

doi:10.3969/j.issn.1673-9833.2025.04.006

基于轻量化神经网络的低照度图像增强算法

刘芸萌, 龙永红, 李 欣

(湖南工业大学 轨道交通学院, 湖南 株洲 412007)

摘 要: 针对低照度场景下图像亮度低的问题, 提出了一种基于轻量化神经网络的无监督低照度图像增强算法。提出一种可学习的内容自适应 S 型亮度映射曲线, 不仅能扩大亮度调整范围, 且能在保证亮度的情况下保持良好的对比度; 此外, 设计了一个轻量化的亮度曲线估计网络, 网络采用无监督训练, 通过学习输入图像与拟合曲线之间的映射关系, 解决了标签数据获取难的问题。实验结果表明, 所提轻量化图像增强网络的计算量较小, 有效减少了计算时间, 在不同数据集上均取得了良好表现, 为低照度场景下的图像增强提供了有效的解决方案。

关键词: S 型亮度映射曲线; 轻量化神经网络; 无监督学习; 图像增强

中图分类号: TP391.413

文献标志码: A

文章编号: 1673-9833(2025)04-0041-07

引文格式: 刘芸萌, 龙永红, 李 欣. 基于轻量化神经网络的低照度图像增强算法 [J]. 湖南工业大学学报, 2025, 39(4): 41-47.

A Low-Light Image Enhancement Algorithm Based on Lightweight Neural Network

LIU Yunmeng, LONG Yonghong, LI Xin

(College of Rail Transit, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: In view of the low image brightness in low-light scenarios, an unsupervised low-light image enhancement algorithm has thus been proposed based on a lightweight neural network. A learnable content-adaptive S-shaped brightness mapping curve is introduced to expand the brightness adjustment range and maintain good contrast while ensuring brightness. A lightweight brightness curve estimation network is designed, which adopts unsupervised training to learn the mapping relationship between the input image and the fitted curve, thus solving the problem of difficult access to labeled data. Experimental results show that the proposed lightweight image enhancement network is characterized with a low computational cost so as to effectively reduce computation time, and achieve a good performance on different datasets, thus providing an effective solution for image enhancement in low light scenarios.

Keywords: S-shaped brightness mapping curve; lightweight neural network; unsupervised learning; image enhancement

1 研究背景

在实际应用中, 由于拍摄环境、设备限制或是传输过程中的干扰等多种原因, 可能会导致图像的质量受到损害, 如出现图像亮度过低、对比度不足等问题。

这些问题不仅影响了图像的视觉效果, 还可能导致图像中的重要信息丢失或被掩盖, 给后续图像分析和处理带来困难。因此, 图像增强技术显得尤为重要。

近年来, 针对低照度图像增强, 研究者们提出了各种算法, 主要归纳为传统方法和基于深度学习的方

收稿日期: 2024-02-26

基金项目: 湖南省自然科学基金资助项目 (2024JJ7144)

作者简介: 刘芸萌, 女, 湖南工业大学硕士生, 主要研究方向为图像处理, E-mail: ymliu_lemon@163.com

通信作者: 龙永红, 男, 湖南工业大学教授, 主要研究方向为图像处理, E-mail: lyhcai@126.com

法两类。传统算法又可以分为基于直方图均衡方法和基于 Retinex 理论方法两类。基于直方图均衡处理方法^[1-3]的主要思想,是利用累计分布函数对图像中像素值的分布直方图重新排列,从而使得各色阶图像像素分布均衡,但因算法未考虑像素间关系,常出现过增强或欠增强现象。Retinex 理论认为,物体具不同颜色是因其对不同波长的反射能力不同导致的,其核心思想是将图像分解为反射分量和环境分量,反射分量表示物体本来的颜色和纹理信息,而环境分量表示环境光的颜色和强度。通过去除环境光分量,可突出反射分量的颜色和细节信息,从而提升图像的对比度和色彩表现。目前,Retinex 算法已有多种实现方式,如单尺度 Retinex^[4]、多尺度 Retinex^[5]和带色彩恢复的 Retinex^[6]等,在实践中都取得过较好效果。这些算法在图像处理过程中,运用了高斯低通滤波技术以分离出照度分量。然而,这些算法在仅仅依赖于反射分量作为增强依据的同时,却忽视了照度分量中蕴含的关键信息,从而削弱了图像的自然性。为此,Yu S. Y. 等^[7]在 Retinex 理论的基础上提出了一个物理照明模型,用来描述低照度图像的退化,通过估计模型参数并求解模型来恢复低照度图像质量。该模型能够有效地消除光晕效应,增强细节信息,保持颜色一致性。Wang S. 等^[8]提出了亮通道滤波器,结合领域的亮度信息,能够很好地保持图像的自然度,同时还可以提高图像的对比度。但基于 Retinex 理论的图像增强方法在处理图像时高度依赖于对现实环境的预设,其先验表征力存在一定的局限性。这种局限性导致算法在不同场景中的泛化能力受限,进而使得在某些复杂场景中算法无法保持一致且优异的性能表现。

