

面向嵌入式环境的暗光图像 GPU 加速增强算法

李鹏亮¹ 韩伟¹ 李丽娜¹ 刘作龙¹ 潘妍¹ 李晨卉¹ 祁俊雄¹
LI Pengliang HAN Wei LI Lina LIU Zuolong PAN Yan LI Chenhui QI Junxiong

摘要

针对已有算法很难满足嵌入式场景下暗光图像增强的高性能和高效性处理需求,面向嵌入式国产 GPU 加速平台提出一种用于暗光图像增强的高阶分式模型,证明了提出的高阶分式模型在特定情况下等价于 Retinex 理论模型。为了减少 GPU 加速过程中每个线程的计算开销,提出一种基于像素抽样的快速 boxfilter 算法,实现 GPU 的进一步加速,同时为了避免传统伽马变换存在过度曝光和亮度提升不够明显的问题,提出了一种自适应伽马变换的算法。通过实验结果的分析,证明提出的算法在嵌入式计算场景下的高效性和有效性,实现了 1280×720 像素分辨率图像约 148 帧/s 的处理速度。

关键词

嵌入式计算;高阶分式模型;快速 boxfilter;自适应伽马变换;国产 GPU 加速

doi: 10.3969/j.issn.1672-9528.2024.04.022

0 引言

嵌入式场景下,高速移动设备端成像时容易发生图像运动模糊情况^[1],通常需要缩短单张图像信号的采集时间。在传感器物理特性确定的情况下,单张图像采集时间越短,传感器对光照强度的感知就越弱,导致图像亮度退化。暗光环境下,退化现象尤为严重,由此造成图像中的目标特征退化,导致后期特征融合^[2-3]、目标检测^[4-5]及跟踪^[6-7]不确定性增大。因此,在嵌入式场景下,高性能实时处理暗光图像具有重大意义。

当前,暗光图像增强算法大致分为两类^[8]:基于模型驱动的方法和基于数据驱动的方法。基于模型驱动是最具典型的直方图均衡化方法,通过改变直方图分布来调节图像的明暗信息^[9]。文献[10]通过提出的伽马变换算法调节图像像素强度实现增强目的。文献[11]提出一种相机对光照强度的感知模型,通过该模型来调节像素亮度。文献[12]通过多分辨率递归融合算法来避免暗光增强时产生信息损失。基于数据驱动的算法已大量应用到暗光图像增强模型训练当中,如文献[13]通过正常光照和暗光环境下成像的图像对来训练增强网络。文献[14]在文献[13]的研究基础上,引入恢复网络来实现更加稳健的增强效果。文献[15]通过生成对抗网络(generative adversarial network, GAN)来实现 Retinex 分解。文献[16]通过场景非匹配的正常光照图像监督训练暗光图像增强网络模型。

目前,虽然已有众多暗光图像增强算法被提出,但是面向嵌入式特定领域需求,既有算法难以通过直接应用来满足

强实时和高可靠要求。

为了避免现有算法的不足,本文提出一种新的基于高阶分式模型和自适应伽马变换的暗光增强算法,并且通过国产 GPU 验证了算法的高可靠性和强实时性。本文工作的主要创新有以下几点。

(1) 面向嵌入式应用场景,提出一种高阶分式模型实现暗光图像增强,并且从理论上证明了高阶分式模型在特定情况下等价于 Retinex 分解模型。

(2) 面向嵌入式应用场景,提出一种新的自适应伽马变换,提升暗部的同时可以抑制高光区域过度曝光。

(3) 面向嵌入式应用场景,提出一种快速 boxfilter 算法,利用 boxfilter 所覆盖的区域抽样值来代表该区域的滤波像素,对抽样像素进行 boxfilter 滤波,极大简化了 GPU 的计算复杂度,同时保证计算效果。

(4) 在嵌入式异构硬件平台,通过 OpenCL 异构并行编程语言实现了国产 GPU 加速的暗光增强算法,实现 1280×720 像素分辨率图像约 148 帧/s 的处理速度。

