

指导教师： 杨涛

提交时间： 2015/3/29

The task of
Digital Image Processing

数字图像处理

School of Computer Science

No: 1

姓名： 张天维

学号： 2012302402

班号： 10011201



动态情景的自由分段去模糊

Tae Hyun Kim and Kyoung Mu Lee

ECE 部门, ASRI, 首尔国立大学, 151-742, 首尔, 韩国

{lliger9,kyoungmu}@snu.ac.kr, <http://cv.snu.ac.kr>



图 1: (a) 模糊图像 (b) 颜色编码的运动流 (c) 我们去模糊的结果

摘要

当前最高水平的动态情景去模糊的方法是基于假设动作模糊很小的准确动作情景或者产生模糊的具体动作类型是已知的。在这片论文中, 区别于常规的方法, 我们研究了一种动态情景自由分段去模糊的方法。当动作能近似于局部的(逐像素的)不同的线性动作时, 我们能处理各个类型产生于相机抖动的模糊, 包括平面外的动作, 深度变化, 径向失真等。因此, 我们建议一个新的同时能量模型估计动作流和基于稳定的整体变异(TV)-LI模型的潜像。这个途径对处理没有分割的动作的突变很有必要。此外, 我们发表了有关传统由粗到细消除模糊架构的问题, 那些当用清晰动作恢复细小结构引起工件的时候。我们因此建议一个新内核重新初始化的方法, 可以减少动作流从粗糙的水平传播而产生的错误。而且, 一个高度有效的凸起优化算法减轻了TV-LI模型的计算难度是公认的。比较挑战真实模糊图像的实验结果, 表明了推荐方法的效率。

1. 引言

不受墨单映像去模糊, 是用于从由于相机抖动产生模糊或者物体在阴暗条件下做动作的影响中来恢复清晰图像的一种方法。这种途径已经在计算机视觉中成为了一个活跃的研究话题, 是因为最近对清晰图像的需求。然而, 去模糊是很难的, 因为指出这个问题是不适当的。为了解决问题, 很多研究者已经研究了联合预计潜像和模糊内核, 因此重新研究去模糊问题, 把它当成一个能量最小化问题, 基于一个一般性的约束:

$$B=KL+N$$

L , B 和 N 分别表示潜像、模糊图像和噪音的向量形式。矩阵 K 表示向量行的模糊内核，相应的模糊内核放置于每一个像素点上。很多内核的估计方法取决于动作模糊的类型。2D 平移相机抖动是最综合的研究动作[3,6,24]。每一个相机动作创造了一个空间上不变的模糊内核，这样的矩阵变换在(1)可以在线性卷积形式中被表示。因此，运用快速傅里叶变换让从 2D 平移相机抖动的快速内核估计成为可能。而且，相机抖动，包括旋转移动，2D 平移动作相机的推广，和由于相机回转[8,10,23]而造成空间变化模糊。虽然塑造真正相机动作的这些努力已经在通过相机动作从而恢复模糊图片中，产生了有希望的成果，但是应用这些方法去解决不是来自全球相机动作的抖动还是很难。




图 2: (a)前进动作产生的部分模糊图像 (b)-(c)[13]的分割和去模糊结果 (d)我们去模糊的结果，特别是出租车的尾灯和后挡泥板被恢复成显然比(c)更好的程度

相比之下，在不清楚具体类型的动作模糊时，传统确定性基于过滤器方法能处理各种类型的抖动[1,7]，但是这些过滤器无法处理大动作模糊以及敏感的噪音。另外，边缘统计也能用于估计局部不同的模糊内核[12]，但是，这个方法仍然受限于小动作的模糊。因此，一些研究者已经研究了能用于处理不知道具体类型的动作模糊的大型模糊的方法。Harmeling 等，提出了一个基于被表示为邻近模糊内核的加权求和的局部模糊内核的假设方法。[11]最初插值使内核强劲。虽然这些方法能顺利处理不同模糊内核，但是这些方法却不能处理模糊内核中的突然变化，这些突变一般发生在包含复数移动物体的数字图像中。

