

基于同态频分聚合的低照度图像增强算法

张雅荔¹, 丁少博¹, 李昌禄^{1*}, 姚昕明², 李文元¹¹天津大学微电子学院, 天津 300072;²中国电子科技集团公司第四十五研究所, 北京 100176

摘要 弱光环境会导致图像采集设备拍摄的照片出现对比度低、亮度较暗、细节缺失等问题,为此提出一种基于同态频分聚合的低照度图像增强算法。首先,改进同态滤波的传递函数,将原始图像分解为高频和低频分量,在不损失亮区细节的同时,增强一部分暗区细节,改进后的同态滤波传递函数参数更少,且易于调整;然后,分别对两个分量进行增强,即设计细节增强网络完善高频部分的细节信息,采用 low-light image enhancement via illumination map estimation (LIME) 算法对低频部分进行亮度提升;最后,设计局部自适应网络对图像高频和低频分量进行联合微调,纠正融合过程中出现的失真。从主观视觉以及客观评价指标两个方面进行实验分析,结果表明,所提算法能有效平衡图像平滑区域与纹理分量的增强效果,提升图像视觉质量。

关键词 图像处理; 图像增强; 同态滤波; 图像分解; 细节增强

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP221078

Low-Light Image-Enhancement Algorithm Based on Homomorphic Frequency Division Aggregation

Zhang Yali¹, Ding Shaobo¹, Li Changlu^{1*}, Yao Xinming², Li Wenyuan¹¹School of Microelectronics, Tianjin University, Tianjin 300072, China;²Forty-Fifth Research Institute of China Electronics Technology Group Corporation, Beijing 100176, China

Abstract A weak-light environment leads to low contrast, dark brightness, missing details, and other problems with pictures captured by image acquisition equipment. Therefore, a low illumination image-enhancement algorithm based on homomorphic frequency division aggregation is proposed. First, the transfer function of homomorphic filtering is improved, the original image is decomposed into high- and low-frequency components, and some dark-area details are enhanced without the loss of bright-area details. The improved homomorphic-filtering transfer function has fewer parameters than the original and is easy to adjust. Next, the two components are enhanced. That is, the detail enhancement network is designed to improve the detailed information of the high-frequency part, and the low-light image enhancement via illumination map estimation (LIME) algorithm is used to enhance the brightness of the low-frequency part. Finally, a local adaptive network is designed to jointly fine-tune the high- and low-frequency components of the image to correct the distortion during fusion. The experimental results from the subjective vision and objective evaluation indicators show that the proposed algorithm can effectively balance the enhancement effect of smooth regions and texture components of the image and improve the image visual quality.

Key words image processing; image enhancement; homomorphic filtering; image decomposition; detail enhancement

1 引言

由于自然环境的复杂多样性,在不同场景(例如背光、阴天、夜晚等)低照度条件下,基于光学的成像设备受到影响,采集的图像通常会存在亮度不足、对比度较

低、细节模糊等问题。而高质量的输入数据是计算机视觉技术进行图像处理分析的前提,低照度环境下获取的图像缺乏系统必需的信息输入,会造成其他基于视觉的智能算法性能下降,例如目标检测^[1]、图像分割^[2]、人脸识别^[3]等。为确保对低照度场景中所拍摄图

收稿日期: 2022-03-22; 修回日期: 2022-04-29; 录用日期: 2022-09-05; 网络首发日期: 2022-09-15

基金项目: 天津市科技支撑项目(16YFZCGX00760)

通信作者: *3383928167@qq.com

像的有效利用,低照度图像增强算法已成为计算机视觉任务的研究热点之一。

近几年,国内外学者进行大量研究并取得一系列成果,比较经典的方法主要包括 3 种:

1) 基于空域的增强算法。其中,在低照度图像增强领域最常用的为直方图均衡化(HE)算法^[4],核心思想是对图像直方图进行操作来拓展图像的动态范围,以达到对较暗图像增亮或增强对比度的效果。由于其原理简单、易于实现的特性而被广泛使用。因此,一系列基于直方图原理的算法被提出,这些算法在提高全局或局部区域内的对比度是有效的,但大多数不够灵活,且会在某些局部区域产生一些不良的视觉效果,例如曝光不足、过度曝光、放大噪声等。

2) 基于 Retinex 的增强算法^[5]。科研人员陆续提出单尺度 Retinex(SSR)算法^[6]、多尺度 Retinex(MSR)算法^[7]以及兼具色彩恢复的多尺度 Retinex(MSRCR)算法^[8]。Guo 等^[9]提出的 low-light image enhancement via illumination map estimation (LIME)算法,同时兼顾图像的光照映射估计与去噪效果。上述基于 Retinex 理论的改进算法在提高图像对比度方面表现良好,并在一定程度上减弱了噪声的影响,但相关参数需要根据先验知识进行手动设置,对不同类型图像的适应能力较差,一旦在大规模数据上测试,往往会产生不理想的结果。

