

中国计算机学会

发给 824818194

2024-06-05 18:04 隐藏信息

发件人: 中国计算机学会 <conf@notice.ccf.org.cn>

收件人: 824818194 <824818194@qq.com>

时间: 2024年6月5日 (周三) 18:04

大小: 10 KB

李潇瑶您好:

您向CCF第39届中国计算机应用大会所投的稿件“P00436-GRM:基于全局鲁棒Retinex模型的多通道弱光图像增强算法”的审核结果如下:

## 程序主席意见:

审核结果: 录用

审核意见: 拟录取推荐中文核心期刊(将被北大核心检索,同时部分期刊还为CSCD、科技核心等数据库检索)。请于6月15日前完成“论文作者”的类别缴费,出版委员会将根据注册缴费情况,陆续通知作者后续工作,未按期注册缴费的作者,视为放弃录取。详情可参考会议官网相关通知。请加入QQ群(464928684),以便及时获得相关消息。

具体审核意见如下:

## 专家意见:

专家1:

审核意见: 弱光增强被广泛用于提高低光照环境下数字图像的质量。论文“GRM:基于全局鲁棒Retinex模型的多通道弱光图像增强算法”,设计了一种用于处理彩色图像所有色彩通道的弱光增强算法。该算法利用分数阶范式梯度,提高照明图的光滑性,通过权重矩阵防止过度平滑并保留更多细节。文中实验表明,通过不同数据集与已有方法相比,该算法具备很强的去噪能力及鲁棒性,在各项指标上均有较好的表现,具备实用性。因此,建议按照如下几点完善后录用该论文。

-----文中的方程( )均需改为公式( )或式( ),因为很多公式并非方程。

-----文中向量或矩阵的加粗情况要一致,如公式(14)中D为粗体,而后续说明文字中D没有加粗。

-----在公式(2)(3)之间同为解释公式(2)意义的语句不要分段。

-----公式(3)下一段中,“正则化子”建议改为“正则化因子”。

-----在2.2节的1)的第一段中,建议简要叙述对I进行预处理的作用。

- 公式(8)下一段中, 建议简单叙述参数序列设置为这些数值的理由。
- 公式(8)上一段中, 首次出现 $P_h$ ,  $P_v$ 时, 并没有说明它们代表的含义。
- 公式(9)中, if应改为若, otherwise应改为其它或其余, 使得表述语言一致。
- 2.2节末尾, 请简要说明参数 $\epsilon$ 和 $K$ 的取值理由。
- 建议在结论中简要说明算法的运行时间。
- 缺少中文参考文献的引用。

## 专家2:

审核意见: 该论文提出了一种基于Retinex模型的多通道弱光图像增强算法。该工作在算法创新性和实验结果上表现一般。

论文存在的主要问题和可以提升的建议如下:

### 1. 算法参数和实验细节的说明不足:

在2.2节中, 求解参数 $W$ 时缺少参数序列取值的理由。建议补充这些参数选择的具体理论或实验依据。对应实验部分缺少对参数变化的讨论及其对结果的影响分析。建议增加相关参数的敏感性分析或对比实验, 以验证参数选择的有效性。

### 2. 数据集的详细描述不够充分:

在3.1节关于数据集的描述中, 应明确指出第一个和第二个数据集的具体名称和来源。应提供数据的分辨率范围, 以便读者能够更好地理解实验条件。图2缺乏必要的说明, 未指明图像分别来自哪个数据集。建议在图注中明确标示。

### 3. 文献回顾的时效性和相关性不足:

参考文献部分缺乏对最新深度学习方法引用和讨论, 例如2023年发表的“Retinexformer: one-stage retinex-based transformer for low-light image enhancement”的研究。建议更新文献回顾部分, 加入这些最新的研究进展。

4. 文章中仅提供了两个定量比较结果, 缺乏足够的实验来支撑结论。建议增加更多的实验结果, 例如定性的视觉比较和更多定量评估指标。

### 5. 关于一些写作的小问题:

摘要的第一句需要进一步精炼和明确, 以更好地概括研究的重点和贡献。常识性内容如PSNR和SSIM的详细描述和公式(如公式24、25)应省略, 以避免文章内容的冗余。

程序委员会主席

2024-06-05

【备注】此为系统邮件，请勿直接回复。

17日

多功能1厅

17:50-18:00	P00417	兰亚杰	基于区块链的图像数字版权保护系统研究
13:30-13:40	P00418	孙明辰	融合图胶囊网络与因果推理的疾病预测
13:40-13:50	P00422	贾文玉	不确定性感知的标签噪声校正算法
13:50-14:00	P00423	屈昌盛	基于离散余弦变换的联邦学习后门攻击
14:00-14:10	P00436	吴翰宁	GRM: 基于全局鲁棒Retinex模型的多通道弱光图像增强算法
14:10-14:20	P00437	王婧婧	基于元学习的标签噪声自适应学习算法
14:20-14:30	P00440	史东辉	基于模拟数据的古建筑火灾检测改进算法研究
14:30-14:40	P00449	毕远萌	基于图注意力机制的软件发行说明自动生成方法
14:40-14:50	P00453	武涛	基于猫群优化算法的多目标边缘任务调度研究
14:50-15:00	P00465	姚黎东	工业主数据管理实践综述
15:00-15:10	P00466	秦学程	面向工业场景的云边协同数据存储与检索架构
15:10-15:20	P00468	金碧	基于多尺度特征翻转并融合的车道线检测方法
15:20-15:30	P00469	王怡梦	融合多模态信息知识感知推荐方法
15:30-15:40	P00475	贾志洋	基于并行优化CBAM的轻量级轴承故障诊断模型
15:40-15:50	P00483	张策	复杂工况下的轴承故障诊断方法综述

