



# (12) 发明专利申请

(10) 申请公布号 CN 116071266 A

(43) 申请公布日 2023.05.05

(21) 申请号 202310159846.9

(22) 申请日 2023.02.17

(71) 申请人 深圳大学

地址 518060 广东省深圳市南山区南海大道3688号

申请人 鹏城实验室

(72) 发明人 高帅博 邬文慧 邱国平

(74) 专利代理机构 深圳市君胜知识产权代理事务所(普通合伙) 44268

专利代理师 刘文求 王永文

(51) Int. Cl.

G06T 5/00 (2006.01)

G06N 3/08 (2023.01)

G06N 3/0464 (2023.01)

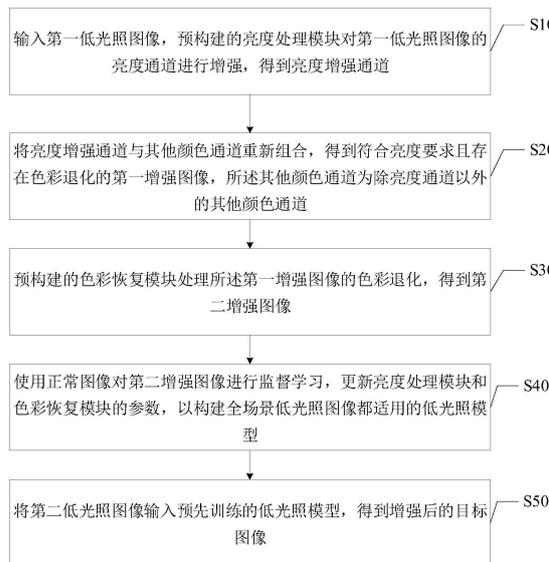
权利要求书2页 说明书11页 附图3页

## (54) 发明名称

一种基于Retinex的低光照图像增强方法、存储介质及终端

## (57) 摘要

本发明公开一种基于Retinex的低光照图像增强方法、存储介质及终端,包括用亮度处理模块增强第一低光照图像的亮度通道,得到亮度增强通道;将亮度增强通道与其他颜色通道重新组合,得到符合亮度要求且存在色彩退化的第一增强图像,所述其他颜色通道为除亮度通道以外的其他颜色通道;用色彩恢复模块处理第一增强图像的色彩退化,得到第二增强图像;用正常图像对第二增强图像进行监督学习,构建全场景低光照图像都适用的低光照模型;将第二低光照图像输入预先训练的低光照模型,得到增强后的目标图像。本发明应用Retinex理论在保持图像纹理的同时增强亮度,分两步依次解决纹理退化、色彩退化,能更有效地处理各类型的退化,从亮度、对比度、色彩、纹理细节等方面提升低光照图像的质量。



CN 116071266 A

1. 一种基于Retinex的低光照图像增强方法,其特征在于包括:

输入第一低光照图像,预构建的亮度处理模块对第一低光照图像的亮度通道进行增强,得到亮度增强通道;

将亮度增强通道与其他颜色通道重新组合,得到符合亮度要求且存在色彩退化的第一增强图像,所述其他颜色通道为除亮度通道以外的其他颜色通道;

预构建的色彩恢复模块处理所述第一增强图像的色彩退化,得到第二增强图像;

使用正常图像对第二增强图像进行监督学习,更新亮度处理模块和色彩恢复模块的参数,以构建全场景低光照图像都适用的低光照模型;

将第二低光照图像输入预先训练的低光照模型,得到增强后的目标图像。

2. 根据权利要求1所述的基于Retinex的低光照图像增强方法,其特征在于,所述输入第一低光照图像,预构建的亮度处理模块对第一低光照图像的亮度通道进行增强,得到亮度增强通道,之前包括:

构建初始化分解模块,通过所述初始化分解模块将图像的亮度通道初步分解为 $R_0$ 和 $L_0$ ,其中 $R_0$ 为粗略估计的物体的反射分量, $L_0$ 为粗略估计的环境光照射分量;

构建展开求解模块,通过所述展开求解模块求解亮度通道上的Retinex分解问题,得到准确的R和L,其中R为物体的反射分量,L为环境光照射分量;

构建亮度融合模块,通过所述亮度融合模块将构建展开求解模块使得到的准确的物体的反射分量与额外补充的新照明图融合,得到亮度增强通道;其中,所述额外补充的新照明图为亮度均匀并且亮度充足的图像。

3. 根据权利要求2所述的基于Retinex的低光照图像增强方法,其特征在于,所述通过所述展开求解模块求解亮度通道上的Retinex分解问题,包括:

对亮度通道上的Retinex分解:

$$\min_{R,L} \|V - R \cdot L\|_F^2 + \alpha_1 \Omega_1(R) + \alpha_2 \Omega_2(L)$$

其中, $\|V - R \cdot L\|_F$ 为F范数, $\min_{R,L} \|V - R \cdot L\|_F^2$ 为重构项, $V$ 为亮度通道, $\Omega_1(R)$ 和 $\Omega_2(L)$ 分别是R和L的正则项, $\alpha_1$ 和 $\alpha_2$ 为超参数。

4. 根据权利要求3所述的基于Retinex的低光照图像增强方法,其特征在于,所述通过所述展开求解模块求解亮度通道上的Retinex分解问题,还包括:

通过有监督学习估计R,根据估计得到的R计算得到环境光照射分量L:

$$L = V/R$$

根据得到的环境光照射分量L,对亮度通道上的Retinex分解:

$$\min_{R,L} \|V - R \cdot L\|_F^2 + \alpha \Omega(R)$$

其中 $\alpha$ 为超参数, $\Omega(R)$ 为R的正则项。

5. 根据权利要求4所述的基于Retinex的低光照图像增强方法,其特征在于,所述通过所述展开求解模块求解亮度通道上的Retinex分解问题,还包括:

引入辅助变量Z,对亮度通道上的Retinex分解:

$$\min_{R,L} \|V - R \cdot L\|_F^2 + \alpha \Omega(Z) + \gamma \|Z - R\|_F^2$$

将Retinex分解问题拆分为3个单变量子问题:

$$\mathcal{O}(Z) = \alpha\Omega(Z) + \gamma\|Z - R\|_F^2$$

$$\mathcal{O}(R) = \|V - R \cdot L\|_F^2 + \gamma\|Z - R\|_F^2$$

$$\mathcal{O}(L) = \|V - R \cdot L\|_F^2$$

其中  $\Omega(Z)$  为Z的正则项,  $\gamma$  为超参数,  $\|Z - R\|_F$  为F范数,  $\mathcal{O}(Z)$  为与辅助变量Z相关的子问题,  $\mathcal{O}(R)$  为与变量R相关的子问题,  $\mathcal{O}(L)$  为与变量L相关的子问题, 子问题  $\mathcal{O}(R)$  和  $\mathcal{O}(L)$  都是最小二乘问题, 可以通过使其一阶导数等于0求解。

6. 根据权利要求2所述的基于Retinex的低光照图像增强方法, 其特征在于, 所述通过所述展开求解模块求解亮度通道上的Retinex分解问题, 之后包括:

