

DOI:10.19651/j.cnki.emt.2519111

基于改进 LU2Net 的浑浊水偏振图像增强^{*}张振楷¹ 张浩¹ 信恒府¹ 元辉² 田艳兵¹

(1. 青岛理工大学信息与控制工程学院 青岛 266520; 2. 山东大学控制科学与工程学院 济南 250061)

摘要: 由于水体散射的原因,水下图像普遍存在质量退化问题。针对该问题,本文提出了一种基于改进 LU2Net 的浑浊水偏振图像增强模型,并在自建数据集上验证。首先,将采集的彩色偏振图像灰度化处理,通过将 0°、45°、90° 这 3 个偏振分量融合来获取完整的线偏振信息,再采用改进的 LU2Net 网络模型对退化的水下偏振图像进行增强,最后获取具有更多细节特征的增强图像。实验结果证明,本文方法在主客观评价以及特征点检测和 Canny 边缘检测结果上都优于用于对比的 FUnIE-GAN、MLLE 等水下图像增强方法,尤其是在特征点检测过程中,本文使用了 ORB、AKAZE 等四种不同的特征点检测方法,本文方法都能提取到更多的特征点。本文方法的 LPIPS 相比现有对比的最优方法降低了 3.35%,UCIQE 相比改进前的算法增加了 1.16%,NIQE 相比改进前的算法降低了 7.59%。本文提出的方法,在自然光状态下的浑浊水环境中,能够提取到更清晰的图像边缘和纹理等细节特征,提升了浑浊水环境中的成像质量。

关键词: 图像增强;偏振成像;浑浊水体;改进 LU2Net 网络模型

中图分类号: TP391;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Polarization image enhancement for turbid water
based on improved LU2NetZhang Zhenkai¹ Zhang Hao¹ Xin Hengfu¹ Yuan Hui² Tian Yanbing¹

(1. School of Information and Control Engineering, Qingdao University of Technology, Qingdao 266520, China;

2. School of Control Science and Engineering, Shandong University, Jinan 250061, China)

Abstract: Due to light scattering in water, underwater images commonly suffer from quality degradation. To address this issue, this paper proposes an enhancement model for turbid underwater polarized images based on an enhanced LU2Net network, validated using a self-constructed dataset. Initially, the acquired color polarization images are converted to grayscale. Complete linear polarization information is obtained by fusing the three polarization components at 0°, 45° and 90°. The degraded underwater polarized images are subsequently enhanced using the proposed enhanced LU2Net network model. Finally, enhanced images possessing richer detail features are acquired. Experimental results demonstrate that the proposed method outperforms comparative underwater image enhancement techniques including FUnIE-GAN and MLLE, in terms of both subjective and objective evaluations, as well as in the outcomes of feature point detection and Canny edge detection. Crucially, during feature point detection employing four distinct methods including ORB and AKAZE, the proposed approach consistently extracted a greater number of feature points. The proposed method achieves a 3.35% reduction in LPIPS compared to the best-performing existing method used for comparison. Furthermore, it increases the UCIQE score by 1.16% and decreases the NIQE score by 7.59% compared to the algorithm prior to enhancement. The proposed method successfully extracts clearer image edges, textures, and other fine details in turbid water environments under natural lighting conditions, thereby enhancing imaging quality in such challenging scenarios.

Keywords: image enhancement; polarization imaging; turbid water; improved LU2Net network model

0 引言

由于光在水下传输的过程中受到水体吸收和散射的影

响,水下图像普遍存在质量退化问题,主要原因在于背景噪声大、对比度低和细节丢失。在对常规 RGB 格式浑浊水图像进行增强时,噪声抑制与细节保留难以协同优化,普遍存

收稿日期:2025-06-16

* 基金项目:山东省自然科学基金重大基础研究项目(ZR2022ZD38)、青岛市科技计划重点研发专项(22-3-3-hygg-30-hy)资助

在强化细节伴随噪声放大,或抑制噪声导致结构信息损失的矛盾现象。因此,将低质量的水下图像增强并恢复成高质量图像已成为水下视觉应用中亟待解决的问题^[1]。在众多水下成像技术中,水下偏振成像技术备受关注。水下偏振成像技术利用散射光的偏振特性在一定程度上可以减小后向散射光对水下成像质量的影响^[2]。此外,可以采用偏振成像技术对浑浊水环境下的图像信息进行数字化处理,提高图像质量,增强目标特征的感知能力^[3]。由此可见,偏振成像在复杂环境成像中展现出了明显的优势。该技术具备多领域适用性,包括定量生物医学成像^[4]、海洋物种监测^[5]等领域。

为了精确、快速地估计偏振去散射过程中的参数,Zhang 等^[6]融合了偏振成像与暗通道先验,实现了背景区域的自动化提取与背景光信息的有效估计,显著改善了图像质量。Hu 等^[7]提出了一种灰度图像增强方法,该方法考虑了线偏振光与圆偏振光对图像的综合影响,在浑浊介质中表现出色,能够更加准确的恢复图像的细节特征。然而,以上基于 Stokes 矢量的偏振成像方法在参数估计过程中易引入误差,导致增强后的图像仍普遍存在亮度不足等相关问题,并且,在图像的主体和背景很难区分时增强效果会受到限制。偏振成像是依赖计算过程重建偏振信息的典型计算成像技术。深度学习凭借强大的非线性建模能力革新了计算成像,能够处理大规模数据、优化复杂成像流程、突破传统模型局限并能够自动提取特征^[8]。在基于深度学习的偏振水下图像增强方面,Hu 等^[9]率先将深度学习引入该领域,构建了大规模偏振图像数据集并提出了基于残差密集网络的增强模型,能够有效学习物体辐射度与偏振信息之间的复杂映射关系,但该模型的复杂度高,训练速度慢,且训练需要大量的水下图像数据。Yang 等^[10]开发了一种融合无监督学习与偏振成像理论的方法,通过将背景光视为空间可变参数,增强了其对非均匀光学场景的适应性,显著提升了处理速度与泛化能力,但是该方法的训练过程不稳定,对训练数据的质量依赖程度较高。Zhang 等^[11]探索了基于密集 U-Net 和信息流的深度学习浑浊水下偏振图像恢复方法。Ding 等^[12]提出了多偏振融合生成对抗网络,旨在学习偏振信息与物体辐射度之间的关联特性,但该模型运算量高,计算成本高。Ren 等^[13]对基于深度学习的水下主动偏振成像方法进行了研究,通过整合深度学习与偏振去雾成像技术的优势,设计了一种具有四输入通道的轻量级卷积神经网络以实现高效的图像去雾,但该模型的泛化性较差。这些基于深度学习的偏振水下图像增强方法具有更强的泛化能力,但是,目前偏振水下图像缺少公开数据集,这是一个亟待解决的问题。

