

文章编号 1004-924X(2026)11-1693-15

空域与频域融合的多尺度浑浊水图像增强

张浩^{1*}, 张庆文¹, 刘飞², 宋雨佳¹, 李长青¹

(1. 青岛理工大学信息管理学院, 山东 青岛 266520;

2. 西安电子科技大学物理与光电工程学院, 陕西 西安 710071)

摘要:针对色偏严重且高度浑浊的水下环境导致图像对比度降低、纹理丢失等问题,提出一种空域与频域融合的多尺度深度学习图像增强网络。通过融合 Retinex 物理机理与多尺度深度特征,有效缓解了浑浊水体中的散射噪声干扰。同时构建混合卷积与空间-频域注意力协同机制,在网络编解码阶段嵌入双路径注意力结构以同步捕捉双域特征,增强了复杂降质环境下的建模能力。利用自适应选择性内核融合机制对深层语义进行特征精炼,实现复杂环境下细节纹理的重构与色偏的精细校正。实验结果表明,在浊度为 54.11 NTU 的无色偏以及绿色色偏和蓝色色偏浑浊水图像上,所提方法相较于最优的对比方法 PSNR 指标平均提升了 0.464, 0.473 和 1.944 dB, LPIPS 指标平均降低了 0.94%。该方法在浑浊水图像增强方面具有较好的效果,可以为水下机器人视觉质量提升提供一种有效方案。

关键词:计算机视觉;水下图像增强;浑浊水体;深度学习

中图分类号:TP391.4 **文献标识码:**A

doi:10.37188/OPE.20263411.1693 **CSTR:**32169.14.OPE.20263411.1693

Multi-scale image enhancement in turbid water via spatial-frequency domain fusion

ZHANG Hao^{1*}, ZHANG Qingwen¹, LIU Fei², SONG Yujia¹, LI Changqing¹

(1. School of Information Management, Qingdao University of Technology, Qingdao 266520, China;

2. School of Physics and Optoelectronic Engineering, Xidian University, Xi'an 710071, China)

* Corresponding author, E-mail: zhanghao@qut.edu.cn

Abstract: To address contrast degradation and texture loss caused by severe color casts and highly turbid underwater environments, a multi-scale deep learning network for image enhancement based on spatial-frequency domain fusion is proposed. By integrating the Retinex physical mechanism with multi-scale deep features, the proposed method effectively suppresses scattering noise interference in turbid water. In addition, a collaborative framework combining hybrid convolution with spatial-frequency domain attention is constructed, in which a dual-path attention structure is embedded within the encoder-decoder stages to simultaneously capture dual-domain features, thereby improving the modeling capability under complex degradation conditions. Furthermore, an adaptive selective-kernel fusion mechanism is employed to refine deep semantic features, enabling accurate texture reconstruction and color correction in complex scenes.

收稿日期:2026-04-11;修订日期:2026-05-11.

基金项目:国家自然科学基金资助项目(No. 62575229);陕西省自然科学基金资助项目(No. S2024-JC-JQ-0077, No. S2025-JC-QYTS-0107)

Experimental results demonstrate that, on turbid images with a turbidity of 54.11 NTU, including color-neutral, green-cast, and blue-cast samples, the proposed method achieves average PSNR improvements of 0.464, 0.473, and 1.944 dB, respectively, over state-of-the-art methods, while reducing the LPIPS metric by an average of 0.94%. These results indicate that the proposed method delivers superior performance in turbid underwater image enhancement and provides an effective solution for underwater robotic vision.

Key words: computer vision; underwater image enhancement; turbid water; deep learning

1 引 言

海洋资源的开发与生物多样性研究使水下观测成为学术界关注的焦点^[1]。然而,由于水体对光波的差异性吸收及悬浮颗粒造成的散射干扰,水下图像常伴随严重的色偏、对比度退化与细节模糊^[2]。特别是在浑浊水域中,能见度的骤降导致图像特征严重缺失,给水下机器人(AUVs/ROVs)的视觉感知带来了巨大挑战^[3]。视觉系统作为机器人实现自主避障、精密作业及即时定位与地图构建(Simultaneous Localization and Mapping, SLAM)的核心模块,其算法精度高度依赖图像的对比度与清晰度。因此,研究针对复杂退化环境的高保真图像增强算法,对于保障水下机器人智能化作业的稳定性与可靠性具有重要的学术价值与工程意义。

为了克服水下环境产生的图像退化缺陷,国内外研究人员在图像质量修复与视觉增强方面开展了广泛的研究。目前,主流技术路线可归纳为传统视觉修复与数据驱动学习两大类,传统方法进一步细分为物理模型方法与非物理模型方法。在物理模型方法中,偏振图像是水下修复图像中的一种,其去噪与增强技术经历了从通用信号处理到物理深度融合的演进^[4]。Wei等^[5]通过考虑目标反射光的空间非均匀分布,并利用独立成分分析技术实现目标光与后向散射光的有效分离,显著提升了复杂水下环境目标信息估计的准确性。Liu等^[6]提出了一种基于穆勒矩阵的偏振去散射算法,通过推导去偏振指数并结合优化函数估计透射率图,有效实现了不同浊度环境下水下目标的反照率恢复与视觉增强。从更广泛的维度来看,这种基于物理特性的成像方式属于计算成像的范畴。通过对光场的编码与解码,打破了传统成像的物理限制,为提取更丰富的水下信息提供了可能^[7]。对于非物理模型的方法,

Zhang等^[8]利用Retinex启发式策略修正水下色偏,随后将图像分解为全局对比度、局部对比度及细节增强三个版本,最后进行自适应融合。Zhang等^[9]提出了一种基于多尺度融合的水下图像增强算法,通过对原始图像进行双分支预处理和多尺度分解机制动态调整融合权重,有效缓解了水下成像中的色彩失真与模糊问题。

随着深度学习技术的飞速发展,基于数据驱动的图像处理方法逐渐成为水下图像增强领域的重要研究方向^[10-11]。Liu等^[12]提出了CCL-Net的两阶段深度学习框架,通过级联的颜色校正与去雾网络分别解决色彩偏差与能见度问题。为了进一步提升复杂退化场景下的色彩表现,DI-CAM模型引入了深度Inception结构与通道注意力模块,通过多尺度特征感知来应对水下图像的比例退化与非均匀色偏^[13]。此类模型虽然在公开数据集上表现优越,但在面对极高浊度的真实水体时,受限于局部感受野,仍难以完全恢复被散射掩盖的细微纹理。

近年来,Transformer架构因其强大的全局建模能力被引入水下视觉任务。Qi等^[14]提出CCMSR-Net算法,通过将CNN的局部提取优势与Transformer的全局语境感知相结合,实现了局部特征与全局信息的协同捕获。Fan等^[15]提出了一种SNR感知的双支路网络,利用SNR先验引导Transformer避开低信噪比区域,并结合多尺度卷积模块实现了特征的高效互补。Han等^[16]提出了UMCTN网络,通过构建多核卷积残差注意力机制并结合特征融合补偿模块对衰减严重的颜色通道与空间区域进行针对性修复,显著提升了模型对复杂水下环境的特征感知能力。虽然Transformer方法在色彩分布重建上展现出优异的稳定性,但其计算开销较大,且在抑制强散射噪声的同时保持高分辨率细节仍是挑战。

