

# 基于并联残差网络的低照度图像增强算法

陈清江, 李金阳\*, 胡倩楠

西安建筑科技大学理学院, 陕西 西安 710055

**摘要** 为了解决低照度图像亮度低、对比度低、信息丢失严重、颜色失真等问题, 提出一种基于并联残差网络的低照度图像增强算法。该网络模型的主要思想是将交替残差模块与局部全局残差模块进行并联, 运用改进的损失函数计算测试集损失, 不断地调整网络参数, 最终得到具有较强增强能力的网络模型。实验结果表明, 本文网络模型能够有效提高图像亮度、对比度, 减少边缘细节丢失。基于合成图像数据集与真实图像数据集进行实验, 本文网络模型均取得良好的增强效果, 在主观视觉上表现得更加自然, 其客观评价指标优于其他对比算法。

**关键词** 图像处理; 低照度图像增强; 残差网络; 区域损失; 卷积神经网络; 特征提取

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.1410015

## Low-Illumination Image Enhancement Algorithm Based on Parallel Residual Network

Chen Qingjiang, Li Jinyang\*, Hu Qiannan

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

**Abstract** To solve the problems of low-illumination image, such as low brightness, low contrast, severe information loss, and color distortion, a low-illumination image enhancement algorithm was proposed based on a parallel residual network. The main function of the network model involved parallelizing the alternating residual module with the local-global residual module, using the improved loss function to calculate the test set loss, constantly adjusting the network parameters, and finally achieving a network model with strong enhancement ability. Experimental results show that the proposed model can effectively improve the brightness and contrast of the image and reduce the loss of edge details. Both synthetic and real image datasets were used in experiments. The subjective vision of our model is more natural, and the objective evaluation index is better than those of other contrast algorithms.

**Key words** image processing; low-illumination image enhancement; residual network; regional loss; convolutional neural network; feature extraction

**OCIS codes** 100.2980; 200.4260; 040.3780

## 1 引言

进入 21 世纪以来, 科学技术飞速发展, 数码相机、手机相机随之普及, 图像成为人们认识世界、了解新生事物的重要媒介。通常在光照不足的环境下采集到的图像存在细节丢失、低对比度、低亮度、颜

色失真等问题, 并且图像含有大量噪声, 严重影响图像内容的获取。面对上述问题, 如何提高图像亮度、对比度、恢复图像细节成为图像增强领域的热门话题。

近年来国内外用于低照度图像增强的传统主流方法主要有以下三种: 1) 基于直方图均衡化 (HE)

收稿日期: 2020-10-14; 修回日期: 2020-11-02; 录用日期: 2020-11-14

基金项目: 国家自然科学基金(61403298)、陕西省自然科学基金(2015JM1024)

通信作者: \*1057042448@qq.com

的图像增强算法<sup>[1]</sup>, Pizer 等<sup>[2]</sup>提出自适应直方图均衡(AHE)算法,该方法的弊端在于在增加亮度的同时也增加了图像噪声。2)李庆忠等<sup>[3]</sup>提出了基于小波变换的图像增强算法,该算法可有效实现图像增强与去噪。3)基于 Retinex 理论的图像增强方法, Jobson 等<sup>[4-5]</sup>相继提出了单尺度 Retinex (SSR)算法与多尺度 Retinex (MSR)算法。随着深度学习技术的发展,该技术在目标检测、指纹识别、图像增强等领域被广泛应用。针对低照度图像增强, Li 等<sup>[6]</sup>提出 LightenNet 网络,即将 Retinex 理论与卷积层结合,对低照度图像进行增强;马红强等<sup>[7]</sup>将色彩空间进行转换,对亮度通道进行增强,从而得到正常曝光度的图像;张红颖等<sup>[8]</sup>提出 HSV (Hue, Saturation, Value)色彩空间的 RetinexNet 低照度图像增强算法; Xu 等<sup>[9]</sup>提出了一种低光残差卷积网络(LRCNN),该网络可以在增强对比度的同时去噪。上述方法相比于传统的低照度方法,增强效果提升明显,但是依然存在噪声、细节丢失、曝光过度等问题。

为了解决增强后图像存在细节丢失、曝光过度等问题,本文提出一种基于并联残差网络的低照度图像增强算法。该方法将两种残差模块采用并联的形式进行连接,目的在于捕获深层特征,增加网络宽度,减少因网络层数增加造成的边缘信息丢失;同时引入新的损失函数,解决照度分布不均匀图像增强后曝光过度的问题。实验结果表明本文网络模型有效地解决了上述问题,同时网络收敛速度较快,具有较强的泛化能力,峰值信噪比(PSNR)和结构相似度(SSIM)两项客观评价指标均优于其他对比算法,获得的增强图像更加自然。

## 2 基本原理

残差网络在 2015 年 ImageNet 视觉识别竞赛中由何凯明、孙剑等<sup>[10]</sup>提出。随着神经网络中卷积层层数的不断加深,在反向传播更新参数时,单纯的卷积堆叠容易造成梯度消失、网络性能饱和或退化等问题。残差学习的引入,解决了网络层数加深导致的网络性能饱和或退化问题,也提高了测试集的准确率。残差网络结构如图 1 所示。

残差模型表达式为

$$H(x) = F(x) + x, \quad (1)$$

式中,  $x$  表示上一层的输出(特征输入),  $F(x)$  表示残差学习后的输出,  $H(x)$  表示残差模型的整体输出, weight layer 在卷积神经网络(CNN)中代表卷




图 1 残差学习模型结构

Fig. 1 Structure of residual learning model

积操作。

## 3 基于并联残差网络的低照度图像增强网络

为了捕获低照度图像中的深层次特征与信息,一般采用加深网络层数来获取深层次特征,但网络层数加深会造成部分浅层信息丢失、更新参数时梯度消失、网络性能退化等问题。针对上述问题,本研究设计了并联残差网络模型,改进损失函数,有效防止了此类问题的发生,能够使增强后的图像边缘细节清晰,更加符合人类的视觉感官要求。

### 3.1 并联残差网络模型结构

本文所提并联残差网络模型结构主要包含两种残差网络:交替残差模块、局部全局残差模块,其中并联是指将两种残差模块采用并排的方式进行连接,并且两个残差分支训练同时进行。通过前向传播计算模型损失,运用反向传播更新参数,进而对模型进行训练和校正。并联残差网络模型结构如图 2 所示。

