

基于多通道 Retinex 模型的低照度图像增强网络

张 箴^{1,2}, 鹿 阳^{1,2}, 苏奕铭^{1,2}, 唐延东¹, 田建东¹

1. 中国科学院沈阳自动化研究所机器人学国家重点实验室, 辽宁 沈阳 110016;

2. 中国科学院大学, 北京 100049

基金项目: 国家自然科学基金(U2013210)

通信作者: 田建东, tianjd@sia.cn 收稿/录用/修回: 2023-08-09/2023-09-11/2023-10-13

摘要

低照度图像增强是近年计算机视觉领域的研究热点之一, 在目标检测、自动驾驶、夜间监控等领域具有广泛的应用价值。本文分析了同一场景在不同曝光下所得到的图像的像素值分布, 发现其低照度图像与正常光照图像在 RGB 三通道的增强比具有一定差异。基于这一现象, 提出了一种基于多通道 Retinex 模型的低照度图像增强网络。为获得更准确的初始化光照和反射分量, 设计了初始化模块。为解决低照度增强后存在的色偏问题, 在光照增强模块中采用了分通道增强的策略, 设计了针对性的颜色损失函数, 并通过对抗性损失函数来提升生成图片的质量。在两种公开数据集上进行了实验, 本文方法与现有的先进算法进行对比并取得了较好的结果。与次优的方法相比, 本文方法得到的增强图像与参考图像之间的峰值信噪比提高了 20%, 结构相似性提高 7.2%, 且消除了图像中的噪声, 与参考图像在数值指标和视觉效果上都更为接近。

关键词

低照度图像增强

光照分解

Retinex 模型

中图法分类号: TP24

文献标志码: A

Low-light Image Enhancement Network Based on Multichannel Retinex Model

ZHANG Zhen^{1,2}, LU Yang^{1,2}, SU Yiming^{1,2}, TANG Yandong¹, TIAN Jiandong¹

1. State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China

Abstract

Low-light image enhancement has been one of the hottest research fields of computer vision in recent years. It has many applications in object detection, autonomous driving, and night monitoring. The pixel value distribution of images obtained from the same scene is analyzed under different exposures. It finds differences in the growth ratio of its low-light and normal-illumination images in RGB three channels. Based on this observation, a low-light image enhancement network is proposed on the basis of multi-channel Retinex model. In order to solve the problem of color deviation after low-light enhancement, a multi-channel enhancement strategy is adopted in the light enhancement module, and a targeted color loss function is designed, which improves the quality of generated pictures through the antagonistic loss function. Experimental results show that the peak signal-to-noise ratio between the enhanced image and the reference image is improved by 20% by

Keywords

low-light image enhancement;

illumination decomposition;

Retinex model

the proposed method in comparison with the existing advanced algorithms through experiments on two public datasets, and structural similarity is improved by 7.2%. The noise of image is eliminated, and it is closer to the reference image in terms of numerical indicators and visual effects.

0 引言

由于自然环境的光照复杂性, 图像往往会受到各种光照条件的限制。在光照不足条件下拍摄的图像称为低照度图像。低照度图像往往存在纹理信息模糊, 亮度及对比度不足等问题。这给后续的机器视觉算法, 例如夜间监控、目标跟踪^[1]、自动驾驶^[2]、特征提取^[3]等任务, 造成了性能下降、鲁棒性降低等问题。因此, 对低照度图像的增强, 已经成为视觉领域的热点问题之一, 具有较高的应用价值。

近年来, 国内外学者围绕低照度图像增强这一问题, 进行了大量研究, 根据建立模型的角度不同, 可以将低照度图像增强方法大致分为基于传统模型的方法以及基于深度学习网络的方法。

基于传统模型的代表性方法主要可以分为两种。一种是基于图像的直方图均衡化, 直方图均衡化是一种通过调整直方图来拉伸图像的动态范围的方法, 以使低照度图像变得更加清晰可见^[4]。然而, 全局应用直方图均衡化会导致局部过曝和放大隐藏的密集噪声。为了改善整体视觉质量, 一些方法采用了新的失真模型, 例如 LEE 等^[5]提出的方法。为了更好地调整直方图, LEE 等^[6]提出了一种基于二维直方图分层差异表示的新型对比度增强算法, 通过增强相邻像素之间的灰度差异来提高图像的对比度。此外, 一些方法引入额外信息来自适应地指导像素值变换, 例如 LEE 等^[7]利用深度信息, YING 等^[8]引入相机响应模型找到最佳曝光率以指导低光图像增强。一般来说, 伴随更多的细节信息和约束条件, 局部区域适应性在基于直方图均衡化的增强过程中不断提升。然而, 现有的基于图像直方图均衡化的低照度增强方法对于局部区域中的视觉属性调整仍旧远远不够精确, 增强后的图像可能出现曝光不足, 曝光过度以及放大噪声。

基于 Retinex 理论^[9]的低照度增强算法则是另外一种常用的传统低照度增强算法。Retinex 理论认为对于任意图像, 都可以通过分解获得输入图像的光照分量和反射分量, 并分别增强它们以重建正

常曝光图像。WANG 等^[10]为 Retinex 分解设计了一个光照滤波器, 可以在增强低照度图像细节的同时尽量保持图像的自然度。在 WANG 等的方法^[11]中, 使用分层贝叶斯模型对反射率和光照的先验分布、以及增强过程的参数进行了联合建模。GUO 等^[12]将图像 RGB 三通道的像素最大值作为初始照明, 并使用结构感知先验来细化初始照明图, 该方法可以提高图像整体亮度, 但会过度曝光某些区域。LI 等^[13]在 Retinex 模型基础上进行了改进, 与传统的 Retinex 模型相比, 该模型还考虑了噪声图, 以提高增强伴有强烈噪声的低光图像的效果。采用反射率梯度的保真项来揭示低照度图像中的结构细节, 并提出了一种基于增强拉格朗日乘子的无对数变换的交替方向最小化算法来估计噪声图。REN 等^[14]引入了一种联合的低光增强和去噪策略, 旨在获得增强良好的低光图像, 同时消除固有的噪声问题。管宇等^[15]通过正交分解的方法将低照度图像分解为光照分量和光照不变量, 并通过多曝光图像生成正常曝光的图像。尽管该方法能使增强后的图像具有更大动态范围, 但恢复后的图像饱和度会有所降低。尽管上述传统方法在一些特定场景中实现了较为优越的恢复结果, 但是这些方法很难对任意场景下获取的低照度图像, 定义出统一化的约束条件。同时, 在约束条件的设定上, 往往也需要手动设定, 以及对物理参数的精心调整, 因此它们的适应性不够好, 在应用于大规模测试数据时通常无法得到令人满意的结果。

