



双分支金字塔网络的微光图像增强算法

陈清江, 顾媛, 李金阳

引用本文:

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 Qing-jiang, GU Yuan, LI Jin-yang. 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.

在线阅读 View online: <https://doi.org/10.37188/CJLCD.2021-0221>

您可能感兴趣的其他文章

Articles you may be interested in

结合全局语义优化的对抗性灰度图像彩色化

Adversarial grayscale image colorization combined with global semantic optimization

液晶与显示. 2021, 36(9): 1305–1313 <https://doi.org/10.37188/CJLCD.2021-0012>

一种高精度的卷积神经网络安全帽检测方法

High precision detection method of safety helmet based on convolution neural network

液晶与显示. 2021, 36(7): 1018–1026 <https://doi.org/10.37188/CJLCD.2020-0309>

基于双残差卷积网络的低照度图像增强

Low-light image enhancement based on dual-residual convolutional network

液晶与显示. 2021, 36(2): 305–316 <https://doi.org/10.37188/CJLCD.2020-0168>

双任务卷积神经网络的图像去模糊方法

Image deblurring method based on dual task convolution neural network

液晶与显示. 2021, 36(11): 1486–1496 <https://doi.org/10.37188/CJLCD.2021-0001>

区域方差和点锐度相结合的多聚焦图像融合

Multi-focus image fusion combining regional variance and EAV

液晶与显示. 2019, 34(3): 278–282 <https://doi.org/10.3788/YJYXS20193403.0278>

文章编号:1007-2780(2022)03-0395-10

双分支金字塔网络的微光图像增强算法

陈清江, 顾媛*, 李金阳

(西安建筑科技大学理学院, 陕西 西安 710055)

摘要:针对微光图像存在亮度低、细节丢失严重以及现有算法增强后的微光图像存在曝光过度、颜色失真等问题,提出双分支金字塔网络的微光图像增强算法。首先,将微光图像从 RGB 颜色空间转换到 HSV 颜色空间。其次,对 V 分量采用双分支金字塔网络的微光图像增强算法,自适应获取图像特征。网络结构由并行双分支构成,含层级残差模块的分支有效增强 V 分量亮度,含特征金字塔注意力模块的分支获取深层特征信息。最后,对双分支结构提取的信息进行融合,并将增强后的图像从 HSV 颜色空间转换回 RGB 颜色空间。所提算法在真实图像上的峰值信噪比及结构相似度的均值分别达到 29.451 dB 和 0.930 1,均高于其他对比算法。实验结果表明,所提算法对 V 分量进行增强提高了图像亮度,有效地恢复了图像细节。

关键词:微光图像增强;层级残差;特征金字塔注意力;卷积神经网络;HSV 颜色空间

中图分类号:TP391.4 **文献标识码:**A **doi:**10.37188/CJLCD.2021-0221

Low-light level image enhancement algorithm based on double-branch pyramid model

CHEN Qing-jiang, GU Yuan*, LI Jin-yang

(School of Science, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: A low light level image enhancement algorithm based on double branch pyramid model is proposed. It is used to solve the problems of low brightness, serious loss of detail, over exposure and color distortion of the low light level image enhanced by existing algorithms. Firstly, the low-light level image is converted from RGB color space to HSV color space. Secondly, the low-light level image enhancement network of double branching pyramid network is constructed for the V component, and the image features are obtained adaptively. The network structure is composed of two parallel branches. The branch with hierarchical residual module can effectively enhance the brightness of V component, and the branch with feature pyramid attention module can obtain deep feature information. Finally, the information extracted from the dual-branch structure is fused, and the enhanced image is converted from HSV color space to RGB color space. The peak signal-to-noise ratio and the average structure similarity of the proposed algorithm on real images are 29.451 dB and 0.930 1 respectively, which are higher than other comparison algorithms. Experimental results show that the

收稿日期:2021-08-25;修订日期:2021-10-04.

基金项目:国家自然科学基金(No.61902304)

Supported by National Natural Science Foundation of China(No.61902304)

* 通信联系人, E-mail:2544020739@qq.com

enhancement of the V component can effectively improve the image brightness and restore the image details.

