

基于多尺度深度曲线估计的微光图像增强算法

郭泓达^{1*}, 董秀成¹, 郑永康², 睢雅玲¹, 张党成¹¹西华大学电气与电子信息学院, 四川 成都 610039;²国网四川省电力公司电力科学研究院, 四川 成都 610041

摘要 针对微光图像增强算法存在泛化能力较差的问题, 提出一种基于多尺度深度曲线估计的微光图像增强算法, 通过学习不同尺度微光图像与正常图像之间的映射关系实现微光图像增强。参数估计网络包括 3 个尺度的编码器和 1 个融合模块, 可以高效直接地学习微光图像。每个编码器由级联的卷积层和池化层组成, 具有特征层重复使用的优点, 提高了计算效率。为增强对图像亮度的约束, 提出一种亮通道损失函数。基于 LIME 数据集、LOL 数据集和 DICM 数据集, 对所提方法与其他 6 种先进算法进行对比。实验结果表明, 所提方法能够得到色彩鲜艳、亮度适中、细节丰富的增强图像, 在主观视觉效果和客观定量评价上均优于其他算法。

关键词 图像增强; 多尺度; 深度曲线估计; 无参考损失函数; 深度神经网络

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP231997

Low-Light Image Enhancement Algorithm Based on Multiscale Depth Curve Estimation

Guo Hongda^{1*}, Dong Xiucheng¹, Zheng Yongkang², Ju Yaling¹, Zhang Dangcheng¹¹School of Electrical Engineering and Electronic Information, Xihua University,

Chengdu 610039, Sichuan, China;

²Sichuan Electric Power Research Institute, State Grid, Chengdu 610041, Sichuan, China

Abstract In this study, a low-light image enhancement algorithm based on multiscale depth curve estimation is proposed to address the poor generalization ability of existing algorithms. Low-light image enhancement is achieved by learning the mapping relationship between normal images and low-light images with different scales. The parameter estimation network comprises three encoders with different scales and a fusion module, facilitating the efficient and direct learning for low-light images. Furthermore, each encoder comprises cascaded convolutional and pooling layers, thereby facilitating the reuse of feature layers and improving computational efficiency. To enhance the constraint on image brightness, a bright channel loss function is proposed. The proposed method is validated against six state-of-the-art algorithms on the LIME, LOL, and DICM datasets. Experimental results show that enhanced images with vibrant colors, moderate brightness, and significant details can be obtained using the proposed method, outperforming other conventional algorithms in subjective visual effects and objective quantitative evaluations.

Key words image enhancement; multi scale; deep curve estimation; no-reference loss function; deep neural network

1 引言

在低照度或逆光条件下获取的图像会因为光源不足而存在亮度低、对比度低等情况, 这种图像称为微光图像^[1]。图像质量的下降会对图像后续的观察、分析和处理等应用产生不利影响。因此对微光图像增强进行研究具有重要意义^[2]。微光图像增强算法大体上可

以分为基于分布映射的方法、基于模型优化的方法和基于深度学习的方法^[3]。

代表性的基于分布映射的方法包括基于直方图均衡化和基于 S 形曲线的方法。直方图均衡化算法通过概率密度函数拉伸图像灰度直方图, 从而使得图像灰度近似分布, 实现了图像动态范围的扩展和图像对比度的增加。基于 S 形曲线的方法最常用伽马校正, 在

收稿日期: 2023-08-28; 修回日期: 2023-09-17; 录用日期: 2023-10-09; 网络首发日期: 2023-11-07

基金项目: 国家自然科学基金(11872069)、四川省科技厅项目(2021ZYD0034)、教育部“春晖计划”科研项目(Z2017076)

通信作者: *476642413@qq.com

此基础上还出现了一些改进算法。然而,基于直方图均衡化和基于S形曲线的方法普遍存在细节丢失和曝光不均匀等现象。

基于模型优化的方法主要包括:基于Retinex的优化算法,该算法从原始图像中去除光照分量的影响,从而求解出物体本身的颜色特征,最终达到图像增强的目的^[4-8]; Low-light image enhancement via illumination mapping estimation(LIME)首先计算低照度图像RGB三通道的最大值,然后通过先验结构确定光照图像,并通过伽马校正算法对光照图像进行校正,最终获得了具有全局平滑和边缘清晰的良好曝光图像^[9]; Adaptive unfolding total variation network for low-light image enhancement(UTVNet)通过学习平衡参数来近似实际SRGB低照度图像中的噪声水平,并通过学习噪声水平图来提供平滑性约束和保真度约束^[10]。基于模型优化的方法非常依赖于先验正则项的设计,而且表现较好的基于模型优化的方法大多需要进行迭代计算。