特征提取:在低照度图像特征提取过程中,首先采用 InceptionNet V1 模型<sup>[11]</sup>对图像浅层特征进行提取。采用 InceptionNet V1 模型进行浅层特征提取的原因在于该模型包含不同尺寸的卷积核,可获得不同大小的感受野,每个分支中  $1 \times 1$  的卷积核利于减少计算量,同时加快模型训练速度,其中 InceptionNet V1 模型如图 3 所示。

其次,采用交替残差模块与局部全局残差模块对图像的深层特征进行提取,在对深层特征进行提取时采用 4 个交替残差模型与 8 个局部全局残差模型。残差模型的引入可在提取深层次特征的同时减少信息丢失。随着网络层数加深,残差网络解决了梯度消失问题,提升了网络的表达能力。其中交替残差模型与局部全局残差模型的连接方式如图 4 所示。

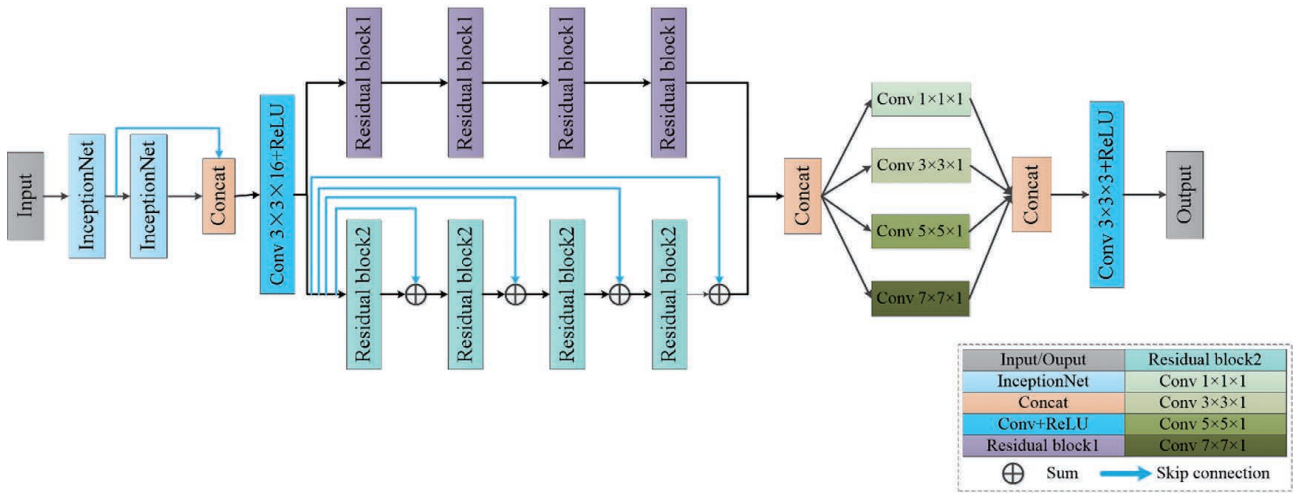


图 2 并联残差网络模型结构  
Fig. 2 Structure of parallel residual network model

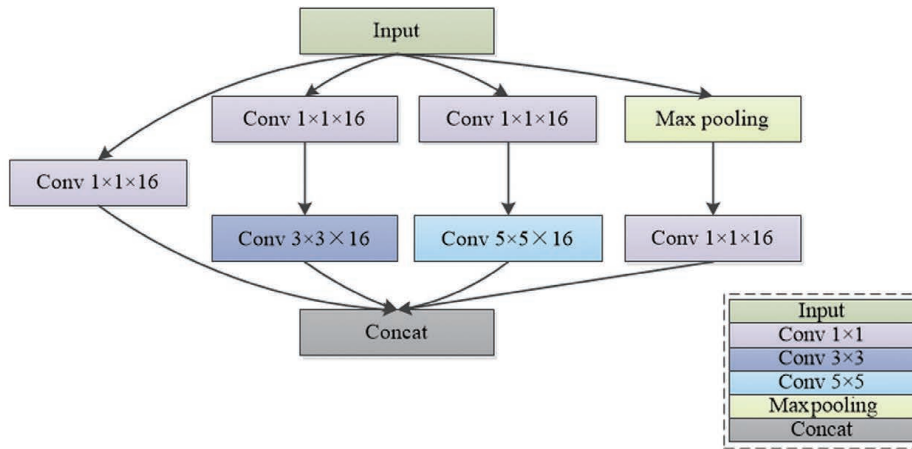


图 3 本文 InceptionNet V1 模型网络结构  
Fig. 3 InceptionNet V1 network structure used in this paper

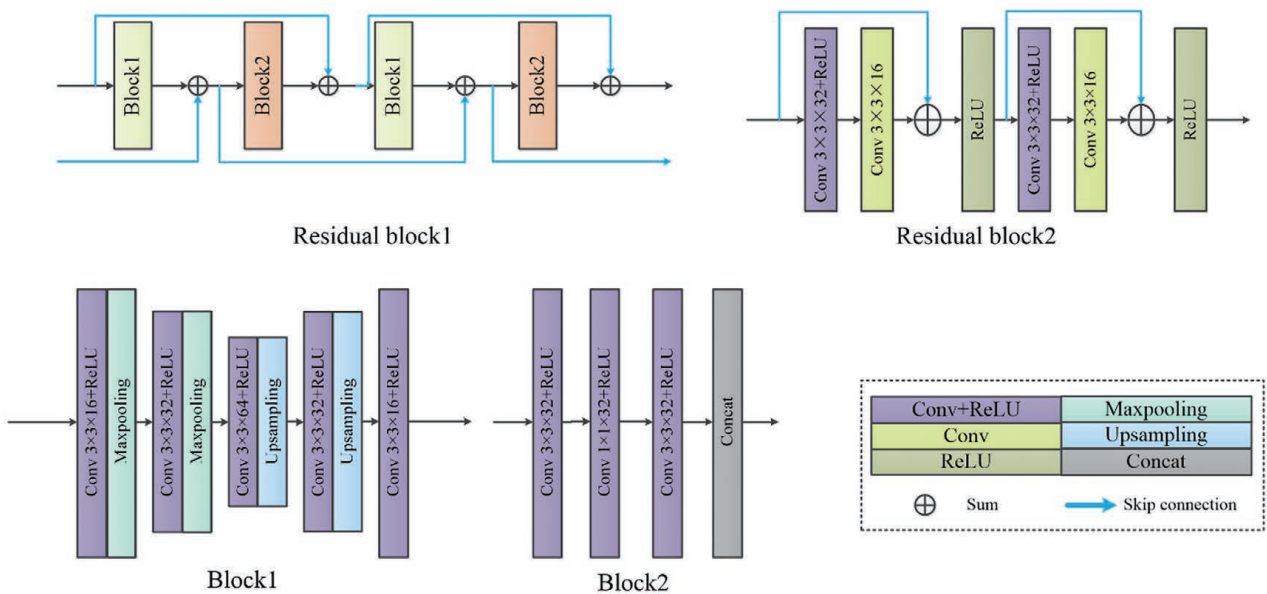


图 4 交替残差模型与局部全局残差模型  
Fig. 4 Alternating residual model and local global residual model