随着深度学习技术在计算机视觉领域的突出表现,基于深度学习的暗场景图像增强算法成为目前的主流算法。基于深度学习的图像增强算法分为有监督和无监督两类。其中,有监督学习方法需要带有标签的数据,而这样的数据很难获取,通常是在数据采集的过程中,通过更改相机设置或者通过图像合成来收集的。近年来,有不少学者在大量带标签的数据基础上,提出了优秀的算法。如 Wei C. 等^[9]提出了 RetinexNet,其在 Retinex 理论基础上,构建了光照增强网络,用卷积神经网络分解反射分量和环境分量,并对分解后的环境分量进行恢复,虽然能更好地还原真实场景,但其对噪声敏感,且对复杂光照条件的处理能力有限,对强光和阴影交织的场景无法很好地恢复图像的细节和颜色。Cai J. R. 等^[10]构造了一个大规模的多曝光数据集,以便更好地训练卷积神经网络,

该方法能够有效地保持图像的边缘清晰,但是其在光照不均匀的场景中表现较差。Wu W. H. 等^[11]提出了 URetinex-net 算法,其将隐式先验正则化模型与 Retinex 理论结合,更好地抑制了噪声,保留了图像细节,但是其在噪声较大的场景下的处理效果会受到影响。Zhang Y. H. 等^[12]提出了 KinD 算法,用 3 个子网络实现了图层分解、反射率恢复以及亮度调整,可有效地提升图像亮度,但是忽略了噪声的影响以及出现的伪影。以上分析表明,有监督学习方法不仅收集数据的成本较高,并且在训练模型时会引入包含虚假和不切实际的数据。

无监督学习^[13-19]方法具有不依赖成对数据进行训练的优点。EnlightenGAN^[13]是第一个使用无监督训练方法实现暗场景图像增强的网络模型,其通过全局和局部对抗损失、规范化的感知损失使得生成的图像更加接近正常光照图像的光照分布。但是其基于生成对抗网络,对噪声和伪影敏感,存在噪声时会导致生成的图像质量下降。Guo C. L. 等^[14]基于 Zero-DCE (zero-reference deep curve estimation) 创造性地给出了基于深度学习的零参考深度曲线估计模型,并设计了一条随输入图像变化的二次曲线作为网络输出。该模型不需要任何成对或不成对数据,具有很好的泛化能力,在不均匀和较差的照明情况下都有不错的表现,但是其二次曲线的动态调整范围有限,当噪声明显时情况并未得到有效解决。为提高模型效率,Liu R. S. 等^[16]提出了一种受 Retinex 启发的 LLIE (low-light image enhancement) 解卷方法,其中合作架构搜索被用来发现基本块的轻量级先验架构,并以非参考损失训练网络。文献[17]提出了快速、灵活与稳健的低光照图像增强方法——自校准光照学习算法,该算法通过构建引入自校准模块的权重共享光照学习过程,摒弃了网络结构的繁杂设计过程,实现了仅使用简单操作进行增强的目的。大量的实验结果表明,该算法的计算效率较高,在下游视觉任务应用方面均取得了突破,但是其易出现过度曝光现象。

为解决低光照图像在实际应用中难以获取训练标签样本的问题,本文提出了一种基于轻量化网络的无监督图像增强方法,主要贡献如下:

1) 设计了一种轻量化的无监督低照度图像增强算法,能够不依赖参考图像训练模型,解决了实际应用中难以获取训练标签样本的问题。

2) 提出可学习的内容自适应 S 型亮度映射曲线,具有较大的亮度调整范围,在保证亮度的情况下能保持良好的对比度。

2 基于轻量化神经网络图像增强算法

本文算法的实现流程如图1所示。




图1 基于轻量化神经网络图像增强算法实现流程

Fig. 1 Implementation process of image enhancement based on lightweight neural network algorithms

