

文章编号 1004-924X(2026)19-3091-13

轴向卷积与通道注意力并行融合的 轻量水下图像增强网络

贺锋涛, 李丽华*, 杨 祎, 张建磊, 刘蕊蕊, 冯斌杰
(西安邮电大学 电子工程学院, 陕西 西安 710121)

摘要:针对水下图像因水体吸收与散射引起的色偏、对比度下降等退化问题,现有方法在增强效果与计算效率间难以取得良好平衡,故提出一种轴向卷积与通道注意力并行融合轻量水下图像增强网络。该网络采用残差补偿的编解码架构,以 ShuffleNet V2 为轻量骨干提取特征,在瓶颈处并行引入轴向深度卷积与通道注意力模块,分别从空间和通道两个维度扩大感受野并自适应校准通道权重,经全局残差连接输出增强结果;训练采用 LSUI 数据集,结合 MSE 与 SSIM 损失函数进行优化。在 LSUI,UIEB 和 EUVP 等多个公开数据集上的实验表明,本文算法在 PSNR,SSIM 等关键指标上均优于主流对比算法,其中在 LSUI 测试集上 PSNR 达 25.13 dB,SSIM 达 0.849 1;在无 GPU 加速平台上,单张推理耗时显著低于同类轻量方法,在 Jetson Orin NX 上处理速度达 144.61 frame/s。该方法以 1.60 M 参数量实现了增强质量与计算效率的协同提升,基本满足水下边缘平台对图像增强的实时性、高精度和轻量化部署要求。

关键词:水下图像增强;轻量化网络;ShuffleNet V2;轴向深度卷积;通道注意力

中图分类号:TP391.41;TP18 **文献标识码:**A

doi:10.3724/OPE.20263419.3091 **CSTR:**32169.14.OPE.20263419.3091

Lightweight underwater image enhancement network with parallel fusion of axial convolution and channel attention

HE Fengtao, LI Lihua*, YANG Yi, ZHANG Jianlei, LIU Ruirui, FENG Binjie

(School of Electronic Engineering, Xi'an University of Posts and Telecommunications,
Xi'an 710121, China)

* Corresponding author, E-mail: lilihua@stu.xupt.edu.cn

Abstract: Underwater images are degraded by wavelength-dependent absorption and scattering, resulting in color casts and reduced contrast. To address these degradations while balancing enhancement quality and computational efficiency, a lightweight underwater image enhancement network based on the parallel fusion of axial convolution and channel attention is proposed. An encoder-decoder architecture with residual compensation is adopted, with ShuffleNet V2 employed as the lightweight feature extraction backbone. At the bottleneck, axial depthwise convolution and channel attention are integrated in parallel to expand the spatial receptive field and adaptively recalibrate channel-wise feature weights, respectively. The enhanced image is reconstructed through a global residual connection. The network is trained on the LSUI dataset using a combined mean squared error (MSE) and structural similarity (SSIM) loss. Evaluations

收稿日期:2026-06-23;修订日期:2026-07-21.

基金项目:装备预研教育部联合基金资助项目(No. 8091B032130)

on multiple public datasets, including LSUI, UIEB, and EUVP, demonstrate superior performance over mainstream comparison methods in key metrics, including PSNR, SSIM, and UCIQE. On the LSUI test set, a PSNR of 25.13 dB and an SSIM of 0.849 1 are achieved. Without GPU acceleration, per-image inference latency is substantially lower than that of comparable lightweight methods, while a processing speed of 144.61 frame/s is achieved on the Jetson Orin NX. With only 1.60 M parameters, the proposed network delivers improved enhancement quality and computational efficiency, supporting real-time, high-quality underwater image enhancement on resource-constrained edge platforms.

Key words: underwater image enhancement; lightweight network; ShuffleNet V2; axial depthwise convolution; channel attention

1 引 言

水下光学图像在海洋资源勘探,水下环境保护及自主水下航行器导航等领域发挥着重要作用^[1]。然而,水下成像环境极其复杂,图像退化主要源于光在水体中的传播特性^[2-3]。根据 Jaffe-McGlamery 成像模型^[4],退化主要由两个物理过程引起:一是水体介质对不同波长光的选择性吸收,导致红光严重衰减,图像出现明显蓝绿偏色;二是悬浮颗粒引起的散射效应,导致背景光增强和透射率降低,图像对比度下降、细节模糊。低质量图像极大限制了目标识别和三维重建等高层视觉任务的性能^[5],因此研究水下图像增强方法是当前水下视觉领域亟待解决的重要问题。

传统水下图像增强方法包括对比度拉伸^[6-9],基于先验知识^[10-14]以及基于 Retinex 理论^[15-19]增强方法等。这些方法在特定场景下取得了一定效果,但依赖理想化的统计或环境假设,面对复杂多变的水体类型时泛化能力不足。近年来,深度学习凭借强大的非线性映射能力成为主流。Li 等^[20]提出的 WaterNet 通过门控融合多通道预处理结果实现端到端增强。Peng 等^[21]将 Transformer 引入该领域,利用全局上下文建模提升色彩校正效果。这类高精度模型参数量大,推理延迟高,难以在算力有限的嵌入式平台上实时运行。

随着移动设备需求的不断增长,轻量化水下图像增强技术的发展越来越受到关注。Islam 等^[22]设计的 FUnIE-GAN 方法支持配对与非配对训练,基本实现实时水下图像增强,初步适配水下机器人的嵌入式部署需求。Naik 等^[23]提出的 Shallow-UWnet 采用浅层神经网络架构和密

