

基于多尺度残差融合的水下图像增强网络^{*}

张剑飞 李 浩

(黑龙江科技大学计算机与信息工程学院 哈尔滨 150022)

摘 要: 水下图像存在蓝绿色偏、清晰度与对比度低等因素严重影响水下研究的准确性和可靠性。针对上述问题,本文提出了一种基于多尺度残差融合的水下图像增强网络。首先,提出一个多尺度通道特征提取模块 MSCFE, MSCFE 模块对各个通道独立建模,避免通道之间的信息干扰,同时引入通道注意力对关键特征进行强化,有效增强颜色与细节。然后,提出一个全局-局部色彩校正模块 GLCC, GLCC 模块采用局部与全局两分支分别对局部颜色细节和长程依赖关系进行建模以校正图像色彩。实验表明,在 UIEB 数据集上,增强后的图像的结构相似性达到了 0.937 8、峰值信噪比达到了 23.768 7、水下彩色图像质量评价指标达到了 0.568 9、图像信息熵达到了 7.572 3;在 EUVP 数据集上,增强后的图像的结构相似性达到了 0.910 5、峰值信噪比达到了 25.169 9、水下彩色图像质量评价指标达到了 0.525 3、图像信息熵达到了 7.347 9,优于其他主流方法。

关键词: 图像处理;水下图像增强;多尺度特征提取;颜色校正

中图分类号: TP391;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.20

Underwater image enhancement network based on multi-scale residual fusion

Zhang Jianfei Li Hao

(School of Computer & Information Engineering, Heilongjiang University of Science & Technology, Harbin 150022, China)

Abstract: The existence of blue-green bias, low clarity and contrast of underwater images seriously affects the accuracy and reliability of underwater research. To address the above problems, this paper proposes an underwater image enhancement network based on multi-scale residual fusion. Firstly, a multi-scale channel feature extraction module MSCFE is proposed. The MSCFE module models each channel independently to avoid information interference between channels, and at the same time, channel attention is introduced to enhance the key features to effectively enhance the colour and details. Then, a global-local colour correction module GLCC is proposed, and the GLCC module adopts two branches, local and global, to model the local colour details and long-range dependencies respectively to correct the image colour. The experiments show that on the UIEB dataset, the structural similarity of the enhanced image reaches 0.937 8, the peak signal-to-noise ratio reaches 23.768 7, the underwater colour image quality evaluation index reaches 0.568 9, and the image information entropy reaches 7.572 3; on the EUVP dataset, the structural similarity of the enhanced image reaches 0.910 5, the peak signal-to-noise ratio reaches 25.169 9, underwater colour image quality evaluation index reached 0.525 3, and image information entropy reached 7.347 9, which are better than other mainstream methods.

Keywords: image processing; underwater image enhancement; multi-scale feature extraction; colour correction

0 引 言

随着科技的不断进步与陆地资源开发瓶颈期的到来,世界各国都将目光放在了海洋资源的开发上。海洋资源是地球资源的重要组成部分,但是由于海洋环境的特殊性,人

类无法直接进行水下研究,需要借助水下设备进行水下研究。然而,水下环境极其复杂,与大气环境相比,由于水体对不同波长色光的吸收程度不同,导致水下图像更容易产生色偏、模糊、对比度低等问题。在此情况下,水下图像的清晰与否将直接影响着研究质量与进度,对水下图像的清

收稿日期:2025-02-24

^{*} 基金项目:国家自然科学基金(61803148)、黑龙江省哲学社会科学研究规划项目(23YSD245)、黑龙江省属高等学校基本科研业务费项目(2024-KYYWF-1099)资助

晰度增强变得尤为重要。

目前,水下图像的增强方式主要分为两类:传统的水下图像增强算法和基于深度学习的水下图像增强算法^[1]。传统图像增强方法不依赖物理模型,直接应用于水下模糊图像,通过调整像素值的方式改变图像视觉效果,最后得到增强后的水下图像^[2-4]。Li 等^[5]提出水下白平衡算法,在水下图像颜色校正、去雾去模糊方面有不错的效果;Malathi 等^[6]提出改进直方图均衡化的对比度自适应直方图均衡化(contrast limited adaptive histogram wqualization, CLAHE)算法,通过将原始的随机分布图转为均匀分布以提高对比度;Li 等^[7]利用最小信息原则来估算投射图,而对水下图像进行增强;陈哲等^[8]提出了提出了一种基于梯度先验的水下图像恢复方法,通过对水下图像梯度先验和建立梯度优化函数来恢复水下图像。传统方法虽然对水下图像的视觉感受在一定程度上有了提升,但仍然存在不小的局限性。传统方法往往依赖与参数和数学公式,受人员影响较大,并且通常只适用于单一问题求解,难以解决受多种条件共同作用的水下图像。此外,对于水下极端环境,传统方法过于依赖像素层面的调整,在增强的同时还存在引入噪声的影响,从而导致结果存在伪影与色偏。

