

基于渐进式双网络模型的低曝光图像增强方法

黄淑英¹⁾ 胡 威²⁾ 杨 勇²⁾ 李红霞³⁾ 汪 斌³⁾

¹⁾ (天津工业大学计算机科学与技术学院 天津 300387)

²⁾ (江西财经大学信息管理学院 南昌 330032)

³⁾ (江西财经大学软件与物联网工程学院 南昌 330032)

摘 要 传统的图像增强方法对低曝光图像进行增强时,通常只考虑到了亮度的提升,忽略了增强过程中带来的噪声放大问题.而当前基于深度学习的方法利用端到端的网络直接学习低曝光图像到正常图像的映射关系,忽略了低曝光图像形成的物理原理,也没有考虑解决噪声放大的问题.针对上述问题,本文通过对图像降质的本质原因进行分析,提出一种基于渐进式双网络模型的低曝光图像增强方法,该方法包含图像增强模块以及图像去噪模块两个部分.对每个模块的构建也采用了渐进式的思想,考虑了图像由暗到亮的亮度变化,以及从粗到细的图像恢复过程,使增强后的结果更接近真实图像.为了更好地训练网络,本文构建了一种双向约束损失函数,从图像降质模型的正反两个方向使网络学习结果逼近真实数据,达到动态平衡.为了验证本文方法的有效性,本文与一些主流的方法从主观和客观两方面进行了实验对比,实验结果证明了本文方法得到的结果更接近真实图像,获得了更优的性能指标.

关键词 低曝光图像增强;渐进式;双网络;双向约束损失函数

中图法分类号 TP391 **DOI号** 10.11897/SR.J.1016.2021.00384

A Low-Exposure Image Enhancement Based on Progressive Dual Network Model

HUANG Shu-Ying¹⁾ HU Wei²⁾ YANG Yong²⁾ LI Hong-Xia³⁾ WANG Bin³⁾

¹⁾ (School of Computer Science and Technology, Tiangong University, Tianjin 300387)

²⁾ (School of Information Management, Jiangxi University of Finance and Economics, Nanchang 330032)

³⁾ (School of Software and Internet of Things Engineering, Jiangxi University of Finance and Economics, Nanchang 330032)

Abstract When the traditional image enhancement methods enhanced the low-exposure image, they usually just considered the enhancement of brightness and ignored the problem of noise amplification. Besides, the current deep learning methods used the end-to-end network to directly learn the mapping relationship between the low-exposure image and the normal image, ignoring the physical principle of the formation of the low-exposure image, and did not consider solving the problem of noise amplification. In order to solve these problems, this paper presents a low-exposure image enhancement method based on progressive dual network model by analyzing the essential causes of image degradation. The proposed method includes two parts: image enhancement module and image denoising module. The construction of each module also adopts the progressive idea by considering the image brightness change from dark to light and the image restoration from coarse to fine, so that the enhanced result is closer to the real image. Furthermore, to train the network better, a bidirectional constraint loss function is designed, which makes the learning result of network approach the real data from positive and negative directions of the

收稿日期: 2019-11-27; 在线发布日期: 2020-05-18. 本课题得到国家自然科学基金(61862030, 61662026)、江西省自然科学基金(20182BCB22006, 20181BAB202010, 20192ACB20002, 20192ACBL21008)资助. 黄淑英, 博士, 副教授, 主要研究方向为图像处理与机器学习. E-mail: shuyinghuang2010@126.com. 胡 威, 硕士研究生, 主要研究方向为图像去雾与图像复原. 杨 勇(通信作者), 博士, 教授, 中国计算机学会(CCF)高级会员, 主要研究领域为图像处理与机器学习. E-mail: greatyangy@126.com. 李红霞, 硕士研究生, 主要研究方向为深度学习与图像复原. 汪 斌, 硕士研究生, 主要研究方向为深度学习与图像复原.

image degradation model, and finally achieves dynamic balance. Experimental results show that the proposed method is more effective than some state-of-the-art enhancement methods from both subjective and objective evaluations.

Keywords low-exposure image enhancement; progressive; dual network; bidirectional constraint loss function

1 引言

在夜间等照明不良的情况下获取到的图像因为曝光不足,往往导致图像存在可见度低、细节不可见、噪声干扰大、光照不均匀等问题^[1].低照度的图像不仅在视觉上给观察者带来较差的感受,而且会严重影响基于图像信息的计算机视觉系统的正常工作.随着各种工业相机设备技术的发展,其分辨率、曝光时间等性能都有了较大的改善,但是利用硬件提高分辨率的方法成本高,泛化能力差,很难做到普及.因此,许多研究者开始运用图像增强的技术,对图像进行后续处理,提高图像的质量.图 1 为图像增强示例,其中第一行为低曝光的图像,第二行为采用本文方法进行亮度增强后的图像.从结果可以看出,图像增强算法使低曝光图像在亮度、细节等方面都得到了很大的提升,因此,低曝光图像增强技术在目标检测、智能驾驶、交通监控、遥感图像等领域具有十分重要的价值.