基于深度学习的方法包括监督学习、强化学习、无监督学习、零参考学习和半监督学习等多种训练方法^[11]。陈清江等^[13]利用双分支金字塔网络实现对微光图像的增强^[12],为提高图像的增强效果,又在多通道融合了注意力机制。Lü等^[14]提出了一种名为MBLLEN(low-light image/video enhancement using CNNs)的端到端多分支低照度图像增强网络解决方案,该方案可以通过特征提取、图像增强和融合模块进行训练,提取出有效的特征表示。Deep Retinex decomposition for low-light enhancement(Retinex-Net)中:分解模型用于将输入图像分解为反射分量和光照分量;调整模型主要用于减少低照度图像的反射分量中的噪声,并对光照分量进行校正;重建模型则用于根据增强后的结果恢复出正常的光照图像^[15]。Kindling the darkness(KinD)由图层分解、反射率恢复和光照度调整模块结合Retinex理论实现图像增强^[16],此外研究人员为解决视觉缺陷问题,引入了多尺度光照注意力模块,形成了KinD⁺⁺算法^[17]。Retinex-based deep unfolding network for low-light image enhancement(URetinex-Net)对Retinex网络进行了深度展开^[18]。此外,还有一些其他方法用于Retinex结合的网络,如DeepUPE^[19]、渐进式Retinex网络^[20]和结合语义分割的Retinex网络^[21]等。在图像恢复与增强方面:Jiang等^[22]基于深度学习提出了简单有效的无监督生成对抗网络,即deep light enhancement without paired supervision(EnlightenGAN); Ma等^[23]在toward fast, flexible, and robust low-light image enhancement(TFR)中提出了新的自校准照明学习框架;Guo等^[24]采用深度学习技术,通过无参数卷积方法来消除噪声和伪影,提出了实时低照度光照增强算法,即zero-reference deep curve estimation for low-light image enhancement(Zero-DCE),还提出了一个快

速和轻量的版本,称为Zero-DCE⁺⁺^[25]。这些方法有效解决了神经网络训练过程中泛化能力不足的问题。总体而言:基于深度学习的方法中监督学习的实现相对容易,但是基于合成数据集进行训练可能会使得神经网络的泛化性能不足;相比之下,无监督学习和半监督学习方法需要克服模型训练稳定性方面的挑战;而强化学习方法需要设计复杂的奖励机制;对于零参考学习方法,设计非参考损失函数是一项具有难度的任务。

为此,本文提出了一种基于多尺度深度曲线估计的微光图像增强算法,该算法通过学习不同尺度下的深度曲线映射关系,实现对微光图像的增强。在模型建立的过程中,首先对图像进行两次降采样,然后利用参数估计模块得到深度曲线的参数,利用参数还原出不同尺度的恢复图像,再通过上采样和多尺度融合得到增强后的结果,最后通过迭代计算,得到理想的增强图像。为了准确提取出图像的多尺度特征,所提方法将在不同分辨率下进行处理。此外,为了提高对图像亮度的约束能力,设计了亮通道损失函数,避免增强图像出现曝光不足或过度曝光的情况。为了解决微光图像增强普遍存在的噪声放大问题,在测试过程中加入了可选择的噪声细化模块,其可以在有需要的情况下对图像进行去噪处理。