特征提取中的卷积计算公式为

$$H_{i,j} = W_{i,j} * C + b_{i,j}, \quad (2)$$

其中  $W_{i,j}$  表示第  $i$  个分支的第  $j$  层卷积核,  $H_{i,j}$  表示第  $i$  个分支的第  $j$  层卷积输出的特征图,  $b_{i,j}$  表示偏执项,  $C$  代表输入图像, “\*” 代表卷积操作。

修正单元中 ReLU 激活函数的计算公式为

$$R_{i,j} = \max(0, W_{i,j} * C + b_{i,j}), \quad (3)$$

其中  $R_{i,j}$  表示第  $i$  个分支的第  $j$  层卷积后的修正单元输出。

**特征融合:** 对于 InceptionNet V1 模型提取的浅层特征, 采用 Concat 连接后运用  $3 \times 3$  卷积对浅层特征进行融合; 对于残差网络提取的深层特征, 采用多尺度特征融合的思想, 扩大感受野, 以获得更加清晰的图像。在多尺度特征融合中将局部全局残差与交替残差模型的输出采用 Concat 进行连接, 作为多尺度特征融合的输入, 卷积核的大小为  $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$  和  $7 \times 7$ , 每层卷积后采用 ReLU 激活函数。

**特征重建:** 在重建中采用  $1 \times 1 \times 3$  的卷积, 减少网络模型参数, 在一定程度上提升了模型运行效率。

### 3.2 损失函数

在图像增强领域常用的损失函数有均方误差 (MSE)、平均绝对误差 (MAE) 等。由于真实的低照

度图像存在照度分布不均匀等现实因素, 因此只采用传统的 MSE 和 MAE 损失函数会使增强后的图像部分区域曝光过度。在进一步考虑图像结构信息、感知信息和区域差异的基础上, 本文提出了一种新的损失函数, 由多尺度结构损失 (SL,  $L_s$ )、多层次区域损失 (RL,  $L_r$ )、平均绝对误差 (MAE,  $L_m$ ) 与感知损失 (PL,  $L_p$ ) 组成, 即

$$L = \lambda_1 L_s + \lambda_2 L_r + \lambda_3 L_m + \lambda_4 L_p, \quad (4)$$

其中  $L$  为总损失,  $\lambda_1, \lambda_2, \lambda_3, \lambda_4$  为权重,  $\lambda_1 = 0.4$ ,  $\lambda_2 = 0.3$ ,  $\lambda_3 = 0.25$ ,  $\lambda_4 = 0.05$ 。

结构损失可以减少边缘信息丢失, 提高图像亮度、对比度, 同时使模型具有较高的稳定性与泛化能力。结构损失的表达式为

$$L_s = L_{\text{SSIM}} + L_{\text{SSIM}_{\text{MS}}}, \quad (5)$$

SSIM 损失表达式为

$$L_{\text{SSIM}} = 1 - \text{SSIM}(X, Y), \quad (6)$$

式中  $\text{SSIM}(\cdot)$  表示结构相似度函数。多尺度结构相似度 ( $\text{SSIM}_{\text{MS}}$ ) 损失表达式为

$$L_{\text{SSIM}_{\text{MS}}} = 1 - \text{SSIM}_{\text{MS}}(X, Y), \quad (7)$$

式中  $\text{SSIM}_{\text{MS}}(\cdot)$  表示结构相似度函数。

根据低照度图像的实际情况, 提出区域损失函数, 其中 40% 为极端低光区域, 40% 为弱光区域, 20% 为其他区域。区域损失可以表示为

$$L_r = \mu_1 \times L_1 + \mu_2 \times L_2 + \mu_3 \times L_3, \quad (8)$$

$$L_1 = \frac{\omega_{L_1}}{n_{L_1} \times m_{L_1}} \sum_{j=0}^{n_{L_1}} \sum_{i=0}^{m_{L_1}} |E_{L_1}(i, j) - G_{L_1}(i, j)|, \quad (9)$$

$$L_2 = \frac{\omega_{L_2}}{n_{L_2} \times m_{L_2}} \sum_{j=0}^{n_{L_2}} \sum_{i=0}^{m_{L_2}} |E_{L_2}(i, j) - G_{L_2}(i, j)|, \quad (10)$$

$$L_3 = \frac{\omega_H}{n_H \times m_H} \sum_{j=0}^{n_H} \sum_{i=0}^{m_H} |E_H(i, j) - G_H(i, j)|, \quad (11)$$

式中:  $E_{L_1}, G_{L_1}$  分别表示增强图像的极端低光区域和对应区域正常图像;  $E_{L_2}, G_{L_2}$  分别表示增强图像的弱光区域和对应区域正常图像;  $E_H, G_H$  分别表示增强图像的其他区域和对应区域正常图像;  $m, n$  分别代表不同区域像素点的横纵坐标个数,  $m \times n$  代表不同区域像素点个数总和;  $L_1, L_2, L_3$  分别表示增强图像的极端低光区域、弱光区域损失和其他区域的损失;  $\omega_{L_1}, \omega_{L_2}, \omega_H$  为权重,  $\omega_{L_1} = 4, \omega_{L_2} = 2, \omega_H = 1$ 。

平均绝对误差损失函数计算公式为

$$L_m = \frac{1}{N} \sum_{k=1}^N \|E_k - G_k\|_1. \quad (12)$$

MAE 和 SSIM 损失函数仅关注了图像的浅层信息, 忽略了深层信息。因此, 本研究借鉴 SRGAN<sup>[12]</sup> 中的思想, 使用类似的策略来指导网络的训练。基本思想是使用训练好的 VGG19<sup>[13]</sup> 作为特征提取器, 如果增强后的图像和真实图像相似, 那么特征提取器对应的输出也应该相似。本研究将这种损失函数定义为感知损失, 计算公式为

$$L_p = \frac{1}{W_{i,j} H_{i,j} C_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} \sum_{z=1}^{C_{i,j}} \|\phi_{i,j}(E)_{x,y,z} - \phi_{i,j}(G)_{x,y,z}\|_2^2, \quad (13)$$