采用迭代更新变量的方式求解亮度通道上的Retinex分解问题, 每次迭代更新的公式为:

$$Z_{k+1} = \mathcal{U}_z(R_k; \theta_z)$$

$$R_{k+1} = \frac{\gamma Z_{k+1} + V \cdot L_k}{L_k \cdot L_k + \gamma}$$

$$L_{k+1} = \frac{V}{R_{k+1}}$$

其中  $\mathcal{U}_z$  为卷积神经网络,  $\theta_z$  是卷积神经网络  $\mathcal{U}_z$  的参数,  $k$  为迭代更新次数,  $R_k$  为第  $k$  次迭代更新时的R值,  $R_{k+1}$  为第  $k+1$  次迭代更新时的R值,  $Z_{k+1}$  为第  $k+1$  次迭代更新时的Z,  $L_k$  为第  $k$  次迭代更新时的L值,  $L_{k+1}$  为第  $k+1$  次迭代更新时的L值。

7. 根据权利要求2所述的基于Retinex的低光照图像增强方法, 其特征在于, 所述色彩恢复模块包括主干网络、下采样第一分支网络和下采样第二分支网络; 所述主干网络包括8层卷积层和激活函数, 其中, 前7层卷积层的激活函数为LeakyReLU, 第8层的激活函数为ReLU。

8. 根据权利要求2所述的基于Retinex的低光照图像增强方法, 其特征在于: 所述初始化分解模块为初始化卷积神经网络, 所述初始化卷积神经网络包括4层卷积层以及激活函数, 其中前3层卷积层的激活函数为LeakyReLU, 最后一层卷积层的激活函数为ReLU。

9. 一种计算机可读存储介质, 其特征在于, 所述计算机可读存储介质存储有一个或者多个程序, 所述一个或者多个程序可被一个或者多个处理器执行, 以实现如权利要求1~8任意一项所述的基于Retinex的低光照图像增强方法中的步骤。

10. 一种终端, 其特征在于包括: 处理器和存储器, 所述存储器上存储有可被所述处理器执行的计算机可读程序; 所述处理器执行所述计算机可读程序时实现如权利要求1~8任意一项所述的基于Retinex的低光照图像增强方法中的步骤。

## 一种基于Retinex的低光照图像增强方法、存储介质及终端

### 技术领域

[0001] 本发明属于数字图像处理和计算机视觉技术领域,具体为一种基于Retinex的低光照图像增强方法、存储介质及终端。

### 背景技术

[0002] 低光照图像往往存在着低可见度、低对比度、色调偏移、纹理丢失、噪声等复杂的退化,而目前的基于模型和基于深度学习的低光照增强方法,往往只考虑了其中的几种退化,或是将这些复杂多样的退化放在一起解决。这些方法或许能在亮度、色彩、纹理细节、噪声处理其中一个方面取得较好的效果,但难以同时在这些方面达到令人满意的效果。RRM能有效去除噪声,但在提高图像亮度方面表现不佳;Retinex-Net (Retinex为一种颜色恒常知觉的计算理论,Retinex为一个合成词,由retina (视网膜)+cortex (皮层) 构成) 能有效提高图像亮度,但出现了严重的噪声和色调偏移;Zero-DCE (Zero-Reference Deep Curve Estimation,零参考深曲线估计) 较好地解决了色彩偏移,但对比度较低、纹理不清晰;RUAS尽管能改善图像低对比度,但常常导致局部过曝;AGLLNet (attention guided low-light Net,注意力引导微光网络) 在色彩、亮度方面表现很亮眼,但局部纹理恢复很差,常常出现伪影;URetinex-Net在纹理、亮度方面表现很好,饱和度偏低,图像不够生动。

[0003] 故此,亟需一种基于Retinex的低光照图像增强方法,能够从亮度、对比度、色彩、纹理细节各个方面提升低光照图像的质量。

### 发明内容

[0004] 本发明的目的在于提供一种基于Retinex的低光照图像增强方法、存储介质及终端,以解决目前的基于模型和基于深度学习的低光照增强方法往往只考虑了其中的几种退化,或是将这些复杂多样的退化放在一起解决,导致这些方法或许能在亮度、色彩、纹理细节、噪声处理其中一个方面取得较好的效果,但难以同时在这些方面达到令人满意的效果的技术问题。

[0005] 为此,本发明提供一种基于Retinex的低光照图像增强方法,包括:

[0006] 输入第一低光照图像,预构建的亮度处理模块对第一低光照图像的亮度通道进行增强,得到亮度增强通道;

[0007] 将亮度增强通道与其他颜色通道重新组合,得到符合亮度要求且存在色彩退化的第一增强图像,所述其他颜色通道为除亮度通道以外的其他颜色通道;

[0008] 预构建的色彩恢复模块处理所述第一增强图像的色彩退化,得到第二增强图像;

[0009] 使用正常图像对第二增强图像进行监督学习,更新亮度处理模块和色彩恢复模块的参数,以构建全场景低光照图像都适用的低光照模型;

[0010] 将第二低光照图像输入预先训练的低光照模型,得到增强后的目标图像。

[0011] 在一个更加优选的实施方式中,所述输入第一低光照图像,预构建的亮度处理模块对第一低光照图像的亮度通道进行增强,得到亮度增强通道,之前包括:

[0012] 构建初始化分解模块,通过所述初始化分解模块将图像的亮度通道初步分解为 $R_0$ 和 $L_0$ ,其中 $R_0$ 为粗略估计的物体的反射分量, $L_0$ 为粗略估计的环境光照射分量;

[0013] 构建展开求解模块,通过所述展开求解模块求解亮度通道上的Retinex分解问题,得到准确的R和L,其中R为物体的反射分量,L为环境光照射分量;

[0014] 构建亮度融合模块,通过所述亮度融合模块将构建展开求解模块使得到的准确的物体的反射分量与额外补充的新照明图融合,得到亮度增强通道;其中,所述额外补充的新照明图为亮度均匀并且亮度充足的图像。

[0015] 在一个更加优选的实施方式中,所述通过所述展开求解模块求解亮度通道上的Retinex分解问题,包括:

[0016] 对亮度通道上的Retinex分解:

$$[0017] \min_{R,L} \|V - R \cdot L\|_F^2 + \alpha_1 \Omega_1(R) + \alpha_2 \Omega_2(L)$$

[0018] 其中, $\|V - R \cdot L\|_F$ 为F范数, $\min_{R,L} \|V - R \cdot L\|_F^2$ 为重构项,V为亮度通道, $\Omega_1(R)$ 和 $\Omega_2(L)$ 分别是R和L的正则项, $\alpha_1$ 和 $\alpha_2$ 为超参数。

[0019] 在一个更加优选的实施方式中,所述通过所述展开求解模块求解亮度通道上的Retinex分解问题,还包括:

[0020] 通过有监督学习估计R,根据估计得到的R计算得到环境光照射分量L:

$$[0021] L = V/R$$

[0022] 根据得到的环境光照射分量L,对亮度通道上的Retinex分解:

$$[0023] \min_{R,L} \|V - R \cdot L\|_F^2 + \alpha \Omega(R)$$

[0024] 其中 $\alpha$ 为超参数, $\Omega(R)$ 为R的正则项。

[0025] 在一个更加优选的实施方式中,所述通过所述展开求解模块求解亮度通道上的Retinex分解问题,还包括:

