UIQM}=c_1\times\mathrm{UICM}+c_2\times\mathrm{UISM}+c_3\times\mathrm{UIConM}。\tag{20}$$

式中,c_1,c_2,c_3 为定值,分别设置为 0.028 2,0.295 3,3.575 3。

UCIQE 则是通过计算水下图像的色度、饱和度以及对比度,通过线性组合的方式测量水下图像的最终质量。色度标准差与人眼主观观察图像感觉呈正相关,其值越大代表人眼感受的画面色彩越丰富。UCIQE 值越高代表图像的质量越高,其计算公式表示为

$$\mathrm{UCIQE}=c_1\times\sigma_c+c_2\times\mathrm{con}_i+c_3\times\mu_S。\tag{21}$$

式中:σ_c 为色度标准差;con_i 为亮度的对比度;μ_S 为饱和度的平均值;c_1,c_2,c_3 为定值,分别设置为 0.468 0,0.274 5,0.257 6。

PSNR 是基于对照图像的全部信息为参考,衡量图像的失真程度,PSNR 值越大代表图像失真越小,计算公式为

$$\mathrm{PSNR}(\boldsymbol{Y},\boldsymbol{X})=10\log_{10}\left[\frac{255^2}{\mathrm{MSE}(\boldsymbol{Y},\boldsymbol{X})}\right]。\tag{22}$$

式中:$\boldsymbol{X}$ 为生成图像;$\boldsymbol{Y}$ 为目标图像;$\mathrm{MSE}(\boldsymbol{Y},\boldsymbol{X})$ 表示生成图像与目标图像的均方误差。

SSIM 在算法上考虑了人眼视觉的特性,比传统方式更符合人眼视觉感知,该指标综合考虑了图像的结构、对比度以及亮度 3 个方面反映图像相似性,值越大代表两幅图像相似性越高,计算公式为

$$\mathrm{SSIM}(\boldsymbol{Y},\boldsymbol{X})=\left(\frac{2\mu_Y\mu_X+c_1}{\mu_Y^2\mu_X^2+c_1}\right)\left(\frac{2\sigma_{YX}+c_2}{\sigma_Y^2\sigma_X^2+c_2}\right)。\tag{23}$$

式中:μ_Y,μ_X 和 σ_Y,σ_X 分别是 $\boldsymbol{Y}$,$\boldsymbol{X}$ 的均值和标准差;σ_{YX} 表示协方差;c_1,c_2 为常量。

为了验证 MCFEGAN 的客观有效性,对比 UIQM,UCIQE,PSNR 以及 SSIM 等评价指标。不同模型得到的结果如表 1 所示,表中粗体字表示该项数值在各算法中最优。

表 1 水下图像增强算法定量分析对比

Table 1 Quantitative analysis and comparison of underwater image enhancement algorithms

方法	UIQM	UCIQE	PSNR	SSIM
原始图像	0.675 1	0.360 1	14.048 6	0.441 2
RGHS	3.770 0	**0.466 4**	20.917 2	0.878 8
IBLA	3.960 3	0.436 0	15.919 5	0.459 7
UGAN	4.406 0	0.402 1	20.350 4	0.850 7
FUnIE-GAN	4.695 0	0.410 5	24.537 2	0.871 6
MCFEGAN	**5.119 7**	0.453 1	**28.426 5**	**0.923 9**

由表 1 可以看出,水下图像经过 MCFEGAN 增强后,UIQM,PSNR 以及 SSIM 都取得了最优成绩,分别比目前最好效果提高了 11.1%,15.9%和 6%。其中,UISM 和 UIQM 体现了该算法增强后的水下图像图片边沿信息多,对比度更高,增强后图像整体质量较高,PSNR 和 SSIM 表明了增强图像在质量和结构上更接近参考图像,所含信息最为丰富。同时,MCFEGAN 的 UCIQE 也都优于大多数算法。UCIQE 是色彩浓度、饱和度以及对比度的线性组合,表明了增强后图像取得了较好的恢复效果。通过上述分析,该算法能够有效地还原水下退化图像、恢复图像的色彩、提高图像的清晰度和对比度,并且可以保留较多的边沿信息和纹理特征。

2.4 消融实验

为了进一步验证色彩平衡算法以及多路特征增强模块的作用,消融实验设置 3 组,分别为无色彩平衡处理、无多路特征增强模块以及完整模型。消融实验的主观视觉对比结果如图 3 所示。各评价指标如表 2 所示,最佳结果以粗体表示。

