

一种自适应去噪保真的无监督暗光图像增强模型

高仁, 郝世杰, 郭艳蓉

引用本文

高仁, 郝世杰, 郭艳蓉. 一种自适应去噪保真的无监督暗光图像增强模型[J]. 计算机科学, 2024, 51(3): 147-154.

GAO Ren, HAO Shijie, GUO Yanrong. [Unsupervised Low-light Image Enhancement Model with Adaptive Noise Suppression and Detail Preservation](#) [J]. Computer Science, 2024, 51(3): 147-154.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于重参数化多尺度融合网络的高效极暗光原始图像降噪](#)

Re-parameterized Multi-scale Fusion Network for Efficient Extreme Low-light Raw Denoising
计算机科学, 2022, 49(8): 120-126. <https://doi.org/10.11896/jsjx.220200179>

[基于数据增广和模型集成策略的图神经网络在抑郁症识别上的应用](#)

Application of Graph Neural Network Based on Data Augmentation and Model Ensemble in Depression Recognition
计算机科学, 2022, 49(7): 57-63. <https://doi.org/10.11896/jsjx.210800070>

[基于低秩矩阵估计的暗光图像增强模型](#)

Low-light Image Enhancement Model with Low Rank Approximation
计算机科学, 2022, 49(1): 187-193. <https://doi.org/10.11896/jsjx.210600090>

[一种融合深度基于灰度共生矩阵的感知模型](#)

Perceptual Model Based on GLCM Combined with Depth
计算机科学, 2019, 46(3): 92-96. <https://doi.org/10.11896/j.issn.1002-137X.2019.03.012>

[语音识别中的噪声抑制方法](#)

计算机科学, 1997, 24(6): 59-62.

一种自适应去噪保真的无监督暗光图像增强模型

高仁 郝世杰 郭艳蓉

合肥工业大学计算机与信息学院 合肥 230601

(hfut.hsj@gmail.com)

摘要 暗光环境下成像往往受到低照度和成像噪声等多种因素干扰,所得图片的视觉质量往往较低。当前各类暗光增强方法多侧重于改善可视度,却常忽略了保持增强结果真实感这一同样重要的目标。为解决该问题,提出了一种自适应去噪保真的无监督暗光图像增强方法,旨在高效便捷地实现改善图像可视度和去噪保真两个目标。模型由暗光增强阶段和去噪保真阶段组成。在暗光增强阶段,构建无监督图像分解模块和光照增强模块,实现改善可视度的目标;在去噪保真阶段,基于前一阶段所得的光照分布来自动构造成对训练数据,驱动去噪模块抑制原本昏暗处的噪声并保持原本明亮处的细节,实现增强结果保真的目标。实验结果表明,相比其他暗光增强方法,所提方法在改善可视度和去噪保真之间能够取得良好的均衡。该模型无须事先采集或准备“昏暗-明亮”成对图像来进行训练,且具有较小的模型尺寸和较快的计算速度,实用性良好。

关键词: 暗光图像;光照增强;噪声抑制;图像分解

中图分类号 TP391

Unsupervised Low-light Image Enhancement Model with Adaptive Noise Suppression and Detail Preservation

GAO Ren, HAO Shijie and GUO Yanrong

School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China

Abstract The visual quality of images taken under low-light environment is usually low, due to many factors such as low lightness and imaging noise. Current low-light image enhancement methods have a common limitation that they only focus on improving lightness condition and suppressing noise, but neglect to preserve image details. To solve this problem, an unsupervised low light image enhancement method is proposed in this paper, aiming to improve the visibility and preserve the fidelity of an image with good efficiency. The model consists of two stages, i. e., low-light enhancement and noise suppression. In the first stage, an unsupervised image decomposition module and a lightness enhancement module are constructed to achieve the goal of improving visibility. In the second stage, under the guidance of the illumination distribution of an image, we synthesize pairwise training data and train the denoising network to depress the imaging noise from the originally-dim regions and preserve the image details of the originally-bright regions. Compared with other methods, experimental results show that our method achieves better balance between the goals of visibility improvement and fidelity preservation. In addition, our method can be attractive in real-world applications, as it does not need to collect bright-dim image pairs, and it has small model size and fast calculation speed.

Keywords Low-light image, Lightness enhancement, Noise suppression, Image decomposition

1 引言

拍照电子设备的快速普及让人们可以方便快捷地拍摄图像。但由于环境光照不佳、拍照者对摄影知识了解甚少等,得到图像的视觉质量往往不够理想。例如,在暗光环境中,成像场景整体或局部亮度和对比度很低时,图像内容往往难以辨识。除此之外,暗光环境下的成像过程容易引入严重的噪声干扰。上述问题使得暗光下拍摄的图像视觉质量较低,影响了用户观感体验和其他视觉分析任务。因此,通过暗光增强来改善图像视觉质量具有重要意义。高质量的暗光增强

应包含改善可视度和维持保真度两大目标。前者指模型应能有效改善暗光图像的亮度和对比度,从而使用户更容易看清其中的内容;后者指模型能够有效抑制暗光之外的其他各类成像干扰,并在此过程中尽可能保持增强结果的真实感,如保持图像的细节、不引入新的伪影等。

学界围绕暗光增强开展了深入的研究,近年来提出了Retinex模型^[1]、融合模型^[2]等模型驱动型方法,以及各类基于神经网络的数据驱动型方法^[3-4],在改善图像可视度方面取得了良好的效果。但要同时高效地完成上述两大目标,当前方法还有若干需要改善之处。首先,一些增强方法仅

到稿日期:2022-12-12 返修日期:2023-05-19

基金项目:国家自然科学基金(62172137)

This work was supported by the National Natural Science Foundation of China(62172137).

