

融合残差结构与注意力机制的暗光图像增强算法

刘 瑶, 贾晓芬

安徽理工大学 电气与信息工程学院, 安徽 淮南 232001

摘要:目的 低光工况或拍摄技巧影响都可能获得低光照图像,为解决此类图像对比度低、噪声大、颜色失真等问题,提出一种卷积神经网络增强模型 RetKIND,包括分解网络、亮度调整网络和降噪网络。方法 它借助残差模块(RB)和跳跃连接,有效抑制分解网络在分解时产生的噪声;融合 U-Net 架构、空洞卷积和 EBAM 高效注意力机制构建降噪网络,利用空洞卷积扩大感受野,提取更多图像信息,提高 EBAM 在通道和空间上提取反射图的细节、纹理、颜色等特征的能力,实现图像去噪;由 UC(亮度调整网络中的自定义模块)和普通卷积组成亮度调整网络,旨在减少光照图细节缺失,提高光照分量对比度。融合去噪后的反射分量和增强后的光照分量,得到正常光照图像。结果 仿真结果表明:在 LOL 数据集上,相较 R2RNet, F_{PSNR} 和 F_{SSIM} 值分别上升了 6.2% 和 4.2%;相较 URetinex-Net, F_{PSNR} 和 F_{SSIM} 值分别上升了 5.9% 和 1.2%;相较 DEANet, F_{PSNR} 和 F_{SSIM} 值分别上升了 2.9% 和 1.1%。结论 Ret-KIND 模型既能提升图像亮度,又能降低图像的噪声,有助于推动低光图像增强模型应用到目标检测领域。

关键词:低光照图像增强;去噪;RB 残差模块;EBAM 注意力机制;Retinex 理论

中图分类号:TP391 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2024.0004.011

Low-light Image Enhancement Algorithm Integrating Residual Structure and Attention Mechanism

LIU Yao, JIA Xiaofen

School of Electrical and Information Engineering, Anhui University of Science & Technology, Anhui Huainan 232001, China

Abstract: Objective Low-light images can be obtained due to either low-light conditions or shooting techniques. In order to solve such problems as low contrast, high noise, and color distortion of images, a convolutional neural network enhancement model RetKIND was proposed, which included a decomposition network, brightness adjustment network, and noise reduction network. **Methods** With the help of the residual block (RB) and skip connection, the noise generated by the decomposition network during decomposition was effectively suppressed. The noise reduction network was constructed by integrating U-Net architecture, dilated convolution, and EBAM efficient attention mechanism. The dilated convolution was used to enlarge the receptive field to extract more image information and EBAM was utilized to extract details, texture, color, and other features of the reflection image in channel and space to achieve image denoising. The brightness adjustment network was composed of a UC module (self-designed module in the brightness adjustment network) and traditional convolution, which aimed to reduce the detail loss of light images and improve the contrast of the light component. Finally, the denoised reflection component and the enhanced light component were fused to obtain the normal illumination image. **Results** Simulation results showed that on the dataset LOL, compared with R2RNet, the values of F_{PSNR} and F_{SSIM} increased by 6.2% and 4.2%, respectively; compared with URetinex-Net, the values of F_{PSNR} and F_{SSIM} of

收稿日期:2023-04-12 修回日期:2023-05-24 文章编号:1672-058X(2024)04-0086-11

基金项目:国家自然科学基金面上项目(52174141);安徽省重点研究与开发计划资助项目(202104A07020005);安徽省自然科学基金面上项目(2108085ME158);安徽高校协同创新项目(GXXT-2020-54)。

作者简介:刘瑶(2000—),女,安徽枞阳人,硕士研究生,从事图像处理研究。

通讯作者:贾晓芬(1978—),女,安徽砀山人,博士,教授,从事深度学习、机器学习、图像处理研究。Email: 2730323681@qq.com.

引用格式:刘瑶,贾晓芬.融合残差结构与注意力机制的暗光图像增强算法[J].重庆工商大学学报(自然科学版),2024,41(4):86—96.

LIU Yao, JIA Xiaofen. Low-light image enhancement algorithm integrating residual structure and attention mechanism[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2024, 41(4): 86—96.

Ret-KIND increased by 5.9% and 1.2%, respectively; compared with DEANet, the values of F_{PSNR} and F_{SSIM} of Ret-KIND increased by 2.9% and 1.1%, respectively. **Conclusion** The Ret-KIND model can not only improve image brightness, but also reduce image noise, which helps to promote the application of the low-light image enhancement model to the field of target detection.

Keywords: low-light image enhancement; denoising; RB residual module; EBAM attention mechanism; Retinex theory

1 引言

由于光照环境不佳或拍摄技巧等因素,会引起图像出现亮度较暗、噪声较大、颜色失真等问题。为有效提升暗光图像的质量,在过去的几十年间,很多研究者提出低光图像增强算法。现有低光照图像增强技术可粗略分为基于分布的映射、基于模型优化和基于深度学习的3类方法。

基于分布的映射方法,指映射暗光输入的分布以放大较小的值,这是解决低光照图像增强的最直观思路。此类方法的两种代表性工作是直方图均衡化和基于S型曲线的方法。董等^[1]引入了直方图动态削峰技术和边缘信息融合技术对低光图像进行增强,且模型参数量较小;Fan等^[2]通过直方图约束和调整对比度来控制图像增强结果,增强效果较好;Hong等^[3]利用伽马校正处理HSV色彩空间中存在的噪声,进一步降低噪声,提升图像的对比度。但现有的基于分布映射的方法仍然存在颜色失真等现象,严重影响了增强结果的观感。现有的基于S型曲线的方法存在着曝光不均匀现象。

基于模型优化的方法Retinex理论^[4]为增强弱光图像的过程进行了直观的物理描述。将低光图像分解为光照和反射率两部分,在保持反射率一致性的前提下,增加照明亮度以增强图像;Isha等^[5]在此基础上,提出一种新型图像复原技术,构建图像的最小颜色通道和暗通道,融合这两个通道的低通和高通分量,得到增强后的图像,进一步减少了图像细节信息的丢失;Gao等^[6]在反射图像通道中使用传统直方图均衡化并引导滤波器来增强图像的对比度,在光照图像通道中通过伽马变换进行光补偿,融合这两个通道后得到的目标图噪声较低。但此类方法,如何设计先验正则项是大部分工作的核心,许多模型参数需要根据实际情况进行手动调整,迭代过程较多且相对耗时,不利于实际的应用。

