

指导教师： 杨涛

提交时间： 2015.3.27

The task of
Digital Image Processing

数字图像处理

School of Computer Science

No: 1

姓名： 陈迪

学号： 2012302406

班号： 10011201



使用相对平滑的单图像层次分离

Yu Li Michael S. Brown

School of Computing, National University of Singapore

liyul@nus.edu.sg sgbrown@comp.nus.edu.sg

摘要:

本文针对从一幅图像中提取两个层次，其中一个层次相对另一层更加平滑。这个问题在本身的图像分解和消除反射干扰方面最为显著。单图像的层次分解属于固有的病态现象，它的解决方法需要额外强制性的约束。我们介绍一种新的策略，使这两个图层的梯度规则化，其中一层有长的尾分布，而另一层有短的尾分布。尽管增加长的尾分布是一个很常见的练习，然而我们在第二图层上关于短的尾分布的介绍很独特。我们在一个概率框架中制定了这个问题，应用迭代的方法解决正规化，描述出了一个优化方案。通过运用我们的方法和其他的技术来解决本身的图像和反射消除问题，分解高质量层问题。但是我们的方法显著地表现出比现行方法更加快速的优点。

$\log(R)+\log(L)$ 被改写成等式 1 的形式。在玻璃窗后拍摄出来的场景照片的反射干扰会上升。这可以被表示为一个反射图层的线性组合 L_R 和所需的场景背景 L_B ，正如：

$$I = L_B + L_R$$

我们使用的论点是建立在 Schechner et al.'s [14]关于焦点的基础上，且经过轻微修正后的版本，该论点表示焦点在所需层次上更加集中而反射很模糊。这有如下表示：

$$I = L_B + L_R * h$$

这里涉及到的反射层做为高斯模糊，有着场内核深度模型。

1.介绍

本文运用以下途径解决从一幅图像中分离图层的问题：

- 1) 本身的图像分解
 - 2) 使用焦点消除单层图像的反射干扰
- 这些问题均采取下列形式：

$$I = L_1 + L_2, \quad (1)$$

这里 I 是被观察的图像， L_1 和 L_2 是结合层。例如，本身的图像模型 [3] 假定图像场景是场景反射率和每个像素照明的产物，表示为： $I = RL$ ， R 是每个像素的反射性或者反射率， L 是每个像素的照度下降量。本身的图像分解旨在给出一个输入 I 的情况下估计 R 和 L 。这可以通过 \log 函数, i.e. $\log(I) =$

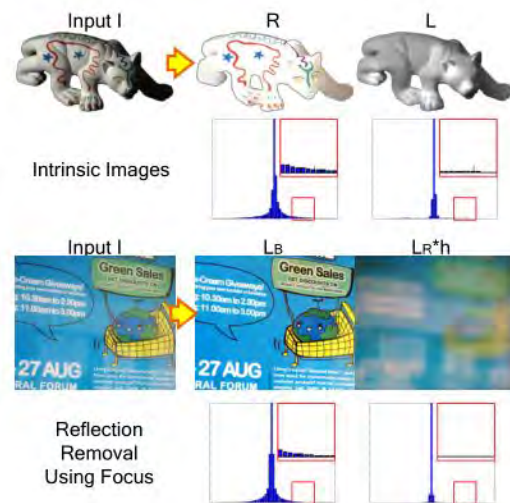


FIG.1 这幅图像展示了我们的理论所支持的两个问题：本身的图像分解和使用焦点消除单图像的反射。每层相应的梯度直方图如下所示。在所有的这些问题中，一个图层比另一个图层有更大的梯度。值得注意的是，为了提高可视化，这两个层次的强度增强。

层次分离的固有挑战是它试图从输入的一幅图形 I 中获取两个不知名的层次 (L_1 和 L_2)。为了使问题易于处理,在解决问题的过程需要用到先验知识。例如,当时对于本身图像分解的方法(见 [6, 8, 18, 20])典型的适应于在照明平稳变化时自然图像有分段反射率的思想。此意味着照明层 L 比反射层 R 更平滑。

单图像反射分离中一个成功的方法是采用了在恢复层上施加先验梯度稀疏度的策略。先验梯度稀疏度(也被称为原始的自然图像)被证明在其他可能拥有多种解决方法的病态问题上成功的。(e.g. 去除模糊的图像[5])。它基本的思想是所需的图像梯度直方图具有长尾分部。

我们的工作受到了在图像上成功强加梯度稀疏约束的启发。然而,在我们的问题中,这两个层次的梯度具有不同的分布,其中一层被认为是平滑的, *i.e.* 照明层 L , 和散焦反射 $L_R * h$, 因此应该很少有大的梯度。Figure1 就是一个例子。这意味着我们需要在平滑层上限制额外的约束。