通信作者:郝世杰(hfut.hsj@gmail.com)

注重改善图像的可视度,因而其增强结果往往含有过增强的噪声或额外引入了新的伪影^[5]。虽然有众多方法专门对成像噪声进行建模^[6],或在模型中引入了噪声抑制环节^[7],但它们的处理结果往往存在局部细节丢失等问题。究其原因,当前方法未能考虑非理想光照下成像噪声的分布规律,进而未能构建出对光照感知的噪声抑制模型。其次,很多暗光增强网络模型是建立在学习成对数据训练基础之上,获取大量此类数据的难度较大,尤其是室外场景的明暗成对数据难以获取。因此,当成对图像数据难以涵盖各类复杂暗光环境时,训练获得的模型泛化能力不足,这也是增强结果表现仍有不足的另一主要原因。此外,部分暗光图像增强方法^[7-10]的模型尺

寸较大,计算效率较低,也是其表现欠佳的原因。

为解决这些问题,本文提出了一种无监督暗光增强模型,如图1所示。该模型将暗光增强过程分为暗光增强和去噪保真两个阶段。在暗光增强阶段,为克服成对数据集难以涵盖各类光照场景的问题,构建了无监督型 Retinex 分解网络 \mathcal{N}_1 ,将图像 S 分解为光照层 I 和反射层 R (并满足约束);在此基础上,针对光照层 I 构建了无监督型光照增强网络 \mathcal{N}_2 ,以改善图像可视度。在去噪保真阶段,构建了自适应去噪保真网络 \mathcal{N}_3 ,使其在光照信息的引导下抑制 S 中暗处的噪声且尽量保持 S 中亮处的细节,从而达到维持保真度的目的。

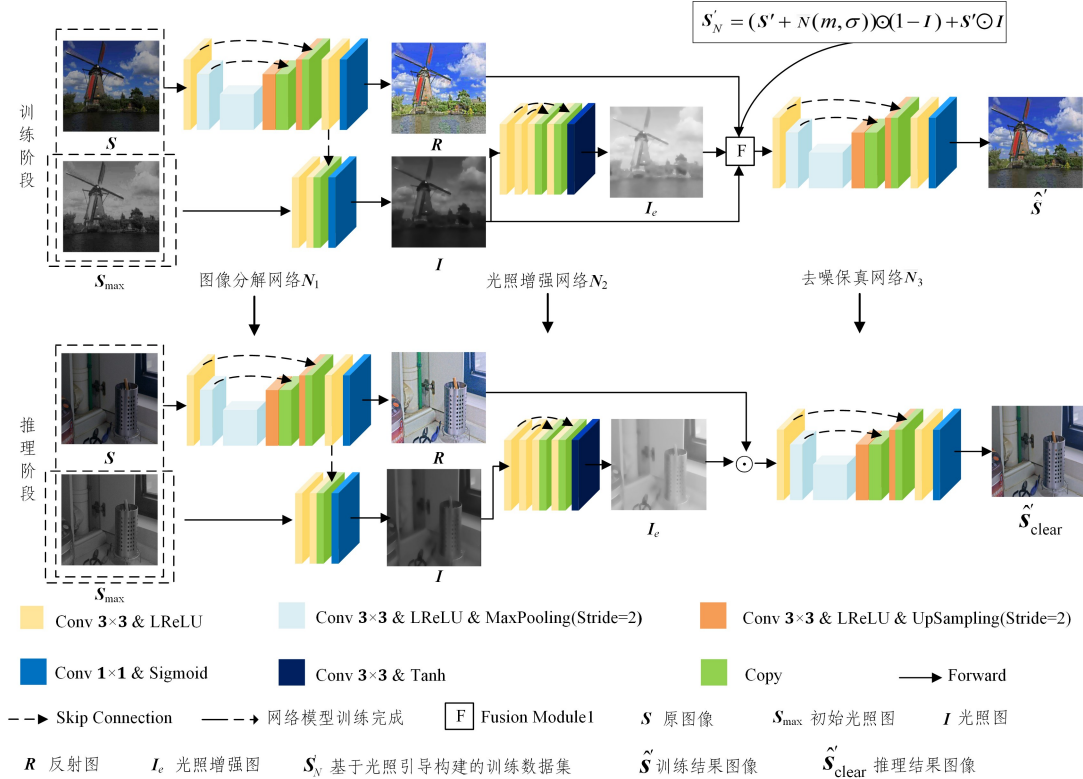


Fig. 1 Schematic diagram of adaptive denoising and low light image enhancement model

本文的主要创新点如下:

1)构造了光照引导的去噪模型,在此模型下可以针对性地去除图像暗处的噪声并保留图像亮处的细节,使最终的增强图像具有更好的保真效果。

2)图像分解网络 \mathcal{N}_1 、光照增强网络 \mathcal{N}_2 和去噪保真网络 \mathcal{N}_3 的模型训练无需真实的“昏暗-明亮”成对图像,仅需要暗光图像即可完成训练。

3)本文方法中各个网络模型尺寸较小,处理速度较快,具有较好的实用性。

本文第2章简要介绍了相关工作及文中涉及的算法;第3章介绍本文算法细节;第4章通过直观和量化实验来验证本文算法的有效性;最后总结全文并展望未来。

2 相关工作

2.1 模型驱动型暗光增强方法

Lee等提出直方图均衡化方法(Histogram Equalization,

HE)^[11],通过改变图像直方图分布来改善图像可视度。但由于直方图并不包含图像的空间位置信息,因此会出现过增强或欠增强等问题。基于Retinex模型的暗光增强方法将输入图像分解为光照层和反射层之后,对光照层进行非线性伽马变换,再将其余反射层重新合并,得到所需增强结果。Li等^[6]聚焦于图像分解这一逆问题的高效精准求解,并考虑暗光图像的成像噪声。近年来,Ren等对Retinex图像表示模型进行推展,将成像噪声也纳入了模型构建之中,提出了LR3M算法^[12],实现了对成像噪声的抑制。但这些方法仍然存在将图像细节过度平滑和引入额外伪影等问题。不同于基于Retinex模型的方法,融合型增强方法旨在将不同曝光程度的图片融为一体。Hao等^[13-14]通过其他增强方法产生若干中间增强结果来模拟不同曝光下的输入,再将其融合得到增强结果。融合型方法本质上是将各个输入进行加权求和,因此能在一定程度上抑制成像噪声的干扰。

