**DOI:**10.16136/j.joel.2023.10.0392

# 基于无监督学习的低照度图像增强算法

苏 赋,敬 梁\*,罗仁泽,王龙业,张凯信,方 东

(西南石油大学 电气信息学院,四川 成都 610500)

摘要::针对目前低照度图像增强算法存在恢复细节丢失、网络复杂度高和配对数据集获取难度 大等问题,提出了一种基于无监督学习的图像增强算法。在YIQ 色彩空间中,通过构建的轻量化 网络和幂指函数计算亮度通道Y的增强曲线,从而获得曝光较差区域增强和高光区域遏制的图 像。该网络使用的无参考损失函数可以隐式地评估图像增强质量并驱动网络学习。实验对比结 果表明,该算法在可训练参数和模型权重仅占9.5 k/88 kB的情形下,在视觉效果与图像质量指标 上都取得了具有竞争力的结果。

关键词:低照度图像增强;增强曲线;无监督学习;轻量级网络 中图分类号:TP391 文献标识码:A 文章编号:1005-0086(2023)10-1036-11

# Low-light image enhancement algorithm based on unsupervised learning

SU Fu, JING Liang<sup>\*</sup>, LUO Renze, WANG Longye, ZHANG Kaixin, FANG Dong (College of Electrical Information, Southwest Petroleum University, Chengdu, Sichuan 610500, China)

Abstract: An image enhancement algorithm based on unsupervised learning is proposed, aim at the problems of low illumination image enhancement algorithms, suffering from loss of recovery details, high network complexity, and difficulty obtaining paired data sets. In YIQ color space, the enhancement curve of luminance channel Y is calculated by the constructed lightweight network and power index function to get the image of the enhancement of the poorly exposed area and the containment of the high light area. The no-reference loss function used in this network can implicitly evaluate image enhancement quality and drive network learning. Experimental results show that the proposed algorithm achieves competitive results regarding visual effects and image quality when the trainable parameters and model weight only account for 9.5 k/88 kB.

Key words: low-light image enhancement; enhancement curve; unsupervised learning; lightweight network

# 0 引 言

近年来,图像处理和深度学习在人脸识别<sup>[1]</sup> 与目标检测<sup>[2]</sup>等人工智能领域取得了广泛的应 用。然而,这些应用需要图片具有良好的曝光水 平。曝光不足的图像容易造成细节的丢失,使得 主观视觉效果降低,同时也给下游视觉任务带来 困难。因此,展开对低照度图像增强的研究,减轻 光照对图像质量带来的影响,不仅可以提高视觉 感受,而且对下游视觉任务也具有重要的意义。 现阶段常用的增强方法主要分为传统算法和基于 神经网络的算法。

在传统增强方法中,主要有基于直方图均衡 化算法、基于 Retinex(retina cortex)理论的算法、 基于频率域算法。直方图均衡化、直方图匹配是 最基本的图像增强算法,其通过重新调整图像灰 度级的概率分布,达到增大图像动态范围和提高 对比度的目的。该方法原理简单、实时性强且易 于实现。Retinex理论则认为图像由反射分量和 光照分量构成,其中反射分量反应图像本身的颜 色和纹理信息,是物体的内在属性,并不随光照强 度而改变。由于反射分量无法直接求得,许多学 者通过不同方法获取并调整物体的光照分量<sup>[3-5]</sup> 并进一步获得增强图像。频率域算法是将图像信 息转换至频率域空间,通过改变图像不同频率的 信息进而增强图像。WANG等<sup>[6]</sup>在频率域采用 Retinex 理论,利用双对数变换平衡反射分量和光 照分量,该算法能有效地增强图像细节信息。FU 等<sup>[7]</sup>则在此基础上使用加权变分模型估计图像的 反射分量和光照分量。文献[8]则将小波变换与 直方图均衡化结合,将变换后的高频信息进行非 线性增强,再逆变换后使用限制对比度直方图均 衡化保持色调。然而传统方法往往存在计算复杂 度高、泛化性能差等缺点。如基于直方图的增强 方法计算效率高,但不能适应复杂的光照环境;基 于Retinex和频率的方法适应性更强,但计算效 率低。

针对传统增强方法存在的局限性,近年来,许 多学者采用深度神经网络的方法对低光图像进行 增强。相比于传统算法,基于深度神经网络的方 法普遍取得了更好的增强结果。LORE 等<sup>[9]</sup>首次 提出使用深度学习实现低光图像增强,并使用自 然低光图像和基于伽马校正的合成图像进行训 练。受 Retinex 理论的启发,文献[10-14]将 Retinex 理论应用于模型构建和损失函数中,其中 WEI 等<sup>[10]</sup>构建了第一个基于 Retinex 理论的网络 模型 RetinexNet。ZHAO 等<sup>[11]</sup>则提出了一种以高 斯白噪声作为网络输入的生成式 Retinex 分解模 型。FAN等<sup>[14]</sup>将 Retinex 理论和语义分割结合, 根据不同的区域调节增强效果。文献[15,16]的 作者则构建了更复杂的多分支网络用于低光图像 恢复。与上述图像到图像的映射方法所不同的 是,WANG<sup>[17]</sup>等在网络中引入了中间照明,学习 图像到中间照明的映射。文献「18,19]则引入了 生成对抗网络(generative adversarial network, GAN),解决了监督学习需要配对的低/正常光图 像的难点。文献[20,21]均引入了递归迭代的网 络模型,前者在训练模型时使用配对图像,在最后 判别增强效果时则使用了 GAN 的思想,而后者则 是在模型中引入了循环层和注意力图。WANG 等<sup>[22]</sup>则巧妙地在模型中嵌入了"Light 网"和 "Dark 网",作者认为,输入的低光图像经过"Light 网"后应该与标签相似,同样的,增强的图像经过 "Dark 网"后,也应与输入的低光图像相似,以此 借助"Dark 网"来提升"Light 网"的增强效果。然 而,监督学习需要配对的是低/正常光图像数据 集,但这样的配对图像在真实世界中获取难度极 大。现有的配对数据集通过调整相机曝光时间、 感光度,以及图像融合等操作生成,无法准确反应