从图 3 可以看出,缺失色彩平衡处理得到的增强图像整体偏绿,依然存在偏色现象,而缺失多路特征增强模块得到的增强图像整体较为模糊,对比所提算法得到的增强图像可知,色彩平衡处理能够有效地帮助网络恢复图像色彩,多路特征增强能够有效地从多角度恢复图像的细节,进而验证了各个模块的作用。



a 原始图像 b 无色彩平衡

c 无多路特征强化 d 本文算法

图 3 消融实验主观视觉对比结果

Fig. 3 Subjective visual comparison results of ablation experiment

由表 2 可知,相较于某一模块缺失的算法,本文所提算法的每一项指标都达到了最优的效果。综合主观视觉对比以及客观评价指标可知,完整的 MCFEGAN 具备更明显的优势,表明色彩平衡处理和多路特征增强模块能够有效提升网络性能。

表 2 消融实验客观评价指标

Table 2 Objective evaluation index of ablation experiment

方法	UICM	UISM	UIConM	UIQM	UCIQE	PSNR	SSIM
原始图像	−9.944 0	1.966 2	0.404 6	0.675 1	0.360 1	14.048 6	0.441 2
无色彩平衡	−8.138 7	6.171 5	0.667 2	3.770 0	0.346 6	17.219 7	0.728 4
无多路特征增强	−6.267 5	6.425 2	0.445 4	3.960 3	0.350 4	23.028 4	0.730 4
MCFEGAN	**−4.845 1**	**7.852 4**	**0.819 5**	**5.119 7**	**0.453 1**	**28.426 5**	**0.923 9**

3 结语

针对水下图像颜色失真、低对比度及模糊等问题,本文设计了一种多路特征增强生成对抗网络的水下图像增强算法。MCFEGAN 由生成网络和判别网络构成。其中生成网络负责合成水下清晰图像,为了更好地学习图像的多层次特征,搭建不同深度的 FEN,提取原始图像和色彩平衡图像的不同层次特征,并且,构建多个 FEM 增强特征,以获取高质量的特征,通过 FM 得到生成图像。判别网络负责联合多个损失函数,驱动生成网络学习生成更高

质量的图像。通过消融实验,验证了色彩平衡处理以及多路特征增强模块的有效性。同时,为验证算法的性能,对比分析多个算法,通过主观和客观的综合评价,验证了所设计的网络能够有效还原图像的真实色彩和纹理细节,提高图像清晰度和对比度,生成高质量图像。

参考文献:

[1] 吴立新,陈朝晖,林霄沛等."透明海洋"立体观测网构建[J].科学通报,2020,65(25):2654-2661.

[2] PEREZ J, ATTANASIO A C, NECHYPORENKO N,et al. A deep learning approach for underwater image enhancement[C]// Biomedical Applications Based on Natural and Artificial Computing: International Work-Conference on the Interplay Between Natural and Artificial Computation. Cham, Springer, 2017: 183-192.

[3] WANG Yang, ZHANG Jing, CAO Yang, et al. A deep CNN method for underwater image enhancement [C]//2017 IEEE International Conference on Image Processing (ICIP). IEEE, 2017: 1382-1386.

[4] ANWAR S, LI C, PORIKLI F. Deep underwater image enhancement [J]. arXiv Preprint arXiv: 1807.03528, 2018.

[5] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//The 27th International Conference on Neural Information Processing Systems, Cambridge, UK, 2014: 2672-2680.

[6] FABBRI C, ISLAM M J, SATTAR J. Enhancing underwater imagery using generative adversarial networks[C]//2018 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2018: 7159-7165.

[7] ISLAM M J, XIA Y, SATTAR J. Fast underwater image enhancement for improved visual perception[J]. IEEE Robotics and Automation Letters, 2020, 5(2): 3227-3234.

[8] DU Rong, LI Weiwei, CHEN Shudong, et al. Unpaired underwater image enhancement based on CycleGAN[J]. Information, 2021, 13(1): 1.

[9] ZONG Xianhui, CHEN Zhehan, WANG Dadong. Local-CycleGAN: a general end-to-end network for visual enhancement in complex deep-water environment[J]. Applied Intelligence, 2021, 51(4): 1947-1958.

[10] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks[C]//International Conference on Machine Learning. PMLR, 2017: 214-223.

[11] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of wasserstein gans[J]. Advances in Neural Information Processing Systems, 2017, 30: 5769-5779

[12] LI C, GUO C, REN W, et al. An underwater image enhancement benchmark dataset and beyond [J]. IEEE Transactions on Image Processing, 2019, 29: 4376-4389.

[13] HUANG Dongmei, WANG Yan, SONG Wei, et al. Shallow-water image enhancement using relative global histogram stretching based on adaptive parameter acquisition [C]//International Conference on Multimedia Modeling. Cham, Springer, 2018: 453-465.

[14] 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.

[15] PANETTA K, GAO C, Agaian S. Human-visual-system-inspired underwater image quality measures [J]. IEEE Journal of Oceanic Engineering, 2015, 41(3): 541-551.

[16] YANG M, SOWMYA A. An underwater color image quality evaluation metric[J]. IEEE Transactions on Image Processing, 2015, 24(12): 6062-6071.

(责任编辑:李琴,秦海明　实习编辑:张昌保)