1 理论知识

1.1 boxfilter 算法

传统 boxfilter 算法^[17]通过计算滤波区域的所有像素的均值来更新中心位置的像素值,计算方式为:

$$f_{\text{boxfilter}}(I_{x,y}) = \frac{1}{W^2} \sum_{i=-w}^w \sum_{j=-w}^w I(x+i, y+j) \quad (1)$$

式中: $I(x, y)$ 分别表示水平 x 和垂直方向 y 像素坐标对应的像素值, i 和 j 表示滤波像素遍历范围, w 为滤波半径, W 表示滤波直径。

由公式(1)可知,处理器实现 boxfilter 算法需要二维像素寻址,随着滤波区域增大,boxfilter 更新每一个输出像素值所需要的计算量就越大,导致计算效率变低,实时性变差。

1.2 伽马变换

在暗光增强领域,伽马变换可实现非常高效的图像像素亮度调节功能,其计算公式为:

$$f = x^\gamma \quad (2)$$

式中: x 为输入暗光像素, γ 为伽马变换参数(通常 $\gamma=1/2.2$)。该算法容易造成图像亮部过度曝光,暗光亮度提升不足,同时,变换之后图像亮度对比度变差。

1.3 Retinex 理论

Retinex 理论^[18]为暗光增强提供了重要的理论依据,该理论认为人类视觉系统对物体颜色信息的感知和环境光强弱无关。基于该理论,将感知到的图像 I 分解为亮度图像 L (由环境光强弱决定)和反射率图像 R (与物体的物理属性相关、与环境光强弱无关)。通常基于 Retinex 理论的方法,需要先求解 R 和 L ,然后可得暗光增强图像为:

$$I_e = R * L' \quad (3)$$

式中: I_e 表示暗光增强后的图像, $*$ 表示像素级乘法。

目前,已有大量 Retinex 理论模型方法被提出^[19]。2005年,美国国家航空航天局通过 Retinex 理论缓解了图像亮度不一致问题^[20]。针对 Retinex 理论模型的求解,学者们也提出了许多方法,如路径法、中央周边法、偏微分方程求解方法、变分法等。通常这些求解方法计算复杂度较高,不适合实时处理需求较高的场景。

2 面向嵌入 GPU 加速的算法建模

高速移动场景下,采集的图像需尽可能使目标特征明显,避免出现过暗或者过曝光区域。因此,需要提出一种适合该场景的高可靠和高效的暗光图像增强算法,确保增强后的图像具有暗部提升足够明显、高光像素区域不会发生过度曝光现象,以及避免对比度退化等情况。

2.1 高阶分式模型

通常借助伽马变换类的暗光图像增强算法均会产生对比度损失的问题,为了弥补这种不足,本文提出一种高阶分式模型来获得对比度增强的暗光图像 I_{hc} ,高阶分式模型为:

$$I_{hc} = \frac{I_h^n}{I_b^{n-1}} \quad (4)$$

式中: $I_h=(I-I_b)*s+I_b$ 表示高频信息预增强图像, s 为高频信息预增强系数, $I_b=f_g(I)$ 为保边平滑图像, $f_g(*)$ 为保边平滑算子, n 为大于 1 的正整数。

2.2 自适应伽马变换

传统的伽马变换通过非线性指数变化提升像素强度,达

到快速提升图像暗部区域像素亮度的目的。然而,传统的伽马变换在提升暗部像素亮度的同时,容易产生高光像素区域过度曝光现象,并且传统伽马变换(通常 $\gamma=1/2.2$)对暗部像素亮度提升不够明显。为了缓解传统伽马变换的不足,本文提出一种新的自适应伽马变换算法,其表示为:

$$\gamma_g = 0.35 + x^2 \quad (5)$$

式中: x 表示输入值, γ_g 根据 x 的变化而变化,其变化曲线如图 1 中紫色曲线所示,橙色曲线表示传统伽马变换曲线。由图 1 可知,本文提出的自适应伽马变换(紫色曲线)相比较传统伽马变换(橙色曲线)优势为: (1) 数值小的区域(x 轴 0 右侧附近)亮度提升明显(y 轴映射的值更大); (2) 数值大的区域(x 轴 1 左侧附近)亮度抑制明显(y 轴映射的值更小)。因此,具有更好的暗部亮度提升和更优的亮部过曝抑制机制。




