

基于任务解耦的低照度图像增强方法

牛玉贞^{1,2,3}, 陈铭铭¹, 李悦洲¹, 赵铁松^{4*}

(1. 福州大学计算机与大数据学院, 福建福州 350108; 2. 福建省网络计算与智能信息处理重点实验室(福州大学), 福建福州 350108;
3. 大数据智能教育部工程研究中心, 福建福州 350108; 4. 福州大学物理与信息工程学院, 福建福州 350108)

摘要: 低照度条件下拍摄的照片往往存在亮度低、颜色失真、噪声高、细节退化等多重耦合问题, 因此低照度图像增强是一个具有挑战性的任务. 现有基于深度学习的低照度图像增强方法通常聚焦于对亮度和色彩的提升, 导致增强图像中仍然存在噪声等缺陷. 针对上述问题, 本文提出了一种基于任务解耦的低照度图像增强方法, 根据低照度图像增强任务对高层和低层特征的不同需求, 将该任务解耦为亮度与色彩增强和细节重构两组任务, 进而构建双分支低照度图像增强网络模型(Two-Branch Low-light Image Enhancement Network, TBLIEN). 其中, 亮度与色彩增强分支采用带全局特征的U-Net结构, 提取深层语义信息改善亮度与色彩; 细节重构分支采用保持原始分辨率的全卷积网络实现细节复原和噪声去除. 此外, 在细节重构分支中, 本文提出一种半双重注意力残差模块, 能在保留上下文特征的同时通过空间和通道注意力强化特征, 从而实现更精细的细节重构. 在合成和真实数据集上的广泛实验表明, 本文模型的性能超越了当前先进的低照度图像增强方法, 并具有更好的泛化能力, 且可适用于水下图像增强等其他图像增强任务.

关键词: 低照度图像增强; 任务解耦; 双分支网络模型; 对比学习; 残差网络

基金项目: 国家自然科学基金(No.62171134); 福建省自然科学基金(No.2023J01067)

中图分类号: TP391.41

文献标识码: A

文章编号: 0372-2112(2024)01-0034-12

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20230189

Task Decoupling Guided Low-Light Image Enhancement

NIU Yu-zhen^{1,2,3}, CHEN Ming-ming¹, LI Yue-zhou¹, ZHAO Tie-song^{4*}

(1. College of Computer and Data Science, Fuzhou University, Fuzhou, Fujian 350108, China;

2. Fujian Key Laboratory of Network Computing and Intelligent Information Processing, Fuzhou University, Fuzhou, Fujian 350108, China;

3. Big Data Intelligence Engineering Research Center of the Ministry of Education, Fuzhou University, Fuzhou, Fujian 350108, China;

4. College of Physics and Information Engineering, Fuzhou University, Fuzhou, Fujian 350108, China)

Abstract: Photos captured under low-light conditions suffer from multiple coupling problems, i.e., low brightness, color distortion, heavy noise, and detail degradation, making low-light image enhancement a challenging task. Existing deep learning-based low-light image enhancement methods typically focus on improving the illumination and color while neglecting the noise in the enhanced image. To solve the above problems, this paper proposes a low-light image enhancement method based on task decoupling. According to the different requirements for high-level and low-level features, the low-light image enhancement task is decoupled into two subtasks: illumination and color enhancement and detail reconstruction. Based on the task decoupling, we propose a two-branch low-light image enhancement network (TBLIEN). The illumination and color enhancement branch is built as a U-Net structure with global feature extraction, which exploits deep semantic information for illumination and color improvement. The detail reconstruction branch uses a fully convolutional network that preserves the original resolution while performing detail restoration and noise removal. In addition, for the detail reconstruction branch, we design a half-dual attention residual module. Our module enhances features through spatial and channel attention mechanisms while preserving their context, allowing precise detail reconstruction. Extensive experiments on real and synthetic datasets show that our model outperforms other state-of-the-art methods, and has better generalization capability. Our method is also applicable to other image enhancement tasks, i.e., underwater image enhancement.

Key words: low-light image enhancement; task decoupling; two-branch network; comparative learning; residual network

Foundation Item(s): National Natural Science Foundation of China (No.62171134); Natural Science Foundation of Fujian Province (No.2023J01067)

1 引言

受限于拍摄环境或技术水平,在光照不足场景下拍摄的照片呈现背光、极弱光、非均匀照明等特征,所摄图像质量严重退化,削弱了图像的信息表达能力,进而影响到其在高层计算机视觉任务中的作用,如目标跟踪、检测和语义分割等^[1,2].为解决上述问题,低照度图像增强任务被提出,增强结果不仅可以提升观看者对图像的主观视觉体验,还可以提高图像的客观质量,提高图像在计算机视觉和机器视觉系统应用中的可用性和鲁棒性.低照度图像增强可广泛应用于城市交通监测、户外视频采集、卫星遥感、军事航空调查等领域,对其他图像增强任务的研究也具有参考价值^[3],如水下图像增强、雾霾图像增强等.低照度图像往往存在亮度低、颜色失真、噪声高、细节退化等多重耦合问题,因此低照度图像增强是一个具有挑战性的任务.

早期的低照度图像增强方法主要基于直方图均衡化和 Retinex 理论.基于直方图均衡化的方法^[4,5]通过扩大像素的分布范围从而提高低照度图像的对比度.基于 Retinex 理论的方法^[6-8]模拟人类视觉系统特性,将图像表示为反射分量和照明分量的乘积,通过对反射分量的增强实现低照度图像增强.上述方法的计算较为简单,但应用性能受限于可学习的参数量和函数的复杂度,在增强后的图像中容易出现光照分布异常.

近年来,基于深度学习技术的低照度图像增强方法^[9-25]受到较多关注,卷积神经网络可以提供强大的特征提取能力,允许模型直接学习不同照度图像间的映射关系^[13-20].具体来说,基于流正则化^[17]、小波变换^[18]、代表性颜色映射^[21,22]等模拟图像转换的方法能较好地对色彩和亮度进行增强,但是缺乏对图像细节的针对性处理,使得增强后的图像仍存在较为明显的噪声和细节退化现象.因此,已有研究采用数据增强^[19]、噪声估计^[23]等方式直接关注噪声信息,或提出渐进式重建^[24]、对抗式学习^[25]等方式纠正细节.然而,这些方法使用相同的网络不加区分地对亮度、色彩和细节处理图像亮度与色彩的同时对细节进行增强,缺乏对不同感知特性的处理的有效性,因而这些方法在细节重构方面的效果仍然受限.

为解决上述问题,本文提出了一种基于任务解耦的低照度图像增强方法,将低照度图像增强任务解耦为两类子任务:亮度与色彩增强和细节重构,并提出了

一种新的双分支结构用于低照度图像增强,使模型在各自的分支上专注于所解决的子任务.其次,本文还设计了高效的半双重注意力残差模块,以实现更精细的噪声去除和细节复原,最后,在损失函数部分,引入对比学习,提出了基于亮度分布加权的对比正则化损失,有助于提高模型的泛化能力.实验结果表明本文模型不仅在低照度图像增强任务上优于当前先进方法,且能很好地适应其他图像增强任务,如水下图像增强.

2 本文工作

在低照度图像增强任务中,重建出令人满意的正常照度图像,需要在提升图像亮度和色彩的同时进行高质量细节重构,包括增强图像细节和去除噪声.其中,图像的亮度与色彩增强需要图像高层语义特征的引导,如图像的整体照明条件和场景布局^[26],从而实现对先验知识(如蓝天白云)的挖掘和利用.然而图像细节、纹理、噪声、模糊等信息更多地蕴含在低层特征中,因此与亮度和色彩增强任务相比,去噪和细节复原任务更依赖低层特征.根据低照度图像增强中不同任务对高层和低层特征的不同需求,本文将低照度图像增强解耦为亮度与色彩增强和细节重构两类子任务,并提出基于任务解耦的双分支低照度图像增强网络(Two-Branch Low-light Image Enhancement Network, TBLIEN).模型的整体框架如图 1 所示,包含细节重构分支(Detail Reconstruction Branch, DRB)和亮度与色彩增强分支(Illumination and Color Enhancement Branch, ICEB).