模型驱动型暗光增强方法的优势在于其具有明确的物理

含义,但此类方法若要在增强可视度基础上实现去噪等维持保真度目标,还需要将图像表示模型加以拓展,或引入额外的先验知识,这往往会使得问题求解过程更加复杂。

2.2 数据驱动型暗光增强方法

近年来,深度神经网络模型被成功应用至暗光增强任务之中。此类方法的基本思路是从训练数据中学习出暗光图像到明亮图像的映射,进而完成图像光照增强。Lore等首先提出了基于自编码器的暗光增强模型LLNet^[4]来提升图像可视度。由于模型驱动型暗光增强方法中所采用的图像表示模型往往具有明确的物理意义,因此很多数据驱动型暗光增强方法也基于这些图像表示框架来进行建模,例如Ren等提出了基于结构层和细节层的图像表示模型^[15],Ma等提出了基于多曝光序列融合模型^[16-17]等。上述方法采用了全监督学习的范式,需要大量具有像素级对应关系的“昏暗-明亮”成对图像作为训练数据。但获得此类数据集的难度和开销往往较大,在室外场景下更是如此。因此,模型的泛化能力欠佳,并在一定程度上制约了全监督暗光增强方法的发展。近年来,无监督或半监督暗光增强方法相继被提出,如无监督暗光图像增强方法EnlightenGAN^[10]和半监督图像增强方法DRBN^[18]。此类方法较好地摆脱了成对数据规模有限的制约,能够充分地更多非成对图像数据中学习出图像表现映射的函数,因而具有更好的泛化性能和应用潜力。

从维持增强结果保真度的视角来看,需要搭建专门的网络结构来实现噪声抑制、色彩校正等目标。Zhang等提出的KinD算法^[7]专门为图像分解得到的反射层构建了复原网络,用于抑制其中的噪声等干扰和失真。Yang等构建了一种两阶段的增强模型DRBN^[18],在改善图像可视度之后,专门构建了旨在综合提升增强结果视觉质量的网络模型。本文亦构建了一种两阶段的增强模型,利用第一阶段获取的光照分布构建了数据集,并在第二阶段利用这些数据驱动和引导去噪模型完成去噪保真作用。此外,Chen等^[19]直接构建面向成像过程的端到端网络模型,用于学习Raw图像到8比特像素图像间的映射函数,将光照增强和噪声抑制统一在单个模型之中。但该方法是在面向成像过程而建,若直接将其应用在8比特数字图像的后处理中,则效果欠佳。

3 本文算法

图1给出了本文提出模型的框架,在模型训练和推理阶段均包含图像分解网络 \mathcal{N}_1 、光照增强网络 \mathcal{N}_2 和去噪保真网络 \mathcal{N}_3 这3个模块。在模型训练阶段,首先,训练图像分解网络 \mathcal{N}_1 ,使之能将待处理图像 \mathbf{S} 分解为光照层 \mathbf{I} 和反射层 \mathbf{R} ;其次,训练光照增强网络 \mathcal{N}_2 ,使之能对光照层 \mathcal{I} 进行改善,并获得可视度增强后的图像 \mathcal{I} ;最后,在光照层 \mathbf{I} 的引导下,构建合成图像对 $\{\mathbf{S}', \mathbf{S}_N'\}$ 来驱动 \mathcal{N}_3 网络的训练,使其能同时抑制 \mathbf{S} 中原本昏暗区域的噪声和保持 \mathbf{S} 中原本明亮区域的细节。在模型推理阶段,如图1下半部分所示,将训练得到的图像分解网络 \mathcal{N}_1 、光照增强网络 \mathcal{N}_2 和去噪保真网络 \mathcal{N}_3 组成可用的暗光图像增强模型。

3.1 图像分解网络

基于Retinex理论,图像 \mathbf{S} 可分为光照层 \mathbf{I} 和反射层 \mathbf{R}

的逐像素相乘:

$$\mathbf{S} = \mathbf{I} \odot \mathbf{R} \quad (1)$$

图像分解网络 \mathcal{N}_1 旨在将 \mathbf{S} 分解为 \mathbf{I} 和 \mathbf{R} ,所得的光照层 \mathbf{I} 可为后续可视度增强和自适应去噪保真环节提供核心支撑。 \mathcal{N}_1 网络结构如图1所示,包含获取反射层 \mathbf{R} 分支和获取光照层 \mathbf{I} 分支。获取反射层 \mathbf{R} 分支由5层U-Net网络^[20]、 3×3 卷积+LReLU层和 1×1 卷积+Sigmoid层组成。获取光照层 \mathbf{I} 分支网络首先包含两层 3×3 卷积+LReLU层,其中一层卷积层与反射层 \mathbf{R} 分支网络的一个卷积层进行串联,该分支网络的最后同样是 1×1 卷积+Sigmoid层。 \mathcal{N}_1 网络构建的损失函数 L_{decom} 如式(2)所示:

$$L_{\text{decom}} = L_{\text{recl}} + \omega_1 L_B + \omega_2 L_S + \omega_3 L_{\text{VGG1}} \quad (2)$$

对其中各损失项构建思路和过程的简述如下:

L_{recl} 用于衡量分解结果重构图像 $(\mathbf{I} \odot \mathbf{R})$ 与原图像 (\mathbf{S}) 之间的距离:

$$L_{\text{recl}} = \|\mathbf{S} - \mathbf{I} \odot \mathbf{R}\|_1 \quad (3)$$

其中, \odot 表示逐像素相乘。

构建 L_B 损失项的动机简述如下:由于我们采取无监督学习的范式训练 \mathcal{N}_1 ,即只使用暗光图像进行网络训练,因而基于待处理图像 \mathbf{S} 得到光照分布预估 \mathbf{B} ,能粗略地描述暗光图像中的光照分布,对精准获取 \mathbf{I} 有很大帮助;根据暗通道先验假设^[21]可知,暗通道先验是大多数图像固有之属性,同时,相反的暗光图像可近似认为与雾天图片的整体表现类似。由此可衍生出暗光图像的亮通道先验假设,并据此来初步估计 \mathbf{S} 的光照层:

$$\mathbf{S}_{\max} = \max_{c \in \{r, g, b\}} \mathbf{S}^c(p) \quad (4)$$

其中, c 表示颜色通道, p 表示 \mathbf{S} 中的像素。由于式(4)获得的结果 \mathbf{S}_{\max} 是通过逐像素估计得到的,而光照层往往满足分段线性平滑的特点,因此进一步利用引导滤波器来对 \mathbf{S}_{\max} 进行后处理:

$$\mathbf{B} = GF(\mathbf{S}_{\max}, \max_{\Omega} \mathbf{S}_{\max}, r, \epsilon) \quad (5)$$

其中, $GF(\ast)$ 表示引导滤波器(Guided Filter),用于细化 $\max_{\Omega} \mathbf{S}_{\max}$ 和去除其中的块效应; \mathbf{S}_{\max} 为引导图像; $\max_{\Omega} \mathbf{S}_{\max}$ 为输入图像; $\max_{\Omega} \ast$ 表示最大值滤波; Ω 表示局部滤波块; r 为空间正则化参数; ϵ 为灰度正则化参数。在本文中, $\Omega = 3 \times 3$, $r = 60$, $\epsilon = 10^{-7}$ 。基于所得 \mathbf{B} , \mathcal{N}_1 中的亮通道先验损失函数 L_B 可定义为:

$$L_B = \|\mathbf{I} - \mathbf{B}\|_2^2 \quad (6)$$

光照层 \mathbf{I} 应具有分段线性光滑特性,该特性不但能确保图像分解的结果质量,还将对后续光照增强和去噪保真环节起到重要作用。因此,本文使用平滑损失函数 L_S 以保证图像分解过程中光照层 \mathbf{I} 的分段线性平滑:

$$L_S = \frac{|\nabla_x \mathbf{I}|}{\max(\nabla_x \mathbf{I}, \epsilon)} + \frac{|\nabla_y \mathbf{I}|}{\max(\nabla_y \mathbf{I}, \epsilon)} \quad (7)$$

其中, $\nabla_{x,y}$ 表示 x 和 y 方向的梯度; $\mathbf{L} = \log(\text{gray}(\mathbf{S}))$; $\text{gray}(\mathbf{S})$ 表示输入暗光图像 \mathbf{S} 的灰度图像; $\epsilon = 0.0001$ 用于数值稳定,避免分母为0。

最后,采用预训练的VGG-19网络模型^[22],在语义特征层面衡量分解结果重构图像 $\mathbf{I} \odot \mathbf{R}$ 与原图像 \mathbf{S} 之间的差异,其损失函数 L_{VGG1} 构建如下:

$$L_{VGG1} = \frac{1}{C_i H_i W_i} \|\psi_i(\mathbf{S}) - \psi_i(\mathbf{I} \odot \mathbf{R})\| \quad (8)$$

其中, $\psi_i(\ast)$ 表示 VGG-19 模型第 i 层卷积得到的特征映射, C_i, H_i, W_i 表示特征映射的维度。

基于上述 4 个损失函数构建 \mathcal{N}_1 的总损失函数 L_{decom} 。其中, 经验式地设定权重参数为 $\omega_1 = 1, \omega_2 = 1$ 和 $\omega_3 = 0.5$ 。

3.2 光照增强网络

为了完成对 \mathbf{S} 的光照增强, 本文对分解所得的 \mathbf{I} 进行增强, 继而再与 \mathbf{R} 进行逐像素相乘, 得到光照增强后的图像 \mathbf{I}_e 。受 Zero-DCE 算法^[23]的启发, 本文构建了基于深度曲线估计的网络 \mathcal{N}_2 来改变光照层 \mathbf{I} 中的亮度分布。相比 Zero-DCE 模型, 本文方法仅需对表观较为简单的光照层 \mathbf{I} 进行处理, 因而 \mathcal{N}_2 可被视为 Zero-DCE 模型的一种简化版本。如图 1 所示, \mathcal{N}_2 仅由 4 层 3×3 卷积 + LReLU 层、1 层 3×3 卷积 + Tanh 层构成, 其中前两层卷积通过跳跃连接结构和后两层卷积相连, 以此提升特征的利用率。 \mathcal{N}_2 能在保证增强效果的同时保持较小的网络参数量, 维持了较高的处理效率。

在此, 对 \mathbf{I} 中的像素 p 进行处理:

$$LE(\mathbf{I}(p), \mathbf{A}(p)) = \mathbf{I}(p) + \mathbf{A}(p)\mathbf{I}(p)(1 - \mathbf{I}(p)) \quad (9)$$

其中, $\mathbf{A}(p)$ 是可学习参量矩阵 \mathbf{A} 在像素 p 位置的取值。为了获得更好的增强效果, 可以用迭代的形式形成更高阶的映射曲线:

$$LE_n(p) = LE_{n-1}(p) + \mathbf{A}_n(p)LE_{n-1}(p)(1 - LE_{n-1}(p)) \quad (10)$$