【电子与信息科学 / Electronics and Information Science】

# 基于全局鲁棒 Retinex 模型的多通道弱光图像增强

吴翰宁<sup>1</sup>, 易积政<sup>2</sup>, 李潇瑶<sup>2</sup>, 李思佳<sup>2</sup>

1) 中南林业科技大学电子信息与物理学院, 湖南长沙 410004; 2) 中南林业科技大学前沿交叉学科学院, 湖南长沙 410004

**摘要:** 针对现有增强光照方法忽略不同光照下色相和饱和度的变化, 且在抑制噪声的同时丢失过多细节信息的问题, 基于 Retinex 理论提出一种在所有色彩通道上增强光照的全局鲁棒 Retinex 模型 (global robust Retinex model, GRM). 采用收缩映射实现分数阶范数, 使分解出的照明图更平滑; 针对反射图梯度, 采用基于输入图像信息计算得到的权重矩阵和正则项来获取噪声少、细节多的反射图; 选择交替方向乘法对模型进行求解, 并通过伽玛校正获取理想照明图; 将处理后的反射图与照明图合并得到最终结果. 在 Adobe FiveK、DICM、VV 和 LIME 数据集上的实验结果表明, GRM 不仅在峰值信噪比、结构相似度、图像质量评估指标等方面可以与鲁棒 Retinex 模型、低秩正则化 Retinex 模型和即插即用 Retinex 模型等方法相媲美, 而且降噪能力更强, 图像光照恢复更明显. GRM 为弱光照环境下拍摄到的含噪声图像的增强处理提供了更优的解决方案.

**关键词:** 计算机图像; 弱光图像增强; Retinex 模型; 交替方向乘法; 分数阶范数; 图像降噪

**中图分类号:** TP391.4; TP37 **文献标志码:** A **DOI:** 10.3724/SP.J.1249.2025.03326

## Multi-channel low-light image enhancement method based on global robust Retinex model

WU Hanning<sup>1</sup>, YI Jizheng<sup>2</sup>, LI Xiaoyao<sup>2</sup>, and LI Sijia<sup>2</sup>

1) College of Electronic Information and Physics, Central South University of Forestry and Technology, Changsha 410004, P. R. China

2) College of Advanced Interdisciplinary Studies, Central South University of Forestry Technology, Changsha 410004, P. R. China

**Abstract:** In response to the issues where existing illumination enhancement methods ignore the changes in hue and saturation under different lighting conditions, resulting in the loss of excessive detail information while suppressing noise, we propose a global robust Retinex model (GRM) based on the Retinex theory to enhance illumination across all color channels. A contraction mapping is used to implement fractional-order norms, making the decomposed illumination map smoother. For the reflection map gradient, we employ a weight matrix and regularization term calculated based on the input image information to obtain a reflection map with less noise and more details. The alternating direction method of multipliers is chosen to solve the model, and gamma correction is applied to obtain the ideal illumination map. The processed reflection map is then combined with the illumination map to yield the final result. Experimental results on the Adobe FiveK, DICM, VV, and LIME datasets show that GRM not only competes with methods such as the robust Retinex model, low-rank regularization Retinex model, and plug-and-play Retinex model in terms of peak signal-to-noise ratio, structural similarity, and image quality assessment metrics, but also demonstrates stronger denoising capabilities and more significant image lighting recovery. The GRM model

**Received:** 2024-07-10; **Accepted:** 2024-11-27; **Online (CNKI):** 2025-01-23

**Foundation:** Hunan Provincial Graduate Research Innovation Project (CX20240692); Graduate Research Innovation Fund Project of Central South University of Forestry and Technology (2023CX02091)

**Corresponding author:** Professor YI Jizheng (T20152279@csuft.edu.cn)

**Citation:** WU Hanning, YI Jizheng, LI Xiaoyao, et al. Multi-channel low-light image enhancement method based on global robust Retinex model [J]. Journal of Shenzhen University Science and Engineering, 2025, 42(3): 326-333. (in Chinese)

**Open access:** This article is licensed under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).



provides a superior solution for enhancing noisy images captured in low-light environments.

**Key words:** computer image; low-light image enhancement; Retinex model; alternating direction method of multipliers; fractional-order norm; image denoising

环境光照条件不佳时拍摄的图像常会出现能见度低、对比度低和噪声严重等现象, 因此, 弱光图像增强算法被广泛用于补偿拍摄到影像的光照, 以使得边缘和细节更清晰. 在计算机视觉研究发展的早期, 有学者提出几类弱光图像增强算法: 基于直方图均衡的方法<sup>[1]</sup>, 此方法常存在照明不均匀或增强不适当问题; 去雾算法, DONG 等<sup>[2]</sup>指出反转的弱光图像与含雾的图像相似; 曝光融合算法, 此方法可以准确增强对比度和亮度<sup>[3]</sup>.

近期基于学习的方法得到了很多关注. 赵明华等<sup>[4]</sup>在增强弱光图像的 U-Net 网络中引入了注意力机制. WANG 等<sup>[5]</sup>基于 Retinex 理论设计网络结构. CAI 等<sup>[6]</sup>将变换器(Transformer)引入弱光图像领域. 陈彬等<sup>[7]</sup>结合了 Transformer 和卷积神经网络各自的优势. 但是, 这些方法通常都需要大量的训练数据, 当测试图像与训练数据集相比差异较大时, 增强后的图像可能存在明显的伪影.

LAND<sup>[8]</sup>提出的 Retinex 理论对人类视觉系统如何捕捉光和颜色进行了建模. JOBSON 等<sup>[9]</sup>提出了多尺度 Retinex 模型, 将分解出的反射图作为结果, 但不考虑照明图会不自然或过度增强. WANG 等<sup>[10]</sup>提出自然度保持弱光图像增强算法, 既能增强细节又能保持图像自然度. 基于全变分的方法在计算机视觉领域得到了广泛应用, 如李潇瑶等<sup>[11]</sup>将全变分用于图像去噪. 还有许多基于 Retinex 模型的方法<sup>[12-16]</sup>在分解照明图和反射图的过程也应用了全变分, 同样增强了显示效果.