基于深度学习的方法,Lore等^[7]首次提出深度自编码器LLNet,对低光图像进行自适应增强;Lyu等^[8]提出多分支低光增强网络MBLLEN,进一步学习了低光图像到正常光照图像的映射;Wei等^[9]基于图像分解思想,首次将整个网络划分成分解模块和增强模块,设

计全新的Retinex-Net网络;Guo等^[10]构建了一个无监督训练网络Zero-dce,以迭代递进的方式估计输入图像的亮度曲线,从而实现低光图像增强;Zhang等提出的KIND^[11]和KIND++^[12]网络通过使用不同曝光程度的图像进行训练,使得到的增强图像具有很好的效果,但KIND++的去噪性能更佳,模型也较KIND更复杂。针对分解过程中产生的噪声;Hai等^[13]在KIND网络的基础上,提出的R2R-Net在分解过程中有效抑制了图片噪声;随后,Wu等^[14]进一步优化了KIND网络,提出了URetinex-Net模型,实现了分解过程中噪声抑制和细节保留;Zhang等^[15]利用KIND模型,设计两个增强网络对反射率进行去噪并增强照明度,将提取的特征重复地交互以合并空间和角度信息,高效同步处理所有视图;Sun等^[16]提出了一种基于Retinex理论和注意力机制的分解网络,设计了具有编解码结构的增强块来实现低照度图像增强,改善了增强后图片的色彩饱和度;Jiang等^[17]进一步改进KIND,每个分支网络都是由DenseNet^[18]和U-Net^[19]组合而成的新网络,进一步减少了图像细节的缺失。此类基于深度学习的方法均取得了不错的效果,但大多数方法在增强过程中没有很好的抑制住噪声,使得增强后的图像出现噪声大,对比度低等问题,不利于图像质量的提升。

为了在低光增强的同时更好地抑制噪声,借助残差结构将输入的含噪图像与输出的噪声图像相减,实现去噪。再利用注意力机制激活感兴趣特征,提高网络提取图像几何信息及纹理细节信息的能力。同时引入UC模块致力于深度提取亮度调整所需的颜色、纹理等有用特征,提高图像对比度并增强其清晰度,得到一种低光照图像增强算法Ret-KIND。

2 Ret-KIND 模型设计

2.1 理论介绍

Retinex理论将图像分解为反射分量和光照分量,其原理如图1所示。不同曝光程度计算如下:

$$S = R \circ I \quad (1)$$

其中,“ $\circ$ ”表示逐像素相乘操作; S 表示任一具有不同曝光程度的图像; R 表示反射分量,反映物体自有属性,与外界光照强度无关; I 表示光照分量,随物体的曝光程度而变化。




图 1 Retinex 理论原理图

Fig. 1 Schematic diagram of Retinex theory

低光照环境下,被拍摄物除了光照分量较低外,通常会出现不平衡的照明分布,引起成像质量退化,出现颜色失真等现象。

2.2 低光图像增强模型 Ret-KIND

由于噪声与光照强度有关,低光照成像时必然会引入噪声,使增强后的低光照图像产生失真或模糊现象,造成图像细节缺失。KIND 作为经典低光图像增强模型,得到了很多学者青睐。它由分解网络、调整网络

及降噪网络构成。图像分解时没有考虑噪声,光照强度调节过程中丢失了纹理、细节等信息。降噪网络是多层 U-Net 结构,在特征提取阶段大量使用普通卷积,增大了计算量,多次使用最大池化层,导致部分特征信息丢失。

为改善上述问题并获取高质量图像,以 KIND 网络为基础,提出图 2 所示的低光照图像增强模型 Ret-KIND。首先,将低光照图像和与其配对的正常光照图像分解为相应的反射分量(R_{low} , R_{normal})和光照分量(I_{low} , I_{normal})。再将低光图像的光照分量 I_{low} 送入光照调节网络中,在结构感知约束下,提升光照分量的亮度。降噪网络将反射分量 R_{low} 和光照分量 I_{low} 作为输入,经过降噪处理后,输出反射分量 R_{en} 。最后,将调节后的光照分量 I_{en} 与去噪后的反射分量 R_{en} 重新组合,形成增强图像,作为网络输出。




图 2 Ret-KIND 模型结构图

Fig. 2 Structure diagram of Ret-KIND model

Ret-KIND 的主要创新点:在分解网络中引入残差块和跳跃连接,旨在有效抑制分解过程中产生的噪声。降噪网络中,融入注意力机制和空洞卷积,通过高效抑制无用信息,达到提高网络识别精度的目的。亮度调整模块中,引入 UC 模块,旨在减少光照图细节缺失,提高对比度。

2.3 分解网络

KIND 模型的分解网络采用多层普通卷积对输入图像进行特征提取,参数量较大,模型冗余。鉴于低光图像

的噪声往往存在于暗区,易在分解网络的上采样结构中被放大,致使反射图上留存大量噪声,严重影响图像增强效果,急需去噪。R2R-Net^[13]利用 DNCNN^[20]去噪网络的残差块高效遏制了反射图上的噪声放大,同时,使神经网络在训练阶段更容易优化,避免发生梯度爆炸,达到很好的分解效果。受此启发,引入 RB 残差块构建图 3 所示的分解网络,它借助残差结构将输入噪声图像减去 RB 输出的噪声图像,实现图像去噪。