值得注意的是,上述方法大多局限于空间域

特征提取,难以有效解耦水下复杂的退化因子。为此,部分研究开始关注图像在频域中的表征能力。FDCE-Net^[17]提出通过空-频双域网络在频域内解耦复杂的退化因子,从而针对性地提升不同图像属性。Li等^[18]则提出了一种基于双编码器架构的增强模型,利用傅里叶增强模块在频域内对结构特征进行细节强化,同时在空域通过色彩补偿模块进行精细调整。该方法通过多尺度稠密特征聚合提升了对复杂环境的感知能力,证明了空-频域联合处理在提升图像泛化性与清晰度方面的有效性。

针对现有方法在处理浑浊水体时难以平衡色彩校正与细节恢复的问题,本文提出了一种多尺度细节增强网络。该方法针对性地设计了空间-频域感知与瓶颈层特征增强机制,旨在解决复杂降质环境下的细节丢失与严重色彩偏移。

2 浑浊水图像增强网络

2.1 总体网络结构

本文所提出的网络结构如图 1 所示,主要由 3 个部分组成:多尺度 SSR 去噪模块(Multi-Scale

SSR Denoising Module, MSSD)、混合卷积-空间频域注意力块(Hybrid Convolution-Spatial-Frequency Attention Block, HCSFAB)为主体的编码器-解码器架构以及多尺度细节增强模块(Multi-Scale Detail Enhancement Block, MSDEB)。

在整体网络架构中,经过 MSSD 模块处理的特征图通过一个初始特征提取模块(Init Block)获得基础特征表示,为后续深层特征学习提供基础。在编码阶段,网络共构建 4 个逐级下采样的编码单元,分别记为 Enc_1, Enc_2, Enc_3 和 Enc_4。各编码单元通过卷积与非线性映射操作,逐步压缩空间分辨率并提升特征维度,使特征表示从浅层结构信息逐渐过渡到具有更强语义表达能力的潜在特征空间。在编码器和解码器之间使用 MSDEB 对最小尺度的编码器特征图进行细节与纹理增强。与编码器对称,解码阶段同样由 4 个解码单元组成,记为 Dec_4, Dec_3, Dec_2 和 Dec_1。解码器通过逐级上采样与特征重建操作,将潜在空间中的高层特征逐步恢复至高分辨率特征图,从而实现对目标结果的逐层重构。

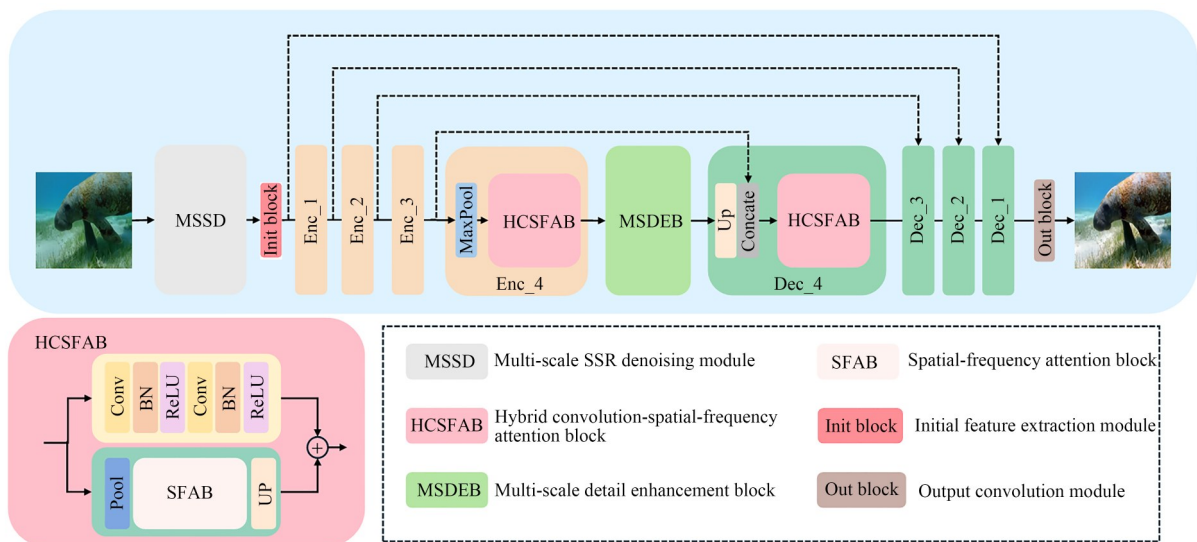


图 1 空频域融合的多尺度浑浊水图像增强网络

Fig. 1 Multi-scale turbid water image enhancement network based on spatial and frequency domain fusion

2.2 多尺度 SSR 去噪模块

基于 Retinex 理论^[19],水下图像通常可被分解为反射分量 R 与照明分量 L 。其中,反射分量

R 主要承载场景的结构与纹理信息,而照明分量 L 则与水体散射及光照条件密切相关:

$$I = R \odot L. \quad (1)$$

多尺度 Retinex^[20] (Multi-Scale Retinex, MSR)通过引入多个尺度的高斯核,从不同感受野对照明分量进行建模,以兼顾局部细节增强与整体亮度。受其启发,本文提出了一种多尺度 SSR 去噪模块(MSSD),其结构如图 2 所示。

该模块构建了一个基于多尺度 Retinex 的特征提取过程。即在尺度为 s 的条件下,首先利用高斯平滑算子 G_s 对输入图像进行滤波,以获得对应尺度的照明估计。然后在对数域中构建改进的 SSR 表达:

$$SSR_s = \log(I + \epsilon) \odot (1 - \log(G_s(I + \epsilon))), \quad (2)$$

其中: G_s 表示尺度为 s 的高斯模糊算子, ϵ 为防止数值不稳定的常数项。在本文中选取 $s \in \{3, 7, 11\}$, 分别对应细粒度纹理增强、中尺度结构增强以及大尺度光照校正。

为了缓解多尺度 Retinex 增强结果伴随着噪声放大和局部伪影问题并在保留多尺度互补特性的同时抑制噪声,本文在 MSR 表达之后设计了一个去噪网络 DenoiseNet, 其结构由 3 个残差

扩张卷积块顺序堆叠而成,扩张率 $d \in \{1, 2, 1\}$, 并在网络末端引入全局残差连接。残差扩张卷积块是共享去噪网络的核心组件,该模块由两层卷积以及通道注意力模块组成。在每个残差块中,先采用一个 3×3 扩张率为 d 的扩张卷积(Dilated Convolution)对输入特征进行空间建模。再使用 LeakyReLU 激活函数增强非线性表达能力,并进一步通过一个标准 3×3 卷积对特征进行精细重建。考虑到不同特征通道在去噪与结构恢复中的重要性存在差异,本文在每个空洞块后加入通道注意力模块(SE),利用轻量级通道映射对特征进行自适应重标定,从而突出对水下图像增强更为关键的特征通道,抑制冗余以及噪声相关特征。

多尺度 SSR 去噪模块可以视为一个非线性映射,其数学表达如下:

$$F_{MSSD} = \text{Concat}(D_1, D_2, D_3), \quad (3)$$

其中: D_k 为 DenoiseNet 对 3 种不同尺度的 SSR 特征处理的输出, $k \in \{1, 2, 3\}$, F_{MSSD} 为多尺度 SSR 去噪模块的最终输出。

