

基于深度先验的盲图像去模糊算法

白勇强, 禹 晶, 李一农, 肖创柏

(北京工业大学信息学部, 北京 100124)

摘要: 盲图像去模糊旨在模糊核未知的情况下从模糊图像恢复清晰图像, 这是一个欠定逆问题, 需要引入图像先验信息限定解空间. 受到SelfDeblur的启发, 本文提出了一种基于深度先验的盲图像去模糊算法, 结合深度网络与正则化模型对清晰图像与模糊核联合建模, 交替迭代估计清晰图像与模糊核. 在图像估计子问题中, 模糊核参与RGB三通道损失函数的约束下, 利用隐含图像平滑性约束的深度卷积神经网络DIP-Net生成清晰图像; 在模糊核估计子问题中, 直接求取模糊核正则化约束模型的全局极小解, 不同于SelfDeblur的全连接网络使用梯度下降法更新模糊核. 本文算法结合深度网络实现正则化方法, 与监督学习相比, 无需成对的模糊/清晰图像数据集训练网络; 与传统模型方法相比, 无需通过多级金字塔的方式由粗到细地估计模糊核. 在模拟与真实模糊图像上的实验结果表明; 本文算法能够快速、准确地估计出清晰图像和模糊核, 并能够有效抑制图像复原过程中存在的噪声放大问题.

关键词: 盲图像去模糊; 深度先验; 卷积神经网络; 正则化; 盲解卷积; 图像复原

基金项目: 北京市自然科学基金(No.4212014); 北京市教育委员会科技计划(No.KM201910005029)

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 0372-2112(2023)04-1050-18

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20211483

Deep Prior-Based Blind Image Deblurring

BAI Yong-qiang, YU Jing, LI Yi-nong, XIAO Chuang-bai

(Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China)

Abstract: Blind image deblurring is the process of removing blurring artifacts from the observation when the blur kernel is unknown, which is a seriously ill-posed problem. It is indispensable to impose prior information constraints on the feasible set. Inspired by the SelfDeblur, in this paper we propose a deep prior-based blind image deblurring method, which uses the deep network and the regularized optimization model to jointly optimize and alternately update the latent image and the blur kernel. Conditioned by the loss of the sum of RGB three-channel errors with the presence of blur kernel, the latent image is estimated using the deep convolutional neural network DIP-Net implicitly involving the smoothness regularizer of the image. The blur kernel estimation subproblem admits the global optimal solution, which is different from the SelfDeblur that applies the fully connected network and takes the gradient descent step to update the blur kernel. Our method uses the structure of the deep network to regularize the latent image. Unlike the supervised image deblurring method, it requires no ground truth of the latent image or the blur kernel. Unlike the traditional model, it requires no progressive transmission from coarse to fine through the multi-level pyramid. Experimental results on simulated and real blur images show that the proposed method achieves a fast and accurate estimation of both the blur kernel and the latent image with efficient noise suppression.

Key words: blind image deblurring; deep image prior; convolutional neural network; regularization; blind deconvolution; image restoration

Foundation Item(s): Beijing Natural Science Foundation (No.4212014); Scientific Research Common Program of Beijing Municipal Commission of Education (No.KM201910005029)

1 引言

图像复原通过建立图像降质模型, 求解图像降质的逆过程, 恢复清晰图像. 在获取图像的过程中, 成像系统与场景之间的相对运动, 导致图像发生运动模糊,

这是一种常见的图像降质过程.

在图像去模糊问题中, 均匀模糊的降质过程可以表示为如下的空域卷积:

$$y = h * x + n \quad (1)$$

其中, y 为模糊图像, h 为模糊核, x 为清晰图像, n 为噪声, $*$ 为二维卷积操作. 根据模糊核是否已知, 图像去模糊问题可分为两类: 在模糊核已知时, 从模糊图像恢复原图像称为非盲图像去模糊; 若模糊核是未知的, 则称为盲图像去模糊. 由于均匀模糊的降质过程建模为模糊核与清晰图像的卷积, 因此盲图像去模糊问题也称为盲解卷积问题. 盲解卷积问题具有严重的病态性, 需要引入图像先验信息来限定可行解的空间. 近年来基于深度卷积神经网络 (Convolutional Neural Network, CNN) 的盲图像去模糊方法取得了显著的进展.

基于深度网络的盲图像去模糊方法自适应地学习清晰图像, 可分为监督学习和非监督学习的方法. 监督学习的方法需要利用大量成对的模糊/清晰图像构成的外部数据集, 学习它们之间的映射关系, 当训练数据集不能提供与待复原图像相似特征或降质过程时, 难以保证图像复原的质量. Nah 等^[1]利用多尺度卷积神经网络建模金字塔结构, 提出了图像去模糊的多尺度网络结构, 粗一级尺度估计的清晰图像与细一级的模糊图像级联作为细一级图像估计的输入, 将不同尺度的清晰图像作为监督标签. Schuler 等^[2]通过交替级联特征提取、模糊核估计和清晰图像估计模块的方式模拟基于统计先验的盲图像去模糊过程. Yan 等^[3]利用预训练的卷积神经网络对高斯模糊、运动模糊和散焦模糊进行分类, 使用广义回归网络 (General Regression Neural Network, GRNN) 估计模糊核参数. Tao 等^[4]利用尺度递归网络 (scale-recurrent network) 由粗到细地聚合多尺度特征, 建模金字塔结构, 实现端到端的去模糊. DeblurGAN^[5]利用成对的模糊/清晰图像训练生成式对抗网络 (Generative Adversarial Network, GAN), 在生成器的损失函数中增加特征表示的 l_2 损失. DeblurGAN-v2^[6]在文献[5]的基础上进一步通过特征金字塔网络 (Feature Pyramid Network, FPN) 结合多尺度特征提升模型性能. Zhang 等^[7]将模糊图像划分为不同尺度的区域来聚合局部到整体的多尺度信息. Suin 等^[8]在 Zhang 等^[7]的基础上引入全局注意力与自适应局部注意力模块, 实现信息互补, 解决动态场景下出现的非均匀运动模糊问题. Yuan 等^[9]在深度网络中引入可变形卷积层使得网络能够根据模糊特征自适应地调整感受域, 有效地去除非均匀模糊. Kaufman 等^[10]在深度网络中引入图像自相关运算层来估计模糊核, 并将其用于去模糊网络实现清晰图像的复原. 非监督学习的方法无需模糊图像对应的清晰图像作为网络训练的监督信号, 主要包括非成对迁移学习和自监督学习两类. 非成对迁移学习即利用生成式对抗网络学习模糊图像域与清晰图像域中分布的映射, 而不是模糊图像与其对应的清晰图像之间的映射. Lu 等^[11]利用两个特征提取网络分别学

习内容特征和模糊特征, 通过与高斯分布的相似性约束模糊特征, 实质上假设图像具有高斯模糊, 根据学习的模糊特征, 通过生成式对抗网络约束去模糊结果与清晰图像数据集相似, 并通过图像内容特征的循环一致性约束保证图像内容的相似性. 自监督学习是以降质图像作为监督信号, 无需外部数据集. SelfDeblur^[12]模型利用 DIP-Net^[13]估计清晰图像, 利用全连接网络 (Fully-Connected Network, FCN) 估计模糊核, 同时更新两个网络的参数估计模糊核与清晰图像.

受到 SelfDeblur^[12]的启发, 本文提出了一种基于深度先验的盲图像去模糊算法 Fast-SelfDeblur, 将深度网络与正则化约束模型相结合, 对清晰图像和模糊核联合建模, 以交替迭代最优化求解的方式, 利用 DIP-Net^[13]估计清晰图像, 通过直接求解模糊核正则化模型的闭合解估计模糊核, 同时估计清晰图像和模糊核. Fast-SelfDeblur 仅利用模糊图像监督网络参数的学习过程, 是一种自监督学习的盲图像去模糊方法. 本文算法与 SelfDeblur 均利用 DIP-Net 作为图像生成网络, 然后将复原误差作为损失函数并更新网络参数. 与 SelfDeblur 的区别在于: SelfDeblur 需要更新全连接和 DIP-Net 两个网络的参数, 模型复杂度高, 而 Fast-SelfDeblur 根据凸优化问题的极值条件直接求取当前估计图像对应模糊核的精确解, 降低算法复杂度; SelfDeblur 使用全连接网络生成模糊核需要将其表示为一维向量的形式, 忽略了模糊核的二维空域相关性, 而 Fast-SelfDeblur 根据卷积定理, 在频域中求解模糊核的正则化模型, 直接求出二维形式的模糊核, 加速算法收敛. 与传统模型的方法相比, Fast-SelfDeblur 无需采用图像金字塔的方式由粗到细估计模糊核; 与监督学习的盲图像去模糊方法相比, Fast-SelfDeblur 无需监督网络训练的外部数据集.

2 相关工作

自然图像的先验模型旨在建立清晰图像的特征表示, 限定图像复原问题的解空间. 传统的统计先验对自然图像的统计特征进行数学建模, 但是数学表达式难以表示复杂的自然图像先验. 近年来利用深度网络显式或隐式地表示图像的先验信息的方法被提出, 称为深度先验.

2.1 统计先验

以往的工作主要利用图像梯度的稀疏性先验. Chan 等^[14]将全变分 (Total Variation, TV) 正则化引入图像去模糊任务, 将模糊核和图像两者在梯度域的稀疏性作为正则化约束. Perrone 等^[15]对图像梯度和模糊核进行 Tikhonov 正则化约束. Xu 等^[16]利用全变分正则化约束图像梯度, 采用 Tikhonov 正则化进行模糊核粗估计, 通过稀疏筛选来细化模糊核. 清晰图像的梯度通常

服从拖尾分布 (heavy-tailed distribution), Fergus 等^[17]和 Levin 等^[18]利用高斯混合模型建模拖尾分布. Shan 等^[19]使用线性函数与二次函数连接的分段函数作为图像梯度的罚函数. 方等^[20]使用 l_0 范数约束图像梯度和模糊核. 余等^[21]使用 l_p 范数与 l_2 范数的比值建模图像先验. 图像梯度描述图像相邻像素间灰度值的变化率, 而图像块先验能够表示更大的图像结构. Michaeli 等^[22]对低分辨率图像与其降采样图像中成对的跨尺度相似图像块构造正则约束项, 通过最大化跨尺度相似性来估计模糊核. Zhang 等^[23]将图像块的稀疏表示作为正则约束项进行模糊核估计. 徐等^[24]将图像的稀疏性先验和同尺度非局部先验作为正则化约束来估计模糊核. Ren 等^[25]构建了图像亮度和梯度的低秩约束先验用于估计模糊核. Pan 等^[26]以正则化约束项的形式将暗通道先验^[27]引入去模糊目标函数. 在文献[26]的基础上, Yan 等^[28]提出了亮通道先验, 并与暗通道先验相结合用于模糊核估计. Chen 等^[29]利用局部最大梯度值作为正则项约束估计模糊核. 基于统计先验的盲图像去模糊方法利用手工设计的先验构建图像先验模型, 通常难以描述复杂的图像特征.

2.2 深度先验

深度先验通过深度网络自适应学习清晰图像隐含的特征, 无需用数学模型解析地表示先验. 目前盲图像去模糊使用深度先验的方法并不多.

在图像复原任务中, 深度先验可分为显式和隐式两类. 一类从外部图像数据集学习清晰图像的先验模型. Zhang 等^[30]利用半二次分裂 (half quadratic splitting) 技术将复原问题目标函数中的保真项与先验项分解为图像复原子问题和图像去噪子问题, 利用由成对的清晰/有噪图像构成的数据集训练深度网络求解去噪子问题, 并将其作为先验信息引入到图像复原过程中. Li 等^[31]使用成对的清晰/模糊图像数据集训练二值分类网络, 将其作为图像判别先验并以正则化约束的形式引入目标函数中. 另一类利用网络结构实现图像的先验约束. Ulynov 等^[13]提出了通过深度网络结构实现正则化的思路, 并在 U-Net^[32]的基础上提出一种具有跨层连接的 U 型编解码结构的深度图像先验网络 (Deep Image Prior Net, DIP-Net), 隐式建模图像的平滑性先验约束. DeepRED^[33]将去噪正则项 (REGularization by Denoising, RED) 引入 DIP-Net 的损失函数, 该正则项使得复原图像可以逼近任何去噪函数的预处理结果. Wang 等^[34]将卷积层中卷积核的正交性约束以正则化项的形式加入到 DIP-Net 的损失函数中, 减少冗余的特征.