图 3 分解网络结构图

Fig. 3 Structure diagram of decomposition network

分解网络由 7 个普通卷积,4 个 RB 残差块以及两次跳跃连接组成。首先,使用 3×3 卷积对输入图像

(S_{low}, S_{normal}) 进行特征提取,然后采用4个RB模块提取纹理、细节等有用特征。通过跳跃连接实现第1、3两个残差块以及第2、4两个残差块之间的间接连接,减少边缘信息的缺失,避免底层颜色失真,确保图像特征的完整提取,得到更准确的光照分量和反射分量。同时,间接跳跃连接避免了多次重复提取相同特征,降低了模型的冗余度。前6个卷积后均使用 ReLU 作为激活函数,增加输入、输出特征的非线性关系,助力深度提取输入图像的有用特征。最后,通过 3×3 的卷积提取反射分量和光照分量并使用 Sigmoid 函数激活,促使输出值映射到 $(0,1)$ 之间,保证分解网络的稳定优化,得到1通道光照分量 (I_{low}, I_{normal}) 和3通道反射分量 (R_{low}, R_{normal}) 。分解网络的实现过程为

$$\begin{aligned} H_1 &= H_{RB}(ReLU(C_{3 \times 3}(ReLU(C_{3 \times 3}(S_{low})))))) \\ H_2 &= H_{RB}(ReLU(C_{3 \times 3}(H_1))) \\ H_3 &= Concat(H_1, H_{RB}(ReLU(C_{3 \times 3}(H_2)))) \\ H_4 &= Concat(H_2, H_{RB}(ReLU(C_{3 \times 3}(H_3)))) \\ (R_{low}, I_{low}) &= Sigmoid(C_{3 \times 3}(ReLU(C_{3 \times 3}(H_4)))) \end{aligned} \quad (2)$$

其中, H_1 、 H_2 分别表示第1、2个RB模块的输出特征, H_3 表示第1、3个RB模块的特征融合输出, H_4 表示第2、4个RB模块的特征融合输出, ReLU 和 Sigmoid 分别表示激活函数, $C_{3 \times 3}$ 表示 3×3 卷积操作, Concat 表示级联操作, H_{RB} 表示 RB 模块的映射函数。

RB 模块如图4所示,先使用 1×1 卷积保留输入图像 F_{in} 的原始特征信息,再通过3个 3×3 卷积后进行 Padding 操作,用于深度提取输入图像 F_{in} 中的噪声,然后使用 1×1 卷积旨在降维,使输入图像 F_{in} 与输出噪声图像 F_2 维度保持一致。最后将输入图像 F_{in} 与噪声图像 F_2 相减,得到最终的干净图像 F_{out} 。




图4 RB 模块图

Fig. 4 Diagram of RB module

RB 模块包含的5个卷积层对应通道数分别为64、128、256、128、64,其中,第1、5层采用 1×1 卷积,中间3层均采用 3×3 卷积。卷积后全部使用 ReLU 作为激活函数,增加输入、输出特征的非线性关系,旨在助力深度提取噪声特征。RB 模块的实现过程为

$$\begin{aligned} F_1 &= ReLU(C_{3 \times 3}(ReLU(C_{3 \times 3}(ReLU(C_{1 \times 1}(F_{in})))))) \\ F_2 &= ReLU(C_{1 \times 1}(ReLU(C_{3 \times 3}(F_1)))) \\ F_{out} &= F_{in} - F_2 \end{aligned} \quad (3)$$

其中, ReLU、 $C_{3 \times 3}$ 、Concat 含义同式(2), $C_{1 \times 1}$ 表示 1×1 卷积操作, F_1 表示 RB 模块中第3层 3×3 卷积的输出特征。

RB 模块的引入,有助于减少亮度图和反射图上的噪声,促使分解网络输出高质量的反射分量 R_{low} 和 I_{low} ,再将 R_{low} 和 I_{low} 送入降噪网络和亮度调整网络中,用于进一步提取有用信息,提高了整个网络对有效信息的获取能力。

2.4 降噪网络

2.4.1 EBAM 注意力模块

注意力机制根据特征信息的重要性进行权重的分配,旨在保留有用信息,摒弃无用信息。CBAM^[21] 注意力机制因其包含空间注意力模块和通道注意力模块,高效地提升了模型的整体性能,从而被广泛应用。在此基础上,进一步对其改进,构建如图5所示的 EBAM 注意力机制。




图5 EBAM 注意力模块图

Fig. 5 Diagram of EBAM attention module

EBAM 对通道注意力和空间注意力采取并联连接。在通道注意力模块中,特征图 A 先经过池化层生成最大值池化描述符 A_{max1} 和均值池化描述符 A_{avg1} ,通过内核的快速一维卷积共享相同的学习参数,高效的聚合 k 个通道的信息,再将卷积后的两个特征元素相加,并使用 Sigmoid 作为激活函数,生成通道注意力权重 M_c 。在空间注意力模块中,特征图 A 经过池化层后分别得到描述符 A_{avg2} 与 A_{max2} ,沿通道进行拼接后使用卷积核大小为3,步长为2的空洞卷积进行降维成单通道,在保证模型整体性能的前提下,进一步降低其冗余度,扩大感受野,捕捉到更多的空间信息,并使用 Sigmoid 激活函数激活,得到权重 M_s 。最后,将输入的特征图 A 与通道注意力权重 M_c 、空间注意力权重 M_s ,按元素相乘,得到最终输出 A_1 。EBAM 注意力模块的实现过程为

$$\begin{aligned}
M_C &= \text{Sigmoid}(f_k(\text{Max_Pool}(A)) + f_k(\text{Avg_Pool}(A))) = \\
&\quad \text{Sigmoid}(f_k(A_{\max 1}) + f_k(A_{\text{avg} 1})) \\
M_S &= \text{Sigmoid}(f_{\text{dilat}}([\text{Max_Pool}(A); \text{Avg_Pool}(A)])) = \\
&\quad \text{Sigmoid}(f_{\text{dilat}}([A_{\max 2}; A_{\text{avg} 2}])) \\
A_1 &= A \times M_C \times M_S \\
k &= \left\lfloor \frac{\log_2 C}{2} + \frac{1}{2} \right\rfloor_{\text{odd}}
\end{aligned} \quad (4)$$

其中, Sigmoid 表示激活函数, f_k 表示卷积核大小为 k 的一维卷积操作, f_{dilat} 表示卷积核大小为 3, 步长为 2 的空洞卷积, Max_Pool、Avg_Pool 表示最大值池化和均值池化, C 表示输入特征图的通道数, $|B|_{\text{odd}}$ 表示与 B 最相近的奇数。