[0026] 引入辅助变量Z,对亮度通道上的Retinex分解:

$$[0027] \min_{R,L} \|V - R \cdot L\|_F^2 + \alpha \Omega(Z) + \gamma \|Z - R\|_F^2$$

[0028] 将Retinex分解问题拆分为3个单变量子问题:

$$[0029] \mathcal{O}(Z) = \alpha \Omega(Z) + \gamma \|Z - R\|_F^2$$

$$[0030] \mathcal{O}(R) = \|V - R \cdot L\|_F^2 + \gamma \|Z - R\|_F^2$$

$$[0031] \mathcal{O}(L) = \|V - R \cdot L\|_F^2$$

[0032] 其中 $\Omega(Z)$ 为Z的正则项, $\gamma$ 为超参数, $\|Z - R\|_F$ 为F范数, $\mathcal{O}(Z)$ 为与辅助变量Z相关的子问题, $\mathcal{O}(R)$ 为与变量R相关的子问题, $\mathcal{O}(L)$ 为与变量L相关的子问题,子问题 $\mathcal{O}(R)$ 和 $\mathcal{O}(L)$ 都是最小二乘问题,可以通过使其一阶导数等于0求解。

[0033] 在一个更加优选的实施方式中,所述通过所述展开求解模块求解亮度通道上的Retinex分解问题,之后包括:

[0034] 采用迭代更新变量的方式求解亮度通道上的Retinex分解问题,每次迭代更新的公式为:

$$[0035] \quad Z_{k+1} = \mathcal{U}_z(R_k; \theta_z)$$

$$[0036] \quad R_{k+1} = \frac{\gamma Z_{k+1} + V \cdot L_k}{L_k \cdot L_k + \gamma}$$

$$[0037] \quad L_{k+1} = \frac{V}{R_{k+1}}$$

[0038] 其中 $\mathcal{U}_z$ 为卷积神经网络, $\theta_z$ 是卷积神经网络 $\mathcal{U}_z$ 的参数, $k$ 为迭代更新次数, $R_k$ 为第 $k$ 次迭代更新时的 $R$ 值, $R_{k+1}$ 为第 $k+1$ 次迭代更新时的 $R$ 值, $Z_{k+1}$ 为第 $k+1$ 次迭代更新时的 $Z$ , $L_k$ 为第 $k$ 次迭代更新时的 $L$ 值, $L_{k+1}$ 为第 $k+1$ 次迭代更新时的 $L$ 值。

[0039] 在一个更加优选的实施方式中,所述色彩恢复模块包括主干网络、下采样第一分支网络和下采样第二分支网络;所述主干网络包括8层卷积层和激活函数,其中,前7层卷积层的激活函数为LeakyReLU,第8层的激活函数为ReLU。

[0040] 在一个更加优选的实施方式中,所述初始化分解模块为初始化卷积神经网络,所述初始化卷积神经网络包括4层卷积层以及激活函数,其中前3层卷积层的激活函数为LeakyReLU,最后一层卷积层的激活函数为ReLU。

[0041] 另一方面,本发明提供一种计算机可读存储介质,所述计算机可读存储介质存储有一个或者多个程序,所述一个或者多个程序可被一个或者多个处理器执行,以实现如上所述的基于Retinex的低光照图像增强方法中的步骤。

[0042] 另一方面,本发明还提供一种终端,包括:处理器和存储器,所述存储器上存储有可被所述处理器执行的计算机可读程序;所述处理器执行所述计算机可读程序时实现如上所述的基于Retinex的低光照图像增强方法中的步骤。

[0043] 与现有技术相比,本发明的特点和有益效果为:针对低光照图像中的复杂退化,本发明采用逐个解决思路,将复杂的问题分解为多个相对简单的问题进行求解。考虑到这些退化不全是互相独立的,本发明粗略将这些退化分为纹理退化、色彩退化两大类,分别建模依次解决。为了处理纹理退化,本发明首先关注亮度调整和纹理保存,提出了一个基于Retinex的亮度处理模块LPM,仅对第一低光照图像的亮度通道进行增强,得到亮度增强通道。在处理完纹理退化后,本发明将亮度增强通道与其他颜色通道重新组合,得到符合亮度要求且存在色彩退化的第一增强图像。接着利用色彩恢复模块来处理第一增强图像的色彩退化,得到第二增强图像。本发明通过应用Retinex理论在保持图像纹理的同时增强亮度,并分两步依次解决纹理退化、色彩退化,所构建的模型相比其他方法能更有效地处理各类型的退化,从亮度、对比度、色彩、纹理细节各个方面提升低光照图像的质量。

## 附图说明

[0044] 为了更清楚地说明本申请实施例中的技术方案,下面将对实施例描述中所需要使用的附图作简单地介绍,显而易见地,下面描述中的附图仅仅是本申请的一些实施例,对于本领域普通技术人员而言,在不符创造性劳动的前提下,还可以根据这些附图获得其他的附图。

[0045] 图1为基于Retinex的低光照图像增强方法的流程示意图;

[0046] 图2为低光照模型的整体框架示意图;

- [0047] 图3为SE的网络结构示意图；
- [0048] 图4和图5为本专利方法与其他方法的可视化比较图；
- [0049] 图6为本发明提供的终端设备的结构原理图。
- [0050] 附图标注:10-处理器、11-显示屏、12-存储器、13-通信接口、14-总线。

### 具体实施方式

[0051] 本发明提供一种基于Retinex的低光照图像增强方法、存储介质及终端,为使本申请的目的、技术方案及效果更加清楚、明确,以下参照附图并举实施例对本申请进一步详细说明。应当理解,此处所描述的具体实施例仅用以解释本申请,并不用于限定本申请。

[0052] 本技术领域技术人员可以理解,除非特意声明,这里使用的单数形式“一”、“一个”、“所述”和“该”也可包括复数形式。应该进一步理解的是,本申请的说明书中使用的措辞“包括”是指存在所述特征、整数、步骤、操作、元件和/或组件,但是并不排除存在或添加一个或多个其他特征、整数、步骤、操作、元件、组件和/或它们的组。应该理解,当本发明称元件被“连接”或“耦接”到另一元件时,它可以直接连接或耦接到其他元件,或者也可以存在中间元件。此外,这里使用的“连接”或“耦接”可以包括无线连接或无线耦接。这里使用的措辞“和/或”包括一个或更多个相关联的列出项的全部或任一单元和全部组合。

[0053] 本技术领域技术人员可以理解,除非另外定义,这里使用的所有术语(包括技术术语和科学术语),具有与本申请所属领域中的普通技术人员的一般理解相同的意义。还应该理解的是,诸如通用字典中定义的那些术语,应该被理解为具有与现有技术的上下文中的意义一致的意义,并且除非像这里一样被特定定义,否则不会用理想化或过于正式的含义来解释。