其中  $W_{i,j}, H_{i,j}, C_{i,j}$  表示描述 VGG19 网络中第  $i$  块第  $j$  个卷积的特征图的尺寸,  $\varphi_{i,j}$  表示第  $i$  块第  $j$  个卷积输出的特征图。

## 4 实验结果与分析

由于真实世界的低照度图像与合成图像相比有较大的差距,为了更好地提高模型的泛化能力,本文采用真实低照度图像数据集进行训练,并采用真实图像数据集与合成图像数据集进行测试。运用峰值信噪比和结构相似度两项客观评价指标进行定量分析。

### 4.1 低照度图像数据集的制作

从 LOL 公开数据集<sup>[14]</sup>中选取 460 幅真实低照度图像。由于真实低照度图像数据量较少,因此首先对 460 幅图片以 95 : 5 的比例进行划分,随后对划分好的两部分图像分别进行 90°、180°与 270° 翻转,以达到扩充训练集与测试集的目的。为了验证本文所提算法的有效性,在实验分析中选取 SSR 算法<sup>[4]</sup>、MSRCR 算法<sup>[15]</sup>、Ying 算法<sup>[16]</sup>、Li 算法<sup>[6]</sup>、Ren 算法<sup>[17]</sup>、BIMEF 算法<sup>[18]</sup>、LIME<sup>[19]</sup> 算法与本

文算法从主观视觉和客观评价指标两方面进行对比。

### 4.2 实验条件及参数设置

采用 TensorFlow2.0 深度学习框架进行训练与测试,计算机硬件配置如下:CPU 为 Intel Core i7-15750H 主频为 2.40 GHz,内存为 16 GB, GPU 为 Nvidia GeForce 1660Ti(6 GB)。由于计算机性能问题,将所有输入图像的大小统一裁剪为  $256 \times 256 \times 3$ ,优化器采用 Adam,动量参数  $\beta_1 = 0.9, \beta_2 = 0.999$ ;批大小为 2,迭代周期为 3000。0~1000 次迭代时设置固定学习率  $\rho = 0.001$ ,1000~2000 次迭代时设置固定学习率  $\rho = 0.0005$ ,2000~3000 次迭代时设置固定学习率  $\rho = 0.0001$ 。

### 4.3 不同损失函数的实验结果与结果分析

为了说明本文损失函数的有效性,本节对多尺度结构损失、多层级区域损失、平均绝对误差与感知损失 4 种损失进行组合: $L'_1 = \lambda_3 L_m, L'_2 = \lambda_1 L_s + \lambda_3 L_m, L'_3 = \lambda_1 L_s + \lambda_2 L_r + \lambda_3 L_m, L'_4 = \lambda_1 L_s + \lambda_2 L_r + \lambda_3 L_m + \lambda_4 L_p$ ,4 种损失函数增强结果如图 5 所示,其客观评价指标如表 1 所示。




图 5 损失函数不同组合方式下的主观视觉结果对比

Fig. 5 Comparison of subjective visual results for different combinations of loss functions

表 1 损失函数不同组合方式下的 PSNR 和 SSIM 计算结果  
Table 1 Calculation results of PSNR and SSIM for different combinations of loss functions

Loss	PSNR	SSIM
$L'_1$	23.039	0.7947
$L'_2$	24.833	0.8269
$L'_3$	27.149	0.8434
$L'_4$	27.375	0.8807

从图 5 中的主观视觉效果上可以看出,采用  $L'_1, L'_2$  损失函数增强后的图像颜色失真,含有伪影,亮度与对比图有一定差距;采用  $L'_3$  损失函数的图像在亮度恢复上与对比图更接近;采用  $L'_4$  损失函数的图像尽管在视觉效果与采用  $L'_3$  损失函数时相比没有明显改变,但从表 1 中可以看出 SSIM 显著提升。

### 4.4 不同对比算法对真实图像数据集进行增强后的结果分析

首先对 LOL 数据集中的低照度图像进行实验,随机选取测试集中 4 幅低照度图像,利用本文算法和 7 种对比算法进行增强,增强后的图像如图 6 所示。

从图 6 中可以看出,在真实数据集上 Ying 算法、Ren 算法、BIMEF 算法、Li 算法增强后的图像亮度偏低;SSR 算法、MSRCR 算法增强后曝光过度现象依然存在;本文算法、Li 算法和 Ying 算法增强后的图像在视觉效果上显得更加真实自然。从色彩角度来看,BIMEF 算法、LIME 算法增强后的图像存在明显的颜色失真。从图像细节恢复来看,Li 算法、Ying 算法和 LIME 算法增强后的图像边缘细节恢复较好,优于其他几种对比算法。本文算法增强后的图像边缘细节清晰,颜色与真实图像更加接近,

