

引用:刘凌风,梁玉雪,扈成双,等. 联合物理模型和先验的无监督低照度图像增强[J]. 聊城大学学报(自然科学版), 2026, 39(3):357-365.

Citation:LIU Lingfeng, LIANG Yuxu, HU Chengshuang, ZHANG Zhen, LIU Jianlang, SHAO Kaixin, CHEN Yong. Un-supervised low-light image enhancement with joint physical modeling and a priori[J]. Journal of Liaocheng University (National Science Edition), 2026, 39(3):357-365.

文章编号 1672-6634(2026)03-0357-09

DOI 10.19728/j.issn1672-6634.2025040002

联合物理模型和先验的无监督低照度图像增强

刘凌风¹, 梁玉雪², 扈成双³, 张祯⁴, 刘鉴朗⁵, 邵凯鑫⁵, 陈勇⁵

(1. 重庆机场集团有限公司, 重庆 401100; 2. 重庆中科云从科技有限公司, 重庆 401120; 3. 北京中航弱电系统工程
有限公司, 北京 100028; 4. 重庆工业职业技术学院 经济与管理学院, 重庆 401120;
5. 重庆邮电大学 人工智能学院, 重庆 400065)

摘要 监督学习的训练和增强效果依赖于配对的数据集,但多数情况下使用的是合成数据集,导致在迁移到真实图像时恢复效果不佳,泛化能力有限。针对上述问题,本文提出了一种结合物理模型和多重先验知识的无监督低照度图像增强方法。该方法首先利用合成数据集对网络模型进行有监督的预训练;随后,基于大气散射模型理论从输入图像中估计其中参数;最后,计算多重物理先验和神经网络估计的参数与增强图像之间的损失,端到端的训练网络模型,并更新网络参数。实验结果表明:与现有的主流算法相比,该算法可有效提高图像照度和对比,保持图像自然性,并具有一定的泛化能力。

关键词 图像处理;低照度图像增强;无监督学习;物理模型;先验知识

中图分类号 TP751

文献标志码 A

开放科学(资源服务)标识码(OSID)



Unsupervised low-light image enhancement with joint physical modeling and a priori

LIU Lingfeng¹, LIANG Yuxue², HU Chengshuang³, ZHANG Zhen⁴,
LIU Jianlang⁵, SHAO Kaixin⁵, CHEN Yong⁵

(1. Chongqing Airport Group Co., Ltd, Chongqing 401100, China; 2. Cloudwalk Technology Co., Ltd, Chongqing 401120, China; 3. Zhonghang Electricity System Engineering Co., Ltd, Beijing 100028, China; 4. School of Economics and Management, Chongqing Industry Polytechnic College, Chongqing 401120, China; 5. School of Artificial Intelligence, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract The training and enhancement effect of supervised learning relies on paired datasets, but most of the data sets are synthetic datasets, which are poorly recovered and weakly generalized when migrated to real images. Based on the above problems, this paper proposes an unsupervised low-light image enhancement model with a joint physical model and multiple priors. First, supervised pre-training is performed on the synthetic dataset to meet the demand of the model to the low illumination; second, the model is further unsupervised, trained, and optimized on the real dataset and jointly with multiple physical a priori

收稿日期:2025-04-02

基金项目:国家自然科学基金项目(51977021);重庆邮电大学大学生科研训练计划(A2023-214)资助

通信作者:陈勇,男,汉族,博士,教授,研究方向:图像处理,新能源材料,E-mail:chenyong@cqupt.edu.cn.

knowledge to better adapt it to the actual low illumination situation. The experiments show that the details and illumination of the images are restored while the dependence on paired datasets is somewhat eliminated.