2 理论模型

低照度图像增强可以通过照片编辑软件中的曲线调整来实现,其中自适应曲线参数完全取决于输入图像。对于具有挑战性的低光照图像,最优曲线往往具有非常高的阶数。Zero-DCE^[24]提出,可以通过低阶曲线的迭代计算逼近最优的高阶曲线。在这项工作中,在每个步骤中应用二阶光线增强曲线,以实现增强。该曲线的表达式为

$$\text{LE}[I(x); A(x)] = I(x) + A(x)I(x)[1 - I(x)], \quad (1)$$

式中: I 表示输入的低光照图像; x 表示像素坐标;函数 $\text{LE}[I(x); A(x)]$ 表示在 x 处输出的增强后的图像; $A(x)$ 是学习到的特征参数,其大小与图像相同。可以多次应用光线增强来逐步接近更高阶的光线增强曲线。在第 t 步($t \geq 1$)中,得到的增强输出为

$$\text{LE}_t(x) = \text{LE}_{t-1}(x) + A_t(x)\text{LE}_{t-1}(x) \times [1 - \text{LE}_{t-1}(x)], \quad (2)$$

这样低照度图像增强任务就可以变成求取特征参数的任务,找到在每一步最优的像素参数映射 $A_t(x)$ 。因此,为了能求出更合适的参数,提出了能够提取图像不同层次特征的多尺度参数估计模块。

3 所提算法内容

3.1 网络模型设计

基于微光图像恢复和深度曲线估计存在的映射关

系,提出了一种基于多尺度深度曲线估计的图像增强网络模型。该网络主要由多尺度参数估计模块、迭代增强模块、可选的噪声细化模块组成。在该模型中,低照度图像首先经过参数估计模块,输出对应的参数

图;然后将得到的参数图代入增强模块,对输入图像所有像素的RGB通道进行映射和迭代计算,以获得增强后的图像;在测试过程中,还可以利用可选的噪声细化模块进行去噪处理。整体网络框架如图 1 所示。

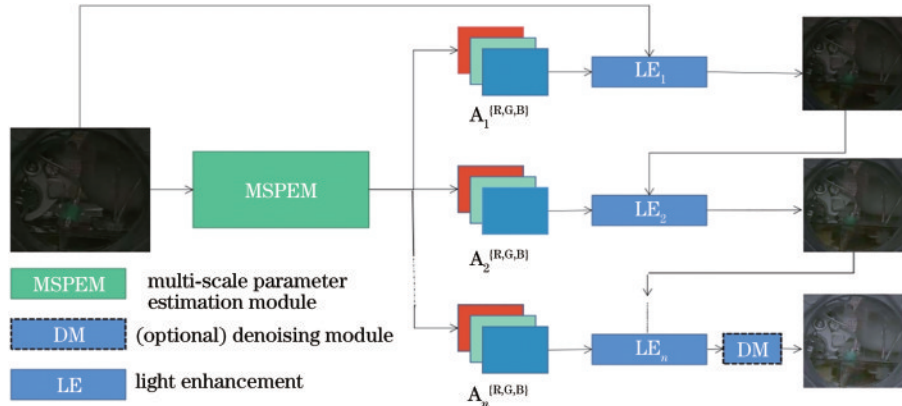


图 1 整体网络框架

Fig. 1 Overall network framework

多尺度参数估计模块(PEM)设计了 3 条路径,采用了高斯金字塔结构将网络扩展为多尺度,提取不同尺度的特征。首先,将输入图像的尺寸调整至 256×256 ;再将输入的微光图像下采样到另外两个尺度,即 $1/2$ 和 $1/4$,分别构建一个参数估计模块,这两个模块的权重不共

享;此外,将从粗略尺度估计的参数图融合到原始尺度;接着,利用一层卷积和 BReLU 函数将参数图调整为 24 通道,并通过 Tanh 函数将参数图映射到 -1 到 1 之间;最后,采用 Split 函数将参数图分解为 8 个 3 通道的参数图,以供增强模块使用。多尺度参数估计模块如图 2 所示。