Key words: low light level image enhancement; hierarchical residual; characteristic pyramid attention; convolutional neural network; hsv color space

1 引言

人类感知世界的大部分信息是通过视觉系统获取的,图像是视觉系统最直接的体现。然而,在夜晚或光照不足的场景中拍摄的图像存在视觉效果不佳、对比度低等问题,难以进行深层分析,如目标识别、目标检测等。因此,设计有效提升图像视觉效果的微光图像增强算法,是一项重要任务。

目前,国内外主流的微光图像增强算法包含传统算法与深度学习算法:(1)基于传统方法,Hummel 等^[1]提出直方图均衡化(HE)方法;Pizer 等^[2]提出局部直方图均衡化(AHE)方法。此类方法虽然简便快捷,但存在纹理模糊问题。随后,基于 Land 等^[3]提出的 Retinex 理论,Jobson 等^[4]提出单尺度 Retinex(SSR)算法;林剑萍等^[5]结合 NSCT 变换和改进的 Retinex 及分数阶微分进行多尺度处理,获取增强图像。此类算法存在颜色失真,边缘模糊问题。Guo 等^[6]通过在 RGB 通道中找每个像素的最大值来估计照明图,设计 LIME 网络,但该算法增强后的图像存在对比度低及伪影问题。(2)随着深度学习热潮,众多基于卷积神经网络的微光图像增强算法被提出。Singh 等^[7]提出基于梯度分解的神经网络图像融合算法,但该方法增强后图像存在噪声及明度分布不均匀现象;Tao 等^[8]设计了 LLCNN 网络,使用一个模块提取多尺度特征图,用以增强图像,但此方法易出现块效应和噪声;Li 等^[9]设计了 LightenNet 网络,学习微光图像和相应照明图之间的映射,用以增强图像,但增强后图像易出现曝光过度问题;Jiang 等^[10]提出非配对训练的 En-lightenGAN 方法,利用对称编码的生成器网络与全局-局部判别器网络增强图像,但 GAN 难以训练,在训练时易产生梯度消失或梯度爆炸等问题。

针对上述问题,本文提出一种新的微光图像增强算法。该方法运用通道转换与分离的思想对单通道进行增强,既降低了网络参数大小提升了训练速度,也有效避免了使用 RGB 图像进行增强

后的图像存在色彩失真及明度分布不均匀的问题。本文的主要贡献如下:

(1)考虑到 HSV 颜色空间各通道相对独立的特性,仅处理 V 分量。该算法与处理 RGB 图像相比,不仅增强后图像亮度提升较好、色彩自然,且模型参数较小、运行时间较快。

(2)设计了一个层级残差模块,该模块提出交叉学习机制,使用不同尺度的卷积核对不同尺度的特征交叉组合相连,实现不同通道信息交互,再将这些特征信息通过局部与全局残差进行自适应特征融合,达到对 V 分量亮度增强的目的。

(3)在编解码结构中引入特征金字塔注意力模块,使网络关注不同尺度信息,保留细节,获取深层特征信息。设计了并行双分支网络结构,在提高图像亮度及对比度的同时有效加强图像特征信息,使增强后的微光图像更好地还原图像原有特征。

2 基本原理

HSV 是由 A.R.Smith 提出的一种颜色空间模型,也称六角锥体模型,包含色调(H),饱和度(S)和亮度(V)3 个参数。由于 HSV 颜色空间比 RGB 颜色空间更接近于人们对色彩的感知且具有直观性的特点,因此本文利用 HSV 颜色空间对微光图像的亮度分量 V 增强。由 RGB 颜色空间向 HSV 颜色空间的转换可表示为:

$$V = \max(R, G, B), \quad (1)$$

$$S = \begin{cases} \frac{V - \min(R, G, B)}{V}, & \text{if } V \neq 0 \\ 0, & \text{if } V = 0 \end{cases}, \quad (2)$$

$$H' = \begin{cases} 60 \times \frac{G - B}{V - \min(R, G, B)}, & \text{if } S \neq 0 \text{ and } V = R \\ 120 + 60 \times \frac{B - R}{V - \min(R, G, B)}, & \text{if } S \neq 0 \text{ and } V = G \\ 240 + 60 \times \frac{R - G}{V - \min(R, G, B)}, & \text{if } S \neq 0 \text{ and } V = B \end{cases} \quad (3)$$

$$H = \begin{cases} H', & \text{if } H' \geq 0 \\ H' + 360, & \text{if } H' < 0 \end{cases}, \quad (4)$$