最近, 基于深度学习网络的低照度图像增强方法^[16-25]逐渐成为主流。在深度学习框架下的低照度增强算法中, 能够有效融合深度学习模型与传统光学模型的网络往往在性能表现上较为突出。ATOUM 等^[16]将输入图像中的颜色分量逐通道进行增强, 将低照度增强问题简化。XU 等^[17]基于频域分解, 提出了注意力上下文编码模块以及跨域变换模块, 能够在抑制噪声的同时, 恢复低照度退化下的图像细节。YANG 等^[18]引入了长短期记忆递归神经网络, 从长短期记忆的角度进一步提升了低照度图像增强的质量。WEI 等^[19]提出了最早期的基

于 Retinex 模型与图像分解思想的低照度增强网络,但由于网络较为简单,该方法会造成色彩和对比度失真,导致不自然的结果。ZHANG 等^[20]提出了一种基于增广拉格朗日乘子法以及交替方向乘子的方法,对总变分模块进行多次迭代优化分解,降低了噪声含量,并提升了低照度增强算法的恢复质量。LYU 等^[21]基于不同特征层的特征,有机融合并增强了多个层内的空间特征以得到最终增强结果,该方法的增强结果具有相对自然的光照分布,但其结果仍然不够明亮。基于全局照明估计模块和细节重建模块,WANG 等^[22]提出了全局光照感知和细节保持网络,该方法能够保持图像细节并提高图像可见性,表现较为优越。ZHAO 等^[23]将低照度图像增强任务看作是在低曝光图像和其配对的增强版本之间进行图像特征转换,并提出了用于解决这一任务的深度对称网络,为了确保互相传播的可逆性,本文特别构建了两对具有相同预训练参数的编码器-解码器。这种可逆机制与双向特征转换既能够避免色彩偏差,又能够有效地恢复图像增强的内容。JIANG 等^[24]提出了一种无监督生成对抗网络。与使用真实数据监督学习算法不同,JIANG 等使用从输入中提取的信息来对非配对的训练数据进行正规化处理,并为低光图像增强问题提出了一系列创新,包括全局-局部鉴别器结构、自我正则化的感知损失融合和注意机制。但该方法容易产生区域性的颜色伪影,难以获得令人满意的增强结果。LI 等^[25]使用图像特定曲线估计方法来实现低照度图像增强,并为此设计了一个轻量级的 DCE-Net 深度神经网络。LIU 等^[26]提出了一种受 Retinex 原理启发的搜索展开网络,同时采用了架构搜索技术,其中合作架构搜索被用来发现基本块的轻量级先验架构,非参考损失被用来训练网络,该方法旨在构建轻量级但高效的图像增强网络,特别适用于在实际场景中的低光图像处理应用。

针对现有低照度图像增强方法的不足,本文提出了基于多通道 Retinex 的低照度图像增强生成对抗网络。本文的主要贡献总结如下:

1) 基于改进的多通道 Retinex 模型,提出了一种新的低照度图像增强生成对抗网络。生成器由 3 个功能清晰的模块组成,分别对应初始化、反射分量去噪和光照分量增强。在判别器中,通过感知质量引导的对抗性学习获得高质量的增强图像。其中

还提出了新的注意力增强模块。

2) 本文分析了同一物体在不同光照下所拍摄得图像的关系,发现在同一物体的低照度图像与正常光照图像对之间 RGB 三通道的增强比例是不同的。对此其中在光照增强模块中对 RGB 三通道进行了分通道增强,并针对增强后可能存在的色偏问题,设计了新的颜色损失函数。

3) 本文在真实世界的数据集上进行了大量实验,证明了本文提出方法的高效性和优越性。本文的方法可以实现噪声抑制和细节保留,并且抑制了色偏的产生,最终增强结果具有一定的优越性。

1 多通道 Retinex 模型

Retinex^[9]理论是 20 世纪 80 年代由 DEWIN 等提出的算法。该理论认为人眼可以感知近似一致的色彩信息,这种性质称为色彩恒定性。这种恒定性是视网膜(retina)与大脑皮层(cortex)所共同作用的结果,即 Retinex 理论。Retinex 模型是一种用于图像处理的计算机视觉模型,其理论基础包括颜色恒常性和三色理论。

Retinex 理论认为图像 $I(x, y)$ 是由照度图像与反射图像组成。前者涵盖物体的入射分量的信息,用 $L(x, y)$ 表示;后者涵盖物体的反射部分的信息,用 $R(x, y)$ 表示^[9]。Retinex 理论可以用式(1)表示:

$$I(x, y) = R(x, y) \odot L(x, y) \quad (1)$$

其中 \odot 表示逐元素相乘。在对低照度图像增强的研究中,通过对大量低照度图像和正常光照图像进行比对,发现低照度图像和正常光照图像 RGB 三通道间存在着线性关系,但像素值在三通道之间增强的斜率是不同的,这是因为低照度和正常光照图像之间光照不同,光照的光谱能量分布不同,即使是通过不同曝光时间所生的低照度图像数据集,如 LOL 数据集,经过相机内置的白平衡和颜色校正等相机图像信号处理后,RGB 三通道之间的增强比例也是不同的,如图 1(c)所示,图中横坐标表示低照度图像像素值,纵坐标表示对应的正常光照图像像素值。因此在低照度增强时,将式(1)改为