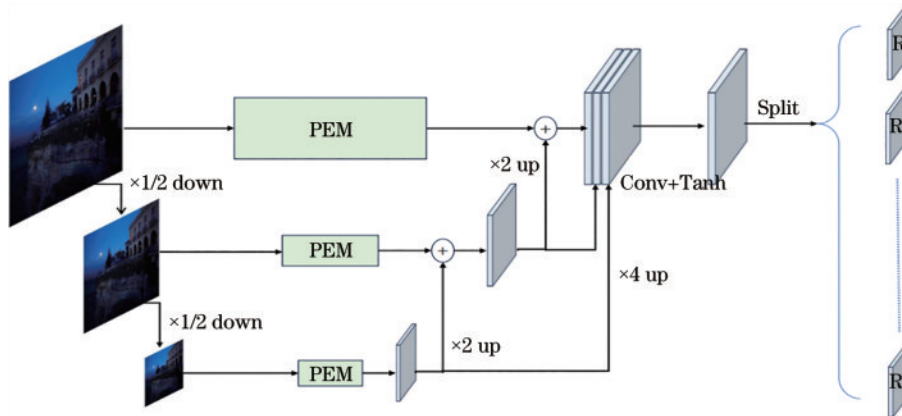


图 2 多尺度参数估计模块网络框架

Fig. 2 Network framework of multi-scale parameter estimation module

其中,单尺度参数估计模块采用了 7 层卷积神经网络(CNN)结构,通过融合不同尺寸的滤波器来形成多尺度特征。每个卷积块仅由 3×3 的卷积和 BReLU 构成,其中 BReLU 能够保持双向约束和局部线性。为了不破坏邻近像素间的关系,在参数估计过程中舍弃了下采样和批归一化(BN)层。同时,为了充分保留不同尺度的信息,将不同层的网络拼接在一起,其中 Concat1 层将 Conv4 和 Conv3 的特征拼接在一起。同样,Concat2 将 Conv5、Conv3 和 Conv2 的特征拼接在一起,Concat3 将 Conv6、Conv3、Conv2 和 Conv1 拼接在一起。这种方法有助于提高网络精度和充分利用不同尺度的特征。单尺度参数估计模块结构如图 3

所示。

3.2 噪声细化模块

在低照度图像增强操作后,图像中可能出现更加明显的噪声,但是目前很少有方法将明确的去噪处理融合到增强过程中。为此,本文在测试框架中提出了一个可选的去噪模块,用于增强测试集结果。总体而言,现有的很多图像去噪方法都可以作为去噪模块的好选择。鉴于 BM3D 具有竞争力的性能,选择使用 BM3D 作为去噪块。需要注意的是,在本文框架中,去噪块是完全可选的,因为它们没有参与训练过程。可以选择在测试阶段的每个步骤中使用 BM3D 来去噪增强后的图像,这种模式不仅可以使测试结果更优,同




图3 单尺度参数估计模块网络框架

Fig. 3 Network framework of single-scale parameter estimation module

时也允许更大的灵活性,也可以使用其他去噪方法,还可以添加处理多种不同类型退化的模块,而不仅仅是去噪。

3.3 无参考损失函数

为了实现零参考学习,采用一组可微分的非参考损失函数,用于评估增强图像的质量。设计一个亮通道曝光损失函数 L_{bri} 来控制图像的曝光水平。亮通道曝光损失函数衡量了局部区域的亮通道平均值与适宜曝光水平 Q 之间的差距。按照亮通道先验,理想的曝光图像经过亮通道处理后,会拥有较高的像素强度。通过将增强后的图像亮通道值约束在理想区域内,可以有效控制图像的曝光结果。实验发现,取 Q 值为 0.65 时在多数情况下可以得到较为理想的效果。亮通道曝光损失函数表示为

$$L_{bri} = \frac{1}{N} \sum_{i=1}^N |B_i - Q|, \quad (3)$$

式中: N 代表大小为 9×9 且不重叠的图像窗口数量; B 表示亮通道图像中窗口内像素强度的平均值; N 是迭代次数。为避免邻近像素之间亮度的激烈和尖锐变化,采用照明平滑度损失函数 L_{tva} 来控制每个状态下的曲线参数映射 A , 以达到图像光照平滑的目的。该损失函数使每个状态下的光照曲线尽可能平滑,防止出现不自然的锐利曲线和卷积痕迹,计算公式为

$$L_{tva} = \frac{1}{N} \sum_{i=1}^N \sum_{c \in \zeta} (|\nabla_x A_i^c + \nabla_y A_i^c|)^2, \quad \zeta = \{R, G, B\}, \quad (4)$$

