

基于多尺度融合卷积神经网络的微光图像增强算法

刘伟强¹, 赵鹏^{1*}, 宋向迎²¹火箭军工程大学作战保障学院, 陕西 西安 710025;²96951 部队, 北京 100085

摘要 由于传统的微光图像增强算法泛化性较差,难以适应复杂多变的真实场景,提出一种基于多尺度融合卷积神经网络的图像增强方法,即通过学习微光图像与正常图像之间的映射关系实现微光图像增强。以微光图像为输入,首先利用预处理模块提取图像浅层信息,然后将选择性卷积核网络(SKNet)融合到局部路径构成特征提取网络,用通道注意力模块对特征图进行权重学习得到局部特征,并对其与提取到的全局特征进行融合。由双边网格上采样还原图像尺寸,得到微光图像对应的映射函数,进而完成图像的增强。基于 MIT-Adobe 5K 数据集,对所提方法与其他 9 种先进方法进行对比。实验结果表明,所提方法可以较好地提升图像的亮度,丰富图像细节,在视觉效果和定量评价上均优于其他对比算法。

关键词 图像增强; 特征融合; 多尺度; SKNet; 注意力机制

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP222189

Low-Light Image Enhancement Algorithm Based on Multi-Scale Concat Convolutional Neural Network

Liu Weiqiang¹, Zhao Peng^{1*}, Song Xiangying²¹College of Operational Support, Rocket Force University of Engineering, Xi'an 710025, Shaanxi, China;²Troops No.96951, Beijing 100085, China

Abstract To overcome the problems of poor generalizability and an inability to adapt to complex real scenes of traditional low-light image enhancement algorithms, a new method based on multi-scale concat convolutional neural network is proposed here. This method achieves low-light image enhancement by learning the mapping relationship between low-light and normal images. Taking the low-light image as input, the shallow layer information of the image is extracted through the preprocessing module. Then, Selective Kernel Network (SKNet) is fused to the local path to form a feature extraction network. Finally, the global feature is fused with the local feature, which is obtained by weight learning of the feature map with a channel attention module. Bilateral guided upsampling is used to restore the image size and obtain the mapping function of the low-light image, after which the image enhancement is completed. Based on the MIT-Adobe 5K dataset, a comparative experiment with nine other advanced methods showed that the proposed method can effectively improve the brightness and details of low-light images. Hence, the proposed method is superior to other contrast algorithms in terms of visual effects and quantitative evaluation.

Key words image enhancement; feature fusion; multi-scale; SKNet; attention mechanism

1 引言

在低照度或逆光等条件下,摄像设备会受到一定干扰,获取的图像会因为光源不足而存在亮度低、对比度低、噪声大、伪影及颜色失真等情况,这种图像称为微光图像。微光图像不仅影响着人类的视觉体验,目标检测^[1]、图像修复^[2]等计算机视觉任务在处理微光图

像时也会受到阻碍。随着计算机视觉对图像有了更高的要求,对微光图像的增强已经成为计算机视觉的重要研究内容。因此,从微光图像中恢复正常曝光的高质量图像在实际应用中具有重要的作用。

众多的微光图像增强算法主要分为两类。

1) 基于传统方法的微光图像增强。为了对微光图像进行增强,研究人员进行了多方面的研究,有基于

收稿日期: 2022-07-29; 修回日期: 2022-08-12; 录用日期: 2022-09-13; 网络首发日期: 2022-09-23

基金项目: 军队科研资助项目

通信作者: *zpxhh@163.com

直方图、Retinex、图像去雾的方法。基于直方图均衡(HE)的方法^[3]通过对微光图像的直方图进行重新分布,改变图像灰度值的动态范围,减少灰度区域内图像的像素数,增强后图像的直方图分布变宽,达到增加图像亮度和对比度的效果,但增强后的图像像素主要分布在中低区域,且相同信息的像素增强后并不能得到不同的像素。基于 Retinex 的图像增强方法^[4-6]认为环境的光照和物体的反射共同构成了人类对物体亮度的感知,通过去除微光图像的光照分量得到反射分量,进而对图像进行增强,该方法在一定程度上改善了图像的亮度和对比度,但是没能抑制增强过程中图像噪声的放大。Dong 等^[7]通过将微光图像转置后得到类似雾天图像,根据雾天图像去雾方法实现微光图像增强,但由于大气光值是一个全局量,微光图像的局部区域无法得到有效增强。