Keywords image processing; low-light image enhancement; unsupervised learning; physical modeling; physical priori

0 引言

低照度图像存在细节缺失、照度不足,所捕获的图像通常具有光照不均匀、纹理细节损失及噪声强烈等图像质量退化现象,由于信息缺失导致图像的信噪比低,无法从图像中提取到关键的信息,给后续的计算机视觉任务带来困难,例如,针对机场的行人检测的准确性、人脸的识别率以及对图像通信质量品质带来了极大的挑战。因此,改善低照度图像的质量是非常有必要的^[1-3]。

低照度图像增强方法主要分为基于模型的方法和基于学习的方法。Guo 等人^[4]基于 Retinex 模型对初始光照图进行估计并利用结构先验对其细化,最后合成增强图像,提出了 LIME(low-light image enhancement)方法;Zhang 等人^[5]受 Retinex 理论启发,将低照度图像增强分为照度增强和反射率增强并分别进行处理,达到了令人满意的效果,提出了 KinD(kindling the darkness)方法;Kar 等人^[6]通过优化一个无参考损失函数来估计模型参数从而直接从退化的图像中恢复清晰的图像;Yang 等人^[7]将半监督学习策略引入低照度图像增强中,提出了 DRBN(deep recursive band network)方法;Ma 等人^[8]设计了自校准照明 SCI(self-calibrated illumination)的框架,并引入了一个自校正模块来优化网络,从而快速而稳定地提升低照度图像的质量;Jiang 等人^[9]将 GAN(generative adversarial network)网络引入到低照度图像增强领域,提出了 EnlightenGAN 方法;Guo 等人^[10]提出了 Zero-DCE(zero-reference deep curve estimation)方法,实现了零次学习的策略;Zheng 等人^[11]通过改进的加权分布自适应 Gamma 校正增强亮度,并通过加权融合技术整合两种增强方法以提升低照度图像质量。上述方法虽然取得了一些效果,然而,在现实生活中获取大量高质量的正常光照参考图像是比较困难,限制了训练集的选择和多样性,进而影响训练结果的质量,这可导致方法(模型)表现不佳,泛化能力受限。

针对上述存在的问题,本文提出了一种结合物理模型和深度学习的低照度图像增强方法(joint physical model and a priori network, JPPNet)。JPPNet 主要包含了两个训练阶段:先在合成数据集上预训练,再利用物理先验指导其在真实数据集上进行第二阶段训练。所提方法不仅引入了先验知识以指导网络学习过程,同时还降低了对物理参数估计的直接依赖,增强了模型的适应性和泛化能力。

1 基本原理

1.1 大气散射模型

大气散射模型可由式(1)表示,其中 x 表示像素点的位置, λ 代表光的波长, L_{∞} 代表在无穷远的大气光值, $I(x, \lambda)$ 表示退化的图像, $R(x, \lambda)$ 表示原始未损坏的图像, $\exp(-\beta(\lambda)d(x))$ 是传输函数,其物理含义是经过粒子衰减能够达到探测系统的那部分光的比例,即光散射衰减率

$$I(x, \lambda) = \exp(-\beta(\lambda)d(x))R(x, \lambda) + L_{\infty}(1 - \exp(-\beta(\lambda)d(x))), \quad (1)$$

简化可得

$$I(x) = t(x)J(x) + A(1 - t(x)), \quad (2)$$

式中 $I(x)$ 表示低照度图像, A 表示大气光值, $J(x)$ 表示原始未损坏的图像,即参考图像, $t(x)$ 表示传输函数。上述物理模型同样也适用低照度图像增强领域^[12]。

图 1 给出了模型总结体结构,主要分为增强网络 R-Net、传输值估计网络 t-Net、以及大气光值估计网络 A-Net 等三个子网络。R-Net 从输入的低照度图像中估计干净的图像 $\tilde{J}$, 同时估计输入图像的传输图 $\tilde{t}$, A-Net 估计输入图像的大气光值 $\tilde{A}$ 。通过重建损失以及物理先验联合优化网络模型改善低照度图像以期获得正常照度下的图像。