成果: 我们提出了一种新的方法来解决层次分离问题,通过为从梯度直方图中得到的两个层次分别建立可能性,其中一层比另一层更平滑。为了得到所需的层次分离,制定了必须的目标函数。一种有效的方案说明这种优化了的目标函数是非凹的,而且具有不等式约束。我们的方法在几秒钟之内提供了建立在数万像素上的高质量结果。这比现存的固有图像和反射分离理论要快的多。

本文的其余部分安排如下。第 2 部分提供了我们目标应用中的更多的细节和相关理论;第 3 部分概述我们的方法;第 4 部分提供了与以前方法的实验对比结果;第 5 部分讨论和总结全文。

2.相关工作

2.1 固有的图像分解

最早解决固有图像处理的工作是 Retinex 算法 [10],应用了简单的启发式搜索,假设在图像中强边梯度属于反射率的变化。其他应用了多个图像[24]或者用户标记[4]的固有图像分解方法已经被提出并且产生了良好的效果。对于单幅自动图像的固有图像估计,许多后来的著作 [8, 17, 20]采用了 Retinex 算法,专注于分离反射率和照明边界。这些方法被称为基于边缘的方法,并根据最近调查 [8],颜色版本的 Retinex 算法 [8]仍是最高端的执行方法。文献 [8]的作者也为固有图像创造了一个包含 16 个真实目标的地面实况数据集 (MIT 数据集)。

最近应用在固有图像上的方法中更多的是利用了近期概率模型和优化理论方面的进步优势。和依赖局部信息而建立起来的边缘理论不同,这些新的理论使用了在场景中存在一组稀疏反射率的思想。这些值在之前的文献[2, 6, 15, 18]中被认为是全局性的稀疏值。且注意到这些稀疏值不用于梯度直方图,而是直接作用于允许的反射值上。这些方法在 MIT 数据集上获得了杰出的效果。

由于我们的理论没有直接使用先前的反射值,在分类上属于使用基于边缘的理论。我们展示并且证实了,我们的理论相比其他基于边缘的理论可以得到更好地表现力。我们的研究结果与那些通过使用复杂模型和推理的先进方法而获得的结果很相近。(在有些情况下有时甚至更好)。而且速度显著加快。

2.2 反射消除

很多消除反射的算法依赖于多种输入的图像。这些理论都需要采取一组不同混合图层中的图像。例如,旋转偏光透镜[9, 16],采用快速、非闪光图像队 [1],捕捉一个视频序列[13],或者视图观点 [12, 19, 21]。这些多种多样的输入方案被用于恢复图层。单图像消除反射更难。一个成功的方法是由 Levin 和 Weiss [11]提出的,它依赖于用户的标记来提供背景和反射的梯度。他们还提出了一个优化框架规定梯度稀疏度。当用户提供正确的标记时他们的理论可以产生引人瞩目的结果。

在第一部分中已经讨论过的 Schechner et al. [14]理论也需要两幅输入图像，特别的是一幅聚焦于反射，而另一幅聚焦于背景。使用我们的理论仅仅在一幅聚焦于背景的图像上就可以获得高质量的反射分离。而且，我们不需要明确估计模糊点的扩散函数，因为在文献[14]中已经做过了。

3.我们的方法

3.1 模型

因受到文献[11]中现有的梯度稀疏度的启发，我们在两层梯度上介绍了先验分布。假设 L_2 比 L_1 更平滑。而 L_1 存在大梯度的可能性更大。我们为这两个概率编码如下：

$$\begin{aligned} P_1(x) &= \frac{1}{z} \max\{e^{-\frac{x^2}{\sigma_1^2}}, \epsilon\}, \\ P_2(x) &= \frac{1}{2\pi\sigma_2^2} e^{-\frac{x^2}{\sigma_2^2}}, \end{aligned} \quad (2)$$

这里 x 是梯度值， z 是一个正规化的因素， σ_1 和 σ_2 是高斯分布下降的很快的两个小值。然而在 P_1 中使用 \max 操作时我们为了防止得到接近零的概率就明确地在尾部添了一个零。

为了解决层次分离问题，在等式 2 中，我们采用了一个概率模型去寻求输入图像最有可能性的解释，此输入图像使用两层的概率公式来定义的。本质上，我们最大化联合概率 $P(L_1, L_2)$ ，这也可以通过最小化 $-\log$ 概率来实现。对等式 2 取 $-\log$ 对数，我们可以得到：

$$\begin{aligned} -\log P_1(x) &\propto \min\left\{\frac{x^2}{\sigma_1^2(-\log \epsilon)}, 1\right\} + C_1, \\ -\log P_2(x) &\propto \frac{x^2}{\sigma_2^2} + C_2. \end{aligned} \quad (3)$$

这里， C_1 和 C_2 是常数，我们以后可以减小它们的值。然而 $-\log P_2(x)$ 在 L_2 的构成中， $-\log P_1(x)$ 被 L_2 截短，即可以化简为 $\rho(x) = \min\{x^2/k, l\}$ 。在我们的理论中 k 作为等于常量 10^{-4} 的小数字。函数 ρ 和在文献[25]中的