其中, $n = 1, \dots, N$ 。本文中迭代次数 N 统一设定为 8。

在损失函数方面, 首先采用曝光损失 L_{exp} 来最小化增强图像局部区域的亮度强度的平均值与曝光阈值 E 之间的距离:

$$L_{\text{exp}} = \frac{1}{M} \sum_k \|Y_k - E\|_2^2 \quad (11)$$

其中, Y_k 表示尺寸为 16×16 的不重叠局部块亮度强度的平均值, 阈值常数 E 统一设定为 0.7, M 是图像中局部像素块的个数。为进一步优化增强效果, 又引入了平滑损失 L_{TV} 来平滑 \mathbf{A}_n 的结构, 以避免或抑制增强结果中的伪影:

$$L_{\text{TV}} = \frac{1}{N} \sum_{n=1}^N ((\nabla_x \mathbf{A}_n)^2 + (\nabla_y \mathbf{A}_n)^2) \quad (12)$$

综上所述, 无监督光照增强网络的总损失函数为:

$$L_{\text{illumination}} = L_{\text{exp}} + \omega_4 L_{\text{TV}} \quad (13)$$

其中, 由于我们希望 \mathcal{N}_2 网络输出 $\{\mathbf{A}_n\}$ 保持良好的局部平滑特性, 以适应 \mathbf{I} 层同样分段线性平滑特性, 故为 L_{TV} 项赋予较大的权重, 本文经验式地将 ω_4 设为 40。获得 $\{\mathbf{A}_n\}$ 后, 基于式(10)得到改善后的光照层 \mathbf{I}_e , 进而得到可视觉度增强结果 $\mathbf{S}' = \mathbf{I}_e \odot \mathbf{R}$ 。

3.3 自适应去噪保真网络

在成像过程中, 昏暗区域往往会混入较多的成像噪声, 这些噪声随着可视觉度增强过程得以显现, 影响了视觉质量。为解决这一问题, 需引入相关处理来抑制 \mathbf{S}' 中的噪声干扰。在常规的图像去噪中, 往往需要给无噪的真值图像添加噪声来构建“有噪-无噪”成对图像, 从而训练网络。但对本应用而言, 无噪的真值图像难以直接获得。本文拟通过人为加噪进而形成图像对的策略来近似解决该问题。另一方面, 暗光

场景的成像噪声往往源于昏暗区域, 对图像全局去噪易使本就明亮的区域产生细节损失。本文基于所构建的图像驱动去噪网络专注于暗处噪声的抑制。为实现上述目标, 首先在光照层 \mathbf{I} 的引导下构建了成对的数据集, 进而驱动去噪网络 \mathcal{N}_3 的训练, 使得该网络兼具光照感知能力和去噪能力, 在抑制原本昏暗区域成像噪声的同时, 保持原本明亮区域的图像细节, 使整个模型兼顾改善可视度和维持保真度两大目标。

由于光照层 \mathbf{I} 描述了原暗光图像 \mathbf{S} 中的明暗分布, 因此假定该分布与 \mathbf{S} 中成像噪声的强弱分布大体相同。基于这一假定, 采取融合的方式构造“有噪声”的图像数据集 \mathbf{S}'_N :

$$\mathbf{S}'_N = (\mathbf{S}' + \mathbf{N}(m, \sigma)) \odot (1 - \mathbf{I}) + \mathbf{S}' \odot \mathbf{I} = \mathbf{S}' + \mathbf{N}(m, \sigma) \odot (1 - \mathbf{I}) \quad (14)$$

其中, $\mathbf{N}(m, \sigma)$ 为均值为 m 、标准差为 σ 的高斯噪声, 实验中均取 $m = 0, \sigma = 0.05$ 。基于该过程, 可获得成对图像数据集 $\mathbf{S}'_N - \mathbf{S}'$, 用于驱动去噪网络 \mathcal{N}_3 的训练优化。

如图 2 所示, \mathcal{N}_3 的网络结构与图像分解网络 \mathcal{N}_1 中获取反射层 R 的分支网络结构相似, 由 5 层 U-Net、 3×3 卷积 + LReLU 层和 1×1 卷积 + Sigmoid 层构成。在训练阶段, \mathbf{S}'_N 为输入, $\hat{\mathbf{S}}'$ 为输出。基于式(14)的构造方式, \mathbf{S}'_N 与 \mathbf{S}' 在光照原本较为明亮区域是高度相似的, 而在原本黑暗之处存在噪声差异。因而大量的此类成对图像数据可驱动 \mathcal{N}_3 网络学会保持原本明亮部分不变, 而对原本昏暗之处进行去噪。

训练 \mathcal{N}_3 使用的损失函数 $L_{\text{denoising}}$ 构造如下:

$$L_{\text{denoising}} = L_{\text{rec2}} + \omega_5 L_{\text{VGG2}} \quad (15)$$

其中, 经验式地设定权重参数 $\omega_5 = 1$ 。

L_{rec2} 项计算 $\hat{\mathbf{S}}'$ 与 \mathbf{S}' 之间的 L1 损失:

$$L_{\text{rec2}} = \|\mathbf{S}' - \hat{\mathbf{S}}'\|_1 \quad (16)$$

由于 \mathbf{S}' 本身就是含有噪声的图像, 加入噪声之后的 \mathbf{S}'_N 的图像质量会变得更差, 因此, 仅用 L_{rec2} 不能很好地恢复细节。本文采用预训练的 VGG-19 模型来进一步缩短 $\hat{\mathbf{S}}'$ 与 \mathbf{S}' 之间的距离以促进图像内容细节的恢复, 支撑 \mathcal{N}_3 去噪保真的能力。该损失函数定义为:

$$L_{\text{VGG2}} = \frac{1}{C_i H_i W_i} \|\psi_i(\hat{\mathbf{S}}') - \psi_i(\mathbf{S}')\| \quad (17)$$