2) 基于深度学习的微光图像增强。传统的微光图像增强方法虽然取得了很大的进步,图像的亮度和对比度得到了增强,但是方法本身存在增强瓶颈,无法增强细节已经丢失的微光图像,同时泛化性也较差,难以适应不同场景、不同照度下的微光图像。而基于深度学习的方法直接从大量训练样本中学习微光图像增强策略,获得增强后的图像。作为第一个将深度学习应用到图像增强的弱光网络(LLNet)^[8],通过构建一个深层网络学习微光图像的特征,并对局部对比度进行改进,防止过度放大已经明亮的像素,其可以有效抑制增强图像的噪声并增强对比度。Wei 等^[9]提出了 RetinexNet,该方法通过分解网络将微光图片分解为反射分量和光照分量,并使用 BM3D 网络^[10]对反射分量进行噪声抑制。Lü 等^[11]提出了多分支微光增强方法,该方法通过融合网络中不同层次的特征得到增强图像。Jiang 等^[12]通过“全局-局部”鉴别器以及自正则注意力机制使网络在训练时不需要成对数据也能获得良好的增强效果。DSLRL^[13]引入拉普拉斯金字塔对低照度图像的全局光照和局部细节分别进行增强,并在后续的图像空间中对结果进行逐步结合。Guo 等^[14-15]设计并改进了一个参数估计网络,通过不断迭代优化的估计曲线逐渐增加图像的亮度和对比度,直到获得相对满意的增强效果。

本文提出了一种基于深度学习的方法,该方法通过学习不同光照条件下图像的映射函数实现对微光图像的增强。在模型的建立过程中,首先对图像进行降采样,然后利用卷积运算获得微光图像的局部特征与全局特征,最后对结果进行上采样,恢复到全分辨率,从而得到映射函数,之后从微光图像中得到增强图像。为了减少网络冗余,加快模型训练速度,所提方法在低分辨率下进行图像处理。此外,为保持增强图像的对比度,本文设计了对比度一致性损失函数,避免增强过程中图像对比度下降的问题。通过与其他算法进行对比,可以发现所提方法得到的增强图像色彩更加自然,

视觉效果更好。

2 理论模型

2.1 光照模型

Retinex 理论^[16]阐释了人类眼睛能够观察到目标对象颜色的基本原理,其假设图像由照射图和反射图组成。假设 S 代表原图像,那么可以表示为

$$S = I * R, \quad (1)$$

式中: I 表示照射图; $*$ 表示矩阵相乘; R 代表反射图。反射图 R 指在变化的光照条件下能够维持不变的图像部分,照射图 I 反映原图像的光照情况^[17]。

所提方法与 Retinex 理论相似,不同的是所提方法假设微光图像 L 由增强图像 \bar{L} 和映射函数 F 组成,那么对 F 进行估计则是微光图像增强的主要任务,表达式为

$$L = \bar{L} * F, \quad (2)$$

对式(2)进行逆运算,为防止分母过小,为 F 设置下限, F_0 设置为 0.001,

$$\bar{L} = \frac{L}{\max(F, F_0)}. \quad (3)$$

2.2 双边引导上采样

为了解决模型的复杂导致处理速度较慢的问题,将原始图像降采样为小图后进行处理,然后再进行上采样得到结果。双边引导上采样(BGU)^[18]的核心思想是:先把高分辨率图降采样为小图,记录仿射变换,在局部小区域内将其简化为线性变换,再把此线性变换应用于高分辨率参考图,得到高分辨率输出。BGU 中的上采样针对的是变换系数而非像素点,可以减少在下采样和上采样过程中图像细节的丢失,使工作效果更为出色。

3 所提算法内容

3.1 网络模型设计

基于微光图像的特征图与映射函数之间存在的非线性映射关系,提出了一种基于多尺度融合卷积神经网络的图像增强网络(MCIEN)模型。MCIEN 设计了两条路径,通过提取不同尺度的特征,预测微光图像和正常图像之间的映射函数 F ,实现对微光图像的增强。MCIEN 模型如图 1 所示。

3.1.1 图像预处理

首先, MCIEN 模型将彩色图像的尺寸调整至 256×256 。以微光图像作为卷积神经网络的输入,连续采用 3 个卷积核大小为 3×3 、步长为 2 的卷积层,对其进行预处理,卷积层的输出为

$$H_n(x) = \delta[W_n \bullet F_{n-1}(x) + b_n], \quad (4)$$

式中: H_n 代表第 n 层特征图; δ 为 ReLU 激活函数; W_n 表示第 n 层的卷积核; \bullet 代表卷积; F_{n-1} 代表第 $n-1$ 层输出的特征图,也即 n 层输入的特征图; b_n 表示本层的偏置。