为解决数据依赖和过拟合问题,同时提升模型的泛化能力,采用了预训练和无监督训练策略。预训练策略通过在多样化数据集上训练模型获取基础特征表示,有效缓解了模型对特定训练数据集的过度依赖,为后续的无监督训练奠定了坚实的基础。然后对模型进行有监督的训练,同时采用 L_0 损失函数以及 L_{Rec} 重建损失来优化网络,前者通过减少与参考图像的差异来优化网络,后者将增强后的图像重建为低照度图像,再和输入图像做损失来更新网络参数,使模型适应低照度图像增强任务,在这种组合策略不仅降低了过拟合的风险,还增强了模型对未见样本和复杂光照条件的适应性和鲁棒性。具体而言,将三个网络的输出 $\tilde{J}$ 、 $\tilde{I}$ 以及 $\tilde{A}$ 通过物理模型重建得到低照度图像 $\tilde{I}$, 即: $\tilde{I} = \tilde{J} \odot \tilde{I} + \tilde{A} \odot (1 - \tilde{I})$ 其中 $\odot$ 是逐元素乘法。在这个阶段,使用有标记的合成数据集进行训练。重建损失^[4]

$$L_{\text{Rec}} = ||I - \tilde{I}||_1, \quad (3)$$

式中 I 表示输入的低照度图像。

联合以上损失函数对网络在合成数据集进行预训练,使网络满足低照度图像增强任务。同时,第二阶段训练网络时利用真实图像进行无监督训练。在监督训练中只是将图像进行亮度调整并没有用到成对数据集,并不影响模型整体性能,并可以有效改善现有方法依赖成对数据集的现状。

在传统架构基础上,本文融合了物理模型和图像先验知识,以实现更为自然且有效的增强效果。不同于以往仅依赖深度学习网络进行图像增强的方法,所提模型通过在输出端引入一路基于物理理论的先验信息,如大气散射模型,和图像先验,例如亮通道先验,从而使网络能够在理解图像光照和内容的基础上进行更加精准的增强。此外,在损失函数中引入了这些先验知识,通过设定特定的损失项来约束网络训练,确保增强过程符合物理规律和图像先验,从而提升增强质量。这种方法信息的协同效应如下:物理模型提供了对低照度环境下图像形成机理的深入理解,而图像先验则辅助网络捕捉和恢复图像中的细节信息,二者结合不仅优化了增强效果,还增强了模型对复杂光照条件下的适应性和鲁棒性。

1.2 网络的设计

增强网络 R-Net 主要由编码器和解码器组成,其中包括卷积层、激活函数、上采样和下采样等。具体而言,输入图像大小为 224×224 , 如图 2 所示该网络包括三个编码器卷积块、一个中间层和对称的解码器部分。在编码器中,第一个和第三个卷积块分别使用 32 个和 128 个 3×3 卷积核来提取图像特征,并通过 2×2 最大池化层进行下采样;第二个卷积块则包含 64 个卷积核并引入了注意力机制,以便有效地捕捉关键信息。为了进一步整合上述特征,中间层使用 256 个卷积核来处理高级特征。在解码器部分,模型通过转置卷积层上采样,并使用注意力机制加强的卷积块来细化和恢复图像细节,最终通过 3 个 1×1 卷积核的层将特征映射回 RGB 空间,生成增强后的图像。与传统 U-Net 不同的是,所提方法引入了注意力机制来增强网络对图像中的重要特征的感知能力,有效地引导网络聚焦于图像的低亮度区域,这对于恢复低照度图像中的细节和提高光照一致性至关重要。通过这种结构改进,能够更准确地识别并处理光照不均和细节丢失问题,尤其是在复杂光照条件下,确保了增强后图像的自然度和视觉质量。

为降低模型复杂度,本文设计了轻量化的 t-Net 和 A-Net 网络,它们通过共享初级层来减少参数量,主要设计思路如图 3 所示。对 t-Net 网络采用轻量的网络设计思路,具体设计如下:首层配置 32 个卷积核的




图1 模型总结体结构

Fig. 1 Model summarizing the physical structure

卷积层,核尺寸 3×3 ,步长设为 1,采用“same”填充以维持输出尺寸不变,后接批量归一化及 ReLU 激活函数。第二层结构与首层相同,但卷积核数量增至 64 个。第三层卷积核数量为 128,核尺寸 3×3 ,步长为 2,目的是缩减特征图的空间尺寸,同样接批量归一化和 ReLU 激活函数。然后,使用逆卷积层,滤波器数量为 64,滤波器大小为 3×3 ,步长为 2,以恢复到原始尺寸,后接批量归一化和 ReLU 激活函数。最后使用一个卷积层,滤波器数量为 1,大小为 3×3 ,步长为 1,并使用 sigmoid 激活函数输出每个像素的透射率估计值,确保输出图像与输入图像在尺寸上一致。对 A-Net 网络仍然采用浅层神经网络结构以减少计算量。其网络结构与 t-Net 网络结构相似,所不同地方在于网络最后通过一个含 256 神经元的全连接层和 ReLU 激活函数,终层通过 sigmoid 激活函数的全连接层精确预测大气光估计值。