真实世界的细节。同时,尽管 GAN 网络无需配对 图像,但仍然需要人为地筛选一组高质量的曝光 图片供判别器使用。

通过文献分析发现,现有的低照度图像增强 算法主要存在以下几个问题:

1) 低光/正常光配对图像获取难度较大;

2)泛化能力较差,由于在不真实的配对数据 集上训练模型,导致模型在真实低照度场景下增 强效果较差,容易引入锐化、过曝光、增强不足等 现象;

3)现有的模型在取得优秀结果的同时,往往 会占据大量的计算资源。

为了解决上述问题,提出了一种无监督学习 方法,该方法不需要低光/正常光配对图像。通过 本文构建的幂指函数、轻量化网络以及一组无参 考的损失函数,可以快速得到特定的低照度图像 的增强曲线(low-light image enhancement curve, LLIE-Curve)。该曲线作为一种特定于图像的曲 线,可以在一个广泛的照明范围内进行图像的 增强。

# 1 本文算法

本文设计了一种轻量化的低照度图像增强网络(low-light image enhancement net, LLIE-Net), 用于估计给定 LLIE-Curve, 通过该曲线来获得最终的增强图像。算法的整体框架如图 1 所示, 在本节中将详细介绍算法中的关键组件, 即 LLIE-Curve、LLIE-Net 和无参考损失函数。

1.1 LLIE-Curve

在图片编辑软件 Photoshop 中,往往通过曲线 图层调整图片的光照强度,并通过手动的设计曲 线形式,使图像原像素值按照曲线形式进行改变。 受此启发,本文设计了一种可以自动将弱光图像 映射到增强图像的 LLIE-Curve(即曲线形式),其 中增强曲线的参数完全依赖输入图像。为了使增 强图像在色彩和对比度方面具有良好的效果,该 增强曲线的设计有4个目标:

1) 增强图像的每个像素值应在[0,1]的归一
 化范围内,避免溢出截断造成信息丢失;

2) 增强曲线应单调,能够保持相邻像素之间 的差异(即对比度);

3)在梯度反向传播过程中,增强曲线的形式 需简单且可微;

4) 增强曲线需灵活,在低照度图像下,增强曲线应增强低光区域,且不使高光区域产生过曝现象。



图1 本文算法的整体框架

Fig. 1 The overall framework of this algorithm

在过曝光图像下,该曲线能保持中低光区域,且 抑制高光区域。

为了实现上述 4 个目标,设计了一个幂指函数 作为增强曲线,其函数表达式为:

$$f(x,A) = x^{\gamma}, \gamma = 2^{x-A}, \qquad (1)$$

式中,A 为模型 LLIE-Net 的输出,用于控制最终的 增强效果,x 为输入像素值,f(x,A)为输出像素值。 为了使像素值不发生溢出和截断,每个像素都被归 一化到[0,1]的范围。图 2 中展示了不同参数 A 对 增强曲线的影响,其中横轴表示输入像素值 x,纵轴 表示增强后的输出像素值 f(x,A)。当 A=0.5 时, LLIE-Curve 呈现"反 S"曲线的形式,此时低光区域 的像素值增加,高光区域的像素值减少,LLIE-Curve 增强低光,抑制高光,适合低照度图像中含有过曝光 区域的图片;当 A=0.7 或 1 时,LLIE-Curve 则增强 中低光区域的像素值,适合图像整体偏暗的情形,并







且对低像素值的增强程度高于高像素值;当A=0时,则整体减弱像素值强度,此时LLIE-Curve适合图像整体偏亮的情形,对高像素值的抑制程度也高于低像素值。显然,LLIE-Curve满足上述4个目标。同时,由于A的取值不同,LLIE-Curve形式也有所不同,使得本文设计的LLIE-Curve在图像增强上具有广泛的适应能力。

虽然 LLIE-Curve 具有较强的适应能力,但参数 A 作为一个全局参数作用于所有输入像素时,往往 无法平衡局部区域,会造成过度/不足的增强局部区 域。为了解决该问题,本文将 A 作为一个像素级参 数,对给定输入图像的每个位置都生成一个局部参 数 A(x),即每个输入像素都有一条对应的增强曲 线。因此式(1)的表达形式可以改写为:

 $f(x,A(x)) = x^{\gamma}, \gamma = 2^{x-A(x)},$  (2) 式中,A(x)是与给定输入图像大小相同的像素级参数,仍是模型 LLIE-Net 的输出。由于局部区域的像 素具有相同的强度,因此以像素级参数 A(x)生成的 LLIE-Curve,仍满足上述 4 个目标。图 3 是 LLIE-Curve 增强的一个包含不均匀照明的弱光图像。从 图中可以看出,LLIE-Curve 增强了图中的暗区域,而 没有使图中亮区域(墙上的壁灯)产生过曝现象。

由于 RGB 色彩空间 3 个通道之间存在强耦合性,直接将 LLIE-Curve 作用于 RGB 上,会使增强图像产生色偏。为了解决该问题,将 LLIE-Curve 作用于 YIQ 色域中的亮度通道 Y,在实验部分证明了在 YIQ 色域增强的效果好于对 RGB 增强的效果。图 1 中算法整体框架也展示了对YIQ色域增强的全部 过程。





图 3 典型弱光图像的增强效果:(a) 原图;(b) 增强图 Fig. 3 Enhancement of typical low-light images;(a) Input;(b) Output

#### 1.2 LLIE-Net

为了学习输入图像到增强图像之间的最佳映射 参数 A(x),本文设计了一个 LLIE-Net。在图 1 中, 给出了 LLIE-Net 详细的网络结构和参数。如图 1 中 LLIE-Net 部分,LLIE-Net 是一个包含 6 层卷积 层的普通 CNN。在前 5 个卷积层中,每个卷积层由 16 个尺寸为 3×3、步幅为 1 的卷积核组成,激活函数 是 Relu。最后一个卷积层由 1 个尺寸为 3×3、步幅 为 1 的卷积核构成。最后一层卷积层组成了 LLIE-Curve 的像素级参数 A(x),为了使 LLIE-Curve 具 有更强的泛化能力,对最后一层卷积未设置激活函 数。同时,为了保持相邻像素之间的关系,LLIE-Net 丢弃了降采样和批处理归一化层。最后,在模型训 练时,将输入图片尺寸调整至 512×512×3。

尽管本文构建的是一个轻量级模型结构,但主 观视觉感受和客观指标均能证明该结构的有效性。 值得注意的是,LLIE-Net 仅有 9.5 k 的可训练参数 和 88 kB 的权重,小于多数基于深度学习的增强模 型,如 MBLLEN (multi-branch low-light enhancement network)<sup>[16]</sup>:450 k/2 MB,Zero-DCE(zero-reference deep curve estimation)<sup>[23]</sup>: 79 k/340 kB, Exc-Net(short for exposure correction network)<sup>[24]</sup>: 52 583 k/200 MB。

#### 1.3 无参考损失函数

为了使 LLIE-Net 实现无监督学习,输出最优像 素级参数 A(x),本文构建了一组无参考损失函数。 该损失函数能够隐式地评估增强图像的质量并驱动 LLIE-Net 学习,损失函数由以下 3 种类型组成。 1.3.1 对比度损失

在传统图像处理中,计算整幅图像对比度<sup>[25]</sup>方 法如式(3)所示:

$$spa = \sum_{\delta} \delta(i,j)^2 P_{\delta}(i,j), \delta(i,j) = |i-j|,$$
(3)

式中, $\delta(i,j)$ 是相邻像素间的灰度差, $P_{\delta}(i,j)$ 是相邻 像素间灰度差为 $\delta$ 的像素分布概率。根据相邻像素 范围的不同,对比度计算分为四近邻对比度和八近 邻对比度,图4是两种不同近邻计算方法的展示。 为保持局部区域之间的对比度差异,受图像对比度 计算方法的启发,ExcNet<sup>[24]</sup>通过最小化输入图像和 增强图像之间的局部对比度差异,使增强图像保持 良好的细节。因此对比度损失  $L_{spa}$  如式(4)所示:

$$L_{\rm spa} = \frac{1}{K} \sum_{i=1}^{K} \sum_{j \in \Omega(i)} (|(Y_i - Y_j)| - |I_i - I_j|)^2, \quad (4)$$

式中,*K*为局部区域的数量,局部区域的大小设为4 ×4,*Y*和*I*分别为增强图像与输入图像局部区域的 平均灰度值,Ω<sub>(i)</sub>表示以区域*i*为中心的4个相邻区 域,即采用四近邻计算。



(a) Four neighbors; (b) Eight neighbors

#### 1.3.2 曝光控制损失

为了使低照度图像取得良好的曝光效果,Zero-Dce<sup>[23]</sup>和 JIANG 等<sup>[26]</sup>通过衡量增强图像到良好曝 光水平之间的距离来调节曝光强度。受到以上工作 启发,本文构建了一个曝光控制损失 $L_{exp}$ ,其表示为式(5):

$$L_{\text{exp}} = \frac{1}{K} \sum_{i=1}^{K} \tanh(Y_i - E) \times (Y_i - I_i), \quad (5)$$

式中,E表示一个良好的曝光水平。局部区域K设 为16×16,E设为0.6。图5为该损失函数的说明, 图5(a)和图5(b)分别固定了 $I_i$ =0.2以及 $I_i$ =0.8,