本文的主要贡献为提出了一种基于 LU2Net 改进的浑浊水偏振图像增强模型,并在自建浑浊水偏振图像数据集上验证。该模型将偏振成像与深度学习相结合,通过增加 LU2Net 模型中编码和解码模块的数量并采用 Hardswish

激活函数,提高了浑浊水图像的细节提取和恢复能力,降低模型的平滑性,从而获得更加丰富的图像边缘和纹理特征。

1 本文方法

针对浑浊水图像存在细节模糊等图像退化问题,本文提出了基于改进 LU2Net 的浑浊水图像增强模型。该模型首先对偏振浑浊水数据集进行预处理,对 0° 、 45° 、 90° 这 3 个偏振分量进行拼接,获取三通道的拼接图像。再将拼接图像输入到改进的 LU2Net 网络架构中,该模型的架构沿用 LU2Net 主体框架,将模型当中的编码模块和解码模块从两级增加到四级,来提高模型提取浑浊水图像边缘和纹理细节的能力,再将全部的 GELU 激活函数转换成 Hardswish 激活函数,来降低模型的平滑能力,提高图像细节的锐度和清晰度。通过对 LU2Net 模型的改进,本文方法能够获取到更多的图像边缘和纹理特征。改进后的模型如图 1 所示,其中图 1(a)展示了改进后模型的整体架构,图 1(b)展示了改动后的 BottleNeck 模块,图 1(c)展示了模型中使用的注意力机制模块。

1.1 数据预处理

该方法首先对采集的数据进行预处理。由于偏振成像的过程当中只需要 0° 、 45° 、 90° 这 3 个偏振分量就可以获取完整的线性偏振信息^[14],本研究仅需对这 3 组偏振分量进行处理。在本实验当中,对偏振图像数据集中的偏振图像进行灰度化处理之后,对图像进行裁剪,意在将图像中的主体目标进行放大,以便看清楚更多的图像细节,本实验在这个过程中中将分辨率为 $1\ 224 \times 1\ 024$ 的浑浊水下偏振图像,裁剪成分辨率为 256×256 的图像。随后本研究在经过裁剪后的图像组中,提取出 0° 、 45° 、 90° 这 3 个偏振分量,并按照 BGR 的通道顺序进行图像的拼接,并将获得的拼接图像作为网络模型的输入图像,具体情形如图 2 所示。

1.2 网络模型

本文通过对 LU2Net 框架进行改进来实现浑浊水偏振图像边缘和纹理的增强。LU2Net 网络模型在实现图像增强的过程中,有着参数量少,能够快速提取图像特征的特点。在本实验中,通过对生成图像的分析发现,LU2Net 在图像细节的还原方面还存在不足,其输出结果普遍存在细节缺失和纹理清晰度下降的现象,尤其在浅色或低对比度场景中,该模型甚至会出现目标主体局部区域与背景的视觉边界模糊的情况。具体情形如图 3 所示。其中图 3(a)是输入的拼接图像,图 3(b)是 LU2Net 的生成图像,图 3(c)是清水中的强度图像,用来体现真实图像的边缘和纹理细节。

LU2Net 是一个轻量化的网络模型,并且借鉴了 U-Net 结构,为了降低模型的参数量和提高了模型的运行效率,该模型仅包含两级编码模块与两级解码模块,导致了模型的深度相对较浅,提取图像细节特征的能力相对较弱。因此,本文通过增加编码模块和解码模块的级数,实现模型深