2.4.2 降噪模块

KIND 模型选用 U-Net 网络进行降噪, 在浅层几何结构信息与深层语义信息进行融合时, 既保留了图像的细节、纹理等有用特征, 又保存了噪声等无用特征。为此, 提出一个注意力机制引导的降噪网络, 结构如图 6 所示。在降噪网络的信息融合过程中, 注意力机制可减少对无关信息的特征响应, 只激活感兴趣的特征, 提高算法对图像细节信息的处理能力。由于反射图上噪声种类多, 存在高斯噪声、泊松噪声等, 且分布比较杂乱, 高度依赖亮度图的亮度分布。因此, 需将反射分量 R_{low} 和亮度(光照)分量 I_{low} 一同输入降噪网络进行降噪处理。




图 6 降噪网络结构图

Fig. 6 Structure diagram of noise reduction network

降噪网络依次包括编码层、瓶颈层和解码层。编码层由 2 个空洞卷积, 4 组编码块组成, 其中编码块包含 2 个卷积和 1 个最大池化层。瓶颈层由 2 个普通卷积构成。解码层由 4 组解码块组成, 其中解码块包含 2 个卷积和 1 个反卷积层。上述卷积后全部使用 ReLU 作为激活函数, 增加输入、输出特征的非线性关系, 旨在助力有效特征的充分提取。在编码阶段, 引用下采样对图像进行相对压缩, 减少部分噪声信息。同时, 将降噪后的反射分量与正常光下的反射分量进行损失函数的计算, 通过反向传播不断自优化网络, 使降噪损失函数达到最优值, 从而得到去噪后的反射分量。在解码阶段中进行上采样, 将编码后的图像恢复到原图尺寸。

在 Ret-KIND 降噪网络中, 将输入的反射分量和光照分量经过两个 3×3 空洞卷积, 用于扩大感受野, 获取多尺度的反射图的细节信息; 再经过四组均由两个 3×3 卷积、一个 2×2 最大池化层组成的编码块, 致力于压缩输入图像特征, 保留关键信息; 用两个 3×3 卷积, 进一步提取反射图的有用特征后, 再经过四组由一个 2×2 反卷积层, 两个 3×3 卷积组成的解码块, 致力于恢复目标图的细节和空间维度。

由于编码过程中, 图像的相对压缩会导致部分细节信息的丢失, 受目标识别网络 CBAM 启发, 将注意力模块嵌入到下采样对上采样的跳跃连接中, 如图 7, 构造出 EBAM 降噪层。将跳跃连接后得到的特征图与反卷积得到的特征图进行融合, 将低层细节、纹理等特征融入高层特征中, 减少下采样导致的空间信息丢失。最后, 通过一个 3×3 的卷积进一步提取反射分量的有用特征, 并使用 Sigmoid 作为激活函数, 促使输出值映射到 $(0, 1)$ 之间, 旨在稳定优化降噪网络, 从而得到去噪后的 3 通道反射分量。EBAM 降噪层的实现过程为

$$\begin{aligned}
N_1 &= \text{ReLU}(C_{3 \times 3}(\text{ReLU}(C_{3 \times 3}(E_{\text{in}})))) \\
N_2 &= \text{ReLU}(C_{3 \times 3}(\text{ReLU}(C_{3 \times 3}(\text{Max_pooling}_{2 \times 2}(N_1))))) \\
N_3 &= \text{Concat}(N_{\text{EBAM}}(N_1), \text{Unsampling}_{2 \times 2}(N_2)) \\
E_{\text{out}} &= \text{ReLU}(C_{3 \times 3}(\text{ReLU}(C_{3 \times 3}(N_3))))
\end{aligned} \quad (5)$$

其中, ReLU 表示激活函数, $C_{3 \times 3}$ 表示 3×3 卷积操作, $\text{Max_pooling}_{2 \times 2}$ 表示 2×2 的最大池化层操作, $\text{Unsampling}_{2 \times 2}$ 表示 2×2 的反卷积操作, Concat 表示级联操作, N_{EBAM} 表示 EBAM 降噪层的映射函数, N_1 、 N_2 分别表示第 1、2 组卷积的输出特征, N_3 表示经过反卷

积与 N_1 融合后的输出特征, E_{in} 、 E_{out} 分别表示 EBAM 降噪层的输入和输出特征。




图 7 EBAM 降噪层

Fig. 7 EBAM noise reduction layer

特征融合时, EBAM 注意力机制将更多的权重分配给颜色、细节和纹理等有用的特征, 为噪声、阴影块等特征分配较少的权重。降噪网络中加入 EBAM 注意力机制后, 有助于高效减少反射图上的噪声, 极大地提升整个网络的增强效果。

2.5 亮度调整网络

KIND 模型选用 4 层卷积来构造亮度调整网络, 鉴于普通卷积对低光亮度图的特征提取能力不足。受降噪网络结构的启发, 致力于全面提取亮度调整网络的有用特征, 引入 UC 模块, 构建图 8 所示的亮度调整网络, 它由 2 个普通卷积, 1 个 UC 模块组成, 其中 UC 模块含 3 个卷积、1 个最大池化层和 1 个反卷积层。




图 8 亮度调整网络结构图

Fig. 8 Structure diagram of brightness adjustment network

在亮度调整网络中, 输入光照分量。经过一个 3×3 卷积, ReLU 函数激活, 提取光照分量的相关特征后, 再经过 1 个 UC 模块旨在深度提取纹理、细节、颜色等特征, 最后通过一个 3×3 卷积进一步提取光照分量的有用特征, 并使用 Sigmoid 函数激活, 促使输出值映射到 $(0, 1)$ 之间, 致力于保障亮度调整网络的稳定优化, 得到调整后的 1 通道光照分量。亮度调整网络的实现过程为

$$I_{en} = \text{Sigmoid}(C_{3 \times 3}(E_{uc}(\text{ReLU}(C_{3 \times 3}(I_{low})))) \quad (6)$$

其中, I_{low} 和 I_{en} 分别表示亮度调整网络的输入和输出特征, ReLU 和 Sigmoid 分别表示激活函数, $C_{3 \times 3}$ 表示 3×3 卷积操作, E_{uc} 表示 UC 模块的映射函数。