式中: ∇_x 和 ∇_y 分别表示水平和垂直梯度运算。遵循 Gray-World 颜色恒常性假设,即整幅图像中每个通道中的颜色平均为灰色,采用颜色恒常性损失函数 L_{col} 修正增强图像中的潜在色彩偏差并调整通道之间的关系。通过增强后的图像灰度均衡化和颜色平衡化,利用颜色恒常性损失函数,可以使图像色彩更加真实,有助于提高视觉效果。 L_{col} 的计算过程为

$$L_{col} = \sum_{(p,q) \in \epsilon} (J^p - J^q)^2, \quad \epsilon = \{(R, G), (R, B), (G, B)\}, \quad (5)$$

式中: J^p 表示增强后图像中 p 通道的平均强度值; (p, q) 代表通道对。为了保留原始图像与增强后图像之间相邻区域之间的差异,来促进增强后图像的空间一致性,引入空间一致性损失。具体而言,就是通过计

算原始图像与增强后图像中相邻区域的距离差,来指导模型优化,从而尽可能保留原始图像的结构和空间排列方式,使得增强后的图像具有更好的视觉效果。空间一致性损失 L_{spa} 的计算过程为

$$L_{spa} = \frac{1}{K} \sum_{i=1}^K \sum_{j \in \Omega(i)} (|Y_i - Y_j| - |I_i - I_j|)^2, \quad (6)$$

式中: K 表示窗口区域的数量; $\Omega(i)$ 表示以区域 i 为中心的 4 个相邻区域(上、下、左、右); Y 表示增强后图像中窗口区域的平均强度值; I 表示原始图像中窗口区域的平均强度值。综上所述,总损失函数的表达式为

$$L_{total} = W_{bri} L_{bri} + W_{spa} L_{spa} + W_{tva} L_{tva} + W_{col} L_{col}, \quad (7)$$

式中: W_{bri} 、 W_{spa} 、 W_{tva} 、 W_{col} 为可调节权重。

4 实验及结果分析

4.1 实验环境及数据集

本次实验使用了 4 个数据集: Zero-DCE 训练数据集^[24]、DICM 数据集^[26]、LIME 数据集^[9] 和 LOL 数据集^[16]。在训练过程中,为了充分发挥宽动态范围调整的能力,将低光和过度曝光的图像混合纳入训练集中,共使用了 2002 张图像。为了避免网络在处理图像时出现图像大小不一致的问题,将所有训练图像的大小统一调整为 512×512 , 这样做既可以使网络的推理速度更快,也可以提高网络的精度。

使用 PyTorch 框架在 RTX3090 GPU 上实现了所提图像增强框架。在实现过程中,将 batch size 设为 16, 并将每个层的滤波器权重初始化为标准的零均值和 0.02 标准差的高斯函数,而偏差则被初始化为一个常数。为了实现更好的网络优化,采用 Adam 优化器,并使用固定的学习率 10^{-4} 。为了平衡损失的规模,将 W_{bri} 、 W_{spa} 、 W_{tva} 和 W_{col} 分别设置为 0.5、5、1 和 200。

4.2 定性比较

对所提基于多尺度深度曲线估计的照度图像增强算法与具有代表性的低照度图像增强算法进行比较,这些算法包括传统低照度图像增强算法(LIME^[9]),以及基于深度学习的低照度图像增强算法(Zero-DCE^[24]、Zero-DCE⁺⁺^[25]、KinD⁺⁺^[17]、TFR^[23]和URetInex-Net^[18]),结果对比如图 4~6 所示。

在第一组对比结果中,所提算法增强后的图像能够更好地保持黑夜天空的特征。在第二组对比结果



图 4 第一组图像对比结果。(a)低照度图像;(b)Zero-DCE;(c)Zero-DCE⁺⁺;(d)KinD⁺⁺;(e)LIME;(f)URetinex-Net;(g)TFR;(h)所提算法

Fig. 4 Comparison results of the first set of images. (a) Low-light image; (b) Zero-DCE; (c) Zero-DCE⁺⁺; (d) KinD⁺⁺; (e) LIME; (f) URetinex-Net; (g) TFR; (h) proposed method




图 5 第二组图像对比结果。(a)低照度图像;(b)Zero-DCE;(c)Zero-DCE⁺⁺;(d)KinD⁺⁺;(e)LIME;(f)URetinex-Net;(g)TFR;(h)所提算法