本文提出的双分支低照度图像增强模型可以表示为

$$\begin{aligned} I_{\text{high}} &= \text{TBLIEN}(I_{\text{low}}) \\ &= \text{Sig}\left(\text{Conv}_{3 \times 3}\left(\text{DRB}(I_{\text{low}}) \circ \text{ICEB}(I_{\text{low}})\right)\right) \end{aligned} \quad (1)$$

其中, I_{low} 和 I_{high} 分别是网络输入的低照度图像和输出的增强结果, TBLIEN, DRB, 和 ICEB 分别表示本文提出的双分支低照度图像增强网络、细节重构分支和亮度与色彩增强分支, $\text{Sig}(\cdot)$ 表示归一化激活函数 Sigmoid, $\text{Conv}_{3 \times 3}$ 表示卷积核大小为 3×3 的卷积层, \circ 表示通道上的拼接操作.

2.1 细节重构分支

针对低照度图像通常存在的噪声和细节退化问题,细节重构分支在保持原始分辨率的全卷积网络上去除拍摄过程中引入的噪声,复原由于低照度拍摄条

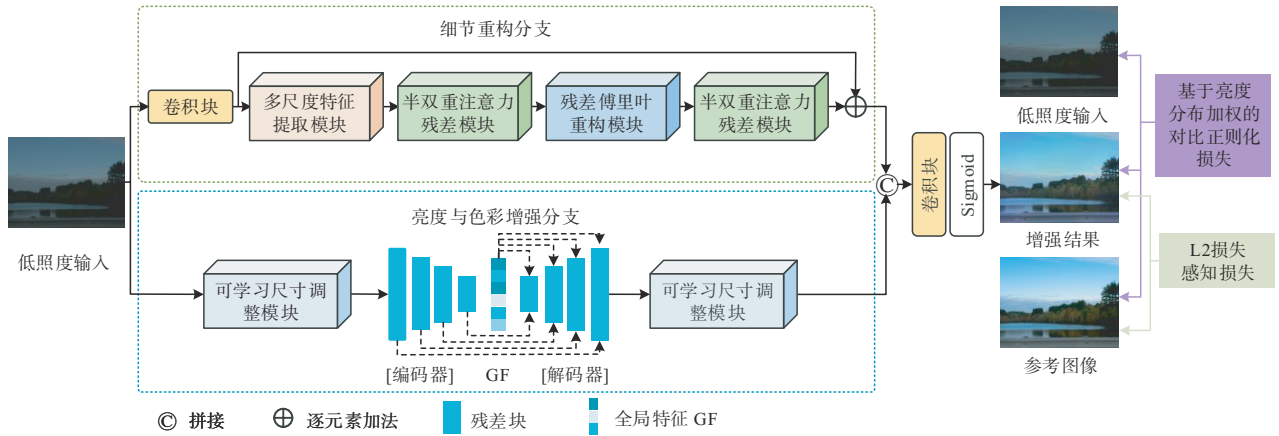


图1 双分支低照度图像增强网络

件导致的场景细节退化. 如图1所示, 细节重构分支依次由卷积块、多尺度特征提取模块(Multi Scale Feature Extraction Module, MSFEM)、半双重注意力残差模块(Half Dual Attention Residual Module, HDARM)、残差傅里叶重构模块(Residual Fast Fourier Transform block, ResFFT)和半双重注意力残差模块组成. 输入图像经由卷积块得到的特征与经过各个模块后的特征进行残差连接, 使得各模块专注于学习图像中的细节信息.

多尺度特征提取模块利用不同尺寸的卷积核捕获丰富的多尺度图像特征. 本文提出的半双重注意力残差模块在保留上下文特征的同时通过空间和通道注意力对特征进行加强. 残差傅里叶重构模块实现在频率域对特征的增强. 此外, 为了保证结构的稳定性, 减少信息在特征传递中的损失, 在每个模块内使用残差连接, 使丰富的低频信息通过跳跃连接直接进行传播, 因而各模块能够专注于学习高频信息. 下文将详细介绍各个模块.

(1) 多尺度特征提取模块

由于真实场景存在不同尺寸的物体, 如建筑、树木等大型物体, 书本、玩偶等小型物体, 使用不同尺寸的卷积核对应不同的感受野, 能够捕捉不同尺度的信息. 为了更好地应对同类物体以不同比例出现或同一场景下出现不同尺寸物体的情况, 本文提出多尺度特征提取模块. 如图2(a)所示, 对于输入的特征, 该模块分别使用 3×3 、 5×5 和 7×7 三种尺寸的卷积核, 得到三种感受野下的特征图, 再经由特征选择模块^[27]聚合不同尺度的信息.

(2) 半双重注意力残差模块

对于细节重构分支, 其核心任务在于尽可能精细地捕获特征、去除噪声和细节复原. 在该目标的指导下, 本文提出的半双重注意力残差模块由残差模块ResBlock改进而来, 如图3所示, 由两组多尺度卷积

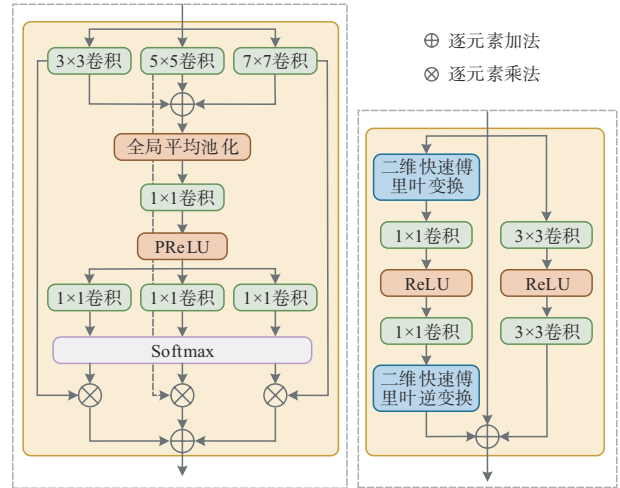


图2 多尺度特征提取模块和残差傅里叶重构模块

层、半双重注意力单元、实例正则化层和ReLU组成, 并与输入特征进行残差连接. 其中多尺度卷积层扩大了特征的感受野. 为了在高效强化特征学习的同时避免特征在传递过程中丢失, 本文提出了半双重注意力单元, 将特征输入按通道划分^[28], 其中一部分通道特征经过残差连接保留原始的上下文信息, 另一部分通道特征经过通道和空间注意力层^[29]进一步强化特征的代表能力, 两类特征并存可以提高特征的鲁棒性^[28].