稀疏惩罚相似。在假设两个图层均是独立 (*i.e.* $P(L_1, L_2) = P(L_1) \cdot P(L_2)$)，该微分

滤波器的输出也是独立的情况下 (*i.e.* $P(L_t)$

$= \prod_i P_t(f_j * L)_i, t \in \{1, 2\}$), $-\log P(L_1, L_2)$ 的最小值变成：

$$\min_{L_1, L_2} \sum_{i,j} \left(\rho(L_1 * f_j)_i + \lambda(L_2 * f_j)_i^2 \right), \quad (4)$$

这里， i 是像素索引， f_j 表示不同的导数滤波器。我们使用两个定向的一阶导数滤波器和一个二阶拉普拉斯滤波器， $f_1 = [-1$

$$1], f_2 = [-1 \ 1], f_3 = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}。为简单$$

起见，我们将 $F_i^j L = (L * f_j)_i$ 写在本文的其他地方。从实验中我们发现在 L_1 使用一阶导数滤波器，在 L_2 中使用二阶拉普拉斯滤波器就会得到很好的结果。一阶导数滤波器帮助恢复 L_1 中的显著边缘，而拉普拉斯滤波器使 L_2 中的编码平滑变化。当参数 λ 控制输出 L_2 的平滑度时，我们将这两项之间的权重和乘数 $\frac{1}{\sigma^2}$ 整合在一起。 λ 的不同效果分别展示

在 Figure 1 和 Figure 2 中。

我们的概率定义在梯度上，为了恢复有意义的层次我们必须约束解决方案的范围在 *i.e.* $(L_1)_i \in [lb_i, ub_i]$ 之间。这些范围是根据第 4 部分讨论过的应用而制定的。而且，我们可以在目标中用 $I - L_1$ 代替 L_2 ，使

建立在参数 L_1 上的最终目标函数为：

$$\min_{L_1} \sum_i \left(\sum_{j=1,2} \rho(F_i^j L_1) + \lambda(F_i^3 L_1 - F_i^3 I)^2 \right) \quad (5)$$

s.t. $lb_i \leq (L_1)_i \leq ub_i.$




FIG.2 该图显示了在合成的情况下，不同的 λ 值作用在最终分离结果上的影响。较大的 λ 值会产生更平滑的 L_2 ，因此在层次分离中控制细节传送。当 λ 值较小时 ($\lambda = 10$)， L_1 会失去很多在 L_2 中不正确显示细节。当值较大时 ($\lambda = 1000$)， L_2 会变得过度平滑而且部分细节会重新在 L_1 中出现。设置 $\lambda = 100$ 是一个最合适的选择，因为它给出了最好的结果。

3.2 优化

由于非凸 $\rho(x)$ 的组成部分，我们的目标函数是非凸的。此外，还有一个不等式约束。

这些问题在优化时需要特别注意。我们采用了两个阶段的方法。首先，我们使用半二次分离方案 [7, 22] 来解决没有不等式约束的非凸问题。在每一次迭代的结尾，我们执行归一化步骤，迫使解决方案落在限制范围内。

使用半二次分离方法，当每个像素上辅助变量 g_i^j 被介绍用于在函数 $\rho(\cdot)$ 外移动

$F_i^j L_1$ 项时，给出了一种新的成本函数：

$$\min_{L_1, g^j} \sum_i \left(\sum_{j=1,2} (\beta(F_i^j L_1 - g_i^j)^2 + \rho(g_i^j)) + \lambda(F_i^3 L_1 - F_i^3 I)^2 \right) \quad (6)$$

在这里 β 是在优化中我们将要增加的衡量标准。(在我们实现的结果中，每次从 10 或者 20 开始，再乘以 $\eta = 2$)。当 β 变得越来越大时，这个解决方案就和等式 5 越来越靠近。对于一个固定的 β ，最小化等式 6 可以通过计算 L_1 和更新 g^j 交替进行。 L_1 的计算和 g^j 的更新均在下面的段落中进行了描述。

更新 g^j ：保持 L_1 不变，在每个像素中以闭合形式的解决方法用于最小化等式 6 中

$$w.r.t. \quad g_i^j = \begin{cases} F_i^j L_1, & (F_i^j L_1)^2 > \frac{1}{\beta} \\ 0, & \text{otherwise.} \end{cases} \quad (7)$$