图 1 低曝光图像(第一行)和本文方法增强后的图像(第二行)示意图

在过去的几十年间,图像增强技术发展迅速,很多方法相继被提出用以解决低曝光图像增强的问题.目前,针对图像增强的方法主要分为三种,分别是基于直方图均衡化的增强方法^[2-5]、基于 Retinex 理论的增强方法^[6-9]以及近年来兴起的基于深度学习的增强方法^[10-13].

基于直方图均衡化的增强方法主要思想是将图像直方图统计的像素动态范围进行拉伸,通过增加

图像的对比度来达到提升视觉效果的目的.这类增强算法主要包含基于局部和基于全局的直方图均衡化.该类方法在处理前景和背景都过暗的图像时能取得较好的效果,同时由于计算量小,该类方法在处理时间上也具有优势,但其往往因为对某些区域增强过度而会出现细节丢失和偏色等问题.针对直方图均衡化增强方法存在的问题,一些改进算法又相继被提出来.Li 等人^[2]提出了一种用于对低曝光图像进行对比度增强和去噪的新型图像增强框架.该框架利用基于超像素的局部自适应方法进行去噪,在保持纹理细节的同时也可消除噪声,同时采用基于暗通道先验去雾方法的亮度信息自适应增强参数,克服了图像过增强或欠增强的问题.Lin 等人^[3]提出了一种包括颜色通道拉伸、直方图平均和重映射的流水线方法,能够取得较好的结果.Sujee 等人^[4]利用金字塔层直方图匹配的方法来增强图像对比度,从而最大限度地提取图像的信息.基于直方图均衡化的增强算法虽然在时间上具有较大优势,但由于在亮度增强的过程中考虑的是图像整体的统计特性,因此在处理复杂场景图像时并不能取得很好的效果.

Retinex 理论是由 Land^[14]在 20 世纪 60 年代首次提出.该理论的主要思想是人眼所感知到的物体的颜色和亮度由物体表面的反射特性和入射特性(或光照特性)共同作用决定.其数学模型可表示为

$$S = R \circ L \tag{1}$$

在低曝光图像形成过程中, S 代表获取到的低曝光图像, R 是正常曝光图像, L 是照度图像,符号“ $\circ$ ”代表逐元素点乘.基于 Retinex 理论的图像亮度增强算法的核心思想是首先估计照度图像 L ,然后从低曝光图像 S 中去除 L 分量,得到正常曝光的图像 R ,其数学表达式为

$$R = S \circ L^{-1} \tag{2}$$

继 Land 提出关于人类视觉系统的 Retinex 理论后,基于 Retinex 理论的图像增强方法被广泛研究.基于单尺度 Retinex 理论^[6],Jobson 等人^[15]提

出了一种多尺度的 Retinex 颜色恢复算法,在进行图像增强的同时保持颜色的一致性. Fu 等人^[16]结合 Retinex 理论提出了一种基于融合的低曝光图像增强方法,既保护了细节又提升了对比度. 受人类视觉系统的启发, Ying 等人^[17]设计了一种用于图像增强的多曝光融合框架,来提供准确的对比度和亮度增强. Guo 等人^[18]提出了结构感知先验细化照度图,并分别在红、绿、蓝三个通道上计算以增强图像. 尽管这些方法在某些情况下能取得较好的结果,但它们在对 Retinex 模型中的反射率和光照分解时仍然存在局限性,因为设计一种适用于各种场景的图像分解约束是图像增强中的主要难点. 此外,由于求解反射率图是一个病态问题,粗略的估计值容易导致图像增强的结果出现过曝光或欠曝光现象.

随着人工智能的发展及神经网络在图像处理领域的优异表现,基于深度学习的方法在图像增强领域得到了迅速发展. Lore 等人^[10]提出了一种基于深度自编码的方法对低曝光图像进行增强和去噪,既提高了图像的亮度,又避免了图像过曝光的情况. Chen 等人^[19]创建了一个根据相机曝光时间而产生的低曝光图像数据集,并设计了一种全卷积的端到端网络来实现图像的增强. Wei 等人^[20]将人类视觉理论和卷积神经网络结合,把低曝光图像分解为反射率图和光照图,并利用增强网络实现图像亮度的增强. Jiang 等人^[21]首次提出利用非配对的低/正常亮度的图像来训练图像亮度增强网络,这种训练策略消除了对成对训练数据的依赖. Wang 等人^[22]没

有直接学习低亮度图像和正常亮度图像之间的映射,而是估计图像到光照图之间的映射来增强曝光不足的图像,该方法增强了网络学习对复杂图像的调整能力. 虽然上述方法都能获得较好的效果,但是这些基于深度学习的方法都是端到端的直接学习低曝光图像到正常图像的映射关系,忽略了低曝光图像形成的物理原理,同时没有显式地包含去噪过程或仅仅依赖于传统的去噪方法,因而在图像增强后存在细节丢失和噪声放大等问题.