2.3 DIP-Net 模型

DIP-Net^[13]是编解码结构的图像生成网络, 学习随机向量 \mathbf{z} 到清晰图像 \mathbf{x} 的映射 $\mathbf{x} = f(\mathbf{z}; \boldsymbol{\theta})$, 其中, $\boldsymbol{\theta}$ 为网

络参数. 实验表明, 若以有噪图像为监督信号, DIP-Net 编码阶段的下采样相当于平滑滤波, 在随机向量到有噪图像的映射过程中, 倾向于拟合无噪的清晰图像, 有效解决图像去噪问题.

对于线性移不变降质过程, 图像复原正则化方法一般可以表示为如下的正则化最小二乘问题:

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \|\mathbf{y} - \mathbf{h} * \mathbf{x}\|_2^2 + \lambda_x R(\mathbf{x}) \quad (2)$$

其中, \mathbf{y} 为模糊图像, \mathbf{h} 为模糊核, \mathbf{x} 为清晰图像, $R(\mathbf{x})$ 为平滑性函数, λ_x 为正则项参数. 目标函数中, 前一项为数据保真项, 保证清晰图像和模糊核的估计符合图像降质模型; 后一项为平滑性先验约束项, 抑制噪声放大.

DIP-Net 利用网络结构隐式地建模式 (2) 中平滑性先验约束项 $R(\mathbf{x})$, 网络损失函数可写为

$$\hat{\boldsymbol{\theta}} = \arg \min_{\boldsymbol{\theta}} \|\mathbf{y} - \mathbf{h} * f(\mathbf{z}; \boldsymbol{\theta})\|_2^2 \quad (3)$$

其中, $\boldsymbol{\theta}$ 为网络参数, \mathbf{z} 为网络输入. $\hat{\mathbf{x}} = f(\mathbf{z}; \hat{\boldsymbol{\theta}})$ 为网络生成的清晰图像, $\hat{\boldsymbol{\theta}}$ 为网络最优参数.

DIP-Net 的输入 \mathbf{z} 为区间 $[0, 1]$ 上均匀分布的随机向量, 即 $\mathbf{z} \sim U(0, 1)$, 并添加随机扰动, 其尺寸与清晰图像 \mathbf{x} 相同. 网络的输出层采用 Sigmoid 函数使得输出图像的值为 $[0, 1]$.

DIP-Net 是一种自监督学习方法, 在网络训练过程中, 无需清晰图像真值作为监督信号. 其本质上是一种正则化方法, 对于每一幅图像都需要学习网络参数, 参数更新过程实际上是最优化问题的求解过程. 图像复原过程是图像降质过程的逆过程, 在逆过程中通常会放大噪声, 而 DIP-Net 具有平滑性约束, 能够抑制噪声放大, 因此可以在图像复原问题中用于清晰图像的估计.

2.4 SelfDeblur 模型

SelfDeblur^[12]在 DIP-Net^[13]的基础上联合两个网络模型实现盲图像去模糊, 利用 DIP-Net 估计清晰图像, 利用全连接网络估计模糊核, 损失函数表示为如下最优化问题:

$$\begin{aligned} \min_{\boldsymbol{\theta}_h, \boldsymbol{\theta}_x} L(\boldsymbol{\theta}_h, \boldsymbol{\theta}_x) &= \left\| f_h(\mathbf{z}_h; \boldsymbol{\theta}_h) * f_x(\mathbf{z}_x; \boldsymbol{\theta}_x) - \mathbf{y} \right\|_2^2 \\ \text{s.t. } &0 \leq (f_x(\mathbf{z}_h; \boldsymbol{\theta}_h))_i \leq 1, \forall i \\ &(f_h(\mathbf{z}_h; \boldsymbol{\theta}_h))_i \geq 0, \forall i, \sum_i (f_h(\mathbf{z}_h; \boldsymbol{\theta}_h))_i = 1 \end{aligned} \quad (4)$$

其中, $f_x(\mathbf{z}_x; \boldsymbol{\theta}_x)$ 为网络输入为 \mathbf{z}_x 、网络参数为 $\boldsymbol{\theta}_x$ 的图像生成网络, $f_h(\mathbf{z}_h; \boldsymbol{\theta}_h)$ 为网络输入为 \mathbf{z}_h 、网络参数为 $\boldsymbol{\theta}_h$ 的模糊核估计网络, $*$ 为二维卷积运算, $(f_x(\mathbf{z}_x; \boldsymbol{\theta}_x))_i$ 和 $(f_h(\mathbf{z}_h; \boldsymbol{\theta}_h))_i$ 分别表示估计图像与模糊核中位置为 i 的元素值.

图 1 为 SelfDeblur^[12]模型的整体结构. \mathbf{z}_x 和 \mathbf{z}_h 为区

间 $[0, 1]$ 上均匀分布的随机向量,即 $z_x, z_h \sim U(0, 1)$, z_x 的尺寸与目标图像尺寸一致, z_h 为200维的列向量. 全连接网络的输出层采用Softmax函数使输出结果满足式(4)中非负性和等式约束. SelfDeblur对图像估计网络 $f_x(z_x; \theta_x)$ 与模糊核估计网络 $f_h(z_h; \theta_h)$ 均利用梯度下降法同时更新两者的参数,联合求解清晰图像与模糊核.




图1 SelfDeblur模型结构

3 基于深度先验的盲图像去模糊算法

本文提出了一种基于深度先验的盲图像去模糊算法Fast-SelfDeblur,对清晰图像和模糊核联合建模,结合深度网络与数学模型,通过变量交替求解的方式估计清晰图像与模糊核,实现盲图像去模糊.本节将详细描述所提出算法的数学模型及其求解过程.

3.1 Fast-SelfDeblur 数学模型

通过引入模糊核 h 的正则化约束项作为模糊核先验,结合式(3)中DIP-Net的损失函数,本文提出的Fast-SelfDeblur的目标函数可表示为

$$(\hat{h}, \hat{\theta}) = \arg \min_{h, \theta} \|y - h * f(z; \theta)\|_2^2 + \lambda_h \|h\|_2^2 \quad (5)$$

其中, y 为模糊图像, $f(z; \theta)$ 为网络输入为 z 、参数为 θ 的图像生成网络, h 为模糊核, λ_h 为正则化参数.目标函数由数据保真项和模糊核 h 的约束项构成.

图2为本文提出的Fast-SelfDeblur算法的整体结构. Fast-SelfDeblur算法将深度网络与正则化约束模型结合,通过变量交替求解式(5)所示的最优化问题,联合估计清晰图像和模糊核. Fast-SelfDeblur算法利用DIP-Net估计清晰图像,最小化损失函数更新网络参数的过程就是图像估计的过程,通过求解模糊核正则化模型估计模糊核,交替迭代更新清晰图像与模糊核.在每一次迭代过程中, Fast-SelfDeblur算法首先利用DIP-Net生成的清晰图像 $x = f(z; \theta)$,与模糊图像 y 估计模糊核 h ,然后固定当前估计的模糊核 h ,计算损失函数关于 x 的梯度,利用梯度下降法更新图像生成网络的参数 θ ,

$$h_k = \mathcal{F}^{-1} \left(\frac{\overline{\mathcal{F}(\partial_h x_{k-1})} \mathcal{F}(\partial_h y) + \mathcal{F}(\partial_v x_{k-1}) \mathcal{F}(\partial_v y)}{\mathcal{F}(\partial_h x_{k-1}) \mathcal{F}(\partial_h x_{k-1}) + \mathcal{F}(\partial_v x_{k-1}) \mathcal{F}(\partial_v x_{k-1}) + \lambda_h} \right) \quad (8)$$

其中, $\mathcal{F}(\cdot)$ 为傅里叶变换, $\mathcal{F}^{-1}(\cdot)$ 为傅里叶逆变换, $\overline{\mathcal{F}(\cdot)}$ 为傅里叶变换的复共轭.

图像的平坦区域会对模糊核的估计造成干扰,且

从而更新清晰图像 $x = f(z; \theta)$,重复以上步骤直至收敛.与SelfDeblur^[12]相比,本文模型仅需学习单个网络的参数,模型复杂度低,加快了算法运行速度以及收敛性,因此将本文算法称为Fast-SelfDeblur.




图2 Fast-SelfDeblur结构示意图

3.2 Fast-SelfDeblur 模型求解

式(5)是关于网络参数 θ 和模糊核 h 的最优化问题.本文采用变量交替的方式求解式(5),即先固定图像生成的网络参数 θ_{k-1} ,求解模糊核 h_k ,再固定模糊核 h_k ,更新图像生成的网络参数 θ_k .

(1) 模糊核估计子问题

对模糊核进行更新,即固定 θ_{k-1} ,估计 h_k ,此时最优问题可以表示为

$$h_k = \arg \min_h \|y - h * f(z; \theta_{k-1})\|_2^2 + \lambda_h \|h\|_2^2 \quad (6)$$

式(6)中使用平方 l_2 范数对 h 进行约束,这是一个凸优化问题,能够直接计算全局极小解,然后对解进行稀疏化处理^[16],以保证运动模糊核的稀疏性.

根据卷积定理,空域中的卷积等效于频域中傅里叶变换的乘积.将式(6)转换在频域求解,以降低计算量.由于离散傅里叶变换固有的周期性假设图像是周期延拓的,周期延拓会造成图像边界具有灰度间断,在频域中表现为高频成分,这将导致复原图像出现吉布斯振荡(Gibbs oscillations),影响图像复原质量.而由于图像一般具有灰度相关性和连续性,除了边缘等细节处,图像的一阶导数为0或接近0,因此本文将数据保真项定义在图像的梯度上,令 $x_{k-1} = f(z; \theta_{k-1})$,式(6)可写为

$$h_k = \arg \min_h \|\nabla y - h * \nabla x_{k-1}\|_2^2 + \lambda_h \|h\|_2^2 \quad (7)$$

其中, $\nabla = [\partial_h, \partial_v]^T$ 为梯度算子, ∂_h 和 ∂_v 分别为图像沿水平方向和垂直方向的偏导数.式(7)是关于 h 的二次函数.求式(7)中目标函数关于 h 的导数并使其为零,可得 h_k 的闭合解为

边缘宽度小于模糊核尺寸时也影响模糊核的估计,筛选有效的显著边缘有助于模糊核的准确估计.本文利用简单的四方向Sobel边缘检测算子,计算水平、垂

直、对角和反对角方向的边缘强度,通过阈值筛选保证各个方向至少有 10% 的最大强度边缘用于估计模糊核.

(2) 图像估计子问题

对清晰图像进行估计,即固定 h_k , 给定 θ_{k-1} , 更新 θ_k , 此时目标函数简化为

$$\theta_k = \arg \min_{\theta} \|y - h_k * f(z; \theta)\|_2^2 \quad (9)$$

Fast-SelfDeblur 使用 DIP-Net 生成清晰图像, 式(9) 中的目标函数即为网络的损失函数:

$$L(\theta) = L(h_k * f(z; \theta); y) = \|y - h_k * f(z; \theta)\|_2^2 \quad (10)$$

式(10) 为均方误差损失函数, 也可以使用其他可微分误差函数作为网络的损失函数. 计算式(10) 的损失函数关于网络参数的梯度, 利用梯度下降法更新 θ_k :

$$\theta_k = \theta_{k-1} - \eta \left. \frac{\partial L(\theta)}{\partial \theta} \right|_{\theta = \theta_{k-1}} \quad (11)$$

其中, η 为学习率.