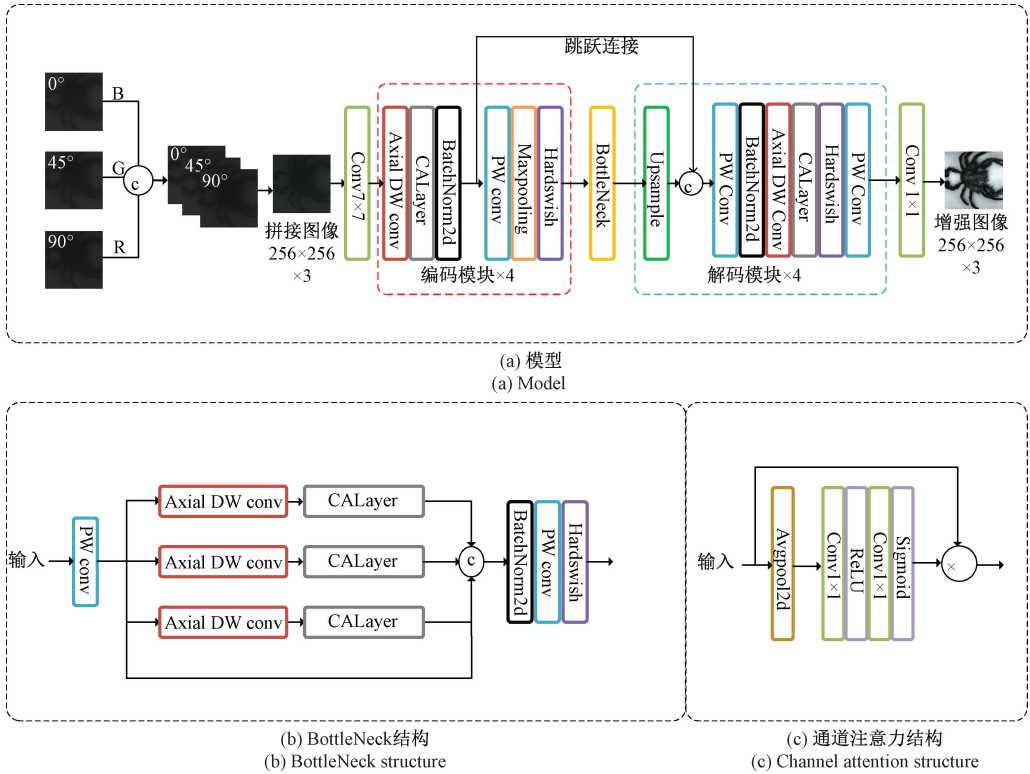


图 1 网络模型结构

Fig. 1 Network model architecture




图 2 偏振图像数据及拼接结果图

Fig. 2 Polarization image data and stitched results

度的增加,进而在深度特征提取过程中捕获更丰富的图像细节特征。其中,编码模块由轴向深度可分离卷积,通道注意力模块,逐点卷积,最大池化层等组成。解码模块由上采样,逐点卷积,轴向深度可分离卷积,通道注意力模块,和第 2 个逐点卷积等组成。LU2Net 模型的输出图像呈现明显的细节过度平滑现象,导致边缘清晰度下降、纹理特征模糊,结构信息损失显著,GELU 激活函数是一个完全平滑的激活函数,而 Hardswish 激活函数由于存在不可导的点相比 GELU 激活函数平滑性低。为了降低模型的平滑性,同时确保核心性能不受显著影响,本文当中将 GELU 激活函

数更换成平滑性更低但是效果相近的 Hardswish 激活函数^[15]。

Hardswish 激活函数的计算如式(1)所示。

$$Hardswish(x) = x \cdot \frac{ReLU6(x+3)}{6} \quad (1)$$

在这之中 ReLU6 的计算如式(2)所示。

$$ReLU6 = \min(6, ReLU(x)) = \min(6, \max(0, x)) \quad (2)$$

Hardswish 激活函数相比 GELU 激活函数有着计算复杂度低,平滑性低等特点^[16],更容易突出图像的细节特征,非常适合处理本文中提到的相关问题,Hardswish 激活函数和 GELU 激活函数的对比如图 4 所示,其中图 4(a)展示 GELU 激活函数的可视化曲线;图 4(b)展示 Hardswish 激活函数的可视化曲线;图 4(c)展示两个激活函数的对比图像。

本实验沿用了 LU2Net^[17]架构的主体框架,完整保留了其编码模块、解码模块和 BottleNeck 结构。在这些结构当中,都使用了轴向深度可分离卷积层(Axial DW Conv),该结构能够减少一定的计算负担,同时还能够提取更多的图像特征,该结构若与膨胀卷积结合还能进一步扩大感受野。BottleNeck 结构主要是为了实现多层次图像特征提取。本文对 LU2Net 的改进主要体现在将 LU2Net 模型当中的编码模块和解码模块从两级增加到四级,并将模型中的 GELU 激活函数全部转化为 Hardswish 激活函数。


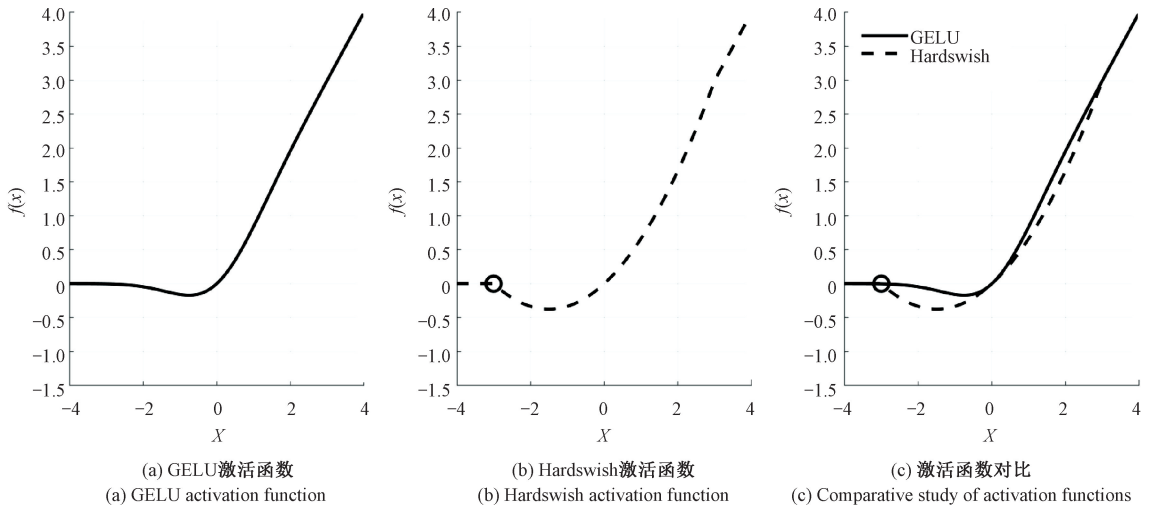


图 3 LU2Net 增强效果

Fig. 3 LU2Net enhancement effects



注:图中圆圈代表的是函数中的不可导点。

图 4 GELU 激活函数与 Hardswish 激活函数对比图

Fig. 4 Comparison diagram of GELU activation function and Hardswish activation function

相似性损失,用来衡量输出图像与真实图像在结构上的相似性, l_{VGG} 为 VGG 感知损失,本实验中采用的是预训练的 VGG19,用来衡量输出图像与真实图像之间的感知一致性。

损失函数中 $\lambda_1, \lambda_2, \lambda_3, \lambda_4, \lambda_5$ 为各部分损失相对应

的权重。该模型需要将预处理获得的拼接图像输入到一个内核大小为 7×7 的卷积层当中,将三通道的图像转换成 16 通道的图像,从而完成了图像的浅层特征提取,之后连续经过了 4 个编码模块, BottleNeck 结构和 4 个解码模块,其中编码模块和解码模块之间引入了 U-net 结构中的跳跃连接机制,该部分实现了更深层次的特征提取。最后通过一个内核为 1×1 的卷积层生成了三通道的增强图像。

1.3 损失函数

损失函数主要是为了计算模型预测结果与真实值之间的差距,在训练模型的过程中,通常要将损失函数的结果最小化,从而提高模型预测结果的准确性。为了更加全面的感知图像的信息并实现更加优秀的图像增强效果,该方法中使用了一个融合的多维度损失函数 l_{total} , 该损失函数的表达式被设计成式(3),即:

$$l_{total} = \lambda_1 l_{pixel} + \lambda_2 l_{LAB} + \lambda_3 l_{LCH} + \lambda_4 l_{SSIM} + \lambda_5 l_{VGG} \quad (3)$$