[0054] 在当今数字化时代,人们的生活已离不开包括图像、视频、语音在内的大量多媒体信息,其中以图像、视频为代表的视觉感知信息,是人们获取的信息中最直接、最重要的部分。数字图像广泛应用于安保监控、交通管理、卫星遥感、军事侦察,和以人脸识别、语义分割、自动驾驶为代表人工智能领域,可以说人类活动的绝大多数领域都离不开对图像的应用。为了充分获取图像中的信息,人们对图像质量的要求也在不断提高,然而在获取图像时,由于外部环境的干扰,不可避免地引入噪声,导致图像的质量下降。在低光照环境下,由于缺乏足够的光,获取到的图像存在大面积的黑暗部分和严重的噪声,图像的可见度和对比度严重下降,严重影响后续高层视觉任务应用的效果,如降低人脸识别、车牌识别的准确率。

[0055] 为了在低光照环境下获取高质量图像,最直接的方式是调整物理成像过程的参数设置来提高成像质量。延长成像设备的曝光时间能获取更多的光线,但非常容易受晃动影响造成模糊。另一种方式是提高底片感光度,尽管可以显著提升图像亮度,但也同时引入了大量噪声,降低了图像细节表现和整体质量。使用闪光灯或者外置灯光也是常用的技巧,但由于光的分布不均匀,也会造成色彩不自然等问题。总而言之,单纯依赖调整物理成像的过程,难以获得理想的图像,因此构建智能化低光照增强算法来获取高质量图片是非常必要的。

[0056] 根据算法设计理念不同,现有的低光照图像增强算法可分为3类:基于分布映射的方法,基于模型优化的方法和基于深度学习的方法。

[0057] 基于分布映射的方法从低光照图像的像素值分布考虑,使用伽马矫正、幂函数、对数函数等曲线变换、直方图均衡、自适应直方图均衡等方法改善图像的像素值分布,从而提高图像亮度。但这种只考虑像素值分布,忽略成像过程与像素值在空间上分布的技术,是人工智能技术发展早期处理图像的常用方式,他们往往无法有效区分图像的语义信息,存在着颜色失真、噪声明显、纹理不清晰的问题。

[0058] 基于模型优化的方法,常常采用Retinex理论对图像进行数学建模,并通过设计目标优化函数,迭代更新模型参数的方式,获取一个能有效增强图像的模型进而实现对图像的增强。Retinex理论模拟了人类的视觉系统,假设图片I由反射图R和照明图L的乘积构成,即: $I=R \cdot L$ ,其中反射图R代表着图像的场景信息,照明图L代表着外部的光照信息。低光照图像与正常光照图像在成像上的区别是外部的光照分布与强度,因而在Retinex理论中,两者的R是相同的,而L是不同的。所以基于Retinex理论的模型优化方法通过分解图像获得R、L后,再将L进行增强,最后将增强后的L与R相乘即可实现低光照增强。然而这类方法对于图像的Retinex分解、L的增强需要人为添加先验正则项,即根据经验为变量设置约束和优化方向,这使得模型的泛化性能较差,往往只能在特定场景下得到较好的增强结果,难以在复杂场景下应用。此外,对于每一张图像,都需要训练一个模型,这使得批量处理图像的时间开销很大,也难以应用于实时图像增强(比如相机的夜景拍摄优化)。

[0059] 在大数据时代,为了克服上述传统方法的弊端,应用数据驱动模型的理念,利用深度学习强大的非线性映射能力,通过设计网络结构建立低光照输入与增强输出之间的关系,已成为一种主流的低光照图像增强模式。

[0060] 针对目前的基于模型和基于深度学习的低光照增强方法往往只考虑了其中的几种退化,或是将这些复杂多样的退化放在一起解决的做法,虽然能在亮度、色彩、纹理细节、噪声处理其中一个方面取得较好的效果,但难以同时在这些方面达到令人满意的效果的技术问题,本发明提出了一种基于Retinex的低光照图像增强方法,该方法为一种新颖的基于深度学习的有监督低光照图像增强方法。

[0061] 实施例一

[0062] 如图1和图2所示,以HSV颜色空间为例,基于Retinex的低光照图像增强方法具体包括:

[0063] S10、输入第一低光照图像,预构建的亮度处理模块LPM(Luminance Processing Module)对第一低光照图像的V通道(亮度通道)进行增强,得到亮度增强通道Venhanced。具体地,首先将第一低光照图像由RGB颜色空间转换到HSV颜色空间,使用亮度处理模块LPM对亮度通道进行增强,得到亮度增强通道Venhanced。其中第一低光照图像为训练样本中的低光照图像。

[0064] 亮度处理模块的构建方法包括构建初始化分解模块Init(Initialization Block)、构建展开求解模块(Unfolding Block)和构建亮度融合模块BIF(Illumination Fusion Block)。初始化分解模块用于将图像的亮度通道初步分解为R0和L0,其中R0为物体的原始反射分量,L0为环境光原始照射分量。展开求解模块用于求解亮度通道上的Retinex分解问题,得到准确的R和L。亮度融合模块用于将额外补充的均匀并且亮度充足的额外补充的新照明图 $\tilde{L}$ 与R一起送入亮度融合模块BIF,输出增强后的亮度增强通道Venhanced。

[0065] 在本实施例中,初始化分解模块为初始化卷积神经网络Init,初始化卷积神经网络

络Init由4层卷积层和激活函数构成,其中前3层卷积层的激活函数为LeakyReLU,最后一层卷积层的激活函数为ReLU。需要说明的是,初始化分解模块还可以采用其他传统的初始化方法实现,如: $L_0 = \max_c I^c, c \in \{R, G, B\}$

[0066] 亮度通道上的Retinex分解问题通常可以描述为:

$$[0067] \quad \min_{R,L} \|V - R \cdot L\|_F^2 + \alpha_1 \Omega_1(R) + \alpha_2 \Omega_2(L) \quad (2)$$

[0068] 其中 $\|V - R \cdot L\|_F$ 为F范数, $\min_{R,L} \|V - R \cdot L\|_F^2$ 为重构项,V为亮度通道,R为物体的反射分量,L为环境光照射分量, $\Omega_1(R)$ 和 $\Omega_2(L)$ 分别是R和L的正则项, $\alpha_1$ 和 $\alpha_2$ 为超参数。

[0069] 由于正常图像Inormal包含充足的场景信息,而反射图R代表着图像中的场景信息,所以本发明在亮度通道上的Retinex分解时,通过有监督学习来估计R,然后利用公式(1)来获得L,公式(1)为:

$$[0070] \quad L = V/R \quad (1)$$

[0071] 因此,本发明丢弃了在L上的正则项,来减少计算量,缩短将近一半的运行时间。此时亮度通道上的Retinex分解问题为:

$$[0072] \quad \min_{R,L} \|V - R \cdot L\|_F^2 + \alpha \Omega(R) \quad (3)$$

[0073] 为了更容易解决这个优化问题,本发明在亮度通道上的Retinex分解时引入辅助变量Z,此时亮度通道上的Retinex分解问题可以转化为:

$$[0074] \quad \min_{R,L} \|V - R \cdot L\|_F^2 + \alpha \Omega(Z) + \gamma \|Z - R\|_F^2 \quad (4)$$

[0075] 公式(4)中的 $\gamma$ 为一个超参数, $\Omega(Z)$ 为Z的正则项, $\|Z - R\|_F$ 为F范数;