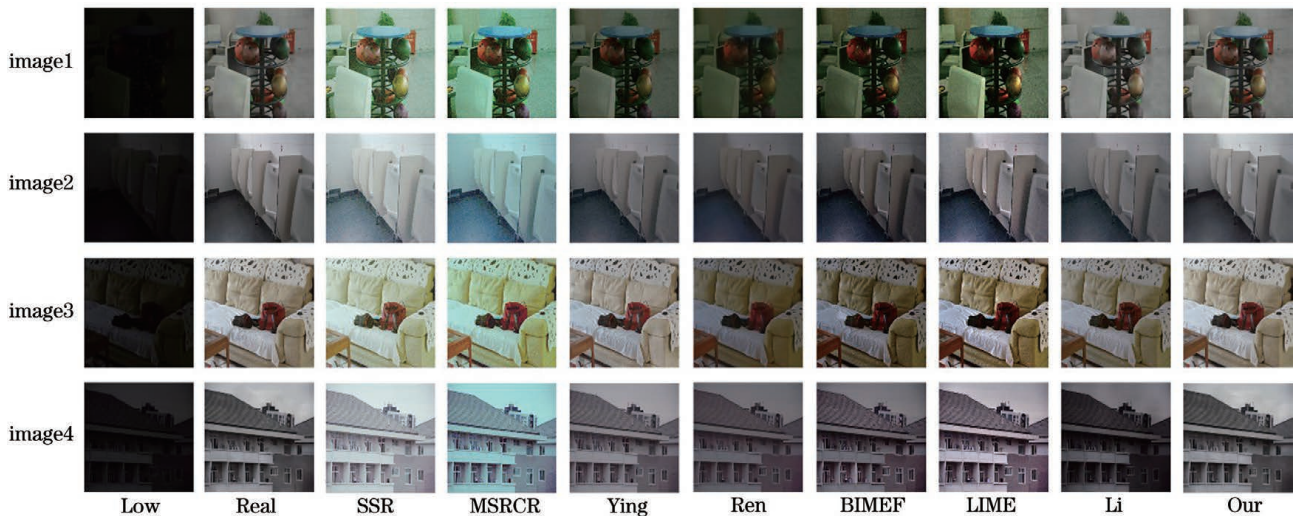


图 6 真实数据集上本文算法与 7 种对比算法主观视觉结果对比

Fig. 6 Comparison of subjective visual results between our algorithm and seven contrast algorithms on real dataset

相比于其他几种对比算法恢复效果明显提升,视觉效果也更加真实自然。

为了定量评价真实图像数据集增强后的图像

质量,对上述 4 幅增强后的图像采用客观评价指标 PSNR 和 SSIM 进行衡量。客观评价指标计算结果见表 2。

表 2 真实数据集上本文算法与 7 种对比算法的 PSNR 和 SSIM

Table 2 PSNR and SSIM of our algorithm and seven contrast algorithms on real dataset

Image	Evaluation index	Method							
		SSR	MSRCR	Ying	Ren	BIMEF	LIME	Li	Our
Image1	PSNR /dB	12.059	17.844	14.412	11.884	18.412	21.345	20.447	<b>28.331</b>
	SSIM	0.6013	0.5794	0.5969	0.6835	0.6469	0.7898	0.7259	<b>0.8997</b>
Image2	PSNR/dB	13.469	14.007	20.891	14.558	14.829	23.968	22.424	<b>31.087</b>
	SSIM	0.5974	0.5743	0.7559	0.8232	0.6001	0.8559	0.7068	<b>0.9365</b>
Image3	PSNR/dB	18.612	21.041	15.982	10.920	11.706	17.700	21.346	<b>30.112</b>
	SSIM	0.7810	0.7346	0.8321	0.6560	0.6826	0.7209	0.7881	<b>0.9331</b>
Image4	PSNR/dB	15.931	13.706	20.5662	14.780	15.394	24.355	17.858	<b>25.914</b>
	SSIM	0.6581	0.4831	0.6405	0.6504	0.5674	0.8334	0.6849	<b>0.8343</b>

由表 2 可看出,在真实图像数据集上本文算法的 PSNR 和 SSIM 远高于 7 种对比算法,这说明本文所提网络在真实低照度图像数据集上效果更好。

#### 4.5 不同对比算法对合成数据集进行增强后的结果分析

对合成的低照度图像进行实验,从 Berkeley Segmentation Dataset 公开数据集<sup>[20]</sup>中选取 30 幅正常照度的图像,基于 Retinex 理论合成了 30 幅低照度图像,利用本文算法和 7 种对比算法对合成的低照度图像进行增强,随机选取其中 4 幅增强图像进行主观评价,部分增强图像如图 7 所示。

从图 7 中可以看出,本文算法与对比算法在合

成数据集上都可提高图像亮度,但基于深度学习的增强方法要优于传统方法。从增强后的低照度图像恢复效果来看,Ying 算法、Li 算法、Ren 算法、BIMEF 算法增强后的图像亮度偏低;SSR 算法、MSRCR 算法增强后的图像曝光过度,影响视觉感官。本文算法与 LIME 算法增强后的图像在视觉效果上更加真实自然。从图像细节与色彩恢复效果来看,SSR 算法、MSRCR 算法增强后的图像细节模糊,颜色失真;Li 算法、Ren 算法增强后的图像存在阴影区域,与清晰的图像相比还有很大差距,说明 Li 算法、Ren 算法的泛化能力较弱。本文算法与 LIME 算法增强后的结果相比于其他几种对比算

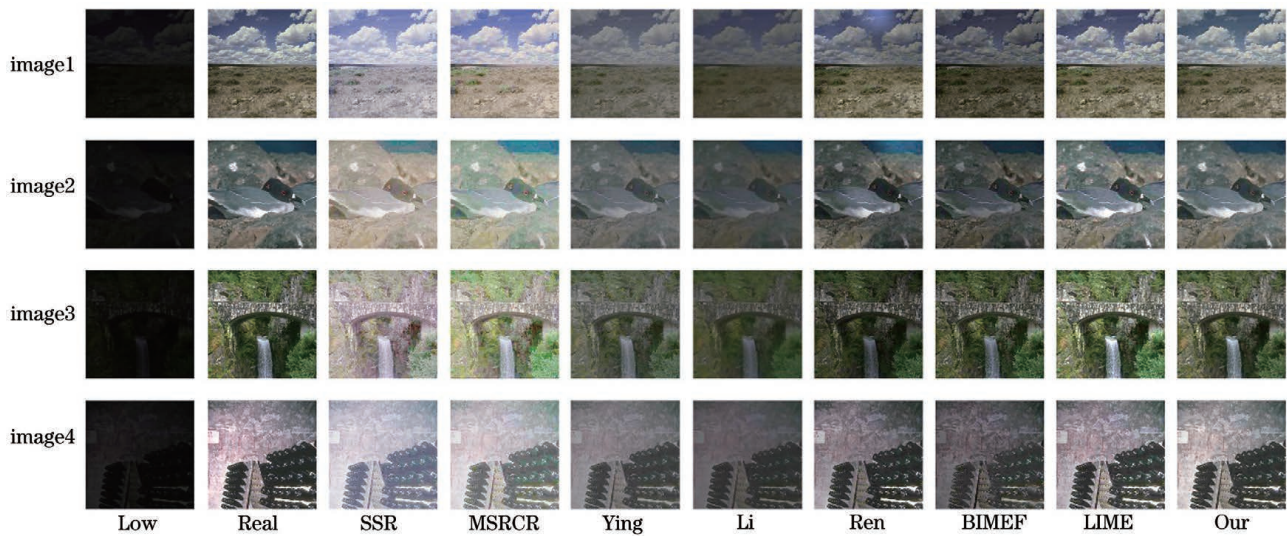


图 7 合成数据集上本文算法与 7 种对比算法主观视觉结果对比

Fig. 7 Comparison of subjective visual results between our algorithm and seven contrast algorithms on synthetic dataset