集跳跃连接设计,在大幅压缩参数量、提升推理速度的同时,保持了与当时主流 SOTA 模型相当的水下图像增强效果。简单网络架构 LiteEnhanceNet^[24]通过深度可分离卷积,SE 通道注意力模块的轻量化设计和一次性聚合残差连接等结构优化进一步提高运行速度。然而,现有轻量级方法仍存在不足,其推理速度高度依赖高端 GPU 硬件加速,在普通 CPU 或低功耗嵌入式平台上性能显著下降,且存在色彩校正不准确、局部过增强等问题。

本文提出一种轴向卷积与通道注意力并行融合的轻量水下图像增强网络。鉴于增强前后主体内容基本不变,网络采用残差补偿而非完整重建,避免对场景结构造成二次破坏。在架构上,以 ShuffleNet V2^[25]为轻量编码器,瓶颈处并行引入轴向深度卷积与通道注意力。轴向深度卷积模块以水平和垂直一维卷积扩大有效感受野,建模大范围光照与结构关系;通道注意力层依据全局退化表征动态重标定特征通道贡献,增强跨场景适应性。融合后的特征经解码器预测三通道补偿残差,插值后与原图恒等连接相加得到增强结果。该设计通过恒等路径保留细节,深层路径补偿低频退化,在低参数量和计算成本下增强水下图像。

2 原 理

2.1 整体网络架构

本文提出的水下图像增强网络采用非对称编码-解码框架,整体结构如图 1 所示。该网络由编码器、多分支并行增强瓶颈和轻量残差解码器三部分组成。给定一张退化的水下输入图像




图1 轻量水下图像增强网络整体架构

Fig. 1 Overall architecture of lightweight underwater image enhancement network

$I \in \mathbb{R}^{3 \times H \times W}$, 首先由预训练的 ShuffleNet V2 骨干网络提取多尺度抽象特征, 将其空间尺寸压缩为原始输入的 $1/32$, 得到 1024 维特征图 F 。然后, 将特征图同时送入空间轴向深度卷积和通道注意力两个并行分支, 分别从空间和通道两个维度增强特征表示, 并通过逐元素求和进行融合, 得到增强特征 F' 。最后, 解码器从 F' 预测三通道残差图, 经双线性上采样恢复到原始分辨率, 并以全局残差连接的形式与输入图像相加, 经钳位操作得到最终增强图像 $I_{\text{enh}} \in \mathbb{R}^{3 \times H \times W}$ 。

本文从编码器选型、瓶颈模块设计和解码器结构 3 个层面系统降低网络的参数量与计算量。编码器采用 ShuffleNet V2 模块, 通过通道分割与混洗机制完成多尺度特征提取; 瓶颈端将二维卷积分解为水平和垂直两个一维深度卷积, 配合仅含全局平均池化和两个 1×1 卷积的轻量通道注意力, 分别以极低成本扩展感受野和校准通道权重; 解码器以 1×1 卷积压缩通道后直接在低分辨率空间预测残差, 避免逐步上采样的冗余计算。全局残差连接使网络仅需学习退化补偿量, 进一步降低容量需求。最终全网络以 1.60 M 参数量和 0.13 G FLOPs 实现高质量增强。

2.2 轻量特征编码器

编码器负责从水下输入图像中提取紧凑的高维特征表示, 为后续增强模块提供丰富的语义与结构信息。选用 ShuffleNet V2 作为骨干网络, 该网络通过通道分割与通道混洗机制在保持极低计算复杂度的同时有效提升了特征复用效率, 非常契合水下图像增强任务对实时性与部署轻量化的需求^[25]。实际使用中丢弃其末端全局池化与全连接分类层, 仅保留堆叠的卷积模块, 最终输出 1024 通道, 空间尺寸为输入 $1/32$ 的特征图。为进一步提升编码器的泛化能力和训练稳定性, 在 ImageNet 大规模自然图像数据集上预

对训练的权重进行初始化。尽管水下图像与自然图像存在域差异, 但底层边缘、纹理等通用特征仍具有良好的可迁移性, 能够为增强网络提供有效的初始视觉先验, 可显著加速收敛并提升对水下退化区域的建模能力。

2.3 多分支并行特征增强瓶颈

水下图像的退化主要由选择性吸收与悬浮散射共同引起, 前者造成通道间的能量失衡而表现为色偏, 后者造成对比度下降与细节模糊, 且其影响往往跨越较大区域。普通卷积的感受野受限局部邻域, 难以充分聚合此类长距离的退化信息。为此, 本文在特征瓶颈处设计了并行特征增强结构, 由轴向深度卷积 (Axial Depthwise Convolution, ADC) 与通道注意力层 (Channel Attention Layer, CAL) 两个并行分支组成, 分别对上述两类退化进行针对性补偿: ADC 面向空间维度, CAL 面向通道维度, 两分支并行处理、互不干扰, 其输出经逐元素相加融合, 使颜色校正与结构增强相互补充, 共同提升瓶颈特征的表达能力。

ADC 将标准深度可分离卷积中的二维核分解为水平和垂直两个一维卷积, 分别沿行和列方向独立建模, 聚合两个正交方向的长距离空间上下文, 有效扩大了感受野, 帮助建模大范围亮度、对比度和区域结构关系^[26]。如图 2 所示, 水平卷积捕获横向依赖, 垂直卷积捕获纵向依赖, 原始特征通过恒等连接保持信息流动性, 三路求和后由一个逐点卷积进行跨通道融合。计算过程可表示为:

$$F_{\text{out1}} = \text{Conv}_{1 \times 1}(\text{Conv}_h(F) + \text{Conv}_v(F) + F), \quad (1)$$

其中: Conv_h 表示水平卷积, Conv_v 表示垂直卷积, $\text{Conv}_{1 \times 1}$ 用于融合两个方向的特征并与恒等映射相加。