其中, $0 \leq V \leq 1, 0 \leq S \leq 1, 0 \leq H \leq 360$ 。

3 双分支金字塔网络的微光图像增强算法

所提算法对 HSV 颜色空间中的 V 分量采用

双分支金字塔网络的微光图像增强算法,实现对 V 分量的增强。网络结构包含两个子网络:浅层网络使用 4 种不同尺度的卷积核提取浅层特征;深层网络包含 2 条并行金字塔注意力分支,在增强 V 分量亮度的同时提取深层特征。整个网络包含 4 个子模块:浅层特征提取模块,层级残差模块,特征金字塔注意力模块和特征重建模块,网络结构如图 1 所示。




图 1 双分支金字塔网络网络结构

Fig.1 Two-branch pyramid model network structure

首先将微光图像转换到 HSV 空间,对 V 分量设计双分支金字塔网络,输出增强后的 V 分量;其次将增强后的 V 分量与 H 和 S 分量合并,得到 HSV 颜色空间中的图像;最后转换回 RGB 颜色空间,整个算法流程图如图 2 所示。




图 2 算法流程图

Fig.2 Flow chart of our algorithm

3.1 浅层特征提取模块

首先对 HSV 颜色空间中的亮度分量 V 分别使用大小 $1 \times 1, 3 \times 3, 5 \times 5, 7 \times 7$, 个数均为 16 的卷积核提取具有不同尺度感受野的特征信息。4 次卷积后进行 concat 操作, 获取更多的全局信息, 给深层网络提供不同尺度的特征信息, 卷积计算公式如式(5)所示。

$$F_i(Y) = W_i * F_{i-1}(Y), \quad (5)$$

其中: Y 为输入图像, $F_i(Y)$ 为第 i 层的特征图, $F_{i-1}(Y)$ 为第 $i-1$ 层的特征图, W_i 为第 i 层的卷积核, $*$ 为卷积操作。每一层卷积均采用 ReLU 激活函数, 其公式表示如下:

$$f(x) = \begin{cases} x_i, & \text{if } x_i \geq 0 \\ 0, & \text{otherwise} \end{cases}, \quad (6)$$

其中: x_i 为第 i 层的特征输入。将提取到的多尺度浅层特征信息按深度方向进行叠加, 用以提升信息维度。

3.2 层级残差模块

本文结合由 He 等人^[11]在 ImageNet 竞赛中提出的残差网络, 提出层级残差模块。该模块首先采用 1 个 INT 模块, 其次采用 3 个 INT 模块, 每个 INT 模块进行局部残差后进行层间堆叠形成层级残差模块, 最后对层级残差模块提取的特征信息采用 1 个 INT 模块并进行全局残差, 形成金字塔注意力分支, 实现对 V 分量的亮度增强。其中 INT 模块采用交叉学习机制, 利用不同大小卷积核提取到的信息交叉组合相连, 将不同通道的信息交互, 加速模型收敛, INT 模块结构如图 3




图 3 INT 模型结构

Fig.3 INT model structure

所示。

3.3 特征金字塔注意力模块

利用 U-Net 网络结构模型,将特征金字塔注意力(FPA)^[12]模块嵌入编码器与解码器之间,最大程度保留细节特征。FPA 模块结构如图 4 所示,分别采用 $3 \times 3, 5 \times 5, 7 \times 7$ 大小的卷积核,形成金字塔结构,该结构精确整合了不同尺度的特征信息。通过 1×1 大小的卷积核,将原始特征与金字塔注意的特征像素相乘,有效关注全局上下文特征,提高了 FPA 模块性能。




图 4 FPA 模块结构

Fig.4 FPA model structure

3.4 特征重建模块

对上述金字塔注意力双分支提取的深层信息进行特征融合,采用大小为 $1 \times 1 \times 1$ 的卷积核,输出单通道重建特征图,其中 1×1 卷积核用来减少网络参数,加快收敛。

3.5 损失函数

为了从微光图像中恢复细节完整、色彩丰富的高质量图像,本文提出由平滑的 L_1 损失(Smooth L_1 Loss)和感知损失(Perceptual Loss)组合的损失函数,即:

$$L = \lambda_1 L_S + \lambda_2 L_P, \quad (7)$$

其中: L 为总损失; L_S 为平滑的 L_1 损失; L_P 为感知损失; λ_1, λ_2 代表权重,其中 $\lambda_1 = 0.85, \lambda_2 = 0.15$ 。