基于上述分析,本文针对现有低曝光图像增强方法存在的局限性,提出一种基于 Retinex 理论的渐进式双网络低曝光图像增强模型(如图 2). 该网络以低曝光图像作为输入,利用不同尺度的卷积核进行特征提取,最终学习到 Retinex 模型中的照度图,接着将该照度图代入 Retinex 模型中计算得到亮度增强后的图像. 然后针对增强过程中出现的噪声放大问题,将增强后的图像再经过一个图像去噪网络,得到最终的增强结果. 论文的创新工作如下:

- (1) 提出一种渐进式的双网络低曝光图像增强模型. 整个模型针对低曝光图像增强中的低亮度和噪声放大问题,利用渐进式的思想设计了图像增强模块和图像去噪模块.
- (2) 在图像增强模型的两个模块内部,分别采用渐进式的思想构建其网络框架,对图像实现从粗到细的修复过程,以取得更好的增强结果.
- (3) 考虑到图像降质理论的可逆性,提出了一




图 2 渐进式双网络低曝光图像增强模型

种双向约束损失函数用于网络学习,从图像降质模型的正反两个方向进行损失计算,使学习到的信息更完整。

本文第2节重点介绍本文所提出的方法;第3节将实验方法与对比实验进行详细说明;第4节总结全文工作及对未来研究展望。

2 渐进式图像增强方法

2.1 网络框架

针对现有的方法在图像增强后存在细节丢失和噪声放大的问题,本文提出一种渐进式的双网络低曝光图像增强模型,该模型包括图像亮度增强模块和图像去噪模块两个子网络,构建的整体框架如图2所示。我们将网络设计与图像增强的物理模型相结合,首先采用渐进式的思想对低曝光图像实现亮度的增强,然后针对增强后图像出现的噪声被加强的问题,对亮度增强结果加入图像去噪过程。值得一提的是,为了取得更好的图像增强结果,本文在图像增强和图像去噪两个模块内部都引入了渐进式的思想,实现从粗到细的亮度增强和噪声的去除。图像去噪模块和增强模块不同的是,图像噪声通常被认为是一种加性噪声,因此在图像去噪模块的最后采用了减法操作,通过将输入图像直接减去学习到的噪声得到最终的输出结果。为了更好地训练网络,本文根据图像降质理论的可逆性,构建了一种正反双向约束的损失函数来训练网络,其具体内容将在2.2节进行详细介绍。

2.1.1 图像亮度增强模块

考虑到真实场景下亮度提升是一个由暗到亮的过程,本文提出一种渐进式的图像增强模块,对低曝光图像先后两次从粗到细地实现图像的亮度和色彩的提升,来完成图像亮度增强的过程。该网络模块的实现过程如下描述。

如图2的图像增强模块(上端虚线框)所示,该模块的输入为低曝光图像,模块中的两个子框架输出均为照度图 L ,输入输出均为红、绿、蓝三个通道。该模块包含亮度初步重建和亮度加强两步,第一步的框架中包含六个卷积层,网络前两层利用卷积操作实现特征图的下采样,该操作既可以保证下采样的效果,同时也避免了下采样造成的信息丢失。通过下采样减小特征图的尺寸,可以扩大卷积核的感受野,使原本只能学习到 3×3 范围信息的卷积核在两

次尺寸下降后可以学习到 7×7 范围的信息。此外,为了保证最后得到的照度图与输入图像的尺寸一样,在网络中使用了2次反卷积操作,来实现尺寸增大的目的,同时也方便梯度下降的计算。第二步的亮度加强的网络框架与第一步类似,这一步的目的是精细化增强后的图像。该部分网络中只设置了四个卷积层,通过以较少的网络训练参数,来提高网络性能。本文在3.3节也给出了实验,证明了使用四个卷积层比直接使用六个卷积层得到了更好的结果。该模块为了保证网络的有效性更好地利用原图信息,首先将初步增强的结果与原图采用一次拼接操作,然后再采用两次卷积和反卷积操作,实现图像进一步增强。在这些卷积层中,每层都包含权重和偏差两类参数,其计算方式如下式:

$$F(x) = \omega * x + b \quad (3)$$

式中, F 是卷积之后得到的特征图, ω 、 b 分别是权重和偏差, x 是输入,符号“ $*$ ”代表卷积计算。

在整个框架中,每个卷积层的后面都有一层激活函数 ReLU,其定义如下:

$$R(x) = \max(0, F(x)) \quad (4)$$

其中, $F(x)$ 为卷积得到的结果, $R(x)$ 是 ReLU 函数得到的结果。ReLU 激活函数的目的是将有效信息保存的同时去除无效信息,从而加快训练速度。

