

# 基于 Retinex 模型的弱光照图像增强算法

李博文, 唐贵进, 崔子冠

(南京邮电大学 江苏省图像处理与图像通信重点实验室, 江苏 南京 210003)

**摘要:**深度 Retinex-Net 算法利用了低/正常光图像具有相同反射率的约束条件,以数据驱动的方式实现了弱光照图像的增强。该算法解决了传统图像增强算法非线性表达能力不强以及增强后的图像不自然等一系列问题。但在该算法中分解出的照度分量模糊且不够平滑,以及对反射分量处理时采用的 BM3D 去噪操作没有考虑噪声对不同光照区域的影响,导致图像增强效果一般。鉴于 Retinex-Net 算法的局限性,提出了一种基于 Retinex 模型的弱光照图像增强算法。为了更准确地计算分解出照度分量的估计值,提出了一个照度分量平滑度损失函数来更好地学习分解的过程,并使用 U-Net 网络结构对反射分量中存在的噪声进行去噪,最后将两者进行融合得到增强后的图像。实验结果表明,该算法不仅能有效地提高主观视觉效果上的图像对比度、亮度和色彩饱和度,在客观评价指标上如 PSNR 和 SSIM 也均得到了进一步提高。

**关键词:**图像增强;Retinex;照度分量;反射分量;U-Net

中图分类号:TP301.6

文献标识码:A

文章编号:1673-629X(2021)05-0079-06

doi:10.3969/j.issn.1673-629X.2021.05.014

## A Weakly Illuminated Image Enhancement Algorithm Based on Retinex Model

LI Bo-wen, TANG Gui-jin, CUI Zi-guan

(Jiangsu Key Laboratory of Image Processing and Image Communication, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

**Abstract:** The deep Retinex-Net algorithm takes advantage of the constraints that low/normal light images have the same reflectivity and light smoothness and realizes the enhancement of weak light images in a data-driven manner. This algorithm solves a series of problems of traditional image enhancement algorithms such as the non-linear expression ability and the unnatural feature of enhanced images. However, the illuminance component decomposed in this algorithm is fuzzy and not smooth enough, and the BM3D denoising operation used in the processing of the reflection component does not consider the effect of noise on different illumination areas, resulting in a general image enhancement effect. In view of the limitations of the Retinex-Net algorithm, a weakly illuminated image enhancement algorithm based on the Retinex model is proposed. In order to calculate the estimated value of the decomposed illuminance component more accurately, a loss function of the illuminance component smoothness is proposed to better learn the decomposition process, and the U-Net network structure is used to denoise in the reflected component. These two measures are fused to obtain the enhanced image. The experiment shows that the proposed algorithm can effectively improve the subjective quality such as the contrast, brightness and color saturation of enhanced images and the objective quality such as PSNR and SSIM.

**Key words:** image enhancement; Retinex; illuminance component; reflection component; U-Net

### 0 引言

在夜间等弱光环境下拍摄的图像,由于其亮度、对比度较低且含有噪声、色彩不饱和、细节模糊等缺点,人的肉眼难以观测,并给后续图像处理带来了严峻的挑战<sup>[1]</sup>。因此,弱光照图像增强变得尤为重要。

目前,国内外已经涌现了大量的弱光照图像增强

算法,广泛使用的有两类:基于传统方法和基于深度学习算法。传统方法中,基于直方图均衡化(histogram equalization, HE)等算法<sup>[2-4]</sup>集中于增强图像对比度,但黑暗区域的细节增强不是很明显。Retinex 理论<sup>[5-6]</sup>产生了一系列图像增强算法,单尺度 Retinex (single-scale Retinex, SSR)<sup>[7]</sup>算法、多尺度 Retinex

收稿日期:2020-06-07

修回日期:2020-10-10

基金项目:国家自然科学基金(61501260);江苏省科协提升计划项目(TJ215039);南京邮电大学科研基金项目(NY219076)

作者简介:李博文(1995-),男,硕士研究生,研究方向为图像增强、图像复原;唐贵进,副教授,博士,研究方向为图像处理、多媒体通信、视频分析等;崔子冠,副教授,硕士,研究方向为视频编码与传输、图像处理、视频质量评价等。