半双重注意力单元的输入特征用 $\mathbf{S}_{in} \in \mathbb{R}^{C \times H \times W}$ 表示, 然后按通道切分特征 \mathbf{S}_{in} , 得到两组特征图 $\mathbf{S}_{mid1}, \mathbf{S}_{mid2} \in \mathbb{R}^{\frac{C}{2} \times H \times W}$, 其中 \mathbf{S}_{mid2} 不做任何处理, 用以保留域特征信息, \mathbf{S}_{mid1} 则经过空间和通道注意力对特征进行加强. 具体来说, \mathbf{S}_{mid1} 依次经过两个 3×3 卷积层和激活函数PReLU层, 得到特征图 $\mathbf{S}'_{mid1} \in \mathbb{R}^{C \times H \times W}$, 再经由通道注意力层CA和空间注意力层SA分别在通道和空间维度对特征进行增强, 两个注意力层的输出在通道维

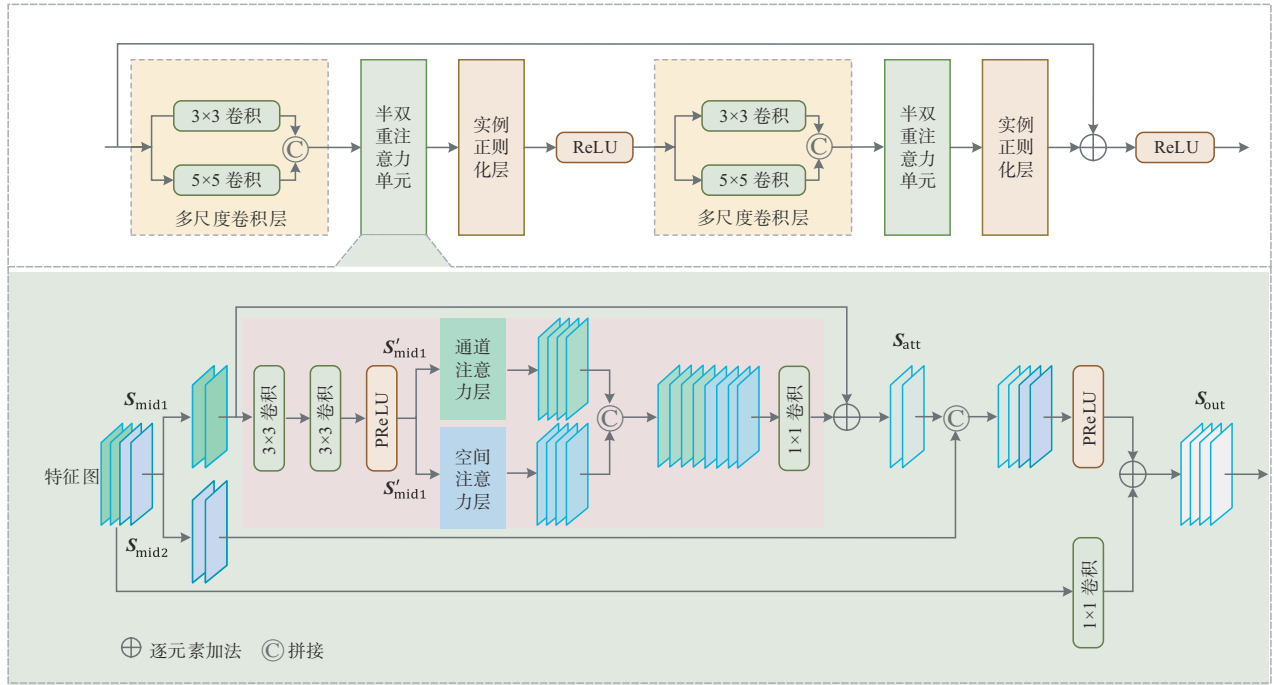


图3 半双重注意力残差模块

度上拼接,并使用 1×1 卷积将其通道数降低为 $\frac{C}{2}$,与 S_{mid1} 逐元素相加,得到具有丰富注意力信息的特征 $S_{att} \in \mathbb{R}^{\frac{C}{2} \times H \times W}$.将 S_{att} 与保留上下文信息的 S_{mid2} 在通道维度上拼接,使用激活函数PReLU进行非线性变换,得到残差特征.最后,将这些残差特征与经过 1×1 卷积后的 S_{in} 逐元素相加,得到半双重注意力单元的输出 $S_{out} \in \mathbb{R}^{C \times H \times W}$,具体公式如下:

$$S'_{mid1} = \text{PReLU}(\text{Conv}_{3 \times 3}(\text{Conv}_{3 \times 3}(S_{mid1}))) \quad (2)$$

$$S_{att} = \text{Conv}_{1 \times 1}(\text{CA}(S'_{mid1}) \odot \text{SA}(S'_{mid1})) + S_{mid1} \quad (3)$$

$$S_{out} = \text{Conv}_{1 \times 1}(S_{in}) + \text{PReLU}(S_{att} \odot S_{mid2}) \quad (4)$$

其中, S_{in} 和 S_{out} 分别是半双重注意力单元的输入和输出特征, $\text{Conv}_{k \times k}$ 表示卷积核大小为 $k \times k$ 的卷积层,CA和SA分别表示通道注意力层和空间注意力层.

为了防止训练过程中出现梯度消失,同时使模型能更好地将数据分布映射到特定区域,本文在半双重注意力单元后使用实例归一化层(Instance Normalization, INor)^[30]对特征进行归一化.深度神经网络通常会在网络结构中加入归一化层,最常使用的是批归一化(Batch Normalization, BNor)^[31],该方法计算训练数据集中沿批次维度的平均值和标准差.但BNor的使用容易导致批量数据处理的相关性,使同批次训练数据间存在依赖.文献[30]提出在图像增强任务中使用INor替换BNor层,避免生成的图像受到同批次数据的影响,保证每个图像的独立性.此外,图像增强任务通常使用小批量数据训练,限制了BNor批量数据处理的能力,容易

导致统计量的不稳定.基于上述考量,本文采用实例归一化方法.

(3)残差傅里叶重构模块

为了充分利用高低频信息的不同特性,尤其是高频信息的细节重构能力,本文引入了Mao等^[32]提出的残差傅里叶重构模块.如图2(b)所示,该模块分别在空间域和频率域学习输入特征的残差特征.使用二维快速傅里叶变换将输入的特征映射到频率域,得到实部R和虚部I,在频率域进行卷积、激活运算,最后逆变换到空间域,从而完成低频、高频中残差特征的学习.由于噪声、边缘、纹理等细节特征更多分布于高频区域,这种做法能敏锐地捕获低质量图像和高质量图像对之间的差异.

2.2 亮度与色彩增强分支

低照度图像的亮度与色彩增强需要综合利用图像高层和底层信息,且高层信息对获得合理的色彩和亮度增强至关重要,如光照分布、场景布局等.如图1所示,本文提出的亮度与色彩增强分支采用带全局特征的编码-解码结构,可以在不同分辨率上提取图像高层和底层特征,从而实现有效合理的亮度与色彩增强.为适应具有不同分辨率的低照度图像,输入的低照度图像 I_{low} 首先由可学习图像尺寸调整模块将图像大小调整为统一尺寸,然后由带全局特征的编码-解码结构提取和融合不同级别特征,最后再经由可学习尺寸调整模块重新上采样至原始输入大小.

(1)可学习尺寸调整模块

带全局特征的编码-解码结构接受固定大小的特征输入,因此需要将不同大小的低照度输入图像调整为满足其结构要求的统一尺寸.直接使用双线性下采样 Bilinear 会损失图像信息,因此本文采用可学习尺寸调整模块 Resizer^[33]完成对图像尺寸的调整.可学习尺寸调整模块结合双线性采样和深度学习网络,通过残差等结构融合不同分辨率的图像特征,最大限度保证了图像尺寸改变的灵活性和结果图像中信息的完整性.

(2)带全局特征的编码-解码结构

本文采用带全局特征的编码-解码结构^[26],融合不同级别特征并在体现图像语义的全局特征的指导下对低照度图像的色彩和亮度进行增强.如图1所示,在编码过程中,通过卷积层对输入图像进行逐步下采样,得到多个级别的亮度与色彩特征,直到获得全局特征 GF,其维度为 $C_g \times 1 \times 1$.全局特征体现的是图像的高层语义信息,如整体光照条件和场景布局等.在解码过程中,由低分辨率特征到高分辨率特征逐层解码,且每个级别的特征解码过程中充分融合了学习到的全局特征、对应级别的编码器特征及上一级别的解码器特征.通过带全局特征的编码-解码结构,利用学习到的全局特征可实现更自然的图像亮度与色彩增强.