Fig. 5 Comparison results of the second set of images. (a) Low-light image; (b) Zero-DCE; (c) Zero-DCE⁺⁺; (d) KinD⁺⁺; (e) LIME; (f) URetinex-Net; (g) TFR; (h) proposed method




图 6 第三组图像对比结果。(a)低照度图像;(b)Zero-DCE;(c)Zero-DCE⁺⁺;(d)KinD⁺⁺;(e)LIME;(f)URetinex-Net;(g)TFR;(h)所提算法

Fig. 6 Comparison results of the third set of images. (a) Low-light image; (b) Zero-DCE; (c) Zero-DCE⁺⁺; (d) KinD⁺⁺; (e) LIME; (f) URetinex-Net; (g) TFR; (h) proposed method

中, TFR、Zero-DCE 和 Zero-DCE⁺⁺处理的图像中在天花板部分存在曝光不足。在第三组对比结果中, TFR 处理的图像存在过度曝光, URetinex-Net 和 Zero-DCE⁺⁺处理的图像中在低亮度处存在细节丢失。综上所述, 所提算法在黑夜天空特征保留和曝光恢复程度方面表现较好, 具有更好的视觉效果。

4.3 定量比较

为了验证所提基于多尺度深度曲线估计的照度图

像增强算法的效果, 在实验部分引入了两种全参考评价指标结构相似度 (SSIM) 和峰值信噪比 (PSNR) 以及无参考评价指标 NIQE, 对图像增强结果进行了分析比较, 具体结果如表 1 和表 2 所示, 其中最优结果以加粗形式表示。

其中用于测试全参考评价指标的图像素材来自于 LOL 数据集, 用于测试无参考评价指标的图像素材来自于 DICM 和 LIME 数据集。对实验结果进行分析比

表1 不同方法的全参考图像质量评价结果

Table 1 Full reference image quality evaluation results of different methods

Method	SSIM	PSNR
Zero-DCE	0.6388	14.6304
Zero-DCE ⁺⁺	0.6532	14.7195
KinD ⁺⁺	0.7133	15.3417
LIME	0.6992	14.1325
URetinex-Net	0.7297	15.6845
TFR	0.7213	15.5998
Proposed method	0.7295	15.7043

表2 两组测试集中不同方法的NIQE结果

Table 2 NIQE results of different methods in two test sets

Method	DICM dataset	LIME dataset
Zero-DCE	3.7125	4.7037
Zero-DCE ⁺⁺	3.8037	4.5185
KinD ⁺⁺	3.5103	4.4169
LIME	3.9451	5.0280
URetinex-Net	3.1157	4.2377
TFR	3.1455	4.5350
Proposed method	3.2025	4.2157

较,可以得出结论:所提基于多尺度深度曲线估计的低照度图像增强算法在图像增强方面表现较好,整体上各项指标均优于其他方法。具体而言,所提算法能够

有效提高图像的质量,表现在PSNR更高、均值方差更小、SSIM更大、结构相似性更高、NIQE更小。通过实验比较可以得出,使用所提算法增强的图像更接近自然图像,所提算法能够更好地恢复图像的细节,提高图像的亮度和对比度,达到了较好的图像增强效果。

4.4 消融实验

为了展示基于多尺度深度曲线估计的低照度图像增强算法中各个组成部分的有效性,进行多项消融实验。

1) 验证各损失函数的贡献

对所提亮通道损失函数与Zero-DCE中使用的曝光控制损失函数进行比较,通过SSIM和PSNR分析图像增强效果,结果如表3所示。其中Zero-DCE-bri是用亮通道损失函数代替Zero-DCE中使用的曝光控制损失函数得到的。还在训练过程中设置了不同的损失函数组合实验,对各个损失函数的贡献进行了验证,具体实验结果如图7所示,对于实验中各个模型使用的不同损失函数组合,详见表4。

表3 亮通道损失函数与曝光控制损失函数的对比结果

Table 3 Comparison results of bright channel loss function and exposure control loss function

Method	SSIM	PSNR
Zero-DCE	0.6388	14.6304
Zero-DCE-bri	0.6442	14.6413




图7 损失函数消融实验。(a)低照度图像;(b)所提算法;(c)模型A;(d)模型B;(e)模型C;(f)模型D

Fig. 7 Loss function ablation experiment. (a) Low-light image; (b) proposed method; (c) model A; (d) model B; (e) model C; (f) model D