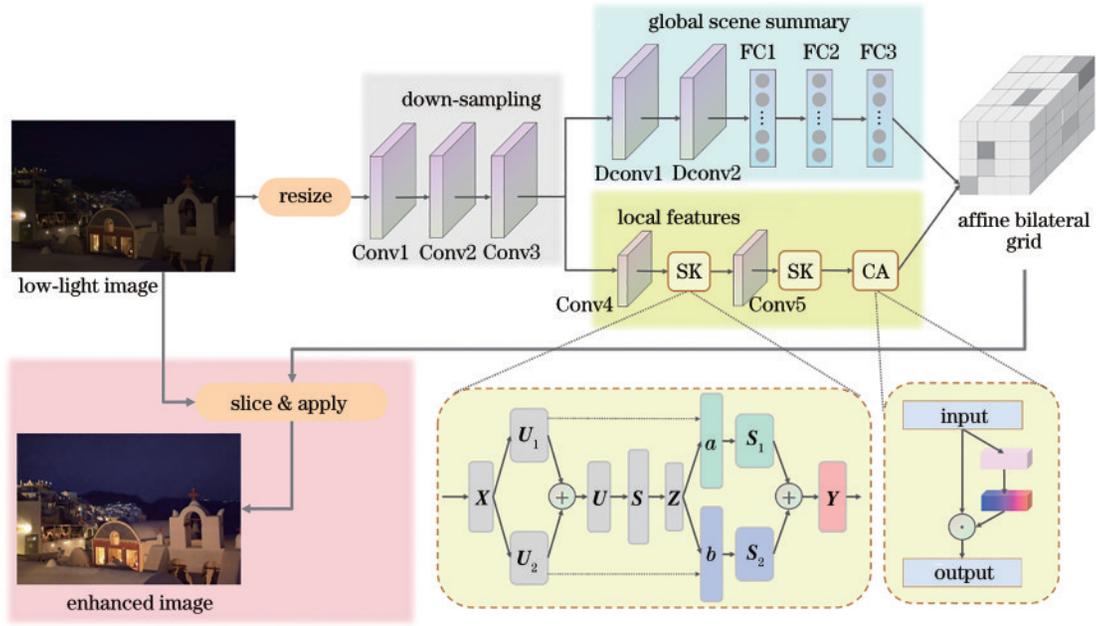


图1 MCIEN模型

Fig. 1 MCIEN model

对图像进行下采样,一方面可以减少计算量,加快计算速度,另一方面也可防止局部细节上的过拟合。在下采样的过程中,池化层会导致图像丢失部分细节,利用步幅为2的卷积层代替池化层后得到的特征图将包含所有像素的信息,在进行降采样的同时实现对微光图像浅层特征的提取。

3.1.2 系数预测

系数预测阶段的主要任务是通过学习输入图像的特征,预测双边仿射变换网格(ABG)。参照HDRNet^[19],将特征提取网络划分成局部路径(local path)和全局路径(global path),分别学习微光图像的局部信息和语义信息。

为了获取图像更准确的上下文信息,全局路径部分采取更大的卷积核来增大感受野,采用空洞卷积(Dconv)减少计算量,这样做的好处是在不增加参数量的前提下扩大卷积核的感受野,使输出包含更大范围的信息,同时还可以保证输出的特征大小保持不变。最后连续采用全连接层,依次降维到256、128和64,得到图像的全局信息。

局部路径负责学习局部的颜色变换,同时决定着最终网格的分辨率。局部路径包括卷积层、SK注意力机制和通道注意(CA)模块,对图像不同层次的特征进行特征提取和融合,获得的特征图不仅包含图像的轮廓信息,同时获得更深层次的信息。再由CA对特征进行筛选,由此得到局部特征。

1) 多尺度特征提取

由于卷积操作的感受野有限,采用固定尺度大小的单个卷积核对图像进行特征提取具有一定的局限性,多尺度特征提取可以提取更加全面的特征。Li

等^[20]通过增加多个卷积核来适应不同尺度的图像,但是每个卷积核的权重是相同的。为了不同图像能够学习到不同重要性的卷积核,本文在局部路径中加入了SK注意力机制,使其可以根据不同尺度的目标选择不同大小的卷积核,产生不同效果,具体内容见图1。

SKNet^[21]可分为拆分、融合、选择3个阶段。在拆分阶段,使用2组不同大小的滤波器进行并行卷积运算,并对不同尺度的卷积结果 U_1 和 U_2 进行特征融合。卷积核大小分别为 3×3 、 5×5 ,多尺度滤波器之间是平行的关系。在融合阶段,将两部分的特征图按元素求和,表达式为

$$U = U_1 + U_2, \quad (5)$$

之后进行全局平均池化,得到 S ,特征图维度从 $C \times H \times W$ 变为 $C \times 1 \times 1$,进入全连接层,得到 Z :

$$S = F_{sp}(U) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U(i, j), \quad (6)$$

$$Z = f(S) = \delta[\beta(W_s)], \quad (7)$$

式中: β 为批归一化(BN)层; W_s 维度为 $d \times C$ 。经过前两个阶段,已经得到不同尺度空间的权重信息,对 Z 进行Softmax函数处理,得到权重特征层 a 和 b ,最终输出为

$$Y = S_1 + S_2 = aU_1 + bU_2, a + b = 1. \quad (8)$$

2) 通道注意模块

在绝大多数微光图像增强网络中,从图像提取到的特征图中每一个通道或像素对最终增强结果的贡献都是平均的,提取到的特征图并不一定都有助于图像增强。为了避免在微光图像增强过程中常出现的色彩失真、噪声放大等现象,通过增加基于通道的注意力模块,对不同的特征图分配不同的学习权重,提升具有明