(multi-scale Retinex, MSR)<sup>[8]</sup>算法以及唐宁等人<sup>[9]</sup>提出的改进多尺度 Retinex 的彩色图像增强算法等,它们增强的效果通常看起来不自然,并且在某些地方过度增强。Dong 等人<sup>[10]</sup>提出了去雾方法来增强弱光照图像,并取得了较好的增强效果。Fu 等人<sup>[11]</sup>提出了一种加权变分模型 SRIE(simultaneous reflectance and illumination estimation)来估计反射分量和照度分量。Guo 等人<sup>[12]</sup>估计具有先验结构的照明,并将反射率作为最终的增强结果。Ying 等人<sup>[13]</sup>提出一种用于低照度图像增强的多重曝光融合框架,根据权重矩阵融合输入图像和合成图像来获得增强的效果。尽管这些方法在某些情况下可能会产生较好的结果,但增强后的图像往往不符合实际场景,且容易在边缘出现伪影。

随着深度神经网络的迅速发展, CNN(convolutional neural networks)已广泛用于图像处理任务当中,其中包括图像去噪<sup>[14]</sup>、图像去雾<sup>[15]</sup>、图像超分辨率<sup>[16]</sup>等方向。Lore K G 等人<sup>[17]</sup>提出了一种基于深度自动编码器的方法,该方法学习从综合暗化和噪声添加的训练示例中同时进行低光增强和降噪。Wei 等人<sup>[18]</sup>设计了一个称为 Retinex-Net 的深度网络,算法中分解出的照度分量有少许的模糊且不够平滑,给后续照度分量的增强带来了一些困难,而且再在对反射分量去噪时,也出现了不同程度的噪声。为了克服这些缺点,该文提出了一种有效的弱光图像增强算法,在引导图像分解时提出了一个损失函数来约束光照分量的平滑,对于反射分量的处理不再使用传统的去噪方法,而是使用卷积神经网络来恢复反射分量,进而增强暗光图像。

## 1 Retinex 理论

Retinex 理论<sup>[19]</sup>作为弱光照图像增强领域的一个

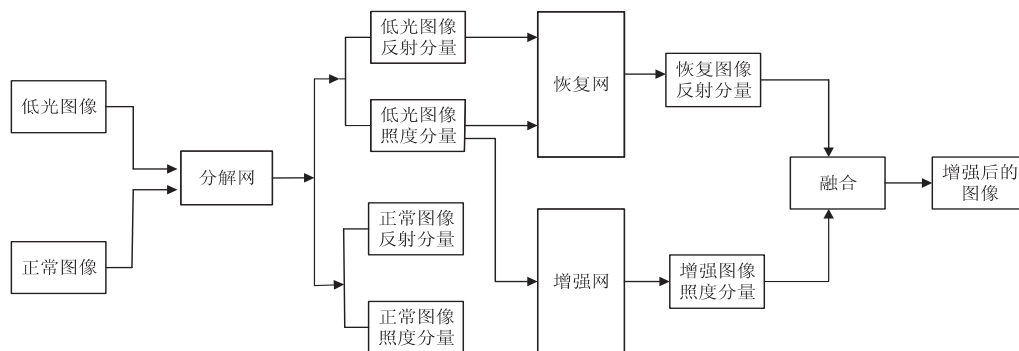


图 1 文中算法的网络结构

### 2.2 分解模块

由图 2 可知,文中提出的分解网中使用多个  $3 \times 3$  卷积层以及 LRelu(leaky rectified linear unit)激活函数和池化操作提取不同层次的图像特征,为结合 U-Net<sup>[20]</sup>思想,首先进行上采样,保证与相结合特征图大

基础理论,该理论假设原始图像分解为光照图像和反射率图像的乘积,可以表示为以下形式:

$$L(x) = I(x)R(x) \quad (1)$$

其中,  $x$  表示像素点;  $L(x)$  表示原始图像;  $I(x)$  表示光照图像;  $R(x)$  表示反射率图像。关于实现图像增强的要点,第一步从原始图像中估计出光照图像  $I(x)$ ,第二步计算出反射率图像  $R(x)$ ,消除  $I(x)$  中弱光照的影响后得到增强后的图像。