另一类方法是基于深度学习的图像增强方法,由于深度学习中卷积神经网络高效的特征提取能力,在图像处理领域有着广泛应用,基于深度学习的水下图像增强有了迅速发展。Fabbri 等^[9]提出了一种基于生成对抗网络的水下图像增强算法,利用非成对图像训练生成网络,之后利用生成网络生成的图像恢复真实水下图像;Li 等^[10]提出了一种基于门控融合的水下图像增强卷积神经网络 Water-Net (underwater generative adversarial networ),以白平衡(white balance, WB)、直方图均衡(histogram equalization, HE)和伽马矫正处理待增强的水下图像,而后通过学习的置信度图融合结果;Li 等^[11]提出一种基于水下场景先验的水下图像增强卷积神经网络(underwater image enhancement fully convolutional neural network, UWCNN),UWCNN 选择直接重构清晰的潜在水下图像,将水下成像物理模型与水下场景光学特征结合,可用于合成水下图像;Naik 等^[12]提出一种可用于便携式设备的水下图像增强网络 Shallow-UWnet(shallow neural network),解决了基于深度学习的水下图像增强网络的计算成本高与内存需求大的问题;Islam 等^[13]提出一种基于条件的生成对抗网络(fast underwater image enhancement generateve adversarial network, FUnIE-GAN),利用全局内容、颜色、局部纹理与风格信息作为感知损失函数监督模型训练;Tolie 等^[14]提出了一种基于深度 Inception 与通道级注意力模块的深度神经网络模型(deep inception and channel-wise attention modules, DICAM),通过考虑比例退化和非均匀色彩偏移来实现水下图像增强。尽管基于深度学习的图像增强算法取得了一定的成功,但是大多数方法都没有考虑

到不同颜色通道在水下的衰减程度不同,这种现象导致水下图像存在严重的蓝绿色偏,虽然少部分方法考虑到了这一方面,但是选择了以相同的方法来处理不同衰减程度的颜色通道,没有针对不同道道的衰减进行自适应优化,从而产生计算冗余、信息丢失、对比度不一致等问题。

针对以上问题,本文提出了一种基于多尺度残差融合的水下图像增强网络(multi-scale residual fusion network, MSRF-Net)。主要贡献如下:

1)提出了一个多尺度通道特征提取模块(multi-scale channel-wise feature extraction, MSCFE)。MSCFE 模块采用多尺度卷积提取不同通道的信息,结合通道注意力模块(channel attention module, CAM)更好的关注颜色特征。同时在 MSCFE 模块中使用密集残差链接,减少信息丢失,保证高级特征与低级特征可以更好的融合。

2)结合 MCC(matrixed color correction)模块^[15]提出了一个全局-局部色彩校正模块(global-local color correction, GLCC)。GLCC 模块分为全局与局部两个分支:全局校正分支为原 MCC 模块,通过建模长程依赖性,减少色偏,进行全局颜色校正;局部校正分支使用 3D 卷积对局部颜色进行增强。GLCC 模块使模型在保持全局色彩一致性的同时,对局部色彩细节进行优化,进而获得更好的增强效果。

1 相关工作

1.1 MSRF-Net 总体结构

MSRF-Net 由 MSCFE 模块、GLCC 模块组成,MSRF-Net 结构如图 1 所示。MSCFE 模块的作用是通过结合多尺度特征提取、密集残差连接和通道注意力的方式,补偿不同色光在水下衰减程度差异,从而解决图像偏蓝绿色调的问题;GLCC 模块的作用是对 MSCFE 模块的输出特征图进行颜色校正,将对全局色彩一致性和局部色彩细节进一步优化还原,以获得更加真实自然的增强图像。随后通过 3×3 卷积和 1×1 卷积对 GLCC 模块的输出特征图进行降维,降维后的输出是 RGB 图像。具体流程为如下:首先,RGB 三通道图像被分解为 R(red, R)、G(green, G)、B(blue, B)三个通道分别被 MSCFE 模块处理,每个分支的输入通道数 1,输出通道为 256,最后将 3 个分支的输出结果延通道拼接。然后,拼接结果由卷积核大小为 1 的卷积操作将通道数由 768 降维至 256,随后输入到 GLCC 模块进行颜色校正。最后,GLCC 的校正结果通过降维将通道数由 256 恢复到 3,得到原图像 hazy_image 增强后的图像 clean_image。

1.2 多尺度通道特征提取模块 MSCFE

如图 2 所示,在真实的水下环境中,不同波长的色光被吸收的程度不同,红色光波长较长,因此衰减最为严重,蓝色光由于波长较短衰减速度最慢,绿色光居于二者之间,所以水下图像看起来总是偏蓝绿色调,同时还存在对比度低




图 1 MSRF-Net 结构

Fig. 1 MSRF-Net structure




图 2 图像与各通道对比

Fig. 2 Image comparison with various channels

等问题。针对此问题,设计了 MSCFE 模块。MSCFE 模块采用多尺度方式提取特征信息,对不同通道的衰减进行补偿,保证对图像的初步恢复。具体来说,使用 3×3 卷积对红色通道局部细节纹理进行捕获,对衰减最严重的红色通道进行有效恢复。在蓝色通道上使用 7×7 卷积,使用大感受野对于更大范围上的颜色信息进行建模,保证图像整体色彩平衡,避免过度增强而导致失真问题。对于介于二者之间的绿色通道,使用 5×5 卷积对作为过渡,对其他两通道特征进行补充,同时保证图像整体色彩一致性。这样的设计使水下不同色光的衰减得到补偿,进而增强了 MSCFE 模块对局部细节处理和平衡整体色彩的能力,使图像颜色更加自然。此外,密集残差连接使不同层级的特征复用进一步强化,提高了特征利用率,降低了模型的计算开销,同时使颜色信息在网络中的衰减有效降低,保证了特征提取过程中的色彩优化的稳定性。随后在每个通道中使用通道注意力对于不同通道的权重自适应调节,提高信息损失最多的红色通道权重,对于蓝色通道与绿色通道的权重分布进行平衡,使颜色分布更合理,确保的初步颜色恢复的准确性,为后续的 GLCC 模块进一步对全局与局部的颜色校正提供高质量输入。MSCFE 模块结构如图 3 所示。