近年来出现了一些考虑噪声抑制的基于 Retinex 模型的弱光增强算法. LI 等<sup>[17]</sup>首次尝试在 Retinex 模型中估计噪声图并且弃用对数变换. REN 等<sup>[18]</sup>通过引入低秩正则化, 在处理图像的全过程中抑制了噪声. LIN 等<sup>[19]</sup>在对照明图进行自引导滤波和  $L_p$  范式的同时, 设计了一个权重矩阵来抑制反射图的噪声并保留纹理. 遗憾的是, 这些处理都仅停留在 HSV(hue, saturation, value)颜色模型中的亮度通道上进行, 忽视了色相通道和饱和度通道中的噪声, 因此降噪能力有限.

本研究提出一个能够在 RGB 色彩空间中同时处理所有色彩通道的基于全局鲁棒 Retinex 模型(global robust Retinex model, GRM)的多通道弱光图

像增强算法, 主要贡献包括: ① 对所有色彩通道进行 Retinex 模型分解, 完整处理 R、G 和 B 三个通道的噪声; ② 使用序列分解的策略获取照明图, 将图像中的噪声尽可能分配给反射图<sup>[17]</sup>, 同时使用分数阶范数约束照明图梯度, 以保持照明图的分区平滑; ③ 同时使用基于输入图像信息计算出的反射图梯度权重矩阵和针对 RGB 全通道设计的抑制小梯度、放大其余梯度的反射图梯度正则项, 以防止反射图过度平滑并保留更多边缘和纹理细节.

## 1 经典 Retinex 模型和变分 Retinex 模型

根据 Retinex 理论, 图像  $I$  可分解为照明图分量  $L$  和反射图分量  $R$ , 即

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

其中,  $\circ$  为哈达玛积操作符;  $L$  描述图像的光照强度, 逐片连续且无纹理;  $R$  描述了图像中物体的物理特性, 包含图像的纹理和细节. 对图像  $I$  的 Retinex 分解可由变分优化模型(2)实现.

$$\arg \min_{L, R} \left( \alpha \|L^{(\tau)} \circ R^{(\tau)} - I\|_F^2 + \beta \|\nabla L^{(\tau)}\|_F^2 + \lambda \|\nabla R^{(\tau)}\|_F^2 \right) \quad (2)$$

其中,  $\alpha$ 、 $\beta$  和  $\lambda$  为各正则项的权重参数;  $\tau$  为迭代次数;  $\|L^{(\tau)} \circ R^{(\tau)} - I\|_F^2$  为保真项;  $\|\cdot\|_F$  为求矩阵的 Frobenius 范数操作. 为降低乘法运算的复杂度, 模型(2)可转换成对数形式来计算<sup>[13]</sup>, 然而这会使正则化因子被隐式加权, 因此本研究选择直接处理原始图像.

## 2 GRM

本研究提出的光照增强方法采用 Retinex 理论, 目标是分解出最理想的照明层和反射层分量. 输入 1 幅彩色图像, 归一化处理后同时在 3 个颜色通道上分别执行算法. 估计出的照明层和反射层分量, 经伽玛校正后组合为最后的输出图像. 图 1 为 GRM 总体框架图.

### 2.1 模型提出

求解反射图和照明图分量的 Retinex 模型为

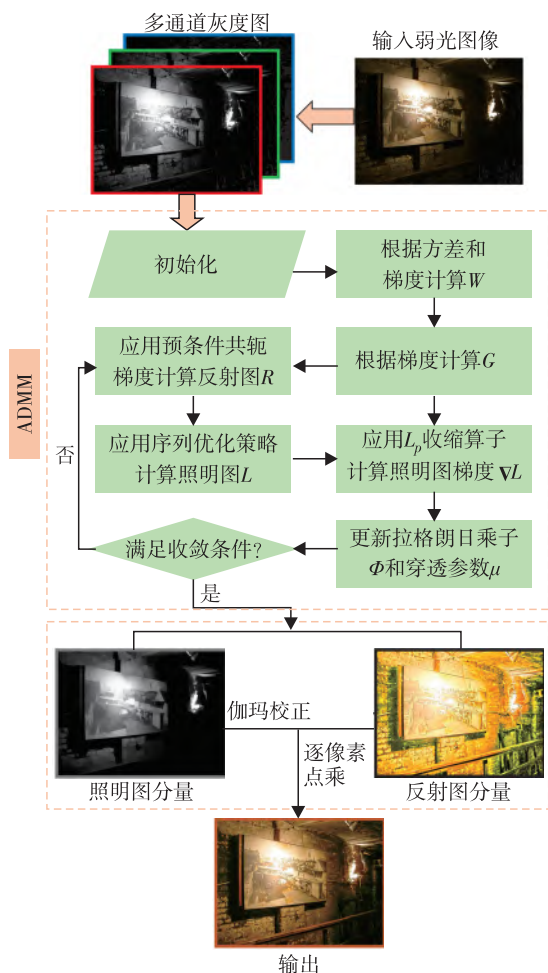


图1 GRM总体框架图

Fig. 1 Overall framework of GRM.

$$\arg \min_{L, R} \left( \alpha \|L^{(\tau)} \circ R^{(\tau)} - I\|_F^2 + \beta \|\nabla L^{(\tau)}\|_p^p + \delta \|W \circ (\nabla R^{(\tau)} - G)\|_F^2 \right) \quad (3)$$

其中,  $\alpha$ 、 $\beta$ 和 $\delta$ 为各正则项的权重参数;  $W$ 为约束反射图梯度的权重矩阵;  $G$ 为输入图像的梯度 $\nabla I$ 过滤掉小梯度并放大大梯度后的替代项. 本研究同时使用了水平梯度和垂直梯度, 来实现完整利用像素点周围信息. 模型(3)中,  $\|L^{(\tau)} \circ R^{(\tau)} - I\|_F^2$ 可确保模型输出接近于输入图像;  $\|\cdot\|_p^p$ 为求矩阵的分数阶范数操作,  $\|\nabla L^{(\tau)}\|_p^p$ 用于约束照明图, 使其分段平滑;  $\|W \circ (\nabla R^{(\tau)} - G)\|_F^2$ 约束反射图, 实现降噪和保留反射图中边缘和纹理细节的效果.