$$I(x, y) = R(x, y) \odot L_c(x, y) \quad (2)$$

其中, $c \in \{R, G, B\}$, 在光照增强模块中,对三通道的光照分别进行增强,以避免色偏的产生。

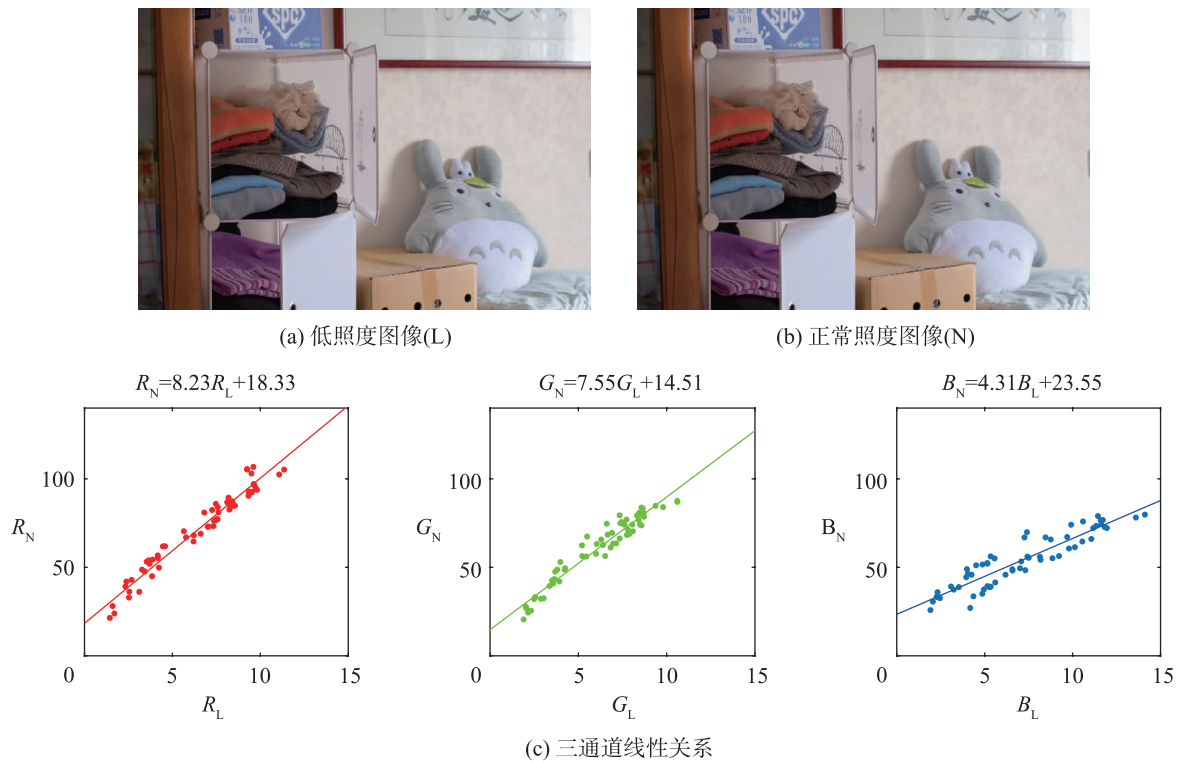


图 1 不同亮度图像三通道线性关系

Fig.1 Three-channel linear relationship between the images with different illuminations

2 基于多通道 Retinex 模型的低照度图像增强网络

由于光照分量 R 和反射分量 L_c 难以准确获取, 本文利用深度网络自适应地拟合 R 和 L_c 。因此, 基于上述优化方案, 将 Retinex 分解和低照度增强的过程映射到深度展开的网络架构, 并为低照

度图像增强提出一个新的框架。如图 2 所示, 本文所提出的基于多通道 Retinex 模型的低照度图像增强网络 (MRetinex-GAN) 由生成器和判别器组成, 其中生成器包括 3 个模块, 即初始化模块、反射去噪模块和光照增强模块。通过初始化模块, 将输入的低照度图像准确地分解为光照分量和反射分量, 将结果分别输入反射去噪模块和光照增强模块进行

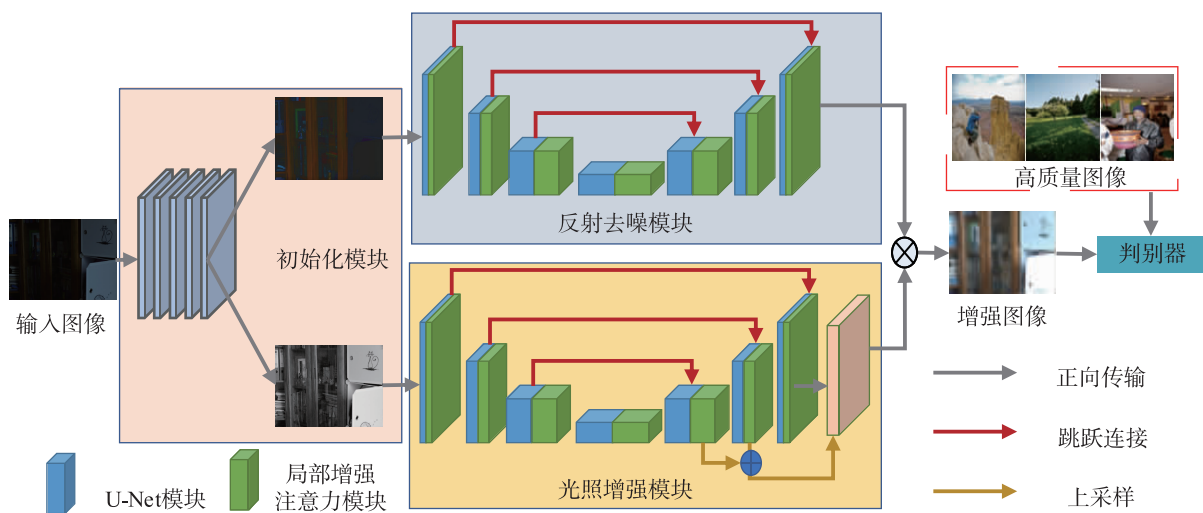


图 2 基于多通道 Retinex 模型的低照度图像增强网络

Fig.2 Low-light image enhancement network based on multichannel Retinex model

去噪和增强,将得到的结果相乘得到最终的低照度图像增强结果。判别器通过和人工选择的高质量图片进行比较,通过对抗性损失判断图像在感知上是否是高质量的。这样无论从信号保真度还是人的感知质量上,本文所提出方法的低照度图像增强结果都取得了良好的效果。