从图7可以看出:去除空间一致性损失 L_{spa} 会使得增强图像对比度变低,从而凸显出损失 L_{spa} 在保持输入图像和增强图像之间邻近区域的差异性方面的

重要性;去除亮通道曝光损失函数 L_{bri} 无法恢复低光照区域,且图像整体偏暗;当舍去颜色恒常性损失 L_{col} 时,严重的颜色偏移问题会出现,因为忽略了三

表 4 各模型的损失函数

Table 4 Loss function of each model

Loss	Model A	Model B	Model C	Model D
L_{bri}	×	✓	✓	✓
L_{spa}	✓	×	✓	✓
L_{tvA}	✓	✓	×	✓
L_{col}	✓	✓	✓	×

个通道之间的关系;最后,去除照明平滑度损失函数

L_{tvA} 会破坏相邻区域之间的相关性,导致明显的伪影。

2) 多尺度参数估计模块的效果

为了验证多尺度参数估计模块的必要性,设计了一组不同尺度下的消融实验,实验结果如图 8 所示。从实验结果可以看出,随着图像尺度的增加,图像增强效果逐渐优化,包括过曝光校正、细节逐渐增强及光晕逐渐缩小等。



图 8 多尺度参数估计模块消融实验。(a)单尺度;(b)双尺度;(c)三尺度

Fig. 8 Ablation experiment of multi-scale parameter estimation module. (a) Single scale; (b) two scales; (c) three scales

3) 噪声细化模块的效果

为验证可选择的噪声细化模块的作用,对噪声细化前和处理后的图像进行分析,结果如图 9 所示。从

图 9 可以看出,经过噪声细化后的图像更平滑,当然相应地也会存在一些边缘细节丢失的情况,所以可以根据实际需求选择在测试时是否添加该模块。



图 9 噪声细化模块消融实验。(a)~(c)无噪声细化的结果图;(d)~(f)选择噪声细化的结果图

Fig. 9 Ablation experiment of noise refinement module. (a)~(c) Results without using noise refinement; (d)~(f) results of selecting noise refinement

5 结 论

针对目前微光图像增强算法存在泛化不足、颜色失真和噪声放大等问题,提出了一种基于多尺度深度曲线估计的图像增强算法。其主要思想是:通过多尺度学习微光图像和正常图像间的映射关系,通过融合和迭代计算对微光图像进行调整,以达到图像增强的目的。提出了多尺度参数估计网络结构,能够得到不同层次的微光图像特征,其中的单尺度参数估计网络具有轻量化的优点。提出了亮通道损失函数,可实现对增强结果亮度的约束,解决图像过曝光或欠曝光的问题。在测试过程中加入可选择的噪声细化模块,解决在增强过程中出现的噪声放大问题。

实验结果证明,亮通道损失函数更好地控制了增强图像的曝光度,多尺度参数估计网络使得增强效果不断得到优化,噪声细化模块使增强图像更加平滑。同时客观评价指标 PSNR、SSIM 和 NIQE 也表明了所提算法的优越性。总的来说,所提算法在保证模块运行速度的同时,克服了微光图像增强算法中存在的曝光不稳定、颜色失真和噪声放大等缺陷,也为微光图像

增强算法的研究提供了新的方案。

参 考 文 献

- [1] 刘伟强, 赵鹏, 宋向迎. 基于多尺度融合卷积神经网络的微光图像增强算法[J]. 激光与光电子学进展, 2023, 60(14): 1410012.
Liu W Q, Zhao P, Song X Y. Low-light image enhancement algorithm based on multi-scale concat convolutional neural network[J]. Laser & Optoelectronics Progress, 2023, 60(14): 1410012.
- [2] 张雅荔, 丁少博, 李昌禄, 等. 基于同态频分聚合的低照度图像增强算法[J]. 激光与光电子学进展, 2023, 60(14): 1410009.
Zhang Y L, Ding S B, Li C L, et al. Low-light image-enhancement algorithm based on homomorphic frequency division aggregation[J]. Laser & Optoelectronics Progress, 2023, 60(14): 1410009.
- [3] 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.
Zheng S S, Wei W X, Xu C. Low illumination image enhancement algorithm combining total variation and gamma[J]. Laser & Optoelectronics Progress, 2023, 60(12): 1210022.