图 2 R-Net 网络图

Fig. 2 R-Net network diagrams

1.3 物理先验的设计

通过结合亮/暗通道先验,对低照度图像中的关键物理参数进行估计(如图 4 所示)。由于亮通道先验反映了非天空区域高亮度的大气光强度,而暗通道先验利用自然图像中某些区域最低强度值的特性。一方面,这些先验知识被整合进损失函数中,优化了关键参数的估计,进而在低照度图像增强中实现更高的颜色一致性和细节清晰度。另一方面,通过将这些先验知识融入损失函数中,使得估计出的大气光值和传输图更接近于真实场景的物理属性。对此,结合两种先验,并引入文献[13]中估计传输值 t ,重新设计了损失函数




图 3 A-Net 和 t-Net 网络结构图

Fig. 3 A-Net and t-Net network structure diagrams

$$L_{\text{BAD}} = ||t - \tilde{t}||_1, \quad (4)$$

式中 t 和 $\tilde{t}$ 分别表示由亮/暗通道先验联合估计的传输值和由子网络所估计的传输值。通过 L_{BAD} 计算物理先验和 t-Net 估计的传输值之间的损失来更新 t-Net 网络参数。

为使损失函数能更好地收敛,引入了直方图均衡 CLAHE (contrast limited adaptive histogram equalization) 算法,通过子网络所估计的大气光值和传输值重建为低照度图像。其损失函数为

$$L_c = ||I - I_c||_1, \quad (5)$$

式中 I 是输入图像, I_c 是通过 CLAHE 方法增强的图像然后重建为低照度的图像。不采用增强后的图像与增强网络输出的图像计算损失,是防止把先验产生的误差代入到网络模型中。重建低照度图像时使用了 t-Net 和 A-Net 网络估计的传输值和大气光值,这样可以将三个子网络联合到一起进行端到端的训练。

最后,将物理先验损失组合在一起获得最后的损失函数

$$L_{\text{con}} = \lambda_a L_{\text{BAD}} + \lambda_c L_c. \quad (6)$$

在实验的过程中,参考文献[14]对式(6)中两个损失的重要程度进行分析,将微调超参数设置为 $\lambda_a = 0.6, \lambda_b = 0.9$ 。目前大多数方法只采用单个先验为指导,但单个先验并不总是可靠的。对此本文联合了 R-Net、A-Net 和 t-Net 子网络以及多个物理先验一起进行训练,共同优化网络:即将子网络所估计的传输值与

多个物理先验所得的传输值进行损失以更好的训练网络得到更准确的传输值。




图4 物理先验指导结构图

Fig. 4 Physical a priori guidance structure

1.4 模型的补充与优化

在预训练之后的无监督训练中,模型容易出现遗忘现象导致预训练的结果不理想。为帮助模型从预训练模型更好地转换到第二阶段训练中,将预训练好的模型称为 M , 在下一阶段训练时将未标记的数据纳入到 M 的训练中,并将在更新模型 M 之前的原始模型记为 M_0 , 其在下一阶段训练时被冻结,最后通过 M_0 来连接两个阶段的训练,然后最小化 M_0 和 M 的特征映射^[14]。引入的损失函数

$$L_{\text{lwf}} = ||F_s - F_{\text{os}}||_1 + ||F_r - F_{\text{or}}||_1, \quad (7)$$

式中 F_s 和 F_{os} 分别表示 M 和 M_0 在合成数据集上的映射, F_r 和 F_{or} 分别表示在真实数据集上的特征映射。

同时,针对物理先验对天空像素估计不准确容易造成颜色偏移和伪影的问题,引入 L_{sky} 损失^[14]来弥补以上问题,该损失如

$$L_{\text{sky}} = ||M_{\text{sky}} \odot (J - J_0)||_1, \quad (8)$$

式中 M_{sky} 代表天空区域的二进制掩码, J 表示 M 增强的图像, J_0 表示 M_0 增强的图像。

总的损失函数 L 为

$$L = L_{\text{lwf}} + L_{\text{con}} + L_{\text{rec}} + L_{\text{sky}}. \quad (9)$$