为了这些为题，一些研究者已经重点关注于消除数字图像模糊和一般需求的准确动作分割的公认方法。其中[16]，Levin 通过比较一组有 ID 盒子过滤器的可能性来分割模糊动作。然而，有限的 ID 盒子过滤器的数字已被使用。因此，不好的分割会导致不希望出现的构件。Cousin Devy 等人扩展了 Levin 在[4]解决复数标签分割问题和估计局部不同模糊的工作。然而，这些方法不能解决大型模糊，原因是候选标签的指数级增长，这些条件限制了模糊内核去缩小 2D 高斯或线性。Kim 等人最近的工作成果，提出了一个方法来估计模糊内核、潜

像和共同分割动作。假设存在的相机抖动，包括回转，和 2D 的物体平移动作，但是此方法仍然在被捕获图像在意外模糊影响下产生模糊时，其分割和去模糊都失败了，比如之前的动作，深度变形，或者径向失真。举个例子，这辆出租车因它向前运动而产生模糊，这样没预料到的动作导致了如图所示的分割和去模糊的失败。2(b)以及 2(c)。

总之，最先进的数字图像去模糊技术需要具体动作模糊类型的准确动作分割。为了减轻限制，我们提出一种不用分割以及限制模糊动作类型就能去除数字图像模糊的方法，那就是当局部各种模糊内核能被近似成 2D 动作向量的时候。虽然这个限制排除了非线性动作，但大量动作类型能在实际情况被线性化[4,5,16]。我们用很多真实模糊图像观察，然后这个方法甚至在小型相机旋转震动存在时也能成功，如实验图所示。

在 Dai 等人之前的工作中，作者们估计了模糊图像从 alpha 通道[17]而来的动作流。然而我们用一个不同于我们自身和基于 RANSAC 的应用隐式分割的约束。此外，其结果取决于给定的 alpha 通道的精确度。相比之下，我们提出一个新机制，这个机制使没有分割的动作的突然变化基于健全的 TV-LI 模型。正如 Fig.1 说明的，这个方法的提出估计了动作流和潜像。我们的方法不能让每个复杂模型去解决具体类型的动作模糊[10,23,27]，且不能取决于动作分割的精确度。此外，这个方法的提出是被嵌入到传统由粗到细机制来解决大型模糊。我们的成果是，明显动作模糊的小型结构引起了由粗到细框架严重的影。因此，我们也提出一个新方法来重新初始化动作流，总而减少在由粗到细框架里的传递错误。

在本篇论文中，我们介绍了一种新的，能共同估计空间的各种动作流和潜像的去模糊框架。我们也提供高度实用求解优化基于 TV-LI 模型凸优化算法。如 Fig.2(d)所示，即便在现在最先进的方法也失败的情况下，我们实现了更好的成果来精确估计动作流。通过挑战常规技术失败的真实图像的实验结果，我们证明了我们新的去模糊框架的效用性和实用性。

2.数字图像去模糊模型

为了解决不适宜盲目去模糊的问题，各种由正规化和数据项组成的能量模型，已经提出了估计清晰图像和其模糊内核的形式：

$$E = E_{data}(\mathbf{L}, \mathbf{K}, \mathbf{B}) + E_{reg}(\mathbf{L}, \mathbf{K}), \quad (2)$$

在数据项 E_{data} 测量数据的保真度，正规化项 E_{reg} 对潜像以及模糊内核强制执行平滑度的限制。在[13]中，作者主张(2)中的常规能量模型对数字图像去模糊是无效的，因为它首要要求动作分割。然而，在本论文中，我们提出了一个基于(2)为了去除数字图像模糊的新

能量模型。所提出的模型不要求明确的动作分割。模型的细节上如下个部分描述。

2.1 基于 L1 强大的模糊模型




图 3：动作流 $\mathbf{u}$ 相对应的模糊内核

在我们的研究中，我们假设模糊内核可以在 2D 运动矢量的期限进行线性化，

$\mathbf{u} = (u, v)^T$ ，可以被表达为：

$$\mathbf{h}(x, y) = \begin{cases} \frac{1}{\|\mathbf{u}\|} \delta(vx - uy), & \text{if } x \leq \frac{\|\mathbf{u}\|}{2}, y \leq \frac{\|\mathbf{u}\|}{2} \\ 0, & \text{otherwise.} \end{cases} \quad (3)$$