显特征的特征图所占的比例,降低对噪声等特征的学习,提高特征的表达能,从而使模型能够灵活地对特征进行取舍,避免失真问题。CA 模块如图 1 所示。

首先 CA 模块对大小为 $C \times H \times W$ 的输入 $\mathbf{X}_{\text{input}}$ 进行全局平均池化,得到 $C \times 1 \times 1$ 大小的特征向量 \mathbf{V} ;利用卷积对向量进行权重学习,采用 Sigmoid 函数将结果映射到 $(0, 1)$,得到权重向量 \mathbf{V}_w ;最后利用 \mathbf{V}_w 对原始特征 $\mathbf{X}_{\text{input}}$ 进行通道加权。具体计算过程分别为

$$\mathbf{V}(\mathbf{X}_{\text{input}}) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W \mathbf{X}_{\text{input}}(i, j), \quad (9)$$

$$\mathbf{V}_w(\mathbf{X}_{\text{input}}) = F_{\text{Sig}}[\mathbf{V}(\mathbf{X}_{\text{input}})], \quad (10)$$

$$\mathbf{X}_{\text{output}} = F_{\text{rescale}}(\mathbf{X}_{\text{input}}, \mathbf{V}_w) = \mathbf{X}_{\text{input}} \odot \mathbf{V}_w, \quad (11)$$

式中: $F_{\text{Sig}}(\cdot)$ 表示 Sigmoid 函数。最后将两条路径汇聚,得到最终的预测,该预测既包含浅层特征,又保留了更多细节信息,避免了信息丢失导致微光图像增强不显著的问题。

3.1.3 图像渲染

将特征信息转换到双边网格后,利用三线插值方法进行上采样,恢复图像的分辨率。该过程通过选取一个参考图,对其任意一个空间的像素进行空域和值域的采样,找到其在 ABG 上的位置,实现对未知范围内亮度值的计算。通过确定的微光图像和期望得到的正常光照图像对双边网格进行训练。由于预处理部分对图像进行的下采样,网络主要在低分辨率下进行特征提取,训练速度得到有效提升。

3.2 损失函数

基于 MCIEN 模型,针对微光图像的特性,一共设计了 3 个损失函数,通过最小化损失函数来实现模型的训练。损失函数为

$$L = \lambda_1 L_r + \lambda_2 L_{\text{con}} + \lambda_3 L_{\text{SSIM}}, \quad (12)$$

式中: L_r 、 L_{con} 、 L_{SSIM} 分别为重建损失、对比度一致性损失、结构相似性损失; λ_1 、 λ_2 、 λ_3 分别为相应的权重。

3.2.1 重建损失

增强图像和正常图像具有一致性,为了预测更为准确的光照映射 \mathbf{F} ,将最小化均方误差在数据集的损失作为预测光照的损失函数 L_r :

$$L_r = \frac{1}{D} \sum (|H_i - \bar{L}_i|)^2, \quad (13)$$

式中: \mathbf{H} 为正常图像; $\bar{\mathbf{L}}$ 为增强图像。

3.2.2 对比度一致性损失

传统方法在微光图像增强过程中经常会遇到对比度减小甚至消失的情况,针对这种问题,设计了对比度一致性损失。此函数在保持图像对比度、防止过拟合、提高网络的泛化能力等方面起到了重要作用。当参照图像中区域 P 的强度相比周围 4 个区域较大或较小时,增强图像仍能保持这种差值,避免增强图像对比度减小的情况。

$$L_{\text{con}} = \frac{1}{D} \sum_{i=1}^D \sum_{j=1}^4 (|\bar{L}_i - \bar{L}_j| - |H_i - H_j|)^2, \quad (14)$$

式中: \bar{L}_i 和 H_i 分别代表增强后的图像和参照图像在 i 区域的平均强度; j 代表区域周围的相邻区域。由于正常图像中的光照一般是局部均匀的,所以将区域划分设计成较小的区域,每个区域大小为 4×4 。

3.2.3 结构相似性损失

为了保证增强图像和正常图像的结构一致性,引入了结构相似性损失 L_{SSIM} 。结构相似性指数 (SSIM) 主要描述两图像结构之间的相似程度,SSIM 值越大,说明增强图像的效果越好。其包含两幅图像之间结构、亮度、对比度三个方面,对局部结构变化敏感。SSIM 的表达式为

$$S_{\text{SSIM}}(x, y) = \frac{(2\mu_x \mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (15)$$

$$L_{\text{SSIM}} = 1 - S_{\text{SSIM}}(\bar{\mathbf{L}}, \mathbf{H}), \quad (16)$$

式中: μ_x 和 μ_y 为两图像的均值; σ_x^2 和 σ_y^2 表示方差, σ_{xy} 为协方差; c_1 和 c_2 是两个常量。

4 实验及结果分析

使用 PyTorch 1.1.0 框架实现所提模型,选取 Adam 优化算法对模型进行优化,批量大小设置为 16,学习率为 1×10^{-4} 。网络训练次数为 200,所有模型的训练次数相同,实验都在 NVIDIA GeForce RTX 2060 6G GPU 下进行。