其中, l_{pixel} 计算的是像素损失,计算的是输出图像与标签图像之间像素差异的平方的总和,即逐像素均方误差。该损失的计算方式如式(4)所示。

$$l_{pixel} = \sum_1^N (I_m - I_m^*)^2 \quad (4)$$

其中, N 表示的是图像中的像素总数, I_m 表示的是增强图像当中的第 m 个像素, I_m^* 表示的是标签图像当中的第 m 个像素,其中 I_m 和 I_m^* 之间是一一对应的关系。

损失函数中的 l_{LAB}, l_{LCH} 计算的分别是输出图像与标签图像在 LAB, LCH 颜色空间上的均方误差。 l_{SSIM} 是结构

的权重。

2 实验结果与分析

2.1 实验环境

本实验使用 Pytorch 平台对该模型进行训练,模型优

化过程当中使用了 Adam 优化器,初始学习率设置为 0.0005,每 40 个 epoch 调整一次学习率,每次调整学习率的过程当中将学习率乘上 0.8,总共训练 200 个 epoch。实验在硬件环境为 8 G 显存的 NVIDIA GeForce RTX 4060 Laptop GPU、Windows11 操作系统的计算机上进行。

2.2 数据集构建与使用

构建了一个浑浊水下的偏振图像数据集,实验装置以及环境如图 5 所示,其中,图 5(a)展示了实验装置的侧视图;图 5(b)展示了实验装置的正视图;图 5(c)展示了实验装置的俯视图。该数据集在实验室环境下进行,主要实验仪器有偏振相机、玻璃水槽、模型(包括海参,海星,海螺等)等。该实验通过在清水中依次等量加入 BaSO_4 粉末来




图 5 偏振图像数据集采集实验环境

Fig. 5 Environment for polarized image dataset acquisition

2.3 主观评价

为了证明本文方法的有效性,设计了涵盖多种主流图像增强模型的对比实验。首先,对各方法的生成结果进行了基于视觉感知的主观评价。在实验中,选择了 3 种传统方法,分别为 UDCP、ULAP^[18] 和 MLLE^[19]。选择了 3 种深度学习的方法,分别为 Shallow-UWNet^[20]、FA⁺-Net^[21] 和 FU⁺IE-GAN^[22]。最后又对比了改进算法和 LU2Net 算法的输出结果。

如图 6 所示,UDCP 算法和 Shallow-UWNet 算法能够起到一些去除水体浑浊效果,但是图像的细节几乎未被恢复。ULAP 能够恢复一些图像的细节,但出现了红色色偏的现象。FA⁺-Net 模型能够在多个尺度上处理输入特征图,从而捕获不同尺度细节信息,但是在该实验当中,增强的效果未达预期,并且在这个过程中出现了绿色的色偏。MLLE 算法能够实现图像的细节增强,并且能够实现图像背景的增强,但是实验的结果当中出现了大量的噪声,严重的影响图像观感。FU⁺IE-GAN 模型快速并且参数较少,在本实验当中能够恢复很多图像的纹理细节并实现图像的背景增强,不过在对浅色物体的细节复原上还存在缺陷。而 LU2Net 算法属于轻量化模型,但是在对图像细节提取上存在问题,并且有过度平滑的现象发生,在训练的过程当中会发现一些浅色区域会与背景融为一体。本文的方法,不仅能够提取和恢复更多的图像纹理和边缘

制造浑浊水环境,实验中设置了 0~50 mg/L 共 11 组不同浓度的 BaSO_4 悬浊液。在图像拍摄的过程中,本实验选择直接使用环境光,以此来模拟真实的环境。实验中使用偏振相机共拍摄了 143 组偏振图像,每组偏振图像中包含了 0°、45°、90°、135° 共 4 个偏振分量的图像。然后通过算法对偏振相机采集到的图像进行灰度化处理,获取到灰度化的浑浊水下偏振图像数据集。为了扩充该数据集,将每组偏振图像进行了旋转和翻转的操作,并将图像中的主体部分切割出来,最终获得了 1 144 组偏振图像。在该数据集当中,清水中拍摄的图像被作为标签图像,又从 45 mg/L 和 50 mg/L 的图像组中挑选出 26 组图像作为测试集,其余的图像组全部用来作为训练集进行模型的训练。

细节,提高图像的视觉观感,还能够完成对图像背景的恢复,甚至连图像在背景上产生的阴影都能够成功复原,整体效果好。

2.4 客观评价

在对图像的客观评价当中,由于标签图像的背景相比结果图像来说更加灰暗,整体图像质量相比一些结果图像更差,因此,在这个过程中峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似性指数(structure similarity index measure, SSIM)两个指标已经很难对生成图像质量的优劣做出评判。本文中使用了有参考的图像指标感知相似性指标^[23](learned perceptual image patch similarity, LPIPS),还有无参考的图像指标,水下图像质量评估指标(underwater image quality measure, UIQM),水下彩色图像质量评估(underwater color image quality evaluation, UCIQE),自然图像质量评估(natural image quality evaluator, NIQE),来对生成的结果图像进行客观的评价。

其中, LPIPS 被用来评价结果图像与标签图像之间的感知差异, LPIPS 的值越小,则能够说明图像之间的感知差异更小。无参考的指标 UIQM 和 UCIQE 也是比较常用的无参考图像评价指标。其中 UIQM 是用来评价水下图像的清晰度和对比度等的一个指标, UIQM 的值越高说明图像的整体质量越高。UCIQE 则是通过统计方法评估图像对比度等的一个指标, UCIQE 的值越高也能够说明图