用于演示当  $I_i$  被固定时,  $L_{exp}$  如何随着  $Y_i$  的变化而变化。

从图 5 中可以看出,曝光控制损失使 Y<sub>i</sub> 尽可能 接近 0.6,以便曝光不足和过度的区域都可以调整到 良好的曝光水平。此外,L<sub>exp</sub>能够保持 I<sub>i</sub> 和 0.6 之间 的大小关系,如果 I<sub>i</sub> 大于(小于)0.6,Y<sub>i</sub> 也会倾向于 大于(小于)0.6。L<sub>exp</sub>的该特性可以保证 I<sub>i</sub> 中较浅/



图 5 固定 I<sub>i</sub> 时,L<sub>exp</sub>随 Y<sub>i</sub> 的变化

Fig. 5  $L_{exp}$  changes with  $Y_i$  when  $I_i$  is fixed

较暗的区域在 Y<sub>i</sub> 中仍然保持较浅/较暗。 1.3.3 光照平滑损失

为了使增强图像与输入图像在相邻像素之间的 单调性关系上保持一致,即需要保持局部区域的像 素值一致。在文献[10]—[12]中,对分离出的光照 分量进行了平滑处理。因此,本文通过在 LLIE-Net 的像素级输出 A(x)中添加一个光照平滑损失 L<sub>tv</sub>, 间接达到对最终增强的亮度通道 Y 进行平滑。L<sub>tv</sub> 可 以定义为式(6):

$$L_{\rm tv} = \frac{1}{(M-1)(N-1)} \sum (|\nabla_x A(x)| + |\nabla_x A(x)|)^2,$$
(6)

式中,M和N分别为输入图像的宽、高, $\nabla_x$ 和 $\nabla_y$ 分别代表A(x)的水平梯度和垂直梯度。

1.3.4 总损失

综上,本文 LLIE-Net 总损失函数 L 可以表示为 式(7):

$$L = \lambda_1 L_{spa} + \lambda_2 L_{exp} + \lambda_3 L_{tv}$$
, (7)  
式中,  $L_{spa}$  为对比度损失,  $L_{exp}$  为曝光控制损失,  $L_{tv}$  为  
光照平滑损失。 $\lambda_1$ 、 $\lambda_2$  和  $\lambda_3$  为各自的权重, 用于平衡  
图像细节和曝光水平。在 2.3 节实验部分, 展示了关  
于损失函数的消融实验, 以验证文中构建的每个损

失函数对最终增强效果的影响。

# 2 实验结果与分析

#### 2.1 实施细节和数据集

本段描述图 1 算法的整体过程。假设输入的暗 光图像为 RGB 格式,记为 X,输出的增强图像仍为 RGB 格式,记为 X。第一步先将输入图像从 RGB 转 为 YIQ 色域;第二步将 YIQ 色域的亮度通道 Y 送入 构建的模型 LLIE-Net 得到模型输出 A(x)值,再通 过本文设计的增强曲线 LLIE-Curve(式(2))得到增 强后的 Ŷ;第三步通过式(8)调整两个色度通道 I 和 Q 得到 Î 和 Q 。最后将增强后的 ŶÎ Q 重新转为 RGB 得到最终的输出 X 。在 2.4 节实验部分,展示了关 于 RGB 和 YIQ 色域通道的消融研究,以证明选择 YIQ 色域进行增强的正确性。

$$\begin{cases} \hat{I} = \frac{\hat{Y}}{Y}I\\ \hat{Q} = \frac{\hat{Y}}{Y}Q \end{cases}$$
(8)

为了使文中算法能够提升欠曝光区域并抑制过 曝光区域,选择了同时具有欠曝光和过曝光图像的 数据集 SICE (single image contrast enhancement)<sup>[27]</sup>的第一部分作为训练集。该部分由 360 张

• 1041 •

不同图像的多曝光序列构成,共计有 3 021 张图片作 为训练集,并且选择 SICE 的第二部分作为验证集, 同样的,该部分共包含 1 779 张不同曝光序列的图 片。每一份曝光序列都有其对应的参考图像。

实验在 NVIDIA 3060GPU 上使用 python 和 tensorflow 实现, batch-size 为 8, 使用 Adam 作为优 化器, 学习率设为 0.0001, 训练 200 个批次。损失函 数权重  $\lambda_1$ 、 $\lambda_2$  和  $\lambda_3$  设为 30、1 和 500。

#### 2.2 实验对比

为验证所提算法的有效性和泛化性,与6种不 同的增强算法在5个公开数据集上进行对比,包括 两种传统的算法 MSRCR-AL(multi-scale Retinex with color restoration + autolevels)<sup>[28]</sup>, LIME(lowlight image enhancement)<sup>[29]</sup>以及4种基于 CNN 的 算法 Zero-Dce<sup>[23]</sup>、ExcNe<sup>[24]</sup>、MBLLEN<sup>[16]</sup>、TBEFN (two-branch exposure-fusion Network)<sup>[30]</sup>。每个算 法使用带有推荐参数的公开源代码来复现结果。5 个公开数据集包括 SICE<sup>[27]</sup>、DICM<sup>[31]</sup>、MEF(multiexposure image fusion)<sup>[32]</sup>、LIME<sup>[29]</sup>和 VV,其中 SICE<sup>[27]</sup>含有专家修饰的参考图像,其余4个数据集 不含对应的参考图像。由于 LLIE-Net 是在含有参 考图像的 SICE<sup>[27]</sup> 数据集上进行训练,因此对其余 4 个无参考图像数据集的评价是验证所提算法泛化能 力的一种重要方法。在图 6-7 中展示了两种典型 场景(室内、室外人像)弱光图像增强的视觉比较。 对于具有挑战性的低照度图像,文中算法可以产生 自然的曝光和清晰的细节。