图 2 轴向深度卷积模块网络结构

Fig. 2 Network structure of axial depthwise convolution module

CAL 依据全局通道统计对各通道响应进行自适应重标定,强化与退化补偿相关的通道响应,抑制冗余或噪声通道^[27]。如图 3 所示,首先通过全局平均池化将每个通道的空间信息压缩为一个标量,随后经过一个两层的 1×1 卷积 MLP 学习通道间依赖关系,最后通过 Sigmoid 门控产生 $0 \sim 1$ 的通道权重,并以乘法方式对原始特征进行加权。对输入特征 $F \in \mathbb{R}^{C \times H \times W}$,首先获得每个通道的全局响应强度,即通过全局平均池化将每个特征图的空间维压为单个描述值:

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F(c, i, j), c = 1, 2, \dots, C, (2)$$

其中: z_c 表示第 c 个通道的全局平均响应。获得通道描述符向量 z 后,需要学习各通道之间的非线性依赖关系,以生成合理的校正权重。第一个 1×1 卷积压缩描述符维度,第二个 1×1 卷积将维度恢复为 C ,并经由 Sigmoid 门控激活获得最终的通道权重向量:

$$s = \sigma(W_2 \delta(W_1 z)), (3)$$

其中: W_1 为降维卷积层的权重矩阵, δ 为 ReLU 激活函数, W_2 为升维卷积层的权重矩阵, σ 为 Sigmoid 函数。最后,将学习到的通道权重 s 按通道乘回原始特征,完成通道级的色彩校正:

$$F_{out2} = s \otimes F. (4)$$

与 CBAM^[28] 等串行级联注意力不同,并行结构使两个分支以原始特征为共同输入、各自独立建模后融合,避免了串行结构中级联误差的传播,以逐元素相加的极低代价实现两类退化补偿的互补叠加。




图 3 通道注意力层网络结构

Fig. 3 Network structure of channel attention layer

2.4 轻量残差解码器

解码器遵循预测残差和全局跳跃的设计范式,以极低的计算量将瓶颈特征恢复为最终的增强图像。如图 4 所示,解码器首先使用一个 1×1 卷积将 1 024 维增强特征压缩至 64 维,并经 ReLU 激活引入非线性,得到紧凑表示 $F_c \in \mathbb{R}^{64 \times H' \times W'}$,其中 $H' = H/32, W' = W/32$ 。随后,应用一个 3×3 卷积直接在低分辨率空间预测三通道残差图:

$$X = \text{Conv}_{3 \times 3}^{64 \rightarrow 3}(\text{ReLU}(\text{Conv}_{1 \times 1}^{1024 \rightarrow 64}(F'))), (5)$$

其中: $X \in \mathbb{R}^{3 \times H' \times W'}$ 。采用双线性插值将残差图 X 上采样至原始输入尺寸 $H \times W$,得到 X_{up} 。最终增强图像由原始输入与缩放后的残差图相加,并通过钳位操作将像素值约束在有效范围:

$$I_{enh} = \text{clamp}(I + 0.5 \cdot X_{up}, 0, 1). (6)$$

为防止过度增强导致的色彩失真与过曝,残差缩放因子设置为 0.5。该设计的全局残差连接确保输出图像完整保留原始场景的结构与纹理,网络仅需学习退化成分的补偿量。




图 4 解码器模块网络结构

Fig. 4 Network structure of decoder module

2.5 损失函数

为了在像素内容和空间结构上使得增强网络生成的图像能够和参考图像保持高度一致,本网络采用 L_{MSE} 损失函数和 L_{SSIM} ^[24] 损失函数。其中, MSE 约束像素精度, SSIM 约束结构一致性。总损失函数可表示为:

$$L_{\text{total}} = L_{\text{MSE}} + \lambda L_{\text{SSIM}}, \quad (7)$$

其中: λ 为 0.3。 L_{MSE} 损失函数可表示为:

$$L_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N \|I_{\text{enh}}^{(i)} - I_{\text{gt}}^{(i)}\|_2^2, \quad (8)$$

其中: N 为批次样本数, 上标 (i) 表示第 i 个样本。 L_{SSIM} 损失函数可表示为:

$$L_{\text{SSIM}} = 1 - \frac{1}{N} \sum_{i=1}^N \text{SSIM}(I_{\text{enh}}^{(i)}, I_{\text{gt}}^{(i)}). \quad (9)$$

3 实验与讨论

3.1 数据集

本实验使用 LSUI 数据集进行模型训练, 并使用多个公共数据集进行模型测试。

(1) LSUI^[21]: 该数据集包含 4 279 对真实世界水下图像及其高质量参考图像, 覆盖丰富的水体类型、光照条件和目标类别, 是目前规模最大、场景最全面的水下图像增强数据集之一。实验选取其中 70% 的图像作为训练集, 20% 作为验证集, 10% 作为测试集。测试集包含 429 张图像, 命名为 Test_LSUI。

(2) EUVP^[22]: 取来自 EUVP 测试集的 515 对有参考水下图像并命名为 Test_EUVP, 参与有参考对比实验。

(3) UIEB^[20]: 该数据集包含 890 对有参考的水下图像和 60 张无参考的水下图像。将 890 对图像参与有参考对比实验, 命名为 Test_UIEB。剩余的 60 张无参考图像命名为 Test_C60, 参与无参考对比实验。

(4) RUOD^[29]: 随机选取来自该数据集多场景下的 285 张水下图像命名为 Test_RUOD, 参与无参考对比实验。

(5) RUIE^[30]: 选择来自 RUIE 的 UCCS 数据集评估水下图像增强方法校正颜色偏差的能力。该数据集包含 100 张偏蓝色、100 张蓝绿色调和 100 张偏绿色的水下图像, 分别命名为 blue、blue-green、green。

3.2 实验配置

模型训练在 Windows11, RTX 3060 Ti 电脑上进行。输入图像大小统一调整为 256×256 , 使用 Adam 优化器, 初始学习率设为 1×10^{-4} , 批次大小为 8, 共训练 300 轮。此外, 大量对比算法的测试在 Ultra 5 125H CPU 环境下进行。