2.3 损失函数

本文定义模型的损失函数如下:

$$L_{\text{total}} = \lambda_1 \cdot L_{\text{rec}} + \lambda_2 \cdot L_{\text{pec}} + \lambda_3 \cdot L_{\text{cr}} \quad (5)$$

其中, L_{total} 表示总损失函数, L_{rec} 、 L_{pec} 、 L_{cr} 和 λ_1 、 λ_2 、 λ_3 分别对应 L2 损失、感知损失^[34]、基于亮度分布加权的对比正则化损失及其相应的系数, \cdot 为实数的点乘操作. L2 损失和感知损失的计算公式如下:

$$L_{\text{rec}} = \left\| \mathbf{I}_{\text{high}} - \mathbf{I}_{\text{gt}} \right\|_2^2 \quad (6)$$

$$L_{\text{pec}} = \frac{1}{H \times W \times C} \left\| F(\mathbf{I}_{\text{high}}) - F(\mathbf{I}_{\text{gt}}) \right\|_2^2 \quad (7)$$

其中, \mathbf{I}_{high} 为低照度图像增强网络得到的增强结果图像, \mathbf{I}_{gt} 为对应的正常照度图像, $F(\cdot)$ 表示使用在 ImageNet 数据集上预训练的 VGG16 模型提取 relu5_4 层输出的特征图, $F(\cdot) \in \mathbb{R}^{H \times W \times C}$.

此外,为适应具有不同照度水平的低照度图像、提高模型泛化能力,本文引入对比学习思想,提出基于亮度分布加权的对比正则化损失函数,约束增强结果的整体光照水平,避免增强结果图像中出现过曝或欠曝区域.在对比学习中模型的目标是,增强后的图像 \mathbf{I}_{high} 在特征空间中与正样本间的距离更加接近,同时与负样本间的距离更远.本文定义模型增强后的图像 \mathbf{I}_{high} 对应的正样本和负样本分别为正常照度图像 \mathbf{I}_{gt} 和低照度图像 \mathbf{I}_{low} ,且由 \mathbf{I}_{gt} 和 \mathbf{I}_{high} 组成正样本对, \mathbf{I}_{low} 和 \mathbf{I}_{high} 组成负样本对.由于各低照度图像的照度水平不同,为了避免增强后的图像出现局部过曝或欠曝现象,本文提

出基于亮度分布加权的对比正则化损失函数.本文首先将图像区分为暗区和亮区,分别在暗区和亮区计算样本间的距离,并在距离聚合时给予暗区更大的权重.受到文献[13]的启发,本文将增强后的图像 \mathbf{I}_{high} 转换为灰度图像 \mathbf{I}_{gray} ,并按照灰度值从低到高排序,通过实验确定处于 $p\%$ ($p=40$) 的值作为区分暗区和亮区的阈值 v ,低于该阈值的像素组成暗区,其他像素组成亮区,赋予亮区、暗区不同的权重,从而得到权重矩阵 \mathbf{I}_{mask} ,具体按如下公式计算基于亮度分布加权的对比正则化损失:

$$v = \text{topk}(\mathbf{I}_{\text{gray}}, p) \quad (8)$$

$$\mathbf{I}_{\text{mask}} = 1 \cdot (\mathbf{I}_{\text{gray}} > v) + 4 \cdot (\mathbf{I}_{\text{gray}} \leq v) \quad (9)$$

$$d(x, y) = \frac{1}{H \times W} \cdot \sum (\mathbf{I}_{\text{mask}} \cdot |x - y|) \quad (10)$$

$$L_{\text{cr}} = \frac{d(\mathbf{I}_{\text{high}}, \mathbf{I}_{\text{gt}})}{d(\mathbf{I}_{\text{low}}, \mathbf{I}_{\text{high}})} \quad (11)$$

其中, $\Sigma(\cdot)$ 表示求和函数, $\text{topk}(\mathbf{I}_{\text{gray}}, p)$ 表示对 \mathbf{I}_{gray} 的所有像素值排序后取位于 $p\%$ 的像素值, (x, y) 表示正样本对或负样本对, H 和 W 则分别表示输入图像的长和宽.

3 实验结果及分析

3.1 实验细节

本文在 NVIDIA GeForce RTX 2080 SUPER GPU 上基于开源深度学习框架 PyTorch^[35]实现并训练了所提出的网络.本文使用真实数据集 LOL^[9]作为训练集,初始学习率设置为 5×10^{-4} ,采用 Adam^[36]作为优化器,经过 1 000 个 epoch,遵循余弦退火策略^[37]使学习率平稳衰减至 1×10^{-6} .训练时输入图像随机裁剪为 384×384 ,批次大小为 2.

3.2 数据集

本文在真实数据集 LOL^[9]、LSRW^[10]和合成数据集 MIT-Adobe FiveK^[38]上进行测试,验证本文所提出方法的有效性.其中, LOL^[9]包含 500 张低照度图像及其配对的正常照度图像,每张图像的大小均为 400×600 .本文依循作者的设置,使用 485 个图像对组成的 LOL-train 用于训练,余下 15 个图像对组成的 LOL-test 用于测试; LSRW^[10]包含 50 个测试图像对,表示为 LSRW-test; MIT-Adobe FiveK^[38]包含 498 对由专业摄影师调整过的低照度图像及其对应的参考图像,本文按照文献[39]的设置选取测试集,表示为 MIT-Adobe FiveK-test.

3.3 实验结果

本文采用峰值信噪比 (Peak Signal to Noise Ratio, PSNR)、结构相似度 (Structural SIMilarity index, SSIM) 和学习感知图像相似度 (Learned Perceptual Image Patch Similarity, LPIPS) 作为客观评价指标,这三个指标

通常被用作图像增强任务中的图像质量评价标准.

在本节中,本文将提出的方法与当前的先进方法进行比较,包括无监督学习方法 EnlightenGAN^[11];零样本学习方法 RRDNet^[40], Self-supervised^[41], RUAS^[42], ZeroDCE++^[43] 和监督学习方法 DSLR^[14], KinD++^[15], R2RNet^[10], EFNet^[16], LLFlow^[17]和 HWMNet^[18].

3.3.1 客观评价指标结果对比

表 1 报告了在 LOL-test、LSRW-test 和 MIT-Adobe FiveK-test 上本文方法与现有先进方法的对比实验结果. 其中,用加粗/下划线/波浪线表示性能第一/第二/第三的数据. 在进行跨数据集验证时,所有的方法均不使用 LSRW-test 和 MIT-Adobe FiveK-test 数据集进行训练,

仅在 LSRW-test 和 MIT-Adobe FiveK-test 数据集上进行测试,从而验证模型的泛化能力. 尽管在 LOL-test 和 LSRW-test 测试集上本文模型的 PSNR 指标和 SSIM 指标低于 LLFlow 和 HWMNet,但在 LPIPS 指标上本文模型在两个数据集上分别是第一和第二,且该指标是基于感知相似度度量的图像质量评价指标,更符合人类的视觉感知. 在图像数量最大的 MIT-Adobe FiveK-test 测试集上,本文模型在 PSNR 和 LPIPS 指标上均取得了最优的性能,在 SSIM 指标上取得了第二优的性能. 最后,如最后一栏的加权平均结果所示,综合三个测试集而言,本文模型在三个指标上的结果均为最优,说明本文模型的表现最稳定.