当 $\beta < \frac{1}{k}$ 时简单的临界值规则起作用。

计算 L_1 ：当 g^j 不变时，等式 6 w.r.t. 的函数 L_1 是二次的。假设是圆形的边界条件，我们使用经过对角化的卷积矩阵 2D FFT F ，可以直接得到最佳的 L_1 ：

$$L_1 = F^{-1}(A), \quad A = \frac{\beta \sum_j (\mathcal{F}(F^j) * \mathcal{F}(g^j)) + \lambda \mathcal{F}(F^3) * \mathcal{F}(F^3) \mathcal{F}(I)}{\beta \sum_j (\mathcal{F}(F^j) * \mathcal{F}(F^j)) + \lambda \mathcal{F}(F^3) * \mathcal{F}(F^3) + \tau} \quad (8)$$

这里 * 表示复数共轭，被加入分母中的参数 τ 是一个小的必须数字，为了增加我们算法的稳定性 (在我们的执行结果中 $\tau = 10^{-16}$) 乘法和除法都是明确的执行。解答等式 8 仅仅需要两个 FFT，分别用于 g^1 和 g^2 。在每个迭代中有一个 IFFT，而其他项均可预先计算。

规范化 L_1 ：在得到 L_1 后，我们执行了一个规范化步骤，使解决方案到达有意义的范围。这一步非常重要。因为等式 6 的解决方案并不是唯一的，它和一个全局常量相关。因此规范化的目标是使解决方案落在 $[lb_i, ub_i]$ 的范围内。为了找到合适的常量

t ，我们试图去最小化下列目标函数：

$$\min_t \sum_i m_i ((L_1)_i + t - lb_i)^2 + \sum_i n_i ((L_1)_i + t - ub_i)^2, \quad (9)$$

这里的 m_i , n_i 是指示函数, 当且仅当 $(L_i)_t < l b_i$ 时 $m_i = 1$, 当且仅当 $(L_i)_t > u b_i$ 时 $n_i = 1$, 其他情况下它们均为 0。从这里可以看出, L_1 可以更新为 $L_1 + t$ 。在这一步骤中可以使用简单的梯度下降。在此之后, 一些值可以落在 $[l b_i, u b_i]$ 的侧区间之内。这些值也可以被裁减至 $l b_i$ 或 $u b_i$ 之间。我们总结了在算法 1 全过程中的步骤。在我们所有的实验中, 不仅最优化收敛速度非常快 (在 5 次迭代之内), 而且会得到高质量的结果。收敛的证明在第四部分。

4. 实验结果

我们的实验在一台配置为 Intel I7 CPU(3.4GHz) 和 8GB RAM 的个人电脑上完成。在 MATLAB 上执行并且没有利用任何 GPU 加速。演示代码可以在作者的网页上下载。

Algorithm 1 Layer Separation using Relative Smoothness

Input: input image I ; smoothness weight λ ; initial β_0 ; iterations number i_{\max} ; increasing rate η ;

Initialization: $L_1 \leftarrow I$; $\beta \leftarrow \beta_0$; $i \leftarrow 0$.

while $i < i_{\max}$ **do**

 update g_i^j using Eqn. 7;

 compute L_1 using Eqn. 8;

 normalize L_1 using Eqn. 9;

$\beta = \eta * \beta, i++$;

end while

$L_2 = I - L_1$;

Output: The estimation of two layers L_1 and L_2 ;

4.1 固有的图像分解

我们在各自的方程式中将 $\log(I)$, $\log(R)$, 和 $\log(L)$ 表示成 \hat{I} , \hat{R} , \hat{L} 。在我们的执行结果中, 原始的图像被归一化在 $[1/256, 1]$ 的范围内。因此, \log, \hat{R} 应该下降在 $[\hat{I}, 0]$ 的范围内, 使用我们的理论, 目标函数变成:

$$\min_{\hat{R}} \sum_i \left(\sum_{j=1,2} \rho(F_i^j \hat{R}) + \lambda (F_i^3 \hat{R} - F_i^3 \hat{I})^2 \right) \quad (10)$$

s.t. $\hat{I}_i \leq \hat{R}_i \leq 0$.

如果我们把平滑权重 λ 设置为 0 而且仅仅运行一次全过程, 这意味着只要梯度临界值到达 g' , 就得到恢复值 \hat{R} , 我们的理论达到的效果和 Retinex 算法[8]类似。我们将这种配置表示为 Retinex (我们的)。我们的 Retinex 算法比原来在[8]中描述算法有着更好地执行结果。因此我们在报告的 Retinex 结果中使用我们的执行情况。

4.1.1 基于 MIT 数据集的评价

我们已经在 MIT 固有图像数据集中测试过我们的算法 [8]。

快速收敛: 在这里展示我们的优化框架可以快速收敛成一个解决方案。(不超过 5 次所需的迭代)。在一个固有分离例子 Figure 3 中, 我们在每次迭代中都绘制出能量值。在每次的迭代中, 我们都要测出当前状态下估计层数据和使用本地均方误差(LMSE) [8] 而得到的真实数据之间的误差。为了展示我们的理论可以快速收敛到高质量的结果, 该曲线也被绘制在 Figure 3 中。