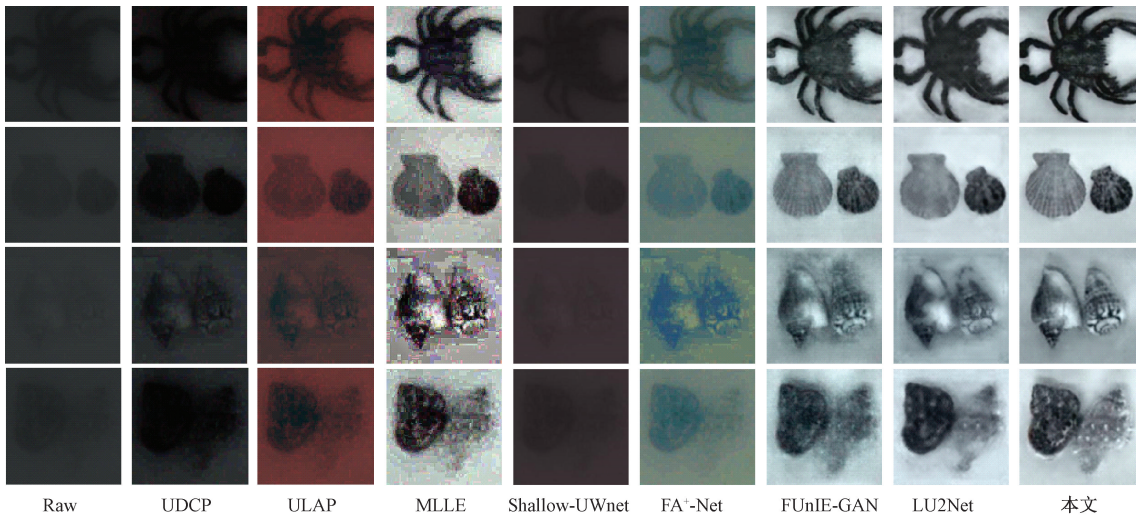


图 6 各图像增强方法实验结果对比

Fig. 6 Comparison of image enhancement results

像的整体质量越高。NIQE 是自然图像质量评估指标, NIQE 的值越低说明图像的视觉观感越好, 图像更加自然。

在实验的过程当中, 发现本文方法的无参考指标并没有达到最优, MLE 方法在 UIQM 和 UCIQE 上反而达到了最优分别达到了 2.44 和 0.551 4。由于 MLE 的生成图像中存在大量的噪声, 这些噪声可能会产生很多的虚假细节, 进而导致无参考图像指标的升高。因此, 要得到准确的结论还需要结合主客观评价结果进行综合评价。

最终, 将获得的图像结果评价指标进行整理, 具体结果如表 1 所示。可知本文方法的 LPIPS 达到了较高水平, 其值为 0.323 3, 对于其他指标, UIQM 值为 1.97, UCIQE 值为 0.463 0, NIQE 达到了 4.592 0, 也达到了较高的水平。由此可知, 本文方法能够使图像的对比度和图像细节的清晰度提高并获得更好的视觉效果。因此, 本文方法具有良好的图像增强效果。

表 1 浑浊水图像增强指标对比

Table 1 Turbid water image enhancement metric comparison

增强方法	LPIPS ↓	UIQM ↑	UCIQE ↑	NIQE ↓
UDCP	0.402 6	1.210 0	0.371 2	6.481 9
ULAP	0.480 2	1.960 0	0.437 0	6.122 6
MLE	0.717 0	2.440 0	0.551 4	7.085 4
Shallow-UWnet	0.334 5	0.830 0	0.302 9	7.446 9
FA ⁺ -Net	0.501 8	1.660 0	0.377 9	6.033 0
FUnIE-GAN	0.456 1	2.400 0	0.452 3	4.561 7
LU2Net	0.418 8	1.920 0	0.457 7	4.969 0
本文	0.323 3	1.970 0	0.463 0	4.592 0

注: 各个指标最优的前 3 名, 分别使用双下滑线、单下划线和波浪线进行标识。

2.5 消融实验

为证明各处改进的具体作用及有效性, 本文从主观和客观两个方面对消融实验的结果进行评估, 具体包括: 只改用 Hardswish 激活函数的实验和只增加模型中编码模块和解码模块的实验。

消融实验对比结果如图 7 所示, 其中图 7(a) 展示了 LU2Net 的生成结果图; 图 7(b) 展示了改用 Hardswish 激活函数后的生成结果图; 图 7(c) 展示了增加编码解码模块层数后的生成结果图; 图 7(d) 展示了本文方法的生成结果图。其中, LU2Net 结构只能提取到少量的图像特征并且存在细节模糊。在改用了 Hardswish 激活函数之后, 图像的纹理更加的清晰, 如图 7(b) 中螃蟹海螺上的花纹和海星上的斑点, 都要比 LU2Net 模型生成的结果更加清晰, 但是这种改动无法获取到更多的细节特征。在只增加模型深度的情况下, 模型提取和恢复的图像纹理和细节更加丰富, 具体情况如图 7(c) 所示, 但是获得的细节特征模糊, 很多区域仍旧存在细节过度平滑的问题。本文方法在结合了两种改进之后, 获取了清晰丰富的图像细节, 增强后的图像获得了最优的视觉观感, 具体情形如图 7(d) 所示。

本文通过 LPIPS, UCIQE 和 NIQE 这几个图像评价指标来对消融实验结果图像的质量进行客观评价。具体结果如表 2 所示。通过表格中的数据, 可以推断出, 本文提及的两处改进删减任意一处都会导致模型的纹理和边缘细节恢复性能下降, 主要体现在图像观感变差, 对比度降低, 感知差异变大等方面。增加原模型深度的同时改用 Hardswish 激活函数能够实现良好的图像增强效果。