$\mathbf{h}(x, y)$ 表示模糊内核相对应的 Fig.3 中的动作流 $\mathbf{u}$ 。 δ 是狄拉克 δ 函数，因此，我们能吧内核估计问题变成动作估计问题。我们给出的新能量模型的数据项：

$$E_{data}(\mathbf{L}, \mathbf{u}, \mathbf{B}) = \lambda \sum_{\mathbf{x}} \sum_{\partial_*} |(\mathbf{k}(\mathbf{x}, \mathbf{u}))^T \partial_* \mathbf{L} - \partial_* \mathbf{B}(\mathbf{x})|, \quad (4)$$

$\mathbf{x} \in \mathbb{R}^2$ 是离散点在图形域的指数， $(\mathbf{k}(\mathbf{x}, \mathbf{u}))^T$ 表示 $\mathbf{h}$ 和总和为一的元素的离散矢量形式。这个矢量也对应着矩阵内核的行向量， $\mathbf{K}$ ，里面的 $\mathbf{x}$ 表示行的指数。

算子 $\partial_* \in \{\partial_x, \partial_y\}$ 表示部分在横和竖方向[3,13]的衍生工具。参数 λ 控制数据项的重要性。




图 4：动作流有与没有边缘图像的比较。(a)模糊图像 (b)没有边缘图像颜色码动作流
(c)有边缘图像的颜色码动作流

正如[13]中提到的，我们用潜像和模糊图像在数据模型中渐变映射来减少振铃现象。此外，所提出的模型必须允许接近动作边界的模糊内核的突变，因为消除数字图像模糊的目标是不靠分割来完成。因此我们提出在数据项基于 L1 的模型，它允许流场的间断。

虽然强大的 L1 模型在估计潜像非盲过程[24]之前被提出，但这个模型没有被用于模糊内核的估算，尽我们所知，因为它的计算难度太大。尽管很难，但我们采用 L1 模型不仅来估算潜像而且也估算模糊内核。

2.2 基于 TV 正规化

当问题提法不当时变量的平滑度必须执行以获得一个可靠的解决方案。在我们的能量模型中，两个初始未知变量是潜像 L 和动作流 u ，它们每个都有不同类型的调整，如下给出：

$$E_{reg}(L, u) = E_{reg}(L) + E_{reg}(u). \quad (5)$$

每个变量更多的规范化细节在下节介绍。

2.2.1 潜像的规范化

在(1)中，噪音被加到了我们的模糊图像中。因此，我们应该在潜像中抑制噪音，同时保留边缘。为了解决问题，许多研究者研究了之前的潜像[14,15,18]。前稀疏梯度是已知描述自然图像的边缘统计。同样，我们采用 TV 模型来规范潜像，就像[13,24]中一样。下面给出公式：

$$E_{reg}(L) = \sum_x |\nabla L|. \quad (6)$$

2.2.2 动作流中边缘感知的规范化

为了得到相似模糊内核其中的相近像素，我们规范了动作流。相似提出了前面部分的数据项，规范化动作流的关键是如何确保动作边缘能保存下来。为此，我们提出了边缘图像加上 TV 模型来规范条件，它遵从：

$$E_{reg}(u) = \mu \sum_x g(x) |\nabla u|, \quad (7)$$

它的参数 μ 控制着规范化的强度，而边缘图形 $g(\mathbf{x})$ 测量相邻像素的相似度，被定义为：

$$g(\mathbf{x}) = \exp\left(-\left(\frac{\max(|\nabla \mathbf{B}|, |\nabla \mathbf{L}_0|)}{\sigma_I}\right)^2\right). \quad (8)$$

参数 σ_I 表示衰减指数， $\mathbf{L}_0$ 是一个从粗等级的由粗到细架构的传播的中间潜像。特别是，模糊图像本身也用于获取边缘图像，因为不模糊区域可能存在于部分模糊图像中，然后它工作于 $\mathbf{L}_0$ 被变平之后。

在边缘图形规范化上的出色性能在 Fig.4 中被证明了。不出所料，被提出的调整装置保持运动的不连续性比没有边缘图形的模型要好。

3.优化架构

被提出的单图像盲消除模糊模型在之前章节中被介绍了，包括数据项和规范化项，然后目标函数给出：

$$\min_{\mathbf{L}, \mathbf{u}} \sum_{\mathbf{x}} |\nabla \mathbf{L}| + \mu g(\mathbf{x}) |\nabla \mathbf{u}| + \lambda \sum_{\partial_*} |(\mathbf{k}(\mathbf{x}, \mathbf{u}))^T \partial_* \mathbf{L} - \partial_* \mathbf{B}(\mathbf{x})|.$$