法,恢复效果提升显著,图像质量得到有效提升,但本文算法在细节恢复上优于 LIME 算法。

接下来本研究将采用定量的方式评价增强后的

图像质量,以说明本文算法的有效性。对上述 4 幅增强后的图像采用 PSNR 和 SSIM 两项客观评价指标进行衡量,客观评价指标计算结果见表 3。

表 3 合成数据集上本文算法与 7 种对比算法的 PSNR 和 SSIM

Table 3 PSNR and SSIM of our algorithm and seven contrast algorithms on synthetic dataset

Image	Evaluation index	Method							
		SSR	MSRCR	Ying	Li	Ren	BIMEF	LIME	Our
Image1	PSNR /dB	11.841	13.085	19.501	17.415	13.601	13.863	26.417	<b>29.053</b>
	SSIM	0.6656	0.6802	0.7273	0.7778	0.5221	0.7088	0.8363	<b>0.8416</b>
Image2	PSNR /dB	11.253	11.674	22.293	19.002	15.951	16.218	23.830	<b>29.959</b>
	SSIM	0.6031	0.6240	0.7887	0.8049	0.6541	0.7653	0.8323	<b>0.8746</b>
Image3	PSNR /dB	9.8805	10.946	21.450	16.578	17.093	20.704	20.307	<b>26.423</b>
	SSIM	0.5483	0.5690	0.6863	0.6675	0.4814	0.7687	0.7725	<b>0.8073</b>
Image4	PSNR /dB	12.746	13.868	15.871	15.769	11.287	11.613	20.699	<b>26.085</b>
	SSIM	0.5681	0.6006	0.6715	0.7619	0.4996	0.6513	0.8129	<b>0.8318</b>

由表 3 可以看出,在合成数据集上本文算法的 PSNR 与 SSIM 明显高于 7 种对比算法,这说明本文所提算法在合成数据集上总体优于其他算法,增强后的图像更接近于真实图像。

#### 4.6 不同对比算法对无参考图的真实低照度图像实验结果分析

为了进一步证明本文算法的有效性,从低照度 DICM<sup>[21]</sup> 图像数据库选取 3 幅真实低照度图像,利用本文算法和 7 种对比算法对选取的图像进行增强,增强后的图像如图 8 所示。

从图 8 中可以看出,本文算法与对比算法在无对比图的真实低照度图像上都可提高图像亮度。但

Ying 算法、Li 算法、Ren 算法、BIMEF 算法增强后的图像亮度偏低;SSR 算法、MSRCR 算法增强后的图像曝光过度,影响视觉感官。从图像细节与色彩恢复效果来看,MSR 算法、SSR 算法、MSRCR 算法增强后的图像边缘轮廓细节较为清晰;Li 算法增强后的图像存在伪影。本文算法与 LIME 算法增强后的结果相比于其他几种对比算法恢复效果显著提升,图像质量得到有效提升,但 LIME 算法相比于本文算法亮度恢复不自然,如 Image 2 中 LIME 算法恢复的图像亮度偏高。从主观视觉效果来说本文算法优于其他几种对比算法,增强后的图像更加接近于真实图像。

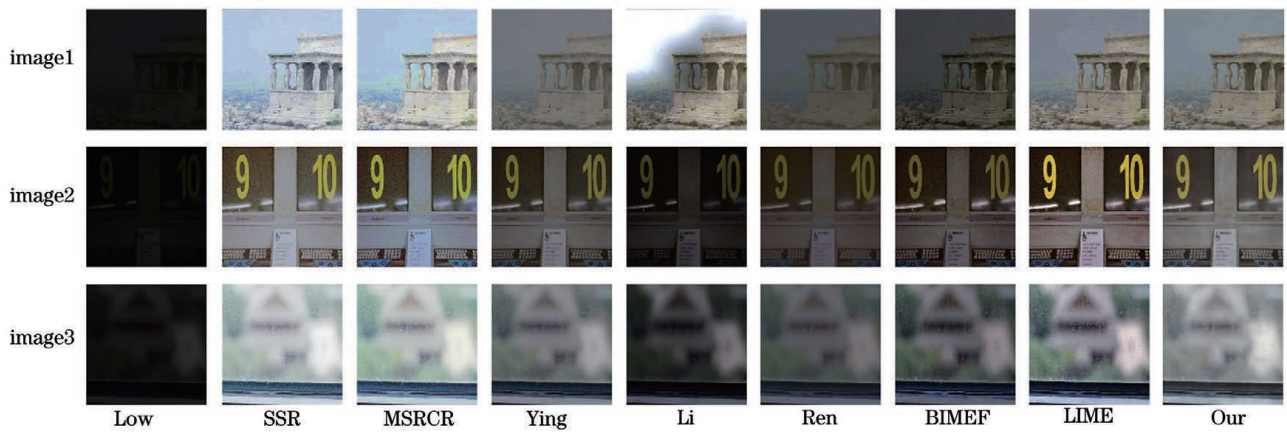


图 8 不同算法在无对比图的低照度图像上主观视觉结果对比

Fig. 8 Comparison of subjective visual results of different algorithms on low-illumination images without contrast map

对于无对比图的真实低照度图像进行定量评价,由于没有光照良好的参考图像,因此一般对此类图像采用信息熵 (Information entropy)、梯度结构相似度 (NRSS)<sup>[22]</sup> 和自然图像质量评估 (NIQE)<sup>[23]</sup> 对增强图像进行定量分析。其中:信息熵与 NRSS

越大,表明图像质量越高;NIQE 反映图像的失真程度,其值越小失真程度越小。对无对比图的 3 幅增强后的图像采用上述 3 种评价指标进行衡量,评价指标计算结果见表 4。

表 4 无对比图的低照度图像信息熵、梯度结构相似度和自然图像质量评估

Table 4 Information entropy, NRSS and NIQE of low-illumination images without contrast map