2.6 特征点检测分析

为了进一步证明本文改进方法的有效性, 本文选择了

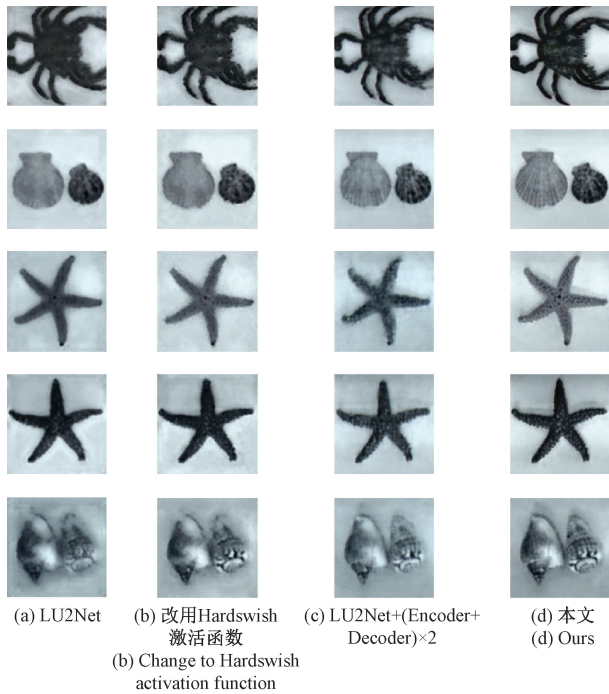


图 7 消融实验结果对比

Fig. 7 Visual comparison of ablation study results

4 种不同的特征点检测方法来检测结果图像的特征点。这 4 种特征点检测方法分别是 AKAZE, BRISK, KAZE 和 ORB。




图 8 AKAZE 特征点检测方法结果图

Fig. 8 AKAZE feature point detection result

本文列出了特征点匹配数目表,具体结果如表 3 所示,在 4 种特征点检测方法中,本文方法能够检测出的特征点数目总能达到 3 种增强方法中的最高值。尤其是在 Image6 和 Image7 两张图的特征点匹配效果中,本文方法在 ORB 特征点匹配方法匹配到的特征点数目分别为 401 和 425,远高于 FUInE-GAN 匹配到的 246 和 374 个特征点,和 LU2Net 匹配到的 164 和 133 个特征点;本文方法在 KAZE 方法中匹配到的特征点数目分别为 245 和 218,远高于 FUInE-GAN 匹配到的 108 和 122 个特征点,和

表 2 消融实验结果评价指标对比

Table 2 Ablation study evaluation metrics comparison

增强方法	LPIPS ↓	UCIQE ↑	NIQE ↓
LU2Net	0.418 8	0.457 7	4.969 0
LU2Net+(Encoder+Decoder)×2	0.388 8	0.459 0	4.774 5
LU2Net 改用 Hardswish	0.435 7	0.455 9	5.071 5
本文方法	<u>0.323 3</u>	<u>0.463 0</u>	<u>4.592 0</u>

注:最优结果使用双下划线标注。

其中,ORB 特征检测方法具有实时性高的特点。KAZE 特征点检测方法有较强的抗噪能力,并且适合高精度匹配。BRISK 特征点检测方法,适用于多尺度图像匹配。AKAZE 是一种加速的 KAZE 算法,运行速度快,并且性能更加的稳定。

本文使用这 4 种不同的特征点检测方法,通过比较结果图像匹配的特征点数目来判断各个增强方法的优劣,检测到的特征点越多,说明该增强方法的效果更好。其中,由于某些增强方法生成的图像存在边缘纹理模糊等质量问题,无法匹配到特征点。因此,本文中恢复效果较好的 FUInE-GAN,LU2Net 和本文方法的特征点匹配结果被列出,具体结果如图 8~11。其中图 8 展示了 AKAZE 特征点检测方法所得的结果,图 9 展示了 BRISK 特征点检测方法所得的结果,图 10 展示了 KAZE 特征点检测方法所得的结果,图 11 展示了 ORB 特征点检测方法所得的结果。

LU2Net 匹配到的 130 和 132 个特征点;本文方法在 BRISK 特征点匹配方法当中匹配到的特征点数目分别为 90 和 141,远高于 FUInE-GAN 方法匹配到的 56 和 64 个特征点,和 LU2Net 方法匹配到的 35 和 23 个特征点;本文方法在 AKAZE 特征点匹配方法当中匹配到的特征点数目分别为 132 和 134,远高于 FUInE-GAN 能够匹配到的 61 和 66 个特征点,和 LU2Net 能够匹配到的 84 和 80 个特征点。由此可知,本文方法在不同种类的图像上都能取得良好的特征点检测效果,证明了本文提出的改进模型,




图 9 BRISK 特征点检测方法结果图

Fig. 9 BRISK feature point detection result

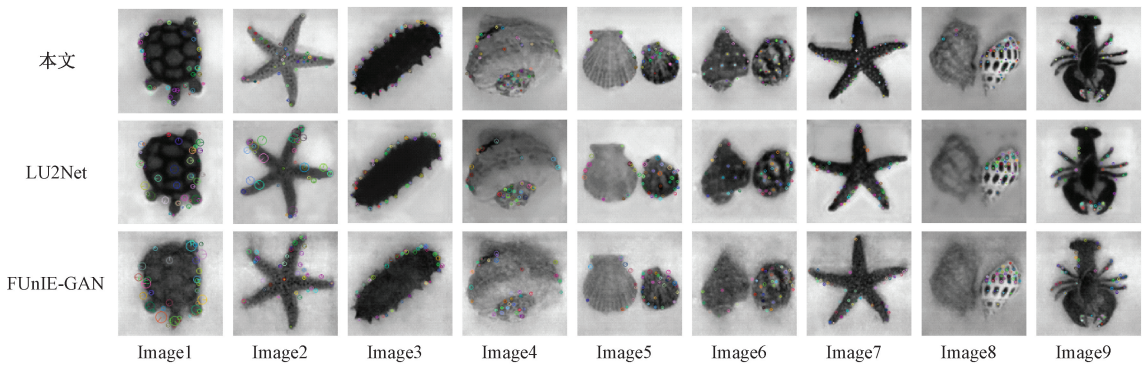


图 10 KAZE 特征点检测方法结果图

Fig. 10 KAZE feature point detection result

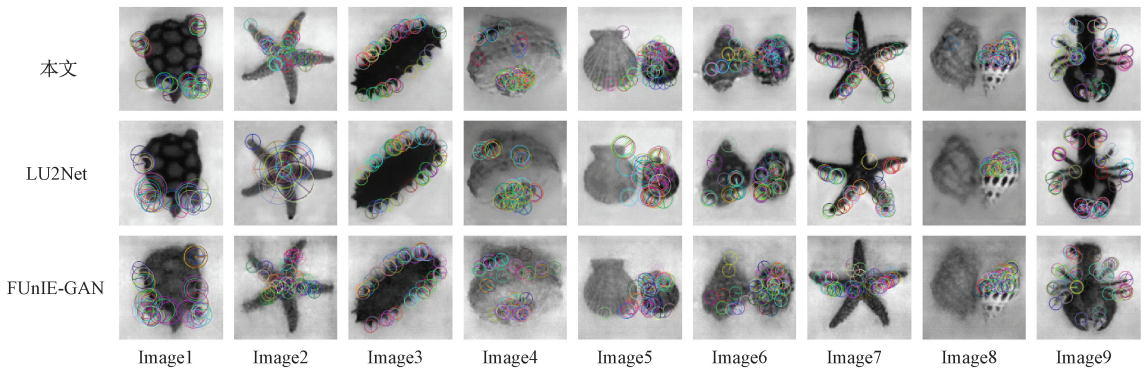


图 11 ORB 特征点检测方法结果图

Fig. 11 ORB feature point detection result

在图像纹理细节的增强方面具有良好的效果,能够获取更多更清晰的边缘和纹理特征。综上分析,增加原模型编码模块和解码模块能够更好的提取图像的边缘和纹理细节,改用平滑性较低但性能优越的 Hardswish 激活函数能够提高图像边缘和纹理的清晰度,因此本文提出的模型能够匹配到更多的特征点,具有更好的细节增强效果。