表 1 在 LOL-test、LSRW-test 和 MIT-Adobe FiveK-test 数据集上的测试结果

方法	LOL-test(15)			LSRW-test(50)			MIT-Adobe FiveK-test(498)			加权平均结果		
	PSNR \uparrow	SSIM \uparrow	LPIPS \downarrow	PSNR \uparrow	SSIM \uparrow	LPIPS \downarrow	PSNR \uparrow	SSIM \uparrow	LPIPS \downarrow	PSNR \uparrow	SSIM \uparrow	LPIPS \downarrow
EnlightenGAN ^[11]	17.483	0.652	0.322	17.077	0.463	0.325	13.270	0.742	<u>0.169</u>	13.720	0.714	0.187
RRDNet ^[40]	11.369	0.509	0.323	13.419	0.379	0.354	10.135	0.620	0.303	10.460	0.596	0.308
Self-supervised ^[41]	19.497	0.701	0.290	16.186	0.461	0.368	7.376	0.524	0.365	8.481	0.596	0.308
RUAS ^[42]	16.405	0.503	0.270	14.332	0.472	0.480	16.123	0.791	0.237	15.971	0.755	0.260
ZeroDCE++ ^[43]	15.142	0.566	0.342	16.266	0.455	0.329	12.375	0.701	0.232	12.794	0.676	0.243
DSLR ^[14]	14.948	0.600	0.384	15.389	0.463	0.481	<u>16.613</u>	<u>0.770</u>	0.186	<u>16.460</u>	<u>0.738</u>	0.217
KinD++ ^[15]	17.752	0.758	0.198	16.090	0.395	0.370	13.870	0.733	0.182	14.171	0.704	0.199
R2RNet ^[10]	18.130	0.739	0.287	16.321	<u>0.508</u>	0.383	7.889	0.565	0.417	8.911	0.564	0.411
EFNet ^[16]	13.457	0.623	0.317	15.460	0.470	<u>0.321</u>	12.947	0.717	0.174	13.184	0.693	0.191
LLFlow ^[17]	24.999	0.870	<u>0.117</u>	17.534	<u>0.500</u>	0.308	<u>17.450</u>	0.766	<u>0.163</u>	<u>17.659</u>	<u>0.745</u>	<u>0.175</u>
HWMNet ^[18]	<u>24.242</u>	<u>0.852</u>	<u>0.114</u>	<u>17.394</u>	0.535	0.329	15.055	0.739	0.172	15.508	0.724	<u>0.184</u>
本文方法	<u>24.001</u>	<u>0.832</u>	0.107	<u>17.199</u>	0.488	<u>0.319</u>	18.056	<u>0.773</u>	0.161	18.138	0.748	0.174

3.3.2 主观视觉效果对比

图 4、图 5 展示了不同低照度图像增强方法的主观视觉效果对比. 本文选取了低光照图像增强领域中先进且有较好量化指标表现的方法. 与输入图像相比,所有方法的增强结果都显著提高了亮度与色彩. EnlightenGAN 和 Self-supervised 的增强结果具有合适的亮度和自然的对比度,但全图均有明显的噪声,如图 4 中右上角放大区域的玻璃花纹处和图 5 中窗台底部绿色箭头处, DSLR 和 ZeroDCE++ 在两个场景中亮度提升均不足,且有较明显的颜色偏差; LLFlow 在图 4 的增强结果中橱窗玻璃上的细节纹理明显丢失; RUAS 和 HWMNet 的增强结果中较好地抑制了噪声,但同时也导致纹理退化,如图 5 所示,在左上角放大处,墙壁上原有的条纹几乎不可见. 而本文的增强结果不仅亮度和色彩提升较为自然,没有明显的噪声,并且更加精细地重构了细节.

3.4 消融实验

本节对本文提出的双分支结构、核心模块和损失函数进行消融实验. 如表 2 中实验①和实验②所示,仅

使用其中一支分支时,方法性能显著下降,尤其是仅使用亮度与色彩增强分支. 实验③至实验⑥分别对两个分支中主要模块的有效性进行验证. 实验⑦中未加入本文提出的基于亮度分布加权的对比正则化损失. 下文将对双分支结构、半双重注意力残差模块和对比正则化损失进行进一步的分析.

(1) 双分支结构

为了更直观地说明本文提出的双分支低照度图像增强网络有效地将低照度图像增强任务解耦为亮度与色彩增强和细节重构两类子任务,并在各自分支上专注于解决所分配的子任务,在消融实验部分,本文在所提出的 TBLIEN 网络中,对两个分支的输出分别与参考图像计算 L2 损失,并加入到总损失函数中,得到两个分支单独的增强结果.

图 6 展示了本文方法中两个分支的特征图与其增强结果. 可以看出,亮度与色彩增强分支(ICEB)的特征图较为粗糙,如图 6(c)所示. 而细节重构分支(DRB)的特征图较为锐利,如图 6(d)所示. 图 6(e)展示了本文提出的双分支结构的增强结果,该结果在亮度与色