1.3 全局-局部色彩校正模块 GLCC

虽然经由 MSCFE 模块处理的图像在一定程度上缓解了颜色失真问题,但并未解决整体色彩平衡与局部细节优化问题。针对此问题,结合 MCC 模块进一步提出了 GLCC 模块。GLCC 模块由全局分支和局部分支组成,保证图像在整体色彩准确、对比度平衡和局部细节完整。

在全局颜色校正分支中,通过层标准化对输入特征进行标准化,而后通过两个卷积提升通道数,随后分解为 Q (query)、K(key)、V(value)三部分。三部分分别由多头注意力进行处理,其中,K 的转置与 Q 相乘的结果通过 softmax 进行归一化,得出注意力权重,而后将注意力权重与 V 相乘得到输出特征,最后将通道数调整回与初始输入相同。此过程能够捕获长程依赖关系,使颜色信息得到补偿,环节全局色彩失衡,确保全局校正的准确性。

但是仅 MCC 模块对于局部色彩损失的问题仍然难以处理,因此使用局部分支来优化局部细节。局部分支采用 3D 卷积进行局部特征提取,与 2D 卷积不同的是 3D 卷积可以同时空间和通道维度建模,因此局部分支不仅可以考虑到单个像素,还能兼顾到周围环境,从而提高局部校正的准确度。之后同样通过 3D 卷积进行通道信息融合,对不同颜色通道之间的颜色与纹理信息得以整合,从而进一步优化不同颜色通道颜色分布,使其更加自然合理。

GLCC 模块通过全局分支与局部分支对图像的整体色彩一致性和局部细节准确性进行优化,确保了图像色彩过渡更加自然,在颜色分布、对比度和细节表现上达到最佳效果。GLCC 模块结构如图 4 所示。

2 实验结果与分析

2.1 实验设置

实验条件:本文采用 Pytorch 深度学习框架,CPU 为 Intel(R) Xeon(R) Platinum 8352V,CPU 频率为 2.10 GHz,GPU 为 RTX 4090 (24 GB),开发平台为 PyCharm 2023.3.3,操作系统为 Ubuntu 20.04,开发语言为 Python 3.8,Cuda 版本为 11.8。

参数设置:首先将两个数据集集中的所有图像大小调整至 256×256 ,优化器选择 Adam,学习率为 0.000 8,batch size 为 4,epoch 为 120。

本文数据集选择 EUVP(enhancement of underwater visual perception)数据集^[13]和 UIEB(underwater image enhancement benchmark)数据集^[10]。EUVP 数据集包含 2 185 对图像,UIEB 数据集包含 890 对配对图像和一个包含 60 张具有挑战性的水下图像。本文对上述 EUVP 和