2.7 Canny 边缘检测分析

本文通过采用 Canny 边缘检测,比较各算法结果图像

的边缘完整性和边缘所占像素数,来判断图像增强方法方面的有效性。图像的边缘完整性越高,边缘所占像素数越高,越能证明图像增强方法的有效性。UDCP 等图像增强方法在增强本文图像时,由于生成图像存在显著的边缘纹理特征弱化现象,Canny 边缘检测无法有效的从中提取出边缘分布图。因此,本文在此处列出 FUInIE-GAN、LU2Net、MLLE 和本文方法的边缘检测结果图。具体结果如图 12 所示。

表 3 图像特征点匹配结果表
Table 3 Feature point matching result

检测方法	增强方法	Image1	Image2	Image3	Image4	Image5	Image6	Image7	Image8	Image9
ORB	FUnIE-GAN	47	260	144	264	142	246	374	319	236
	LU2Net	37	23	154	113	73	164	133	348	168
	本文方法	<u>72</u>	<u>290</u>	<u>197</u>	<u>350</u>	<u>252</u>	<u>401</u>	<u>425</u>	<u>384</u>	<u>298</u>
KAZE	FUnIE-GAN	55	80	109	69	80	108	122	147	155
	LU2Net	64	61	109	75	90	130	132	160	159
	本文方法	<u>92</u>	<u>126</u>	<u>149</u>	<u>129</u>	<u>144</u>	<u>245</u>	<u>218</u>	<u>196</u>	<u>219</u>
BRISK	FUnIE-GAN	8	22	36	46	27	56	64	55	38
	LU2Net	7	3	38	26	17	35	23	53	17
	本文方法	<u>13</u>	<u>52</u>	<u>39</u>	<u>88</u>	<u>54</u>	<u>90</u>	<u>141</u>	<u>71</u>	<u>59</u>
AKAZE	FUnIE-GAN	22	38	41	45	52	61	66	75	85
	LU2Net	35	19	55	38	17	84	80	87	83
	本文方法	<u>44</u>	<u>59</u>	<u>64</u>	<u>84</u>	<u>79</u>	<u>132</u>	<u>134</u>	<u>110</u>	<u>135</u>

注:最优结果使用双下划线标注。

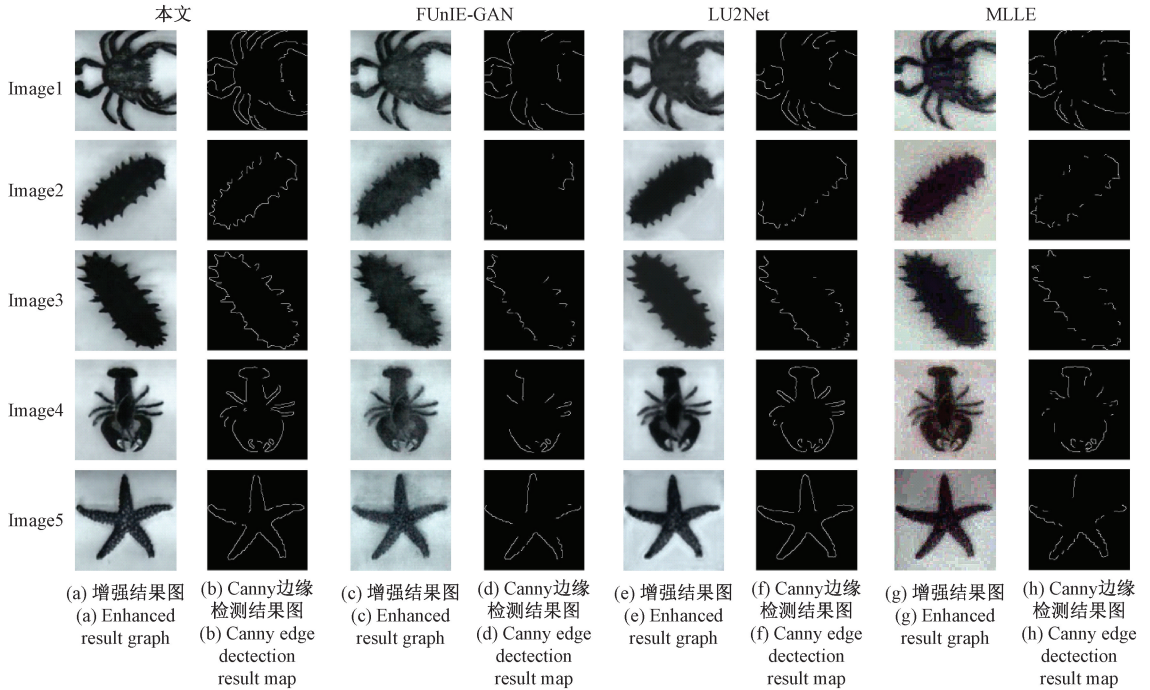


图 12 Canny 边缘检测结果对比图

Fig. 12 Canny edge detection comparison

如表 4 所示,本文方法检测出的边缘像素数较高。尤其是在 Image1 和 Image3 两幅图当中,本文方法获得的边缘像素数分别为 2 836、2 141,远高于 FUnIE-GAN 获得的边缘像素数依次为 2 085、1 610;LU2Net 获得的边缘像素数分别为 2 197、1 681;MLLE 获得的边缘像素数依次为 2 069、1 615。上述结果证实了该模型在边缘信息恢复方面的有效性。该模型能够增强边缘特征的学习,同时抑制细节过度平滑导致的边缘模糊问题,从而提升了边缘轮廓的锐度和清晰度,最终优化了图像边缘的恢复质量。