图 1 不同伽马变换曲线对比

1.3 快速 boxfilter 算法

为降低计算复杂性,提高实时性,同时保证计算效果,本文提出一种基于抽样像素的快速 boxfilter 方法,用滤波区域的抽样像素滤波计算方式代替传统的滤波计算方式。计算公式为:

$$f_{fbfilter}(I_{x,y}) = \frac{1}{\left(\frac{w}{K} + 1\right)^2} \sum_{i=-w/k}^{w/k} \sum_{j=-w/k}^{w/k} I(x+ki, y+kj) \quad (6)$$

式中: k 表示抽样步长。传统方法要实现滤波直径为 W 边长的 boxfilter 需要双重循环遍历 $W \times W$ 像素。本文提出的快速 boxfilter 方法只需要双重循环遍历 $(w/k+1)^2$ 个像素值,其中, $w=(W-1)/2$ 。具体来说,传统方法要实现 31×31 像素区域的滤波,需要在 x 和 y 方向分别完成 31 次像素索引及求和,而通过本文方法可将 k 设置为 5 或 3,仅仅在 x 和 y 方向分别索引 7 次或 11 次索引及求和,极大提高了计算效率,计算开销理论上仅为原来的 $(7 \times 7)/(31 \times 31)=49/961$ 或 $(11 \times 11)/$

$(31 \times 31) = 121/961$ 。

1.4 模型先进性分析

通过本文提出的自适应伽马变换算法，基于高阶分式模型的暗光图像增强算法可表示为：

$$I_e = I_{hc}^{\gamma_g} = \left(\frac{I_h^n}{I_b^{n-1}} \right)^{\gamma_g} \quad (7)$$

式中： I_e 为增强后的图像。

在 $I_b = f_g(I)$ 以及 $I_h = (I - I_b) * s + I_b$ 已知的情况下， I_h 可进一步表示为 $R * I_b$ ，其中 R 的值由 I_b 和 I_h 决定。在理论层面，提出的高阶分式模型等价于 Retinex 模型：

证明：

$$\begin{aligned} I_{hc}^{\gamma_g} &= \left(\frac{I_h^n}{I_b^{n-1}} \right)^{\gamma_g} = \left(\frac{(R * I_b)^n}{I_b^{n-1}} \right)^{\gamma_g} \\ &= R^{n * \gamma_g} * I_b^{\gamma_g} \end{aligned} \quad (8)$$

由以上证明可知当 $n * \gamma_g$ 时，通过对比公式(3)和(8)可得，提出的方法等价于 Retinex 理论方法。由此可知 Retinex 模型为本文提出方法的一种特殊情况，因此证明本文提出的方法在理论层面具有先进性。

2 国产 GPU 加速算法实现

GPU 内部具有众多计算单元，因此非常适合处理大规模并行计算任务。本文提出的算法具有高度并行性，非常适合通过 GPU 实现实时高效处理。

2.1 算法实现流程

保边平滑图像 I_b 通过提出的快速 boxfilter 算法加速的 Guided image filtering (GIF) 算法获得。提出的算法完整计算流程如下：

- 步骤 1：计算 $I_{mean} = f_{boxfilter}(I)$ ；
- 步骤 2：计算 $I_{corr} = f_{boxfilter}(I * I)$ ；
- 步骤 3：计算 $I_{var} = I_{corr} - I_{mean} * I_{mean}$ ；
- 步骤 4：计算 $a = I_{var} / (I_{var} + \epsilon)$ ；
- 步骤 5：计算 $b = I_{mean} - a * I_{mean}$ ；
- 步骤 6：计算 $a_{mean} = f_{boxfilter}(a)$ ；
- 步骤 7：计算 $b_{mean} = f_{boxfilter}(b)$ ；
- 步骤 8：计算 $I_b = a_{mean} * I + b_{mean}$ ；
- 步骤 9：计算 $I_h = (I - I_b) * s + I_b$ ；
- 步骤 10：计算 $I_e = (I_h^n / I_b^{n-1})^{\gamma_g}$ 。