3) 基于深度学习的增强算法。Lore 等^[10]提出 LLNet,通过伽马矫正^[11]和高斯噪声来模拟自然低光环境,结果验证了基于合成数据集训练模型的有效性,不足在于没有使用真实场景下采集的低照度图像进行训练,泛化性较差。Wei 等^[12]基于卷积神经网络(CNN)实现 Retinex 理论模型,设计了一个包含图像分解和图像增强的两阶段网络 RetinexNet,然而其分解出的光照图比较模糊,增强图像质量不高。Guo 等^[13]提出无参考的 Zero-DCE 算法,通过设计合理的损失函数对曝光和颜色进行约束,避免过拟合风险,但对于照度极低图像的增强结果不太理想。Jiang 等^[14]设计了基于生成对抗网络(GAN)的 EnlightenGAN 算法,其泛化效果较好,推动了 GAN 在图像增强领域的应用^[15],但这一类算法往往具有较高的模型复杂度。上述基于学习的增强算法在提升图像亮度、对比度等方面有着出色的表现,但算法性能对数据集依赖性较强,且运行时间较长。

针对低照度图像中高低频信息增强效果难以平衡的问题,本文提出一种基于同态频分聚合的低照度图像增强(HFNet)算法。对图像进行分解,细化任务,有助于明确各阶段的训练目标,相较于整体网络来说,更具有针对性,增强效果也更加明显。关键技术和创新点如下:

1) 改进同态滤波的传递函数。常用的同态滤波算法通过高频抑制低频,达到图像增强的目的,但这样做

会丢失部分低频信息。为了能同时获得高频成分和低频成分,本实验基于不同同态滤波传递函数进行图像分解。在传统低通滤波中,阶数 n 越大,振铃现象越明显,且参数数量较多。为减少参数设置、避免振铃现象,设计了新的低通滤波传递函数。改进后的同态滤波传递函数参数更少,且易于调整。

2) 通过分析低照度图像高频分量的特点,对细节信息采取递进式增强方式。首先,改进的同态滤波算法可以在不损失亮区细节的同时,增强一部分暗区细节;在此基础上,以正常光照图像分解出的高频分量作为输出期望,细节增强网络可以恢复和增强低照度图像中的纹理细节;最后,局部自适应网络的强化训练可以对细节信息进行补充和完善。

3) 设计局部自适应网络强化训练。由于低频分量的亮度提升和高频分量的细节增强是分开进行的,两个步骤之间没有引入任何约束,则增强后的图像在合并时,可能出现颜色偏移或其他失真现象。利用局部自适应网络对图像高频和低频分量进行联合微调,为两者之间建立一定的约束和关联,不仅能对先前的增强过程起到补充作用,也能平衡平滑区域与纹理分量的增强效果,提升图像融合后的视觉体验。

2 基本原理

2.1 同态滤波

对于一幅图像 $f(x, y)$, 可以表示为入射分量 $i(x, y)$ 与反射分量 $r(x, y)$ 的乘积, 即:

$$f(x, y) = i(x, y) \cdot r(x, y), \quad (1)$$

式中: $i(x, y)$ 代表低照度光照分量, 即低频分量; $r(x, y)$ 主要体现图像中的边缘和细节等高频信息, 即高频分量。

同态滤波^[16]技术可以将乘性问题转换为加性问题, 对式(1)两边同时取对数可得:

$$\ln f(x, y) = \ln i(x, y) + \ln r(x, y), \quad (2)$$

然后做傅里叶变换, 可得:

$$F(u, v) = I(u, v) + R(u, v). \quad (3)$$

记 $H(u, v)$ 为同态滤波的传递函数, 对 $F(u, v)$ 进行滤波, 可以得到:

$$S(u, v) = H(u, v) F(u, v) = H(u, v) I(u, v) + H(u, v) R(u, v), \quad (4)$$

其中, $H(u, v)$ 对滤波效果起到重要作用。此时, 入射分量和反射分量被分离。滤波后, 做傅里叶逆变换到空间域, 取指数, 得到输出图像 $g(x, y)$:

$$g(x, y) = \exp[S(x, y)]. \quad (5)$$

2.2 残差网络

理论上, 随着网络深度的增加, CNN 模型会取得更好的结果, 但是实际并非如此。大量实验发现, 深度

网络存在退化问题,即随着卷积层数增加,网络准确率会达到饱和,甚至出现下降的情况。

针对这一问题,He 等^[17]提出残差网络,如图 1 所示。

weight layer 在 CNN 中代表卷积操作,当输入信




图 1 基本残差模块网络结构图

Fig. 1 Network structure diagram of basic residual module

息为 x 时,通过恒等映射、残差学习后的输出为 $F(x)$,残差模型的整体输出为 $H(x)$ 。残差模型表达式为

$$H(x) = F(x) + x. \quad (6)$$

3 网络模型

将低照度图像增强任务划分成以下步骤:1)改进同态滤波的传递函数,将原始低照度图像分解成表征图像细节的高频分量和表征图像全局亮度的低频分量,并引入 BM3D 算法^[18]对噪声进行抑制;2)对于高频分量,设计增强网络模型,恢复图像细节信息;对于低频分量,采用 LIME 算法进行图像全局的亮度提升;3)融合增强后的图像高低频分量,设计局部自适应网络对其进行联合微调,以纠正图像融合过程中产生的颜色偏移,得到最终的输出图像。算法的整体流程如图 2 所示。