如图 2 所示, 在推理阶段, 只需将一张新的图片 \mathbf{S}' 输入去噪网络, \mathcal{N}_3 网络即可对其进行有针对性的噪声抑制, 并较好地保持原本明亮处的细节, 得到最终的增强结果 $\hat{\mathbf{S}}'_{\text{clear}}$ 。

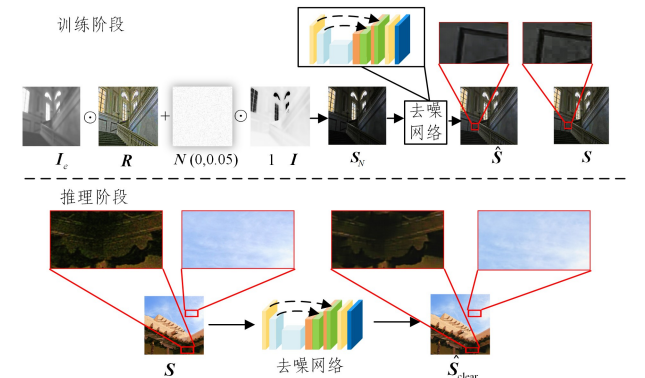


图 2 自适应去噪保真模型示意图

Fig. 2 Illustration of adaptive fidelity-preserving denoising model

4 实验结果与分析

4.1 数据集及实验设置

本文方法使用 Tensorflow 实现,模型在 Nvidia RTX 2080Ti GPU 上进行训练。将每一模块的网络训练初始学习率统一设置为 1×10^{-4} ,优化器选取 ADAM。本文模型的训练基于 SICE 方法^[24]提出的数据集完成,该数据集由 4413 张高分辨率的多重曝光图片组成,本文实验选取其中的 2 002 张图片作为训练集。同时,本文从有真值参考的公共数据集 MBLLEN^[25]中选取 144 例成对图片,以及若干无真值参考的公共数据集 DICM(44 张)、LIME(10 张)、VV(24 张)、MEF(79 张)、Fusion(18 张)、Fu(10 张),构成本文的测试数据集。选取峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)、结构相似度(Structural Similarity, SSIM)和基于感知的图像质量评价指标(Perception based Image Quality Evaluator, PIQE)作为客观评价量化指标。对比方法结果均基于原文献公布的代码实现。

为验证本文方法的有效性,选取了模型驱动方法 NPE^[26], SIRE^[27], LIME^[5],以及数据驱动方法 RetinexNet^[8], DeepUPE^[9], KinD^[7], RRDNet^[28], DRBN^[18], EnlightenGAN^[10], Zero-DCE^[23]进行主观视觉和客观量化指标上的比较。接下来,与相关去噪方法 BM3D^[29], DnCNN^[30], DIDN^[31]进行了主观视觉上的比较,用于验证本文方法能够更好地完成去噪保真。

4.2 对比实验

4.2.1 主观视觉评估

如图 3 所示,所有方法均能在整体上较好地改善图片的可视度。但在维持保真度上,各方法的表现不一。部分对比方法或整体出现了较大的过曝(如 LIME)和失真(如 RetinexNet),或在局部区域未能较好地保留图像细节,如图 3(f)一图 3(i)所示的 DeepUPE, KinD, EnlightenGAN 和 DRBN 结果中的红框区域就未能较好地保持该局部纹理细节,出现了过曝或模糊的问题。



图 3 本文算法与其他算法增强的图像对比示例 1(电子版为彩图)

Fig. 3 Example 1 of the visual comparison between the proposed algorithm and other algorithms

来看,所有方法均能改善图像的可视度,但 RetinexNet 有较为明显的失真。从各图右下角放大的局部来看,DeepUPE 和 RRDNet 对原图极暗处的增强效果并不明显(见图 4(f)和图 4(j)),其他方法均能在一定程度上改善该处的可视度。但 NPE, SIRE, Enlighten-GAN 和 Zero-DCE(见图 4(b)、图 4(c)、图 4(h)、图 4(k))对该处的成像噪声未能实现较好的抑制。相比之下,本文方法则能在较好地改善整体可视度的同时,有效地抑制成像噪声并保持了局部的细节,达到了维持增强结果保真度的目的。




图 4 本文算法与其他算法增强的图像对比示例 2

Fig. 4 Example 2 of the visual comparison between the proposed algorithm and other algorithms

为验证光照层引导下去噪保真模块的有效性,我们将可视度增强结果 S' 直接交由 BM3D, DnCNN, DIDN 处理,并与本文方法进行对比。

表 1 本文算法及其他算法在 MBLLEN 数据集上的 PSNR 均值和 SSIM 均值 \uparrow

Table 1 PSNR and SSIM average values of our algorithm and other algorithms on MBLLEN dataset

分类	算法	PSNR	SSIM
模型驱动型方法	NPE ^[26]	16.7890	0.6470
	SIRE ^[27]	15.2159	0.5422
	LIME ^[5]	17.0289	0.6465
	RetinexNet ^[8]	16.4821	0.5847
数据驱动型算法	DeepUPE ^[9]	17.5389	0.6048
	KinD ^[7]	19.7393	0.6885
	RRDNet ^[28]	16.1273	0.5495
	DRBN ^[18]	16.3434	0.5935
	EnlightenGAN ^[10]	18.3985	0.6868
	Zero-DCE ^[23]	20.3411	<u>0.6948</u>
	本文方法	19.3131	0.7040