- (12): 1210022.
- [4] 游达章, 陶加涛, 张业鹏, 等. 基于灰度变换及改进 Retinex 的低照度图像增强[J]. 红外技术, 2023, 45(2): 161-170.
You D Z, Tao J T, Zhang Y P, et al. Low-light image enhancement based on gray scale transformation and improved Retinex[J]. Infrared Technology, 2023, 45(2): 161-170.
- [5] 王奎, 黄福珍. 基于光照补偿的 HSV 空间多尺度 Retinex 图像增强[J]. 激光与光电子学进展, 2022, 59(10): 1010004.
Wang K, Huang F Z. Multiscale Retinex image enhancement in HSV space based on illumination compensation[J]. Laser & Optoelectronics Progress, 2022, 59(10): 1010004.
- [6] Xu J, Hou Y K, Ren D W, et al. STAR: a structure and texture aware Retinex model[J]. IEEE Transactions on Image Processing, 2020, 29: 5022-5037.
- [7] Shen L R, Ma Z Y, Er M J, et al. Blind adaptive structure-preserving imaging enhancement for low-light condition[J]. IEEE Signal Processing Letters, 2022, 29: 917-921.
- [8] Kong X Y, Liu L, Qian Y S. Low-light image enhancement via Poisson noise aware Retinex model[J]. IEEE Signal Processing Letters, 2021, 28: 1540-1544.
- [9] 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.
- [10] Zheng C J, Shi D M, Shi W T. Adaptive unfolding total variation network for low-light image enhancement[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2022: 4419-4428.
- [11] Li C Y, Guo C L, 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.
- [12] 陈清江, 顾媛, 李金阳. 双分支金字塔网络的微光图像增强算法[J]. 液晶与显示, 2022, 37(3): 395-404.
Chen Q J, Gu Y, Li J Y. Low-light level image enhancement algorithm based on double-branch pyramid model[J]. Chinese Journal of Liquid Crystals and Displays, 2022, 37(3): 395-404.
- [13] 陈清江, 顾媛. 多通道融合注意力网络的低照度图像增强[J]. 光学精密工程, 2023, 31(14): 2111-2122.
Chen Q J, Gu Y. Low-light image enhancement algorithm based on multi-channel fusion attention network [J]. Optics and Precision Engineering, 2023, 31(14): 2111-2122.
- [14] Lü F F, Lu F, Wu J H, et al. MBLLEN: low-light image/video enhancement using CNNs[EB/OL]. [2023-05-06]. <http://bmvc2018.org/contents/papers/0700.pdf>.
- [15] Wei C, Wang W J, Yang W H, et al. Deep Retinex decomposition for low-light enhancement[EB/OL]. (2018-08-14)[2023-05-06]. <https://arxiv.org/abs/1808.04560>.
- [16] 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, October 21-25, 2019, Nice, France. New York: ACM Press, 2019: 1632-1640.
- [17] 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.
- [18] 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), June 18-24, 2022, New Orleans, LA, USA. New York: IEEE Press, 2022: 5891-5900.
- [19] Wang R X, Zhang Q, Fu C W, et al. Underexposed photo enhancement using deep illumination estimation [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2020: 6842-6850.
- [20] Wang Y, Cao Y, Zha Z J, et al. Progressive Retinex: mutually reinforced illumination-noise perception network for low-light image enhancement[C]//Proceedings of the 27th ACM International Conference on Multimedia, October 21-25, 2019, Nice, France. New York: ACM Press, 2019: 2015-2023.
- [21] Fan M H, Wang W J, Yang W H, et al. Integrating semantic segmentation and retinex model for low-light image enhancement[C]//Proceedings of the 28th ACM International Conference on Multimedia, October 12-16, 2020, Seattle, WA, USA. New York: ACM Press, 2020: 2317-2325.
- [22] 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.
- [23] Ma L, Ma T 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), June 18-24, 2022, New Orleans, LA, USA. New York: IEEE Press, 2022: 5627-5636.
- [24] 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), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1777-1786.
- [25] 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.
- [26] 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.