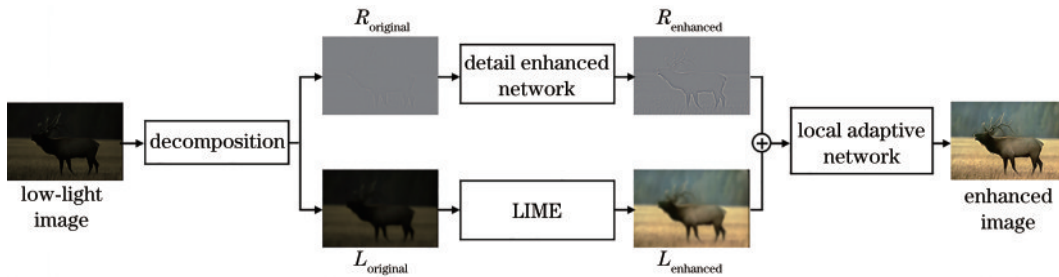


图 2 基于同态频分聚合的低照度图像增强算法

Fig. 2 Low-light image enhancement algorithm based on homomorphic frequency division aggregation

3.1 图像分解

由第 2.1 节分析可得:传递函数的选择在图像高低频分量的处理中起着重要作用。传统同态滤波的传递函数参数过多,计算过于复杂。为了以尽可能少的参数获得最佳的滤波效果,分别设置高通滤波传递函数和低频滤波传递函数,得到图像高频分量和低频分量。

采用文献[16]中设计的高通滤波传递函数,其对

应的三维图如图 3(a)所示,计算式如下:

$$H_H(u, v) = 1 / \sqrt{1 + D(u, v)^{-t}}. \quad (7)$$

以传统的巴特沃斯低通滤波器为基础,为减少参数设置、避免振铃现象,设计低通滤波传递函数,其对应的三维图如图 3(b)所示,计算式如下:

$$H_L(u, v) = 1 / \sqrt{1 + D(u, v)/d_0}, \quad (8)$$

式中: d_0 代表滤波器的截止频率。

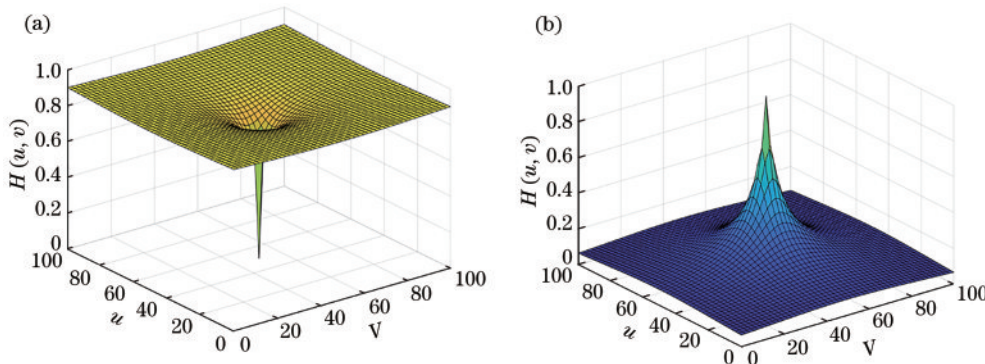


图 3 滤波传递函数三维图。(a)高通滤波传递函数三维图;(b)低通滤波传递函数三维图

Fig. 3 3D diagrams of filter's transfer function. (a) 3D diagram of high-pass filter's transfer function; (b) 3D diagram of low-pass filter's transfer function

通过同态高通、低通滤波,不仅能够将图像分解为表征图像局部细节的高频分量 R_{original} 和表征图像全局自然度的低频分量 L_{original} ,而且可以在不损失亮区细节的同时,增强一部分暗区细节。

3.2 高低频分量增强

将图像分解后,要细化增强任务、明确各阶段的训练目标。考虑到图像高频分量的像素值普遍较小,网络设计层数过多可能会在训练中丢失大量数据信息,但过少又可能学习不到图像深层次的细节信息,影响细节网络的恢复效果。残差学习的思想非常适合图像高频分量的训练,残差网络通过短接部分网络层的输入与输出,给网络提供一种选择退化的能力,并且增加了深层网络与浅层网络的信息交换。因此,对于原始低频分量 L_{original} ,采用 LIME 算法来提升其亮度,得到增强后的低频分量 L_{enhanced} 。对于原始高频分量 R_{original} ,引入 BM3D 算法抑制其中被放大的噪声,并