平滑的 L_1 损失:针对平均绝对误差(L_1 Loss)在训练后期难以收敛到更高精度,均方误差(L_2 Loss)在训练后期不稳定,易产生梯度消失或爆炸的问题,本文采用平滑的 L_1 损失,避免两者的缺点,以确保最佳的网络训练。计算公式如式(8)所示。

$$L_S(x) = \begin{cases} 0.5x_{i,j}^2, & |x_{i,j}| < 1 \\ |x_{i,j}| - 0.5, & \text{otherwise} \end{cases}, \quad (8)$$

其中 $x_{i,j}$ 为增强图像与真实图像第 i 行第 j 列的像素值之差。

感知损失:为了获得真实图像并保留细节,引入训练过的 VGG19^[13] 产生的特征图计算感知损失,测量重建图像的特征和相应真实图像之间的差异,计算公式如式(9)所示。

$$L_P = \frac{1}{W_{i,j} H_{i,j} C_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} \sum_{z=1}^{C_{i,j}} \|\varphi_{i,j}(I^h)_{x,y,z} - \varphi_{i,j}(I^s)_{x,y,z}\|_1, \quad (9)$$

其中: $\varphi_{i,j}$ 表示在 ImageNet 数据集上预处理的 VGG19^[13] 网络 φ 的第 i 块第 j 个卷积输出的特征图,具体是指第 3 块第 3 个卷积的特征图; I^h, I^s 分别为增强图像与真实图像, $W_{i,j}, H_{i,j}, C_{i,j}$ 分别表示第 i 块第 j 个卷积特征图的宽、长及其通道数。

4 实验结果与分析

为评估模型性能,将本文算法与其他算法分别从主观与客观方面进行对比,7 种对比算法包括 HE^[1]、AHE^[2]、SSR^[4]、LIME^[6]、LLCNN^[8]、BIMEF^[14] 和 L_i ^[9] 算法。

4.1 实验条件及参数设置及其算法步骤

本文实验使用的是 Tensorflow2.0 深度学习框架,在 Windows10, Inter i7-10750H, 2.6 GHz, 16G RAM, Nvidia GeForce 1660Ti GPU 平台上完成。采用 Adam 优化器对模型进行优化,动量参数为 $\beta_1 = 0.9, \beta_2 = 0.999$, 学习率 $l_r = 0.0001$, epoch 设置为 3 000 次。

4.2 合成微光图像实验

首先对人工合成的微光图像进行实验,从公开数据集 Berkeley Segmentation Dataset^[15] 中选取 110 幅正常光照图像。首先对 110 幅图像分别进行 90° 与 180° 翻转,将数据集扩充至 330 幅图像;其次利用 Retinex 理论^[3] 将每幅正常光照图

像的光照分量在 $(0,1)$ 之间随机取值;最终合成330幅微光图像。其中264幅图像作为训练集,

66幅图像作为测试集,从测试集随机选取4幅图像进行主观评价,如图5所示。




图5 不同算法对合成微光图像增强效果对比

Fig.5 Contrast of different methods for synthesizing low-light images enhancement

从图5可以看出,所提算法的主观视觉效果优于其他算法。其中,经AHE^[2]算法处理后的图像亮度几乎没有增强;经BIMEF^[14]算法处理后的图像比AHE亮度虽有所提升,但依然偏低;经HE^[1]算法增强后的图像,其颜色严重偏离真实图像;经LIME^[6]和LLCNN^[8]算法增强后的Bird图像中出现不规则蓝点,Scenery和Building图像的天空中出现不存在的纹理;经SSR^[4]和Li^[9]算法增强后的图像出现过曝光现象,且Li增强后

的Building图像存在伪影;经本文算法增强后的图像真实自然,最接近原始图像。

为进一步说明本文算法的有效性,利用峰值信噪比(PSNR)^[16]与结构相似度(SSIM)^[17]两项客观评价指标,对上述4幅图像进行计算。本文算法与其他7种对比算法的客观评价指标计算结果如表1所示。