和之前的方法相比较: 我们已经将我们理论的执行结果和几种代表性的固有图像预测方法作了些比较, 报道出了每幅图像的运行时间和 Table 1 中 MIT 数据集上的 LMSE。Tappen et al 的方法[20]是基于边缘的方法, 学会用一个分类来区分反射边缘和光照边缘。方法 [2, 6, 18]中使用先前的全局稀疏性, [2]中的框架使用更多的限制解决来自于原图像中阴影形状的问题。这三种方法一般认为在 MIT 数据集中具有最先进的性能。值得注意的是, 在方法 [6] 和 [2]中, 我们不能得到和原始论文一样小的 LMSE 值。作者认为我们的这篇报告是他们最好的执行结果。

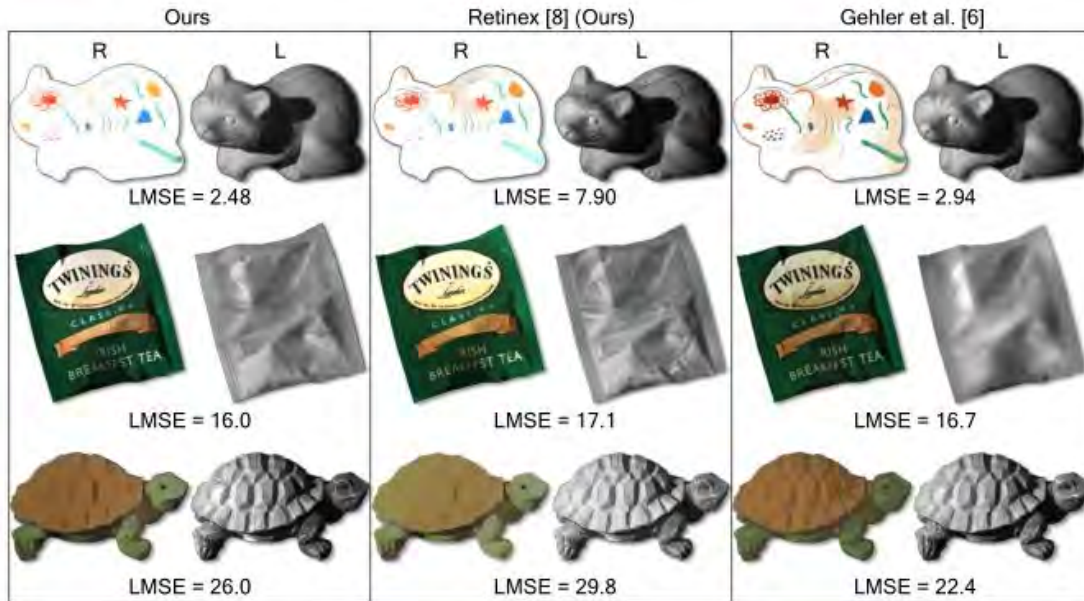


FIG.4 该图显示的是通过 Retinex [8]得到的分离结果。文献[6]中的理论和我们的方法作用于 MIT 原有的数据集中的三幅图片。LMSE 误差低于 10^{-3} 。

Table 1. Quantitative Comparison with Previous Methods

Method	Runtime	LMSE
Tappen <i>et al.</i> 2005 [20]	>200 s	0.0347
Shen & Yeo 2011 [18]	>300 s	0.0204
Gehler <i>et al.</i> 2011 [6]	>600 s	0.0131*
Barron & Malik 2012 [2]	>200 s	0.0133*
Retinex [8] (Ours)	<1 s	0.0217
Ours	1-3s	0.0149

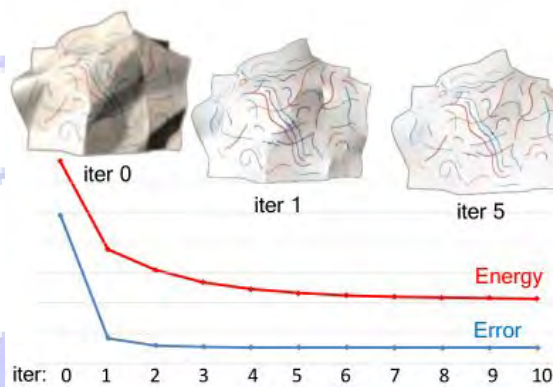


FIG.3 这幅图片说明了我们算法的收敛性。红线和蓝线分别表示由我们目标函数定义的能量和当前预估的值与使用 LMSE 测出

来的真实值之间的误差。注意，能量的标度和误差均是不同的。我们把它们放在一起作说明。预估的一些步骤中反射值也被绘制在上图中。

正如可以看到的，由于使用 FFT 加速，我们用 Matlab 实现的优化比其他方法更有效。甚至即使不使用先前的全局稀疏性理论，我们的理论也可以实现高质量的性能，接近为固有图像特殊设计的理论而得到的结果。(e.g. [2, 6]).