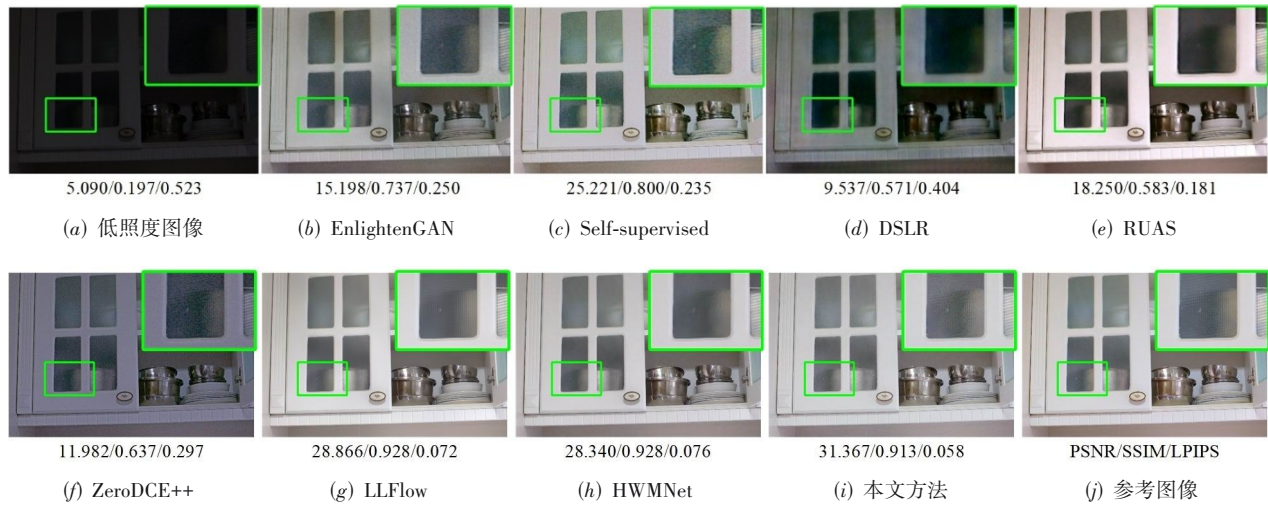


图4 不同方法增强结果的视觉对比

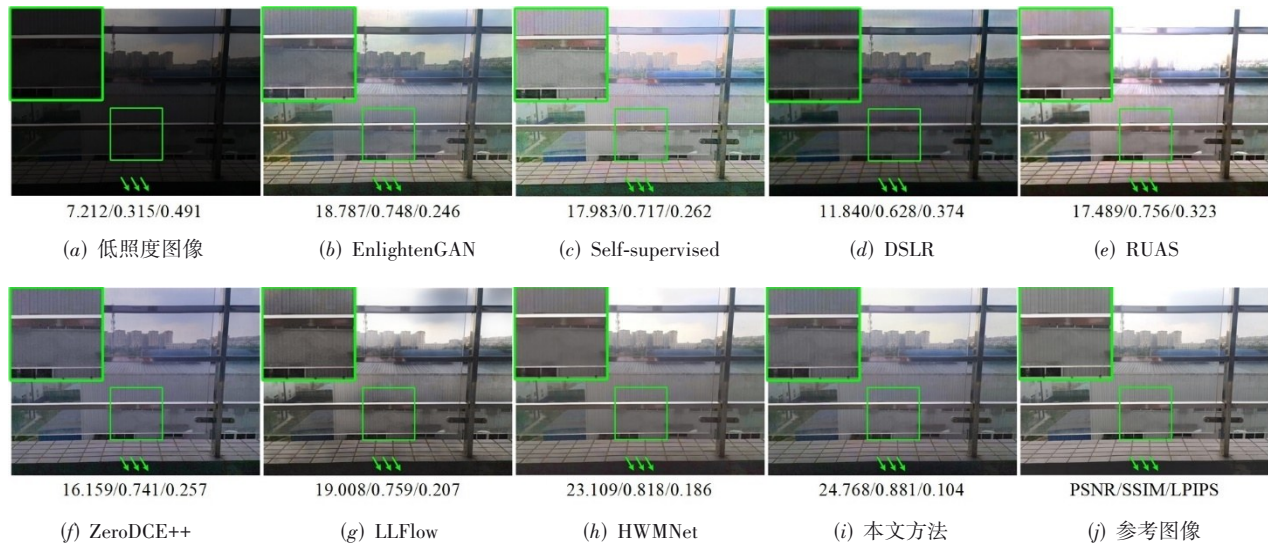


图5 不同方法增强结果的视觉对比




图6 双分支结构消融实验结果

彩增强和细节重构两方面均接近参考图像。此外,图6(f)与图6(g)的增强结果展示了两个分支所关注的不同感知特性,进一步说明了本文双分支结构能够实现任务的解耦。

(2) 半双重注意力残差模块

表3验证了半双重注意力残差模块的内部结构的合理性,分别使用不含残差结构的半双重注意力模块替代半双重注意力残差模块、批归一化层替代实例正则化层、双重注意力残差模块替代半双重注意力残差

模块,实验结果表明上述替代方案均导致模型的性能明显下降。在该模块中,本文提出的半双重注意力单元首先将特征从通道上进行切分,一半特征用于保留原始域特征,另一半特征进入使用空间和通道的双重注意力单元对特征进行强化,在降低计算量的同时强化特征的学习,避免了特征在传递过程中的丢失,从而提高特征的鲁棒性。

图7给出了本文提出的半双重注意力单元计算过程中的特征的可视化。图7(a)为保留的原始域特征,图7(b)

表 2 在 LOL-test 上的消融实验结果

方法对应的实验	细节重构分支		亮度与色彩增强分支		基于亮度分布加权的对比正则化损失	实验结果		
	半双重注意力残差模块	残差傅里叶重构模块	可学习尺寸调整模块	全局特征		PSNR ↑	SSIM ↑	LPIPS ↓
实验①			√	√		19.492	0.738	0.251
实验②	√	√				22.831	0.822	0.126
实验③		√	√	√		21.989	0.802	0.121
实验④	√		√	√		22.367	0.812	0.136
实验⑤	√	√	√			22.765	0.827	0.113
实验⑥	√	√		√		23.464	0.822	0.113
实验⑦	√	√	√	√		23.880	0.828	0.112
本文方法	√	√	√	√	√	24.001	0.832	0.107

表 3 在 LOL-test 上的消融实验结果

半双重注意力残差模块			实验结果		
残差结构	实例正则化层	特征切分处理	PSNR ↑	SSIM ↑	LPIPS ↓
	√	√	22.367	0.812	0.136
√		√	22.561	0.810	0.119
√	√		22.748	0.828	0.113
√	√	√	22.831	0.822	0.126

为经过空间和通道双重注意力强化后的特征图,图 7(c)为半双重注意力单元的输出,即两部分特征自适应融合后的特征,图 7(d)为作为参考的正常照度图像.如图 7(b)所示,双重注意力强化后的特征之间的对比度明显增强,

但同时部分重要细节特征会退化,而图 7(c)所示的融合后的特征能很好地避免这个问题,即增强特征的对比度的同时保留原始特征中的重要细节特征(如红色箭头所示).

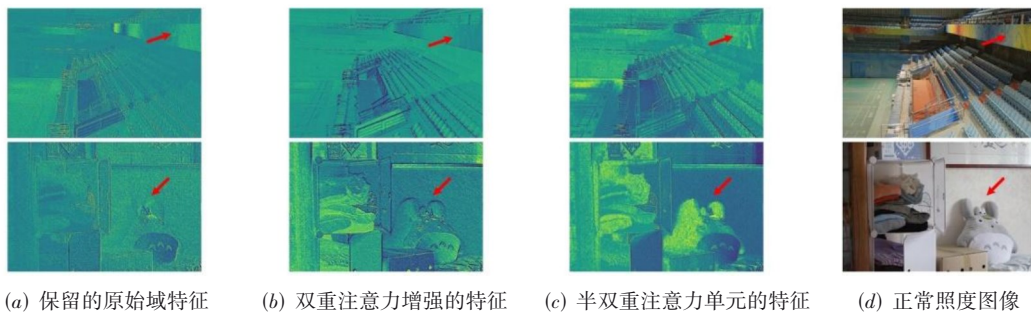


图 7 半双重注意力单元计算过程中的特征可视化

(3)对比正则化损失

由于增强后的图像与正常照度图像相同,仍然存在亮区和暗区,为了避免增强后图像出现过曝/欠曝,导致暗区或亮区的消失,本文使用对比正则化损失约束增强后图像的亮区/暗区与参考图像对应区域的距离,使模型能适应更复杂光照条件下的低照度图像增强,学习更合理的光照分布.如表 2 中实验⑦所示,不使用本文提出的基于亮度分布加权的对比正则化损失 L_{cr} 时,模型性能有所下降.如表 4 所示,在划分图像的亮区和暗区时,本文分别设置 p 值为 0.2、0.4、0.6、0.8 进行实验,当 p 值为 0.4 时,本文模型在三个评价指标上的性能均为最优.此外,当 p 值为 0.4、0.6 或 0.8 时,本文模型在三个评价指标上的性能均优于不使用基于亮度分

布加权的对比正则化损失时的性能,说明本文模型性能对 p 值的取值较为鲁棒.

进一步地,为了验证提出的基于亮度分布加权的对比正则化损失对于提高模型泛化能力的有效性,本文在 LSRW-test 和 MIT-Adobe FiveK-test 测试集上进行

表 4 使用不同分区系数的基于亮度分布加权的对比正则化损失在 LOL-test 上的消融实验结果

p	PSNR ↑	SSIM ↑	LPIPS ↓
0	23.892	0.831	0.112
0.2	23.926	0.827	0.113
0.6	23.945	0.831	0.108
0.8	23.923	0.832	0.110
本文方法(0.4)	24.001	0.832	0.107

了消融实验. 如表 5 所示, 实验②使用本文提出的基于亮度分布加权的对比正则化损失, 模型具有更好的泛化能力, 与不使用该损失的实验①相比, 模型的 PSNR 指标在两个测试集上分别提升 0.429 dB 和 0.185 dB.