UC 模块主要由下采样块和上采样块构成。下采样块由一个 3×3 卷积和一个 2×2 最大池化层组成, 致

力于降低网络参数, 增大感受野, 促使后面的卷积核能够抓取更加全局的信息。下采样块与上采样块之间通过一个 3×3 的卷积相连, 旨在深度提取亮度图像的颜色、纹理等信息。上采样块由一个 2×2 反卷积层和一个 3×3 卷积构成, 使图像由小分辨率映射到大分辨率, 经过相应的裁剪, 与下采样中对应的特征映射进行拼接, 补偿丢失的亮度细节信息, 增强清晰度, 上述卷积后全部使用 ReLU 作为激活函数, 增加输入、输出特征的非线性关系, 旨在助力提取图像细节特征。UC 模块映射函数 E_{uc} 的实现过程为

$$U_1 = \text{ReLU}(C_{3 \times 3}(E_1))$$

$$U_2 = \text{ReLU}(C_{3 \times 3}(\text{Max_pooling}_{2 \times 2}(U_1)))$$

$$E_2 = \text{ReLU}(C_{3 \times 3}(\text{Concat}(U_1, \text{Unsamplng}_{2 \times 2}(U_2)))) \quad (7)$$

其中, E_1 、 E_2 分别表示 UC 模块的输入和输出特征, U_1 和 U_2 分别表示 UC 模块中第 1 个卷积和第 3 个卷积的输出特征, ReLU、Sigmoid、 $C_{3 \times 3}$ 的含义同式 (6), $\text{Max_pooling}_{2 \times 2}$ 表示 2×2 最大池化层操作, $\text{Unsamplng}_{2 \times 2}$ 表示 2×2 反卷积操作, Concat 表示级联操作。

为了更好地处理图像的边界像素, UC 模块引用了 U-Net 结构中的 Overlap-tile 策略, 即对图像的某一块像素点进行预测时, 需要该图像块周围的像素点提供上下文信息。同时提前计算输入、输出图像之间的尺寸差, 对输入图像的边缘采用镜像扩充, 扩充的像素点均由原图沿白线对称得到, 以此来解决输入、输出图片尺寸不一致的问题。UC 模块的引入, 极大地提升了亮度调整网络提取图像细节的能力, 对整个增强网络起到了至关重要的作用。

2.6 损失函数

Ret-KIND 模型由 3 个子网络构成, 如图 2, 整个网络损失由分解损失、降噪损失以及亮度调整损失累加而成。其中, 分解损失由 D_{loss1} 和 D_{loss2} 组成, D_{loss1} 促使低光图片分解后的反射分量与正常光图片的反射分量相似, D_{loss2} 保障低光图片分解后的光照分量和正常光图片的光照分量相像, 降噪损失 R_{loss} 旨在保证降噪处理后的反射分量和正常光图片的反射分量在结构、纹理信息等方面一致, 亮度调整损失 I_{loss} 致力于使调整后的低光图片的光照分量与正常光图片的光照分量在细节信息上高度相近。

3 实验结果和分析

3.1 实验环境

采用 LOL 作为训练集, 为验证 Ret-KIND 模型能够去除噪声, 在 PASCAL-VOC 图像数据集上选取 144 张分别进行了含噪声和不含噪声的测试。此外, 分别选取 50 张 DICM 数据集、LIME 数据集、Fusion 数据集

和 VV 数据集进行测试。训练和测试的图像的大小均为 600×400 , 位深为 24 bit。在训练过程中, 采用 Adam 自适应矩估计优化器, 分解网络和光照调整网络的批量化大小为 16, 块大小为 48×48 , 训练次数为 3 000 次。降噪网络的批量化大小为 8, 块大小为 384×384 , 训练次数为 2 000 次。实验所使用的 TensorFlow-gpu1.15 的深度学习框架在 Nvidia GeForce RTX 2080Ti 设备上完成。

为了更好地评估增强后图片的质量, 选取峰值信噪比值 ($F_{\text{PSNR}}^{[22]}$)、结构相似性值 ($F_{\text{SSIM}}^{[23]}$)、自然图像质量评估值 ($F_{\text{NIQE}}^{[24]}$) 和无参考图像空间质量评估值 ($F_{\text{BRISQUE}}^{[25]}$) 进行定量评估。 F_{PSNR} 和 F_{SSIM} 的值越高, 表示增强后得到的图像质量越好。 F_{NIQE} 和 F_{BRISQUE} 的值越高, 增强后的图像质量越差。 F_{Params} 表示模型参数量, 参数量越小, 模型越简单。

3.2 消融实验

Ret-KIND 的设计过程中, 在分解网络引入了残差块 RB 和跳跃连接 SC, 降噪网络融入了注意力机制 EBAM 和空洞卷积 DC, 亮度调整模块引入 UC 模块。为了验证各模块设计的有效性, 开展 6 个消融实验, 结果见表 1。

表 1 各改进模块的消融实验结果

Table 1 Ablation experimental results of each improved module

序 号	算 法	$F_{\text{PSNR}} \uparrow$	$F_{\text{SSIM}} \uparrow$	$F_{\text{Params}} \downarrow$ (M)
1	KIND	15.764 6	0.688 8	8.16
2	KIND+RB	17.509 6	0.758 3	10.67
3	KIND+SC	15.972 4	0.721 4	9.13
4	KIND+UC	16.822 4	0.744 5	8.46
5	KIND+DC	16.547 6	0.731 7	8.43
6	KIND+EBAM	16.647 1	0.733 4	9.17
7	KIND+RB+SC+UC+DC+EBAM (Ret-KIND)	19.883 9	0.795 7	13.23

由表 1 可知: 各改进模块对整个网络都起到了促进作用。首先, 在分解网络中引入残差块 RB, 虽然模型参数增大到 10.67 MB, 但 F_{PSNR} 、 F_{SSIM} 分别提高了 13.58% 和 10.09%。随后在亮度调整网络引入 UC 模块, F_{PSNR} 、 F_{SSIM} 分别提高了 6.71% 和 8.09%, 当模型包含 RB、SC、UC、DC 和 EBAM 时, 整个网络处理图像的性能得到飞升, 与 KIND 相比, F_{PSNR} 提高了 26.13%, F_{SSIM} 提高了 15.52%。