我们在(9)中的最终目标高度复杂，就是说，为了获得全球最佳。因此我们划分初始问题为两个简单子问题为 $\mathbf{L}$ 和 $\mathbf{u}$ 。我们之后应用交替优化过程，它在[3.21.26]中被介绍过了。该方法整体算法所提出的方法在算法 1 中给出。

而且，我们的方法被嵌入到传统的由粗到细架构[6,19]来解决大型动作模糊。然而，我们发现当其应用于数字图像时会引起严重的影，这些数字图像是有特殊动作模糊的小型结构。因此，我们提出一个新颖的重新自定义方法来解决这些问题。进一步细节在接下来的章节中给出。

3.1 内核的重新自定义

常规由粗到细方法广泛应用于各种领域，也已经展现了去除静态图像模糊的成功结果。这些方法能用于数字图像去模糊，但是它限制于还没有被观察到静态图像的恢复。

举个例子，一个小型结构，例如细线，拥有特殊动作模糊，不能在粗等级中被看到。因此，一些结构的动作流是其有不同动作的相邻的在规范化帮助下的估计。

Algorithm 1 Overview of the proposed method

Input: A blurry image B

Output: Latent image L and motion flow u

- 1: Build an image pyramid with 10 levels and a scale factor of 0.8
- 2: Kernel re-initialization. (Sec. 3.1)
- 3: **for** $t = 1$ to 3 **do**
- 4: Continuous optimization of motion flow u with fixed L . (Sec. 3.2)
- 5: Continuous optimization of latent image L with fixed u . (Sec. 3.3)
- 6: **end for**
- 7: Propagate variables to the next pyramid level if exists.
- 8: Repeat steps 2-7 from coarse to fine pyramid level.

然而，当小结构突然出现在模糊图像这一过程时会产生重构误差。特别是，一个相似的问题已经被在其他视觉应用[22,25]中被提出了。

在估计全球相机动作时，局部和稀疏的重构误差也许不会引发严重的影，这个动作在局部方法更严重，就像此研究中提出的方法。

为了缓和这个问题，我们给两个动作流和潜像提出了一个新内核重自定义方法。这个想法的关键是去检测错误的区域和用确定性过滤器[20]的去模糊，在那些准确动作流被估计后。于是，我们把这个问題看成标签问题来检测错误区域，这就是：

$$\min_e \sum_x e(x)(c - |(k(x, u))^T L - B(x)|) + \frac{1}{\nu} |e(x)|, \quad (10)$$

其中的向量变量 e 是逐像素二进制指针变量， $e(x) \in \{1, 0\}$ ，常数 c 是正阈值。

在(10)中介绍的第一项是重构错误时引起 $e(x)$ 为 1 的可能项， $|(k(x, u))^T L - B(x)|$ ，大于 c 。第二个项是先前给的第二项是事先给予的量 e 的稀疏，如我们假设的，高重建误差是稀疏分布，而参数 ν 控制着先前的重要性。

通过 e 的不断放宽，我们能很快获得(10)的近似结果，通过适应一阶原始偶算法，如下：

$$\begin{cases} r(x)^{n+1} = \frac{r(x)^n + \sigma e(x)^n}{\max(1, r(x)^n + \sigma e(x)^n)} \\ e(x)^{n+1} = \arg \min_e \frac{(e - (e(x)^n - \tau r(x)^{n+1}))^2}{2\tau} + \\ \quad \nu \cdot e(x)(c - |(k(x, u))^T L - B(x)|) \\ e(x)^{n+1} = \max(0, \min(1, e(x)^{n+1})), \end{cases}$$