选择交替方向乘子法 (alternating direction method of multipliers, ADMM) 优化目标模型. 用辅助变量  $T$  代替  $\nabla L^{(\tau)}$ , 则模型(3)的增广拉格朗日函数可写为

$$\begin{aligned} \mathcal{L} = & \alpha \|L^{(\tau)} \circ R^{(\tau)} - I\|_F^2 + \beta \|T\|_p^p + \\ & \delta \|W \circ (\nabla R^{(\tau)} - G)\|_F^2 + \\ & \langle \Phi, \nabla L^{(\tau)} - T \rangle + \frac{\mu}{2} \|\nabla L^{(\tau)} - T\|_F^2 \end{aligned} \quad (4)$$

其中,  $\Phi \in \mathbb{R}^{M \times N \times 3}$ 为拉格朗日乘子,  $M$ 和 $N$ 分别为输入图像水平和垂直方向上的像素数量;  $\mu$ 为正惩罚参数;  $\langle \cdot, \cdot \rangle$ 表示计算矩阵的内积. 优化模型的极小值即为 $\mathcal{L}$ 的鞍点.  $\mathcal{L}$ 中的5个变量 $L^{(\tau)}$ 、 $R^{(\tau)}$ 、 $T$ 、 $\Phi$ 和 $\mu$ 可由子问题迭代求解得出.

## 2.2 子问题求解

### 2.2.1 求解 $W$

首先求解反射图分量梯度 $\nabla R^{(\tau)}$ 的 $W$ . 限制 $\nabla R^{(\tau)}$ 有助于模型优化<sup>[18]</sup>.  $W$ 可分区域检测输入图像的特征, 保护反射图分量纹理和边缘尽可能清晰, 有效保留暗部纹理细节.  $W$ 中每个元素的值都是由函数 $f_1$ 和 $f_2$ 计算得来, 如式(5). 令 $I' = I^{1/\gamma}$ ,  $\gamma = 2.2$ , 可得到更明亮的 $I'$ , 来计算更准确的 $W$ .

$$W(x, y) = f_1(I'(x, y))^\omega \times f_2(I'(x, y))^\omega \quad (5)$$

$$f_1(I'(x, y)) = 1 - \min \left( K_1 |g_{a, \sigma} \{ [I'(x, y)]^2 \} - \{ g_{a, \sigma} [I'(x, y)] \}^2, 1 \right) \quad (6)$$

$$f_2(I'(x, y)) = 1 - \max \left( P_h(I'(x, y)), P_v(I'(x, y)) \right) \quad (7)$$

其中,  $(x, y)$ 为像素坐标;  $K_1$ 为放大参数.  $f_1$ 的计算基于 $I'(x, y)$ 相邻区域中的局部方差. 为抑制噪声, 应用低通高斯滤波器 $g_{a, \sigma}$ 计算该局部方差,  $a$ 为核大小,  $\sigma$ 为标准差. 使用最小值函数可将 $f_1$ 的结果限制在 $[0, 1]$ . 平坦区域中的较小方差会导致 $f_1$ 接近1, 反之较大方差会使 $f_1$ 接近0. 遵循文献[18]在HSV色彩空间中亮度通道上的实验经验, 设置式(5)至式(7)中的 $K_1 = 4\ 500$ ,  $a = 5$ ,  $\sigma = 2$ ,  $\omega = 1.25$ .  $f_2$ 的值与 $I'$ 的水平梯度和垂直梯度有关. 在计算 $f_2$ 之前, 同样要在梯度图上应用 $g_{a, \sigma}$ . 分别对 $I'$ 在水平和垂直方向上的梯度 $\nabla I'_h$ 和 $\nabla I'_v$ 进行调整,  $P_h(I') = \min(K_2 |g_{a, \sigma}(\nabla I'_h)|, 1)$ ,  $P_v(I') = \min(K_2 |g_{a, \sigma}(\nabla I'_v)|, 1)$ ,  $P_h$ 和 $P_v$ 中取值更大者决定函数 $f_2$ 的结果. 若 $I'(x, y)$ 在某一方向上梯度较大, 则权重往往较低. 其中,  $K_2 = 220$ .

### 2.2.2 求解 $G$

为抑制反射图平滑区域的梯度并最大化保持边缘, 采用文献[16-17]方法调整输入图像的梯度后

得到

$$G = \left(1 + \lambda_1 e^{-|\nabla I|/\lambda_2}\right) \circ \nabla I'' \quad (8)$$

$$\nabla I'' = \begin{cases} 0, & |\nabla I(x, y)| < \epsilon \\ \nabla I, & \text{其他} \end{cases} \quad (9)$$

其中,  $\lambda_1$  控制放大的程度;  $\lambda_2$  控制不同梯度的放大率;  $\epsilon$  为过滤小梯度的阈值, 用来抑制噪声. 本研究中分别设  $\epsilon = 1$ ,  $\lambda_1 = 2.5$ ,  $\lambda_2 = 10^{[17]}$ .

### 2.2.3 更新 $R$ 的子问题

保留与  $R$  相关的项, 得到子问题

$$\operatorname{argmin}_R \left( \alpha \|L^{(\tau)} \circ R^{(\tau+1)} - I\|_F^2 + \delta \|W \circ (\nabla R^{(\tau+1)} - G)\|_F^2 \right) \quad (10)$$

其中,  $L^{(\tau)}$  为第  $\tau$  次迭代  $L$  的结果,  $L^{(0)}$  初始化为输入图像  $I$ .