2.1 初始化模块

初始化在优化过程中起着重要作用,随机或全零初始化广泛用于传统的优化方案。考虑到可靠的初始化有利于后续的图像增强,希望获得一个信息更丰富的初始化光照和反射率,而不是随机值或全零。为了保持输入图像 I 的整体结构,有些方法通过寻找 3 个颜色通道的最大值来初始化初始照明 L_0 ^[12],并且可以相应地导出初始反射率 $R_0 = I_0 \oslash L_0$,其中 \oslash 表示逐元素相除。然而,以这种方式进行初始化会导致颜色失真,改变 3 个通道 (R, G, B) 的强度统计特征。

因此,为了增强图像细节的同时避免失真,本文提出了一个数据依赖的初始化模块,它使用完全卷积 (Conv) 网络自适应地同时学习反射率 R_0 和初始化光照 L_0 。初始化模块由 4 个 Conv + LeakyReLU 层组成,后面是一个卷积层和 GELU^[27] 层。整个卷积层的内核大小设置为 3×3 。在初始化模块中,损失函数设计如下:

$$l_{\text{init}} = \|I_0 - R_0 \odot L_0\|_1 + \mu \|L_0 - \max_{c \in \{R, G, B\}} I_0^{(c)}\|_F^2, \quad (3)$$

其中, $\|\cdot\|_1$ 表示 1 范数, $\|\cdot\|_F$ 表示弗罗贝尼乌斯范数, μ 是超参数, \max 表示三通道最大值。等式右侧第一项是重建损失,第二项旨在约束初始化光照以保持输入图像的整体结构。

由于没有真实反射图像,因此本文在训练时利用正常光照图像生成清晰的反射图像,这应该接近低照度图像的反射图像。因此,在接下来的反射分量去噪模块中,以正常光照图像的反射图像作为参考。基于初始化模块的网络架构,进一步对正常光照图像的光照施加结构感知平滑约束,分解正常光照图像的损失函数如下:

$$\min_{\hat{R}, \hat{L}} \|\hat{I} - \hat{R} \odot \hat{L}\|_1 + \hat{\mu} (\hat{L} - \max_{c \in \{R, G, B\}} \hat{I}^{(c)})^2 + e^{-\varepsilon \nabla \hat{L}} \cdot \nabla \hat{L} \|_1 \quad (4)$$

其中, \hat{I} 表示正常光照图像, \hat{R} 和 \hat{L} 分别表示正常光图像的反射率和照度, ε 和 $\hat{\mu}$ 是超参数, $\nabla(\cdot)$ 表示梯度操作。 $\|e^{-\varepsilon \nabla \hat{L}} \odot \nabla \hat{L}\|_1$ 为正常光照图像照度的梯度加权,这样照明可以在结构感知上更加平滑。

2.2 反射去噪和光照增强模块

在反射去噪模块和光照增强模块使用了相似的网络,两个模块的输入分别是初始化模块生成的初始化光照分量和初始化反射分量,为了在 RGB 通道得到不同的光照增强结果,输入的初始化光照分量将被复制为 3 份后再处理。

低照度图像往往伴随着大量噪声,针对这一问题设计了反射去噪模块。如图 2 所示,以 U-Net 网络为基础构建了深度神经网络,在 U-Net 网络每一层的末尾,添加了新提出的局部增强注意力模块,以捕捉输入图像的重要特征。初始化反射分量进入特征空间,然后通过几个卷积层转换特征。在中间层中,特征的空间分辨率首先被下采样,然后通过步幅卷积和反卷积进行上采样。通过跳跃连接将具有相同空间分辨率的特征从浅层连接到深层。将网络最后一层尺度上的输出 R_{s_3} 作为反射分量去噪的结果。反射模块的损失函数如下:

$$l_R = \|\hat{R} - R_{s_3}\|_F^2 + (1 - \text{SSIM}(\hat{R}, R_{s_3})) \quad (5)$$

其中, $\text{SSIM}(\cdot)$ 表示两张图像的结构相似性。

在光照增强模块中,因为光照变化具有连续性,设计了多尺度学习网络,网络主干与反射去噪模块类似,输入改为复制为 3 份后的初始化光照分量,输出信号改为多尺度信号输出。多尺度学习网络分别在 $s_1 = 1/4$ 、 $s_2 = 1/2$ 和 $s_3 = 1$ 的尺度上产生特征。

$$\begin{aligned} [f_{s_1}, f_{s_2}, f_{s_3}] &= F_{\text{DLN}_F}(L_0) \\ L_{s_1} &= F_{L_{s_1}}(f_{s_1}) \\ L_{s_2} &= F_{L_{s_2}}(f_{s_2}) + F_U(L_{s_1}) \\ L_{s_3} &= F_{L_{s_3}}(f_{s_3}) + F_U(L_{s_2}) \end{aligned} \quad (6)$$

其中, $f_{s_1}, f_{s_2}, f_{s_3}$ 分别是初始化光照分量 L_0 中以其相应比例提取的特征; $F_{\text{DLN}_F}(\cdot)$ 是多尺度学习网络提取特征的过程; $F_{L_{s_1}}(\cdot), F_{L_{s_2}}(\cdot)$ 和 $F_{L_{s_3}}(\cdot)$ 是将特征转换到相应尺度的图像域的过程; $F_U(\cdot)$ 是上采样过程。首先以最粗略的尺度 s_1 重建光照。然后,在精细尺度上,更准确的光照信息被恢复与增强。 L_{s_3} 包括 RGB 三通道光照增强的结果。最终的低照度图像增强结果 \tilde{I} 为

$$\tilde{I} = R_{s_3} \cdot L_{s_3} \quad (7)$$

图像的重建损失为

$$l_{\text{rec}} = \|\hat{I} - \tilde{I}\|_F^2 + (1 - \text{SSIM}(\hat{I}, \tilde{I})) \quad (8)$$

针对重建图像容易产生色偏的问题,设计了颜

色损失函数:

$$l_c = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n (1 - \cos(\tilde{I}(i, j), \hat{I}(i, j))) \quad (9)$$