从表1可以看出,本文算法的PSNR值与SSIM值均高于其他对比算法,说明该双分支金字

表1 合成微光图像上不同算法的PSNR与SSIM

Tab.1 PSNR and SSIM of different algorithms for synthesizing low-light images

Image	Evaluation index	Method							
		HE	AHE	SSR	LIME	LLCNN	BIMEF	Li	Ours
Bird	PSNR/dB	13.094	10.543	8.461 6	23.776	20.232	17.105	21.514	29.326
	SSIM	0.499 2	0.420 5	0.625 6	0.817 6	0.763 2	0.729 8	0.819 4	0.870 6
Scenery	PSNR/dB	14.970	8.737 1	7.778 0	23.756	21.294	14.217	11.714	28.358
	SSIM	0.654 2	0.416 3	0.668 2	0.829 5	0.829 5	0.771 4	0.760 0	0.863 5
Bear	PSNR/dB	15.205	8.142 8	9.329 9	21.687	18.149	12.817	21.619	29.686
	SSIM	0.551 0	0.409 2	0.707 0	0.835 7	0.800 7	0.707 9	0.810 7	0.871 8
Building	PSNR/dB	16.204	9.578 1	8.176 7	27.003	22.302	13.831	16.562	28.026
	SSIM	0.668 4	0.436 5	0.584 5	0.847 9	0.815 6	0.673 3	0.786 3	0.868 8
Average	PSNR/dB	14.868	9.250 3	8.436 6	24.056	20.494	14.493	17.852	28.849
	SSIM	0.593 2	0.420 6	0.646 3	0.832 7	0.802 2	0.720 6	0.79 41	0.868 7

字塔网络的微光图像增强算法具有明显优势。

4.3 真实微光图像实验

在真实微光图像上进行实验。LOL dataset^[18]公开数据集中包含 500 对微光图像和正常光照图像。选取 400 幅图像作为训练集,100 幅图像作为测试集,从测试集中随机选取 4 幅图像进行主观评价,评价结果如图 6 所示。

从图 6 可以看出,经 AHE^[2]、BIMEF^[14]与




图 6 不同算法对真实微光图像增强效果对比

Fig.6 Contrast of different methods for real low-light images enhancement

Li^[9]算法处理后的图像亮度较暗,尤其是经 AHE 算法处理后的图像亮度几乎没有得到增强;由于传统的 HE^[4]算法泛化性能较差,对不同数据集的表现不同,经 HE 算法处理后的图像较图 5 中 HE 算法处理后的图像没有出现严重偏色现象,但存在不规则噪点;经 SSR^[4]算法处理后的图像存在曝光过度,颜色失真现象;经 LIME^[6]与 LLCNN^[8]算法处理后的图像存在边缘模糊,明度不均匀现象;经文本算法处理后的图像颜色和纹理保留相对完整,最接近原始像。

进一步对本文算法进行客观评价,对上述 4 幅图像计算 PSNR 与 SSIM 值,结果如表 2 所示。

表 2 真实微光图像上不同算法的 PSNR 与 SSIM

Tab.2 PSNR and SSIM of different algorithms for real low-light images

Image	Evaluation index	Method							
		HE	AHE	SSR	LIME	LLCNN	BIMEF	Li	Ours
Clothes	PSNR/dB	16.291	10.200	9.4567	22.412	22.561	16.248	16.577	29.880
	SSIM	0.596 3	0.578 4	0.734 7	0.779 0	0.819 9	0.844 6	0.726 4	0.943 3
Fans	PSNR/dB	15.323	9.187 2	11.435	23.256	21.084	15.311	12.120	29.442
	SSIM	0.507 4	0.492 0	0.771 6	0.715 8	0.744 9	0.797 8	0.656 7	0.914 0
Bathroom	PSNR/dB	15.750	9.299 8	13.121	25.469	22.524	15.935	14.019	29.619
	SSIM	0.436 0	0.475 4	0.784 6	0.683 1	0.683 7	0.799 7	0.714 5	0.934 9
Rabbit	PSNR/dB	12.136	13.045	7.878 2	18.999	20.221	21.596	16.014	28.864
	SSIM	0.372 3	0.553 4	0.617 9	0.608 0	0.601 2	0.822 4	0.699 1	0.928 1
Average	PSNR/dB	14.875	10.433	10.473	22.534	21.598	17.273	14.683	29.451
	SSIM	0.478 0	0.524 8	0.727 2	0.696 5	0.712 4	0.816 1	0.699 2	0.930 1