上述计算过程中步骤 1 到步骤 8 与 GIF 算法原理流程一致，区别在于本文创新性地提出快速 boxfilter 引入 GIF 算法，提高了 GIF 算法在嵌入式平台的执行效率。

2.2 嵌入式国产 GPU 实现流程

面向嵌入式平台国产 GPU，开放计算语言 OpenCL 提供了非常灵活的异构计算框架^[21]。在 OpenCL 执行模型中，kernel 函数为 GPU 端编译后执行的代码。因此，对于算法的 GPU 实现，需要在“*.cl”文件中编写相应的 kernel 函数。

面向本文提出的算法，通过 5 个 kernel 函数实现了嵌入式环境下国产 GPU 加速执行，其流程图如图 2 所示。

不同 kernel 函数负责的具体任务如下。

(1) kernel1：快速 box-filter 的 GPU kernel 函数，包含：(i) 输入图像 I 的快速滤波，用来统计图像的区域均值特性；(ii) 输入图像像素自身平方的快速滤波，用来统计图像局部的自相关特性。

(2) kernel2：计算单个像素对应的滤波系数 a 和 b 。

(3) kernel3：该 kernel 函数与第一步的相同。由于滤波过程中每个滤波区域存在像素重叠情况，因此需要计算滤波系数 a 和 b 区域均值特性。该 kernel 函数与第一步 kernel 函数复用。

(4) kernel4：通过滤波系数 a 和 b 区域均值特性计算最终的保边平滑输出。

(5) kernel5：获得预增强图像，通过提出的高阶分式模型以及自适应伽马变换计算最终的暗光增强输出。

3 实验与分析

本文提出的算法在国产 NA16D3C7C1 GPU 上进行了验证，该 GPU 子卡通过 PCIe 卡槽连接到飞腾 D2000 开发板，其硬件实物如图 3 所示。该国产 GPU 主频为 1.25 GHz，热功耗为 5 ~ 15 W，支持 OpenCL3.0，片内集成 1280 个通用计算渲染核心，可提供 1.5 TFLOPS 单精度浮点算力。




图 3 硬件验证环境实物图




图 2 本文提出方法的 GPU kernel 函数执行顺序

3.1 快速 boxfilter 加速验证和分析

根据本文提出的算法流程可知, boxfilter 算法使用 4 次, 并且 GPU 中每个 boxfilter 的计算线程均需执行双重循环, 因此, 该算法占据了较大比例的计算开销。

本实验中, boxfilter 滤波模板大小设置为 15×15 。在国产 NA16D3C7C1 GPU 上分别测试了采用传统 boxfilter 方法和采用快速 boxfilter 方法时, 本文提出算法的 GPU 加速时间。测试图像均为 3 通道彩色图像, 大小分别为 1280×720 、 1920×1080 、 2560×1440 和 4096×3112 。

GPU 加速计算时间如表 1 所示, 由表 1 可知, 采用 boxfilter 时, 相比于采用 boxfilter, 本文提出的算法达到 5 倍以上的加速比。在图像像素大小为 1280×720 时, 本文提出的算法可实现约 148 帧/s 的处理速度; 在图像像素大小为 1920×1080 时, 本文提出的算法可实现约 77 帧/s 的处理速度; 在图像像素大小为 2560×1440 时, 本文提出的算法可实现约 46 帧/s 的处理速度; 在图像像素大小为 4096×3112 时, 本文提出的算法可实现约 15 帧/s 的处理速度。

表 1 国产 NA16D3C7C1 GPU 加速处理时间

单位: ms

图像大小	1280×720	1920×1080	2560×1440	4096×3112
提出算法 (使用 boxfilter)	43.818	65.917	170.251	580.729
提出算法 (使用快速 boxfilter)	6.752	12.954	21.637	68.125