在图 6 的室内场景中, ExcNet<sup>[24]</sup>与 Zero-Dce<sup>[23]</sup> 不能清晰地恢复玫瑰花的细节。而 LIME<sup>[29]</sup>、 MSRCR+AL<sup>[28]</sup>、TBEFN<sup>[30]</sup>、MBLLEN<sup>[16]</sup>在恢复玫 瑰花细节的同时,LIME<sup>[29]</sup>出现了色彩偏差,MSRCR +AL<sup>[28]</sup>降低了色彩饱和度,TBEFN<sup>[30]</sup>出现了伪影, MBLLEN<sup>[16]</sup>和 ExcNet<sup>[24]</sup>使图中白色杯子出现了过 度增强的现象。在图 7 的户外人像场景中, Exc-Net<sup>[24]</sup> 与 Zero-Dce<sup>[23]</sup> 使人脸产生了过度曝光。 LIME<sup>[29]</sup>与 MSRCR+AL<sup>[28]</sup>尽管对黑暗区域的增强 效果最明显,但出现了严重的色彩偏差。而 TBE-FN<sup>[30]</sup>在增强黑暗场景时,与图6相同,引入了伪影, 且使黑暗区域的路灯出现了色彩畸变。本文算法对 黑暗区域的增强与 MBLLEN<sup>[16]</sup>相当,但对人脸细节 的保护优于 MBLLEN<sup>[16]</sup>。与其他算法在增强弱光 区域时,引入的过曝光、锐化过度以及增强不足相 比,本文方法能够很好地平衡图像在亮度与细节之 间的表现。

在定量评价中,对含有参考图像的 SICE<sup>[28]</sup> 数据 集,使用全参考图像质量评价指标峰值信噪比(peak signal to noise ratio, PSNR)和结构相似性(structural similarity index measure,SSIM)衡量增强图像 的质量。对不含参考图像的 VV、MEF<sup>[32]</sup>、 LIME<sup>[29]</sup>、DICM<sup>[31]</sup>数据集,使用无参考图像质量评 价指标 NIQE (natural image quality evaluator)<sup>[33]</sup>、 LOE (lightness order error)<sup>[34]</sup> 衡量增强图像的质 量。其中 PSNR 用于衡量两张图像之间的差异。 SSIM 用于衡量增强图像与参考图像之间的整体相 似性,是对增强图像在亮度、对比度、结构3个方面 的综合评价。NIQE<sup>[33]</sup>是一个用于衡量待测图像质 量的模型,该模型从一些简单并且高度规则的自然 景观中提取特征,并用一个多元高斯模型去拟合该 特征,用于衡量待测图像在多元高斯模型上的差异。 LOE<sup>[34]</sup>反映的是图像的自然保持能力,它能够检测 出因过度增强而导致的伪影和光晕现象,其值越小 说明图像具有更好的亮度顺序,看起来更自然,当亮 度顺序完全一致时,该值应为0。表1是不同算法在 SICE<sup>[27]</sup>数据集第二部分的相应指标。表 2 是不同算 法在 VV、MEF<sup>[32]</sup>、LIME<sup>[29]</sup>、DICM<sup>[31]</sup>4个数据集上 的相应指标。其中最好的结果加粗表示,第二好的 结果添加下划线表示,指标中 ↑ 表示该指标越大越 好,↓表示该指标越小越好。

从表1可以看出,由于LLIE-Curve 在增强对比度的同时,也会在一定程度上放大黑暗处的噪声,本 文算法在 PSNR 指标上略低于 TBEFN<sup>[30]</sup>算法。在 SSIM 指标上则优于其他6种算法,这得益于 LLIE-Net 并非直接实现图像到图像的端到端训练,而是基 于 LLIE-Curve 进行增强,在增强亮度的同时,也能 更好地保持图像整体结构。

从表 2 中可以看出, NIQE<sup>[33]</sup>和 LOE<sup>[34]</sup>在 4 个数据集上的平均指标取得了最优和次优,在单个数据集上,也取得了具有竞争力的结果。由于所选数据集涵盖人像、室内外场景、风景照以及不同程度照明条件的图像,因此表 2 结果证明了本文算法具有较强的泛化性能。在图 8 中,展示了所提算法在各种场景中的增强效果,如前所述,本文算法在增强暗部区域的同时,会很好地保持亮区域的细节,不会使亮区域产生过曝光现象,为了更好地展示增强效果,请放大观察图中的细节。

由于 LLIE-Curve 具有的简洁性以及 LLIE-Net 具有的轻量性,使得本文算法具有良好的计算效率。 表 3 是本文算法和其余算法在尺寸为 5472×3648× 3 的图片上的实际运行时间、权重大小、可训练参数