从表2可以看出,本文算法的PSNR值与SSIM值明显高于其他对比算法,说明了该算法的有效性。

4.4 无参考图的微光图像实验

为进一步说明本文算法有效性,在DICM数据库^[19]中随机选取2幅图像进行主观评价,如图7所示。




图7 不同算法对无参考微光图像增强效果对比

Fig.7 Contrast of different methods for no reference low-light images enhancement

由于难以采集同一时刻的真实图像与微光图像,为此使用信息熵(IE)与梯度结构相似度(NRSS)^[20]两项无参考图像质量评价指标,对上

述2幅图像计算其值,结果如图8所示。其中IE值越大表明图像信息越丰富,NRSS值越大表明图像失真越小。




图8 无参考微光图像的信息熵与梯度结构相似度

Fig.8 IE and NRSS of low-light images without reference

从图8可以看出,对无参考微光图像增强的算法中,本文算法的IE值最大,说明所含信息最丰富。对于Image 1,本文算法的NRSS值最大,对于Image 2,LLCNN算法的NRSS值最大,但本文算法仅次于最优值,说明图像的色彩及细节恢复程度较好。

4.5 消融实验

通过实验证明所提算法的有效性,展示训练细节,在LOL dataset^[18]的测试集中随机选取1幅图像,执行消融实验,将仅含第一分支(Model 1)、仅含第二分支(Model 2)、无层级残差(Model 3)以及无特征金字塔注意力(FPA)模块^[12](Model 4)与本文模型(Model 5)进行对比,不同

模型的主观视觉效果如图9所示,其客观评价指标如表3所示。



图9 不同模型的主观视觉对比

Fig.9 Comparison of subjective visual results of different models

从图9可以看出,经Model 1增强后的图像出现边缘信息丢失及伪影现象;经Model 2与Model 4增强后的图像中植物绿叶颜色失真;经Model 3增强后的图像背景细节不足;经Model 5增强后的图像色彩与细节方面最接近真实图像。

表 3 不同模型的 PSNR 与 SSIM
Tab.3 PSNR and SSIM of different models

Image	不同模块	PSNR/dB	SSIM
Fans	Model 1	19.730	0.886 0
	Model 2	25.524	0.891 6
	Model 3	18.457	0.851 4
	Model 4	26.084	0.894 5
	Model 5	29.442	0.914 0

从表 3 可以看出, Model 1 和 Model 3 的 PSNR 值与 SSIM 值与 Model 5 相比较低,说明含 FPA 的金字塔注意力分支较好地防止了特征丢失,获取了深层信息; Model 2 和 Model 4 的 PSNR 值与 SSIM 值与 Model 5 相比略低,说明含层级残差模块的金字塔注意力分支较好地增强了 V 分量的亮度; Model 5 的 PSNR 值与 SSIM 值均为最高,说明所提网络模型无论是在特征提

取还是亮度增强方面都是最优的。

4.6 模型时间复杂度分析

除了对模型的主客观分析外,模型时间复杂度也是一项评测指标,运行时间越短,即模型复杂度越小。在测试集中随机选取 2 幅图像计算本文算法与其他对比算法的运行时间,每种方法分别对每幅图像运行 4 次,取其均值作为最终结果,如表 4 所示。

表 4 不同算法的运行时间
Tab.4 Running time of different algorithms (s)

Image	HE	AHE	SSR	LIME	LLCNN	BIMEF	Li	Ours
Clothes	1.594 3	1.840 5	1.995 7	1.882 5	5.346 7	2.987 6	1.556 4	3.621 2
Fans	1.827 6	1.543 4	1.826 2	1.793 4	5.339 8	2.765 7	1.524 3	3.496 0