在残差网络基础上进行改进,构建细节增强网络,恢复低照度图像的细节信息,得到增强后的高频分量 R_{enhanced} 。

细节增强网络模型如图 4 所示:使用 3×3 卷积层从低照度图像中提取初始特征,提取出的特征经过 n 个由 3×3 卷积层和激活函数层所构成的残差块。考虑到图像在网络中的正负响应都可能包含重要的局部信息,这些信息对于学习图像的细节部分至关重要,因此选择 LReLU^[19] 作为激活函数,保证负数响应不会被置为零,以避免模型零梯度问题。参考大多数图像重建网络^[20-21],对经典残差结构进行改进,去除模块中的批归一化(BN)层。最后,经过 3×3 的卷积重建层,通过全局残差连接将输入数据添加到网络输出中,不仅可以有效降低网络的优化复杂度,同时还可加快训练过程中的收敛速度。




图 4 细节增强网络

Fig. 4 Detail enhanced network

考虑到图像的高频分量可能包含一些噪声和异常值,选用 L_1 损失函数:

$$L(\theta) = \frac{1}{N} \sum_{i=0}^N \|R_{\text{ref}} - R_{\text{enhanced}}\|_1, \quad (9)$$

式中: $\|\cdot\|_1$ 代表 L_1 范数; θ 代表网络中的可学习参数; N 代表像素数量; R_{ref} 代表参考图像的高频分量。

3.3 图像融合

将处理后的高频分量和低频分量相加,可以得到初步的增强图像。然而,由于低频分量的亮度增强和高频分量的细节提升是分别进行的,因此两个增强步骤间不存在必要的关联和约束。另外,低照度图像同时包含暗区和亮区,仅靠分量网络不足以模拟从低照度图像到正常照度图像的映射关系。因此,对两个增强后的分量进行简单融合容易造成图像失真。

针对这一问题,采用局部自适应网络对图像高频和低频分量进行联合微调。通过强化训练,一方面可以对先前的增强过程起到补充作用;另一方面,还可以提升图像融合之后的视觉效果。考虑到局部自适应网络与细节增强网络任务目标相似,因此采用相同的网络架构,唯一的不同点在于,局部自适应网络中的残差模块添加 BN 层。此外,由于细节增强网络已获得图像的部分映射关系,因此将训练好的模型参数迁移到局部自适应网络中可以降低模型的训练难度。

将 L_1 损失和基于 VGG16^[22] 的内容感知损失^[23] 组

合到一起进行实验,目的是在保持图像整体风格尽量接近的同时,进一步提高图像像素级评价指标。损失函数定义如下:

$$L_{\text{all}} = L_1 + L_{\text{content}}, \quad (10)$$

式中: L_{all} 表示总的损失; L_{content} 表示内容感知损失,定义如下:

$$L_{\text{content}}(\hat{y}, y) = \frac{1}{C_j H_j W_j} \|\phi_j(\hat{y}) - \phi_j(y)\|_2^2, \quad (11)$$

式中: ϕ_j 代表 VGG16 网络从 j 层提取的特征图; \hat{y} 和 y 分别表示经过神经网络增强后的正常照度图像和真实的正常照度图像; $C_j H_j W_j$ 表示特征图的尺寸。

训练过程中,将初步增强图像作为网络的输入数据,未进行分解的参考图像作为输出期望,通过局部自适应网络输出最终的增强图像。

4 实验结果分析

4.1 实验数据

为增强算法的泛化性能,在合成图像数据集和真实场景下拍摄的低照度图像数据集 LOL 上分别进行实验。

合成图像数据集:从 BSD 数据集^[24] 和 DIVERse 2K (div2k)^[25] 数据集筛选图像,通过随机调整伽马参数^[11],使图像亮度发生非线性变化来模拟低照度环境,公式如下:

$$I_L = r_{\text{random}} \times (I_H)^\gamma, \quad (12)$$

式中: I_L 为低照度图像; r_{random} 为 $(0, 1)$ 之间的随机参数; I_H 为高分辨率图像; γ 表示 gamma 系数。

LOL 数据集: 2018 年由北京大学提出, 包含 500 对尺寸为 400×600 的低照度-正常照度图像。该数据集来源广泛, 包括从各种场景中捕获的图像, 例如房屋、校园、俱乐部以及街道等。

4.2 实验设置

所提算法基于 PyTorch 框架构建网络架构, 使用 Nadam^[26] 优化器进行网络训练。为提高对计算机存储和数据集数量的利用率, 每张图片被随机裁剪成大小为 256×256 的 patch, 并使用旋转和翻转操作进行数据增强, 每个批次训练样本数目为 32, 学习率初始化为 0.01, 每 10 个 epoch 递减为原来的 1/10, 共迭代 50 个 epoch。在整个实验的训练和测试中, 均采用

Intel-i7 和 NVIDIA 1080Ti 的硬件设备。主观实验部分采用 Hisense 55E3G 55 英寸液晶电视, 供实验参与者对样本素材进行主观评价。