表 4 Canny 边缘检测结果比表

Table 4 Comparative results of Canny edge detection

增强方法	Image1	Image2	Image3	Image4	Image5
FUnIE-GAN	2 085	1 258	1 610	1 671	1 758
LU2Net	2 197	1 415	1 681	2 193	2 129
MLLE	2 069	1 476	1 615	1 814	1 733
本文方法	<u>2 836</u>	<u>1 838</u>	<u>2 141</u>	<u>2 366</u>	<u>2 143</u>

注:最优结果使用双下划线标注。

3 结 论

本文提出了一种基于改进 LU2Net 的浑浊水偏振图像增强模型,将偏振成像和深度学习进行结合,提高了对图像边缘和纹理特征的提取和恢复效果。该方法在 Canny 边缘检测算法和 ORB 等特征点检测方法当中,与对比方法相比,都拥有更多的边缘像素值和特征点。在对应的指标方面本文模型的 LPIPS 相比现有对比的最优方法降低了 3.35%,UCIQE 相比改进前的算法增加了 1.16%,NIQE 相比改进前的算法降低了 7.59%。该方法能够解决浑浊水中因散射和吸收造成的图像边缘和纹理等特征缺失的图像退化问题。实验结果表明,该方法能够在自然光状态下的浑浊水环境中提取到更多的图像细节特征,尤其是在图像的边缘和纹理的增强方面能够取得优秀的表现,这也验证了该改进模型的有效性和合理性。在本方法的基础上,可以继续完成浑浊水下的目标识别和分类等相关工作。还可以继续改进模型的浅层特征提取,使模型在浅层特征提取的过程中即可获取更多的细节特征。同时,浑浊水偏振图像数据集有待扩充,可模拟多种水下环境,提高方法的鲁棒性,从而提高复杂水下场景的匹配程度,进而应用于海洋观测等方面。

参考文献

- [1] 胡雨航,赵磊,李恒,等.多特征选择与双向残差融合的无监督水下图像增强[J].电子测量与仪器学报,2023,37(9):190-202.
HU Y H, ZHAO L, LI H, et al. Unsupervised underwater image enhancement with multi-feature selection and bidirectional residual fusion[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(9): 190-202.
- [2] HUANG B J, LIU T G, HU H F, et al. Underwater image recovery considering polarization effects of objects[J]. Optics express, 2016, 24(9): 9826-9838.
- [3] LI X B, YAN L, QI P F, et al. Polarimetric imaging via deep learning: A review[J]. Remote Sensing, 2023, 15(6): 1540.
- [4] DONG Y, WAN J CH, WANG X J, et al. A polarization-imaging-based machine learning framework for quantitative pathological diagnosis of cervical precancerous lesions[J]. IEEE Transactions on Medical Imaging, 2021, 40(12): 3728-3738.
- [5] LIU F, WEI Y, HAN P L, et al. Polarization-based exploration for clear underwater vision in natural illumination [J]. Optics Express, 2019, 27(3): 3629-3641.
- [6] ZHANG W F, LIANG J, JU H J, et al. A robust haze-removal scheme in polarimetric dehazing imaging based on automatic identification of sky region[J]. Optics & Laser Technology, 2016, 86: 145-151.
- [7] HU H F, ZHAO L, LI X B, et al. Polarimetric image recovery in turbid media employing circularly polarized light[J]. Optics Express, 2018, 26(19): 25047-25059.
- [8] LUO X Y, WANG S, LIU J P, et al. Revolutionizing optical imaging: Computational imaging via deep learning[J]. Photonics Insights, 2025, 4(2): R03.
- [9] HU H F, ZHANG Y B, LI X B, et al. Polarimetric underwater image recovery via deep learning [J]. Optics and Lasers in Engineering, 2020, 133: 106152.
- [10] YANG SH L, QU B W, LIU G SH, et al. Unsupervised learning polarimetric underwater image recovery under nonuniform optical fields[J]. Applied Optics, 2021, 60(26): 8198-8205.
- [11] ZHANG R, GUI X Y, CHENG H Y, et al. Underwater image recovery utilizing polarimetric imaging based on neural networks[J]. Applied Optics, 2021, 60(27): 8419-8425.
- [12] DING X Y, WANG Y F, FU X P. Multi-polarization fusion generative adversarial networks for clear underwater imaging [J]. Optics and Lasers in Engineering, 2022, 152: 106971.
- [13] REN Q M, XIANG Y F, WANG G CH, et al. The underwater polarization dehazing imaging with a lightweight convolutional neural network[J]. Optik, 2022, 251: 168381.
- [14] 刘贺东,韩宜霖,李校博,等.基于深度神经网络的水下图像偏振信息复原方法[J].光学学报,2024,44(12): 61-70.
LIU H D, HAN Y L, LI X B, et al. Polarization information restoration of underwater images based on deep neural network[J]. Acta Optica Sinica, 2024, 44(12): 61-70.
- [15] ALHASSAN A M, ZAINON W M N W. Brain tumor classification in magnetic resonance image using hard swish-based RELU activation function-convolutional neural network [J]. Neural Computing and Applications, 2021, 33(15): 9075-9087.
- [16] ZHANG S, ZHAO SH L, AN D, et al. LiteEnhanceNet: A lightweight network for real-time single underwater image enhancement [J]. Expert Systems with Applications, 2024, 240: 122546.
- [17] YANG H D, XU J SH, LIN ZH L, et al. LU2Net: A lightweight network for real-time underwater image enhancement[J]. ArXiv preprint arXiv: 2406.

- 14973, 2024.
- [18] SONG W, WANG Y, HUANG D M, 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, Hefei: Springer International Publishing, 2018: 678-688.
- [19] ZHANG W D, ZHUANG P X, 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.
- [20] 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.
- [21] JIANG J, YE T, BAI J, et al. Five A+ network: You only need 9K parameters for underwater image enhancement[J]. ArXiv preprint arXiv: 2305.08824, 2023.
- [22] 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.
- [23] ZHANG R, ISOLA P, EFROS A A, et al. The unreasonable effectiveness of deep features as a perceptual metric[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 586-595.

作者简介

张振楷, 硕士, 主要研究方向计算机视觉、水下偏振成像。
E-mail: zzkai_99@163.com

张浩(通信作者), 博士, 副教授, 主要研究方向计算机视觉、水下成像。
E-mail: zhanghao@qut.edu.cn