图 6 对典型室内场景弱光图像增强比较:

(a) 原图; (b) ExcNet; (c) LIME; (d) MBLLEN;

(e) MSRCR+AL; (f) TBEFN; (g) Zero-Dce; (h) Our

Fig. 6 Comparison of low-light image enhancement in typical indoor scenes:

(a) Original; (b) ExcNet; (c) LIME; (d) MBLLEN; (e) MSRCR+AL; (f) TBEFN; (g) Zero-Dce; (h) Our



图 7 对典型室外场景弱光图像增强比较:

(a) 原图; (b) ExcNet; (c) LIME; (d) MBLLEN;

(e) MSRCR+AL; (f) TBEFN; (g) Zero-Dce; (h) Our

Fig. 7 Comparison of low-light image enhancement in typical outdoor scenes: (a) Original;

(b) ExcNet; (c) LIME; (d) MBLLEN; (e) MSRCR+AL; (f) TBEFN; (g) Zero-Dce; (h) Our

• 1043 •

以及测试平台。量由于 MSRCR + AL<sup>[28]</sup> 和 LIME<sup>[29]</sup>受图片尺寸影响较大,将其下采样至(512, 512)进行增强后,再上采样至原始尺寸。从表 3 中 可以看出,传统算法 MSRCR+AL<sup>[28]</sup>、LIME<sup>[29]</sup>以及 含有全连接层的 ExcNet<sup>[24]</sup>算法复杂度较高,处理时 长均超过1s。全卷积层算法 Zero-Dce<sup>[23]</sup>、 MBLLEN<sup>[16]</sup>、以及 TBEFN<sup>[30]</sup>随着参数量的增加,处 理时长也随之增加。本文算法在计算效率各项指标 上均优于其他6种算法。

### 表 1 不同算法在 SICE 数据集上的 PSNR ↑、SSIM ↑ 指标 Tab. 1 PSNR ↑, SSIM ↑ indicators of different algorithms on SICE data set

Method	PSNR 🕇	SSIM 1
MSRCR+AL <sup>[28]</sup>	13.17	0.442
$LIME^{[29]}$	13.64	0.485
$ExcNet^{[24]}$	13.13	0.474
Zero-Dce <sup>[23]</sup>	12.18	0.462
MBLLEN <sup>[16]</sup>	14.07	0.471
TBEFN <sup>[30]</sup>	15.42	0.516
Our	14.93	0.54

#### 2.3 损失函数的消融研究

在图 9 中展示了本文构建的损失函数对最终增 强效果的视觉对比,以证明文中选择的每个损失函 数的重要性。图 9(b)中,当缺少曝光控制损失 L<sub>exp</sub> 时,无法对低光区域进行有效恢复。图 9(c)中,当缺 少对比度损失 L<sub>spe</sub>时,算法更倾向于增强图像整体亮 度,无法保留输入图像和增强图像相邻区域之间的 差异性。图 9(d)中,当缺少光照平滑损失 L<sub>tv</sub>时,将 丢失相邻区域的相关性,使最终恢复结果产生色彩 畸变和伪影。结果表明,文中使用的每个损失函数 对最终增强效果都起着重要的作用。

#### 2.4 YIQ 色域调整的消融研究

为展示本文算法在 YIQ 色域中的优势,在 RGB 色域中对 RGB 3 个通道运用 LLIE-Curve,并进行可 视化对比实验,图 10 为视觉对比效果图。从图 10 中 可以看出,无论在 RGB 还是 YIQ 色域中进行增强, 对于给定低照度图像在亮度方面都能有效地增强, 然而,从图中可以看出,RGB 3 通道之间由于存在强 耦合性,同时对 3 个通道进行增强会导致色偏存在, 使增强图像整体出现"泛白"的现象,导致 RGB 色域 增强的结果在对比度方面不如 YIQ 色域,如图 10 草 坪中的红色椅子所示。

	表 2	不同算法在 VV、MEF、LIME、DICM 数据集上的 NIQE ↓ /LOE ↓ 指标
Tab. 2	NIQE ↓ /L	DE  i  indicators of different algorithms on VV, MEF, LIME and DICM data sets

	Method							
		$MSRCR + AL^{[28]}$	LIME <sup>[29]</sup>	$ExcNet^{[24]}$	$\text{Zero-Dce}^{[23]}$	MBLLEN <sup>[16]</sup>	TBEFN <sup>[30]</sup>	Our
Data	LIME	4.28/0.048	5.36/0.144	4.29/0.088	5.18/0.109	4.66/0.171	<u>4.21</u> /0.118	4.08/0.031
	DICM	3.75/0.1 <b>57</b>	3.8/0.185	3.59/0.211	3.76/0.193	3.79/0.2	<b>3.22</b> / <u>0.172</u>	<u>3.51</u> /0.196
	MEF	3.67/0.058	3.9/0.091	3.67/0.077	3.85/ <u>0.047</u>	3.97/0.178	<b>3.36</b> /0.123	<u>3.46</u> /0.035
	VV	3.43/0.147	7.09/0.266	<u>3.21</u> /0.183	4.48/0.243	4.49/0.23	4.63/0.217	<b>3.05</b> / <u>0.172</u>
Ave	erage	3.78/0.103	5.03/0.172	<u>3.69</u> /0.14	4.31/0.148	4.22/0.195	3.85/0.158	<b>3.52</b> / <u>0.109</u>