## 2 文中算法

### 2.1 算法描述

受到 Wei 等人<sup>[18]</sup>提出的 Retinex-Net 算法的启发,文中算法基于 Retinex 模型建立了一个深层的神经网络结构来实现弱光照图像增强。网络结构如图 1 所示。该网络结构分为三个网络:分解网、恢复网、增强网。在分解网中,由于没有反射分量和光照分量对应的真实值,网络利用两个约束条件学习图像分解的过程。Retinex-Net 算法分解出的照度分量有少许的模糊且不够平滑,文中提出了一个约束光照分量平滑度的损失函数,能够很好地分解出比较真实的反射分量和光照分量。在恢复网中,由于分解出的反射分量中包含有噪声,因此在重建输出图像之前,要对反射分量进行去噪处理,由于 Retinex-Net 算法对反射分量去噪时使用的传统的方法效果不是很好,文中采用了典型的卷积神经网络结构。最后在增强网中,在弱/正常光照图像对之间建立一个映射关系,学习正常光照的全局信息,从而将弱光图像分解出的照度分量进行增强。最后将增强的照度分量和恢复的反射分量进行融合,进而重建增强后的图像。

小一致,将前几层的特征图引入到更深层,将其复制对应拼接,之后进行特征融合,得到细节保存更完整的特征图,最后一个  $3 \times 3$  的卷积层从特征空间投影出反射分量和照度分量,使用 Sigmoid 函数将两者约束在  $[0, 1]$  的范围内。




图2 分解网

分解网的损失函数  $L_{\text{decom}}$  由三部分组成:重建损失  $L_{\text{re}}$ 、反射分量损失  $L_r$ 、照度分量平滑损失  $L_i$ , 其中  $\lambda_r$ 、 $\lambda_i$  分别表示反射分量一致性和照度分量平滑度的系数:

$$L_{\text{decom}} = L_{\text{re}} + \lambda_r L_r + \lambda_i L_i \quad (2)$$

重建损失  $L_{\text{re}}$  为了衡量低/正常图像分解前后的误差,可表示为:

$$L_{\text{re}} = \|I_l R_l - I_l\|_1 + \|I_h R_h - I_h\|_1 \quad (3)$$

其中,  $I_l$  和  $I_h$  分别表示分解网分解出的弱光照和正常光照图像的照度分量,  $R_l$  和  $R_h$  分别表示分解网分解出的弱光照和正常光照图像的反射分量,  $L_l$  和  $L_h$  分别表示弱光照和正常光照图像,  $\|\cdot\|_1$  表示  $L_1$  范数。

反射分量损失  $L_r$  来约束反射分量的一致性,可表示为:

$$L_r = \|R_l - R_h\|_1 \quad (4)$$

照度分量平滑损失  $L_i$  保证分解出的照度分量是分段平滑的,可表示为:

$$L_i = \left\| \frac{\nabla I_l}{\max(|\nabla I_l|, \varepsilon)} \right\|_1 + \left\| \frac{\nabla I_h}{\max(|\nabla I_h|, \varepsilon)} \right\|_1 \quad (5)$$

其中,  $\nabla I_l$  和  $\nabla I_h$  分别表示分解网分解出的弱光照和正常光照图像的照度分量的梯度值,  $\nabla L_l$  和  $\nabla L_h$  分别表示弱光照和正常光照图像的梯度值,  $\varepsilon$  为一个很小的

正数,防止分母为零。

### 2.3 反射分量恢复模块

文中提出的恢复网如图3所示,该子网和分解网中的网络结构一样,层数更深,不仅能很好地调节网络的自适应能力,而且还能很好地去除反射分量中的噪声,在很大程度上减小色彩失真。文中采用分解网输出的正常图像的反射分量作为真实值,为了更好地恢复反射分量,提出的损失函数  $L_{\text{restore}}$  如下所示:

$$L_{\text{restore}} = \|R_{\text{re}} - R_h\|_2^2 + \|\nabla R_{\text{re}} - \nabla R_h\|_2^2 + \lambda_c L_c \quad (6)$$

其中,  $R_{\text{re}}$  为恢复的反射分量,  $\|\cdot\|_2$  表示  $L_2$  范数,  $\nabla R_{\text{re}}$  和  $\nabla R_h$  分别表示恢复的反射分量和正常图像的反射分量的梯度值,  $L_c$  为颜色损失函数,  $\lambda_c$  为颜色感知平衡系数。

$$L_c = \|R_{\text{reb}} - R_{\text{hb}}\|_2^2 \quad (7)$$

$$R_{\text{reb}} = \sum_{k,j} R_{\text{re}}(i+k, j+l) * G(k, l) \quad (8)$$

$$R_{\text{hb}} = \sum_{k,j} R_h(i+k, j+l) * G(k, l) \quad (9)$$

$$G(k, l) = A e^{-\left(\frac{(k-\mu_x)^2}{2\sigma_x^2} + \frac{(l-\mu_y)^2}{2\sigma_y^2}\right)} \quad (10)$$