4.1 实验数据集

选取由 Bychkovsky 等^[22]提出的 MIT-Adobe 5K 数据集,该数据集包括 5000 张真实场景下拍摄的微光图像和分别由 5 个 (A、B、C、D、E) 专业修图人员手工修饰后的图像,本文将专家 C 处理后的图像视为正常光照下的图像。训练过程中选取 90% 的数据作为训练集,10% 的数据进行测试。如图 2 所示,MIT-Adobe 5K 数据集包含不同场景、不同光照条件的图像。

4.2 定性比较

对所提算法分别与现阶段较先进的 9 种方法进行比较,所得结果如图 3~5 所示。9 种方法包括 LIME^[5]、LLNet^[8]、RetinexNet^[9]、MBLLEN^[11]、EGAN^[12]、DSLRL^[13]、MIRNet^[23]、KinD++^[24]、ZDCE^[15]。

LIME 算法和 EGAN 处理后图像的对比度得到明显改善,但是整体亮度与对照图像相比存在较大差距;观察图 3(c)、图 4(c)、图 5(c) 可知,LLNet 并没有有效提升微光图像的对比度,增强结果普遍模糊;RetinexNet 处理后的图像有明显的噪声,图像的亮度也没有得到足够的增强;图 4 中 DSLR 处理的增强图像颜色失真;KinD++ 处理的图 4(i) 存在局部过曝的问题,并且轮船下方产生伪影;ZDCE 对色彩饱满度的增强效果欠

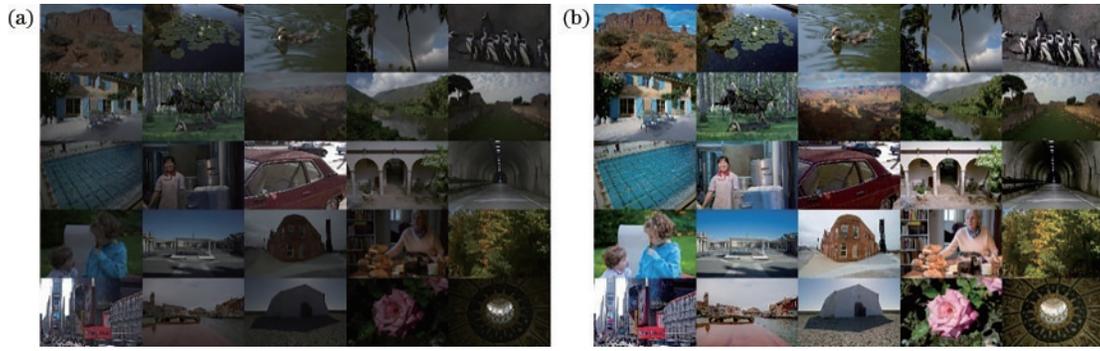


图 2 MIT-Adobe 5K 数据集示例。(a)低光照图像;(b)正常图像

Fig. 2 Example images in MIT-Adobe 5K dataset. (a) Low-light images; (b) normal images



图 3 第一组微光图像的增强结果。(a)微光图像;(b) LIME;(c) LLNet;(d) RetinexNet;(e) MBLLEN;(f) EGAN;(g) DSLR;(h) MIRNet;(i) KinD++;(j) ZDCE;(k)所提算法;(l)专家处理图像

Fig. 3 Enhanced results of the first group of images. (a) Underexposed image; (b) LIME; (c) LLNet; (d) RetinexNet; (e) MBLLEN; (f) EGAN; (g) DSLR; (h) MIRNet; (i) KinD++; (j) ZDCE; (k) proposed method; (l) expert-retouched image

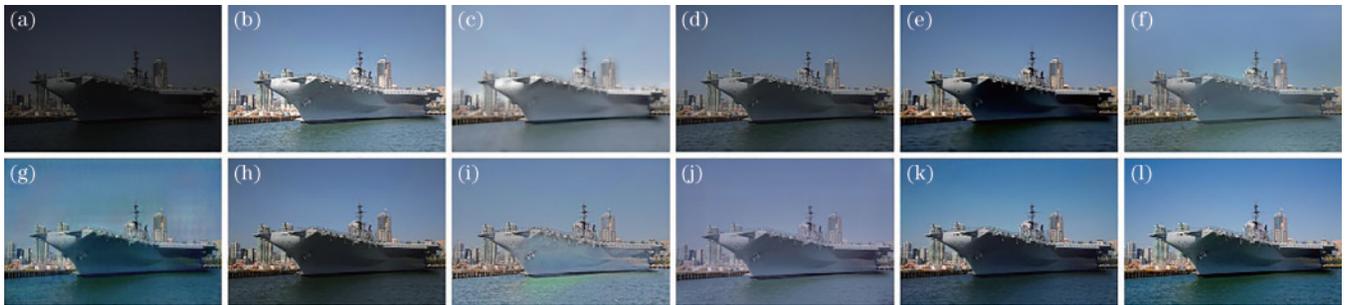


图 4 第二组微光图像的增强结果。(a)微光图像;(b) LIME;(c) LLNet;(d) RetinexNet;(e) MBLLEN;(f) EGAN;(g) DSLR;(h) MIRNet;(i) KinD++;(j) ZDCE;(k)所提算法;(l)专家处理图像