2.1.2 图像去噪模块

低曝光图像在成像过程中除了光照不足以外,还会受多种噪声影响。在低亮度情况下由于图像的对比度比较低,噪声难以被发现。但经过对低曝光图像增强后,噪声同样也会出现被增强的问题。因此,为了去除噪声,本文在图像增强模块之后增加了一个噪声去除模块。

如图2的图像去噪模块(下端虚线框)所示,该模块的网络设计思想与增强模块类似,采用渐进式的思想先后两次从粗到细来学习噪声图像,实现对亮度重建图像的噪声去除。在模块内部通过对多个尺寸的特征图卷积的方式来扩大感受视野,学习更丰富的特征。该网络模块的目的是学习图像中存在的噪声成分,而通常图像中噪声被认为是一种加性噪声,因此在两个子块后端采用了减法操作,将增强后的图像与网络学习到的噪声成分相减,得到去噪后的图像。由于该网络模块学习噪声成分并不需要考虑图像特征信息复用的问题,因此在去噪网络模块中并没有采用类似于增强模块中的拼接操作。

2.2 损失函数

网络模型的执行功能主要取决于损失函数的定义. 在图像复原的网络模型学习中, 通常使用均方误差 MSE (Mean Squared Error) 或平均绝对误差 MAE (Mean Absolute Error) 之类的误差指标来定义损失函数. 但是, 由于低曝光图像亮度较低, 仅使用诸如 MSE 或 MAE 之类误差指标可能导致结构失真, 例如模糊效应或伪影. 所以为了提高视觉质量, 本文设计由结构损失和双向约束损失构建新损失函数来训练网络. 其中, 图像亮度增强模块的损失函数定义如下:

$$L_E = L_S + L_f \quad (5)$$

式中, L_S 为结构相似度损失函数, L_f 为双向约束损失函数.

图像去噪模块的损失函数定义为

$$L_N = L_{sp} + L_{sn} \quad (6)$$

其中, L_{sp} 是正向结构损失函数, L_{sn} 是反向结构损失函数. 双向约束损失函数是从图像降质模型正反两个方向, 通过分别向真实数据逼近来定义的. 结构相似度损失函数是用来保证图像结构信息的完整性, 具体定义将在下面给出.

2.2.1 结构相似度损失函数

在获取全局信息的同时, 网络还通过对多个尺寸的特征图卷积来学习结构细节信息, 因此我们用多尺度结构相似性 $MSSSIM$ (MultiScale Structural Similarity)^[23] 质量评价方法作为损失函数, 以保持图像结构, 避免模糊. 其获取方式为

$$MS(a_1, a_2) = l(a_1, a_2)_m^{\alpha m} \prod_i^m c(a_1, a_2)_i^{\beta i} s(a_1, a_2)_i^{\gamma i} \quad (7)$$

其中, a_1, a_2 为对应的图像输入, $l(a_1, a_2)$ 为亮度信息, c 为对比度信息, s 为结构相似性, i 为像素坐标, m 为像素总数, α, β, γ 为调整重要性的参数, MS 的值越大, 则结构信息越完整, 结构相似度损失函数定义为

$$L_{MS}(a_1, a_2) = 1 - MS(a_1, a_2) \quad (8)$$

因此, 基于上述式(8), 图像亮度增强模块的结构相似度损失函数 L_S 可以定义为

$$L_S = L_{MS}(y_i, f(S)) \quad (9)$$

其中, y 代表真实正常曝光图像, S 为低曝光图像, $f(S)$ 为网络输出结果.

2.2.2 双向约束损失函数

增强模块学习的目的是得到精确的照度图 $L = f(S)$, 再根据成像模型(2)计算得到增强后的图像 $R = S * f(S)^{-1}$. 传统的深度学习定义损失函数的方

法, 主要是通过将网络输出与真实数据之间的差异最小化来训练网络, 这样可以让输出结果向真实数据快速接近. 因此, 本文也将考虑利用将图像增强结果与正常曝光图像之间差的绝对值最小化来训练增强网络模块, 其计算方法为

$$L_p = \sum_i^n |y_i - (S * f^{-1}(S))_i| \quad (10)$$

其中, n 指的是样本的数量, i 指的是第 i 个样本.

根据式(1), 我们也可以通过反推的方法来验证增强网络输出的照度图 $f(S)$ 的精确性, 即将 $f(S)$ 代入到式(1)中, 用真实的图像与 $f^{-1}(S)$ 相乘, 得到的降质图像与网络输入的低曝光图像进行比较, 如果越接近网络的输入图像 S , 则说明网络模型输出结果越精确. 基于该思想, 本文将反推过程引入到网络训练中, 我们将上述式(10)定义为正向推进损失, 将反推过程定义为反向推进损失, 使网络不仅能正向逼近真实结果, 还能反向逼近输入, 达到动态平衡, 提高网络准确率. 基于上述分析, 本论文提出一种双向约束的损失函数, 其定义如下:

$$L_f = L_p + L_n \quad (11)$$

其中,

$$L_n = \sum_i^n |S_i - (y * f(S))_i| \quad (12)$$

表示反向推进损失.