Method	Evaluation index				NRSS				NIQE			
	Image1	Image2	Image3	Average	Image1	Image2	Image3	Average	Image1	Image2	Image3	Average
SSR	6.3635	7.0093	7.0177	6.7968	0.4208	0.6408	0.4511	0.5042	21.543	30.237	28.735	26.838
MSRCR	6.2553	7.1503	7.1858	6.8305	0.4168	0.6437	0.4847	0.4125	21.173	23.282	13.111	19.189
Ying	4.9771	6.4808	6.8622	6.8638	0.2963	0.5007	0.4406	0.5151	9.352	11.769	9.21	10.11
Li	4.7706	5.6065	6.5899	5.6557	0.3614	0.4961	0.3948	0.4174	11.513	12.074	9.927	11.171
Ren	4.2115	5.6318	6.1182	5.3205	0.3559	0.3442	0.2184	0.3062	9.927	17.351	11.738	13.005
BIMEF	5.3003	6.4905	6.8105	6.2004	0.3445	0.6266	0.5277	0.4996	8.793	17.855	13.26	13.303
LIME	5.9361	6.274	7.153	6.4544	0.4394	0.6492	0.3226	0.4704	8.347	20.275	12.72	13.781
Our	6.5744	6.8264	7.0261	6.809	0.3772	0.6425	0.6024	0.5407	8.269	11.727	7.593	9.196

由表 4 可以看出,对于无对比图的低照度图像,MSRCR 算法的信息熵最大,说明该算法增强后的图像所含信息更加丰富;本文算法、Ying 算法的 NRSS 评价指标计算结果远高于其他几种算法,其中本文算法的 NRSS 值最大,说明上述两种算法恢复后的图像与原图像相比有较高的相似程度;本文算法、Ying 算法的 NIQE 评价指标计算结果略低于其他几种算法,说明上述几种算法增强后的图像色彩恢复良好,失真程度小。根据 3 种无对比图的图像质量评价指标可以看出,本文算法具有较强的泛化性。

#### 4.7 模型对比实验结果与结果分析

采用本文所提的并联残差网络模型 (Model1)

与 Residual block1 网络模型分支 (Model2)、Residual block2 模型分支 (Model4)、多分支并联残差网络模型 (Model3) 进行模型对比实验,Model2、Model3、Model4 模型如图 9 所示,不同模型增强后的结果如图 10 所示,其客观评价指标计算结果如表 5 所示。

表 5 4 种模型的 PSNR 和 SSIM 计算结果

Table 5 PSNR and SSIM results of four network models

Model	PSNR /dB	SSIM
Model1	29.552	0.9026
Model2	29.564	0.9048
Model3	27.942	0.8208
Model4	26.147	0.8321