图 3 给出了图像生成网络参数更新的过程. 在图像估计过程中, 给定输入随机向量 z 和初始网络参数 θ_0 , 图像初始估计 $x_0 = f(z; \theta_0)$. 在第 k 次迭代时, 固定当前更新的模糊核 h_k , 已知上一次迭代的网络参数 θ_{k-1} , 计算损失函数在 $\theta = \theta_{k-1}$ 处的梯度, 利用梯度下降法更新网络参数, 根据当前网络参数 θ_k 即可生成清晰图像 $x_k = f(z; \theta_k)$. 重复上述迭代过程, 直至损失函数收敛或达到最大迭代次数.

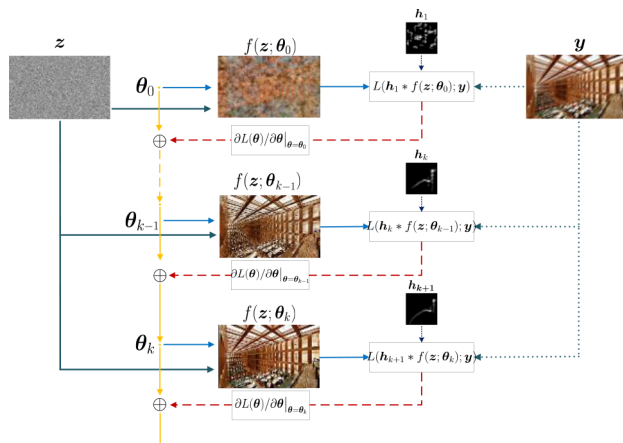


图 3 图像生成网络参数更新过程

3.3 实现细节

本文算法利用 DIP-Net^[13] 生成清晰图像, 根据凸优化问题的极值条件直接求取模糊核正则化问题的闭合解, 通过交替迭代同时估计清晰图像和模糊核. 算法 1 给出了基于深度先验的盲图像去模糊算法的伪代码. 随机初始化 DIP-Net 网络参数 θ_0 , 以随机向量 z 作

为网络输入, 交替迭代更新模糊核和清晰图像. 在模糊核更新阶段, 利用前一次估计的清晰图像 $x_{k-1} = f(z; \theta_{k-1})$, 求解式(8) 更新模糊核 h_k . 在图像更新阶段, 固定模糊核 h_k , 根据式(10) 计算损失函数在前一次网络参数 θ_{k-1} 处的梯度, 使用 Adam 梯度下降法^[35] 更新图像生成网络的参数 θ_k , 从而生成当前估计的清晰图像 $x_k = f(z; \theta_k)$. 重复上述两个阶段, 在每一次迭代中交替更新模糊核与网络参数, 直到算法收敛或达到最大迭代次数.

算法 1 基于深度先验的盲图像去模糊算法

输入: 模糊图像 y

输出: 模糊核 h , 清晰图像 x

参数设置: 学习率 η , 网络输入随机向量 z , 模糊核尺寸 s , 正则化参数 λ_0 , 最大迭代次数 K

初始化网络参数 θ_0 , 清晰图像初始估计 $x_0 = f(z; \theta_0)$

1. For $k = 1$ To K Do

2. 给定 x_{k-1} , 根据式(8), 估计模糊核 h_k

3. 给定模糊核 h_k 和 θ_{k-1} , 计算式(10) 的损失函数关于网络参数的梯度, 利用 Adam 算法^[35] 更新网络参数 θ_k

4. 根据参数 θ_k 生成清晰图像 $x_k = f(z; \theta_k)$

5. End For

6. $x = x_K, h = h_K$

Fast-SelfDeblur 图像生成网络采用 U 型编解码结构的 DIP-Net, 其具体结构如图 4 所示, 编码器包含 5 组卷积和下采样层, 解码器包含 5 组卷积和上采样层, 编码器中每一尺寸的下采样卷积特征均通过跨层连接与解码器中相应尺寸的上采样卷积特征进行融合, 跨层连接的通道数为 16. 网络输入随机向量 z 的尺寸与模糊图像相同, 其通道数一般设置为 8 或 16, 本文设置为 8, 输出图像通道数为 3. SelfDeblur^[12] 将 RGB 通道转换为 YCbCr 颜色表示, 仅亮度分量参与损失函数的计算, 网络输出为单通道的灰度图像, 对其他两个色度分量不做处理, 因此在 RGB 图像合成时易于发生颜色失真以及通道不对齐的问题. 为了提高彩色图像的保真度, 本文算法直接处理彩色图像. 在损失函数中对网络生成图像的 RGB 三个通道分别卷积然后级联, 将其与彩色 RGB 模糊图像的误差反向传播, 使得图像复原结果在三个通道上一致逼近清晰图像, 更好地抑制颜色失真. 图 4 中输入向量尺寸为 $8 \times 271 \times 271$, 其中 8 为通道数, 271×271 为空间尺寸, 各个卷积层特征图尺寸和通道数在图中标出, 从第一组卷积层至第六组卷积层, 特征图尺寸从 271×271 下降至 9×9 , 每一层的特征通道数固定为 128.

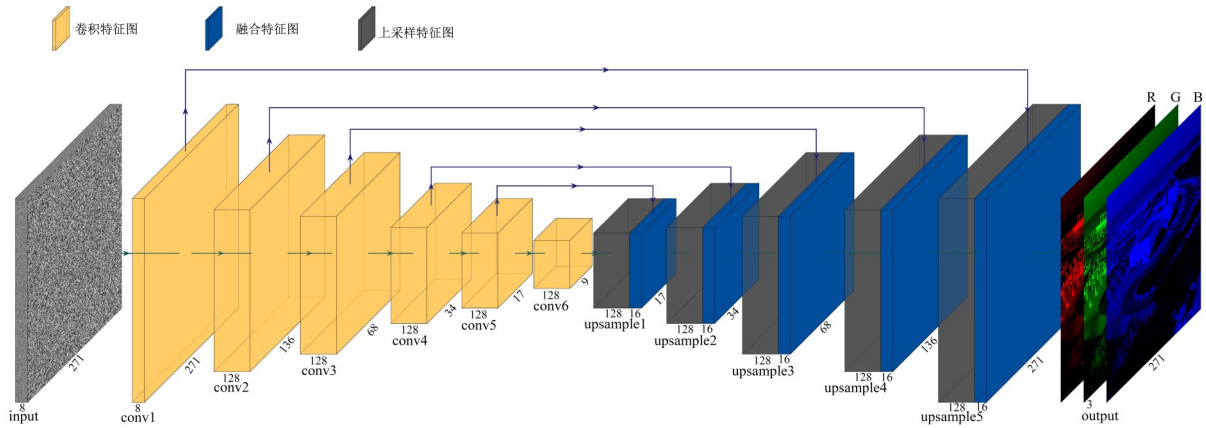


图4 图像生成网络模型

4 实验结果与分析

本文在 Levin^[18], Lai^[36]和 Kohler^[37]数据集上从定量和定性两个方面验证算法的有效性,其中 Lai 数据集包含真实模糊图像和模拟模糊图像.若不做特别说明,实验中设置模糊核正则化参数 λ_h 为 2×10^{-5} ,图像生成网络中输入数据通道数为 8,输出通道数为 3,学习率衰减系数为 0.5.本文模型在开源深度学习框架 PyTorch 实现,使用 Python 语言开发,系统版本为 Ubuntu 18.04.本文的实验在单频为 2.5 GHz、内存为 128 GB 的至强 E5-2678 CPU,显存为 24 GB 的 NVIDIA Geforce RTX 3090 的 GPU 上实现.

4.1 Levin 数据集的实验

Levin 等^[18]将照相机固定在三脚架上,在快门打开期间手动控制照相机在平面上移动,对同一平面上打印的 4 幅图片成像,产生运动模糊图像,然后利用清晰图像与模糊图像估计出模糊核将其作为参考的模糊核真值.由此 Levin 数据集共包括 4 幅清晰图像和 8 个运动模糊轨迹,产生 32 幅模糊图像.本文算法在 Levin 数据集上的实验设置如下:迭代次数为 1 500,学习率 η 的初始值为 0.01,在迭代次数达到 700,900 和 1 300 时衰减为上一次的 1/2.

在 Levin 数据集上将本文算法与 Krishnan 等^[38]、Levin 等^[39]、Cho 和 Lee^[40]、Xu 等^[41]、Sun 等^[42]、Zuo 等^[43]、Pan 等^[26]和 Ren 等^[12]方法进行比较. Krishnan 等^[38]、Levin 等^[39]、Cho 和 Lee^[40]、Xu 等^[41]、Sun 等^[42]、Zuo 等^[43]、Pan 等^[26]方法均为基于统计先验的盲去模糊方法,使用图像金字塔的方式由粗到细地估计模糊核,利用估计的模糊核再结合非盲去模糊算法恢复清晰图像. Ren 等^[12]方法和本文方法直接在原图像尺度估计模糊核,并能够同时估计出模糊核和清晰图像,无需再使用非盲去模糊方法.

本文使用峰值信噪比 (Peak Signal to Noise Ratio, PSNR)、结构相似性 (Structural SIMilarity, SSIM) 以及误

差比 (Error Ratio, ER) 作为定量评价指标. PSNR 是最大图像信号能量与噪声能量的比值,噪声能量用复原图像与真值图像之间均方误差 (Mean-Square Error, MSE) 的度量. SSIM 从均值、标准差和相关系数三个变量度量复原图像与真值图像的相似度,其值域为 [0, 1]. 这两个指标越高,表示复原图像越接近真值图像. ER 是估计模糊核 \hat{h} 以及真值模糊核 h 的复原图像与真值图像误差的比值:

$$ER = \frac{\|x - \hat{x}_h\|_2^2}{\|x - \hat{x}_h\|_2^2} \quad (12)$$

ER 是模糊核评价指标,值越小,估计的模糊核越接近真值模糊核,ER 值最小为 1. 表 1 列出了各种图像去模糊算法在 Levin 数据集上的平均 PSNR, SSIM, ER 和运行时间,其中 Δ 标记了需要结合非盲去模糊算法恢复清晰图像的方法,加粗表示最优结果.从表中可以看出, Fast-SelfDeblur 的平均 PSNR 和 SSIM 均达到最高,平均 ER 更接近 1,且相比于 SelfDeblur^[12]有效降低了算法运行时间.

图 5 和图 6 比较了各种算法在 Levin 数据集中两幅图像的去模糊结果.其中图 5(a) 和图 6(a) 为模糊图

表 1 各种算法在 Levin 数据集上的平均 PSNR, SSIM, ER 和运行时间

方法	PSNR	SSIM	ER	运行时间/s
已知模糊核 h^Δ	34.53	0.949 2	1.000 0	—
Krishnan 等 ^{Δ[38]}	29.88	0.866 6	2.452 3	8.940 0
Cho 和 Lee ^{Δ[40]}	30.57	0.896 6	1.711 3	1.395 1
Levin 等 ^{Δ[18]}	30.80	0.909 2	1.772 4	78.263
Xu 等 ^{Δ[41]}	31.67	0.916 3	1.489 8	1.184 0
Sun 等 ^{Δ[42]}	32.99	0.933 0	1.284 7	191.03
Zuo 等 ^{Δ[43]}	32.66	0.933 2	1.250 0	10.998
Pan 等 ^{Δ[26]}	32.69	0.928 4	1.255 5	295.23
Ren 等 ^[12]	33.07	0.931 3	1.196 8	224.01
本文算法	33.10	0.933 8	1.185 2	73.52

像,图5(b)和图6(b)为真值图像,左上角为真实模糊核,图5(c)~图5(f)和图6(c)~图6(f)分别为 Xu 等^[41]、Sun 等^[42]、Zuo 等^[43]、Pan 等^[26]、Ren 等^[12]方法和本文算法的去模糊结果,左上角为各种算法估计的模糊核,图像下方为局部细节图.从图中可以看出,Xu 等^[41]和 Sun

等^[42]方法复原的图像存在明显的模糊;Zuo 等^[43]和 Pan 等^[26]方法的复原结果趋于平滑,复原图像缺少细节信息;Ren 等^[12]与本文算法复原的清晰图像相比于其他方法有更明显的边缘细节信息,且与 Ren 等^[12]相比,本文算法能够更好地抑制噪声的放大.