式中, \cos 表示两个向量夹角的余弦值, m 和 n 分别表示图像的水平分辨率和垂直分辨率, 两个向量的夹角越小表明该位置像素颜色越接近。生成器总的损失函数为

$$l_A = l_{rec} + \alpha_1 l_c + \alpha_2 l_r \quad (10)$$

根据多次训练的经验, 将 α_1 的值设为 0.5, α_2 的值设为 0.3。

2.3 局部增强注意力模块

标准的 U-Net 网络提取局部信息的能力有限, 但相邻像素是图像增强的重要参考。为了克服这个问题, 向网络中添加了局部增强注意力模块, 该模块受压缩激发模块启发, 使用 GELU 作为两个全连接层之间的激活函数。如图 3 所示, 首先对每个输入应用线性投影层以增加其特征维度。接下来, 通过 Reshape 层将通道特征重塑为 2 维特征图, 并使用改进后的压缩激发模块来学习不同通道特征图的权重信息。然后将空间特征展平为通道特征, 并通过另一个 1(1 卷积层缩小通道以匹配输入通道的维度。

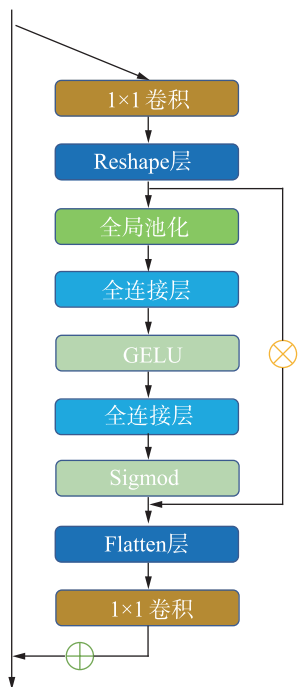


图 3 局部增强注意力模块

Fig.3 Locally-enhanced attention module (LEAM)

2.4 判别器

借助配对数据的信息, 网络可以很好地学习从

低光图像到正常光图像的恢复过程, 细节还原良好, 噪声得到抑制。但数字信号并不总是与人类视觉感知一致, 特别是对于图像的光照强度、颜色分布等全局属性。因此, 进一步让本文的模型通过感知质量引导的对抗性学习获得高质量的增强图像。基于人工选择的高质量图像用于表示人类感知的先验知识。判别器的损失函数为

$$l_{Quality} = -\lg D(\tilde{I}) \quad (11)$$

其中, D 是鉴别器, 用于测量人类视觉偏好的概率。

3 实验结果与分析

3.1 对比实验

本文所提出的 MRetinex-GAN 网络模型训练和测试的在一个单 NVIDIA 3090 GPU 上进行, 所用设备为联想刃 9000K, CPU 为 Intel® Core™ i9-10900K, 内存为 64 G, Python 版本为 3.9。

分别从视觉效果和数值指标两个方面, 对本文方法与 8 个代表性的低照度增强方法的效果进行比较, 包括基于传统物理模型的 NPE^[10], LIME^[12], JED^[14], MEIG^[15] 和基于深度学习的 EnlightenGAN^[24], RUAS^[26], RetinexNet^[19] 和 ZeroDCE + +^[25]。比较将在低照度图像增强中最常用的两个公开数据集 (LOL 和 MIT-Adobe FiveK) 上进行。LOL 数据集是为解决低照度图像增强问题而创建的, 它旨在帮助研究人员开发和评估算法, 以提高在低光条件下拍摄的图像的质量。数据集包含 500 张图像, 其中 485 张用于训练算法, 15 张用于测试。每个图像对都包括一个低照度输入图像和一个曝光良好的参考图像。由于低照度条件下拍摄的图像通常包含大量噪声, LOL 数据集中的图像也反映了这一挑战性情况。MIT-Adobe FiveK 数据集旨在研究图像增强算法, 但不仅限于低照度。它包括多种光照条件下的图像, 以及专业摄影师手动调整的图像, 用于评估算法性能。数据集共包含 5 000 张图像, 前 4 500 张用于算法训练, 后 500 张用于测试。这些图像代表了不同场景和光照条件。MIT-Adobe FiveK 数据集中的图像经过专业摄影师的手动调整, 专家 C 的增强图像被视为真实值。这些图像提供了专业人士对图像质量的优化参考。这一数据集中的都是具有很大分辨率的高质量图像, 在对比数据集上很难进行运算和测试, 为了对比实验的公平性, 本文将所有图像的分辨率重塑为 400×400 。