3.3 评价指标

采用多种图像质量评价指标对增强结果进行定量评估。有参考指标包括均方误差 (Mean Squared Error, MSE)、峰值信噪比 (Peak Signal to Noise Ratio, PSNR)^[31] 和结构相似性指数 (Structural Similarity Index Measure, SSIM)^[31]。并引入图像熵 (Image Entropy, IE)^[32]、水下图像质量度量 (Underwater Image Quality Measure, UIQM)^[33] 和水下彩色图像质量评价 (Underwater Colour Image Quality Evaluation, UCIQE)^[34] 3 种无参考指标。UIQM 由色彩测量指标 (Underwater Image Colourfulness Measure, UICM)、清晰度测量指标 (Underwater Image Sharpness Measure, UISM) 和对比度测量指标 (Underwater Image Contrast Measure, UICONM) 加权求和得到, 权重系数分别为 0.15, 0.25 和 0.6。UCIQE 由色度标准差 (σ_c)、亮度对比度 (con_l) 和饱和度平均值 (μ_c) 线性组合而成, 权重系数分别为 0.468 0, 0.274 5 和 0.257 6。

3.4 对比实验

为验证所提方法对水下图像的实际增强效果, 将本文算法与现有水下图像增强算法进行对比, 包括 MSRCP^[35], UDCP^[36], FUnIE-GAN^[22], WaterNet^[20], Shallow-UWnet^[23], LiteEnhanceNet^[24], LU2Net^[37] 和 Phaseformer^[38]。

3.4.1 定性评价

在有参考数据集 Test_LSUI, Test_UIEB 和 Test_EUVP 上将所提出的方法和其他方法进行了对比, 结果如图 5、图 6 和图 7 所示。由此可见, MSRCP 和 UDCP 虽然能去雾, 但会加深颜色偏差, 甚至出现不自然的荧光绿; FUnIE-GAN 整体色彩校正效果较好, 但存在部分图像偏红过补偿的问题, 在 Test_UIEB 的部分图像处理上引入红色调; WaterNet 和 Shallow-UWnet 的去色偏效果有限, 重度色偏无法有效校正; Shallow-UWnet 也存在增强图片整体偏橙色的问题, Li-




图 5 在 Test_LSUI 数据集上的对比结果
Fig. 5 Comparison results on Test_LSUI dataset




图 6 在 Test_UIEB 数据集上的对比结果
Fig. 6 Comparison results on Test_UIEB dataset




图 7 在 Test_EUVP 数据集上的对比结果
Fig. 7 Comparison results on Test_EUVP dataset

teEnhanceNet、LU2Net 和 Phaseformer 对图像的处理效果较好,与参考图的相似度较高,但 LiteEnhanceNet 在对如图 6 所示图像的处理中出现曝光,影响图中细节信息的呈现;经 Phaseformer 处理的图像偏淡,饱和度欠缺。相比之下,通过本文方法增强得到的图像效果更好,更贴近参考图。

为了进一步评估各方法的泛化性,在 5 个无

参考数据集上进行测试分析。如图 8 所示,MSRCP 和 UDCP 的处理效果依旧较差。FUnIE-GAN 和 Shallow-UWnet 的处理效果偏黄,且 FUnIE-GAN 对偏蓝色水下图像的处理能力不足,未明显校正色偏。结合 FUnIE-GAN 在有参考数据集上的处理效果分析,该算法对色偏的处理能力不稳定,容易过补偿或补偿不足,但处理后的图像颜色比较鲜艳。WaterNet 和 Phaseformer 整




图 8 在无参考数据集上的对比结果

Fig. 8 Comparison results on unseen reference dataset

体上对图像的增强效果有限,图像色调偏暗沉。相比之下,本文方法与 LiteEnhanceNet,LU2Net 算法在无参考数据集的处理效果、泛化性更好。

3. 4. 2 定量评价

为全面评估各方法的增强性能,在 Test_LSUI, Test_UIEB 和 Test_EUVP 3 个有参考数据集上计算了 PSNR, SSIM, MSE, IE, UIQM 和 UCIQE 指标,结果如表 1 所示。在 Test_C60, blue, blue-green, green 以及 Test_RUOD 无参考数据集上计算了 UIQM, UCIQE 和 IE 指标,结果如表 2 所示。表中加粗字体为最优。

由表 1 可见,在 3 个有参考数据集上,本文方法在多项指标上均展现出优势。在 Test_UIEB 数据集上,本文模型的有参考指标表现不如 LiteEnhanceNet 和 Phaseformer,但 UIEB 数据集的多数图像都被用于这两种方法的模型训练,而本文方法的 IE 和 UCIQE 指标均达到最优, PSNR 指标也在前三,这充分证明了本文方法在 Test_UIEB 数据集的有效性。在 Test_LSUI 和 Test_EUVP 数据集上,本文方法的有参考指标 PSNR, SSIM 和 MSE 均为最优,且无参考指标表现较好。由表 2 可见,本文方法在 Test_C60,

表 1 有参考数据集的评价指标对比

Tab. 1 Comparison of evaluation metrics on full-reference datasets

Dataset	Methods	PSNR/dB	SSIM	MSE	IE	UIQM	UCIQE
Test_UIEB	Ours	19.09	0.737 8	1 041.844 4	7.192 7	3.395 1	0.577 4
	WaterNet	17.79	0.786 7	1 544.817 3	6.881 1	3.467 3	0.523 0
	FUnIE-GAN	17.62	0.713 8	1 489.798 5	7.150 4	3.975 9	0.569 0
	MSRCP	10.49	0.552 3	6 208.304 0	6.002 4	2.245 2	0.455 5
	UDCP	14.19	0.676 8	3 094.605 1	6.826 9	3.525 4	0.561 6
	Shallow-UWnet	17.09	0.680 0	1 624.576 9	6.884 5	3.052 9	0.525 2
	LiteEnhanceNet	21.48	0.856 1	615.659 5	7.138 5	3.966 7	0.567 9
	LU2Net	19.01	0.828 3	1 097.438 0	7.085 4	3.654 5	0.556 0
	Phaseformer	23.01	0.897 4	436.273 7	7.099 9	4.131 5	0.546 8