我们在 Figure 4 中也展示了这三个例子的结果，同 Retinex 的方法 [8]相比较，最好的执行结果是方法 [6]。我们的理论给出了比 Retinex 的方法 [8]更好地视觉效果，因为我们的研究结果显示了清晰的边缘，而且无出血迹象。对于浣熊和茶叶袋的情况，我们的结果甚至比 [6]更好。[6]的结果中两层间有多个区域具有不正确的分离。e.g. 在反射图中，保持在浣熊上光照部分的反射率和在茶叶袋边界的光照细节。

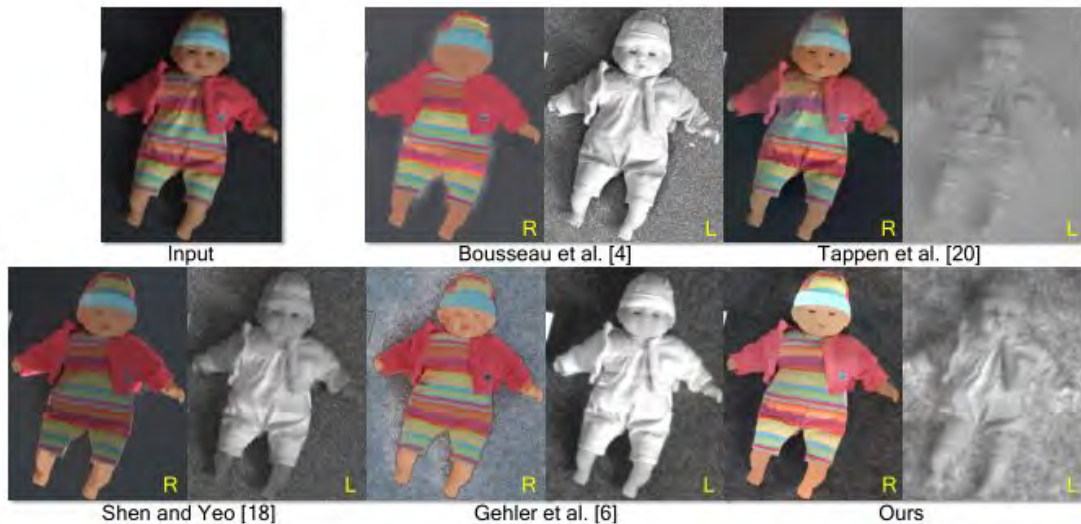


FIG.5 将一幅图片上使用用户协助方法[4]得到的分离结果和其他具有代表性的自动方式得到的结果做比较。所有的照明图像用灰度表示。

4.1.2 实物投入比较

我们也将之前在文献 [4]中使用过的图像作为输入图像进行测试。该文献中的方法是一个用户协助方法，在各个地区分享相同的反射率和光照的用户标注下，可以生成更多的分段恒定反射率。然而，他们的本地 2D 子空间模型在高对比度区域将会失败 (e.g.玩偶的边界)，从而导致反射图像的失真。其他三种方法或多或少将画布上的纹理混合成了照度地图。综合考虑到分段平坦反射率，清晰的边缘和纹理信息，我们的理论辩证的显示出可以得到最好的反射结果和光照分解结果。

4.2 应用焦模糊的单图像反射消除

对于消除反射问题，预估的背景值 $(L_B)_i$ 应该落在 $[0, I_i]$ 的范围内，可得到目标函数：

$$\min_{L_B} \sum_i \left(\sum_{j=1,2} \rho(F_i^j L_B) + \lambda (F_i^3 L_B - F_i^3 I)^2 \right) \quad (11)$$

s.t. $0 \leq (L_B)_i \leq I_i.$

4.2.1 基于 Synthetic 数据的结论

建立在混合过程 $I = L_B + L_r * h$ 的基础上，我们已经合成了层次混合数据。标准偏差为 5 的 2D 高斯分布在我们的合成中被用作散焦的模糊内核 h 。输入混合图像和 Figure 6 一样。分离结果在图 6 中有所显示。为了定量评估我们的算法，我们计算出结构相似度指数(SSIM) [23] 作为背景恢复图层质量的衡量。