将矩阵  $R$ 、 $I$  和  $G$  分别变为向量形式  $r$ 、 $i$  和  $g$ , 则式(10)变形为

$$\operatorname{argmin}_r \left( \alpha \|\hat{L}^{(\tau)} r^{(\tau+1)} - i\|_2^2 + \delta \|\hat{W}(\nabla r^{(\tau+1)} - g)\|_2^2 \right) \quad (11)$$

其中,  $\hat{L}^{(\tau)}$  和  $\hat{W}$  分别是  $L^{(\tau)}$  和  $W$  的对角矩阵表示. 令式(11)对  $r^{(\tau+1)}$  的一阶导数为 0, 得到

$$\alpha \hat{L}^{(\tau)} (\hat{L}^{(\tau)} r^{(\tau+1)} - i) + \delta \sum_{d \in \{h, v\}} D_d^T \hat{W} \hat{W} (D_d r^{(\tau+1)} - g) = 0 \quad (12)$$

解式(12), 得到第  $\tau + 1$  次迭代时  $R$  的闭合解为

$$r^{(\tau+1)} = \frac{\alpha \hat{L}^{(\tau)} i + \delta \sum_{d \in \{h, v\}} D_d^T \hat{W} \hat{W} g}{\alpha \hat{L}^{(\tau)} \hat{L}^{(\tau)} + \delta \sum_{d \in \{h, v\}} D_d^T \hat{W} \hat{W} D_d} \quad (13)$$

其中,  $D_h$  和  $D_v$  是由后向差分的离散梯度算子得到的 Toeplitz 矩阵, 维数为  $(M \times N \times 3) \times (M \times N \times 3)$ . 由于维数较大, 用预条件共轭梯度法<sup>[19]</sup>求解式(13).

### 2.3.4 更新 $L$ 的子问题

设定目标子问题

$$\operatorname{argmin}_L \left( \alpha \|L^{(\tau+1)} \circ R^{(\tau+1)} - I\|_F^2 + \frac{\mu^{(\tau)}}{2} \left\| \nabla L^{(\tau+1)} - T^{(\tau)} + \frac{\Phi^{(\tau)}}{\mu^{(\tau)}} \right\|_F^2 \right) \quad (14)$$

为确保大多数噪声留在反射图中, 应用序列分解<sup>[17]</sup>求解上述目标函数. 设定初始值  $L^{(0)}$ , 从式(15)得到  $L^{(\tau+1)}$ , 并转换为式(16)的向量形式.

$$\operatorname{argmin}_L \left( \alpha \|L^{(\tau+1)} - L^{(0)}\|_F^2 + \frac{\mu^{(\tau)}}{2} \left\| \nabla L^{(\tau+1)} - T^{(\tau)} + \frac{\Phi^{(\tau)}}{\mu^{(\tau)}} \right\|_F^2 \right) \quad (15)$$

$$\operatorname{argmin}_l \left( \alpha \|l^{(\tau+1)} - l^{(0)}\|_2^2 + \frac{\mu^{(\tau)}}{2} \left\| \nabla l^{(\tau+1)} - t^{(\tau)} + \frac{\varphi^{(\tau)}}{\mu^{(\tau)}} \right\|_2^2 \right) \quad (16)$$

其中,  $l^{(\tau)}$  为  $L^{(\tau)}$  的向量形式;  $t^{(\tau)}$  为  $T^{(\tau)}$  的向量形式;  $\varphi^{(\tau)}$  为  $\Phi^{(\tau)}$  的向量形式.

针对式(16)对  $l^{(\tau)}$  取一阶导数, 可得

$$\alpha (l^{(\tau+1)} - l^{(0)}) + \frac{\mu^{(\tau)}}{2} \sum_{d \in \{h, v\}} D_d^T (D_d l^{(\tau+1)} - t^{(\tau)} + \frac{\varphi^{(\tau)}}{\mu^{(\tau)}}) = 0 \quad (17)$$

$$l^{(\tau+1)} = \frac{\alpha l^{(0)} + \frac{\mu^{(\tau)}}{2} \sum_{d \in \{h, v\}} D_d^T (t^{(\tau)} - \frac{\varphi^{(\tau)}}{\mu^{(\tau)}})}{\alpha E + \frac{\mu^{(\tau)}}{2} \sum_{d \in \{h, v\}} D_d^T D_d} \quad (18)$$

其中,  $E$  为单位矩阵.

### 2.2.5 更新 $T$ 的子问题

收集并重新排列所有  $T$  项, 得到子问题

$$\operatorname{argmin}_T \left( \beta \|T\|_p^p + \frac{\mu^{(\tau)}}{2} \left\| \nabla L^{(\tau+1)} - T + \frac{\Phi^{(\tau)}}{\mu^{(\tau)}} \right\|_F^2 \right) \quad (19)$$

式(19)可表示为  $L_p$  拟范数的近端映射, 应用  $L_p$  收缩算子  $\mathcal{S}_p(\chi, s) = \operatorname{sign}(\chi) \max(|\chi| - s^{2-p}, 0)$  后, 得到  $T$  的近似解为

$$T^{(\tau+1)} = \mathcal{S}_p \left( \nabla L^{(\tau+1)} + \frac{\Phi^{(\tau)}}{\mu^{(\tau)}}, \frac{\beta}{\mu^{(\tau)}} \right) \quad (20)$$

其中,  $\chi$  为待收缩变量;  $s$  为收缩阈值. 因此, 为  $P$  设置合适值可以实现  $L_p$  拟范数正则化.