表 5 基于亮度分布加权的对比正则化损失在 LSRW-test 和 MIT-Adobe FiveK-test 上的消融实验结果

实验	LSRW-test Dataset			MIT-Adobe FiveK-test		
	PSNR ↑	SSIM ↑	LPIPS ↓	PSNR ↑	SSIM ↑	LPIPS ↓
实验①	16.770	0.481	0.324	17.871	0.770	0.168
实验②	17.199	0.488	0.319	18.056	0.773	0.161

图 8 中展示了加入本文提出的基于亮度分布加权的对比正则化损失前后增强结果的对比图, 与图 8(b) 中未使用该损失函数时的结果相比, 图 8(c) 使用该损失的增强结果的光照分布与图 8(d) 参考图像的光照分布更加接近, 如第一行图像中红色箭头所示的右上角太阳光亮处, 第二行图像中红色箭头所示的图像上端的天空处.



(a) 低照度图像 (b) w/o L_{cr} (c) 本文方法 (d) 参考图像

图 8 加入基于亮度分布加权的对比正则化损失前后的视觉效果对比

3.5 水下图像增强

由于光在水下衰减性传播导致水下拍摄的图像存在对比度低、模糊、细节退化等问题. 与低照度图像增强类似, 水下图像增强也可视为细节重构和色彩与亮度增强这两类子任务, 因此本文选择在水下图像增强任务上验证本文方法的泛化能力.

本文遵循文献[44]的设置, 使用 UIEB^[45] 训练本文的模型, 并在该数据集提供的有参考数据集(表示为


Test-U90) 和无参考挑战数据集(表示为 Test-C60), 以及 SQUID 数据集^[46] 上评估模型效果. 对于有参考的数据集, 本文使用 PSNR 和 SSIM 评价增强效果, 而对于无参考的测试集, 本文使用针对水下图像增强任务提出的基于图像内容的感知质量评价方法 UIQM(Underwater Image Quality Measure, UIQM)^[47] 感知指标评价模型的增强性能, 它考虑了人类视觉感知的特征, 如对比度、饱和度、清晰度等, 以及图像的结构和纹理信息.

表 6 报告了在有参考数据集 Test-U90 和无参考数据集 Test-C60 和 Test-U16 上本文和当前先进方法的对比实验结果, 用加粗/下划线分别表示性能第一/第二的结果. 本文方法在 Test-U90 上的 PSNR 指标领先于性能第二的 URSC-T-UIE 方法 0.850 dB. 在 Test-U16 和 Test-C60 数据集上, 本文方法分别获得了第一名和第二名的 UIQM 指标.

表 6 不同方法在 UIEB-test90、Test-C60 及 Test-U16 上的指标结果

方法	Test-U90		Test-C60	Test-U16
	PSNR ↑	SSIM ↑	UIQM ↑	UIQM ↑
Fusion ^[48]	19.04	0.82	2.624	1.786
IBLA ^[49]	15.78	0.73	3.328	1.258
HL ^[46]	15.11	0.70	2.628	2.140
UWCNN-type1 ^[50]	13.76	0.61	2.339	1.503
WaterNet ^[44]	19.81	0.86	2.754	2.127
Ucolor ^[45]	20.78	0.87	2.527	1.850
U-Trans ^[51]	21.25	0.84	2.525	1.951
URSC-T-UIE ^[52]	<u>22.72</u>	0.91	2.678	<u>2.368</u>
本文方法	23.57	<u>0.87</u>	2.998	2.575

图 9 展示了不同方法对 2 张来自 Test-U90 数据集的图像的增强结果. 在颜色方面, IBLA、HL 均不能有效去除水下图像的绿色偏差或引入了额外的颜色失真. 在细节重构方面, WaterNet、Ucolor 和 U-Trans 较好地还原了图像的颜色, 但与参考图像相比其对比度和细节仍有所欠缺. 相比之下, 本文方法有效地去除了蓝绿色调, 提高了对比度并复原了细节, 视觉上与参考图像最接近.



(a) 水下图像 (b) HL (c) IBLA (d) WaterNet (e) Ucolor (f) U-Trans (g) 本文方法 (h) 参考图像

图 9 不同方法在 Test-U90 数据集上的水下图像增强结果对比

4 结论

本文提出基于任务解耦的低照度图像增强方法, 具体来说, 本文构造了一种双分支结构的低照度图像增强模型, 其中细节重构分支实现噪声去除和细节复原, 而亮度与色彩增强分支使用多级别特征引导合理自然的亮度与色彩增强. 在损失函数部分, 提出基于亮度分布加权的对比正则化损失函数. 本文模型与现有的先进方法在低照度图像数据集相比具有更好的性能, 并且可用于水下图像增强. 在今后的工作中, 本文计划研究基于任务解耦的轻量化低照度图像增强方法和低照度无人驾驶飞机 (Unmanned Aerial Vehicle, UAV) 视频增强方法, 满足实际应用中嵌入式设备对低照度图像和视频的增强需求.


参考文献

- [1] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.
- [2] 陈科圻, 朱志亮, 邓小明, 等. 多尺度目标检测的深度学习研究综述[J]. *软件学报*, 2021, 32(4): 1201-1227.
CHEN K Q, ZHU Z L, DENG X M, et al. Deep learning for multi-scale object detection: A survey[J]. *Journal of Software*, 2021, 32(4): 1201-1227. (in Chinese)
- [3] LIM J, HEO M, LEE C, et al. Contrast enhancement of noisy low-light images based on structure-texture-noise decomposition[J]. *Journal of Visual Communication and Image Representation*, 2017, 45: 107-121.
- [4] CHENG H D, SHI X J. A simple and effective histogram equalization approach to image enhancement[J]. *Digital Signal Processing*, 2004, 14(2): 158-170.
- [5] 江巨浪, 张佑生, 薛峰, 等. 保持图像亮度的局部直方图均衡算法[J]. *电子学报*, 2006, 34(5): 861-866.
JIANG J L, ZHANG Y S, XUE F, et al. Local histogram equalization with brightness preservation[J]. *Acta Electronica Sinica*, 2006, 34(5): 861-866. (in Chinese)
- [6] LAND E H, MCCANN J J. Lightness and retinex theory [J]. *Journal of the Optical Society of America*, 1971, 61(1): 1-11.
- [7] JOBSON D J, RAHMAN Z, WOODSELL G A. A multi-scale retinex for bridging the gap between color images and the human observation of scenes[J]. *IEEE Transactions on Image Processing*, 1997, 6(7): 965-976.
- [8] LEE C H, SHIH J L, LIEN C C, et al. Adaptive multiscale retinex for image contrast enhancement[C]//2013 International Conference on Signal-Image Technology & Internet-Based Systems. Piscataway: IEEE, 2013: 43-50.
- [9] WEI C, WANG W J, YANG W H, et al. Deep retinex decomposition for low-light enhancement[C]//Proceedings of the Conference on British Machine Vision Conference. Newcastle: BMVA, 2018: 1-12.
- [10] HAI J, XUAN Z, YANG R, et al. R2RNet: Low-light image enhancement via real-low to real-normal network[J]. *Journal of Visual Communication and Image Representation*, 2023, 90: 103712-103720.
- [11] JIANG Y F, GONG X Y, LIU D, et al. EnlightenGAN: Deep light enhancement without paired supervision[J]. *IEEE Transactions on Image Processing*, 2021, 30: 2340-2349.
- [12] PRIYADARSHINI R, BHARANI A, RAHIMANKHAN E, et al. Low-light image enhancement using deep convolutional network[M]//Innovative Data Communication Technologies and Application. Berlin: Springer, 2021: 695-705.
- [13] LV F F, LU F, WU J H, et al. MBLLEN: Low-light image/video enhancement using CNNs[C]//Proceedings of the Conference on British Machine Vision Conference. Newcastle: BMVA, 2018: 1-13.
- [14] LIM S, KIM W. DSLR: Deep stacked Laplacian restorer for low-light image enhancement[J]. *IEEE Transactions on Multimedia*, 2021, 23: 4272-4284.
- [15] ZHANG Y H, GUO X J, MA J Y, et al. Beyond brightening low-light images[J]. *International Journal of Computer Vision*, 2021, 129(4): 1013-1037.
- [16] LIU C X, WU F D, WANG X. EFNet: Restoration for low-light images via enhancement-fusion iterative network[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2022, 32(12): 8486-8499.
- [17] WANG Y F, WAN R J, YANG W H, et al. Low-light image enhancement with normalizing flow[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Menlo Park: AAAI, 2022, 36(3): 2604-2612.
- [18] FAN C M, LIU T J, LIU K H. Half wavelet attention on M-Net+ for low-light image enhancement[C]//2022 IEEE International Conference on Image Processing (ICIP). Piscataway: IEEE, 2022: 3878-3882.
- [19] LORE K G, AKINTAYO A, SARKAR S. LLNet: A deep autoencoder approach to natural low-light image enhancement[J]. *Pattern Recognition*, 2017, 61: 650-662.
- [20] REN W Q, LIU S F, MA L, et al. Low-light image enhancement via a deep hybrid network[J]. *IEEE Transactions on Image Processing*, 2019, 28(9): 4364-4375.