为了更好地验证 Ret-KIND 算法的性能, 将其与 5 种传统经典算法: LIME^[26]、MF^[27]、NPE^[28]、PLE^[29] 和 SIRE^[30] 等, 以及 7 种深度学习方法: Retinex-Net^[9]、Zero-Dce^[10]、KIND^[11]、KIND++^[12]、R2Rnet^[13]、URetinex-Net^[14] 和 DEANet^[17] 开展对比实验。为保证

公平性, 对比方法均采用原文献提供的模型或源代码进行训练和测试。对比试验的客观指标如表 2—表 5 所示, 主观指标如图 9—图 12 所示。

表 2 是利用 4 个客观指标在 LOL 数据集上对各算法进行评估的结果。其中, 黑色加粗数字表示最优结果, “↑”表示值越高, 图像的质量越好, “↓”表示值越低, 图像的质量越好。可见, 相比 5 种经典算法, Ret-KIND 的 F_{PSNR} 、 F_{SSIM} 、 F_{NIQE} 和 F_{BRISQUE} 4 个客观指标均取得了最好数值。相比 PLE, Ret-KIND 的 F_{PSNR} 、 F_{SSIM} 分别提高了 90.96% 和 105.61%, F_{NIQE} 和 F_{BRISQUE} 分别降低了 45.07% 和 51.07%。相较于 7 种影响力较大的深度学习方法, Ret-KIND 的 F_{NIQE} 略低于 URetinex-Net 的 F_{NIQE} , 但其余指标均取得了绝对优势。相比 URetinex-Net, Ret-KIND 的 F_{PSNR} 和 F_{SSIM} 分别提高了 5.85%、1.23%。相比 DEANet, Ret-KIND 的 F_{PSNR} 和 F_{SSIM} 分别提高了 2.91%、1.05%。

表 2 LOL 数据集上各算法的结果对比

Table 2 Comparison of the results of each algorithm on the LOL dataset

算法	指标			
	$F_{\text{PSNR}} \uparrow$	$F_{\text{SSIM}} \uparrow$	$F_{\text{NIQE}} \downarrow$	$F_{\text{BRISQUE}} \downarrow$
LIME	15.969 8	0.420 1	8.478 6	40.140 0
MF	14.957 8	0.443 0	9.799 5	44.674 6
NPE	15.158 0	0.437 0	8.897 9	41.770 6
PLE	10.412 7	0.387 0	8.294 0	26.802 8
SRIE	12.495 1	0.421 2	7.851 6	27.763 2
Zero-Dce	17.496 6	0.534 4	8.185 6	32.646 7
Retinex-Net	16.495 3	0.514 4	7.609 8	42.047 8
KIND	15.764 6	0.688 8	4.830 6	19.250 2
KIND++	16.346 2	0.717 2	5.102 0	28.936 4
R2Rnet	18.730 1	0.767 8	4.667 9	13.598 7
URetinex-Net	18.784 5	0.786 0	4.143 7	14.884 0
DEANet	19.322 3	0.787 4	4.732 8	14.573 2
Ret-KIND	19.883 9	0.795 7	4.555 8	13.113 3

表 3 是 Ret-KIND 及各种对比方法在 PASCAL-VOC 图像数据集成的大量低光图像上, 选取不含噪声及含 4 级高斯噪声的图片进行综合性评估的 F_{PSNR} 、 F_{SSIM} 、 F_{NIQE} 和 F_{BRISQUE} 对比结果。由表 3 可知, 在不含噪声的图片上, Ret-KIND 算法在 F_{PSNR} 、 F_{SSIM} 、 F_{NIQE} 和 F_{BRISQUE} 均取得了最优值, 且与 R2Rnet 相比 F_{PSNR} 、 F_{SSIM} 分别提高了 10.68% 和 3.41%。在 4 级高斯噪声的图片上, 相较其他算法, Ret-KIND 算法对噪声的抑制有一定的效果, 且与 URetinex-Net 相比 F_{PSNR} 、 F_{SSIM} 分别

提高了 9.73% 和 3.67%, 与 DEANet 相比 F_{PSNR} 、 F_{SSIM} 分别提高了 8.63% 和 4.30%。这些都表明 Ret-KIND 模型在合成低光图像上的性能达到了 SOTA。

表 4 和表 5 分别是 Ret-KIND 及各种对比方法在 4 个数据集, DICM、Fusion、LIME、VV 上进行综合性评估的 F_{NIQE} 和 F_{BRISQUE} 对比结果。由表 4 可知, 在 DICM 和

LIME 数据集上, Ret-KIND 算法取得了最优值, 而在 Fusion 数据集上, LIME、MF、Zero-DCE 算法所取得的数值略低于 Ret-KIND 算法得到的数值。由表 5 可知, 在 Fusion、LIME 和 VV 数据集上, Ret-KIND 算法均取得了最优值, 但在 DICM 数据集上, 所取得的数值略高于在 MF、PLE、SRIE 算法上得到的数值。

表 3 合成低光图像上各算法的结果对比

Table 3 Comparison of the results of each algorithm on the synthetic low-light images