就像所看到的那样，使用我们的方法分离合成图像，和其他原始混合图像相比，SSIM 至少增加了 0.1。在视觉方面，经过分离后，背景图层更加清楚。

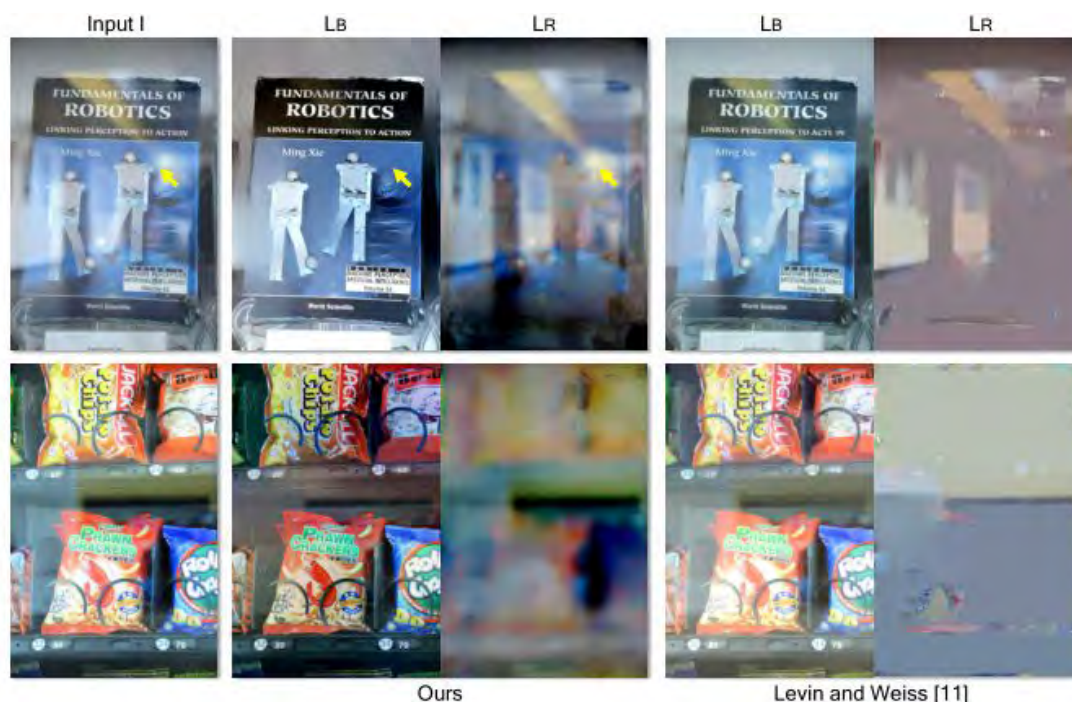


FIG.7 这两个消除反射的例子分别用我们的方法和文献[11]中先前关于单幅图像消除反射的方法得到结果。我们的方法提供了更清晰的分离结果。但是在顶部的情况下，背景的一小部分是平滑的（黄色箭头指出的地方），和我们的假设不符，从而导致了在该小区域不正确的分离。（Figure 8 中展示如何纠正这种情况）

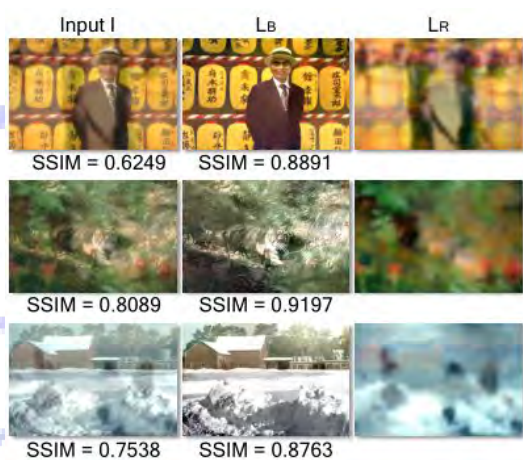


FIG.6 三个在合成数据上消除反射的例子。相应的地面真实背景层的 SSIM 也在下面列出，定量的表示我们分离的效果。值得注意的是，我们只写了恢复反射层 I_r 。

4.2.2 基于真实世界数据的结论

在真实世界情况影像分离上测试过我们的方法，我们用 Levin 和 Weiss 的用户辅助方法做过对比（用户提前使用稀疏性辅助分离一个图像中的影像）。为了用[11]产生结论，提供了大量的用户标记。然而，在某些方面，背景边缘和影像边缘相交，这使得用户标注梯度变得困难，尤其是因为影像层的散焦模糊。我们的方法可以比[11]更清楚

地分离背景和影像层。消耗时间研究 [11] 的方法是值得的。手工提供足够的标签肯定是一个挑战。另外这个方法用最小二乘法解决非凸优化，只需要几分钟。我们的方法是自动的且需要在两秒之内产生结果。然而，在上面 Figure 7 中，显示了一个我们工作中的限制。特别的，这本书封面的高光球模式（黄色线指出的）把影像层错误的分类了。这是由于加亮区是一个违反我们假设的光滑模式，背景层比影像层更清晰。

5. 讨论和结论

我们提出了一个方法，从一个图像中提取两个图层，一个图层比另一个图层平滑。我们的方法是通过相对平滑的梯度直方图模型，为每种图层构建两种可能性。为了解决图层分离问题，提出找到最有可能解释两种图层的必要目标函数。我们得到了一个有效的方案，非凸优化和一个约束不等式来优化目标函数。我们在固有图像分离和采用散焦模糊进行影像消除这两个图层分离问题上测试了我们的图像分离方法。我们的方法以一种明显快于先前工作的方式提供了高质量的结果。