续表 1 有参考数据集评价指标对比

Tab. 1 Comparison of evaluation metrics on full-reference datasets

Dataset	Methods	PSNR/dB	SSIM	MSE	IE	UIQM	UCIQE
Test_LSUI	Ours	25.13	0.849 1	265.733 3	7.150 1	3.322 9	0.573 4
	WaterNet	21.22	0.819 1	592.545 7	7.028 0	3.360 2	0.526 9
	FUnIE-GAN	21.65	0.791 8	773.879 7	7.130 9	3.910 1	0.570 9
	MSRCP	12.36	0.570 3	4 446.882 5	6.104 7	1.963 6	0.456 5
	UDCP	15.61	0.685 0	2 427.484 5	6.812 6	3.036 2	0.542 8
	Shallow-UWnet	20.45	0.768 7	949.169 0	6.852 4	3.020 9	0.522 3
	LiteEnhanceNet	20.52	0.826 7	801.719 2	7.132 2	3.341 7	0.594 7
	LU2Net	25.06	0.845 8	339.697 8	7.125 6	3.752 6	0.563 8
	Phaseformer	20.34	0.788 4	768.156 0	7.075 7	4.515 3	0.569 7
Test_EUVP	Ours	25.69	0.821 7	226.731 7	7.129 1	3.470 5	0.575 6
	WaterNet	20.79	0.787 7	669.092 0	7.120 5	3.523 6	0.544 0
	FUnIE-GAN	23.53	0.806 1	399.244 0	7.299 5	4.179 4	0.594 2
	MSRCP	12.95	0.542 9	3 998.593 5	6.088 4	1.879 1	0.460 6
	UDCP	17.58	0.695 1	1 411.794 4	7.014 6	3.391 1	0.580 5
	Shallow-UWnet	22.65	0.801 6	458.027 1	7.157 2	3.567 5	0.565 2
	LiteEnhanceNet	18.72	0.768 9	1 119.859 2	7.546 4	3.616 0	0.614 1
	LU2Net	24.80	0.815 8	291.836 0	7.100 1	3.807 7	0.565 1
	Phaseformer	19.14	0.755 8	956.856 7	7.365 6	4.561 1	0.584 6

表 2 无参考数据集评价指标对比

Tab. 2 Comparison of evaluation metrics on no-reference datasets

Dataset	Indicator	Ours	MSRCP	UDCP	FUnIE	WaterNet	Shallow	LiteEn	LU2Net	Phaseformer
Test_C60	UIQM	2.631 0	2.053 0	2.365 3	3.045 0	2.622 0	2.269 8	2.455 1	2.267 2	3.357 6
	UCIQE	0.539 8	0.453 2	0.512 6	0.535 0	0.488 8	0.479 3	0.534 0	0.513 2	0.527 9
	IE	6.922 4	5.960 0	6.272 2	6.798 6	6.574 4	6.479 0	6.149 8	6.651 2	6.766 7
blue	UIQM	3.516 3	1.907 1	2.950 4	3.953 5	3.213 9	2.911 0	3.690 2	3.827 3	4.111 9
	UCIQE	0.538 3	0.432 0	0.480 5	0.511 0	0.465 4	0.462 2	0.550 2	0.527 8	0.545 3
	IE	7.361 4	6.027 4	6.820 3	7.155 1	6.963 5	6.862 5	7.267 6	7.261 6	7.333 2
blue-green	UIQM	2.556 2	1.729 6	1.740 6	3.038 4	2.675 7	1.823 8	2.856 7	3.236 1	2.633 4
	UCIQE	0.569 5	0.440 8	0.448 4	0.533 1	0.480 4	0.406 8	0.536 5	0.561 6	0.495 2
	IE	7.234 1	6.218 3	6.411 5	6.993 2	7.022 1	6.297 8	7.177 0	7.152 3	6.948 4
green	UIQM	2.343 3	1.786 4	1.273 2	2.692 0	2.479 4	1.336 8	2.504 1	2.674 8	2.274 2
	UCIQE	0.527 9	0.436 7	0.406 3	0.493 1	0.447 6	0.381 8	0.487 5	0.511 5	0.437 3
	IE	7.135 9	6.308 1	5.186 3	6.876 9	6.996 9	6.000 2	7.056 4	7.300 6	6.812 3
Test_RUOD	UIQM	3.551 8	2.402 1	3.644 7	4.075 3	3.698 6	3.179 9	4.352 7	3.672 9	4.292 0
	UCIQE	0.590 3	0.463 3	0.567 2	0.577 8	0.539 5	0.539 0	0.589 0	0.546 8	0.568 9
	IE	7.190 4	5.923 2	6.731 6	7.105 9	6.875 1	6.893 1	7.085 2	6.945 7	7.156 1

blue, blue-green, green 和 Test_RUOD 无参考数据集也表现出较好成绩,IE 指标和 UCIQE 指标基本保持最优或次优。

本文方法在损失函数设计上偏向保持增强

图像与参考图像的像素和结构上的一致性,PSNR 等有参考指标表现优秀;而对图像细节与鲜艳度的感知有限,可能导致其在 UIQM 等无参考指标上的表现一般。MSE 倾向于寻找条件分

布的均值,使模型在重建过程中抑制高频噪声的同时,也平滑掉了一些细微的纹理细节和极端的色彩波动,从而导致生成图像在视觉上虽然准确但略显平淡。相比之下,Phaseformer等方法使用针对水下图像的损失函数,在图像质量指标上展现出一定优势。未来研究中将尝试引入感知损