2 实验分析

2.1 实验设计

在模型的预训练阶段,使用了多个数据集,从 SICE(single image contrast enhancement)^[15]数据集中随机挑选户外/室内图像中照度良好的图像并进行照度调整来进行预训练,同时还特别将亮/暗通道先验集成到损失函数中,这一步骤显著提升了模型对照度恢复和细节增强的学习能力。进入第二阶段训练时,选择了成对的 LOL^[16]数据集,其包括 500 个低光/正常光图像对,随机选择其中 200 张图像进行训练,其他图像作为测试集;从 EnGAN^[9]、ExDark^[17]中随机选择 400 张图像进行训练,然后再从 LOL 数据集中随机选择图像用来测试。通过这种多数据集训练策略,模型不仅学习了光照增强,同时也提升了对不同场景和光照条件下细节的恢复能力。

输入图像大小为 $224 \times 224 \times 3$, 归一化像素为 $[-1, 1]$ 。在训练过程中,采用 Adam^[18]优化器,其中优化器参数设置为: $\beta_1 = 0.9, \beta_2 = 0.999$, 以确保训练的稳定性 and 效率。在预训练阶段,初始学习率设置为 0.000 1, 训练周期为 140 代。在第二阶段训练中,初始学习率设置为 0.000 1, 训练周期为 70 代, 批量大小设为 32, 训练期间每运行 10 代, 监控模型的损失和验证集上的性能指标(PSNR 和 SSIM), 以调整学习率和判断训练的停止。当连续多个训练周期验证集上的性能没有显著提升时采用早停策略以避免过拟合。该模型在 Pytorch 深度学习框架中实现, 实验配置为: NVIDIA GeForce GTX3090, 4 块 NVIDIA GTX 1080 Ti GPU, 64 GB 内存。

在实验中采用了峰值信噪比 PSNR(peak signal to noise ratio)、结构相似性指数 SSIM(structural simi-

larit)^[19]、自然图像质量评估器 NIQE (natural image quality evaluator)^[20]、基于感知的无参考图像质量评估器 PIQE (perception based image quality evaluator)^[21]以及基于对比度增强的非参考图像质量评估指标 CEIQ (perception features for contrast-distorted images)^[22]作为评价指标。PSNR 指标用于全局评估增强图像与参考图像的相似度,数值越高表示图像增强效果越佳。SSIM 指标则从亮度、对比度和结构三个维度来衡量增强图像与参考图像的相似性,数值越高则意味着增强结果与参考图像越接近。NIQE 专注于评估增强图像的自然度,其较低的数值表示图像质量更佳。PIQE 评估图像的失真情况,数值降低表示图像质量提升。最后,CEIQ 则根据人类的感知特征来评估图像质量,数值越高,表明图像更符合人类视觉的审美标准。

对比算法的选择:选用 Dong^[23]、LIME^[4]、DRBN^[5]、EnGAN^[9]、Zero-DCE^[10]、Kind^[6]具有代表性的低光照图像增强算法,并在本地服务器上实现其测试代码,为保证公平性,所采用的输入图像,评价指标计算代码以及测试设备都一致,因此所计算的评价指标与原文献可能不一样。在客观评价中,本文在 LOL 数据集上测量了 PSNR、SSIM 和 NIQE 三个指标,在没有参考图像的真实图像上,测量了 NIQE、CEIQ 以及 PIQE 指标。

2.2 主观对比实验

图 5 给出了在 LOL 数据集测试集中处理的效果:图 5(b~e)虽然在亮度提升上取得了一定成效,但在高亮区域的细节保留上存在挑战;图 5(c)在对比度提升上表现出色,但在极低光照环境下其亮度恢复仍有改善的空间;图 5(f)在亮度调整存在一些不足;图 5(g)在细节恢复方面进行了有益尝试,但在色彩还原上还有待提高;所提方法在图 5(h)亮度增强、细节恢复、色彩还原和噪声抑制方面表现优异,与基准图像[图 5(i)]有较好的接近度。