4.3 实验分析

实验分析部分从主观和客观评价两个方面, 将所提算法与其他低照度图像增强算法, 包括传统算法 LIME、基于深度学习的 LLNet 算法、RetinexNet 算法、Zero-DCE 算法以及 EnlightenGAN 算法在合成图像和真实数据集上进行全面对比。此外, 通过消融实验验证亮度提升、细节增强和局部自适应网络的有效性。

4.3.1 合成数据集的评价结果

图 5 和图 6 展示了合成数据集的部分实验结果图像, 一些重建图像的放大区域已经在图中标出, 参见图左和右上角。

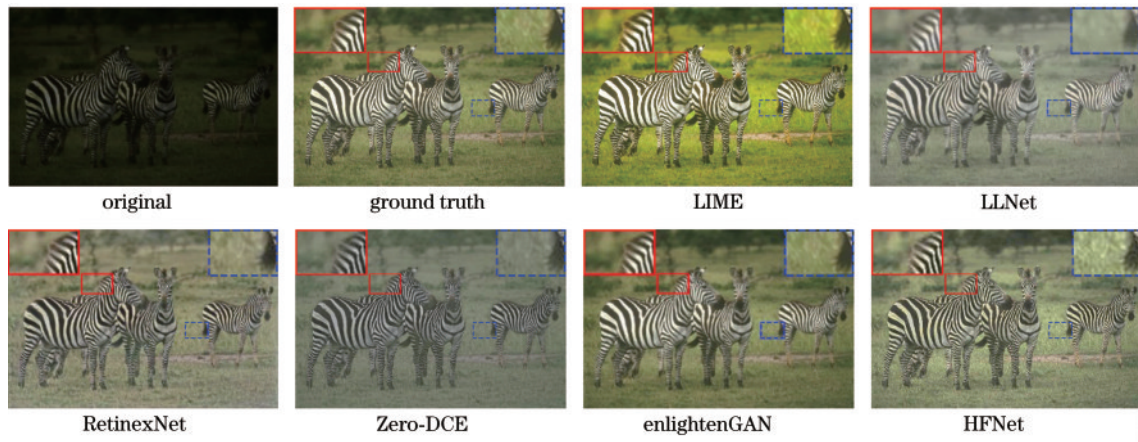


图 5 zebra 图像使用不同算法的增强效果对比

Fig. 5 Enhancement effects of zebra image using different algorithms




图 6 building 图像使用不同算法的增强效果对比

Fig. 6 Enhancement effects of building image using different algorithms

LIME 算法在提升图像亮度方面表现良好, 但色彩过于饱和, 图像细节不清晰; LLNet 算法避免了亮度过度增强, 但存在对比度不足的问题; RetinexNet 算法能够改善图像的亮度和对比度, 但重建图像稍显模糊; Zero-DCE 算法对低照度图像细节的增强效果相

对较好, 但对于局部较暗区域的处理存在欠缺; EnlightenGAN 算法的输出图像没有亮度和对比度的缺陷, 纹理区域稍显模糊; 所提 HFNet 算法不仅可以重建出更明亮、自然的图像, 而且在提升图像细节方面效果较好。

对合成测试集中增强后的图像进行定量评估,选用的评价指标包括峰值信噪比(PSNR)和结构相似度

(SSIM)^[27]。各算法的评估指标结果如表 1 所示,粗体表示在该指标上的最佳结果。

表 1 不同算法在合成低照度图像上的定量对比

Table 1 Quantitative comparison of synthetic low-light images obtained by different algorithms

Algorithm	LIME	LLNet	RetinexNet	Zero-DCE	EnlightenGAN	HFNet
PSNR	24.95	26.09	28.36	28.62	28.97	28.84
SSIM	0.620	0.718	0.789	0.824	0.851	0.862

为了更加直观地对比不同算法的客观指标,图 7 以柱状图形式进行展示。通过分析图 7 可以得到以下结论:实验过程中采用 BM3D 算法有针对性地分离出的反射图,即高频分量中被放大的噪声进行了抑制,再将去噪后的高频分量送入设计的细节增强网络,因此 HFNet 算法的 PSNR 值仅次于 EnlightenGAN 算法,代表重建图像产生的失真较小。由于 SSIM 指标

能够凸显轮廓和细节等特征信息,实验过程中对高频细节进行了 3 次递进增强:同态滤波增强暗区细节;细节增强网络进一步恢复纹理细节;局部自适应网络完成强化训练。这有助于所提 HFNet 算法获得最优的 SSIM 值,表明该算法增强后的图像与参考图像的结构相似度高于其他算法。




图 7 不同算法在合成数据集上的客观指标对比

Fig. 7 Comparison of objective indicators of different algorithms on synthetic dataset

人是图像最终的接收者,因此,邀请 20 名测试人员作为参与者,其中,男女各 10 人。所有参与者均具备良好的视力与色觉,且无图像处理相关经验。实验参与者在并未事先观看参考图像的前提下,依据平均