失等水下专属约束,进一步平衡与参考图像相似度和图像色彩鲜艳度。

3.5 消融实验

为验证本文提出各模块的有效性,在Test_LSUI上设计了消融实验。逐步引入ADC和CAL,实验结果如表3所示。

表 3 不同模型配置的性能比较
Tab. 3 Performance comparison of different model configurations

Baseline	ADC	CAL	PSNR/dB	SSIM	UIQM	UCIQE	Params/M
√			23.99	0.841 5	3.305 7	0.572 3	0.41
√		√	24.76	0.848 0	3.307 7	0.573 5	0.54
√	√		24.41	0.845 6	3.309 6	0.572 4	1.47
√	√	√	25.13	0.849 1	3.322 9	0.573 4	1.60

基础模型(Baseline)仅使用骨干网络进行特征提取,PSNR 仅为 23.99 dB,该模型虽具有一定的特征提取能力,但缺乏对水下图像色偏与模糊问题的针对性设计,增强效果有限。加入CAL后,PSNR 提升至 24.76 dB,SSIM 提升至 0.848 0,UIQM 和 UCIQE 也相对提升,模型有效感知各通道的响应强度差异,通过自适应重校准通道权重,改善了颜色校正效果。在Baseline上加入ADC后,PSNR 提升至 24.41 dB,SSIM 提升至 0.845 6,验证了方向性卷积在扩大感受野、增强细节纹理方面的有效性。同时引入CAL和ADC后,PSNR 进一步提升至 25.13 dB,SSIM 达到 0.849 1。两个模块的协同作用带来了超越单一模块的增益,UIQM 和 UCIQE 指标的同步提升也证明了该设计在增强图像感知质量方面的有效性。

为了确定模型的关键超参数,本文进行了敏感性分析实验。首先,对于损失函数中的权重参数 λ ,测试了其在 $[0.1,1.0]$ 内的不同取值。如表4所示,当 $\lambda=0.3$ 时,模型在PSNR和SSIM指标上均达到峰值,分别为 25.13 dB 和 0.849 1。无参考指标也表现较好。因此,将 λ 设置为 0.3,以在像素级保真度和结构相似性之间取得最佳平衡。

对于轴向卷积的核大小 k ,实验评估了 $k=5,7,9$ 和 11 对模型性能的影响。实验结果如表5所示,当 $k=7$ 时,模型取得了最优的综合性能,较小

的核感受野有限,而较大的核在增加计算负担的同时并未带来性能提升。因此,本文最终选择 $k=7$ 作为轴向卷积的核大小。

表 4 损失函数超参数敏感性实验
Tab. 4 Loss function hyper-parameter sensitivity experiment

λ	PSNR/dB	SSIM	UIQM	UCIQE
0.1	24.88	0.848 2	3.315 7	0.571 6
0.2	24.83	0.847 8	3.312 8	0.572 8
0.3	25.13	0.849 1	3.322 9	0.573 4
0.5	24.45	0.840 8	3.323 4	0.570 6
0.7	24.70	0.845 3	3.320 3	0.572 0
1.0	24.75	0.846 8	3.314 6	0.572 2

表 5 轴向深度卷积模块超参数敏感性实验
Tab. 5 Experiment on hyperparameter sensitivity of axial depthwise convolution module

k	PSNR/dB	SSIM	UIQM	UCIQE
5	25.01	0.849 7	3.273 4	0.570 7
7	25.13	0.849 1	3.322 9	0.573 4
9	24.80	0.846 2	3.266 9	0.571 0
11	24.97	0.841 1	3.275 2	0.572 4

为了验证本文提出方法在计算效率与增强性能之间的平衡优势,分别将本文并行融合模块和ADC模块分别替换为功能相似的轻量模块

CBAM^[28]和 Strip Pooling^[39]进行对比。

从表 6 可以看出,虽然使用 CBAM 的参数数量和计算量最低,但其增强性能也最弱。相比之下,本文的模型仅增加了 0.07 G 的计算量,PSNR 却有 1.67 dB 的提升。与使用 Strip Pool-

ing 的模型相比,本文方法的计算开销与之几乎相同,但 PSNR 和 SSIM 指标上分别取得了 0.75 dB 和 0.045 8 的优势。相比而言,本文方法能够更有效地提取和融合特征,是面向边缘设备部署的更好选择。

表 6 不同轻量级模块效率与性能评估

Tab. 6 Efficiency and performance evaluation of different lightweight modules

Method	Params/M	FLOPs/G	PSNR / dB	SSIM	UIQM	UCIQE
Ours	1.60	0.13	25.13	0.849 1	3.322 9	0.573 4
CBAM	0.54	0.06	23.46	0.823 1	3.284 6	0.572 2
Strip pooling	1.59	0.13	24.38	0.803 3	3.325 2	0.572 9

3.6 处理速度

在 CPU 上,对 100 张不同分辨率水下图像开展无 GPU 加速的推理耗时测试,与近年轻量级水下图像增强算法 LU2Net, LiteEnhanceNet 和 Shallow-UWnet 的对比结果如表 7 所示。本文方法在 256×256 至 $3\,840 \times 2\,160$ 的全分辨率区间内,单张平均运行时间均显著低于对比算法,且分辨率越高,速度优势越突出。在 4 K ($3\,840 \times 2\,160$) 分辨率下,本文方法单张耗时仅 0.535 0 s。