图 5 不同方法在 LOL 数据集的主观对比视觉图

Fig. 5 Subjective Comparison Visuals of Different Methods on the LOL Dataset

为评估所提模型的泛化能力,在真实图像上进行主观对比实验(如图 6 所示):图 6(b)在亮度上有所提升,但部分区域平滑度不够;图 6(c)在色调处理上较好,但在亮度和对比度上改善不足,失去了一些自然感;图 6(d)结果在亮度上有所改善,但在局部区域上过于平滑导致图像出现模糊;图 6(e)和图 6(f)在恢复真实场景的亮度上做出了较好的尝试,并且在整体亮度提升上表现出一致性,然而在某些区域色彩恢复不理想,出现了局部色彩失真的现象,比如树木和沙滩呈现偏绿的色调;图 6(g)则在色彩真实性和亮度平衡方面取得了较好的效果,但与原始场景相比,对比度略显不足。相较而言所提方法在图 6(h)保持图像的自然色调和细节的同时,实现了较为自然的亮度恢复和细节增强,对比度也有明显的提升。

2.3 客观评价实验

2.3.1 特定数据集上的评价。在 LOL 数据集上,与其他先进方法进行定量比较,评估的结果如表 1 展现,

所提方法在 PSNR、SSIM 和 NIQE 的得分分别为 19.893、0.848 和 5.209, 较高于其他对比算法表明所提方法在亮度恢复和细节保留方面的优异性, 同时图像的结构信息和亮度特征保持了较高的一致性。这是因为, 采用的物理模型对光照传播进行了准确模拟, 帮助网络较好地恢复图像亮度和颜色; 同时结合先验知识有效指导了图像细节和边缘的恢复, 特别是在暗区域部分; 无监督学习方法的利用使得网络在处理真实世界的复杂光照条件时其鲁棒性更强。



图6 不同方法在真实图像上的主观对比视觉图

Fig. 6 Subjective Comparison Visuals of Different Methods on a real image

表1 不同算法在 LOL 数据集上测试的客观评价指标

Tab. 1 Objective evaluation metrics for different algorithms tested on the lol dataset

Metrics	Dong ^[23]	LIME ^[4]	DRBN ^[5]	EnGAN ^[9]	Zero-DCE ^[10]	Kind ^[6]	Ours
PSNR/dB ↑	15.721	15.813	16.311	17.677	16.831	18.247	19.893
SSIM ↑	0.635	0.642	0.648	0.783	0.687	0.834	0.848
NIQE ↓	8.861	8.413	8.647	7.342	7.573	7.768	5.209

2.3.2 其他数据集上的评价。为了进一步证明所提方法有效性和泛化能力, 从多个数据集中随机抽取图像进行测试, 分别在 MEF^[24]数据集、DICM^[25]数据集、NPE^[26]以及 LIME^[4]数据集中随机选择了 10 张图像对各个方法进行 NIQE、CEIQ 以及 PIQE 的平均得分计算。表 2 显示了各个算法的平均得分。

从表 2 中可以看出, 所提方法在各个数据集上的 NIQE、CEIQ 和 PIQE 评价指标上均有不同程度的改善。这是因为联合物理模型和先验的无监督方法能更好地恢复低照度图像中的细节和对比度, 同时抑制噪声。此外, 在 LIME 数据集上, 尽管在 CEIQ 指标上提升不是最高的, 但在 NIQE 和 PIQE 两个指标上展现出了不错的性能, 表明该方法在提高图像质量的同时也保持了图像的自然感。

2.3.3 算法复杂度。表 3 给出了在相同输入图像大小下的不同算法复杂度对比结果(注意, Dong 算法和 LIME 是偏传统方法, 因此无模型大小和浮点数运算次数)。从实验结果表明, Dong 算法需要变换图像的不同空间, 处理时间略长。其他基于学习的算法在很大程度上取决于模型大小、计算浮点次数等。从表中可以看出, 所提算法在处理时间上优于其他算法; 与深度学习方法相比, 所提算法在模型大小和浮点运算次数上也具有一定优势。由于所提算法采用了轻量级的网络架构, 以及优化的计算路径, 这减少了冗余计算并加速了前向传播。另外, 结合物理模型和先验知识的方法在设计时就考虑了计算复杂度, 从而实现了更快的处理速度。因此在这些因素共同作用, 减少了计算负担, 从而提高了整体性能。