图 8 本文算法在不同场景下的增强效果:(a) 街道;(b) 大厅;(c) 凉亭;(d) 山区;(e) 书房 Fig. 8 The enhancement effect of this algorithm in different scenarios:(a) The street; (b) The hall;(c) The pavilion;(d) The mountain;(e) The study

different algorithms on $5472 \times 3648 \times 3$ images					
Method	Run/s	Weight size/MB	Para/k	Platform	
MSRCR+AL <sup>[28]</sup>	1.83	_	_	Python(CPU)	
LIME <sup>[29]</sup>	16.4	_	_	Python(CPU)	
ExcNet <sup>[24]</sup>	2.6	200	52 593.2	Tensorflow(GPU)	
Zero-Dce <sup>[23]</sup>	0.31	0.33	79.4	Tensorflow(GPU)	
MBLLEN <sup>[16]</sup>	0.92	1.95	450.1	Tensorflow(GPU)	
TBEFN <sup>[30]</sup>	0.43	1.85	390	Tensorflow(GPU)	
Our	0.26	0.09	9.5	Tensorflow(GPU)	





图 9 各损失函数对最终增强效果的贡献:



Fig. 9 The contribution of each loss function to the final enhancement effect; (a) Input; (b) Without  $L_{exp}$ ; (c) Without  $L_{spa}$ ; (d) Without  $L_{tv}$ ; (e) Our



图 10 YIQ 色域调整优势的消融研究:(a) 原图; (b) RGB 色域增强; (c) YIQ 色域增强 Fig. 10 Ablation of YIQ gamut adjustment advantage:(a) Input; (b) RGB gamut enhancement; (c) YIQ gamut enhancement

#### 3 结 论

针对低照度图像在细节和对比度上的不足,提 出了一种基于无监督学习的图像增强算法,通过文 中设计的增强曲线以及构建的无参考损失函数实现 轻量级网络的无监督学习。不同于传统神经网络学 习图像到图像的映射,本文算法在Y通道上实现图 像到对应增强曲线的映射。构建的轻量级网络 LLIE-Net不仅具有更快的速度,同时具有更好的增 强效果,在增强弱光区域的同时,不使高光区域产生 过曝光现象。与其他 6 种算法在 5 个公开数据集上 的实验结果表明,本文算法在计算效率最高和权重 最小的情形下,在图像质量评价指标 PSNR、SSIM、 NIQE、LOE 和视觉效果上都取得了具有竞争力的 结果。

## 参考文献:

- [1] KURMI Y, CHAURASIA V. Content-based image retrieval algorithm for nuclei segmentation in histopathology images[J]. Multimedia Tools and Applications, 2021, 80(2): 3017-3037.
- [2] ZHU X, LYU S, Wang X, et al. TPH-YOLOv5: improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios [C]//IEEE/CVF International Conference on Computer Vision, October 11-17, 2021, Montreal, Canada. New York; IEEE, 2021; 2778-2788.
- [3] LIU Z C, WANG D W, LIU Y, et al. Adaptive correction algorithm for image uneven illumination based on two-dimensional gamma function[J]. Journal of Beijing Institute of Technology, 2016,36(5):191-196.
  刘志成, 王殿伟, 刘颖, 等. 基于二维伽马函数的光照不均匀图像自适应校正算法[J]. 北京理工大学学报, 2016,36(2):191-196.
- [4] LIGF, LIGJ, HANGL, et al. Bright channel prior retinex illumination compensation for low-light images [J]. Systems Engineering and Electronic Technology, 2018, 26 (5):1191-1200.

李赓飞,李桂菊,韩广良,等.亮通道先验 Retinex 对低 照度图像的光照补偿[J].光学精密工程,2018,26(5): 1191-1200.

WANG D W, WANG J, XU Z J, et al. An adaptive correction algorithm for images with uneven illumination [J].
 Systems Engineering and Electronic Technology, 2017, 39 (6):1383-1390.

王殿伟,王晶,许志杰,等.一种光照不均匀图像的自适 应校正算法[J].系统工程与电子技术,2017,39(6): 1383-1390.

- [6] WANG S H, ZHENG J, HU H M, et al. Naturalness preserved enhancement algorithm for non-uniform illumination images [J]. IEEE Transactions on Image Process, 2013,22(9):3538-3548.
- [7] FU X Y,ZENG D L,HUANG Y,et al. A weighted variational model for simultaneous reflectance and illumination estimation[C]//2016 IEEE Conference on Copputer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV,USA. New York: IEEE, 2016: 2782-2790.