[0076] 进而可以将公式(4)拆分为3个单变量子问题:

$$[0077] \quad \mathcal{O}(Z) = \alpha \Omega(Z) + \gamma \|Z - R\|_F^2 \quad (5)$$

$$[0078] \quad \mathcal{O}(R) = \|V - R \cdot L\|_F^2 + \gamma \|Z - R\|_F^2 \quad (6)$$

$$[0079] \quad \mathcal{O}(L) = \|V - R \cdot L\|_F^2 \quad (7)$$

[0080] 其中 $\mathcal{O}(Z)$ 为与辅助变量Z相关的子问题, $\mathcal{O}(R)$ 为与变量R相关的子问题, $\mathcal{O}(L)$ 为与变量L相关的子问题。传统方法中 $\Omega(Z)$ 是认为设计的,本发明则是用卷积神经网络 $\mathcal{U}_Z$ 从数据中学习得到 $\Omega(Z)$ ,使之能够适用于不同场景。子问题 $\mathcal{O}(R)$ 和 $\mathcal{O}(L)$ 都是最小二乘问题,可以通过使其一阶导数等于0求解。

[0081] 本发明采用迭代更新变量的方式求解亮度通道上的Retinex分解问题,每次迭代更新的公式为:

$$[0082] \quad Z_{k+1} = \mathcal{U}_Z(R_k; \theta_Z) \quad (9)$$

$$[0083] \quad R_{k+1} = \frac{\gamma Z_{k+1} + V \cdot L_k}{L_k \cdot L_k + \gamma} \quad (10)$$

$$[0084] \quad L_{k+1} = \frac{V}{R_{k+1}} \quad (11)$$

[0085] 其中 $\mathcal{U}_z$ 为卷积神经网络, $\theta_z$ 是卷积神经网络 $\mathcal{U}_z$ 的参数, $k$ 为迭代更新次数, $R_k$ 为第 $k$ 次迭代更新时的 $R$ 值, $R_{k+1}$ 为第 $k+1$ 次迭代更新时的 $R$ 值, $Z_{k+1}$ 为第 $k+1$ 次迭代更新时的 $Z$ , $L_k$ 为第 $k$ 次迭代更新时的 $L$ 值, $L_{k+1}$ 为第 $k+1$ 次迭代更新时的 $L$ 值。在一个具体的实施例中, $k$ 设置为3,此时能够兼顾运行时间和模型效果。迭代更新次数越多,估计出来的 $R$ 、 $L$ 越准确,但时间开销也越大。本领域技术人员可以根据实验情况,将 $k$ 设置为其他具体数值。

[0086] 第一低光照图像的亮度通道在通过初始化分解模块和展开求解模块之后,分解为 $R$ 和 $L$ 。由于 $L$ 只和获取图像时的光照相关,第一低光照图像与正常光照的 $L$ 可以是独立的、不相关的。因此,本发明与现有的其他方法不同,不对 $L$ 进行从低光照到正常光照的映射,而是额外补充一个亮度均匀的、亮度充足的额外补充的新照明图 $\tilde{L}$ ,并和 $R$ 一起送入亮度融合模块BIF,输出增强后的亮度增强通道 $V_{enhanced}$ 。这个过程可以描述为:

$$[0087] \quad V_{enhanced} = \mathcal{B}_{IF}(R_K, \tilde{L}; \theta_{IF}) \quad (12)$$

[0088] 其中 $R_K$ 为展开求解模块中最后一次迭代的 $R$ , $\theta_{IF}$ 为神经网络BIF的参数。为了确保额外补充的新照明图 $\tilde{L}$ 是均匀的,本发明先计算正常光照图像的照明图 $L_{normal}$ 的均值 $\omega$ ,然后将 $\omega$ 扩展成和 $R_K$ 相同尺寸,以获得额外补充的新照明图 $\tilde{L}$ 。 $\omega$ 的计算公式为:

$$[0089] \quad \omega = \text{mean}(L_{normal}) = \text{mean}\left(\frac{V_{normal}}{R_K}\right) \quad (13)$$

[0090] 亮度融合模块BIF包括5层卷积+激活函数,其中前4层激活函数是LeakyReLU,最后一层激活函数是ReLU。

[0091] S20、将亮度增强通道 $V_{enhanced}$ 与其他颜色通道重新组合,得到符合亮度要求且存在色彩退化的第一增强图像 $I_{obe}$ ,其他颜色通道指的是除亮度通道以外的其他颜色通道。具体地,以HSV颜色空间为例,将亮度增强通道 $V_{enhanced}$ 与 $H$ 、 $V$ 颜色通道重新组合,得到符合亮度要求且存在色彩退化的第一增强图像 $I_{obe}$ 。

[0092] S30、预构建的色彩恢复模块CRM处理第一增强图像的色彩退化,得到第二增强图像 $I_{enhanced}$ 。

[0093] CRM由一个色彩恢复网络CRNet构成,色彩恢复模块包括主干网络、下采样第一分支网络和下采样第二分支网络。其中主干网络由8层卷积层和激活函数构成,其中前7层卷积层的激活函数为LeakyReLU,第8层的激活函数为ReLU,主干网络的第1层卷积层与第7层卷积后的特征图堆叠拼接并参与下一次卷积,主干网络的第2层卷积层与第6层卷积后的特征图堆叠拼接并参与下一次卷积,主干网络的第3层卷积层与第5层卷积后的特征图堆叠拼接并参与下一次卷积;下采样第一分支网络的第1层卷积层与第3层卷积后的特征图堆叠拼接并参与下一次卷积。

[0094] 主干网络卷积2次后对得到的特征图进行下采样并进入到下采样第一分支网络,下采样第一分支网络经过4层卷积层和激活函数后对得到的特征图进行上采样,并与主干网络第6次卷积得到的特征图拼接并参与下一次卷积。

[0095] 下采样第一分支网络经过一次卷积后进行下采样并进入下采样第二分支网络,下采样第二分支网络经过2层卷积层和激活函数后进行上采样,并与下采样第一分支网络第3次卷积得到的特征图拼接并参与下一次卷积。

[0096] 此外,下采样第一分支网络和下采样第二分支网络上采样后拼接的特征图都采用了SE模块进行特征融合,SE模块的结构如图3所示。采用下采样第一分支网络和下采样第二分支网络,能有效扩大特征图的感受视野,有利于恢复图像细节。引入SE模块,则能有效融合图像特征,有利于图像整体的色彩恢复。CRNet网络的详细信息如表1所示。

[0097] 表1.CRNet网络的详细信息

[0098]

所属分支	输入	操作	输出
主干	Iobe	Conv & LeakyReLU	F1
	F1	Conv & LeakyReLU	F2
	F2	Conv & LeakyReLU	F3
	F3	Conv & LeakyReLU	F4
	F4	Conv & LeakyReLU	F5
	F5、F3	Concatenation	CF1
	CF1	Conv & LeakyReLU	F6
	F6、F2、UF1	Concatenation	CF2
	CF2	SE & Conv & LeakyReLU	F7
	F7、F1	Concatenation	CF3
	CF3	Conv & ReLU	Ienhanced
下采样第一分支	F2	Maxpool	DF1
	DF1	Conv & LeakyReLU	DF2
	DF2	Conv &	DF3