表 2 不同算法在其他数据集上的 NIQE/CEIQ/PIQE 平均得分测试结果

Tab. 2 Test results of average NIQE/CEIQ/PIQE scores of different algorithms on other datasets

Dataset	Dong ^[23]	LIME ^[4]	DRBN ^[5]	EnGAN ^[9]	Zero-DCE ^[10]	Kind ^[6]	Ours
MEF	7.321/	7.311/	7.613/	7.034/	7.134/	7.116/	6.961/
	2.867/	3.067/	3.204/	3.316/	3.301/	3.168/	3.588/
	35.187	34.691	35.815	35.807	31.138	35.124	33.201
DICM	7.218/	7.357/	7.764/	6.937/	6.731/	7.801/	6.591/
	3.097/	3.391/	3.146/	3.378/	3.461/	3.114/	3.667/
	34.687	35.687	35.811	34.302	34.047	35.133	32.813
NPE	8.449/	7.517/	7.691/	7.533/	7.733/	7.488/	7.226/
	2.681/	3.267/	3.295/	3.401/	3.268/	3.311/	3.497/
	36.681	35.730	35.817	33.813	33.455	33.855	34.217
LIME	7.934/	8.817/	7.958/	7.409/	7.536/	8.227/	7.311/
	3.117/	3.016	2.937/	3.077/	3.188/	3.138/	3.436/
	36.768	33.682	34.893	34.132	32.224	33.883	31.361

表 3 不同算法的复杂度对比

Tab. 3 Complexity comparison of different algorithms

Method	Dong ^[23]	LIME ^[4]	DRBN ^[5]	EnGAN ^[9]	Zero-DCE ^[10]	Kind ^[6]	Ours
RT/s	0.781 1	0.362 1	0.053 3	0.016 2	0.005 1	0.196 1	0.004 8
Size/MB	-	-	0.577	8.636	0.079	8.514	0.074
FLOPs/G	-	-	37.79	61.01	5.211	29.135	5.134

2.3.4 消融实验。为证明先验损失函数的有效性,设计了消融实验。主要分为没有 L_{BAD} 损失函数和没有 L_C 损失函数的实验,结果如表 4 显示,w/o 表示分别缺少 L_{BAD} 和 L_C 损失函数后,PSNR 和 SSIM 指标明显减少,表明图像质量下降。由此可以证明,两个先验损失函数可以相互补充,共同优化网络,以获得更好的结果。图 7 给出了其可视化结果,从图中可以看出缺少 L_C 增强的图像在照度恢复有所欠缺,而缺少 L_C 所增强的图像在照度上恢复不佳并且局部区域出现了模糊情况,可以看出联合两个损失函数具有更好恢复效果。




图 7 损失函数消融结果

Fig. 7 comparative complexity report of different algorithms for loss function ablation results

表 4 不同损失函数所作贡献的消融实验

Tab. 4 Ablation experiments with contributions from different loss functions

Loss function missing cases	PSNR ↑	SSIM ↑
w/o L_C	18.234	0.714
w/o L_{BAD}	17.581	0.583
Full loss	19.826	0.841

3 结论

本文设计了一个结合物理先验与深度学习的无监督低照度图像增强框架(JJPNet)。该框架首先在合成数据集上进行预训练,以调整模型以适应低照度图像的增强任务。随后,模型在真实数据集上进行进一步训练,同时采用物理先验知识共同优化网络,以进一步提升图像增强的效果。通过定性和定量的实验,证明了所提方法相较于其他算法在图像增强方面的优越性,并在一定程度上摆脱了对成对数据集的依赖。此项