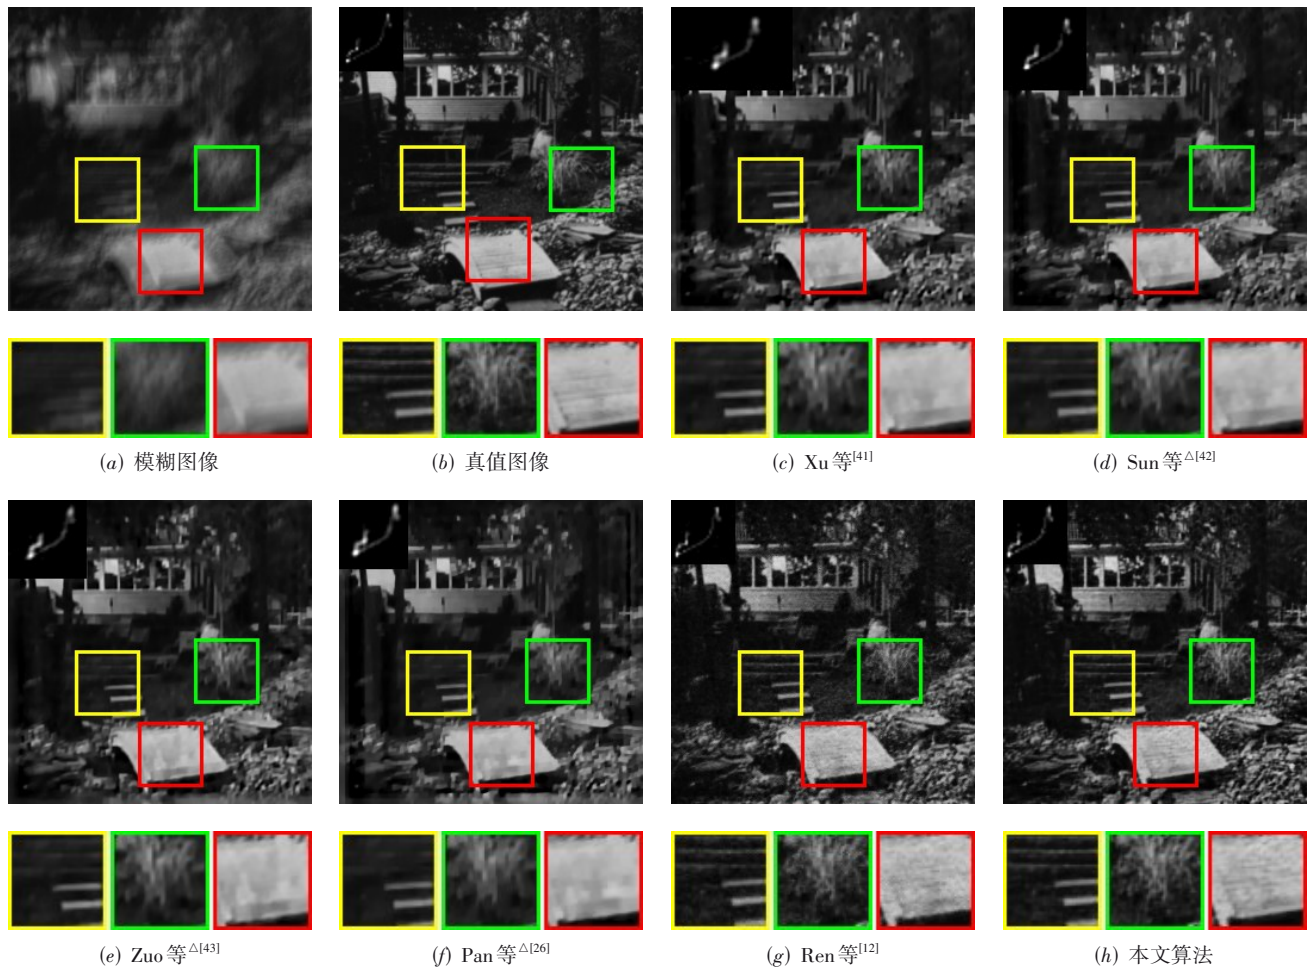


图5 各种算法对Levin数据集中一幅模糊图像的复原结果比较

4.2 Lai 模拟数据集的实验

Lai 数据集^[36]的模拟模糊图像集包含 25 幅清晰图像和 4 个不同尺寸的模糊核,通过清晰图像与模糊核的卷积运算共生成 100 幅模糊图像. Lai 数据集^[36]中的模糊图像包括 Manmade, Natural, People/Face, Saturated 和 Text 五类,每类包含 20 幅模糊图像.本文算法在 Lai 模拟图像数据集上的实验设置如下:迭代次数为 4 000,学习率 η 的初始值为 0.001,每迭代 500 次学习率衰减为之前的一半.在 Lai 模拟图像数据集上将本文算法与 Cho 和 Lee^[40]、Xu 和 Jia^[16]、Xu 等^[41]、Michaeli 等^[22]、Perrone 等^[15]、Pan 等^[26]和 Ren 等^[12]方法进行比较,其中,Cho 和 Lee^[40]、Xu 和 Jia^[16]、Xu 等^[41]、Michaeli 等^[22]、Perrone 等^[15]以及 Pan 等^[26]方法均为基于统计先验的盲去模糊

方法,需要结合非盲图像去模糊方法复原出清晰图像.

表 2 为各种算法在 Lai 数据集中不同类模糊图像上的平均 PSNR 和 SSIM.从表 2 可以看出,本文算法分别在 Manmade, Natural, People/Face, Saturated 以及 Text 这五类上达到最高的平均 PSNR,在 Manmade, Natural, Saturated 和 Text 这四类上达到最高的平均 SSIM,同时在整个数据集上的平均 PSNR 和 SSIM 均达到最高.

图 7 和图 8 比较了各种算法对 Lai 数据集中的两幅模糊图像的复原结果,其中图 7(a)和图 8(a)为模糊图像,图 7(b)和图 8(b)为真值图像,左上角图像为模糊核真值,图 7(c)~(h)和图 8(c)~(h)分别为 Xu 等^[41]、Michaeli 等^[22]、Perrone 等^[15]、Pan 等^[26]、Ren 等^[12]和本文算法的复原结果,左上角为各种算法估计的模糊核,图像

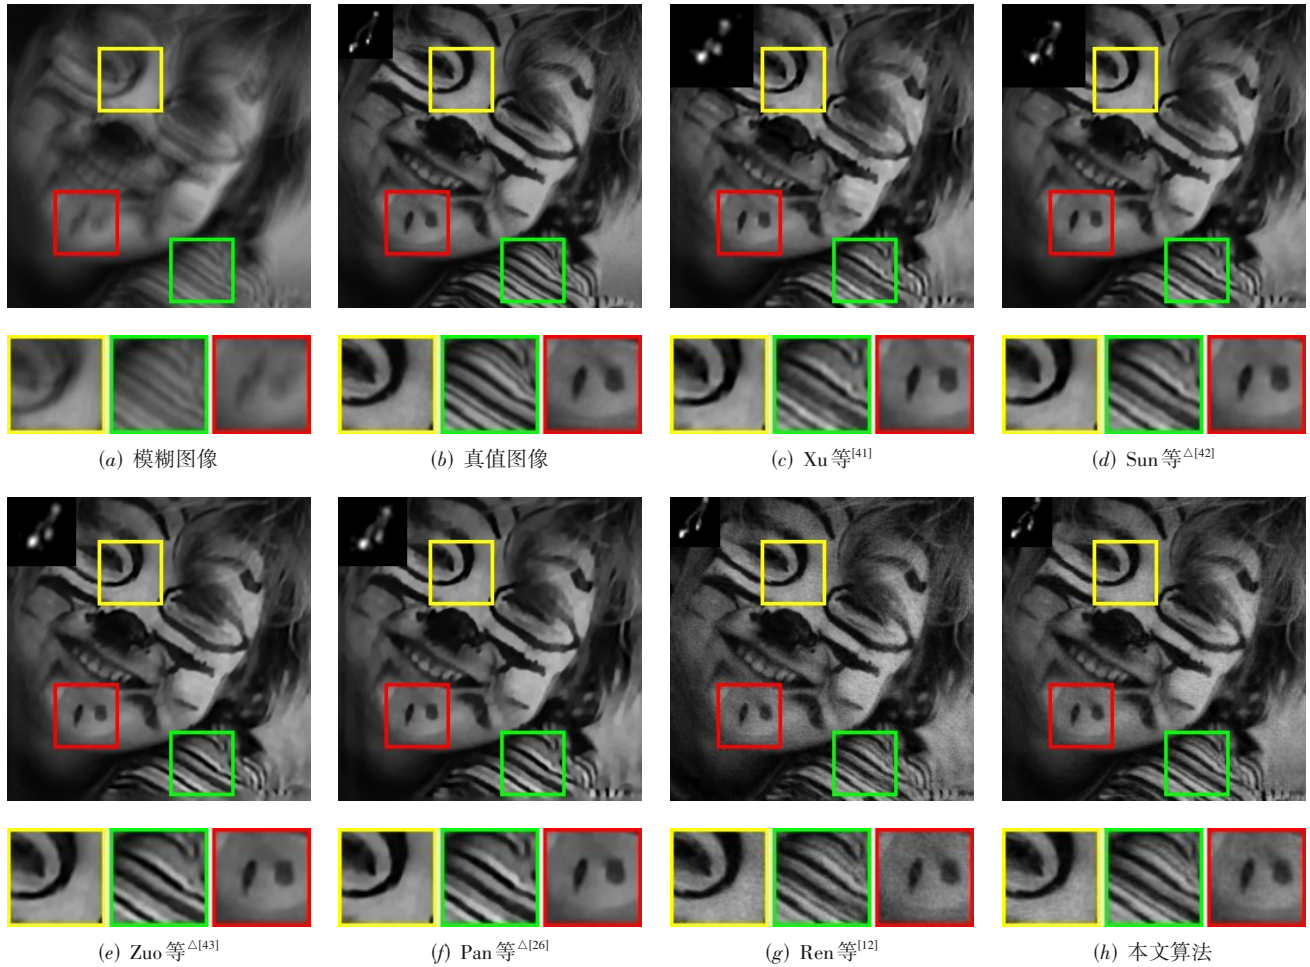


图6 各种算法对 Levin 数据集中另一幅模糊图像的复原结果比较

表2 各种算法在 Lai 数据集上的平均 PSNR 和 SSIM 比较

方法	模糊图像类别					平均值
	人造物 Manmade	自然 Natural	人 People/Face	饱和 Saturated	文字 Text	
Cho 和 Lee 等 ^[40]	16.35/0.389 0	20.14/0.519 8	19.90/0.556 0	14.05/0.492 7	14.87/0.442 9	17.06/0.480 1
Xu 和 Jia ^[16]	19.23/0.654 0	23.03/0.754 2	25.32/0.851 7	14.79/0.563 2	18.56/0.717 1	20.18/0.708 0
Xu 等 ^[41]	17.99/0.598 6	21.58/0.678 8	24.40/0.813 3	14.54/0.538 3	17.64/0.667 7	19.23/0.659 3
Michaeli 等 ^[22]	17.43/0.418 9	20.70/0.511 6	23.35/0.699 9	14.14/0.491 4	16.23/0.468 6	18.37/0.518 1
Perrone 等 ^[15]	17.41/0.550 7	21.04/0.676 4	22.77/0.734 7	14.24/0.510 7	16.94/0.592 7	18.48/0.613 0
Pan 等 ^[26]	18.59/0.594 2	22.60/0.698 4	24.03/0.771 9	16.52/0.632 2	17.42/0.619 3	19.89/0.665 6
Ren 等 ^[12]	20.35/0.754 3	22.05/0.709 2	25.94/0.883 4	16.35/0.636 4	20.16/0.778 5	20.97/0.752 4
本文算法	22.40 /0.860 6	24.04/0.841 7	26.13/0.820 7	18.64/0.725 2	24.17/0.814 1	23.07/0.812 4

下方为局部细节图. 从图中可以看出, Michaeli 等^[22]和 Pan 等^[26]方法由于未准确估计模糊核, 复原结果较差; Xu 等^[41]方法相比于其他基于统计先验的盲图像去模糊方法, 复原结果有更好的视觉效果, 估计出的模糊核也更加准确, 但复原结果仍然过于平滑, 图像细节缺失; Perrone 等^[15]方法复原图像趋于平滑, 且发生颜色失真; SelfDeblur^[12]方法估计出的模糊核过于稀疏, 图像复

原结果严重失真. 与上述方法相比, 本文算法能够准确估计模糊核, 更好地保持复原图像的细节, 复原结果更接近于真值图像.