双向约束损失的思想不仅在图像增强模块中有效, 在去噪模块中也能起到同样的作用. 同样基于双向约束的思想, 本文定义正向与反向结构损失函数来训练图像的去噪模块, 其分别表示为

$$L_{sp} = L_{MS}(y, y_n - f(y_n)) \quad (13)$$

$$L_{sn} = L_{MS}(y_n, y + f(y_n)) \quad (14)$$

其中, y_n 是加噪的数据集, $f(y_n)$ 为去噪网络学习得到的噪声.

2.3 网络训练

2.3.1 训练方法

由于增强模块和去噪模块是分开训练的, 所以在最小化损失函数的时候, 两个模块的损失函数也是不同的. 我们采用式(5)来训练图像增强模块, 用式(6)训练图像去噪模块, 优化方式为 Adam 梯度下降方法. 整个网络的训练过程如算法 1 所示.

算法 1. 网络训练过程.

输入: 单次训练样本数 n

输出: 照度图 $f(S)$, 去噪后图像

步骤:

for $num=1$; $num \leq iterations$ do

低曝光图像集 S ;

```
    输出增强图： $R \leftarrow f(S)$ ；
    梯度下降法更新图像增强损失函数；
end
for  $num=1$ ;  $num \leq iterations$  do
    加噪图像  $y_n$ ；
    输出去噪图： $R' \leftarrow f(y_n)$ ；
    梯度下降法更新图像去噪损失函数；
end
```

2.3.2 网络设置

整个网络共有 20 个卷积层,包含增强和去噪两个部分.其中每个模块有三个采用步长为 2 的卷积层以及 3 个反卷积层,在所有卷积层中,除了 3×3 大小卷积核以外,还采用了 1×1 大小的卷积核,来增强模型的非线性,减少参数量,提高计算速度.其具体参数设置如表 1 所示.

表 1 网络参数表

网络部分	卷积层	输出尺寸	卷积核数量	卷积核尺寸	步长
图像亮度增强模块	输入	$3 \times 384 \times 384$	—	—	—
	1	$32 \times 384 \times 384$	32	3×3	1
	2	$64 \times 192 \times 192$	64	3×3	2
	3	$128 \times 96 \times 96$	128	3×3	2
	4	$128 \times 96 \times 96$	128	1×1	1
	5	$64 \times 192 \times 192$	64	3×3	2
	6	$32 \times 384 \times 384$	32	3×3	2
	输出	$3 \times 384 \times 384$	3	3×3	1
图像去噪模块	输入	$3 \times 384 \times 384$	—	—	—
	1	$32 \times 384 \times 384$	32	3×3	1
	2	$64 \times 192 \times 192$	64	3×3	2
	3	$64 \times 192 \times 192$	64	1×1	1
	4	$32 \times 384 \times 384$	32	3×3	2
	输出	$3 \times 384 \times 384$	3	3×3	1

3 实验结果与分析

我们将在合成图像数据集和真实场景图像数据集上验证本文提出方法的有效性,并与其它六种图像增强方法进行比对,这六种方法分别是: BIMEF^[17]、Retinex-net^[20]、LIME^[18]、MSRCR^[15]、MF^[16]、DONG^[24].

此外,对低曝光图像只经过第一个亮度增强模块后的结果与对亮度增强后图像进行去噪的结果也分别进行了展示,来验证只对图像进行增强会产生噪声放大的问题,进一步说明了本论文提出的渐进式的双网络模型的有效性.相关的实验在 3.3 节进行了说明.

3.1 实验设置

用于图像增强模块训练的数据库包括两个,一是低曝光图像对数据库 (LOL)^[20],其中包含了 500 张低曝光图像和对应的正常曝光图像,每张图像的大小为 400×600 . LOL 的大部分图像都是在自然场景下通过调整曝光时间来获得的,场景包括房屋、郊区、街道等,本文方法将使用该数据库 485 个


图像对用于训练,余下 15 个图像对用于测试.

另一个数据库为合成数据库,该数据库从 RAISE^[25] 数据库挑选 1000 张原始图像,用 Adobe Lightroom 提供的接口,调整图像亮度通道 Y 的值,将这些图像合成低曝光图像,得到 1000 对相应图像对.最后,将这些图像对调整为 400×600 大小.在对网络训练时,为了方便计算,所有输入都将调整为 384×384 大小.