本文方法的性能指标满足水下边缘平台的工程部署需求。水下自主航行器和水下机器人通常搭载嵌入式计算平台,存储与功耗资源均有限,本文模型参数量仅为 1.60 M, FLOPs 仅为 0.13 G。在实时性方面,水下目标检测、避障等下游任务通常要求图像处理帧率不低于 10~15 FPS,本文在 Jetson Orin NX 上未开启 TensorRT 加速,对 256×256 图像的处理速度达 144.61 frame/s, 1080P 实时视频流稳定在 20 frame/s, 满足实时性约束。

表 7 不同分辨率下各种方法的平均运行时间

Tab. 7 Average running time of various methods at different resolutions

(s)

Method	256×256	$1\,280 \times 720$	$1\,920 \times 1\,440$	$3\,840 \times 2\,160$
Ours	0.017 2	0.076 3	0.197 5	0.535 0
LU2Net	0.047 6	0.534 6	1.450 0	5.281 8
LiteEnhanceNet	0.046 5	0.688 1	1.638 8	7.817 5
Shallow-UWnet	0.112 9	1.612 9	4.098 0	12.648 2

4 结 论

本文提出了一种轴向卷积与通道注意力并行融合的轻量水下图像增强网络。针对水下图像颜色失真、细节模糊等问题,以 ShuffleNet V2 为轻量编码器实现紧凑特征提取,在瓶颈处并行设计轴向深度卷积模块与通道注意力层,分别从空间与通道维度精炼特征表示,并通过全局残差连接完成增强重建,兼顾了增强质量与计算效

率。在 LSUI, UIEB, EUVP 等多个公开数据集上的实验表明,本文方法在 PSNR, SSIM, UCIQE 等关键指标上优于主流对比算法,增强图像色彩自然、细节清晰,主观视觉效果贴近参考图像;无参考数据集上的评估结果进一步验证了其在多场景下的良好泛化能力。消融实验验证了轴向深度卷积与通道注意力模块的协同增益效应,二者联合使用可获得超越单一模块的性能提升。从编码器选型、瓶颈模块设计到解码器结

构,本文从网络全链路角度系统实现了轻量化,以 1.60 M 参数量和 0.13 G FLOPs 达到了增强质量与计算效率的协同提升。在 CPU 及 Jetson Orin NX 嵌入式平台上的速度测试表明,本文方法在全分辨率区间内推理耗时显著低于同类轻量算法,具备良好的实时部署潜力。

后续研究将进一步聚焦极端浑浊、弱光不均等复杂水下场景的算法稳定性优化,并探索图像增强算法与下游目标检测、语义分割等高层视觉任务的端到端联合优化,拓展其在真实海洋工程

场景中的应用边界。

作者贡献声明:

贺锋涛:写作指导,论文审核;

李丽华:方法提出,实验验证,数据整理和分析,初稿写作;

杨 玮、张建磊:提供资源,实验指导;

刘蕊蕊:数据分析;

冯斌杰:调查研究。

参考文献:

- [1] 商家硕,李颖,袁靖懿,等. 均值强度差先验驱动的水下图像复原[J]. 光学精密工程, 2025, 33(18): 2962-2979.
SHANG J SH, LI Y, YUAN J Y, *et al.* Underwater image restoration driven by the mean intensity difference prior[J]. *Optics and Precision Engineering*, 2025, 33(18): 2962-2979. (in Chinese)
- [2] 常志文,王立忠,梁晋,等. 基于图像块分解融合的水下标定图像增强[J]. 中国光学(中英文), 2024, 17(4): 810-822.
CHANG ZH W, WANG L ZH, LIANG J, *et al.* Underwater calibration image enhancement based on image block decomposition and fusion[J]. *Chinese Optics*, 2024, 17(4): 810-822. (in Chinese)
- [3] 郭梨,黄智奇,何润丰,等. 一种基于改进 DCGAN 的水下图像增强方法[J]. 光学学报, 2026, 46(2): 0210005.
GUO L, HUANG ZH Q, HE R F, *et al.* Underwater image enhancement method based on improved DCGAN[J]. *Acta Optica Sinica*, 2026, 46(2): 0210005. (in Chinese)
- [4] JAFFE J S. Computer modeling and the design of optimal underwater imaging systems [J]. *IEEE Journal of Oceanic Engineering*, 1990, 15(2): 101-111.
- [5] 王驰,沈晨,黄庆,等. 夜间动物图像自监督学习增强与检测方法[J]. 中国光学(中英文), 2024, 17(5): 1087-1097.
WANG CH, SHEN CH, HUANG Q, *et al.* Self-supervised learning enhancement and detection methods for nocturnal animal images[J]. *Chinese Optics*, 2024, 17(5): 1087-1097. (in Chinese)
- [6] 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.
- [7] ZHOU J C, PANG L, ZHANG D H, *et al.* Underwater image enhancement method *via* multi-interval subhistogram perspective equalization [J]. *IEEE Journal of Oceanic Engineering*, 2023, 48(2): 474-488.
- [8] ACHARYA U K, KUMAR S. Directed searching optimized mean-exposure based sub-image histogram equalization for grayscale image enhancement [J]. *Multimedia Tools and Applications*, 2021, 80(16): 24005-24025.
- [9] PENG Y T, CHEN Y R, CHEN Z H, *et al.* Underwater image enhancement based on histogram-equalization approximation using physics-based dichromatic modeling [J]. *Sensors*, 2022, 22(6): 2168.
- [10] PENG Y T, CAO K M, COSMAN P C. Generalization of the dark channel prior for single image restoration [J]. *IEEE Transactions on Image Processing*, 2018, 27(6): 2856-2868.
- [11] 林森,白莹,李文涛,等. 基于修正模型与暗通道先验信息的水下图像复原[J]. 机器人, 2020, 42(4): 427-435, 447.
LIN S, BAI Y, LI W T, *et al.* Underwater image restoration based on the modified model and dark channel prior[J]. *Robot*, 2020, 42(4): 427-435, 447. (in Chinese)
- [12] LIANG Z, DING X Y, WANG Y F, *et al.* GUD-CP: generalization of underwater dark channel prior for underwater image restoration [J]. *IEEE Transactions on Circuits and Systems for Video*