其中 $n \geq 0$ 表明迭代数，变量 r 表示 e 的双变，更新步 σ 和 γ 控制收敛速度[2]。




图 5: (a)粗等级估计潜像(b)黄色表示检测错误区域(c)粗等级下的裁剪结果(d)没用重自定义在最细等级下的裁剪结果(e)用了重自定义在最细等级下的裁剪结果

在检测错误区域后，我们重新自定义了值为零区域的传播动作，它们表示模糊内核的脉冲。通过应用章节 3.3 中的清晰图像恢复，我们恢复了特殊模糊动作的小构件。然而，新的恢复小构件依然模糊，应为它是从模糊内核的脉冲中估计的。因此，我们应用了确定性过滤器来去除构件的模糊并且使动作流估计的快速收敛更容易。为了这个过程，我们用[3]中介绍的预测步。整个过程呈现在算法 2 中。

我们重自定义步的必要性在 Fig.5 中被介绍。特别是一条 Fig.5(c)中在粗等级中看不见的细线，相比 Figs.5(d)到(e)，应用我们的方法恢复成功了。

Algorithm 2 Kernel re-initialization algorithm

Input: A blurry image B , intermediate latent image L and motion flow u propagated from coarser pyramid level.

Output: Re-initialized motion flow u and edge-enhanced L .

- 1: for $n = 1$ to 50 do
- 2: Compute e using (11)
- 3: end for
- 4: $u(x) \leftarrow 0$, if $e(x) > 0.5$
- 5: Continuous optimization of L with re-initialized u (Sec. 3.3)
- 6: Enhance edge by applying prediction step in [3]

3.2 估计动作流

潜像 L 被确定，在(9)中提出的能量模型很简单。但是数据项 $\rho(x, u)$ 在 u 上是非凸的，它使优化变得棘手。

$$\rho(x, u) = \sum_{\theta_*} |(k(x, u))^T \partial_* L - \partial_* B(x)|.$$

为了让优化方便，我们让从 Taylor 近似数据函数变得线性来获得：

$$\rho(\mathbf{x}, \mathbf{u}) \approx \rho(\mathbf{x}, \mathbf{u}_0) + \nabla \rho(\mathbf{x}, \mathbf{u}_0)^T (\mathbf{u} - \mathbf{u}_0),$$

其中的 $\mathbf{u}_0$ 是动作流 $\mathbf{u}$ 的初值， $\nabla \rho(\mathbf{x}, \mathbf{u}_0)$ 表示一阶导数。通过近似，提出的能量模型成为近似于 $\mathbf{u}_0$ 的凸，其结果为：

$$\mathbf{u} = \arg \min_{\mathbf{u}} \sum_{\mathbf{x}} \mu \cdot g(\mathbf{x}) |\nabla \mathbf{u}| + \lambda (\rho(\mathbf{x}, \mathbf{u}_0) + \nabla \rho(\mathbf{x}, \mathbf{u}_0)^T (\mathbf{u} - \mathbf{u}_0)),$$

为了解决，我们采用[2]中的凸优化算法，下面给出原始的双重更新过程：

$$\begin{cases} \mathbf{p}^{n+1} = \frac{\mathbf{p}^n + \sigma(\mathbf{GA})\mathbf{u}^n}{\max(1, \mathbf{p}^n + \sigma(\mathbf{GA})\mathbf{u}^n)} \\ \mathbf{u}^{n+1} = (\mathbf{u}^n - \tau(\mathbf{GA})^T \mathbf{p}^{n+1}) - \tau(\frac{\lambda}{\mu}) \nabla \rho(\mathbf{x}, \mathbf{u}_0), \end{cases}$$

其中 $\mathbf{p}$ 表示 $\mathbf{u}$ 在向量域的双变。连续线性算子 $\mathbf{A}$ 与其相邻像素的计算有所不同，对角线矩阵 $\mathbf{G}$ 是加权矩阵，表示为 $\mathbf{G} = \text{diag}(g(\mathbf{x}))$ 。这个更新过程对实施和快速收敛来说很容易。

3.3 清晰图像估计

动作流 $\mathbf{u}$ 和相应内核矩阵 $\mathbf{K}$ 是固定的，则提出的能量模型成为有名非盲去模糊模型。

然而，在我们提出数据项所应用的 $L1$ 模型中，要求高计算量。为了解决问题，我们采用了二次松弛方法[22]来简化结果。因此，我们介绍辅助变量 $\mathbf{f}^*$ ，表示为：

$$\min_{\mathbf{L}, \mathbf{f}} \sum_{\mathbf{x}} |\nabla \mathbf{L}| + \lambda \sum_{\mathbf{x}} |\mathbf{f}_*(\mathbf{x})| + \frac{1}{2\theta} \sum_{\mathbf{x}} ((\mathbf{k}(\mathbf{x}, \mathbf{u}))^T \partial_* \mathbf{L} - \partial_* \mathbf{B}(\mathbf{x}) + \mathbf{f}_*(\mathbf{x}))^2.$$