注:粗体表示最优结果,下划线表示次优结果, \uparrow 表示该指标越大越好。

如图 5 中蓝框所示,本文方法与各类去噪方法均能有效抑制暗处的成像噪声;但对比图 5 中红框可以看到, BM3D, DnCNN, DIDN 的处理结果使图像中原本明亮区域的纹理丢失,而本文方法则可以有效保留该处的细节。其原因在于本文通过光照引导的策略构建了训练数据集,使得 \mathcal{N}_3 在处理原本明亮的区域时可近似视为一个不变映射。

图 4 进一步展示了各方法在抑制噪声方面的效果。整体




图5 去噪同时保持图像细节的视觉效果对比(电子版彩为图)

Fig. 5 Visual contrast of de-noising while maintaining image details

4.2.2 客观定量评估

首先,基于含有真值图像的 MBLLEN 数据集,使用全参考图像质量评价指标 PSNR 和 SSIM 对所有方法进行了量化比较。从表 1 的结果可以看到,本文方法在结构相似度 SSIM 上取得了最佳的效果,在峰值信噪比 PSNR 上也

取得了良好的表现。

继而选取基于感知的图像质量评价指标 PIQE 对各类方法进行测试和比较。如表 2 所列,本文方法在 LIME, Fusion 和 Fu 数据集上均取得了最优的表现,在 VV 和 MEF 数据集上取得了次优的表现。

表 2 本文算法及其他算法在不同数据集上的 PIQE 均值 ↓

Table 2 Average values of PIQE of our algorithm and other algorithms on different datasets

分类	方法	LIME	VV	MEF	Fusion	Fu
模型驱动型方法	NPE ^[26]	36.4120	30.2570	42.2350	36.6520	37.1070
	SIRE ^[27]	36.4620	31.4590	40.0650	38.2720	38.3760
	LIME ^[5]	61.2540	55.7920	65.5620	52.6960	51.4880
数据驱动型方法	RetinexNet ^[8]	42.9556	30.3946	40.9106	40.8278	34.2572
	KinD ^[7]	45.3090	37.7390	56.4110	43.3240	43.8530
	DeepUPE ^[9]	34.5230	27.5720	36.0920	44.5970	33.7550
	RRDNet ^[28]	<u>32.6090</u>	31.3620	36.3300	39.0610	37.4810
	DRBN ^[18]	44.1090	42.7180	59.2560	45.7100	46.2450
	EnlightenGAN ^[10]	33.0810	25.7460	31.3950	<u>36.1350</u>	<u>32.3920</u>
	Zero-DCE ^[23]	35.8670	29.6230	36.5890	36.4160	37.5220
	本文方法	30.9000	26.4370	<u>35.6880</u>	30.3220	29.5430

注:粗体表示最优结果,下划线表示次优结果,↓表示指标越小越好。

4.2.3 计算效率评估

本文从计算效率的视角对各个数据驱动型方法进行了比较,在 Nvidia RTX 2080Ti GPU 硬件平台上测试了各类模型的可训练参数、FLOPs(处理 $1200 \times 900 \times 3$ 图像的结果)和时间(处理 10 张 $1200 \times 900 \times 3$ 图像的总时间),结果如图 6 所示。




图 6 各类方法计算效率方面的综合比较

Fig. 6 Comprehensive comparison of various methods in computational efficiency

图 6 中横坐标表示模型的可训练参数量(Parameters),纵坐标表示模型的浮点运算次数(FLOPs),散点的大小表示模型处理图像的时间(runtime)。越趋近于坐标右上角且

散点越小的模型,其参数量越小、复杂度越低、处理速度越快。综合来看,Zero-DCE 方法在计算效率方面具有最佳的综合性表现。与 RRDNet 方法相比,本文方法的 FLOPs 和 Parameters 略高,但处理速度更快。

4.3 消融实验

本文对模型损失函数进行了消融实验。针对模型 3 个子网络的损失函数,分别单独移除其中的单一损失函数项,再对网络进行重新训练得到相应结果,然后与本文方法相应结果进行比较,结果如图 7 所示。在图像分解阶段,去除 L_{rec1} 或 L_{VGG} 均会导致 \mathcal{A}_1 分解的反射层带有局部失真;去除平滑损失 L_S 会导致 \mathcal{A}_1 分解的光照层不能很好地保持线性平滑;去除亮通道先验损失 L_B 则会导致 \mathcal{A}_1 分解结果不能准确描述原图像的光照分布。在光照增强阶段,去除曝光损失 L_{exp} 会导致 \mathcal{A}_2 无法增强暗光区域的亮度(如天花板区域);去除平滑损失 L_{TV} 会使得 \mathcal{A}_2 无法学习出有效的参量矩阵 $\{A_n\}$,使得光照增强趋于失败。因此,在选取该损失项参数时,本文选取了一个较大的权重 $\omega_1 = 40$ 。在去噪阶段,消除 L_{rec2} 会导致 \mathcal{A}_3 输出具有明显的棋盘效应,而消除 L_{VGG2} 则会导致 \mathcal{A}_3 输出在暗处(如天花板区域)的去噪效果不佳。




图7 面向损失函数的消融实验

Fig. 7 Ablation study on loss functions

为验证通过构建光照引导数据集来训练 \mathcal{M}_3 这一策略的有效性,改为简单的全局加噪 $S'_N = S' + N(m, \sigma)$,相关参数仍与式(14)相同。基于该数据集训练所得的处理结果和本文方法的结果如图8所示。基于式(14)构成成对数据集得到的 \mathcal{M}_3 在有效抑制噪声的同时,能更好地保留原图像中的细节(如图8(c)红框所示的云层细节),实现了兼顾可视度和保真度的目标。



图8 面向光照引导的消融实验(电子版为彩图)