### 2.2.6 更新 $\Phi$ 的策略

$$\Phi^{(\tau+1)} = \Phi^{(\tau)} + \mu^{(\tau)} [\nabla L^{(\tau+1)} - T^{(\tau+1)}] \quad (21)$$

### 2.2.7 更新 $\mu$ 的策略

$$\mu^{(\tau+1)} = \rho \mu^{(\tau)} \quad (22)$$

其中,  $\rho$  为收敛控制参数,  $\rho > 1$ .

至此 1 轮迭代结束, 并令  $\tau = \tau + 1$ . 设收敛阈值  $\varepsilon = 0.001$ . 当达到收敛条件  $\|(L^{(\tau+1)} - L^{(\tau)}) / (M \times N \times 3)\|_F < \varepsilon$ , 或  $\|(R^{(\tau+1)} - R^{(\tau)}) / (M \times N \times 3)\|_F < \varepsilon$ , 或最大迭代次

数  $K$  时, 更新停止.

### 2.3 调整照度

经过多次迭代收敛后得到照明图和反射图分别用  $L^*$  和  $R^*$  表示, 采用伽玛校正来增强  $L^*$ , 则有

$$I^* = (L^{(\tau+1)})^{1/\gamma} \circ R^{(\tau+1)} \quad (23)$$

算法伪代码请扫描论文末页右下角二维码查看补充材料图 S1.

## 3 实验

实验在配备 AMD Ryzen 5600X CPU (主频 4.2 GHz) 和 48 Gbyte 内存的个人计算机上使用 Matlab R2023b 进行, 操作系统是 Windows 10.

### 3.1 实验设置

用于测试的数据集 1 包含 500 幅有对应参考图像的弱光图像(来自 Adobe FiveK<sup>[5]</sup>); 数据集 2 的 40 幅弱光图像没有对应参考图像, 它们来自文献[12]和[21-22]). 分辨率过高的图像使用 Matlab 软件按比例缩小, 确保输入的弱光图像的分辨率不超过  $1\,000 \times 1\,000$  个像素. 实验中式(3)各正则项的平衡权重参数设置为  $\alpha = 1$ ,  $\beta = 3$ ,  $\delta = 0.1$ .

### 3.2 对比实验

#### 3.2.1 主观对比

图 2 和图 3 分别源自数据集 1 和 2, 包含了输入图像、真实图像(图 3 中此处为对比算法 DONG<sup>[2]</sup>的

结果), 以及使用生物启发的多曝光融合框架<sup>[3]</sup>(the bio-inspired multi-exposure fusion framework, BIMEF)、通过估计照明图的弱光照图像增强<sup>[12]</sup>(the low-light image enhancement via illumination map estimation, LIME)算法、自然度保持增强算法<sup>[10]</sup>(the naturalness preserved enhancement algorithm, NPE)、用于同时估计反射图和照明图的加权变分模型<sup>[13]</sup>(the weighted variational model for simultaneous reflectance and illumination estimation, SRIE)、鲁棒 Retinex 模型<sup>[17]</sup>(robust Retinex model, RRM)、低秩正则化 Retinex 模型<sup>[18]</sup>(low-rank regularized retinex model, LR3M)、即插即用 Retinex 模型<sup>[19]</sup>(plug-and-play Retinex model, PNP)和 GRM 的结果. 由图 2 和图 3 可见, 部分方法有增强不足导致暗细节丢失, 或增强过度导致颜色失真和泛白化的现象. 比如图 2(d), LIME 的结果整体增强过度; 图 2(g)和(h)中, 鲁棒 Retinex 模型(robust Retinex model, RRM)和低秩正则化 Retinex 模型(low-rank regularized retinex model, LR3M)的结果过于平滑, 丢失了很多纹理细节; 同时 LR3M 增强不足而 RRM 的结果色彩失真. 采用 GRM 方法获得的增强图片具有适中的亮度增强和更理想的对比度, 在保留更多细节的同时不会产生光晕和伪影, 在多数情况下都能得到令人满意的结果.



图 2 数据集 1 中弱光图像增强结果

Fig. 2 Comparison of enhanced results for low-light images in the Dataset 1.

#### 3.2.2 客观对比

选择峰值信噪比(peak signal to noise ratio, PSNR)、结构相似度(structural similarity index measure, SSIM)、自然图像质量评估指标<sup>[23]</sup>

(natural image quality evaluator, NIQE)、基于颜色感知的图像质量指标<sup>[24]</sup>(color perception-based picture quality index, CPCQI)和基于特征集成和回归建模的无参考图像质量评估指标<sup>[25]</sup>(no-reference

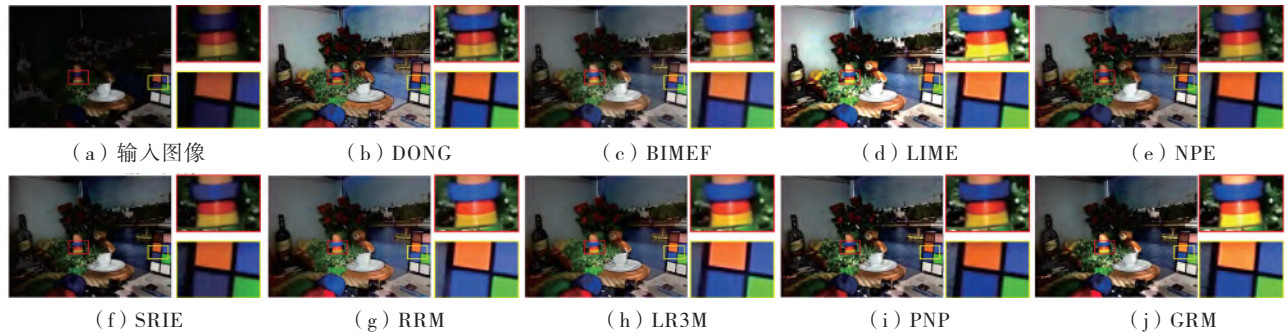


图3 数据集2中弱光图像增强结果

Fig. 3 Comparison of enhanced results for low-light images in the Dataset 2.

image quality assessment via feature ensemble and regression modeling, NFERM) 5个指标对不同弱光图像增强算法的性能进行评价. 对数据集1中有参考图像的500幅图像, 测试了所有指标. 而对数据集2中的40幅图像, 由于缺少作为参考的真实图像, 因此仅测试了无需参考图像的NIQE、CPCQI和NFERM指标, 结果见表1. 从表1可见, 对于数据

集1, GRM模型在PSNR和SSIM指标上都表现最优, 在CPCQI指标上表现次之, 说明该模型的结果最接近参考图像, 降噪效果最佳; 而对于数据集2, GRM模型在12种模型中具有最佳的NIQE和NFERM值, CPCQI指标表现第3, 可见GRM综合最理想.