主观意见分数(MOS)对所看到的重建图像进行主观评分,分值为 1~5。所有参与者依次观看同一组图像,之后再继续进行下一组实验。实验结束后,分别计算全部图像所得平均主观分值,如表 2 所示。

表 2 合成低照度图像主观评价对比

Table 2 Comparison of subjective evaluation on synthetic low-light images

Image number	LIME	LLNet	RetinexNet	Zero-DCE	EnlightenGAN	HFNet
1	2.95	2.70	3.05	3.15	3.20	3.35
2	3.00	2.85	2.90	3.10	3.25	3.30
3	2.95	2.65	2.85	3.05	3.20	3.10
4	2.50	2.60	2.75	3.00	2.95	3.05
5	2.95	2.90	2.85	3.05	3.00	3.15
6	2.90	2.95	3.05	3.10	3.15	3.25
7	2.85	2.70	2.80	3.00	2.95	3.10
8	3.00	2.80	2.85	3.05	3.10	3.25

经过多组图像的对比分析,所提算法在多数情况下获得比其他算法更高的分数,表明 HFNet 可以有效实现低照度图像增强。

4.3.2 真实数据集

图 8 和图 9 展示了 LOL 数据集中所完成实验结果的部分图像,以验证 HFNet 算法对真实场景下低照度图像的增强效果。以图 8 为例:LIME 算法输出后的图像饱和度和亮度过高,导致色彩失衡;LLNet 算法色彩还原度较高,但整体亮度略低于原始图像;

RetinexNet 算法改善了弱光图像的视觉质量,但重建图像会存在不自然的色偏;Zero-DCE 算法增强后的图像细节比较清晰,但亮度和对比度相对较低;EnlightenGAN 算法可以有效增强低照度图像,但背景颜色与参考图像存在差异,产生了轻微颜色失真;而所提算法增强后的图像亮度适中,内容保持较为完整。因为所提算法将图像增强的任务分解成多个阶段,每个阶段的任务明确,更具有针对性。




图 8 doll 图像使用不同算法的增强效果对比

Fig. 8 Enhancement effects of doll image using different algorithms




图 9 room 图像使用不同算法的增强效果对比

Fig. 9 Enhancement effects of room image using different algorithms

在对真实低照度图像进行定量评估时,选取信息熵(IE)、自然图像质量评价(NIQE)^[28]和用于对比度失真的无参考图像质量(NIQMC)^[29]度量。表 3 展示了不

同算法在真实场景中低照度图像的客观对比结果。

为了更加直观地对比不同算法的客观指标,图 10 以柱状图的形式进行展示。

表 3 不同算法在真实低照度图像上的定量对比

Table 3 Quantitative comparison of different algorithms on real low-light images

Algorithm	LIME	LLNet	RetinexNet	Zero-DCE	EnlightenGAN	HFNet
IE	7.2012	6.4424	6.7328	6.8950	6.8336	7.0159
NIQE	6.9801	7.6243	7.4405	6.8572	6.6491	6.7696
NIQMC	5.0122	4.1691	4.3819	4.8927	4.6607	5.1008

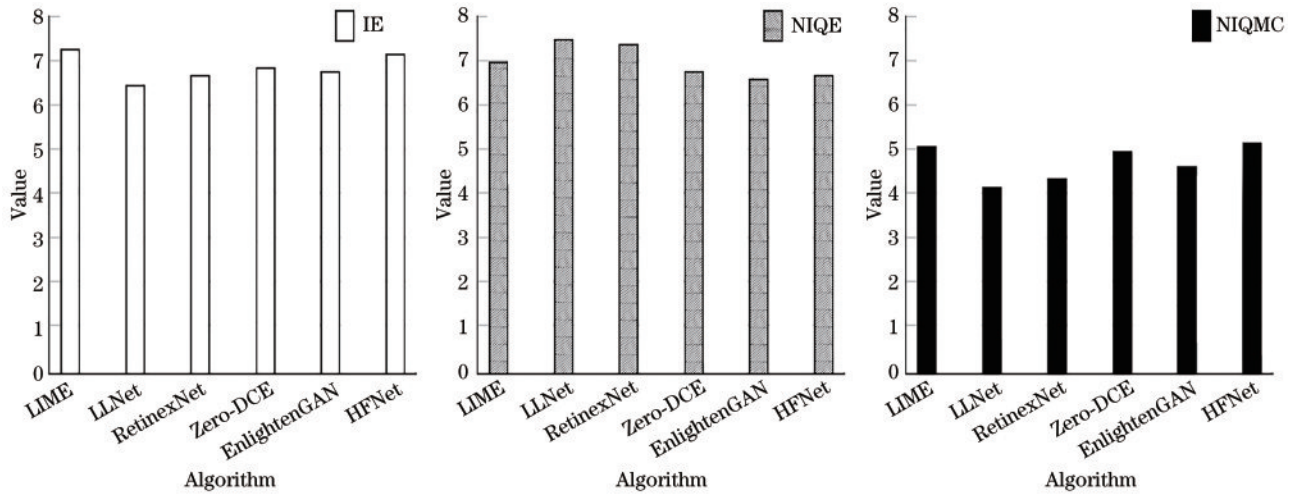


图 10 不同算法在真实数据集上的客观指标对比

Fig. 10 Comparison of objective indicators of different algorithms on real datasets