4.3 Kohler 数据集的实验

Kohler 数据集^[37]是由相机记录的六维自由度运动轨迹合成的非均匀模糊数据集, 包含 4 幅清晰图像和 12 个模糊核, 共 48 幅模糊图像, 通常用于非均匀去模糊方

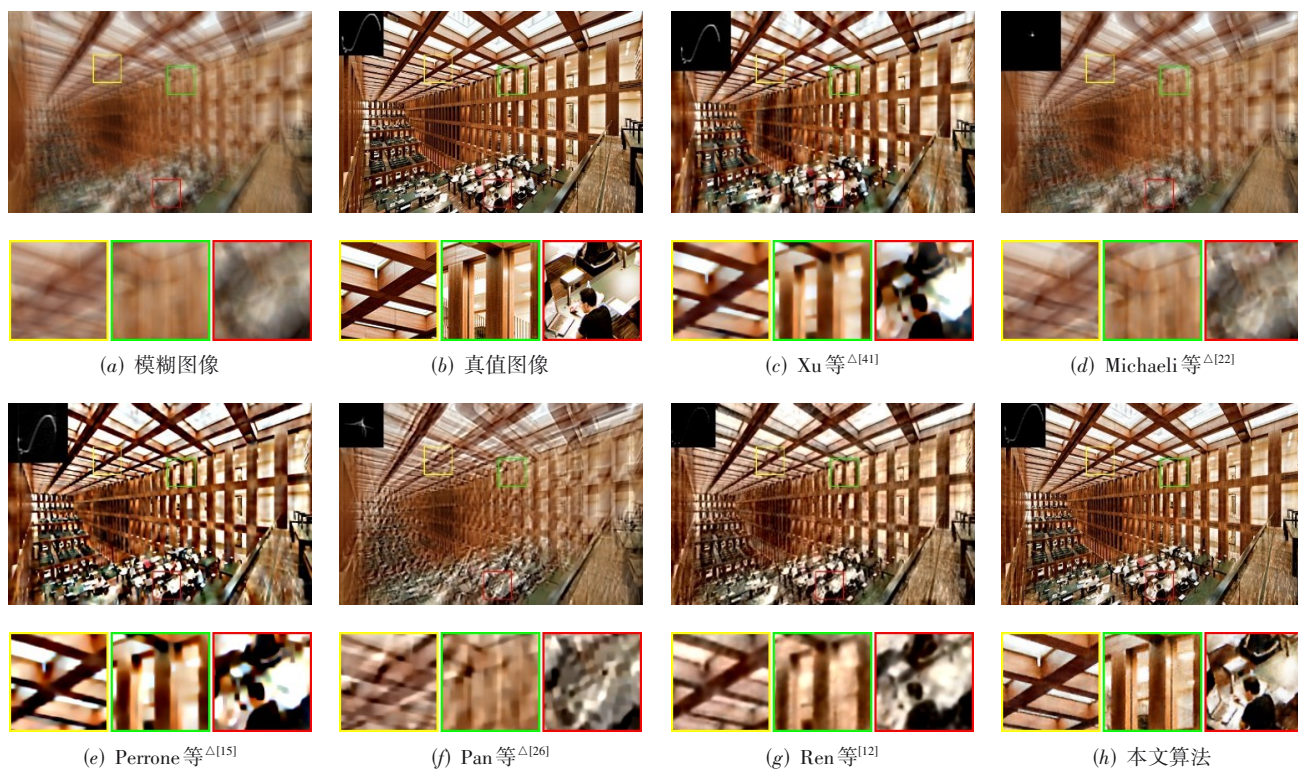


图7 各种算法对Lai数据集中一幅模糊图像的复原结果比较



图8 各种算法对Lai数据集中另一幅模糊图像的复原结果比较

法的评价. 本文算法在 Kohler 数据集上的实验设置如下: 迭代次数为 4 000, 学习率 η 的初始值为 0.01, 每迭代 1 000 次衰减为上一次的 1/2. 在 Kohler 数据集上将本文算法与 Pan 等^[26]、Yan 等^[28]、Chang 等^[44]、Chen 等^[29]、Peng 等^[45] 和 Ren 等^[12] 方法进行比较. Pan 等^[26]、Yan 等^[28]、Chang 等^[44]、Chen 等^[29] 以及 Peng 等^[45] 方法为基于统计先验的盲去模糊方法, 需要结合非盲图像去模糊方法.

图 9 为各种图像去模糊方法在 Kohler 数据集中 4 幅图像的平均 PSNR. 从图 9 可以看出, 本文方法在全部 4 幅图像上的平均 PSNR 高于 Ren 等^[12] 方法的 PSNR, 在前三幅图上的 PSNR 高于 Chang 等^[44] 方法, 与其他方法也具有可比性.

图 10 和图 11 比较了各种算法在 Kohler 数据集中两幅图像的去模糊结果, 其中图 10(a) 和图 11(a) 为模糊图像, 图 10(b) 和图 11(b) 为真值图像, 图 10(c)~(h) 和图 11(c)~(h) 分别为 Pan 等^[26]、Yan 等^[28]、Chang 等^[44]、Peng 等^[45]、Ren 等^[12] 方法和本文方法的复原结果, 左上角为各种算法估计的模糊核, 图像下方为局部




图 9 Kohler 数据集 PSNR 的平均值

细节图. 从图中可以看出, SelfDeblur^[12] 未能准确估计出模糊核, 复原图像严重失真. 本文算法与其他方法的复原结果较为接近, 但 PSNR 值更高, Yan 等^[28] 方法复原的图像存在明显的锐化现象, Chang 等^[44]、Peng 等^[45] 方法复原图像的颜色存在失真.