如图1所示, 首先, 输入一张低照度的图片, 即图1中的输入图片, 其经过亮度恒常网络, 得到RGB 3个通道的 A 、 B 共6个系数矩阵, 然后将每个系数矩阵代入亮度映射曲线公式中, 求解亮度恒常后的图像。在网络训练过程中, 采用无监督学习方法进行优化, 避免了有监督学习方法中对大量标注数据的依赖。

2.1 亮度映射曲线

亮度映射曲线描述了输入图像中每个像素的亮度值如何被映射到输出图像中的对应亮度值。其通常被用于图像增强和调整中, 调整亮度映射曲线可以改变图像对比度、亮度和动态范围, 从而改变图像视觉效果和质量。因此, 为满足实际应用需求, 亮度映射曲线的合理设计尤为重要。本文基于对亮度映射曲线分析, 设计了一种内容自适应S型亮度映射曲线, 其可根据输入图像特性进行自适应调整, 在保证亮度的同时保持良好的对比度。

设计亮度映射曲线时, 需满足以下要求: 1) 归一化范围。为了防止信息丢失, 增强后图像的每个像素值均在 $[0, 1]$ 范围内。这就要求亮度映射曲线具有合适的缩放和偏移参数, 以确保像素值的有效映射。2) 单调性。单调性要求曲线保持相邻像素之间的差异不变, 这意味着增强过程中, 应保留相邻像素的相对关系, 避免出现伪影或失真现象。3) 简单性与可微性。为便于计算和优化, 亮度映射曲线应形式简洁, 同时在梯度反向传播过程中保持可微。这有助于提高算法的效率和稳定性, 使得模型能够快速收敛并获得高质量的增强结果。

基于上述要求, 本文提出了一种内容自适应的S型亮度映射曲线。该曲线通过学习输入图像特征, 能

够自适应地调整其参数, 以满足不同图像的增强需求, 曲线设计见式(1)。

$$LE(I(x), \alpha, \beta) = (c - a) / (b - a). \quad (1)$$

式中: $LE(I(x), \alpha, \beta)$ 为输出的增强图像, 其中 α 和 β 为对应网络输出权重, $I(x)$ 为输入图像;

a 、 b 、 c 分别为

$$\begin{cases} a = 1 / (1 + e^{\alpha * \beta}); \\ b = 1 / (1 + e^{(\alpha - 1) * \beta}); \\ c = 1 / (1 + e^{(\alpha - I(x)) * \beta}). \end{cases} \quad (2)$$

将曲线分别作用在RGB 3个通道, 能更好地保留图像原有色彩, 降低饱和度高风险。相较于二次曲线, sigmoid曲线增大了动态调整范围的同时, 在暗区域的调整更加灵活, 且能提升图像对比度。如图2所示, 图2a为当 $\beta=5$ 时, 不同 α 取值输出的亮度映射曲线, 图2b为当 $\alpha=0.6$ 时, 不同 β 取值输出的亮度映射曲线。




图2 不同 α 和 β 值下的亮度映射曲线分布

Fig. 2 Distribution of brightness mapping curves with different values of α and β

式(2)所描述的亮度映射曲线可在较大动态范围内调整图像亮度, 但该式仍是一个全局映射。若 α 和 β 作用于所有像素, 这样的全局映射往往会增强不足或过度增强局部区域。为解决这一问题, 本节将公式中 α 和 β 化为逐像素参数, 即给定输入图像的

每个像素都有一条具有最佳拟合 α 和 β 的对应曲线，以调整其动态范围。因此，亮度增强曲线 $LE(x)$ 可以重新表述为

$$LE(x) = (C - A) / (B - A). \quad (3)$$

式中： A 、 B 、 C 分别为

$$\begin{cases} A = 1 / (1 + e^{A_n * B_n}); \\ B = 1 / (1 + e^{(B_n - 1) * B_n}); \\ C = 1 / (1 + e^{(A_n - I(x)) * B_n}), \end{cases} \quad (4)$$

其中， A_n 和 B_n 为具有与给定图像相同大小的参数图。

这里，假设局部区域中的像素具有相同的调整曲线和强度，因此输出结果中的相邻像素仍然保持单调关系。以这种方式处理，逐像素的高阶曲线也符合 3 个条件。

2.2 网络模型设计

U-Net 模型结构简单，左右对称，运行速度快，支持少量的数据训练模型。因此，本文使用对称的 5 个普通 CNN (convolutional neural network) 卷积层，形如 U-Net 网络结构，如图 3 所示。网络结构由一个下采样路径和一个上采样路径组成。