通过分析可以得到以下结论:LIME算法对图像亮度提升较大,获得最高的IE值,但其重建结果真实性和自然度较差。与其他基于深度网络的算法相比,所提HFNet算法获得更高的IE值。HFNet算法在NIQE这一指标上仅次于EnlightenGAN算法,表明图像的失真程度较小,色彩保持较好。NIQMC值通过分析局部细节和全局直方图来衡量图像质量,HFNet取得最高的指标值,证明该算法对细节的增强效果比

较显著。

主观实验同样邀请20名测试人员作为参与者,其中,男女各10人。实验参与者在并未事先观看参考图像的前提下,依据MOS对所看到的重建图像进行主观评分,分值为1~5。所有参与者依次观看同一组图像,之后再继续进行下一组实验。实验结束后,分别计算全部图像所得平均主观分值,如表4所示。

表 4 真实场景中的低照度图像主观评价对比

Table 4 Comparison of subjective evaluation on real low-light images

Image number	LIME	LLNet	RetinexNet	Zero-DCE	EnlightenGAN	HFNet
1	2.90	2.75	3.00	3.10	3.15	3.25
2	3.05	2.80	2.95	3.10	3.25	3.30
3	2.90	2.75	2.95	3.15	3.20	3.25
4	2.95	2.80	2.85	3.00	3.05	3.20
5	3.05	2.95	2.80	3.10	3.25	3.15
6	3.00	2.90	3.05	3.15	3.25	3.30
7	2.95	2.80	2.75	3.20	3.15	3.25
8	3.00	2.85	2.90	3.15	3.10	3.20

由以上实验结果可知,从增强图像的亮度、对比度和图像细节等多方面可以看出,所提HFNet算法获得了更高的主观评价。

4.3.3 消融实验

为验证网络中各个阶段所起到的作用,进行消融实验。参与对比的主要结构包括细节增强、亮度提升和局部自适应模块。其中:细节增强模块的作用是恢复纹理细节信息;亮度提升模块旨在通过LIME算法拓展低频部分的亮度范围;局部自适应网络通过对增强后的高频分量和低频分量进行联合微调,平衡平滑区域与纹理分量的增强效果。

图11展示了缺少不同模块的输出图像对比图。可以观察到:缺少细节增强模块时,重建结果部分细节模糊;缺少亮度提升模块会使图像的整体亮度变暗;缺少局部自适应网络模块时,会使图像的质感变得粗糙。这是由于低频分量的亮度提升和高频分量的细节增强是分开进行的,使得两个步骤之间没有引入任何约束,各像素点之间无法保持所期望的映射关系,会导致图像产生颜色失真,影响视觉效果。通过对初步增强图像进行局部自适应的强化训练后,纠正了融合过程中出现的颜色偏移问题,并使得图像平滑区域和高频区域的增强效果达到平衡,获得了更好的视觉体验。




图 11 缺少不同模块的输出图像对比。(a)输入图像;(b)缺少细节增强模块;(c)缺少亮度提升模块;(d)缺少局部自适应网络;(e) HFNet 的输出图像;(f)参考图像

Fig. 11 Output image comparison of missing different modules. (a) Input image; (b) lack of detail enhancement module; (c) lack of brightness enhancement module; (d) lack of local adaptive network; (e) output image of HFNet; (f) reference image

5 结 论

为解决弱光环境中所拍摄照片的对比度较低、亮度较暗、细节信息丢失导致图像内容不完整的问题,提出基于同态频分聚合的低照度图像增强算法。首先,改进同态滤波的传递函数,获得图像的高频成分和低频成分,在不损失亮区细节的同时,增强一部分暗区细节,且改进后的传递函数参数更少,易于调整;然后,设计细节增强网络,在同态滤波增强后的基础上进一步完善高频部分的细节信息,并采用 LIME 算法拓展低频部分的亮度范围,由于细化了各阶段的任务目标,相较于整体网络来说更具有针对性,增强效果更加明显;最后,训练局部自适应网络对图像高频和低频分量进行联合微调,平衡图像平滑区域与纹理分量增强效果。实验结果表明,所提算法能有效提高亮度和对比度,增强图像细节信息,图像视觉质量得到提升。下一步将继续优化模型,进行算法研究,以期减少对真实场景图像的依赖。

参 考 文 献

- [1] 武加文, 王世勇. 基于统计的灰度视频自适应背景建模算法[J]. 中国激光, 2021, 48(3): 0309001.
Wu J W, Wang S Y. Statistical-based adaptive background modeling algorithm for grayscale video[J]. Chinese Journal of Lasers, 2021, 48(3): 0309001.
- [2] 邱云飞, 温金燕. 基于 DeepLabV3+ 与注意力机制相结合的图像语义分割[J]. 激光与光电子学进展, 2022, 59(4): 0410008.
Qiu Y F, Wen J Y. Image semantic segmentation based on combination of DeepLabV3+ and attention mechanism [J]. Laser & Optoelectronics Progress, 2022, 59(4): 0410008.
- [3] Schroff F, Kalenichenko D, Philbin J. FaceNet: a unified embedding for face recognition and clustering[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA.