图 4 展示了 LOL 测试集^[19]上的低照度图像增强结果, 图 5 展示了 MIT-Adobe FiveK 测试集^[28]上

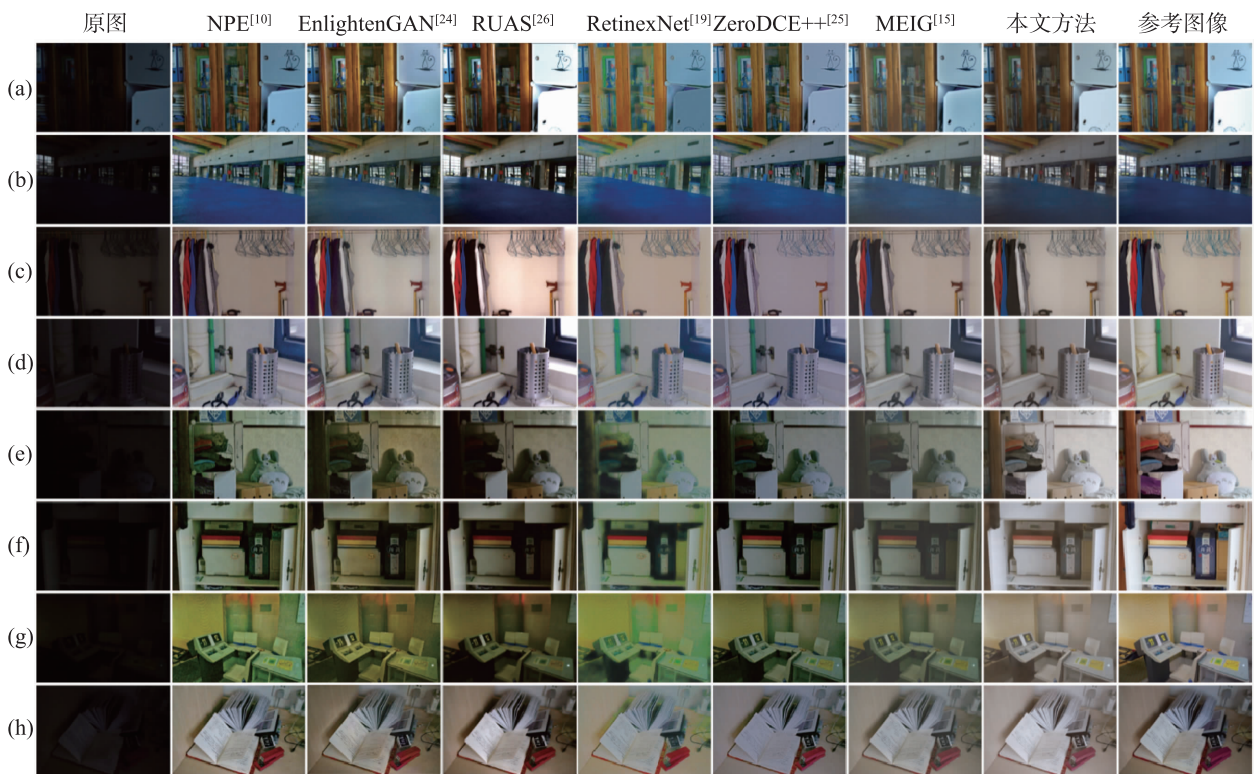


图4 LOL 测试数据集上低照度图像的增强结果

Fig.4 Enhanced results of low-light images on the dataset of LOL

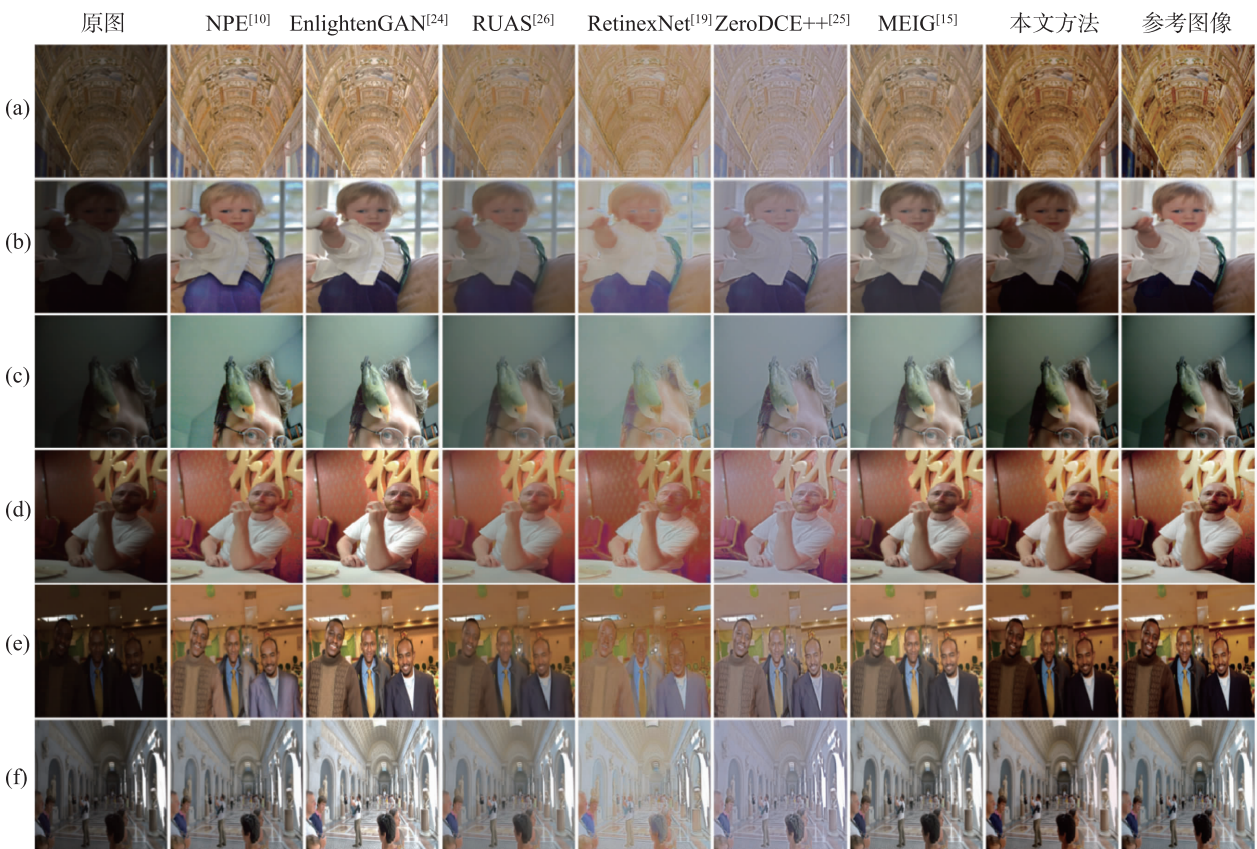


图5 MIT 测试数据集上低照度图像的增强结果

Fig.5 Enhanced results of low-light images on the test set of MIT dataset

的低照度图像增强结果。从图 4 可以看出, 在噪声问题较为严重的 LOL 数据集中, 只有本文的方法在去除噪声的同时保留了图像较为完整的纹理信息, 且在数据集中部分低照度和正常光照图片对存在色偏时, 只有本文的方法将低照度图像恢复成接近正常照度的图像颜色, RUAS^[26] 方法在输入图像本身稍亮时恢复得较好, 但当输入图像较暗时无法恢复到正常图像亮度, 且增强后的图像仍存在泊松噪声。在低照度图像质量相对较高的 MIT-Adobe FiveK 数据集上, 除 RetinexNet^[19] 和 ZeroDCE + +^[25] 外其余比较方法均没有太多图像纹理信息的损失, 但增强后的颜色均与参考图像产生了偏差, 这在图 5 (b) 中表现得尤为明显, 除了本文的方法外, MEIG^[15] 方法在 MIT-Adobe FiveK 数据集上也取得了较好的效果, 但图像增强结果也都在不同程度上降低了图像的饱和度。与以上方法相比, 本文方法因为增加了初始化模块, 对光照层和反射层分解得更为准确, 且分通道增强光照可以更为准确地恢复图像颜色, 有效地避免色差, 注意力模块可以更加准确地学习输入图像信息, 使得图像保存更多细节, 因而最终的增强结果对原始色彩的保持更好, 与真实拍摄图像的颜色更接近, 且能在去除噪声的同时保留图像的纹理信息, 没有降低图像的视觉效果和饱和度。