Fig. 4 Enhanced results of the second group of images. (a) Underexposed image; (b) LIME; (c) LLNet; (d) RetinexNet; (e) MBLLEN; (f) EGAN; (g) DSLR; (h) MIRNet; (i) KinD++; (j) ZDCE; (k) proposed method; (l) expert-retouched image

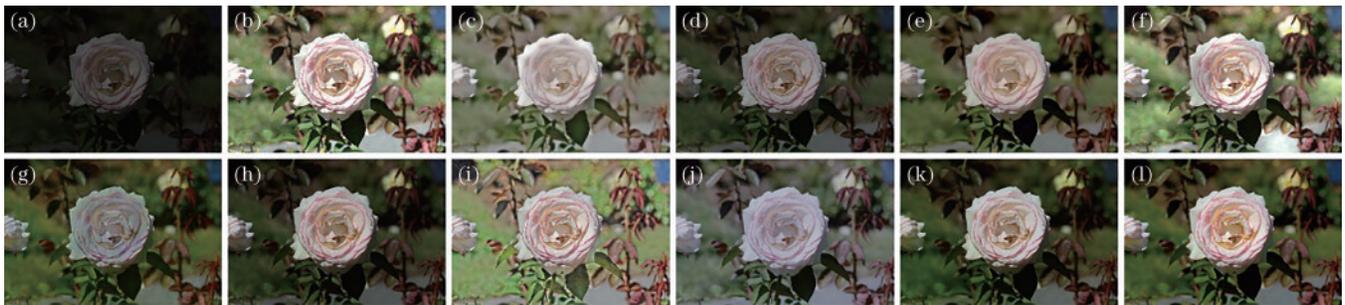


图 5 第三组微光图像的增强结果。(a)微光图像;(b) LIME;(c) LLNet;(d) RetinexNet;(e) MBLLEN;(f) EGAN;(g) DSLR;(h) MIRNet;(i) KinD++;(j) ZDCE;(k)所提算法;(l)专家处理图像

Fig. 5 Enhanced results of the third group of images. (a) Underexposed image; (b) LIME; (c) LLNet; (d) RetinexNet; (e) MBLLEN; (f) EGAN; (g) DSLR; (h) MIRNet; (i) KinD++; (j) ZDCE; (k) proposed method; (l) expert-retouched image

佳。对图 4(e)、图 4(h)、图 4(k)进行了放大处理,结果如图 6 所示。从图 6(a)和图 6(b)可以看出,方法虽然较好地还原了建筑的主要特征,在主观视觉上有显著提升,但是图像整体亮度没有得到有效提升,图 6(a)

还存在结构纹理不够细腻的问题。相比于其他算法,所提方法对图像的增强效果更佳,图像的对比度得到提升,颜色得到较好表达,细节也得到了很好的保留。



图 6 第二组增强图像的局部放大图。(a)图 4(e)的放大图,MBLLEN;(b)图 4(h)的放大图,MIRNet;(c)图 4(k)的放大图,所提算法

Fig. 6 Local amplification of the second group of enhanced images. (a) Local amplification of Fig. 4(e), MBLLEN; (b) local amplification of Fig. 4(h), MIRNet; (c) local amplification of Fig. 4(k), proposed method

此外,还采用直方图对不同方法增强后的图像进行评价。当图像的直方图分布较宽时,图像的视觉效果也更好,图 7 为第一组视觉效果较好的图像增强结

果的直方图。通过分析直方图可以发现,所提方法得到的增强图像直方图分布更均匀。

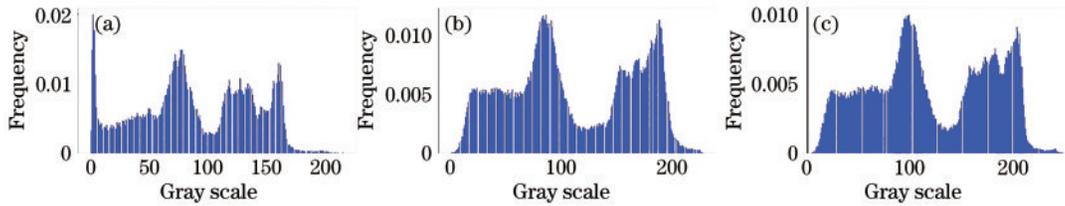


图 7 第一组增强图像的直方图对比结果。(a)图 3(e)的直方图,MBLLEN;(b)图 3(h)的直方图,MIRNet;(c)图 3(k)的直方图,所提算法

Fig. 7 Histogram comparison results of the first group of enhanced images. (a) Histogram of Fig. 3(e), MBLLEN; (b) histogram of Fig. 3(h), MIRNet; (c) histogram of Fig. 3(k), proposed method

4.3 定量比较

为使实验结果更具说服力,将正常照度下的照片作为对比图像,选取了 SSIM、峰值信噪比 (PSNR) 作为数据分析的评价指标。图像增强的数据分析如表 1 所示,表中黑体数字表示最优结果。PSNR 表示最大信号量与噪声强度的比值,值越大,