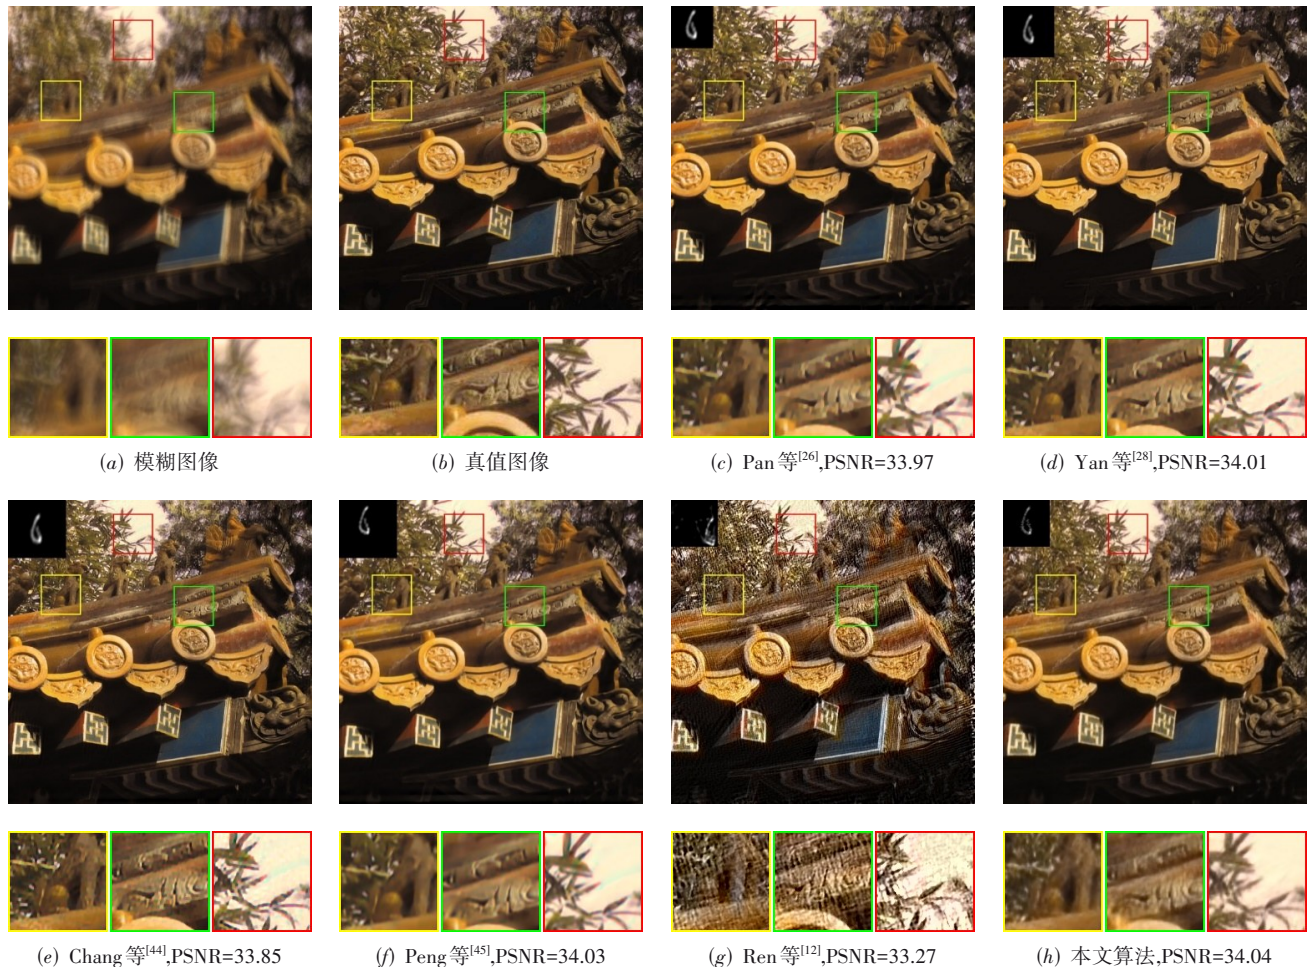


图 10 各种算法对 Kohler 数据集中一幅模糊图像的复原结果比较

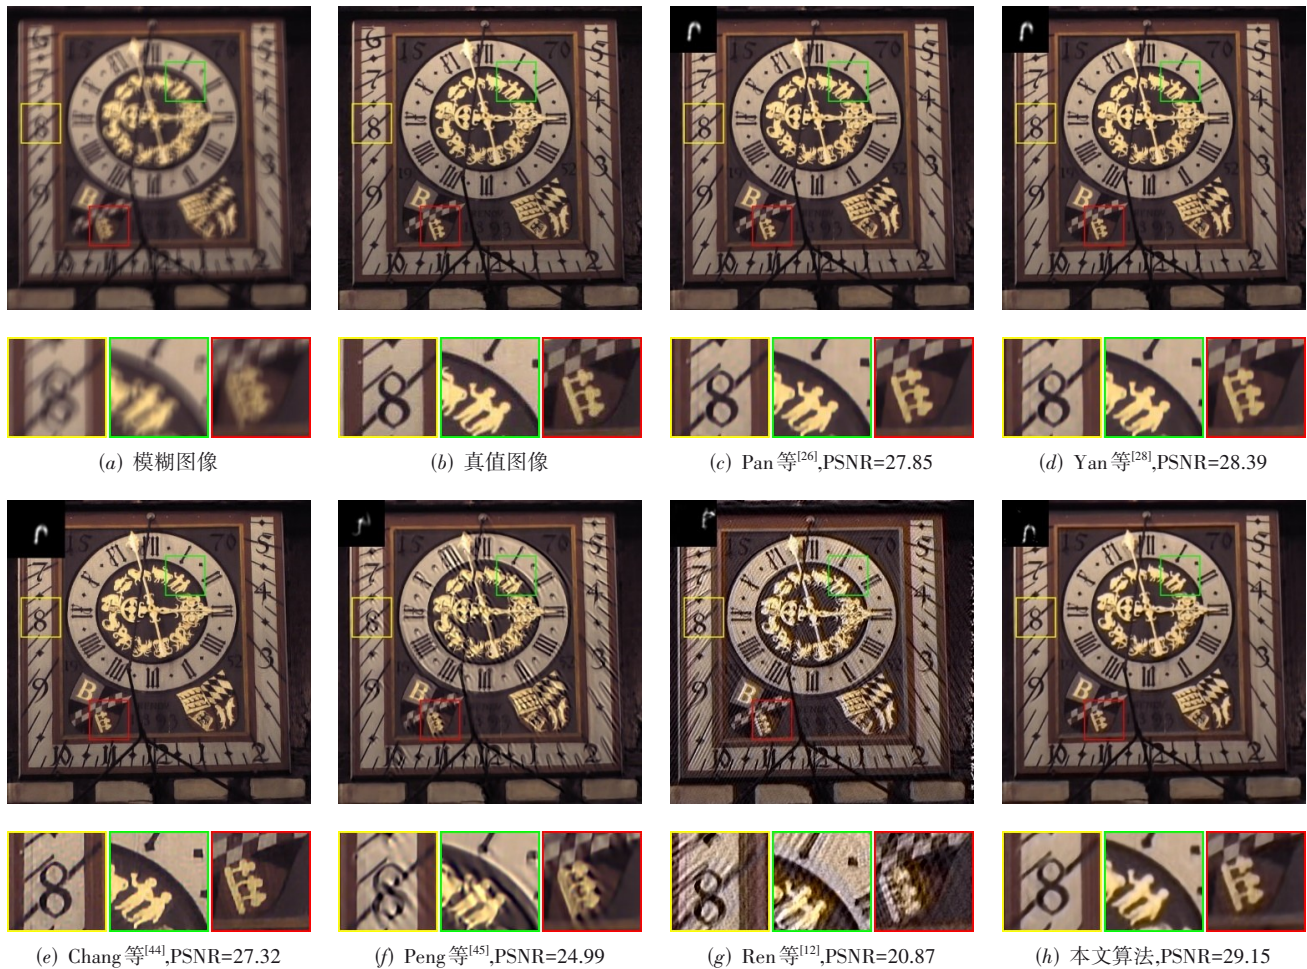


图 11 各种算法对 Kohler 数据集中另一幅模糊图像的复原结果比较

4.4 Lai 真实模糊数据集的实验

本文在 Lai 等^[36]提供的真实模糊图像数据集上验证本文算法对真实模糊图像复原的有效性,该数据集收集了 100 幅真实模糊图像. 本文算法在真实模糊图像上的实验设置如下:迭代次数为 4 000,学习率的初始值为 0.1,每迭代 1 000 次衰减为上一次的 1/2. 在 Lai 真实模糊图像数据集上将本文算法与 Perrone 等^[15]、Pan 等^[26]、Yan 等^[28]、Chang 等^[44]、Chen 等^[29]、Peng 等^[45]和 Ren 等^[12]方法进行比较.

图 12、图 13 和图 14 分别为各种算法在三幅真实模糊图像上的复原结果. 其中图 12~14 的图 (a) 为模糊图像,图 (b)~(h) 分别为 Perrone 等^[15]、Pan 等^[26]、Yan 等^[28]、Chang 等^[44]、Chen 等^[29]、Peng 等^[45]和 Ren 等^[12]方法以及本文方法的复原结果,左上角为各种算法估计的模糊核,图像下方为局部细节图. 可以看出, Perrone 等^[15]和 Ren 等^[12]方法估计出的模糊核较为稀疏,复原结果缺少纹理细节,视觉效果差. 通过观察图 12 可以看出, Perrone 等^[15]、Peng 等^[45]、Ren 等^[12]方法难以准确估计出模糊核,复原图像质量较差, Pan 等^[26]、

Yan 等^[28]、Chang 等^[44]、Chen 等^[29]方法的复原结果存在振荡现象. 与上述方法相比,本文方法能够准确估计模糊核,同时抑制复原图像中的噪声,达到更好的图像复原质量.

5 分析与讨论

本节对 Fast-SelfDeblur 方法的收敛性和噪声鲁棒性进行分析.

5.1 收敛性分析

SelfDeblur^[12]利用全连接网络通过梯度下降法更新模糊核,全连接网络参数量大,参数学习周期长,且将具有空域相关性的二维稀疏模糊核表示为一维向量的形式,需要更多的迭代次数学习模糊核,而 Fast-SelfDeblur 在频域中直接计算模糊核正则化模型的全局极小解,因此本文的 Fast-SelfDeblur 收敛速度更快. Fast-SelfDeblur 使用 DIP-Net 求解图像估计子问题,文献[13]指出网络在学习噪声图像的过程中,首先拟合图像的低频内容,然后是高频细节,当迭代次数达到足够大(约 5×10^4)时,网络才能学习噪声图像,因此