如果固定参数 θ 被设为很小的值，那么(16)的最小值接近于其原始的 TV- $L1$ 模型。运用分解，两个 $\mathbf{L}$ 的函数和 $\mathbf{f}^*$ 的函数解决起来会简单 1000 倍，而且每个在[2]中的交替优化过程变量都被解决了。

$$\begin{cases} \mathbf{q}_*(\mathbf{x})^{n+1} = \frac{\mathbf{q}_*(\mathbf{x})^n + \sigma \mathbf{f}_*(\mathbf{x})^n}{\max(1, \mathbf{q}_*(\mathbf{x})^n + \sigma \mathbf{f}_*(\mathbf{x})^n)} \\ \mathbf{f}_*(\mathbf{x})^{n+1} = \arg \min_{\mathbf{f}} \frac{(\mathbf{f} - (\mathbf{f}_*(\mathbf{x})^n - \tau \mathbf{q}_*(\mathbf{x})^{n+1}))^2}{2\tau} + \\ \frac{1}{2\theta\lambda} \sum_{\mathbf{x}} ((\mathbf{k}(\mathbf{x}, \mathbf{u}))^T \partial_* \mathbf{L} - \partial_* \mathbf{B}(\mathbf{x}) + \mathbf{f}_*(\mathbf{x}))^2, \end{cases} \quad (17)$$

其中变量 $\mathbf{q}^*$ 是 $\mathbf{f}^*$ 的双变。

近似地， $\mathbf{f}^*$ 被固定时 $\mathbf{L}$ 的更新过程给出为：

$$\begin{cases} \mathbf{s}^{m+1} = \frac{\mathbf{s}^m + \sigma_L \mathbf{A} \mathbf{L}^m}{\max(1, \mathbf{s}^m + \sigma_L \mathbf{A} \mathbf{L}^m)} \\ \mathbf{L}^{m+1} = \arg \min_{\mathbf{L}} \frac{(\mathbf{L} - (\mathbf{L}^m - \tau_L \mathbf{A}^T \mathbf{s}^{m+1}))^2}{2\tau_L} + \\ \frac{1}{2\theta\lambda} \sum_{\partial_*} (\mathbf{K} \partial_* \mathbf{L} - \partial_* \mathbf{B} + \mathbf{f}_*)^2, \end{cases} \quad (18)$$

其中 $m \geq 0$ 表示迭代数，参数 σ_L 和 τ_L 表示更新步和向量 $\mathbf{s}$ 是 $\mathbf{L}$ 的双变。此外，我们采用共轭梯度（CG）方法来更新原始变量 $\mathbf{L}$ ，在(18)中。

估计清晰图像的全部步骤在算法 3 中展示：

Algorithm 3 Sharp Image Estimation

Input: A blurry image $\mathbf{B}$ and motion flow $\mathbf{u}$

Output: Sharp image $\mathbf{L}$

```
1: for  $n = 1$  to 3 do
2:   Update  $\mathbf{f}_*$  using (17)
3:   for  $m = 1$  to 30 do
4:     Update  $\mathbf{L}$  using (18)
5:   end for
6: end for
```

3.4 执行

执行过程中，我们大部分实验用固定参数除了参数 λ ，因为每个模糊图像都有不同的噪音量和不同的模糊内核大小，参数 λ 调整能改变的动作流和潜像的稳定。我们设置参数：

$$\mu = 1, \sigma_I = \frac{15}{255}, c = 0.05, \nu = 0.02, \\ \sigma = \frac{1}{2\sqrt{(2)}}, \tau = \frac{1}{2\sqrt{(2)}}, \sigma_L = 10, \tau_L = 0.0125, \theta = \frac{0.1}{\lambda}.$$