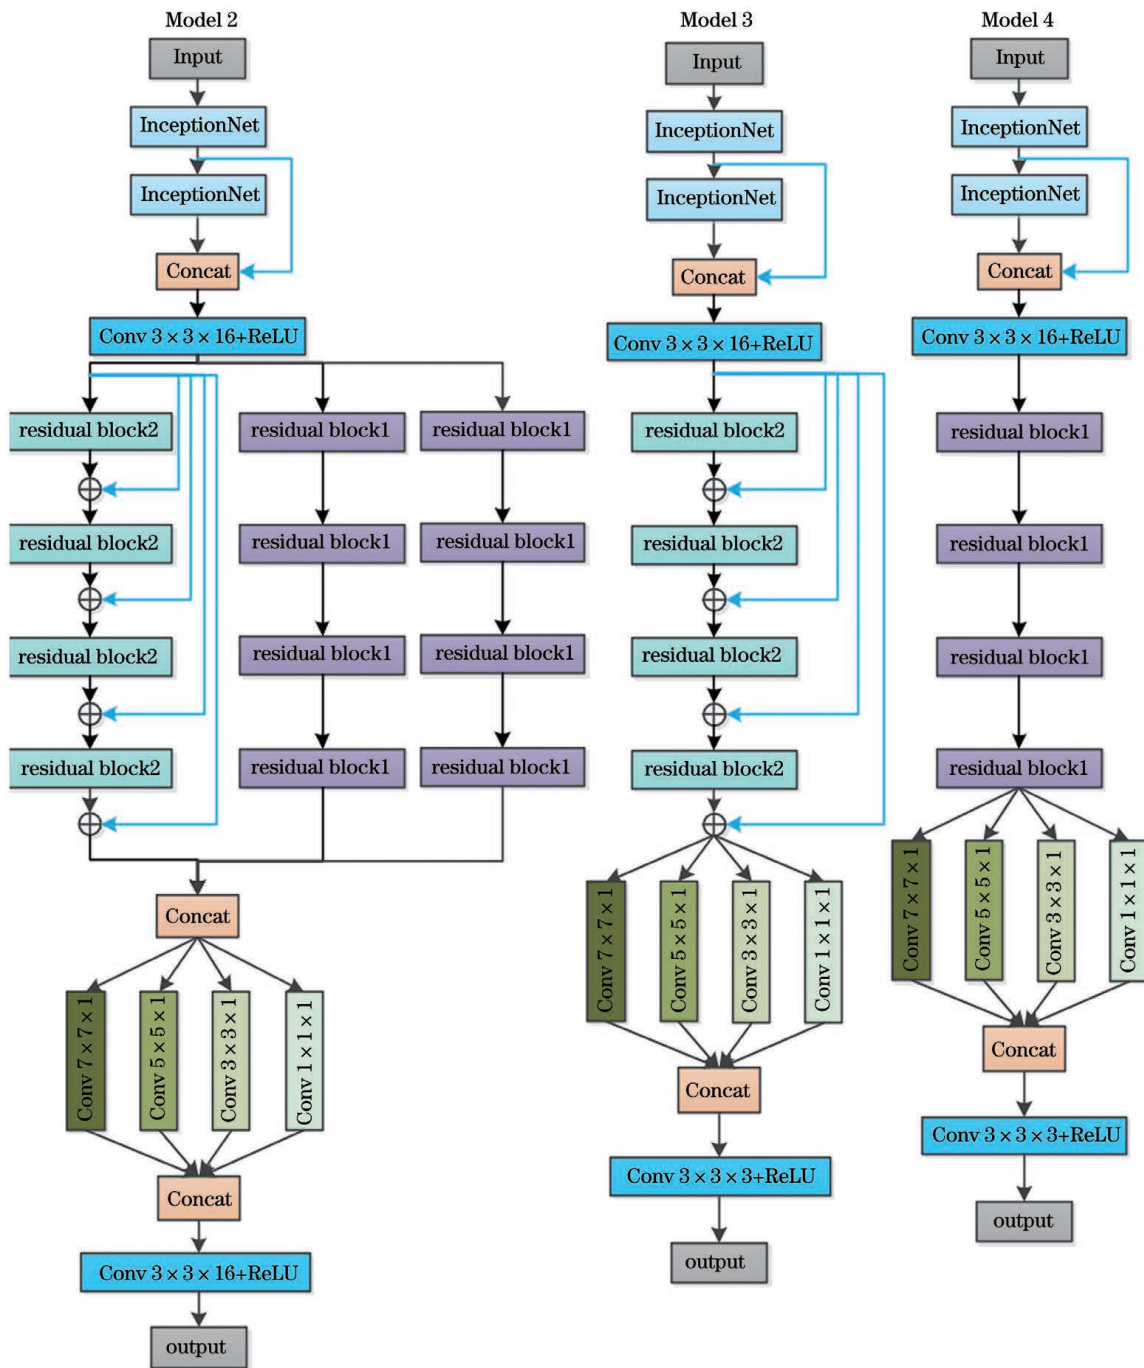


图 9 3 种对比模型结构

Fig. 9 Three comparative model structures




图 10 4 种模型结构的主观视觉结果对比

Fig. 10 Comparison of subjective visual results of four model structures

从图 10 和表 5 可以看出, Model1、Model2 增强后的主观视觉效果和客观评价指标的计算结果都优

于 Model4、Model3; 采用三个残差模型并联的 (Model2) 与采用两个残差网络并联的 (Model1) 相

比,主观视觉效果和客观评价指标的计算结果没有明显提升。因此,可以看出仅采用多个残差模块并联不能进一步提升增强效果。

#### 4.8 网络模型时间复杂度分析

为了对并联后模型的时间复杂度进行分析,对 4 种模型增强单幅图像的运行时间进行计算与对比,具体时间见表 6。

表 6 4 种模型增强单幅图像运行时间对比

Table 6 Comparison of running time of four models for enhancement of single image

Image	Model			
	Model1	Model2	Model3	Model4
Synthetic image	0.6572	0.8374	0.5982	0.6067
Real image	0.6497	0.8679	0.5889	0.6164

由表 6 可以看出,本文所提 Model1 相比于未采用并联方式的 Model3、Model4,增强单幅图片的时间略有增加,但从 4.6 节的主观视觉结果和客观评价指标计算结果可以看出:采用并联方式增强后的图片增强效果更优,失真程度更小;采用多个残差网络并联的方式,并不能达到效果增强的目的,以三个残差网络并联为例,Model2 增强单幅图片的时间明显增加,但增强效果和客观评价指标与 Model1 相比没有明显提升。

## 5 结 论

现有的低照度图像增强算法大多数都采用合成数据集进行训练,忽略了真实低照度图像照度分布不均匀等因素。为了解决这些问题,提出一种基于并联残差网络的低照度图像增强算法,它引入并联残差网络模型,减少了梯度消失、特征丢失现象;同时引入多层次区域损失函数,解决了照度分布不均匀图像的增强问题,避免了弱光区域出现曝光过度的问题。实验结果表明,所提算法能够显著提高图像的亮度,解决颜色失真问题;此外,还可以防止增强后图像边缘出现细节丢失的问题。但网络模型较大,训练时间较长,下一步将继续优化网络模型,缩短模型训练时间,提升网络模型性能,以获得更好的增强效果。

### 参 考 文 献

- [1] Chang Y C, Chang C M. A simple histogram modification scheme for contrast enhancement [J]. IEEE Transactions on Consumer Electronics, 2010, 56(2): 737-742.
- [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] Li Q Z, Liu Q. Adaptive enhancement algorithm for low illumination images based on wavelet transform [J]. Chinese Journal of Lasers, 2015, 42(2): 0209001. 李庆忠, 刘清. 基于小波变换的低照度图像自适应增强算法[J]. 中国激光, 2015, 42(2): 0209001.
- [4] 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.
- [5] 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.
- [6] 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.
- [7] Ma H Q, Ma S P, Xu Y L, et al. Low-light image enhancement based on deep convolutional neural network [J]. Acta Optica Sinica, 2019, 39(2): 0210004. 马红强, 马时平, 许悦雷, 等. 基于深度卷积神经网络的低照度图像增强 [J]. 光学学报, 2019, 39(2): 0210004.
- [8] Zhang H Y, Zhao J D. RetinexNet low illumination image enhancement algorithm in HSV space [J]. Laser & Optoelectronics Progress, 2020, 57(20): 201504. 张红颖, 赵晋东. HSV 空间的 RetinexNet 低照度图像增强算法 [J]. 激光与光电子学进展, 2020, 57(20): 201504.
- [9] Xu W J, Lee M, Zhang Y J, et al. Deep residual convolutional network for natural image denoising and brightness enhancement [C] // 2018 International Conference on Platform Technology and Service (PlatCon), January 29-31, 2018, Jeju, Korea (South). New York: IEEE Press, 2018: 1-6.
- [10] 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.
- [11] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR),

- June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1-9.
- [12] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 105-114.
- [13] Qiao S Y, Zhang Z S, Shen W, et al. Gradually updated neural networks for large-scale image recognition [EB/OL]. (2017-11-25) [2020-10-10]. <https://arxiv.org/abs/1711.09280>.
- [14] Chen C, Chen Q F, Xu J, et al. Learning to see in the dark [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 3291-3300.
- [15] 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.
- [16] Ying Z Q, Li G, Ren Y R, et al. A new low-light image enhancement algorithm using camera response model [C] // 2017 IEEE International Conference on Computer Vision Workshops (ICCVW), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 3015-3022.
- [17] Ren X T, Li M D, Cheng W H, et al. Joint enhancement and denoising method via sequential decomposition [C] // 2018 IEEE International Symposium on Circuits and Systems (ISCAS), May 27-30, 2018, Florence, Italy. New York: IEEE Press, 2018: 1-5.
- [18] Ying Z, Li G, Gao W. A bio-inspired multi-exposure fusion framework for low-light image enhancement [EB/OL]. (2017-11-02) [2020-11-10]. <https://arxiv.org/abs/1711.00591v1>.
- [19] 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.
- [20] Chen X Y, Wang S A. Superpixel segmentation based on delaunay triangulation [C] // 2016 23rd International Conference on Mechatronics and Machine Vision in Practice (M2VIP), November 28-30, 2016, Nanjing, China. New York: IEEE Press, 2016: 1-6.
- [21] 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.
- [22] 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.  
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.
- [23] Mittal A, Soundararajan R, Bovik A C. Making a "completely blind" image quality analyzer [J]. IEEE Signal Processing Letters, 2013, 20(3): 209-212.