一个具有挑战性的问题是，如果违反了我们的假设，两个图层有不同的平滑度，我们的方法将无法正确的分离图层。第 4 部分举了一个例子。如果违反假设的事发生了，用户干预将提供帮助。举个例子，如 Figure 8 所示，我们可以简单地拥有特殊区域属于哪一个图层的用户指示。

在未来，我们想要研究可能会得益于我们这个方法的其它图层分离问题。



FIG. 8 这是先前 Figure 7 中部分图像不正确分离的例子，我们在这里展示了一个简单地用户交互（e.g.画一个红色矩形，表示该地区属于背景）可以帮助解决这个问题。

感谢

这项工作是由新加坡 A*STARPSF grant 11212100 支持进行的。

参考文献

- [1] A. K. Agrawal, R. Raskar, S. K. Nayar, and Y. Li. Removing photography artifacts using gradient projection and flash-exposure sampling. *ToG*, 24(3):828 – 835, 2005.
- [2] J. T. Barron and J. Malik. Color constancy, intrinsic images, and shape estimation. In *ECCV*, 2012.
- [3] H. G. Barrow and J. M. Tenenbaum. Recovering intrinsic scene characteristics from images. In *Computer Vision Systems*, 1978.
- [4] A. Bousseau, S. Paris, and F. Durand. User-assisted intrinsic images. *ToG*, 28(5):130:1 – 130:10, 2009.
- [5] R. Fergus, B. Singh, A. Hertzmann, S. T. Roweis, and W. T. Freeman. Removing camera shake from a single photograph. *ToG*, 25(3):787 – 794, 2006.
- [6] P. V. Gehler, C. Rother, M. Kiefel, L. L. Zhang, and B. Schölkopf. Recovering intrinsic images with a global sparsity prior on reflectance. In *NIPS*, 2011.
- [7] D. Geman and C. Yang. Nonlinear image recovery with half-quadratic regularization. *TIP*, 4(7):932 – 946, 1995.
- [8] R. Grosse, M. K. Johnson, E. H. Adelson, and W. T. Freeman. Ground truth dataset and baseline evaluations for intrinsic image algorithms. In *ICCV*, 2009.
- [9] N. Kong, Y.-W. Tai, and S. Y. Shin. A physically-based approach to reflection separation. In *CVPR*, 2012.
- [10] E. H. Land and J. J. McCann. Lightness and retinex theory.

- JOSA, 61(1):1 - 11, 1971.
- [11] A. Levin and Y. Weiss. User assisted separation of reflections from a single image using a sparsity prior. TPAMI, 29(9):1647 - 1654, 2007.
- [12] Y. Li and M. S. Brown. Exploiting reflection change for automatic reflection removal. In ICCV, 2013.
- [13] B. Sarel and M. Irani. Separating transparent layers through layer information exchange. In ECCV, 2004.
- [14] Y. Y. Schechner, N. Kiryati, and R. Basri. Separation of transparent layers using focus. IJCV, 39(1):25 - 39, 2000.
- [15] M. Serra, O. Penacchio, R. Benavente, and M. Vanrell. Names and shades of color for intrinsic image estimation. In CVPR, 2012.
- [16] Y. Y. Shechner, J. Shamir, and N. Kiryati. Polarization and statistical analysis of scenes containing a semireflector. JOSA A, 17(2):276 - 284, 2000.
- [17] L. Shen, P. Tan, and S. Lin. Intrinsic image decomposition with non-local texture cues. In CVPR, 2008.
- [18] L. Shen and C. Yeo. Intrinsic images decomposition using a local and global sparse representation of reflectance. In CVPR, 2011.
- [19] R. Szeliski, S. Avidan, and P. Anandan. Layer Extraction from Multiple Images Containing Reflections and Transparency. In CVPR, 2000.
- [20] M.F.Tappen, W.T.Freeman, and E.H.Adelson. Recovering intrinsic images from a single image. TPAMI, 27(9):1459 - 1472, 2005.
- [21] Y. Tsin, S. B. Kang, and R. Szeliski. Stereo matching with linear superposition of layers. TPAMI, 28(2):290 - 301, 2006.
- [22] Y. Wang, J. Yang, W. Yin, and Y. Zhang. A new alternating minimization algorithm for total variation image reconstruction. SIAM Journal on Imaging Sciences, 1(3):248 - 272, 2008.
- [23] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli. Image quality assessment: From error visibility to structural similarity. TIP, 13(4):600 - 612, 2004.
- [24] Y. Weiss. Deriving intrinsic images from image sequences. In ICCV, 2001.
- [25] L. Xu, S. Zheng, and J. Jia. Unnatural L0 sparse representation for natural image deblurring. In CVPR, 2013.