对于去噪网络,由于现有带噪声的低曝光图像数据库缺乏,所以我们结合低曝光图像噪声的特征,在增强模块训练集的正常曝光图像上进行了泊松噪声添加的处理,以此作为去噪模块的训练数据,图 3 为部分原始数据及对应加噪数据展示.

在训练时,上述 LOL 数据库及合成数据库所有图像都会作为训练数据,出于方便计算,输入与输出的像素值都会经过归一化操作变换到 0 至 1 之间.为了避免在计算正常曝光图像时出现分母为零的现象,我们将照度图的值设定在 $0.0039(1/255)$ 到 1 之间.网络学习率设置为 0.00001.


所有实验都在 Windows 10 系统、PyTorch 框架以及英伟达 2080Ti GPU 上运行的.



低曝光数据集

正常曝光数据集

(a) 部分低曝光数据集及对应的正常曝光数据集



加噪数据集

无噪数据集

(b) 部分加噪数据集及对应的无噪清晰数据集,第二、四列为局部放大示例

图 3 数据库实例

3.2 客观指标

为了证明本文方法的性能优势,我们采用峰值信噪比(PSNR)、结构相似度(SSIM)^[26]以及色差值(CIEDE2000)^[27]三种指标来对各种方法进行客观评价。

PSNR 是一种全参的图像质量评价指标,计算每个像素点之间的差异,其计算方法为

$$P=10\log\left(\frac{I_{\max}^2}{MSE}\right) \quad (15)$$

其中, $I_{\max}$ 指的是图像中像素点的最大值,一般取 255, MSE 指的是均方误差, MSE 计算如下:

$$MSE=\frac{1}{HW}\sum_i^H\sum_j^W(X(i,j)-Y(i,j))^2 \quad (16)$$

其中, H 、 W 是图像长宽, X 、 Y 对应图像中的像素值, (i,j) 是图像中像素点的坐标。PSNR 的值越高,则图像质量越好。

SSIM 也是全参的图像质量评价指标,其值分布在 0 到 1 之间,值越大说明差异越小,则图像质量越好。其计算方法为

$$SS=l(a_1,a_2)\cdot c(a_1,a_2)\cdot s(a_1,a_2) \quad (17)$$

其中, l 、 c 、 s 分别表示两张图片的亮度、对比度、结构三方面的相似度。

CIEDE2000 能够测试增强图像与真实数据之间的色差。首先,将 RGB 图像转换到 Lab 颜色空间,参照 CIEDE2000 计算色差的方法得到两幅图像 y 和 L 对应的每个像素点之间的色差 ΔE ,并按如下定义计算两幅图像的色差:

$$C=\frac{1}{N}\sum_i^N\Delta E(y_i,L_i) \quad (18)$$

其中, N 是为像素数量, ΔE 表示 Lab 空间中两个图像之间的每个像素的色差, y 为网络输出图像, L 为真实数据,色差值越低,表示颜色越接近真实图像。

3.3 实验结果

在这一部分,我们将展示本文方法对 LOL 数据集以及合成数据库中部分图像进行增强的最终结果。主观效果好坏是人眼最直接的感受,如图 4 所示,为本文方法与其它六种方法在不同场景下得到的结果。从图中可以看出, BIMEF 得到了较为清晰的细节,并且控制了噪声的扩张,但是其结果整体亮度偏低。DONG 在亮度增强方面比较有效,但其在图像增强后出现了噪声放大的问题,如在第二列和第三列中的图像,白色框中的平滑区域,可以看出噪声放大非常严重;同样,在第五列的图像中也出现了偏色问题。LIME 和 MSRCR 方法在得到丰富细节的同时,产生了过曝的现象,并且也出现了噪声放大的问题,如白色框中区域可以观察到明显的过曝光情况,所有图像的亮度都高于真实图像,同样在第五列中可以看到较严重的偏色问题。MF 实现了较为自然的结果,但也伴随了轻微的噪声与偏色效果;Retinex-Net 出现了较严重的色彩失真和噪声放大问题,如平滑区域可以观察到较严重的噪声存在,在白色框区域也可以看到明显的色彩失真。与这些方法相比,我们的方法既实现了亮度增强,图像的色彩更自然,也没有产生多余的噪声,其结果也最接近真实图像。




图 4 图像增强结果

除了主观效果以外,本文也利用了 3.2 节中介绍的客观指标来对各方法进行了比较.图 5 给出了本文方法与其它六种方法对 15 幅图像进行增强得到的客观指标 $PSNR$, $SSIM$ 和 $CIEDE2000$ 的平

均值, Ours 柱状数据是本文方法的结果. 通过比较可以看出,本文方法的结果得到的 $PSNR$, $SSIM$ 及 $CIEDE2000$ 值与其它六种方法相比都是最优的,说明了本文方法的有效性.