- [21] YAN Z C, ZHANG H, WANG B Y, et al. Automatic photo adjustment using deep neural networks[J]. *ACM Transactions on Graphics*, 2016, 35(2): 1-15.
- [22] KIM H, CHOI S M, KIM C S, et al. Representative color transform for image enhancement[C]//2021 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE, 2021: 4459-4468.
- [23] 黄淑英, 胡威, 杨勇, 等. 基于渐进式双网络模型的低曝光图像增强方法[J]. *计算机学报*, 2021, 44(2): 384-394.
- HUANG S Y, HU W, YANG Y, et al. A low-exposure image enhancement based on progressive dual network model[J]. *Chinese Journal of Computers*, 2021, 44(2): 384-394. (in Chinese)
- [24] 江泽涛, 伍旭, 张少钦. 一种基于MR-VAE的低照度图像增强方法[J]. *计算机学报*, 2020, 43(7): 1328-1339.
- JIANG Z T, WU X, ZHANG S Q. Low-illumination image enhancement based on MR-VAE[J]. *Chinese Journal of Computers*, 2020, 43(7): 1328-1339. (in Chinese)
- [25] YANG W H, WANG S Q, FANG Y M, et al. From fidelity to perceptual quality: A semi-supervised approach for low-light image enhancement[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2020: 3063-3072.
- [26] LIU X D, GAO Z, CHEN B M. MLFcGAN: Multilevel feature fusion-based conditional GAN for underwater image color correction[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(9): 1488-1492.
- [27] ZAMIR S W, ARORA A, KHAN S, et al. Learning enriched features for real image restoration and enhancement[M]//Computer Vision—ECCV 2020. Cham: Springer International Publishing, 2020: 492-511.
- [28] CHEN L Y, LU X, ZHANG J, et al. HINet: Half instance normalization network for image restoration[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway: IEEE, 2021: 182-192.
- [29] 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.
- [30] SU Z H, ZHANG H S, LIU Z W, et al. Image deblurring algorithm by using conditional generation adversarial network[C]//2021 40th Chinese Control Conference (CCC). Piscataway: IEEE, 2021: 8128-8133.
- [31] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on Machine Learning. Lille: PMLR, 2015: 448-456.
- [32] MAO X T, LIU Y M, LIU F Z, et al. Intriguing findings of frequency selection for image deblurring[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Menlo Park: AAAI, 2023, 37(2): 1905-1913.
- [33] TALEBI H, MILANFAR P. Learning to resize images for computer vision tasks[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2021: 497-506.
- [34] JOHNSON J, ALAHI A, LI F F. Perceptual losses for real-time style transfer and super-resolution[M]//Computer Vision—ECCV 2016. Cham: Springer International Publishing, 2016: 694-711.
- [35] PASZKE A, GROSS S, MASSA F, et al. PyTorch: An imperative style, high-performance deep learning library [EB/OL]. (2019-12-03) [2023-03-01]. <https://arxiv.org/abs/1912.01703>.
- [36] KINGMA D P, BA J. Adam: A method for stochastic optimization[EB/OL]. (2014-12-22) [2023-03-01]. <https://arxiv.org/abs/1412.6980>.
- [37] LOSHCHILOV I, HUTTER F. SGDR: Stochastic gradient descent with warm restarts[C]//International Conference on Learning Representations. Toulon: Openreview.net, 2017: 163-178.
- [38] BYCHKOVSKY V, PARIS S, CHAN E, et al. Learning photographic global tonal adjustment with a database of input/output image pairs[C]//2011 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2011: 97-104.
- [39] LI C Y, GUO C, HAN L H, et al. Low-light image and video enhancement using deep learning: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(12): 9396-9416.
- [40] ZHU A Q, ZHANG L, SHEN Y, et al. Zero-shot restoration of underexposed images via robust retinex decomposition[C]//2020 IEEE Conference on International Conference on Multimedia and Expo (ICME). Piscataway: IEEE, 2020: 1-6.
- [41] LIANG J X, XU Y, QUAN Y H, et al. Self-supervised low-light image enhancement using discrepant untrained network priors[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2022, 32(11): 7332-7345.
- [42] LIU R S, MA L, ZHANG J A, et al. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscat-

away: IEEE, 2021: 10561-10570.

- [43] LI C Y, GUO C L, LOY C C. Learning to enhance low-light image via zero-reference deep curve estimation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(8): 4225-4238.
- [44] 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, 2019, 29: 4376-4389.
- [45] LI C Y, ANWAR S, HOU J H, et al. Underwater image enhancement via medium transmission-guided multi-color space embedding[J]. IEEE Transactions on Image Processing, 2021, 30: 4985-5000.
- [46] BERMAN D, LEVY D, AVIDAN S, et al. Underwater single image color restoration using haze-lines and a new quantitative dataset[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(8): 2822-2837.
- [47] 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.
- [48] ANCUTI C, ANCUTI C O, HABER T, et al. Enhancing underwater images and videos by fusion[C]//2012 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2012: 81-88.
- [49] WANG S H, ZHENG J, HU H M, et al. Naturalness preserved enhancement algorithm for non-uniform illumination images[J]. IEEE Transactions on Image Processing, 2013, 22(9): 3538-3548.
- [50] LI C Y, ANWAR S, PORIKLI F. Underwater scene prior inspired deep underwater image and video enhancement [J]. Pattern Recognition, 2020, 98: 107038.
- [51] PENG L, ZHU C, BIAN L. U-shape transformer for underwater image enhancement[J]. IEEE Transactions on Image Processing, 2023, 32: 3066-3079.
- [52] REN T D, XU H Y, JIANG G, et al. Reinforced swin-convs transformer for underwater image enhancement[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-16.



陈铭铭 女,1997年生.福州大学计算机与大数据学院硕士研究生.主要研究方向为计算机视觉、图像增强与复原.
E-mail: 675997270@qq.com



李悦洲 男,1995年生.福州大学计算机与大数据学院博士研究生.主要研究方向为图像增强与复原、视觉目标跟踪.
E-mail: liyuezhou.cm@gmail.com



赵铁松 男,1984年出生,博士.福州大学物理与信息工程学院教授、博士生导师.主要研究方向为多媒体通信系统、人工智能和视频编码等.中国电子学会会员编号:E190014840S.
E-mail: t.zhao@fzu.edu.cn

作者简介



牛玉贞 女,1982年出生,博士.福州大学计算机与大数据学院教授、博士生导师.主要研究方向为计算机视觉.
E-mail: yuzhenniu@gmail.com