表1 数据集1(500幅图像, 有参考)和数据集2(40幅图像, 无参考)的定量比较

Table 1 Quantitative comparison of Dataset 1 (500 images with references) and Dataset 2 (40 images without references)

方法	数据集1					数据集2		
	PSNR	SSIM	NIQE	CPCQI	NFERM	NIQE	CPCQI	NFERM
MSRCR <sup>[9]</sup>	13.235	0.611	2.966	0.841	26.929	3.374	0.766	20.033
DONG <sup>[2]</sup>	15.134	0.704	3.754	0.821	27.226	3.892	0.966	16.360
NPE <sup>[10]</sup>	17.176	0.771	<u>2.921</u>	0.860	27.022	3.194	0.973	16.516
MF <sup>[14]</sup>	17.488	0.780	<u>2.949</u>	0.871	26.506	3.411	<u>1.010</u>	15.393
BIMEF <sup>[3]</sup>	17.808	0.719	3.039	0.812	<u>24.901</u>	3.207	0.954	16.756
LIME <sup>[12]</sup>	13.275	0.728	2.967	0.844	32.137	3.629	0.980	19.762
SRIE <sup>[13]</sup>	18.440	0.790	3.017	0.893	<u>25.240</u>	<u>3.187</u>	0.983	17.287
JIEP <sup>[15]</sup>	18.445	0.795	3.039	0.903	26.766	3.259	0.994	15.571
RRM <sup>[17]</sup>	17.637	0.763	3.568	0.755	25.431	3.597	0.834	20.114
LR3M <sup>[18]</sup>	15.846	0.701	3.771	0.764	29.892	3.722	0.788	28.462
PNP <sup>[19]</sup>	<u>18.495</u>	<u>0.798</u>	2.954	<u>0.922</u>	26.530	3.336	<u>1.037</u>	<u>13.257</u>
GRM	<u>19.253</u>	<u>0.805</u>	3.019	<u>0.918</u>	26.783	<u>2.921</u>	0.999	<u>11.849</u>

注: 灰底数据为该指标下的最优值, 下划线数据为该指标下的次优值.

### 3.3 模型分析

表2给出了基于数据集1的模型参数敏感性分析结果. 分析表2可以确定,  $\beta$ 取值范围应为1~10, 再结合收敛的轮次、主观效果和对照明图与反射图分解的成效, 可确定 $\beta = 3$ ; 同样分析可取 $\alpha = 1, \delta = 0.1$ .

图4给出了采用GRM模型对某幅随机测试图像的收敛性分析结果. 由图4可见, 模型于25~35轮迭代收敛, 反射图的曲线在第2轮时有1次凸起, 是与初始化有关的正常现象. 通常情况下, 模型在35轮迭代内即可收敛, 因此可将最大迭代轮数 $K$ 设为40.

表2 参数敏感性分析

Table 2 Analysis of parameter sensitivity

$\alpha$	$\beta$	$\delta$	PSNR	SSIM	NIQE	CPCQI
1	0.1	0.1	18.086	0.778	3.321	0.858
1	1.0	0.1	18.618	0.797	3.057	0.911
1	3.0	0.1	19.253	0.805	3.019	0.918
1	5.0	0.1	19.700	0.809	3.016	0.918
1	10.0	0.1	20.478	0.810	3.149	0.888
1	20.0	0.1	21.254	0.817	3.024	0.909
1	3.0	1.0	19.246	0.801	3.164	0.890
1	3.0	10.0	19.220	0.793	3.409	0.846




图4 GRM模型收敛性分析

Fig. 4 Convergence analysis of GRM model.

## 结 语

本研究基于Retinex理论,提出一种能有效处理含噪声的弱光图像增强模型GRM,从输入图像中分解出反射图和照明图,并在该过程中消除噪声,通过伽马校正照明图以增强对比度和亮度,获得理想结果.引入收缩映射实现分数阶范数以满足分解出理想照明图的要求.针对反射图估计,利用输入图像信息,采用两种策略保留图像原始边缘和纹理细节,并有效剔除噪声.采用交替方向乘法有效求解GRM,对于一张分辨率为 $512 \times 340$ 的自然环境弱光图像,GRM计算耗时约为22.782 s.在多个公开测试数据集上的实验结果表明,GRM不仅在视觉质量方面表现出色,而且在客观图像质量评估指标得分上,与目前最先进的方法相比也具有竞争力.

基金项目:湖南省研究生科研创新资助项目(CX20240692);中南林业科技大学研究生科研创新基金资助项目(2023CX02091)

作者简介:吴翰宁(765058609@QQ.com),中南林业科技大学硕士研究生.研究方向:计算机视觉.

引文:吴翰宁,易积政,李潇瑶,等.基于全局鲁棒Retinex模型的多通道弱光图像增强[J].深圳大学学报理工版,2025,42(3):326-333.