图 5 本文方法与其它方法的 $PSNR$ 、 $SSIM$ 以及 $CIEDE2000$ 指标比较(其中, $PSNR$ 和 $SSIM$ 的值越大图像质量越好, $CIEDE2000$ 越小图像质量越好)

最后,为了验证本文方法所提出的渐进式双网络模型及双向约束损失函数的有效性,我们对本文构建的网络做了大量的实验进行对比.图 6 给出了双渐进网络框架的几种变形网络所得结果的客观指标 $PSNR$ 和 $SSIM$ 的变化趋势.其中,纵坐标为客观指标值,横坐标为网络训练的迭代次数.图中黑色粗线条显示的是本文渐进式双网络模型的结果值;黑色虚线条显示的是没有采用双向约束损失得到的结果值;黑色点划线条为本文方法基础上加深网络深度(精细部分采用 6 个卷积层结构)得到的结果值;黑色细线条是只有第一部分的增强模块得到的结果值.从图(a)和(b)中指标曲线的走势可以看出,只有第一部分增强模块得到的结果计算的 $PSNR$ 和 $SSIM$ 值都较低;其它三种网络结构包含去噪

模块的渐进式增强网络得到的增强结果的 $PSNR$ 和 $SSIM$ 值都有了明显的提高;但从黑色点划线条的走势来看,增加精细化部分网络的深度相比采用四个卷积层降低了客观指标值;从黑色虚线条和黑色粗线条的走势可以看出,采用本文提出的双向约束损失函数对网络的训练进一步提高了网络的精确性,得到了更高的指标.由此可以说明,本文提出的网络结构是有效的,具有较强鲁棒性.

4 总结与展望

本文提出了一种渐进式双网络结构的低曝光图像增强方法,针对低曝光图像的亮度降质和噪声降质的问题,采用渐进式的思想先对图像进行亮度和色彩的增强,然后再去除被放大的噪声.针对这两步操作,本文构建了两个渐进式的模块来拟合现实场景亮度由暗到亮的亮度变化,及从粗到细的图像恢复过程,使结果更自然.为了更好地训练网络,本文提出一种双向约束的损失函数,不仅能正向逼近真实结果,还能反向逼近输入,达到动态平衡,提高网络准确率.

为了验证所提出的方法的有效性,本文做了大量的实验,并与多个方法从主观和客观两方面进行比较,实验结果也验证了本文方法具有更优的性能.未来我们计划将视频监控应用与图像增强算法研究相结合,提高实时视频监控在夜间或者光照不足等情况下的监控能力.

参 考 文 献

[1] Rao Y, Chen L. A survey of video enhancement techniques. *Journal of Information Hiding and Multimedia Signal Processing*, 2012, 13(1): 71-99




图 6 对比实验结果(M 为本文方法,DM 为在本文方法基础上加深网络深度,M-L 为本文方法不使用双向约束损失函数,M-N 为本文方只含增强模块)