Fig. 8 Light guided ablation experiment

结束语 本文提出了一种两阶段的暗光图像增强模型,旨在同时改善暗光图像的可视度和维持增强结果的保真度。在暗光增强阶段,构建了无监督的图像分解网络和光照增强网络,仅需暗光图像即可完成分解和增强网络的训练。在去噪保真阶段,在图像分解所得光照层的引导下构建成对数据集,进而训练自适应去噪保真网络,实现对原本昏暗处的噪声抑制和原本明亮处的细节保真。通过在多个数据集上的直观视觉效果比较和量化评价指标对比可以看出,相比其他暗光增强方法,本文方法在兼顾暗光增强、噪声抑制和图像保真方面均取得了较好的平衡,且具有模型尺寸小、计算速度较快等特点。在接下来的研究工作中,将重点考虑如何将语义信息

引入暗光增强模型之中,为提升增强结果的自然度^[32-33]提供更丰富的技术框架。

参考文献

- [1] CAI B L, XU X M, GUO K L, et al. A Joint Intrinsic-Extrinsic Prior Model for Retinex[C]//International Conference on Computer Vision(ICCV). IEEE, 2017:4020-4029.
- [2] FU X Y, ZENG D L, HUANG Y, et al. A fusion-based enhancing method for weakly illuminated images[J]. Signal Processing, 2016, 129: 82-96.
- [3] LI C Y, GUO C L, HAN L H, et al. Low-Light Image and Video Enhancement Using Deep Learning: A Survey[J]. arXiv: 2104.10729, 2021.
- [4] 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.
- [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] 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.
- [7] ZHANG Y H, ZHANG J W, GUO X J. Kindling the Darkness: A Practical Low-light Image Enhancer[C]//ACM International Conference on Multimedia, Association for Computing Machinery. 2019: 1632-1640.

- [8] WEI C, WANG W J, YANG W H, et al. Deep Retinex Decomposition for Low-Light Enhancement[C]// British Machine Vision Conference. IEEE, 2018; 4020-4029.
- [9] WANG R X, ZHANG Q, FU C W, et al. Underexposed Photo Enhancement Using Deep Illumination Estimation[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). IEEE, 2019; 6842-6850.
- [10] 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.
- [11] 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.
- [12] REN X T, YANG W H, CHENG WH, et al. LR3M: Robust Low-Light Enhancement via Low-Rank Regularized Retinex Model[J]. IEEE Transactions on Image Processing, 2020, 29: 5862-5876.
- [13] HAO S J, GUO Y R, WEI Z. Lightness-aware contrast enhancement for images with different illumination conditions[J]. Multimedia Tools and Application, 2019, 78: 3817-3830.
- [14] HAO S J, HAN X, GUO Y R, et al. Low-Light Image Enhancement With Semi-Decoupled Decomposition [J]. IEEE Transactions on Multimedia, 2020, 22(12): 3025-3038.
- [15] REN W Q, LIU S F, XU Q Q, et al. Low-Light Image Enhancement via a Deep Hybrid Network[J]. IEEE Transactions on Image Processing, 2019, 28(9): 4364-4375.
- [16] MA K D, DUANMU Z F, ZHU H W, et al. Deep Guided Learning for Fast Multi-Exposure Image Fusion[J]. IEEE Transactions on Image Processing, 2019, 29: 2808-2819.
- [17] MA K D, LI H, YONG H W, et al. Robust Multi-Exposure Image Fusion: A Structural Patch Decomposition Approach[J]. IEEE Transactions on Image Processing, 2017, 26(5): 2519-2532.
- [18] YANG W H, WANG S Q, FANG Y M, et al. From Fidelity to Perceptual Quality: A Semi-Supervised Approach for Low-Light Image Enhancement[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). IEEE, 2020: 3060-3069.
- [19] CHEN C, CHEN Q F, XU J, et al. Learning to See in the Dark [C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2018: 3291-3300.
- [20] 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. 2015: 234-241.
- [21] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior[C]// 2009 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2009: 1956-1963.
- [22] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]// International Conference on Learning Representations. 2014: 1956-1963.
- [23] 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). IEEE, 2020: 1777-1786.
- [24] CAI J R, GU S H, ZHANG L. Learning a Deep Single Image Contrast Enhancer from Multi-Exposure Images [J]. IEEE Transactions on Image Processing, 2018, 27(4): 2049-2062.
- [25] LV F F, LU F, WU J H, et al. MBLLen: Low-Light Image/Video Enhancement Using CNNs[C]// British Machine Vision Conference. 2018.
- [26] 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.
- [27] FU X Y, LIAO Y H, ZENG D L, et al. A Probabilistic Method for Image Enhancement With Simultaneous Illumination and Reflectance Estimation[J]. IEEE Transactions on Image Processing, 2015, 24(12): 4965-4977.
- [28] ZHU A Q, ZHANG L, SHEN Y, et al. Zero-Shot Restoration of Underexposed Images via Robust Retinex Decomposition[C]// 2020 IEEE International Conference on Multimedia and Expo (ICME). IEEE, 2020: 1-6.
- [29] 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.
- [30] ZHANG K, ZUO W M, CHEN Y J, 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.
- [31] YU S, PARK B, JEONG J. Deep Iterative Down-Up CNN for Image Denoising[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops(CVPRW). IEEE, 2019: 2095-2103.
- [32] SHEN R H, ZHOU M R, LING S. Image Enhancement Technology Based on Improved FA Algorithm and Incomplete Beta Function[J]. Journal of Chongqing Technology and Business University(Natural Science Edition), 2023, 40(2): 57-63.
- [33] WANG M M, PENG D L. Retinex-ADNet: a Low-light Image Enhancement System[J]. Journal of Chinese Computer Systems. 2022, 43(2): 367-371.



GAO Ren, born in 1997, postgraduate. His main research interests include image processing and pattern recognition.



HAO Shijie, born in 1983, Ph.D., professor, is a member of CCF(No. 77721M). His main research interests include image processing and pattern recognition.