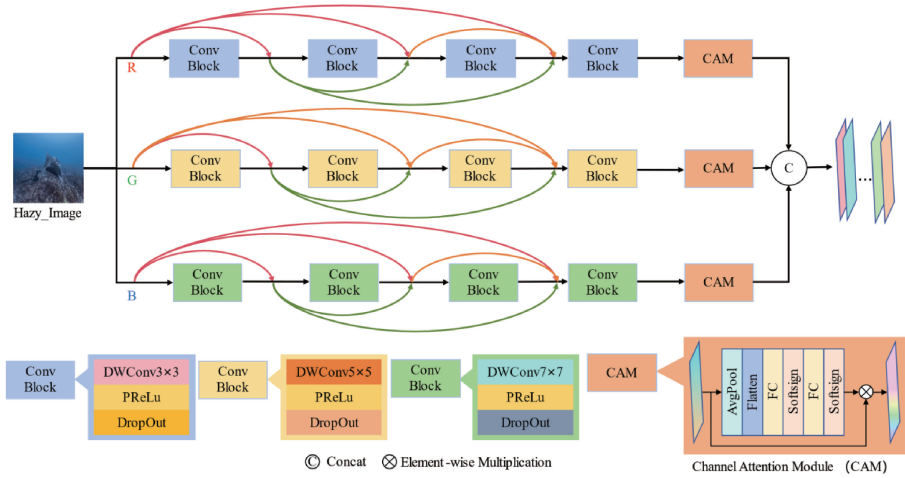


图 3 MSCFE 模块结构

Fig. 3 MSCFE module structure

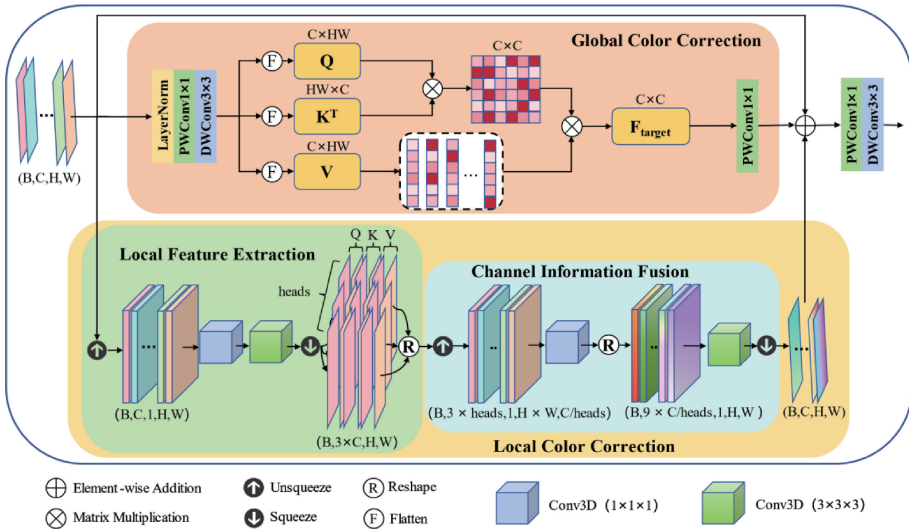


图 4 GLCC 模块结构

Fig. 4 GLCC module structure

UIEB 两个数据集通过翻转和对对比度调整的方式将数据集分别扩充至 6 555 对图像和 2 670 对图像,随后将两个数据集均按照 4 : 1 的比例划分为训练集与测试集。

2.2 评价指标

本文选择有参考指标:结构相似性^[16](structural similarity index measure, SSIM)、峰值信噪比^[16](peak signal-to-noise ratio, PSNR)和无参指标:水下彩色图像质量评价^[17](underwater color image quality evaluation, UCIQE)、图像信息熵^[17](image entropy, IE) 4 个指标对增强后的图像进行评估。

SSIM 通常用于评估两幅图像之间相似程度,更加关注图像的结构信息,可以更好地反映人类视觉的感知情况。SSIM 由亮度比较、对比度比较、结构比较 3 个方面加权组成,取值范围为[0,1],值越大说明两张图片结构越相似。SSIM 的计算如式(1)所示。

$$SSIM(a,b) = \frac{(2\delta_a\delta_b + \epsilon_1)(2\beta_{ab} + \epsilon_2)}{(\delta_a^2 + \delta_b^2 + \epsilon_1)(\beta_a^2 + \beta_b^2 + \epsilon_2)} \quad (1)$$

其中, a 和 b 分别表示图像 a 和图像 b , δ_a 和 δ_b 分别表示图像 a 和图像 b 的平均亮度; β_a 和 β_b 分别表示图像 a 和图像 b 的方差; β_{ab} 表示图像 a 和图像 b 的协方差; ϵ_1 和 ϵ_2 为避免分母为零的稳定常数。

PSNR 通常为评估增强图像与原图像之间的差异。单位为分贝(decibel, dB), PSNR 的值越大表示两图像之间差异越小,进而说明增强效果越好。PSNR 的计算如式(2)所示。

$$PSNR = 10\lg\left(\frac{MAX_I^2}{MSE}\right) \quad (2)$$

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - K(i,j)]^2 \quad (3)$$

其中, MAX_I^2 为图像像素点最大值的平方; MSE 为原

图像与增强图像之间像素点的平均误差值; $I(i, j)$ 为原图像的像素值; $K(i, j)$ 为增强图像像素值; m 和 n 为图像的宽高。

UCIQE 专门用于评估水下彩色图像质量,通过分析水下图像的颜色、对比度和饱和度量化图像质量,无需与参考图像对比。UCIQE 主要基于亮度对比度(contrast of luminance, CL)、饱和度标准差(saturation standard deviation, SSD)、色调平均值(mean of hue, MH)进行计算,UCIQE 的值越大,说明增强效果越好。UCIQE 的计算如式(4)所示。

$$UCIQE = \alpha_1 CL + \alpha_2 SSD + \alpha_3 MH \tag{4}$$

其中, α_1 、 α_2 、 α_3 为权重参数,分别对应 CL、SSD、MH。

IE 通常用来描述图像中信息量的多少,信息熵越大说明图像包含的信息量越多。信息熵的计算公式如式(5)所示。

$$IE = - \sum_{i=1}^N p(x_i) \log p(x_i) \tag{5}$$

其中, x_i 为像素值; $p(x_i)$ 为像素值出现的概率。

2.3 结果分析

1)客观评价

将本文方法与目前主流方法 UWCNN、Shallow-UWnet、FUnIE-GAN、U-shape^[18]、DICAM、X-CAUNET^[19]、Five A+ Net^[20] 在 UIEB 数据集和 EUVP 数据集上进行定量比较。

上述模型在 EUVP 数据集和 UIEB 数据集上的表现如表 1 和 2 所示。其中加粗表示最优,下划线表示次优。

表 1 各个模型在 EUVP 数据集上的结果对比

Table 1 Comparison of results of various models on the EUVP dataset

模型	SSIM	PSNR/dB	UCIQE	IE/bits
UWCNN	0.810 5	16.080 7	0.452 0	7.033 7
Shallow-UWnet	0.867 8	22.647 9	0.494 3	7.094 7
FUnIE-GAN	0.867 1	21.867 5	0.471 7	7.064 7
U-shape	0.877 2	22.792 5	0.489 9	7.154 9
DICAM	0.883 7	21.619 1	0.493 0	6.928 0
X-CAUNET	0.890 0	<u>23.993 8</u>	0.498 7	7.256 4
Five A+ Net	<u>0.902 9</u>	23.194 8	0.548 3	<u>7.321 0</u>
Ours	0.910 5	25.169 9	<u>0.525 3</u>	7.347 9