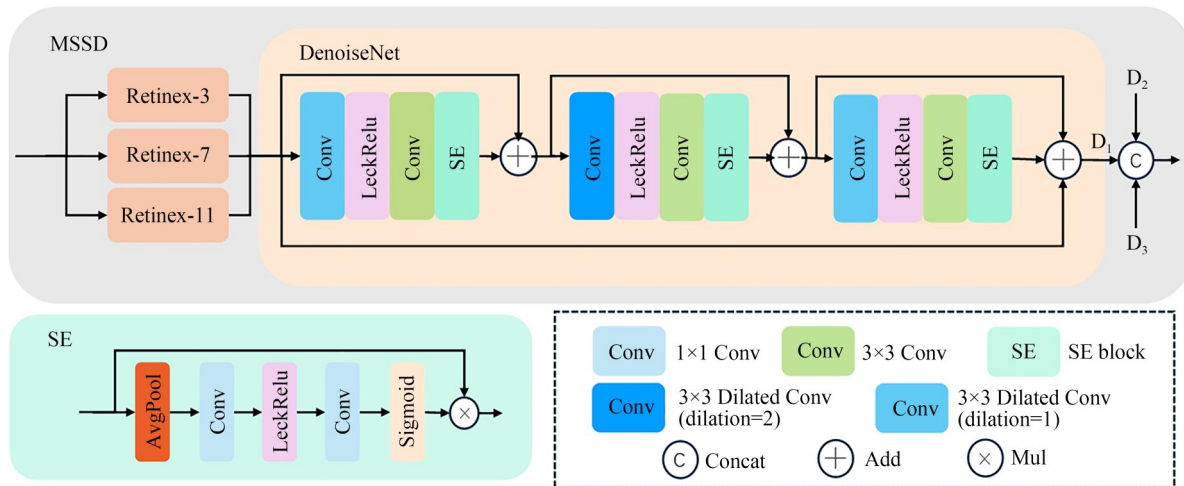


图 2 多尺度 SSR 去噪模块

Fig. 2 Multi-scale SSR denoising module

2.3 混合卷积-空间频域注意力块

本文设计了 HCSFAB, 在保持卷积结构高效性的同时,通过空间与频域注意力对特征进行补充增强,从而更有效地提升水下图像的整体质量与细节表现。

在浑浊水下场景中,图像退化主要表现为由散射引起的低频雾化和结构对比度下降。为此,

提出了 HCSFAB, 用于在特征层面抑制与浑浊相关的冗余信息。HCSFAB 由两个并行的子模块组成,即卷积子模块和空间-频域注意力子模块(Spatial-Frequency Attention Block, SFAB)。其中,卷积子模块由两层连续的 3×3 卷积构成,每一层卷积后接批量归一化层(Batch Normalization, BN)和 ReLU 激活函数,主要用于提取输入

特征中的局部结构和细节信息。与之并行的 SFAB 通过在空间域和频域对特征进行联合增强,频域注意力分支通过显式区分不同频率成分,有效削弱由水体散射导致的低频干扰;空间注意力分支则进一步在空间维度上突出结构显著区域,降低均匀浑浊背景的影响,引导网络更加关注具有判别性的区域和结构信息。

如图 3 所示, SFAS 采用双分支架构,由频域自注意力(FSA)分支和空间注意力(Spatial Attention, SA)分支组成。在 FSA 分支中^[22],为了高效捕获周期性模式和纹理细节,模块在频谱域执行注意力机制。与传统的自注意力不同,在 FSA 分支中,为了兼顾计算效率和较大范围的上下文关系,将按固定尺寸特征图划分为若干局部块 patch。随后,对每个 patch 应用二维快速傅里叶变换(2D Real Fast Fourier Transform, 2D RFFT),将这些局部块从空间域映射至频域:

$$Q_{in} = \mathcal{F}(F_q), K_{in} = \mathcal{F}(F_k). \quad (4)$$

频域自注意力本质上是在频域隐式完成了 QK^T 矩阵的计算。依据卷积定理^[23],空间域内 q_i

与所有 k_j 的内积(即 $(QK^T)_{ij} = \langle q_i, k_j \rangle$),等价于 Q_{in} 和 \bar{K}_{in} 的逐元素乘积。使用逆快速傅里叶变换 \mathcal{F}^{-1} (2D Inverse Real Fast Fourier Transform, 2D IRFFT) 可求得 Q_{in} 和 K_{in} 在频域中的相关性图,然后利用层归一化 L 求得频域注意力的权重:

$$V_{att-f} = L(\mathcal{F}^{-1}(Q_{in} \odot \bar{K}_{in})). \quad (5)$$

这种操作避免了显式构建注意力矩阵,使网络能够以远低于标准自注意力的计算成本在每个局部块内获得类全局的感受野。将注意力权重与 F_v 聚合,再经过一个 1×1 卷积进行通道压缩后得到频域注意力分支的输出 X_f 。

引入并行的 SA^[24] 分支,以增强对水下场景中显著区域和结构细节的表达,该分支的最终输出为 X_s 。两分支的融合过程可以表示为:

$$X_{out} = X_f + X_s. \quad (6)$$

针对浑浊水下图像中由光散射引起的低频雾化与对比度退化问题,频域注意力能够抑制与浑浊相关的冗余低频成分,SA 进一步突出结构显著区域并减弱均匀浑浊背景的干扰。

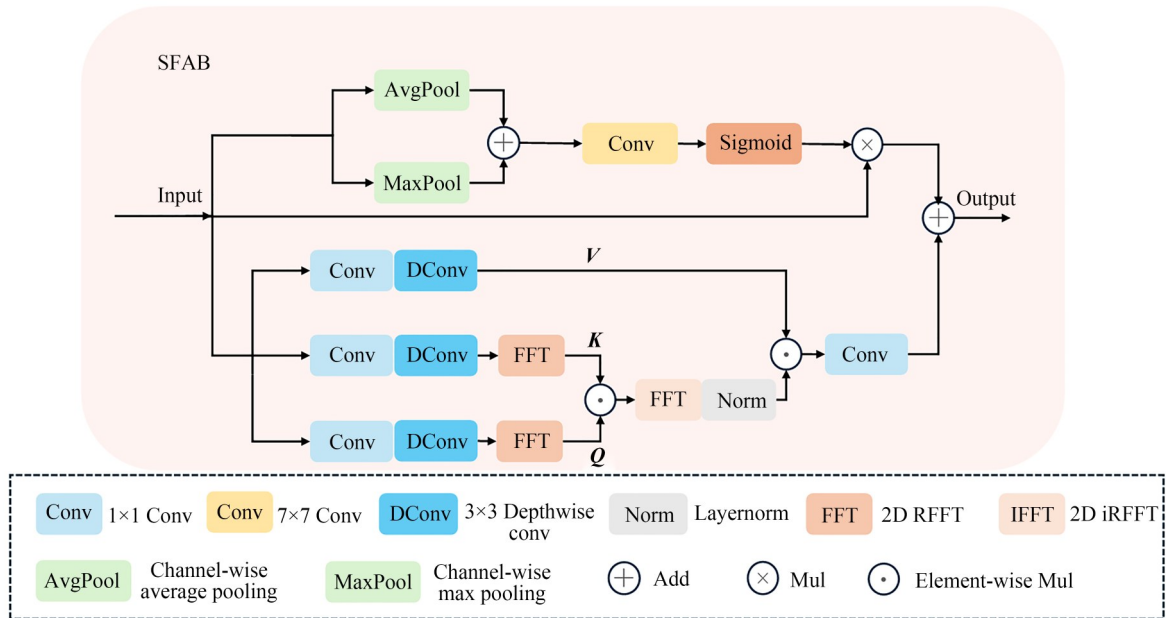


图 3 空间-频域注意力模块

Fig. 3 Spatial-frequency domain attention module

2.4 多尺度细节增强模块

本文在网络瓶颈层设计了 MSDEB,用于对

深层特征进行细化与补偿,其结构如图 4。针对水下图像在不同尺度上表现出的退化特性,首先

利用并行的深度可分离卷积(DSC)捕获跨尺度的空间信息。其中,1×1卷积侧重于保留逐像素的颜色信息,有助于校正蓝绿色偏;3×3和5×5

卷积则通过更大的感受野捕获被浑浊散射掩盖的结构边缘。引入RCB模块^[25]来捕获图像的全局环境信息。

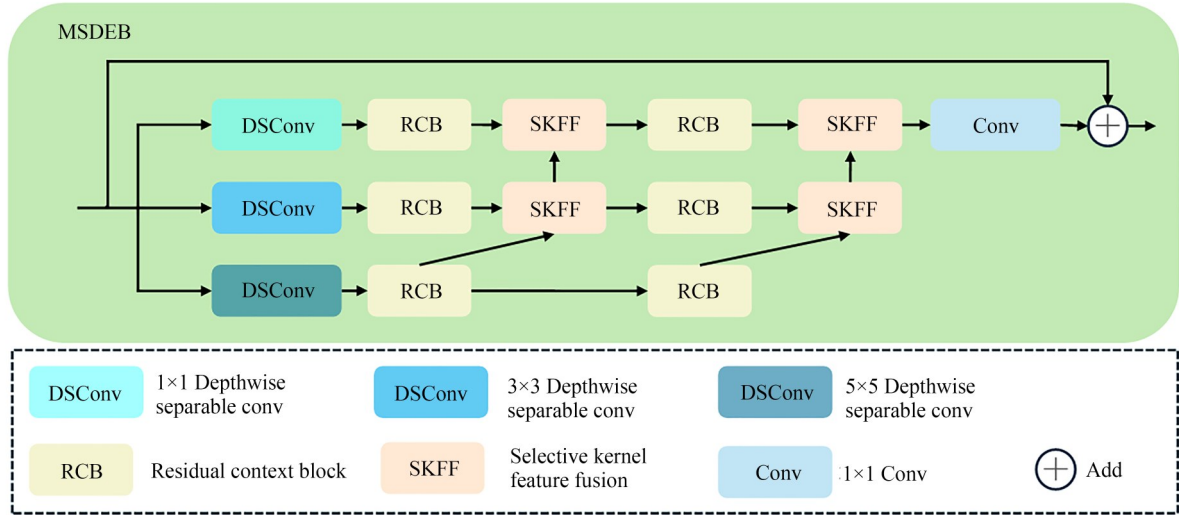


图4 多尺度细节增强模块

Fig. 4 Multi-scale detail enhancement block

水下环境的浑浊度是动态变化的,单一尺度的卷积难以应对所有降质情况。因此,利用SKFF机制来实现特征的动态筛选。SKFF的结构如图5所示。图中, F_{top} 和 F_{mid} 分别指输入

SKFF的大感受野和小感受野特征图,经Softmax算子在分支维度上进行竞争,产生 F_{top} 和 F_{mid} 两个输入分支的归一化选择性注意力权重 a 和 b 。这样在面对严重色偏或极度浑浊的区域时,SKFF会自动分配更高的权重给具有更强结构捕获能力的那一个输入分支,从而确保在增强细节的同时,不会过度放大背景噪声或引入伪影。

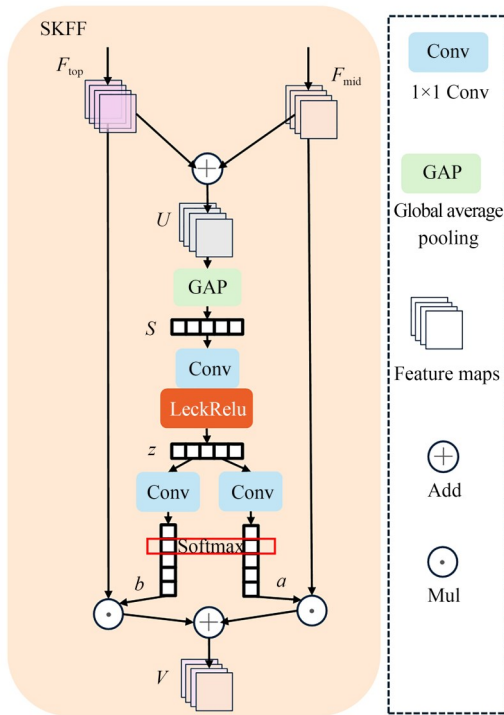


图5 选择性内核融合

Fig. 5 Selective kernel feature fusion

MSDEB采用了级联的两阶段融合策略。在第一阶段融合初步整合多尺度特征后,再次引入RCB块进行全局上下文的二次校准。这种迭代细化的过程显著增强了模型对复杂浑浊环境的适应性,让最终输出特征可以兼顾色彩一致性和纹理清晰度。

2.5 损失函数

为了监督所提出的增强网络并确保生成的图像 I_{out} 在内容和结构上与真实参考图像 I_{GT} 保持高度一致,采用均方误差(Mean Squared Error, MSE)作为目标优化函数。在水下图像增强任务中,MSE损失通过计算增强图像与参考图像之间所有像素点差值的平方和,强制模型在空间维度上实现精确的像素对齐。其数学表达式如下:

$$L_2 = \text{MSE}(I_{out}, I_{GT}) = \frac{1}{CHW} \| I_{out} - I_{GT} \|_F^2 \quad (7)$$

尽管浑浊水下图像面临复杂的退化问题,但该损失函数能够约束网络在宏观尺度上恢复图像的亮度与对比度。

3 实验与结果分析

3.1 实验环境及参数设置

本实验的模型训练与测试均在 PyTorch 平台上完成,硬件配置使用 AMD EPYC 9354 多核处理器以及 NVIDIA RTX 4090 GPU。训练阶段共进行 200 个 epoch,优化器采用 Adam,初始学习率设定为 1×10^{-4} ,批大小(batch size)设置为 12。

为开展本文的实验研究,在受控条件下构建了浑浊水体数据集。该数据集在封闭实验室环境中利用透明水槽进行采集。实验过程中,通过在清水中逐步加入等量的硫酸钡颗粒来调节水体浑浊度,共设置从 5 mg/L 至 50 mg/L 的 10 个梯度浓度,对应浊度为 11.56~54.11 NTU。

为模拟不同水下照明环境,分别采用蓝光、绿光和白光 3 种光源进行场景布光。为了更贴近真实海底视觉效果,水槽底部铺设了沙砾,并放置了珊瑚、龙虾、海螺及海星等多类仿真海洋物体。最终数据集共包含 600 幅浑浊水体图像,用在清水条件下拍摄的画面作为参考真值。

3.2 数据集

本研究采用多个公开的水下图像增强数据集对模型进行训练与评估,包括 UIEB^[26]、LSUI 以及 EUVP^[27]等数据集。UIEB 数据集从中随机抽取 800 张用于模型训练与验证,其余 90 张以及额外 60 张无参考的困难样本 Challenge-60 用于性能测试。LSUI 数据集从中选取 1 000 张用于训练与验证,另取 100 张构成测试集。为进一步验证所提方法在多种环境下的适应能力,还在 U45 数据集^[28]上与多种代表性方法进行了对比实验,以全面评估本方法的稳定性与泛化能力。

构建的浑浊水体数据集作为测试集,以进一步检验模型在高浑浊度场景下的适应能力和真实性能表现。该数据集具备更强的场景复杂度与光散射特性,专门用于模型的泛化验证,而不参与模型训练过程。