[0099]		LeakyReLU	
	DF3	Conv & LeakyReLU	DF4
	DF4、DF2、UF2	Concatenati on	CDF1
	CDF1	SE & Conv & LeakyReLU	DF5
	DF5	Upsample	UF1
下采样第二 分支	DF1	Maxpool	DDF1
	DDF1	Conv & LeakyReLU	DDF2
	DDF2	Conv & LeakyReLU	DDF3
	DDF3	Upsample	UF2

[0100] S40、使用正常图像对第二增强图像进行监督学习,更新亮度处理模块和色彩恢复模块的参数,以构建全场景低光照图像都适用的低光照模型。

[0101] 训练初始化分解模块的损失函数如下:

$$[0102] \quad \mathcal{L}_{init} = \|V - R_0 \cdot L_0\|_1 + \|L_0^T L_0 - \lambda E_n\|_F^2 \quad (8)$$

[0103] 其中 $E_n$ 为单位矩阵,第二约束项 $\|L_0^T L_0 - \lambda E_n\|_F^2$ 是为了防止 $L_0$ 全为0, $T$ 为矩阵的转置操作。

[0104] 展开求解模块和亮度融合模块是共同训练的,其损失函数为:

$$[0105] \quad \mathcal{L}_p = \sum_{k=1}^K \gamma \|Z_k - R_k\|_F^2 + 1 - SSIM(V_{enhanced}, V_{normal}) + \|\phi(R_k) - \phi(V_{enhanced})\|_1 + \|V_{enhanced} - V_{normal}\|_F^2 \quad (14)$$

[0106] 其中 $\phi(R_k)$ 为经过VGG19神经网络特征提取器提取的 $R_k$ 中的特征, $\phi(V_{enhanced})$ 为经过VGG19神经网络特征提取器提取的 $V_{enhanced}$ 中的特征, $SSIM(V_{enhanced}, V_{normal})$ 为 $V_{enhanced}$ 和 $V_{normal}$ 的结构相似度, $\gamma$ 为超参数, $Z_k$ 为展开求解模块中最后一次迭代的 $Z$ , $V_{normal}$ 为亮度正常通道。

[0107] 色彩恢复模块训练时的损失函数为:

$$\begin{aligned}
 \mathcal{L}_{Cr} = & \|I_{enhanced} - I_{normal}\|_F^2 + \|\nabla I_{enhanced} - \nabla I_{normal}\|_F^2 + 1 \\
 [0108] & - SSIM(I_{enhanced}, I_{normal}) \quad (15)
 \end{aligned}$$

[0109] 公式(15)中的 $I_{normal}$ 为正常图像,  $\nabla$ 为梯度运算符, 包含水平和垂直方向,  $SSIM(I_{enhanced}, I_{normal})$ 为 $I_{enhanced}$ 和 $I_{normal}$ 的结构相似度。

[0110] S50、将第二低光照图像输入预先训练的低光照模型, 得到增强后的目标图像。第二低光照图像为输入样本中的图像。

[0111] 通过应用Retinex理论在保持图像纹理的同时增强亮度, 并分两步依次解决纹理退化、色彩退化, 本发明的模型相比其他方法能更有效地处理各类型的退化, 从亮度、对比度、色彩、纹理细节各个方面提升低光照图像的质量。

[0112] 图4和图5是本发明的增强方法与其他方法的比较。其他方法可能在亮度、纹理、噪声抑制、色彩其中某一方面表现得不错, 而本发明的方法不仅能在保持纹理清晰的前提下有效提高亮度、对比度和抑制噪声, 在色彩恢复上更加自然。

[0113] 需要说明的是, 本发明中的亮度调节模块除了能对HSV颜色空间中的亮度通道使用, 也可以对Lab、YUV、YCbCr等其他颜色空间中的亮度通道使用。

[0114] 实施例二

[0115] 基于上述基于Retinex的低光照图像增强方法, 本发明提供了一种计算机可读存储介质, 计算机可读存储介质存储有一个或者多个程序, 一个或者多个程序可被一个或者多个处理器执行, 以实现如上的基于Retinex的低光照图像增强方法中的步骤。

[0116] 实施例三

[0117] 基于上述基于Retinex的低光照图像增强方法, 本发明还提供了一种终端, 如图6所示, 至少包括一个处理器10; 显示屏11; 以及存储器12, 还可以包括通信接口13和总线14。其中处理器10、显示屏11、存储器12和通信接口13可以通过总线14完成相互间的通信。显示屏11设置为显示初始设置模式中预设的用户引导界面。通信接口13可以传输信息。处理器10可以调用存储器12中的逻辑指令, 以执行上述实施例中的方法。

[0118] 此外, 上述的存储器12中的逻辑指令可以通过软件功能单元的形式实现并作为独立的产品销售或使用, 可以存储在一个计算机可读取存储介质中。

[0119] 存储器12作为一种计算机可读存储介质, 可设置为存储软件程序、计算机可执行程序, 如本公开实施例中的方法对应的程序指令或模块。处理器10通过运行存储在存储器12中的软件程序、指令或模块, 从而执行功能应用以及数据处理, 即实现上述实施例中的方法。

[0120] 存储器12可包括存储程序区和存储数据区, 其中, 存储程序区可存储操作系统、至少一个功能所需的应用程序; 存储数据区可存储根据终端设备的使用所创建的数据等。此外, 存储器12可以包括高速随机存取存储器, 还可以包括非易失性存储器。例如, U盘、移动硬盘、只读存储器(Read-Only Memory, ROM)、随机存取存储器(Random Access Memory, RAM)、磁碟或者光盘等多种可以存储程序代码的介质, 也可以是暂态存储介质。

[0121] 此外, 上述存储介质以及终端设备中的多条指令处理器加载并执行的具体过程在上述方法中已经详细说明, 在这里就不再一一陈述。

[0122] 综上所述,本发明针对低光照图像中的复杂退化,本发明采用逐个解决思路,将复杂的问题分解为多个相对简单的问题进行求解。考虑到这些退化不全是互相独立的,本发明粗略将这些退化分为纹理退化、色彩退化两大类,分别建模依次解决。为了处理纹理退化,本发明首先关注亮度调整和纹理保存,提出了一个基于Retinex的亮度处理模块LPM,仅对第一低光照图像的亮度通道进行增强,得到亮度增强通道。在处理完纹理退化后,本发明将亮度增强通道与其他颜色通道重新组合,得到符合亮度要求且存在色彩退化的第一增强图像。接着利用色彩恢复模块来处理第一增强图像的色彩退化,得到第二增强图像。本发明通过应用Retinex理论在保持图像纹理的同时增强亮度,并分两步依次解决纹理退化、色彩退化,所构建的模型相比其他方法能更有效地处理各类型的退化,从亮度、对比度、色彩、纹理细节各个方面提升低光照图像的质量。

[0123] 本发明将经典Retinex分解问题中对R的约束项 $\Omega(R)$ ,由传统的人为设计改为使用卷积神经网络自适应拟合,估计出R后,可以利用 $L=V/R$ 来获得L,因此本发明丢弃了在L上的正则项,来减少计算量,缩短将近一半的运行时间。