与其他方法相比,本文方法在有参考指标和无参靠指标中均取得了最优或次优的成果。本文方法在 EUVP 数据集上 SSIM、PSNR 和 IE 三个指标均为最优,UCIQE 指标取得次优,接近最优的 Five A+ Net;在 UIEB 数据集上 PSNR、UCIQE 和 IE 三个指标为最优,次优的 SSIM 指标与最优的 Five A+ Net 接近。综合来看,本文方法在噪声抑制、细节恢复、颜色校正与对比度增强方面不亚于目前

的主流方法,验证了方法的合理性,适用于高质量、高要求的水下图像增强任务。

表 2 各个模型在 UIEB 数据集上的结果对比

Table 2 Comparison of results of various models on the UIEB dxataset

模型	SSIM	PSNR/dB	UCIQE	IE/bits
UWCNN	0.808 6	14.244 0	0.535 7	6.940 1
Shallow-UWnet	0.803 4	17.602 0	0.509 9	7.058 1
FUnIE-GAN	0.846 1	22.782 2	0.529 9	7.310 3
U-shape	0.799 3	20.602 8	0.516 7	7.343 0
DICAM	0.914 4	19.641 9	0.528 5	7.324 3
X-CAUNET	0.933 8	22.370 8	0.553 4	7.488 1
Five A+ Net	0.940 4	<u>22.803 5</u>	<u>0.558 4</u>	<u>7.542 7</u>
Ours	<u>0.937 8</u>	23.768 7	0.568 9	7.572 3

2)主观评价

本文方法和其他模型在 UIEB 数据集与 EUVP 数据集上的实验结果对比分别如图 5 与图 6 所示。其中,实线方框表示关注区域,虚线方框表示关注区域放大图。

图 5 中,UWCNN 模型引入了大量红色伪影,增强后的图像严重失真,效果不佳;Shallow-UWnet 模型在第 1 行中增强效果相较于 UWCNN 模型更好,但是图像整体偏暗,在第 2、3 行中图像整体泛黄,第 4 行中引入了红色伪影使图像整体视觉效果呈现红色;FUnIE-GAN 模型在第 2、3、4 行上的效果与 Shallow-UWnet 类似,但是在第 1 行上的视觉效果优于 UWCNN 与 Shallow-UWnet,但是物体边缘模糊,细节有所丢失;U-shape 模型在四幅图上的增强效果均强于前几个模型,但是与参考图像相比在局部的细节和色彩恢复上仍然有所欠缺,如第 1 行关注区域偏暗,第 4 行关注区域偏黄;DICAM 模型的增强效果在视觉效果上存在图像整体偏蓝绿色的问题,如在第 1 行中图像泛黄,第 2、3 行中图像存在绿色色偏;X-CAUNET 在第 1 行中有微小的黄色色偏,在第 2、3、4 行中引入了红色色偏;Five A+ Net 对于第 1、2、3 行整体色彩呈现轻微绿色,在第 4 行中对比度过高使图像视觉上失真;与上述模型相比,本文模型在第 1 行中,有效提高了对比度与蓝绿色偏,并且边缘清晰,在第 2、3 行中,将原图像中的黄绿色进行有效消除且没有引入其他噪声,第 4 行视觉上更加真实自然。

图 6 中,UWCNN 模型的增强结果与参考图像相比,第 1 行引入了轻微红色噪声并且细节模糊,其他 3 幅图片引入了明显的红色伪影;Shallow-UWnet 模型的增强结果相比其他模型呈现出更加灰暗的视觉效果;FUnIE-GAN 模型在第 3、4 行上存在黄色伪影,第 2 行总体偏向红色,增强效果不佳;U-shape 模型在第 1、4 行存在蓝色色偏,在第 2 行上曝光度较高且有轻微红色和蓝色噪声;DICAM 模型与 Shallow-UWnet 模型的结果类似,图像总体偏暗,但在

细节上相较于前面的模型处理得更好;X-CAUNET 模型对第 1 行的色彩恢复还有欠缺,存在蓝色色偏,在第 2 行中上存在蓝色色偏为消除,第 3 行中存在黄色色偏,第 4 行中引入了额外的内容;Five A+ Net 模型同样对第 1 行的色彩恢复有不足,并且对于第 2 行中蓝色噪声没有去除,第 4 行中同样引入了额外的内容;本文方法在第 1 行上没有偏暗或蓝色色偏,并且清晰度与其他模型相比最为清晰,在

第 2 行上也没有引入红色噪声且图片细节保留比其他模型高,在其他两幅图中也最为接近参考图片,没有光晕和灰暗问题出现。

综合来看,本文方法相比于其他模型可以有效的去除蓝绿色偏,对图像的色彩恢复效果更好,在对比度明显提升的同时清晰度也有显著增强,视觉效果相比其他模型更加自然,能够有效的增强图像细节,使图像层次更加清晰。