4.1 自适应伽马变换验证和分析

本文提出自适应伽马变换的主要目的是克服传统伽马变换的不足, 更好适应嵌入式场景。本小节测试了本文提出的自适应伽马变换的优势, 如图 4 所示, 图 4 (a) 为输入暗光图像, 图 4 (b) 为 $\gamma_g=2.2$ 时本文提出算法的 GPU 加速计算结果, 图 4 (c) 为 $\gamma_g=1/(0.35+F^2)$ 时, 本文提出的算法的 GPU 加速计算结果。从图 4 可知, 本文提出的适应算法可以更好地提升暗部亮度, 压制过亮区域的亮度, 更加符合嵌入式应用场景。




图 4 本文提出自适应伽马变换可视化分析

4.2 对比验证和分析

本实验通过一些性能优秀的基准方法来说明本文提出算法的有效性, 对比方法包括 LDR^[22]、RRM^[23] 和 STAR^[24] 传

统算法, 以及深度学习 Zero-DCE++^[25] 算法。对比算法的实验结果, 根据作者提供的开源代码运行所得, 本文提出算法在图 3 所示的嵌入式硬件环境下 GPU 加速计算所得。

图 5 给出了基准对比算法和本文提出算法的实验结果图, 测试图像大小为 1280×720 。由图 5 可知, LDA 算法对暗部的提升不够明显。RRM 算法和 STAR 算法均实现了优秀的暗光增强效果, 由于该方法的计算复杂度高, 并且通过传统伽马变换提升像素亮度, 因此不能满足高速移动场景强实时应用需求。基于深度学习的 Zero-DCE++ 算法使得图像清晰度退化, 本文提出的算法既可以保障暗部像素亮度提升明显, 避免了亮部区域像素过度曝光, 实现了约 148 帧/s 的处理速度。




图 5 本文提出算法与基准算法的对比分析

5 结论

本文提出一种高可靠和强实时的嵌入式环境下暗光图像增强算法, 并且在国产 GPU 验证了加速实时性和增强的有效性。

(1) 通过理论证明提出的高阶分式模型等价于 Retinex 理论模型, 进而证明本文提出算法的理论先进性。

(2) 通过实验证明提出算法在图像像素大小为 1280×720 时, 实现约 148 帧/s 的处理速度。

目前国产 GPU 相比于英伟达 GPU 性能差距明显, 随着国产 GPU 技术的更新, 本文提出的算法将会具备更优秀的加速效果。

参考文献:

- [1] 冯雨欣, 厉小润, 丁桦刚. 高速飞行条件下长曝光图像复原方法 [J]. 激光与红外, 2023, 53(10):1610-1616.
- [2] 顾文娟, 丁灿, 魏金, 等. 基于双边滤波 MSR 与 AutoMSRCR 融合的低光照图像增强 [J]. 光学精密工程, 2023, 31(24):3606-3617.
- [3] 谭豪, 张惊雷, 贾鑫. 基于多级特征提取的低光照目标检测算法 [J/OL]. 计算机工程与应用, 1-10[2024-03-29]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20240102.1444.004>.