其中,  $R_{\text{reb}}$ 、 $R_{\text{hb}}$  是  $R_{\text{re}}$ 、 $R_h$  经过高斯模糊后的图像,  $G(k, l)$  为高斯核,  $A$  为幅值,  $k$  和  $l$  是中心点坐标,  $\mu_x$  与  $\mu_y$  为均值,  $\sigma_x$  与  $\sigma_y$  为方差。




图3 恢复网

### 2.4 照度分量增强模块

由于不存在照度分量的真实值,需要在弱光图像和正常图像之间建立一种机制来灵活地学习映射的过

程。增强网采用编解码器结构的总体框架如图4所示。




图4 增强网

首先,输入图像依次向下采样到小尺度,此时网络可以看到大规模的光照信息分布。下采样块由一系列

$3 \times 3$  的卷积层和一个线性修正单元 Relu 组成。利用大规模光照信息,上采样块重建局部光照分布。在上

采样块中,使用了最近邻插值操作和与之同样大小的卷积层和线性修正单元。使用跳跃连接将下采样块的特征图引入到对应的镜像上采样块并与之相加,从而强制网络学习残差。通过最近邻插值将这些特征图调整到同样大小的尺度,并将它们拼接到特定多个通道的特征图。然后,通过一个  $1 \times 1$  的卷积层将连接的特征图降为 3 通道。最后使用一个  $3 \times 3$  个卷积层来重建照度分量。

增强网的损失函数  $L_{\text{enhance}}$  如下所示,其中  $I_{\text{en}}$  为增强后的照度分量。

$$L_{\text{enhance}} = \|I_{\text{en}} - I_{\text{h}}\|_2^2 + \|\nabla I_{\text{en}} - \nabla I_{\text{h}}\|_2^2 \quad (11)$$

### 3 实验结果与分析

#### 3.1 实验

文中使用 LOL 数据集<sup>[18]</sup>作为训练数据集,其中包括 500 个低/正常光图像对。其中 485 张图片用来训练,15 张图片用来测试,部分测试图片如图 5 所示。三个子网络批大小设置为 10,补丁大小设置为  $48 \times 48$ ,  $\lambda_r$ 、 $\lambda_i$ 、 $\lambda_c$  分别设置为 0.02、0.15、0.004,学习率设置为  $1 \times 10^{-4}$ ,网络整体迭代 2 000 次。使用 Tensorflow 框架在 Nvidia GTX 1080Ti GPU 和 Intel Core i7-8700 3.20 GHz CPU 上训练整个网络。



图 5 测试图片

(左侧为弱光照图片,右侧为对应的正常光照图)

#### 3.2 评价

为了评估文中方法的性能,与几种较先进的方法进行了对比,其中包括 Dong 等人<sup>[10]</sup>提出的去雾算法, Fu 等人<sup>[11]</sup>提出的 SRIE 算法, Guo 等人<sup>[12]</sup>提出的 LIME 算法,以及 Wei 等人<sup>[18]</sup>提出的 Retinex-Net 算法,效果如图 6 ~ 图 8 所示。