为了对所提出的基于多通道 Retinex 模型的低照度图像增强网络对低照度图像的增强效果进行定量评估, 本节采用了全参考的评价指标, 包括峰值信噪比 (PSNR)、特征相似性 (FSIM)^[29] 和结构相似性 (SSIM), 以对比不同方法在增强结果上的数值表现。这些评价指标各有其意义: PSNR 数值越高, 表示增强结果的像素值与正常光照图像越接近; FSIM 数值越高, 表示增强结果在图像特征上与正常光照图像越接近; SSIM 数值越高, 表示增强结果的图像结构与正常光照图像越相似。

表 1 显示了在 LOL 数据集上使用不同算法对低照度图像增强的数值比较结果, 表 2 显示了在 MIT-Adobe FiveK 数据集上使用不同算法对低照度图像增强的数值比较结果。在这些表格中, 使用红色字体表示最优的数值指标, 对于次优的数值指标使用加粗字体表示。从表 1 和表 2 中可以明显看出, 本文方法在 LOL 测试集和 MIT-Adobe FiveK 测试集上在峰值信噪比、特征相似性和结构相似性评价指标中都取得了最优的结果, 也就是说, 本节方法在增强结果上与真实拍摄图像以及手工调整的正常照度图像之间达到了最高的相似度。

表 1 LOL 数据集上使用不同算法对低照度图像增强的数值比较

Tab.1 Numerical comparison of low-light image enhancement using different algorithms on the LOL dataset

方法	PSNR	SSIM	FSIM
NPE ^[10]	16.97	0.599 5	0.896 4
LIME ^[12]	17.18	0.594 6	0.888 0
JED ^[14]	13.69	0.718 3	0.881 2
EnlightenGAN ^[24]	17.48	0.677 2	0.895 4
RUAS ^[26]	18.23	0.717 9	0.904 2
RetinexNet ^[19]	17.92	0.669 2	0.876 0
ZeroDCE + + ^[25]	17.04	0.674 3	0.918 2
MEIG ^[15]	18.35	0.738 2	0.925 1
本文方法	21.94	0.839 4	0.942 1

表 2 MIT-Adobe FiveK 数据集上使用不同算法对低照度图像增强的数值比较

Tab.2 Numerical comparison of low-light image enhancement using different algorithms on the MIT-Adobe FiveK dataset

方法	PSNR	SSIM	FSIM
NPE ^[10]	17.50	0.823 5	0.918 9
LIME ^[12]	16.03	0.550 8	0.881 1
JED ^[14]	13.04	0.683 2	0.867 7
RetinexNet ^[19]	16.39	0.651 0	0.851 0
ZeroDCE + + ^[25]	15.96	0.625 1	0.905 4
MEIG ^[15]	17.16	0.840 8	0.962 1
本文方法	20.71	0.853 5	0.962 5

3.2 消融实验

首先通过寻找 3 个颜色通道的最大值来初始化初始照明, 并比较分析初始化模块的有效性。然后, 为了研究局部增强注意力模块的有效性, 使用压缩激发残差模块代替局部增强注意力模块, 而其余设置与 U-Net 相同。最后, 为了证实分通道增强的必要性, 在光照增强模块中, 在三通道中使用相同的光照增强结果来代替三通道分别增强光照。消融研究的结果见表 3, 第 1 行显示, 删除初始化模

表 3 消融研究的定量结果

Tab.3 Quantitative results of the ablation research

方法	PSNR	SSIM	FSIM
无初始化模块	21.04	0.821 1	0.936 4
无局部增强注意力模块	20.73	0.801 5	0.928 3
三通道使用相同光照	20.82	0.820 8	0.931 5
本文方法	21.94	0.839 4	0.942 1

块会导致性能显著下降。这是因为使用三通道最大值来初始化初始照明可能会破坏输入图像的三个通道的强度统计特性,从而进一步影响后续学习结果。第2行显示当使用压缩激发残差模块代替局部增强注意力模块时性能下降,这证明了本文的局部

增强注意力模块的有效性。在第3行中可观察到,在三通道中使用相同的光照增强结果来代替三通道分别增强光照时,最终的增强结果会有色偏产生,网络性能下降。图6显示了消融研究的视觉结果,图6(a)~6(d)分别代表表3中的4个阶段。



图6 消融研究的视觉对比

Fig.6 Visual comparison in the ablation research

4 结论

本文提出了一个基于多通道 Retinex 的低照度图像增强生成对抗网络。该方法基于多通道 Retinex 模型。在生成器中,首先使用初始化模块将输入图像分解为反射分量和光照分量,然后将这些分量分别输入反射去噪模块和光照增强模块进行去噪和增强,继而得到生成的正常光照图像。在判别器

中,使用对抗性损失函数来提高生成图像的质量。实验结果表明,所提出的低照度增强方法可以有效提升低照度图像的亮度,与现有低照度增强方法相比,本文方法的增强结果对原始色彩的保持更好,与真实拍摄图像的颜色更接近,且能在去除噪声的同时保留图像的纹理信息,获得更准确的视觉效果和饱和度,消融实验的结果也证明了本文所提出模块的有效性。

参考文献

- [1] 苏贇,王挺,姚辰,等. 基于合作目标的无人机目标跟踪方法[J]. 机器人, 2019, 41(4): 425-432.
SU Y, WANG T, YAO C, et al. A target tracking method of UAV based on cooperative target[J]. Robot, 2019, 41(4): 425-432.
- [2] 高兴波,史旭华,葛群峰,等. 面向动态物体场景的视觉 SLAM 综述[J]. 机器人, 2021, 43(6): 733-750.
GAO X B, SHI X H, GE Q F, et al. A survey of visual SLAM for scenes with dynamic objects[J]. Robot, 2021, 43(6): 733-750.
- [3] 谢自强,葛为民,王肖锋,等. 发展型机器人实时特征提取方法研究[J]. 机器人, 2017, 39(2): 189-196.
XIE Z Q, GE W M, WANG X F, et al. Real time feature extraction method of developmental robot[J]. Robot, 2017, 39(2): 189-196.
- [4] ABDYLLA-AL-WADUD M, KABIR M H, DEWAN M A A, et al. A dynamic histogram equalization for image contrast enhancement[J]. IEEE Transactions on Consumer Electronics, 2007, 53(2): 593-600.