- html.
- [4] 王磊, 关英, 孟志敏, 等. 嵌入式平台下红外图像坦克目标识别的实现方法[J]. 兵器装备工程学报, 2021, 42(4): 132-137.
- [5] 刘航. 基于特征增强的暗光目标检测方法研究[D]. 上海: 东华大学, 2023.
- [6] 邓健, 张驰, 高赞. 基于特征感知增强的孪生跟踪[J/OL]. 计算机工程与应用, 1-12[2024-03-29]. <http://kns.cnki.net/kcms/detail/11.2127.tp.20240104.1339.038.html>.
- [7] 由韶泽, 朱华, 李猛钢, 等. 井下低照度环境下的钻孔机器人目标跟踪器[J]. 矿业安全与环保, 2022, 49(5): 11-17+23.
- [8] LI P, LIANG J, ZHANG M. A degradation model for simultaneous brightness and sharpness enhancement of low-light image[J]. Signal processing, 2021, 189: 108298.
- [9] 肖汉, 孙陆鹏, 李彩林, 等. 面向 GPU 的直方图统计图像增强并行算法[J]. 计算机科学与探索, 2022, 16(10): 2273-2285.
- [10] HUANG S C, CHENG F C, CHIU Y S. Efficient contrast enhancement using adaptive gamma correction with weighting distribution[J]. IEEE transactions on image processing, 2013, 22(3): 1032-1041.
- [11] YING Z, LI G, REN Y, et al. A new low-light image enhancement algorithm using camera response model[C]//In: IEEE International Conference on Computer Vision Workshops (ICCVW). Piscataway: IEEE, 2017: 3015-3022.
- [12] 徐勤功, 郭杜杜. 基于 Retinex 理论的暗光图像增强算法[J]. 中国科技论文, 2023, 18(11): 1267-1274.
- [13] WEI C, WANG W, YANG W, et al. Deep Retinex decomposition for low-light enhancement[EB/OL]. (2018-08-14)[2024-01-19]. <https://arxiv.org/abs/1808.04560>.
- [14] ZHANG Y, ZHANG J, GUO X. Kindling the darkness: a practical low-light image enhancer[C]// Proceedings of the 27th ACM International Conference on Multimedia. New York: ACM, 2019: 1632-1640.
- [15] WANG J, TAN W, NIU X, et al. RDGAN: retinex decomposition based adversarial learning for low-light enhancement[C]// Proceedings of IEEE International Conference on Multimedia and Expo (ICME). Piscataway: IEEE, 2019: 1186-1191.
- [16] JIANG Y, GONG X, LIU D, et al. EnlightenGAN: deep light enhancement without paired supervision[J]. IEEE transactions on image processing, 2021, 30: 2340-2349.
- [17] HE K, SUN J, TANG X. Guided image filtering[J]. IEEE transactions on pattern analysis and machine intelligence, 2012, 35(6): 1397-1409.
- [18] LAND E H. The Retinex theory of color vision[J]. Scientific American, 1977, 237(6): 108-129.
- [19] 谢凤英, 汤萌, 张蕊. 基于 Retinex 的图像增强方法综述[J]. 数据采集与处理, 2019, 34(1): 1-11.
- [20] HINES G D, RAHMAN Z, JOBSON D J, et al. Single-scale Retinex using digital signal processors[EB/OL]. (2015-03-22)[2024-01-20]. <https://www.semanticscholar.org/paper/Single-Scale-Retinex-Using-Digital-Signal-Hines-Rahman/59271dbb46fe48735ef341653608e5ab29b2582b>.
- [21] 顾经纬. 基于 OpenCL 并行框架的异构系统计算加速研究[D]. 合肥: 中国科学技术大学, 2023.
- [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] LI M, LIU J, YANG W, et al. Structure-revealing low-light image enhancement via robust Retinex model[J]. IEEE transactions on image processing, 2018, 27(6): 2828-2841.
- [24] XU J, HOU Y, REN D, et al. STAR: a structure and texture aware Retinex model[J]. IEEE transactions on image processing, 2020, 29: 5022-5037.
- [25] LI C, GUO C, CHEN C L. Learning to enhance low-light image via zero-reference deep curve estimation[J]. IEEE transactions on pattern analysis and machine intelligence, 2021(3): 4225-4238.

【作者简介】

李鹏亮(1989—), 男, 陕西岐山人, 博士, 工程师, 研究方向: 异构并行计算、类脑计算等。

韩伟(1988—), 男, 吉林松原人, 硕士, 高级工程师, 研究方向: 分布式计算、三维视觉等。

李丽娜(1991—), 女, 陕西西安人, 博士, 工程师, 研究方向: 计算技术、信息检索等。

刘作龙(1988—), 男, 辽宁东港人, 硕士, 高级工程师, 研究方向: 嵌入式硬件架构。

潘妍(1989—), 女, 陕西咸阳人, 硕士, 工程师, 研究方向: 人工智能、图像处理。

李晨卉(1996—), 女, 陕西西安人, 硕士, 工程师, 研究方向: 可重构计算、虚拟化等。

祁俊雄(1991—), 男, 山东青岛人, 硕士, 工程师, 研究方向: 嵌入式计算、嵌入式硬件等。

(收稿日期: 2024-03-12)