图 6 各算法在书柜图像上的主观视觉对比

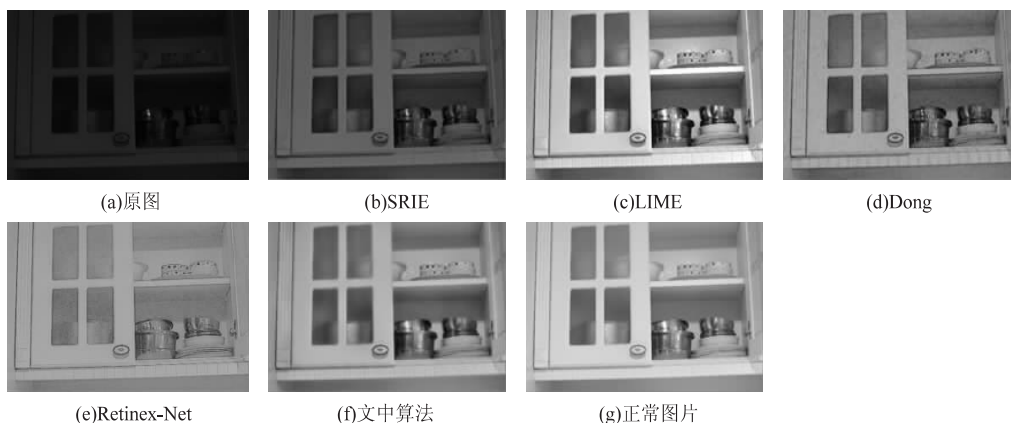


图 7 各算法在碗柜图像上的主观视觉对比




图8 各算法在跳水台图像上的主观视觉对比

由以上三幅图中可以看出,文中算法和对比的四种算法都能够在不同程度上实现对弱光照图像的增强。SRIE 算法没有充分改善低光图像的亮度,并且细节不能清楚地看到,增强效果不明显,图像亮度仍较暗;LIME 算法中明亮区域的图像增强过度,增强后的图像光照不自然,且会出现程度不等的色彩失真,如图6中书柜颜色泛绿,而真实图片为白色,图7和图8中图片增强过度,显得格外刺眼,与原始光照较好的图像有一定的差距;Dong 算法中的图像亮度整体偏暗,图像边缘处有明显的黑色轮廓,如图6中碗柜的边缘是一些阴影,但增强后出现了严重的轮廓线;Retinex-Net 算法能够有效地改善图像的亮度,但会导致图像噪声过多,图像整体较模糊且会出现程度不等的色彩失真,如图6和图7中的书柜和碗柜中出现了很多黑

色的噪声点,而且颜色泛绿,显然不符合实际场景。与其他四种方法相比,文中算法能够提高图像的亮度、对比度和色彩饱和度,产生了更加生动和自然的结果,更加接近正常光照下的原始图像。

为了更客观地对比各算法的增强表现,使用峰值信噪比 PSNR (peak signal to noise ratio) 和结构相似性指数 SSIM (structural similarity index) 对图像质量进行评估。表1给出了使用不同算法对测试集中15幅弱光照图像增强后的 PSNR 和 SSIM 的值。从表中可以看出,文中算法相对其他四种算法在 PSNR 和 SSIM 上是最优的,算法的增强效果尤为突出。以上实验结果表明,从主观视觉和客观评价指标这两个角度来说,文中算法对弱光照图像的增强能力均优于其他几种算法。

表1 各种算法的 PSNR 和 SSIM 值

图像	SRIE	LIME	Dong	Retinex-Net	文中算法
	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
测图 1	10.61/0.548 6	16.16/0.675 8	14.72/0.687 4	13.61/0.537 6	23.76/0.877 7
测图 2	9.26/0.589 1	19.84/0.666 3	16.04/0.663 3	17.82/0.440 2	20.52/0.891 1
测图 3	11.02/0.609 9	19.96/0.673 9	20.85/0.709 2	21.78/0.591 4	25.13/0.876 8
测图 4	18.85/0.733 0	15.11/0.530 1	18.09/0.610 6	15.59/0.546 2	16.94/0.734 2
测图 5	9.87/0.475 7	19.23/0.557 7	17.28/0.649 2	18.34/0.482 4	20.50/0.864 5
测图 6	6.84/0.311 0	13.56/0.366 9	9.67/0.404 7	12.34/0.294 9	21.26/0.820 9
测图 7	14.38/0.527 5	15.53/0.521 8	19.46/0.581 8	18.65/0.398 9	14.25/0.617 6
测图 8	14.26/0.644 3	15.98/0.436 9	25.30/0.680 7	17.22/0.358 5	13.45/0.786 3
测图 9	6.67/0.322 3	13.01/0.292 6	9.33/0.390 9	11.93/0.311 2	21.47/0.849 3
测图 10	9.30/0.333 5	15.51/0.285 4	12.31/0.395 9	15.44/0.291 2	24.11/0.789 9
测图 11	10.67/0.583 8	19.66/0.523 2	17.86/0.606 2	19.81/0.388 9	19.61/0.835 7
测图 12	14.40/0.606 0	15.55/0.445 3	20.87/0.578 7	17.62/0.409 2	20.02/0.854 3
测图 13	11.32/0.310 4	16.24/0.393 8	14.89/0.417 9	18.33/0.436 4	17.81/0.716 7
测图 14	16.76/0.617 7	14.26/0.369 2	21.42/0.574 6	15.35/0.305 8	19.73/0.754 6
测图 15	8.81/0.569 2	20.08/0.666 9	16.04/0.646 4	17.78/0.494 0	19.05/0.896 2
平均值	11.53/0.518 8	16.65/0.493 8	16.94/0.573 2	16.77/0.491 1	19.84/0.811 1