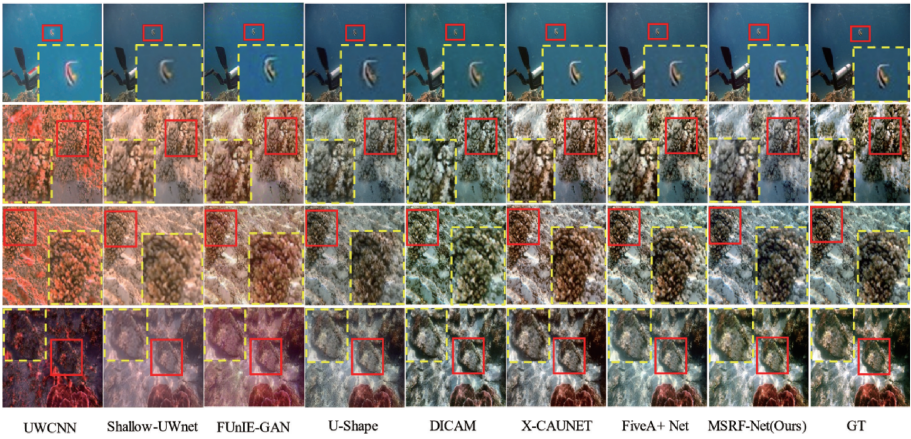


图 5 各模型在 UIEB 数据集上的增强结果

Fig. 5 Enhancement results of various models on the UIEB dataset

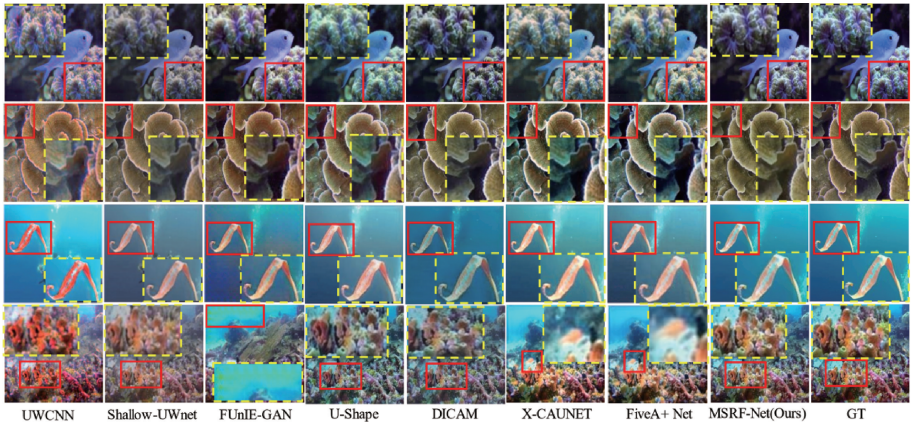


图 6 各模型在 EUVP 数据集上的增强结果

Fig. 6 Enhancement results of various models on the EUVP dataset

3) 消融实验

为进一步论证本文改进的有效性,分别在 EUVP 数据集与 UIEB 数据集上进行消融实验,通过逐渐添加改进以证明本文所提改进的有效性。实验共分为 5 组,G1 为模型结构中仅有 MSCFE 模块并且每个分支均为 3×3 卷积;G2 为在 G1 的基础上将 G 分支 3×3 卷积替换为 5×5 卷积;G3 为在 G2 基础上将 B 分支 3×3 卷积替换为 7×7 卷积;G4 为在 G3 基础上引入 MCC 模块(全局分支);G5 为在 G4 基础上加入局部分支。实验结果分别如表 3 和 4 所示。

实验结果表明,采用不同感受野的方式能够增强模型

的特征提取能力,引入 MCC 模块后模型 PSNR、UCIQE 和 IE 三个指标均有提升,证明模型的全局色彩校正能力有明显提高,进一步引入局部校正分支后,模型局部细节恢复能力提升,各个指标达到最佳,验证了 MSCFE 和 GLCC 模块的有效性。

4) 泛化实验

为了评估模型的泛化性和在低光照与强浑浊等极端场景的局限性,在 UFO-120 数据集^[21]和 UIEB 数据集中的非配对子集 Challenging-60 上进行验证,并与本文中其他模型进行对比。其中,泛化性实验结果如图 7 所示,低光照与强浑浊场景实验结果如图 8 所示。其中,实线方框

表示关注区域,虚线方框表示关注区域放大图。

表 3 在 EUVP 数据集上的消融实验结果
Table 3 Results of ablation experiments on the EUVP dataset

组别	SSIM	PSNR	UCIQE	IE
G1	0.895 2	22.986 5	0.487 5	6.913 9
G2	0.901 7	23.702 6	0.496 0	6.939 1
G3	0.905 0	23.867 5	0.507 1	7.060 8
G4	0.908 7	24.115 5	0.513 4	7.219 3
G5	0.910 5	25.169 9	0.525 3	7.347 9

表 4 在 UIEB 数据集上的消融实验结果
Table 4 Results of ablation experiments on the UIEB dataset