其中 λ 值的范围从 10 到 50。

在由粗到细架构中，我们建立了一个 10 层的图像金字塔和 0.8 比例因子，然后给每个传播中的动作流和潜像进行双三次插值。最初，所有双变设置为 0。此外，模糊图像本身被用来初始化潜像 $\mathbf{L}$ ，然后我们用小随机数来初始化动作流 $\mathbf{u}$ 。然而，就像我们的模糊内核是对称的 (i.e. $\mathbf{k}(\mathbf{x}, \mathbf{u}) = \mathbf{k}(\mathbf{x}, -\mathbf{u})$)，我们约束动作流：

$$(u, v), \text{ to be on a set, } \mathbb{B} = \{(u, v) \in \mathbb{R}^2 | u \geq 0\} - \{(u, v) \in \mathbb{R}^2 | u = 0, v < 0\}.$$

我们目前用 MATLAB 执行大约需要 25 分钟来消除 VGA 图像的模糊。通过在

GPGPU 模型中优化 C 或 CUDA，能使运行时间极大缩短。

4.实验结果

本节中，我们把提出的工作的优秀性能和效率展现出来。

在 Fig.6 中，去模糊结果和动作流估计在真正具有挑战性的动态场景被展示过了。在定性分析中，去模糊图像的边缘被敏锐地恢复而不分割、不限制动作模糊的类型。动作流估计的颜色码在纹理区域中跟我们期待的一样准确，除了同质区域不能产生严重的影。特别是最下一行的动作流是对应于潜像的深度图，他能成为我们工作的另一个应用，来从模糊单图中估计深度图。

在 Fig.7 中，介绍了包括了旋转相机动作的相机抖动的去模糊结果。因为提出的方法是基于局部线性模糊内核的近似，其结果也许不比估计低纹理区域的全球相机动作估计的方法准确。然而合成图像最上行被恢复的粗边和真实图像在底边表示，我们的近似是针对小程度小型旋转相机抖动。

此外，我们比较了在各种有挑战性条件下，我们的结果和最先进的去模糊方法。首先，在 Fig.8(a)中，模糊图像被严重的径向畸变退化而且它引起了常规方法中的严重问题。第二，在 Fig.8(b)中，因为引发具体向前运动不能用常规方法解决，我们的优化和恢复物体的边和让箭头更明显。第三，在 Fig.8(c)中，[26]在模糊图像中中断存在的去模糊过程中失败了。虽然基于分割方法的去模糊是可能的，但是[13]也失败了。因此，两个常规方法提供了差强人意的结果。最后，在 Fig.8(d)中，深度中断的合成图像，模糊产生于旋转相机抖动，所以，两个常规方法失败，我们的方法却展现出了成功的结果。

5.讨论和限制

在研究中，我们已经介绍了一个有效率的，不要求在基于 TV-L1 模型的帮助下准确动作分割的数字图像的去模糊方法。此外，被提出的方法在内核能被近似为线性动作时，能解决各种类型的模糊内核。我们特提供了有效率且实际的解决方法优化 TV-L1 模型，然后证明了提供的方法在各种挑战性条件下，性能优于最先进的方法。

另外，剩余的问题是，在知道动作模糊的具体类型的情况下，常规去模糊方法估计全球相机动作运行良好，其结果在纹理较少区域中比我们的好。因此我们未来的工作将在统一架构上结合这些全球和我们自己的研究。




图 6: (a)真实模糊数字图像 (b)去模糊结果 (c)结果比较 (d)动作流估计




图 8: 从左到右: 模糊图像, Xu[26]等人的结果, Kim 等人[13]的结果, 和提出方法的结果。



图 7: (a)旋转相机抖动的模糊图像 (b)去模糊结果

(c)比较结果

感谢

本研究部分由 MKE(The Ministry of Knowledge Economy)支持, 韩国和微软科研, 在 IT/SW Creative 研究计划下, 监督于 NIPA(National IT Industry Promotion Agency) (NIPA-2013-H0503-13-1041)。