## 参考文献 / References:

- [1] IBRAHIM H, PIK KONG N S. Brightness preserving dynamic histogram equalization for image contrast enhancement [J]. IEEE Transactions on Consumer Electronics, 2007, 53(4): 1752-1758.
- [2] DONG Xuan, WANG Guan, PANG Yi, et al. Fast efficient algorithm for enhancement of low lighting video [C]// 2011 IEEE International Conference on Multimedia and Expo. Piscataway, USA: IEEE, 2011: 1-6.
- [3] YING Zhenqiang, LI Ge, GAO Wen. A bio-inspired multi-exposure fusion framework for low-light image enhancement [EB/OL]. (2017-11-02) [2023-10-18]. <https://arxiv.org/abs/1711.00591>.
- [4] 赵明华, 汶怡春, 都双丽, 等. 基于照度与场景纹理注意力图的低光图像增强[J]. 中国图象图形学报, 2024, 29(4): 862-874.  
ZHAO Minghua, WEN Yichun, DU Shuangli, et al. Low-light image enhancement algorithm based on illumination and scene texture attention map [J]. Journal of Image and Graphics, 2024, 29(4): 862-874. (in Chinese)
- [5] WANG Ruixing, ZHANG Qing, FU C W, et al. Underexposed photo enhancement using deep illumination estimation [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2019: 6842-6850.
- [6] CAI Yuanhao, BIAN Hao, LIN Jing, et al. Retinexformer: one-stage Retinex-based transformer for low-light image enhancement [C]// IEEE/CVF International Conference on Computer Vision. Piscataway, USA: IEEE, 2023: 12470-12479.
- [7] 陈彬, 陈克远, 伍世虔. 基于跨域特征融合的低光图像增强算法[J]. 激光与光电子学进展, 2024, 61(24): 340-349.  
CHEN Bin, CHEN Keyuan, WU Shiqian. Low-light image enhancement via cross-domain feature fusion [J]. Laser & Optoelectronics Progress, 2024, 61(24): 340-349. (in Chinese)
- [8] LAND E H. The Retinex theory of color vision [J]. Scientific American, 1977, 237(6): 108-128.
- [9] JOBSON D J, RAHMAN Z, WOODDELL G A. A multi-scale Retinex for bridging the gap between color images and the human observation of scenes [J]. IEEE Transactions on Image Processing, 1997, 6(7): 965-976.
- [10] WANG Shuhang, ZHENG Jin, HU Haimiao, et al. Naturalness preserved enhancement algorithm for non-uniform

- illumination images [J]. *IEEE Transactions on Image Processing*, 2013, 22(9): 3538-3548.
- [11] 李潇瑶, 王炼红, 周怡聪, 等. 基于四元数非局部低秩和全变分的图像混合噪声去噪算法[J]. *电子学报*, 2023, 51(4): 975-983.
- LI Xiaoyao, WANG Lianhong, ZHOU Yicong, et al. Image mixed denoising using quaternion-based non-local low rank and total variation [J]. *Acta Electronica Sinica*, 2023, 51(4): 975-983. (in Chinese)
- [12] GUO Xiaojie, LI Yu, LING Haibin. LIME: low-light image enhancement via illumination map estimation [J]. *IEEE Transactions on Image Processing*, 2017, 26(2): 982-993.
- [13] FU Xueyang, ZENG Delu, HUANG Yue, et al. A weighted variational model for simultaneous reflectance and illumination estimation [C]// *IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway, USA: IEEE, 2016: 2782-2790.
- [14] FU Xueyang, ZENG Delu, HUANG Yue, et al. A fusion-based enhancing method for weakly illuminated images [J]. *Signal Processing*, 2016, 129: 82-96.
- [15] CAI Bolun, XU Xianming, GUO Kailing, et al. A joint intrinsic-extrinsic prior model for Retinex [C]// *IEEE International Conference on Computer Vision*. Piscataway, USA: IEEE, 2017: 4020-4029.
- [16] 刘波, 田广粮, 肖斌, 等. 利用自适应光照初始化的弱光图像增强方法[J]. *电子与信息学报*, 2024, 46(2): 643-651.
- LIU Bo, TIAN Guangliang, XIAO Bin, et al. Low light image enhancement with adaptive light initialization [J]. *Journal of Electronics & Information Technology*, 2024, 46(2): 643-651. (in Chinese)
- [17] LI Mading, LIU Jiaying, YANG Wenhan, et al. Structure-revealing low-light image enhancement via robust Retinex model [J]. *IEEE Transactions on Image Processing*, 2018, 27(6): 2828-2841.
- [18] REN Xutong, YANG Wenhan, CHENG Wenhua, et al. LR3M: robust low-light enhancement via low-rank regularized Retinex model [J]. *IEEE Transactions on Image Processing*, 2020, 29: 5862-5876.
- [19] LIN Y H, LU Yichang. Low-light enhancement using a plug-and-play Retinex model with shrinkage mapping for illumination estimation [J]. *IEEE Transactions on Image Processing*, 2022, 31: 4897-4908.
- [20] KAASSCHIETER E F. Preconditioned conjugate gradients for solving singular systems [J]. *Journal of Computational and Applied Mathematics*, 1988, 24(1/2): 265-275.
- [21] VONIKAKIS V. Busting image enhancement and tone-mapping algorithms: a collection of the most challenging cases [EB/OL]. [2023-10-24]. Available: <https://sites.google.com/site/vonikakis/datasets>.
- [22] 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.
- [23] MITTAL A, SOUNDARARAJAN R, BOVIK A C. Making a "completely blind" image quality analyzer [J]. *IEEE Signal Processing Letters*, 2013, 20(3): 209-212.
- [24] GU Ke, TAO Dacheng, QIAO Junfei, et al. Learning a no-reference quality assessment model of enhanced images with big data [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(4): 1301-1313.
- [25] GU Ke, ZHAI Guangtao, YANG Xiaokang, et al. Using free energy principle for blind image quality assessment [J]. *IEEE Transactions on Multimedia*, 2015, 17(1): 50-63.

【中文责编: 英子; 英文责编: 木柯】



补充材料