- [8] ABUDURUSULI A, AILIMINUER A. Color image enhancement algorithm based on wavelet transform and histogram equalization [J]. Journal of Optoelectronics Laser, 2021,32(1):14-18.
  阿ト杜如苏力・奥斯曼,艾力米努・阿布力江.小波 变换和直方图均衡化的保持色调不变彩色图像增强算 法[J].光电子・激光,2021,32(1):14-18.
- [9] 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.
- [10] WEI C.WANG W.YANG W.et al. Deep retinex decomposition for low-light enhancement [EB/OL]. (2018-08-14) [2022-08-10]. https://arxiv.org/abs/1808.04560.
- ZHAO Z, XIONG B, WANG L, et al. RetinexDIP: A unified deep framework for low-light image enhancement [J].
   IEEE Transactions on Circuits and Systems for Video Technology, 2021, 32(3):1076-1088.
- [12] ZHANG Y, ZHANG J, GUO X. Kindling the darkness: A practical low-light image enhancer[C]//27th ACM International Conference on Multimedia, October 21-25, 2019, Nice, France. New York: ACM, 2019:1632-1640.
- [13] YANG W, WANG W, HUANG H, et al. Sparse gradient regularized deep retinex network for robust low-light image enhancement[J]. IEEE Transactions on Image Processing, 2021, 30: 2072-2086.
- [14] FAN M, ANG W, YANG W, et al. Integrating semantic segmentation and retinex model for low-light image enhancement[C]//28th ACM International Conference on Multimedia, October 12-16, 2020, Seattle WA, USA. New York: ACM, 2020:2317-2325.
- LV F, LI Y, LU F. Attention guided low-light image enhancement with a large scale low-light simulation dataset
   [J]. International Journal of Computer Vision, 2021, 129 (7):2175-2193.
- [16] LV F,LU F,WU J,et al. MBLLEN:Low-light image/video enhancement using CNNs[C]//The British Machine Vision Conference, September 3-6, 2018, Newcastle, UK. Durham; BMVA Press, 2018, 220(1):4.
- WANG R, ZHANG Q, FU C W, et al. Underexposed photo enhancement using deep illumination estimation [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 15-20, 2019, Long Beach, CA, USA. New York: IEEE, 2019:6849-6857.
- [18] YU R,LIU W,ZHANG Y, et al. DeepExposure: learning to expose photos with asynchronously reinforced adversarial learning[C]//32nd International Conference on Neural Information Processing Systems, December 3-8, 2018, Montréal, Canada. Red Hook, NY: Curran Associates Inc.

2018:2153-2163.

- [19] 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.
- [20] YANG W, WANG S, FANG Y, et al. From fidelity to perceptual quality: A semi-supervised approach for low-light image enhancement[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 13-19, 2020, Seattle, WA, USA. New York: IEEE, 2020: 3063-3072.
- [21] LI J, FENG X, HUA Z. Low-light image enhancement via progressive-recursive network[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 31 (11):4227-4240.
- [22] WANG L W,LIU Z S,SIU W C, et al. Lightening network for low-light image enhancement [J]. IEEE Transactions on Image Processing, 2020, 29:7984-7996.
- [23] LI C.GUO C.LOY C C. Learning to enhance low-light image via zero-reference deep curve estimation [J]. IEEE Transactions on Software Engineering, 2021, 44(8): 4225-4238.
- [24] ZHANG L,ZHANG L,LIU X,et al. Zero-shot restoration of back-lit images using deep internal learning [C]//27th ACM International Conference on Multimedia,October 21-25, 2019, Nice, France. New York: ACM, 2019: 1623-1631.
- [25] JIA Y H. Digital image processing[M]. 3rd ed. Wuhan: Wuhan University Press, 2015:197-206.
  贾永红.数字图像处理[M].3版.武汉:武汉大学出版 社,2015:197-206.
- [26] JIANG Z, LI H, LIU L, et al. A switched view of retinex: deep self-regularized low-light image enhancement[J]. Neurocomputing, 2021, 454:361-372.

- [27] CAI J, GU S, ZHANG L. Learning a deep single image contrast enhancer from multi-exposure images[J]. IEEE Transactions on Image Processing, 2018, 27 (4): 2049-2062.
- [28] JIANG B, WOODELL G A, JOBSON D J. Novel multi-scale retinex with color restoration on graphics processing unit [J]. Journal of Real-Time Image Processing, 2015, 10 (2):239-253.
- [29] GUO X,LI Y,LING H. LIME: Low-light image enhancement via illumination map estimation [J]. IEEE Transactions on Image Processing, 2016, 26(2):982-993.
- [30] LU K, ZHANG L. TBEFN: A two-branch exposure-fusion network for low-light image enhancement [J]. IEEE Transactions on Multimedia, 2020, 23: 4093-4105.
- 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.
- [32] MA K, ZENG K, WANG Z. Perceptual quality assessment for multi-exposure image fusion[J]. IEEE Transactions on Image Processing. 2015, 24(11): 3345-3356.
- [33] MITTAL A, SOUNDARAJAN R, BOVIK A C. Making a "completely blind" image quality analyzer[J]. IEEE Signal Processing Letters, 2012, 20(3): 209-212.
- [34] YING Z, LI G, GAO W. A bio-inspired multi-exposure fusion framework for low-light image enhancement [EB/ OL]. (2017-11-02) [2022-08-10]. https://arxiv.org/ abs/1711.00591.

#### 作者简介:

**苏 赋** (1973-),女,博士,副教授,硕士生导师,主要从事信号与信息处理的模式识别、目标检测、图像检索等研究.