组别	SSIM	PSNR	UCIQE	IE
G1	0.919 4	20.811 3	0.529 8	7.396 5
G2	0.925 7	21.437 9	0.535 8	7.438 2
G3	0.929 8	21.841 3	0.543 1	7.454 7
G4	0.934 4	22.596 3	0.554 4	7.502 2
G5	0.937 8	23.768 7	0.568 9	7.572 3

图 7 中,UWCNN 模型在第 1、2 行中引入了蓝色噪声和红色伪影,并且第 2 行中存在细节模糊问题;Shallow-UWnet 模型在第 1、2 行中引入了轻微的蓝色色偏;FUnIE-GAN 模型对于第 1、2 行的细节恢复效果优于前面两个模型,但是第 1 行中的蓝色色偏并未完全消除;U-shape 模型对第 1 行中物体色彩恢复效果良好,但整体仍存在蓝色色偏,第 2 行中细节信息恢复不理想;DICAM 模型中,第 1 行中存在严重的青蓝色色偏,并且出现内容丢失问题,第 2 行整体色彩失衡,呈现黄绿色;X-CAUNET 模型第 1 行中存在明显蓝色色偏,并且物体边缘细节模糊不清,第 2 行中存在明显色彩问题,但对边缘细节的恢复较好;FiveA+Net 模型的效果与 X-CAUNET 模型类似;相比于其他模型,本文模型在色彩校正与细节恢复能力上有明显优势,第 1、2 行中物体保持细节良好的同时颜色恢复也更加自然,最为接近参考图像。

图 8 中,UWCNN 模型对第 1 行的蓝绿色偏没有完全去除,在第 2 行中引入了黄色色偏,第 3 行中引入红色噪声并且对于低光现象没有有效恢复,第 4 行对低光现象仅有微弱恢复;Shallow-UWnet 模型对第 1 行中色偏未完全纠正并且图正整体偏暗,第 2 行中引入了黄色色偏,第 3 行中




图 7 各模型在 UFO-120 数据集上的增强结果
Fig. 7 Enhancement results of various models on the UFO-120 dataset

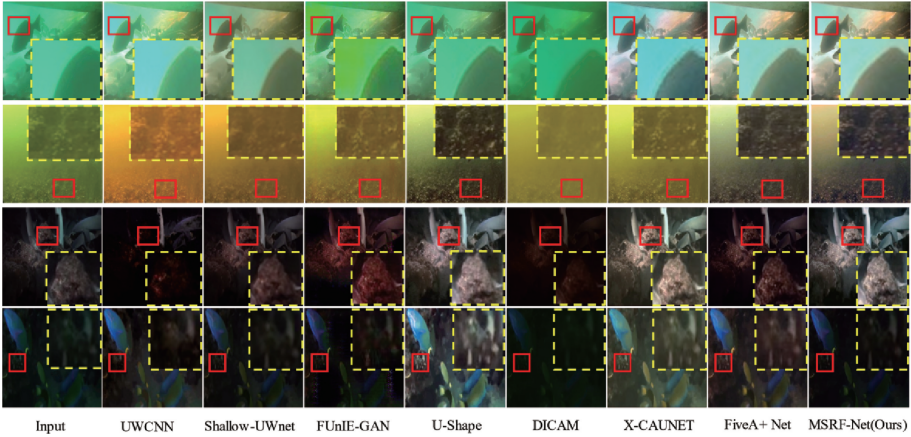


图 8 各模型在 Challenging-60 数据集上的增强结果
Fig. 8 Enhancement results of various models on the Challenging-60 dataset

对低光现象恢复较好但引入了轻微红色噪声,第 4 行中对低光现象恢复不明显;FUnIE-GAN 模型在第 1 行中引入了严重绿色噪声,第 2 行引入了黄绿色偏,在第 3 行中对低光现象恢复较好,但是图像整体存在红色色偏,第 4 行对低光现象恢复不明显;U-shape 模型在第 1 行中同样存在未消除色偏的问题,对第 2 行中色彩恢复和细节恢复优于前面模型,但还存在轻微绿色色偏,第 3 行中对低光现象恢复效果优秀,仅有微小的红色色偏,对第 4 行中的低光现象的恢复效果同样良好,但图像整体存在轻微蓝绿色偏;DICAM 模型的效果对于第 1 行中色偏未完全消除并且加重了色偏现象,图像也更模糊,第 2 行更加模糊,色偏也更严重,第 3 行整体更暗,且有红色色偏,第 4 行几乎没有任何细节和颜色信息;X-CAUNET 模型在第 1 行中物理边缘模糊,但对绿色色偏的消除相较于前面模型更加完全,第 2 行效果与 FUnIE-GAN 模型效果类似,第 3 行中光照恢复良好,物体细节也有效保留,仅存在微弱黄绿色色偏;FiveA+Net 模型对第 1 行的绿色色偏消除效果较好,但图像偏暗,第 2 行存在微弱黄色色偏现象,但细节保留较好,第 3 行中引入了红色色偏,第 4 行中图像偏暗,存在红色色偏;本文模型在第 1 行上消除了绿色色偏,对边缘细节也保留完好,第 2 行中的细节也有较高度度的保留,色偏消除效果相比其他模型为最佳,对第 3 行的光照相比其他模型恢复的最好,并且没有色偏,第 4 行中对光照恢复不够理想。