- Technology*, 2022, 32(7): 4879-4884.
- [13] 李文彪, 陶洋, 董源, 等. 基于颜色先验引导和注意力机制的水下图像增强[J]. 液晶与显示, 2025, 40(8): 1163-1176.
- LI W B, TAO Y, DONG Y, *et al.* Underwater image enhancement based on color prior guidance and attention mechanism [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(8): 1163-1176. (in Chinese)
- [14] RUAN R, ZENG W H, LEI Y, *et al.* Image restoration method based on adaptive multiple priors fusion in scattering scenes[C]. Fourteenth International Conference on Graphics and Image Processing (ICGIP 2022). October 21-23, 2022. Nanjing, China. SPIE, 2023: 20.
- [15] 郝显权, 陈洁, 赵慧慧. 基于Retinex的边缘定位水下图像增强算法[J]. 传感器世界, 2025, 31(8): 7-11.
- HAO Y Q, CHEN J, ZHAO H H. Edge localization underwater image enhancement algorithm based on retinex[J]. *Sensor World*, 2025, 31(8): 7-11. (in Chinese)
- [16] 张傲琳, 赵辉, 刘天阳, 等. 基于Retinex理论的水下图像多尺度自适应增强算法[J]. 激光与光电子学进展, 2026, 63(4): 0437001.
- ZHANG A L, ZHAO H, LIU T Y, *et al.* Multi-scale adaptive enhancement algorithm for underwater images based on retinex theory[J]. *Laser & Optoelectronics Progress*, 2026, 63(4): 0437001. (in Chinese)
- [17] MA H P, SUN S Y, YE S G, *et al.* Non-uniform illumination underwater image enhancement via minimum weighted error entropy loss [J]. *IEEE Signal Processing Letters*, 2023, 30: 1187-1191.
- [18] ZHOU J C, WANG Y Y, LI C Y, *et al.* Multi-color light attenuation modeling for underwater image restoration[J]. *IEEE Journal of Oceanic Engineering*, 2023, 48(4): 1322-1337.
- [19] 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.
- [20] 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.
- [21] PENG L T, ZHU C L, BIAN L H. U-shape transformer for Underwater image enhancement [C]. *Computer Vision -ECCV 2022 Workshops*. Cham: Springer, 2023: 290-307.
- [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] NAIK A, SWARNAKAR A, MITTAL K. Shallow-UWnet: compressed model for underwater image enhancement [EB/OL]. 2021: *arXiv*: 2101.02073. <https://arxiv.org/abs/2101.02073>.
- [24] 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.
- [25] MA N N, ZHANG X Y, ZHENG H T, *et al.* ShuffleNet V2: practical guidelines for efficient CNN architecture design [C] *Computer Vision-ECCV 2018*. Cham: Springer, 2018: 122-138.
- [26] DINH B D, NGUYEN T T, TRAN T T, *et al.* 1M parameters are enough? A lightweight CNN-based model for medical image segmentation [C]. 2023 *Asia Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)*. October 31-November 3, 2023, Taipei, China. IEEE, 2023: 1279-1284.
- [27] 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.
- [28] WOO S, PARK J, LEE J Y, *et al.* CBAM: convolutional block attention module [C]. *Computer Vision-ECCV 2018*. Cham: Springer International Publishing, 2018: 3-19.
- [29] FU C P, LIU R S, FAN X, *et al.* Rethinking general underwater object detection: Datasets, challenges, and solutions [J]. *Neurocomputing*, 2023, 517: 243-256.
- [30] LIU R S, FAN X, ZHU M, *et al.* Real-world underwater enhancement: challenges, benchmarks, and solutions under natural light [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2020, 30(12): 4861-4875.
- [31] 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.*
- [32] MITTAL A, SOUNDARARAJAN R, BOVIK A C. Making a “completely blind” image quality analyzer [J]. *IEEE Signal Processing Letters*, 2013, 20(3): 209-212.
- [33] 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.
- [34] YANG M, SOWMYA A. An underwater color image quality evaluation metric [J]. *IEEE Transactions on Image Processing*, 2015, 24(12): 6062-6071.
- [35] LIU Z W, YANG Y. Adaptive MSRCP-based color image enhancement method using SSA [C]. *2024 2nd International Conference on Algorithm, Image Processing and Machine Vision (AIPMV)*. July 12-14, 2024, Zhenjiang, China. IEEE, 2024: 209-214.
- [36] DREWS P Jr, NASCIMENTO EDO, MORAES F, *et al.* Transmission estimation in underwater single images [C]. *2013 IEEE International Conference on Computer Vision Workshops*. December 2-8, 2013, Sydney, NSW, Australia. IEEE, 2014: 825-830.
- [37] YANG H D, XU J S, LIN Z L, *et al.* LU2Net: a lightweight network for real-time underwater image enhancement [EB/OL]. 2024: *arXiv*: 2406.14973. <https://arxiv.org/abs/2406.14973>.
- [38] 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.
- [39] HOU Q B, ZHANG L, CHENG M M, *et al.* Strip pooling: rethinking spatial pooling for scene parsing [C]. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 4002-4011.

作者简介:



贺锋涛(1974—),男,陕西西安人,博士,副教授,硕士生导师,2000年于西北大学获得硕士学位,2004年于中国科学院西安光学精密机械研究所获得博士学位,主要从事水下无线光通信及水下信息处理等方面的研究。E-mail:Hefengtao@xupt.edu.cn

通讯作者:



李丽华(2001—),女,陕西宝鸡人,硕士研究生,2024年于西安邮电大学获得学士学位,主要研究方向为水下图像增强及水下目标检测等。E-mail:lilihua@stu.xupt.edu.cn