图像失真情况越少,当两幅图几乎相同时,则 PSNR 值接近 100。

数据显示,所提方法得到的增强图像的 PSNR 值和 SSIM 值均高于其他方法,表明所提方法得到的增强图像更接近正常曝光下的图像,增强后图像的质量较高。

表 1 不同算法对微光图像的客观评价指标

Table 1 Objective evaluation index of different methods for low-light images

Parameter	LIME	LLNet	RetinexNet	MBLLEN	EGAN	DSLRL	MIRNet	ZDCE	Proposed method
PSNR ↑	18.73	14.63	17.68	22.05	21.71	19.33	23.87	21.46	24.43
SSIM ↑	0.638	0.588	0.651	0.869	0.856	0.758	0.889	0.836	0.897

4.4 消融研究

为验证特征信息融合的重要性,分别以通道注意模块和多尺度特征提取模块为变量进行了对比实验。

对比实验的网络模型结构如图 8 所示,除 SK 和 CA 两模块外,其余部分均保持一致。

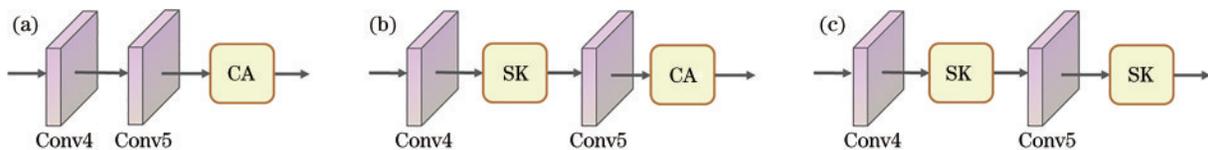


图 8 网络模型对比。(a)无 SK;(b)1 个 SK;(c)无 CA

Fig. 8 Comparison of network model. (a) w/o SK; (b) one SK; (c) w/o CA

选择信息熵(IE)对3个消融实验的结果进行对照分析。表2给出了对比网络与所提网络对图3~5中的微光图像进行增强后测得的信息熵。

从表2可得,所提网络在微光图像增强的任务中

表2 消融实验的信息熵对比

Table 2 Comparison of information entropy in ablation experiment

Image No.	Unprocessed	IE ↑			
		w/o SK	One SK	w/o CA	Proposed method
Fig. 3(a)	6.120	7.497	7.440	7.599	7.644
Fig. 4(a)	5.534	7.059	7.077	7.265	7.271
Fig. 5(a)	6.513	7.009	7.172	7.178	7.350
Average value	6.056	7.188	7.230	7.347	7.422

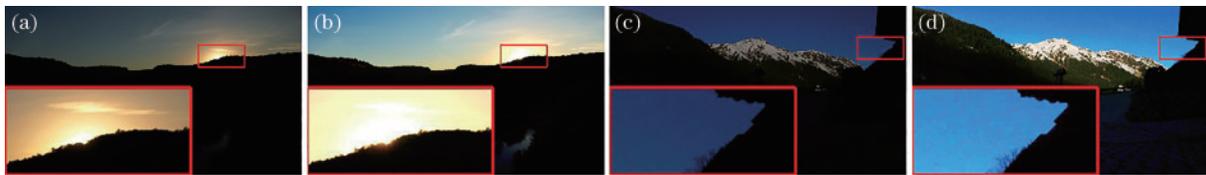


图9 极端条件下微光图像增强结果展示。(a) Sunrise;(b) Sun_en;(c) Mountain;(d) Moun_en

Fig. 9 Examples of enhanced image acquired under extreme conditions. (a) Sunrise; (b) Sun_en; (c) Mountain; (d) Moun_en

5 结 论

针对目前微光图像增强算法存在亮度过饱和、颜色失真等增强效果稳定性较差的问题,提出了一种多尺度融合卷积神经网络的微光图像增强算法。其主要思想是:学习微光图像的映射函数,利用光照的性质对微光图像进行调整,达到微光图像增强的效果。首先通过预处理提取得到微光图像的浅层特征;再通过多尺度特征融合得到图像的局部特征,融合局部特征和全局特征,进而得到微光图像的映射函数 F ;利用MIT-Adobe 5K数据集对所提模型进行训练,之后利用训练好的模型对微光图像进行测试,最终获得增强后的图像。

实验结果证明,多尺度结构可以使网络框架应用更加广泛,适应于不同照度的微光图像。同时客观评价指标PSNR和SSIM也表明所提算法较其他对比算法更优。通过实验的验证,所提方法克服了目前微光图像增强算法存在的亮度过饱和、颜色失真等缺陷,在提升模型速度的同时,也为后续的高级视觉系统提供了技术支撑。

参 考 文 献

- [1] 邓世杰,王海晏,徐安,等.基于对抗生长的目标检测方法[J].光学学报,2022,42(2):0210002.
Deng S J, Wang H Y, Xu A, et al. Target detection method based on antigrowth[J]. Acta Optica Sinica, 2022, 42(2): 0210002.
- [2] 王得成,陈向宁,易辉,等.基于自适应联合双边滤波