- [2] Li L, Wang L, Wang W, Gao W. A low-light image enhancement method for both denoising and contrast enlarging//Proceedings of the IEEE International Conference on Image Processing. Quebec City, Canada, 2015: 3730-3734
- [3] Lin S, Wong C, Rahman M, et al. Image enhancement using the averaging histogram equalization (AVHEQ) approach for contrast improvement and brightness preservation. Computers & Electrical Engineering, 2015, 46: 356-370
- [4] Sujee R, Padmavathi S. Image enhancement through pyramid histogram matching//Proceedings of the IEEE International Conference on Computer Communication and Informatics. Coimbatore, India, 2017: 1-5
- [5] Sun S Y, Wang L P, Zhang B M, Jing Z L. Low light level image enhancement based on dualistic sub-image and two dimensional histogram analysis. Journal of Infrared and Millimeter Waves, 2003, 22(3): 220-224
- [6] Jobson D J, Rahman Z U, Woodell G A. Properties and performance of a center/surround Retinex. IEEE Transactions on Image Processing, 1997, 6(3): 451-462
- [7] Zhang Qing, Yuan Gan-Zhao, Xiao Chun-Xia, et al. High-quality exposure correction of underexposed photos//Proceedings of the ACM Multimedia Conference on Multimedia Conference. Seoul, Korea, 2018: 582-590
- [8] Fu Xue-Yang, Liao Ying-Hao, Zeng De-Lu, et al. A probabilistic method for image enhancement with simultaneous illumination and reflectance estimation. IEEE Transactions on Image Processing, 2015, 24(12): 4965-4977
- [9] Li Ma-Ding, Liu Jia-Ying, Yang Wen-Han, Guo Zong-Ming. Joint denoising and enhancement for low-light images via Retinex model. International Forum on Digital TV and Wireless Multimedia Communications, 2017: 91-99
- [10] Lore K G, Akintayo A, Sarkar S. LLNet: A deep autoencoder approach to natural low-light image enhancement. Pattern Recognition, 2017, 61: 650-662
- [11] Zhang Yong-Hua, Zhang Jia-Wan, Guo Xiao-Jie. Kindling the darkness: A practical low-light Image Enhancer//Proceedings of the ACM International Conference on Multimedia. Nice, France, 2019: 1632-1640
- [12] Tao L, Zhu C, Xiang G Q, et al. LLCNN: A convolutional neural network for low-light image enhancement//Proceedings of the IEEE Visual Communications and Image Processing. Florida, USA, 2017: 1-4
- [13] Shen L, Yue Z H, Fang F, et al. MSR-net: Low-light image enhancement using deep convolutional network. arXiv preprint arXiv: 1711.02488, 2017
- [14] Land E H. The Retinex theory of color vision. Scientific American, 1977, 237(6): 108-129
- [15] Jobson D J, Rahman Z U, Woodell G A. A multiscale Retinex for bridging the gap between color images and the human observation of scenes. IEEE Transactions on Image Processing, 1997, 6(7): 965-976
- [16] Fu X, Zeng D, Huang Y, et al. A fusion-based enhancing method for weakly illuminated images. Signal Process, 2016, 129: 82-96
- [17] Ying Z, Li G, Gao W. A bio-inspired multi-exposure fusion framework for low-light image enhancement. arXiv preprint arXiv: 1711.00591, 2017
- [18] Guo X, Li Y, Ling H. LIME: Low-light image enhancement via illumination map estimation. IEEE Transactions on Image Processing, 2017, 26(2): 982-993
- [19] Chen Chen, Chen Qi-Feng, Koltun V. Learning to see in the dark//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, Utah, 2018: 3291-3300
- [20] Wei C, Wang W J, Yang W H, Liu J Y. Deep Retinex decomposition for low-light enhancement//Proceedings of the British Machine Vision Conference. Newcastle, UK, 2018: 1-10
- [21] Jiang Y, Gong X, Liu D, et al. EnlightenGAN: Deep light enhancement without paired supervision. arXiv preprint arXiv: 1906.06972, 2019
- [22] Wang R, Zhang Q, Fu C, et al. Underexposed photo enhancement using deep illumination estimation//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Long Beach, USA, 2019: 6849-6857
- [23] Wang Z, Simoncelli E P, Bovik A C. Multiscale structural similarity for image quality assessment//Proceedings of the 37th Asilomar Conference on Signals, Systems and Computers. Pacific Grove, USA, 2003: 1398-1402
- [24] Dong X, Wang G, Pang Y, et al. Fast efficient algorithm for enhancement of low lighting video//Proceedings of the IEEE International Conference on Multimedia and Expo. Barcelona, Spain, 2011: 1-6
- [25] Dang Nguyen D T, Pasquini C, Conotter V, Boato G. RAISE: A raw images dataset for digital image forensics//Proceedings of the ACM Multimedia Systems Conference. Oregon, USA, 2015: 219-224
- [26] Wang Z, Bovik A C, Sheikh H R, Simoncelli E P. Image quality assessment: From error visibility to structural similarity. IEEE Transactions on Image Processing, 2014, 13(4): 600-612
- [27] Sharma G, Wu W C, Dalal E N. The CIEDE2000 color-difference formula: Implementation notes, supplementary test data, and mathematical observations. Color Research and Applications, 2005, 30(1): 21-30



HUANG Shu-Ying, Ph. D. , associate professor. Her main research interests include image processing and machine learning.

HU Wei, M. S. candidate. His research interests include image dehazing and image restoration.

YANG Yong, Ph. D. , professor. His main research interests include image processing and machine learning.

LI Hong-Xia, M. S. candidate. Her research interests include deep learning and image restoration.

WANG Bin, M. S. candidate. His research interests include deep learning and image restoration.

Background

With the development of artificial intelligence and the excellent performance of neural network in the field of image processing, the method based on deep learning has been applied to various fields of image processing. Such as image fusion, image defogging, image enhancement, image super-resolution and image quality evaluation. Experimental results show that deep learning is effective for feature extraction and analysis of digital images. With the rapid increase of the number and types of image data, the generalization ability of deep learning method has been greatly challenged.

There are three kinds of image enhancement methods, which are based on histogram equalization, Retinex theory and deep learning. Histogram based methods mainly enhance the visual effect by enhancing the image contrast. Such methods have low computational complexity, but are prone

to detail loss and color deviation problems. Retinex based methods can get the better visual effect, but they still have limitations in model solving. Deep learning based methods can avoid the limitations of model solving, but they also ignore the imaging principle of images.

In this paper, we combine the advantages of deep learning and physical model, and propose a low exposure image enhancement method based on the progressive dual network model, which is divided into two modules: image enhancement and image denoising. We also propose a bidirectional constraint loss function to make the learning result of network approach the real data from the positive and negative directions. The experimental results show that the method proposed in this paper can achieve excellent results.