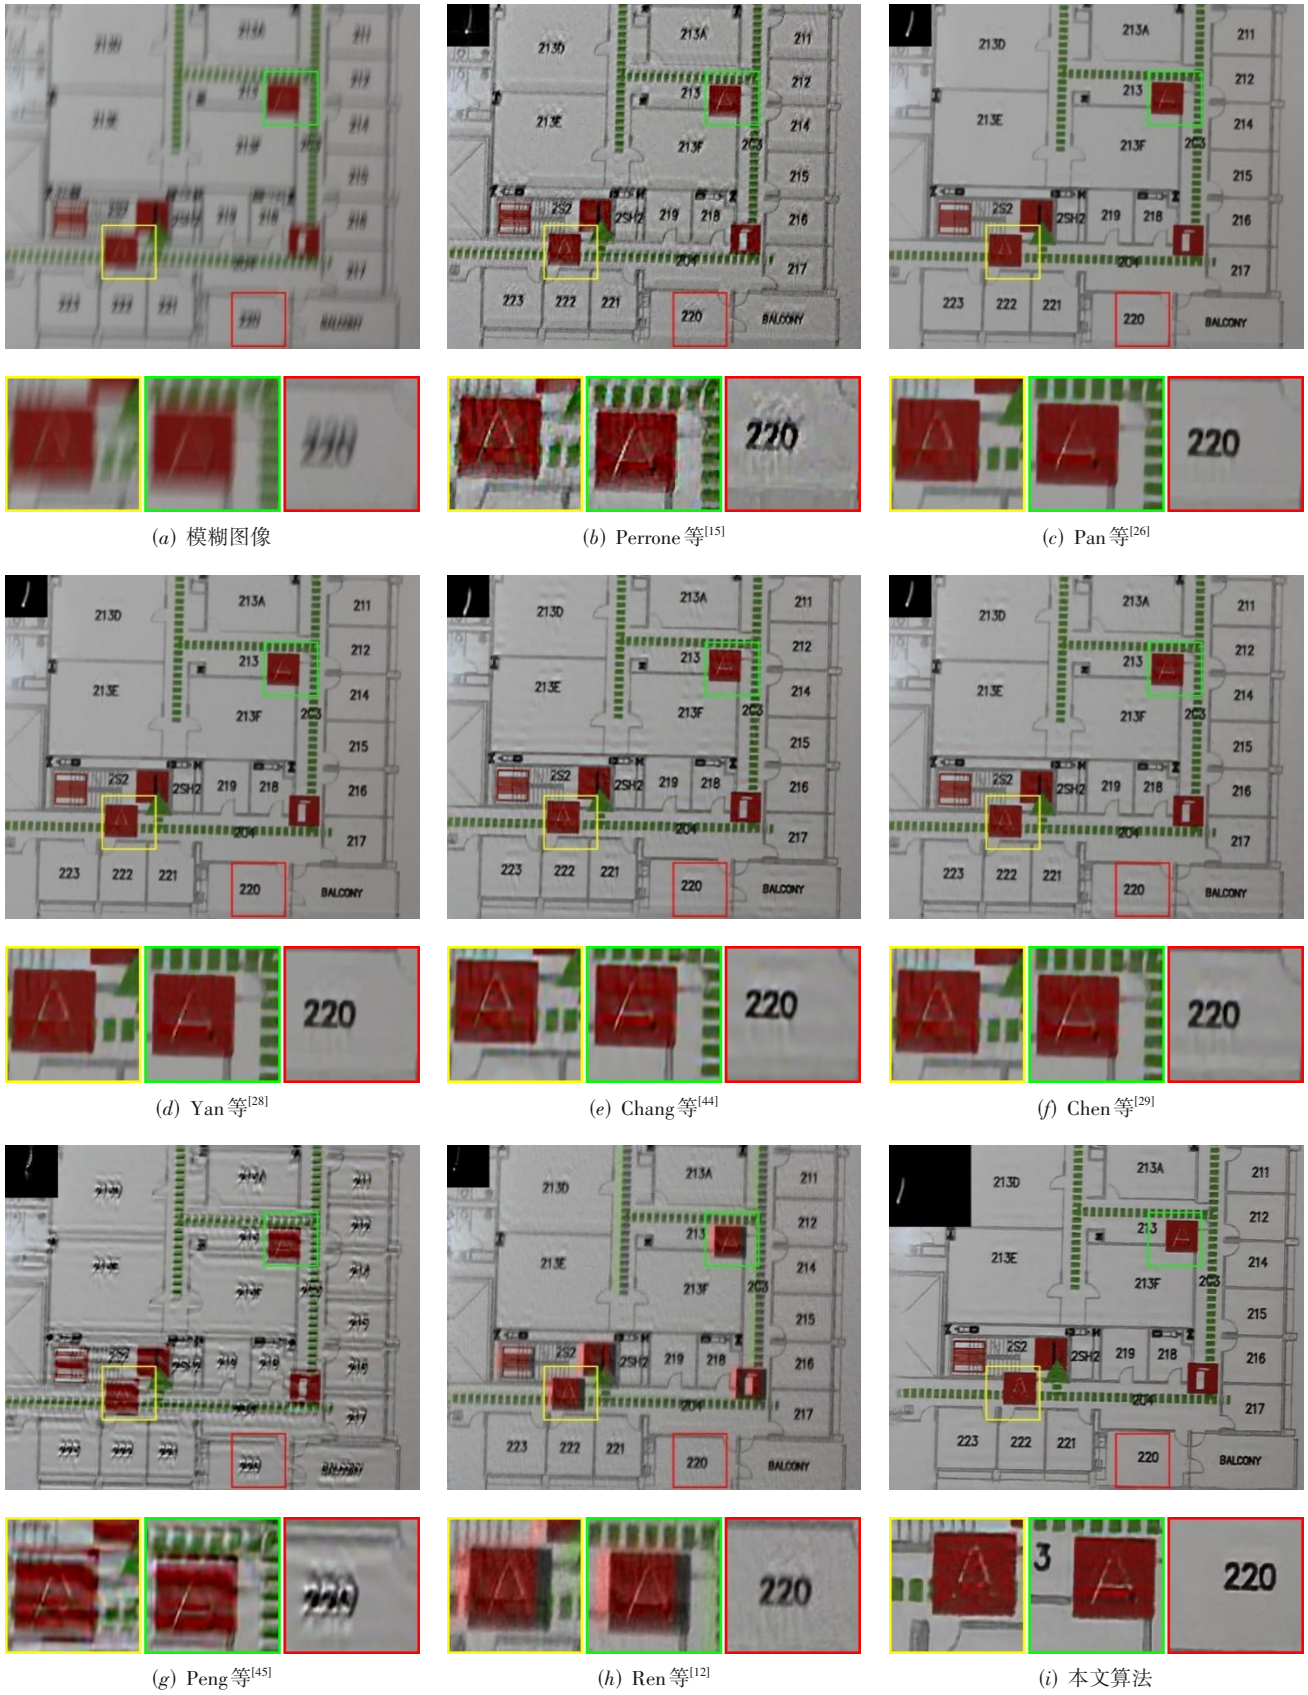


图 12 各种算法在第一幅真实模糊图像上的复原结果比较

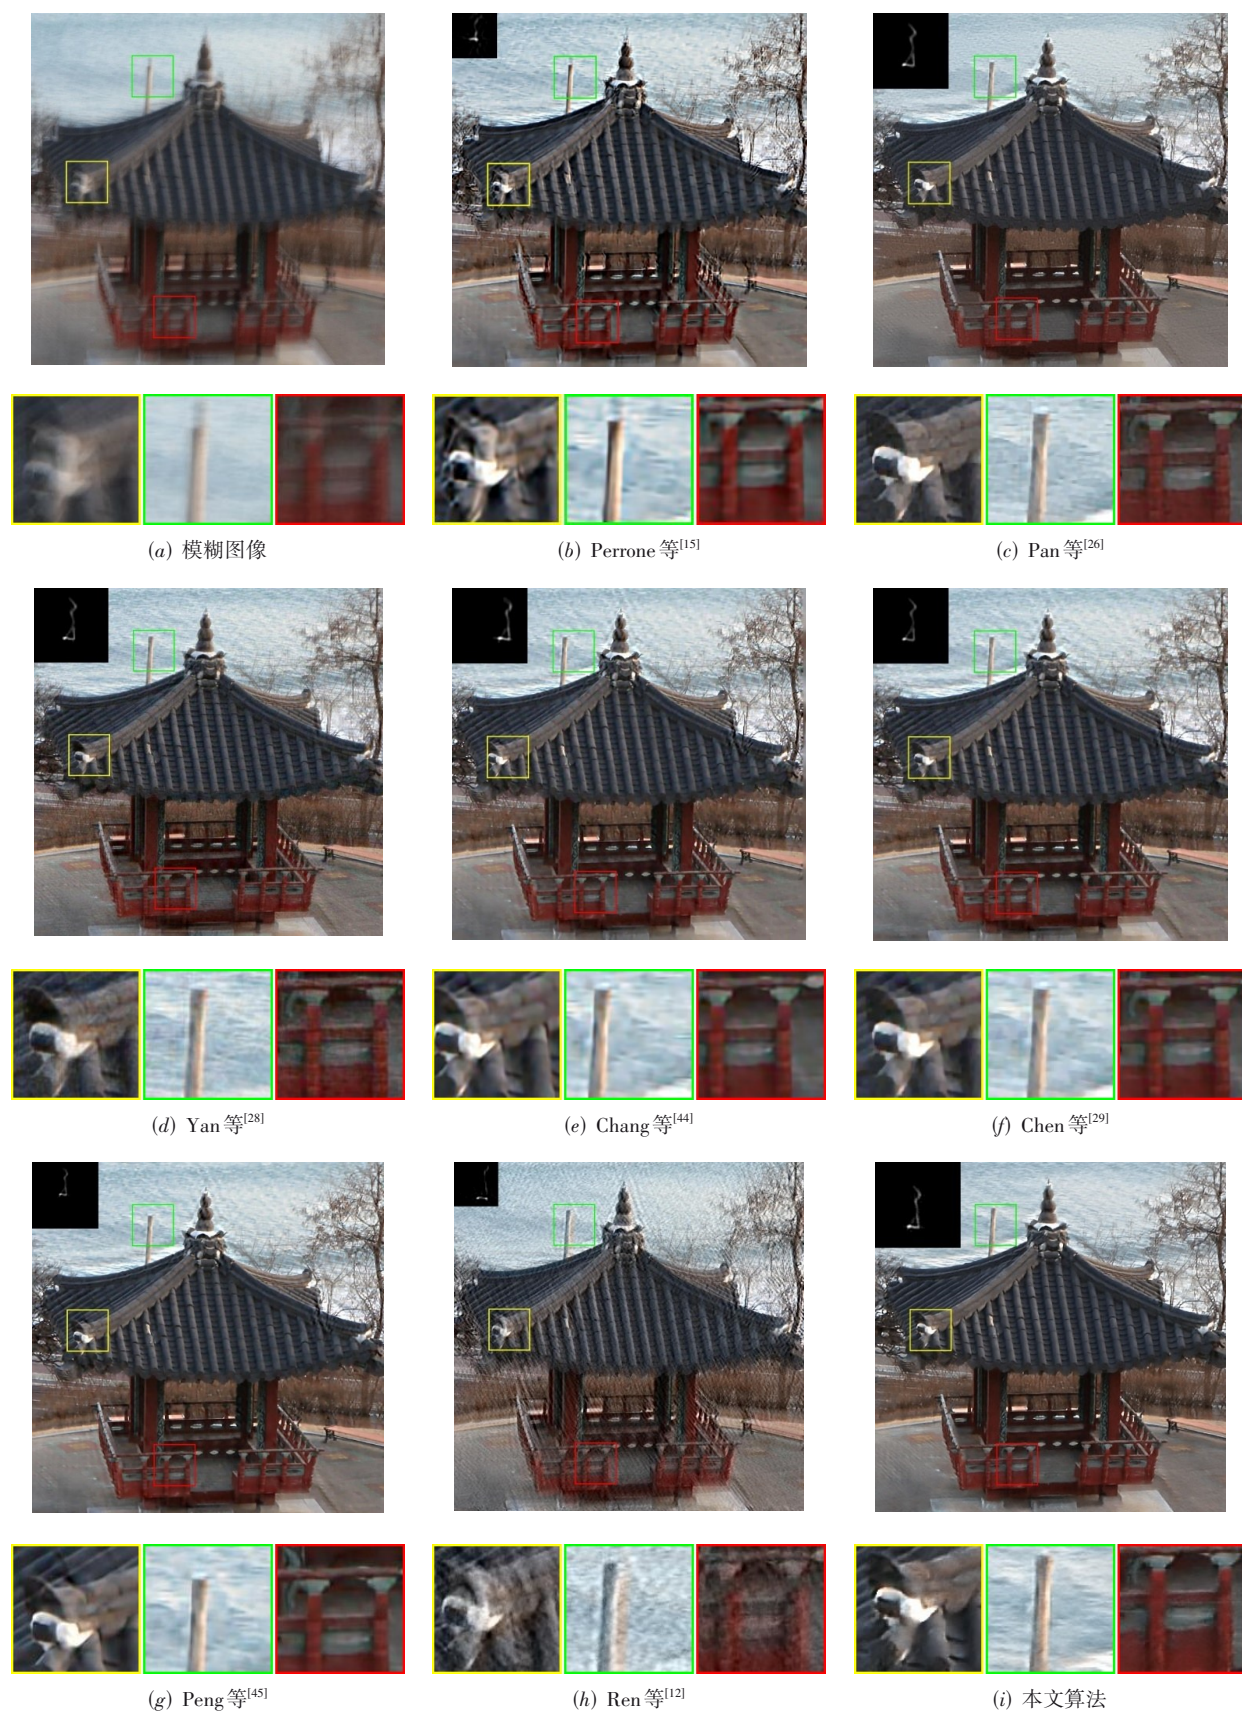


图 13 各种算法在第二幅真实模糊图像上的复原结果比较



图 14 各种算法在第三幅真实模糊图像上的复原结果比较

Fast-Selfdeblur 对迭代次数具有鲁棒性.

图 15 为 SelfDeblur^[12]和 Fast-SelfDeblur 对 Lai 数据集中一幅模糊图像复原的迭代过程,图中横轴为迭代次数,纵轴为损失函数值.网络以模糊图像为监督图

像,随着损失函数的减小,网络达到收敛. SelfDeblur 方法仅对图像中亮度通道进行图像去模糊,模型输出为灰度图像,而本文算法直接对 RGB 三通道图像去模糊,输出结果为彩色图像.从图中可以看出,本文算法在迭

代次数达到700时已经能够复原出清晰图像,损失误差很快减小并收敛,此时SelfDeblur还没有准确地估计模糊核,且复原图像含有噪声. SelfDeblur在第5000次迭代时的PSNR仍低于本文算法在第700次迭代时的PSNR值. 本文算法相比SelfDeblur有更快的收敛速度,且有更高的PSNR.

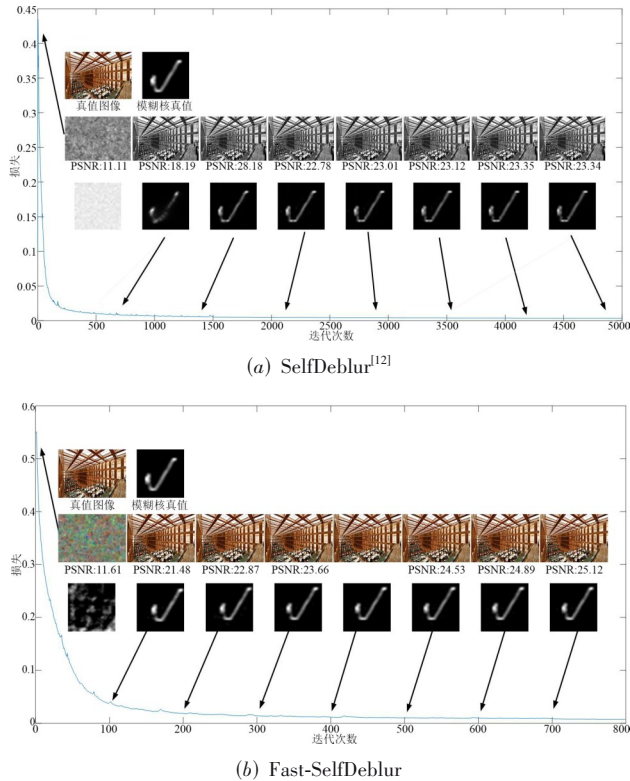



图15 SelfDeblur^[12]和Fast-SelfDeblur在不同迭代次数时估计的模糊核与清晰图像


图16显示了本文算法在Lai数据集中Manmade, Natural, People, Saturated和Text五类图像去模糊的平均PSNR和SSIM与迭代次数之间的关系. 图16的横坐标为迭代次数,图16(a)和图16(b)的纵坐标分别为平均PSNR和平均SSIM. 由图16可见,当Fast-SelfDeblur迭代至1000次后,数据集中各类图像去模糊结果的平均PSNR和SSIM随迭代次数的增加保持平稳,一方面表明本文算法对迭代次数的不敏感性,另一方面进一步验证了Fast-SelfDeblur的收敛性.

5.2 噪声鲁棒性分析

除了网络结构本身可以提供平滑性约束抑制噪声之外, Fast-SelfDeblur通过对输入向量 \mathbf{z} 添加一定程度



(a) 平均PSNR



(b) 平均SSIM

图16 Fast-SelfDeblur在Lai数据集^[36]上的收敛性

的随机扰动 δ ,进一步提升模型对噪声的抑制能力. 本文算法的输入 \mathbf{z} 为区间 $[0, 1]$ 上均匀分布的随机向量,即 $\mathbf{z} \sim U(0, 1)$,对其添加扰动相当于扩大了输入向量的范围,使得网络输入在 \mathbf{z} 的基础上扩展至 \mathbf{z} 及其 δ 邻域,网络的输出结果需要同时满足扰动范围内的多个输入,因此模型的输出结果更加趋于平滑.

图17为对输入向量 \mathbf{z} 加入不同程度扰动的图像复原结果,图17(a)为清晰图像,图17(b)和图17(c)中随机扰动 δ 分别设置为1/1000和1/30,从图中可以看出,当 δ 值较小时,复原的图像具有明显的噪声,当 δ 较大时,复原的图像更加平滑,能够有效抑制噪声. 根据噪声水平设置不同的扰动值,本文中 δ 设置为1/30,抑制复原图像中的噪声,同时避免生成的图像过于平滑.