参考

- [1] P. Bhat, C. L. Zitnick, M. Cohen, and B. Curless. Gradientshop: A gradient-domain optimization framework for image and video filtering. *ACM Transactions on Graphics (TOG)*, 29(10), 2010. 2
- [2] A. Chambolle and T. Pock. A first-order primal-dual algorithm for convex problems with applications to imaging. *Journal of Mathematical Imaging and Vision*, 40(1):120–145, May 2011. 4, 5
- [3] S. Cho and S. Lee. Fast motion deblurring. In *SIGGRAPH*, 2009. 1, 3, 4, 5
- [4] F. Couzinie-Devy, J. Sun, K. Alahari, and J. Ponce. Learning to estimate and remove non-uniform image blur. In *CVPR*, 2013. 2
- [5] S. Dai and Y. Wu. Motion from blur. In *CVPR*, 2008. 2
- [6] R. Fergus, B. Singh, A. Hertzmann, S. T. Roweis, and W. Freeman. Removing camera shake from a single photograph. In *SIGGRAPH*, 2006. 1, 4
- [7] G. Gilboa, N. Sochen, and Y. Y. Zeevi. Image enhancement and denoising by complex diffusion processes. *IEEE Trans. Pattern Analysis Machine Intelligence*, 26(8):1020–1036, 2004. 2
- [8] A. Gupta, N. Joshi, L. Zitnick, M. Cohen, and B. Curless. Single image deblurring using motion density functions. In *ECCV*, 2010. 1
- [9] S. Harmeling, H. Michael, and B. Schoelkopf. Space-variant single-image blind deconvolution for removing camera shake. In *NIPS*, 2010. 2
- [10] M. Hirsch, C. J. Schuler, S. Harmeling, and B. Scholkopf. Fast removal of non-uniform camera shake. In *ICCV*, 2011. 1, 2
- [11] H. Ji and K. Wang. A two-stage approach to blind spatially-varying motion deblurring. In *CVPR*, 2012. 2
- [12] N. Joshi, R. Szeliski, and D. Kriegman. Psf estimation using sharp edge prediction. In *CVPR*, 2008. 2

- [13] T. H. Kim, B. Ahn, and K. M. Lee. Dynamic scene deblurring. In *ICCV*, 2013. 2, 3, 6, 8
- [14] D. Krishnan and R. Fergus. Fast image deconvolution using hyper-laplacian priors. In *NIPS*, 2009. 3
- [15] D. Krishnan, T. Tay, and R. Fergus. Blind deconvolution using a normalized sparsity measure. In *CVPR*, 2009. 3
- [16] A. Levin. Blind motion deblurring using image statistics. In *NIPS*, 2006. 2
- [17] A. Levin, D. Lischinski, and Y. Weiss. A closed form solution to natural image matting. *IEEE Trans. Pattern Analysis Machine Intelligence*, 30(2):228–242, 2008. 2
- [18] A. Levin and Y. Weiss. User assisted separation of reflections from a single image using a sparsity prior. *IEEE Trans. Pattern Analysis Machine Intelligence*, 29(9):1647–1654, 2007. 3
- [19] A. Levin, Y. Weiss, F. Durand, and W. T. Freeman. Understanding and evaluating blind deconvolution algorithms. In *CVPR*, 2009. 4
- [20] S. Osher and L. I. Rudin. Feature-oriented image enhancement using shock filters. *SIAM Journal on Numerical Analysis*, 27(4):919–940, 1990. 4, 5
- [21] Q. Shan, J. Jia, and A. Agarwala. High-quality motion deblurring from a single image. In *SIGGRAPH*, 2008. 4
- [22] F. Steinbruecker, T. Pock, and D. Cremers. Large displacement optical flow computation without warping. In *ICCV*, 2009. 4, 5
- [23] O. Whyte, J. Sivic, A. Zisserman, and J. Ponce. Non-uniform deblurring for shaken images. *International Journal of Computer Vision*, 98(2):168–186, 2012. 1, 2
- [24] L. Xu and J. Jia. Two-phase kernel estimation for robust motion deblurring. In *ECCV*, 2010. 1, 3
- [25] L. Xu, J. Jia, and Y. Matsushita. Motion detail preserving optical flow estimation. *IEEE Trans. Pattern Analysis Machine Intelligence*, 34(9):1744–1757, 2012. 4
- [26] L. Xu, S. Zheng, and J. Jia. Unnatural 10 sparse representation for natural image deblurring. In *CVPR*, 2013. 4, 6, 8
- [27] S. Zheng, L. Xu, , and J. Jia. Forward motion deblurring. In *ICCV*, 2013. 2