3.3 评估指标

在具有参考图像的测试集上,本研究采用

PSNR^[29],SSIM^[30]以及 LPIPS^[31]对增强结果进行定量评估。其中,PSNR 主要衡量重建图像与参考图像在像素层面的差异,数值越高表示失真越小;SSIM 从亮度、对比度和结构等维度综合评价图像结构保真度;LPIPS 利用深度特征度量图像间的感知差异,数值越低表明增强图像与参考图像在视觉感知层面更为接近。

对于无参考图像的数据集,使用 UIQM^[32],UCIQE^[33]和 NIQE^[34]作为评价指标。其中,UIQM 从清晰度、对比度与色彩饱和度 3 个方面综合反映水下图像质量;UCIQE 则通过亮度对比度、色调分离度和饱和度统计量评估图像的水下色彩质量;较低的 NIQE 分数通常表示增强图像更符合自然图像的统计分布,具有更高的视觉质量。

3.4 实验结果分析

3.4.1 定性评估

为了验证本文所提方法对浑浊水体图像增强的实际优化效果,将本文方法与现有方法进行对比分析,对比方法包括传统水下图像增强方法 MLLE^[35]和 WWPF^[36],以及深度学习的 LiteEnhance^[37],PUIE^[38],U-shape Transformer,NU²Net^[39],Phaseformer^[40]。在测试集中选取浊度值为 12.62,21.74,38.21,47.71 及 54.11 NTU 这 5 个不同浊度、不同模拟光环境下的浑浊水下图像进行增强,实验结果如图 6 所示。

MLLE 方法对亮度成分的调节幅度偏大,容易产生过度增强现象,其结果在亮度分布上与真实参考图像仍存在明显差异。在有色偏的浑浊水环境中,WWPF 方法能够在一定程度上削弱蓝绿色偏移,使图像色彩分布得到初步校正,但整体颜色不够自然,在视觉上与真实场景存在一定差距。

LiteEnhance 的优势在于模型计算需求低,但是面对浑浊水体和水下光线被吸收这一复杂退化情景,这类轻量级的方法的表现效果比较有限。PUIE 方法结合共识推断生成稳定的增强结果,一定程度上缓解了色偏,但是此方法对于细节的增强处理仍存在不足。U-shape 对于无色偏浑浊图像有较好的恢复能力,但是对于色偏浑浊图像的校正能力较为有限。NU²Net 对于蓝绿色偏都有一定的增强能力,但在增强后色彩仍不够




图 6 浑浊水测试集定性实验的比较

Fig. 6 Comparison of qualitative experiments on turbid water test sets

自然且图像的亮度偏暗。Phaseformer 利用频域中相位先验知识引导空域建模,该方法能够在一定程度上抑制浑浊水体造成的雾化效应,但对存在明显色偏的浑浊水质,其增强能力有限,尤其在散射与色偏同时存在时,输出图像中仍残留较重的雾状散射,难以恢复清晰的色彩与纹理细节。本文方法对不同浊度的浑浊图像的增强结果与参考图像更加接近,色偏校正与图像去雾以及细节的处理在所有对比方法中都有比较好的效果。

3.4.2 定量评估

本文从全参考和非参考两个角度对多种水

下图像增强方法进行了定量对比分析。表1展示了5种不同浊度环境、不同光照环境下的评估结果。可以看出,本文方法在5种浑浊度的水下图像的PSNR,SSIM和LPIPS指标上均取得了很好的表现。以47.71 NTU浑浊水测试集为例,增强后的图像PSNR指标在无色偏、绿色色偏和蓝色色偏3种光照环境下的数值为17.755,17.699,16.403,远高于PUIE(MP)的16.854,16.825,14.228和NU²Net的16.895,17.301,14.301。

在SSIM指标上,本文方法增强后3种光照图像的数值为0.449,0.304,0.281,相较于PUIE

表 1 浑浊数据集指标对比

Tab. 1 Comparison of metrics in turbid datasets

NTU	Methods	White				Green				Blue			
		PSNR	SSIM	LPIPS	NIQE	PSNR	SSIM	LPIPS	NIQE	PSNR	SSIM	LPIPS	NIQE
12.62	MLLE	14.497	0.369	0.377	6.459	14.158	0.329	0.509	7.228	12.712	0.272	0.539	10.257
	WWPF	14.734	0.402	0.354	4.809	14.288	0.359	0.486	4.885	13.247	0.317	0.501	6.149
	LiteEn	16.766	0.514	0.322	3.998	14.666	0.450	0.484	4.075	10.740	0.401	0.667	3.908
	PUIE(MP)	17.874	0.539	0.358	3.989	18.220	0.505	0.495	4.101	16.541	0.485	0.587	4.307
	U-shape	18.644	0.548	0.354	3.709	17.807	0.511	0.508	3.891	11.934	0.423	0.647	4.603
	NU ² Net	18.443	0.533	0.335	4.033	17.774	0.481	0.486	4.780	16.904	0.474	0.512	4.570
	Phaseformer	18.230	0.532	0.360	4.173	17.768	0.482	0.492	4.468	12.057	0.437	0.654	4.650
	Ours	19.330	0.560	0.346	3.717	18.404	0.514	0.473	3.931	17.832	0.491	0.493	3.718