研究为低照度图像增强技术的应用提供了参考。

参 考 文 献

- [1] HUANG S Y, LI W, YANG Y, et al. Low-light image enhancement network guided by illuminance map[J]. Journal of Computer-Aided Design and Computer Graphics, 2024, 36(1): 93-101.
- [2] LI X F, WANG W W, HAN Y, et al. Structure aware transfer function network for low light image enhancement[J]. Engineering Applications of Artificial Intelligence, 2025, 141: 109749.
- [3] 张爽,李震. 基于耦合映像格子的明文关联图像加密方案[J]. 聊城大学学报(自然科学版), 2025, 38(1): 14-22.
- [4] GUO X J, LI Y, LING H B. LIME: low-light image enhancement via illumination map estimation[J]. IEEE Transactions on Image Processing, 2017, 26(2): 982-993.
- [5] ZHANG Y H, ZHANG J W, GUO X J. Kindling the darkness: a practical low-light image enhancer[C]// Proceedings of ACM MM, 2019: 1632-1640.
- [6] KAR A, DHARA S K, SEN D, et al. Zero-shot single image restoration through controlled perturbation of koschmieders model[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition IEEE, 2021: 16200-16210.
- [7] YANG W, WANG S, FANG Y, 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 (CVPR). IEEE, 2020: 3060-3069.
- [8] MA L, MA T Y, LIU R S, et al. Toward fast, flexible, and robust low-light image enhancement[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition IEEE, 2022: 5627-5636.
- [9] 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.
- [10] GUO C L, LI C Y, GUO J C, et al. Zero-reference deep curve estimation for low-light image enhancement[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 2020: 1777-1786.
- [11] 郑爽爽,卫文学,徐聪. 融合全变分与 Gamma 的低照度图像增强算法[J]. 激光与光电子学进展, 2023, 60(12): 1210022.
- [12] LIU X N, LI H, ZHU C. Joint contrast enhancement and exposure fusion for real-world image dehazing[J]. IEEE Transactions on Multimedia, 2022, 24: 3934-3946.
- [13] SHI Z, ZHU M M, GUO B, et al. Nighttime low illumination image enhancement with single image using bright/dark channel prior[J]. EURASIP Journal on Image and Video Processing, 2018, 13.
- [14] CHEN Z Y, WANG Y C, YANG Y, et al. PSD: principled synthetic-to-real dehazing guided by physical priors[C]// Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Nashville, TN, USA, 2021: 7176-7185.
- [15] CAI J R, GU S H, ZHANG L. Learning a deep single image contrast enhancer from multi-exposure images[J]. IEEE Transactions on Image Processing, 2018, 27(4): 2049-2062.
- [16] WEI C, WANG W, YANG W, et al. Deep retinex decomposition for low-light enhancement[EB/OL]. ArXiv preprint arXiv:1808.04560, 2018.
- [17] LOH Y P, CHAN C S. Getting to know low-light images with the exclusively dark dataset[J]. Computer Vision and Image Understanding, 2019, 178: 30-42.
- [18] Kingma D P, Ba J. Adam: a method for stochastic optimization[EB/OL]. ArXiv preprint arXiv:1412.6980, 2014.
- [19] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [20] MITTAL A, SOUNDARARAJAN R, BOVIK A C. Making a “completely blind” image quality analyzer[J]. IEEE Signal Processing Letters, 2013, 20(3): 209-212.
- [21] VENKATANATH N, PRANEETH D, BH M C, et al. Blind image quality evaluation using perception based features[C]//2015 Twenty first National Conference on Communications (NCC). IEEE, 2015: 1-6.
- [22] YAN J, LI J, FU X. No-reference quality assessment of contrast-distorted images using contrast enhancement[EB/OL]. ArXiv preprint arXiv:1904.08879, 2019.
- [23] DONG X, WANG G, PANG Y, et al. Fast efficient algorithm for enhancement of low lighting video[C]. IEEE International Conference on Multimedia and Expo(ICME), 2011: 1-6.
- [24] MA K D, ZENG K, WANG Z. Perceptual quality assessment for multi-exposure image fusion[J]. IEEE Transactions on Image Processing, 2015, 24(11): 3345-3356.
- [25] LEE C, LEE C, KIM C S. Contrast enhancement based on layered difference representation of 2D histograms[J]. IEEE Transactions on Image Processing, 2013, 22(12): 5372-5384.
- [26] 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.

(责任编辑:赵海军)