#### 4 结束语

提出了一种有效的弱光图像增强算法,在引导图像分解时提出了一个损失函数来约束光照分量的平滑,能够更加准确地估计弱光图像的照射分量和反射分量。对于反射分量中噪声的处理不再使用传统的去噪方法,而是使用 U-Net 网络来恢复反射分量,照度分量增强过程中学习了一种有效映射功能,进而增强暗光图像。实验结果表明,该算法在主观视觉上亮度适中、颜色自然、细节清晰,在峰值信噪比和结构相似性等客观指标下也得到了很大程度的提高。接下来的工作,会继续对该算法进行改进,使得算法能够适应在一些颜色鲜艳的场景中,更进一步地减小颜色失真。

#### 参考文献:

- [1] 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):0209001-1-0209001-7.
- [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] ABDULLAHALWADUD M, KABIR H, DEWAN M A, et al. A dynamic histogram equalization for image contrast enhancement[C]//2007 international conference on consumer electronics (ICCE). Las Vegas, Nevada, USA: IEEE, 2007: 593-600.
- [4] IBRAHIM H, KONG N S. Brightness preserving dynamic histogram equalization for image contrast enhancement[J]. IEEE Transactions on Consumer Electronics, 2007, 53(4): 1752-1758.
- [5] 智宁,毛善君,李梅. 基于相对梯度正则化的 Retinex 变分模型及其应用[J]. 通信学报,2017,38(11):65-75.
- [6] 李学明. 基于 Retinex 理论的图像增强算法[J]. 计算机应用研究,2005,22(2):235-237.
- [7] JOBSON D J, RAHMAN Z, WOODDELL G A, et al. Properties and performance of a center/surround retinex[J]. IEEE Transactions on Image Processing, 1997, 6(3):451-462.
- [8] JOBSON D J, RAHMAN Z, WOODDELL G A, et al. A multi-scale 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] 唐宁,赵鹏,吴绍启. 改进多尺度 Retinex 的彩色图像增强[J]. 电子设计工程,2016,24(12):168-171.
- [10] DONG X, WANG G, PANG Y, et al. Fast efficient algorithm for enhancement of low lighting video[C]//2011 international conference on multimedia and expo(ICME). Barcelona, Spain: IEEE, 2011:1-6.
- [11] FU X, ZENG D, HUANG Y, et al. A fusion-based enhancing method for weakly illuminated images[J]. Signal Processing, 2016, 129(1):82-96.
- [12] GUO X, LI Y, LING H, et al. LIME: low-light image enhancement via illumination map estimation[J]. IEEE Transactions on Image Processing, 2017, 26(2):982-993.
- [13] YING Z, LI G, REN Y, et al. A new image contrast enhancement algorithm using exposure fusion framework[C]//2017 international conference on computer analysis of images and patterns (CAIP). Ystad, Sweden: IEEE, 2017:36-46.
- [14] ZHANG K, ZUO W, CHEN Y, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.
- [15] CAI B, XU X, JIA K, et al. DehazeNet: an end-to-end system for single image haze removal[J]. IEEE Transactions on Image Processing, 2016, 25(11):5187-5198.
- [16] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2):295-307.
- [17] LORE K G, AKINTAYO A, SARKAR S, et al. LLNet: a deep autoencoder approach to natural low-light image enhancement[J]. Pattern Recognition, 2017, 61(1):650-662.
- [18] WEI C, WANG W, YANG W, et al. Deep retinex decomposition for low-light enhancement[C]//2018 British machine vision conference (BMVC). Newcastle, UK: IEEE, 2018:1-12.
- [19] LAND E H. The retinex theory of color vision[J]. Scientific American, 1977, 237(6):108-128.
- [20] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//2015 international conference on medical image computing and computer-assisted intervention (MICCAI). Munich, Germany: IEEE, 2015:234-241.