续表 1 浑浊数据集指标对比
Tab. 1 Comparison of metrics in turbid datasets

NTU	Methods	White				Green				Blue			
		PSNR	SSIM	LPIPS	NIQE	PSNR	SSIM	LPIPS	NIQE	PSNR	SSIM	LPIPS	NIQE
21. 74	MLLE	15. 633	0. 387	0. 461	6. 115	14. 683	0. 238	0. 597	10. 083	12. 918	0. 204	0. 605	11. 164
	WWPF	15. 173	0. 411	0. 442	4. 630	14. 282	0. 282	0. 575	6. 577	12. 900	0. 240	0. 584	6. 840
	LiteEn	16. 227	0. 492	0. 431	4. 236	15. 133	0. 371	0. 587	5. 548	10. 231	0. 322	0. 754	4. 469
	PUIE(MP)	17. 377	0. 506	0. 471	3. 974	17. 877	0. 401	0. 594	5. 355	15. 682	0. 383	0. 690	5. 011
	U-shape	17. 288	0. 507	0. 449	3. 721	17. 312	0. 416	0. 627	4. 819	10. 760	0. 317	0. 749	5. 363
	NU ² Net	17. 334	0. 494	0. 459	4. 508	18. 096	0. 380	0. 582	6. 238	16. 130	0. 359	0. 616	5. 491
	Phaseformer	17. 506	0. 499	0. 444	3. 905	18. 043	0. 409	0. 577	5. 004	11. 862	0. 355	0. 742	4. 877
	Ours	18. 556	0. 521	0. 450	4. 117	18. 359	0. 427	0. 556	4. 754	16. 913	0. 380	0. 585	4. 180
38. 21	MLLE	16. 079	0. 333	0. 506	8. 976	14. 219	0. 185	0. 635	12. 212	12. 817	0. 170	0. 637	12. 824
	WWPF	15. 473	0. 377	0. 479	5. 852	14. 037	0. 233	0. 614	7. 813	12. 676	0. 204	0. 620	8. 628
	LiteEn	16. 079	0. 456	0. 474	4. 460	14. 454	0. 321	0. 637	6. 421	9. 619	0. 295	0. 786	4. 924
	PUIE(MP)	17. 027	0. 462	0. 508	4. 751	17. 176	0. 348	0. 637	6. 142	14. 897	0. 349	0. 750	5. 592
	U-shape	16. 707	0. 472	0. 482	4. 202	16. 566	0. 360	0. 711	5. 648	9. 848	0. 286	0. 786	6. 216
	NU ² Net	17. 076	0. 447	0. 498	5. 593	17. 648	0. 322	0. 629	7. 079	15. 287	0. 320	0. 662	6. 105
	Phaseformer	17. 874	0. 466	0. 479	4. 407	17. 419	0. 350	0. 614	5. 325	11. 339	0. 331	0. 771	5. 004
	Ours	18. 420	0. 490	0. 481	4. 235	18. 056	0. 367	0. 596	5. 302	16. 826	0. 346	0. 621	4. 733
47. 71	MLLE	16. 488	0. 314	0. 557	10. 102	13. 919	0. 130	0. 667	12. 768	12. 297	0. 115	0. 673	12. 936
	WWPF	15. 807	0. 363	0. 532	6. 483	13. 825	0. 173	0. 647	8. 558	12. 291	0. 141	0. 661	9. 177
	LiteEn	16. 372	0. 431	0. 538	4. 877	14. 608	0. 274	0. 674	6. 933	9. 067	0. 266	0. 816	5. 554
	PUIE(MP)	16. 854	0. 427	0. 572	5. 266	16. 825	0. 288	0. 672	6. 601	14. 228	0. 294	0. 814	6. 141
	U-shape	15. 729	0. 432	0. 541	4. 415	15. 897	0. 302	0. 752	6. 176	8. 709	0. 225	0. 829	6. 281
	NU ² Net	16. 895	0. 412	0. 569	6. 118	17. 301	0. 258	0. 664	7. 507	14. 301	0. 255	0. 723	6. 535
	Phaseformer	17. 453	0. 430	0. 538	4. 078	16. 957	0. 288	0. 651	5. 186	10. 873	0. 299	0. 801	4. 920
	Ours	17. 755	0. 449	0. 536	4. 505	17. 699	0. 304	0. 625	5. 859	16. 403	0. 281	0. 668	5. 083
54. 11	MLLE	16. 060	0. 249	0. 601	11. 151	13. 073	0. 090	0. 687	13. 476	12. 065	0. 091	0. 684	15. 161
	WWPF	15. 594	0. 299	0. 581	7. 197	13. 233	0. 125	0. 669	9. 373	12. 147	0. 116	0. 672	10. 103
	LiteEn	15. 826	0. 376	0. 588	5. 333	13. 568	0. 240	0. 694	7. 679	8. 963	0. 257	0. 814	5. 769
	PUIE(MP)	16. 497	0. 372	0. 621	5. 728	16. 269	0. 247	0. 689	7. 080	14. 052	0. 271	0. 817	6. 671
	U-shape	15. 358	0. 378	0. 586	5. 029	15. 726	0. 256	0. 796	6. 970	8. 563	0. 211	0. 833	6. 923
	NU ² Net	16. 405	0. 354	0. 632	6. 663	16. 643	0. 209	0. 684	8. 051	13. 824	0. 226	0. 737	7. 030
	Phaseformer	17. 022	0. 365	0. 586	4. 098	16. 595	0. 248	0. 664	5. 288	10. 744	0. 290	0. 801	5. 589
	Ours	17. 486	0. 390	0. 578	4. 932	17. 116	0. 254	0. 645	6. 541	15. 996	0. 245	0. 676	5. 422

(MP) 的 0. 427, 0. 288, 0. 294 和 U-shape 的 0. 432, 0. 302, 0. 225 有较大的提升, 说明本文方法在处理色偏与浑浊退化时, 能够在增强效果与结构保持之间取得较好的平衡。

3. 4. 3 公开数据集评估

为验证本文所提方法的泛化性能, 分别在 UIEB, LSUI, EUVP 这 3 个有参考数据集和两个无参考数据集 U45, Challenge-60 数据集上进

行测试, 测试结果如图 7 和图 8 所示。与其他对比方法相比, 所提方法在去雾效果和色彩校正方面更加充分, 增强后的图像在亮度分布、色彩过渡以及整体视觉观感上均与参考图像更为接近。

从表 2 可以看出, 本文方法在公开有参考测试集 (UIEB, LSUI, EUVP) 的结果均在 PSNR, SSIM 和 LPIPS 指标上取得了优异表现。以




图7 UIEB,LSUI和EUVP测试集定性实验的比较

Fig. 7 Comparison of qualitative experiments on UIEB, LSUI, and EUVP test sets




图8 U45和C60测试集定性实验的比较

Fig. 8 Comparison of qualitative experiments on U45 and C60 test sets

表2 UIEB,LSUI和EUVP测试集的指标对比

Tab. 2 Comparison of metrics across UIEB, LSUI, and EUVP test sets

Method	UIEB			LSUI			EUVP		
	PSNR	SSIM	LPIPS	PSNR	SSIM	LPIPS	PSNR	SSIM	LPIPS
MLLE	18.783	0.836	0.234	18.749	0.769	0.283	15.244	0.656	0.398
WWPF	18.753	0.835	0.224	18.674	0.768	0.270	16.143	0.664	0.383
LiteEn	21.893	0.903	0.168	24.123	0.885	0.225	23.526	0.835	0.275
PUIE(MP)	21.509	0.873	0.182	22.968	0.883	0.209	21.101	0.820	0.288
U-shape	20.837	0.786	0.246	24.995	0.866	0.225	23.043	0.816	0.285
NU ² Net	23.428	0.900	0.162	25.848	0.889	0.234	24.539	0.840	0.283
Phaseformer	22.838	0.907	0.124	25.200	0.896	0.153	25.672	0.847	0.251
Ours	23.751	0.903	0.159	27.448	0.903	0.193	25.299	0.859	0.246

LSUI测试集为例,本文方法的PSNR达到27.448,明显高于Phaseformer的25.200和NU²Net的25.848,表明本文方法在细节恢复能力方面有更大的优势。

无参考测试集选取了U45以及Challenge-60两个数据集,结果如表3所示。本文方法在无参考指标UIQM和UCIQE上表现出色,优于大部

分的对比方法。尽管本文方法在UCIQE和NIQE等无参考指标上取得了较好的成绩,但并未达到数值最优。其原因在于一些传统算法如通过直方图拉伸强制提升对比度或饱和度,这些在设计目标上更侧重于提升特定的视觉属性,虽契合了UCIQE的计算倾向,却忽略了图像的自然性与一致性。

表 3 U45 与 Challenge-60 测试集的指标对比

Tab. 3 Comparison of metrics between U45 and Challenge-60 test sets

Method	U45			Challenge-60		
	UIQM	UCIQE	NIQE	UIQM	UCIQE	NIQE
MLLE	2.599	0.595	6.410	2.310	0.579	4.218
WWPF	2.932	0.600	4.366	2.618	0.588	3.899
LiteEn	3.275	0.586	4.337	2.549	0.559	5.002
PUIE(MP)	3.318	0.583	4.144	2.658	0.567	6.205
U-shape	3.246	0.567	4.484	2.786	0.545	4.928
NU ² Net	3.369	0.581	4.283	2.776	0.561	5.057
Phaseformer	3.005	0.556	4.420	2.719	0.555	4.097
Ours	3.318	0.593	4.168	2.827	0.574	4.844

3.4.4 消融实验

本文在自建的浑浊水数据集上进行了消融实验。首先,以基础模型为基准,分别集成多尺度 SSR 去噪模块(w/MSSD)、混合卷积-空间频域注意力块中的空间频域注意力部分(w/SFA)、多尺度细节增强模块(w/MSDEB)。然后,依次消融多尺度 SSR 去噪模块(w/o MSSD)、混合卷积-空间频域注意力块中的空间频域注意力部分(w/o SFA)、多尺度细节增强模块(w/o MSDEB)。最后为分析空域与频域的协同作用,进一步分别消融 SFA 中的空间注意力分支(w/SFA-Sp)与频域注意力分支(w/SFA-FFT)。