New York: IEEE Press, 2015: 815-823.

- [4] Hummel R. Image enhancement by histogram transformation[J]. Computer Graphics and Image Processing, 1977, 6(2): 184-195.
- [5] Land E H, McCann J J. Lightness and retinex theory[J]. Journal of the Optical Society of America, 1971, 61(1): 1-11.
- [6] Jobson D J, Rahman Z, Woodell G A. Properties and performance of a center/surround retinex[J]. IEEE Transactions on Image Processing, 1997, 6(3): 451-462.
- [7] Rahman Z, Jobson D J, Woodell G A. Multi-scale retinex for color image enhancement[C]//Proceedings of 3rd IEEE International Conference on Image Processing, September 19, 1996, Lausanne, Switzerland. New York: IEEE Press, 1996: 1003-1006.
- [8] Jobson D J, Rahman Z, Woodell G A. A multiscale 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.
- [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] 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.
- [11] Xiao Z T, Zhang X P, Zhang F, et al. Diabetic retinopathy retinal image enhancement based on gamma correction[J]. Journal of Medical Imaging and Health Informatics, 2017, 7(1): 149-154.
- [12] Wei C, Wang W J, Yang W H, et al. Deep retinex decomposition for low-light enhancement[EB/OL]. (2018-08-14)[2022-02-04]. <https://arxiv.org/abs/1808.04560>.
- [13] 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.
- [14] 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.
- [15] 查体博, 罗林, 杨凯, 等. 基于改进超分辨率生成对抗网络的图像重建算法[J]. 激光与光电子学进展, 2021, 58(8): 0810005.
Zha T B, Luo L, Yang K, et al. Image reconstruction algorithm based on improved super-resolution generative adversarial network[J]. Laser & Optoelectronics Progress, 2021, 58(8): 0810005.
- [16] 程新. 基于同态滤波的图像增强算法研究[D]. 西安: 西安邮电大学, 2016.
Cheng X. Image enhancement algorithm based on homomorphic filtering[D]. Xi'an: Xi'an University of Posts and Telecommunications, 2016.
- [17] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [18] Dabov K, Foi A, Katkovnik V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering[J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080-2095.
- [19] He K M, Zhang X Y, Ren S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification[C]//2015 IEEE International Conference on Computer Vision, December 11-18, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1026-1034.
- [20] 王爱丽, 张宇泉, 吴海滨, 等. 基于空洞卷积胶囊网络的激光雷达数据分类[J]. 中国激光, 2021, 48(11): 1110003.
Wang A L, Zhang Y X, Wu H B, et al. LiDAR data classification based on dilated convolution capsule network[J]. Chinese Journal of Lasers, 2021, 48(11): 1110003.
- [21] 李勇, 金秋雨, 赵怀慈, 等. 基于改进残差密集网络的高光谱重建[J]. 光学学报, 2021, 41(7): 0730001.
Li Y, Jin Q Y, Zhao H C, et al. Hyperspectral image reconstruction based on improved residual dense network [J]. Acta Optica Sinica, 2021, 41(7): 0730001.
- [22] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2022-02-04]. <https://arxiv.org/abs/1409.1556>.
- [23] Johnson J, Alahi A, Li F F. Perceptual losses for real-time style transfer and super-resolution[M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9906: 694-711.
- [24] Arbeláez P, Maire M, Fowlkes C, et al. Contour detection and hierarchical image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(5): 898-916.
- [25] Agustsson E, Timofte R. NTIRE 2017 challenge on single image super-resolution: dataset and study[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1122-1131.
- [26] 杨观赐, 杨静, 李少波, 等. 基于Dropout与ADAM优化器的改进CNN算法[J]. 华中科技大学学报(自然科学版), 2018, 46(7): 122-127.
Yang G C, Yang J, Li S B, et al. Modified CNN algorithm based on Dropout and ADAM optimizer[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2018, 46(7): 122-127.
- [27] 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.
- [28] Mittal A, Soundararajan R, Bovik A C. Making a "completely blind" image quality analyzer[J]. IEEE Signal Processing Letters, 2013, 20(3): 209-212.
- [29] Gu K, Lin W S, Zhai G T, et al. No-reference quality metric of contrast-distorted images based on information maximization[J]. IEEE Transactions on Cybernetics, 2017, 47(12): 4559-4565.