[0124] 传统的基于模型优化方法中关于R、L的正则项都是人工设计的,难以适用于复杂的场景。本发明将深度学习与基于模型优化两者相结合,采用展开求解的方式(迭代更新变量)求解Retinex分解问题,本发明使用卷积神经网络从数据中学习一个自适应的正则项,能大大提升模型泛化性能。

[0125] 最后应说明的是:以上实施例仅用以说明本申请的技术方案,而非对其限制;尽管参照前述实施例对本申请进行了详细的说明,本领域的普通技术人员应当理解:其依然可以对前述各实施例所记载的技术方案进行修改,或者对其中部分技术特征进行等同替换;而这些修改或者替换,并不使相应技术方案的本质脱离本申请各实施例技术方案的精神和范围。

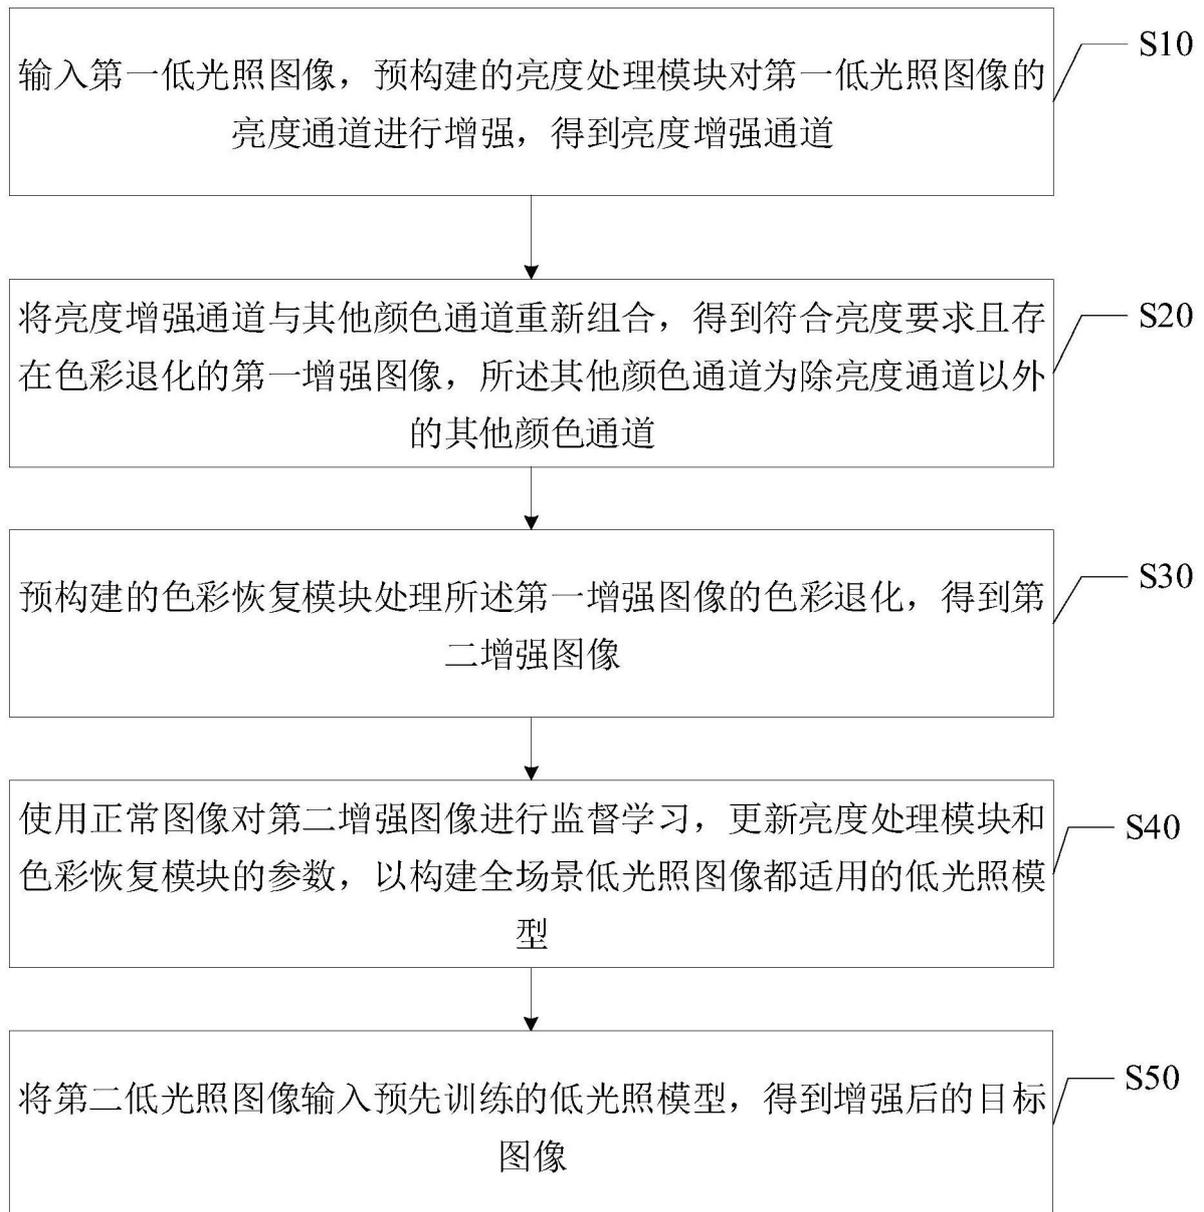


图1

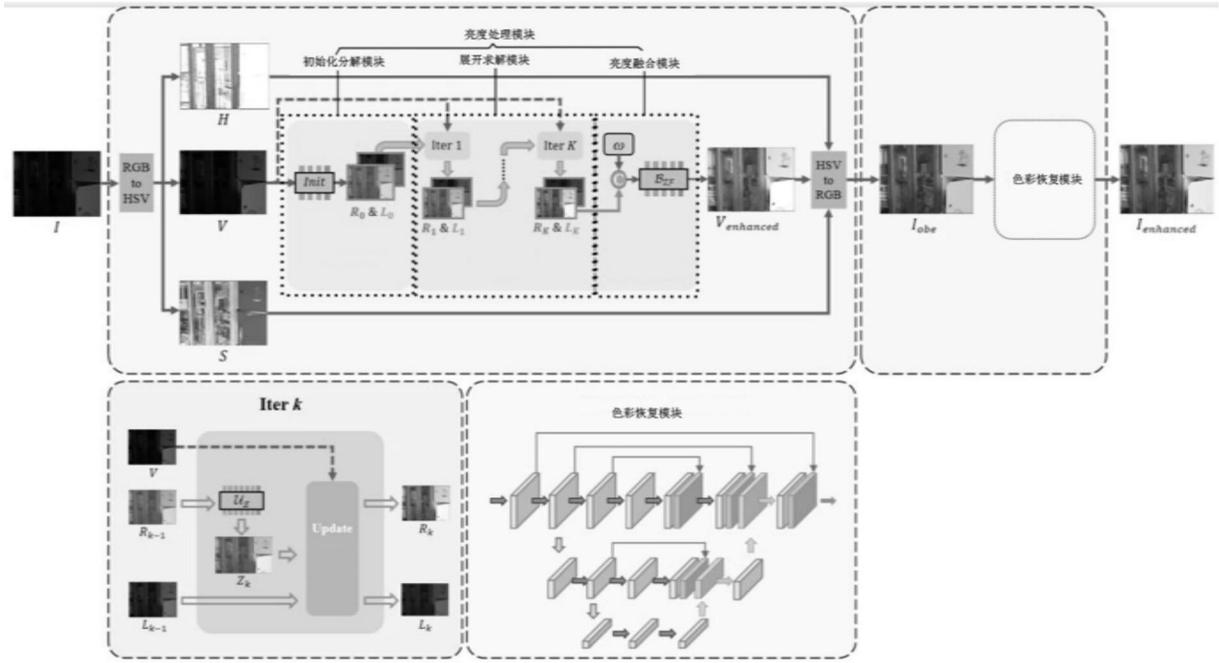


图2

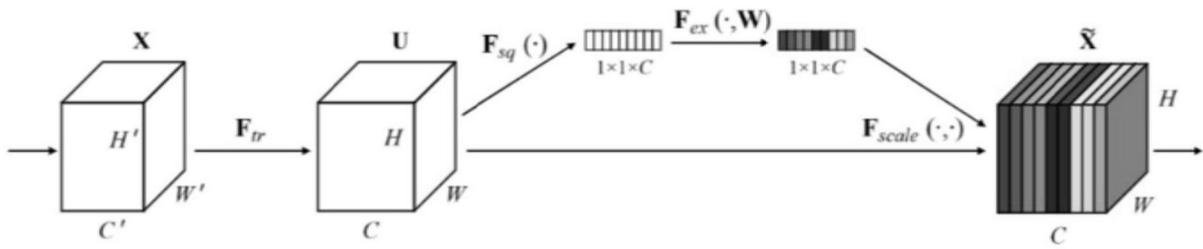


图3

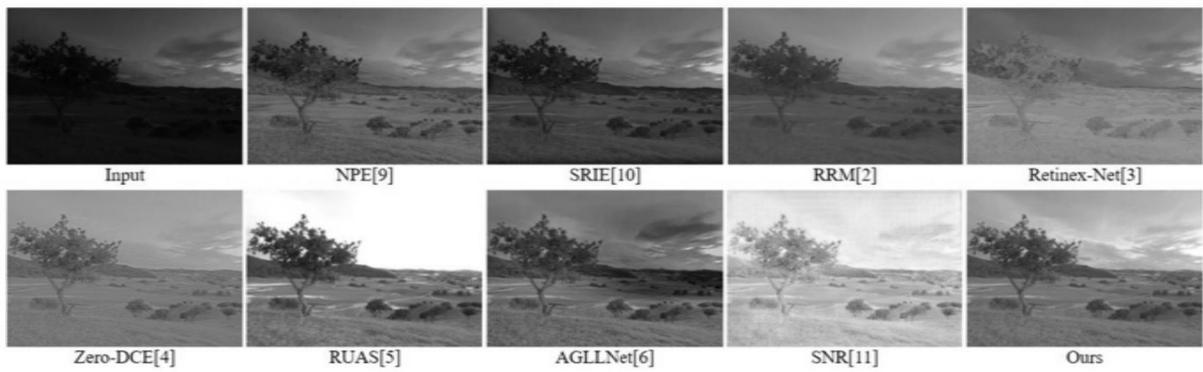


图4

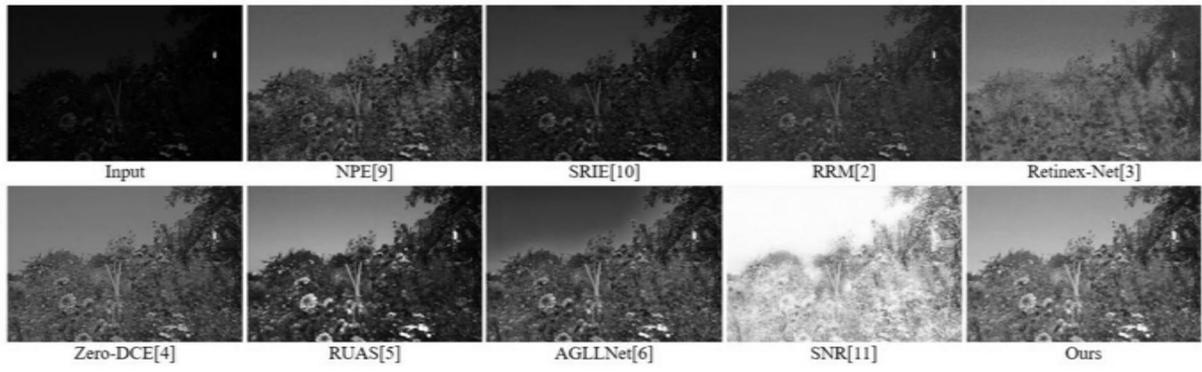


图5

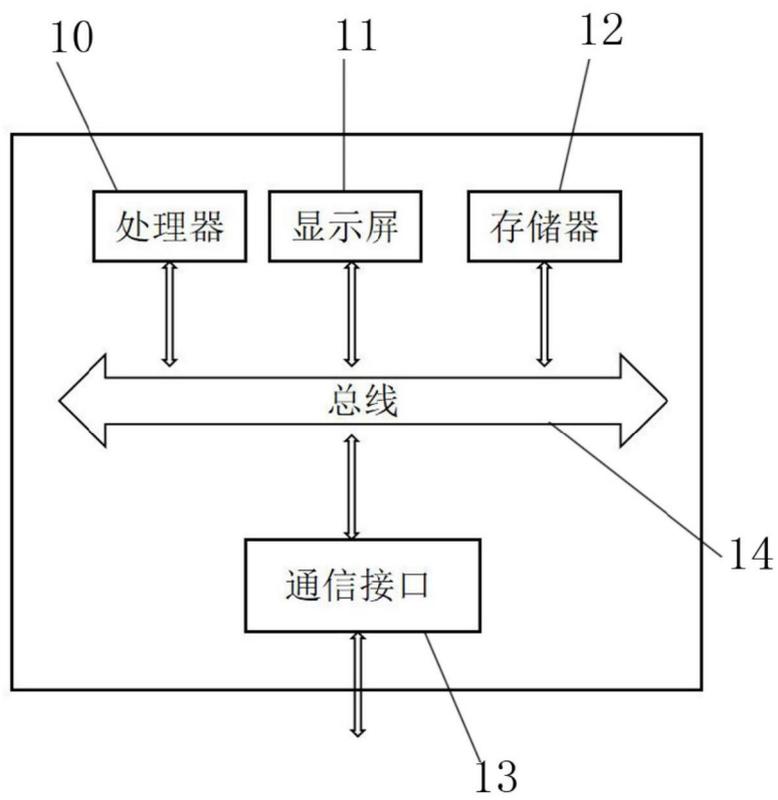


图6