图 3 U-Net 网络结构示意图

Fig. 3 Schematic diagram of the U-Net network structure

卷积层由大小为 3×3 ，步长为 2 的卷积核组成，激活函数为 ReLU。本文中网络结构详细配置如表 1 所示。

表 1 网络结构详细配置

Table 1 Detailed configurations of network structure

input image	output	layer	stride	kernel	in	out
256 256 3	128 128 16		2	3 3 3	3	16
128 128 16	64 64 16	Conv3-16	2	3 3 3	16	16
64 64 16	32 32 16		2	3 3 3	16	16
32 32 16	64 64 16	ConvTrans3-16	2	3 3 3	16	16
64 64 32	128 128 16		2	3 3 3	32	16
128 128 32	256 256 6	ConvTrans3-6	2	3 3 3	32	6

2.3 损失函数设计

针对无监督学习中亮度不一致和低照度问题，本文设计了 3 组无参考损失函数，用以提高图像增强的质量和稳定性，分别是空间一致性损失、曝光控制损失和色彩恒常性损失。空间一致性损失旨在确保增强后的图像在不同区域间具有一致的亮度分布；曝光控制损失旨在解决图像在增强过程中出现的曝光过度或曝光不足问题；色彩恒常性损失旨在保持增强后的图像色彩的稳定性。

2.3.1 空间一致性损失

为保持空间一致性，则需要调整输入图像与增强图像相邻区域的梯度。通过计算两个图像三通道均值，得到两个灰度图像，将其分解成若干个 4×4 的块，最后计算每个块内中心像素与相邻像素的插值并求其均值，如式 (5) 所示：

$$L_{\text{spa}} = \frac{1}{K} \sum_{i=1}^K \sum_{j \in \Omega(i)} (|Y_i - Y_j| - |I_i - I_j|)^2. \quad (5)$$

式中： L_{spa} 为空间一致性损失；

K 为局部区域数目；

$\Omega(i)$ 为以区域 i 为中心上下左右 4 个相邻区域；

Y 和 I 分别为增强版本和输入图像中局部区域的平均强度值。

2.3.2 曝光控制损失

为了抑制图像曝光不足或者曝光过度的问题，设计曝光控制损失来控制曝光水平。用曝光控制损失 L_{exp} 衡量局部区域的平均强度值与曝光良好水平 E 之间的距离：

$$L_{\text{exp}} = \frac{1}{M} \sum_{k=1}^M |Y_k - E|. \quad (6)$$

式中， M 为大小为 16×16 的非重叠局部区域数量。

2.3.3 色彩恒常性损失

根据灰色世界颜色恒常性假设，即每个传感器通道中的颜色在整个图像上平均为灰色，设计了颜色恒常性损失来纠正增强图像中潜在的颜色偏差，并建立 3 个调整通道之间的关系，用 L_{col} 表示：

$$L_{\text{col}} = \sum_{(p, q) \in \varepsilon} (J^p - J^q)^2. \quad (7)$$

式中： J 为增强图像相应通道的平均亮度；

(p, q) 代表一对通道；

$\varepsilon = \{(R, G), (R, B), (G, B)\}$ 。

2.3.4 总损失

总损失为空间一致性损失 L_{spa} 、曝光控制损失 L_{exp} 及色彩恒常性损失 L_{col} 的累计损失，令 ω 为权重，将 3 个损失函数累加即可得到总损失 L_{all} ，即

$$L_{\text{all}} = L_{\text{spa}} + L_{\text{exp}} + L_{\text{col}}. \quad (8)$$

3 实验验证

3.1 实验环境

本实验中选用 GPU 为 NVIDIA 1080Ti、内存为 64 GB 的台式电脑。训练用实验数据采用 UHE-LL^[20] 数据集, 共选用了 2 150 张图片, 且其大小均调整为 $256 \times 256 \times 3$ 。将其在 PyTorch 平台上进行网络训练, 得到其训练集上的损失函数衰减曲线, 如图 4 所示。




图 4 损失函数衰减曲线

Fig. 4 Loss function attenuation curves

本文实验中, 当迭代次数为 20 000 次时, 损失函数已经收敛, 整个训练过程约需要 1 h。在模型训练过程中, 采用以下参数设置: 每次权重更新时使用的样本数量为 8, 输入图像大小统一为 $256 \times 256 \times 3$; 优化器为 Adam, 其正则项设置为 0.000 1, 学习率设置为 0.000 1。