- [5] LEE C, KIM J H, LEE C, et al. Optimized brightness compensation and contrast enhancement for transmissive liquid crystal displays[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2013, 24(4): 576 – 590
- [6] 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.
- [7] LEE J T, LEE C, SIM J Y, et al. Depth-guided adaptive contrast enhancement using 2D histograms[C]//2014 IEEE International Conference on Image Processing. Piscataway, USA: IEEE, 2014: 4527 – 4531
- [8] YING Z Q, LI G, REN Y R, et al. A new image contrast enhancement algorithm using exposure fusion framework[C]//17th International Conference on Computer Analysis of Images and Patterns. Piscataway, USA: IEEE, 2017: 36 – 46.
- [9] EDWIN H L, JOHN J M. Lightness and Retinex theory[J]. *Journal of the Optical Society of America*, 1971, 61(1): 1118 – 1125.
- [10] WANG S H, ZHENG J, HU H M, et al. Naturalness preserved enhancement algorithm for non-uniform illumination images[J]. *IEEE Transactions on Image Processing*, 2013, 22(9): 3538 – 3548.
- [11] WANG L Q, XIAO L, LIU H Y, et al. Variational Bayesian method for Retinex[J]. *IEEE Transactions on Image Process*, 2014, 23(8): 3381 – 3396.
- [12] GUO X J, LI Y, LING H B. LIME: Low-light image enhancement via illumination map estimation[J]. *IEEE Transactions on Image Processing*, 2016, 26(2): 982 – 993.
- [13] LI M D, LIU J Y, YANG W H, et al. Structure-revealing low-light image enhancement via robust Retinex model[J]. *IEEE Transactions on Image Processing*, 2018, 27(6): 2828 – 2841.
- [14] 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. Piscataway, USA: IEEE, 2018: 1 – 5.
- [15] 管宇, 陈希爱, 田建东, 等. 基于多曝光图像生成的低照度图像增强[J]. *机器人*, 2023, 45(4): 422 – 430.
GUAN Y, CHEN X A, TIAN J D, et al. Low-light image enhancement based on multi-exposure images generation[J]. *Robot*, 2023, 45(4): 422 – 430.
- [16] ATOUM Y, YE M, REN L, et al. Color-wise attention network for low-light image enhancement[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway, USA: IEEE, 2020: 2130 – 2139.
- [17] XU K, YANG X, YIN B C, et al. Learning to restore low-light images via decomposition-and-enhancement[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2020: 2281 – 2290.
- [18] YANG W H, WANG S Q, Fang Y M, et al. Band representation-based semi-supervised low-light image enhancement: Bridging the gap between signal fidelity and perceptual quality[J]. *IEEE Transactions on Image Processing*, 2021, 30(2): 3461 – 3473.
- [19] WEI C, WANG W J, YANG W H, et al. Deep Retinex decomposition for low-light enhancement[EB/OL]//(2018 – 06 – 28) [2023 – 01 – 10]. <https://arxiv.org/pdf/1808.04560.pdf>.
- [20] 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. Piscataway, USA: IEEE, 2021: 4419 – 4428.
- [21] LYU F F, LU F, WU J H, et al. MBLLEN: Low-light image/video enhancement using CNNs[EB/OL]. (2018 – 08 – 20) [2023 – 1 – 21]. <https://phi-ai.buaa.edu.cn/project/MBLLEN/index.htm>.
- [22] WANG W J, CHEN W, YANG W H, et al. GLADNet: Low-light enhancement network with global awareness[C]//2018 13th IEEE International Conference on Automatic Face & Gesture Recognition. Piscataway, USA: IEEE, 2018: 751 – 755.
- [23] ZHAO L, LU S P, CHEN T, et al. Deep symmetric network for underexposed image enhancement with recurrent attentional learning[C]//IEEE/CVF International Conference on Computer Vision. Piscataway, USA: IEEE, 2021: 12075 – 12084.
- [24] 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(3): 2340 – 2349.
- [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] LIU R S, MA L, ZHANG J A, et al. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2021: 10556 – 10565.

2020; 4183 – 4192

- [24] COHEN N, HOSHEN Y. Sub-Image anomaly detection with deep pyramid correspondences[EB/OL]. (2021 – 02 – 03)[2023 – 03 – 27]. <https://arxiv.org/abs/2005.02357>. DOI: 10.48550/arXiv.2005.02357.
- [25] YI J, YOON S. Patch SVDD: Patch-level SVDD for anomaly detection and segmentation[C]//Asian Conference on Computer Vision. Berlin, Germany: Springer, 2021: 375 – 390.
- [26] MVTec. The MVTec anomaly detection dataset[DS/OL]. [2023 – 03 – 05]. <https://www.mvtec.com/company/research/datasets/mvtec-ad>.

作者简介

魏金洋(1996 –), 男, 硕士生。研究领域为机器视觉, 缺陷检测。

苑明哲(1971 –), 男, 博士, 研究员, 博士生导师。研究领域为工业物联网, 分布式控制系统和工业过程控制。

曹飞道(1991 –), 男, 博士。研究领域为机器视觉, 缺陷检测。

(上接第 661 页)

- [27] Hendrycks D, Gimpel K. Gaussian error linear units (GELUs)[EB/OL]. (2020 – 07 – 08)[2022 – 05 – 01]. <https://doi.org/10.48550/arXiv.1606.08415>.
- [28] BYCHKOVSKY V, PARIS S, CHAN E, et al. Learning photographic global tonal adjustment with a database of input/output image pairs[C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2011: 97 – 104.
- [29] ZHANG L, ZHANG L, MOU X Q, et al. FSIM: A feature similarity index for image quality assessment[J]. IEEE Transactions on Image Processing, 2011, 20(8): 2378 – 2386.

作者简介

张 箴(1994 –), 男, 博士生。研究领域为机器人视觉和图像处理。

鹿 阳(1998 –), 男, 博士生。研究领域为机器人视觉和图像处理。

苏奕铭(1996 –), 男, 博士生。研究领域为机器人视觉和图像处理。