算 法	指标 噪声	$F_{\text{PSNR}} \uparrow$		$F_{\text{SSIM}} \uparrow$		$F_{\text{NIQE}} \downarrow$		$F_{\text{BRISQUE}} \downarrow$	
		有噪	无噪	有噪	无噪	有噪	无噪	有噪	无噪
LIME		16.762 4	16.374 3	0.461 2	0.451 6	7.374 3	7.813 4	38.431 1	39.761 2
MF		15.752 1	15.414 4	0.483 4	0.472 9	9.214 3	9.475 6	42.890 2	43.674 3
NPE		16.158 4	16.034 1	0.496 1	0.483 2	8.131 7	8.374 8	40.373 4	41.275 9
PLE		12.371 4	12.165 7	0.421 3	0.416 2	7.998 6	8.131 6	24.994 3	25.464 3
SRIE		14.374 3	14.214 8	0.459 8	0.443 1	7.478 2	7.674 3	26.672 3	27.214 1
Zero-Dce		18.131 2	17.998 7	0.675 6	0.663 7	7.868 5	7.998 6	30.978 8	31.675 8
Retinex-Net		17.672 4	17.415 4	0.653 1	0.645 9	7.219 7	7.614 3	39.762 4	40.967 7
KIND		17.104 3	16.894 7	0.693 4	0.687 3	4.534 2	4.678 8	17.947 8	18.795 5
KIND++		18.226 4	18.096 8	0.721 4	0.710 6	4.979 7	5.034 2	27.535 0	28.356 4
R2Rnet		19.567 2	19.352 6	0.774 8	0.763 5	4.361 2	4.467 6	13.014 2	13.451 8
URetinex-Net		19.872 1	19.638 9	0.791 3	0.770 4	4.343 2	4.395 6	13.772 1	13.998 3
DEANet		20.042 3	19.874 3	0.788 6	0.765 7	4.472 4	5.042 4	13.251 4	13.774 7
Ret-KIND		21.658 3	21.594 7	0.801 2	0.798 6	4.016 7	4.087 4	12.764 7	12.942 7

表 4 不同数据集上的 F_{NIQE} 对比

Table 4 Comparison of F_{NIQE} on different datasets

算 法	数据集			
	DICM	Fusion	LIME	VV
LIME	3.523 4	3.702 7	3.915 9	3.357 5
MF	3.343 3	3.773 3	3.933 2	3.259 3
NPE	3.276 7	3.968 4	3.914 2	3.592 2
PLE	3.655 9	4.077 0	3.951 2	3.503 0
SRIE	3.340 0	3.967 6	3.958 8	3.656 5
Zero-Dce	3.657 6	3.733 0	4.268 0	3.207 0
Retinex-Net	4.102 7	4.606 1	4.908 1	3.985 7
KIND	3.777 2	4.233 4	4.668 2	3.642 4
KIND++	4.374 6	4.540 4	5.609 6	3.793 2
R2Rnet	5.045 3	5.143 0	5.331 8	4.284 3
URetinex-Net	3.915 6	4.392 7	4.626 4	3.451 0
DEANet	3.874 4	4.123 1	4.231 2	3.773 2
Ret-KIND	3.315 8	3.815 9	3.840 7	3.243 8

表 5 不同数据集上的 F_{BRISQUE} 对比

Table 5 Comparison of F_{BRISQUE} on different datasets

算 法	数据集			
	DICM	Fusion	LIME	VV
LIME	28.201 6	26.643 6	26.170 4	32.908 0
MF	22.191 2	24.001 3	24.712 5	25.354 6
NPE	23.513 5	24.097 5	23.837 2	26.825 7
PLE	22.281 8	28.234 5	25.967 8	23.481 4
SRIE	22.225 7	25.769 3	24.567 3	24.995 0
Zero-Dce	24.237 2	29.108 1	26.374 4	30.018 3
Retinex-Net	26.988 7	23.411 4	33.614 8	30.456 4
KIND	24.297 3	23.512 3	29.350 0	23.888 4
KIND++	29.443 6	33.324 5	35.610 5	27.780 6
R2Rnet	22.941 7	25.624 8	23.364 0	22.610 7
URetinex-Net	23.142 4	26.627 6	26.394 1	24.708 0
DEANet	24.143 5	23.675 8	25.536 4	27.475 8
Ret-KIND	22.831 5	21.336 7	19.694 7	21.066 1




图 9 LOL 数据集上各算法的视觉效果图

Fig. 9 Visual effects of each algorithm on the LOL dataset




图 10 合成低光图像增强(不含噪声)

Fig. 10 Enhancement of synthetic low-light images (without noise)




图 11 合成低光图像增强(含噪)

Fig. 11 Enhancement of synthetic low-light images (with noise)




图 12 DICM 数据集上各算法的视觉效果图

Fig. 12 Visual effects of each algorithm on the DICM dataset

图9是在LOL数据集上随机选中一幅图像进行低光增强的效果图及其局部放大图像,可见,LIME、NPE、Zero-Dce、Retinex-Net、KIND++的增强结果中存在非常明显的噪声,MF、PLE、SRIE和KIND的增强结果偏暗,R2RNet的增强结果偏白,对比度较低,URetinex-Net增强后的效果图不仅噪声大,还整体偏白。Ret-KIND与其他算法相比,增强后的图片更贴近自然光照下采集的图片,不仅很好地还原了图片的色彩,丰富了图像的细节信息,还有效地减少了噪声。

图10是在PASCAL-VOC数据集合成的不含噪声的低光数据集上随机选中一幅图像进行低光增强的效果图及其局部放大图像,可以看出Ret-KIND模型与其他方法相比色彩更接近自然光下采集的图片,而且从放大的图像中可以清晰地看到长颈鹿的眼睛和斑纹,进一步还原了图像的细节特征。

图11是在PASCAL-VOC数据集合成的含噪(噪声级别为4的高斯噪声)低光数据集上随机选中一幅图像进行低光增强的效果图及其局部放大图像,可见,SRIE、PLE、KIND和KIND++的增强效果图偏暗,Zero-Dce的增强效果图过度曝光,R2RNet、URetinex-Net的增强效果图偏白,存在大量噪声,DEANet的增强效果图对比度较低,而在Ret-KIND增强后的效果图中,小船和玫瑰花清晰可见,但增强后的效果图仍存在少量噪声,有待进一步改进。

图12是在DICM数据集上随机选中一幅图像进行低光增强的效果图及其局部放大图像,可见,KIND和KIND++的增强效果偏暗,存在大量噪声,R2RNet、URetinex-Net的增强效果图过度偏白,对比度极差,而在Ret-KIND增强后的效果图中,男孩衣服上的字母清晰可见,身后的大树更贴合自然光下采集的图片,色彩均匀,亮度适中。

综上,虽然Ret-KIND算法没有在所有的数据集上取得最优值,但相对其他算法, F_{PSNR} 和 F_{SSIM} 有了较大幅度的提升,增强后的效果图的噪声大大减少,暗部细节得到了明显的改善,但Ret-KIND较KIND,参数量偏大,后续将继续优化,致力于在提升增强后图片质量的同时,实现模型的轻量化。