3.2 实验验证

本实验中选择了 6 种方法与本文所提出的方法进行比证, 分别展示数据集 MEF^[21]、DICM、NPE、VV、LIME^[22]、BAID^[23]、Backlit300^[19] 上的测试结果, 具体如表 2 所示。表 3 中展示了在 BAID 数据集上的定量分析结果, 其中最优结果用加粗展示, 次优结果用下划线加粗展示。本文采用全参考图像质量评价指标 PSNR (peak signal-to-noise ratio)、SSIM (structural similarity index)、MUSIQ (multi-scale image quality), 以及基于深度学习技术的图像质量评价指标 LPIPS (learned perceptual image patch similarity) 进行量化。

表 2 各算法在不同数据集上的结果对比

Table 2 Comparative results of different algorithms on different datasets

方法	数 据 集						
	MEF	DICM	NPE	VV	LIME	BAID	Backlit300
原图							
RUAS ^[16]							
SCI ^[17]							
Enlighten-GAN ^[13]							
ExCNet ^[18]							
CLIP-LIT ^[19]							
Zero-DCE ^[14]							
本文方法							

表 3 不同方法在 BAID 测试集的定量比较结果

Table 3 Quantitative comparison results of different methods in BAID test dataset

方 法	评 价 指 标			
	PSNR	SSIM	LPIPS	MUSIQ
input	16.641	0.768	0.197	52.115
RUAS ^[16]	13.312	0.758	0.347	45.008
SCI ^[17]	12.766	0.762	0.347	44.176
EnGAN ^[13]	17.550	0.864	0.196	48.417
ExCNet ^[18]	19.437	0.865	0.168	52.576
CLIP_LIT ^[19]	21.579	0.883	0.159	55.689
Zero ^[14]	18.553	0.863	0.194	52.576
本文算法	19.652	0.874	0.156	54.861

根据表 3 中数据可知, 本文的结果均处于最优和次优之中, 但 CLIP-LIT 参数量较大, 为了验证本文模型的轻量化, 将本文提出的方法与其他质量明显提升的方法在模型参数量、计算复杂度以及训练时长等方面的表现进行对比。

具体的模型大小、计算量以及训练时间 3 个方面的比较结果见表 4。从表 4 中可以看出, 本章算法展现出明显的轻量化优势, 相较于其他算法具有更低的计算量。其参数量在图片质量有所提升的几个方法中最少, FLOPs 最小, 并具有最短的训练时长。因此, 可以说本文算法在计算量、训练时长和增强效果之间取得了良好的平衡。

表 4 不同方法下模型参数量、FLOPs、训练时长结果对比

Table 4 Number of model parameters under different methods FLOPs, comparison of training duration and results

方 法	参数量/k	FLOPs/G	GPU	训练时长/h
EnGAN ^[13]	86.63	61.01	3 卡 NVIDIA 1080Ti	3
ExCNet ^[18]	4 335.62	180.43	单卡 TITAN X	5
CLIP_LIT ^[19]	947.20	41.38	单卡 NVIDIA GTX 3090Ti	12
Zero ^[14]	79.80	5.21	单卡 NVIDIA 2080Ti	3
本文算法	13.77	0.16	单卡 NVIDIA 1080Ti	1

4 结 语

本文提出了一种基于轻量化神经网络的无监督低照度图像增强算法, 旨在解决低照度场景下的图像增强问题。通过重新定义图像增强任务为曲线估计问题, 设计了一条可学习的内容自适应 S 型曲线, 实现了大范围内的亮度调整。此外, 本文还构建了一个轻量化的图像增强网络, 通过学习输入图像与拟合曲线之间的映射关系, 有效减小了计算量和训练时长。

实验结果表明, 本文算法在不同数据集上均表现出色, 为低照度场景下的图像增强提供了有效的解决方案。与其他先进方法相比, 本文算法在模型大小、计算复杂度和训练时长等方面均具有优势, 实现了高效、准确的图像增强。但在本文算法中并未考虑噪声的影响, 因此, 后续可以从如何减少噪声方面进行深入研究。

参考文献:

- [1] SEPASIAN M, BALACHANDRAN W, MARES C. Image Enhancement for Fingerprint Minutiae-Based Algorithms Using CLAHE, Standard Deviation Analysis and Sliding Neighborhood[J]. Lecture Notes in Engineering and Computer Science, 2008, 2173(1): 1199.
- [2] 马敏慧, 王红茹, 王 佳. 基于改进的 MSRCR-CLAHE 融合的水下图像增强算法 [J]. 红外技术, 2023, 45(1): 23-32.
MA Minhui, WANG Hongru, WANG Jia. An Underwater Image Enhancement Algorithm Based on Improved MSRCR-CLAHE Fusion[J]. Infrared Technology, 2023, 45(1): 23-32.
- [3] 方丹阳, 付青青, 吴爱平. 基于自适应动态范围 CLAHE 的雾天图像增强 [J]. 激光与光电子学进展, 2023, 60(4): 150-157.
FANG Danyang, FU Qingqing, WU Aiping. Foggy Image Enhancement Based on Adaptive Dynamic Range CLAHE[J]. Progress in Laser and Optoelectronics Progress, 2023, 60(4): 150-157.
- [4] JOBSON D J, RAHMAN Z, WOODDELL G A. Properties and Performance of a Center/Surround Retinex[J]. IEEE Transactions on Image Processing, 1997, 6(3): 451-462.
- [5] JOBSON D J, RAHMAN Z, WOODDELL G A. A Multiscale Retinex for Bridging the Gap Between Color Images and the Human Observation of Scenes[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 1997, 6(7): 965-976.
- [6] 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. Lausanne, Switzerland: IEEE, 1996, 3: 1003-1006.
- [7] YU S Y, ZHU H. Low-Illumination Image Enhancement Algorithm Based on a Physical Lighting Model[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2017, 29(1): 28-37.
- [8] WANG S, 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.
- [9] WEI C, WANG W, YANG W, et al. Deep Retinex Decomposition for Low-Light Enhancement[J/OL]. arXiv Preprint arXiv:1808.04560, 2018. [2024-02-24]. <https://doi.org/10.48550/arXiv.1808.04560>.
- [10] 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.
- [11] WU W H, WENG J, ZHANG P P, et al. URetinex-Net: Retinex-Based Deep Unfolding Network for Low-Light Image Enhancement[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans: IEEE, 2022: 5901–5910.
- [12] ZHANG Y H, ZHANG J W, GUO X J. Kindling the Darkness: A Practical Low-Light Image Enhancer[C]//Proceedings of the 27th ACM International Conference on Multimedia. Nice France: ACM, 2019: 1632–1640.
- [13] JIANG Y, GONG X, LIU D, et al. EnlightenGAN: Deep Light Enhancement Without Paired Supervision[J]. IEEE Transactions on Image Processing, 2021, 30: 2340–2349.
- [14] GUO C L, LI C Y, GUO J C, et al. Zero-Reference Deep Curve Estimation for Low-Light Image Enhancement[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 1780–1789.
- [15] 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.
- [16] 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 (CVPR). Nashville: IEEE, 2021: 10561–10570.
- [17] MA L, MAT Y, LIU R S, et al. Toward Fast, Flexible, and Robust Low-Light Image Enhancement[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans: IEEE, 2022: 5637–5646.
- [18] ZHANG L, ZHANG L J, LIU X, et al. Zero-Shot Restoration of Back-Lit Images Using Deep Internal Learning[C]//Proceedings of the 27th ACM International Conference on Multimedia. Nice France: ACM, 2019: 1623–1631.
- [19] LIANG Z X, LI C Y, ZHOU S C, et al. Iterative Prompt Learning for Unsupervised Backlit Image Enhancement[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Paris: IEEE, 2023: 8094–8103.
- [20] LI C, GUO C L, ZHOU M, et al. Embedding Fourier for Ultra-High-Definition Low-Light Image Enhancement[J/OL]. arXiv Preprint arXiv:2302.11831, 2023. [2024-02-24]. <https://doi.org/10.48550/arXiv.2302.11831>.
- [21] MA K, ZENG K, WANG Z. Perceptual Quality Assessment for Multi-Exposure Image Fusion[J]. IEEE Trans Image Process, 2015, 24(11): 3345–3356.
- [22] GUO Xiaojie, LI Yu, LING Haibin. LIME: Low-Light Image Enhancement via Illumination Map Estimation[J]. IEEE Transactions on Image Processing, 2017, 26(2): 982–993.
- [23] LÜ X, ZHANG S, LIU Q, et al. BacklitNet: A Dataset and Network for Backlit Image Enhancement [J]. Computer Vision and Image Understanding, 2022, 218: 103403.

(责任编辑: 廖友媛)