表 4 中实验结果显示,去除任一模块均导致 SSIM 和 PSNR 显著下降,LPIPS 值上升,表明图像的结构相似性降低,感知质量变差。在非参考指标方面,完整模型在 NIQE 指标上表现最为优异,相较于消融各模块的方法,其 NIQE 值平均

降低了 0.627,这有力地证明了完整模型生成的图像具有更高的自然度,更符合真实场景的统计特性。

图 9 是对方法的各主要功能模块所进行的消融效果的展示。从视觉结果可以看出,仅包含基础网络架构的模型(baseline)虽能在一定程度上提升对比度,但在极端浑浊的水体中,由于缺乏针对强散射噪声的物理建模,画面整体仍伴随明显的雾感,且背景区域的细节依旧模糊。在基础模型上集成尺度 SSR 去噪模块(w/MSSD)后,图像的“雾感”得到了显著抑制,这表明该模块通过融合 Retinex 物理机理,成功在预处理阶段缓解了高浊度水体中的散射噪声干扰,恢复了原本被掩盖的背景轮廓。在基础模型中单独引入空间频域注意力部分(w/SFA)后,图像在非均匀退化区域的整体色彩分布表现得更加均衡与自然,色偏得到了初步校正。集成多尺度细节增强

表 4 消融实验结果

Tab. 4 Ablation experiment results

Model	PSNR	SSIM	LPIPS	UIQM	UCIQE	NIQE
baseline	16.513	0.388	0.571	3.314	0.526	4.888
w/ MSSD	16.677	0.402	0.555	3.379	0.540	4.861
w/ SFA	16.778	0.410	0.547	3.382	0.541	4.965
w/ MSDEB	16.672	0.406	0.569	3.405	0.525	5.050
w/o MSSD	16.790	0.413	0.557	3.387	0.539	5.082
w/o SFA	17.091	0.414	0.563	3.380	0.535	4.914
w/o MSDEB	16.723	0.408	0.550	3.379	0.538	5.036
w/o SFA-Sp	17.189	0.420	0.554	3.404	0.533	5.089
w/o SFA-FFT	16.727	0.413	0.560	3.369	0.536	4.908
Full model	17.943	0.443	0.531	3.362	0.531	4.350




图9 关键模块消融对比

Fig. 9 Key module ablation comparison

模块(w/ MSDEB)的模型在恢复背景岩石缝隙的结构上边缘更锐利、纹理更丰富。

随后对完整模型进行单模块消融。首先,对多尺度 SSR 去噪模块进行消融实验(w/o MS-SD),移除该模块后,图中残余的雾状感明显增强,悬浮颗粒导致的噪声未能得到有效抑制。其次,针对 HCSFAB 中的空间频域注意力块 SFA 进行了消融实验(w/o SFA),移除该模块后图像的局部对比度出现显著下降,部分纹理区域显得黯淡且缺乏对比,图像的视觉冲击力减弱。最后,对多尺度细节增强模块进行消融实验(w/o MSDEB),移除 MSDEB 后,图像的边缘清晰度大幅下降,细小目标变得模糊,且出现了轻微の色偏反弹。

为了验证空域频域联合建模的作用,对双分支 SFA 模块的空间注意力分支与频域注意力分支分别进行消融实验。单空间分支受限于感受野,对大面积非均匀色偏和全局亮度衰减的恢复不均匀。对单频域分支,由于频域特征缺乏空间定位,图像边缘偏平滑,局部高频细节重构不足。对于融合了双域的 SFA 模块,空间分支捕捉局部特征,频域分支解耦全局退化,两者优势互补,打破了单一空域提取的瓶颈,实现了非均匀降质环境下的高效建模。综上所述,网络中的各主要模块对图像质量恢复均有显著提升作用。

3.4.5 应用测试

利用 SIFT (Scale-Invariant Feature Transform) 算子在增强图像与旋转 45° 后的参考图像之间提取尺度与旋转不变特征。采用 BFMATCHER (Brute-Force Matcher) 进行初始双向关联,并计算每幅图像的平均原始匹配数。然后,引入 RANSAC (Random Sample Consensus) 算法进行

几何约束校验,仅保留符合全局几何变换规律的有效匹配对,并统计测试图像的平均内点数。同时计算平均内点率,即有效内点在原始匹配中的占比,用以表征特征描述符的辨识度与稳定性。统计结果如表 5 所示。

表 5 浑浊水图像特征匹配

Tab. 5 Turbid water image feature matching

方法	原始 匹配点数	平均 内点数	平均 内点率/%
输入图像	4.43	2.38	19.97
MLLE	84.87	39.93	46.33
WWPF	93.30	41.60	43.73
LiteEn	40.92	22.53	41.53
PUIE(MP)	51.05	27.43	50.39
U-shape	44.68	24.12	52.52
NU ² Net	68.42	35.63	50.01
Phaseformer	53.13	19.33	28.74
本文方法	67.15	34.03	48.82

MLLE 和 WWPF 在增强过程中对局部纹理的过度锐化及对水体散射噪声的非均匀放大,在图像中产生了符合全局几何变换模型的重复性伪纹理。这些结构化伪影虽然提升了 SIFT 的初始响应数量,但相当一部分被 RANSAC 的几何一致性检验所保留,导致内点数量虚高。这并非真实匹配质量的提升,而是算法对伪纹理的过拟合。在与多种深度学习增强方法的对比实验中,本文方法在 RANSAC 验证后的内点率指标上略低于部分对比方法,差异约为 2%。该比例差异并未导致几何有效匹配数量的下降,相反本文方法在绝对内点数量上取得了较高的结果,平均内

点数达到 34,较其他大部分深度学习方法的内点数提升约 8 个。

4 结 论

本文提出了一种空域与频域融合的多尺度浑浊水图像增强网络。首先,使用多尺度 SSR 去噪模块抑制原始图像的噪声。在编码器-解码器网络中使用混合卷积-空间频域注意力块实现了全局结构感知与局部纹理细节的动态平衡。位于瓶颈层的多尺度细节增强模块结合 SKFF 机制,在深层图像特征中有效捕获并补偿了受损的边缘信息。最终,在浊度为 54.11 NTU 的

无色偏以及绿色色偏和蓝色色偏浑浊水图像上,本方法相较于最优的对比方法在 PSNR 指标上平均提升了 0.464,0.473 和 1.944 dB,在 LPIPS 指标上平均降低了 0.94%。该方法能够增强浑浊水图像,为水下机器人视觉提升提供有效方案。

作者贡献声明:

张 浩:写作指导,提供资源;
张庆文:方法提出,初稿写作,实验验证;
刘 飞:论文审核与编辑;
宋雨佳:调查研究;
李长青:项目管理。

参考文献:

- [1] WANG Z Y, SHEN L Q, YU Y H, *et al.* UI-ERL: internal-external representation learning network for underwater image enhancement[J]. *IEEE Transactions on Multimedia*, 2024, 26: 9252-9267.
- [2] ZHU R X, SHENG L, *et al.* Toward efficient underwater visual perception through image enhancement, compression, and understanding[J]. *ACM Computing Surveys*, 2026, 58(8): 1-46.
- [3] ZHANG W H, LI X B, HUANG Y Z, *et al.* Turbidity-graded adaptive underwater image enhancement[J]. *Optics & Laser Technology*, 2026, 194: 114496.
- [4] LIU H D, LI X B, WANG Z H, *et al.* Review of polarimetric image denoising[J]. *Advanced Imaging*, 2024, 1(2): 022001.
- [5] WEI Y, HAN P L, LIU F, *et al.* Polarization descattering imaging: a solution for nonuniform polarization characteristics of a target surface[J]. *Chinese Optics Letters*, 2021, 19(11): 111101.
- [6] LIU F, ZHANG S C, HAN P L, *et al.* Depolarization index from Mueller matrix descatters imaging in turbid water[J]. *Chinese Optics Letters*, 2022, 20(2): 022601.
- [7] LIU J P, FENG Y, WANG Y Z, *et al.* Future-proof imaging: computational imaging[J]. *Advanced Imaging*, 2024, 1(1): 012001.
- [8] ZHANG W D, DONG L L, XU W H. Retinex-inspired color correction and detail preserved fusion for underwater image enhancement[J]. *Computers and Electronics in Agriculture*, 2022, 192: 106585.
- [9] ZHANG H, GONG L X, LI X C, *et al.* An underwater imaging method of enhancement *via* multi-scale weighted fusion[J]. *Frontiers in Marine Science*, 2023, 10: 1150593.
- [10] XU C P, ZHOU W H, HUANG Z X, *et al.* Fusion-based graph neural networks for synergistic underwater image enhancement[J]. *Information Fusion*, 2025, 117: 102857.
- [11] XIANG D, HE D Y, SUN H, *et al.* HCMPE-Net: an unsupervised network for underwater image restoration with multi-parameter estimation based on homology constraint[J]. *Optics & Laser Technology*, 2025, 186: 112616.
- [12] LIU Y, JIANG Q P, WANG X Y, *et al.* Underwater image enhancement with cascaded contrastive learning[J]. *IEEE Transactions on Multimedia*, 2025, 27: 1512-1525.
- [13] TOLIE H F, REN J C, ELYAN E. DICAM: Deep Inception and Channel-wise Attention Modules for underwater image enhancement[J]. *Neurocomputing*, 2024, 584: 127585.
- [14] QI H, ZHOU H Y, DONG J Y, *et al.* Deep color-corrected multiscale retinex network for underwater image enhancement[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 4200613.
- [15] FAN G D, ZHOU J C, XU C P, *et al.* Deep dive into clarity: Leveraging signal-to-noise ratio awareness and knowledge distillation for underwater image enhancement[J]. *Expert Systems with Applications*

- ations, 2025, 269: 126317.
- [16] HAN G J, YU S, ZHU H B, *et al.* UMCTN: real-world underwater image enhancement based on transformer with multikernel convolution [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 4207715.
- [17] CHENG Z, FAN G D, ZHOU J C, *et al.* FDCE-net: underwater image enhancement with embedding frequency and dual color encoder [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2025, 35(2): 1728-1744.
- [18] LI J X, YAN Z P. Generative adversarial network based frequency domain enhancement and color compensation underwater image enhancement [J]. *Optics and Lasers in Engineering*, 2025, 193: 109102.
- [19] LAND E H. The retinex theory of color vision [J]. *Scientific American*, 1977, 237 (6) : 108-129.
- [20] RAHMAN Z, JOBSON D J, WOODDELL G A. Multi-scale retinex for color image enhancement [C]. *Proceedings of 3rd IEEE International Conference on Image Processing. September 19-19, 1996, Lausanne, Switzerland.* IEEE, 2002: 1003-1006.
- [21] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018, Salt Lake City, UT, USA.* IEEE, 2018: 7132-7141.
- [22] KONG L S, DONG J X, GE J J, *et al.* Efficient frequency domain-based transformers for high-quality image deblurring [C]. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 17-24, 2023, Vancouver, BC, Canada.* IEEE, 2023: 5886-5895.
- [23] RAO Y M, ZHAO W L, ZHU Z, *et al.* Global filter networks for image classification [EB/OL]. 2021: *arXiv*: 2107.00645. <https://arxiv.org/abs/2107.00645>.
- [24] WOO S, PARK J, LEE J Y, *et al.* CBAM: Convolutional Block Attention Module [M]. *Computer Vision-ECCV 2018.* Cham: Springer International Publishing, 2018: 3-19.
- [25] YU Y K, LIU H, FU M H, *et al.* A two-branch neural network for non-homogeneous dehazing via ensemble learning [C]. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). June 19-25, 2021. Nashville, TN, USA.* IEEE, 2021: 193-202.
- [26] LI C Y, GUO C L, REN W Q, *et al.* An underwater image enhancement benchmark dataset and beyond [J]. *IEEE Transactions on Image Processing*, 2020, 29: 4376-4389.
- [27] 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.
- [28] LI H Y, LI J J, WANG W. A fusion adversarial underwater image enhancement network with a public test dataset [EB/OL]. 2019: *arXiv*: 1906.06819. <https://arxiv.org/abs/1906.06819>.
- [29] KORHONEN J, YOU J Y. Peak signal-to-noise ratio revisited: Is simple beautiful? [C]. 2012 *Fourth International Workshop on Quality of Multimedia Experience. July 5-7, 2012, Melbourne, VIC, Australia.* IEEE, 2012: 37-38.
- [30] HORÉ A, ZIOU D. Image quality metrics: PSNR vs. SSIM [C]. 2010 *20th International Conference on Pattern Recognition. August 23-26, 2010, Istanbul, Turkey.* IEEE, 2010: 2366-2369.
- [31] ZHANG R, ISOLA P, EFROS A A, *et al.* The unreasonable effectiveness of deep features as a perceptual metric [C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018, Salt Lake City, UT, USA.* IEEE, 2018: 586-595.
- [32] PANETTA K, GAO C, AGAIAN S. Human-visual-system-inspired underwater image quality measures [J]. *IEEE Journal of Oceanic Engineering*, 2016, 41(3): 541-551.
- [33] YANG M, SOWMYA A. An underwater color image quality evaluation metric [J]. *IEEE Transactions on Image Processing*, 2015, 24(12): 6062-6071.
- [34] MITTAL A, SOUNDARARAJAN R, BOVIK A C. Making a “completely blind” image quality analyzer [J]. *IEEE Signal Processing Letters*, 2013, 20(3): 209-212.
- [35] 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.

- [36] ZHANG W D, ZHOU L, ZHUANG P X, *et al.* Underwater image enhancement *via* weighted wavelet visual perception fusion [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2024, 34(4): 2469-2483.
- [37] ZHANG S, ZHAO S L, AN D, *et al.* LiteEnhanceNet: a lightweight network for real-time single underwater image enhancement [J]. *Expert Systems with Applications*, 2024, 240: 122546.
- [38] FU Z Q, WANG W, HUANG Y, *et al.* Uncertainty inspired underwater image enhancement [C]. *Computer Vision-ECCV 2022*. Cham: Springer, 2022: 465-482.
- [39] GUO C L, WU R Q, JIN X, *et al.* Underwater ranker: learn which is better and how to be better [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2023, 37(1): 702-709.
- [40] KHAN M R, NEGI A, KULKARNI A, *et al.* Phaseformer: phase-based attention mechanism for underwater image restoration and beyond [C]. *2025 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*. February 26-March 6, 2025, Tucson, AZ, USA. IEEE, 2025: 9618-9629.

作者简介:

张 浩(1980—),男,博士,副教授,2011年于西安电子科技大学获得博士学位,主要从事水下光学成像、计算机视觉和模式识别等方面的研究。E-mail: zhanghao@qut.edu.cn