表现更佳,其信息熵高于其他对比网络,这表明多尺度特征提取和特征融合可以提高模型对微光图像特征信息重构和提取能力,抑制无用特征,提高特征的利用率。

4.5 局限性

图9展示了所提方法对极低照度下的微光图像的增强效果,其中图9(a)和图9(c)为微光图像,图9(b)和图9(d)为增强图像。从图9(b)和图9(d)可以看出,所提方法对天空区域、雪山及树木的增强效果较好,但未对极暗且难以提取到图像纹理的黑暗区域进行有效增强。另外所提方法需要大量成对的训练样本,训练结果易受参照图像风格影响,未来将选择非成对图像作为训练集,对半监督、无监督的训练方法进行研究,实现对微光图像的增强。

的深度图像空洞填充与优化算法[J].中国激光,2019,46(10):1009002.

Wang D C, Chen X N, Yi H, et al. Hole filling and optimization algorithm for depth images based on adaptive joint bilateral filtering[J]. Chinese Journal of Lasers, 2019, 46(10): 1009002.

- [3] Pizer S M, Johnston R E, Ericksen J P, et al. Contrast-limited adaptive histogram equalization: speed and effectiveness[C]//Proceedings of the First Conference on Visualization in Biomedical Computing, May 22-25, 1990, Atlanta, GA, USA. New York: IEEE Press, 1990: 337-345.
- [4] Tajeripour F, Fekri-Ershad S. Developing a novel approach for stone porosity computing using modified local binary patterns and single scale Retinex[J]. Arabian Journal for Science and Engineering, 2014, 39(2): 875-889.
- [5] 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.
- [6] 黄辉先,陈凡浩.基于注意力机制和Retinex的低照度图像增强方法[J].激光与光电子学进展,2020,57(20):201004.
Huang H X, Chen F H. Low-illumination image enhancement method based on attention mechanism and Retinex[J]. Laser & Optoelectronics Progress, 2020, 57(20): 201004.
- [7] Dong X, Wang G, Pang Y, et al. Fast efficient algorithm for enhancement of low lighting video[C]//2011 IEEE International Conference on Multimedia and

- Expo, July 11-15, 2011, Barcelona. New York: IEEE Press, 2011.
- [8] 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.
- [9] Wei C, Wang W J, Yang W H, et al. Deep retinex decomposition for low-light enhancement[EB/OL]. (2018-08-14)[2022-03-05]. <https://arxiv.org/abs/1808.04560>.
- [10] 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.
- [11] Lü F F, Lu F, Wu J H, et al. MBLLen: low-light image/video enhancement using CNNs[C]//British Machine Vision Conference 2018, September 3-6, 2018, Newcastle, UK. London: British Machine Vision Conference, 2018: 220-228.
- [12] 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.
- [13] Lim S, Kim W. DSLR: deep stacked Laplacian restorer for low-light image enhancement[J]. *IEEE Transactions on Multimedia*, 2021, 23: 4272-4284.
- [14] 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), Seattle, WA, USA. New York: IEEE Press, 2020: 1777-1786.
- [15] Li C, Guo C, 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.
- [16] Land E H. The retinex theory of color vision[J]. *Scientific American*, 1977, 237(6): 108-128.
- [17] 黄玉明, 徐光佑, 叶培建. 彩色图像中的本征图像的抽取[J]. *中国空间科学技术*, 1991, 11(5): 25-28.
Huang Y M, Xu G Y, Ye P J. Extracting intrinsic images in color image[J]. *Chinese Space Science and Technology*, 1991, 11(5): 25-28.
- [18] Chen J W, Adams A, Wadhwa N, et al. Bilateral guided upsampling[J]. *ACM Transactions on Graphics*, 2016, 35(6): 203-210.
- [19] Gharbi M, Chen J W, Barron J T, et al. Deep bilateral learning for real-time image enhancement[J]. *ACM Transactions on Graphics*, 2017, 36(4): 1-12.
- [20] Li X, Wang W H, Hu X L, et al. Selective kernel networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 510-519.
- [21] de Marsico M, Nappi M, Riccio D, et al. Mobile iris challenge evaluation (MICHE)-I, biometric iris dataset and protocols[J]. *Pattern Recognition Letters*, 2015, 57: 17-23.
- [22] Bychkovsky V, Paris S, Chan E, et al. Learning photographic global tonal adjustment with a database of input/output image pairs[C]//CVPR 2011, June 20-25, 2011, Colorado Springs, CO, USA. New York: IEEE Press, 2011: 97-104.
- [23] Zamir S W, Arora A, Khan S, et al. Learning enriched features for real image restoration and enhancement[EB/OL]. (2020-03-15)[2022-03-05]. <https://arxiv.org/abs/2003.06792>.
- [24] Zhang Y H, Guo X J, Ma J Y, et al. Beyond brightening low-light images[J]. *International Journal of Computer Vision*, 2021, 129(4): 1013-1037.