3 结 论

对于水下图像存在蓝绿色偏、对比度低与模糊等问题,本文提出了一种基于多尺度残差融合的水下图像增强网络 MSRF-Net。MSRF-Net 通过 MSCFE 模块对图像不同通道进行特征提取与初步色彩恢复,随后通过 GLCC 模块对进行颜色校正。实验表明本文方法在 SSIM、PSNR、UCIQE 和 IE 四个指标整体优于其他主流方法,证明本文方法可以有效的对水下图像的蓝绿色偏、清晰度和对比度进行增强。泛化性实验结果表明本文模型在低光照图像的恢复上仍有不足,在未来的模型中会进一步优化,提高模型的泛化性,解决低光严重图像恢复不足的问题。

参考文献

- [1] WANG Y, SONG W, FORTINO G, et al. An experimental-based review of image enhancement and image restoration methods for underwater imaging[J]. IEEE Access, 2019, 7: 140233-140251.
- [2] 王柯俨,黄诗芮,李云松. 水下光学图像重建方法研究进展[J]. 中国图象图形学报, 2022, 27(5): 1337-1358.
WANG K Y, HUANG SH R, LI Y S. Research progress on underwater optical image reconstruction methods[J]. Journal of Image and Graphics, 2022, 27(5): 1337-1358.
- [3] 田青,赵宇,张正,等. 基于 Enhanced Zero-DCE++ 的水下选通图像增强技术研究[J]. 电子测量技术, 2025, 48(1): 166-174.
TIAN Q, ZHAO Y, ZHANG ZH, et al. Research on underwater selective image enhancement technology based on Enhanced Zero DCE++ [J]. Electronic Measurement Technology, 2025, 48(1): 166-174.
- [4] YAO L P, PAN ZH. The Retinex-based image dehazing using a particle swarm optimization method[J]. Multimedia Tools and Applications, 2021, 80(3): 3425-3442.
- [5] LI CH Y, GUO CH L, REN W Q, et al. An underwater image enhancement benchmark dataset and beyond[J]. IEEE Transactions on Image Processing, 2019, 29: 4376-4389.
- [6] MALATHI V, MANIKANDAN A. An enhancement of underwater images using dcp and clahe algorithm[J]. International Journal of Recent Technology and Engineering, 2019, 9(2): 2805-2813.
- [7] LI C Y, GUO J C, CONG R M, et al. Underwater image enhancement by dehazing with minimum information loss and histogram distribution prior[J]. IEEE Transactions on Image Processing, 2016, 25(12): 5664-5677.
- [8] 陈哲,周旭,沈洁,等. 基于梯度先验的水下图像恢复[J]. 仪器仪表学报, 2022, 43(8): 39-46.
CHEN ZH, ZHOU X, SHEN J, et al. Underwater image restoration based on gradient prior[J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 39-46.
- [9] FABBRI C, ISLAM M J, SATTAR J. Enhancing underwater imagery using generative adversarial networks[C]. 2018 IEEE International Conference on Robotics and Automation(ICRA), 2018: 7159-7165.
- [10] LI CH Y, GUO CH L, REN W Q, et al. An underwater image enhancement benchmark dataset and beyond[J]. IEEE Transactions on Image Processing, 2019, 29: 4376-4389.
- [11] LI C, ANWAR S, PORIKLI F. Underwater scene prior inspired deep underwater image and video enhancement [J]. Pattern Recognition, 2020, 98: 107038.
- [12] NAIK A, SWARNAKAR A, MITTAL K. Shallow-uwnet: Compressed model for underwater image enhancement(student abstract)[C]. AAAI Conference on Artificial Intelligence, 2021, 35 (18): 15853-15854.
- [13] 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.
- [14] TOLIE H F, REN J CH, ELYAN E. DICAM: Deep inception and channel-wise attention modules for underwater image enhancement[J]. Neurocomputing, 2024, 584: 127585.
- [15] JIN X, HAN L H, LI ZH, et al. DNF: Decouple and feedback network for seeing in the dark[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 18135-18144.
- [16] HORÉ A, ZIOU D. Image quality metrics: PSNR vs. SSIM [C]. 2010 20th International Conference on Pattern Recognition. IEEE, 2010: 2366-2369.
- [17] YANG M, SOWMYA A. An underwater color image quality evaluation metric[J]. IEEE Transactions on Image Processing, 2015, 24(12): 6062-6071.
- [18] PENG L T, ZHU CH, BIAN L H. U-shape transformer for underwater image enhancement [J]. IEEE Transactions on Image Processing, 2023, 32: 3066-3079.
- [19] PRAMANICK A, SARMA S, SUR A. X-CAUNET: Cross-color channel attention with underwater image-enhancing transformer [C]. ICASSP 2024-2024 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP). IEEE, 2024: 3550-3554.
- [20] JIANG J X, YE T, BAI J B, et al. Five A + network: You only need 9K parameters for underwater image enhancement[J]. ArXiv preprint arXiv:2305.08824, 2023.
- [21] ISLAM M J, EDGE C, XIAO Y, et al. Semantic segmentation of underwater imagery: dataset and benchmark [C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems(IROS). IEEE, 2020: 1769-1776.

作者简介

张剑飞(通信作者),博士,教授,主要研究方向为图像处理与模式识别。

E-mail:zjfnfu2008@163.com

李浩,硕士研究生,主要研究方向为图像处理。

E-mail:2081768544@qq.com