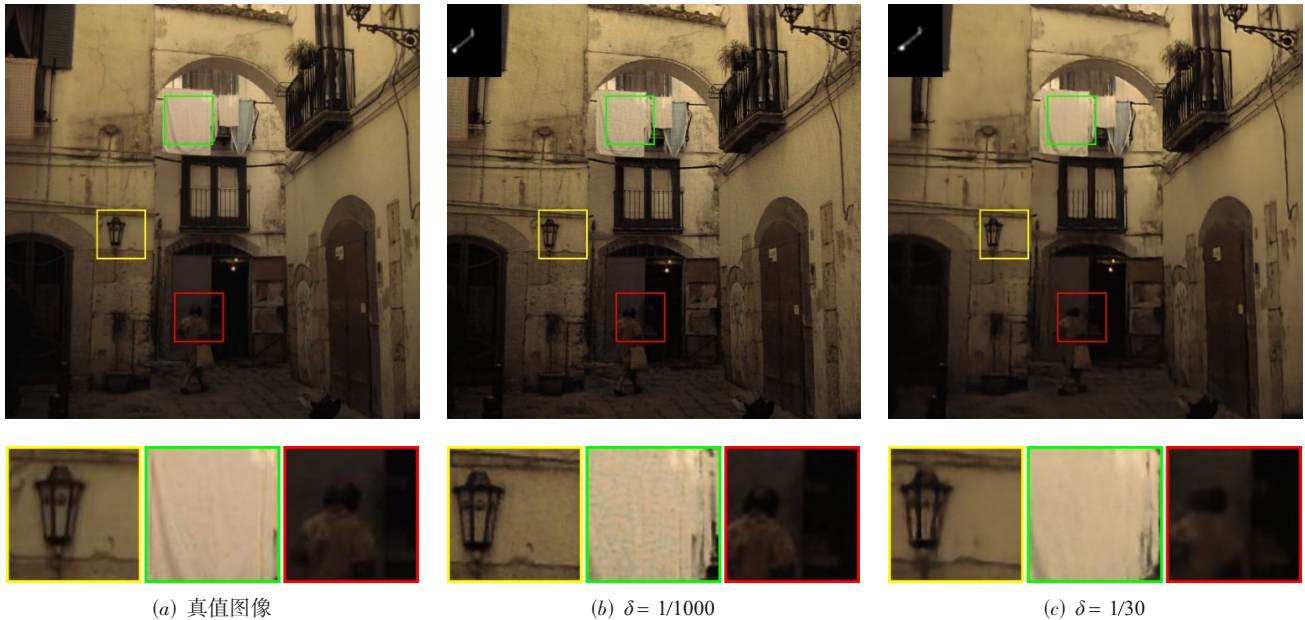


图 17 不同扰动下 Fast-SelfDeblur 生成的图像

6 结论

本文提出了一种基于深度先验的盲图像去模糊算法,联合建模清晰图像与模糊核,采用深度网络与正则化模型相结合的方式同时估计出清晰图像与模糊核.本文算法使用 DIP-Net 估计清晰图像,利用模糊核的正则化模型估计模糊核,通过交替迭代的方式联合估计清晰图像和模糊核.本文算法仅利用模糊图像实现了联合建模的自监督学习盲图像去模糊,无需数据集的训练过程.在模拟数据集和真实数据集上的实验结果表明,本文算法能够准确估计模糊核,恢复清晰图像,并有效抑制复原图像中的噪声.本文算法在无任何外部图像数据集和附加图像先验的情况下,去模糊性能优于多种盲和非盲去模糊算法.在后续的研究中通过设计多尺度的网络结构来进一步提升大模糊图像复原的鲁棒性.本文算法相关内容可参考发明专利[46].

参考文献

- [1] NAH S, KIM T H, LEE K M. Deep multi-scale convolutional neural network for dynamic scene deblurring[C]// Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 257-265.
- [2] SCHULER C J, HIRSCH M, HARMELING S, et al. Learning to deblur[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(7): 1439-1451.
- [3] YAN R M, SHAO L. Blind image blur estimation via deep learning[J]. IEEE Transactions on Image Processing, 2016, 25(4): 1910-1921.
- [4] TAO X, GAO H Y, SHEN X Y, et al. Scale-recurrent network for deep image deblurring[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 8174-8182.
- [5] KUPYN O, BUDZAN V, MYKHAILYCH M, et al. DeblurGAN: Blind motion deblurring using conditional adversarial networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 8183-8192.
- [6] KUPYN O, MARTYNIUK T, WU J R, et al. DeblurGAN-v2: Deblurring (orders-of-magnitude) faster and better[C]// International Conference on Computer Vision. Seoul: IEEE, 2019: 8877-8886.
- [7] ZHANG H G, DAI Y C, LI H D, et al. Deep stacked hierarchical multi-patch network for image deblurring[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 5971-5979.
- [8] SUIN M, PUROHIT K, RAJAGOPALAN A N. Spatially-attentive patch-hierarchical network for adaptive motion deblurring[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 3603-3612.
- [9] YUAN Y, SU W, MA D D. Efficient dynamic scene deblurring using spatially variant deconvolution network with optical flow guided training[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 3552-3561.
- [10] KAUFMAN A, FATTAL R. Deblurring using analysis-

- synthesis networks pair[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 5810-5819.
- [11] LU B Y, CHEN J C, CHELLAPPA R. Unsupervised domain-specific deblurring via disentangled representations [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 10217-10226.
- [12] REN D W, ZHANG K, WANG Q L, et al. Neural blind deconvolution using deep priors[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 3338-3347.
- [13] ULYNOV D, VEDALDI A, LEMPITSKY V. Deep image prior[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 9446-9454.
- [14] CHAN T F, WONG C K. Total variation blind deconvolution[J]. IEEE Transactions on Image Processing, 1998, 7(3): 370-375.
- [15] PERRONE D, FAVARO P. Total variation blind deconvolution: The devil is in the details[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus: IEEE, 2014: 2909-2916.
- [16] XU L, JIA J Y. Two-phase kernel estimation for robust motion deblurring[C]//European Conference on Computer Vision. Berlin: Springer, 2010: 157-170.
- [17] FERGUS R, SINGH B, HERTZMANN A, et al. Removing camera shake from a single photograph[J]. ACM Transactions on Graphics, 2006, 25(3): 787-794.
- [18] LEVIN A, WEISS Y, DURAND F, et al. Understanding and evaluating blind deconvolution algorithms[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami: IEEE, 2009: 1964-1971.
- [19] SHAN Q, JIA J Y, AGARWALA A. High-quality motion deblurring from a single image[J]. ACM Transactions on Graphics, 2008, 27(3): 15-19.
- [20] 方帅, 刘远东, 曹洋, 等. 基于模糊结构图的模糊核估计[J]. 电子学报, 2017, 45(5): 1226-1233.
FANG S, LIU Y D, CAO Y, et al. Blur kernel estimation using blurry structure[J]. Acta Electronica Sinica, 2017, 45(5): 1226-1233. (in Chinese)
- [21] 余义斌, 彭念, 甘俊英. 凹凸范数比值正则化的快速图像盲去模糊[J]. 电子学报, 2016, 44(5): 1168-1173.
YU Y B, PENG N, GAN J Y. Fast blind image deblurring using ratio of concave norm to convex norm regularization[J]. Acta Electronica Sinica, 2016, 44(5): 1168-1173. (in Chinese)
- [22] MICHAELI T, IRANI M. Blind deblurring using internal patch recurrence[C]//European Conference on Computer Vision. Zurich: Springer, 2014: 783-798.
- [23] ZHANG H C, YANG J C, ZHANG Y N, et al. Close the loop: Joint blind image restoration and recognition with sparse representation prior[C]//International Conference on Computer Vision. Barcelona: IEEE, 2011: 770-777.
- [24] 徐焕宇, 孙权森, 李大禹, 等. 基于投影的稀疏表示与非局部正则化图像复原方法[J]. 电子学报, 2014, 42(7): 1299-1304.
XU H Y, SUN Q S, LI D Y, et al. Projection-based image restoration via sparse representation and nonlocal regularization[J]. Acta Electronica Sinica, 2014, 42(7): 1299-1304. (in Chinese)
- [25] REN W Q, CAO X C, PAN J S, et al. Image deblurring via enhanced low-rank prior[J]. IEEE Transactions on Image Processing, 2016, 25(7): 3426-3437.
- [26] PAN J S, SUN D Q, PFISTER H, et al. Deblurring images via dark channel prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(10): 2315-2328.
- [27] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(12): 2341-2353.
- [28] YAN Y Y, REN W Q, GUO Y F, et al. Image deblurring via extreme channels prior[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 6978-6986.
- [29] CHEN L, FANG F M, WANG T T, et al. Blind image deblurring with local maximum gradient prior[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 1742-1750.
- [30] ZHANG K, ZUO W M, GU S H, et al. IRCNN: Learning deep CNN denoiser prior for image restoration[C]//Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 2808-2817.
- [31] LI L, PAN J S, LAI W S, et al. Learning a discriminative prior for blind image deblurring[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 6616-6625.
- [32] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin: Spring-


er, 2015: 234-241.

- [33] MATAEV G, MILANFAR P, ELAD M. DeepRED: Deep image prior powered by red[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 1-10.
- [34] WANG J Y, CHEN Y B, CHAKRABORTY R, et al. Orthogonal convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 11502-11512.
- [35] Kingma D P, Ba L J. Adam: A method for stochastic optimization[C]//International Conference on Learning Representation. San Diego: IEEE, 2015: 1-13.
- [36] LAI W S, HUANG J B, HU Z, et al. A comparative study for single image blind deblurring[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 1701-1709.
- [37] KOHLER R, HIRSCH M, MOHLER B, et al. Recording and playback of camera shake: Benchmarking blind deconvolution with a real-world database[C]//European Conference on Computer Vision. Berlin: Springer, 2012: 27-40.
- [38] KRISHNAN D, TAY T, FERGUS R. Blind deconvolution using a normalized sparsity measure[C]//Computer Vision and Pattern Recognition. Colorado Springs: IEEE, 2011: 233-240.
- [39] LEVIN A, WEISS Y, DURAND F, et al. Efficient marginal likelihood optimization in blind deconvolution[C]//Computer Vision and Pattern Recognition. Providence: IEEE, 2011: 2657-2664.
- [40] CHO S, LEE S. Fast motion deblurring[J]. ACM Transactions on Graphics, 2009, 28(5): 1-8.
- [41] XU L, ZHENG S C, JIA J. Unnatural l0 sparse representation for natural image deblurring[C]//Computer Vision and Pattern Recognition. Portland: IEEE, 2013: 1107-1114.
- [42] SUN L B, CHO S, WANG J, et al. Edge-based blur kernel estimation using patch priors[C]//International Conference on Computational Photography. Cambridge: IEEE, 2013: 1-8.
- [43] ZUO W M, REN D W, ZHANG D, et al. Learning iteration-wise generalized shrinkage-thresholding operators for blind deconvolution[J]. IEEE Transactions on Image Processing, 2016, 25(4): 1751-1764.
- [44] 常振春, 禹晶, 肖创柏, 等. 基于稀疏表示和结构自相似性的单幅图像盲解卷积算法[J]. 自动化学报, 2017, 43(11): 1908-1919.

CHANG Z C, YU J, XIAO C B, et al. Single image blind deconvolution using sparse representation and structural self-similarity[J]. Acta Automatica Sinica, 2017, 43(11): 1908-1919. (in Chinese)

- [45] 彭天奇, 禹晶, 肖创柏. 基于跨尺度低秩约束的图像盲解卷积算法[J]. 自动化学报, 2022, 48(10): 2508-2525.
- PENG T Q, YU J, XIAO C B. Blind image deconvolution via cross-scale low rank prior[J]. Acta Automatica Sinica, 2022, 48(10): 2508-2525. (in Chinese)
- [46] 肖创柏, 王晓宁, 郭乐宁, 等. 一种基于深度先验的盲图像去模糊方法: CN202210052867.6[P]. 2022-04-29.

作者简介



白勇强 男, 1995年1月出生于河南洛阳. 北京工业大学计算机科学与技术工学硕士. 主要研究方向为图像复原.
E-mail: sunskybai@gmail.com



禹晶 女, 1981年12月出生于陕西延安. 2011年获清华大学电子工程系博士学位. 北京工业大学信息学部计算机学院副教授、硕士生导师. 主要研究方向为图像处理与机器学习.
E-mail: jing.yu@bjut.edu.cn



李一稔 女, 1995年3月出生于辽宁沈阳. 北京工业大学信息学部计算机学院博士研究生. 主要研究方向为图像超分辨率重建.
E-mail: liyinong@emails.bjut.edu.cn



肖创柏(通讯作者) 男, 1962年2月出生于湖南临湘. 北京工业大学信息学部计算机学院教授. 主要研究方向为数字信号处理、音频信号处理与网络通信. 中国电子学会会员编号: E190002739S.
E-mail: cbxiao@bjut.edu.cn