从表 4 可以看出,由于 Li 算法模型结构较简单,运行时间最短;而本文模型参数较大,因此运行时间较长,这将是下一步要优化的问题。

5 结 论

本文提出的双分支金字塔网络的微光图像增强算法是将微光图像在 HSV 颜色空间上的 V 分量增强。并行双分支网络结构的设计改进了传统

的残差结构,提出层级残差模块,缓解了梯度消失,实现了 V 分量的亮度增强。同时,优化了网络结构,在编码器与解码器之间引入特征金字塔注意力模块,获取深层特征,整合上下文信息。实验结果表明,所提算法在真实图像上的峰值信噪比及结构相似度的均值分别达到 29.451 dB 和 0.930 1,均优于其他对比算法。随后将对网络结构进一步优化,降低了模型的空间复杂度与时间复杂度,获得更好的增强效果。

参 考 文 献:

[1] HUMMEL R. Image enhancement by histogram transformation [J]. *Computer Graphics and Image Processing*, 1977, 6(2): 184-195.
[2] PIZER S M, AMBURN E P, AUSTIN J D, et al. Adaptive histogram equalization and its variations [J]. *Computer Vision, Graphics, and Image Processing*, 1987, 39(3): 355-368.
[3] LAND E H. The retinex theory of color vision [J]. *Scientific American*, 1977, 237(6): 108-128.
[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] 林剑萍,廖一鹏.结合分数阶微分及 Retinex 的 NSCT 自适应低照度图像增强[J].液晶与显示,2020,35(4): 360-373.
LIN J P, LIAO Y P. NSCT adaptive low illumination image enhancement combining fractional differential and Retinex [J]. *Chinese Journal of Liquid Crystals and Displays*, 2020, 35(4): 360-373. (in Chinese)
- [6] 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.
- [7] SINGH S, GUPTA D. Detail enhanced feature-level medical image fusion in decorrelating decomposition domain [J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 70: 4502009.
- [8] TAO L, ZHU C, XIANG G Q, et al. LLCNN: a convolutional neural network for low-light image enhancement [C]. *Proceedings of 2017 IEEE Visual Communications and Image Processing (VCIP)*. St. Petersburg: IEEE, 2017: 1-4.
- [9] LI C Y, GUO J C, PORIKLI F, et al. LightenNet: a convolutional neural network for weakly illuminated image enhancement [J]. *Pattern Recognition Letters*, 2018, 104: 15-22.
- [10] 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.
- [11] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(12): 2341-2353.
- [12] LI H C, XIONG P F, AN J, et al. Pyramid attention network for semantic segmentation [J]. *arXiv*:1805.10180, 2018.
- [13] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. *arXiv*: 1409.1556, 2015.
- [14] YING Z Q, LI G, GAO W. A bio-inspired multi-exposure fusion framework for low-light image enhancement [J]. *arXiv*:1711.00591, 2017.
- [15] CHEN X Y, WANG S A. Superpixel segmentation based on Delaunay triangulation [C]//*Proceedings of the 23rd International Conference on Mechatronics and Machine Vision in Practice (M2VIP)*. Nanjing, China: IEEE, 2016: 1-6.
- [16] MANNOS J, SAKRISON D. The effects of a visual fidelity criterion of the encoding of images [J]. *IEEE Transactions on Information Theory*, 1974, 20(4): 525-536.
- [17] 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.
- [18] CHEN C, CHEN Q F, XU J, et al. Learning to see in the dark [C]//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018: 3291-3300.
- [19] LEE C, LEE C, KIM C S. Contrast enhancement based on layered difference representation [C]//*Proceedings of the 19th IEEE International Conference on Image Processing*. Orlando: IEEE, 2012: 965-968.
- [20] 谢小甫,周进,吴钦章.一种针对图像模糊的无参考质量评价指标[J].计算机应用,2010,30(4):921-924.
XIE X F, ZHOU J, WU Q Z. No-reference quality index for image blur [J]. *Journal of Computer Applications*, 2010, 30(4): 921-924. (in Chinese)

作者简介:



陈清江(1966—),男,河南信阳人,博士,教授,2006年于西安交通大学获博士学位,主要从事小波分析、图像处理与信号处理方面的研究。E-mail: qjchen66xytu@126.com



顾媛(1998—),女,陕西汉中,人,硕士研究生,2020年于咸阳师范学院获得学士学位,主要从事小波分析、图像处理与信号处理方面的研究。E-mail: 2544020739@qq.com



李金阳(1996—),男,陕西商洛人,硕士研究生,2019 年于咸阳师范学院获得学士学位,主要从事小波分析,图像处理与信号处理方面的研究。E-mail:1057042448@qq.com