4 结论

低光图像严重影响了人们的日常生活,文中提出的Ret-KIND算法有助于提升图片质量,增强后的效果图更贴近自然光照下采集的图片。Ret-KIND的分解

网络中融入残差块和跳跃连接后,分解过程中产生的噪声大大减少,在光照调整网络中加入UC模块,不仅能深度提取光照细节信息,还有助于增强光照分量的对比度,降噪网络中引入的空洞卷积和EBAM注意力机制,能促进网络对反射分量中有效信息的提取,降低噪声。Ret-KIND在LOL数据集上, F_{PSNR} 和 F_{SSIM} 达到了19.883 9、0.795 7,相较KIND,分别提升了26.13%和15.52%。无论是在降低图像噪声,还是提高图像的对比度上,都能取得令人满意的结果,有助于推动低光图像增强模型应用到目标检测领域。

参考文献(References):

- [1] 董丽丽,丁畅,许文海.基于直方图均衡化图像增强的两种改进方法[J].电子学报,2018,46(10):2367—2375.
DONG Li-li, DING Chang, XU Wen-hai. Two improved methods based on histogram equalization for image enhancement[J]. Acta Electronica Sinica, 2018, 46(10): 2367—2375.
- [2] FAN X, WANG J, WANG H, et al. Contrast-controllable image enhancement based on limited histogram[J]. Electronics, 2022, 11(22): 3822.
- [3] HONG N M, CHI THANH N. A single image dehazing method based on adaptive gamma correction[C]//Proceedings of the 6th NAFOSTED Conference on Information and Computer Science. Piscataway: IEEE Press, 2019: 558—562.
- [4] PARK S, YU S, KIM M, et al. Dual autoencoder network for Retinex-based low-light image enhancement [J]. IEEE Access, 2018, 6: 22084—22093.
- [5] KANSAL I, KASANA S S. Fusion-based image de-fogging using dual tree complex wavelet transform[J]. International Journal of Wavelets, Multiresolution and Information Processing, 2018, 16(6): 1850054.
- [6] GAO Z, ZHAI Y. Image dehazing based on multi-scale Retinex and guided filtering[C]//Proceedings of the International Conference on Image Processing, Computer Vision and Machine Learning. Piscataway: IEEE Press, 2022: 123—126.
- [7] 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.
- [8] LV F, LU F, WU J. MBLEN: low-light image video enhancement using CNNs[C]//Proceedings of the 2018 British Machine Vision Conference. Newcastle: BMVA Press, 2018: 1—15.
- [9] WEI C, WANG W J, YANG W H, et al. Deep Retinex

- decomposition for low-light enhancement[C]//Proceedings of the 2018 British Machine Vision Conference. Newcastle: BMVA Press, 2018: 1—15.
- [10] GUO C, LI C, GUO J, et al. Zero-reference deep curve estimation for low-light image enhancement[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 1777—1786.
- [11] ZHANG Y, ZHANG J, GUO X. Kindling the darkness: a practical low-light image enhancer [C]//Proceedings of the Proceedings of the 27th ACM International Conference on Multimedia. New York: ACM, 2019: 1632—1640.
- [12] ZHANG Y, GUO X, MA J, et al. Beyond brightening low-light images [J]. International Journal of Computer Vision, 2021, 129(4): 1013—1037.
- [13] HAI J, XUAN Z, HAN S, et al. R2RNet: Low-light image enhancement via real-low to real-normal network [EB/OL]. 2021: 2106. <http://arxiv.org/abs/2106.14501v2>.
- [14] WU W, WENG J, ZHANG P, et al. URetinex-net: Retinex-based deep unfolding network for low-light image enhancement [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2022: 5891—5900.
- [15] ZHANG S, LAM E Y. A deep Retinex framework for light field restoration under low-light conditions [C]//Proceedings of the 26th International Conference on Pattern Recognition. Piscataway: IEEE Press, 2022: 2042—2048.
- [16] SUN Q. RADFNet: A low illumination image enhancement network based on Retinex model and attention mechanism [C]//Proceedings of the 4th International Conference on Frontiers Technology of Information and Computer. Piscataway: IEEE Press, 2022: 123—127.
- [17] JIANG Y, LI L, ZHU J, et al. DEANet: decomposition enhancement and adjustment network for low-light image enhancement[J]. Tsinghua Science and Technology, 2023, 28(4): 743—753.
- [18] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 2261—2269.
- [19] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 234—241.
- [20] 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: A Publication of the IEEE Signal Processing Society, 2017, 26(7): 3142—3155.
- [21] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[M]. Cham: Springer International Publishing, 2018: 3—19.
- [22] HUYNH-THU Q, GHANBARI M. Scope of validity of PSNR in image/video quality assessment [J]. Electronics Letters, 2008, 44(13): 800—801.
- [23] 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: A Publication of the IEEE Signal Processing Society, 2004, 13(4): 600—612.
- [24] MITTAL A, SOUNDARARAJAN R, BOVIK A C. Making a “completely blind” image quality analyzer [J]. IEEE Signal Processing Letters, 2013, 20(3): 209—212.
- [25] MITTAL A, MOORTHY A K, BOVIK A C. No-reference image quality assessment in the spatial domain[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2012, 21(12): 4695—4708.
- [26] GUO X, LI Y, LING H. LIME: low-light image enhancement via illumination map estimation [J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2017, 26(2): 982—993.
- [27] FU X, ZENG D, HUANG Y, et al. A fusion-based enhancing method for weakly illuminated images[J]. Signal Processing, 2016, 129: 82—96.
- [28] WANG S, ZHENG J, HU H M, et al. Naturalness preserved enhancement algorithm for non-uniform illumination images[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2013, 22(9): 3538—3548.
- [29] FU X, LIAO Y, ZENG D, et al. A probabilistic method for image enhancement with simultaneous illumination and reflectance estimation[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2015, 24(12): 4965—4977.
- [30] FU X, ZENG D, HUANG Y, et al. A weighted variational model for simultaneous reflectance and illumination estimation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 2782—2790.

责任编辑:陈 芳